Universidad de San Andrés

Escuela de Negocios

Maestría en Gestión de Servicios Tecnológicos y de Telecomunicaciones

Promesas de la Inteligencia Artificial y el Aprendizaje Automático para la Banca Tradicional Privada.
Un análisis de oportunidades, aplicaciones, barreras y riesgos.

Autor: Natalia Nocetti

DNI: 25.360.350

Director de Tesis: Dr. Alejandro Prince

Buenos Aires, 3 de julio de 2019

Dedicatoria

QUAERERE VERUM
Universidad de
SanAndrés

A mis abuelas Mercedes y Enriqueta.

Agradecimientos

Esta tesis es el resultado final de mucho trabajo y del apoyo incondicional de muchas personas durante 2 años y medio a quienes quisiera agradecer.

En primer lugar, quiero agradecer al Director de la Maestría, el Ing. Enrique Hofman y a toda la institución por haber hecho posible que pueda cursar esta maestría gracias a la beca completa otorgada.

A mi tutor, el Dr. Alejandro Prince, sin el cual este trabajo hubiera sido inalcanzable, por todos sus consejos y su guía en el armado de la estrategia y ejecución de la tesis.

A todos mis profesores y compañeros de la maestría, ya que fue un placer transitar con ellos este desafío. Especialmente quisiera agradecer al "Team Uber" con el que compartimos tantos sábados camino al campus.

A las "Super Híper Poderosas", compañeras de trabajos durante el último año de maestría, mujeres excepcionales con las que aprendí y aprendo cada vez que compartimos un momento.

A Moni y a Peter, "mis compañeros de tesis" en estos meses de camino incansable con la brújula apuntando a concluir nuestros trabajos. Gracias por compartir su conocimiento en forma tan generosa y con tanto desinterés y gracias por la compañía, el apoyo y el empuje.

A mi equipo del Santander con el que comparto largas horas de jornadas laborales, por su calidad humana y profesional, de los que no dejo de aprender cada día.

A mis amigas, en el lugar del mundo en el que se encuentren, que siempre me apoyan en todos mis proyectos, aunque signifiquen ausencias, siempre están junto a mí.

A mi madre, que siempre me ha dejado ser.

Y a mi compañero en esta etapa de mi vida, Sergio, que estoicamente me ha acompañado todos los días durante estos dos años y medio, facilitándome la cotidianeidad para poder alcanzar esta meta, siempre dándome fuerzas en momentos de desasosiego. Gracias por toda su paciencia, comprensión y ayuda.

A todos los que me han acompañado durante esta etapa de muchos sacrificios para llegar a este objetivo, a todos los que me alentaron y creyeron en mí, sin su apoyo esto no sería posible. Muchas gracias.

Resumen Ejecutivo

El objetivo fundamental de este trabajo de tesis está orientado a identificar si las soluciones de aprendizaje automático pueden otorgarle a la banca tradicional privada ventajas competitivas que le sirvan de oportunidad para acelerar su ritmo de innovación y enfrentar el entorno de disrupción del sistema financiero. Estos incumbentes deben afrontar el imparable avance tecnológico que marca un nuevo entorno de relación con los clientes, así como también la entrada de nuevos competidores que desafían su negocio. Por otro lado, la inteligencia artificial y el aprendizaje automático están siendo impulsados por la convergencia y los avances en tecnologías como el *Big Data*, el *Cloud Computing* o el *Internet of Things* y permitirían gestionar la gran cantidad de información a la que se tiene acceso y elevar la calidad de atención a los clientes a un nivel más personalizado que constituye el gran desafío de los bancos tradicionales.

Esta tesis se ha desarrollado de acuerdo a las pautas del paradigma cualitativo y un tipo de investigación descriptiva que permitió analizar la situación actual para identificar el grado de adopción de estas tecnologías por parte de los bancos tradicionales privados y su perspectiva a futuro. Se utilizó un proceso exhaustivo de compilación y análisis de información, así como también, se analizaron casos de éxito para tratar de identificar patrones de buenas prácticas. El foco del trabajo de campo fue la realización de entrevistas con expertos cuyas opiniones y respuestas juegan un rol central en esta tesis.

Para la banca tradicional privada, los modelos de aprendizaje automático podrían ser utilizados en diferentes áreas y actividades, permitirían la optimización de procesos, la mejora en la calidad de los productos y servicios, la creación de nuevos y la personalización, de manera de reducir costos, aumentar la productividad y mejorar los ingresos. No obstante, existen barreras, desafíos y riesgos que los bancos tradicionales privados deben atacar para poder incorporar estas soluciones.

Palabras Clave: transformación digital en banca, Inteligencia Artificial en Banca, Aprendizaje Automático, Machine Learning en Bancos, Colaboración Fintech y Bancos

Tabla de contenido

Dedicatoria ii
Agradecimientos iii
Resumen Ejecutivo iv
Tabla de contenido v
Lista de Figuras x
Lista de Tablas xii
1. Capítulo I. Introducción 1
1.1. Preguntas de Investigación 3
1.2. Objetivos 4
1.3. Alcance 4
1.4. Metodología de investigación 5
1.4.1. Paradigma 5
1.4.2. Tipo de Investigación 6
1.4.3. Instrumentos 6
1.5. Estructura de la Tesis 13
2. Capítulo II. Conceptos principales en la Transformación Organizacional 15
2.1. Innovación, tecnologías y empresas 15
2.2. La Cultura Organizacional, factor primordial en la innovación 22
2.3. El Liderazgo como facilitador del cambio 25
3. Capítulo III. Entendiendo la Inteligencia Artificial y el Aprendizaje Automático 29
3.1. Conceptualización de Inteligencia Artificial 29
3.2. Florecimiento de la Inteligencia Artificial ¿Por qué ahora? 30
3.3. La inteligencia artificial actual: el Aprendizaje Automático 32
3.4. Perspectivas de la Adopción de Inteligencia Artificial y Aprendizaje Automático en la actualidad 35
4. Capítulo IV. La Banca y la transformación digital 38
4.1. Impacto de la disrupción en el Sistema Financiero 38
4.2. El nuevo consumidor de servicios financieros 40
4.3. Retos competitivos de incumbentes de servicios financieros 42
4.4. La colaboración como estrategia de los Bancos tradicionales frente a la disrupción 46

5. Capítulo V. La Inteligencia Artificial y el Aprendizaje Automático como herramientas de los Bancos Tradicionales Privados para enfrentar la disrupción 49
5.1. Promesas de la Inteligencia Artificial y el Aprendizaje Automático 49
5.2. Aplicaciones de Aprendizaje Automático en la Banca (Casos de Uso) 53
5.2.1. Calificación Crediticia 55
5.2.2. Asesoramiento y Planificación 57
5.2.3. Customer Insights y Personalización 58
5.2.4. Asistentes virtuales orientados a clientes 60
5.2.5. Detección de Fraude 61
5.2.6. Otras aplicaciones 61
6. Capítulo VI. Factores que actúan como Barreras, Desafíos o Riesgos para la Adopción de Aprendizaje Automático en la Banca 63
6.1. Principales obstáculos 63
6.2. Gestión de Datos: la clave de los algoritmos de Aprendizaje Automático 65
6.2.1. Propiedad y Protección de Datos 66
6.2.2. Opacidad de Datos 67
6.2.3. Sesgos o Discriminación algorítmica 68
6.2.4. Infraestructura de datos 69
6.3. El Capital humano 70
6.4. El marco regulatorio 72
6.5. Otros Desafíos y Riesgos 76
7. Capítulo VII. Estudio de Casos 78
7.1. Visión Banco y su ML Journey 78
7.2. Danske Bank y una solución de aprendizaje profundo para la detección de fraude en tiempo real 80
7.3. DBS Bank y la reposición de cajeros automáticos 83
7.4. Banco Superville Argentina y la optimización de Remesas en la Gestión de Efectivo 84
7.5. Seacost Bank y el aprendizaje automático para mejorar la experiencia del cliente 85
7.6. Principales aspectos relevados en los casos de estudio 87
8. Capítulo VIII. Trabajo de Campo - Análisis Cualitativo de las Entrevistas 89
8.1. Situación Actual de los Bancos - Impacto de la Disrupción 89

8.2. Promesas y Oportunidades 92
8.3. Aplicaciones 97
8.4. Barreras y Desafíos 101
8.4.1. Cultura Organizacional y Liderazgo 102
8.4.2. Gestión de los Datos 105
8.4.3. Sistemas Legacy 107
8.4.4. Marco Regulatorio 108
8.4.5. Talento y Capital Humano 109
8.4.6. Otras Barreras 110
8.5. Riesgos 111
8.6. Perspectivas sobre la Adopción 115
9. Capitulo IX. Conclusiones 118
9.1. Panorama de la situación actual del AA 118
9.2. Panorama de la situación actual de los Bancos Tradicionales Privados 119
9.3. Argumentación de las preguntas de investigación 120
9.3.1. Promesas y oportunidades de la IA y el AA para mejorar la competitividad de los bancos tradicionales privados y sus aportes para transformar la industria 121
9.3.2. Actividades que las soluciones de AA representan para la banca tradicional privada. 121
9.3.3. Principales barreras y desafíos con las que se enfrentan los Bancos tradicionales privados en su camino a la adopción de estas soluciones 122
9.3.4. Algunas reflexiones y recomendaciones 125
9.3.5. El Aprendizaje Automático como oportunidad para los bancos tradicionales privados para hacer frente a la disrupción del sistema financiero 127
9.4. Una Visión de Futuro para la inteligencia artificial y el aprendizaje automático en los Bancos tradicionales privados 128
9.5. Futuras investigaciones 130
Lista de Referencias 131
Anexos 152
Anexo I. Proveedores de soluciones 152
Anexo II. Detalle Referencias Entrevistados 155

Anexo III. Preguntas Entrevistas para análisis de Campo 167
Anexo IV. Proceso de Innovación Disruptiva 168
Anexo V. Adopción de innovaciones 169
Anexo VI. Tecnologías de Avanzada y su convergencia. La IA en el centro de la interrelación 185
Anexo VII. Definiciones de IA 191
Anexo VIII. Resumen de la Historia de la IA 193
Anexo IX. Tipos de Aprendizajes Automáticos 199
Anexo X. Índice de Digitalización y Adopción de IA (McKinsey) 203
Anexo XI. Hype Cycle de Inteligencia Artificial 2018 (Gartner) 204
Anexo XII. Amplitud y Frecuencia de Casos de Uso de Aprendizaje Automático por sector) 205
Anexo XIII. Inversiones en Inteligencia Artificial y Aprendizaje Automático 206
Anexo XIV. Uso de Canales transaccionales de los Bancos en EE. UU. 207
Anexo XV. Uso de Canales transaccionales de los Bancos en América Latina 208
Anexo XVI. Madurez Digital de los Bancos en América Latina 209
Anexo XVII. Productos y Servicios bancarios que podrían desaparecer en los próximos 15 a 20 años. 211
Anexo XVIII. Uso de la tecnología y su impacto en paradigmas de la banca tradicional, algunos datos 212
Anexo XIX. Tipos de consumidores (Accenture) 213
Anexo XX. Panorama del ROE luego de la Crisis de 2008 217
Anexo XXI. Preocupación de los Bancos sobre la Amenaza Fintech 218
Anexo XXII. Crecimiento Fintech 220
Anexo XXIII. Ejemplos de Mercados con gran presencia Fintech: Caso China, Bangladesh, India y Kenia 222
Anexo XXIV. Aceleración de adopción de smartphones en América Latina 223
Anexo XXV. Fortalezas de Fintech y de Bancos tradicionales 224
Anexo XXVI. Tendencia asociación de bancos tradicionales y Fintech 225
Anexo XXVII. Principales barreras para la colaboración 230
Anexo XXVIII. Potencial Económico de la IA 231

Anexo XXIX. Potencial Económico de IA en América Latina 235
Anexo XXX. Potencial Económico de IA en Argentina..... 237
Anexo XXXI. Mapa de calor de áreas con potencial de IA 240
Anexo XXXII. Áreas de Entidades Bancarias donde la IA puede apoyar 241
Anexo XXXIII. Desafíos de las organizaciones para implementar nuevas tecnologías 242
Anexo XXXIV. Tipos de Opacidad de Datos 244
Anexo XXXV. Crecimiento de Requerimientos de puestos de trabajo de IA y AA 245
Anexo XXXVI. Nuevos puestos de trabajo de la banca en el futuro..... 246
Anexo XXXVII. Impactos Positivos y Negativos de las nuevas tecnologías en los objetivos regulatorios..... 248
Anexo XXXVIII. Enfoques Proactivos: Oficinas de Innovación, Sandbox Regulatorio y RegTech 250
Anexo XXXIX. Desafíos Potenciales según encuesta Baker & McKenzie..... 257
Anexo XL. Etapas de la Disrupción de los Servicios Financieros..... 259
Anexo XLI. Análisis Entrevistas Resumen Amenazas de los Bancos 260
Anexo XLII. Análisis Entrevistas Resumen Fortalezas de los Bancos..... 262
Anexo XLIII. Análisis Entrevistas Resumen Promesas y Oportunidades 264
Anexo XLIV. Análisis Entrevistas Resumen Aplicaciones..... 266
Anexo XLV. Análisis Entrevistas Resumen Barreras y Desafíos..... 268
Anexo XLVI. Análisis Entrevistas Resumen Riesgos 271
Anexo XLVII. Análisis Entrevistas Resumen Perspectiva de Adopción 273

Lista de Figuras

Figura 1. Modelo de Valores de Competencia 24
Figura 2. Madurez de casos de uso en entidades financieras 55
Figura 3. Reducción de Tasa de Falsos Positivos – Caso Danske Bank 81
Figura 4. Oportunidades detectadas por los entrevistados 93
Figura 5. Oportunidades de la IA y AA en los bancos tradicionales privados 96
Figura 6. Aplicaciones de AA identificadas por los entrevistados 97
Figura 7. Aplicaciones de la IA y AA en los bancos tradicionales privados 101
Figura 8. Barreras para la adopción de AA según los entrevistados. 102
Figura 9. Riesgos detectados por los Entrevistados 112
Figura 10. Perspectiva de adopción 115
Figura 11. The Forrester Wave. Plataformas de Analítica Empresarial 153
Figura 12. Cuadrante mágico de Gartner para la ciencia de datos y las plataformas de aprendizaje automático. 154
Figura 13. Innovación Disruptiva 168
Figura 14. Categorización de Adoptantes 171
Figura 15. Tasa de Adopción de una Innovación 172
Figura 16. Adopción de Tecnologías en EE. UU. a partir del siglo XX 173
Figura 17. Ciclo Vital de Adopción de Tecnología Revisado 177
Figura 18. Proceso de Decisión de Innovaciones 180
Figura 19. La Brújula del Posicionamiento Competitivo 183
Figura 20. Penetración de Internet en Latinoamérica 186
Figura 21. Evolución de Usuarios de Redes Sociales 187
Figura 22. Convergencia de tecnologías que permite la transformación digital 190
Figura 23. Clasificación de tipos y técnicas de Aprendizaje Automático o Machine Learning . 202
Figura 24. Índice de IA e Índice de Digitalización 203
Figura 25. Hype Cycle Inteligencia Artificial 204
Figura 26. Amplitud y Frecuencia de Casos de Uso de Aprendizaje Automático por sector 205
Figura 27. Inversión en IA 206
Figura 28. Porcentaje de clientes sin visitar a sucursales por ventana de tiempo 207
Figura 29. Intensidad de uso de los clientes de los canales transaccionales 208

Figura 30. Categorías de Bancos según su madurez digital..... 209
Figura 31. Bancos por Categoría 210
Figura 32. Cantidad de consumidores de servicios financieros por tipo y por país..... 215
Figura 33. Retorno de capital vs. Costo de capital de Bancos Europeos..... 217
Figura 34. Porcentaje de titulares que creen que parte de su negocio está en riesgo..... 218
Figura 35. Amenazas al negocio bancario como consecuencia del desarrollo Fintech. 219
Figura 36. Crecimiento de Préstamos vía plataformas Fintech a nivel global..... 220
Figura 37. Préstamos vía plataformas Fintech en América Latina 221
Figura 38. Aceleración de Adopción de Smartphones en América Latina..... 223
Figura 39. Asociación de Bancos y Fintechs actuales y previstas por País..... 226
Figura 40. Estrategia de las compañías para enfrentar el desarrollo Fintech..... 227
Figura 41. Principales Socios en la Colaboración, perspectiva Fintech 229
Figura 42. Formas en que las entidades tradicionales interactúan con Fintechs 229
Figura 43. Desafíos en la colaboración para Fintech e Incumbentes..... 230
Figura 44. Impacto del PIB global por efecto de la IA..... 231
Figura 45. Impacto de IA en el crecimiento de la industria por industria. 233
Figura 46. Impacto de IA en las ganancias por Industria. 234
Figura 47. Impacto Económico de la IA en América Latina 236
Figura 48. Escenarios de Adopción de IA en Argentina 238
Figura 49. Escenarios de Adopción de IA en Argentina por Sector..... 239
Figura 50. Mapa de Calor de áreas bancarias con potencial para la IA..... 240
Figura 51. Principales desafíos de las empresas para implementar las nuevas tecnologías 242
Figura 52. Crecimiento de Ofertas de trabajo requeridas con habilidades de IA 245
Figura 53. Framework de Innovación Regulatoria 251
Figura 54. Tipos de Iniciativas Innovadoras de Regulación por país..... 252
Figura 55. Obstáculos para introducir IA en pequeñas y grandes empresas del Sistema Financiero 258
Figura 56. Fases de la Disrupción en los servicios Financieros. 259

Lista de Tablas

Tabla 1. Autores por variables y dimensiones estudiadas 7
Tabla 2. Lista de Entrevistados por grupos 11
Tabla 3. Casos de Uso de Aprendizaje automático 53
Tabla 4. Resumen estudios realizados con algoritmos de AA aplicados a calificación crediticia 56
Tabla 5. Resumen estudios realizados con algoritmos de AA aplicados a *Customer Insights* y Personalización 59
Tabla 6. Otros Casos de Usos 61
Tabla 7. Principales aspectos relevados en casos de estudio 87
Tabla 8. Definiciones de Inteligencia Artificicial. 191
Tabla 9. Detalle de los Productos o Servicios Financieros actuales y su reemplazo en el futuro 211
Tabla 10. Beneficios de la colaboración entre Bancos y Fintechs 224
A continuación, se presenta las áreas de Entidades Bancarias donde la IA puede apoyar según King (2018). 241
Tabla 11. Áreas de Entidades Bancarias donde la IA puede apoyar 241
Tabla 12. Impactos positivos y Negativos de las nuevas tecnologías en los objetivos regulatorios. 248
Tabla 13. Resultados relacionados a la identificación de Amenazas que los Bancos tradicionales privados 260
Tabla 14. Resultados relacionados a la identificación de Fortalezas que los Bancos tradicionales privados tienen a la hora de implementar soluciones de IA y AA 262
Tabla 15. Resultados relacionados a la identificación de las Oportunidades que representa de IA y AA en los Bancos tradicionales privados 264
Tabla 16. Resultados relacionados a la identificación de Aplicaciones de IA y AA en los Bancos tradicionales privados 266
Tabla 17. Resultados relacionados a la identificación de Barreras y Desafíos que los Bancos tradicionales privados tienen a la hora de implementar soluciones de IA y AA 268
Tabla 18. Resultados relacionados a la identificación de Riesgos de soluciones de IA y AA en los Bancos tradicionales privados 271

Tabla 19. Resultados relacionados a estado de Adopción de soluciones de IA y AA en los Bancos tradicionales privados 273

Universidad de SanAndrés

1. Capítulo I.

Introducción

Con los cambios tecnológicos de los últimos años, la tecnología digital ha producido un cambio de paradigma en la forma de producir y comercializar bienes y servicios. Internet está transformando los hábitos de consumo, de compra, de entretenimiento, de comunicación y relacionamiento entre las comunidades y el Sistema Financiero no ha sido la excepción.

Las empresas incumbentes de este sector, particularmente los bancos tradicionales privados, se enfrentan a un nuevo entorno de relación con el cliente marcado por la digitalización e impulsado fundamentalmente por los avances tecnológicos y la penetración de herramientas que amplifican la interacción de los usuarios con las marcas. Esto ha derivado en una modificación de los hábitos de consumo y comportamiento del cliente final, exigiendo a las empresas desarrollar nuevos modelos de negocio o transformar los actuales para poder satisfacer las necesidades de sus clientes y seguir creciendo en la era digital. El nuevo cliente es un consumidor más exigente e informado que plantea nuevas demandas a las empresas y espera de las organizaciones un mayor grado de personalización. El gran desafío para la banca es personalizar su oferta de productos y servicios a los deseos de un cliente que necesita sentirse escuchado. Uno de los factores necesarios para llevar adelante este desafío es el tratamiento de los datos. Hoy no solamente se acceden a datos estructurados sino también a datos desestructurados que brindan muchísima información. Pero es tal el aluvión de datos que se torna imposible analizar los mismos a través de métodos manuales, por lo cual se vuelve cada vez más imprescindible el uso de tecnologías para sacar provecho de estos.

Por otro lado, las Fintech están desafiando todos y cada uno de los productos y servicios que un Banco puede ofrecer. Están concediendo créditos en minutos (en contraposición a las semanas que tardan habitualmente los bancos) o están presentándose como competidores en el mundo de los pagos, entre otros tantos ejemplos. Estas empresas han tenido éxito al ser más rápidas a la hora de aprovechar la innovación tecnológica para desarrollar productos más centrados en el usuario, a menor costo y con una mejor experiencia de cliente, optimizados para los canales digitales. Los bancos en la actualidad se encuentran ante un escenario en el que se les dificulta la transformación digital y la obtención de la agilidad necesaria para la adopción de nuevos modelos de negocio. Las Fintech desafían el orden establecido, introduciendo innovación, mejores experiencias de usuario y menores costos para tomar una parte creciente de cuota de mercado; y,

por último, la amenaza (no menor) que representan las grandes empresas tecnológicas (Google, Apple, Facebook, Amazon, etc.) si deciden entrar de forma decisiva a competir directamente en el sector financiero.

Debido a estos factores los Bancos deben acelerar su ritmo de innovación y prepararse para la era digital. Necesitan las nuevas tecnologías, así como las habilidades técnicas y el talento para operar en el mundo digital.

La convergencia y los avances en tecnologías como el Big Data, el Cloud Computing o el Internet de las Cosas (IoT) son los motores de cambio que están siendo incorporados para dar respuesta a estas nuevas necesidades de los clientes, y que a su vez están impulsando el crecimiento y la innovación en la Inteligencia Artificial (o IA a partir de ahora). Estas tecnologías representan una oportunidad para la banca tradicional privada ya que permitirían, tanto gestionar la gran cantidad de información a la que se tiene acceso hoy en día tomando decisiones estratégicas en las compañías a partir de los datos, como elevar el trato al cliente a un nivel más personalizado.

La IA es una disciplina dentro de la informática y la ingeniería cuyo objetivo es el desarrollo de sistemas inteligentes (capaces de aprender y adaptarse) tomando como referencia la inteligencia humana. Y de la misma manera que la inteligencia humana es diversa, compleja y múltiple, la IA también lo es. De hecho, hay numerosas ramas de estudio dentro de la IA: la robótica, la percepción por ordenador (visión, reconocimiento del habla, etc.), el aprendizaje automático, la planificación, el razonamiento, la representación del conocimiento, el procesamiento del lenguaje natural, las ciencias sociales computacionales, la informática afectiva, los agentes inteligentes, los asistentes virtuales, entre otros.

Hasta hace poco, la IA, que ya tenía bastante historia (casi 70 años), comprendía un terreno del mundo tecnológico que no había alcanzado las expectativas esperadas en su nacimiento. Pero hoy existen diversos factores, con origen fundamentalmente en la tecnología, que impulsan su uso: el incremento sin precedentes del volumen y tipología de datos disponibles, la conectividad y el acceso al dato, la mejora de los algoritmos utilizados y el aumento de la capacidad computacional de los sistemas. En las últimas 2 décadas la disponibilidad de datos digitales se ha incrementado casi 1000 veces, mientras que su relación con la algoritmia, se han registrado mejoras de10 veces en su eficiencia, al tiempo que la velocidad de computación ha aumentado 100 veces su desempeño (Brynjolfsson &McAfee, 2017).

Dentro del ámbito de IA, el aprendizaje automático (aprendizaje automático o AA o *Machine Learning* a partir de ahora) está experimentando un crecimiento y auge sin precedente, mucho debido a los factores tecnológicos mencionados anteriormente, lo que grandes expectativas o promesas.

Las técnicas de aprendizaje automático pueden definirse como un conjunto de métodos capaces de detectar automáticamente patrones en los datos (Murphy, 2012). Este concepto de aprendizaje automático incluye el uso de los patrones detectados para realizar predicciones, o para tomar otro tipo de decisiones en entornos de incertidumbre. La introducción de técnicas de AA permite mejorar el proceso de estimación de modelos, no solo con relación al aumento del poder predictivo a través de nuevas metodologías y técnicas de selección de variables, sino también de la mejora de la eficiencia de los procesos a través de la automatización.

En el campo de la Banca tradicional privada, los modelos de AA podrían ser utilizados en diferentes áreas y actividades, permitirían clasificar mejor el riesgo de las personas y empresas, optimizar el seguimiento de las carteras de clientes detectando comportamientos, tasar automáticamente inmuebles con un alto grado de éxito, prevenir el fraude y maximizar los resultados en el recupero de créditos, entre otros grandes impactos en la gestión de instituciones financieras. Por lo que estas soluciones podrían implicar una herramienta para los Bancos tradicionales privados para generar ventajas competitivas y hacer frente a la disrupción que se está produciendo en el Sistema Financiero.

1.1. Preguntas de Investigación

Ante el escenario planteado de necesidad por parte de los Bancos tradicionales privados de generar ventajas que le permitan hacer frente a la disrupción del sistema financiero, el presente trabajo tiene por objetivo responder la siguiente pregunta principal:

¿La implementación de soluciones de Aprendizaje Automático representa una oportunidad para los bancos tradicionales privados para hacer frente a la disrupción del sistema financiero ayudando a incorporar ventajas competitivas?

Y las siguientes preguntas secundarias:

- ¿Cuáles son las promesas y oportunidades que la IA y el AA pueden brindar para mejorar la competitividad de los bancos tradicionales privados y sus aportes para transformar la industria?

- ¿En qué actividades las soluciones de AA pueden ayudar a la banca?

- ¿Cuáles son las principales barreras, desafíos y riesgos con las que se enfrentan los Bancos tradicionales privados en su camino a la adopción de estas soluciones?

1.2. Objetivos

El principal objetivo de este trabajo de investigación es analizar los posibles aportes que el aprendizaje automático puede realizar a los Bancos Tradicionales Privados para mejorar sus ventajas competitivas y analizar las oportunidades de adopción.

A partir de este objetivo principal, el presente trabajo de investigación tiene los siguientes objetivos secundarios:

- Introducir los conceptos relacionados a innovación y comprender los principales factores que estimulan o inhiben la adopción de nuevas tecnologías.
- Introducir los conceptos de inteligencia artificial, aprendizaje automático y su perspectiva de adopción actual
- Comprender la situación actual de los bancos tradicionales privados, su relación con la disrupción del sistema financiero y los nuevos escenarios
- Proporcionar una comprensión de las promesas, oportunidades y aplicaciones específicas que las soluciones de aprendizaje automático pueden generar para los bancos tradicionales privados.
- Reflexionar acerca de cuáles son las barreras, desafíos y riesgos a los que se enfrenta la banca tradicional privada para avanzar en la adopción de soluciones de aprendizaje automático.

1.3. Alcance

Este trabajo de investigación apunta a investigar la implementación de soluciones de aprendizaje automático en bancos tradicionales privados, medianos y grandes, que cuentan con canales físicos (como por ejemplo sucursales) y digitales, preferentemente en Argentina.

1.4. Metodología de investigación

1.4.1. Paradigma

Kuhn (1970) define a un paradigma de una investigación, en sentido amplio, como una matriz disciplinaria que abarca generalizaciones, supuestos, valores y creencias y ejemplos compartidos de lo que constituye el interés de la disciplina. Enumera cuatro aspectos sobre la utilidad de los paradigmas, el primero se refiere como guía para los profesionales de una disciplina al indicar los problemas, cuestiones e interrogantes con los que se enfrenta. El segundo aspecto es que orienta la construcción de modelos y teorías cuya finalidad es tratar de resolver los problemas. En tercer lugar, establece los criterios para el uso de las herramientas pertinentes, desde la metodología, instrumentos para la recolección de datos, etc. Y en cuarto lugar brinda una epistemología. Desde esta perspectiva la diferencia central entre los paradigmas cuantitativo y cualitativo encuentra su argumento clásico en las corrientes filosóficas del realismo e idealismo y sus reformulaciones. El proceso de conocimiento encuentra diferentes respuestas desde estas posturas. Creswell (2009) argumenta que la diferencia principal entre el paradigma cualitativo y el cuantitativo radica en que el enfoque de investigación cualitativo es útil para explorar y comprender significados, en tanto que la investigación cuantitativa es usada para probar teorías al examinar las relaciones entre las variables que se miden.

Bajo estos conceptos mencionados esta investigación se realizará bajo un paradigma cualitativo debido a que se basará en análisis de datos, información y entrevistas, y se realizarán generalizaciones tratando de descubrir patrones, como lo establece Jacobs (1987) mencionado en Gutiérrez (1999).

El conocimiento generado por la investigación bajo un paradigma cualitativo es principalmente formulado en términos del razonamiento inductivo. En este razonamiento se generalizan para todos los elementos de un conjunto la propiedad observada en un número finito de casos. Hay que tener en cuenta que las observaciones favorables a las conclusiones arribadas no convierten en verdadera la conclusión, ya que podría haber excepciones. De ahí que la conclusión de un razonamiento inductivo sólo pueda considerarse probable y, de hecho, la

información que se obtiene por medio de esta modalidad de razonamiento es siempre una información incierta y discutible. Este paradigma establece un abordaje subjetivo de la materia bajo estudio. El objetivo está más asociado al entendimiento que a la predicción del fenómeno en estudio.

1.4.2. Tipo de Investigación

De acuerdo a Yin (1994) y Zikmund (2000) existen tres formas de encuadrar una investigación: el abordaje exploratorio, el descriptivo y el explicatorio. También Babbie y Huitt (1979) ha clasificado los tipos de investigación en estos tres tipos de estudios. Dankhe (1989) en cambio los divide en exploratorios, descriptivos, correlacionales y explicativos. Una investigación descriptiva debe ser realizada cuando el área de investigación tiene una alta complejidad (Zikmund, 2000). Se centra, simplemente, en ofrecer una visión de la realidad de un fenómeno, sin explicar posibles causas que lo hayan podido provocar. Best (1988) se refiere a la investigación descriptiva como aquella que minuciosamente interpreta lo que es. Está relacionada a condiciones o conexiones existentes, prácticas que prevalecen, opiniones, puntos de vista o actitudes que se mantienen, procesos en marcha, efectos que se siente o tendencias que se desarrollan. En este caso se aborda una investigación de tipo descriptiva debido a que se intenta describir exhaustivamente las oportunidades que la IA y el AA aportan a los Bancos tradicionales privados, el estado de situación actual, así como también las barreras, desafíos, riesgos y amenazas que inhiben su adopción.

1.4.3. Instrumentos

Con respecto a la instrumentación, tal como expresa Blaikie (1991), es conveniente utilizar una estrategia de triangulación debido a que uno de sus objetivos es aumentar la validez de los resultados y disminuir los problemas de sesgo. También para Denzin (1989), la triangulación consiste en una estrategia de investigación a través de la cual un mismo objeto de estudio es abordado desde distintas perspectivas de contraste o instantes temporales, donde la triangulación se pone en juego al comparar datos, confrontar perspectivas de diferentes investigadores o simplemente comparar teorías, contextos o instrumentos. Es conveniente entonces, utilizar dos o más métodos que converjan, con el objetivo de disminuir el sesgo. Por esto, en este proyecto de investigación se ejecutó por un lado un proceso exhaustivo de compilación y análisis de

información existente, utilizando como fuentes ya sean primarias o secundarias a autores académicos, consultoras expertas y empresas del sector. Las fuentes de datos están disponibles públicamente con alta credibilidad de las instituciones acreditadas a nivel académico, asociaciones o instituciones, o fueron obtenidos a través de los expertos que intervinieron el desarrollo de esta investigación. Debido a la alta orientación descriptiva y de alto grado de actualidad de la temática abordada, la búsqueda de información no se limitó solamente a fuentes académicas. Utilizando bases de datos relevantes y motores de búsqueda se consideraron artículos científicos, libros, publicaciones de autores y estudiosos del tema, así como estudios realizados por consultoras de relevancia internacional. A continuación, se presenta una tabla donde se detalla, por cada variable y sus dimensiones que conforman el presente trabajo, los autores o publicaciones elegidos, utilizados para obtener fuentes primarias y secundarias de información.

Tabla 1. Autores por variables y dimensiones estudiadas

Variables	***Dimensiones***	***Autores***	
Innovación	Tipos de Innovaciones	• Afuah • Chesbrough • Chesbrough y Crowther • Chesbrough, Vanhaverbeke & West • Christensen • Christensen y Reynor • Drucker • Enkel, Gassmann, & Chesbrough • Katz • King y Baatartogtokh • Moore	• OECD (Organización para la Cooperación y el Desarrollo Económicos) • Porter • Raymond • Rogers • Pollock • Sandulli & Chesbrough • Solow • Shumpeter • Van de Vrande, de Jong, Vanhaverbeke, & de Rochemont • Von Hippel
Innovación	Factores organizacionales primordiales para impulsar la adopción de innovaciones	• Ajzen • Bass • Bovey & Hede • Burns & Stalker • Cameron & Quinn • Chiavenato • Contreras y Barbosa • Denison • Hartmann • Hruska, Rasic & Bakovic	• Lupano Perugini & Castro Solano • Mitzberg • Naranjo Valencia, Saenz Valle & Jiménez Jiménez • Schein • Smoralek • Van Dam, Oreg & Schyns • Varela • Yukl

Variables	*Dimensiones*	*Autores*	
		• Kotter	
Inteligencia Artificial y Aprendizaje Automático	Conceptualización de Inteligencia Artificial	• Agrawal, Gans & Goldfarb • Amat • Basco et al • Bellman • Brynjolfsson & McAfee • Charniak y McDermott • CEPAL • Costa • Delgado • Estevadeordal et al • Haugeland • Jordan & Mitchell • Kurzweil	• Lee • Luger y Stubblefield • Mckinsey • Minsky • Murphy • Rao & Verweij • Rich y Knight • Russell & Norvig • Shallkoff • Shapiro • Von Krogh • Winston • Word Economic Forum
Inteligencia Artificial y Aprendizaje Automático	Conceptualización de Aprendizaje Automático	• Agrawal, Gans & Goldfarb • Brynjolfsson & McAfee • CEPAL • Goodfellow, Bengio & Courville	• Mitchell • Murphy • Kolanovic &Krishnamachari • Samuel
Inteligencia Artificial y Aprendizaje Automático	Adopción de IA y AA	• Accenture • Brynjolfsson & McAfee • Gartner • Katz	• Mckinsey • Word Economic Forum • OECD
La Disrupción en la Banca Tradicional Privada	Nuevo consumidor de Servicios Financieros	• Accenture • Barberis • Brynjolfsson & McAfee • Frost & Sullivan	• Indra • King • OEDC • Rojas
La Disrupción en la Banca Tradicional Privada	Disrupción del Sistema Financiero y retos de los incumbentes	• Anif, Felaban & CAF • Barberis • Basco et al. • Brynjolfsson & McAfee • Capgemini, Linkedn & Efma • CEPAL • Citi GPS • Finnovista • Frost & Sullivan	• García Montalvo • GSMA • Indra • King • Nava & Medica • OEDC • PWC • Palacio Garcés • Rojas • Skinner •

Universidad de SanAndrés

Variables	*Dimensiones*	*Autores*	
La Disrupción en la Banca Tradicional Privada	Colaboración entre Fintech y Bancos Tradicionales	• Accenture • BBVA • Capgemini, Linkedn & Efma • Citi GPS	• Ernst &Young • King • PWC • Rojas
Inteligencia Artificial y Aprendizaje Automático como herramienta para los Bancos Tradicionales privados	Promesas de IA y AA	• Abbosh &Ovanessoff • Accenture • Albrieu et al. (CIPPEC) • CEPAL • Chitra &Subashini • Daugherty &Wilson • Estevadeordal et al. • Financial Stability Board	• Hendershott, Jones & Menkveld • Jagtiani, Vermilyea & Wall • Katz • King • McKinsey • OECD • Rao & Verweij • Schwab
Inteligencia Artificial y Aprendizaje Automático como herramienta para los Bancos Tradicionales privados	Aplicaciones de AA en la Banca	• Abidin, Ismail, Maarop & Alias • Accenture • Altman • Angelini et al. • Auria & Moro • Aziz and Dowling • Bellotti & Crook • Budworth • Butaru et al. • Carney • Chitra &Subashini • Davis, Edelman & Gammerman • Dhandayudam & Krishnamurthi • Estevadeordal et al. • Fernandez • Financial Stability Board • Frost & Sullivan • Galindo y Tamayo • Gartner • IDC • Jagtiani & Lemieux • Jagtiani, Vermilyea & Wall • Jones & Kim • Khandani et al. • King	• Kennedy • Laurens & Zou • Letham, Rudin, McCormick & Madigan • Li, Shiue & Huang • Li, Wang & He • Gomes Lopes, Ladeira & Calrvalho • Lopez Lázaro, Barbero Jiménez & Takeda • McKinsey • OECD • Perol • Rao & Verweij • Sirignano et al. • Smeureanu, Ruxanda & Badea • Tsai & Chen • Van Liebergen

Universidad de SanAndrés

Variables	*Dimensiones*	*Autores*	
Inteligencia Artificial y Aprendizaje Automático como herramienta para los Bancos Tradicionales privados	Factores que actúan como Barreras o Desafíos	• Agrawal, Gans & Goldfarb • McKinsey	• Nieponice • Rao & Verweij
Inteligencia Artificial y Aprendizaje Automático como herramienta para los Bancos Tradicionales privados	Riesgos del AA	• Accenture • Addo, Guegan & Hassani • Agrawal, Gans & Goldfarb • Banco Interamericano de Desarrollo y Finnovista • Barocas & Selbst • Basco et al • Bauer et al. • BBVA • BBVA Innovation Center • BBVA Research • Berrell • Buenadicha Sanchez et al. • Budworth • Estevadeordal et al. • Fernandez • Financial Stability Board • Guegan & Hassani	• Herrera y Vadillo • Indra • Jagtiani & Lemieux • Jagtiani, Vermilyea & Wall • King • Lopez & Martínez • McKinsey • Nieponice • OECD • PWC • Rao & Verweij • Rojas • Skinner • UNSGSA FinTech Workig Group &CCAF • Van Liebergen • World Economic Forum

Elaboración Propia en función de los autores relevados en cada capítulo del presente trabajo.

Luego se llevaron adelante entrevistas para lograr el chequeo de los análisis realizados con los referentes de la materia. La opinión y las respuestas de los expertos juegan un rol central en este trabajo. Con la elección de entrevistas como instrumento seguimos los postulados teóricos de Cook y Reichardt (1982), Bogdam y Bilken (1992) y Creswell (1998) que exponen que los dos instrumentos investigadores más importantes en una investigación cualitativa son precisamente la entrevista abierta o en profundidad y la observación participante, por el acercamiento y la relación que se establece con ellos, lo que facilita la obtención de información. La entrevista es una variante

en el método de encuesta, en la cual la información se obtiene directamente del interlocutor. En la entrevista el investigador habla cara a cara con el entrevistado. Las ventajas de este instrumento es la flexibilidad en la obtención de la información al permitir adaptar a la medida de cada sujeto el contacto personal. Se utilizó un cuestionario (de orientación cualitativa) que permitió triangular con los datos obtenidos del análisis inicial.

Para seleccionar a los entrevistados se consideraron expertos y referentes del mercado. Experto es una persona reconocida como una fuente confiable de un tema, técnica o habilidad cuya capacidad para juzgar o decidir en forma correcta, justa o inteligente le confiere autoridad y estatus por sus pares o por el público en una materia específica. En forma más general, un experto es una persona con un conocimiento amplio o aptitud en un área particular del conocimiento. Los expertos son requeridos para dar consejos sobre su tema de especialización. Se entiende que un experto puede, gracias a su entrenamiento, educación, profesión, trabajos realizados o experiencia, tener un conocimiento sobre un cierto tema que excede el nivel de conocimiento de una persona común, de manera tal que otros puedan confiar en la opinión del individuo en forma oficial y legal. Para la selección de los individuos entrevistados, considerados como expertos para el objeto de estudio, se definió como estrategia identificar grupos que aporten diferentes visiones a la investigación, a saber: Banco tradicionales privados (Incumbentes); Fintechs y Bancos Digitales (No Incumbentes); ente regulador de la industria, el Banco Central de la República Argentina (BCRA); referentes académicos, asesores y docentes expertos en digitalización o transformación digital, inteligencia artificial y/o aprendizaje automático; consultores reconocidos en el mercado y proveedores de soluciones de Inteligencia Artificial y Aprendizaje Automático líderes en la industria. Para seleccionar estos últimos se analizaron los principales proveedores a nivel mundial según Forrester (Hopkins, 2019) y Gartner (2019) (Anexo I) y se identificó cuáles de ellos se desempeñan localmente. Se analizaron los posibles candidatos de las entrevistas y se contactó a los mismos a través de redes sociales (Linkedn, Twitter) y vía correo electrónico. A continuación, se detallan los entrevistados (sus referencias se detallan en el Anexo II).

Tabla 2. Lista de Entrevistados por grupos

Grupo	*Entrevistados*
Bancos tradicionales privados (Incumbentes)	**Virginia Martini Zanetti** (Head de Datos Banco Santander) **Nicolas Martins** (Gerente de Inteligencia Comercial & Gobierno de Datos del Cliente en Banco Macro) **Eduardo Peralta** (Gerente de Desarrollo Banco Supervielle) **Fernando Turri** (CIO en Banco Galicia)
Fintechs y Bancos Digitales (No Incumbentes)	**Leonardo Aranda** (Chief Data Scientist en Moni) **Juan Pablo Bruzzo** (CEO & Co-Fundador Moni y Presidente de la Cámara Argentina Fintech) **Florencia Vidal** (Gerente Regional de Prensa y Comunicaciones en Afluenta)
Banco Central de la República Argentina (BCRA)	**Marcelo Hector Gonzalez** (Inspector General de Sistemas de Información en BCRA)
Referentes académicos y docentes expertos en digitalización o transformación digital, inteligencia artificial y/o aprendizaje automático	**Hernán Borré (**Experto en Inteligencia Artificial y Aprendizaje Automático. Head de Machine Learning en el Ministerio de Producción y Trabajo de la República Argentina) **Ignacio R. Carballo** (Especialista en Inclusión Financiera – Profesor UCA, UBA y Austral. Fundador de Cimientos Económicos) **Carlos A. Giménez** (*Chief Analytics Officer* en Digital Naranja y Docente de la Universidad de San Andres) (*Head of AI en SAI Holanda* y co-fundador de Fon,ai **Juan Martín Maglione** empresa que brinda soluciones de IA y Analytics. Profesor Universidad de San Andrés)
Expertos, consultores y asesores reconocidos en el mercado	**Guillermo Marchionni** (Director en Digital Bank Latam) **Ignacio Perrone** (Gerente de Investigación en Frost & Sullivan)
Proveedores de soluciones de Inteligencia Artificial y Machine Learning líderes en la industria.	**Alejandro Bolaños** (*Head de AI & Data Science* SAS Argentina) **José Luis Nugoli** (Gerente de Ventas del Cono Sur en SAS Argentina) **Ana Hidalgo** (Gerente de Pre-Ventas en SAS Argentina especialista en proyectos de IA y AA) **Maria de las Mercedes Nogueira** (Líder de Social Media e Inteligencia Artificial en IBM) **Wenceslao Cova** (Líder de Watson en IBM)

Elaboración Propia con el detalle de los entrevistados por tipo

Además de la revisión bibliográfica y de las entrevistas se participó de un evento donde participaron de un panel, María Fernanda González (Gerente de Canales Digitales en Santander Rio), Sergio Bauzá (Gerente de Calidad y Servicios al Cliente), como representantes del Banco Santander Río, y Fernando Turri del Banco Galicia; sus referencias en el Anexo II. Este panel, respondió preguntas y respuestas sobre inteligencia artificial y aprendizaje automático en la Banca Tradicional Privada. Estas entrevistas se analizan dentro del trabajo de campo en el capítulo VIII.

Finalmente se analizaron diferentes casos de implementaciones de soluciones de aprendizaje automático en proveedores de servicios financieros tanto Bancos Tradicionales como digitales. Los casos perteneces a experiencias en diferentes partes del mundo. Los casos analizados fueron: Visión Banco (Paraguay); Danske Bank (Dinamarca); DBS Bank (Singapur); Seacost Bank (EE. UU.) y Banco Santander Río (Argentina) y Banco Supervielle (Argentina).

El objetivo final de estos instrumentos elegidos y detallados es evaluar datos primarios y secundarios obtenidos de diferentes fuentes de manera de lograr los datos necesarios que permitan responder las preguntas de investigación. Todos los datos se contrastarán entre sí para detectar patrones de concordancia y diferenciación. Con estos datos, obtenidos desde diferentes puntos de vista y fuentes se buscará una posible respuesta a los interrogantes planteados en un esquema de triangulación de los instrumentos metodológicos mencionados.

1.5. Estructura de la Tesis

El texto de la presente tesis de maestría está dividido en cuatro partes claramente diferenciadas. Cada una de ellas contiene uno o varios capítulos de diversa índole, cuyas líneas generales se presentan a continuación. La primera parte está compuesta de un solo capítulo y constituye la introducción del presente trabajo. Ofrece una justificación del estudio realizado, las preguntas de investigación, los objetivos, alcance y la metodología con la cual se ha estructurado el presente trabajo.

La segunda parte de la tesis expone el marco teórico en el que se va a basar la investigación, dividiéndose en cinco capítulos.

El capítulo II indaga sobre los conceptos principales que llevan a la transformación de las organizaciones, focalizando en innovación, adopción y como grandes factores que propician el cambio, la cultura organizacional y el liderazgo.

El capítulo III consta de varias secciones que abarcan los conceptos principales de inteligencia artificial y aprendizaje automático. También es parte de este capítulo un análisis de las causas del florecimiento de estas tecnologías en los últimos tiempos y cuenta con una sección sobre los métodos y técnicas de aprendizaje automático que, aunque no es objetivo de este trabajo entrar en detalle técnico de los algoritmos, un breve conocimiento de ellos ayuda a entender el estado de situación de estos. Por último, se desarrolló una sección que permita entender el escenario actual de adopción de estas tecnologías a nivel general sin entrar en una industria o campo en particular para luego profundizar en el sector financiero/bancario en un capítulo posterior.

El capítulo IV introduce el mundo de la Banca, con el objetivo de entender el escenario actual de la industria con respecto a los cambios tecnológicos disruptivos, entender al nuevo consumidor de servicios financieros para luego analizar retos que tienen los proveedores de servicios establecidos ante la aparición de nuevos entrantes. Por último, se desarrolla una sección analizando la colaboración de los Bancos tradicionales provocados con las Fintech como estrategia ante la disrupción.

El capítulo V aborda las promesas y oportunidades de la IA y el AA en la Banca, y presenta un análisis de los casos de uso que se pueden implementar en la Banca.

Por último, el Capítulo VI introduce los factores que actúan como barreras o desafíos para la adopción de estas técnicas por los Bancos.

La tercera parte está compuesta por el análisis de casos y el trabajo de campo realizado con las entrevistas realizadas. El capítulo VII detalla el estudio de los casos relevados y su relación con los ejes de estudio y el capítulo VIII desarrolla el trabajo de campo llevado a cabo, dividendo el análisis de las entrevistas realizadas en 6 secciones, situación actual de los bancos ante la disrupción, promesas y oportunidades, aplicaciones, barreras y desafíos, riesgos, y perspectivas sobre la adopción.

La última parte está conformada por el capítulo final, IX, donde se desarrollan las conclusiones que permiten reflexionar acerca de la investigación realizada y sobre el cumplimiento de objetivos y respuesta sobre las preguntas de investigación planteada. Además, se suman recomendaciones, una visión sobre el futuro de la inteligencia artificial y el aprendizaje automático y futuras investigaciones posibles resultantes de este trabajo.

2. Capítulo II.

Conceptos principales en la Transformación Organizacional

En este capítulo se aborda los conceptos principales relacionados a innovación, su relación con la tecnología y las empresas. Es importante profundizar sobre estos conceptos, antes de abordar los conceptos de Inteligencia Artificial y Aprendizaje Automático como tecnología puntual, para elaborar un marco conceptual de las innovaciones en general para su desarrollo y adopción, para identificar y comprender los principales factores involucrados. Con este objetivo, en este capítulo se profundiza en los tipos y modalidades de innovación y los conceptos de innovación más cercanos a la actualidad como innovación disruptiva, innovación abierta, innovación de usuarios y democratización de la innovación para obtener el marco conceptual mencionado que permita comenzar a entender el impacto de las innovaciones tecnologías en general. Además, se encaran dos variables fundamentales a la hora de gestionar los cambios organizacionales para la adopción de nuevas tecnologías, la cultura organizacional y el liderazgo que inhiben o estimulan los cambios.

2.1. Innovación, tecnologías y empresas

Actualmente la sociedad vive profundos y continuos cambios en todos sus ámbitos, siendo uno de sus grandes desafíos la sustentabilidad y la competitividad en un entorno global. La innovación es uno de los doce pilares que conforman la competitividad de las regiones, y las empresas son reconocidas como los agentes del desarrollo económico y competitividad de los países (OECD, 2006; Schumpeter, 1966; Solow, 1956). La innovación es un factor clave para el logro de ventajas competitivas y para el éxito de las empresas (Rogers, 2003). Existe una relación fundamental entre la innovación y la productividad a largo plazo (OECD, 2016). Así, la innovación, como factor explicativo de la competitividad de un país o de las empresas, recibe cada vez mayor atención.

El concepto innovación ha sido definido por varios autores. Schumpeter (1934) es el primer autor que describe la innovación como motor del desarrollo, y como un proceso de destrucción creativa, donde nuevos productos destruyen viejas empresas y modelos de negocio. Las innovaciones de los emprendedores son la fuerza que hay detrás de un crecimiento económico sostenido a largo plazo, pese a que puedan destruir en el camino el valor de compañías bien establecidas. La destrucción creativa permite que la economía y los agentes económicos

evolucionen; asimismo, es la forma en que la empresa administra sus recursos a través del tiempo y desarrolla competencias que influyen en su competitividad.

La innovación está en estrecha relación con la tecnología (Christensen, 1999). La innovación y el progreso tecnológico han tenido un papel muy relevante para el crecimiento económico y la competitividad, especialmente mediante la introducción de nuevos procesos de producción. Algunos autores relacionan los ciclos económicos de crecimiento a largo plazo con las "oleadas" de innovaciones tecnológicas claves (Schumpeter, 1934; Katz 2017). También Afuah (1999) presenta a la innovación relacionada a la tecnología ya que la define como el uso de "conocimiento tecnológico y de mercado" que utiliza una empresa para desarrollar y brindar un nuevo producto o servicio a sus clientes.

Las empresas han desempeñado un papel central en los procesos de desarrollo, introducción y difusión de innovaciones al mercado (Schumpeter, 1966). Al respecto, Porter (1990) afirma que el proceso de innovación no se puede separar del contexto estratégico y competitivo de una empresa. De acuerdo con esto, Drucker (1997) argumenta que la innovación sistemática consiste en la búsqueda, organizada y con un objetivo, de cambios y en el análisis sistemático de las oportunidades que ellos pueden ofrecer para la innovación social o económica. También es el medio a través del cual el emprendedor crea nuevos recursos generadores de riqueza o dota a los recursos existentes de mayor potencial para crearla (Drucker, 2000). Entonces, se puede describir la innovación en términos de los procesos por los cuales una organización transforma el trabajo, el capital, los materiales y la información, en productos y servicios de mayor valor para el cliente. Esta conceptualización se refiere tanto a los procesos de diseño del producto o del servicio, marketing, inversión y administración (Christensen,1999). Rogers (2003) por su parte define al proceso de desarrollo de una innovación como todas las decisiones, actividades y sus impactos, que ocurren desde el reconocimiento de una necesidad o un problema, la investigación, desarrollo y comercialización de una innovación, hasta la difusión y adopción de la innovación por parte de los usuarios.

El Manual de Oslo de la OECD (2006) también define la innovación tecnológica como la conversión del conocimiento tecnológico en nuevos productos, servicios o procesos para su introducción en el mercado. La innovación es la aplicación, por primera vez, de conocimientos y de prácticas racionales a la satisfacción de necesidades socioeconómicas y el proceso de innovación sólo se completa cuando se ha introducido en el mercado.

Las innovaciones pueden ser radicales, cuando implican un cambio brusco e importantes cambios en dirección del proceso innovador o pueden ser innovaciones incrementales que consisten en aquellas que alimentan en forma continua el proceso de cambio de paradigma o progresivas cuando son mejoras dentro del mismo paradigma (Schumpeter ,1934; OCDE 2006). Las innovaciones radicales pueden llegar a lo que Schumpeter llama la creación destructiva, donde un nuevo producto o una tecnología deja obsoleto a productos o tecnologías existentes. Moore (2015) también define los tipos de innovación y reciben el nombre de innovaciones discontinuas o perturbadoras y en términos opuestos, las innovaciones continuas o sostenidas, que se refieren a la renovación normal de productos que no obligan a cambiar de comportamiento. También en esta línea está lo planteado por Christensen (1999) que diferencia una tecnología sustentada de una tecnología disruptiva.

Las tecnologías disruptivas son las que sirven para crear oportunidades de negocios. Pero las tecnologías disruptivas en un primer momento tienen varias desventajas: a corto plazo, adoptar una tecnología de este tipo resulta en un producto de peor desempeño; atraen a un mercado mucho más pequeño ya que una tecnología disruptiva es adoptada inicialmente por el cliente menos rentable en un mercado, el innovador (Christensen 1999, Moore 2015), hasta que éstas sean ampliamente aceptadas y por último ofrecen menos ganancias ya que son más baratas, pequeñas, simples y fáciles de usar. Otra barrera para la pronta implementación de una tecnología disruptiva es que su desempeño será incierto, como con cualquier cosa nueva y no completamente desarrollada. Inicialmente, la base de clientes para el nuevo producto puede ser pequeña y el producto puede ser muy costoso. El hecho de que probablemente estos productos no se vendan bien al principio hace que las grandes compañías se interesen aún menos en estos lo que hace que sea altamente improbable que las compañías que se centran en productos de alto rendimiento y alto valor para el cliente inviertan en tecnologías disruptivas que puedan tener un valor agregado en el futuro. Pero conforme las nuevas tecnologías mejoran, sus costos caen y los clientes descubren nuevos usos para estos y, en consecuencia, su valor aumenta. Es racional que las grandes empresas se resistan a adoptar tecnologías disruptivas, ya que inicialmente estas tecnologías son menos rentables y menos atractivas para el consumidor. Pero esta estrategia facilita el camino para que la participación de mercado decline mientras que las nuevas tecnologías ganan rentabilidad, atracción del consumidor y dominio. Las tecnologías disruptivas son difíciles de aceptar, ya que se comercializan por primera vez en mercados emergentes o insignificantes, y generalmente no

son (al menos inicialmente) deseadas por los clientes más rentables de una empresa. En el Anexo IV se grafica el proceso de innovación disruptiva.

Según Christensen la forma más efectiva de establecer una presencia en los nuevos mercados es creando una organización autónoma (spin-off), un negocio nuevo e independiente, que explote la nueva tecnología y desarrolle nuevos clientes en torno a ella. Los esfuerzos para nutrir estas nuevas tecnologías dentro de una gran compañía están generalmente condenados ya que las presiones institucionales desalientan sus desarrollos (Christensen, 1999). Las spin-off y las spin-out son organizaciones nuevas (*start-ups)* que surgen a partir del conocimiento interno generado en la organización parental. De la organización parental pueden recibir apoyo financiero, recursos humanos, apoyo administrativo, apoyo legal, etc. Es una alternativa que permite desarrollar una tecnología fuera de la compañía, de tal manera que, si ésta resulta rentable, el capital que posee la empresa raíz puede impulsarla al mercado (Chesbrough, 2006).

Si bien los principios básicos de la teoría de la innovación disruptiva mantienen su vigencia, varios autores han planteado la existencia de limitaciones en la misma. King y Baatartogtokh (2015) analizan los 77 casos citados en las investigaciones de Christensen (1999) y realizaron consultas a especialistas de cada uno de esos sectores, e intentaron evaluar cuántos de esos casos cumplían con los cuatro criterios que caracterizan la teoría, desarrollado en los párrafos anteriores. Los autores encontraron que solo el 9 % de los casos cumplieron con todas las exigencias de la teoría y concluyeron que la teoría, si bien es útil no sustituye el pensamiento crítico y pueden dar lugar a un falso sentido de seguridad a las organizaciones por lo que las decisiones deben basarse en un análisis cuidadoso de los fundamentos de la competencia en un sector y en las fuentes de las ventajas competitivas de la empresa.

Otro autor que incorpora nuevos conceptos y que ha desarrollado sus teorías y modelos con base en investigaciones realizadas en empresas que han llevado a cabo innovaciones es Henry Chesbrough (2003) que acuña el término “innovación abierta” (*open innovation*). Este autor parte de la idea de que las empresas ya no son capaces de abordar por sus propios medios todo el proceso de la innovación y deben contar con recursos externos (propiedad intelectual, ideas, productos, personas, empresas) que deben integrarse en su propia cadena de innovación. En los últimos años la competitividad y la permanencia en el mercado de las organizaciones se ven afectadas por varios factores. La movilidad laboral y el aumento de personas altamente capacitadas, el capital de riesgo abundante para la creación de nuevas empresas (Chesbrough, 2003;Van de Vrande, de Jong,

Vanhaverbeke, & de Rochemont, 2009), la reducción de los ciclos de vida de los productos (Enkel, Gassmann, & Chesbrough, 2009), el alto costo en el desarrollo de tecnologías (Chesbrough, 2006) y la diversidad de conocimiento de múltiples organizaciones públicas y privadas (Chesbrough, 2003) hacen insostenible que una empresa innove por cuenta propia, por lo que se han modificado las condiciones de dinámica de la gestión de la innovación. Chesbrough (2003) concluye que la innovación por sí sola no garantiza la supervivencia empresarial, ni el rendimiento de las organizaciones.

La concepción inicial de la innovación abierta trata de definir un nuevo modelo de innovación industrial, el cual establece el uso de flujos de entradas y salidas de conocimiento que agilizan la innovación interna, y trata de ampliar los mercados para uso externo de la innovación, respectivamente intencionales (Chesbrough, 2003, 2006). Existen muchas vías por las que puede llevar un proyecto al mercado, como las licencias de explotación o empresas spin-off, aparte de los canales de marketing y ventas propios de la compañía (Chesbrough, 2006). Este paradigma asume que las empresas pueden y deben hacer uso tanto del conocimiento externo como del interno y deben utilizar los diferentes medios de acceso al mercado si esperan desarrollar su tecnología (Chesbrough, Vanhaverbeke & West, 2006). Las empresas que incorporan conocimientos y tecnologías desde el exterior obtienen ventajas en términos de la velocidad en el desarrollo de nuevos productos y de la facilidad de acceso a recursos externos que hubieran sido costosos y difíciles de desarrollar (Sandulli & Chesbrough, 2009).

Según Moore (2015) es muy difícil que funcione la colaboración entre empresas. Las compañías parten de culturas empresariales tan distintas que no logran colaborar. Los ciclos de decisión son muy desincronizados y tienen como consecuencia una gran frustración entre los emprendedores y una actitud prepotente por parte de los gestores establecidos. Las complejidades del desarrollo y el mantenimiento de las alianzas estratégicas sobre el terreno en el que se producen las ventas bastan para ocasionar fricciones incluso entre las organizaciones más experimentadas. Lo que sí funciona según Moore (2015) son las alianzas que tienen como un único propósito la aceleración de la formación de la infraestructura necesaria para el compromiso básico que exige el suministro conjunto de un producto completo en el mercado y su comercialización cooperativa. Ese procedimiento beneficia al administrador del producto completo, porque garantiza la satisfacción del cliente y también beneficia a los socios que contribuyen al producto completo, porque expande su mercado sin que ellos tengan que hacerse cargo del marketing.

Von Hippel (2005) introduce un actor más a la innovación abierta propuesta por Chesbrough (2003) ya que considera que la innovación se está democratizando, es decir que los usuarios de productos y servicios, tanto empresas como consumidores individuales, son cada vez más capaces de innovar por sí mismos. Los procesos de innovación centrados en el usuario ofrecen grandes ventajas sobre los sistemas de desarrollo de innovación centrados en el fabricante que han sido el pilar del comercio durante cientos de años.

En las investigaciones consideradas en su trabajo, Von Hippel (2005) identifica que muchos de los productos más importantes y novedosos de una amplia gama de campos han sido desarrollados por empresas usuarias y usuarios particulares. La mayoría de los productos son desarrollados por usuarios que están a la vanguardia de una o varias tendencias importantes del mercado, y por lo tanto están experimentando necesidades que luego experimentarán muchos usuarios en ese mercado y anticipan beneficios relativamente altos al obtener una solución a sus necesidades y, por lo tanto, pueden innovar (Von Hippel, 2005).

El desarrollo de productos y servicios por parte de los usuarios se ve impulsado por dos tendencias técnicas relacionadas entre sí: la mejora constante de las prestaciones de diseño (conjuntos de herramientas de innovación) que los avances en el hardware y el software informáticos hacen posible para los usuarios y la mejora constante de la capacidad de los usuarios particulares para combinar y coordinar sus iniciativas de innovación a través de nuevos medios de comunicación como Internet (Von Hippel, 2005).

Las altas tasas de innovación de usuarios documentadas por Von Hippel (2005) sugieren que muchos usuarios pueden querer productos personalizados debido a que tienen necesidades diferentes, y muchos también tienen la voluntad suficiente de pagar y recursos suficientes para obtener un producto personalizado (Von Hippel, 2005).

Con respecto a la difusión de estas innovaciones, la investigación empírica demuestra que los usuarios consiguen a menudo una difusión generalizada debido a que revelan libremente lo que han desarrollado, es decir que el innovador cede voluntariamente todos los derechos de propiedad intelectual de esa información y que todas las partes interesadas pueden acceder a ella, de modo que la información se convierte en un bien público mismos (Von Hippel, 2005). Un ejemplo de esto son las prácticas de desarrollo de software de código abierto; en ese ámbito existe una política clara que establece que quienes contribuyen a un proyecto revelarán de manera libre, rutinaria y sistemática el código desarrollado por ellos con un coste privado (Raymond, 1999).

La innovación impulsada por los usuarios suele estar enormemente distribuida, en lugar de concentrarse en un número muy limitado de usuarios muy innovadores. Como consecuencia, es importante para los usuarios innovadores buscar formas de combinar y potenciar conjuntamente sus esfuerzos. Es frecuente la cooperación organizada a través de redes y comunidades que proporcionan estructuras y herramientas útiles para sus interacciones y para la distribución de las innovaciones. Las comunidades de innovación pueden aumentar la velocidad y la eficacia con las que los usuarios y también los productores desarrollan, prueban y difunden sus innovaciones. También permiten aumentar considerablemente la facilidad con la que los innovadores pueden construir sistemas más grandes a partir de módulos interconectables creados por miembros de la comunidad. Los proyectos de software de código libre y abierto son una forma de comunidad de innovación a través de Internet de gran éxito y relativamente bien desarrollada. Los productos, servicios y procesos desarrollados por los usuarios adquieren más valor para la sociedad si se dan a conocer de algún modo a otras personas que también puedan beneficiarse de ellos. (Von Hippel, 2005).

En la actualidad se está discutiendo acerca de las leyes de autor (Von Hippel, 2005; Pollock 2018). Mientras unos abogan por la reducción de la protección legal a los derechos de autor otros no sólo persiguen una mayor protección, apoyando leyes que penalicen el uso de estas nuevas tecnologías cuando violan sus derechos, sino que, además buscan extenderla en el tiempo. Los usuarios que divulgan libremente sus innovaciones pueden beneficiarse de un espaldarazo a su reputación, de efectos de red positivos debidos al incremento de la difusión de su innovación y de otros factores. Ser el primero en revelar libremente una innovación también aumenta en muchos casos los beneficios obtenidos, lo que puede generar cierta prisa por divulgar, como la que se da entre los científicos para publicar con el fin de disfrutar de las ventajas de ser el primero en realizar un avance concreto (Von Hippel, 2005). En esta línea Rufus Pollock (2017) muestra cómo la economía digital "cerrada" de hoy es la fuente de problemas que van desde una creciente desigualdad hasta el poder de un puñado de monopolios tecnológicos sobre innumerables cuestiones. Propone una solución que promueve el uso abierto de información sin cargo, incluyendo contenidos y datos online, proponiendo la sustitución total de los monopolios de propiedad intelectual tales como patentes y derechos de autor. Pollock (2017) parte de dos premisas: que el nivel de protección óptimo decrece a medida que caen los costos de producción, (y vice-versa) y, que el nivel de protección óptimo decae, en general, a medida que transcurre el

tiempo ya que se observa una "dramática y permanente caída en los costos de producción en casi todos los tipos de obras sujetas a protección intelectual", el crecimiento de internet y la caída de los precios de las tecnologías de copiado son las principales causas.

La información debe estar disponible para la mayor cantidad de gente posible, ya que la riqueza, la información y la oportunidad de crear están profundamente entrelazadas. Hoy en día, gran parte de esta información se encuentra, en la práctica, estrechamente controlada, a pesar de que podría ser legal y legítimamente compartida con todos. Está bajo derechos de autor y ley de patentes lo que limita su uso y obstaculiza la innovación aumentando artificialmente los precios o denegando el acceso completo (Pollock, 2017).

Un sistema abierto o plataforma permite que cualquiera pueda construir sobre lo construido, y así permite la máxima posibilidad de innovación. Internet y la web han sido las mayores plataformas de innovación de todos los tiempos en términos de cantidad, calidad y velocidad de lo que se ha construido sobre y alrededor de ellas, y en gran parte es debido a que no tienen un monopolio los controla.

El modelo abierto propuesto por Pollock (2017) consiste en una plataforma neutra democráticamente supervisada, que esté mediando entre usuarios y proveedores. Lo que se propone es la sustitución total de los monopolios de propiedad intelectual. Se reemplazarían cada uno de los principales derechos de propiedad intelectual (patentes y derechos de autor), con un derecho de remuneración similar. Las principales ventajas del modelo abierto son: el acceso universal a la información; el aumento de la innovación y la creatividad, la maximización del uso positivo de las capacidades de las tecnologías de la información; el aumento de la competencia; la finalización de los monopolios globales a través de varias formas de información; la reducción de las desigualdades de oportunidades y resultados y el aumento de la riqueza global (Pollock, 2017).

2.2. La Cultura Organizacional, factor primordial en la innovación

Hay diversos factores determinantes en las innovaciones, entre ellos la estructura organizacional, el tamaño de la empresa, los recursos humanos o la comunicación. En la actualidad uno de los factores que se considera primordial a la hora de impulsar una conducta innovadora por parte de los miembros en las organizaciones es la cultura organizacional (Naranjo Valencia, Saenz Valle & Jiménez Jiménez, 2014).

La Cultura organizacional es un factor clave que acompaña a la innovación debido que es la esencia misma de la organización ya que se refiere a los valores, las creencias, (Denison, 1990; Cameron & Quinn, 1999), las normas y los principios fundamentales que constituyen los cimientos del sistema gerencial de una organización (Denison, 1990). La cultura organizacional es un modo de vida, un sistema de creencias y valores, una forma aceptada de interacción y relaciones típicas de la organización (Chiavenato, 1995).

Según Denison et. Al. (2012) establecen que la cultura organizacional impacta en el desempeño empresarial mediante la creación de un sentido de misión y dirección, la construcción de un alto nivel de adaptabilidad y flexibilidad, por ello, la cultura organizacional puede estimular una conducta innovadora en los miembros de la organización, ya que puede lograr que los miembros acepten la innovación como un valor fundamental en la organización y se comprometan con ella. La cultura organizacional puede afectar el comportamiento de los trabajadores y puede fomentar o frenar la innovación en las empresas (Hartmann, 2006). La cultura es un determinante de la innovación (Naranjo Valencia, Saenz Valle & Jiménez Jiménez, 2014).

Partiendo del concepto que la cultura organizacional es un determinante para la innovación, se deben identificar los factores, tipos de cultura o valores culturales, que estimulan o inhiben la innovación. Si se toma como referencia el Modelo de Valores de Competencia de Cameron y Quinn (1999), se definen cuatro tipos de cultura teniendo en cuenta 2 dimensiones. Las dimensiones son la estabilidad y control versus la flexibilidad y la discreción, y, por otro lado, el Foco en el interior de la organización, esto es que la empresa tenga una orientación interna donde se preocupa principalmente por sus colaboradores versus el Foco en el exterior, que implica una orientación externa hacia los clientes, proveedores y contexto en general.

Combinando estas dos dimensiones, se definen 4 tipos de cultura organizacional, jerárquica, clan, de mercado y adhocrática y cada una de ellas tienen rasgos que las caracterizan: que características dominan en la organización, el tipo de liderazgo organizacional, la gestión del personal o de recursos humanos, el vínculo organizacional, el énfasis estratégico y el criterio de éxito (Cameron & Quinn, 1999).

La cultura clan refuerza la flexibilidad y tiene orientación interna es decir que enfatiza el desarrollo humano, el trabajo en equipo, la participación de los trabajadores y el compromiso de todos con la organización. Además, el papel del líder, como tutor y protector de todos, es fundamental. Existe un compromiso corporativo hacia los empleados.

Una cultura adhocrática enfatiza la flexibilidad y el cambio, pero su orientación no es interna como el clan sino externa. Este tipo es propio de las empresas que operan en contextos dinámicos y que buscan ser líderes en el mercado y que operan en una situación de cambio permanente. En consonancia, son valores importantes en esta cultura la iniciativa, la creatividad, el espíritu emprendedor y la asunción de riesgos.

Una cultura de mercado pone el énfasis en lo externo, pero requiere estabilidad y control para lograr mejoras en su productividad y competitividad. Potencia principalmente el cumplimiento de objetivos, la consistencia y la competitividad.

Por último, la cultura jerárquica tiene una orientación interna, como la cultura clan, pero al contrario que esta última, busca la estabilidad y el control. Sus valores más importantes son la eficiencia, el cumplimiento de las normas, reglas y regulaciones y la formalización de los procesos, así como la estabilidad en el empleo.

En la figura mostrada a continuación se visualizan los tipos de cultura según Cameron & Quinn (1999).

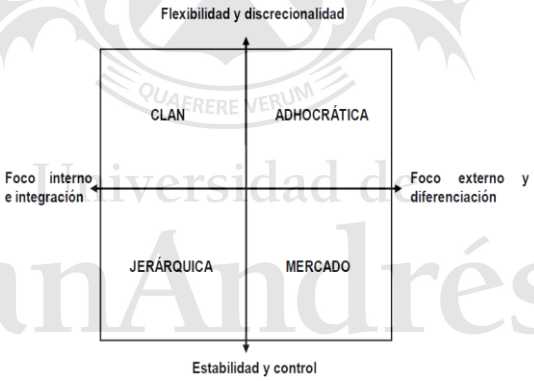

Figura 1. Modelo de Valores de Competencia

Esta figura representa los tipos de cultura organizacional según Cameron y Quinn (1999).

Para identificar qué tipos de cultura estimulan mejor la innovación se deben analizar las dimensiones del modelo de Cameron & Quinn (1999). Con respecto a la Flexibilidad vs Estabilidad y control, inicialmente cabe esperar que mientras una cultura sea más flexible más estimulará la innovación. La creatividad e iniciativa, la autonomía y la asunción de riesgos son difíciles de potenciar cuando una empresa pone el énfasis en la estabilidad y el control, “una cultura que fomente a flexibilidad favorecerá el desarrollo de la innovación en la empresa” (Naranjo

Valencia, Sáenz Valle & Jiménez Jiménez, 2014). También se considera que las organizaciones más orgánicas, es decir más flexibles, favorecen la innovación mientras que las más mecanicistas la dificultan (Naranjo Valencia, Sáenz Valle & Jiménez Jiménez, 2014) debido a alta formalización y centralización (Burns & Stalker, 1961). Cuando menos centralizado está, se fomenta el desarrollo y el aprendizaje de los miembros de la organización lo que las hace más capaces de asumir los riesgos asociados a la innovación. La existencia de reglas y regulaciones sobre las actividades también limita la capacidad de adaptación al cambio. Por todo esto, las culturas organizacionales orientadas a la flexibilidad favorecen la innovación y las orientadas a la estabilidad la dificultan (Naranjo Valencia, Sáenz Valle & Jiménez Jiménez, 2014).

Con respecto a la dimensión orientación interna vs. externa, varios autores señalan que las culturas con énfasis en lo interno podrían provocar una falta de atención a los cambios en el mercado, que son condición necesaria de los procesos de innovación. Y por otro lado plantean que las empresas con énfasis en el exterior tienen más probabilidades de obtener información del entorno (clientes, proveedores, contexto en general) que facilita la generación de innovaciones en la empresa (Naranjo Valencia, Sáenz Valle & Jiménez Jiménez, 2014).

Debido a que la flexibilidad y la orientación externa son lo que caracterizan a las culturas adhocráticas, este tipo de cultura es la que más estimula la innovación. La cultura organizacional que estimula los procesos innovadores es aquella que entiende que la información que se incorpora del exterior es una oportunidad, que puede lidiar con la incertidumbre, que mejora las comunicaciones y la toma de decisiones, que empuja a los empleados a ser más independientes y aquella que favorece la creatividad, la cooperación y la innovación.

2.3. El Liderazgo como facilitador del cambio

Actualmente los cambios del entorno son más rápidos e impredecibles, y éstos demandan a las organizaciones una mejor capacidad de adaptación. Usualmente los cambios en el entorno ocurren de manera inesperada (permeando a la sociedad en general, la economía, la industria, las funciones de negocios entre otras) y en muchas ocasiones las organizaciones no están preparadas para asumir sus efectos. La gestión del cambio en las organizaciones implica que el líder promueva procesos que aseguren la flexibilidad de la organización para perdurar ante los cambios (Hruska, Rasic & Bakovic, 2010). La escasa capacidad de adaptación a los cambios tiene efectos

devastadores sobre el desempeño organizacional e incluso puede amenazar su existencia (Bovey & Hede, 2001).

Son los líderes los responsables de promover una cultura organizacional que estimule la innovación. Según Schein (1992) los líderes son creadores y sustentadores de la cultura organizacional y también son los artífices del cambio organizacional. El proceso de creación de cultura tiene lugar de tres modos: los empresarios solamente contratan y conservan a los subordinados que piensan y sienten del mismo modo que ellos; los empresarios adoctrinan a sus subordinados y los adaptan a su modo de pensar y de sentir y por último el propio comportamiento de los empresarios es un modelo de misión que alienta a los subordinados a identificarse con ellos y de ese modo interiorizar sus convicciones, valores y suposiciones.

En los momentos de cambio los líderes tienen que empezar a pensar como artífices del cambio. Es responsabilidad del líder planificar los cambios y demostrar que son necesarios (Ajzen, 1991). El rol del líder es primordial y su responsabilidad como agente de cambio es asegurar un resultado positivo (Kotter, 1995). Con este objetivo claro los líderes deben evaluar y prever la posible resistencia que se puede generar, la cual indudablemente va a depender del compromiso de los trabajadores con los procesos organizacionales y del sentido de control que éstos tengan respecto a las oportunidades, recursos y habilidades necesarias para asumir el cambio (Ajzen, 1991). El problema no consiste solamente en que los trabajadores deben adquirir nuevos conceptos y destrezas sino también en cómo desaprenden las cosas que ya no son útiles para la organización. Desaprender es un proceso totalmente distinto, que implica ansiedad, actitudes defensivas y resistencia al cambio (Schein, 1992).

Los líderes que sean artífices del cambio que se hallan en una organización madura que ha desarrollado procesos de cambio, necesitan poseer dos características particulares: en primer lugar, tienen que tener la fuerza emocional necesaria para apoyar la organización al mismo tiempo que se enfrentan con las ansiedades que acompañan al desaprendizaje de los procesos que previamente tuvieron éxito; y en segundo lugar, necesitan una verdadera comprensión de la dinámica cultural y las características de su propia cultura organizacional (Schein , 1992). Deben conocer claramente la organización, comprender la cultura, las creencias, los valores, el clima y la identidad organizacional, para poder construir vínculos en sus diferentes niveles y dimensiones, que potencien la comunicación y fortalezcan la creatividad y la innovación. El estilo de liderazgo y el clima organizacional pueden afectar la implementación de los cambios y como consecuencia

influir sobre la forma en que los miembros de la organización reaccionan ante él (Van Dam, Oreg & Schyns, 2008).

Los líderes deben desarrollar la cultura edificando sobre sus puntos fuertes al tiempo que permiten que con el tiempo se atrofien sus puntos débiles. La cultura se ensancha (cambia) a través de los cambios en conceptos clave de los modelos mentales de las personas que son los principales vehículos de la cultura y que han sido parte de los éxitos obtenidos haciendo las cosas de cierta manera y ha desarrollado modelos mentales basándose en dichos métodos. Para que la cultura pueda ensancharse y ampliarse se necesita un cambio genuino en el comportamiento del líder, y la incorporación de nuevas definiciones en los procesos y hábitos organizacionales (Schein, 1992).

Para enfrentar los nuevos cambios son necesarios líderes transformacionales en contraposición a los líderes transaccionales (o burocráticos) que están más orientados a llevar adelante cambios planificados (Bass, 1985). Los líderes transaccionales son aquellos que utilizan el poder, recompensando o sancionando a los trabajadores en función de su rendimiento; no van más allá de las tareas y se limitan a mantener el flujo normal de las operaciones en la organización, sin tendencia al desarrollo. Este tipo de liderazgo resulta funcional y efectivo en el contexto de empresas tradicionales, ya que éstas buscan líderes que planeen y generen estrategias que garanticen el cumplimiento estricto de los procesos que conduzcan a los resultados deseados (Contreras y Barbosa, 2013). Es un estilo instruccional y directivo que premia los comportamientos esperados cuando el cambio está orientado hacia la búsqueda de la eficiencia mediante la reducción máxima del riesgo, lo cual se refuerza a través del reconocimiento a las personas cuando se logran las metas preestablecidas por el líder. El liderazgo transaccional se concentra principalmente en motivar a los trabajadores a través de la relación que se establece por la posición que tienen dentro de la organización (jefes y subordinados) (Bass, 1985).

Los líderes transformacionales, en cambio, van más allá de las tareas. Este tipo de liderazgo está centrado en el papel del líder como un agente del cambio, que promueve el compromiso y motiva al equipo, concentrándose en las cualidades intangibles buscando generar relaciones; también se fundamenta en los valores, creencias y cualidades personales tanto del propio líder como de los seguidores (Varela, 2010). Las cualidades carismáticas de estos líderes se incrementan en momentos en que las organizaciones atraviesan procesos de transformación importantes que potencialmente comprometen la supervivencia o el desarrollo de la organización (Yukl, 2002). Estos líderes proporcionan mejores resultados organizativos, a través del carisma, la inspiración y

la búsqueda del interés de la organización (Lupano Perugini & Castro Solano, 2008). Durante los tiempos de cambio e incertidumbre este líder visionario, logra incidir en la percepción de éxito por parte de los colaboradores lo que incrementa la motivación, la dedicación y el compromiso de los colaboradores que constituyen aspectos particularmente importantes en momentos de cambio caracterizados por la inestabilidad y la escasa posibilidad de predicción. Por otra parte, estos líderes suelen canalizar mejor la incertidumbre y los temores de las personas en cuanto infunden confianza y generan entusiasmo a través de la visión y el logro de metas; poseen carisma (influencia idealizada), estimulación intelectual, consideración.

Según Varela (2010) este modelo de liderazgo presenta un gran número de ventajas, ya que el líder se convierte en un modelo a seguir, se desarrolla una colaboración cooperativa en la que se desarrollan las habilidades socio-personales, aumentando la autoestima de ambos, líder y seguidores, por consiguiente, conlleva mejores resultados y beneficios para la organización. Pero este tipo de liderazgo también tiene ciertas limitaciones debido a que necesitan tiempo para crear una situación de confianza con los seguidores, por lo que los resultados se suelen obtener a largo plazo. A pesar de ello, el liderazgo transformacional tiene un gran impacto en los seguidores, ya que se logra una visión compartida, a través del de la cooperación y la innovación, los cuales benefician tanto a la empresa como a los mismos colaboradores. Los líderes transformacionales intentan crear una cultura de organización promoviendo compromiso, lealtad y motivación tanto individual como grupal (Contreras y Barbosa, 2013).

Entonces, la supervivencia de las organizaciones, su sustentabilidad y competitividad, depende en gran medida de su posibilidad de cambio, su capacidad de adaptación a las demandas del entorno, de su flexibilidad para afrontar la incertidumbre y su capacidad de respuesta de su cultura lo cual, a su vez, depende de la forma en que las organizaciones son lideradas (Kotter, 1995; Schein, 1992).

3. Capítulo III.

Entendiendo la Inteligencia Artificial y el Aprendizaje Automático

En el capítulo anterior se desarrollaron los conceptos principales de innovación y adopción de tecnologías y los factores clave para su desarrollo, como capítulo introductorio general a los conceptos primordiales para el desarrollo de las organizaciones actuales teniendo en cuenta las innovaciones tecnológicas.

En este capítulo se tratan y profundizan los conceptos de una de las variables estudiadas en este trabajo, Inteligencia Artificial en general y aprendizaje automático en particular con el objetivo de entender los conceptos básicos pero principales. Además, se analizan las causas del florecimiento de estas tecnologías y se profundiza sobre el estado actual del desarrollo, la adopción, y los impactos social y económico lo que ayuda a entender la oportunidad de IA y AA a través del estado actual del desarrollo de estas tecnologías.

3.1. Conceptualización de Inteligencia Artificial

La incorporación de tecnologías de avanzada en la producción, la velocidad de los cambios y la convergencia y combinación de múltiples tecnologías de avanzada está permitiendo la transformación digital produciendo eficiencias operativas (reducción de costos), mejora de productividad y nuevas oportunidades y modelos de negocio. Entre las tecnologías que comprenden la cuarta revolución industrial o la tercera ola se puede identificar: *Big data/Analytics*, Internet de las Cosas, *Robotics*, Impresión 3D e Inteligencia Artificial y el aprendizaje automático como estandarte de esta última. El detalle de este análisis se encuentra en el Anexo VI.

Dentro de las tecnologías de la cuarta revolución digital inteligencia artificial aporta un componente crítico que es la predicción (Agrawal, Gans & Goldfarb, 2018), que constituye un valor fundamental en la toma de decisiones. Estas máquinas que predicen son tan valiosas porque pueden realizar mejores predicciones, más rápidas y más baratas que las que realizan los humanos (Agrawal, Gans & Goldfarb, 2018; Brynjolfsson & McAfee, 2017. La IA ofrece, por un lado, decisiones, es decir, conclusiones alcanzadas a partir de la deliberación algorítmica basada en los datos disponibles y por otro, soluciones, es decir cursos alternativos de acción para resolver un problema (Von Krogh, 2018). Las empresas generan una enorme cantidad de datos que, gracias a estos nuevos sistemas computacionales y algoritmos avanzados, pueden ser procesados y analizados minimizando el esfuerzo humano. Esto permite descentralizar la toma de decisiones, y

pasar de modelos preventivos a modelos predictivos que pueden aplicarse en todas las áreas de la organización (Basco et al., 2018).

La IA es el único campo que persigue la construcción de máquinas que funcionen automáticamente en medios complejos y cambiantes (Russell & Norvig, 1995). Este campo no sólo intenta comprender, sino que también se esfuerza en construir entidades inteligentes. No existe una única definición simple de IA (En el Anexo VII se muestra un compilado de algunas definiciones). El concepto de IA es lograr un comportamiento inteligente semejante al humano; sin embargo, dentro de la IA también se estudian aquellos problemas que les resultan difíciles incluso a los humanos. Las motivaciones que han llevado al estudio de la IA son en primer lugar la resolución de los problemas y en segundo la emulación del comportamiento humano.

Stuart Russell y Peter Norvig (1995), autores del ya clásico texto dentro de este campo, *Artificial Intelligence: A Modern Approach (AIMA)*, compilan las definiciones de Inteligencia Artificial en cuatro tipos: los Sistemas que piensan como humanos que son aquellos que intentan emular el pensamiento humano, como, por ejemplo, las redes neuronales artificiales; los Sistemas que actúan como humanos que imitan el comportamiento humano, como hace la robótica; los Sistemas que piensan racionalmente que tratan de imitar o emular el pensamiento lógico racional del ser humano, en la línea de los sistemas expertos y los Sistemas que actúan racionalmente que tratan de emular de forma racional el comportamiento humano, algo que hacen los agentes inteligentes (Russell & Norvig, 1995).

Rao & Verweij (2017) plantean una interesante definición y clasificación, define que la IA es un término colectivo para los sistemas informáticos que pueden detectar su entorno, pensar, aprender y actuar en respuesta a lo que perciben y sus objetivos; y los clasifica en: inteligencia automatizada que es la automatización de tareas manuales / cognitivas y rutinarias / no rutinarias; la inteligencia asistida que consiste en ayudar a las personas a realizar tareas más rápido y mejor; la inteligencia aumentada que ayuda a las personas a tomar mejores decisiones y la inteligencia autónoma que consta de la automatización de los procesos de toma de decisiones sin intervención humana.

3.2. Florecimiento de la Inteligencia Artificial ¿Por qué ahora?

Si se analiza la historia de la IA (Anexo VIII) se puede identificar que este es un concepto que tiene aproximadamente 70 años y que tuvo altibajos, pasando por etapas denominadas

"inviernos" en las cuales sólo algunos equipos de investigadores continuaron con sus trabajos. Pero en los últimos años el uso y aplicación de IA ha tenido un auge exponencial y según Brynjolfsson & McAfee (2017) finalmente está comenzando a ofrecer beneficios en la vida real. Esto se debe a que se unieron varios factores, principalmente: el crecimiento significativo del poder de procesamiento de las computadoras, potenciado por la disminución de su costo, la sofisticación de los algoritmos y, quizás lo más importante de todo, la generación de vastas cantidades datos que es lo que alimenta a la IA, miles de millones de gigabytes de nuevos datos todos los días (Mckinsey, 2017a; Jordan & Mitchell, 2015). Muchos expertos creen que el factor más importante ha sido el aumento en la capacidad de procesamiento y la disminución de los costes de este. Las redes neuronales se vuelven mucho más poderosas y capaces a medida que aumenta su tamaño, y solo recientemente las redes suficientemente grandes se han vuelto lo suficientemente baratas como para que estén disponibles para muchos investigadores. La implantación de la computación en la nube ha permitido bajar los costos lo que ayudó a abrir el campo de la IA a investigadores con menos presupuestos (Brynjolfsson & McAfee, 2017).

Otra indiscutible causa es el volumen de información producida que crece a una velocidad vertiginosa de casi un 30% al año (CEPAL, 2018a). Hay un diluvio global de datos que en un 80% no se encuentra estructurado (como los de texto, audio, video e imágenes) (Estevadeordal et al., 2018). Todos estos datos documentan la vida de las personas y mejoran la comprensión humana del mundo. A medida que se introducen billones de sensores los datos se harán cada vez más grandes. El procesamiento de toda esta información asistido por IA permite utilizar estos datos, entre otras cosas, para descubrir patrones históricos y realizar predicciones más eficientes y recomendaciones más efectivas (Estevadeordal et al., 2018). Ante la explosión de la información digital, el manejo de la información por los seres humanos resulta imposible, la única manera de gestionarla es mediante el uso de tecnologías digitales (CEPAL, 2018a). Lo mismo expresa Murphy (2012), que considera que el diluvio de datos requiere métodos automatizados de análisis, que es lo que proporciona el aprendizaje automático. Esta amplia disponibilidad de datos dio lugar a grandes avances en el campo de la IA. Por ejemplo, las redes neuronales profundas (*Deep Neural Networks*) permitieron reducir la tasa de palabras equivocadas (*Word error rate* (WER)) en el reconocimiento de voz del 26% al 4% en solo cuatro años (entre 2012 y 2016) (Lee, 2016). La explosión de texto ha sido casi tan importante para el aprendizaje automático como la ley de Moore ya que al igual que un niño pequeño necesita escuchar muchas palabras y oraciones para aprender

el lenguaje, los sistemas de aprendizaje automático deben ser expuestos a muchos ejemplos para mejorar el reconocimiento de voz, la clasificación de imágenes y otras tareas, y en la actualidad existe un suministro interminable de este tipo de datos (Brynjolfsson & McAfee, 2017).

A estos factores, el Word Economic Forum (2018) suma el liderazgo de las IA que actualmente está siendo encabezado por tecnólogos en lugar de académicos ya que los ingenieros de software están creando aplicaciones reales a la par del mundo real con innumerables casos de uso exitosos.

Otro factor que ha sido un gran impulso para el aprendizaje automático es la popularidad de los videojuegos modernos. Las unidades especializadas de procesamiento de gráficos (GPU) que manejan las consolas de juegos populares resultan extremadamente adecuadas para los tipos de cálculos necesarios para las redes neuronales (Brynjolfsson & McAfee, 2017).

Por último, en las dos últimas décadas se ha producido avances significativos en la ciencia y la tecnología que subyace en los métodos de IA, por ejemplo, largas unidades de memoria a corto plazo, las redes neuronales recurrentes, y redes neuronales convolucionales (Von Krogh, 2018).

Estevadeordal et al. (2018) suman algunos otros factores: el mundo interconectado, donde las plataformas de las redes sociales han cambiado de un modo fundamental la forma en que interactúan los individuos. Esta creciente conectividad ha acelerado la difusión de la información (ver el concepto de difusión en el Anexo V) y ha alentado la socialización del conocimiento, lo que llevó al surgimiento de una inteligencia colectiva, que incluye comunidades de código abierto que desarrollan herramientas de IA y comparten aplicaciones, tal lo identificado por Von Hippel (2005) en el capítulo anterior. También mencionan otro factor, el Software y los datos de dominio público que están acelerando la democratización y el uso de la IA; que se ve reflejado en la popularidad de las plataformas y los estándares de Aprendizaje Automático de código abierto (Von Hippel 2005, Estevadeordal et al., 2018). Finalmente, agregan el factor de los rendimientos acelerados, las presiones competitivas que han motorizado el desarrollo de la IA, ya que las empresas han utilizado los algoritmos y el software de código abierto para impulsar sus ventajas competitivas y aumentar sus rendimientos, por ejemplo, a través de una mayor personalización de los bienes de consumo o utilizando la automatización inteligente para incrementar su productividad.

3.3. La inteligencia artificial actual: el Aprendizaje Automático

Hoy en día, los términos aprendizaje de máquina e inteligencia artificial se han vuelto casi equivalentes (CEPAL, 2018a).

Uno de los principales objetivos de los modernos sistemas de IA es distinguir y extraer patrones de datos sin procesar para construir su propio conocimiento. Agrawal, Gans y Avi Goldfarb (2018) en su libro "*Prediction Machines*" las llama precisamente las máquinas de predicción. El objetivo mencionado de generar sus propios patrones de datos deriva de las dificultades que surgen con el enfoque basado en el conocimiento para el aprendizaje artificial. El enfoque tradicional, implementado por sistemas expertos, apunta a codificar (*hard code*) el conocimiento sobre el mundo en lenguajes formales, de manera que las computadoras usen reglas de inferencia lógica para razonar en esos lenguajes (Goodfellow, Bengio y Courville, 2016). Este enfoque es limitado porque las personas no pueden establecer reglas formales que puedan detectar y representar con precisión sutilezas en el sistema de lenguaje. Por lo tanto, la solución actual no es trabajar con una base de conocimiento sino aprender conocimiento. La capacidad de la IA para construir su propio conocimiento se conoce como aprendizaje automático (AA) o *Machine Learning* (ML) y permite que las computadoras resuelvan problemas que requieren cierta comprensión del mundo real y tomen decisiones que parecen ser situacionales y subjetivas. El AA se puede definir como un método para diseñar una secuencia de acciones para resolver un problema, conocido como algoritmos que optimizan automáticamente a través de la experiencia y con una limitada intervención humana o no. Estas técnicas se pueden utilizar para encontrar patrones en grandes cantidades de datos de fuentes cada vez más diversas e innovadoras.

En contraste con los sistemas expertos basados en el conocimiento de la década de 1980, los nuevos sistemas adoptaron un enfoque de aprendizaje mucho más parecido al de los niños, que aprenden por medio de ejemplos y no de reglas (Brynjolfsson & McAfee, 2017). Los sistemas expertos se centraron en automatizar los conocimientos adquiridos por los humanos e incorporar las reglas resultantes en el código.

Arthur Samuel (1959) fue el primero que acuñó la frase "*machine learning*", definió al aprendizaje automático como el "campo de estudio que da a las computadoras la capacidad de aprender sin ser programados de forma explícita", mientras que Tom Mitchell (1997) lo define como "la cuestión de cómo construir equipos que mejoran automáticamente a través de la experiencia". Murphy (2012) lo considera como un conjunto de métodos que pueden detectar

automáticamente patrones en los datos, y luego usar los patrones descubiertos para predecir datos futuros, o para realizar otros tipos de toma de decisiones bajo incertidumbre.

Otra de las características del aprendizaje automático es que permite que la máquina mejore el rendimiento a medida que crece su experiencia. Se puede ver al aprendizaje automático como un intento de descubrir relaciones entre variables, donde dados los patrones históricos (entrada y salida), la máquina pronostica resultados fuera de la muestra. El aprendizaje automático también puede verse como una forma independiente del modelo (o estadística o basada en datos) para reconocer patrones en grandes conjuntos de datos de experiencia (Kolanovic & Krishnamachari, 2017). La computadora recibe una entrada (conjunto de variables y conjuntos de datos) y una salida que es una consecuencia de las variables de entrada. La máquina encuentra o "aprende" una regla que vincula la entrada y la salida. En última instancia, el éxito de esta tarea de aprendizaje se prueba "fuera de muestra": su capacidad para obtener un conocimiento útil de la relación entre las variables y predecir los resultados en situaciones aún no vistas (Kolanovic & Krishnamachari, 2017).

Los componentes principales del aprendizaje automático se pueden clasificar en cuatro grupos: las fuentes de información, que pueden aportar datos, tanto estructurados como no estructurados, y que son la base del resto de componentes; las técnicas y algoritmos para el tratamiento de la información no estructurada (texto, voz, video, etc.) y para la obtención de patrones a partir de los datos; el uso de sistemas y software como vehículo para la visualización de la información y la programación.

El aprendizaje automático incluye una amplia clase de estadísticas y técnicas informáticas para mejorar el desempeño de la realización de una tarea desde alguna experiencia (Mitchell, 1997). Las técnicas de aprendizaje automático pueden definirse como un conjunto de métodos capaces de detectar automáticamente patrones de datos (Murphy, 2012). Hay varias categorías de algoritmos de aprendizaje automático. Estas categorías varían según el nivel de intervención humana requerida en el etiquetado de los datos. Murphy (2012) divide en 2 principales tipos: Predictivo o Supervisado y Descriptivo o No supervisado. Hay un tercer tipo de aprendizaje, denominado por Refuerzo, este tipo cae en el medio de aprendizaje supervisado y no supervisado. En este caso, el algoritmo se alimenta un conjunto de datos sin etiqueta, elige una acción para cada punto de datos, y recibe retroalimentación (tal vez de un ser humano) que ayuda a aprender al algoritmo. Por ejemplo, el aprendizaje por refuerzo se puede utilizar en la robótica, la teoría de

juegos, y los coches autoconducción. Según Murphy (2012) este tercer tipo de aprendizaje automático es útil para aprender cómo actuar o comportarse cuando se dan señales ocasionales de recompensa o castigo. Las redes neuronales han tenido sus mejores éxitos con el aprendizaje supervisado, en el que los ejemplos de aprendizaje son etiquetados. Pero han hecho solo un pequeño progreso con el aprendizaje no supervisado, que es la principal manera en que los humanos aprenden sobre el mundo (Brynjolfsson & McAfee, 2017).

Hay un último tipo de aprendizaje, el profundo, que es un método de aprendizaje automático que analiza los datos en múltiples niveles de aprendizaje. Utiliza algoritmos que trabajan en "capas" inspiradas en la estructura y en la función del cerebro. Puede comenzar a hacerlo aprendiendo sobre conceptos más simples y combinando estos conceptos para aprender sobre conceptos más complejos y nociones abstractas (Kolanovic & Krishnamachari, 2017). El aprendizaje profundo presenta un marco general para el uso de grandes conjuntos de datos para optimizar el rendimiento predictivo. Como tales, los marcos de aprendizaje profundo son adecuados para muchos problemas, tanto prácticos como teóricos, por ejemplo, en finanzas (Heaton, Polson & Witte, 2016). Los detalles de los tipos de aprendizaje automático se detallan en el anexo IX.

3.4. Perspectivas de la Adopción de Inteligencia Artificial y Aprendizaje Automático en la actualidad

Son muchos los referentes que sitúan a la IA en un estadio temprano de adopción, aunque perciben su desarrollo de forma muy rápida. Esto se debe a que mejoran a medida que se hacen más grandes, corren sobre hardware más rápido y más especializado, ganan acceso a más datos y contienen algoritmos mejorados (McKinsey 2017a; Katz, 2017; Brynjolfsson & McAfee, 2017; Accenture, 2017; Word Economic Forum 2018). A nivel mundial, son cada vez más las empresas que implementan tecnologías de la industria 4.0 para lograr incrementos de productividad y para conseguir una mejora en su posición competitiva, aunque se observan importantes diferencias entre los países (OECD, 2016).

Tanto el desarrollo como la adopción de IA (como las demás tecnologías de la tercera ola de digitalización) se encuentran en curso de desarrollo y adopción, pero que la difusión por toda la economía y lograr que sus efectos en la productividad se realicen plenamente podría llevar un

tiempo considerable, aún incierto (OECD, 2016), Katz (2017) asevera que el impacto social y económico se daría a partir del 2020.

De acuerdo a lo planteado por Katz (2017) y la OECD (2016), también McKinsey (2017a) confirma que las tecnologías de IA han avanzado significativamente en los últimos años pero que la adopción, sin embargo, permanece en su etapa temprana, según su Índice de Adopción de IA (ver Anexo X). Esto también hace que sea difícil evaluar el verdadero impacto potencial de la IA en las empresas y sectores (Katz, 2017; McKinsey, 2017a).

Según Gartner (2018), el aprendizaje profundo y el aprendizaje automático alcanzarán la adopción general dentro de dos a cinco años. Muchos de los tratamientos de IA como Robots Inteligentes, Asesores Expertos, Cognitivos y *Machine Learning* se encuentran en el pico de expectativas de tecnologías emergentes, para su consideración en los próximos cinco (5) años (Ver Anexo XI).

Dentro de los sectores más propensos a adoptar rápidamente la IA se encuentra el sector financiero (McKinsey 2017a; McKinsey, 2017c). Este sector presenta los de casos de uso de alto potencial como, por ejemplo, la personalización de los productos financieros y la identificación de transacciones fraudulentas, prevención de fraude y realizar evaluaciones crediticias, casos de uso que se desarrollan en el capítulo V. Los casos de uso con mayor potencial por industria se detallan en el Anexo XII

En general, pocas empresas han incorporado la IA en sus cadenas de valor a escala; la mayoría de las empresas que tienen conocimiento de las tecnologías de inteligencia artificial pero todavía se encuentran en fases experimentales o piloto (McKinsey, 2017a; Gartner, 2018; Accenture, 2017b).

McKinsey (2017a) plantea seis características del patrón inicial de adopción de la IA, que está ampliamente en línea con las formas en que las compañías han estado adoptando y utilizando las tecnologías digitales. La primera característica es que los primeros usuarios de la IA son de sectores que ya están invirtiendo a gran escala en tecnologías relacionadas, como servicios en la nube (Cloud Computing) y Big Data. En segundo lugar, independientemente de los sectores, las grandes empresas tienden a invertir en IA más rápido a escala. Las grandes empresas tienen tasas de adopción más altas. En todos los sectores, las empresas más grandes, son al menos un 10% más propensas que las empresas más pequeñas a adoptar al menos una tecnología de IA a escala o en una parte central de su negocio. Tercero, los primeros usuarios no se están especializando en un

tipo de tecnología. Se amplían a medida que adoptan múltiples herramientas de IA que abordan varios casos de uso diferentes al mismo tiempo. Cuarto, las compañías que invierten a gran escala lo hacen cerca de su negocio principal. En quinto lugar, los adoptantes tempranos (ver definición en Anexo V) que implementan a escala, tienden a estar motivados tanto por el potencial de crecimiento alcista de IA como por la reducción de costos. Finalmente, en el sexto lugar, un liderazgo ejecutivo fuerte va de la mano con una adopción de IA más fuerte.

Un factor que puede ayudar a entender la importancia y crecimiento que está teniendo esta tecnología más allá de la adopción, es la inversión y el gasto que las empresas incurren en esta tecnología. En el primer caso, se identifica un crecimiento importante y sobre todo el foco de esa inversión se encuentra en aprendizaje automático (McKinsey, 2017a). También los analistas de la industria de TI coinciden en que el tamaño del mercado para la tecnología de IA experimentará un fuerte crecimiento en los próximos tres años (detalle en el Anexo XIII) (McKinsey, 2017a).

QUAERERE VERUM
Universidad de
SanAndrés

4. Capítulo IV. La Banca y la transformación digital

En este capítulo se aborda otra de las variables determinadas como objetivo de estudio que lo conforma la Banca tradicional privada. El foco de análisis se establece sobre su situación actual ante los factores que acarrean la transformación digital entre los que se pueden mencionar los nuevos consumidores y los nuevos competidores. Además, se analiza la situación actual de la banca en función del impacto de la disrupción y los retos competitivos que tiene en la actualidad. Finalmente se aborda la colaboración como eje de las nuevas estrategias que están adoptando los bancos tradicionales privados ante la disrupción del sistema financiero.

4.1. Impacto de la disrupción en el Sistema Financiero

Los avances en curso en las telecomunicaciones y la tecnología informática han sido una fuerza importante en la transformación de las finanzas. Los avances tecnológicos han mejorado mucho la calidad y la velocidad de procesamiento y han ayudado a reducir los costos de información y otros costos de transacción. Estos desarrollos han tenido implicaciones tanto para los proveedores como para los usuarios de productos y servicios financieros (OEDC, 2018).

Al masificarse la difusión de las tecnologías digitales, surgen innovaciones en aplicaciones y servicios en todos los sectores económicos. El mayor acceso a teléfonos móviles y la migración a teléfonos inteligentes han impulsado el desarrollo de soluciones en plataformas móviles que apuntan a enfrentar problemas sociales. El acceso a servicios financieros se está masificando mediante el uso del dinero móvil, especialmente importante en los países con baja bancarización (CEPAL, 2018b).

Las tecnologías digitales y sus aplicaciones están resultando en costos mucho más bajos de interacción y le dan menor importancia a la proximidad geográfica. La importancia de los lugares físicos para proporcionar estas funciones, tales como las sucursales bancarias, se ha reducido considerablemente para muchos tipos de transacciones financieras como por ejemplo para pagos. En algunos escenarios futuros concebibles, la viabilidad económica de los modelos de negocio tradicionales vinculados a estos servicios es altamente cuestionable. El problema de estas infraestructuras, especialmente las redes de sucursales físicas de los bancos tradicionales comerciales, es que son muy costosos para establecer y mantener (King, 2018). Los bancos grandes generalmente gastan hasta el 65% de los costos relacionados con la banca minorista en el mantenimiento de sucursales bancarias y los gastos del personal asociado en las sucursales (Frost

&Sullivan, 2016). A pesar de los avances hoy todavía las redes de sucursales son los cimientos de los bancos, aunque existan estrategias de multicanalidad en las que los canales tratan de integrarse (Skinner, 2014).

Para muchos bancos, la plataforma de distribución es su red de sucursales, es su identidad de acceso, es la forma en que están incrustados en la comunidad, donde se siente su marca y es la forma en que miden la excelencia del cliente, la experiencia y el compromiso (King 2018). Pero existen tendencias de cambios de consumo por los diferentes canales de los servicios financieros, por ejemplo, en EE. UU., donde una alta tasa de clientes, el 30%, no había acudido a la sucursal bancaria en los últimos seis meses (ver detalle en el Anexo XIV).

Según King (2018) para 2025 la mayoría de las sucursales se volverán mucho más difíciles de sostener económicamente, ya que se está visualizando que los enfoques alternativos a la banca física ganan terreno, aunque en algunas regiones puede ser más incipiente. Esto se apalanca con lo que ocurre en América Latina que a pesar de las tendencias en canales digitales y de los avances en la oferta digital todavía muchos clientes utilizan los canales físicos tradicionales (detalle en el Anexo XV) (Anif, Felaban &CAF, 2018).

Ante esta amenaza los bancos de América Latina se encuentran en un estadio temprano de adopción de tecnologías digitales de avanzada, ya que la mayoría de los bancos tienen una cultura digital inmadura (Ver detalle en Anexo XVI), no ofrecen funciones digitales avanzadas ni recursos importantes dedicados en sus plataformas y productos de banca digital o lo que se puede considerar más desalentador, los bancos carecen tanto de visión global digital en la gerencia, así como de productos bancarios digitales avanzados. Ofrecen productos digitales básicos como banca en Internet y aplicaciones para teléfono móvil, pero no poseen capacidades más avanzadas vinculadas al posicionamiento digital de marca y a los bancos líderes digitales (Technisys, 2017).

Los cambios a los que se enfrentan los incumbentes del sistema financiero presentan una realidad que va a cambiar el contexto de los productos y servicios que brindan los bancos. King (2018) establece que los productos bancarios como se conocen van a desaparecer y cambiará completamente el concepto de cuenta bancaria, tarjeta de crédito, préstamos personales, entre otros. En el Anexo XVII se muestra la lista planteada por King (2018).

A medida que las tecnologías entran en juego y se van desarrollando y adoptando, el requisito de reducir los costos fijos y mejorar la agilidad en la prestación de servicios será mucho

mayor. Convertirse en líderes digitales es un verdadero desafío para los incumbentes del sistema financiero (King, 2018).

4.2. El nuevo consumidor de servicios financieros

El perfil del cliente de banca tradicional ha sufrido un proceso de cambio. En la actualidad el nuevo perfil de cliente está ligado a la tecnología, hace uso de ella en su día a día, está familiarizado con todos los avances tecnológicos y por tanto quiere aplicar este conocimiento no solo a sus tareas más rutinarias si no también algo tan complicado y delicado como la gestión de su patrimonio. La educación financiera juega un papel principal ayudando a los consumidores a entender mejor a los mercados financieros, a los productos y servicios que lo conforman, y la tecnología ha jugado un papel importante para el desarrollo de ese conocimiento. Al reducir los costos de búsqueda, las tecnologías han permitido a los consumidores financieros adquirir más fácilmente la información, no sólo sobre los productos y servicios alternativos, sino también acerca de los proveedores de estos servicios, y también sobre la calidad de la experiencia del cliente que ofrecen (OEDC, 2018).

Las tendencias sociales son un factor determinante en el cambio del perfil del cliente, el crecimiento de la clase media, la concientización sobre inclusión financiera, las soluciones personalizadas y por su puesto el crecimiento de la población de tipo Generación Y y Generación Z (Frost & Sullivan, 2016).

La Generación Y (*millennials*) es la primera generación nativa digital nacida en un mundo de tecnología. Esta población nativa digital aumenta cada vez más. Hay que tener en cuenta que hoy los *millennials* representan el mayor grupo de población en Estados Unidos, con más de 80 millones de personas y se calcula que para 2020 esa generación represente el 60% de los consumidores mundiales, por lo que sus hábitos impactan en la forma en la que se consumen muchos productos (Rojas, 2016). Y estas personas no piensan en sucursales, centros de llamadas, etc., ven a los canales digitales integrados a sus vidas. Los nuevos consumidores bancarios no tienen un comportamiento heredado basado en la banca y el comercio tradicionales (King, 2018). Los *millennials* se han acostumbrado al uso de las redes sociales y a los mercados electrónicos y esperan el mismo tipo de experiencia cuando se trata de comprar servicios financieros: transacciones en línea, a través de múltiples plataformas digitales y especialmente móviles, que puedan hacerse de manera simple y con la menor inversión de tiempo y costo posible (Rojas,

2016). Los *millennials* esperan que la banca funcione sin fricción y en tiempo real (King, 2018). Algunos datos que convalidan estos análisis se detallan en el Anexo XVIII.

Un factor adicional es la pérdida de confianza en las instituciones financieras tradicionales por parte de los *millennials*. Rojas (2016) comenta el *Millenial Disruption Index*, indica que el 75% de los *Millennials* responderían mejor a la oferta de servicio de Amazon, Google, Apple o PayPal que a la de un Banco. De hecho, un 33% piensa que no necesita un banco para nada (Rojas, 2016). La lealtad está disminuyendo rápidamente, hay un alto grado de consumidores que está dispuesto a utilizar estos proveedores (Accenture, 2017c). Barberis (2015), estudiando el caso de China establece que un factor que apalanca el desarrollo Fintech en este país está respaldado poblaciones jóvenes con conocimiento digital equipadas con dispositivos móviles.

Lejos queda el cliente de avanzada edad con un desconocimiento casi absoluto de internet y reacio a la aplicación de las nuevas tecnologías como medio de trabajo para gestionar sus activos financieros. Asimismo, el incremento de blogs, portales financieros, redes sociales financieras, entre otros, ha generado que los clientes tengan acceso a una gran cantidad de información que les permite elegir de manera adecuada el producto que se acomode más a sus necesidades (King, 2018).

Existe otro factor que constituye una amenaza. Anteriormente, en la banca minorista, los bancos tenían la envidiable posición de poder "rechazar" a los clientes porque eran demasiado riesgosos o no eran lo suficientemente rentables. Esto, se opone al papel percibido de los bancos en la sociedad, donde se considera que proporcionan un derecho social básico. Hoy en día, los clientes están evaluando en las redes sociales las marcas bancarias con una mirada social que ahora les permite rechazar ciertas políticas bancarias, o la marca completa, según las recomendaciones de la “multitud”. El acceso a la “multitud” tiene sus pros y contras. La masa o multitud (*crowd*) es grande, diversa, mayormente no controlable y con frecuencia desordenada. El centro permanece relevante y útil, pero en una era de redes globales y plataformas robustas, la masa se ha convertido en una fuerza crecientemente poderosa. La estructura de la masa es emergente, aparece en el tiempo como un resultado de las interacciones de sus miembros. Los mercados de títulos y acciones, los mercados de predicción y los modernos motores de búsqueda extraen valiosa información de esta estructura emergente. Las grandes masas se pueden concertar y juntar para construir productos altamente útiles (Brynjolfsson & McAfee, 2017). La multitud abierta y global ha permitido obtener resultados mucho mejores de los que las empresas habrían sido capaces de

obtener con su equipo interno. El poder de la red es tal que, si la multitud dice que el banco tiene una visión negativa, no hay gasto en publicidad que pueda dar vuelta esto. En la era de las redes sociales, el balance de "valor" se ha inclinado hacia el consumidor y ha debilitado la propuesta de valor de la marca bancaria promedio. Los bancos ya no pueden darse el lujo de poder tratar con clientes de manera unilateral y sin tener en cuenta a la multitud. Los clientes confían en los bancos cuando se comprometen de manera abierta y honesta, con un compromiso real de servicio (King, 2013).

Para entender cómo se conforma el universo de los consumidores de servicios financieros Accenture ha llevado a cabo un estudio con resultados muy interesantes (Ver detalle en el Anexo XIX). Según este estudio los consumidores de hoy están dispuestos a compartir sus datos, pero esperan que se les brinde servicios más personalizados, como por ejemplo aprobaciones rápidas de préstamos o beneficios monetarios (Accenture, 2017c). Además, los clientes más jóvenes quieren ser más partícipes, por medio de las plataformas on-line, para ayudar a moldear futuros productos y servicios bancarios que satisfagan sus necesidades. Esto apalanca la teoría de Von Hippel (2005) de la democratización de la innovación abordada en el capítulo II. También los clientes de hoy están abiertos a una experiencia de servicio y soporte puramente automático, incluso cuando se toman decisiones más complejas en torno a opciones de productos. Asimismo, el asesoramiento personalizado relacionado con la selección de productos y la asignación de activos es clave para una relación exitosa entre los clientes y sus proveedores financieros. Las personas esperan cada vez más interacciones personalizadas y relevantes para cubrir sus necesidades y objetivos financieros. La principal preocupación de los consumidores es que puedan conseguir lo que necesitan en forma rápida y ágil sin importar el canal (Accenture, 2017c).

4.3. Retos competitivos de incumbentes de servicios financieros

A los problemas asociados al propio modelo de negocio que tienen los bancos se añade la competencia creciente de nuevos actores en la intermediación financiera que favorecen la desintermediación y, por tanto, afectan también las cuentas de resultados de los intermediarios bancarios tradicionales. En general, la potencial competencia en medios de pago con monedas criptográficas, pagos vía móvil, las llamadas monedas complementarias, los préstamos clientes *peer to peer* o la financiación de la banca en la sombra a través de vehículos alternativos suponen un desafío para los modelos de negocio tradicionales que va más allá de la adopción de la

multicanalidad o la omnicanalidad y amenaza a la esencia del negocio bancario (García Montalvo, 2014).

Tras la crisis financiera del 2008, los bancos no han podido recuperarse y siguen con niveles bajos de rentabilidad exigida por los accionistas (ROE) (Ver detalle en Anexo XX). Esto impactó la percepción pública de los Bancos además de que se registró un aumento en las exigencias regulatorias que limitó la capacidad de competencia de los mismos (Barberis, 2015). Las reformas regulatorias aumentaron significativamente la carga de cumplimiento normativo, operativo y tecnológico de los bancos (Palacio Garcés, 2017). Esta crisis actuó como un punto de inflexión, la industria de servicios financieros se vio afectada lo que permitió el ingreso de un nuevo grupo de actores en el mercado estableciendo un nuevo paradigma donde lo destacable es la aplicación de la tecnología a los servicios financieros (Barberis, 2015) y donde la actividad económica principal de estos nuevos actores poco tiene que ver con el mercado en que están desembarcando (Basco et al., 2018). Estos nuevos actores generalmente son denominados Fintech.

Innumerables autores definen las *Fintech*, pero se puede tomar la nueva propuesta de la OECD (2018) que las define no solo como la aplicación de nuevas tecnologías digitales a los servicios financieros, sino también el desarrollo de modelos de negocios y productos que se basan en estas tecnologías y, en general, en plataformas y procesos digitales. Este sector está integrado por dos grupos de empresas: nuevos emprendimientos y empresas jóvenes en su mayoría y Gigantes de la tecnología. Las *startups* han innovado tanto en las soluciones que ofrece como en los modelos de negocio y tiende a especializarse en nichos dentro la cadena de valor de los bancos. Los gigantes de la tecnología, el comercio electrónico y la telefonía, como Google, Amazon, Samsung, Vodafone, Alibaba, MercadoLibre tiende a ubicarse en varios segmentos del negocio bancario de forma simultánea, e integra los servicios financieros a su modelo de negocios y paquete de servicios (Rojas, 2016). Las Fintech aprovecharon la ventana de oportunidad para entrar al sector financiero, en muchos casos fuera del radar de los entes reguladores (Rojas, 2016). Concepto que también Barberis (2015) refuerza ya que establece que estos nuevos jugadores ingresan a la industria financiera con una interacción preexistente limitada o inexistente con los reguladores financieros.

Las empresas Fintech desagregan la cadena de valor de un banco al entrar al mercado con servicios digitales en los distintos segmentos que la componen, tanto en los que se relacionan directamente con el cliente (*front-office*) como en los que realizan funciones finales o intermedias

de apoyo a la atención al cliente (*back-office* y las que facilita procesos entre estas dos (*middle-office*) (Rojas, 2016). Debido al uso de estas tecnologías disruptivas, las innovaciones del sector *Fintech* tienen el potencial de transformar el sector financiero y ayudar a proveer servicios a grupos sociales tradicionalmente desentendidos por la Banca incluyendo, en particular, el mercado de masas y los grupos más vulnerables (Rojas, 2016; OECD, 2018).

Las instituciones de servicios financieros tradicionales consideran que las entrantes, se han transformado en un poderoso *driver* de disrupción y en este escenario, las probabilidades de que las instituciones financieras tradicionales pierdan ingresos debido a las alternativas más innovadoras son cada vez mayores. Los grandes bancos son conscientes de las amenazas que los nuevos competidores pueden suponer para su modelo de negocio (PricewaterhouseCoopers, 2017a; Anif, Felaban & CAF, 2018) (Ver detalle en el Anexo XXI) y del crecimiento que han tenido en los últimos años (ver Anexo XXII). La participación de mercado de las empresas entrantes continuará en aumento hasta que se llegue a un punto de inflexión. A partir del mismo, la disrupción primero limitará el crecimiento de los bancos tradicionales, y luego los forzará a reducir su participación de mercado. Las instituciones financieras que no se hayan transformado, primero verán que su crecimiento será lento y luego comenzarán a declinar, los bancos tradicionales que se adapten prosperarán, mientras que aquellos que no lo hagan enfrentarán dificultades (Citi GPS, 2016).

El BBVA por su parte, asegura que las empresas Fintech monopolizarán la interacción con el cliente y los bancos que no adopten una estrategia de transformación digital quedarán relegados a los segmentos más regulados de la banca o a ejecutar funciones de backoffice para las Fintech (Rojas, 2016). En muchos mercados emergentes las empresas entrantes están más allá del punto de inflexión. Por ejemplo, en China los bancos comerciales, Mastercard, Visa y Union Pay simplemente no son jugadores líderes en los pagos móviles debido a que hoy ya el plástico no se está utilizando en este país. Este es un mundo donde la solicitud y emisión de plástico ya no tiene ningún valor significativo. En 2016, los pagos móviles superaron a los pagos con tarjeta en China (King 2018).

La tasa de disrupción será diferente en los distintos países, dependiendo de su nivel de desarrollo, pero en especial de la interacción de distintas fuerzas en juego, entre ellas: los hábitos de consumo; el nivel de penetración de celulares y en especial de teléfonos inteligentes; el nivel

de penetración de internet y la velocidad de transmisión de datos; el porcentaje de población bancarizada; y las regulaciones gubernamentales (Rojas ,2016).

El potencial disruptivo de las empresas Fintech tiene que ver con sus características competitivas y propuestas de valor, superiores a la de los bancos tradicionales. Estas nuevas empresas tienen una serie de ventajas sobre los incumbentes: adaptabilidad a las necesidades individuales de los clientes, sin infraestructuras heredadas y focalizadas solo en unos pocos servicios centrales, estas nuevas empresas pueden ofrecer a los usuarios un servicio más personalizado, más rápido y más rentable (OECD, 2018; Rojas 2016;). El núcleo de la diferencia es su misión: los nuevos entrantes quieren simplificar radicalmente la experiencia bancaria. La fricción es la antítesis de la premisa de diseño para los nuevos entrantes del sistema financiero. Cada una de estas empresas está tratando de eliminar la fricción de la experiencia, haciéndola más rápida, más fácil y más sexy (King, 2018). Tienen herramientas para entender al cliente y satisfacer sus necesidades y protegerlo de fraude, como análisis de grandes datos, modelos predictivos e inteligencia artificial; y por último aprovechan la tecnología para entrar en segmentos donde los bancos y otros proveedores tradicionales de servicios son ineficientes o sufren por falta de transparencia o de asimetrías en información (OEDC, 2018). Estas plataformas le prestan una gran atención a la interface del usuario y a la experiencia del usuario y tienen éxito en capturar y crear valor porque reducen las asimetrías de información que impiden la concreción de algunas transacciones beneficiosas (Brynjolfsson & McAfee, 2017).

La propuesta de valor de las Fintech en la mayor parte de los casos es de nicho. Se centran en un solo segmento o producto, dando gran importancia a la relación con el cliente, y a menudo usando como back-office los servicios de instituciones financieras o proveedores de servicios de pagos que cumplen los requisitos regulatorios. Las tecnologías digitales hacen posible que las instituciones se especialicen en producción (donde soportan los riesgos de los productos y servicios) o en distribución (donde administran la interfaz del cliente). En cambio, los bancos, tienden a ofrecer una gama de productos y servicios, sin que necesariamente optimicen ninguno de ellos (OECD, 2018).

La abundancia de servicios amigables para el cliente brindados por las Fintech está desagregando la oferta de los bancos, creando grietas por las que las entidades financieras que no se adapten podrían perder no sólo los beneficios de ese negocio, sino también su papel como interlocutor central con el cliente en lo relativo a su vida financiera. La desintermediación de los

servicios financieros tradicionales y el mejoramiento o perfeccionamiento de los servicios financieros básicos prestados por los bancos tradicionales es la estrategia Fintech. Para PricewaterhouseCoopers (2016) la desintermediación es el "arma letal" de las Fintech. El caso de china es emblemático, se detalla en el Anexo XXIII.

América Latina parece ser un terreno fértil para la disrupción en los próximos años, sus países poseen un sistema bancario débil, con una infraestructura de sucursales poco desarrollada y tienen un alto porcentaje de población no bancarizada (Rojas, 2016). Además, tiene un uso masivo de tecnologías móviles., a mediados de 2018, ya había 442 millones de suscriptores móviles únicos en América Latina y el Caribe, que representaban el 68% de la población y se espera que esta penetración aumente hasta el 78% de la población hasta 2025 (GSMA, 2018) (ver detalle anexo XXIV).

La amenaza de la desintermediación para los bancos es evidente. Pero dependerá, en parte, de tres factores. El primero es el grado en que los consumidores perciben los productos de los proveedores de servicios financieros digitales entrantes para que sean sustitutos próximos de los de los intermediarios tradicionales y las configuraciones de mercado que permiten a los consumidores a cambiar fácilmente de un proveedor de servicio a otro, la segunda es en la lealtad de los consumidores a productos específicos, y, finalmente, en la calidad percibida del producto existente en relación con las alternativas (OECD, 2018).

4.4. La colaboración como estrategia de los Bancos tradicionales frente a la disrupción

Los bancos se caracterizan por tener plataformas de tecnología de información que fueron instaladas en las décadas de los sesenta y setenta, además de estructuras organizativas que se superponen entre sí y recrean sistemas que operan como compartimientos estancos (silos). El reto tecnológico de transformar esos sistemas es enorme y en ese sentido sigue abierta la discusión sobre la mejor forma de hacerlo, si transformar los sistemas centrales o si modernizar por partes. Esa modernización es clave para poder moverse a la banca digital, pues los sistemas heredados tienen limitaciones para almacenar y procesar las cantidades enormes de datos que serán recogidos a través de los omnicanales (Rojas, 2016). Pocos bancos están reemplazando sus sistemas centrales tan radicalmente.

Los bancos tienen cuatro opciones para responder a los cambios estructurales que están experimentando los servicios financieros como resultado de la explosión de la innovación liderada por las FinTech: (i) no hacer nada; (ii) asociarse con las Fintech que es menos costoso y más rápido; (iii) adquirir FinTechs que es potencialmente rápido, costoso y culturalmente desafiante; y por último (iv) copiar o imitar las innovaciones de FinTech que sería lento y muy costoso (King (2018). Por la complejidad de desarrollar internamente las nuevas tecnologías y debido al estado de la modernización de los sistemas bancarios, las entidades financieras están adaptando sus estrategias adoptando modelos de colaboración con empresas Fintech (BBVA Research, 2015; Rojas, 2016; PricewaterhouseCoopers, 2017a).

Las redes de innovación son modos de organización en los que dos o más organizaciones independientes tienen como objetivo la investigación, desarrollo y comercialización de innovaciones en colaboración. Esta forma de colaboración apalanca lo planteado Chesbrough con el concepto de innovación abierta desarrollado en el capítulo II.

La tendencia a la colaboración se hará más profunda pues ambas partes se han dado cuenta de que cada una tiene fortalezas. Los Bancos tienen la base de consumidores, el capital, la liquidez, la experiencia y protección regulatoria y de manejo de riesgos, productos existentes (Citi GPS, 2016; King, 2018). Las Fintech por su lado tienen las habilidades técnicas, el talento, el diseño optimizado entendiendo al cliente en la era digital, espíritu emprendedor y las nuevas ideas, la rapidez, la agilidad para las implementaciones y la gestión de datos y análisis de vanguardia (King, 2018; Rojas, 2016). Las fortalezas de cada una se detallan en el Anexo XXV.

Al trabajar con las Fintechs los bancos pueden ampliar su oferta de servicios a nivel internacional, llegar a usuarios antes desatendidos y acceder a nuevas fuentes de ingresos o sin tener que invertir en el desarrollo de nuevas infraestructuras tecnológicas. Desde el punto de vista de las Fintech, estas se beneficiarían de la experiencia, el respaldo y los recursos económicos y de mercado que pueden proveerles los bancos a través de la colaboración (EY, IPADE & Startupbootcamp, 2018).

Según King (2018) las asociaciones entre los bancos y las FinTechs todavía están en su etapa incipiente. Pero existe una tendencia positiva (King, 2018; PricewaterhouseCoopers 2017a; PricewaterhouseCoopers, 2017b; Rojas, 2016; Anif, Felaban y CAF, 2018), esta puede visualizar en detalle en el Anexo XXVI.

Por otro lado, existen barreras y factores claves para la colaboración, entre las que se pueden mencionar el pobre ajuste cultural, las diferencias de gestión, carga de trabajo para la adquisición, abismo tecnológico, la seguridad, enfoque ROI a corto plazo, la incertidumbre regulatoria, construcción de mentalidad interna (detalle en el Anexo XXVII) (King, 2018; PricewaterhouseCoopers, 2017a).

QUAERERE VERUM
Universidad de
SanAndrés

5. Capítulo V.

La Inteligencia Artificial y el Aprendizaje Automático como herramientas de los Bancos Tradicionales Privados para enfrentar la disrupción

En los dos capítulos anteriores se trataron y profundizaron por un lado los conceptos de las tecnologías de avanzadas de la nueva ola de digitalización y se desarrollaron las definiciones básicas de Inteligencia Artificial y Aprendizaje Automático con el objetivo de entender los principales conceptos y tipos de algoritmos para comprender este tipo de tecnologías. Además, se analizaron las causas de su explosión en los últimos años y se profundizó sobre el estado actual del desarrollo, la adopción, y los impactos social y económico. Por otro lado, se analizó la situación de la Banca tradicional privada frente a la disrupción que está sufriendo el sistema financiero.

En este capítulo se trata de profundizar sobre los impactos de la inteligencia artificial y el aprendizaje automático en los procesos de producción actuales en general y en la banca en particular para identificar las promesas y oportunidades y aplicaciones específicas que las soluciones de AA pueden generar en los bancos tradicionales privados.

5.1. Promesas de la Inteligencia Artificial y el Aprendizaje Automático

El impacto económico de la IA en las empresas sería impulsado por 3 pilares: las ganancias en la productividad debido a la automatización, la mayor demanda de los consumidores y la difusión de la innovación.

La primera promesa consiste en obtener ganancias de productividad masivas para las empresas que automatizan sus procesos. La IA puede aportar automatización inteligente, que se diferencia de manera crucial de todas las formas anteriores de automatización debido a que las máquinas de IA pueden aprender y, por lo tanto, realmente mejorar con el tiempo, en lugar de deteriorarse (Accenture, 2017a). Las empresas maximizan el valor al mejorar la productividad de los insumos como mano de obra, capital y activos (Rao & Verweij, 2017) y los avances en aprendizaje automático ya han dado lugar a aplicaciones que, cuando se adopten en una escala masiva, deberían tener un impacto significativo en los costos operativos (Katz, 2017). Esta promesa está relacionada a la automatización de procesos robóticos y cognitivos, sistemas de colaboración multiagente y aprendizaje automático y natural. En el corto plazo, es probable que la mayor mejora económica potencial de la IA provenga de la mejora en la productividad. Los sectores de capital intensivo verían las mayores ganancias de productividad de la IA, dado que

muchos de sus procesos operativos son altamente susceptibles de automatización (Rao & Verweij, 2017).

La nueva ola de automatización inteligente impulsada por la IA ya está generando crecimiento a través de una serie de características distintas de aquellas de las soluciones automatizadas tradicionales. La primera característica es su capacidad de automatizar tareas complejas del mundo físico que requieren adaptabilidad, agilidad y aprendizaje. A diferencia de la tecnología de automatización tradicional, que es específica para cada tarea, el segundo rasgo distintivo de la automatización inteligente impulsada por el AA es su capacidad de resolver problemas en diferentes industrias y puestos de trabajo. La tercera característica y la más poderosa de la automatización inteligente es el autoaprendizaje logrado gracias a la repetitividad a escala (Estevadeordal et al., 2018).

La segunda promesa está relacionada con el aumento de la demanda de los consumidores. Esto estaría impulsado por la disponibilidad de productos y servicios mejorados y personalizados y/o de mayor calidad. La IA puede generar soluciones más personalizadas y holísticas, que hacen que el dinero trabaje más y se adapte a medida que cambien las necesidades del consumidor (Rao & Verweij, 2017).

Los consumidores se sentirán más atraídos por productos y servicios con mayor calidad y más personalizados, pero también tendrán la oportunidad de hacer un mejor uso de su tiempo debido a los servicios que brinden las soluciones de IA. A su vez, un mayor consumo crea un ciclo virtuoso de más puntos de contacto para la obtención de datos y, por lo tanto, más datos, mejores perspectivas, mejores productos y, por lo tanto, más consumo. La revolución de los consumidores iniciada por la IA abre el camino para una disrupción masiva ya que tanto las empresas establecidas como los nuevos participantes impulsan la innovación y desarrollan nuevos modelos de negocios (Rao & Verweij, 2017). Los beneficios competitivos inmediatos incluyen una capacidad mejorada para aprovechar las preferencias del consumidor, adaptar la producción para satisfacer estas demandas individuales y, al hacerlo, capturar una porción cada vez mayor del mercado. La capacidad de las empresas para dar forma a los desarrollos de productos en torno a esta abundante oferta de datos de clientes hará que cada vez sea más difícil para los competidores más lentos mantener el ritmo y, eventualmente, puede hacer que su ventaja sea indiscutible. Ya se puede ver esta innovación y diferenciación basada en datos en la forma en que hoy se producen, distribuyen y consumen libros, música, video y entretenimiento, lo que da como resultado nuevos modelos de

negocios, nuevos líderes del mercado y la eliminación de los jugadores tradicionales que no se adaptan lo suficientemente rápido (Rao & Verweij, 2017; Accenture, 2017b).

Los efectos del lado del consumo aparecen más rezagados, pero son de una magnitud sorprendente y exceden a la contribución del incremento de la productividad del trabajo al aumento del PIB hacia fines de los años 2020 (Accenture, 2017b; Katz, 2017). Tanto la naturaleza rezagada como la magnitud de estos impactos se pueden explicar por el complejo mecanismo de transmisión de estas mejoras de los productos al consumo. Dado que el mecanismo de transmisión de las mejoras en los productos del lado del consumo demanda un tiempo considerable, el efecto de las mejoras en los productos sobre el PIB demanda considerablemente mucho más tiempo para concretarse que los efectos derivados de aumentos de la productividad (Estevadeordal et. al, 2018).

Daugherty y Wilson (2018) en su investigación realizada en más de 1500 organizaciones concluyeron que a medida que las empresas implementan aprendizaje automático algunos experimentarán modestos aumentos de productividad a corto plazo, pero otros, al comprender y aprovecharse de la verdadera naturaleza del impacto de IA, lograrán mejoras innovadoras en el rendimiento, a menudo mediante el desarrollo de innovaciones que cambian el juego. Mientras más empresas utilicen y se familiaricen con la IA, más potencial de crecimiento verán en ella, las empresas con menos experiencia tienden a centrarse más estrechamente en la reducción de costos (McKinsey, 2017) que constituye la primera promesa y a medida que más se familiarizan con estas tecnologías las utilizan para aumentar su participación en el mercado (segunda promesa).

Una tercera promesa está relacionada con la difusión de la innovación que refiere a cómo la innovación engendra más innovación, por ejemplo, al fomentar nuevas ideas y modelos empresariales entre negocios adyacentes e industrias en un efecto colateral (Rao & Verweij, 2017). La IA tiene una gran capacidad para impulsar la innovación, ya que puede analizar rápidamente los datos que de otra manera habrían tardado en procesarse, reducir los costos de I + D y crear nuevas posibilidades de experimentación.

A nivel macro, la absorción de IA puede ser un factor de aceleración del crecimiento económico muy importante. Es una tecnología que cambia todo, y en todos los sectores se generan oportunidades de expansión sostenida. En el Anexo XXVIII se detallan los estudios relacionados tanto a nivel mundial, en el anexo XXIX de Latinoamérica y en el anexo XXX específicamente de Argentina.

Ahora, si se profundiza en los servicios Financieros, los beneficios que promete la IA a estos son más claros que en otras industrias y de una mayor precisión y velocidad (McKinsey, 2017). La IA y el AA tienen un creciente interés y popularidad en la comunidad de servicios financieros, ya que pueden mejorar drásticamente la capacidad de análisis y simplificar y automatizar todo tipo de líneas de negocio incluyendo la suscripción de crédito, el cumplimiento, la interacción con los clientes, y gestión de riesgos (Bart van Liebergen, 2017; Financial Stability Board, 2017).

Estas empresas han estado aplicando grandes volúmenes de datos y AA en una amplia variedad de áreas, para proporcionar mejores productos y servicios a sus clientes y para bajar sus costos (Jagtiani, Vermilyea & Wall, 2018). Por ejemplo, tres de cada cuatro transacciones en los mercados de valores de los Estados Unidos ya se realizaban en 2011 mediante algoritmos automatizados de negociación (Hendershott, Jones & Menkveld, 2011) y entre 2009 y 2016, los algoritmos inteligentes de máquina representaron el 49,73 por ciento de todo el volumen de operaciones con acciones de los EE. UU y el 38 por ciento en la UE en 2016 (King, 2018).

Los algoritmos de AA han mejorado enormemente la capacidad de identificar patrones en datos económicos (Jagtiani, Vermilyea & Wall, 2018; Chitra & Subashini, 2013). La combinación de big data y AA cambia la forma en que se producen, entregan y consumen los servicios financieros (Jagtiani, Vermilyea & Wall, 2018). King (2018) por su lado plantea cuatro beneficios principales que impulsan la adopción de la IA para los bancos que son: (i) la identificación de nuevas oportunidades de negocios, (ii) la automatización de tareas repetitivas, (iii) la mejora de la productividad de la fuerza laboral, y (iv) la competencia.

Las técnicas de AA, como las redes neuronales y el aprendizaje profundo, analizados en el capítulo III, tienen el potencial de resolver un amplio espectro de problemas de larga data. Ya sea para encontrar una segmentación óptima de la base de clientes para apuntar a nuevos productos, detectar y prevenir actividades de lavado de dinero, administrar el riesgo crediticio a través de sofisticados análisis predictivos o cumplir con los requisitos regulatorios para las pruebas de estrés en su balance, el AA ha surgido como una herramienta poderosa que la industria debería adoptar rápidamente como una oportunidad importante para mantener su posición competitiva (Accenture , 2017a).

Una encuesta realizada por Accenture (2018a) sostiene una visión optimista sobre el impacto de la IA en las empresas estableciendo que los bancos que inviertan en IA y desarrollen

la colaboración hombre-máquina podrían aumentar sus niveles de ingreso en un 44 por ciento. Tres de cada cuatro ejecutivos Bancarios entrevistados creen que la industria se transformará completamente con tecnologías inteligentes y que la IA será fundamental para su organización para diferenciarse en el mercado. El estudio encontró que el 77 por ciento de los bancos planean usar la IA para automatizar las tareas en una gran o muy gran medida en los próximos tres años. El 51 por ciento cree que la colaboración hombre-máquina es importante para lograr sus prioridades estratégicas. Más de dos de cada tres creen que IA mejorará la productividad de la fuerza laboral, y casi todos (99 por ciento) dicen que pretenden usarla para mejorar las capacidades de los trabajadores. Y según se evidencia en la encuesta esto ya está en marcha ya que el 28 por ciento de los empleados encuestados informaron que trabajan con tecnologías inteligentes durante más del 50 por ciento de su tiempo.

Por último, la IA y el AA no sólo contribuye a la competitividad de cada Banco, sino que puede impactar también a nivel sistema. El *Financial Stability Board* (2017) estima que el procesamiento más eficaz de la información, por ejemplo, en las decisiones de crédito, mercados financieros, contratos de seguros, y la interacción del cliente, puede contribuir a un sistema financiero más eficiente. Pero al mismo tiempo, los efectos de red y escalabilidad de las nuevas tecnologías en el futuro puede dar lugar a dependencias de terceros. Esto a su vez podría conducir a la aparición de nuevos actores de importancia sistémica que podrían caer fuera del perímetro regulatorio. Aplicaciones de la IA y el AA podría dar lugar a nuevas e inesperadas formas de interconexión entre los mercados y las instituciones financieras, por ejemplo, basados en el uso de diversas instituciones de las fuentes de datos previamente no relacionados (Financial Stability Board, 2017).

5.2. Aplicaciones de Aprendizaje Automático en la Banca (Casos de Uso)

Las instituciones financieras, dadas las características de sus negocios, son demandantes naturales de tecnologías relacionadas al aprendizaje automático (Estevadeordal et al., 2018). Con respecto a los casos de uso de AA, los mismos incluyen una variedad de áreas y focos específicos que se plantean en la tabla en función de la revisión bibliográfica consultada:

Tabla 3. Casos de Uso de Aprendizaje automático

Autor y Año	***Descripción***

Accenture (2018b)	Con muy alto y alto potencial: *Customer Insights*, gestión del fraude y gestión de los Canales, como Internet, Centros de Atención y Sucursales, Segmentación de Clientes, Marketing, Gestión de Riesgos, Gestión de RRHH, entre otros. En Anexo XXXI se detallan todas las áreas y sus potencialidades.
King (2018)	Define al AA como un factor fundamental de las entidades financieras y establece las áreas de los Bancos en las que esta tecnología puede apoyar: Cumplimiento regulatorio; Marketing, Sentimiento y Marca; Onboarding/Adquisición; Trading, Prevención de blanqueo de capitales y Prevención de fraudes; Credit Scoring / Evaluación de Riesgos; Fijación de precios; Administración de portfolio; análisis de datos y personalización; optimización del backoffice. En el Anexo XXXII se detallan estás áreas y los drivers de adopción en cada una de ellas.
Budworth (2018)	Identifica los casos de uso gestión de riesgos, el análisis financiero y la gestión de inversiones/cartera.
Van Liebergen (2017)	Identifica los casos de uso Riesgos de Crédito y modelado de ingresos; Fraude y vigilancia de la conducta y abuso del mercado en el comercio.
OECD (2018)	Asesoramiento, inversión y trading, seguros y comunicaciones.
Rao & Verweij, (2017)	Planificación financiera personalizada, la detección de fraudes y lavado de dinero y la automatización de procesos, no solo funciones de back office, sino también operaciones de atención al cliente

Elaboración Propia en base a los autores.

En resumen, como se muestra en la figura 45, las aplicaciones de esta tecnología en los distintos ámbitos del sector financiero son múltiples y se pueden encontrar en toda la cadena de valor, desde las tareas de procesamiento (back-office) hasta la interacción con el cliente o en el mercado (front-office), pasando por las actividades relacionadas con el control y con el monitoreo de la operativa (middle-office). Las entidades financieras están aplicando herramientas de inteligencia artificial en toda la cadena de valor y para todo tipo de servicios (Fernández, 2019).

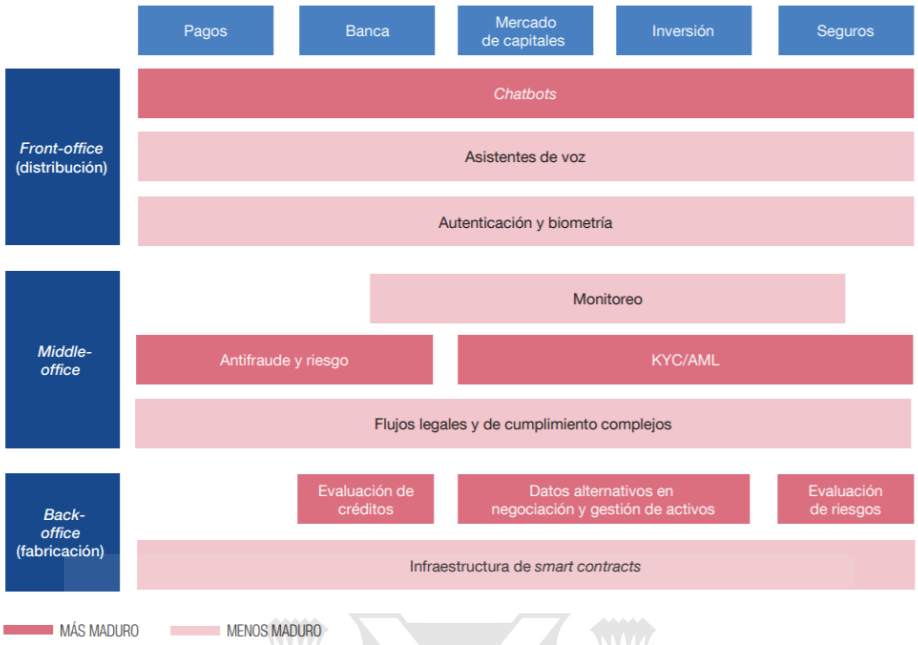

Figura 2. Madurez de casos de uso en entidades financieras

La siguiente figura muestra el estado de madurez de los diferentes casos de uso según sea *de Front-Office, Middle-Office y Back-Office* (Fernández, 2019). Copyright 2019. Recuperado de: https://www.bde.es/f/webbde/SES/Secciones/Publicaciones/InformesBoletinesRevistas/ArticulosAnaliticos/19/T2/descargar/Fich/be1902-art7.pdf

5.2.1. Calificación Crediticia

Los campos del modelo de riesgo son y ha sido un dominio natural de la aplicación de técnicas de AA (Jagtiani & Lemieux, 2018). Hay tipos de riesgo para los cuales el AA tiene mayor aplicabilidad que otros, por ejemplo, sería más probable encontrar AA en entornos ricos en datos, como la calificación del riesgo crediticio minorista (tarjeta de crédito e hipotecas) (Accenture, 2017).

La capacidad de gestión del riesgo de crédito se puede mejorar de manera significativa a través IA y el aprovechamiento de las técnicas de aprendizaje automático debido a su capacidad de comprensión semántica de los datos no estructurados (Aziz & Dowling, 2018). Los bancos y otros prestamistas están recurriendo cada vez más a fuentes de datos adicionales, no estructurados y semiestructurados, que incluyen actividades de redes sociales, uso de teléfonos móviles y mensajes de texto, para capturar una visión más matizada de la solvencia crediticia y mejorar la precisión de la calificación de los préstamos. La aplicación de algoritmos de AA a estos nuevos

datos permite evaluar factores cualitativos, como el comportamiento de consumo y la disposición a pagar. La capacidad de aprovechar datos adicionales en tales medidas permite una segmentación mayor, más rápida y más barata de la calidad del prestatario y conduce a una decisión de crédito más rápida (Financial Stability Board, 2017). Además de facilitar una evaluación segmentada de la capacidad crediticia potencialmente más precisa, el uso de algoritmos de AA puede ayudar a permitir un mayor acceso al crédito. También el uso de fuentes de datos alternativas, big data y AA, podría reducir el costo de tomar decisiones de crédito y reducir los costos operativos para los prestamistas (Jagtiani & Lemieux, 2018).

Desde la década de 1990, se ha desarrollado una extensa literatura académica sobre el uso de métodos de aprendizaje automático para modelar el riesgo de crédito. A continuación, algunos destacables.

Tabla 4. Resumen estudios realizados con algoritmos de AA aplicados a calificación crediticia

Autores y Años	***Estudio***
Davis, Edelman y Gammerman (1992)	Plantearon dos modelos de AA para predecir la credibilidad de clientes bancarios en los procesos de evaluación de tarjetas de crédito. En este estudio el modelo Bayes adecuado alcanzó un nivel de precisión más alto que le Bayes simple.
Altman et al. (1994).	Compararon métodos tradicionales estadísticos y un algoritmo de red neural alternativa, y el enfoque combinado mejoró exactitud significativamente
Galindo y Tamayo (1997)	Determinaron que los árboles de decisión produjeron los modelos más precisos para préstamos hipotecarios
(Li, Shiue & Huang, 2006; Bellotti & Crook, 2009).	Utilizaron funciones de base radial, clasificadores basados en árboles y máquinas de vectores de soporte, y demostraron que son ideales para el análisis de riesgo crediticio debido a los grandes tamaños de muestra y la complejidad de las posibles relaciones entre las transacciones y características del consumidor
Angelini et al. (2007)	Utilizaron un enfoque de redes neuronales para modelar el riesgo de crédito de las PYME.
Auria y Moro (2008)	Evaluaron la solvencia de la empresa utilizando máquinas de vectores de soporte.

Khandani et al. (2010) y Butaru et al. (2016)	Utilizaron árboles de regresión para predecir morosidad de las tarjetas de crédito del consumidor.
(Tsai & Chen, 2010).	Utilizaron técnicas de AA combinadas, denominadas hibridas, para proporcionar una mayor precisión en la predicción
(Kennedy, 2013; Letham, Rudin, McCormick & Madigan, 2013)	Compararon diferentes algoritmos e identificaron que el bosque aleatorio demuestra ser uno de los modelos más predictivos.
Sirignano et al. (2016)	Utilizó una red neuronal profunda para el pago anticipado de hipotecas, la morosidad y la ejecución hipotecaria.
Gomes Lopes, Ladeira y Carvalho (2016)	Aplicaron técnicas de AA para predecir la probabilidad de recuperación de las transacciones de crédito.

Elaboración propia a partir de los autores mencionados.

Universidad de SanAndrés

La disponibilidad de datos históricos, la calidad y la confiabilidad de los datos sobre el desempeño del producto prestatario en una amplia gama de circunstancias financieras es clave para el desempeño de estos modelos de riesgo (Financial Stability Board, 2017).

5.2.2. Asesoramiento y Planificación

Otra aplicación de AA en servicios de consumo que ha generado un gran interés son los robo-asesores, que implementan big data y algoritmos de AA para prestar servicios de asesoramiento financiero y planificación financiera a clientes minoristas (Jagtiani, Vermilyea & Wall, 2018; OEDC, 2018).

Las plataformas de Robo-asesores ofrecen servicios de inversión y gestión de cartera que pueden comerciar automáticamente para mantener los perfiles de riesgo deseados de las carteras o realizar pérdidas de inversión para fines fiscales. Las plataformas de asesoría robusta también pueden usar algoritmos para recomendar una determinada estrategia de inversión dado el perfil o

riesgo de un inversor. IA también tiene aplicaciones potenciales para la optimización de la inversión, al reconocer patrones y predecir qué inversiones tendrán un alto desempeño futuro (OECD, 2018).

Los Robo-asesores eliminan un nivel de intermediación, ofreciendo a los consumidores un acceso directo a los tipos de herramientas que los asesores financieros han estado utilizando durante años. Agentes de distribución móviles que venden seguros móviles o proporcionan servicios de pago móvil en los países emergentes son otra forma nueva de intermediario (OEDC, 2018).

Se pronostica que los Robo-asesores gestionarán alrededor de $ 1 billón de dólares para 2020, y de alrededor de $ 4,6 billones de dólares para 2022. Como tendencia, para 2030 se esperaría que los robo-asesores dominen la industria de inversión en el mercado masivo (King, 2018).

Los desarrollos de IA del tipo robo-asesores han hecho posible el desarrollo de soluciones de inversión personalizadas para consumidores del mercado masivo de manera que, hasta hace poco, solo hubieran estado disponibles para clientes de alto patrimonio. La tecnología y los datos están en su lugar, aunque la aceptación del cliente aún tendría que aumentar para alcanzar el máximo potencial (Accenture, 2017a).

5.2.3. Customer Insights y Personalización

Los algoritmos de IA están siendo utilizando para ofrecer más "compromiso personalizado" entre la firma y sus clientes, utilizando soluciones de compromiso cognitivas para anticiparse a las necesidades y demandas de los clientes, y ofrecer sugerencias adaptadas a ellos. Además de la información que dispone el banco sobre cada cliente, las entidades pueden tener acceso a información externa del mismo, como de redes sociales o comportamientos en Internet, lo que permitan enriquecer el ecosistema de datos que rodea a cada cliente. También, incluir en el análisis datos externos, puede generar nuevas oportunidades de negocio incluso sobre personas que no son clientes de la entidad financiera ya que se puede detectar necesidades concretas de una persona y ofrecerle un producto que pueda desencadenar en el alta de este (Laurens & Zou, 2016). Según King (2018) las áreas más impactadas por la IA son aquellas con cierto nivel de interacción/conversación entre el cliente y la institución. La IA afectará masivamente el marketing, cambiará radicalmente las expectativas de servicio al cliente y dominará la capacidad para atraer clientes sobre una base de comportamiento.

A continuación, se detallan algunos casos de uso detectados durante la revisión bibliográfica:

Tabla 5. Resumen estudios realizados con algoritmos de AA aplicados a *Customer Insights* y Personalización

Autores y Años	***Descripción***
Smeureanu, Ruxanda y Badea (2013)	Aplicación de redes neuronales redes neuronales y máquinas de vectores de soporte a un proceso de segmentación
Dhandayudam y Krishnamurthi (2014)	Uso de algoritmos de AA para segmentación de clientes con el objetivo de recomendar la ubicación física de sucursales o la ubicación de un cajero automático recopilando datos sobre qué zonas son frecuentadas por sus clientes, en qué horarios, dónde hacen sus compras, qué tipos de clientes son y qué en qué zonas tiene menor número de clientes.
López Lázaro, Barbero Jiménez y Takeda (2017)	Utilización de algoritmos de AA para identificar la vía de comunicación más adecuada para comunicarse con el cliente. Las entidades financieras deben analizar cuál es el canal prioritario (redes sociales, correo electrónico o mensajería instantánea) del cliente, aquel con el que se siente más cómodo para recibir notificaciones y canalizarlas por dicha vía.
López Lázaro, Barbero Jiménez y Takeda (2017)	Nuevas vías de negocio para monetizar los datos agregados y anónimos, debido a que los datos de los clientes suponen el activo más importante de la entidad financiera, pero a su vez, esta información puede suponer un gran valor para otra entidad financiera o empresa, que explote dichos datos anonimizados y agregados, puede resultar una oportunidad importante de negocio vender los datos anonimizados de los gastos de suministros habituales de un cierto perfil de población para que empresas del sector diseñen ofertas atractivas.
López Lázaro, Barbero Jiménez y Takeda (2017)	optimización de procesos y recursos de la entidad para recopilar datos y su posterior análisis lo que permitirá descubrir patrones y comportamientos ocultos y desconocidos hasta el momento, que permitan maximizar el beneficio con un menor gasto
Jones & Kim (2016)	Analizando la actividad de la cuenta de un cliente, y combinando la información con datos internos del resto de canales y datos externos, de redes sociales, se puede determinar si el cliente abandonará la entidad

Farquad, Ravi & Raju (2012)	Utilización de algoritmos SVM (*Support Vector Machine*) para predicción de abandono de clientes de tarjetas de crédito bancarias
Abidin, Ismail, Maarop & Alias (2017).	Detectan patrones y comportamientos de los clientes lo que permite ofrecerle productos financieros personalizados y a medida que logren una mejor experiencia del cliente, una mayor satisfacción debido a que puede tener acceso a información externa del mismo, como de redes sociales o comportamientos en Internet

Elaboración propia a partir de los autores mencionados.

Las aplicaciones de cara al cliente se ven ahora como una de las áreas clave para el uso de la IA en los servicios financieros (Budworth, 2018). En 2016, sólo el 20% de los encuestados para este estudio dijo que el mayor potencial de IA fue su capacidad para mejorar la experiencia del cliente, mientras que, en 2018 esa cifra pasó a más del doble, a 42%. Ningún otro segmento registró un salto tan importante (Budworth, 2018)

5.2.4. Asistentes virtuales orientados a clientes

Los asistentes virtuales ayudan a los clientes a tramitar o resolver problemas. Estos programas automatizados interactúan con los clientes en lenguaje natural (por texto o voz), y utilizan algoritmos de AA para mejorar con el tiempo. Los asistentes virtuales están siendo introducidos por una gama de empresas de servicios financieros, a menudo en sus aplicaciones móviles o redes sociales. Si bien muchos aún se encuentran en la fase de prueba, existe un potencial de crecimiento a medida que los asistentes virtuales aumentan su uso, especialmente entre las generaciones más jóvenes, y se vuelven más sofisticados. La generación actual de asistentes virtuales en uso por las empresas de servicios financieros es simple, generalmente proporciona información de saldos o alertas a los clientes, o responde preguntas sencillas.

El mayor uso de esta tecnología en la banca se está dando en los servicios de atención al cliente, si bien algunas entidades financieras han venido incorporando la robótica en muchos de sus procesos el reto en este sentido está en desarrollar verdaderos robots que logren interpretar de manera asertiva las inquietudes y necesidades de los clientes y resolver sus preguntas de la forma en que lo hace una persona. La inmersión en esta tecnología apenas comienza y de allí la importancia de incrementar su desarrollo y explotar su potencial (Financial Stability Board, 2017; OEDC, 2018).

5.2.5. Detección de Fraude

La potencia de cómputo más accesible, el uso generalizado de Internet y el crecimiento sustancial en la cantidad de datos valiosos por un lado facilitaron e impulsaron el AA, pero también han originado un aumento en el riesgo de seguridad de los datos. Los bancos han estado utilizando las técnicas de AA durante más de una década para detectar el fraude de tarjetas de crédito con cierto éxito (Van Liebergen, 2017). IDC (2018) identifica dentro de los casos de uso clave del sector financiero el análisis e investigación de fraudes. Según este referente los sistemas de IA utilizarán el aprendizaje basado en reglas para identificar las transacciones que indican la actividad fraudulenta o el aumento del riesgo de fraude; los sistemas aprenden automáticamente las reglas para identificar numerosos esquemas de fraude; estos incluyen, entre otros, lavado de dinero, los umbrales de efectivo, exención de tasas de facturación, verificación de la manipulación, hurto y fraude en los estados financieros. También en el estudio de Frost & Sullivan (2016) se evidencia que la IA está evolucionando lentamente para convertirse en una solución llave en mano en el espacio de análisis de fraude.

Con ayuda de algoritmos de AA, los bancos son capaces de detectar actividad sospechosa dentro de los datos de una manera no prescriptiva. Mientras el sistema observa las transacciones del usuario, descubre patrones de comportamiento comunes al agrupar transacciones similares (Chitra & Subashini; 2013). Perols (2011) comparó el desempeño de seis modelos populares de estadística y de AA para detectar el fraude en los estados financieros. Los resultados mostraron que las máquinas de vectores de soporte de regresión logística funcionan bien en relación con una red neuronal artificial.

5.2.6. Otras aplicaciones

A continuación, se detallan otras aplicaciones de algoritmos de AA en el sistema financiero:

Tabla 6. Otros Casos de Usos

Autores y Años	***Descripción***
(Jagtiani, Vermilyea & Wall, 2018; IDC, 2018).	AA está siendo utilizado por las empresas financieras para mejorar la eficacia y reducir los costes de cumplimiento de la normativa

López Lázaro, Barbero Jiménez & Takeda, 2017	Los algoritmos de AA pueden mejorar en gran medida las operaciones de logística en efectivo pronosticando la demanda de efectivo de sucursales, atendiendo las anteriores demandas y los efectos de calendario.
Dhandayudam y Krishnamurthi (2014)	Realización de recomendaciones de cuánto dinero cargar a los cajeros automático, analizando el calendario local de la ubicación del cajero, las condiciones climatológicas y los eventos de la ciudad y su ubicación, con el objetivo de no bloquear dinero ni que se impida dar el servicio por falta de este.
Jones & Kim, 2016	Se puede considerar dentro de los casos de uso relacionados a cajeros automáticos la identificación de las operaciones más frecuentes realizados en los mismos ya que muchos clientes, cuando acuden a un cajero automático, siempre realizan la misma operación. El objetivo de este caso de uso es determinar el patrón y su comportamiento y ofrecerle dicha operación directamente evitando preguntas y navegaciones.
Farquad, Ravi & Raju (2012)	Utilización de algoritmos SVM (*Support Vector Machine*) para la detección de fraudes en seguros.

Elaboración propia a partir de los autores.

QUAERERE VERUM
Universidad de
SanAndrés

6. Capítulo VI.

Factores que actúan como Barreras, Desafíos o Riesgos para la Adopción de Aprendizaje Automático en la Banca

En el capítulo anterior se profundizó sobre los impactos de la inteligencia artificial y el aprendizaje automático en los procesos de producción actuales en general y en la banca en particular para identificar las promesas y oportunidades y aplicaciones específicas que las soluciones de AA pueden generar en los bancos tradicionales privados.

En este capítulo se profundiza acerca de cuáles son las barreras, desafíos y riesgos a los que se enfrenta la Banca Tradicional privada para avanzar en la adopción de soluciones de aprendizaje automático.

6.1. Principales obstáculos

Los principales obstáculos para implementar las tecnologías de la Industria 4.0 entre las que se encuentran la IA y el AA, son: la falta de personal calificado, la incertidumbre respecto al impacto de las inversiones en las ganancias de la compañía, la resistencia al cambio y a la innovación (ver detalle en anexo XXXIII); (Nieponice et al., 2018), falta del ecosistema de datos correcto con el acceso adecuado, los procesos organizacionales y la cultura del flujo de trabajo (McKinsey, 2017b). También el tipo de liderazgo desde la cima y el talento en cuanto a capacidades de gestión y técnicas son habilitadores clave (Rao & Verweij, 2017). Para Skinner (2014), es imprescindible que exista fuerte experiencia tecnológica dentro del equipo de liderazgo del banco.

Es imprescindible una cultura organizativa abierta a la colaboración de personas y máquinas (McKinsey, 2017). La confianza es un factor clave. En lugar de los pasos predeterminados de un algoritmo, son, en cierto sentido, los datos utilizados para entrenarlo lo que conduce al resultado. Las personas necesitarán algo de tiempo para adaptarse a este cambio de paradigma. La creación de una cultura preparada para la IA debe ser una prioridad desde el principio (McKinsey, 2017b). Como la IA es aplicable a todos los elementos de la cadena de valor, como lo vimos anteriormente, esto puede llevar a múltiples silos de iniciativas o confusión en la búsqueda de un buen punto de partida. Por lo tanto, es fundamental desarrollar el conocimiento, la gobernanza y la colaboración organizativa para elegir su lugar e impulsar las iniciativas (Rao & Verweij, 2017).

Una cultura data driven es fundamental. Se puede requerir para desarrollar las capacidades de los trabajadores, para comprender cómo utilizar la información de IA basada en datos y confiar en ellos como la base para tomar decisiones (Rao & Verweij, 2017).

A menudo, no hay una única respuesta correcta a la pregunta de cuál es la mejor estrategia de implementación de IA o el mejor conjunto de herramientas de IA, básicamente porque estas tecnologías implican concesiones: más velocidad versus menos precisión; más autonomía versus menos control; más datos versus menos privacidad (Agrawal, Gans & Goldfarb, 2018). Para llevar a cabo una implementación de IA las tareas deben descomponerse para ver dónde se pueden insertar los algoritmos. Esto permite estimar el beneficio de la predicción mejorada y el costo de generar esa predicción (Agrawal, Gans & Goldfarb, 2018). Luego se debe establecer un caso de negocios de inteligencia empresarial sólido y conectarlo a la estrategia de la empresa (McKinsey, 2017a). Una vez que se hayan generado estimaciones razonables, se deben ordenar las iniciativas de IA desde el ROI (Retorno de Inversión) más alto al más bajo implementando las herramientas de IA siempre que el ROI esperado tenga sentido. También lo obliga a articular con precisión lo que necesita para predecir, el juicio requerido para evaluar el valor relativo de las diferentes acciones y resultados, las posibilidades de acción y las posibilidades de resultado (Agrawal, Gans & Goldfarb, 2018). Esto requiere identificar las capacidades reales de IA en un contexto específico y sus limitaciones lo que requiere al menos un alto nivel de comprensión de cómo funciona la IA y cómo difiere de los enfoques tecnológicos convencionales. Un enfoque basado en casos de uso en un horizonte de uno a cinco años puede ser útil. Las organizaciones que quieren implementar IA deben comenzar enfocándose en los casos de uso donde existen soluciones tecnológicas probadas en la actualidad que se pueden adoptar a escala, como la automatización de procesos robóticos y algunas aplicaciones de aprendizaje automático. Luego se pueden identificar casos de uso en los que está surgiendo una tecnología pero que aún no se ha probado a escala. Y a más largo plazo, se pueden elegir casos de usos no probados, pero de alto impacto para innovar, obteniendo una posible ventaja de primer movimiento en el futuro (Agrawal, Gans & Goldfarb, 2018).

El objetivo es implementar un enfoque rápido y ágil que pueda ayudar a validar el caso de negocio, realizar experimentos de tiempo limitado para ver qué funciona realmente y luego aumentar los alcances. La orientación debe ser opuesta: orientada a los negocios y enfocada en el valor. Este enfoque dirigido por el negocio sigue los enfoques de adopción exitosos en otras olas digitales (McKinsey, 2017a).

6.2. Gestión de Datos: la clave de los algoritmos de Aprendizaje Automático

Un elemento fundamental planteado en el uso ético y responsable de la IA lo constituyen los datos (Estevadeordal et al., 2018). Sin datos, conseguir el arranque del motor de IA es imposible (McKinsey, 2017). La IA utiliza tres tipos de datos: de entrenamiento, es necesaria una gran cantidad de datos para los sistemas de entrenamiento; de entrada, para predecir y de retroalimentación para mejorar la precisión de la predicción (Agrawal, Gans & Avi Goldfarb, 2018; Mckinsey, 2017a).

Los Bancos ya cuentan con grandes cantidades de datos debido a que los han estado utilizado durante muchos años para sus actividades. Pero también las instituciones se han dado cuenta de la gran cantidad de datos que genera cada uno de sus clientes diariamente. Esto ha resultado en que los datos que deben gestionar las instituciones financieras han aumentado significativamente en los últimos años y sobre todo las cantidades de los datos de tipo no estructurado. Otro factor a tener en cuenta es que la calidad de los datos dentro de los bancos no siempre es lo suficientemente adecuada para un análisis estadístico avanzado y además los bancos no siempre pueden consolidar los datos de sus clientes, debido a definiciones de datos inconsistentes y al uso de múltiples sistemas (Van Liebergen, 2017). Además, debido a que las instituciones deben estar muy centradas en ofrecer lo que los clientes realmente lo que quieren, es necesario que conozcan a los mismos más allá de sus actividades financieras por lo que aquí se identifica que una de las implicancias para los incumbentes del sistema financiero: necesitan información detallada del comportamiento de los clientes, tanto dentro como fuera del servicio Bancario (Word Economic Forum, 2018).

Pero los datos a menudo son costosos de adquirir, es una inversión, por lo que los bancos deben saber a qué datos ya tienen acceso y dónde pueden obtener datos adicionales relevantes para el éxito de las implementaciones de AA (McKinsey, 2017a). El costo de la obtención de datos depende de la cantidad de datos que se necesite y del proceso de recopilación. Además, hay que tener en cuenta que el 90 % de los datos que se producen en la industria en la actualidad no tienen estructura relacional. Hacer que estos datos sean utilizables requiere nuevos enfoques para manejar grandes volúmenes de diferentes tipos de datos (McKinsey, 2017a). También se deben reconocer los tipos de datos potencialmente distintivos que pueden crear una ventaja competitiva. Por

ejemplo, los datos de eventos en tiempo real de geolocalización son diferenciadores para los cuales es probable que se intensifique la competencia por el acceso exclusivo (McKinsey, 2017a).

Es fundamental equilibrar el costo de adquisición de datos con el beneficio de una precisión de predicción mejorada. Determinar el mejor enfoque requiere estimar el ROI de cada tipo de datos. Las organizaciones necesitan entender la relación entre agregar más datos, mejorar la precisión de la predicción y aumentar la creación de valor (Agrawal, Gans & Avi Goldfarb, 2018).

Por lo tanto, se deben tomar decisiones sobre la escala y el alcance de la adquisición de datos. Más tipos de datos, más objetos y más frecuencia significan un mayor costo, pero también potencialmente un mayor beneficio. Al pensar en esta decisión, se debe determinar cuidadosamente lo que quiere predecir (Agrawal, Gans & Avi Goldfarb, 2018; McKinsey, 2017a).

6.2.1. Propiedad y Protección de Datos

El aumento de la disponibilidad y uso de los datos de los clientes plantea cuestiones relativas a la propiedad y uso de estos datos y las consecuencias que esto podría tener para la privacidad. También plantea preguntas sobre el grado en que los datos disponibles deben ser compartidos para mejorar las protecciones de regulación y de consumo (OEDC, 2018). Estos riesgos están relacionados con la protección de estos y, en un sentido más amplio, el de la privacidad (Financial Stability Board, 2017). Buenadicha Sánchez et al. (2019) plantean la preocupación de los ciudadanos sobre el uso y la gestión de los datos personales y muestran que existe un sentimiento de urgencia sobre la necesidad de proteger la seguridad y privacidad de los datos usados.

En 2018 entró en vigencia el Reglamento General de Protección de Datos (RGPD) de la Unión Europea, que en poco tiempo se ha convertido en una suerte de estándar de referencia global. ¿Quién debe tener la propiedad de los datos y qué salvaguardas se necesitan para proteger los datos altamente sensibles, sin destruir su utilidad? Hay todavía muchas preguntas por responder.

El RGPD establece que los datos personales deben ser tratados de forma lícita, leal y transparente; se deben recolectar con fines determinados explícitos y legítimos; deben ser adecuados, pertinentes y limitados a lo necesario dependiendo del uso; deben ser exactos y estar siempre actualizados; deben mantenerse de forma tal que se permita la identificación de los interesados durante no más tiempo del necesario para los fines del tratamiento; y deben ser tratados de tal manera que se garantice su seguridad (Buenadicha Sánchez et al., 2019). Además de los

temas relacionados a la seguridad y a la legalidad, quienes recolecten y gestionen datos deberán asegurarse siempre de haber informado a sus propietarios y obtener su consentimiento tantas veces como sea necesario si la finalidad del uso que se le dará a sus datos cambia. Los cortafuegos, el cifrado, la anonimización y la codificación son algunas de las modalidades de protección de los datos personales (Buenadicha Sánchez et al., 2019).

6.2.2. Opacidad de Datos

La falta de transparencia en los sistemas de datos (qué clase de información recogen, cómo la gestionan, con quién la comparten, qué decisiones se toman a partir de ella y con base en qué factores) representa riesgos de Opacidad de Datos (Estevadeordal et al., 2018; McKinsey, 2017a). En el ámbito tecnológico, este riesgo se acentúa debido a que los sistemas informáticos son percibidos como "cajas negras" (Buenadicha Sánchez et al., 2019; Accenture, 2017a).

En el caso de AA, obtener la comprensión de cómo funcionan, dependiendo de qué algoritmos de AA se estén utilizando, puede ser un problema. El funcionamiento de los algoritmos suele ser complejo, de modo que resulta difícil entender en algunos casos el razonamiento que siguen para llegar a un determinado resultado (Fernández, 2019). La forma en que la mayoría de los modelos de algoritmos de AA complejos generan su salida puede no ser fácilmente interpretable incluso por la persona que realizó el análisis (Jagtiani, Vermilyea & Wall, 2018). Aunque en ciertos casos el hecho de no entender este proceso puede resultar irrelevante (por ejemplo, en un chatbot), en otras ocasiones puede ser necesario explicar por qué se ha tomado una determinada decisión (por ejemplo, en una calificación crediticia) (Fernández, 2019).

La opacidad de los datos y algoritmos constituye uno de los impedimentos clave para la adopción de AA en los Bancos. Los tipos de opacidad de datos se describen en el Anexo XXXIV. Este es un punto que los reguladores plantean constantemente a las entidades financieras, así como a sus propias funciones de control (Accenture, 2017a). También es una preocupación para el Financial Stability Board (2017) que define que la falta de "interpretabilidad" o "capacidad de auditoría" de la IA y los métodos de AA podrían convertirse en un riesgo a nivel macro.

Como cualquier otro sistema de software, los sistemas de AA necesitan ser verificados y validados utilizando metodologías estándar. Son muchos los referentes que reivindican la necesidad de planificar metodologías de auditoría algorítmica para poder evaluar de forma periódica cómo van aprendiendo los algoritmos y cuáles son sus impactos. Ha llevado también al

surgimiento de nuevos derechos, específicamente, el derecho a la "explicabilidad". El RGPD, por ejemplo, requiere a los organismos que manejan algoritmos realicen un procesamiento justo y transparente, y que expliquen la manera como los sistemas automatizados toman decisiones, especialmente aquellas que afectan significativamente las vidas (Buenadicha Sánchez et al., 2019).

Para llevar a cabo su "explicabilidad" hay que asegurarse de que los datos proporcionados para su entrenamiento sean representativos, que no contengan sesgos, que se entienda de qué modo el sistema está identificando las características distintivas y de qué modo está haciendo sus recomendaciones. Pero dificultad que entraña hacer esto en muchos de los algoritmos de IA hace que sea difícil afirmar si el rendimiento o los resultados de los algoritmos de IA son acertados o deseables (Addo, Guegan, & Hassani, 2018).

En el caso de los bancos, se deben utilizar AA supervisado (abordado en el capítulo III) para que los procesos analíticos y las conclusiones sean totalmente transparentes y se pueden documentar con detalles paso a paso, para el caso por ejemplo de decisiones de crédito. Hay otros casos, en cambio que se podría utilizar AA no sea supervisado, por ejemplo, cuando los algoritmos se utilizan para señalar posibles fraudes o infracciones que se investigarán más a fondo (Jagtiani, Vermilyea & Wall, 2018).

Particularmente para las actividades de préstamos, Jagtiani & Lemieux (2018) plantean que el uso de algoritmos complejos podría resultar en una falta de transparencia para los consumidores. Cuando se utiliza AA para asignar puntajes de crédito a la hora de tomar decisiones de crédito, generalmente es más difícil proporcionar a los consumidores, auditores y supervisores una explicación de un puntaje de crédito y la decisión de crédito resultante si se cuestiona.

6.2.3. Sesgos o Discriminación algorítmica

Otro de los riesgos importantes que se plantea en la actualidad (Estevadeordal et al., 2018) es la discriminación algorítmica que refiere a aquellos procesos a través de los cuales los distintos tipos de discriminación que ocurren en el mundo real son reproducidos en entornos de datos, como bien lo señalan Barocas y Selbst (2016), los datos son "frecuentemente imperfectos" porque pueden reflejar los sesgos de las personas que tomaron las decisiones sobre su recolección. Asimismo, pueden presentar problemas de insuficiencia, errores, y exceso o déficit de representación de ciertos grupos de la sociedad, que podría impactar en una decisión algorítmica equivocada. También la falta de actualización oportuna de los datos puede tener efectos. Por

ejemplo, si no se actualizan a tiempo los datos de una persona que estaba en un registro de deudores, esta puede resultar perjudicada a la hora de ser evaluada (Buenadicha Sánchez et al., 2019). En el caso de un crédito, por ejemplo, un conjunto de datos históricos sobre préstamos minoristas puede excluir categorías de consumidores, como los prestatarios de mayor riesgo. Por lo tanto, es necesario comprender el proceso mediante el cual los individuos se incluyen o excluyen del conjunto de datos grandes. De lo contrario, el proceso de selección de la muestra para algunos conjuntos de datos puede no proporcionar predicciones de pérdida precisas para grupos que históricamente han tenido acceso limitado al crédito (Jagtiani, Vermilyea & Wall, 2018).

El problema de los sesgos también lo identifica McKinsey (2017a), que plantea que a causa de esto la IA presenta una gama de problemas éticos, legales y regulatorios. Los sesgos del mundo real corren el riesgo de integrarse en los datos de entrenamiento. Dado que el mundo real es sesgado de muchas otras maneras, los datos del mundo real que alimentan los algoritmos también pueden tener estas características, y cuando los algoritmos de IA aprenden de los datos de entrenamiento sesgados, internalizan los sesgos, exacerbando esos problemas (McKinsey, 2017a).

Las investigaciones actuales tratan de reducir el sesgo del modelo, producto de los sesgos de los datos de entrenamiento, y mejorar la estabilidad de su rendimiento. Es importante realizar verificaciones de la calidad de los datos en el proceso de preparación y limpieza para omitir variables redundantes, y además es importante tratar con un conjunto de datos de entrenamiento desequilibrado para evitar sesgos a una clase mayoritaria (Addo, Guegan, & Hassani, 2018).

6.2.4. Infraestructura de datos

Para sacar el máximo partido de la IA, los bancos deben abordar en primer lugar sus retos de gestión de datos existentes. Las instituciones financieras deben revisar su infraestructura de datos creando una arquitectura empresarial que permita la interoperabilidad y el intercambio de información. Las instituciones financieras deben hacer frente a las estructuras de gestión de datos heredados que se basan en silos. Muchos datos están “encerrados” dentro de estos silos dispares a través de las múltiples líneas de negocio dentro de los bancos. Esto hace que sea difícil para los bancos ver sus datos en forma estratégica y sacar el máximo provecho de lo que debería ser un activo importante. Una plataforma de datos unificada permitirá a los bancos gobernar eficazmente y compartir datos con terceros (Finextra & Intel, 2018). Pero para implementar esta plataforma además de los problemas técnicos hay consideraciones políticas. La transformación de las

estructuras de datos para crear plataformas de intercambio de datos implica la eliminación de los silos que se mencionaron, que a menudo son vistos como feudos de diferentes líneas de propietarios de negocios.

El análisis de datos complejos se está convirtiendo rápidamente en una fuente de enorme ventaja competitiva para las instituciones financieras. Para mover y adelantarse a los competidores rápidamente, los bancos deben unificar mejor, comprender, aprender y actuar sobre la información, sobre los grandes volúmenes de datos que posee. Para ello, las organizaciones competitivas se deben mover más allá de las bases de datos tradicionales, rígidas y el procesamiento por lotes de latencia, hacia las nuevas tecnologías. Los bancos deben crear una plataforma de datos y análisis para hacer frente a la gobernabilidad y la seguridad de los riesgos. Los bancos deben eliminar las barreras políticas y de seguridad para el intercambio de datos y poner en práctica analítica avanzada para el uso en toda la empresa: La creación de una plataforma de datos analítica que puede hacer frente a un flujo continuo de datos será de vital importancia (Finextra & Intel, 2018). Hoy la geolocalización, el contexto, el comportamiento, los comentarios y opiniones sociales y los indicadores de identidad son puntos de datos y capacidades de la plataforma tecnológica que se encuentran en gran medida fuera de las arquitecturas bancarias existentes. Esto creará una plataforma de nuevos intermediarios e intermediarios que se volverán esenciales en la prestación de servicios financieros en el futuro (King, 2018).

No solamente es importante considerar la viabilidad tecnológica de la IA y la disponibilidad de los datos necesarios para respaldarla, sino que también es importante inculcar una cultura basada en datos que combine la intuición y la información analítica con un enfoque en las decisiones prácticas y viables en todos los niveles (Rao & Verweij, 2017).

6.3. El Capital humano

Un tema recurrente para los empresarios y académicos es la escasa reserva de talentos (Estevadeordal et al., 2018; McKinsey, 2017b) y el costo de adquisición (McKinsey, 2017b) ya que la demanda de científicos de datos, ingenieros de robótica y otros especialistas en tecnología está creciendo claramente según el reporte anual del Índice de IA (el detalle se puede visualizar en el Anexo XXXV) (Bauer et al., 2018).

Para hacer frente a este problema, será crucial mejorar la calidad de los sistemas educativos, así como ampliar el acceso a la educación terciaria en varios países. Pero preparar a la próxima

generación no será suficiente. La generación actual de trabajadores también necesitará apoyo para adaptarse a los cambios producidos por el AA, se necesitarán competencias técnicas para diseñar e implementar estos sistemas (OCDE, 2018).

Particularmente en América Latina, Accenture (2018a) revela numerosas deficiencias estructurales que dificultan la capacidad de integrar nuevas tecnologías en la economía. Debilidades regionales comunes incluyen la calidad de los sistemas de educación (desde niveles primarios hasta universitarios) y de instituciones de investigación científica, así como también ecosistemas deficientes de innovación e investigación a nivel nacional, regional y mundial. Pero los desafíos más significativos para la adopción de IA no son diferentes en América Latina con respecto a cualquier otro lugar. Se trata de preparar responsables para las principales inquietudes intelectuales, tecnológicas, políticas, éticas y sociales que surgirán a medida que la IA se integra en mayor profundidad a la vida de las personas.

En Argentina, según Nieponice et al. (2018) el capital humano es la cuestión más relevante para alcanzar Industria 4.0. Esto se debe a que la transformación requiere nuevas capacidades, tanto de las personas como de las empresas. La lista de las capacidades que serán más demandadas en los próximos años está liderada, en primer lugar, por la ingeniería y el desarrollo del proceso de producción (capacidad necesaria para coordinar el uso de las nuevas tecnologías en el proceso productivo) y, en segundo lugar, por la ciencia de datos.

Particularmente King (2018) presenta nuevos puestos de trabajo que se considerarán críticos en el crecimiento de los ingresos y la capacidad de los servicios financieros durante los próximos cinco años, entre los que figuran en primer lugar los científicos de datos y los especialistas de AA (ver detalle en Anexo XXXVI). También Accenture (2018a) identificó que existirán nuevos roles y descubrió que existen tres nuevas categorías de trabajos impulsados por la IA: los "capacitadores", los "explicadores" y los "sostenedores". Los capacitadores ayudarán a las computadoras a medida que aprenden; los explicadores interpretarán los resultados de los algoritmos para mejorar la transparencia y la responsabilidad de sus decisiones y los sostenedores garantizarán que los sistemas inteligentes se mantengan fieles a sus objetivos originales sin cruzar las líneas éticas, alejándose de los resultados deseados o reforzando el sesgo, estos factores de riesgo serán analizados en secciones venideras.

Por lo tanto, en la transición hacia la Industria 4.0, es crucial la inversión en el desarrollo de nuevas habilidades de los trabajadores que permitan hacer frente a las oportunidades y desafíos

de la digitalización (OECD, 2016). Ya que el impacto más significativo de la IA no será en la cantidad de puestos de trabajo, sino en el contenido del trabajo (Accenture, 2018a).

Las habilidades de los trabajadores y las tecnologías digitales son complementarias en los nuevos procesos de producción (OECD, 2016). Es importante prepararse para una fuerza laboral híbrida en la que la IA y los seres humanos trabajen codo a codo. Las personas deberán ser responsables de determinar la aplicación estratégica de la IA y el AA y proporcionar desafíos y supervisión a las decisiones (Rao & Verweij, 2017).

6.4. El marco regulatorio

La actividad innovadora en el sistema financiero no es hoy algo exclusivo de las empresas entrantes del mercado, sino que puede venir de la mano de empresas ya consolidadas, que quieren diversificar sus actividades y que están reguladas, como los bancos tradicionales. La irrupción de las nuevas tecnologías en general trae consigo una serie de retos para reguladores y supervisores financieros (Herrera & Vadillo, 2018). El uso de la IA y AA, en particular, requiere la consideración de cómo este tipo de algoritmos deben ser auditados y supervisados, y qué tipo de impacto podría tener la implementación de estos modelos en las valoraciones del mercado y la estabilidad (OEDC, 2018). El desarrollo de AA ha hecho que el rol de los datos sea más crítico para el proceso de supervisión porque son el insumo esencial en la mayoría de los tipos de algoritmos de AA. Específicamente, se espera que las empresas bancarias desarrollen procesos y procedimientos rigurosos en torno a la recopilación y el almacenamiento de datos, comprendan sus datos y sus limitaciones, definan adecuadamente las variables y utilicen una muestra representativa de sus datos en el proceso de AA (OEDC, 2018).

Por un lado, el uso de grandes volúmenes de datos y AA podría ayudar a las empresas financieras a ser más eficientes y eficaces en cumplir con las obligaciones de cumplimiento de normativas y hacer que sea más fácil para los supervisores bancarios monitorear conformidad, pero, por otro lado, podría ser utilizado para evitar las regulaciones financieras y hacer más difícil para los supervisores bancarios monitorear el cumplimiento normativo (Jagtiani, Vermilyea & Wall, 2018).

Una de las principales barreras a superar en el uso de estas tecnologías es la aceptación regulatoria (Rao & Verweij, 2017), ya que las entidades financieras consideran que la principal amenaza para la expansión de sus negocios sería un exceso de regulación debido a las restricciones

impuestas, lo que impide su capacidad de competir (OECD, 2018; PricewaterhouseCoopers, 2017a). King (2018) asevera esto último, expresando que la excesiva regulación limita la innovación. Esto debido a que las entidades podrían verse desincentivadas a emprender nuevos negocios, en primer lugar, por el tiempo y los costos asociados al registro y cumplimiento de los requisitos legales y, en segundo lugar, por las consecuencias derivadas del incumplimiento de dichos requisitos (Herrera & Vadillo, 2018). En esta línea King (2018) define que cuanto más *legacy* sea la regulación, más difícil será que los bancos estén preparados para enfrentar los cambios y se transformen porque obliga a la nueva tecnología a una adaptación lenta (King, 2018). Los modelos tradicionales de supervisión resultan inadecuados, por lo que se hace necesario articular fórmulas más ágiles, que promuevan la innovación, dentro de un entorno controlado y con riesgos mínimos (Herrera & Vadillo, 2018). Los marcos regulatorios necesitan un replanteamiento total (King, 2018).

Los riesgos operacionales, informáticos y cibernéticos son una de las principales preocupaciones para las autoridades, junto con los efectos derivados de la presión adicional sobre la rentabilidad de las entidades derivada de una competencia más dura. También hay que tener en cuenta las implicancias de estabilidad financiera a nivel sistémico (Financial Stability Board, 2017), que pueden verse exacerbadas por un aumento en la volatilidad del mercado impulsadas por el uso creciente de herramientas y servicios automatizados, y una mayor concentración como resultado de economías de escala y efectos de red (BBVA Research, 2017). Los reguladores financieros también deben considerar cómo la innovación financiera interactúa con objetivos regulatorios como la inclusión financiera, la estabilidad financiera, la integridad financiera y la protección del consumidor (UNSGSA FinTech Working Group & CCAF, 2019; King 2018). Teniendo en cuenta estos objetivos regulatorios, las innovaciones financieras basadas en tecnología pueden tener impactos positivos o negativos en los mismos (Ver detalle en Anexo XXXVII).

Los reguladores y supervisores reconocen que los marcos regulatorios son anteriores a las nuevas tecnologías y modelos comerciales, y esto puede crear barreras no deseadas para la innovación y también puede generar condiciones desiguales entre los diferentes actores. Los reguladores y supervisores reconocen la necesidad de revisar los marcos existentes para equilibrar las expectativas de seguridad y de protección del consumidor, minimizando el riesgo de obstaculizar la innovación (BBVA Research, 2017).

Ante estos desafíos, los reguladores están avanzando en iniciativas normativas innovadoras que han creado buscan garantizar que la innovación financiera refuerce sus objetivos de política regulatoria, incluidos los objetivos financieros (UNSGSA FinTech Working Group & CCAF, 2019). Existen tres tipos de respuestas de los reguladores y supervisores ante la aparición de modelos de negocios novedosos o disruptivos generando tres enfoques regulatorios: aproximación ex ante con un enfoque restrictivo; ex post con un enfoque proactivo; ex post con un enfoque vigilante.

La primera es denominada aproximación ex ante con un enfoque restrictivo, en la cual se prohíben o restringen los productos o procesos a la vista de sus riesgos o por la incertidumbre que generan al público en general o al supervisor/ regulador (Herrera & Vadillo, 2018; BBVA Innovation Center, 2016 y Rojas 2017). En este enfoque los gobiernos son reacios al riesgo o cargan con mucha burocracia. El gobierno de Estados Unidos es visto como un ejemplo de este enfoque, debido a que el ente regulador a nivel federal (Security Exchange Commission, SEC) se preocupa más por los riesgos, que por colaborar en la innovación (Rojas 2016). Este país tiene distintos organismos reguladores en cada estado, por lo que el cumplimento es difícil y costoso. Adicionalmente, las empresas deben cumplir con regulaciones a nivel estatal que a veces contradicen las normas federales, complicando el cumplimiento de las regulaciones (BBVA Innovation Center, 2016). No obstante Estados Unidos empieza a reconocer que la industria es demasiado importante y las regulaciones demasiado anticuadas. Recientemente, la OCC (Office of the Controller of the Currency) inició una investigación sobre cómo regular fomentar la innovación (BBVA Innovation Center, 2016).

La segunda se trata de una aproximación ex post con un enfoque proactivo en la cual el objetivo es facilitar activamente y regular los nuevos productos o procesos, considerando sus potenciales beneficios sociales y económicos (Herrera & Vadillo, 2018). En este enfoque, también denominado activo, los organismos reguladores trabajan en estrecha colaboración con las empresas financieras para entender los nuevos desarrollos y los próximos obstáculos, y para ayudarlas a hacer frente a estos desafíos. Se basa en establecer regulaciones específicas que permitan la prestación de los servicios con la debida atención a la protección de los consumidores y la prevención de otros riesgos (BBVA Innovation Center, 2016 y Rojas 2017). El enfoque activo es utilizado por los gobiernos de Gran Bretaña, Singapur, Kenia, Irlanda, y Hong Kong, entre otros.

En particular el gobierno del Reino Unido es visto como una referencia de enfoque activo ya que se han producido los avances más concretos en la nueva regulación.

Y por último una aproximación ex post con un enfoque vigilante cuyo objetivo es actuar únicamente cuando los riesgos se han materializado o cuando la actividad ha alcanzado un volumen suficientemente grande o atiende a una cantidad significativa de consumidores financieros (Herrera & Vadillo, 2018). En este enfoque, también denominado pasivo, los organismos reguladores nacionales no tienen un papel activo para desarrollar la innovación, pero tampoco lo obstaculizan. El organismo regulador alemán, BaFin, ha tenido históricamente este enfoque (Rojas 2016) pero actualmente se está moviendo hacia un enfoque activo, aunque es pronto para hablar de un entorno como el que existe en Reino Unido (BBVA Innovation Center, 2016).

A nivel internacional, algunas autoridades financieras han avanzado en el enfoque proactivo y han establecido iniciativas especiales que facilitan la adopción de innovaciones en tecnología financiera. En general, existen tres tipos de iniciativas facilitadoras que abren el camino para la colaboración entre las instituciones tradicionales y las Fintech, y al mismo tiempo promueve la adaptación de los bancos, Oficinas de Innovación, Sanbox regulatorios y Regtech, que se detallan en el Anexo XXXVIII.

Los obstáculos para la innovación regulatoria son numerosos, masivos y entrelazados, incluyen estructuras y dominios (con cimientos que datan del siglo XIX o anterior), culturas organizacionales, sistemas de incentivos, políticas externas e internas, conjuntos de habilidades, marcos legales, procedimientos, ritmos lento, restricciones de comunicación y colaboración; lideres predigitales, entre otros (King, 2018).

Si los reguladores no innovan sus modelos regulatorios, la misma regulación insuficiente y las brechas en los dominios reguladores heredados permitirán que surjan y crezcan nuevos riesgos. Esto incluirá la perdida de la privacidad del consumidor y la seguridad cibernética, el aumento del lavado de dinero, el sesgo y la inexactitud en la toma de decisiones algorítmicas y la inestabilidad en el sistema financiero (King, 2018). También es probable que los bancos continúen siendo forzados a asumir mayores costos y riesgos regulatorios que los competidores y a mantener los sistemas antiguos, como mantener las sucursales abiertas, especialmente en áreas de bajos ingresos que llevará a la pérdida de participación de mercado. Las restricciones y los costos regulatorios continúan impulsando la innovación fuera del sector bancario y hacia un espacio

menos controlado. Los riesgos aumentarán, sin ser detectados, lo que a veces llevará a crisis que producen políticas reactivas que pueden empeorar las cosas a largo plazo. Estas tendencias podrían provocar crisis sistémica (King, 2018)

Se requiere una nueva gobernanza, normas e instituciones ágiles que acompañen las trasformaciones en todas sus dimensiones, cuidando los derechos de las personas, garantizando inclusión tecnológica y social, priorizando tanto el acceso y como el desarrollo de las habilidades. Se requieren leyes que protejan los datos de las personas y de las empresas, que regulen los aspectos de seguridad y de privacidad, que regulen las actividades en la nube. También se necesitan regulaciones sobre los derechos y obligaciones de los nuevos actores y de los nuevos mercados, como el de la economía colaborativa (Estevadeordal et al., 2018). La mayoría de los reguladores actuales necesitan repensar las misiones, el alcance y los protocolos. Necesitan reclutar nuevas habilidades especialmente para ciencia de datos. Deben reorganizarse en torno a los problemas centrados en la tecnología, y crear nuevos roles de liderazgo. Asimismo, tendrán que alterar las culturas que son conservadoras y se centran en gran medida en evitar riesgos en lugar de abrirse a la innovación.

6.5. Otros Desafíos y Riesgos

Se suman a los riesgos hasta acá desarrollados, el riesgo relacionado a ciberseguridad y el riesgo de dependencia de proveedores. Con respecto a los riesgos relacionados a Seguridad los modelos de AA (especialmente, los de aprendizaje profundo) pueden ser engañados por datos de entrada maliciosos. El uso inapropiado de la IA por parte de piratas informáticos es un riesgo grave, ya que muchos algoritmos desarrollados con buenas intenciones pueden ser repensados para hacer daño (Brundage et al., 2018). El uso creciente de Big Data y AA se suma a la importancia de los programas de ciberseguridad de los bancos. Específicamente, Big Data y AA pueden crear nuevos puntos de vulnerabilidad de acceso y datos adicionales valiosos que pueden ser robados o corruptos. Los planes para ataques cibernéticos, el intercambio de información y el monitoreo del propio sistema de un banco son elementos importantes de un programa integral de ciberseguridad (Jagtiani, Vermilyea & Wall, 2018).

Y, por último, también existe el riesgo de dependencia de proveedores. Muchas instituciones financieras dependen de proveedores externos para aprovechar las promesas de la IA. El cumplimiento de la guía de administración de riesgos del proveedor es una importante pregunta

de umbral con la que todas las instituciones financieras deben lidiar a medida que exploran el potencial de la IA a través de un proveedor externo. Los supervisores han enfatizado durante mucho tiempo que los programas de gestión de riesgos de los bancos deberían estar enfocados en el riesgo, en el sentido de que deberían proporcionar supervisión y controles acordes con el nivel de riesgo presentado por los acuerdos de subcontratación. De ello se deduce que la profundidad y formalidad del programa de gestión de riesgos del proveedor de servicios asociado con el uso de los servicios de IA y AA por parte de un banco "dependerá de la importancia crítica, la complejidad y la cantidad de actividades comerciales importantes que se subcontraten" (King, 2018). Otra preocupación en la que están pensando los supervisores bancarios es que muchas instituciones financieras pueden suscribirse a los mismos proveedores externos para sus servicios de IA, las empresas bancarias podrían estar expuestas a los riesgos de los mismos proveedores, lo que podría generar una mayor interconexión y podría tener un impacto sobre la estabilidad global del sistema bancario (Jagtiani, Vermilyea & Wall, 2018). Esto también lo evidencia Fernández (2019) ya que estima que una dependencia significativa de las herramientas y de las infraestructuras proporcionadas por las empresas de tecnología para su uso en operaciones consideradas como críticas podría suponer un incremento del riesgo operativo que soportan las entidades y, dado que el número de proveedores es reducido, derivar en riesgo sistémico.

Universidad de
SanAndrés

7. Capítulo VII.

Estudio de Casos

En el presente capítulo se analizan algunos casos de éxito identificados con el uso de AA ya sea en Bancos tradicionales privados y Bancos Digitales de Argentina, América y Europa, con el objetivo de identificar qué tipo de soluciones de AA se han implementado para poder identificar las oportunidades capitalizadas y que prácticas pueden ser útiles a la hora de incorporar estas soluciones para que se transformen en una oportunidad para los Bancos tradicionales privados en Argentina.

7.1. Visión Banco y su ML Journey

Con sede en Asunción, Paraguay, Visión Banco ofrece servicios de tarjetas de crédito, remesas, servicios públicos y recaudación de impuestos, planes de contribución, planes de pensiones y servicios de transferencia de pagos. Este banco está dentro de los 10 bancos más grandes de Paraguay, tiene más de 95 sucursales y es el mayor empleador del sistema financiero en su país con más de 1700 empleados.

Hace unos años los Científicos de datos en Visión Banco realizaban inteligencia empresarial utilizando técnicas tradicionales, como el modelado dimensional y el traslado de datos a un almacén mediante extracción, transformación y carga (ETL) pero el equipo sabía que necesitaba expandir sus servicios y ofertas a los clientes, determinar fácilmente los riesgos de crédito y hacerlo con precisión y rapidez. También tenía como objetivo mejorar sus prácticas mediante la implementación de análisis predictivos, como predecir el incumplimiento de pago o la pérdida de clientes, pero identificaron que no podrían hacerlo a escala sin nuevas herramientas o tecnologías.

En el año 2017 el Banco comenzó varias etapas, a las que en su conjunto denominó Journey ML. En la primera etapa, que duró un año, utilizaron modelos de regresión logística. La segunda etapa, marcada por la implementación de modelos más avanzados como *Random Forest, GBM*, entre otros, permitió la implementación de estos modelos, pero la analítica predictiva todavía llevaba mucho tiempo y esfuerzo. En la tercera, implementó IA de código abierto e introdujo modelos aún más complejos como *XG Boost, Deep Learning*, etc. y por último la cuarta etapa que consistió en *Auto ML con Driverless Al* que implicaba la implementación de una plataforma de aprendizaje automático de H2O.ai que permite a los científicos de datos e ingenieros de datos

trabajar en proyectos de manera más rápida y eficiente utilizando la automatización y la potencia informática más avanzada para llevar a cabo tareas que, de lo contrario, pueden llevar meses. Dentro del Cuadrante Mágico de Gartner H2O.ai está muy bien conceptuado con muchas fortalezas detectadas, y se coloca en el grupo de proveedores visionarios (Anexo I). Actualmente las implementaciones en Visión Banco pueden reducirse potencialmente a horas o minutos al ofrecer ingeniería automática de características, validación de modelos, ajuste de modelos, selección e implementación de modelos, interpretabilidad de aprendizaje automático, series de tiempo, procesamiento de lenguaje natural (NLP) y canalización automática. Cada fase del Journey llevado a cabo por el Banco mejoró la precisión y la velocidad de construcción e implementación de los modelos.

Los casos de uso implementados en Visión Banco se corresponden con los revisados en el Capítulo IV sección 2, ya que consistieron en los relacionados a gestión de riesgos como calificación de crédito (revisado en el apartado 5.2.1), predicción de default y detección de fraude (apartado 5.2.2); y de cara a los negocios, los casos de uso implementados estuvieron orientados a la propensión de compra (*Lead Scoring* predictivo, apartado 5.2.4); predicción de abandono de clientes (apartado 5.2.4); segmentación de clientes (apartado 5.2.4) y motores de recomendación (apartado 5.2.4).

Desde la implementación de la nueva plataforma los científicos de datos de Visión Banco han ahorrado tiempo e incrementado los ingresos al construir e implementar los modelos. Los logros de Visión Banco con la implementación de AA fueron: ahorro de tiempo, ya que en el pasado el promedio para la construcción de modelos era de 6 meses o más, y en la actualidad lo están haciendo en una semana; mejoras en la precisión con modelos más ajustados, el banco estima que puede obtener millones de dólares en ingresos adicionales al poder orientar mejor las ofertas; y por último duplicación del número de clientes que aceptaron ofertas en comparación con el modelado tradicional. Esto señala que, en este caso, se hacen evidentes dos de las promesas de la IA y el AA revisados en la sección 5.1 Promesas de la IA y el AA, mejora de productividad y el aumento de la demanda de los consumidores debido a que se logró una orientación más precisa de las ofertas a los clientes.

Además de los modelos implementados Visión Banco espera implementar más casos de uso como, por ejemplo, prevención del lavado de dinero (caso de uso abordado en la sección 5.2.2),

predicción de series cronológicas, asistentes virtuales (abordado en el apartado 5.2.5), reconocimiento de voz y sonido, reconocimiento de imagen y detección de video.

Una característica de los que los modelos implementados en Visión Banco es que son interpretables. Este punto es de crucial importancia debido a que demuestra que se pueden utilizar algoritmos complejos y encontrar una forma de que sean explicables debido a las necesidades tanto de los reguladores como de la propia organización, tal como se abordó en el apartado 6.2.2 Opacidad de Datos donde se evidenció la falta de transparencia como uno de los riesgos más críticos a resolver por los bancos a la hora de implementar técnicas de AA.

Por último, otra lección de este caso es el uso de las soluciones de H2O que al ser de código abierto apalanca lo planteado en el capítulo 2.1 Innovación, tecnologías y empresas, donde se trató la democratización de la información, donde se identifica que en la actualidad los usuarios revelan libremente información detallada sobre las innovaciones (Von Hippel, 2005).y esta práctica visible de H2O.ai de desarrollo de AA a través de código abierto lo apalanca.

Este caso se extrajo de (Diaz, Coss & Armenta, 2019) y (H2o.ai, 2019).

7.2. Danske Bank y una solución de aprendizaje profundo para la detección de fraude en tiempo real

Mitigar los fraudes es una prioridad fundamental para los Bancos. El problema es generalizado y se vuelve más frecuente y sofisticado. A medida que los clientes realizan más operaciones bancarias en línea a través de una mayor variedad de canales y dispositivos, existen más oportunidades de fraude. Los viejos métodos para identificar el fraude, como uso de motores escritos por el ser humano identifican un porcentaje pequeño de casos de fraude y produce un número significativo de falsos positivos.

Danske Bank es un banco universal nórdico con fuertes raíces locales. Fundada en octubre de 1871. Su sede se encuentra en Dinamarca, y cuenta entre sus principales mercados a Dinamarca, Finlandia, Noruega y Suecia.

El Danske Bank necesitaba modernizar sus defensas de detección ya que tenía una baja tasa de detección de fraude del 40 % y gestionaba hasta 1200 falsos positivos por día con un 99,5% de casos investigados no relacionados a fraude. Este Banco implementó una solución analítica empresarial y logró una reducción del 60% de falsos positivos con una expectativa de alcanzar el 80 por ciento, aumentó los verdaderos positivos en un 50 por ciento y logró enfocar los recursos

en casos reales de fraude. Como se analizó en la sección 6.2.2, la detección de fraudes es uno de los casos de usos de AA más abordados ´por los autores y con más impacto en la banca.

A continuación, se presenta una figura donde se visualiza la mejora de detección de falsos positivos con los algoritmos de AA. El gráfico muestra cómo las tasas de verdaderos y falsos positivos mejoraron con el análisis avanzado. El punto rojo representa el antiguo motor de reglas, que detectó solo el 40 por ciento de todo el fraude. El aprendizaje profundo permitió a Danske Bank detectar mejor el fraude con falsos positivos mucho más bajos, lo que apalanca la primera promesa de IA y AA logrando mejorar la productividad debido a que logró enfocar los recursos en casos reales de fraude.

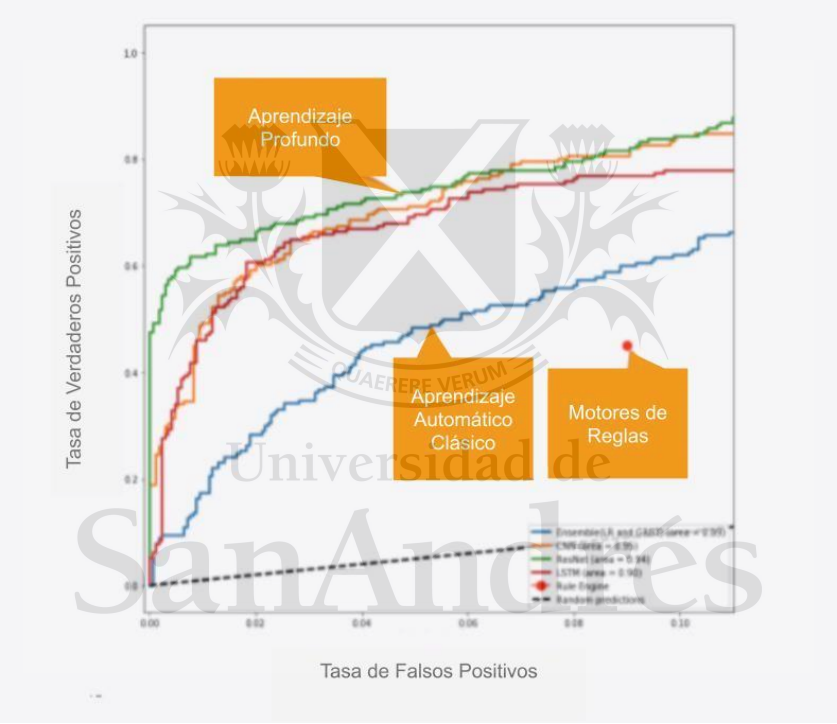

Figura 3. Reducción de Tasa de Falsos Positivos – Caso Danske Bank

Figura que muestra la mejora en la detección del fraude con falsos positivos mucho más bajos. Recuperada de: http://assets.teradata.com/resourceCenter/downloads/CaseStudies/CaseStudy_EB9821_Danske_Bank_Fights_Fraud.pdf. Copyright 2019. Traducción propia.

Para el desarrollo de esta solución Danske Bank integró el software de aprendizaje profundo con dispositivos de unidades de procesamiento gráfico (GPU) que también fueron

optimizados para el aprendizaje profundo. El software ayuda al modelo analítico a identificar posibles casos de fraude a la vez que evita inteligentemente los falsos positivos.

En este caso, al igual que en el caso de Visión Banco, se detecta un patrón que consiste en ir utilizando algoritmos más complejos a medida que se aprende del anterior. En este caso se comenzó por algoritmos de AA clásicos y en la actualidad se utilizan algoritmos de aprendizaje profundo. Estos tipos de AA fueron detallados en la sección 3.4. donde se identificaron las diferencias entre AA supervisado, AA No supervisado y Aprendizaje profundo. A diferencia de las fuentes analizadas en la sección donde se analiza el caso de uso de Detección de Fraude (5.2.2), este ejemplo utiliza no solamente algoritmos supervisados y no supervisados sino también aprendizaje profundo. Este ejemplo también evidencia que a medida que los algoritmos se tornan más complejos, más asertivos son.

En el caso de Danske Bank la intervención humana sigue siendo necesaria en algunos casos. Por ejemplo, el modelo puede identificar anomalías, como las compras con tarjeta de débito que tienen lugar en todo el mundo, pero se necesitan analistas para determinar si es un fraude o si un cliente del banco simplemente realizó una compra en línea. Este ejemplo apalanca lo revisado en la sección 5.3.2 donde se analiza la reconversión de la fuerza laboral como consecuencia de estas nuevas técnicas, donde se concluye que es importante contar con una fuerza laboral híbrida en la que la IA y los seres humanos trabajen codo a codo (Rao & Verweij, 2017). En este caso se redefinió el papel que desempeñan las personas en el nuevo modelo, y consiste en una clara colaboración hombre – máquina (OECD, 2016).

Otra característica no menor de lo logrado por esta solución es que para asegurar transparencia y confianza, la herramienta ofrece explicación e interpretación de la actividad bloqueada. Aquí también, al igual que en el caso de Visión Banco, se evidencia la factibilidad de contar con algoritmos complejos de AA que pueden ser explicables para mitigar las preocupaciones planteadas en los capítulos 5.3.1 Gestión de Datos y Transparencia de Modelos sobre la necesidad de minimizar la opacidad de los algoritmos y la sensación de caja negra que generan, del mismo modo que las decisiones tomadas necesitan ser explicables ante los entes reguladores.

Danske Bank enfrentó varios desafíos al pasar del aprendizaje automático a un entorno de aprendizaje profundo. La solución debía tener la capacidad de identificar el fraude en todos los canales y productos, incluido el móvil. Esto requirió la recopilación e integración de datos de

calidad de fuentes emergentes y existentes, el establecimiento de conductos para el procesamiento de datos y la garantía de que los datos correctos estaban disponibles para las técnicas analíticas correctas. Esto evidencia las prácticas necesarias sobre gestión de datos que se deben implementar para sacar el máximo partido de las técnicas de AA según lo detallado en la sección 5.3.1 Gestión de Datos… donde se analizó que los bancos deben abordar en primer lugar sus retos de gestión de datos existentes, es decir deben revisar su infraestructura de datos creando una arquitectura empresarial que permita la interoperabilidad y el intercambio de información además de la definición de los datos a utilizar y asegurarse de mitigar los riesgos de sesgos (Finextra &Intel, 2018).

La solución implantada en Danske Bank requirió la colaboración multifuncional con científicos de datos, profesionales de TI, ingenieros, representantes bancarios y otros para asegurarse de que la solución brindaría los resultados de alto valor que el banco necesitaba.

El proyecto implicó la integración de soluciones de código abierto y la implementación de modelos de producción, y luego la aplicación de análisis de aprendizaje profundo para ampliar y mejorar los modelos. Se creó un marco para administrar y rastrear los modelos en el sistema de producción, y para asegurar que los modelos sean confiables.

Este caso de estudio se extrajo de (Teradata, 2018).

Universidad de SanAndrés

7.3. DBS Bank y la reposición de cajeros automáticos

El DBS Bank es el banco más grande de Singapur, realiza 25 millones de transacciones al mes en más de 1100 cajeros automáticos. Este banco necesitaba mejorar las malas experiencias de los clientes relacionados a los retiros en cajeros automáticos y reducir los costos de transporte de efectivo. Debido a que este banco tiene una de las tasas más altas de utilización de cajeros automáticos en el mundo, cualquier tiempo de inactividad de un solo cajero significaría inconvenientes para los clientes. Este banco implementó una solución con algoritmos de AA que les ayudó a pronosticar la actividad de retiro y optimizar el proceso de recarga. El motor de optimización consumió los resultados de la predicción como insumo que indicaba cuando era probable que los retiros de efectivo ocurrieran, la verdadera fortaleza del modelo era su capacidad para minimizar tanto el número de posibles retiros como el número de viajes necesarios para reponer la red. Con los modelos implementados el DBS Bank logró pronósticos precisos de los patrones de retiro en cada cajero automático, y definió un programa de reposición para toda la red.

El resultado fue la reducción de los Cash-outs en un 80% y una reducción del 20% de los viajes necesarios para reponer a redes de cajeros automáticos.

Este caso evidencia la aplicación de AA para mejorar a un proceso interno del banco para eficientizar las operaciones de logística de efectivo. Estos casos de uso fueron desarrollados en el apartado 5.2.4 donde se analizaron fuentes que apalancan el uso de algoritmos de AA con el objetivo de recomendar cuánto dinero cargar a los cajeros automático, analizando la segmentación de los clientes, el calendario local de la ubicación del cajero, las condiciones climatológicas y los eventos de la ciudad y su ubicación, entre otros datos. Estos algoritmos pueden determinar óptimamente cuál es la cantidad adecuada para cargar el cajero automático, con el objetivo de no bloquear mucho dinero ni que se impida dar el servicio por falta de este. Este caso es un ejemplo de mejora de productividad debido a que disminuye los costos operativos por la gestión del efectivo y mejora de calidad de servicio al cliente (ambas promesas desarrolladas en la sección 5.1).

Este caso se extrajo de Taylor (2019).

7.4. Banco Superville Argentina y la optimización de Remesas en la Gestión de Efectivo

Banco Supervielle es el séptimo banco privado más grande de Argentina en términos de préstamos y el décimo sumando los bancos públicos. Tiene una larga trayectoria en el sistema financiero argentino con 130 años operando en el país, y una posición competitiva líder en ciertos segmentos atractivos del mercado. El Banco cuenta con presencia directa en las principales regiones y ciudades de Argentina. Al 30 de septiembre de 2018 contaba con 182 sucursales bancarias.

El Banco Superville ha implementado modelos estadísticos avanzados multivariables para la optimización de pedidos de remesas que, a través de un análisis sofisticado de múltiples variables combinadas con una asertiva estimación de demanda, logra optimizar y automatizar el proceso de pedido de remesas y reaprovisionamiento de cajeros reduciendo los costos de gestión entre un 7 y 15%. El objetivo fue lograr un adecuado balance de saldos en las sucursales y cajeros lo que permite cumplir con la demanda de efectivo en el mercado procurando evitar tener saldos ociosos que podrían ser invertidos (costos de oportunidad), gastos por pedidos de remesas de emergencia y costos de transporte.

La oportunidad consistió en mejorar la estimación de demandas de remesas, optimizando cuanto efectivo es necesario enviar, que días y cómo se puede transportar el mismo. Se implementaron algoritmos para identificar cuánto dinero enviar que tuvieran en cuenta estimaciones base diaria de necesidad de dinero, conocimiento del negocio de eventos específicos para trabajar sobre la estimación base, niveles de servicio deseado y stock de Seguridad necesario. Para identificar el momento de envío se tuvieron en cuenta algoritmos para optimizar los días de envío de remesas y el nivel de precisión de la demanda. Para identificar como enviar las remesas se implementaron algoritmos que tuvieran en cuenta los precios de los transportes (fijo, fijo y variable, o variable), el tipo de transporte (por aire o por tierra) y el agrupamiento de sucursales y ATM´s.

Para la implementación de los modelos se trabajaron 4 meses para la recolección de los datos, el armado de los algoritmos y las validaciones. El resultado fue la implementación de una cultura del trabajo orientada, basada y dirigida por los datos (Data Driven) y se redujo el tiempo de cálculo, se liberó la capacidad de sucursales y se disminuyó el costo operativo.

Este caso al igual que el anterior (DBS Bank) implementa técnicas de AA par optimizar la gestión de efectivo, no solamente de ATM´s sino también de sucursales, evidenciando lo analizado en el apartado 5.2.6 sobre casos de uso relacionados a gestión de efectivos en sucursales y cajeros automáticos utilizando algoritmos de AA para pronosticar la demanda de efectivo por ejemplo de sucursales, atendiendo las anteriores demandas y los efectos de calendario. Este caso representa un éxito debido que se ha reducido los costos de operación entre un 7 y 15 % apoyando lo presentado en el capítulo de Promesas de la IA y el AA.

Este caso se extrajo de Accenture (2017d).

7.5. Seacost Bank y el aprendizaje automático para mejorar la experiencia del cliente

Seacoast Bank es un Banco comunitario, el mayor banco del estado de Florida, EE. UU., fundado en 1926. El banco definió ajustar sus estrategias de tratamiento del cliente, así como los esfuerzos de adquisición de clientes para generar rendimientos muy altos. Para esto el Seacoast Bank implementó una solución de aprendizaje automático con el objetivo de obtener información sobre deseos y necesidades de sus clientes y comprenderlos mejor para mejorar la experiencia del cliente.

El primer paso fue reunir los datos de diferentes fuentes para que sean útiles de manera consistente y confiable. Esto evidencia nuevamente lo aseverado en la sección 5.3.1. que para ser uso de técnicas de AA es necesario contar con los datos necesarios por lo que es imprescindible reorganizarlos, incorporar los faltantes y formar una arquitectura que permita la interoperabilidad y el intercambio de información (Finextra &Intel, 2018).

Luego, de la agregación y la contextualización de sus datos para el análisis, el banco implementó modelos de AA para construir un modelo de valor de vida del cliente (CLTV), que mira a cada cliente, mide su valor y especifica en qué y porqué son valiosos. El cálculo de CLTV es fundamental para estimar el potencial de un cliente y cuánto debe invertir el banco para alcanzar y servir a ese cliente para recibir el máximo de ROI (retorno de la inversión). En función de estos resultados identifican los clientes que generan más valor y ajustan las estrategias de tratamiento de clientes, así como los esfuerzos de adquisición para generar rendimientos altos. Con el modelo CLTV implementado, Seacoast agregó modelos predictivos y aplicó el aprendizaje automático para resolver problemas comerciales específicos, como la personalización a escala (estos casos de uso se analizaron en el apartado 5.2.4 donde se identificó que técnicas de AA están siendo utilizadas para ofrecer soluciones anticipándose a las necesidades de los clientes y ofrecer sugerencias adaptadas a ellos). Con la implementación realizada, este banco hoy tiene la capacidad de realizar marketing individual por cliente en función de sus preferencias y su historial de transacciones.

Con la información de los clientes en toda la organización, los profesionales de marketing pueden automatizar las campañas, el personal de primera línea puede fortalecer la relación del banco con sus clientes más valiosos, y los banqueros comerciales pueden ver sus portafolios personales de clientes y realizar un seguimiento de su desempeño mediante paneles interactivos.

En el pasado, si los empleados de Seacoast querían obtener más información sobre un cliente, tenían que ejecutar una solicitud de servicio para cada consulta. Esta solución le permite al personal del Banco acceder y visualizar datos de sus clientes para su operación. Por ejemplo, pueden visualizar tendencias a más de un año, hasta cuatro años.

La plataforma de análisis de clientes de Seacost Bank ha generado ganancias tanto en eficiencia como en rentabilidad. Desde la implementación de las nuevas tecnologías los ingresos ajustados por riesgo por cliente han aumentado en un 30 por ciento, mientras que el ROI para las campañas de marketing automatizadas es de tres dígitos, logrando una mejora de la productividad

y de los servicios brindados al cliente (promesas desarrolladas en la sección 5.1). El Seacost Bank logró maximizar el beneficio con un mejor costo, detectando patrones y comportamientos en sus clientes lo que les permite ofrecerles productos personalizados, logrando mejor experiencia y mayor satisfacción (desarrollado en el apartado 5.2.4).

Para el éxito de este caso fue fundamental el ordenamiento de sus datos, evidencia que, como en casos anteriores es necesario primero definir una estrategia de datos que permita el desarrollo de AA sobre ellos; y la maduración respecto del aprendizaje automático y los algoritmos utilizados que al igual que el caso de Danske Bank demuestran que es necesario un camino de aprendizaje sobre los algoritmos utilizados.

Este caso también apalanca lo desarrollado en el apartado 5.2.4 Customer Insights y Personalización donde se identificó que las áreas más impactadas por el la IA y el AA son las que tienen cierto nivel de interacción con los clientes, particularmente afectando masivamente a las áreas de marketing (King, 2018).

Este caso de obtuvo de SAS (s.f.).

7.6. Principales aspectos relevados en los casos de estudio

A continuación, se muestra una tabla con los principales aspectos de cada caso de estudio, identificando aplicaciones implementadas, oportunidades desarrolladas y variables principales analizadas.

Tabla 7. Principales aspectos relevados en casos de estudio

Caso	***Aplicaciones***	***Oportunidades***	***Aspectos principales de la implementación***
Visión Banco	Calificación de Crédito Predicción de Default Detección de Fraude Propensión de Compra Predicción de abandono de clientes Segmentación de clientes Motores de Recomendaciones	Reducción de tiempos en la implementación de modelos Mejora en los ingresos Duplicación de la venta de ofertas	Utilización de código abierto de AA Implementación de Modelos interpretables Implementación en etapas para madurar la precisión y la velocidad de construcción e implementación de los modelos
Danske Bank	Detección de Fraude	Reducción de falsos positivos mejorando la productividad debido a que se logró enfocar	Mejora incremental de modelos de AA

Caso	*Aplicaciones*	*Oportunidades*	*Aspectos principales de la implementación*
		los recursos en casos reales de fraude	Implementación de Modelos interpretables Implementación de un proceso que asegure la recopilación e integración de datos de manera de que los mismos sean correctos y estén disponibles Rediseño del trabajo, colaboración hombre – máquina
DBS Bank	Gestión de Efectivo en ATM´s	Mejora en la experiencia del cliente mejorando el servicio debido a la reducción en un 80% de los *cashouts* Mejora de la productividad debido a la reducción de un 20% en los viajes de reposición	Fortaleza del modelo de AA implementado
Banco Supervielle Argentina	Gestión de efectivo en ATM´s y sucursales	Mejora en la productividad reduciendo costos de gestión entre un 7% y un 15%	Implementación de algoritmos con nuevos datos Fuerte etapa de recolección de datos y armado de algoritmos Cultura de trabajo *Data Driven*
Seacost Bank	Marketing individual Seguimiento de clientes	Mejoras en eficiencia y productividad logrando ingresos ajustados por riesgo por cliente de mas del 30% y roi de 3 dígitos de las campañas comerciales	Implementación de algoritmos que permiten detectar patrones de comportamiento de clientes Recopilación y organización de datos de diferentes fuentes para que sean consistentes y confiables Rediseño del trabajo, colaboración hombre – máquina

Elaboración propia en función de lo relevado en los casos de estudio.

8. Capítulo VIII.

Trabajo de Campo - Análisis Cualitativo de las Entrevistas

Como se detalló en la sección de Metodología, para el trabajo de campo se llevaron a cabo entrevistas a diferentes referentes tanto de Banco tradicionales (Incumbentes); Fintechs y Bancos Digitales (No Incumbentes); ente regulador de la industria (BCRA); referentes académicos, asesores y docentes expertos en digitalización o transformación digital, inteligencia artificial y/o aprendizaje automático; consultores reconocidos en el mercado y proveedores de soluciones de Inteligencia Artificial y Aprendizaje Automático líderes en la industria. En el Anexo II se detallan las referencias de cada uno de los entrevistados.

Los resultados de las encuestas se analizaron abordando los diferentes objetivos tanto principal como complementarios del presente trabajo. El objetivo primario consistió en analizar los posibles aportes que el aprendizaje automático puede realizar a los Bancos Tradicionales Privados, y los objetivos complementarios planteados relacionados a identificar las promesas y oportunidades, así como las principales barreras, desafíos y riesgos que estimulan o inhiben la adopción de nuevas tecnologías. Para ayudar a alcanzar dichos objetivos se analizaron las entrevistas realizadas en función de los ejes planteados, que se organizan en las secciones siguientes: Situación actual de los Bancos Tradicionales Privados producidas por el contexto de disrupción del sistema financiero; Fortalezas; Promesas y Oportunidades; Aplicaciones; Barreras y Desafíos; Riesgos y por último, un análisis de las perspectivas sobre la adopción.

8.1. Situación Actual de los Bancos - Impacto de la Disrupción

Durante las entrevistas llevadas a cabo, se identificaron varias amenazas relacionadas a la aparición de nuevos competidores. En el Anexo XLI se realiza un resumen muy sintético de lo identificado por cada entrevistado.

Tal lo analizado en el Marco Teórico existe una gran preocupación por las amenazas que representa el sector Fintech y el impacto en la desagregación de los servicios financieros. Aunque no hay, por ahora, una amenaza de desaparición o destrucción de los Bancos tradicionales, pero si existen amenazas de redistribución de los márgenes de ganancia y pérdida de clientes para aquellos incumbentes que no se actualicen de manera rápida. La Banca está acostumbrada a brindar todo el abanico de servicios financieros, y hoy no sólo compite con otras instituciones que brindan estos, sino que compite con muchas empresas que dan servicios puntuales de nicho, es decir, la amenaza

para los Bancos es la desagregación de los servicios financieros (I.R. Carballo, comunicación personal, 26 de abril de 2019). Esto concuerda con lo planteado en la sección 4.3 Retos competitivos de los incumbentes del sistema financieros, donde se estableció que la abundancia de servicios amigables para el cliente brindados por las Fintech está desagregando la oferta de los bancos, creando grietas por las que las entidades financieras que no se adapten podrían perder no sólo los beneficios de ese negocio, sino también su papel como interlocutor central con el cliente en lo relativo a su vida financiera (OECD, 2018; PricewaterhouseCoopers, 2016; Rojas, 2016). Particularmente en los países en desarrollo hay un mercado muy grande para que las nuevas iniciativas se expandan sin competir directamente con la Banca, lo que significa que los Bancos no van a poder acceder a esos nuevos mercados perdiendo esas oportunidades (I.R. Carballo, comunicación personal, 26 de abril de 2019), lo que también lo expresan (Rojas, 2016; OECD, 2018).

Los que pueden llegar a constituir una verdadera amenaza son las grandes empresas tecnológicas, Google, Amazon, Facebook, Apple, Tencent, WeChat, Microsoft, IBM, debido a la proliferación a nivel mundial que tienen (I.R. Carballo, comunicación personal, 26 de abril de 2019). Los grandes de la tecnología ya están brindando servicios financieros (Rojas, 2016). Teniendo en cuenta, además, que el 72% de los Millennials en el último *Disruption Index,* dijeron que preferían un servicio financiero de Google, Apple, Amazon antes que, del Banco Nacional (I.R. Carballo, comunicación personal, 26 de abril de 2019). Dato que se suma al analizado en la sección 4.2 El nuevo consumidor de servicios financieros, donde se expresaba que el Millenial Disruption Index indicaba que el 75% de los millenials responderían mejor a las ofertas de Amazon, Google, Apple o PayPal (Rojas, 2016). El obstáculo más grande de los bancos tradicionales privados es que recientemente comienzan a percibir la posibilidad de que estos grandes nuevos competidores, como por ejemplo en Argentina, Mercado Libre, y en España, Amazon. Son empresas muy volcadas a experiencia de los clientes, y lograron lo que más les cuesta a los bancos que es la captación de clientes (G. Marchionni, comunicación personal, 14 de mayo de 2019). Las soluciones de las Fintech que apalancan es una de sus fortalezas que es la experiencia de clientes (Rojas 2016; King 2018)

No entender y no implementar este tipo de tecnologías reduciría la efectividad de los servicios que presta las instituciones bancarias y solo competiría en servicios básicos de *comodity* sin diferenciarse y los clientes terminarían migrando de institución (E. U. Peralta, comunicación

vía correo electrónico, 3 de mayo de 2019). Si la banca no comienza a utilizar *Machine Learning* quedaría relegada con respecto a otros jugadores como Mercado Libre, "es hacerlo o desaparecer" (N. Martins, comunicación telefónica, 24 de junio de 2019). Esto apalanca lo planteado en la sección 4.3 donde se estableció que los bancos que no adopten una estrategia de transformación digital quedarían relegados a los segmentos más regulados de la banca o a ejecutar funciones de *backoffice* para las Fintech (Rojas, 2016).

En la actualidad ya hay más de 133 en Argentina que impactan en diferentes puntos de la cadena de valor de los Bancos y siguen creciendo. Están acostumbradas a la implementaciones ágiles y rápidas y trabajan sobre las necesidades de los usuarios (F. Vidal, comunicación telefónica, 26 de abril de 2019). Esto también apalanca lo descripto como fortaleza de las Fintech en la sección 4.3, donde se identifica que el potencial disruptivo de las Fintech tiene que ver con su adaptabilidad a las necesidades individuales de los clientes, brindando pocos servicios centrales ofreciendo a los clientes servicios más personalizados, más rápidos y más rentables (OECD, 2018; Rojas, 2016).

En este mismo sentido Juan Martín Maglione expresó que las empresas que ya utilizan este tipo de tecnologías van a absorber *marketshare* de los Bancos (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019). Para José Luis Nugoli, Alejandro Bolaños y Ana Hidalgo de SAS hay un espacio muy grande de no bancarizados y de toda una nueva generación que se viene con conceptos diferentes, que representan una clara amenaza para los Bancos tradicionales privados (J. L. Nugoli, comunicación personal, 3 de junio de 2019; A. Bolaños, 3 de junio de 2019; A. Hidalgo, 3 de junio de 2019).

Por otro lado, la colaboración entre los Bancos y los diferentes actores del ecosistema Fintech es una práctica que se está evidenciando según los entrevistados. Varios de ellos han mencionado la existencia de esa colaboración como estrategia de crecimiento tanto para los Bancos como para las Fintech. Se pueden ver grandes avances en términos de colaboración entre Bancos y Fintech, sobre todo en el resto del mundo, donde se va hacia una estrategia de "copetición" como lo ha implementado el BBVA (I. R. Carballo, comunicación personal, 26 de abril de 2019). Las Fintech están colaborando con los Bancos (F. Vidal, comunicación telefónica, 26 de abril de 2019; J. P Bruzzo, comunicación personal, 3 de mayo de 2019), por ejemplo, Moni tiene acuerdos con 14 bancos. La colaboración no se visualiza a gran escala, pero algunas Fintech están colaborando con bancos utilizando IA (J. P Bruzzo, comunicación personal, 3 de mayo de 2019). El ecosistema Fintech aceleró el proceso de transformación de la Banca y hoy se está integrando muchas Fintech

con ls Bancos tradicionales, por ejemplo, el 90% de las actividades de Digital Bank Latam están enfocadas a esto. En algunas ocasiones los Bancos solicitan como servicio buscar soluciones para cierto tipo de iniciativas y en algunas oportunidades es mucho más fácil integrar una *startup* o una Fintech que hacer todo un desarrollo tecnológico (G. Marchionni. Comunicación personal, 14 de mayo de 2019). Se están comenzando a ver algunas iniciativas de colaboración (I. Perrone, comunicación personal, 2 de mayo de 2019). Esto coincide con la lo analizado en la sección 4.4 ya que las asociaciones entre los bancos y las FinTechs todavía están en su etapa incipiente. Pero existe una tendencia positiva (King, 2018; PricewaterhouseCoopers, 2017a; P PricewaterhouseCoopers, 2017b; Rojas, 2016; Anif, Felaban y CAF, 2018). Lo analiado hasta aca apalanca la estrategia de colaboración entre Fintech y Bancos tradicionales como una posibilidad para ambos tipos de organizaciones para aprovechar cada una las fortalezas de la otra. En el caso de las Fintech tienen nuevas ideas, implementaciones ágiles, realizan análisis de vanguardia y gestión de datos, adquieren clientes en forma online y tienen un diseño optimizado de experiencia OnLine/móvil. Por el lado de los bancos, tienen una amplia base de clientes existentes, un amplio conjunto de productos ya existentes, bajo costo de capital, protección regulatoria y fuente de ingresos (King, 2018, Rojas, 2016).

Además de las amenazas identificadas, que tuvieron un mayor peso durante las entrevistas, algunos entrevistados identificaron fortalezas de los Bancos tradicionales, características que pueden ser aprovechada por estos ante el escenario de disrupción. En el Anexo XLII se realiza un resumen de lo identificado por cada entrevistado.

Los Bancos tienen acceso a recursos monetarios, infraestructura y clientes (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019). Estas fortalezas son coincidentes con algunas de las detalladas en la sección 4.4 donde se establece que los bancos tienen una amplia base de clientes existentes, un amplio conjunto de productos ya existentes, un bajo costo de capital, protección regulatoria y fuente de ingresos (Citi GPS, 2016; King, 2018; Rojas, 2016).

Otra fortaleza que identificaron los entrevistados es el poder de adaptación que mostraron los Bancos tradicionales en el pasado (I. Perrone, comunicación personal, 2 de mayo de 2019; I. R. Carballo, comunicación personal, 26 de abril de 2019). “Los Bancos siempre se adaptaron a los cambios Tecnológicos” (I. Perrone, comunicación personal, 2 de mayo de 2019).

8.2. Promesas y Oportunidades

En el análisis de las entrevistas realizado se encontró que el 100% de los entrevistados están de acuerdos en que IA y AA representan una oportunidad para los Bancos y que las promesas se van a volver realidad para la Banca privada tradicional, en distintas ventanas de tiempo, pero finalmente se van a volver realidad. En el Anexo XLIII se realiza un resumen muy sintético de lo identificado por cada entrevistado en este aspecto. Lo identificado por cada entrevistado se tradujo a una tipología de oportunidad y se elaboró el siguiente gráfico que resume lo dicho por estos.

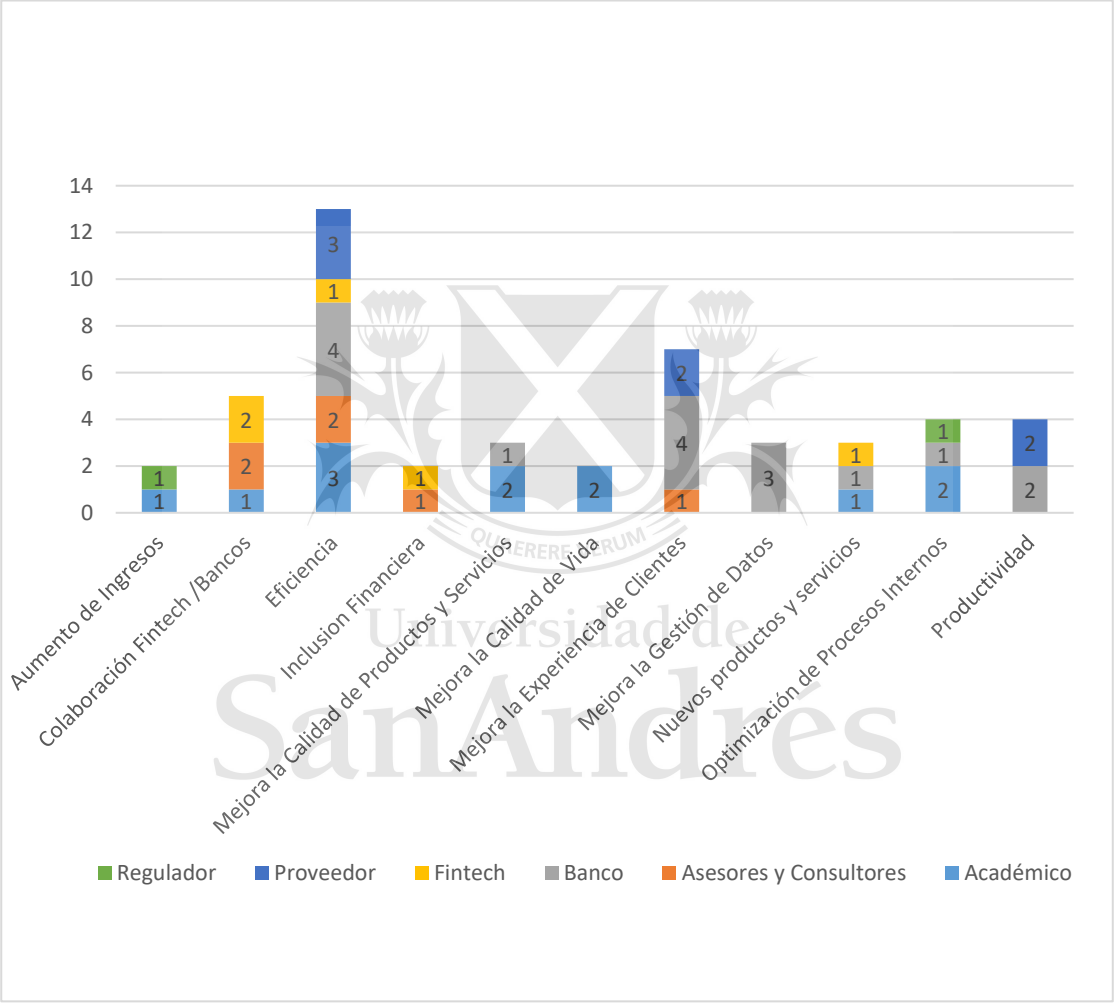

Figura 4. Oportunidades detectadas por los entrevistados

Esta figura muestra la cantidad de respuestas por tipo de oportunidad por tipo de entrevistado.
Elaboración propia.

Algunos entrevistados destacaron promesas y oportunidades que la IA le otorgará a la humanidad en general, como mejoras a las condiciones laborales y mejora a la calidad de vida (H.

Borré, comunicación personal, 14 de mayo de 2019). "El advenimiento de esta tecnología mejora la calidad de vida, porque hace más efectivo el resultado que se obtiene. Hay que aprovechar este tipo de tecnologías para incorporarlas a la organización y lograr una ventaja competitiva con respecto al entorno" (C. A. Giménez, comunicación personal, 7 de mayo de 2019).

Ya entrando a las oportunidades para los Bancos tradicionales privados particularmente, entre las oportunidades identificadas se destaca la reducción de costos y la mejora en la productividad, ya que un alto porcentaje de los entrevistados los identificaron.

El aprendizaje automático proporciona muchas oportunidades para eficientizar los procesos, obsoletos o ineficientes (N.Martins, comunicación telefónica, 24 de junio de 2019). Los bancos tienen procesos con mucha burocracia, por lo que hay una gran oportunidad no solamente para brindar un servicio de mayor calidad sino también de reducir costos (I.R. Carballo, comunicación personal, 26 de abril de 2019). Estas tecnologías pueden poner a los servicios financieros en otro nivel por la velocidad, sofisticación, especialización, escucha y entendimiento del cliente. A través de ellas se posibilita ofrecer a los clientes no lo que decide la entidad, en forma sistemática, sino que se puede ofrecer con inteligencia y en forma personalizada, es decir selectivamente y no masivamente como las entidades están acostumbradas (E. U. Peralta, comunicación vía correo electrónico, 3 de mayo de 2019). La IA y el AA ayudan a los Bancos a ser significativamente más eficientes, y no necesariamente con una reducción de costos sino en la reasignación de esos recursos a mejores actividades para atender mejor a los clientes, para darle una mejor experiencia y un mayor valor (F. Turri, comunicación personal, 6 de junio de 2019). En el proyecto de Transformación Digital que está llevando adelante el Banco Galicia, se está contemplando el uso de IA en todos los *journey* que se están digitalizando. Si bien se comenzó con el uso de los asistentes virtuales, hoy se ve como oportunidad a escala en general (F. Turri, participación conferencia, 23 de mayo de 2019). Esto es coincidente con lo analizado en la sección 5.1 Promesas de la IA y AA donde se identificó que las organizaciones a medida que más utilizan estas técnicas más potenciales de crecimiento ven en ellas; las empresas con menos experiencia tienden a centrarse en la reducción de costos, pero a medida que se familiarizan con estas tecnologías las utilizan para otros casos de uso que le permitan aumentar su participación en el mercado (Daugherty &Wilson, 2018; McKinsey, 2017). "La Inteligencia artificial apalanca nuestros tres ejes de estrategia: eficiencia, ya que la inteligencia artificial acompaña los colaboradores para que dejen de hacer actividades que no le dan valor a la compañía; experiencia

de cliente y crecimiento ya que creemos que todo nuestro negocio va a crecer exponencialmente debido al procesamiento de datos que vamos a poder realizar a través del uso de herramientas de *machine learning*" (F. Turri, participación conferencia, 23 de mayo de 2019).

Con respecto a la reducción de costos se daría a través de la optimización de procesos automatizables (por ejemplo, Gestión de Cobranzas, Centros de Atención, BackOffice); por reducción de gestión en la red de sucursales (ya que indefectiblemente desaparecerían y/o cambiarían su impronta) y en los centros de atención (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019). Con respecto al aumento de ingresos, la IA y el AA serán fundamentales para realizar un *pricing* personalizado. IA y AA también pueden lograr una mejora sustancial en la segmentación de clientes incorporando variables psicográficas (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019; M. H. González, comunicación personal, 7 de mayo de 2019). Y por último la IA y el AA pueden ayudar a crear nuevos productos orientados a esos nuevos segmentos creados (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019). Esto refuerza los casos de uso presentados en la sección 5.2.4 Customer Insights y Personalización, donde se consideran diferentes datos no solamente los datos históricos de los bancos, para analizar la segmentación de los clientes y la oferta de productos y servicios (Laurens & Zou, 2016).

La IA también puede ayudar a crear modelos de optimización para las campañas de marketing que posibilitarían no invertir lo mismo por cada cliente ya que el valor de cada uno no impacta en forma uniforme en el ROI. Es decir que se puede optimizar el ROI de las campañas (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019; E. U. Peralta, comunicación vía correo electrónico, 03 de mayo de 2019). Estas opiniones se alinean al caso de éxito de Seacost Bank (apartado 7.5) donde se logró implementar técnicas de AA para elaborar campañas de marketing diferenciadas por el valor que aporta cada cliente. También King (2018) apoya el concepto que una de las áreas más impactadas por la IA y el AA es la de marketing.

Hasta acá, lo recabado en las entrevistas relacionado a oportunidades de reducción de costos, aumento de productividad, mejora en la calidad de los productos y servicios se alinea a lo planteado en la sección 5.1 Promesas de la IA y el AA.

Además de la reducción de costos, la IA y el AA en los bancos puede ayudar a la inclusión financiera, ya que hoy hay mucha información de los clientes o no clientes que los bancos no toman y que, por ello, por ejemplo, no se otorga un préstamo. Hay personas que no logran el *score*

definido por los bancos, pero su comportamiento de pago es bueno y podrían ser acreedoras de un préstamo. A los clientes les es indiferente si es una Fintech, un neo banco o un banco tradicional, el cliente quiere que lo traten bien como cliente, y que pueda acceder a servicios buenos y de calidad, y la IA y el AA pueden colaborar con los Bancos para lograrlo (J. P. Bruzzo, comunicación personal, 3 de mayo de 2019). Este punto soporta lo identificado en la sección donde se revisa el caso de uso de calificación crediticia (apartado 5.2.1), ya que apalanca que se están recurriendo cada vez más a fuentes de datos adicionales, no estructurados y semiestructurados, que incluyen actividades de redes sociales, uso de teléfonos móviles y mensajes de texto, para capturar una visión más matizada de la solvencia crediticia y mejorar la precisión de la calificación de los préstamos (Financial Stability Board, 2017). Además, se relaciona con la sección 4.1 El nuevo consumidor de servicios financieros donde se identificó que hoy los clientes tienen gran cantidad de información lo que les permite elegir de manera adecuada el producto que se acomode más a sus necesidades. Por otro lado, corrobora lo identificado por el Financial Stability Board (2017) que estima que puede contribuir a un sistema financiero más eficiente.

Figura 5. Oportunidades de la IA y AA en los bancos tradicionales privados

Esta figura es de elaboración propia y resume lo obtenido de las entrevistas llevadas a cabo en el trabajo de campo del presente trabajo.

8.3. Aplicaciones

Con respecto a las aplicaciones de AA en Banca tradicional el total de los entrevistados otorgaron variados ejemplos de casos de uso. En el Anexo XLIV se realiza un resumen muy sintético de lo identificado por cada entrevistado en este aspecto. A continuación, se muestra un gráfico resultado de agrupar las respuestas en tipologías.

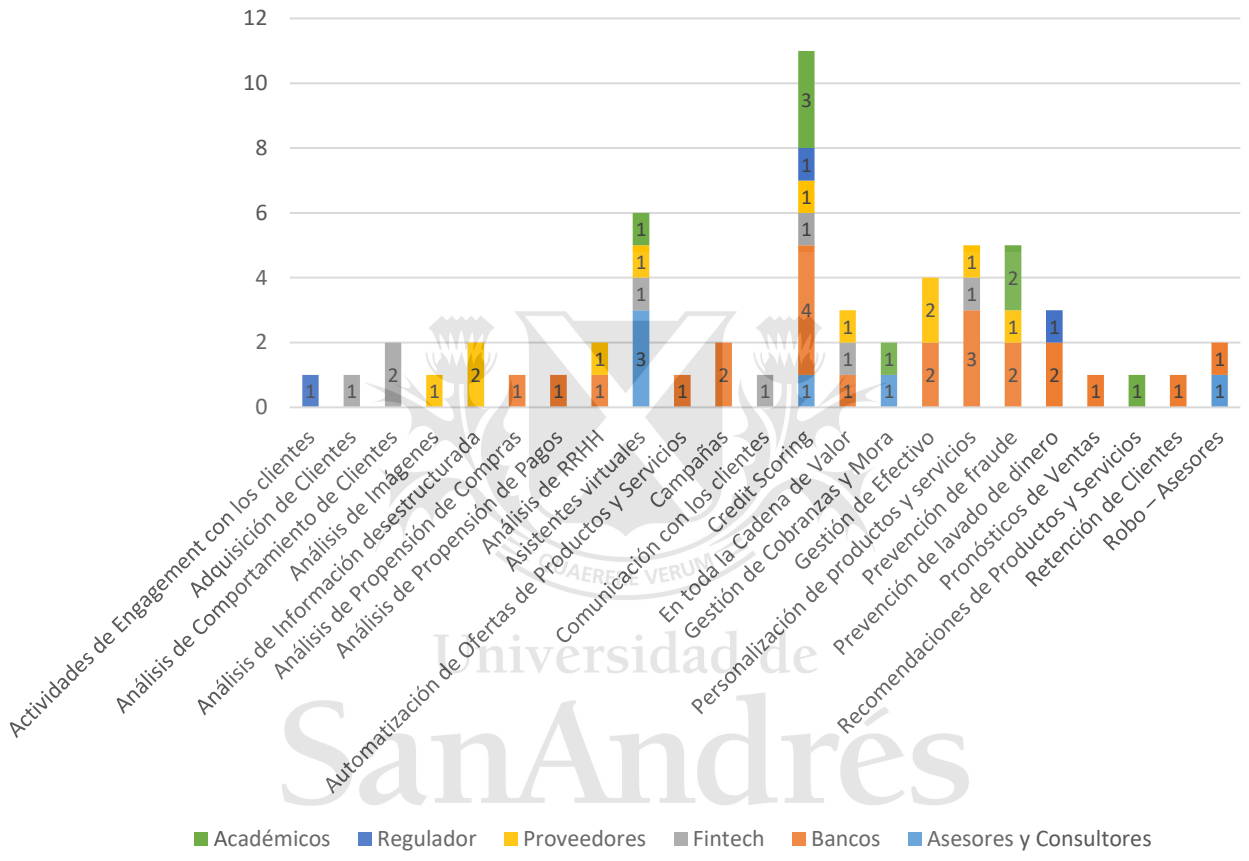

Figura 6. Aplicaciones de AA identificadas por los entrevistados

La figura muestra la cantidad de respuestas por tipo de aplicaciones de AA en los Bancos tradicionales privados. Elaboración propia.

Como resultado de las entrevistas se puede identificar que el AA puede sumar valor a toda la cadena de valor de todas las compañías en general (L. Aranda, comunicación personal; 3 de mayo de 2019), es decir que puede ayudar a todos los procesos donde haya datos y se deba tomar decisiones (F. Turri, comunicación personal, 6 de junio de 2019; A. Hidalgo, comunicación personal, 3 de junio de 2019). Esto es coincidente con lo identificado en el apartado 5.2

Aplicaciones de aprendizaje automático en la Banca (Casos de Uso), donde se analiza que las aplicaciones de esta tecnología en los distintos ámbitos del sector financiero son múltiples y se pueden encontrar en toda la cadena de valor y para todo tipo de servicios (Accenture, 2018b; King, 2018; Fernández, 2019), desde las tareas de procesamiento (back-office) hasta la interacción con el cliente o en el mercado (front-office), pasando por las actividades relacionadas con el control y con el monitoreo de la operativa (middle-office).

Las aplicaciones más identificadas por los entrevistados fueron las relacionadas con el de Análisis de Comportamiento de Clientes. Los casos de uso relacionados a *Credit Scoring* (para créditos hipotecarios, personales, tarjetas de crédito, entre otros) fueron identificados en un alto porcentaje. Se puede incorporar a los algoritmos de AA datos demográficos y de comportamiento a la hora de otorgar un crédito por ejemplo (C. A. Giménez, comunicación personal, 7 de mayo de 2019). Con estos algoritmos se puede otorgar un préstamo a personas que no logran el score definido por los bancos, pero su comportamiento de pago es bueno (J. P. Bruzzo, comunicación personal, 3 de mayo de 2019; L. Aranda, comunicación personal, 3 de mayo de 2019). Cabe destacar que lo mencionado por los entrevistados se alinea al apartado 5.2.1 donde se destallan los casos de uso y los algoritmos relacionados a calificación crediticia.

La personalización de servicios también fue identificada en varias oportunidades, por los entrevistados. En el Banco Galicia, por ejemplo, se está remplazando la plataforma comercial incorporando técnicas de AA para que se pueda hacer la mejor oferta al cliente *real time* a través de la combinación de los datos de ese cliente con información estructurada y no estructurada (F. Turri, comunicación personal, 6 de junio de 2019). María Fernanda González expresó que la inteligencia artificial ayuda a mejorar la experiencia de los clientes (M.F. González, participación conferencia, 23 de mayo de 2019). Estos ejemplos apalancan los casos de usos que se encuentra en el apartado 5.2.4 Costumer Insights y Personalización.

El análisis de comportamiento se puede aplicar AA al entendimiento del potencial de los clientes en cuanto a la capacidad de pago o cancelación de deuda y al análisis de comportamiento para identificar la posibilidad de que un cliente se dé de baja (J. P. Bruzzo, comunicación personal, 3 de mayo de 2019; L. Aranda, comunicación personal, 3 de mayo de 2019; E. U. Peralta, comunicación vía correo electrónico, 3 de mayo de 2019). También se puede sumar como ejemplo las experiencias que se están presentando en gestión de cobranzas y negociación de mora, utilizados para focalizar los esfuerzos en los clientes que se identifiquen con mayor voluntad de

pago (G. Marchionni, 14 de mayo de 2019; J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019). El AA puede ayudar para evaluar cuando un cliente va a dejar de operar, cuando va a entrar en mora o se debe bajar la línea de crédito (J. P. Bruzzo, comunicación personal, 3 de mayo de 2019). Otro caso de uso identificado dentro de esta categoría es el Análisis de Propensión de Compras (E. U. Peralta, comunicación vía correo electrónico, 3 de mayo de 2019) para hacer *upselling* o *croselling*, donde se realizan recomendaciones de servicios a los clientes que se ajustan mejor a su tipo de consumo (C. A. Giménez, comunicación personal, 7 de mayo de 2019). Otro ejemplo es el uso de sistemas de recomendaciones de promociones o servicios (C. A. Giménez, comunicación personal, 7 de mayo de 2019). También estos casos están relacionados a las diferentes aplicaciones detalladas en el apartado 5.2.4 Costumer Insights y Personalización.

Otro grupo de aplicaciones identificadas fueron las relacionadas a *engagement* con los clientes (M. H. González, comunicación personal, 7 de mayo de 2019), por ejemplo, el AA puede ayudar en la comunicación con los clientes en todos los puntos de contacto ya que lo principal es entender en profundidad al mismo y mejorar la atención que es la principal queja en los reclamos a los Bancos tradicionales. También acotó que es muy importante la optimización de los procesos que hacen al *costumer journey* del cliente, el AA es fundamental para pasar de los procesos más tradicionales donde la relación con el cliente es más física a procesos más digitales, esto no solamente impacta en el *engagement* con el cliente, sino que permite digitalizar los procesos que hace posible capturar datos y entender el comportamiento de los clientes (L. Aranda, comunicación personal, 3 de mayo de 2019).

La Atención de Clientes y la comunicación con los clientes también ha surgido en varios entrevistados como aplicación de las soluciones de AA. Se identificó que los Bancos están utilizando los asistentes virtuales como punta de iceberg para la implementación de estas tecnologías (I. Perrone, comunicación personal, 2 de mayo de 2019). Para algunos entrevistados ya en la actualidad se están implementando aplicaciones de atención de clientes en forma personalizada (G. Marchionni, comunicación personal, 14 de mayo de 2019; E. U. Peralta, comunicación vía correo electrónico, 3 de mayo de 2019; J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019). El asistente virtual del Banco Santander Río que comenzó en 2016 atendiendo consultas de un producto en particular y fue creciendo y aprendiendo hasta hoy que resuelve el 90% de preguntas de casi todos los productos del banco. (S. Bauza,

participación conferencia, 23 de mayo de 2019). Lo relevado en estas entrevistas apalanca el caso de uso detallado y analizado en el apartado 5.2.5 Asistentes virtuales orientados a clientes.

También se han identificado aplicaciones de Robo-Asesores (E. U. Peralta, comunicación vía correo electrónico, 3 de mayo de 2019; I. Perrone, comunicación personal, 2 de mayo de 2019). Estas aplicaciones mencionadas sustentan lo analizado en la sección 5.2.3. Asesoramiento y Planificación.

También se mencionó como caso de uso la detección de fraude (C. A. Giménez, comunicación personal, 7 de mayo de 2019; H. Borré, comunicación personal, 14 de mayo de 2019 y sobre todo en tiempo real (N. Martins, comunicación telefónica, 24 de junio de 2019). Se pueden sacar patrones potencialmente fraudulentos observando transacciones. Por ejemplo, se puede cuantificar el tiempo en que se realizan una serie de operaciones y con esa información identificar patrones fraudulentos si se están realizando una serie de operaciones en un muy corto tiempo existe una posibilidad de que haya un algoritmo o persona que esta impulsivamente tomando decisiones y ese patrón se puede capturar y levantar una alerta porque rompe lo que se llama el *outlier* de comportamiento (C. A. Giménez, comunicación personal, 7 de mayo de 2019). Lo aportado por los entrevistados con respecto a detección de fraude sustenta lo analizado en las fuentes en el apartado 5.2.2 Detección de Fraude.

Varios entrevistados también identificaron aplicaciones de AA a los procesos internos de los Bancos (F. Turri, comunicación personal, 6 de junio de 2019), por ejemplo, automatización de procesos de Backoffice (J. M. Maglione, comunicación personal, 15 de mayo de 2019) y optimización de procesos para pasar de procesos más tradicionales (punto de contacto físico) a procesos más digitales (J. P. Bruzzo, comunicación personal, 3 de mayo de 2019). También se mencionaron casos de uso relacionados a modelos predictivos para entender cómo distribuir mejor el efectivo y bajar los costos de distribución (F. Turri, comunicación personal, 2019). Lo mencionado apalanca algunos de los casos analizados el apartado 5.2.6 Otras aplicaciones. Con respecto a procesos internos, también se podría aplicar aprendizaje automático para lo que se denomina *People Analytics,* para analizar perfiles de los empleados, desarrollo de carrera, evaluaciones 360 (N. Martins, comunicación telefónica, 24 de junio de 2019; J.L. Nugoli, comunicación personal, 3 de junio de 2019).

Para el referente del Banco Central de la República Argentina entrevistado, otras aplicaciones de la IA y AA en Banca pueden ser: monitoreo de prevención de lavado de dinero,

gestión de inversiones y actividades de trading (M. H. González, comunicación personal, 7 de mayo de 2019). Estos casos se detallan en el apartado 5.2.6 otras aplicaciones.

Por último, un dato identificado es que los algoritmos que hoy mejor se desempeñan son los Supervisados (H. Borré, comunicación personal, 14 de mayo de 2019) coincidiendo con lo expresado por (Brynjolfsson & McAfee, 2017) analizado en la sección 3.4.

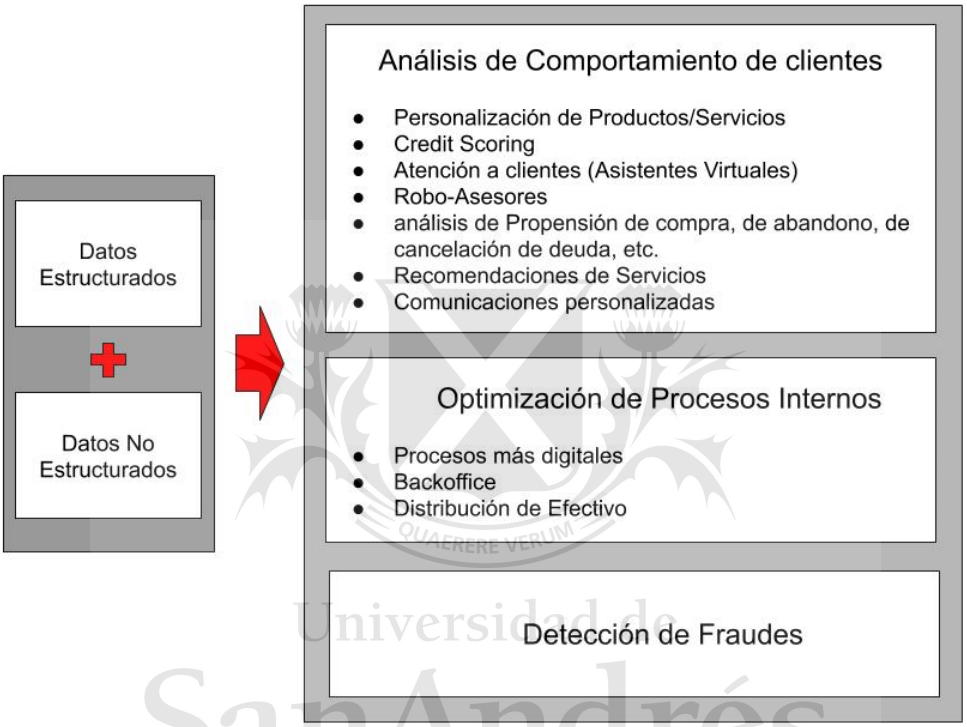

Figura 7. Aplicaciones de la IA y AA en los bancos tradicionales privados

Esta figura es de elaboración propia y resume lo obtenido de las entrevistas llevadas a cabo en el trabajo de campo del presente trabajo.

8.4. Barreras y Desafíos

Según las entrevistas realizadas, los entrevistados identificaron barreras y desafíos variadas y de alto impacto, a los que los Bancos tradicionales deben enfrentarse para poder aplicar IA y AA. En el Anexo XLV se realiza un resumen muy sintético de lo identificado por cada entrevistado en este aspecto. Además, a continuación, se visualiza un gráfico donde, para elaborarlo, se ha tipificado cada respuesta y agrupado según tipo de entrevistados y barrera.

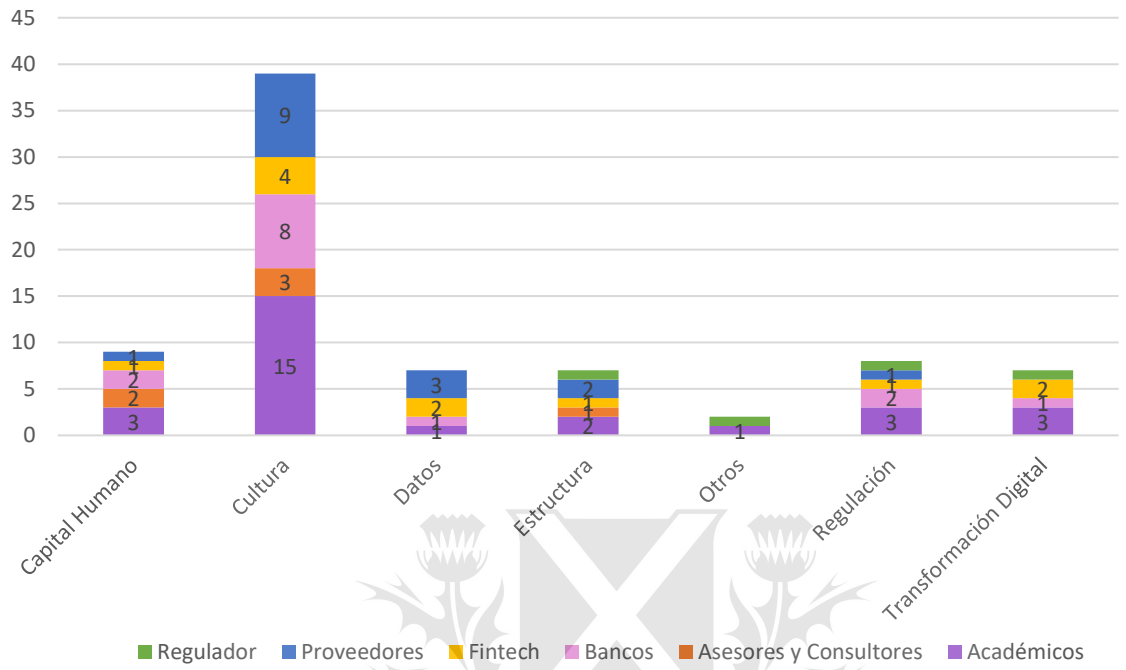

Figura 8. Barreras para la adopción de AA según los entrevistados.

Esta figura muestra la cantidad de respuestas relacionadas a tipos de barreras por tipo de entrevistado. Elaboración propia.

8.4.1. Cultura Organizacional y Liderazgo

Indiscutiblemente, según los entrevistados la principal barrera para la adopción de IA y AA en los bancos tradicionales es la cultura organizacional

Uno de los factores evidenciados son los procesos burocráticos de los Bancos tradicionales, en contraposición con las Fintech que son flexibles y veloces a la hora de la toma de decisión y la implantación de soluciones (F. Vidal, comunicación telefónica, 26 de abril de 2019). También un factor preponderante en las culturas como barreras son las estructuras de las organizaciones. En el caso de los Bancos las estructuras son grandes en contraposición con las Fintech son más chicas lo que acelera y agiliza la toma de decisiones (F. Vidal, comunicación telefónica, 26 de abril de 2019; M. H. González, comunicación personal, 7 de mayo de 2019). “La rapidez y la agilidad es un diferenciador de las Fintech con respecto a los Bancos tradicionales, las Fintech son empresas chicas, lo que les permite que también haya una mesa de dirección chica, y que no haya burocracia.

No necesitamos ir a ninguna casa matriz, que aprueben de afuera, los cambios en las grandes corporaciones tienden a tener ese curso" (F. Vidal, comunicación telefónica, 26 de abril de 2019). Las estructuras muy grandes, lentas, burocráticas y "transnacionalizadas" son una de las mayores barreras. "… la velocidad de respuesta es fundamental" (I. R. Carballo, comunicación personal, 26 de abril de 2019).

Con respecto a estructuras, también se identificó que falta empoderar a un área de Datos, IA y AA que se ubique estratégicamente en la organización, entre las áreas de sistemas y las áreas comerciales, debido es fundamental que el negocio esté involucrado para obtener buenas predicciones (H. Borré, comunicación personal, 14 de mayo de 2019). Es necesaria un área que sea transversal a la organización (W. Cova, comunicación personal, 12 de junio de 2019). Los Bancos deben dejar de trabajar en silos y comenzar a trabajar por células para poder brindar servicios orientados a clientes y dejar de seguir ofreciendo productos y servicios masivos (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019).

Otro aspecto dentro de la cultura organizacional que se identificó como una barrea son las metodologías utilizadas en los Bancos tradicionales. Los Bancos tradicionales privados siguen utilizando metodologías de tipo cascada (N.Martins, comunicación telefónica, 24 de junio de 2019). Los bancos deben incorporar un tipo de perfil nuevo y hacer la gestión adecuada para que las soluciones sean agiles, cortas, de 2 a 3 meses, luego de los cuales se evalúa y se define los próximos pasos. (C. A. Giménez, comunicación personal, 7 de mayo de 2019). Los Bancos deben cambiar sus metodologías y ser más ágiles ya que la forma de trabajar actual impacta en la creación de una cultura orientada a cliente (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019). Las iniciativas deben ser ágiles y tratarse con mecanismos de prueba y error, que hoy son metodologías muy difíciles de implementar en los Bancos tradicionales (G. Marchionni, comunicación personal, 14 de mayo de 2019). "Una costumbre en el sector financiero es tener proyectos faraónicos, la banca tradicional tiene que aprender de otras industrias y de sus competidores, empezar con alguna funcionalidad, fallar rápido, aprender del error y una vez que se estabilizó el primer piloto empezar a evolucionar. La banca tiene poca costumbre de hacer esto debido a que es muy difícil llegar a producción ya que generalmente desarrollan proyectos con alcances enormes y cuando se falla, se falla estrepitosamente, hay una cultura que debe cambiar que es el poder implementar metodologías agiles. Los bancos también deben crecer en tolerancia a fallas." (A. Hidalgo, comunicación personal, 3 de junio de 2019).

Todos los aspectos relacionados a cultura organizacional identificados por los entrevistados se relacionan y apalancan lo analizado sobre cultura organizacional en la sección 2.3 La cultura organizacional, factor primordial de la innovación. En este apartado se concluyó que para que se estimule las innovaciones tecnológicas dentro de una organización es imprescindible que las organizaciones se orienten a la flexibilidad y agilidad como es el caso de las Fintech, en contraposición a la cultura más orientada a la estabilidad y el control que caracteriza a los Bancos tradicionales privados.

Otro factor identificado como una barrera fue el liderazgo y su impacto en la cultura de los Bancos. Varios de los entrevistados consideraron que los líderes de los Bancos tradicionales deben cambiar para lograr una cultura organizacional distinta (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019) necesaria para poder implementar este tipo de tecnologías, deben cambiar tanto los mandos altos como los recursos claves de mandos medios para propagar el cambio en toda la institución (E. U. Peralta, comunicación vía correo electrónico, 3 de mayo de 2019). Estos análisis llevados a cabo por los entrevistados son coincidentes por lo aportado en el estudio realizado en el apartado 2.4 El Liderazgo como facilitar del cambio, donde se concluyó que, los líderes transaccionales que se desarrollan en empresas tradicionales, y a los que hacen mención los entrevistados, no estimulan efectivamente los cambios. Para incorporar innovaciones tecnológicas, donde muchas veces implica una transformación cultural, es necesario que la organización cuente con líderes transformacionales que actúen como agentes de cambio. También lo analizado va de la mano de lo relevado en la sección 3.5 Perspectivas de adopción de IA y AA en la actualidad, donde se identificó que un liderazgo fuerte va de la mano con una adopción de IA más fuerte.

Algunos entrevistados consideraron que es muy difícil que, por el ADN de los bancos, se pueda hacer un cambio fuerte para implementar estas tecnologías que implican un cambio sustancias. La cultura, los sistemas y los procesos ya establecidos son demasiados fuertes. La opción para la implementación de estas tecnologías es armar un equipo diferenciado, y que vaya por caminos separados a la estructura actual de los Bancos, por ejemplo, una *spin-off* (J. P. Bruzzo, comunicación personal, 3 de mayo de 2019; G. Marchionni, comunicación personal, 14 de mayo de 2019). Esta opción planteada sostiene lo analizado en la sección 2.1 Innovación, tecnología y empresas, donde se incluyó lo defino por Christensen (1999) que estableció que la forma más efectiva de establecer una presencia en nuevos mercados es creando una organización autónoma

que explote la nueva tecnología y la desarrolle debido a que los esfuerzos para nutrir estas nuevas tecnologías dentro de una gran compañía como lo son los bancos tradicionales privados, están generalmente condenados ya que las presiones desalientan sus desarrollos.

8.4.2. Gestión de los Datos

La estructura de datos de los Bancos es otra inquietud presentada como barrera por varios entrevistados ya que los Bancos tradicionales tienen estructuras de datos obsoletas, hasta de 30 o 40 años atrás (G. Marchionni, comunicación personal, 14 de mayo de 2019). Los Bancos deben entender que los datos son fundamentales. Hoy los bancos tienen una gran cantidad de datos, pero una baja tasa de uso (están explotados en alrededor de un 20%) y muy desorganizados. Los modelos de datos de estas organizaciones son los tradicionales de la industria financiera, donde se combinan datos y en función a eso se explotan (F. Turri, comunicación personal, 6 de junio de 2019; H. Borré, comunicación personal, 14 de mayo de 2019). Hoy los equipos técnicos de los bancos tradicionales están muy familiarizados con las bases de datos relacionales, y actualmente hay muchos datos que son no estructurados. Este tipo de bases, que constituyen nuevos paradigmas tecnológicos son muy difícil de adoptar en los Bancos que no comenzaron con la transformación digital. Todavía existe una cultura de la base relacional y de la seguridad que el advenimiento de AA genera un desafío importante (C.A. Giménez, comunicación personal, 7 de mayo de 2019). Hay un desconocimiento en las áreas de tecnología de los bancos sobre las nuevas tecnologías en general, por ejemplo, *cloud computing* o herramientas de AA *open source* (N. Martins, comunicación telefónica 24 de junio de 2019).

Para poder usar AA en cualquier organización se necesita tener los datos prolijos, ordenados, centralizados, un denominado "*datalake*", la posibilidad de utilizar datos no estructurados, y los bancos en la actualidad están muy lejos de contar con esta estructura de datos (H. Borré, comunicación personal, 14 de mayo de 2019; F. Turri, comunicación personal, 6 de junio de 2019). Es fundamental que los bancos tengan una estrategia de datos que le de soporte al área de IA, AA y ciencia de datos. En el proceso que tienen que hacer los bancos para transformarse en entidades más ágiles para poder competir con las organizaciones nativas digitales, van a necesitar indefectiblemente reestructurar sus datos (H. Borré, comunicación personal, 14 de mayo de 2019).

Con respecto a los datos no estructurados, datos fundamentales para que los casos de uso de AA exploten las promesas, el uso de estos es muy incipiente en los bancos (W. Cova, comunicación personal, 12 de junio de 2019). Los Bancos deben aprender a trabajar con datos no estructurados y en tiempo real. Los bancos tradicionales privados deben entender que cuanto más volumen de datos no estructurados más valor aportan (W. Cova, comunicación personal, 12 de junio de 2019).

Hoy los Bancos se encuentran muy atrasados en cuando a tener una arquitectura tecnológica orientada a los datos, deben crearse una arquitectura empresarial para gestionar todos los datos de los Bancos (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019). Pero también los procesos de los bancos no apalancan una cultura orientada a datos. Por ejemplo, en la actualidad los Bancos pierden mucha información en el momento de alta de un cliente ya que en muchos casos sigue siendo no digital y hay mucha información que no se capta, o que se capta en forma muy subjetiva (J. P. Bruzzo, comunicación personal, 3 de mayo de 2019). Es indispensable que los Bancos generen más contactos digitales para tener la mayor cantidad posible de información (J. P. Bruzzo, comunicación personal, 3 de mayo de 2019). Esto apalanca lo planteado en 6.2.4 Infraestructura de Datos, donde se concluye que, para implementar técnicas de AA, los bancos deben abordar en primer lugar sus retos de gestión de datos existentes, deben revisar su infraestructura de datos creando una arquitectura empresarial que permita la interoperabilidad y el intercambio de información. Además, las instituciones financieras deben hacer frente a las estructuras de gestión de datos heredados que se basan en silos lo que hace que sea difícil para los bancos ver sus datos en forma estratégica y sacar el máximo provecho. (Finextra &Intel, 2018).

Además de una estructura de datos, falta empoderar al área de Datos y/o de IA, y definir y comunicar lineamientos claros sobre la importancia de los datos. Las organizaciones deben crecer en culturas orientadas a datos y tener un gobierno de ellos (H. Borré, comunicación personal, 14 de mayo de 2019; A. Hidalgo, comunicación personal, 3 de junio de 2019). Además de la falta de integración de los datos y la falta de gobierno, las áreas de los Bancos suelen tener poca disposición para compartir información. Al ser información sensible existe un choque cultural entre los que quieren utilizar los datos para poder generar conocimiento y los que quieren proteger los datos (A. Hidalgo, comunicación personal, 3 de junio de 2019). Esto sostiene lo identificado en el apartado 6.2.4 Infraestructura de Datos, donde se establece que para implementar una plataforma de gestión

de datos hay consideraciones políticas ya que la transformación de las estructuras de datos para crear plataformas de intercambio de datos implica la eliminación de los silos culturales, que a menudo son vistos como feudos de diferentes líneas de propietarios de negocios (Finextra &Intel, 2018).

Un desafío para los Bancos es generar una cultura *data driven*, donde en lugar de tomar decisiones por el *expertise* de unos pocos, la generación e alternativas o la toma de decisiones sean apalancadas por los resultados de los datos (C. A. Giménez, comunicación personal, 7 de mayo de 2019; N. Martins, comunicación telefónica, 24 de junio de 2019). Los bancos tradicionales deben cambiar su cultura de datos, ya que deben pasar de determinístico a probabilístico (J. P. Maglione, comunicación por videoconferencia, 15 de mayo de 2019). Estas expresiones apalancan lo planteado en la sección 6.2 Gestión de datos … donde se identificó que es importante inculcar una cultura basada en datos que combine la intuición y la información analítica con un enfoque en las decisiones prácticas y viables en todos los niveles (Rao & Verweij, 2017).

8.4.3. Sistemas Legacy

En forma general hubo algunos entrevistados que coincidieron con que una de las principales barreras para la implantación de estas tecnologías es el *core bancario legacy* (H. Borre, comunicación personal, 14 de mayo de 2019; M. H. González, comunicación personal, 7 de mayo de 2019) y la complejidad de la integración de estas nuevas tecnologías con estos sistemas *legacy* (M. H. González, comunicación personal, 7 de mayo de 2019).

Contrariamente a las opiniones anteriores hubo quienes opinaron que los temas de los sistemas legacy y de infraestructura no son una preocupación porque hoy los proveedores que hacen implementaciones de estos sistemas tienen en cuenta estas configuraciones y crean capas intermedias para su resolución (I. Perrone, comunicación personal, 2 de mayo de 2019). Con respecto a estas capas intermedias Marcelo González opinó que no son suficientes para lograr la integración entre los sistemas Legacy de los Bancos y estas nuevas tecnologías (M. H. González, comunicación personal, 7 de mayo de 2019). Con respecto a esta barrera identificada, se analizó en el apartado 4.4. La colaboración como estrategia … que los bancos se caracterizan por tener plataformas de tecnología de información que fueron instaladas hace muchos años y el reto tecnológico de transformar esos sistemas es enorme.

8.4.4. Marco Regulatorio

Otra de las principales barreras identificadas fue el marco regulatorio del sistema financiero actual. La regulación está generando problemas en la industria financiera debido a que hay competidores que no están regulados. Además, existen regulaciones como la GDPR en Europa que limitan el procesamiento, la obtención, el almacenamiento, "maniobrabilidad" de los datos, y la publicación de estos (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019; M. H. González, comunicación personal, 7 de mayo de 2019; I. R. Carballo, comunicación personal, 26 de abril de 2019). Hoy existen regulaciones que impiden la implementación de ciertos casos de uso como por ejemplo el Scoring por la opacidad de los algoritmos, debido a que los mecanismos con los que se audita estos modelos requieren que se vea claramente cada variable. La opacidad de los algoritmos entonces constituye una barrera regulatoria (J. P. Bruzzo, comunicación personal, 3 de mayo de 2019; C.A. Giménez, comunicación personal, 7 de mayo de 2019; G. Marchionni, comunicación personal, 14 de mayo de 2019). Por otro lado, hay una necesidad de los usuarios de negocio de conocer cómo se resuelven los requerimientos, ya que los mismos asimilan mejor y tienen menor resistencia si el algoritmo es más transparente (G. Marchionni, comunicación personal, 14 de mayo de 2019).

Es necesario discutir con los entes reguladores sobre la "interpretabilidad" de los algoritmos debido a que puede haber nuevas metodologías de supervisión y auditorias (C.A. Giménez, comunicación personal, 7 de mayo de 2019). Lo dicho por los entrevistados sostiene lo analizado en el apartado 6.2.2 donde se identifica que la opacidad de los datos y algoritmos constituye uno de los impedimentos clave para la adopción de AA en los Bancos debido a la regulación existente.

Contrariamente a las posiciones anteriores con respecto a las barreras que representa el marco regulatorio hubo entrevistados que no consideraron las regulaciones como una barrera, ya que en el caso de Argentina el BCRA se ha abierto en los últimos tiempos, y se muestra colaborativo a la implementación de nuevas tecnologías (I. Perrone, comunicación personal, 2 de mayo de 2019). Con respecto al resto de Latinoamérica existen tres escenarios diferentes, el primero la Ley de México que regula todas las nuevas tecnologías y el ecosistema Fintech, el segundo escenario es Brasil que está próximo a regular y por último el resto de los países que está dejando hacer debido al incentivo muy fuerte de inclusión financiera. Los reguladores priorizan la bancarización lo máximo posible y luego se revisan las normas como es el caso de Argentina,

Chile, Colombia, Perú y Ecuador (G. Marchionni, comunicación personal, 14 de mayo de 2019). Lo analizado por los entrevistados apalanca la sección 6.4 donde se profundiza sobre las particularidades de las diferentes iniciativas de innovación regulatoria que se están planteando en el mundo. En esta sección se analizan los *Sanboxes* regulatorios, las oficinas de innovación y los RegTech, opciones que, aunque con algunas soluciones incipientes, están tratando de abordar la necesidad de regulación sobre las tecnologías financieras.

8.4.5. Talento y Capital Humano

Con respecto a Talento y Capital humano, también un alto porcentaje de entrevistados lo identificaron como una barrera. En la actualidad se está dando una competencia entre las organizaciones para captar talento, sobre todo de aquellos que tienen *background* de finanzas y tecnología debido a la escasez (F. Vidal, comunicación telefónica, 26 de abril de 2019). Uno de los principales desafíos que tienen los bancos es incorporar nuevos perfiles, diferentes a los habituales, por ejemplo, científicos de datos, psicólogos, físicos cuánticos, sociólogos que hoy en día están trabajando en AA por el tema demográfico. (C. A. Giménez, comunicación personal, 7 de mayo de 2019). Estos nuevos perfiles son necesarios porque a medidas que se va madurando se van implementando estas tecnologías, se va avanzando y requiriendo nuevos talentos, hoy hay una gran cantidad de necesidad de talento que es escasa y no se encuentra en el mercado. También existe otro factor que es la altísima rotación de estos perfiles. Estos se incorporan a la organización, se forman y rotan, es una barrera compleja y mundial (F. Turri, comunicación personal, 6 de junio de 2019). Hoy ya se evidencia que existen nuevas profesiones que ya estas teniendo auge como los *Data Scientist* que por ahora son perfiles escasos (W. Cova, comunicación personal, 12 de junio de 2019).

A los Bancos les falta conocimiento y hoy se pueden implementar mecanismos para trabajar con proveedores, universidades, Fintech, entre otros para poder generar ese conocimiento (H. Borré, comunicación personal, 14 de mayo de 2019). Hoy los Bancos no terminan de confiar en la tecnología y están seguros de que tienen todo el conocimiento (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019). En las transformaciones digitales que están llevando adelante los Bancos, se incorporan nuevos perfiles que provienen del exterior de la organización que trae paradigmas nuevos, y empiezan asperezas con los colaboradores que ya están trabajando en los Bancos. Por ejemplo, la gente que viene de trabajar en los bancos está acostumbrada a

trabajar con algoritmos más estadísticos y a responder auditorias, y la gente que viene de afuera sabe que Google procesa miles de millones de datos en segundos y utiliza herramientas muy complejas. Alguien que viene de afuera va directo a probar a ver que algoritmo es más eficiente mientras los que pertenecen a los Bancos tienden a asegurarse varios factores antes (Carlos A. Giménez, comunicación personal, 7 de mayo de 2019).

Por otro lado, los Bancos tradicionales también tiene que trabajar en la reconversión de sus colaboradores (F. Turri, comunicación personal, 6 de junio de 2019; W. Cova, comunicación personal, 12 de junio de 2019)

8.4.6. Otras Barreras

Existen también otras barreras y desafíos que en el caso de Argentina lo constituyen el marco económico y social que vive el país, por ejemplo, el contexto sindical que muchas veces impide la implementación de tecnologías debido a la creencia de la existencia de la posibilidad que impacte en la fuerza laboral (I. R. Carballo, comunicación personal, 26 de abril de 2019; M. H. González, comunicación personal, 7 de mayo de 2018).

Por último, existen algunas otras barreras como por ejemplo la desconfianza que los Bancos tienen sobre estas tecnologías (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019; A. Bolaños, comunicación personal, 3 de junio de 2019; A. Hidalgo, comunicación personal, 3 de junio de 2019). Esto es un punto sustancial, ya que la confianza es un *driver* clave para la implantación de estas técnicas (apartado 5.3 Factores que actúan como Barreras o Desafíos).

Se necesita un cambio estructural que es una visión amplia que requiere entrenamiento de personas, cambio en la forma de pensar de las personas y también de las empresas que deben definir claramente la estrategia (A. Bolaños, comunicación personal, 3 de junio de 2019). La implantación de estas tecnologías implica un proceso que representa un cambio en los cimientos de varias instituciones financieras tradicionales, quien esté dispuesta a asumir el costo de esa transformación y pueda atravesar la transformación estará en condiciones de competir y dependerá de la calidad de servicios que esté dispuesta a prestar. Eduardo Concluyó que “la tecnología está y sirve, hay cientos de casos de éxito en el mercado” (E. U. Peralta, comunicación vía correo electrónico, 3 de mayo de 2019).

Los proyectos deben encararse con casos de negocio concretos, porque se corre el riego de hacerlo para todos los procesos y quizás no es necesario, pero sí se debe hacer en los procesos o áreas donde se puede aportar más valor, y se puede acompañar a los bancos para brindar mejor experiencia a sus clientes y/o lograr más eficiencia (F. Turri, comunicación personal, 6 de junio de 2019). Esto es coincidente con la estrategia para llevar a cabo una implementación de IA y AA analizada en la sección 6.1 Principales obstáculos, donde se planteó que para definir los casos de uso de AA que se deben implementar, las tareas deben descomponerse y estimar el beneficio de la predicción mejorada y el costo de generar esa predicción. Luego se debe establecer un caso de negocios de inteligencia empresarial sólido y conectarlo a la estrategia de la empresa y evaluar el ROI (Retorno de Inversión) (Agrawal, Gans & Goldfarb, 2018; McKinssey, 2017). También lo concluido por este entrevistado se alinea a lo revisado en esa misma sección en la que se identificó que debido a que la IA y AA es aplicable a múltiples puntos de la cadena de valor (Accenture; 2018b; Fernández, 2019; King, 2018), esto puede llevar a múltiples silos de iniciativas, por lo que es fundamental desarrollar el conocimiento, la gobernanza y la colaboración organizativa. Existe una necesidad de crear un área o responsabilidad *cross* a la organización que sea dueña de todas las iniciativas y concentre el relacionamiento con todas las áreas necesarias de la organización (W. Cova, comunicación personal, 12 de junio de 2019).

8.5. Riesgos

En casi todas las entrevistas llevadas a cabo en el trabajo de campo se identificaron riesgos que traen aparejados las implementaciones de técnicas de AA. Dependiendo del perfil del entrevistado, los riesgos surgentes fueron más o menos técnicos. En el Anexo XLVI se realiza un resumen muy sintético de lo identificado por cada entrevistado en este aspecto y a continuación, se presenta un gráfico donde se visualizan las respuestas según una tipificación definida.

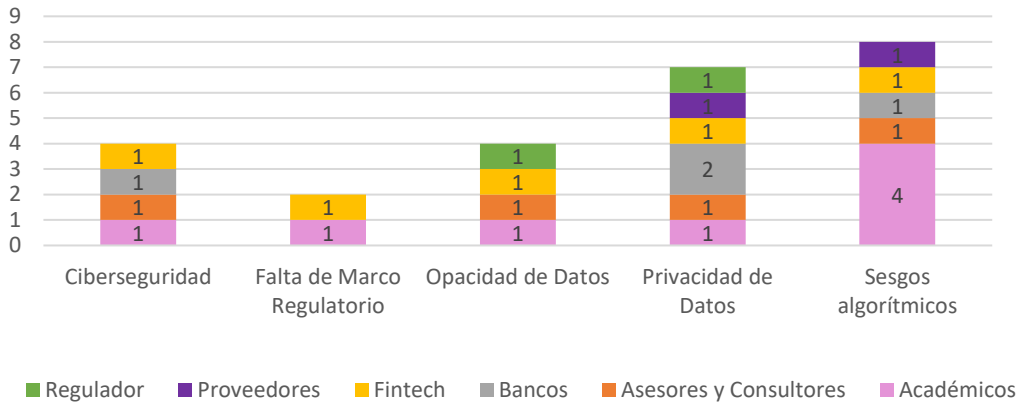

Figura 9. Riesgos detectados por los Entrevistados

Esta figura muestra la cantidad de riesgos por tipo y por tipo de entrevistados identificados. Elaboración propia.

La mayor preocupación que transmitieron los entrevistados durante las entrevistas fue el de sesgo algorítmico. Este riesgo constituye un riesgo ético (N.Martins, comunicación telefónica, 24 de unió de 0219). Los sesgos que introducen las personas que modelan los algoritmos pueden profundizar la exclusión financiera, las diferencias de oportunidades y también la marginalización para las economías emergentes. El objetivo o el fin que tenga la organización al momento de programar los algoritmos puede decantar en que se marque la profundización de las aristas más negativas del sistema financiero actual o se ejecute una transformación positiva que realmente sea superadora (I.R. Carballo, comunicación personal, 26 de abril de 2019). Es improbable que no se introduzcan sesgos debido a que los algoritmos son programados por seres humanos que ya tienen sesgos por su propia naturaleza (M. M. Nogueira, comunicación personal, 31 de mayo de 2019). Hay que estar atentos cuando se construyen los modelos algorítmicos para que no se introduzcan sesgos de partes minoritarias de la población (L. Aranda, comunicación personal, 3 de mayo de 2019). En la construcción de las soluciones existen distintas fases, la primera fase es entender la necesidad de negocio y el tipo de problema que hay que resolver, la siguiente fase es recolectar los datos, para identificar de qué tipo de información se es propietario, que tipo de información se necesita, y si es interna o externa; también en esta etapa se identifican los datos que no están

correctos, por lo que se realiza una "limpieza" inicial. Luego de esta etapa viene la fase del análisis exploratorio que tiene como fin entender las distribuciones, potenciales sesgos, si las bases están balanceadas o desbalanceadas, se analiza el comportamiento, y ahí se debería identificar y corregir algún sesgo (C.A. Jiménez, comunicación personal, 7 de mayo de 2019). En la actualidad existentes algunas herramientas que detectan sesgos en los algoritmos de *machine learning* (N. Martins, comunicación telefónica, 24 de junio de 2019). Pero en general hoy no hay solución de IA y AA que no tenga sesgo ya que no se puede entrenar a los algoritmos con toda la información existente por lo que se debe trabajar en cómo mitigar los riesgos de sesgo (J. M. Maglione, comunicación por videoconferencia, 15 de mayo de 2019). En la actualidad los riesgos de sesgos algorítmicos constituyen un tema que se está tratando en sectores académicos y tecnológicos, pero todavía es transparente a los clientes que no están preocupados por los sesgos que se pueden introducir en los algoritmos (I. Perrone, comunicación personal, 2 de mayo de 2019).Todos los análisis realizados por los entrevistados son coincidentes con el riesgo de discriminación logarítmica identificado y analizado en profundidad en el apartado 6.2 Gestión de datos.

En las preocupaciones relevadas en las diferentes encuestas se ha identificado el riesgo de privacidad de datos como otro factor preponderante en las opiniones. Debido a que el AA se basa en el almacenamiento de información, está básicamente en contra de las leyes europeas, con lo cual, no es factible que pueda avanzar en este contexto para los Bancos regulados (M. H. González, comunicación personal, 7 de mayo de 2019). La confidencialidad de los datos representa una barrera ya que hoy hay varios grises con respecto a la regulación y eso está limitando el avance tecnológico de estas soluciones de IA y AA (J.L. Nugoli, comunicación personal, 3 de junio de 2019). Lo relevado con los entrevistados apalanca lo analizado en la sección 5.3.1 Gestión de datos.

Pero hay varios entrevistados que tienen un punto de vista en la vereda de enfrente de esto. Por ejemplo, los modelos que se pueden construir en los bancos pueden ser híbridos en los cuales se puede publicar información sin identificar clientes, sin romper la confidencialidad. Se pueden elaborar los modelos de acuerdo a la normativa (F. Turri, comunicación personal, 6 de junio de 2019). También existe la opción de trabajar con datos anonimizados sin identificar al cliente. Cuando se trabaja con AA no interesa la identificación de la persona, sino el comportamiento, se puede ver cómo se comporta la persona sin tener los datos privados (C. A. Giménez, comunicación personal, 7 de mayo de 2019; A. Bolaños, comunicación personal, 3 de junio de 2019). También

hay que tener en cuenta que las soluciones disponibles se pueden implementar completamente en la nube o en forma local en los bancos de manera de cumplir con las regulaciones vigentes (W. Cova, comunicación personal, 12 de junio de 2019).

También la ciberseguridad fue identificada como riesgo por varios de los entrevistados. En la medida que los bancos tienen más datos de los clientes tendrían un problema potencial de sufrir vulnerabilidades (N. Martins, comunicación telefónica, 24 de junio de 2019).

Otro de los riesgos identificados durante las entrevistas es la falta de Marco Regulatorio que provocan que los riesgos aumenten y también va en contra de otros objetivos de los Bancos Centrales de los países como por ejemplo la estabilidad financiera, la defensa al consumidor, la inclusión financiera y la integridad financiera digital (I.R. Carballo, comunicación personal, 26 de abril de 2019). Es necesario un marco regulatorio que ayude a dar seguridad a los clientes (F. Vidal, comunicación telefónica, 26 de abril de 2019). Deberían existir marcos regulatorios y políticas públicas *"friendlys"* para los bancos para apalancar la adopción (N. Martins, comunicación telefónica, 24 de junio de 2019).

Por último, aunque sólo algunos de los entrevistados identificaron el riesgo de transparencia de las decisiones de los algoritmos, resulta de marcada importancia para los Bancos tradicionales por las regulaciones existentes en la actualidad que actúan como barrera para la adopción (G. Marchionni, comunicación personal, 14 de mayo de 2019; M. M. Nogueira, comunicación personal, 31 de mayo de 2019; C. A. Giménez, comunicación personal, 7 de mayo de 2019). AA se trata de algoritmos bastantes avanzados que manejan volúmenes de datos que no pueden ser procesados por una persona y existe todo un gradiente de complejidad de los modelos. A medidas que se avanza en algoritmos más complejos estos se vuelven más flexibles, pero también más opacos. Por esto los algoritmos con cajas oscuras representan un problema para la Banca tradicional, debido a que se encuentra regulado y en consecuencia es auditado, para reproducir el resultado, ahí es donde se encuentran las limitaciones lo que hace bastante difícil la adopción (C. A. Giménez, comunicación personal, 7 de mayo de 2019). A la hora de implementar estos mecanismos se deben tener en cuenta ya que se deben explicar las decisiones que toman ciertos modelos (L. Aranda, comunicación personal, 3 de mayo de 2019). Se deben tener en cuenta los casos de uso que están bajo estos requerimientos regulatorios, por ejemplo, los relacionados a definición de límites de crédito), es mucho más necesaria y meticulosa la interpretación, a los casos de uso que se utilizan para inferir determinados comportamientos de un cliente (C. A. Giménez,

comunicación personal, 7 de mayo de 2019). En estos casos de uso que están regulados es posible la implementación de algoritmos de caja blanca, como lo son los árboles de clasificación o enjambre de árboles que se pueden aplicar sin problemas regulatorios (N. Martins, comunicación telefónica, 24 de junio de 2019) Todos los análisis realizados por los entrevistados relacionados a transparencia de modelos son coincidentes con el riesgo identificado y analizado en profundidad en el apartado 5.3.1 Gestión de datos y transparencia de modelos.

En general, para los reguladores, los sistemas de AA constituyen un sistema más y por el estado de implementación en el sistema financiero no representan un riesgo. Si los bancos realizan estas soluciones con un tercero deben cumplir la normativa vigente y son considerados como un tercero más, por ahora no se identifican riesgos sistémicos porque es muy incipiente (M. H. González, comunicación personal, 7 de mayo de 2019).

8.6. Perspectivas sobre la Adopción

En las distintas entrevistas llevadas a cabo la mayoría de los entrevistados consideró que definitivamente las soluciones de AA se van a volver realidad en la Banca tradicional argentina pero un elevado porcentaje opinó que se daría en un largo plazo, tanto por las barreras y desafíos que tienen los Bancos como por los riesgos que surgen de estas tecnologías, variables que fueron tratadas en las secciones inmediatamente anteriores. A continuación, se muestra el resultado de las entrevistas relacionado a este punto:

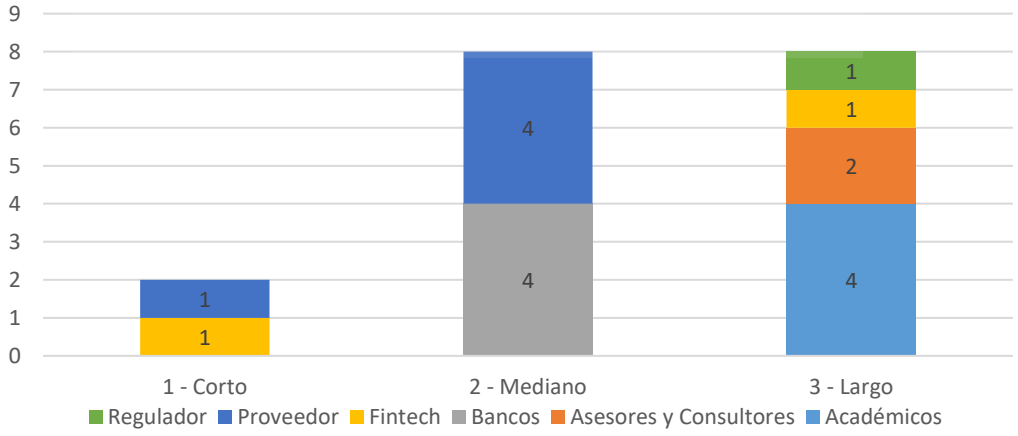

Figura 10. Perspectiva de adopción

Esta figura muestra la cantidad de respuestas sobre perspectivas de adopción a corto, mediano y largo plazo, por tipo de entrevistados. Elaboración propia

Al tratarse de una tecnología muy nueva, generalmente los Bancos esperan a que exista un caso de éxito avasallante para poder implementarlo y por el estado de los sistemas, se adoptaría a muy largo plazo (M. H. González, comunicación personal, 7 de mayo de 2019). En el otro extremo se encontró el testimonio de María de las Mercedes Nogueira que expresó que, aunque hoy son incipientes los casos de uso implementados considera que a mediano plazo las soluciones de IA estarán siendo utilizadas por los Bancos ya que son empresas innovadoras (M. M. Nogueira, comunicación personal, 31 de mayo de 2019). Juan Pablo Bruzzo y Leonardo Aranda en cambio opinaron que, teniendo en cuenta que hay "sobre promesas" de la IA y el AA, las aplicaciones que hoy son aplicables van a serlo en el corto plazo en la Banca tradicional (J. P. Bruzzo, comunicación personal, 3 de mayo de 2019; L. Aranda, comunicación personal, 3 de mayo de 2019).

En cuanto a la variable adopción, Eduardo Peralta también se mostró optimista ya que mencionó que las implementaciones ya son una realidad en la Banca Local e ilustró 2 casos: el primero de ellos relacionado a algoritmos de *traiding* financiero, métodos que resuelven problemas matemáticos, enviando órdenes de compra y venta de acciones en base a parámetros establecidos para que los algoritmos analicen de manera instantánea, enriquecidos por IA para saber cuándo es el mejor momento para comprar o vender. Según lo mencionado por Eduardo varias mesas de dinero de instituciones locales están evaluando o implementando de estos algoritmos. Otro ejemplo mencionado en el ámbito local fue el caso de Watson (IBM), que se trata de en una solución de IA y AA en la nube que tiene la capacidad de aprender e interactuar en lenguaje natural con personas para atender y contestar sobre diferentes tópicos y que hay que entrenar y que está implementado en los Bancos (por ejemplo, Banco Santander Río, Banco Supervielle, entre otros). Otros bancos de plaza están evaluando esta herramienta para centralizar bases de conocimiento (E.U. Peralta, comunicación vía correo electrónico, 3 de mayo de 2019).

Fernando Turri también opinó que hay promesas que se van a volver realidad, algunas a corto plazo debido a que ya se están implementado en el mercado soluciones y otras a mediano plazo. Por ejemplo, mencionó que el Banco Galicia tiene casos concretos de utilización de IA y AA por ejemplo en bastanteo, que es un proceso que consiste en asegurar que los estatutos de empresas participen las personas que dicen ser, también por ejemplo en el centro de atención de la

entidad ya atienden con asistentes virtuales y también en canales como Facebook o Whatsapp. También mencionó el caso del Banco ICBC que ya tiene implementada una tecnología para detectar la rotura de cajeros en forma predictiva (F. Turri, comunicación personal, 6 de junio de 2019).

Para Ana Hidalgo de SAS la implantación de las promesas va a ocurrir más rápido en las áreas que están más maduras en la gestión de datos, por ejemplo, el área de riesgos que tiene una amplia experiencia en el uso de los datos, al tener mayor madurez en la generación de la base para poder aplicar algoritmos es cuestión que empiecen a competir. Entonces, hay ritmos muy distintos en cuanto a la implantación de promesas que tienen que ver con la madurez del uso de datos en las áreas y con la madurez en el uso de algoritmos (A. Hidalgo, Comunicación personal, 3 de junio de 2019).

Según lo relevado, existen casos de uso implementados, pero hay una gran potencialidad que todavía no ha sido explotada (N. Martins, comunicación telefónica, 24 de junio de 2019).

En el Anexo XLVII se realiza un resumen muy sintético de lo identificado por cada entrevistado en este aspecto.

QUAERERE VERUM
Universidad de
SanAndrés

9. Capitulo IX. Conclusiones

El principal objetivo con el que se encaró este trabajo de investigación fue analizar las oportunidades que la inteligencia artificial en general y el aprendizaje automático como su principal estandarte podía representar para los Bancos Tradicionales Privados para mejorar sus ventajas competitivas frente a la disrupción del sistema financiero. El uso de la IA y AA en los servicios financieros podrían aportar beneficios clave para la transformación digital de los Bancos logrando optimización de costos, mayor productividad y mejores ingresos en la prestación de servicios financieros.

Para poder abordar el objetivo mencionado se plantearon objetivos complementarios con el foco puesto en responder las preguntas de investigación del presente trabajo. Para esto se realizó una revisión bibliográfica, se analizaron casos de éxito y se realizaron entrevistas a referentes relacionados con la industria bancaria con el objetivo de: comprender los conceptos relacionados a innovación y los principales factores que estimulan o inhiben la adopción de nuevas tecnologías; introducir los conceptos de inteligencia artificial, aprendizaje automático y su perspectiva de adopción actual; comprender la situación actual de los bancos tradicionales privados, su relación con la disrupción del sistema financiero y los nuevos escenarios; proporcionar una comprensión de las promesas, oportunidades y aplicaciones específicas que las soluciones de aprendizaje automático pueden generar para los bancos tradicionales privados y reflexionar acerca de cuáles son las barreras, desafíos y riesgos a los que se enfrenta la banca tradicional privada para avanzar en la adopción de soluciones de aprendizaje automático.

A continuación, se presentan las conclusiones arribadas durante el presente trabajo comenzando por plantear un panorama sobre las dos principales variables de estudio de este trabajo, luego se abordan las respuestas a las preguntas de investigación, una visión sobre el futuro del AA en los Bancos tradicionales privados y para finalizar las líneas de futuras investigaciones identificadas como producto del presente trabajo.

9.1. Panorama de la situación actual del AA

La inteligencia artificial, y el aprendizaje automático como su estandarte, se encuentran dentro de las tecnologías denominadas de avanzada que conforman la cuarta revolución industrial que permiten la transformación digital, produciendo eficiencias operativas, mejoras en la productividad y la generación de nuevas oportunidades y nuevos modelos de negocio.

El desarrollo y aplicación de AA ha tenido en los últimos años una explosión debido a varios factores relacionados: el crecimiento del poder de procesamiento con su reducción de costos asociada, la sofisticación de algoritmos y la generación de enormes cantidades de datos, producidos cada vez más en un mundo altamente interconectado que alcanza a consumidores, empresas, organismos y es posible gracias a dispositivos como *smarthpones*, sensores, *wereables*, computadoras, y a través de sistemas y plataformas digitales. La necesidad de gestión de esta información, tanto estructurada como desestructurada, impulsa el uso de tecnologías digitales, como por ejemplo el aprendizaje automático, para poder analizarla ya que es imposible que pueda realizarlo el ser humano. A su vez la gran cantidad de datos disponibles impulsa las mejoras en los algoritmos. Estos factores plantean la generación de un circulo virtuoso para el crecimiento del desarrollo y la adopción del aprendizaje automático. Sumado a estos factores, también se vislumbra la democratización de los datos y del uso de AA de código abierto lo que también acelera su desarrollo y adopción.

9.2. Panorama de la situación actual de los Bancos Tradicionales Privados

Por otro lado, los avances que se están produciendo en la tecnología y las comunicaciones han tenido un alto impacto en la transformación de las finanzas. Han mejorado la velocidad y la calidad del procesamiento y han ayudado a reducir los costos de información y los costos de transacción. Estos avances han tenido implicaciones tanto para los Bancos tradicionales privados como para sus usuarios de productos y servicio.

La primera implicancia se refiere al perfil del cliente de la banca tradicional privada que está cambiando drásticamente. En la actualidad los clientes están ligados cada vez más a tecnologías, hace uso de ellas y está familiarizado con los avances tecnológicos y lo que espera es poder aplicar lo mismo a sus servicios financieros. La tecnología abrió una puerta a la adquisición de información, no solo de los servicios brindados por sus bancos sino también acerca de los brindados por sus competidores. Hoy la mayoría de los clientes están cerca de la tecnología, con un gran número creciente de *millenials* y *centennial* que han cambiado radicalmente la forma de consumir servicios financieros. Estos consumidores nativos digitales no tienen un comportamiento heredado basado en la banca tradicional, sino que esperan de sus bancos las mismas experiencias que tienen, por ejemplo, cuando utilizan las redes sociales o los mercados electrónicos. Buscan que la experiencia sea sin fricción y en tiempo real. Los *millennials* están ajustando rápidamente

su comportamiento y los hacen más velozmente que las generaciones pasadas. Pero lo más preocupante es la pérdida de confianza en las instituciones financieras de este grupo cada vez más mayoritario de consumidores y la disminución de la lealtad de estos.

Es claro que los consumidores de hoy requieren una atención personalizada, relevante, de alta calidad y con capacidad de respuesta para cubrir sus necesidades, y muchos están dispuestos a una experiencia de servicio automatizada, lo que abre la puerta a la inteligencia artificial en general.

La segunda implicancia de los avances tecnológicos se refiere a que los Bancos tradicionales privados han sufrido desde la crisis financiera del 2008, un constante deterioro de sus ventajas competitivas ya sea asociados a sus propios modelos de negocios como a la competencia creciente de nuevos actores que favorecen la desintermediación financiera. Estos nuevos actores que están desagregando las ofertas de valor de los bancos, creando grietas por las que las entidades financieras que no se adapten podrían perder no sólo los beneficios de sus negocios actuales, sino también su papel como interlocutor central con el cliente en lo relativo a su vida financiera. Estos nuevos jugadores establecieron un nuevo paradigma donde lo destacable es la aplicación de tecnologías de avanzada a los servicios financieros. El potencial de estas empresas, ya sean Fintech de nicho o grandes tecnológicas, tiene que ver con sus características competitivas y propuestas de valor superiores a la de los bancos tradicionales. Estas empresas tienen una serie de ventajas, son ágiles y flexibles, usan las tecnologías disruptivas y de avanzada lo que les permite ofrecer servicios más personalizados, más rápidos (a veces en tiempo real) y más rentables.

Los Bancos se enfrentan a amenazas claras de redistribución de los márgenes de ganancia, pérdida de mercado, imposibilidad de acceso a nuevos mercados, y reconversión a servicios básicos de *comodity* sin diferenciación.

Los Bancos deberían hacer frente a la modernización de sus sistemas para poder atender a los nuevos consumidores y presentar batalla a los nuevos entrantes más ágiles y más centrados en los clientes. Para ello deberían implementar tecnologías de avanzada, como por ejemplo el aprendizaje automático, que les permita transformarse digitalmente.

9.3. Argumentación de las preguntas de investigación

A continuación, se trata de responder las preguntas de investigación en función de la revisión bibliográfica, los casos de éxito analizados y el resultado de las entrevistas llevadas a cabo

con los referentes que permitieron abordar los interrogantes planteados en el presente trabajo. En primera instancia se tratará de responder las preguntas secundarias para luego de plantear reflexiones finales, abordar la pregunta principal de investigación.

9.3.1. Promesas y oportunidades de la IA y el AA para mejorar la competitividad de los bancos tradicionales privados y sus aportes para transformar la industria

En este apartado se trata de responder la primera pregunta de investigación planteada en este trabajo de investigación; ¿Cuáles son las promesas y oportunidades que la IA y el AA pueden brindar para mejorar la competitividad de los bancos tradicionales privados y sus aportes para transformar la industria?

Los beneficios que promete el AA en los servicios financieros serían muy claros ya que existe un creciente interés y se identifican implementaciones de casos de uso en variados procesos y sectores en los Bancos tradicionales privados, aunque todavía se considera incipiente, ya que no hay una implementación a escala.

Existirían una gran cantidad de oportunidades que el AA puede brindar a la banca. Los entrevistados y los casos analizados otorgaron un gran panorama de todas las aplicaciones posibles del AA que corroborarían lo planteado en la revisión bibliográfica: optimización de procesos para lograr minimizar la burocracia y sumar valor, la confección de nuevos productos y servicios, y mayor calidad de estos, personalización de productos y servicios y de pricings, segmentación de clientes, optimización de campañas de marketing e inclusión financiera. Todo esto apalancaría las ganancias de productividad por reducciones de costos, aumento de demanda de los consumidores traccionadas por la mejora en los productos y servicios personalizados y con mayor calidad, aumento de ingresos y participación en el mercado.

La introducción de AA en los Bancos tradicionales podría afectar significativamente las cadenas de valor de estos, ya que según lo analizado y relevado estas soluciones podrían implementarse tanto en procesos y áreas de back-office, middle-office y de front-office

9.3.2. Actividades que las soluciones de AA representan para la banca tradicional privada.

En este apartado se trata de responder la segunda pregunta de investigación planteada en este trabajo de investigación: ¿En qué actividades las soluciones de AA pueden ayudar a la banca?

El AA en los bancos tradicionales privados ya es una realidad tangible, aunque con casos de uso más y menos maduros con respecto a la adopción de estas técnicas, según lo resultante del análisis bibliográfico como del trabajo de campo y de los casos analizados. Se pudo identificar la implementación de una gran cantidad de casos de uso más maduros con impacto en diferentes sectores como por ejemplo los de asistentes virtuales, prevención de fraude, gestión de efectivo para sucursales y ATM´s, casos de uso para marketing y ventas, y robo-asesores. Y otros casos que en la revisión bibliográfica aparecen como maduros, pero en el trabajo de campo no se pudo sustentar, como por ejemplo los relacionados con Gestión de Riesgos y Crédito.

Tanto el análisis bibliográfico como el análisis de los casos y el trabajo de campo evidencian que los bancos tradicionales privados han comenzado a explorar esta tecnología y los casos de uso que están siendo implementados corroborarían el cumplimiento de las promesas, ya que se han obtenido mejoras medibles tanto en costos operativos, como en la calidad de los productos y servicios brindados, es decir, resultados muy positivos que alientan su adopción.

En el trabajo de campo habría indicios claros que las promesas de IA y AA en la banca tradicional privada se van a volver realidad, y hay enormes oportunidades, aunque a mediano y largo plazo. Las tendencias en el trabajo de campo realizado son claras: los académicos, asesores, consultores y supervisores mostraron una visión más pesimista identificando la implementación a largo plazo, y por el lado de los referentes de los bancos, la visión es un poco más optimista, identificando las implementaciones a mediano plazo.

9.3.3. Principales barreras y desafíos con las que se enfrentan los Bancos tradicionales privados en su camino a la adopción de estas soluciones

En este apartado se trata de responder la tercera pregunta de investigación planteada en este trabajo de investigación: ¿Cuáles son las principales barreras, desafíos y riesgos con las que se enfrentan los Bancos tradicionales privados en su camino a la adopción de estas soluciones?

El resultado de las tendencias de adopción de mediano y largo plazo se apalanca en la identificación de varios factores que actúan como barreras para su adopción. Entre ellos el más destacado es el de la cultura organizacional de los bancos tradicionales privados, debido a que tienen procesos burocráticos, lentos, en contraposición a sus competidores que son flexibles y más veloces, característica de una organización adhocrática que impulsa la innovación y les permite realizar implementación de soluciones ágiles y rápidas. Lo bancos hoy no están acostumbrados a

implementar iniciativas cortas con pruebas y feedback rápido para poder probar y corregir. Tampoco tienen tolerancia a fallas. Las estructuras organizacionales conforman un factor dentro de las culturas, que actúa como barrera debido a que son demasiado grandes, jerarquizadas y muchas veces con toma de decisiones centralizadas, inclusive en otros países. También, los caracteriza la escaza cultura data driven, es decir la toma de decisiones en los bancos tradicionales privados siguen ejecutándose por el expertise de los colaboradores en lugar de que se arriben a ellas apalancadas por los resultados de la gestión de los datos.

La Gestión de datos, merece un tratamiento especial, porque constituye una barrera decisiva a la hora de implementar técnicas de AA, ya que sin datos organizados, confiables y ordenados no se pueden implementar estas técnicas o soluciones. Hoy la mayoría de los bancos trabaja con una cultura todavía de base de datos relacional, lo que apalanca la necesidad identificada de nuevos enfoques que puedan manejar grandes volúmenes de datos de diferentes tipos (no solamente estructurados y no solamente financieros que permitan por ejemplo la segmentación psicográfica) y por lo tanto nuevas capacidades. Los bancos deberían abordar sus retos de gestión de datos existentes, deberían revisar su infraestructura de datos, atacando los modelos de datos existentes que se basan en silos, creando una arquitectura empresarial que permita la interoperabilidad y el intercambio de información. Deberían, además, generar modelos de gobernanza sobre los datos que apalanque el uso de técnicas de AA.

El tema de datos no solo está relacionado con la estructura o la arquitectura, sino que también está fuertemente relacionado a un comportamiento organizacional propio de los bancos tradicionales que evitan compartir información, tan lejos de los conceptos de innovación abierta o democratización de las innovaciones que se han estudiado, transformándose en claras barreras para la adopción de estas tecnologías.

Una preocupación identificada tanto en el análisis de fuentes como en el trabajo de campo es la privacidad de datos. Debido a que el aumento de la disponibilidad y uso de los datos se plantean cuestiones relativas a la propiedad y al uso de los datos y las consecuencias que esto podría tener en la privacidad de los consumidores. Hoy existen regulaciones como por ejemplo el Reglamento General de Protección de Datos de la Unión Europea, que plantea cuestiones sobre el manejo de datos personales que generan dudas en los bancos tradicionales por lo que esto está actuando como barrera para la adopción. Según lo identificado existen opciones hoy en día, que

permiten la protección de estos datos, como por ejemplo la anonimización, pero a pesar de esto, los bancos continúan teniendo dudas.

No menos importante es el factor de opacidad de datos o transparencia algorítmica. En el caso del aprendizaje automático, obtener la comprensión de cómo funcionan, dependiendo de qué algoritmos de AA, suele ser complejo, de modo que resulta difícil entender el razonamiento que siguen para llegar a un determinado resultado. Aunque en ciertos casos el hecho de no entender este proceso puede resultar irrelevante, en otras ocasiones puede ser necesario explicar por qué se ha tomado una determinada decisión (por ejemplo, en una calificación crediticia) ya que una opacidad en este tipo de casos de uso difícilmente sea justificable por los reguladores, por los cual se está ante el escenario donde las regulaciones impiden estos casos de uso. La falta de "interpretabilidad" o "capacidad de auditoría" de los métodos de AA podrían convertirse en un riesgo a nivel macro. La opacidad de los datos y algoritmos constituye uno de los impedimentos clave para la adopción de AA en los Bancos, aunque existirían posibilidades de implementar algoritmos de caja blanca con algoritmos más sencillos para casos de uso regulados.

Relacionado a este punto, también se identificó como una barrera de adopción debido a los riesgos subyacentes, la discriminación algorítmica. Este riesgo se refiere a aquellos procesos a través de los cuales los distintos tipos de discriminación que ocurren en el mundo real son reproducidos en entornos de datos. Estos sesgos algorítmicos podrían profundizar las aristas más negativas del sistema financiero actual y podrían profundizar la exclusión financiera y las diferencias de oportunidades. Esta discriminación puede producirse porque los datos son imperfectos o incompletos o porque pueden reflejar los sesgos de las personas que tomaron las decisiones sobre su recolección. Asimismo, pueden presentar problemas de insuficiencia, errores, y exceso o déficit de representación de ciertos grupos de la sociedad, todo lo cual podría redundar en una decisión algorítmica equivocada.

La falta de un marco regulatorio claro también funciona como barrera, ya que muchas de las instituciones están aumentando las preocupaciones sobre las restricciones impuestas sobre ellos por los marcos reguladores ante la incorporación de este tipo de tecnologías, lo que impide su capacidad de competir. Los reguladores y supervisores reconocen que los marcos regulatorios son anteriores a las nuevas tecnologías y modelos comerciales, y esto puede crear barreras no deseadas para la innovación y también puede generar condiciones desiguales entre los diferentes actores. Muchas entidades podrían verse desmotivadas a emprender la implementación de estas

innovaciones, en primer lugar, por el tiempo y los costos asociados al cumplimiento de los requisitos legales y, en segundo lugar, por las consecuencias derivadas del incumplimiento de dichos requisitos. Debido a que no existe claridad sobre el impacto de la implementación de modelos de AA, estos deben realizarse con cuidado, ya que la filosofía dinámica implícita aún no puede ser manejada adecuadamente por la regulación estática actual y la gobernanza interna.

El Talento o capital humano también constituye una barrera debido a la escasez de este. Los Bancos deben reconvertir a sus trabajadores no solamente para poder hacer frente a las necesidades de nuevos perfiles para implementar AA, como por ejemplo los Científicos de Datos, sino también a los restantes colaboradores, ya que la implementación de este tipo de tecnologías implica una gestión muchas veces de colaboración humano - maquina, es decir habilidades que son complementarias en el proceso de producción. Si se observa particularmente en América Latina, que hay numerosas deficiencias estructurales para el desarrollo de estos talentos necesarios.

También entre los riesgos identificados y relevados en el trabajo de campo se encuentra los riesgos de ciberseguridad y de la dependencia de proveedores externos, debido a que las instituciones financieras pueden suscribirse a los mismos proveedores externos para sus servicios de AA, las empresas bancarias podrían estar expuestas a los riesgos de los mismos proveedores, lo que podría generar una mayor interconexión y podría tener un impacto sobre la estabilidad global del sistema bancario.

Finalmente, el estado de la misma transformación digital de los Bancos actúa como barrera, ya que todavía no se entiende a los clientes digital, se tienen procesos por ejemplo de alta de clientes donde se pierde mucha información al no estar digitalizados. Además, el estado de los sistemas *legacy* heredados dificulta la Integración de estas tecnologías con estos.

9.3.4. Algunas reflexiones y recomendaciones

Los bancos tienen varias opciones para responder a la necesidad de transformación digital para atender la explosión de innovación, aunque la opción más viable es la implementación de modelos de asociación y colaboración con las Fintech. Este modelo constituye una opción menos costosa y más rápida que desarrollar las innovaciones internamente, esto debido a la complejidad que tienen estos desarrollos a causa del estado de modernización de los sistemas bancarios. Por los fuertes indicios que se obtuvieron tanto en la revisión bibliográfica como en el trabajo de campo,

se entiende que los bancos están comenzando este camino, aunque no es una práctica extendida y adoptada, pero si se evidencia una tendencia positiva.

Ya que la amenaza más fuertemente percibida es la que puedan generar las grandes tecnológicas como Mercado Libre, Google, Amazon, Tencent, IBM, Microsoft, entre otros, generar un ecosistema eficaz de colaboración entre Bancos y Fintechs se presenta como una opción a la hora de aprovechar las fortalezas de ambos tipos de organizaciones. Los bancos tradicionales tienen una amplia base de clientes existentes y de productos y servicios, tiene un bajo costo de capital, protección regulatoria, fuente de ingresos y acceso a recursos, y por sobre todo datos, una enorme cantidad de datos producto de años de actividad. También se puede sumar como fortaleza, la experiencia de ya haber pasado varios cambios tecnológicos. Y por el lado de las Fintech, son empresas generadoras de nuevas ideas, tienen una cultura organizacional que les permite implementaciones agiles, rápidas y flexibles, tienen herramientas de vanguardia con la que realizan análisis y la gestión de datos, adquieren clientes en forma online y saben realizar diseños optimizados para las experiencias de usuario online o móviles, o sea tienen el conocimiento del cliente digital que le falta la banca tradicional privada.

Con respecto a la barrera de opacidad, una opción relativamente extendida y que ofrece en la mayoría de los casos un razonable equilibrio entre beneficios y riesgos es utilizar las herramientas de inteligencia artificial de manera complementaria a las técnicas tradicionales. Es decir, no sustituir las técnicas actuales sino utilizar los resultados como parte de un proceso de refuerzo y de validación de las decisiones. Es decir, no se trata de aceptar automáticamente los resultados que proporcionan los algoritmos de un modo automático, sino de utilizarlos para tomar decisiones en un trabajo colaborativo hombre máquina.

Es importante distinguir entre los distintos tipos de actividades a las que se están aplicando estas herramientas, dado que problemas como sesgos en los resultados o las dificultades para la interpretación de los razonamientos que subyacen no tienen la misma relevancia según el ámbito, áreas y casos de uso. En consecuencia, se deberán sopesar para cada caso de uso los beneficios y los inconvenientes de emplear esta tecnología, y valorar asimismo el modo en que debería utilizarse.

Para la implementación de los casos de uso de aprendizaje automático es importante que las tareas involucradas se descompongan de manera de estimar el beneficio de la implementación del algoritmo o de la solución y el costo de generar esa predicción. Luego se debe establecer un

caso de negocios sólido y conectarlo a la estrategia de la empresa y evaluar el ROI (Retorno de Inversión).

Para impulsar estas innovaciones tecnológicas es primordial que la organización cuente con una cultura que estimule la conducta innovadora. La cultura empresarial, como hemo visto puede frenar o fomentar la innovación en las empresas y como se ha concluido en un apartado anterior, un factor que limita la adopción de estas tecnologías por parte de los Bancos en su cultura organizacional, ya que sus procesos estructuras y metodologías de trabajo no apalancan la agilidad necesaria para la implantación de este tipo de tecnologías. Debido a que las organizaciones con más foco en el exterior y más foco en la flexibilidad son las más propensas al desarrollo de la innovación los bancos tradicionales privados deberían impulsar este tipo de cultura.

En general la estructura de los bancos es más mecanicista debido a la alta formalización y centralización y no tan orgánicas, factor que también influye en la flexibilidad y por lo tanto en la estimulación de las innovaciones. Debido a que los Bancos se encuentran en una industria regulada y al tener una cultura fuertemente procedimental, esto también limita la capacidad de adaptación al cambio.

Los líderes juegan un rol fundamental en la adopción del aprendizaje automático como herramienta para los bancos debido a que son ellos los que impulsan los cambios en la cultura organizacional imperante. Para enfrentar estos cambios son necesarios líderes transformacionales, es decir líderes centrados en el papel de agente del cambio, que promueve el compromiso y motiva a los equipos a la adopción de nuevas innovaciones.

Finalmente, una condición *sine qua non* para adoptar estas tecnologías es que se debe invertir en tecnologías relacionadas como servicios de computación en la nube (*Cloud Computing*) y Big data.

9.3.5. El Aprendizaje Automático como oportunidad para los bancos tradicionales privados para hacer frente a la disrupción del sistema financiero

En este apartado se trata de responder la última pregunta de investigación planteada en este trabajo de investigación que engloba los conceptos estudiados: ¿La implementación de soluciones de Aprendizaje Automático representa una oportunidad para los bancos tradicionales privados para hacer frente a la disrupción del sistema financiero ayudando a incorporar ventajas competitivas?

Luego de la investigación realizada se puede concluir que la implementación de soluciones de aprendizaje automático representaría una oportunidad para los Bancos Tradicionales Automáticos para incorporar soluciones que agregarían valor y generarían ganancias y beneficios en varias áreas y procesos de estos bancos. Implicarían una oportunidad para optimizar procesos internos y también de cara al cliente, pero las implementaciones a escala no se darían en un corto plazo debido a que existen barreras sustanciales que deberán hacer frente los bancos tradicionales privados. Algunas de estas barreras podrían ser zanjeadas con un liderazgo transformacional que acompañe a la organización en el cambio cultural necesario para incorporar estas soluciones. Pero también existen también otras barreras que dependen de factores exógenos, como el marco regulatorio, que es indispensable que maduren o cambien para que ciertos casos de uso puedan ser implementados.

9.4. Una Visión de Futuro para la inteligencia artificial y el aprendizaje automático en los Bancos tradicionales privados

Es probable que la inteligencia artificial transforme el mundo de los negocios y la vida cotidiana de las personas, de manera tan profunda y beneficiosa como cualquiera de las grandes innovaciones del pasado. Pero también es probable que lo haga en un plazo mucho más corto que lo han hecho aquellas, lo que deja a los bancos tradicionales privados menos tiempo para implementar este tipo de tecnologías que los ayuden a implementar ventajas competitivas para hacer frente a los cambios. El impacto será en todas las industrias y en todas las empresas, por lo que tiene sentido que los bancos tradicionales se aseguren de tener una estrategia empresarial y un liderazgo a nivel empresarial dedicado a la IA y el AA.

En los próximos años se seguirán implementando casos de uso de manera de obtener ganancias de productividad en forma masiva. Esto se verá apalancado por la capacidad de aprendizaje de las maquinas que pueden mejorar con el tiempo y con lo ya se ha identificado en los análisis de la revisión bibliográfica y los casos que es la mejora de los algoritmos.

En un corto plazo es probable que la mayor mejora económica potencial de la IA y el AA provenga de la mejora de la productividad. Y luego, se podrán visualizar un aumento de la demanda de los consumidores como consecuencia de la disponibilidad de productos y servicios mejorados y personalizados y el aumento de la calidad. Cuando los bancos tradicionales privados más utilicen y se familiaricen con el AA, más potencial de crecimiento verán en ella, utilizando

estas tecnologías para aumentar su participación en el mercado. Con la implantación de IA y AA surgen nuevos servicios y las cadenas de valor se reconfigurarán definitivamente. El desarrollo de nuevos modelos de negocio y/o nuevos productos y servicios será fundamental para la subsistencia de los Bancos tradicionales privados.

También la fuerza laboral se reconfigurará ya que la IA y el AA generará una franja de nuevos empleos y prosperarán nuevas habilidades en diferentes áreas, pero también se eliminarán empleos existiendo un riesgo potencial de que empeorará la desigualdad. La proporción de roles que requieren de conocimientos de IA y AA aumentará en los próximos siguientes años. Por lo cual es necesario promover el desarrollo de las personas orientados en este sentido y otras habilidades que cobran importancia en este escenario como la creatividad, la programación, la resolución de problemas, las habilidades interpersonales y la inteligencia emocional. En la transición que se está viviendo es necesario que los Bancos inviertan en el desarrollo de nuevas habilidades de los trabajadores, responsabilidad que trasciende las empresas, y son también responsables los gobiernos. En América Latina el escenario es bastante desalentador, ya que como se mencionó durante la investigación existen deficiencias estructurales.

En el futuro corto y mediano las sucursales se volverán mucho más difícil de mantener económicamente, los enfoques alternativos de canales tanto físicos como digitales ganarán terreno, por lo que es fundamental el desarrollo de tecnologías que apalanquen el uso de los canales digitales.

Los cambios que se esperan en los próximos años presentan un contexto donde se cambiará el concepto de los producto y servicios bancarios actuales pasando de éstos a experiencias de clientes integradas en los canales digitales, como por ejemplo acceso al crédito predictivo y contextual, herramientas de ahorro comportamentales, asistentes de compras, análisis predictivo de flujo de efectivo, servicio de optimización y monitorización de la salud, gestión de la longevidad, entre otros. Para todos estos servicios, a primera vista los algoritmos de AA son fundamentales.

Pero para el desarrollo y la adopción de la IA y el AA en los bancos tradicionales privados, re requiere una nueva gobernanza, normas e instituciones reguladoras ágiles que acompañen las trasformaciones en todas sus dimensiones, cuidando los derechos de las personas, garantizando inclusión tecnológica y social, priorizando tanto el acceso y como el desarrollo de las habilidades. Se requieren leyes que protejan los datos de las personas y de las empresas, que regulen los

aspectos de seguridad y de privacidad, y que regulen las actividades en la nube. La mayoría de los reguladores actuales necesitan repensar las misiones, el alcance y los protocolos. Necesitan reclutar nuevas habilidades especialmente para la ciencia de datos. Deben reorganizarse en torno a los problemas centrados en la tecnología, y crear nuevos roles de liderazgo. Asimismo, tendrán que alterar las culturas que son conservadoras y se centran en gran medida en evitar riesgos en lugar de abrirse a la innovación.

9.5. Futuras investigaciones

Como continuación de este trabajo de tesis, existen diversas líneas de investigación que quedan abiertas y en las que es posible continuar trabajando. Estas líneas futuras que se han dejado abiertas se esperan puedan ser atacadas en un futuro y se detallan a continuación:

- Debido a que los usos de aprendizaje automático en los bancos privados tradicionales están en una fase incipiente, evoluciona rápidamente, y los datos sobre los resultados no están disponible en muchos casos, cualquier análisis es necesariamente preliminar, y la evolución en esta área se debe continuar investigando para analizar como continúa su desarrollo y adopción.
- Un punto de particular importancia que requerirá una revisión son los avances en los marcos regulatorios que mitiguen los riesgos identificados.
- Además, es necesario ahondar en casos de uso de relevancia donde se hayan implementado soluciones complejas con baja opacidad que permitan ser interpretables o explicables.
- También se deberá estudiar en profundidad los casos donde se trabaje con anonimización para identificar si realmente constituye una opción para la protección y privacidad de datos.

Lista de Referencias

Abidin, W. Z., Ismail, N. A., Maarop, N., & Alias, R. A. (2017). Skills Sets Towards Becoming Effective Data Scientists. Knowledge Management in Organizations, 97–106. DOI:10.1007/978-3-319-62698-7_9

Accenture. (2017a). Model Behavior. Nothing Artificial. Emerging Trends in the Validation of Machine Learning and Artificial Intelligence Models. Recuperado de: https://www.accenture.com/us-en/insight-emerging-trends-machine-learning

Accenture. (2017b). How AI Boost Industry profits and Innovation. Recuperado de: https://www.accenture.com/_acnmedia/PDF-84/Accenture-AI-Industry-Growth-Full-Report.pdf

Accenture. (2017c). Más allá de lo Digital: ¿Cómo pueden satisfacer los Bancos las demandas de los clientes? Recuperado de: https://www.accenture.com/_acnmedia/Accenture/Conversion-Assets/DotCom/Documents/Local/cl-es/Accenture-Banking-Global-Distribution-Marketing-Consumer-Study-Espanol.pdf#zoom=50

Accenture. (2017d). Gestión del Efectivo. Recuperado de: Entrevista llevada a cabo con Juan José Nugoli de SAS el día 3 de Junio de 2019.

Accenture. (2018a). Realizing the Full Value of AI in Banking. Recuperado de https://www.accenture.com/us-en/insights/banking/future-workforce-banking-survey 14.

Accenture. (2018b). Redefine Banking with Artificial Intelligence. Recuperado de: https://www.accenture.com/_acnmedia/PDF-68/Accenture-Redefine-Banking.pdf

Accenture. (2018c). Informe Ecosistema Fintech Argentino. Recuperado de: https://www.eleconomista.com.ar/wp-content/uploads/2018/11/S%C3%ADntesisInformeFintech_Prensa.pdf

Addo, P., Guegan, D., & Hassani, B. (2018). Credit risk analysis using machine and deep learning models. Risks, 6(2), 38. DOI:10.3390/risks6020038

Afuah, A. (1999). La dinámica de la innovación organizacional: El nuevo concepto para lograr ventajas competitivas y rentabilidad. México D.F, México: Oxford University Press, Inc.

Agrawal, A., Gans, J., & Goldfarb, A. (2018). Prediction machines: the simple economics of artificial intelligence. Harvard Business Press.

Ajzen, I. (1991). The theory of planned behavior. Organizational Behavior and Human Decision Processes, 50, 179–211.

Albrieu, R., Rapetti, M., Brest López, C., Larroulet, P. & Sorrentino, A. (2018). Inteligencia artificial y crecimiento económico. Oportunidades y desafíos para Argentina. Inteligencia Artificial y Crecimiento Económico en América Latina. Buenos Aires: CIPPEC. Recuperado de https://www.cippec.org/wp-content/uploads/2018/11/ADE-ARG-vf.pdf

Allen, K. (2015). How a Toronto professor's research revolutionized artificial intelligence. The Star. Recuperado de https://www.thestar.com/news/world/2015/04/17/how-a-toronto-professors-research-revolutionized-artificialintelligence.html

Altman, E. I., Marco, G., & Varetto, F. (1994). Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (the Italian experience). Journal of banking & finance, 18(3), 505-529. DOI: https://doi.org/10.1016/0378-4266(94)90007-8

Amarimber, S. I. (1972). Characteristics of random nets of analog neuron-like elements. IEEE Transactions on Systems, Man, and Cybernetics, (5), 643-657. DOI: 10.1109/TSMC.1972.4309193

Amat Noguera, N. (1989). Documentación científica y nuevas tecnologías de la información (No. 025.4 AMA).

Anderson, J. A., Silverstein, J. W., Ritz, S. A., & Jones, R. S. (1977). Distinctive features, categorical perception, and probability learning: Some applications of a neural

model. Psychological review, 84(5), 413. DOI: http://dx.doi.org/10.1037/0033-295X.84.5.413

Angelini, L., Marinazzo, D., Pellicoro, M., & Stramaglia, S. (2007, April). Causality and communities in neural networks. In ESANN (pp. 459-464). Recuperado de: https://pdfs.semanticscholar.org/71cd/a30fd1cc4adf20604fac3f2a1f49b0903c30.pdf

Anif, Felaban & CAF. (2018). Los Servicios Financieros Digitales en América Latina. Recuperado de: http://felaban.s3-website-us-west-2.amazonaws.com/documentos_interes/archivo20181204163600PM.pdf

Auria, L., & Moro, R. A. (2008). Support vector machines (SVM) as a technique for solvency analysis. Recuperado de: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1424949

Aziz, S., & Dowling, M. (2018). AI and Machine Learning for Risk Management. SSRN Electronic Journal. DOI: 10.2139/ssrn.3201337

Babbie, E. R., & Huitt, R. E. (1979). The Practice of Social Research, 2d ed. Belmont, CA: Wadsworth, 434.

Bankrate (2015). Branch banking still popular with Americans. Recuperado de: https://www.bankrate.com/finance/consumer-index/branch-banking-still-strong-among-americans.aspx

Barberis, J. (2015). The evolution of Fintech, 1(1), 8–23. DOI: https://doi.org/10.3868/s050-004-015-0003-8.

Barocas, S., & Selbst, A. D. (2016). Big data's disparate impact. Calif. L. Rev., 104, 671. DOI: http://dx.doi.org/10.2139/ssrn.2477899.

Basco, A., Beliz,G., Coatz, D. & Garnero, P. (2018). Industria 4.0. Fabricando el Futuro. DOI: http://dx.doi.org/10.18235/0001229. Recuperado de: https://publications.iadb.org/es/industria-40-fabricando-el-futuro

Bass, B. M. (1985). Leadership and performance beyond expectations. New York: The Free Press.

Bauer Z., Brynjolfsson E., Clark J., Etchemendy J., Grosz B., Lyons T., Manyika J., Niebles J. C., Perrault, R., & Shoham, Y. (2018). "The AI Index 2018 Annual Report", AI Index Steering Committee, Human-Cente red AI Initiative, Stanford University, Stanford, CA, December. Recuperado de: http://cdn.aiindex.org/2018/AI%20Index%202018%20Annual%20Report.pdf

BBVA Research (2015). Bancos y Fintech: hacia un ecosistema colaborativo. Recuperado de: https://www.bbvaresearch.com/wp-content/uploads/2015/12/Situacion-Banca_Dic15_Cap6.pdf

BBVA Innovation Center (2016). Revolución Fintech. Recuperado de: https://www.bbva.com/wp-content/uploads/2017/08/ebook-cibbva-fintech.pdf.

BBVA Research (2017). Fintech: implicaciones en materia de regulación y supervisión. Recuperado de https://www.bbvaresearch.com/wp-content/uploads/2017/.../DEO_dic17_Cap_05.pdf .

Bellman, R. (1978). An introduction to artificial intelligence: Can computers think? Thomson Course Technology.

Bellotti, T., & Crook, J. (2009). "Support Vector Machines for Credit Scoring And Discovery Of Significant Features", Expert Systems with Applications 36, 3302–3308. DOI https://doi.org/10.1016/j.eswa.2008.01.005

Best, W. (1988). Cómo investigar en educación. Madrid: Morata, S.L.

BID & Finnovista (2018). Fintech en América Latina 2018: crecimiento y consolidación. DOI: http://dx.doi.org/10.18235/0001377

Blaikie, N.W.H. (1991). A critique of the use of triangulation in social research. Quality and Quantity, 25, 115-136.

Bogdan, R. C. & Biklen, SK (1992). Qualitative research for education: An introduction to theory and methods. Needham Heights, MA: Allyn and Bacon.

Bovey, W. H., & Hede, A. (2001). Resistance to organizational change: The role of cognitive and affective processes Leadership & Organization Development Journal, 22(8), 372–382.

Brynjolfsson, E. & McAfee, A. (2017). Machine, platform, crowd: Harnessing our digital future. WW Norton & Company

Brundage, M., Avin, S., Clark, J., Toner, H., Eckersley, P., Garfinkel, B., ... & Anderson, H. (2018). The malicious use of artificial intelligence: Forecasting, prevention, and mitigation. arXiv preprint arXiv:1802.07228.

Buchanan, B. G., Sutherland, G. L. & Feigenbaum, E. A. (1969). Heuristic DENDRAL: a program for generating explanatory hypotheses in or- ganic chemistry. In: Meltzer, B.; Michie, D.; Swann, M. (Eds.), Machine Intelligence 4, Edinburgh, Scotland: Edinburgh University Press, 209- 254.

Budworth, D. (2018). GHOSTS IN THE MACHINE: Artificial intelligence, risks and regulation in financial markets. Recuperado de: www.euromoneythoughtleadership.com/ghostsinthemachine.

Buenadicha Sánchez C., Galdon Clavell G., Hermosilla M.P., Loewe D., & Pombo C. (2019). La Gestión Etica de los Datos. Por qué importa y cómo hacer un uso justo de los datos en un mundo digital. Recuperado de: https://publications.iadb.org/es/la-gestion-etica-de-los-datos. DOI: http://dx.doi.org/10.18235/0001623

Burns, T. y Stalker, G. (1961). The management of innovation. London: Tavistock Publications.

Burrell, J. (2015). How the Machine "Thinks:" Understanding Opacity in Machine Learning Algorithms. SSRN Electronic Journal. DOI:10.2139/ssrn.2660674

Butaru, F., Chen, Q., Clark, B., Das, S., Lo, A. W., & Siddique, A. (2016). Risk and risk management in the credit card industry. Journal of Banking & Finance, 72, 218-239. DOI: https://doi.org/10.1016/j.jbankfin.2016.07.015

Cameron, K. S., & Quinn, R. E. (1999). Diagnosing and changing organization: Based on the competing values framework. Addison Wesley Longman.

Capgemini, LinkedIn, & Efma (2018). World Fintech Report Survey. Recuperado de: https://www.capgemini.com/wp-content/uploads/2018/02/world-fintech-report-wftr-2018.pdf

Cepal. (2017). Políticas Industriales y Tecnológicas en América Latina. Recuperado de: https://www.cepal.org/es/publicaciones/42363-politicas-industriales-tecnologicas-america-latina

Cepal. (2018a). Datos, algoritmos y políticas. La redefinición del mundo digital. Recuperado de: https://www.cepal.org/es/publicaciones/43477-datos-algoritmos-politicas-la-redefinicion-mundo-digital

Cepal. (2018b). La nueva revolución digital: de la Internet del consumo a la Internet de la producción. Recuperado de: https://www.cepal.org/es/publicaciones/38604-la-nueva-revolucion-digital-la-internet-consumo-la-internet-la-produccion

Charniak, E., & McDermott, D. (1985). Introduction to Artificial Intelligence. ADDISON. Reading, MA.

Chesbrough, H. W. (2003). Open Innovation. The New Imperative for creating and profiting from technology. Hardvard Business School Press.

Chesbrough, H. (2006). Open Business Models: How to drive in the New Innovation Landscape. Harvard Business School Press.

Chesbrough, H., Vanhaverbeke, W., y West, J. (2006). Open Innovation: Researching a New Paradigm. New York, USA: Oxford University Press

Chiavenato, I. (1995). Introducción a la teoría general de la administración. Mc Graw Hill.

Chitra, K., & Subashini, B. (2013). Data mining techniques and its applications in banking sector. International Journal of Emerging Technology and Advanced Engineering, 3(8), 219-226. Recuperado de: https://pdfs.semanticscholar.org/87da/9ade5ca2f0547c86e0d29f65ede5f544de90.pdf

Christensen, C. M. (1999). El dilema de los innovadores. Buenos Aires: Ediciones Granica, S.A.

Citi GPS. (2016). Digital Disruption: How Fintech is Forcing Banking to a Tipping Point. Recuperado de: https://www.ivey.uwo.ca/cmsmedia/3341211/citi-2016-fintech-report-march.pdf

Contreras Torres, F., & Barbosa Ramírez, D. (2013). Del liderazgo transaccional al liderazgo transformacional: implicaciones para el cambio organizacional. Revista virtual universidad católica del norte, 2(39), 152-164. Recuperado de: http://revistavirtual.ucn.edu.co/index.php/RevistaUCN/article/view/433/908

Cook, T. D. & Reichardt, C. S. (1986). Hacia una superación del enfrentamiento entre los métodos cualitativos y los cuantitativos (pp. 25-58). Madrid: Morata, S.L.

Creswell, J. (1998). Qualitative Inquiry and Research Design: Choosing among five traditions. London and Thousand Oaks: Sage Publications.

Creswell, J. W. (2009). Research design: Qualitative and mixed methods approaches. London and Thousand Oaks: Sage Publications.

Dankhe, G. L. (1989). Investigación y comunicación, en C. Fernández-Collado y G.~ Dankhe (Eds): "La comunicación humana: ciencia social". México, D, F.: McGra~ HiII de México. Capítulo 13, pp. 385-454.

Daugherty, P. R., & Wilson, H. J. (2018). Human+ machine: reimagining work in the age of AI. Harvard Business Press.

Davis, R. H., Edelman, D. B., & Gammerman, A. J. (1992). Machine-learning algorithms for credit-card applications. IMA Journal of Management Mathematics, 4(1), 43-51. DOI:10.1093/imaman/4.1.43.

Delgado, A. (1998). Inteligencia artificial y minirobots. Ecoe Ediciones.

Denison, D. (1990). Corporate Culture and Organizational Effectiveness. New York: Wiley.

Denison, D., Hooijberg, R., Lane, N, y Lief, C. (2012). Leading Culture change in global organizations. Alining culture and strategy. United States. B Jossey-Bass A Wilew Imprint.

Denzin, N. K. (1989). Strategies of Multiple Triangulation. The Research Act: A Theoretical Introduction to Sociological Methods. Chicago: Aldine Publishing Company.

Dhandayudam, P., & Krishnamurthi, I. (2014). A Rough Set Approach for Customer Segmentation. Data Science Journal. 13. 1-11. DOI: 10.2481/dsj.13-019.

Diaz, R., Coss, R. & Armenta, L. (2019). H2O Driveless AI – Introduction and Uses Cases.Vision Banco – Improving Profitability of Core Financial Services. H2O AI World. Evento llevado a cabo en San Francisco en Febrero de 2019. Recuperado de: https://www-01.ibm.com/events/wwe/grp/grp309.nsf/vLookupPDFs/4%20Use%20Cases%20Jofai%20Chow/$file/4%20Use%20Cases%20Jofai%20Chow.pdf

Drucker, P. (1997). The future that has already happened. Harvard Business Review, 75(5), 20-22.

Drucker, P. (2000). La disciplina de la innovación. Creatividad e innovación, 157-174. Recuperado de: http://www.sela.org/media/2366647/r-la-disciplina-de-la-innovacion.pdf

Enkel, E., Gassmann, O., & Chesbrough, H. (2009). Open R&D and open innovation: exploring the phenomenon. R&d Management,39(4), 311-316. DOI: https://doi.org/10.1111/j.1467-9310.2009.00570.x

Ernst & Young, IPADE & Startupbootcamp (2018). Un camino de doble sentido. La coopetición de instituciones financieras y Fintechs, una mirada en América Latina. Recuperado de https://www.ey.com/Publication/vwLUAssets/ey-un-camino-de-doble-sentido/$FILE/ey-un-camino-de-doble-sentido.pdf

Estevadeordal, A., Beliz, G., Estevez, E., Ovanessoff, A., Plastino, E., Rao, A., Diamond, P., Barral, W., Petrus, G., Donaldson, D., Vashistha, A., Vashistha, An., Herrera, M., Heymann, D., Mira, P., Chesñevar, C., Lakhani, K., Tinn, P., Lin, M., Ascencio, L., González Ramírez, R., Atkinson, J., Núñez Tabales, J., Caridad y Ocerín, J., García Moreno, M., Siri, Julián, Serur, J., Miailhe, N., Lannquist, Y., Mulgan, G., Lavista, J.,

Corvalán, J., Pounder, K., Liu, G., Chelala, S., Korinek, A., Schapira, D., Reif, R., & Gillam, M.(2018). Revista Integración & Comercio: Año 22: No. 44: Julio, 2018: Algoritmolandia: inteligencia artificial para una integración predictiva e inclusiva de América Latina. BID INTAL. DOI: 10.18235/0001287

Farquad, M. A. H., Ravi, V., & Raju, S. B. (2012). Analytical CRM in banking and finance using SVM: a modified active learning-based rule extraction approach. International Journal of Electronic Customer Relationship Management, 6(1), 48.DOI:10.1504/ijecrm.2012.046470

Fernandez, A. (2019). Inteligencia artificial en los Servicios Financieros. Boletín Económico 2/2019. Banco de España. Recuperado de https://www.bde.es/f/webbde/SES/Secciones/Publicaciones/InformesBoletinesRevistas/ArticulosAnaliticos/19/T2/descargar/Fich/be1902-art7.pdf.

Financial Stability Board (2017). "Artificial intelligence and machine learning in financial services". Recuperado de http://www.fsb.org/2017/11/artificial-intelligence-and-machine-learning-in-financial-service/

Finextra & Intel (2018). Capturing the AI opportunity: Transforming Financial Services, Technology and Culture. Recuperado de: https://www.intel.la/content/dam/www/public/us/en/documents/research/saffron-finextra-v4-ai-opportunity-research.pdf

Frost & Sullivan (2016). Future of Financial Services Growth in FinTech is Shaping the Future of Invisible Finance & Virtual Banking.

Fukushima, K. (1975). Cognitron: "A self-organizing multilayered neural net-work". Biological Cybernetics, 20, 121-136.

Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. Biological cybernetics, 36(4), 193-202.

Galindo J., & Tamayo, P. (1997). Credit Risk Assessment Using Statistical and Machine Learning: Basic Methodology and Risk Modeling Applications. Thinking Machines Corp., 16 New England Executive Park, Burlington MA 01803 December 19.

García Montalvo, J. (2014). El impacto de Big data en los servicios financieros. Papeles de Economía Española, 43-59.

Gartner. (2018). Hype Cycle for Artificial Intelligence, 2018. Recuperado de: https://www.gartner.com/doc/3883863/hype-cycle-artificial-intelligence-

Gartner (2019). Magic Quadrant for Data Science and Machine Learning Platforms. Recuperado de https://www.gartner.com/doc/reprints?id=1-65WC0O1&ct=190128&st=sb

Gomes Lopes, R., Ladeira, M., & Carvalho, R. (2017). Use of machine learning techniques in the prediction of credit recovery. Advances in Science, Technology and Engineering Systems Journal. 2. 1432-1442. DOI: 10.25046/aj0203179.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT press.

Grossberg, S. (1968). A prediction theory for some nonlinear functional-differential equations i. learning of lists. Journal of Mathematical Analysis and Applications, 21(3), 643-694. Recuperado de: https://core.ac.uk/download/pdf/82048062.pdf

Grossberg, S. (1972). Neural expectation: Cerebellar and retinal analogs of cells fired by learnable or unlearned pattern classes. Kybernetik, 10(1), 49-57.

GSMA (2018). The Mobile Economy, Latina American and Caribbean 2018. Recuperado de: https://www.gsmaintelligence.com/research/?file=26d3b58c5ef4fa27930c973feff2d9ff&download

Guegan, D., & Hassani, B. (2018). Regulatory Learning: how to supervise machine learning models? An application to credit scoring. The Journal of Finance and Data Science, 4(3), 157-171. DOI: https://doi.org/10.1016/j.jfds.2018.04.001

Gutiérrez, E. J. D. (1999). La estrategia del caracol: el cambio cultural en una organización. Oikos-tau.

Hartmann, A. (2006). The role of organizational culture in motivating innovative behavior in construction firms. ConstructionInnovation, 6(3), 159-172.

Haugeland, J. (1985). Artificial intelligence: the very idea.

Heaton, J. B., Polson, N. G., & Witte, J. H. (2016). Deep learning in finance. arXiv preprint arXiv:1602.06561. DOI: https://doi.org/10.1002/asmb.2209

Hendershott, T., Jones, C., & Menkveld, A. (2011). "Does algorithmic trading improve liquidity?". The Journal of Finance, vol. 66, Nº 1, Hoboken, Wiley, febrero. DOI: https://doi.org/10.1111/j.1540-6261.2010.01624.x

Herrera, D. &Vadillo,S. (2018). Sandbox Regulatorio en América Latina y el Caribe para el ecosistema FinTech y el sistema financiero. Banco Interamericano de Desarrollo. Marzo. Recuperado de :https://publications.iadb.org/es/publicacion/17483/sandbox-regulatorio-en-america-latina-el-caribe-para-el-ecosistema-fintech-y-el

Hinton, G. E., Osindero, S., & Teh, Y.-W. (2006). A Fast Learning Algorithm for Deep Belief Nets. Neural Computation, 18(7), 1527–1554. DOI:10.1162/neco.2006.18.7.1527

Hootsuite & We are Social. (2019). Digital 2019 Global Digital Overview (January 2019) v01. Recuperado de https://www.juancmejia.com/wp-content/uploads/2019/03/Digital-2019-WeAreSocial-y-HootSuite.pdf

Hopkins, B. (2019). The Forrester Wave: Plataformas de analítica empresarial, 1Q 2019. Recuperado de: https://www.ibm.com/downloads/cas/PKXDXX7M

Hruska, D., Rasic, S., & Bakovic, T. (2010). Implementation of strategic change by belief driven and action driven processes. En B. Katalinic (Ed.). Annals of DAAAM for 2010 & Proceedings of the 21st International DAAAM Symposium. Simposio llevado a cabo en la conferencia de DAAAM International, Viena, Austria.

H2O.ai (2019). AI Improves Profitability at Paraguay Bank. Recuperado de: https://www.h2o.ai/wp-content/uploads/2019/03/H2O_VisionBanco_CaseStudy.pdf

IDC. (2018). IDC'S Worldwide Semiannual Cognitive/Artificial Intelligence Systems Spending Guide Taxonomy 2018. Recuperado de https://www.idc.com/getdoc.jsp?containerId=US43607318

Indra. (2017). La nueva Banca, una plataforma al servicio de tu bienestar financiero. Recuperado de: https://www.indracompany.com/sites/default/files/d7/Documentos/Servicios_financieros/Informe-financiero/informefinanciero2017.pdf

Jagtiani, J., & Lemieux, C. (2018). "The Roles of Alternative Data and Machine Learning in Fintech Lending: Evidence from the LendingClub Consumer Platform." Federal Reserve Bank of Philadelphia working paper No. 18-15. Recuperado de https://www.philadelphiafed.org/-/media/research-and-data/publications/workingpapers/2018/wp18-15.pdf.

Jagtiani, J., Vermilyea, T., & Wall, L. (2018). "The Roles of Big Data and Machine Learning in Bank Supervision," Banking Perspectives, The Clearing House publication, Q1. Recuperado de: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3221309

Jones, I., & Kim, K. (2016). Systematic Service Product Requirement Analysis with Online Customer Review Data. Journal of Integrated Design and Process Science. 19. 25-48. DOI: 10.3233/jid-2015-0011.

Jordan, M., & Mitchell T. (2015). "Machine learning: Trends, perspectives, and prospects," Science 349(6245): 255-260. DOI: 10.1126/science.aaa8415

Katz, R. L. (2017). Social and economic impact of Digital Transformation on the economy. Recuperado de: https://www.itu.int/en/ITU-D/Conferences/GSR/Documents/GSR2017/Soc_Eco_impact_Digital_transformation_finalGSR.pdf

Katz, R. L. (2018). Capital humano para la transformación digital en América Latina. CEPAL - Serie Desarrollo Productivo N° 219. Recuperado de: https://www.cepal.org/es/publicaciones/43529-capital-humano-la-transformacion-digital-america-latina

Kennedy K. (2013). Credit Scoring Using Machine Learning (Tesis de Doctorado). Dublin Institute of Technology. Irlanda. Recuperado de https://arrow.dit.ie/sciendoc/137/.

Khandani, A. E., Kim, A. J., & Lo, A. W. (2010). Consumer credit-risk models via machine-learning algorithms. Journal of Banking & Finance, 34(11), 2767-2787. DOI: https://doi.org/10.1016/j.jbankfin.2010.06.001

King, A. A., & Baatartogtokh, B. (2015). How Useful is the Theory of Disruptive Innovation?. MIT Sloan Management Review, 57(1), 77. Recuperado de: https://pdfs.semanticscholar.org/60e8/86aed65be4c6eecad9a27117a0c635bffaff.pdf

King, B. (2013). Bank 3.0. John Wiley and Sons.

King, B. (2018). Bank 4.0: Banking everywhere, never at a bank.

Knight, W. (2016). ¿Podemos confiar la inversión de riesgo al criterio de una inteligencia artificial? Recuperado de https://www.technologyreview.es/s/5540/podemos-confiar-la-inversion-de-riesgo-al-criterio-de-una-inteligencia-artificial

Knight, W. (2017a). "The Dark Secret at the Heart of AI", MIT Technology Review (April 13). Recuperado de: https://www.technologyreview.com/s/604087/the-dark-secret-at-the-heart-ofai/.

Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. Biological cybernetics, 43(1), 59-69.

Kolanovic, M. & Krishnamachari, R.T. (2017). Big Data and AI Strategies: Machine Learning and Alternative Data Approach to Investing. JP Morgan, Mayo. Recuperado: https://www.cfasociety.org/cleveland/Lists/Events%20Calendar/Attachments/1045/BIG-Data_AI-JPMmay2017.pdf

Kotter, J. P. (1995). Leading change: Why transformation efforts fail. Harvard Business Review, 73(2), 59–65.

Kuhn. (1970). The Structure of Scientific Revolutions. Univ de Chicago Press (1962).

Kurzweil, R., Richter, R., & Schneider, M. L. (1990). The age of intelligent machines (Vol. 579).

Laurens, R., & Zou, C. C. (2016). Using Credit/Debit Card Dynamic Soft Descriptor as Fraud Prevention System for Merchant. 2016 IEEE Global Communications Conference (GLOBECOM). DOI:10.1109/glocom.2016.7842369.

Lee, A. (2016). "The meaning of AlphaGo, the AI program that beat a Go champ", Maclean's, Toronto, Rogers Media, 18 de marzo. Recuperado de http://www.macleans.ca/society/science/the-meaning-of-alphago-the-ai-program-that-beat-a-go-champ/.

Letham, B., Rudin, C., McCormick, T. H., & Madigan, D. (2015). Interpretable classifiers using rules and bayesian analysis: Building a better stroke prediction model. The Annals of Applied Statistics, 9(3), 1350-1371.

Li, S. T., Shiue, W., & Huang, M. H. (2006). The evaluation of consumer loans using support vector machines. Expert Systems with Applications, 30(4), 772-782. DOI: https://doi.org/10.1016/j.eswa.2005.07.041

López Lázaro, J., Barbero Jiménez, Á., & Takeda, A. (2018). Improving cash logistics in bank branches by coupling machine learning and robust optimization. Expert Systems with Applications, 92, 236–255. DOI: 10.1016/j.eswa.2017.09.043

Luger, G. F., & Stubblefield, W. A. (1993). Artificial intelligence: its roots and scope. Artificial intelligence: structures and strategies for, 1-34.

Lupano Perugini, M. L., & Castro Solano, A. (2008). Liderazgo y género. Identificación de Prototipos de liderazgo efectivo. Perspectivas en Psicología, 5(1), 69-77.

McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics, 5(4), 115-133.

Mckinsey Global Institute. (2017a). Artificial Intelligence. The Next Digital frontier? Recuperado de: https://www.mckinsey.com/~/media/McKinsey/Industries/Advanced%20Electronics/Our%20Insights/How%20artificial%20intelligence%20can%20deliver%20real%20value%20to%20companies/MGI-Artificial-Intelligence-Discussion-paper.ashx

Mckinsey Global Institute. (2017b). Un Futuro que funciona: Automatización, Empleo y Productividad. Enero. Recuperado de: https://www.mckinsey.com/~/media/mckinsey/featured%20insights/digital%20disruption/harnessing%20automation%20for%20a%20future%20that%20works/a-future-that-works-executive-summary-spanish-mgi-march-24-2017.ashx

Mckinsey Global Institute. (2017c). What´s now and next in Analytics, AI and Automation. Recuperado de: https://www.mckinsey.com/featured-insights/digital-disruption/whats-now-and-next-in-analytics-ai-and-automation

Minsky, M. (1986). La sociedad de la mente: la inteligencia humana a la luz de la inteligencia artificial. Ediciones Galápago.

Minsky, M., & Papert, S. A. (2017). Perceptrons: An introduction to computational geometry. Cambridge, MA: MIT press.

Mitchell, T. (1997). Machine Learning. New York: McGraw Hill.

Moore, G. A. (2015). Cruzando el abismo. Barcelona, España: Grupo Planeta.

Murphy, K. P. (2012). Machine learning: a probabilistic perspective. MIT press.

Naranjo Valencia, J. C. N., Valle, R. S., & Jiménez, D. J. (2008). Cultura organizacional e innovación: un estudio empírico. In Estableciendo puentes en una economía global (p. 5). Escuela Superior de Gestión Comercial y Marketing, ESIC. Recuperado de: https://dialnet.unirioja.es/servlet/articulo?codigo=2710833.

Nieponice, G., Rivera, R., Tfeli, A., & Drewanz, J. (2018). Acelerando el desarrollo de Industria 4.0 en Argentina. Boston Consulting Group. Recuperado de http://image-src.bcg.com/Images/Acelerando-el-Desarrollo-de-Industria-40-en-Argentina_tcm62-184622.pdf

OECD. (2006). Manual de Oslo: Guía para la recogida e interpretación de datos sobre innovación. Recuperado de: https://www.oecd-ilibrary.org/science-and-technology/manual-de-oslo_9789264065659-es

OECD (2016). Enabling the next production revolution: the future of manufacturing and services-interim report: Meeting of the OECD Council at Ministerial Level Paris. Paris.

OECD. (2018). Financial Markets, Insurance and Private Pensions: Digitalisation and Finance. Recuperado de: https://www.oecd.org/competition/financial-markets-insurance-and-pensions-2018.htm

Palacio Garcés, R. A. (2017). La convergencia del FinTech, LawTech & RegTech: Panorama global de aprendizaje para Américа Latina. Recuperado de: https://www.felaban.net/monografias/ganadores/2017/Ricardo%20Palacio%20-%20LA%20CONVERGENCIA%20DEL%20FINTECH%20LAWTECH%20Y%20REGTECH.pdf

Perols, J. (2011). Financial Statement Fraud Detection: An Analysis of Statistical and Machine Learning Algorithms. AUDITING: A Journal of Practice & Theory, 30(2), 19–50. DOI:10.2308/ajpt-50009

Pollock, R. (2018). The Open Revolution. A/E/T Press.

Porter, M.E. (1990). The Competitive Advantage of Nations. Free Press, New York; London; Toronto.

PricewaterhouseCoopers. (2016). “Blurred lines: how Fintech is shaping the Financial Industry”. Recuperado de: https://www.pwc.de/de/newsletter/finanzdienstleistung/assets/insurance-inside-ausgabe-4-maerz-2016.pdf

PricewaterhouseCoopers. (2017a). Global FinTech Report 2017. Redrawing the Lines: FinTech's Growing Influence on Financial Services. Londres: PwC. Recuperado de: https://www.pwc.com/gx/en/industries/financial-services/fintech-survey/report.html

PricewaterhouseCoopers. (2017b). Encuesta Global de FinTech, capítulo Argentina. La influencia de las FinTech renueva la industria financiera. Recuperado de: https://www.pwc.com.ar/es/publicaciones/assets/la-influencia-de-las-fintech.pdf

Rao, A. S., & Verweij, G. (2017). PWC. Sizing the prize. ¿What's the real value of AI for your business and how can you capitalise? Recuperado de: https://www.pwc.com/gx/en/issues/data-and-analytics/publications/artificial-intelligence-study.html

Raymond, E. (1999), The Cathedral and the Bazaar: Musings on Linux and Open Source by an accidental revolutionary, Sebastopol, CA: O'Reilly.

Rich, E.& Knight, K. (1994). Inteligencia Artificial. Madrid: McGraw-Hill, D. L.

Rogers, E.M. (2003). Diffusion of innovations (5ta. Ed.). Nueva York, USA: Free Press (1962).

Rojas, L. (2016). La revolución de las empresas Fintech y el futuro de la Banca. Banco de desarrollo de América Latina. DOI: https://doi.org/978-980-6810-67-9

Rojas, L. (2017). Nº 25: Transformación Digital e Innovación Abierta en la Banca. Caso del BBVA. Políticas públicas y transformación productiva;26, Caracas: CAF. Recuperado de: http://scioteca.caf.com/handle/123456789/1026.

Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. Psychological review, 65(6), 386. DOI: http://dx.doi.org/10.1037/h0042519

Russell, S., & Norvig, P. (1995). Artificial intelligence: A modern approach prentice-hall. Englewood cliffs, NJ.

Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. IBM Journal of Research and Development, 3(3), 210-229. DOI: https://doi.org/10.1007/978-1-4613-8716-9_15

Sandulli, F. D., & Chesbrough, H. Open Business Models: Las dos caras de los Modelos de Negocio Abiertos. UCJC Business and Society Review (formerly Known As Universia Business Review), 2(22). Recuperado de: https://journals.ucjc.edu/ubr/article/view/693

SAS (s.f.). Seacoast Bank enhances customer value using AI and SAS® Visual Analytics on SAS® Viya®. Recuperado de: https://www.sas.com/en_ie/customers/seacoast-bank.html

Schein, E. H. (1992). Organizational Culture and leadership. 2nd ed. San Francisco: Jossey Bass.

Schumpeter, J. A. (1934). The Theory of Economic Development, Nueva York: Oxford University Press.

Schumpeter, J. A. (1966). El Manifiesto Economista en la Sociología y la Economía. id., Ensayos. Barcelona, Oikos-Tau, 289-307.

Schwab, K. (2016). The Fourth Industrial Revolution. World Economic Forum. Geneva, Switzerland.

Shapiro, S. C. (1992). Encyclopedia of artificial intelligence second edition. John.

Sirignano, J., Sadhwani, A., & Giesecke, K. (2016). Deep learning for mortgage risk. arXiv preprint arXiv:1607.02470.

Skinner, C. (2014). Digital Bank. Strategies to succeed as a digital Bank.

Smeureanu, I., Ruxanda, G., & Badea, L. M. (2013). Customer segmentation in private banking sector using machine learning techniques. Journal of Business Economics and Management, 14(5), 923-939. DOI: https://doi.org/10.3846/16111699.2012.749807

Solow, R. M. (1956). A contribution to the theory of economic growth. The quarterly journal of economics, 70(1), 65-94.

Taylor, K. (2019). Artificial Intelligence in Banking. Presentación llevada a cabo en *headquarters* de SAS en Carolina del Norte, USA, mayo. Recuperado de: entrevista llevada a cabo con Juan José Nugoli de SAS el día 3 de junio de 2019.

Taylor, W.K. (1956). Electrical simulation of some nervous system functional activities. Information theory, 3, 314-328.

Technisys. (2017). La Banca Digital en América Latina Tendencias, desafíos y prioridades del escenario actual 2ª edición - 2015/2016. Recuperado de: https://www.technisys.com/wp-content/uploads/2017/02/La_Banca_Digital_en-America_Latina_ES.pdf

Teradata (2018). Danske Bank Fights Fraud with Deep Learning and AI. Recuperado de: http://assets.teradata.com/resourceCenter/downloads/CaseStudies/CaseStudy_EB9821_Danske_Bank_Fights_Fraud.pdf

Tsai, C. F., & Chen, M. L. (2010). Credit rating by hybrid machine learning techniques. Applied Soft Computing, 10(2), 374–380. DOI: 10.1016/j.asoc.2009.08.003.

UNSGSA FinTech Working Group and CCAF. (2019). Early Lessons on Regulatory Innovations to Enable Inclusive FinTech: Innovation Offices, Regulatory Sandboxes, and RegTech. Office of the UNSGSA and CCAF: New York, NY and Cambridge, UK. Recuperado de: https://www.unsgsa.org/files/2915/5016/4448/Early_Lessons_on_Regulatory_Innovations_to_Enable_Inclusive_FinTech.pdf

Van Dam, K., Oreg, S. & Schyns, B. (2008). Daily Work Contexts and Resistance to Organisational Change: The Role of Leader-Member Exchange, Development Climate, and Change Process Characteristics. Applied Psychology: An international review, 57 (2), 313–334.

Van de Vrande, V., de Jong, J. P. J., Vanhaverbeke, W., & de Rochemont, M. (2009). Open innovation in SMEs: Trends, motives and management challenges, 29, 423– 437. DOI: https://doi.org/10.1016/j.technovation.2008.10.001

Van Liebergen B. (2017). Machine Learning: A Revolution in Risk Management and Compliance? Journal of Financial Transformation, 45, 60-67. Recuperado de: https://www.iif.com/portals/0/Files/private/32370132_van_liebergen_-_machine_learning_in_compliance_risk_management.pdf

Varela, H. (2010). Liderazgo transaccional vs liderazgo transformacional. Recuperado de: http://manuelgross. bligoo. com/content/view/785903/TablacomparativaLiderazgo-Transaccional-vs-Liderazgo-Transformacional. html.

Von Hippel, E. (2005). Democratizing Innovation, Cambridge, MA: The MIT Press.

Von Krogh, G. (2018). Artificial Intelligence in Organizations: New Opportunities for Phenomenon-Based Theorizing. Academy of Management Discoveries, 4(4), 404–409.d DOI:10.5465/amd.2018.0084

Widrow, B., & Hoff, M. E. (1960). Adaptive switching circuits (No. TR-1553-1). Stanford Univ Ca Stanford Electronics Labs.

Winston, P. (1992). Learning by building identification trees. Artificial intelligence, 423-442.

World Economic Forum (2018). New Physics of Financial services. Understanding how artificial intelligence is transforming the financial ecosystem. Agosto. Recuperado de: https://www.weforum.org/reports/the-new-physics-of-financial-services-how-artificial-intelligence-is-transforming-the-financial-ecosystem.

Wu, W., Chen, J., Yang, Z. B., & Tindall, M. L. (2018). A Cross-Sectional Machine Learning Approach for Hedge Fund Return Prediction and Fund Selection. DOI: http://dx.doi.org/10.2139/ssrn.3238466

Yin, R. (1994) Case study research: design and methods. Segunda Edición. Thousand Oaks. SAGE. California. Estados Unidos.

Yukl, G. (2002). Leadership in organizations, (5a ed.). Upper Saddle River, NJ: Prentice Hall.

Zikmund, W. G., & Carr, G. (2000). Business Research Methods. 7th. USA, Dryden.

QUAERERE VERUM
Universidad de
SanAndrés

Anexos

Anexo I. Proveedores de soluciones

Forrester ha evaluado el estado del mercado de las plataformas de analítica empresarial y compara los proveedores entre sí. Forrester estudió los proveedores teniendo en cuenta tres factores principales: la oferta actual, la estrategia y la cuota de mercado. La oferta actual refiere a la posición de cada proveedor en el eje vertical del gráfico de Forrester Wave e indica la solidez de su oferta actual. Los criterios esenciales de estas soluciones son la gestión de datos, la analítica, las herramientas de desarrollo de aplicaciones de conocimiento y las funciones de administración de la plataforma. La Estrategia es la posición en el eje horizontal que indica la solidez de las estrategias de los proveedores. Forrester analizó la visión del producto, el rendimiento anterior, las hojas de ruta de la innovación, los modelos de prestación y los ecosistemas de socios. La cuota de mercado, las puntuaciones de presencia en el mercado reflejan los ingresos y el número de clientes de cada proveedor y se indican en el gráfico por el tamaño de los marcadores. Continuación se visualiza el resultado del estudio de Forrester donde se identifica a SAS, IBM y Microsoft como líderes.

Figura 11. The Forrester Wave. Plataformas de Analítica Empresarial

La figura muestra el resultado obtenido midiendo de cada proveedor, la cuota de mercado, la estrategia y la oferta actual. Fuente: Hopkins (2019). Recuperado de: https://www.ibm.com/downloads/cas/PKXDXX7M. Copyright 2019.

Por el lado de Gartner (2019), se ha elaborado el Cuadrante Mágico para la ciencia de datos y las plataformas de aprendizaje automático que evalúa a los proveedores de plataformas de ciencia de datos y aprendizaje automático. Estos son productos de software que permiten a científicos expertos en datos, científicos de datos ciudadanos y desarrolladores de aplicaciones crear, implementar y administrar sus propios modelos analíticos avanzados. En este caso, Gartner califica a IBM (con su producto Watson como estandarte) y Microsoft como visionarios y a SAS (con sus productos SAS Enterprise Miner (EM) y SAS Visual Data Mining and Machine Learning (VDMML)) como líder. Se puede visualizar que la plataforma H2O.ai está calificada como visionaria. Gartner (2019) evalúa a esta plataforma con componentes de aprendizaje automático de alto rendimiento. Esta herramienta tiene una capa de aprendizaje profundo, una capa GPU y capacidades de automatización (H2O Driverless AI), según Gartner (2019) H2O.ai supera a la mayoría de sus competidores en el empleo de capacidades de tecnología de vanguardia.

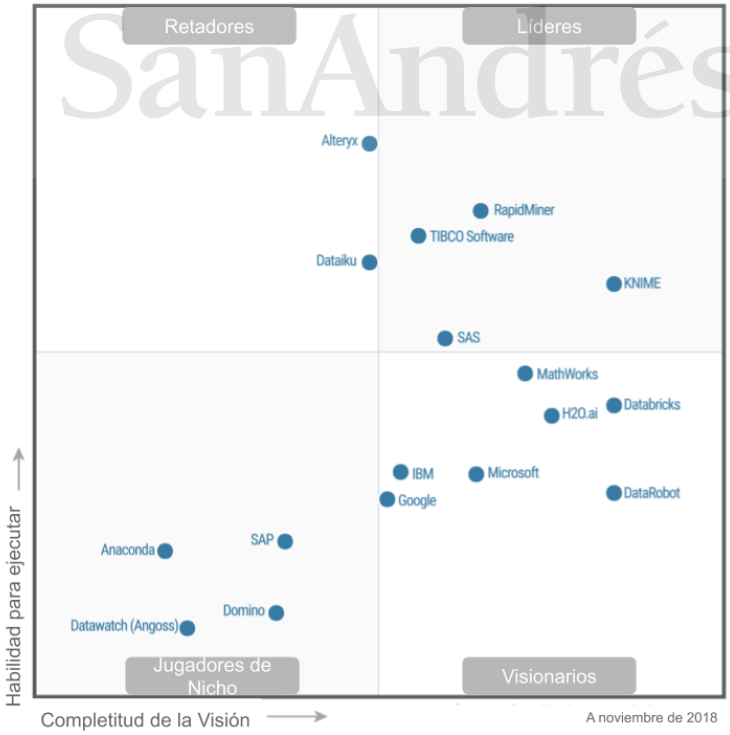

Figura 12. Cuadrante mágico de Gartner para la ciencia de datos y las plataformas de aprendizaje automático.

La figura muestra el cuadrante mágico con los resultados de os proveedores ubicados en los cuadrantes según la evaluación realizada por Gartner. Recuperado de https://www.gartner.com/doc/reprints?id=1-65WC0O1&ct=190128&st=sb. Copyright 2019. Traducción propia.

QUAERERE VERUM
Universidad de
SanAndrés

Anexo II. Detalle Referencias Entrevistados

Para el trabajo de campo como se mencionó en la sección de metodología se llevaron a cabo entrevistas semiestructuradas con expertos y referentes, con el fin de identificar su visión y postura respecto al objeto de estudio del presente trabajo. Las entrevistas se llevaron a cabo en la Ciudad de Buenos Aires entre los meses de abril y junio de 2019. A continuación, se detalla la lista de entrevistados y sus referencias agrupados según la estrategia definida:

Bancos Privados Tradicionales

Fernando Turri

Fecha Entrevista: 6 de junio de 2019

Tipo de Entrevista:

Referencias: Fernando es un profesional con más de 22 años de experiencia en servicios de negocios globales (consultoría, TI, gestión de proyectos, procesos de negocios y centros de servicios compartidos) con un registro constante de registros que impulsan un aumento de la productividad, la excelencia de los procesos de negocios, implementaciones, transformaciones y procesos internos / externos la satisfacción del cliente. Reconocido como un líder y agente de cambio que diseña e implementa soluciones empresariales / técnicas a nivel mundial con ganancias y un ROI sólido. Tiene un sólido conocimiento en los procesos de suministro de productos, logística, ventas, marketing y finanzas. Tiene Experiencia mundial / multicultural en América Latina (viviendo en Argentina, Brasil y México), Europa (viviendo en Suiza) y Asia (viviendo en China y Filipinas). Trabajó en diferentes industrias: petróleo y gas, medios de comunicación, bienes de consumo y servicios financieros. Fernando tiene una amplia experiencia en gestión de programas de transformación y transformación digital.

Actualmente se desempeña como CIO de Banco Galicia y anteriormente fue CIO y Business Process Leader en Banco Hipotecario.

Fernando es contador Público egresado de la Universidad de Belgrano y tiene realizado varios programas y posgrados en IAE.

Eduardo U. Peralta

Fecha Entrevista: 03 de mayo de 2019

Tipo de Entrevista: Comunicación vía correo electrónico con cuestionario enviado previamente

Referencias: Eduardo Peralta es Gerente de Desarrollo de Sistemas Centrales en Banco Supervielle. Tiene amplia experiencia gerenciando áreas de Desarrollo de Bancos y Entidades Financieras. Eduardo es calculista científico egresado de la Universidad Nacional de La Plata.

Nicolas Martins

Fecha Entrevista: 24 de junio de 2019

Tipo de Entrevista: Comunicación telefónica

Referencias: Nicolás es especialista en *Data & Analytics*. En la actualidad es Gerente de Inteligencia Comercial & Gobierno de Datos del Cliente en Banco Macro y está liderando el desarrollo de proyectos relacionados con la visión 360 del cliente, modelos predictivos, explotación analítica y automatización de soluciones basadas en grandes volúmenes de datos y aprendizaje automático.

Nicolás tiene una amplia experiencia en áreas comerciales bancarias.

Es Licenciado en Administración egresado de la Universidad de Buenos Aires, tiene una maestría en Economía Aplicada de la Universidad Católica Argentina y una especialización en Ciencia de Datos del Instituto Tecnológico de Buenos Aires.

Virginia Martini Zanetti

Fecha Entrevista: 25 de junio de 2019

Tipo de Entrevista: Comunicación personal

Referencias: Virginia es Head de Datos del Banco Santander responsable de definir e implementar la estrategia de Datos en el banco con el objetivo de garantizar la transformación digital del Banco hacia una organización *data driven*, con disponibilidad, escalabilidad, eficiencia, agilidad y calidad de datos para el negocio. Es responsable de definir y coordinar las necesidades de digitalización, BI, RPA, analytics, machine learning, robotics, entre otros y de implantar herramientas comunes para la explotación y visualización de datos.

Virginia es Licenciada en Administración de empresas de la UADE.

María Fernanda González

Fecha Entrevista: 23 de mayo de 2019

Tipo de Entrevista: participación en conferencia

Referencias: María Fernanda tiene una extensa carrera en el área de Banca Comercial de Banco Santander Rio. Entre sus últimas posiciones se pueden mencionar que fue Gerente de Marketing Directo, Comunicación Digital e Integración Digital con el negocio, Gerente de Internet y Marketing Directo y hace 5 años se destaca como Gerente de Canales Digitales. Fernanda es responsable de definir la estrategia, desarrollo funcional y comercial de los canales digitales de la Banca de Personas y Empresas, entre estos canales se encuentra: Online Banking Personas (el Home Banking más completo, utilizado y premiado de Argentina), Online Banking Empresas, la APP de Santander Río (la APP de bancos más descargada y usada de Argentina), los sitios web públicos de Santander Río (los sitios de banco más utilizados de Argentina), las redes sociales del banco y acciones de marketing digital de performance para el logro de los objetivos comerciales de los canales digitales. Fernanda es Licenciada en Comercialización de la Universidad Argentina de la Empresa y tiene un Executive MBA del Instituto Argentino de la Empresa.

Sergio Bauzá

Fecha Entrevista: 23 de mayo de 2019

Tipo de Entrevista: participación en conferencia

Referencias: Sergio es Gerente de Calidad y Servicios al Cliente en el Banco Santander Río. Tiene una larga trayectoria en el Banco Santander Rio. Particularmente durante los últimos 10 años ha estado trabajando en Calidad y Servicios al Cliente. Es responsable de elaborar y procesar las métricas estándar, definir, implementar y entregar una amplia gama de proyectos de mejora y garantizar altos estándares en la resolución de quejas de los clientes.

Sergio es licenciado en Economía de la Universidad del Salvador y tiene una maestría en Economía Aplicada en la Universidad de CEMA

Fintech y Bancos Digitales

Juan Pablo Bruzzo y Leonardo Aranda

Fecha Entrevista: 3 de mayo de 2019

Tipo de Entrevista: Comunicación Personal

Referencias: Juan Pablo Bruzzo es CEO & Co-Founder MONI. Moni es una solución de banca móvil que permite a sus clientes tener acceso instantáneo a los pagos de crédito y facturas. La compañía opera en México y Argentina. Juan Pablo es Presidente Cámara Argentina Fintech desde agosto de 2018. Fue CO-Ceo de Dinero Mail de Julio de 2006 hasta 2013. Es Ingeniero Industrial egresado del Instituto Tecnológico de Buenos Aires y tiene un EMBA (Executive MBA) del Instituto Argentino de la Empresa.

Leonardo Aranda es Chief Data Scientist en MONI. Es Licenciado en Administración egresado de la Universidad Nacional de Loma de Zamora y ha cursado el Master of Science (M.Sc.), Data Mining and Knowledge Discovery de la Universidad de Buenos Aires. Tiene experiencia en marketing science, sistemas de recomendación, prevención de fraudes e iniciativas de inteligencia empresarial para impulsar el crecimiento y la participación del cliente en el comercio electrónico. Es experto en métodos estadísticos multivariantes, aprendizaje automático y tecnologías de big data. Leonardo tiene una amplia experiencia ayudando a las organizaciones a identificar, comprender y mejorar sus procesos de negocio críticos, convirtiendo los datos en información procesable.

Guillermo Marchionni

Fecha de la Entrevista: 14 de mayo de 2019

Tipo de Entrevista: Comunicación Personal

Referencias: Guillermo es director para Argentina, Brasil y España en Digital Bank Latam, con una historia demostrada de trabajo en la industria de servicios financieros. Guillermo tiene un fuerte foco en potenciar nuevos modelos de negocio a través de la transformación digital de las empresas.

Es director y cofundador de CG2 que tiene por objetivo implementar soluciones innovadoras en Banca Digital y Fintech.

Guillermo es contador público egresado de la Universidad de Buenos Aires y es doctor en ciencias económicas de la misma universidad.

Florencia Vidal

Fecha Entrevista: 26 de abril de 2019

Tipo de Entrevista: Comunicación Telefónica

Referencias: Florencia Vidal es Regional Press & Communications Manager en Afluenta. Desarrolla, implementa y administra las estrategias de comunicación corporativas de Afluenta dentro de la red interna y externa, la prensa y los canales de medios sociales. En la entrevista llevada a cabo Florencia comunicó la posición de Afluenta ante las preguntas realizadas.

Ente Regulador BCRA

Marcelo Hector González

Fecha de la Entrevista: 7 de mayo de 2019

Tipo de Entrevista: Comunicación Personal

Referencias: Marcelo Héctor González, CISA, CRISC es Inspector General de Sistemas de Información de la Entidades Financieras en la Superintendecia de Entidades Financieras y Cambiarias – Banco Central de la República Argentina, donde entre otras tareas ha realizado auditorias en centros de procesamiento de datos, tales como: Volkswagen Bank GmbH y VW Financial Services AG en Braunschweig – Alemania; Deutsche Bank AG en Alemania (Frankfurt y Dusseldorf); Deutsche Bank AG en United Kingdom (Londres); Deutsche Bank AG en los Estados Unidos de América (New York y New Jersey); Citibank N.A. en los Estados Unidos de América (New York, New Jersey, Delaware, Texas y Maryland); Republic National Bank of New York en los Estados Unidos de América (New York); Banco do Brasil en Brasil (Brasilia); Ford Credit Data Center en Australia (Melbourne), y Banco BBVA en España (Madrid).

Es miembro del Comité de Supervisión Bancaria de Basilea (BCBS, sigla de Basel Committee on Banking Supervision en inglés) del Banco de Pagos Internacionales (BIS, sigla de Bank for International Settlements). Forma parte de una Task Force sobre tecnología financiera, donde se evalúa los riesgos y desafíos de supervisión asociados con la innovación y los cambios tecnológicos que afectan a la banca. También es miembro del *Operational Resillience Group* del mismo Comité que evalúa los problemas relacionados con el riesgo cibernético y la resistencia operativa más amplia.

Ha ocupado distintas posiciones en ISACA Internacional (*Information System, Audit and Control Association*) en Chicago – USA, desde Junio del 2013 ha sido presidente del *Government and Regulatory Agencies Regional Subcommittee* Area 2, desde 2011 a 2013 se desempeñó como miembro regional del mismo Subcomité; durante el año 2010 ocupó el puesto de miembro en el

External Relations Committee; en el año 2009 fue miembro del *Professional Influence & Advocacy Committee*, además ha sido miembro activo del *Standards Board* y del *Government and Regulatory Agencies Board*. Ha sido responsable de gestar la "Audit Guideline of Internet Banking" y diversos artículos para el "IS Control Journal"siendo el más reciente el publicado en Abril de 2015 sobre "Riesgo de Internet de las Cosas"; ha contribuido en el desarrollo de los manuales de revisión CISA, desde el año 2001 a 2010. Ha sido miembro del "Basel best practice ISACA team" que concluyo con la publicación en un libro sobre "IT Control Objectives for Basel II", revisor del Cobit 5. En el ámbito de ISACA *Buenos Aires Chapter (Information System, Audit and Control Association)*, actualmente se desempeña como Director de Nominaciones, fue Director de Relaciones Institucionales e Internacionales desde 2010 a 2012, ha sido presidente desde el 2008 al 2010, Vicepresidente desde 2006 a 2007; Director de Relaciones Institucionales desde 2004 a 2005; Vicepresidente desde 2002 a 2003; Director de Relaciones Institucionales desde 1999 a 2001, y Secretario desde 1996 a 1998.

Es un activo conferencista para ISACA, ADACSI, MarcusEvans, Forum, CXO y otras instituciones locales e internacionales, en temas tales como: Business Continuity Plan, Security Risks and Controls in Data Centers, Audit, Control and Security in Telecommunications, Audit, Control and Security for e-Commerce, COBIT Best Practices, Telecommunications – Secure communication protocols, E-Commerce, e-Business and e-Banking, Internet Banking, Wi-Fi Security, Governance, Risk and Compliance, entre otros temas de actualidad. Ha estado entrenando en temas tales como: Preparación para el examen CISA en ISACA Buenos Aires Chapter desde 1994; preparación para el examen CISA en ISACA Panamá Chapter durante el año 2002; control del riesgo tecnológico y su vinculación con el riesgo operacional en el Banco BHD (Banco Hipotecario Dominicano) en la Republica Dominicana in 2007.

Ha recibido el premio "John Kuyers Best Speaker/Conference Contributor Award" en el año 2006. El mismo reconoce la contribución en el desarrollo de las conferencias globales de ISACA. La nominación fue aprobada por el Presidente Internacional de ISACA Everett Johnson, el Global Conference Program Committee, y el ISACA/ITGI Board.

Ha sido parte del Comité del Programa del Latin CACS para las conferencias del año 2001 y 2002 y presidente del Comité del Programa del Latin CACS para el evento del año 2003. Ha participado activamente en innumerables eventos en carácter de conferencista invitado.

Ha certificado como CRISC (Certified in Risk and Information Systems Control) en el año 2010, con el número 1001742 y ha certificado CISA (Certified Information Systems Auditor) en el año 1994, con el número 9414298.

Posee distintas certificaciones académicas de grado y post-grado en electrónica, sistemas de información y en investigación operativa, además de varios postgrados en finanzas y economía.

Su carrera profesional se ha desarrollado en diversas compañías: Banco Central de la República Argentina, como Inspector General; MULTICARD S.A. como IT Manager Director; MASTERCARD Argentina, como senior IT Auditor; Municipalidad de la Ciudad de La Plata como Telecommunication Administrator and Systems Programmer; y en la Suprema Corte de Justicia de la Provincia de Buenos Aires como consultor de sistemas de información.

Referentes Académicos en temas de Digitalización, Transformación Digital y /o, Inteligencia Artificial y Machine Learning

Ignacio R. Carballo

Fecha de la Entrevista: 26 de abril de 2019

Tipo de Entrevista: Comunicación Personal

Referencias: Ignacio E. Carballo es especialista en Inclusión Financiera. Licenciado en Economía por la Universidad de Buenos Aires con título cum-laude y magíster por la Universidad Autónoma de Madrid del Máster Internacional en Microfinanzas e Inclusión Financiera con diploma de honor mediante beca otorgada por la Fundación Carolina. Posee certificados de Experto en Políticas de Inclusión Financiera (CEFIP) y Experto en Microfinanzas (CEMF) por la Frankfurt School of Finance & Management, Alemania, y de Analista en Microfinanzas por la Pontificia Universidad Católica Argentina (UCA) y UNED de España. Es profesor de grado en la Universidad Católica Argentina (UCA), en la Universidad de Buenos Aires (UBA), en la Universidad Austral, Profesor principal e impulsor del Curso de Posgrado en Inclusión Financiera y Economía Social de la UCA y director del Programa Ejecutivo en Fintech & Digital Banking en la Escuela de Negocios de dicha universidad. Se ha desempeñado como Investigador en el Centro de Investigación Aplicada perteneciente a la Escuela de Negocios de la Pontificia Universidad Católica Argentina y en el IAE Business School de la Universidad Austral además de haber colaborado en la Agencia Española de Cooperación Internacional para el Desarrollo (AECID) y

en proyectos de consultoría internacional financiados por el BID-FOMIN. Es a su vez doctorando en la Facultad Latinoamericana de Ciencias Sociales (FLACSO) y colabora en tareas de investigación como parte del Centro de Estudios de la Estructura Económica (CENES) de la FCE-UBA. Es creador de Cimientos Económicos (www.ignaciocarballo.com)

Hernán Borré

Fecha de la Entrevista: 14 de mayo de 2019

Tipo de Entrevista: Comunicación Personal

Referencias: Hernán es un experto en Inteligencia Artificial, Ingeniería de Aprendizaje Automático, Ingeniería de Software y Desarrollo de Software relacionado a aprendizaje automático, ciencia de datos, Aprendizaje de refuerzo, Aprendizaje profundo, Redes neuronales profundas, Java, Python, C ++, Python, Keras, Tensorflow, Theano, Numpy, Pandas, Sklearn, OpenCV, Máquinas de vectores de soporte, Regresión lineal, Árboles de decisión, Bosques aleatorios, Bayas ingenuas y Redes neuronales de alimentación directa.

En la actualidad se desempeña como Head de Machine Learning en el Ministerio de Producción y trabajo de la República Argentina.

Hernán es Ingeniero en Sistemas de Información de la Universidad Tecnológica Nacional y tiene un Master en Inteligencia Artificial en la Universidad de Essex, Reino Unido.

Carlos A. Giménez

Fecha de la Entrevista: 7 de mayo 2019

Tipo de Entrevista: Comunicación Personal

Referencias: Carlos es un científico de datos orientado al modelado computacional y la aplicación de técnicas de big data, inteligencia artificial y aprendizaje automático. En la actualidad se desempeña como Chief Analytics Officer en Digital Tarjeta Naranja y Docente en Universidad de San Andrés. Tiene una amplia carrera desempeñándose como Científico de Datos y líder en empresas como Telefónica, San Cristóbal Seguros, Legal HUB.

Carlos tiene una amplia experiencia académica ya que fue profesar de mecánica cuántica I y II, y de Mecanismos Nucleares de la Universidad Nacional del Nordeste, Además fue profesor del Posdoctorado de la UBA de Mecánica Cuántica Relativista y fue instructor de Data Science de la EANT, Escuela argentina de Nuevas Tecnologías.

Carlos egresó de la Universidad Nacional del Nordeste como Licenciado en física atómica y molecular y tiene un Doctorado en Filosofía y Física (2015); además, tiene un posdoctorado en Mecánica Cuántica Relativista de la UBA en 2016. En la actualidad está cursando un MBA en la Universidad de San Andrés. Carlos tiene varias licencias y certificaciones relacionados a Datos, *Machine Learnin*g y *Data Science* de la Johns Hopkins University.

Expertos en la Industria

Juan Martín Maglione

Fecha Entrevista: 15 de mayo de 2019

Tipo de Entrevista: Comunicación por Videollamada

Referencias: Juan Martín Maglione es Licenciado en Administración de Empresas, con Magister en Dirección Estratégica y Tecnológica en ITBA, Máster en Dirección Estratégica y Tecnológica en EOI (España) y especializado en International Business Consultancy en Fontys University of Applied Sciences en Eindhoven, Holanda. También ha realizado una Diplomatura en Big Data y en Metodologías Ágiles de Product Management en ITBA.

Es Head of Artificial Intelligence en SAI (Amsterdam, Holanda), co-Founder de Fictionary, un juego mobile y de Fon.ai, una organización que brinda soluciones de Inteligencia Artificial y Analytics para organizaciones nacionales e internacionales públicas y privadas.

Se desempeñó como Engagement Manager Regional en Cognitiva para Argentina, Paraguay y Uruguay. Fue el líder de la creación, construcción y actualización de las metodologías consultivas que utiliza Cognitiva, habiendo coordinado al equipo de consultores de toda la región (Costa Rica, Colombia, México, Chile y Argentina).

Formó parte de la firma de consultoría KPMG, habiendo participado en la creación de la práctica de S&OP - Strategy and Operations.

Ignacio Perrone

Fecha de la Entrevista: 2 de mayo de 2019

Tipo de Entrevista: Comunicación Personal

Referencias: Ignacio Perrone es un experto de la industria con más de 15 años de experiencia en el sector de Tecnologías de la Información y la Comunicación (TIC). Actualmente

se desempeña como Research Manager del área de Tecnologías de la Información y la Comunicación de Frost & Sullivan en América Latina, cubriendo la gestión regional de los estudios de inteligencia de mercado y proyectos de consultoría estratégica, asistiendo a los participantes de la cadena de valor globales y regionales. Además de su papel de interacción con los clientes, Perrone también participa en los eventos más importantes de la región como conferencista, moderador y panelista, y contribuye con artículos y comentarios relacionados a la industria en prensa latinoamericana e internacional. Su experiencia en el sector abarca proyectos de consultoría relacionados con el tamaño del mercado en términos de Telecom y servicios de TI, tendencias de consumo, soluciones/servicios por vertical, movilidad empresarial, M2M y VAS. Anteriormente, Perrone trabajó para Logicalis, AIM, The Yankee Group y Pyramid Research. Ignacio Perrone posee una licenciatura en Sociología de la Universidad de Buenos Aires, una maestría en Sociología Económica de la UNSAM (Buenos Aires) y un MBA de la Universidad Di Tella (Buenos Aires).

Proveedores

Alejandro Bolaños; Ana Hidalgo y Juan José Nugoli (SAS Argentina)

Fecha de la Entrevista: 3 de Junio de 2018

Tipo de Entrevista: Comunicación Personal

Referencias:

Alejandro Bolaños es especialista en Analytics y Big Data, desarrolla modelos analíticos para importantes empresas del mercado argentino (telcos, banca, retail, industría pesada, entre otros). Es un experto en el uso de tecnologías Open Source como Python, Hadoop, Hive y Spark y de High Performance Analytics para analizar y obtener modelos sobre grandes volúmenes de datos. También es un experto en Analytics en Tiempo Real (IoT, CEP) y de desarrollo de pipelines analíticos y text mining. En la actualidad es HEAD AI &Data Science en SAS Argentina y también tiene una larga trayectoria en soluciones de tecnología.

Alejandro es Licenciado en Matemática de CAECE, tiene una Especialidad en Data Mining en UBA en el año 2012 y en el año 2013 también en UBA cursó una maestría en Data Mining de la cual tiene su tesis en desarrollo.

Es también profesor auxiliar de la Maestría en Data Mining y Data Mining para Economía & Finanzas y fue Profesor de Probabilidades y Estadística de CAECE.

José Luis Nugoli es *Sales Manager for South Cone* en SAS. Gestiona las cuentas más grandes en SAS Argentina (industrias financieras y de seguros), así como de compañías de Nivel 1 en Uruguay, Paraguay y Bolivia. Desarrollo de pipeline, canales, crecimiento del uso y conocimiento de los productos SAS. Además, responsable de renovaciones de clientes y venta de proyectos. Coordina equipos multidisciplinares para el desarrollo empresarial. José es Ingeniero Industrial egresado de la Universidad de la Plata

Ana Hidalgo tiene una amplia experiencia en encabezar proyectos de desarrollo de software, especializándose en minería de datos e inteligencia de clientes para compañias locales y de EE. UU. Ha llevado adelante exitosos proyectos proyectos de minería de datos, gestión de campañas y software de medios digitales. En la actualidad se desempeña como *Pre Sales Manager at SAS*.

Ana es Ingeniera Informática egresada de la Universidad Nacional de la Región Centroccidental de Venezuela. Tiene una Especialidad en explotación de Datos y descubrimiento del conocimiento, Data Mining de la Universidad de Buenos Aires y una Maestría en explotación de Datos y descubrimiento del conocimiento, Data Mining de la misma Universidad.

María de las Mercedes Noriega Canellas (IBM Argentina)

Fecha de la Entrevista: 31 de mayo de 2019

Tipo de Entrevista: Comunicación Personal

Referencias: María de las Mercedes se desempeña en la actualidad como Líder de Comunicación interna en Argentina, Social Media e Inteligencia Artificial en IBM. Tiene una amplia experiencia con Watson Analytics y Watson Analytics for Social Media. Líder de proyectos de monitoreo de las Redes Sociales en tiempo real para la industria bancaria (Santander Río y Bancolombia) con entrenamiento de algoritmos para clasificar las conversaciones en Twitter/ Facebook, y agruparlas por categorías.

María de las Mercedes es Licenciada en Comunicación Social de la Universidad Nacional de La Matanza y Magister en Comunicación, Cultura y Discursos Mediáticos de la misma universidad.

Wenceslao Cova (IBM Argentina)

Fecha de la Entrevista: 13 de junio de 2019

Tipo de Entrevista: Comunicación Personal

Referencias: Wenceslao es Data Science & IA Sales Leader de IBM. Es Licenciado en Sistemas de la Universidad Kennedy. Wenceslao tiene una amplia experiencia liderando proyectos de Tecnología de avanzada como Inteligencia artificial y Cloud Computing entre otros. En la actualidad desarrolla negocios y soluciones de servicios y soluciones de Watson en Argentina, Chile y Uruguay.

QUAERERE VERUM
Universidad de
SanAndrés

Anexo III. Preguntas Entrevistas para análisis de Campo

Las entrevistas semiestructuradas que se llevaron a cabo fueron presenciales, telefónicas o por Video llamadas y se basaron en las siguientes preguntas:

1. ¿Considera que las promesas de la inteligencia artificial y aprendizaje automático o *Machine Learning* en cuanto a reducción de costos, productividad, aumento del consumo, innovación, etc., pueden volverse realidad en la banca tradicional privada argentina?
2. ¿En qué actividades las aplicaciones de aprendizaje automático pueden ayudar a la Banca?
3. ¿Cuáles son las principales oportunidades que las soluciones de inteligencia artificial y aprendizaje automático o *Machine Learning* representan para la Banca?
4. ¿Qué barreras y desafíos tienen los Bancos a la hora de adoptar estas tecnologías en sus procesos operativos y comerciales?
5. ¿Existen riesgos resultantes de su implementación en la banca tradicional privada?

QUAERERE VERUM
Universidad de
SanAndrés

Anexo IV. Proceso de Innovación Disruptiva

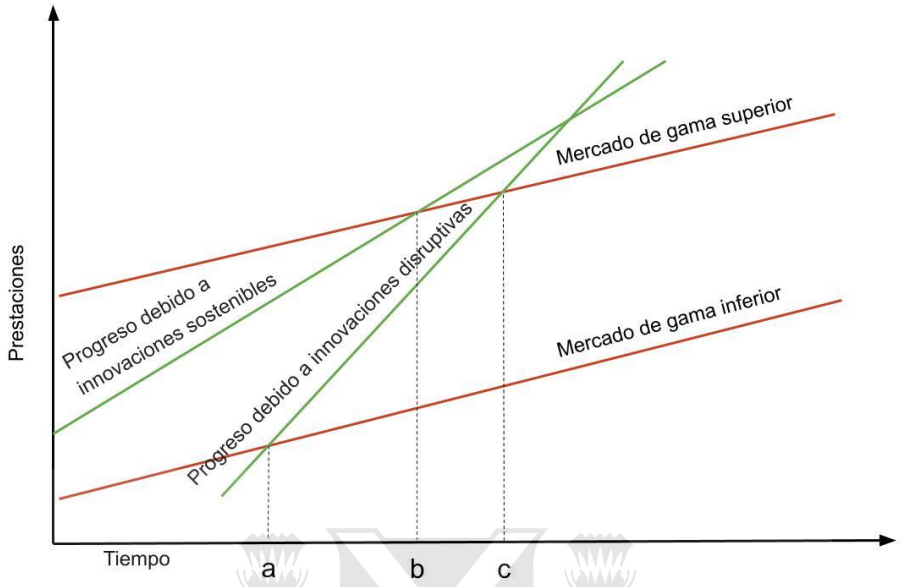

Figura 13. Innovación Disruptiva

En esta figura se puede observar lo planteado por Christensen con la innovación disruptiva. El momento "a" es aquel en el que la innovación disruptiva puede satisfacer la demanda de los consumidores menos exigentes (frecuentemente coincidirá con el Producto Mínimo Viable). En ese momento, los consumidores menos demandantes abandonan el producto de calidad superior, más caro, y que proporciona funcionalidades que estos consumidores no necesitan. El momento "b" es aquel en que el producto establecido en el mercado excede las necesidades de los consumidores menos demandantes, ofreciendo prestaciones que son poco utilizadas por estos usuarios, quienes, sin embargo, están pagando por esas prestaciones no utilizadas. Y por último el momento "c" en el que la innovación disruptiva alcanza las prestaciones exigidas por los consumidores más demandantes. Es el punto crítico o de no retorno en que el producto innovador elimina del mercado al producto establecido. Basado en Christensen (1999). Elaboración propia.

Anexo V. Adopción de innovaciones

Una vez entendido el concepto de innovación, sus tipos y principales variables involucradas en las innovaciones actuales se debe avanzar en comprender los factores que empujan o inhiben su adopción.

Los atributos de las innovaciones que podrían influir en su tasa de adopción son las ventajas relativas, la posibilidad de observación, la compatibilidad, la complejidad y la posibilidad de ensayo. Las ventajas relativas son las características de la innovación que indican si en realidad lo que se está proponiendo es mejor que lo que está remplazando o si vale la pena el cambio e implica riesgos razonables. Es el grado en que la innovación se considera mejor que la idea, práctica, programa o producto al que reemplaza. La posibilidad de observación, lo constituyen las características que hacen ver los resultados y las consecuencias de la aplicación de la innovación y hasta qué punto la innovación proporciona resultados tangibles o visibles. La compatibilidad, son las características que definen si la innovación es compatible con los valores, cultura, experiencias previas y necesidades de los usuarios potenciales y cuán compatible es la innovación con los valores, hábitos, experiencia y necesidades de las personas que posiblemente la adoptarían. La complejidad, indica si son fáciles de aplicar, comprender, mantener y si es fácil de entender su aplicabilidad, además de cuán difícil parece entender o utilizar la innovación. Y por último la posibilidad de ensayo, es decir hasta qué punto la innovación puede probarse/experimentarse, antes de que se adquiera el compromiso para adoptarla. Una innovación para ser adoptada con mayor rapidez debe contar con un nivel alto de percepción de ventaja, compatibilidad, experimentación y visibilidad, mientras que debe poseer una baja complejidad. El concentrarse en las características de las innovaciones, puede mejorar sus posibilidades de adopción y, por tanto, de difusión (Rogers, 2003).

Pero ¿qué es la difusión? La difusión de una innovación es el proceso mediante el cual una innovación es comunicada en el tiempo y es difundida por determinados canales, entre los miembros de un sistema social. Esta difusión constituye un tipo especial de comunicación, pues sus mensajes están encargados de difundir nuevas ideas. La teoría de la Difusión de Innovaciones de Rogers (2003) propone cuatro elementos que conforman el proceso de innovación: (i) la innovación misma; (ii) los canales de comunicación empleados para la difusión, (iii) el tiempo de difusión de la innovación y, (iv) el sistema social donde se difunde la innovación. El elemento

tiempo constituye el elemento clave de esta teoría, ya que su fundamento se sostiene en que la adopción se completa a través del tiempo. Consta de tres dimensiones, el proceso de decisión de la innovación, que es el proceso mental por el que un individuo o una organización toma una decisión; las categorías de adoptantes, según lo cercanos que están en adoptar la innovación; y el ritmo de adopción dentro del sistema social, en función del período de tiempo transcurrido. Con respecto a esta última dimensión, se define como la relativa velocidad con que una innovación es adoptada por los miembros de un sistema social. Se mide por el número de individuos que adoptan una idea en un período determinado de tiempo, indicador numérico que afecta a la curva de adopción de una innovación.

Categorías de adoptantes

Uno de los principales aportes de Rogers (2003) y de su Teoría de la Difusión de las Innovaciones está relacionado con el planteamiento de categorías de personas u organizaciones que adoptan innovaciones, sumado a la cuantificación de la participación de dichos perfiles en un proceso de adopción e implementación de una innovación en un sector específico. Identifica cinco grupos que resultan en las diferentes etapas de la adopción de una innovación. Los innovadores o generadores, que representan el 2,5% del sistema social que conforma la innovación, son los primeros en utilizar la innovación dentro del sistema social. Se les caracteriza como aventureros, siempre ansiosos de experimentar nuevas tecnologías. Son orientados al riesgo y son hábiles para entender y aplicar tecnologías complejas. Los primeros adoptantes, que representan el 13,5%, son calificados como respetables, líderes en el negocio. Personifican el concepto de utilizar nuevas ideas con éxito y discreción. Adoptan la tecnología porque reconocen sus beneficios y no por la necesidad de tener referencias confiables. Son reconocidos como líderes capaces de influenciar la conducta de otros en el negocio, son fijadores de tendencias.

La primera mayoría, que representan el 34%, son los deliberantes, ya que realizan una alta deliberación antes de acoger totalmente una nueva idea, por lo que tienen tiempos de decisión más altos. "Ni el último en abandonar lo viejo ni el primero en ensayar lo nuevo". Requieren tener referencia de experiencias exitosas antes de adoptar la innovación.

La mayoría tardía (34%), son los escépticos. Asumen un aire de desconfianza y cautela ante las innovaciones. Se sienten incómodos con la tecnología y les resulta indispensable la presión de sus congéneres para motivar la adopción. Llegan a esta por presiones económicas o sociales.

Y por último los rezagados (16%) que son los últimos en adoptar la innovación o simplemente la rechazan. Aquí se incluyen por lo tanto los individuos u organizaciones que en su mayoría nunca llegan a adoptar. Son los tradicionales, su única referencia es el pasado y toman sus resoluciones con el criterio de lo que ha realizado la generación anterior.

Al momento de representar de manera gráfica las participaciones de los distintos perfiles de manera separada, se obtiene una curva similar a una distribución normal (Figura 9).

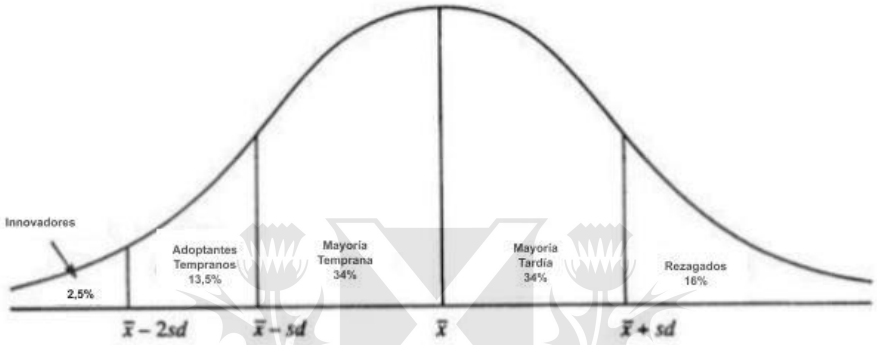

Figura 14. Categorización de Adoptantes

Esta figura representa la distribución de las categorías de personas u organizaciones definidas por (Rogers, 2003) que adoptan innovaciones, sumado a la cuantificación de la participación de dichos perfiles en un proceso de adopción e implementación de una innovación en un sector específico.
Copyright 2003.

La difusión de las innovaciones inicialmente sigue una curva en forma de S. Esta curva muestra la lentitud de la adopción de una innovación en la etapa inicial y se incrementa al mismo tiempo que el número de adoptantes también lo hace. Cuando disminuye el número de nuevos adoptantes, naturalmente, la curva de difusión también lo hace, pues casi todo usuario potencial ya usa la nueva tecnología. La curva puede ser alargada (hacia arriba) o aplanada, dependiendo del tiempo que tarde la adopción de la innovación.

La figura 10 representa esta curva en forma de S que mide cuántos usuarios adoptan una innovación en un período determinado de tiempo y se considera sólo en relación a grupos sociales y no a individuos particulares o unidades de análisis. Se considera que la innovación se mueve lentamente a través de un grupo social en sus fases iniciales. Luego, a medida que el número de

individuos (los adoptantes) experimentan la innovación, se incrementa la difusión de la nueva idea y la tasa de adopción crece de una manera más rápida.

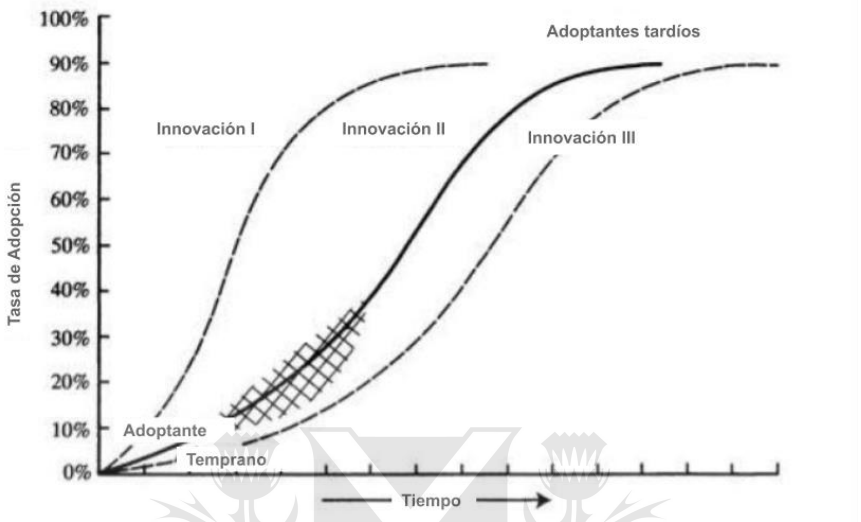

Figura 15. Tasa de Adopción de una Innovación

Esta figura representa la difusión de las innovaciones a través de una tasa de adopción. Ésta mide el tiempo requerido por cierto porcentaje de miembros de un sistema social para adoptar una innovación. Elaborado a partir de (Rogers, 2003). Copyright 2003.

Lo que ha estado ocurriendo constantemente desde fines del siglo XIX es que las tasas de adopción y difusión de tecnología en la sociedad se están acelerando. Si bien el teléfono tardó aproximadamente 50 años en alcanzar una masa crítica, la televisión tardó solo la mitad (alrededor de 22 a 25 años), los teléfonos móviles o celulares y las PC de 12 a 14 años (la mitad nuevamente), y luego Internet tardó solo siete años (la mitad de nuevo) (King, 2013).

En la siguiente figura (11) se puede observar la tasa de adopción de tecnologías en EE. UU. a partir del siglo XX donde se aprecian las curvas en S y también la aceleración de las adopciones.

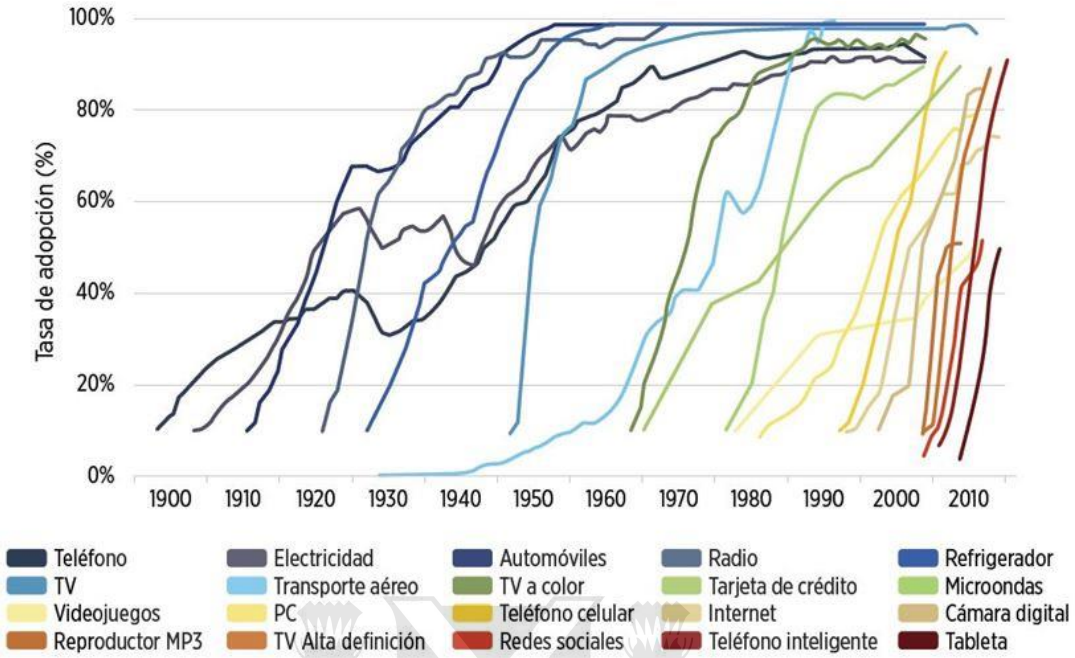

Figura 16. Adopción de Tecnologías en EE. UU. a partir del siglo XX

Esta figura representa la difusión de las principales innovaciones que se dieron en el siglo XX y XXI en EE. UU. Por un lado, muestra las curvas en S de cada innovación y por otro la aceleración de las innovaciones. Fuente: El futuro del trabajo en América Latina y el Caribe (BID, 2018). Recuperado de https://www.iadb.org/es/trabajo-y-pensiones/el-futuro-del-trabajo-en-america-latina-y-el-caribe-una-gran-oportunidad-para

A medida que las personas se acostumbran a la tecnología y la innovación, cada vez es menor el tiempo para adoptar estas tecnologías, y esto fomenta aún más la innovación y, por lo tanto, aumenta el impacto en las empresas (que tienen menos tiempo para adaptarse). Si no se introducen innovaciones en la experiencia del cliente al mismo ritmo que los clientes están adoptando estas nuevas tecnologías, las empresas se encuentran en desventaja considerable y corren el riesgo de perder a sus clientes, ya que los intermediarios más ágiles y los terceros aprovechan el beneficio de la innovación (King, 2013).

Moore (2015) también propone un modelo para comprender la aceptación de productos nuevos, el Ciclo Vital de Adopción de Tecnología. Este modelo plantea que cualquier comunidad absorbe la tecnología por etapas, que corresponden a los perfiles psicológicos y sociales de los diversos segmentos de dicha comunidad. Este proceso se puede tomar como un continuo con fases

definidas, asociadas cada una con un grupo definido, y en el que cada grupo constituye una porción predecible del conjunto.

El modelo de Moore (2015) describe la penetración en el mercado de cualquier producto tecnológico nuevo, expresada en forma de progresión del tipo de consumidores que atrae a lo largo de su vida útil. Cada grupo se distingue de los demás por su respuesta característica a una innovación discontinua basada en una tecnología nueva. Representan un perfil único: una combinación de psicología y demografía que diferencia sus respuestas de marketing respecto a las de los otros grupos. Tanto los grupos como sus distribuciones son coincidentes con la Teoría de Difusión de Rogers (2003).

Los innovadores buscan ansiosamente nuevos productos tecnológicos. La tecnología es uno de los intereses centrales de sus vidas, sea cual sea la función que realice.

Los adoptadores tempranos, al igual que los innovadores, compran el concepto de los productos nuevos en una fase muy inicial de su Ciclo Vital, pero a diferencia de los innovadores no son tecnólogos. Les cuesta poco imaginar, comprender y apreciar las ventajas de una tecnología nueva y relacionar dichas ventajas potenciales con los otros temas que les afectan. Los adoptadores tempranos prefieren confiar en su propia intuición y visión, son cruciales para abrir cualquier segmento del mercado de alta tecnología. Al ser los primeros en aplicar un cambio en su sector, los adoptantes tempranos esperan adquirir ventajas respecto a sus rivales, ya sea en forma de unos costes del producto más bajos, de una mayor rapidez de salida al mercado, de una atención al cliente más completa o de cualquier otra ventaja empresarial comparable. Al ser los primeros también están dispuestos a tolerar los inevitables defectos e imperfecciones que acompañan a cualquier innovación que acaba de salir al mercado.

La mayoría temprana comparte parcialmente con los adoptantes tempranos su capacidad para relacionarse con la tecnología, pero responden a un intenso sentido práctico. Los clientes de la mayoría temprana desean comprar una mejora de productividad para su actividad actual. Quieren una evolución, no una revolución. Quieren tecnologías que refuercen la forma establecida de hacer negocios, no que la derriben. Y por encima de todo, no quieren depurar un producto ajeno. Cuando lo adoptan, quieren que funcione correctamente y que se integre apropiadamente con la base tecnológica que ya tienen.

La mayoría tardía, también denominados conservadores, esperan hasta que las cosas se asientan como estándares, y aún entonces desean contar con mucho apoyo y por ello tienden a

comprar a empresas grandes y bien establecidas. Lo que define a los conservadores es su antipatía por las innovaciones radicales. Creen mucho más en la tradición que en el progreso. Suelen sentir cierto temor ante las nuevas tecnologías. Las empresas productoras de alta tecnología deben entender que los conservadores no esperan mucho de sus inversiones en alta tecnología y que, por ello, no nos permitirán establecer precios con un margen elevado de ganancias.

Por último, los rezagados también llamados escépticos son la gente que simplemente no quiere tener nada que ver con tecnologías nuevas, por diversos motivos. No participan en el mercado de la alta tecnología, salvo para bloquear las ventas. Así, la función primaria del marketing de alta tecnología en relación con los escépticos consiste en neutralizar su influencia.

Los mercados iniciales, el conjunto de los clientes iniciales de un nuevo producto tecnológico, se componen, ante todo, de innovadores (entusiastas) y de adelantados en la adopción de nuevas tecnologías (visionarios). Los innovadores o entusiastas son los primeros en apreciar la arquitectura del producto y en darse cuenta de los motivos por los que podrá aventajar a otras ofertas que se encuentran ya en el mercado. Los visionarios son las personas con capacidad de visión para identificar las oportunidades estratégicas implícitas en una tecnología emergente, el carácter necesario para transformarlas en un proyecto de visibilidad elevada y alto riesgo, y el carisma imprescindible para conseguir que el resto de la organización se adhiera a dicho proyecto. Son los adelantados en la adopción de productos de alta tecnología. Los visionarios son el motor que hace avanzar la industria de alta tecnología, porque son ellos quienes detectan la posibilidad de que una inversión fuera de lo común genere un salto cualitativo en la producción de ganancias y aceptan los riesgos necesarios para alcanzar dicho objetivo. Para poner en marcha un mercado inicial, se necesita una compañía con espíritu emprendedor que ofrezca un producto tecnológico revolucionario, con aplicaciones nuevas y muy atractivas; un entusiasta de las tecnologías capaz de evaluar y apreciar la superioridad de dicho producto por encima de las alternativas ya existentes; y un visionario con recursos que sepa predecir la mejora radical que se producirá como resultado de su utilización. Son los visionarios impulsan el desarrollo del mercado inicial.

Los mercados mayoritarios están dominados por los clientes iniciales de dicho mercado, conocidos en el mundo de la alta tecnología como pragmáticos. Los clientes que adoptan la tecnología en una fase posterior, o conservadores, suelen aceptarlos como líderes, mientras que los que se han quedado atrás, o escépticos, los rechazan. El objetivo de los pragmáticos radica más bien en conseguir mejoras porcentuales: un progreso gradual, mensurable y predecible. Asumirán

riesgos cuando sea preciso, pero entonces instalarán redes de protección y seguirán muy de cerca los resultados. Los pragmáticos son difíciles de conquistar, pero una vez conseguido, son fieles. Al comprar, se interesan por la compañía a la que compran, la calidad del producto que compran, la infraestructura de productos de soporte e interfaces del sistema, y la fiabilidad del servicio que obtendrán. Los pragmáticos tienden a pensar en términos «verticales». Con ello se quiere decir que prefieren comunicarse con personas que se parezcan a ellos dentro de la misma industria, mientras que los entusiastas de las tecnologías y los visionarios se comunicarán de manera «horizontal» con espíritus afines que pueden hallarse en industrias distintas. Así, es muy difícil entrar en una nueva industria por medio de ventas a los pragmáticos. Los compradores pragmáticos es que quieren ver competencia entre diversas opciones, en parte para rebajar los costes, en parte para disponer de más de una alternativa por si algo sale mal, y en parte para estar seguros de que compran a un reconocido líder de mercado. Están dispuestos a pagar un poco más por un producto de excelente calidad, o provisto de servicios especiales, pero en ausencia de características diferenciadoras elegirán la opción más barata.

Las afinidades básicas establecidas por el mercado hacen que los diferentes grupos se mantengan relativamente cercanos entre sí. Así, por ejemplo, los visionarios que adoptan la nueva tecnología en sus inicios tratan de mantenerse en contacto con los entusiastas de las tecnologías y respetan sus puntos de vista. De manera análoga, los conservadores tienen en cuenta a los pragmáticos, porque éstos pueden orientarlos en la adquisición de tecnología.

QUAERERE VERUM
Universidad de SanAndrés

La clave de la adopción: cruzar el abismo

Sobre el Ciclo Vital de Adopción de Tecnología, Moore (2015), plantea una versión revisada del mismo. En esta, se agrega al ciclo inicial una brecha entre grupos que simboliza una disociación entre ambos; es decir, la dificultad que cualquier grupo tendrá para aceptar un producto nuevo si éste le es presentado del mismo modo que al grupo situado inmediatamente a su izquierda. Cada una de estas brechas representa una oportunidad de que el marketing pierda impulso y no alcance el segmento siguiente.

Dos de las brechas del Modelo de Marketing de Alta Tecnología son relativamente menores. La primera es la que hay entre los innovadores y los adoptadores tempranos. Es una brecha que se produce cuando un producto tecnológico no se puede traducir fácilmente en una ventaja nueva y sustancial. La segunda, situada entre la mayoría temprana y la mayoría tardía,

donde el mercado ya está bien desarrollado y el producto tecnológico ha sido absorbido por las tendencias mayoritarias, la transición de la mayoría temprana a la tardía tiene que ver más con la exigencia residual de competencia tecnológica por parte del usuario final. Cuando un producto alcanza este punto de desarrollo de su mercado, hay que hacer que sea cada vez más fácil adoptarlo para seguir teniendo éxito. De no ser así, la transición hacia la mayoría tardía se atascará.

Pero lo realmente importante de identificar es el abismo profundo y divisor que separa a los adoptadores tempranos de la mayoría temprana, o sea es el principal bache se encuentra en la transición entre los visionarios y los pragmáticos.

Esto se puede visualizar en la figura 17, a continuación.

Figura 17. Ciclo Vital de Adopción de Tecnología Revisado

Esta figura muestra el Ciclo Vital de Adopción de Tecnología de Moore (2015) donde se pueden visualizar las brechas entre los grupos psicográficos y la brecha principal entre los adoptadores tempranos y la mayoría temprana denominada abismo. Copyright 2015.

Hay cuatro características fundamentales de los visionarios que alejan a los pragmáticos: (i) los visionarios carecen de todo respeto por el valor de las experiencias de sus colegas. Son los primeros en el correspondiente segmento de la industria que perciben el potencial de las nuevas tecnologías, tienen capacidad para reconocer oportunidades que podrían aprovechar para mejorar su propia competitividad. Sólo lo conseguirán si nadie más las ha visto. Los pragmáticos, en cambio, valoran muchísimo la experiencia de sus colegas en otras empresas. Cuando compran,

buscan un gran número de referencias, y quieren que provengan en su mayor parte de su propio segmento dentro de la industria. Esta actitud provoca un círculo vicioso: como por lo general tan sólo hay uno o dos visionarios en cada uno de los segmentos de la industria, los visionarios sienten mayor interés por la tecnología que por su propia industria. Los visionarios definen el futuro. Los pragmáticos, por otra parte, no prestan mucha atención al futuro. Se ven a sí mismos en los términos del presente, como personas dedicadas a garantizar que las ruedas de la industria no dejen de girar. Son incapaces de reconocer la importancia de la infraestructura de productos ya existente.

Para cruzar el abismo Moore (2015) propone la entrada en un nicho de mercado muy específico en el que se puede ocupar una posición dominante desde el principio, expulsar a los competidores y adquirir una base para operaciones más amplias, concentrar una gran fuerza en un objetivo muy bien definido. Lo que permite a la empresa naciente ganarse clientes pragmáticos antes de obtener el acceso a mercados más amplios, es la concentración de recursos en un nicho de mercado bien delimitado. Esta propuesta tiene la cualidad de poner en marcha a toda una empresa y concentrarla en un objetivo muy específico que (i) se puede alcanzar de manera inmediata; y (ii) se puede aprovechar también de manera inmediata para obtener el éxito a largo plazo. La mayoría de las empresas no logran cruzar el abismo, porque tienen que enfrentarse a la variedad de posibilidades que les ofrece el mercado mayoritario y no se fijan un objetivo específico, sino que van detrás de todas las oportunidades que se les presentan.

El único objetivo de la empresa durante esta etapa de desarrollo en el mercado es crearse una clientela de compradores pragmáticos que sirvan como referencia y que permitan, a su vez, acceder a otros sectores del mercado mayoritario. Con el fin de capturar esa base de referencia, se tiene que estar seguros de que el grupo inicial de clientes vea totalmente satisfechas las expectativas que se había creado en el momento de comprar. Se debe garantizar que el cliente no adquiera tan sólo el producto, sino también lo que se denomina producto completo: es decir todo el repertorio de productos y servicios necesarios para que el cliente alcance el resultado que deseaba, es decir, todo lo que se ke ha prometido en el momento de la compra.

Existe una tercera razón indiscutible, para centrarse en un solo nicho en el momento de cruzar el abismo: la necesidad de alcanzar el liderazgo en el mercado. Los clientes pragmáticos quieren comprar a los líderes del mercado. El motivo es bien sencillo: los productos completos se desarrollan en torno a los productos que lideran el mercado, y no en torno a los demás. Por todos estos motivos, aprovechamiento del producto completo, efectividad del boca a boca y percepción

de liderazgo en el mercado, es crucial que en el momento de cruzar el abismo la organización se concentre exclusivamente en alcanzar una posición de dominio en uno o dos segmentos de mercado muy bien delimitados. Si la organización no se compromete plenamente con dicho objetivo, las probabilidades de que llegue a entrar en el mercado mayoritario serán mínimas.

La clave para dejar atrás el nicho que se había elegido inicialmente como objetivo se halla en la selección inicial de segmentos de mercado con valor estratégico. Es decir: hay que seleccionar un segmento que, en virtud de sus conexiones, nos sirva como punto de entrada en uno o más segmentos adyacentes.

Entonces, el principio fundamental que se debe aplicar cuando se cruza el abismo es el siguiente: se debe seleccionar un segmento específico de mercado como punto de ataque y emplear todos los recursos para alcanzar cuanto antes la posición de liderazgo en dicho segmento.

Proceso de adopción

Para Rogers (2003), la adopción de una innovación es un proceso mediante el cual el individuo (o una unidad de adopción) pasa de tener un primer conocimiento sobre la innovación, hasta su adopción o rechazo. Es un proceso de distintas etapas que es influenciado por antecedentes propios del entorno en el que se va a implementar la innovación tales como la identidad del actor o la percepción de la situación y produce un resultado, que, a manera de resumen, se manifiesta en la decisión de adoptar o rechazar una innovación. Este proceso se da en cinco etapas que se muestran en la figura 18.

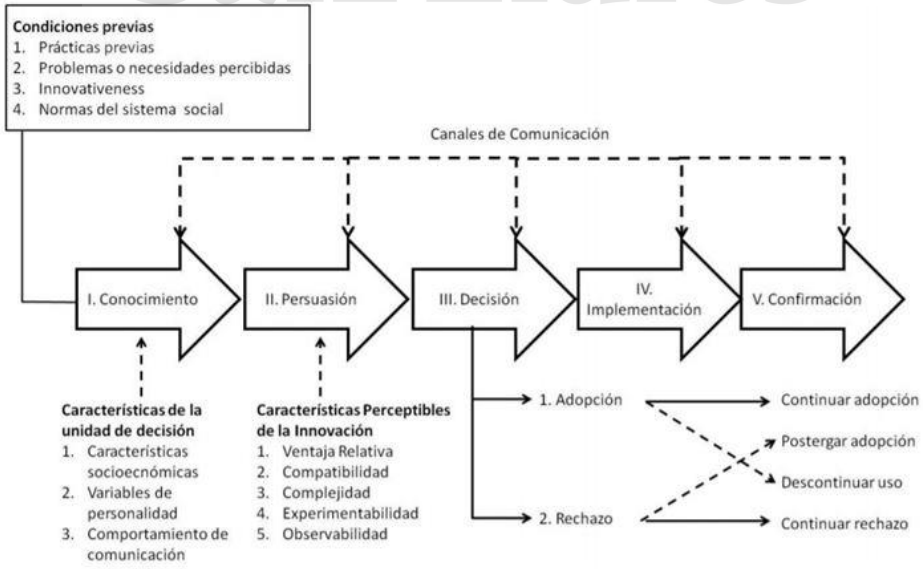

Figura 18. Proceso de Decisión de Innovaciones

Esta figura muestra las cinco etapas del proceso de desarrollo de una innovación planteada por Rogers (2003). Copyright 2003.

La primera de ella, el «Conocimiento», es la etapa en que el adoptador potencial conoce y entiende la innovación, el objetivo de esta etapa es la búsqueda de información por parte de la unidad de decisión, la cual, busca disminuir el nivel de incertidumbre asociado a la aparición de una innovación. Luego viene la etapa de "Persuasión", en la que se desarrolla una actitud (positiva o negativa) hacia la innovación y se dan argumentos a favor y en contra de esta. En tercera instancia se encuentra la etapa de "Decisión" que es la etapa en la que se acuerda la aceptación de la innovación como una buena idea (o se rechaza definitivamente y no se pasa a la siguiente etapa). Luego la etapa de "Implementación", en la que se pone a prueba la innovación. Y por último la etapa de "Confirmación" que es la etapa de refuerzo de una decisión de adopción favorable. Luego de esta etapa la innovación pasa a formar parte de la rutina de quien la adopta.

Con respecto a procesos de adopción, Moore (2015) define el Modelo de Marketing de Alta Tecnología para desarrollar un mercado de alta tecnología. En este modelo se debe trabajar la curva del Ciclo Vital de Adopción de Tecnología, descripta más arriba, de izquierda a derecha: dedicarse primero a los innovadores y cultivar ese segmento del mercado; pasar a continuación a los adoptadores tempranos y cultivar ese segmento del mercado; y así sucesivamente con la mayoría temprana, la mayoría tardía y hasta los rezagados. Es importante mantener el impulso para crear un efecto de tendencia que favorezca de modo natural la adopción por parte del grupo siguiente.

Los Canales de Comunicación

Los canales de comunicación son los medios por los cuales los mensajes llegan de un individuo a otro. La teoría de la difusión de Rogers (2003) considera la comunicación como un proceso que se da a través de las redes sociales o canales interpersonales y por los medios de difusión. Los líderes de la comunidad son aliados importantes en la comunicación de nuevas prácticas o ideas. Cuando se reiteran la información sobre la innovación a través de los medios de comunicación masiva, aumentan las posibilidades de que se adopte la innovación. Para que ocurra la difusión de innovaciones se requiere que los individuos tengan similitudes en ciertos atributos, tales como educación, creencias, estado socioeconómico, lenguaje, códigos culturales, etc. y esto

ocurre generalmente cuando estos individuos pertenecen al mismo grupo o tienen intereses similares. En estos casos, la comunicación ocurre con mayor facilidad y las nuevas ideas tienden a tener un efecto mayor en términos de adquisición de conocimientos, formación de actitudes y cambio. Uno de los problemas más importantes de la difusión de innovaciones es que los participantes (o usuarios potenciales) por naturaleza poseen atributos diferentes. La naturaleza de la difusión requiere, por ende, que exista de ambas características ya que debe existir intercambio de información con respecto a la innovación, lo que da que se tenga atributos diferentes, pero también cierto nivel de atributos comunes que faciliten la comunicación.

Para Moore (2015) una de las claves de la entrada en un nuevo mercado es el establecimiento de una buena reputación entre los compradores por medio del boca a boca. Para que el boca a boca funcione en un determinado mercado, se necesita una masa crítica de individuos bien informados que se reúnan cada cierto tiempo, intercambien puntos de vista y refuercen el posicionamiento del producto o de la empresa. Alimentar dicho proceso de comunicación es caro, sobre todo cuando se abandona el primer mercado, al que en general se podía llegar mediante la prensa especializada y medios afines. En cambio, los compradores pragmáticos, como se identificó en su descripción, se comunican en el ámbito de la industria y de las asociaciones profesionales.

En el momento de cruzar el abismo, las empresas deben tener como objetivo número uno asegurarse un canal de distribución que les permita acceder al mercado mayoritario, debe ser un canal donde el cliente pragmático se sienta a gusto. Este objetivo debe anteponerse a las ganancias, a los beneficios, a la prensa e incluso a la satisfacción del cliente. El objetivo primario es asegurarse el acceso a un canal de distribución orientado al cliente. Éste es el canal que se entiende van a esperar los compradores pragmáticos, el canal en el que querrán comprar el producto. Por otro lado, el tipo de canal que se seleccione para proveer el mercado a largo plazo dependerá del nivel de precios del producto. Pero si no se trata de ventas directas, entonces, durante el período de transición que tiene lugar mientras se cruza el abismo, quizá se tenga que adoptar un canal suplementario, o incluso alternativo, orientado a la creación de demanda, para estimular una aceptación temprana en el mercado mayoritario. Hay que tener en cuenta que, en el mercado mayoritario, el precio comunica un mensaje. Dicho mensaje puede lograr que el producto sea más fácil de vender. Como el único mensaje aceptable es el que comunica liderazgo en el mercado, se debe que transmitirlo también mediante el precio. Así pues, los precios se decidirán de acuerdo con los de productos comparables que se encuentren en el repertorio de competidores identificados.

Finalmente, se debe recordar que los márgenes son la compensación que se cobra el canal de distribución. Como la empresa que intenta cruzar el abismo crea presión sobre dicho canal, y a menudo se trata de sacar partido de los recursos que el canal ha adquirido mediante sus relaciones con los clientes pragmáticos, se tendrá que pagar un margen de excepcional cuantía al canal de distribución durante ese período.

Posicionamiento Competitivo

Uno de los conceptos de marketing más útiles entre todos los que se emplean en altas tecnologías es el de Producto Completo (Moore, 2015). Hay un foso que separa la promesa que se le hace al cliente y la capacidad del producto distribuido para cumplir dicha promesa. Sólo se puede salvar ese foso si el producto viene acompañado de una variedad de servicios y de productos secundarios que se complementarán con éste para formar lo que se llama el Producto Completo. Si se relaciona el Ciclo Vital de Adopción de Tecnologías y el producto completo, los clientes que menos necesitan del producto completo son los entusiastas de la tecnología. Están acostumbrados a ensamblar partes de sistemas diversos y a construirse por sí mismos un producto completo que les agrade. En cambio, los visionarios no tienen ningún interés en componer productos propios, pero lo hacen igualmente si con ello pueden ser los primeros que dispongan del nuevo servicio dentro de su respectiva industria y así ganan una ventaja estratégica sobre sus competidores. Para pasar a la derecha del abismo, para entrar en el mercado mayoritario, como ya se definió anteriormente, se tiene que satisfacer las demandas de los clientes pragmáticos. Dichos clientes quieren que el producto completo esté disponible desde el principio. Los pragmáticos evalúan y compran productos completos. La diferencia más importante entre los mercados iniciales y los que forman parte del mercado mayoritario es que los primeros están dispuestos a asumir la responsabilidad por la elaboración del producto completo (a cambio de un salto cualitativo en competitividad), mientras que los segundos no.

A medida que avanza el Ciclo Vital de Adopción de Tecnologías, la naturaleza de la competición se transforma de manera espectacular. Estos cambios son tan radicales que en más de una de las fases del ciclo se puede decir, literalmente, que no se tiene competidores. Se debe tener en cuenta que los pragmáticos son reacios a comprar sin comparar. Así pues, la existencia de competidores es un requisito de compra fundamental para ellos. Cuando se abandona el mercado

inicial, en el que no suele haber competencia, con el objetivo de penetrar en el mercado mayoritario, muchas veces los entrantes tienen que crear sus propios competidores.

El marketing de altas tecnologías comprende cuatro ámbitos: tecnología, producto, mercado y empresa. El ámbito más valioso para el cliente no es el mismo en todos los estadios del Ciclo Vital de Adopción de Tecnologías. En el mercado inicial, en el que los entusiastas de las tecnologías y los visionarios controlan las decisiones, los ámbitos clave son la tecnología y el producto. En el mercado mayoritario, en el que los pragmáticos y conservadores controlan las decisiones, los ámbitos clave son el mercado y la empresa. En este contexto, cruzar el abismo representa una transición entre una valoración basada en el producto a otra basada en el mercado. La Brújula de Posicionamiento Competitivo, figura 19, ilustra esta dinámica:

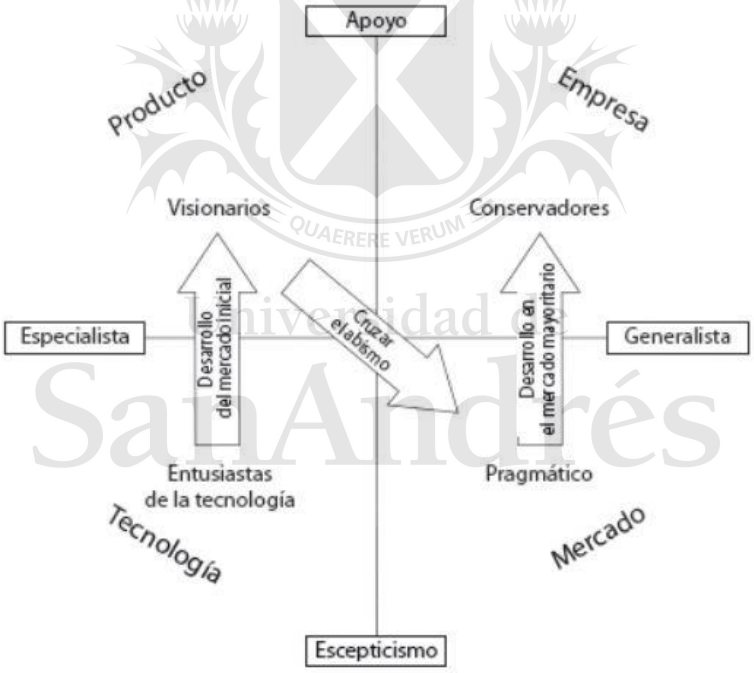

Figura 19. La Brújula del Posicionamiento Competitivo

Esta figura muestra la mecánica para cruzar el abismo donde es necesaria una transición entre una valoración basada en el producto a otra basada en el mercado (Moore, 2015). Copyright 2015.

Si se quiere ganar el cuadrante inferior derecho, los pragmáticos escépticos, todos los diálogos a propósito de un grupo de competidores emergente tendrá que referirse a cuestiones de mercado. Eso es lo que interesa a los pragmáticos. El trabajo de marketing dejará de centrarse en atributos de valor característicos del producto y girará en torno a los que son característicos del mercado, por ejemplo, tener el más completo de los productos, experiencia de usuario sólida, compatibilidad con los estándares, precio del producto completo, valor situacional e idoneidad para un propósito determinado, entre otros.

QUAERERE VERUM
Universidad de
SanAndrés

Anexo VI. Tecnologías de Avanzada y su convergencia. La IA en el centro de la interrelación

La digitalización se refiere a las transformaciones provocadas por la adopción masiva de las tecnologías digitales que generan, procesan, comparten y transfieren información. A diferencia de otras innovaciones impulsadas por una única innovación, la digitalización se basa en la evolución de múltiples tecnologías (Katz, 2017). Entre los pilares tecnológicos de la denominada Industria 4.0 se destacan: sistemas ciber-físicos de integración; máquinas y sistemas autónomos (robots); internet de las cosas (IoT); manufactura aditiva (impresión 3D); big data y análisis de macro datos; computación en la nube; simulación de entornos virtuales; inteligencia artificial; ciberseguridad y realidad aumentada. La transformación más profunda se produce por la digitalización y la posibilidad de conectar en tiempo real a todos los actores sociales mediante Internet. La conectividad alcanza a consumidores, empresas, gobierno, organizaciones de la sociedad civil, y es posible mediante dispositivos (*smartphones*, computadoras, sensores, *wearables*, entre otros), sistemas informáticos y plataformas digitales (*e-commerce*, *e-government*, redes sociales). Para tener una noción de este impacto se puede analizar el número de personas con acceso a Internet, que ronda los 4.156 millones en todo el mundo, esto es, alrededor del 54% de la población mundial. Y en Latinoamérica, la penetración media es 13 puntos superior a la global, de un 67%, y el número de personas que son usuarios de la Red asciende a casi 440 millones.

Universidad de SanAndrés

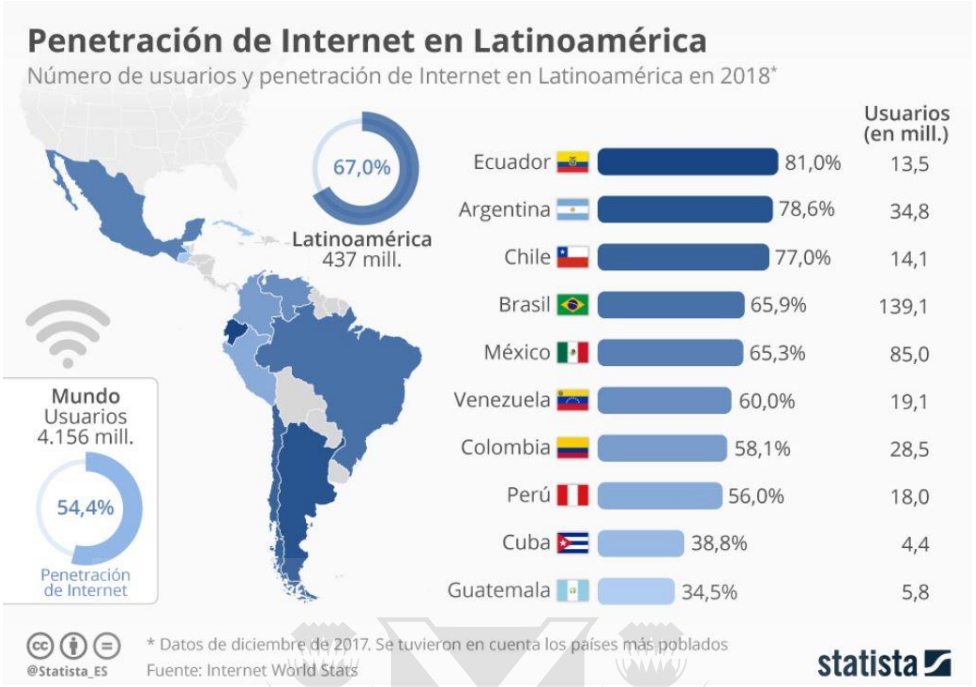

Figura 20. Penetración de Internet en Latinoamérica

Esta figura muestra varios datos relacionados a la penetración de Internet comparando por un lado los países de Latinoamérica, porcentaje total de Latinoamérica y porcentaje total mundial. Los datos son a diciembre de 2017. El porcentaje de la penetración de Internet en Latinoamérica es superior al porcentaje global, 12,6%. Estadística obtenida de Statista cuya fuente fue Internet World Stats. Recuperado de *https://es.statista.com/grafico/13903/cuantos-usuarios-de-internet-hay-en-america-latina/*

En la actualidad, uno de los actores primordiales indiscutibles son las Redes Sociales. Lo que convierte a éstas en un canal para los negocios es la cantidad de usuarios que tiene cada una de ellas. Según el estudio Digital 2019 Global Digital Overview v01 realizado por las empresas *Hootsuite y We are Social* (2019) se demuestra la constante creciente de usuarios de redes sociales como se puede ver en la figura 21 a continuación.

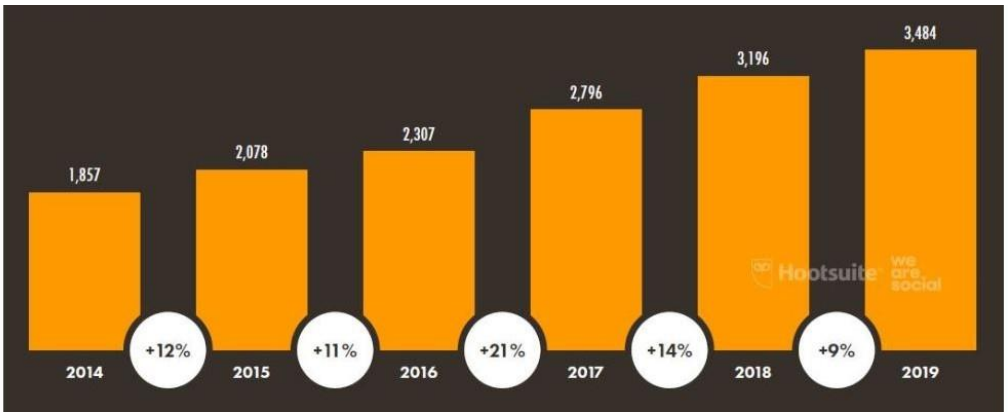

Figura 21. Evolución de Usuarios de Redes Sociales

En la figura se muestra la evolución de la cantidad de usuarios de redes sociales desde el año 2014 al 2019, el gráfico mide en millones y el porcentaje que se suma año a año. Datos tomados a enero de 2019. Recuperado de: Digital 2019 Global Digital Overview v01 (2019) realizado por las empresas We are Social y Hootsuite. Copyright 2019.

En este mismo reporte, con respecto a las redes sociales en América Latina, hay 4 países: Brasil, México, Argentina y Colombia, incluidos en el listado de los 19 países con mayor cantidad de usuarios del mundo.

Otro factor determinante de esta época es que la conectividad alcanza también a los objetos permitiendo la conexión en varios sentidos: máquina-máquina (M2M), máquina-producto, máquina-humano, producto-humano. Así, se conectan las máquinas y las unidades productivas dentro de una misma empresa, e incluso, dentro de las cadenas de valor (proveedores, operarios, áreas comerciales, sistemas logísticos, consumidores, entre otros). Si bien muchas de las tecnologías que hoy convergen, ya existían, aunque de forma embrionaria y sin la robustez que hoy aportan, la diferencia con respecto al pasado se basa en la forma en que se combinan para generar disrupciones significativas (Basco et al., 2018). Desde hace unos años se están implementando gran cantidad de estas iniciativas, que se fundamentan en la combinación de elementos novedosos provenientes de la tecnología digital, para la transformación tanto de los procesos como de los sistemas utilizados por las empresas. Este conjunto de cambios no es únicamente una continuación y sofisticación de los actuales sistemas de producción, sino que supone un nuevo paradigma, Klaus Schwab (2016) lo llama la Cuarta Revolución Industrial. Este paradigma se basa en cambios radicales en la producción, ligados a la velocidad de implantación, que no tiene precedentes históricos, y en el alcance de la transformación, que afecta a un conjunto

elevado de elementos de la cadena de valor. La Cuarta Revolución Industrial, que ya está entre nosotros, se asocia con la informatización y digitalización de la producción, y con la generación, integración y análisis de una gran cantidad de datos a lo largo del proceso productivo y del ciclo de vida de los productos, facilitados fundamentalmente por Internet (Basco et al., 2018)

Según Katz (2017) de la misma manera que otras revoluciones tecnológicas como la máquina de vapor, el telégrafo y el automóvil, la digitalización evoluciona en término de "olas". La primera ola estaba asociada con la introducción y adopción de tecnologías denominadas maduras, como lo son los sistemas informáticos de gestión, el procesamiento automático de datos aplicados al monitoreo de negocios, y las tecnologías de telecomunicaciones que permiten el acceso remoto a información. La segunda ola de digitalización involucró la difusión de Internet y sus correspondientes plataformas (buscadores, *marketplaces*, entre otros) que permiten la vinculación entre consumidores y empresas y entre empresas entre sí para la compra de insumos y la distribución de la producción. Además de la adopción de Internet, esta ola condujo a la difusión de la computación en la nube (*Cloud Computing*). Finalmente, la tercera ola incluye la difusión de tecnologías enfocadas en el mejoramiento de la toma de decisiones gerenciales, así como la automatización de operaciones rutinarias llevadas adelante en la producción de bienes y servicios (Katz, 2017).

Cada una de las olas ejerció y ejerce un impacto creciente en los procesos productivos. La primera ola permitió la automatización de funciones discretas como el manejo de inventarios y la gestión de líneas de producción. Al mismo tiempo, el desarrollo de la banda ancha facilitó la descentralización de funciones, permitiendo la optimización en el acceso a factores de producción. A partir de ello, la empresa puede localizar funciones productivas en aquellas regiones donde se pueda acceder de mejor manera a recursos como materias primas y fuerza laboral, al tiempo que continúa manteniendo, de manera virtual, una estructura centralizada.

La segunda ola (basado en la introducción de Internet) permitió comenzar a reconfigurar procesos productivos de punta a punta. Las plataformas basadas en Internet optimizaron los costos de acceso a materias primas en la medida de que estas reducían los costos de búsqueda de bienes y servicios al mejor precio. Al mismo tiempo, Internet permitió desplegar canales de distribución electrónicos para llegar al consumidor, creciendo, de esta manera, el alcance y cobertura de los mercados.

Finalmente, la tercera ola, conformada por el conjunto de tecnologías llamadas de avanzada, permiten encarar una refundación de empresas tradicionales a partir de la generación de nuevos modelos de negocio, la virtualización de estadios de la cadena de valor, y una redefinición de las fronteras de eficiencia del negocio (Katz, 2018). Esta ola implica mayor incorporación de las tecnologías avanzadas en la producción. Schwab (2016) plantea tres características que diferencian la actual revolución industrial de las anteriores: i) la velocidad de los cambios, ii) el alcance de los cambios, basado en la combinación de múltiples tecnologías, y iii) el impacto sistémico de la transformación a nivel de las empresas, las industrias y la sociedad.

Los modelos de manufactura están evolucionando, desde procesos de automatización especializada a nivel de fábrica y una robotización aislada y estandarizada, hacia otra con procesos más complejos y autónomos, que abarcan toda la cadena de valor de los productos, con una robotización colaborativa y con nuevos protocolos de interacción entre personas y máquinas, y entre máquinas y máquinas (CEPAL, 2017) como lo mencionado en párrafos anteriores. La transformación digital permite la automatización de las operaciones comerciales, produciendo eficiencias operativas, como la reducción de costos de transacción, con un impacto en la productividad. Del mismo modo, la transformación digital ofrece nuevas oportunidades de negocio, impactando el empleo y el espíritu empresarial (Katz, 2017). Muchos referentes argumentan de diversas maneras que las nuevas tecnologías digitales van a aumentar la productividad, por ejemplo, Brynjolfsson y McAfee (2013). En cambio, hay algunos que son más pesimistas y afirman que la innovación será más lenta debido a que el costo de la innovación se eleva a medida que avanza la tecnología.

También la OECD (2016) expresa que las nuevas tecnologías de producción afectarán la productividad a través de muchos y variados mecanismos. Esta organización, del mismo modo que los autores que se vienen estudiando, identifica a la confluencia de diferentes tecnologías como lo que está impulsando la transformación digital de la producción industrial. Según esta organización hay dos tendencias que hacen que las tecnologías digitales sean transformacionales para la producción: (i) la caída de los costos, lo que ha permitido una mayor difusión; y lo más importante, (ii) la combinación de diferentes TIC, y su convergencia con otras tecnologías. De una manera muy conceptual, la figura 17 representa las TIC clave que están permitiendo la transformación digital de los procesos industriales y se puede visualizar la inteligencia Artificial en el centro de la figura relacionándose con las diferentes tecnologías.

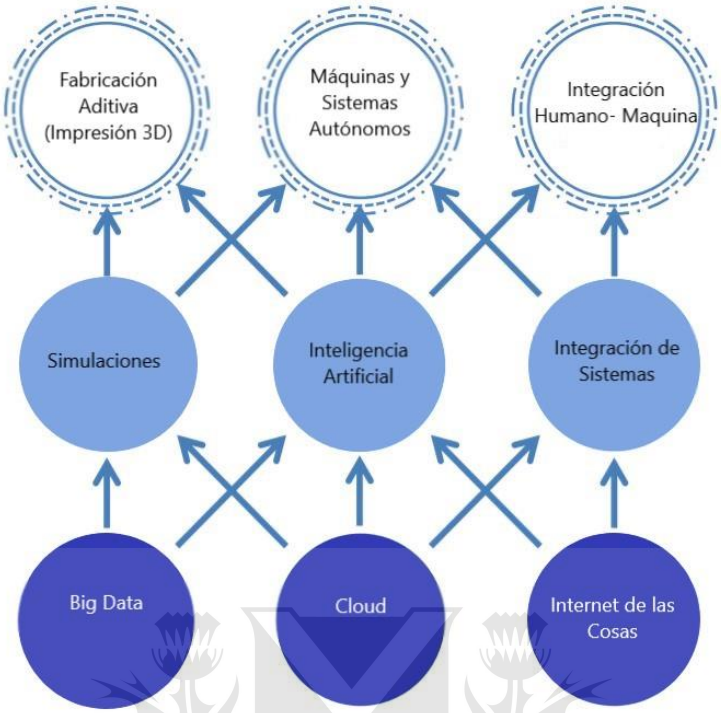

Figura 22. Convergencia de tecnologías que permite la transformación digital

Esta figura muestra a la Inteligencia Artificial en el centro de la convergencia. Obtenido del informe de la OECD (2016), "Enabling the next production revolution: the future of manufacturing and services-interim report: Meeting of the OECD Council at Ministerial Level Paris". Traducción Propia.

La interrelación de las nuevas tecnologías, propia de la Industria 4.0, facilita su rápida difusión, evolucionando a una tasa exponencial en comparación con una más de tipo lineal que caracterizó a las olas tecnológicas previas (Schwab, 2016). En el estudio de Frost & Sullivan (2016) sobre el futuro de las finanzas, se hace hincapié en la conectividad y la convergencia como factor fundamental para la transformación de la industria financiera. Entre las tecnologías mencionadas se encuentran el *Machine Learning*, el *Big Data*, los nuevos modelos de negocio digitales e Internet de las Cosas.

Anexo VII. Definiciones de IA

Tabla 8. Definiciones de Inteligencia Artificicial.

Autor	*Año*	*Definición*
Bellman	1978	[La automatización de] actividades que vinculamos con procesos de pensamiento humano, actividades tales como toma de decisiones, resolución de problemas, aprendizaje...
Haugeland	1985	La interesante tarea de lograr que las computadoras piensen...máquinas con mente, en su amplio sentido literal.
Charniak y McDermott	1985	El estudio de las facultades mentales mediante el uso de modelos computacionales.
Minsky	1986	IA es el arte de construir máquinas capaces de hacer cosas que requieran inteligencia en caso de que fuesen hechas por los seres humanos.
Amat	1989	La parte de la informática que trata de los sistemas computarizados inteligentes, es decir, sistemas que muestran las características que pueden asociarse a la inteligencia en lo que se refiere al comportamiento humano: compresión de lenguaje, aprendizaje, resolución de problemas, etc.
Kurzweil, Richter & Schneider	1990	El arte de crear máquinas con capacidad de realizar funciones que realizadas por personas requieren de inteligencia.
Shapiro	1992	Es un campo de la ciencia y de la ingeniería que se ocupa de la comprensión a través de la computadora de lo que comúnmente llamamos comportamiento inteligente y de la creación de herramientas que exhiben tal comportamiento.
Winston	1992	El estudio de los cálculos que permiten percibir, razonar y actuar.
Luger y Stubblefield	1993	La rama de la ciencia de la computación que se ocupa de la automatización de la conducta inteligente.
Rich y Knight	1994	La IA estudia cómo lograr que las máquinas realicen tareas, que, por el momento son realizadas mejor por seres humanos.

Delgado	1998	Es el campo de estudio que se enfoca en la explicación y emulación de la conducta inteligente en función de procesos computacionales basados en la experiencia y el conocimiento continuo del ambiente

Elaboración Propia

Universidad de SanAndrés

Anexo VIII. Resumen de la Historia de la IA

La Historia de la IA es extensa. El concepto tiene aproximadamente 70 años, y luego de tanto tiempo, es importante entender porque en su momento no tuvo alto impacto y ahora es una tecnología que puede traer grandes oportunidades.

En esta parte del trabajo se trata de realizar un resumen de los principales hitos para comprender los inicios de la IA, porqué se transitó un "invierno" y el resurgimiento de este campo en los últimos años.

En los orígenes de la IA se encuentran diferentes puntos de vista. Algunos autores vinculan el surgimiento de la IA con el origen de las computadoras principalmente en la segunda mitad del siglo XX. Russell y Norvig (1996), dividen la historia de la disciplina en una serie de fases que hacen bastante comprensible la evolución de ésta. Se tomarán los principales hitos mencionados por ellos y se complementará con otros autores.

Génesis (1943-1956): Se puede decir que esta fase comienza con los primeros trabajos de McCulloch y Pitts (1943), neuro fisiólogo y matemático respectivamente, quienes idearon un modelo de red neuronal artificial. Pero fue Alan Turing (que además de contribuir significativamente al esfuerzo bélico británico durante la Segunda Guerra Mundial trabajando en descifrar con sus conocimientos matemáticos los códigos secretos del Reich, está considerado como uno de los padres de la computación y de los ordenadores de hoy) quien articuló primero una visión de la IA en su artículo Computing Machinery and Intelligence, en 1950. Allí, introdujo la Prueba de Turing, el aprendizaje automático, los algoritmos genéricos y el aprendizaje por refuerzo. Esta prueba evaluaba la capacidad de una máquina de actuar de forma similar a una persona. Básicamente, y con una gran simplificación, planteaba una situación en la que dos interlocutores mantenían una conversación y un juez tenía que determinar cuál de ellos era humano y cuál un ordenador. La inteligencia artificial debía conseguir pasar la prueba como si fuese un humano.

En la actualidad, se puede decir que programar un computador para que supere la prueba de Turing requiere un trabajo considerable ya que debe poseer las siguientes capacidades: procesamiento de lenguaje natural que le permita comunicarse satisfactoriamente en inglés; representación del conocimiento para almacenar lo que se conoce o siente, razonamiento automático para utilizar la información almacenada para responder a preguntas y extraer nuevas conclusiones, aprendizaje automático para adaptarse a nuevas circunstancias y para detectar y extrapolar patrones.

La Prueba de Turing evitó deliberadamente la interacción física directa entre el evaluador y el computador, dado que para medir la inteligencia es innecesario simular físicamente a una persona. Sin embargo, la llamada Prueba Global de Turing incluye una señal de video que permite al evaluador valorar la capacidad de percepción del evaluado, y también le da la oportunidad al evaluador de pasar objetos físicos. Para superar la Prueba Global de Turing el computador debe estar dotado de visión computacional para percibir objetos y robótica para manipular y mover objetos. Estas seis disciplinas abarcan la mayor parte de lo que se conoce por IA (Russell & Norvig, 1995).

Según la AAAI (Association for The Advancement of Artificial Intelligence), la historia moderna de la IA comienza en el año de 1956 con la conferencia de Dartmouth College de New Hampshire (EE.UU.) que tuvo lugar en el verano de 1956 en la cual se reunieron los principales científicos involucrados con el tema, como: J. McCarthy del Dartmouth College, M. L. Minsky de la Universidad de Harvard, N. Rochester de la Corporación IBM, y C. E. Shannon de los Laboratorios Bell Telephone. En este encuentro científico sobre informática John McCarthy definió a la IA como "La Ciencia e ingeniería de hacer máquinas inteligentes" (Brynjolfsson & McAfee, 2017).

Según Brynjolfsson y McAfee (2017) al principio, la comunidad de AI se dividió en dos campos. Uno perseguía la llamada inteligencia artificial "simbólica", basada en reglas, mientras que la otra construía sistemas de reconocimiento de patrones estadísticos. El primero intentó generar IA de la misma manera que un adulto intenta aprender una segunda lengua; el segundo trató de hacer que sucediera de la misma manera que los niños aprenden su primer idioma. Knight (2017a) en cambio plantea que el foco de las escuelas de pensamiento era en qué tan comprensible o explicable debería ser la IA. Muchos pensaron que tenía más sentido construir máquinas que razonaran de acuerdo con las reglas y la lógica, haciendo que su funcionamiento interno fuera transparente para cualquiera que se interesara en examinar algún código. Otros sintieron que la inteligencia surgiría más fácilmente si las máquinas se inspiraran en la biología y aprendieran observando y experimentando. Según Brynjolfsson & McAfee estos últimos investigadores han creado el campo del "aprendizaje automático".

Entusiasmo inicial, grandes esperanzas (1952-1969). En esta fase los detractores de la disciplina fueron planteando retos que se fueron superando uno tras otro, de ahí que otros autores la denominen la fase del "Mira mamá ahora sin manos". De esta época se destacan el Solucionador

General de Problema (SGP) de 1957 del que fueron responsables Newell y Simon, que se diseñó para que imitara protocolos de razonamiento humanos.

Entre 1952 y 1962 Arthur Samuel desarrolló el primer programa para juegos de damas, que logró obtener suficiente pericia como para desafiar al campeón mundial, sus programas con aprendizaje de máquina fueron responsables del incremento en el rendimiento de los jugadores de damas. También florecieron actividades enfocadas a las redes neuronales, Taylor (1956) inicia el estudio sobre las memorias asociativas, Rosenblatt (1958), un científico del Laboratorio Aeronáutico de Cornell introduce el Perceptrón para el reconocimiento de patrones, capaz de generalizar. Este proyecto estaba financiado por la Armada de los Estados Unidos. El objetivo con el Perceptron, era poder clasificar las cosas que veía: perros contra gatos, por ejemplo. Con este fin, se configuró un poco como una pequeña versión de un cerebro. El Perceptron fue construido solo para hacer clasificaciones de imágenes simples. Tenía 400 fotocélulas de detección de luz conectadas al azar (para estimular el desorden del cerebro) a una sola capa de neuronas artificiales. Una demostración temprana de esta "red neuronal", junto con las confiables predicciones de Rosenblatt (1958), llevó al New York Times a escribir en 1958 que era "el embrión de una computadora electrónica que [la Marina] espera que pueda caminar, hablar, ver" (Brynjolfsson & McAfee, 2017).

En 1958 John McCarthy inventó el lenguaje de programación LISP, concebido para inteligencia artificial y con un enfoque diferente al que ahora se conoce.

En 1960 Widrow y Hoff formulan una variante del Perceptrón, la ADALINE (AD Aptative LINear Elements), que fue la primera red neuronal aplicada a un problema real (filtros adaptativos para evitar ecos en las líneas telefónicas), comercializada durante muchos años, así como su extensión MADALINE (Widrow, 1960).

En 1961, James Slagle escribió en LISP el primer programa de integración simbólica llamado SAINT, que resolvía problemas de cálculo.

En 1962, fue fundada Unimation la primera compañía para desarrollo de robots industriales.

En 1963, Edward A. Fiegenbaum y Julian Feldman publican el libro "Computers and Thought" (Computadoras y Pensamiento), la primera colección de artículos sobre IA que mostraba el trabajo de los científicos responsables de haberla definido y de sentar las bases para su desarrollo.

En 1965 J. A. Robinson inventó un procedimiento mecánico de prueba: el método de resolución, que permitía a los programas trabajar eficientemente con lógica formal como representación del lenguaje. En ese mismo año Joseph Weizenbaum construyó ELIZA un programa interactivo que

conduce un diálogo de cualquier tema en inglés. Fue muy popular en arpa net cuando fue programada una versión que simulaba el dialogo con un psicoterapeuta.

En 1966 se desarrolló el primer "Machine Intelligence Workshop" (Taller sobre Máquinas Inteligentes) en Edinburgh organizado por Donald Michie, consolidándose como el primer taller sobre IA a nivel internacional. Estos talleres todavía se realizan anualmente.

En 1969, Edward Feigenbaum, Joshua Lederberg y Bruce Buchanan de la Universidad de Stanford desarrollaron el programa DENDRAL para interpretar espectros de masa orgánicos en compuestos químicos, este fue considerado el primer sistema basado en conocimiento para razonamiento científico que fue exitoso. En ese mismo año, Joel Moses demostró el poder del razonamiento simbólico para integración de problemas con el programa MACSYMA, el primer sistema basado en conocimiento para matemáticas que tuvo gran aceptación.

Una dosis de realidad (1966-1974): Propiciadas por los éxitos obtenidos en la etapa anterior, se hicieron previsiones excesivamente optimistas, como más tarde se demostró. Los avances no eran los esperados, los escollos que se encontraron fueron principalmente dos, en primer lugar, se pensó que la extensión de las técnicas que demostraron funcionar con ejemplos sencillos, pocos objetos, pocas manipulaciones, etcétera, llegarían a los problemas reales con el aumento de la velocidad de cómputo. Sin embargo, estos métodos resultaron demasiado débiles dada la explosión combinatoria que se recibía de la realidad, y a pesar del enorme incremento habido en la capacidad de cálculo. El segundo obstáculo correspondía a las limitaciones de las estructuras utilizadas. Un caso particular fue puesto de manifiesto en el libro "Perceptrons: Una Introducción a la Geometría Computacional" de Minsky y Papert (1969). En este libro publicaron una crítica devastadora ya que demostraron matemáticamente que el diseño de Rosenblatt era incapaz de realizar algunas tareas básicas de clasificación. Para la mayoría en el campo de la inteligencia artificial, esto fue suficiente para hacer que se alejaran no solo de los Perceptrones, sino de los conceptos más amplios de las redes neuronales y el aprendizaje automático en general. Aunque solamente afectaba a este tipo de redes supuso la retirada de fondos para las redes neuronales artificiales en general. El invierno de la IA descendió a todos los campos de investigadores (Brynjolfsson & McAfee, 2017). Pero algunos equipos continuaron con el aprendizaje automático porque estaban convencidos de que la manera correcta de hacer que las computadoras pensaran de manera humana era construir redes neuronales inspiradas en el cerebro que pudieran aprender con el ejemplo. Estos investigadores llegaron a comprender y superar las limitaciones del Perceptrón. Hicieron esto con

una combinación de matemática sofisticada, un hardware informático cada vez más poderoso y un enfoque pragmático que les permitió inspirarse en cómo funciona el cerebro, pero no estar limitados por él (Brynjolfsson & McAfee, 2017).

Sistemas basados en el conocimiento (1969-1979): Para encontrar la solución, los programas de la década anterior utilizaban mecanismos de búsqueda junto con pasos de razonamiento elementales. Una forma de superar la explosión combinatoria es emplear conocimiento sobre el dominio del problema para conseguir pasos de razonamiento más amplios. El DENDRAL (ya mencionado anteriormente) (Buchanan et al. 1969) constituye uno de los primeros ejemplos de este enfoque, diseñado en Stanford para inferir una estructura molecular a partir de la información proporcionada por un espectrómetro de masas.

El siguiente esfuerzo de consideración se dio en el área del diagnóstico médico con el programa MYCIN, que con un respaldo de 450 reglas era capaz de hacer diagnósticos de infecciones sanguíneas tan buenos como los de un experto y, desde luego, mejores que los de un médico recién graduado.

Se convierte en una industria (1980-1988): El primer sistema experto comercial, R1, inició sus actividades en Digital Equipment Corporation (McDermott, 1982).

En 1988, el grupo de inteligencia artificial de la DEC había distribuido ya 40 sistemas expertos, y esperaba tener más. Du Pont utilizaba ya 100 de éstos y estaban en etapa de diseño 500 más, lo que le generaba ahorros de diez millones de dólares anuales. Casi todas las compañías importantes de USA contaban con su propio grupo de desarrollo que utilizaba o investigaba la tecnología de los sistemas expertos. En 1981 los japoneses anunciaron el proyecto de la "quinta generación", un plan de 10 años para construir computadoras inteligentes que ejecutasen Prolog, de manera idéntica a como las computadoras comunes lo hacen con el código de máquina, lo que le devolvió el crédito a la disciplina.

El despertar de las redes neuronales (1980 al presente): Tras el libro de Minsky y Papert se redujo drásticamente la investigación en ese campo, aunque se continuó en otras áreas. Grossberg (1968) y Amarimber (1972) introducen independientemente el modelo aditivo de neurona, explorado para el estudio de la memoria a corto plazo, que serviría de base al posterior modelo de Hopfield. También surgieron en esta década de "letargo" los primeros estudios sobre mapas autoorganizativos que utilizaban un aprendizaje competitivo (Malsburg 1973, Grossberg 1972) y dieron pie a Kohonen (1982) para iniciar sus estudios. Anderson presenta el "Asociador Lineal" y

una potente extensión llamada Brain-State-in-a-Box (BSB) (Anderson et al. 1977), al mismo tiempo que Fukushima (1975) desarrolla el Cognitrón e inicia su investigación sobre el Neocognitrón(1980). Con esta base en los años 80 resurge el interés por las redes neuronales y se presentan nuevas aportaciones a la teoría y diseño de éstas desde diferentes frentes. En 1982 se celebró la U.S.-Japan Joint Conference on Cooperative/Competitive Neural Networks y Fujitsu comenzó el desarrollo de computadores pensantes para hacer aplicaciones en robótica.

En los años ochenta Paul Werbos, Geoff Hinton, Yann LeCun construyen exitosos sistemas de aprendizaje de máquinas que permitieron que la información viajara hacia adelante y hacia atrás a través de la red. Esta "propagación hacia atrás" condujo a un rendimiento mucho mejor, pero el progreso siguió siendo frustrantemente lento. En la década de 1990, un sistema de aprendizaje automático desarrollado por LeCun para reconocer números leía hasta el 20% de todos los cheques escritos a mano en los Estados Unidos (Brynjolfsson & McAfee, 2017).

El avance actual en IA se remonta a 2012, cuando Geoffrey Hinton y sus colaboradores sorprendieron al mundo académico demostrando el poder de las redes neuronales convolucionales profundas (deep convolutional neural networks) usadas para la clasificación de imágenes (Allen, 2015). Estas no se basan en sistemas expertos alimentados con patrones identificados (conocimiento, gramática, reglas de decisión, entre otros) sino en algoritmos de AA que descubren patrones. El artículo “Un algoritmo de aprendizaje rápido para redes de creencias profundas” de Hinton et al. (2006), demostró que las redes neuronales suficientemente poderosas y correctamente configuradas podrían aprender por sí mismas, sin entrenamiento ni supervisión humana.

Anexo IX. Tipos de Aprendizajes Automáticos

En el aprendizaje Supervisado, el algoritmo se alimenta de un conjunto de datos de una denominada “formación” que contiene las etiquetas de una parte de las observaciones. Por ejemplo, un conjunto de datos de transacciones puede contener etiquetas de algunos puntos de datos que identifican los que son fraudulentos y los que no son fraudulentos. El algoritmo “aprenderá” la regla general de clasificación que se utilizará para predecir las etiquetas de las observaciones restantes del conjunto de datos (Kolanovic & Krishnamachari, 2017).

En el aprendizaje supervisado se trata de encontrar una regla, una "ecuación" que se pueda usar para predecir una variable. Por ejemplo, se puede querer buscar una señal de impulso (seguimiento de tendencias) que tenga la mejor capacidad para predecir el desempeño futuro del mercado. Esto puede lograrse ejecutando modelos de regresión avanzados para evaluar cuál tiene mayor poder predictivo y es más estable a los cambios de régimen.

El aprendizaje supervisado se adapta idealmente para la automatización de muchas tareas que actualmente son efectuadas por las personas, especialmente en áreas de apareamiento de patrones, diagnóstico, clasificación, predicción y recomendación. La visión, el reconocimiento de voz y otras capacidades que antes eran imposibles para las máquinas ahora se realizan en niveles comparables a los humanos en muchos dominios (Brynjolfsson & McAfee, 2017).

El segundo tipo principal de aprendizaje automático es el enfoque de aprendizaje descriptivo o no supervisado. Aquí solo se tienen entradas, y el objetivo es encontrar "interesantes patrones” en los datos. Esto a veces se llama descubrimiento del conocimiento. Este es un problema mucho menos definido, ya que no se nos dice qué tipos de patrones buscar, y no hay una métrica de error evidente que usar (a diferencia del aprendizaje supervisado, donde se puede comparar la predicción de y para una x dada el valor observado) (Murphy, 2012). Este tipo de aprendizaje se refiere a situaciones en las que los datos proporcionados al algoritmo no contienen etiquetas. Se le pide al algoritmo detectar patrones en los datos mediante la identificación de grupos de observaciones que dependen de las características subyacentes similares (Kolanovic & Krishnamachari, 2017).

En el aprendizaje supervisado se dispone de una variable objetivo, observada en los datos, mientras que en el aprendizaje no supervisado el objetivo es encontrar patrones o relaciones entre ellos.

Hay un último tipo de aprendizaje, el profundo, que es un método de aprendizaje automático que analiza los datos en múltiples niveles de aprendizaje. Utiliza algoritmos que trabajan en “capas” inspiradas en la estructura y en la función del cerebro. Puede comenzar a hacerlo aprendiendo sobre conceptos más simples y combinando estos conceptos para aprender sobre conceptos más complejos y nociones abstractas. A menudo se dice que el objetivo de la automatización es realizar tareas que sean fáciles para las personas definir, pero tedioso de realizar. Por otro lado, el objetivo de los sistemas de aprendizaje profundo (denominados Deep Learning) es realizar tareas que son difíciles de definir para las personas, pero fáciles de realizar. El aprendizaje profundo es en su esencia más similar a cómo aprenden las personas, y por lo tanto es un intento genuino de recrear artificialmente la inteligencia humana (Brynjolfsson & McAfee, 2017). Por ejemplo, un niño aprenderá a reconocer el concepto de "cara" mirando las imágenes e identificando algunas características simples como los ojos, la nariz, la boca, etc. A partir de características simples, se construye un concepto más complejo, como la relación entre estas características (los ojos están por encima de la nariz, etc.) y su importancia relativa (por ejemplo, una cara sin un ojo todavía identificado como un ' cara'). Mediante el proceso de reconocer estas características y vincularlas, un niño podrá reconocer ejemplos nunca antes vistos de: caras de animales, personajes de ficción o representaciones completamente estilizadas, como emoticones. Solo un sistema de aprendizaje flexible, a diferencia de la IA simbólica puede lograr este nivel de reconocimiento y generalización de patrones (Kolanovic & Krishnamachari, 2017; Brynjolfsson & McAfee, 2017).

El aprendizaje profundo se utiliza en el preprocesamiento de conjuntos de Big Data no estructurados (por ejemplo, se utiliza para contar automóviles en imágenes de satélite, identificar sentimientos en un comunicado de prensa, etc.). Una ilustración del Aprendizaje Profundo en una hipotética serie de tiempo financiera sería por ejemplo predecir (o estimar) la probabilidad de una corrección de mercado: se puede incluir una gran cantidad de conjuntos de datos en un modelo de Aprendizaje Profundo y este puede identificar primero algunas características simples que afectan negativamente al mercado, como una caída del impulso, un aumento de la volatilidad, una disminución de la liquidez, etc. Además, el algoritmo puede identificar patrones entre estas características simples y relaciones no lineales entre ellas. A partir de esos modelos, puede crear características más complejas, como por ejemplo de estrés financiero, que eventualmente puede

llevar a correcciones de mercado más significativas o incluso a recesiones (Kolanovic & Krishnamachari, 2017).

El tipo de "aprendizaje no supervisado" sigue siendo relativamente raro en el campo del aprendizaje automático. En su lugar, la mayoría de los sistemas exitosos se basan en el "aprendizaje supervisado", en el que se les asigna esencialmente un conjunto de preguntas y respuestas correctas antes de que se les pida que respondan cualquier pregunta nueva por su cuenta. También hay éxitos comerciales que han utilizado el aprendizaje por refuerzo (Brynjolfsson & McAfee, 2017).

Entonces, hay diferentes tipos de aprendizaje automático y se usan para diferentes propósitos. El propósito del aprendizaje supervisado es establecer una relación entre dos conjuntos de datos y usar un conjunto de datos para pronosticar el otro. El propósito del aprendizaje no supervisado es tratar de comprender la estructura de los datos e identificar los principales impulsores detrás de ella. El propósito del aprendizaje profundo es utilizar redes neuronales de múltiples capas para analizar una tendencia, mientras que el aprendizaje por refuerzo fomenta los algoritmos para explorar y encontrar las estrategias comerciales más rentables (Kolanovic & Krishnamachari, 2017).

No es el objetivo de este trabajo ahondar en las técnicas o métodos de los tipos de *Machine Learning*, pero se aborda un resumen para su comprensión de alto nivel. Los métodos de aprendizaje supervisado se clasifican en regresión y clasificación. Las regresiones intentan predecir las variables de salida en función de una serie de variables de entrada mientras que los métodos de clasificación intentan agrupar o clasificar los resultados en categorías. Un método simple de regresión de aprendizaje automático se llama regresión de Lasso, esta intenta establecer la relación o un pronóstico al elegir el conjunto de variables de entrada más pequeño y relevante. Las regresiones de *K-nearest neighbors* predicen los datos simplemente mirando las muestras históricas y estableciendo lo que ha sucedido en situaciones similares como la mejor previsión del futuro. La regresión logística, es un método de clasificación adaptado al manejo de datos donde la salida es una decisión binaria. Otro método son las clasificaciones de árbol de decisión que intentan encontrar la regla óptima para pronosticar un resultado basándose en una secuencia de pasos de decisión simples. Un "árbol de decisiones" tan simple puede explicar los rendimientos pasados, pero no funcionar bien fuera de la muestra. *Random Forests* es un método de clasificación de AA que se basa en “árboles de decisión”. Los bosques aleatorios promedian modelos de árboles de

decisión y, a menudo, producen pronósticos mejores y más confiables en comparación con los árboles de decisión.

Los métodos de aprendizaje no supervisado a menudo se pueden clasificar en *Clustering* o *Factor Analysis*. El *Clustering* implica dividir un conjunto de datos en grupos más pequeños en función de alguna noción de similitud. Un ejemplo de este tipo es la técnica *K-means* que divide los datos en subconjuntos de datos de tal manera que se minimice la dispersión de puntos dentro de cada grupo. Los análisis factoriales tienen como objetivo identificar los principales impulsores de los datos o identificar la mejor representación de los mismos. Un método muy conocido de *Factor Analysis* es el Análisis de Componentes Principales (*Principal Component Analysis*, PCA) (Mitchell, 1997; Murphy, 2012, Kolanovic & Krishnamachari, 2017).

En resumen, se presenta a continuación los tipos de Aprendizaje Automático o *Machine Learning*, y aunque no se profundiza en las técnicas de cada uno de ellos, se puede visualizar en la figura 23 las categorizaciones.

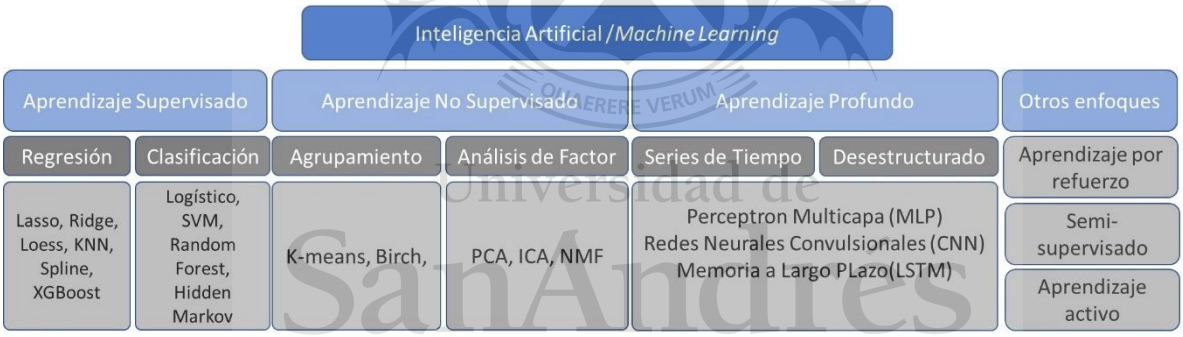

Figura 23. Clasificación de tipos y técnicas de Aprendizaje Automático o Machine Learning

Esta figura muestra los tipos de Aprendizaje Automático o *Machine Learning* y las diferentes técnicas que se agrupan dentro de los tipos Supervisado, No Supervisado y Profundo, además de otros enfoques. Recuperada de (Kolanovic & Krishnamachari, 2017). Traducción Propia. Copyright 2017.

Anexo X. Índice de Digitalización y Adopción de IA (McKinsey)

Según un estudio de McKinsey (2017a) sobre 3.000 ejecutivos con conciencia de IA, de 10 países y 14 sectores, solo el 20 por ciento expresó que en ese momento utilizaba tecnología relacionada con IA a gran escala o en una parte central de sus negocios. En este mismo estudio se muestra el resultado de una revisión de más de 160 casos de uso y la elaboración del índice de adopción de IA por sector. Los sectores que están ubicados más arriba en el índice de digitalización de la industria como la alta tecnología y los servicios de telecomunicaciones o financieros también son los principales adoptantes de la IA y son los que tienen las intenciones de inversión en IA más agresivas (McKinsey, 2017a).

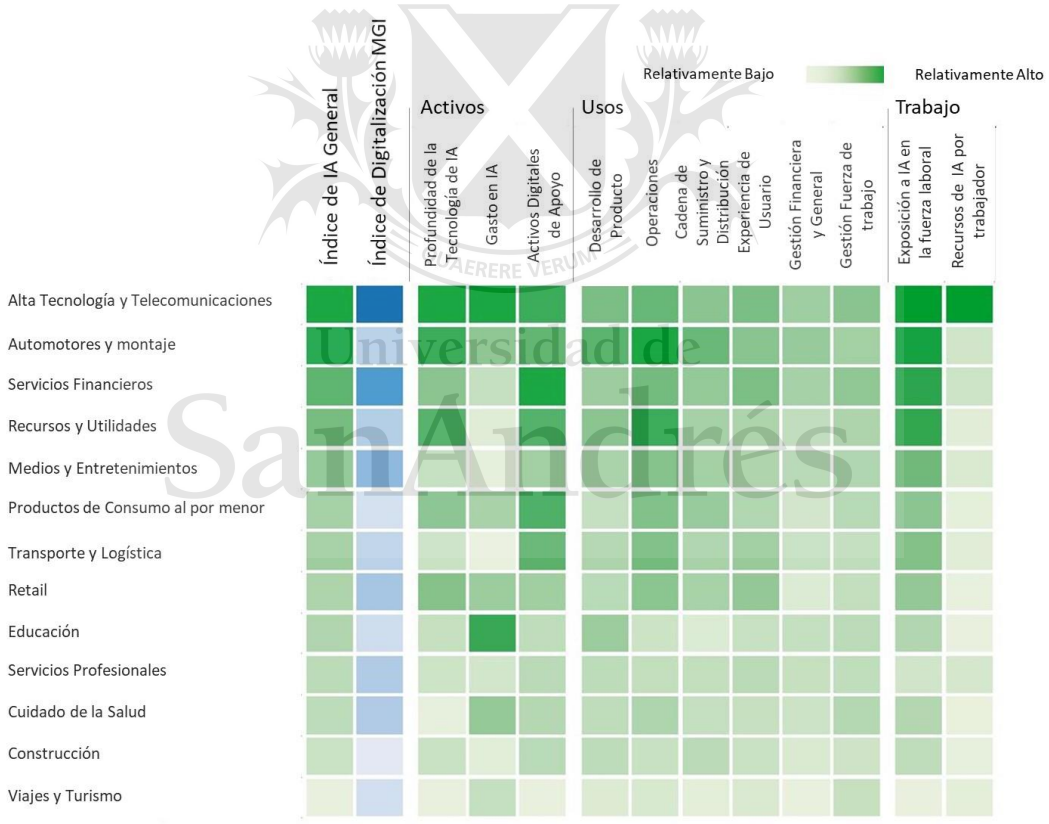

Figura 24. Índice de IA e Índice de Digitalización

La figura muestra el Índice de Digitalización de la Industria obtenido con promedio ponderado del PIB de Europa y EE. UU. obtenido por McKinsey Global Institute (2017). Copyright 2017. Traducción propia.

Anexo XI. Hype Cycle de Inteligencia Artificial 2018 (Gartner)

A continuación, se presenta el Ciclo de Hype de Inteligencia Artificial publicado por Gartner (2018).

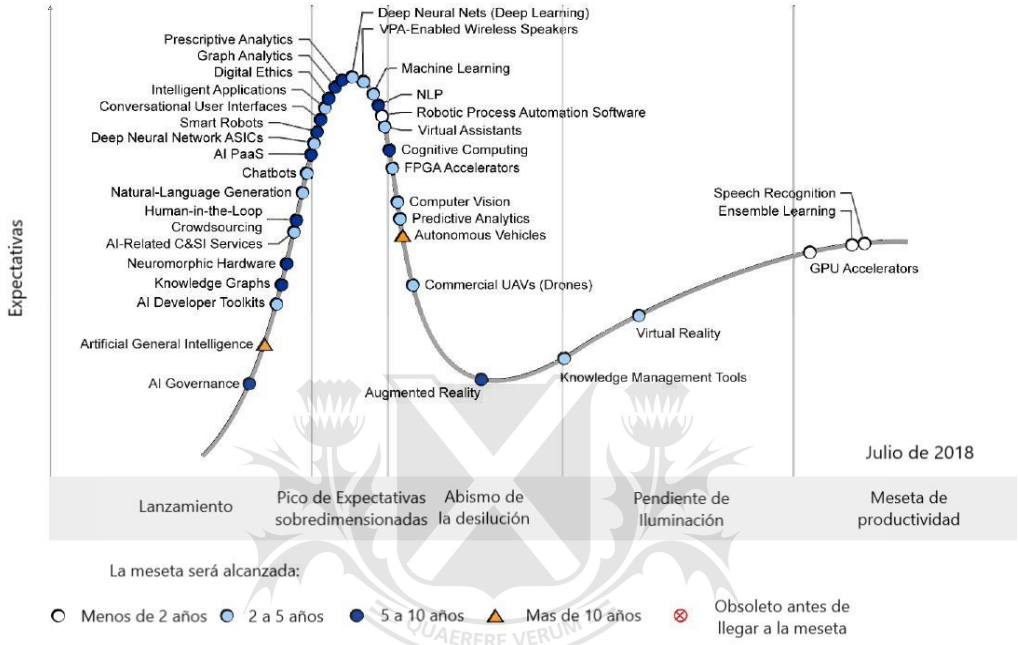

Figura 25. Hype Cycle Inteligencia Artificial

La figura muestra el Hype Cycle de Inteligencia Artificial a Julio de 2018 recuperado de (Gartner, 2018). Copyright 2018. Traducción Propia.

Anexo XII. Amplitud y Frecuencia de Casos de Uso de Aprendizaje Automático por sector)

A continuación, se muestra el resultado de un estudio de McKinsey (2017) donde se muestra los casos de uso con su potencial.

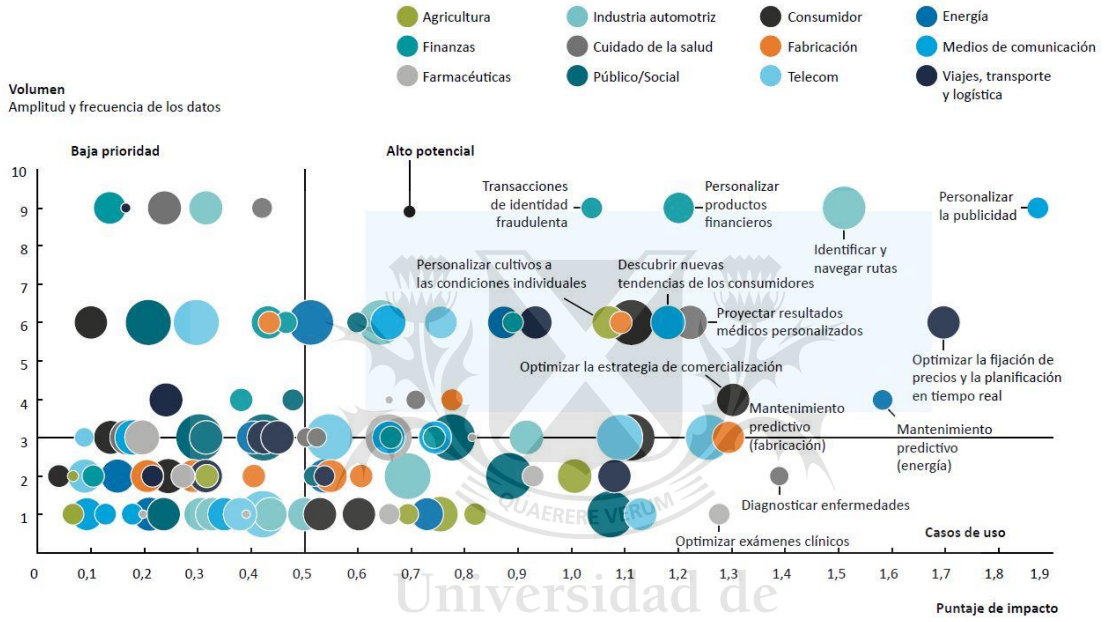

Figura 26. Amplitud y Frecuencia de Casos de Uso de Aprendizaje Automático por sector

La Figura muestra un comparativo de los diferentes casos de uso de AA por industria teniendo en cuenta la amplitud y la frecuencia de los casos de uso en mismas marcando una zona de alto potencial. Recuperada de https://www.mckinsey.com/~/media/McKinsey/Featured%20Insights/Digital%20Disruption/Whats%20now%20and%20next%20in%20analytics%20automation/Final%20PDF/MGI-Briefing-Note-Automation-final.ashx. Copyright 2017.

Anexo XIII. Inversiones en Inteligencia Artificial y Aprendizaje Automático

La mayoría de las empresas que encuestaron esperaban aumentar el gasto en IA en los próximos tres años. estudio de McKinsey (2017a) se estimó que el crecimiento de la inversión externa anual total fue de $ 8 mil millones a $ 12 mil millones en 2016. El AA atrajo a casi el 60 por ciento de esa inversión.

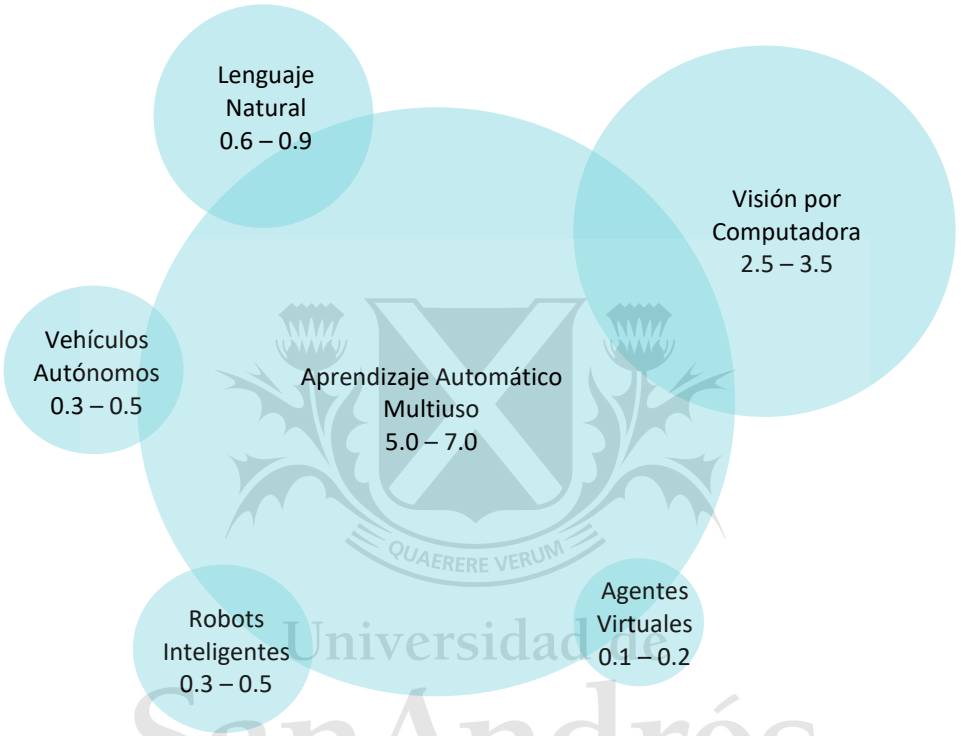

Figura 27. Inversión en IA

La figura muestra en miles de millones de U$S la inversión en diferentes dimensiones de IA.
Fuente: (McKinsey, 2017). Copyright 2017. Traducción Propia.

En el estudio de McKinsey (2017a) también se evidencia que los analistas de la industria de TI coinciden en que el tamaño del mercado para la tecnología de IA experimentará un fuerte crecimiento en los próximos tres años. La mayoría de las empresas que encuestaron esperaban aumentar el gasto en IA en los próximos tres años.

Anexo XIV. Uso de Canales transaccionales de los Bancos en EE. UU.

De acuerdo con un estudio de Bankrate de diciembre de 2015, el 30% de los clientes de banca encuestados no había acudido a la sucursal bancaria en los últimos seis meses. Esto es un indicio de los cambios en los canales de consumo de los servicios financieros. A continuación, en la figura 28 se muestra el resultado de la encuesta.

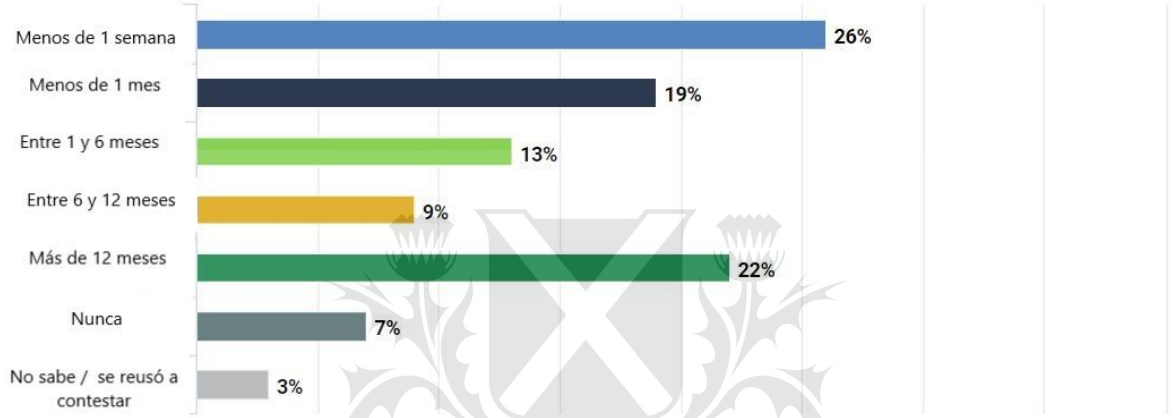

Figura 28. Porcentaje de clientes sin visitar a sucursales por ventana de tiempo

La Figura muestra el resultado de la encuesta realizada por Bankrate en 2015, donde se muestra el porcentaje de clientes sin acudir a sucursales por ventana de tiempo. Recuperada de https://www.bankrate.com/finance/consumer-index/branch-banking-still-strong-among-americans.aspx . Traducción propia.

Anexo XV. Uso de Canales transaccionales de los Bancos en América Latina

El estudio llevado a cabo por Anif, Felaban y CAF (2018) muestra para América Latina algunas divergencias con respecto a la demanda y los canales por donde se expresan, pues a pesar de los avances en la oferta digital, se observa que las preferencias de muchos clientes permanecen estancadas en canales físicos tradicionales como se puede ver en la siguiente figura.

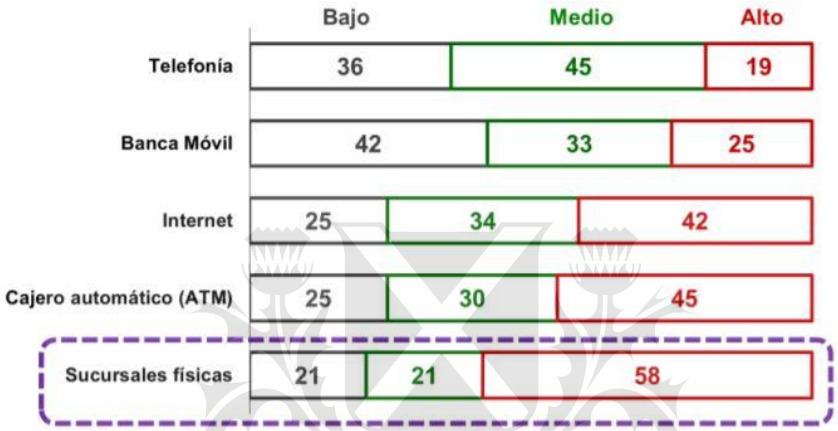

Figura 29. Intensidad de uso de los clientes de los canales transaccionales

La figura muestra en % de encuestados el uso de los canales tradicionales. Fuente: "Los Servicios Financieros Digitales en América Latina" Anif, Felaban &CAF (2018). Recuperada de: http://felaban.s3-website-us-west-2.amazonaws.com/documentos_interes/archivo20181204163600PM.pdf

Este gráfico ilustra un alto" uso de canales transaccionales tradicionales como las sucursales físicas (58% de la muestra) y cajeros automáticos (45%) y se mantiene para los canales transaccionales de internet (42%) pero se reduce rápidamente en el caso de la banca móvil (25%) y telefonía (19%).

Anexo XVI. Madurez Digital de los Bancos en América Latina

Technisys junto con la Universidad de Stanford llevó a cabo un estudio para trazar un panorama sobre la banca digital en América Latina, entrevistando a los principales bancos de América, 56 en total, de 13 países (Technisys, 2017). Este trabajo consistió en clasificar a cada banco de acuerdo con su intensidad digital, es decir el grado de avance de las iniciativas dentro de la organización, y también conforme a su profundidad en la Gestión del Cambio, que hace referencia a la capacidad de los altos ejecutivos de impulsar los cambios en una organización a través de una visión clara, de la coordinación entre departamentos y de una cultura preparada para adoptar la digitalización. Las características descriptivas de los cuatro tipos de organizaciones se describen en la siguiente figura:

Figura 30. Categorías de Bancos según su madurez digital.

Esta figura muestra los diferentes niveles de madurez de los Bancos en función de las dimensiones de Intensidad Digital e Intensidad de la Gestión del Cambio.
Basado en Technisys (2017), recuperado de https://www.technisys.com/wp-content/uploads/2017/02/La_Banca_Digital_en-America_Latina_ES.pdf. Copyright 2017.
Traducción propia.

Del informe se obtiene el resultado que se puede visualizar a continuación (figura 26) donde la principal observación es que la primera mayoría corresponde a Bancos conservadores (32%), seguida por un 30% de Adoptantes tardíos. O sea que el 62 % de los bancos en América Latina aún no ofrecen funciones digitales avanzadas ni recursos importantes dedicados en sus plataformas y productos de banca digital o lo que se puede considerar es más desalentador los

bancos carecen tanto de visión global digital en la gerencia, así como de productos bancarios digitales avanzados. Ofrecen productos digitales básicos como banca en Internet y aplicaciones para teléfono móvil, pero no poseen capacidades más avanzadas vinculadas al posicionamiento digital de marca y a los bancos líderes digitales (Technisys, 2017).

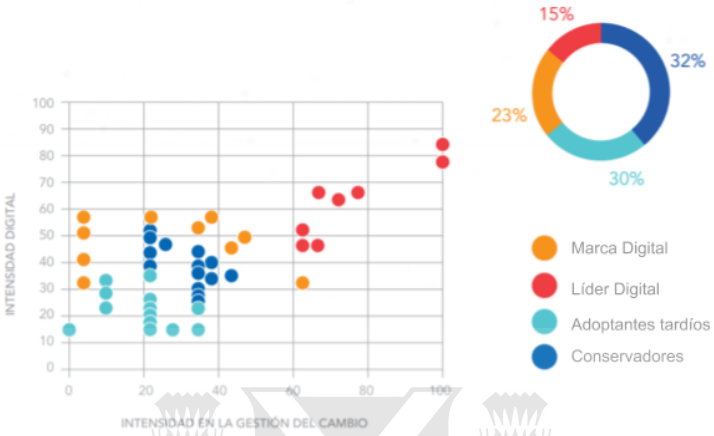

Figura 31. Bancos por Categoría

La figura muestra la distribución de los bancos analizados en cuanto a la intensidad digital que poseen y la intensidad de gestión del cambio.
Basado en Technisys (2017), recuperado de https://www.technisys.com/wp-content/uploads/2017/02/La_Banca_Digital_en-America_Latina_ES.pdf. Copyright 2017.
Traducción propia.

Universidad de SanAndrés

Anexo XVII. Productos y Servicios bancarios que podrían desaparecer en los próximos 15 a 20 años.

Lista de productos bancarios típicos que podrían desaparecer en los próximos 15 a 20 años como resultado de la fricción y la obsolescencia del canal, para ser reemplazados por experiencias receptivas en tiempo real que surgen en la utilidad bancaria. A continuación, en la tabla 5 se detallan los mismos.

Tabla 9. Detalle de los Productos o Servicios Financieros actuales y su reemplazo en el futuro

Producto o Servicio Financiero actual	***Remplazo por Experiencia integrada***
Tarjeta de Crédito	Acceso al crédito Predictivo y Contextual
Overcraft	Acceso al crédito de emergencia
Cuenta Corriente o Tarjetas de débito	Tienda de valor personal basada en la nube vinculada a una billetera móvil.
Caja de Ahorro	Herramientas de ahorro comportamentales
Préstamo Personal	Opciones de pago con asesoramiento en tienda o contextual
Hipotecas	Asistente de compra de vivienda
Préstamo/ arrendamiento de automóvil	Subscripción de acceso de vehículo autónomo
Cuenta Bancaria Pyme	Tienda de valor empresarial inteligente (con contabilidad, impuestos y pagos por IA).
Créditos a Empresas	Análisis predictivo de flujo de efectivo
Seguros de Vida	Gestión de la longevidad
Cobertura de Seguros de Salud	Servicio de optimización y monitorización de la salud.

En esta tabla se presenta una lista de los productos los servicios financieros que actualmente forman parte de los modelos de negocio que pueden ser reemplazados. Traducción Propia basado en King (2018).

Anexo XVIII. Uso de la tecnología y su impacto en paradigmas de la banca tradicional, algunos datos

Los millennials y la Gen Z (generación *post millennial*), al estar más centrados en la tecnología, están ajustando su comportamiento más rápido que las generaciones anteriores. Por lo tanto, se ve una correlación directa entre el uso de la tecnología y la no aceptación de los paradigmas más antiguos, como el uso de las sucursales, las tarjetas de crédito o el uso de cheques. Hay varios ejemplos, entre ellos se puede mencionar el uso de los cheques que ha disminuido casi el 70% en los EE. UU. desde el año 2000. Otro ejemplo es que menos de un tercio de los millennials también en este mercado posee una tarjeta de crédito en la actualidad (los niveles más bajos de su grupo de edad en los últimos 40 años desde que se lanzaron las tarjetas de crédito). Por lo tanto, se vislumbra un cambio de comportamiento, a medida que los *millennials* envejecen, no están tan interesados en endeudarse como las generaciones anteriores. Los programas tradicionales de recompensas de tarjetas de crédito tampoco estimulan el uso del crédito. El total de recompensas pagadas por los seis principales emisores de tarjetas de EE. UU. se duplicó de $ 11 mil millones a $ 23 mil millones entre 2010 y 2016, en un claro intento de atraer a más jóvenes a usar tarjetas de crédito 6 y, sin embargo, los *millennials* permanecen inamovibles.

Los *millennials* de los EE. UU. acceden a su banco a través de un dispositivo móvil con un promedio de 8,5 veces al mes, en comparación con solo 3,1 veces al mes para los no *millennials*. También son más propensos a conectarse con el banco por correo electrónico (4,6 veces por mes frente a 0,9 veces). La apertura de cuenta en línea es la forma preferida por los *millennials* (King, 2018). El 10 por ciento de los *millennials* están usando un banco exclusivamente digital como su relación principal, y el 15 por ciento de los individuos de alto patrimonio neto también están usando ofertas digitales de juego puro. La Reserva Federal de los EE. UU. publicó un estudio en 2016 que mostraba que el móvil era el principal canal de elección para los *millennials:* el 67 por ciento de las veces. En el Reino Unido, el uso de la banca móvil aumentó un 356 por ciento a partir de 2012, con los *millennials* con el doble de probabilidades de usar la banca móvil que sus predecesores.

Datos obtenidos de (King, 2018)

Anexo XIX. Tipos de consumidores (Accenture)

Para tratar de entender cómo se conforma el universo de los consumidores de servicios financieros Accenture (2017c) ha llevado a cabo un estudio acerca de estos, donde recogió 33.000 opiniones de consumidores de estos servicios (incluyendo banca, seguros y asesorías de inversión).

En este estudio se identificaron 6 tendencias de los consumidores.

Los consumidores están dispuestos a compartir sus datos personales con los proveedores financieros, pero quieren algo a cambio. Los consumidores de hoy comprenden el valor de sus datos, y esperan que los proveedores le brinden beneficios adicionales por el uso de sus datos. El 67% permitirá que los bancos accedan a más datos personales, pero el 63% quiere una orientación más personalizada, y el mismo número demanda servicios prioritarios como aprobaciones rápidas de préstamos o un beneficio monetario, como precios más competitivos, a cambio de la información compartida.

Para muchos consumidores -en especial de la Generación Y y la Generación Z - Google, Apple, Facebook y Amazon (conocidos colectivamente como GAFA) son alternativas atractivas a sus proveedores financieros tradicionales. Esto refuerza la atracción de los servicios altamente reactivos y personalizados con los que los consumidores se han acostumbrado en esas plataformas. Además, los clientes más jóvenes quieren ser más partícipes, por medio de las plataformas on-line, para ayudar a moldear futuros productos y servicios bancarios que satisfagan sus necesidades.

Un número muy elevado de los encuestados están abiertos a una experiencia de servicio y soporte puramente automático, incluso cuando se toman decisiones más complejas en torno a opciones de productos.

El asesoramiento personalizado relacionado con la selección de productos y la asignación de activos es la clave para una relación exitosa entre los clientes y sus proveedores financieros. Las personas esperan cada vez más interacciones personalizadas y relevantes para cubrir sus necesidades y objetivos financieros. Los clientes quieren que los bancos tengan un papel de soporte en el proceso de adquisición de otros productos no bancarios, como una casa o un automóvil nuevo, o servicios relacionados a éstos.

Conforme los consumidores se van abriendo cada vez más a los servicios dirigidos por datos, las relaciones personales van dejando de ser el principal factor de confianza. El principal

factor de fidelidad para los clientes de bancos es poder confiar en la capacidad de sus bancos para proteger sus datos personales (un 43% cita ese factor).

Y por último, la mayoría de los encuestados dijeron que cada vez menos se preocupan por el canal que utilizan para comunicarse con su banco, compañía de seguros o asesor de inversiones. Su principal preocupación es que pueden conseguir lo que necesitan de forma rápida y fácil. Pero, los clientes de bancos aún no están preparados para renunciar a las sucursales bancarias. Es más, tener un fácil acceso a una sucursal es el tercer factor de fidelidad más importante: un 40% lo citó. Sin embargo, a medida que más servicios migran hacia plataformas on-line, los clientes buscan una experiencia de sucursal que asocie lo físico y lo digital de forma integrada. Un punto de la encuesta es que los servicios bancarios omnicanales todavía parecen ser una meta, puesto que los clientes afirman que la coordinación entre los canales está deteriorándose en vez de mejorar.

En el estudio también se identificaron tres tipos de consumidores, cada una con características específicas vinculadas a lo que más valoran de sus proveedores de servicios financieros, lo que impulsa su lealtad y cómo les gustaría que sus proveedores para abrazar la innovación digital. Los principales impulsores de la lealtad son el costo, el servicio al cliente (que se define por la alta calidad y capacidad de respuesta), la confianza (en particular en lo que respecta a la actuación en el mejor interés de los clientes y para la protección de datos) y el apetito o el deseo de considerar nuevos modelos digitales.

Los tres tipos identificados son los Nómades, los Cazadores y los Buscadores de Calidad. Los primeros son un grupo altamente digital, valoran la innovación digital y adoptar nuevas formas de interactuar con los proveedores de acceso a los servicios y el soporte. No están vinculados a los proveedores tradicionales de servicios financieros (78 por ciento va a utilizar una firma de tecnología como Google o Amazon para la banca). Para los Cazadores los precios competitivos son cruciales para mantenerse leales (83 por ciento dice que es esencial para la banca). Este tipo de consumidor prefiere usar los servicios financieros tradicionales. Los Buscadores de Calidad exigen una alta calidad y servicio al cliente. Estos consumidores quieren proveedores de servicios financieros que pueden confiar para proteger sus datos personales, el 53 por ciento se mantiene fiel a los bancos.

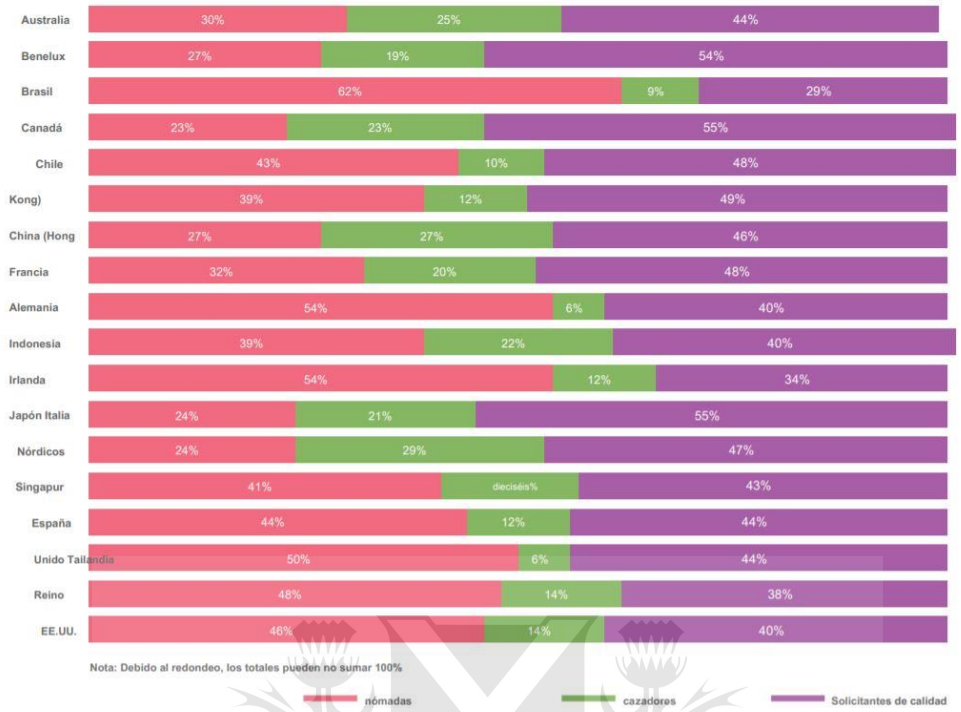

Figura 32. Cantidad de consumidores de servicios financieros por tipo y por país

Esta figura muestra el porcentaje de consumidores agrupados por tipo nómada, cazador y solicitantes o buscadores de calidad. Recuperada de "Más allá de lo Digital: ¿Cómo pueden satisfacer los Bancos las demandas de los clientes?", Accenture (2017c). Copyright 2017.

El informe refleja que la lealtad está disminuyendo rápidamente, según lo indicado por el alto porcentaje de nómadas dispuestos a utilizar proveedores GAFA. También los Cazadores y los Buscadores de Calidad muestran una disposición a cambiar sus proveedores de servicios financieros. Estos deben sacar provecho de la tendencia de los consumidores a compartir más datos personales. Mediante la implementación de almacenes de datos centralizados y motores de análisis avanzadas, los bancos pueden obtener una vista de 360 grados de sus clientes en tiempo real (Accenture, 2017c).

Los clientes están invirtiendo cada vez más tiempo en las plataformas digitales, como los ofrecidos por las compañías GAFA (Google, Amazon, Facebook, Apple). Para seguir siendo relevantes para los clientes, los proveedores de servicios financieros necesitan llegar a ellos en estas plataformas con productos adaptados en el momento adecuado. Esto es especialmente cierto para los nómadas, que son más abiertos a la innovación digital.

Los proveedores de servicios financieros, como los bancos, deben aprender de los GAFA, y proporcionar un conjunto de productos y servicios que son relevantes para la etapa de la vida o las necesidades financieras inmediatas del cliente. Esto requiere dos conjuntos de posibilidades: en primer lugar, el análisis avanzado para entender las necesidades del cliente en tiempo real; y en segundo lugar, la capacidad de construir un ecosistema de servicios internos y externos que se adaptan a las necesidades del cliente y pueden ser dirigidos a los segmentos adecuados en el momento adecuado. La omnicanalidad se ha convertido en una forma de vida para los consumidores de hoy en día. En la encuesta de Accenture (2017c), el 57 por ciento de los consumidores dicen que no les importa qué canal utilizan para comunicarse con su proveedor, siempre y cuando puedan conseguir lo que necesitan. Sin embargo, sólo el 20 por ciento de los consumidores sienten que el servicio al cliente que reciben es de la misma calidad a través de todos los canales de comunicación que utilizan con sus proveedores de servicios financieros.

QUAERERE VERUM
Universidad de
SanAndrés

Anexo XX. Panorama del ROE luego de la Crisis de 2008

La rentabilidad sobre recursos propios (RoE) comparado a la rentabilidad exigida por los accionistas (Cost of Equity – CoE) es la diferencia que mide la creación de valor de la banca para los accionistas. Tras la caída de Lehman Brothers en 2008, el RoE de la región europea se situó por debajo del CoE, es decir, destruyendo valor para el accionista, problema que aún persiste. Cuando en un sector, el gap de destrucción de valor pasa de ser coyuntural a ser estructural las alternativas son la desaparición o la reconversión industrial (Indra, 2017).

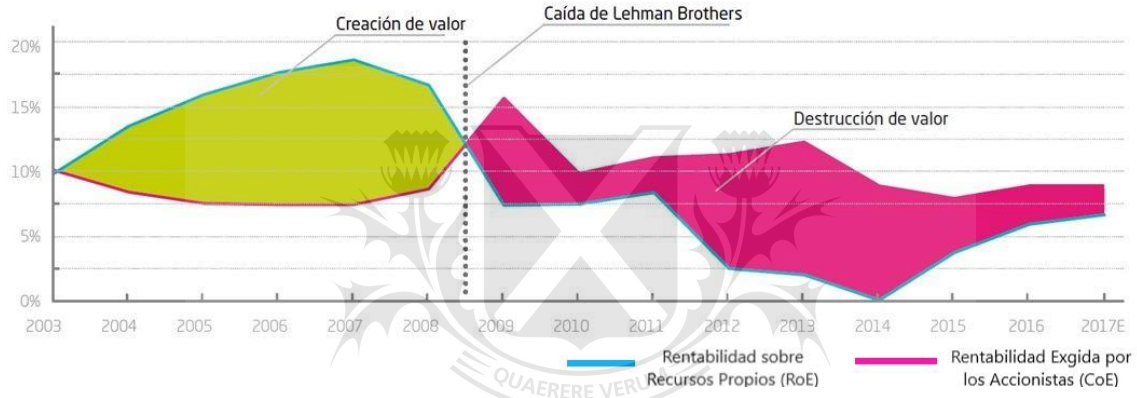

Figura 33. Retorno de capital vs. Costo de capital de Bancos Europeos

Esta figura muestra la evolución del Retorno de capital vs. costo de capital de Bancos Europeos desde 2003 a 2017, donde puede verse que el RoE de la región se sitúa por debajo del CoE desde 2008. Recuperado de Indra (2017) cuya fuente original es el Banco Central Europeo.

Anexo XXI. Preocupación de los Bancos sobre la Amenaza Fintech

A continuación (figura 34), se incorpora el resultado de la encuesta mundial realizada por PricewaterhouseCoopers (2017a) donde se vislumbran los altos índices de preocupación de los titulares o incumbentes del sistema financiero (entre los que se encuentran los bancos) sobre el riesgo a su negocio y el crecimiento de la preocupación de 2016 a 2017, con excepción de África.

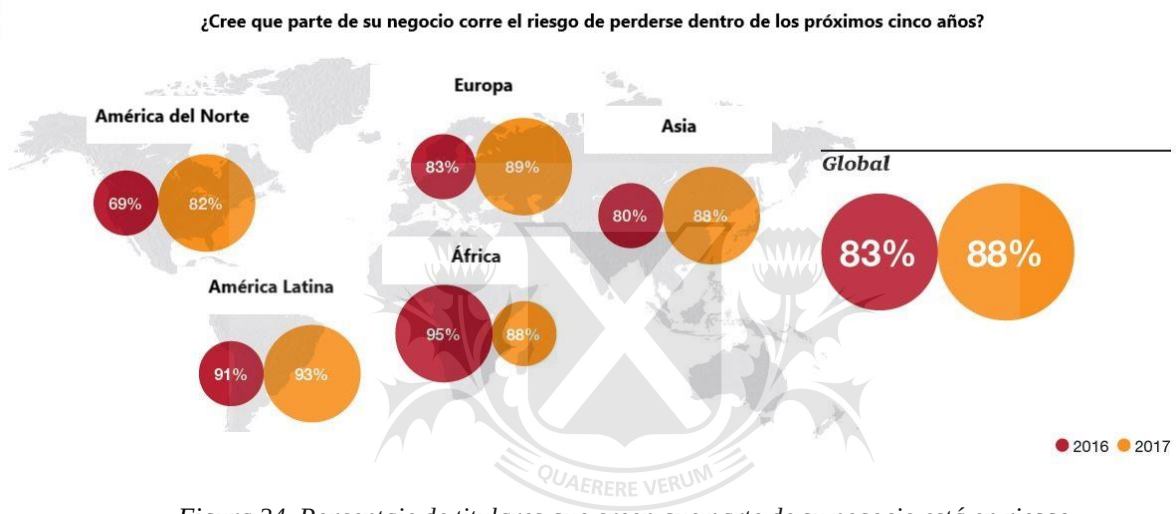

Figura 34. Porcentaje de titulares que creen que parte de su negocio está en riesgo

Esta figura muestra a nivel global, como ha crecido el porcentaje de titulares del Sistema Financiero que creen que su negocio está en riego. Fuente: Global FinTech Report 2017. Redrawing the Lines: FinTech's Growing Influence on Financial Services, PricewaterhouseCoopers (2017a). Copyright 2017.

Universidad de SanAndrés

En América Latina, en el estudio llevado a cabo por Anif, Felaban &CAF (2018), un 39% de los bancos considera a las Fintech como un riesgo para su organización, especialmente en temas relacionados con la seguridad de la información.

En Argentina, particularmente, según la Encuesta Global Fintech, capítulo Argentina realizada por PricewaterhouseCoopers (2017b), las instituciones de servicios financieros tradicionales consideran que las entrantes, se han transformado en un poderoso driver de disrupción y en este escenario, las probabilidades de que las instituciones financieras tradicionales pierdan ingresos debido a las alternativas más innovadoras son cada vez mayores. El 89% de los encuestados en Argentina cree que pueden perder ingresos debido a los nuevos entrantes y que algún porcentaje de su negocio podría ser captado por estas empresas en los próximos 5 años; entre

ellos, 3 de cada 10 consideró que podría perder entre el 21% y el 40% de sus ingresos. Tales datos confirman que la oferta de los nuevos entrantes dista mucho de ser una tendencia pasajera: el total de los encuestados en Argentina anticipó que en los próximos 5 años no habrá sector de la industria financiera que escape a su influjo innovador, en especial la banca de consumo (82%), pero también las transferencias de fondos y pagos (50%) y la banca comercial (46%) sector que incluye a Pymes (pequeñas y medianas empresas).

Según Anif, Felaban y CAF (2018) para América Latina entre las preocupaciones que sobresalen se encuentran la reducción de márgenes de intermediación (percepción de "riesgo medio" en el 47% de la muestra, y "riesgo alto" en el 16% de la muestra) y la pérdida de clientes (percepción de "riesgo medio" en el 39% de la muestra, y "riesgo alto" en el 10% de la muestra).

Figura 35. Amenazas al negocio bancario como consecuencia del desarrollo Fintech.

La figura muestra el porcentaje (%) de encuestados por tipo de amenaza y tipo de impacto (alto, medio y bajo). Recuperado de: "Los Servicios Financieros Digitales en América Latina" Anif, Felaban &CAF (2018). Recuperado de: http://felaban.s3-website-us-west-2.amazonaws.com/documentos_interes/archivo20181204163600PM.pdf

Anexo XXII. Crecimiento Fintech

El crecimiento de los servicios brindados por las Fintech a nivel global se obtiene del reporte realizado por Anif, Felaban y CAF (2018) donde se muestran las estimaciones recientes que sugieren que los préstamos Fintech rondan niveles del orden de US$284.000 millones a nivel global, según las cifras más recientes del año 2016 vs. niveles de solo US$10.555 millones en 2013. Nótese cómo ello equivale a casi triplicar dichos volúmenes crediticios cada año durante el período 2013-2016 (expansiones promedio anual del 200%). En la figura siguiente se puede identificar el crecimiento.

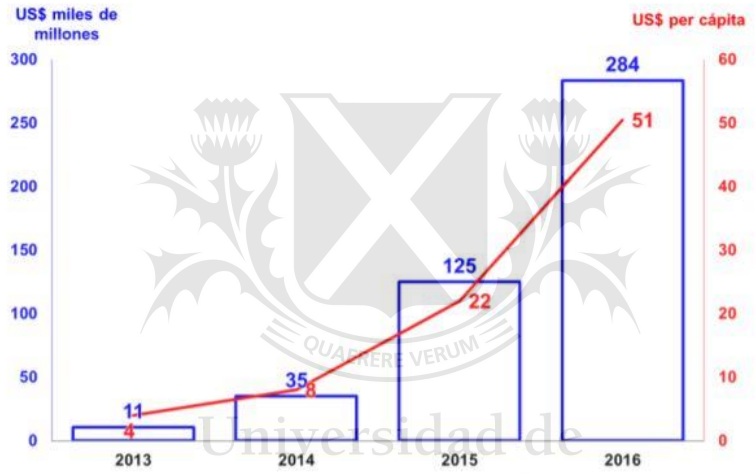

Figura 36. Crecimiento de Préstamos vía plataformas Fintech a nivel global

La figura muestra en miles de millones de dólares el crecimiento de préstamos realizados por Fintech total y per cápita. Fuente: "Los Servicios Financieros Digitales en América Latina" Anif, Felaban &CAF (2018). Recuperado de: http://felaban.s3-website-us-west-2.amazonaws.com/documentos_interes/archivo20181204163600PM.pdf

Además, se observa el crecimiento de las Fintech en la región. En un estudio realizado por el BID (Banco Interamericano de Desarrollo) y Finnovista (2018), han sido identificadas en la región 1166 startups Fintech, reflejando un crecimiento del 66% desde la primera medición realizada por ambas instituciones en 2017. La actividad Fintech creció de 15 a 18 países en el último año. Siguiendo la tendencia observada en 2017, Brasil es el país que aporta el mayor número de emprendimientos con 380, seguido por México con 273, Colombia con 148, Argentina con 116 y Chile con 84. Si bien cinco países concentran un 86% de las empresas Fintech en la región,

se han identificado emprendimientos en cada uno de los países de América Latina y una creciente tendencia a la internacionalización, lo cual muestra las oportunidades que perciben los emprendedores (BID & Finnovista, 2018).

En el reporte realizado por Anif, Felaban y CAF(2018), para América Latina se observan incrementos importantes en préstamos vía plataformas Fitechs, sobresaliendo el crecimiento de Colombia (US$131 millones en 2016 vs. valores nulos en 2013; 30% del total de América Latina), México (US$106 millones en 2016 vs. US$1 millón en 2013; 24% del total de América Latina), Chile 8 (US$93 millones en 2016 vs. US$12 millones en 2013; 21% del total de América Latina) y Brasil (US$61 millones en 2016 vs. US$1 millón en 2013; 14% del total de América Latina)

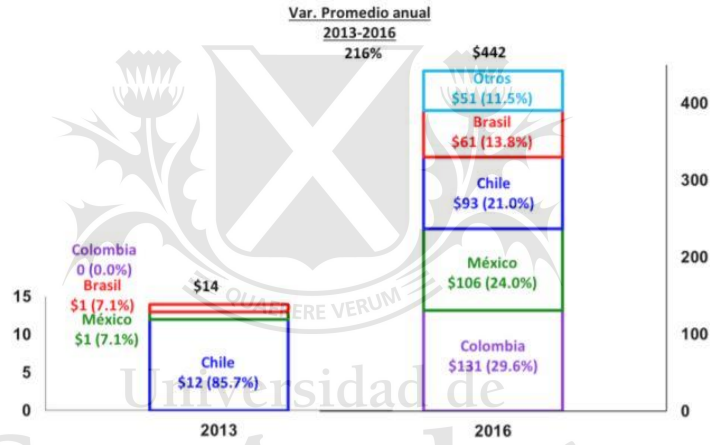

Figura 37. Préstamos vía plataformas Fintech en América Latina

La figura muestra en porcentaje (%) la variación de Préstamos vía plataformas Fintech de 2013 a 2016, mostrando un incremento considerable en sólo 3 años. Fuente: "Los Servicios Financieros Digitales en América Latina" Anif, Felaban &CAF (2018). Recuperado de: http://felaban.s3-website-us-west-2.amazonaws.com/documentos_interes/archivo20181204163600PM.pdf

Anexo XXIII. Ejemplos de Mercados con gran presencia Fintech: Caso China, Bangladesh, India y Kenia

El caso de china es emblemático. Para fines de 2015, más de 350 millones de chinos usaban sus teléfonos móviles regularmente para comprar bienes y servicios y para 2017 superaban los 750 millones. La empresa Alipay maneja una gran cantidad de este tráfico, lo que convierte en la red de pagos más grande del mundo por un amplio margen. Pero WeChat también superó a MasterCard y Visa en volumen de transacciones en 2017.

Alipay es mucho más grande hoy en día que las redes de pagos convencionales, en 2015 se reportó que Visa alcanzó su punto máximo de 9000 transacciones por segundo a través de su red mientras que Alipay realizó 87.000 transacciones, casi 10 veces más que Visa. Alipay ahora está disponible en 89 países de todo el mundo y se sigue expandiendo rápidamente. En China, el 92% del mercado de pagos móviles se realiza a través de Ant Financial (Alipay) y Tenccent (We Chat), o sea sólo por 2 jugadores tecnológicos y no por bancos o por redes de pago tradicionales (King, 2018).

Hoy Ant Financial vale lo mismo que Goldman Sachs uno de los jugadores bancarios más respetados del mundo (King, 2018).

Bangladesh, India y Kenia son ejemplos de cómo las Fintech aprovechan mercados desatendidos. En el 2000, la inclusión financiera en Bangladesh era solo del 14 por ciento; hoy en día, casi el 40 por ciento de la población adulta está en bKash, una empresa de servicios financieros móviles y hace sus pagos diarios a través del teléfono móvil. También en el año 2000, la inclusión financiera en Kenia era del 27 por ciento y hoy en día casi el 100 por ciento de la población adulta usa el dinero móvil de M-Pesa (M de móvil, pesa en Swahili significa dinero) con regularidad, ahorrando un 20 por ciento más que antes de M-Pesa. En 2011, India tenía 557 millones de personas sin acceso a servicios bancarios, y para 2015 se había reducido a la mitad, a 233 millones debido al acceso móvil y al nuevo esquema de tarjeta de identidad de Aadhaar. Paytm, la billetera móvil líder de la India ahora tiene 280 millones de usuarios y apunta a 500 millones en tres años, y se ha asociado con Softbank de Japón y Alipay de China (King, 2018)

Anexo XXIV. Aceleración de adopción de smartphones en América Latina

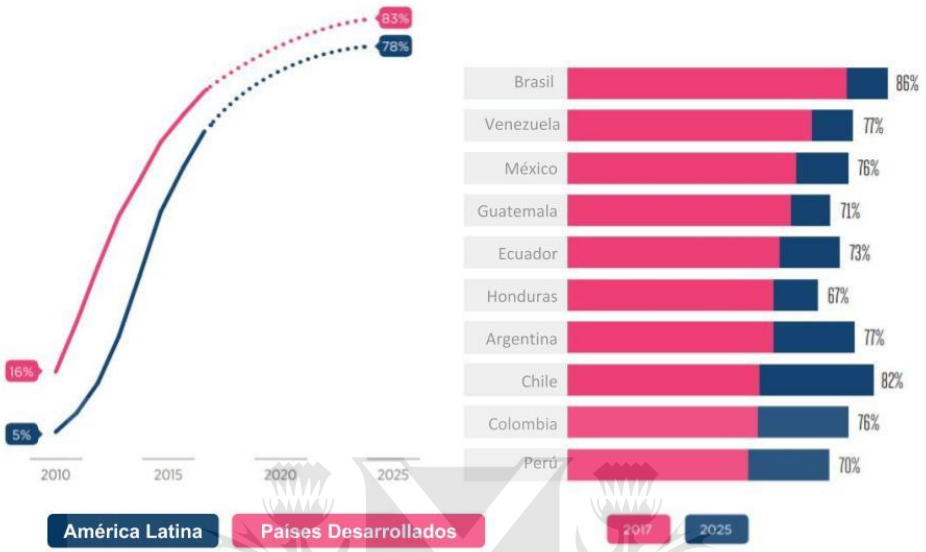

Figura 38. Aceleración de Adopción de Smartphones en América Latina

Esta figura muestra el crecimiento en la Adopción de celulares de tipo smartphones en América Latina y Países Desarrollados de 2010 a 2025. Está medido en porcentaje de conexiones. Fuente: The Mobile Economy, Latina American and Caribbean 2018, GSMA (2018). Copyright 2018.

Anexo XXV. Fortalezas de Fintech y de Bancos tradicionales

A continuación, en la tabla 6 se detallan las fortalezas de los Bancos, las fortalezas de las Fintech y su diferenciación para comprender los beneficios de la colaboración.

Tabla 10. Beneficios de la colaboración entre Bancos y Fintechs

Fortalezas de los Bancos	***Fortalezas de las Fintechs***	***Diferenciación de las Fintech***
Amplia base de clientes existentes	Nuevas ideas	Experiencias adaptadas a grupos de clientes específicos.
Amplio conjunto de productos existentes	Implementación ágil	Mayor flexibilidad en los enfoques de servicio.
Bajo costo de capital	Análisis de vanguardia y gestión de datos.	Nuevos modelos de negocio que cambian la economía.
Protección regulatoria	Adquisición de clientes en forma online	Inclusión y servicio a clientes desatendidos.
Fuente de ingresos	Diseño optimizado de experiencia OnLine/movil	Cambiar de productos a experiencias tecnológicas diferenciadas.

Esta Tabla muestra las fortalezas de los bancos, las fortalezas de las Fintech y su diferenciación. Traducción propia a partir de (King, 2018).

Universidad de SanAndrés

Anexo XXVI. Tendencia asociación de bancos tradicionales y Fintech

Rojas (2017) en su trabajo para el CAF "Transformación digital e innovación abierta en la banca. El caso del BBVA." menciona que cada una las grandes corporaciones financieras han puesto en funcionamiento su propia estrategia para hacer frente a la potencial disrupción y parte importante de la misma es acelerar su transformación digital y su propio ritmo de innovación a través de la colaboración con empresas Fintech. El BBVA ha sido uno de los bancos innovadores implementando un sistema completo de programas de innovación abierta desde 2009. Bancos muchos más grandes, como Citibank, Wells Fargo, Banco de América, tienen programas similares y están comprando nuevos emprendimientos, incubando proyectos y estableciendo alianzas estratégicas con los competidores Fintech para adquirir las habilidades tecnológicas y el espíritu innovador que necesitan, entrar en nuevos mercados y posicionarse competitivamente en el nuevo terreno digital. Esos bancos también parecen estar de acuerdo en que comprar empresas Fintech no es suficiente para adquirir los elementos que necesitan rápidamente: habilidades técnicas, espíritu emprendedor, conocimiento del consumidor y agilidad para innovar, entre otros. Por ello, los grandes bancos al igual que el BBVA, han situado la colaboración con las Fintech en el centro de su estrategia de reinvención (Rojas, 2017).

También visualizando una tendencia positiva, King (2018) menciona que, en 2012, más del 50 por ciento de los bancos encuestados por Statista consideraron que las tecnologías de FinTech eran en gran medida irrelevantes, pero para 2017 esa cifra había cambiado, y el 93 por ciento de los bancos tenían la intención de asociarse con las empresas de FinTech.

También PricewaterhouseCoopers (2017a) observa que la industria está yendo a un enfoque más colaborativo confirmando la tendencia. El 82% de los titulares encuestados en su estudio esperan aumentar las asociaciones con *FinTech* en los próximos tres a cinco años. La asociación con innovadores permitirá a los incumbentes subcontratar parte de su I + D y llevar las soluciones al mercado rápidamente. Las empresas de *FinTech* también se benefician de estas asociaciones. Ya que a medida que desarrollan nuevas teorías y modelos, para probarlos, necesitan acceso a grandes conjuntos de datos que los incumbentes ya poseen. A su vez, la asociación también le da acceso a una base de clientes grande y existente. Esto es enfatizado aún más por los segmentos de FinTech que están comenzando la transición de puramente B2C a B2B.

Adoptar estrategias de crecimiento efectivas e integrarse con FinTech será esencial para los Bancos para la innovación. La asociación con las empresas de FinTech ha subido del 32% en 2016 al 45% en 2017 año en promedio, pero existen grandes discrepancias por país (PricewaterhouseCoopers, 2017a). A continuación, se puede observar el porcentaje de entidades incumbentes que ya tienen asociaciones con Fintech y lo que esperan tener en los próximos 3 a 5 años.

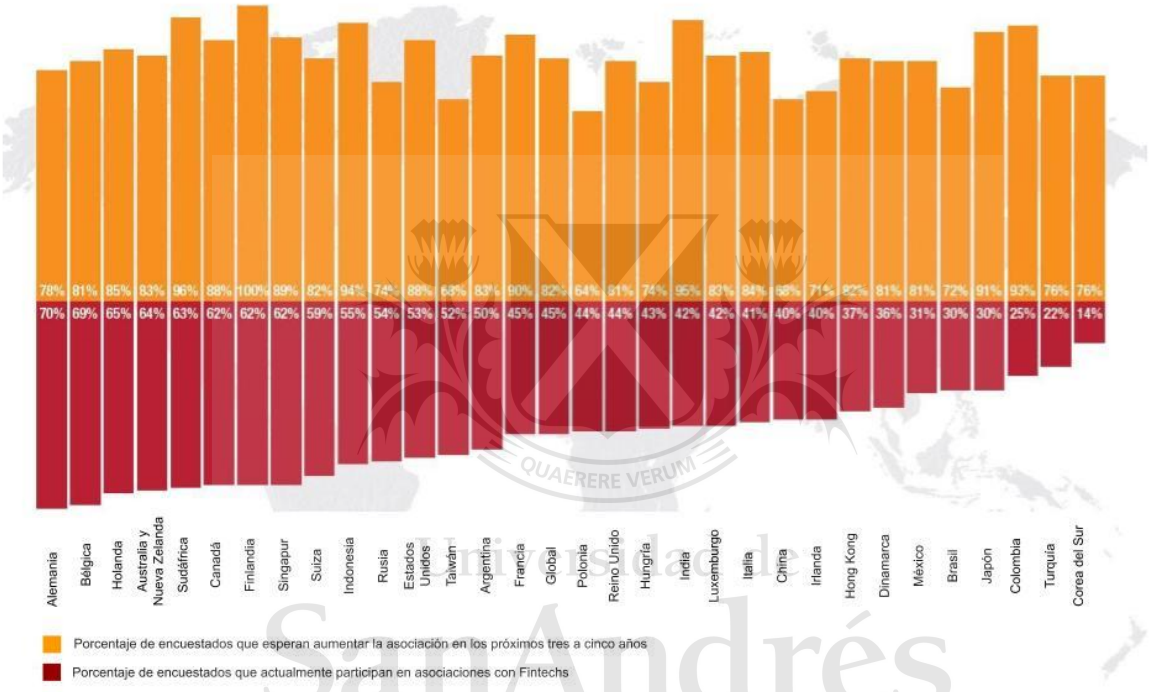

Figura 39. Asociación de Bancos y Fintechs actuales y previstas por País

En la Figura se muestra el porcentaje de encuestados que esperan aumentar las alianzas en los próximos tres a cinco años y el porcentaje de encuestados que actualmente participan en alianzas con empresas de FinTech, por país estudiado. Fuente: Global FinTech Report 2017. Redrawing the Lines: FinTech's Growing Influence on Financial Services, PricewaterhouseCoopers (2017a). Copyright 2017.

En América Latina también se están desarrollando estrategias de colaboración, según lo identificado por el estudio de Anif, Felaban y CAF (2018). El 36% de la muestra está desarrollando estrategias de asociaciones con Fintech; entre tanto, un 29% ha fortalecido sus áreas de innovación, un 21% ha contratado servicios digitales de 'outsourcing' con las 'fintech' y un 9% ha adquirido estas compañías.

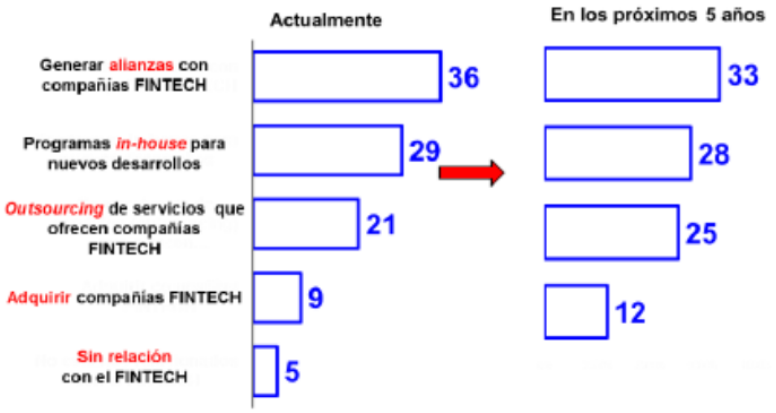

Figura 40. Estrategia de las compañías para enfrentar el desarrollo Fintech

Esta figura muestra en porcentaje de encuestados las estrategias de las compañías en América Latina para enfrentar el desarrollo Fintech tanto en la actualidad como en los próximos 5 años. Fuente: "Los Servicios Financieros Digitales en América Latina" Anif, Felaban &CAF (2018). Recuperada de: http://felaban.s3-website-us-west-2.amazonaws.com/documentos_interes/archivo20181204163600PM.pdf

En el escenario argentino, la colaboración entre incumbentes y Fintech´s se evidencia en la Encuesta Global de Fintech, capítulo Argentina realizada por PricewaterhouseCoopers (2017b), donde la mitad de las organizaciones del sector financiero aseguraron que ya están trabajando o en proceso de asociación con desarrollos tecnológicos Fintech y en los próximos 3 años el 83 % de los encuestados espera participar de alguna asociación con ellas. También es un indicador interesante el que muestra que el 64% prevé adquirir una empresa del tipo Fintech.

Los ejecutivos entrevistados en Argentina opinaron también sobre las actividades en las que ya están operando con empresas Fintech, entre las que destacaron pagos (83%), pero también préstamos personales (66%), finanzas personales (63%) y transferencias de fondos (57%). Asimismo, anticiparon que durante los próximos 5 años las actividades con mayores perspectivas de incrementar sus operaciones a través del segmento Fintech son préstamos personales (61%), pagos (53%) y transferencias de fondos (47%).

Capgemini y LinkedIn (2018), en colaboración con Efma, han realizado el *World Fintech Report* partiendo de una encuesta mundial entre empresas de servicios financieros tradicionales y Fintech de banca y servicios de crédito, pagos y transferencias, gestión de inversiones y seguros. Según este reporte más de 70% de las Fintech colaborarían con la banca tradicional. Señala además que las Fintech identifican entre sus objetivos empresariales principales la colaboración con este

tipo de instituciones, con el fin de construir un servicio que mezcle lo mejor de los dos mundos: agilidad y confianza.

En este reporte se observa que el auge de las Fintech continúa revitalizando la experiencia del cliente en el ámbito de los servicios financieros, sin embargo, muchas de ellas han comprobado que están solas en su batalla para lograr el éxito. Por ello, y debido a las fortalezas complementarias que aportan, las Fintech están cada vez más interesadas en establecer una colaboración simbiótica con las empresas tradicionales de servicios financieros a las que, en su día, pretendían desbancar (Capgemini, LinkedIn & Efma, 2018).

A pesar de que las Fintech han conseguido captar cerca de 110.000 millones de dólares en financiación desde 2009, el informe se detiene en que muchas podrían acabar fracasando si no crean un ecosistema eficaz de colaboración ya que se enfrentan a retos como la expansión a otros mercados, conseguir la fidelidad del cliente y contener los costes operativos de escala. Al mismo tiempo, las entidades financieras tradicionales están adoptando muchas de las mejoras propiciadas por las Fintech en los servicios al cliente, sin descuidar sus fortalezas características como, entre otras, la gestión de riesgos, las infraestructuras, la experiencia en el ámbito regulatorio, la confianza del cliente y el acceso a capital. Ciertamente, Fintech y entidades tradicionales ganarán al unísono con una relación colaborativa y simbiótica (Capgemini, LinkedIn & Efma, 2018). Este informe de Capgemini pone de relieve que la colaboración será esencial para promover el éxito a largo plazo tanto para Fintech como para las empresas financieras tradicionales. Y el éxito en una alianza depende de encontrar al mejor socio y el mejor modelo de colaboración.

Desde el punto de vista de la Fintech la interacción con los nativos digitales (como Google, Microsoft y Amazon Web Services) es indispensable y necesaria, y figuran entre los principales socios colaborativos. Pero también las Fintech encuestadas creen que una mayor colaboración entre las Fintechs y los bancos puede resultar beneficiosa para ambas partes.

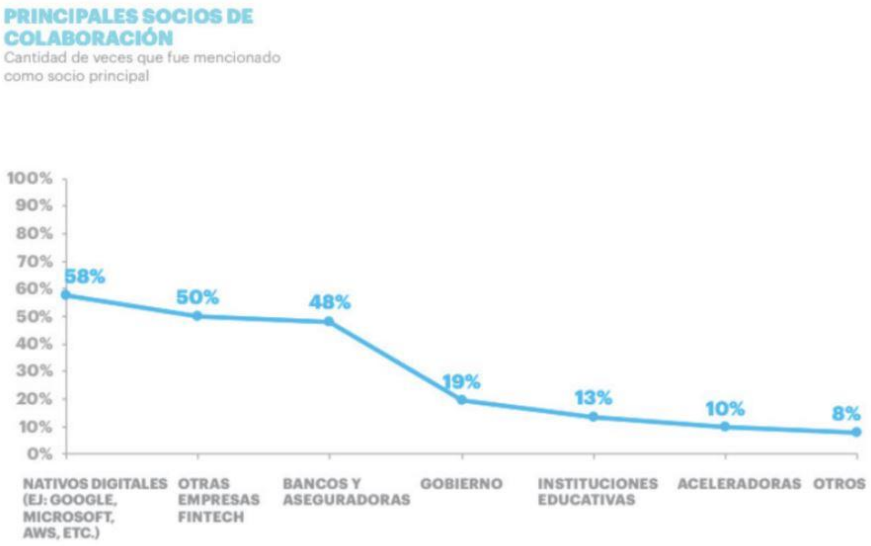

Figura 41. Principales Socios en la Colaboración, perspectiva Fintech

La Figura muestra el resultado de la encuesta realizada a Fintechs que muestra en porcentaje con qué tipo de empresas colaborarían las mismas. Fuente: Informe Ecosistema Fintech Argentino, (Accenture, 2018c). Copyright 2018.

Las formas en que se relacionan los bancos y las Fintech pueden observarse en la siguiente figura:

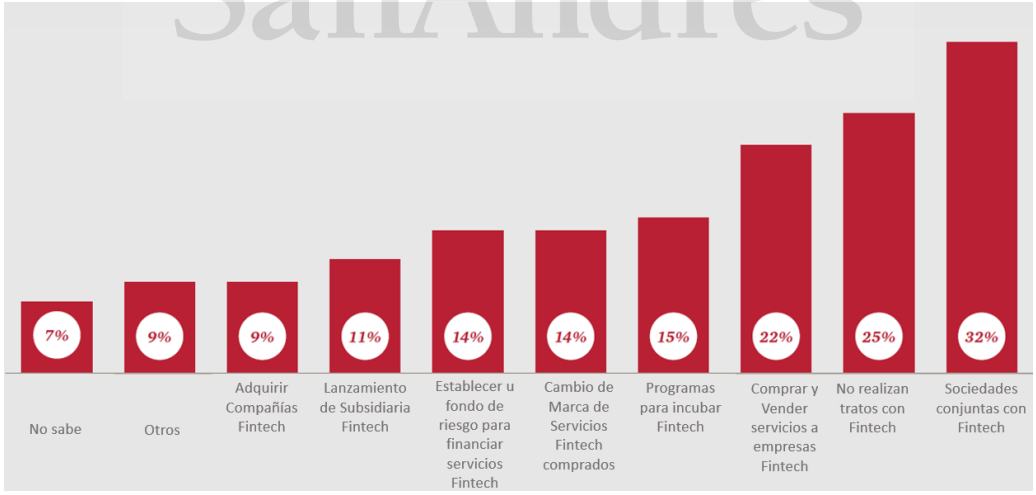

Figura 42. Formas en que las entidades tradicionales interactúan con Fintechs

Fuente: PWC Global FinTech Survey (2016). Copyright 2016. Traducción propia.

Anexo XXVII. Principales barreras para la colaboración

PricewaterhouseCoopers (2017a) presenta los resultados de la encuesta realizada tanto a Fintech como a incumbentes del Sistema Financiero obteniendo las principales barreras para ambas a la hora de trabajar colaborativamente. Desde el punto de vista de los incumbentes los principales desafíos son la seguridad, dudas con respecto a la regulación y las diferencias en la gestión y la cultura. Por el lado de las Fintech los principales desafíos se encuentran alrededor de la regulación, y las diferencias en la gestión y la cultura, coincidiendo con la visión en parte de los incumbentes, pero también las diferencias de modelos de negocio. A continuación, se muestra el resultado total de la encuesta:

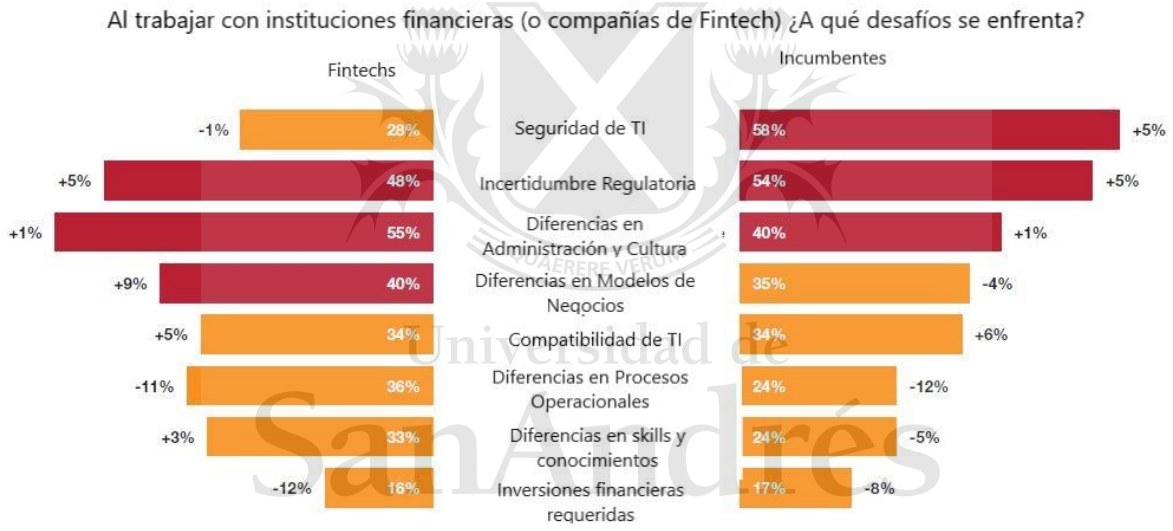

Figura 43. Desafíos en la colaboración para Fintech e Incumbentes

Esta figura muestra los porcentajes por desafío tanto para incumbentes como Fintech. Tradución Propia. Fuente recuperada de: Global FinTech Report 2017. Redrawing the Lines: FinTech's Growing Influence on Financial Services, PricewaterhouseCoopers (2017a). Copyright 2017.

Anexo XXVIII. Potencial Económico de la IA

Según una investigación realizada por PriceWaterhouseCooper (PWC) que mide el potencial económico de la IA, esta podría aportar hasta $ 15.7 trillones a la economía global en 2030, más que la producción actual de China e India combinadas, lo que la convierte en la mayor oportunidad comercial en la economía (Rao & Verweij, 2017). Con respecto a los efectos en términos de mejora de los productos, se espera que casi todo el impacto sobre el PIB derive de una mayor variedad de bienes, así como de incrementos de su calidad.

A continuación, se muestra el resultado del estudio de PWC presentado por Rao y Verweij (2017) donde se puede visualizar el crecimiento de los aportes probables de la IA en los diferentes conceptos.

Figura 44. Impacto del PIB global por efecto de la IA

La figura muestra el probable crecimiento del PIB debido a productividad, personalización, ahorro de tiempo y calidad, medido en trillones de U$S. Recuperada de (Rao & Verweij, 2017) cuya fuente original es la investigación llevada a cabo por PWC.

Como se puede apreciar es probable que U$D 6.6 trillones provengan de una mayor productividad (primera promesa planteada en esta sección). También en el informe de PWC se pronostica que las ganancias derivadas de la demanda del consumidor (segunda promesa) superarán las ganancias provenientes de la productividad, generando un aumento en el PIB de potencialmente más de $ 9.1 trillones (Rao & Verweij, 2017).

En la investigación consultada realizada por Accenture (2017b) con la colaboración de *Frontier Economics* se concluye que las compañías que incorporen IA a sus modelos de negocio podrán ver incrementados sus beneficios en un 38% para 2035. Esta investigación ha comparado las hipotéticas tasas de crecimiento de 16 industrias para 2035, con las tasas de crecimiento estimadas tras integrar IA en los procesos económicos de las compañías. Se tuvo en cuenta para la evaluación el potencial impacto económico de la IA en el valor agregado bruto (VAB) de las corporaciones (aproximación del producto bruto interno que mide el valor generado por los bienes y servicios producidos). El resultado arroja que la IA tiene el potencial de aumentar la tasa de crecimiento en una media ponderada de 1,7 puntos porcentuales y contribuirá a aumentar el VAB en 14 billones de dólares de 16 industrias diferentes, en 12 mercados (EE. UU. y países europeos).

De las industrias analizas en el estudio, las relacionadas con información y telecomunicaciones, producción industrial y servicios financieros son las que presentan un mayor crecimiento del VAB tras la implementación de la IA, con un 4,8%, un 4,4% y un 4,3%, respectivamente, para 2035. Esto se traduce en un incremento de seis billones de dólares en el VAB para 2035 en estos tres sectores. Incluso industrias en las que el capital humano es indispensable, como la educación y los servicios sociales (donde el crecimiento de la productividad suele darse a un ritmo lento) verán un aumento en su VAB. Al examinar la rentabilidad en cada industria, el estudio demuestra que la IA ofrece grandes oportunidades. En sectores como *retail* y distribución, la IA permite a los profesionales ser más productivos, y por tanto contribuye al incremento de los beneficios hasta en un 60%. En los sectores intensivos en capital, como la fabricación industrial, la maquinaria impulsada por IA permitirá eliminar tanto los dispositivos defectuosos como el equipamiento inactivo. Esto contribuirá a incrementar las tasas de retorno, de manera que los beneficios aumenten en un 39% para 2035.

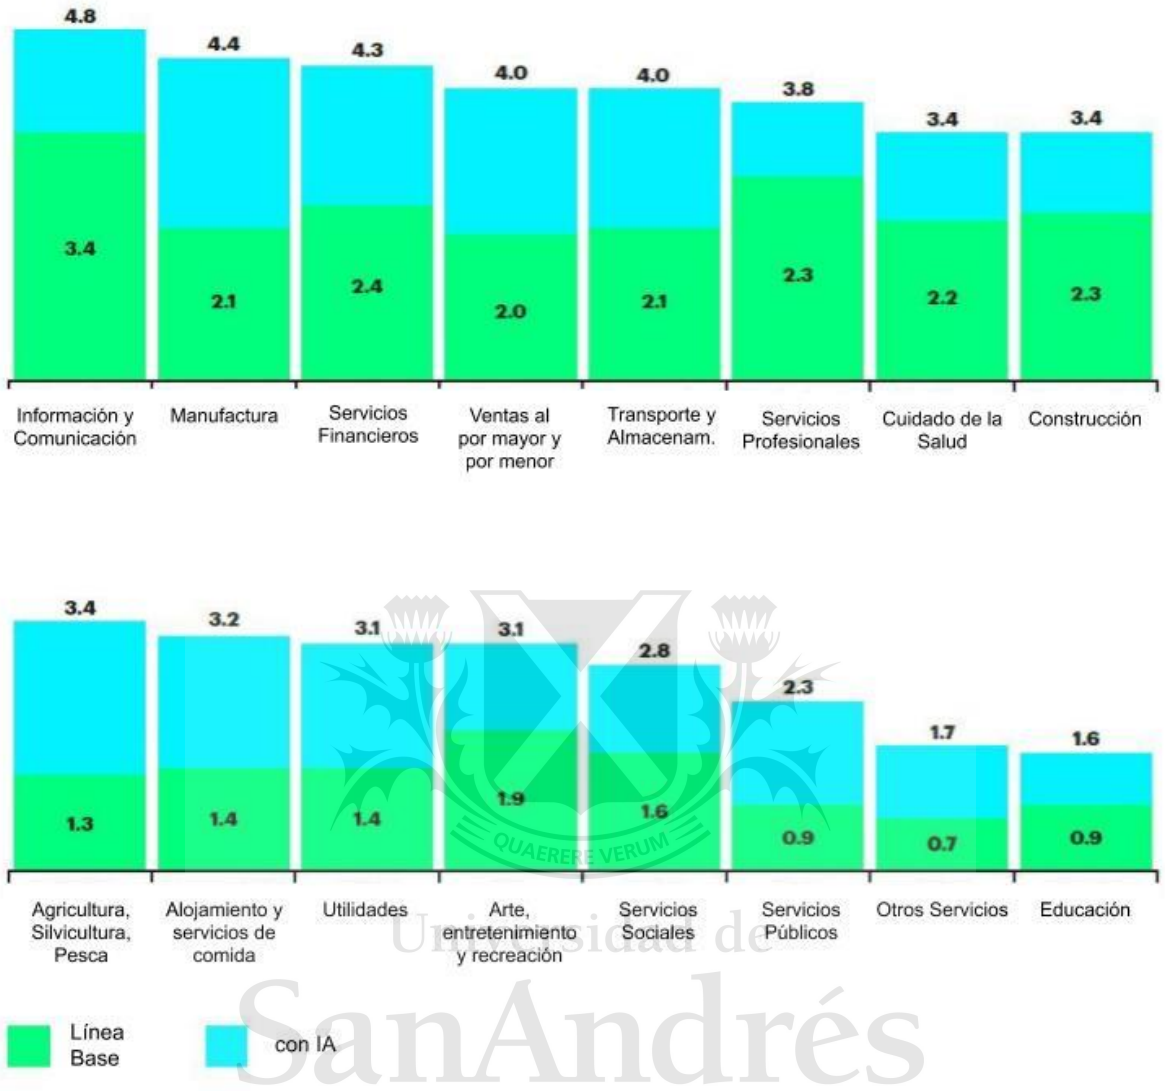

Figura 45. Impacto de IA en el crecimiento de la industria por industria.

Esta figura muestra el Crecimiento anual real del VAB para 2035 en porcentaje (%) donde se muestra que la IA tiene el potencial de aumentar las tasas de crecimiento económico en un promedio ponderado de 1.7 puntos porcentuales para 2035 en 16 industrias. Fuente: Accenture (2017b) obtenido de la investigación llevada a cabo por Accenture Research y Frontier Economics. Copyright 2017. Recuperado de: https://www.accenture.com/_acnmedia/PDF-84/Accenture-AI-Industry-Growth-Full-Report.pdf

También el estudio consideró el aumento de la participación en las ganancias por industria entre el nivel de referencia en 2035 y el estado estacionario de IA en 2035 (%)

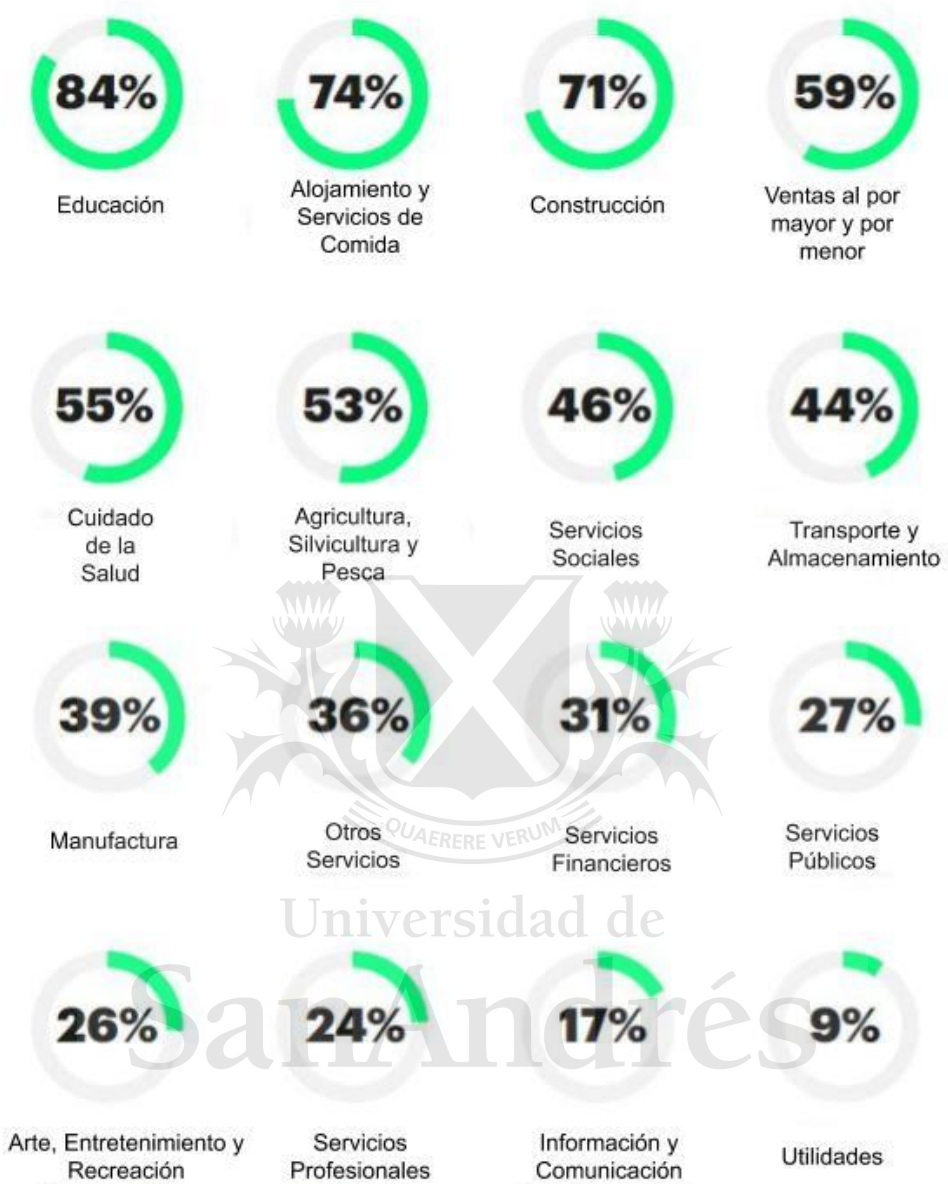

Figura 46. Impacto de IA en las ganancias por Industria.

Esta figura muestra el aumento de la participación en las ganancias por industria entre el nivel básico en 2035 y el estado estacionario de IA en 2035 (%). Fuente: Accenture (2017b) obtenido de la investigación llevada a cabo por Accenture Research y Frontier Economics. Copyright 2017. Recuperado de: https://www.accenture.com/_acnmedia/PDF-84/Accenture-AI-Industry-Growth-Full-Report.pdf

Anexo XXIX. Potencial Económico de IA en América Latina

Mirando América Latina, la IA podría ayudar a revertir la desaceleración económica de América Latina (CEPAL, 2018a).

En la investigación llevada a cabo por Accenture, en colaboración con *Frontier Economics* (2017b) para comprender el valor de la IA como un nuevo factor de producción, se modeló el impacto potencial de la IA en cinco economías que juntas generan un 85% del producto económico de América del Sur, Argentina, Brasil, Chile, Colombia y Perú. Se descubrió que al igual que en el resto de los países del mundo analizados, la IA tiene el potencial de añadir un punto entero de porcentaje a las tasas anuales de crecimiento económico en la región hacia 2035. Es decir que hay oportunidades destacables para la creación de valor. Para estimar el potencial económico de la IA se compararon dos escenarios para cada país. El primero es la línea de base, que muestra la tasa de crecimiento económico anual esperada bajo los supuestos actuales acerca del futuro. El segundo es un escenario con IA, que muestra el crecimiento económico esperado una vez que el impacto de la IA haya sido absorbido por la economía. La IA produce los beneficios económicos más altos en términos absolutos en Brasil, cuyo valor agregado bruto (VAB) culminaría con US$ 432.000 millones adicionales en 2035. La IA también podría hacer que Chile y Perú incrementen su VAB en un punto porcentual en 2035. Por su parte, Colombia podría obtener una expansión adicional de 0,8 puntos porcentuales. Las comparaciones entre países ocultan el impacto significativo que la IA podría tener sobre las economías aparentemente rezagadas. Por ejemplo, se espera que, para 2035, la IA aumente la tasa de crecimiento de Argentina del 3,0% al 3,6%. Esto implica que, de los cinco países, Argentina sería el que recibiría el impulso más moderado debido a la IA, pero incluso esta contribución relativamente modesta sigue siendo de una magnitud importante: se trata de cerca de US$ 59.000 millones adicionales de VAB, que llevarían a un VAB total de US$ 702.000 millones en 2035. En general, se espera que la IA redunde en beneficios extraordinarios en los distintos países y posibilite comenzar un periodo de crecimiento económico más alto y más duradero.

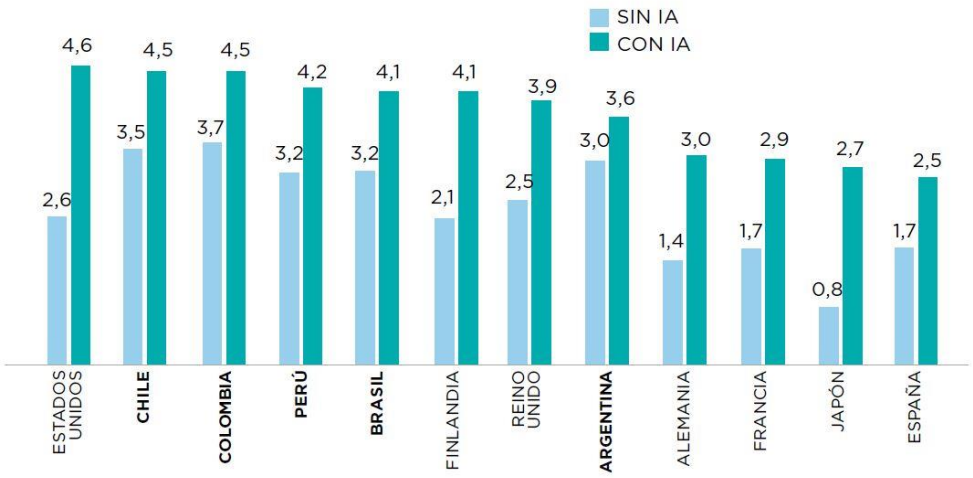

Figura 47. Impacto Económico de la IA en América Latina

La figura muestra el crecimiento del VAB en distintos paises medidos en porcentuales (%), donde se pueden identificar los 5 países de Latinoamérica estudiados. Figura recuperada de (Estevadeordal et al., 2018) donde se menciona el estudio de Accenture y Frontier Economics llevado a cabo en 2017).

Según este informe, América Latina ya toma la IA de forma seria. Tanto los líderes empresariales como los consumidores muestran un fuerte interés por usar las herramientas y capacidades de la IA. Un dato muy interesante para la investigación que se desarrolló lo aportó una encuesta también realizada por esta reconocida consultora donde descubrió que el 83% de los consumidores de servicios financieros de Brasil confiarían en un asesoramiento bancario completamente generado por una computadora (Accenture, 2017c).

Anexo XXX. Potencial Económico de IA en Argentina

En el caso de la Argentina, Albrieu et al. (2018) en su estudio para la CIPPEC (Centro de Implementación de Políticas Públicas para la Equidad y el Crecimiento), desarrollaron tres escenarios alternativos de adopción de IA para evaluar el posible impacto en Argentina para los próximos diez años. Los principales resultados del trabajo muestran las tasas de crecimiento anual promedio del PBI para Argentina en los próximos 10 años según los tres escenarios futuros posibles planteados.

Para medir la capacidad de adopción tecnológica y de innovación de una economía usaron el principal indicador disponible denominado "Productividad Total de los Factores" o PTF. La PTF mide la parte del nivel de actividad que no es explicada directamente por cuánto trabajo o capital se utiliza en el proceso productivo sino por cómo se utilizan dichos factores productivos. Así, la principal fuente de crecimiento de la productividad que tiene una economía es la adopción de nuevas tecnologías que potencien la capacidad productiva del trabajo y del capital existente, así como su capacidad de innovar.

El escenario negativo planteado en este estudio refleja un deterioro con respecto a la tendencia histórica de adopción y difusión de tecnologías. Supone que no existe adopción de IA y, por lo tanto, el crecimiento económico no se ve afectado por ninguno de los dos efectos mencionados. Se asume que, a diferencia de lo que ocurrió durante la tercera revolución industrial con las TIC, no hay automatización de tareas a lo largo del período considerado y que la evolución de la PTF se mantiene sin cambios en relación a la trayectoria observada en el pasado. El segundo escenario es un escenario neutral, y representa continuidad, y asume que Argentina absorbe las tecnologías asociadas a la IA al mismo ritmo que lo hizo con las TIC durante la tercera revolución industrial. En el modelo elaborado a propósito del ejercicio, el escenario se representa con un efecto de automatización suave que acelera el crecimiento económico, pero sin efecto de innovación. Esto último implica que el comportamiento de la PTF se asume igual al del escenario anterior, vale decir, sin cambios con respecto a la trayectoria pasada. El tercer escenario, es uno positivo que asume una adopción y difusión de IA en Argentina muy superior a lo ocurrido durante la tercera revolución industrial con las TIC. En el modelo, se representa con un Efecto Automatización que es un 50% superior al ocurrido con las TIC y un Efecto Innovación que genera

la mitad del crecimiento de la PTF que lograron las economías de Asia emergente durante la tercera revolución industrial.

El escenario negativo (con cero adopciones de IA) implicaría una caída del ritmo de crecimiento, desde 3,0% anual observado como tendencia histórica desde 1990 a 2,0% en la próxima década. El escenario neutral muestra una tasa de crecimiento anual promedio de 3,7%. Esta tasa se encuentra algo por encima del promedio histórico. Por último, el escenario positivo muestra una aceleración muy marcada del ritmo de crecimiento económico: el crecimiento se incrementa a 4,4% por año hasta 2028. Esto se puede visualizar en la siguiente figura.

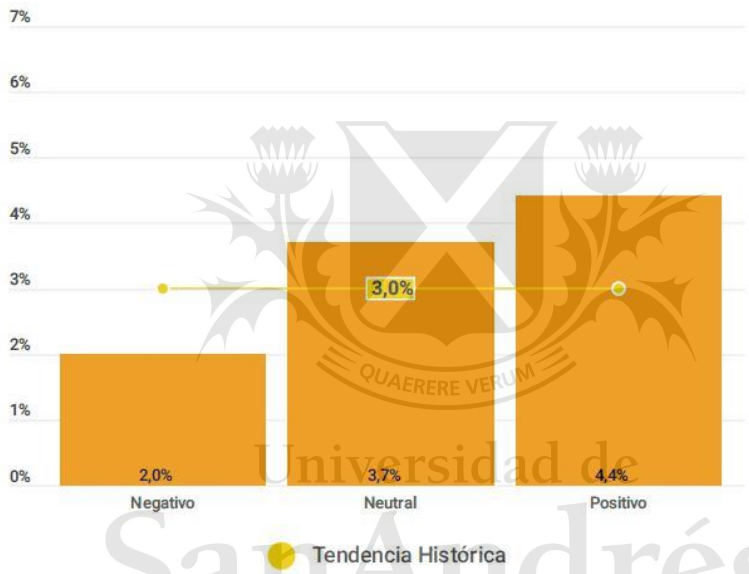

Figura 48. Escenarios de Adopción de IA en Argentina

La Figura muestra las tasas de crecimiento anual promedio del PIB en Argentina para los 3 escenarios planeados por Albrieu et al. (2018). Recuperado de: https://www.cippec.org/wp-content/uploads/2018/11/ADE-ARG-vf.pdf

El estudio también muestra las tasas de crecimiento anual promedio de la producción de cada sector para los próximos diez años para los tres escenarios. El resultado principal es que en todos los sectores estudiados el impacto de la adopción de IA es potencialmente alto. Cualitativamente los resultados no difieren de aquellos que se aprecian a nivel agregado. A nivel sectorial, no se aprecian impactos diferenciales marcados de la absorción de IA en los diferentes sectores. La tasa de crecimiento promedio resulta superior al 4% en el escenario positivo, entre 2,9% y 3,7% para el neutral y 0,8% y 2,6% para el caso negativo. En el caso de los servicios

financieros, se identifica que hay un crecimiento de 2,5% para el escenario negativo, 3,7 % para el escenario neutral y 4,1 % para el positivo.

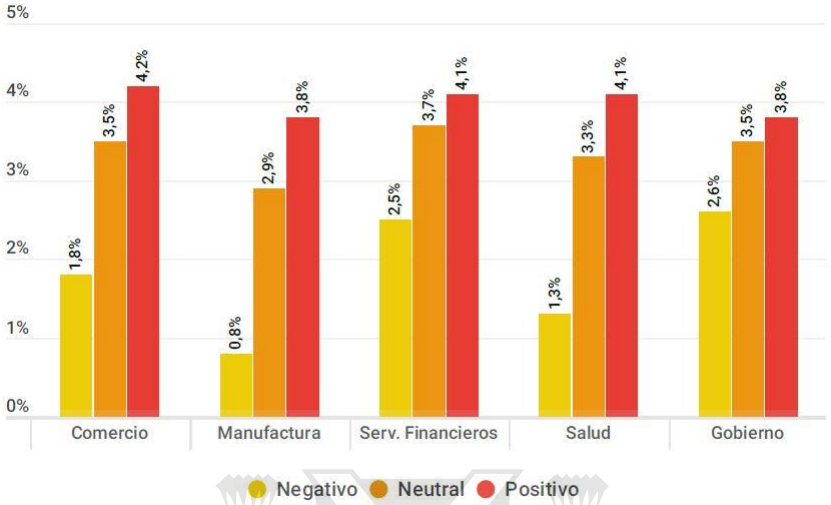

Figura 49. Escenarios de Adopción de IA en Argentina por Sector

La Figura muestra las tasas de crecimiento anual promedio de la producción de cada sector para los próximos diez años para los 3 escenarios planeados por Albrieu et al. (2018). Recuperado de: https://www.cippec.org/wp-content/uploads/2018/11/ADE-ARG-vf.pdf

QUAERERE VERUM
Universidad de
SanAndrés

Anexo XXXI. Mapa de calor de áreas con potencial de IA

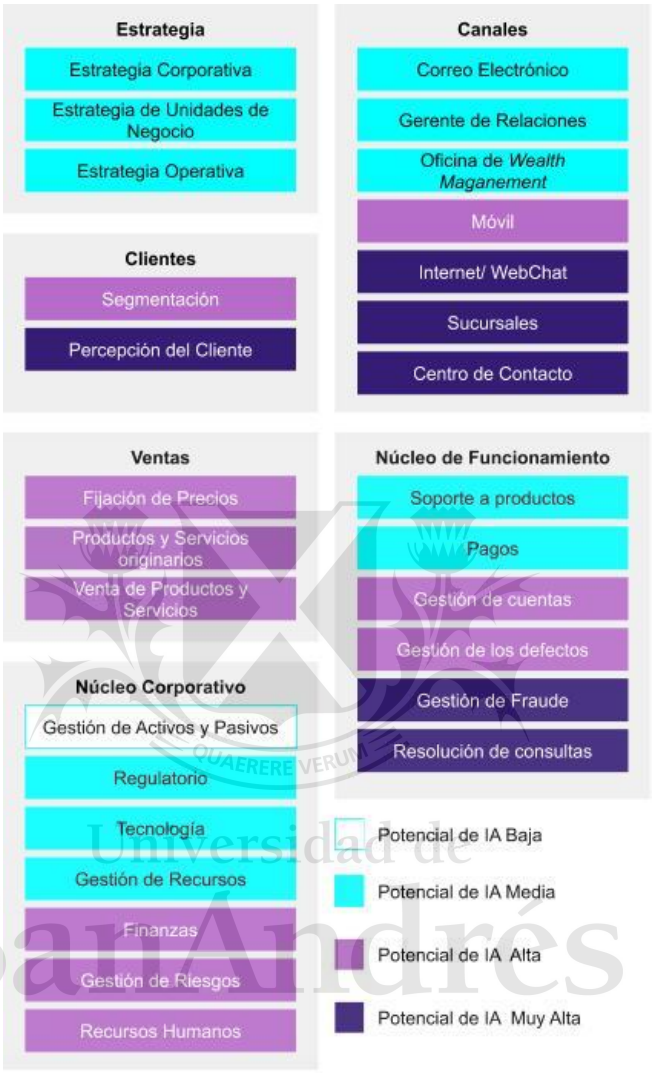

Figura 50. Mapa de Calor de áreas bancarias con potencial para la IA

La figura muestra diferentes áreas de Bancos, y donde la IA puede tener bajo, medio, alto y muy alto potencial. Recuperada de: https://www.accenture.com/_acnmedia/PDF-68/Accenture-Redefine-Banking.pdf.Copyright 2018.

Anexo XXXII. Áreas de Entidades Bancarias donde la IA puede apoyar

A continuación, se presenta las áreas de Entidades Bancarias donde la IA puede apoyar según King (2018).

Tabla 11. Áreas de Entidades Bancarias donde la IA puede apoyar

Area Organizacional	***Competencia de IA***	***Drivers de Adopción***
Cumplimiento Regulatorio	Machine / Deep Learning	Regulatorio, Costo
Mejora Tecnológica	Varios	Ahorros, presión del lado de la oferta
Avances en infraestructuras	Cognitiva, Machine Learning	Competencia, Economice
Marketing / sentimiento / marca	NLP, Machine Learning	Competencia, sensibilidad
Onboarding/adquisición	NLP, Machine Learning	económico
Señales de Trading	Machine Learning	Económico
Prevención de Blanqueo de Capitales / Prevención de fraudes	Machine Learning	Regulatorio, económico
Credit Scoring / Evaluación de Riesgos	Machine / Deep Learning	Competencia, comportamiento
Fijación de Precios	Machine Learning	Económico, rentabilidad
Administración de Portfolio	Machine Learning	Desempeño, productividad, consistencia
Optimización de Back Office	Cognitiva, Deep Learning	Economico, demanda
Trading Algoritmico	Machine Learning	Competencia
Análisis de Datos / Personalización	Data Modelling, Deep Learning	Competencia, Oferta

Traducción propia basada en (King, 2018).

Anexo XXXIII. Desafíos de las organizaciones para implementar nuevas tecnologías

Nieponice et al. (2018) muestra los resultados del trabajo realizado por Boston Consulting Group junto con la Secretaría de la Transformación Productiva del Ministerio de Producción de Argentina cuyo objetivo era conocer el progreso en la implementación de nuevas tecnologías en sus procesos productivos y los desafíos más importantes que encuentran a la hora de ejecutar esta transformación. Para realizar este informe se realizó una encuesta online a 78 ejecutivos de 66 grandes empresas industriales argentinas de diferentes sectores económicos. En el mismo los ejecutivos encuestados destacan como principales obstáculos la falta de personal calificado, la incertidumbre respecto al impacto de las inversiones en las ganancias de la compañía y la resistencia al cambio y a la innovación. A continuación, se puede visualizar el resultado de dicha encuesta.

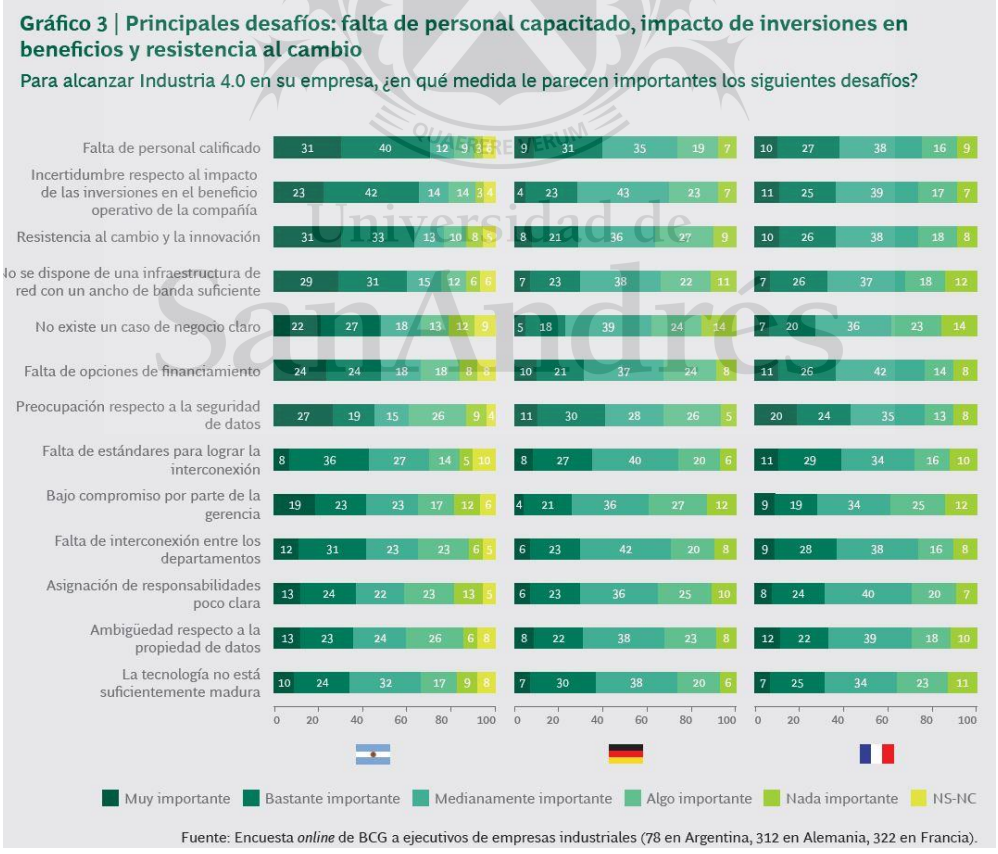

Figura 51. Principales desafíos de las empresas para implementar las nuevas tecnologías

La figura muestra el resultado de las encuestas posicionando los factores que constituyen desafíos para las empresas para la implementación de nuevas tecnologías. Recuperado de Fuente: Nieponice et al. (2018) obtenido a de la encuesta realizada a 78 ejecutivos de empresas de Argentina. Copyright 2018.

Más del 70% de los ejecutivos encuestados coincide en que la falta de personal capacitado es un desafío relevante para alcanzar Industria 4.0 en Argentina. Esta es una problemática que comparten las empresas en todo el mundo: en Alemania y Francia, por ejemplo, la disponibilidad de capital humano se encuentra en los puestos más altos de la lista de los principales desafíos (Nieponice et al., 2018). Otros retos, que coinciden con la etapa inicial en la que se encuentra el país, en el camino a implementar las tecnologías de la Industria 4.0, es que el 65% de las empresas argentinas considera que la incertidumbre respecto al impacto de las inversiones en el resultado operativo es un desafío importante, en contraste con el 27% en Alemania y el 36% en Francia.

QUAERERE VERUM
Universidad de
SanAndrés

Anexo XXXIV. Tipos de Opacidad de Datos

Según Burrell (2015) en el contexto de las nuevas tecnologías de datos, se pueden identificar tres tipos de opacidad:

(i) la opacidad intencional, es la que ocurre cuando, por ejemplo, un algoritmo no es transparente por motivos relacionados con la propiedad intelectual (el motor de búsqueda de Google, por ejemplo), o cuando la revelación de su funcionamiento pudiera llevar a su irrelevancia (en la detección de evasión de impuestos, por ejemplo);

(ii) la opacidad analfabeta, es la que ocurre debido a la falta de competencias técnicas de las personas potencialmente afectadas para entender el funcionamiento de los algoritmos y los modelos de aprendizaje automático, en este caso, aunque un algoritmo sea explicable, si este es comprensible solo para aquella población dotada de altas capacidades técnicas, la confianza necesaria entre los actores involucrados puede disminuir. En consecuencia, la transparencia formal no sería aconsejable en el desarrollo;

(iii) y por último, la opacidad intrínseca, que surge de la dificultad de explicar los procesos algorítmicos en los que participan redes neuronales complejas. En los casos de AA, un sistema algorítmico puede realizar tal cantidad de cálculos que en algunas situaciones ni siquiera sus creadores logran explicar cómo llegó el sistema a una solución o cálculo determinado.

Universidad de SanAndrés

Anexo XXXV. Crecimiento de Requerimientos de puestos de trabajo de IA y AA

El proyecto del "Estudio de cien años sobre la IA" de la Universidad de Stanford, el Índice IA es un proyecto abierto, sin fines de lucro, para rastrear la actividad y el progreso en la IA, evidencia el crecimiento de requerimientos de puestos de trabajo en IA y AA. La proporción de trabajos que requieren habilidades de AA por ejemplo ha aumentado hasta 6 veces en EE. UU. cómo se puede ver a continuación.

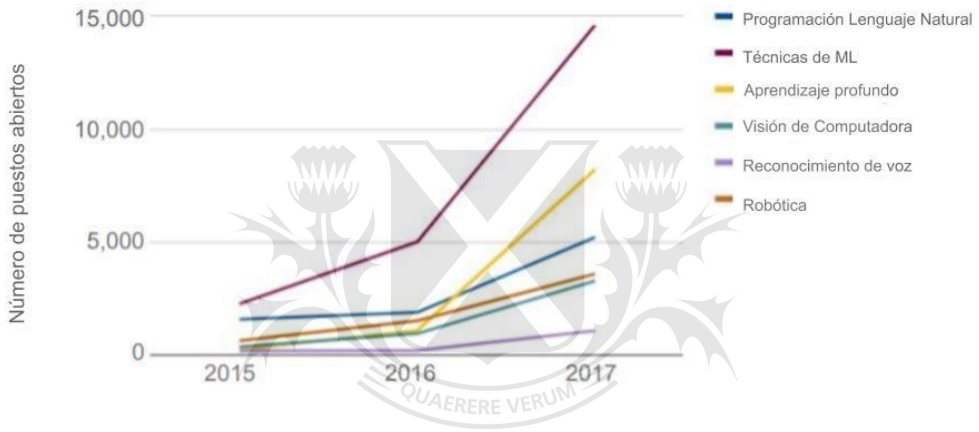

Figura 52. Crecimiento de Ofertas de trabajo requeridas con habilidades de IA

Esta figura muestra la evolución de la cantidad de ofertas de trabajo con *skills* de IA desde 2015 a 2017. Recuperada de (Bauer et al., 2018). Copyright 2018. Traducción propia.

Anexo XXXVI. Nuevos puestos de trabajo de la banca en el futuro

King (2018) presenta nuevos puestos de trabajo que se considerarán críticos en el crecimiento de los ingresos y la capacidad de los servicios financieros durante los próximos cinco años. Estos puestos son:

- Científico de Datos: que son una nueva generación de analistas y arquitectos de datos que tienen las habilidades técnicas para resolver problemas complejos y responder preguntas importantes. Generalmente se encuentran explorando exactamente qué problemas deben resolverse, en función de dónde los llevan los datos. Son parte matemático, parte científico informático y parte detector de tendencias. Se sientan entre los negocios y los mundos de TI.
- Especialista de AA, que son especialistas en programación, arquitectos y modeladores que construyen sistemas utilizando algoritmos de vanguardia. Diseñan algoritmos de AA, datos de origen, capacitan, evalúan e implementan modelos de AA y trabajan para desarrollar capacidades de procesamiento predictivo y cognitivo. La capacidad para probar sistemas rápidamente y desplegarse a escala rápidamente es clave.
- Diseñador de Experiencia, que son narradores de historias pueden colocar el banco y su utilidad en la vida de los clientes a través de la tecnología. Miran aspectos del diseño como la interacción y el diseño de la interfaz, la creación rápida de prototipos y la facilidad de uso para desarrollar un compromiso altamente convincente y de baja fricción. La capacidad de pensar de manera diferente, sortear los procesos y políticas existentes y desafiar a la organización es clave.
- Psicólogos de comportamiento, que son los capaces de entender cómo reaccionará una persona, qué modelos de comportamiento aplicarán en ciertos escenarios y el uso de activadores conscientes y subconscientes para identificar los comportamientos.
- Programador de Cumplimiento y Riesgo que integrará el trabajo con los reguladores que también deberán implementar sistemas similares, por lo que la IA del banco hablará con la IA del regulador.
- Defensor de la comunidad, que buscará ubicar la nueva experiencia en los mejores lugares para obtener la tracción y la escala más rápidas. Observa las tendencias de los consumidores, el efecto de la red y las tecnologías emergentes para ver dónde el banco necesita ser más activo en el futuro para atraer a los clientes, al igual que los planificadores

solían mirar el tránsito peatonal y los flujos de vehículos en una ciudad para decidir dónde se necesitaba una sucursal estar físicamente situado.

- Los agentes de identidad, las entidades no bancarias tendrán mucha mejor identidad, heurística, biometría e información de comportamiento que la de los bancos, por lo que se necesitan agentes para identificar a los clientes de manera precisa y en tiempo real. Los agentes de identidad construirán los nuevos sistemas de verificación de identidad que reemplazarán a los procesos actuales.

QUAERERE VERUM
Universidad de
SanAndrés

Anexo XXXVII. Impactos Positivos y Negativos de las nuevas tecnologías en los objetivos regulatorios

A continuación, se presenta el detalle por cada objetivo regulatorio, sus impactos positivos y negativos (UNSGSA FinTech Working Group & CCAF, 2019).

Tabla 12. Impactos positivos y Negativos de las nuevas tecnologías en los objetivos regulatorios.

Objetivos Regulatorios	***Impactos Positivos***	***Impactos Negativos***
Estabilidad Financiera	La mayor diversificación de la base de depósitos y las carteras de préstamos puede reducir la concentración entre las instituciones financieras sistémicas La calidad mejorada de los datos y la agregación de datos de riesgo pueden aumentar la resiliencia sistémica.	El aumento de la interconexión financiera puede dar lugar a shocks financieros adversos acelerados. El aumento de los riesgos operativos, como los riesgos cibernéticos, puede aumentar el riesgo sistémico.
Integridad Financiera	Promover la trazabilidad de las transacciones, apoyando la lucha contra la financiación del terrorismo Facilitar la verificación más fácil para el proceso de conocimiento de los clientes, reduciendo así los costos de cumplimiento. Uso de tecnología de los reguladores para apoyar la integridad financiera.	
Protección al Cliente	Mayor transparencia y más y mejor información para los consumidores, reduciendo las asimetrías de información. Comparación de productos y servicios financieros de forma más rápida y sencilla.	Transparencia limitada de tarifas y cargos, lo que puede inducir a error en los consumidores. Sobreendeudamiento debido a la falta de visibilidad de los múltiples préstamos digitales de cada prestatario. Falta de protección de datos, lo que lleva al mal uso de los datos del cliente.
Inclusión Financiera	Costos más bajos y más eficientes que los sistemas tradicionales y / o informales. Acceso al crédito a través de fuentes de datos alternativas para los que no cuentan con servicios bancarios o son subbancarizados. Simple, más confiable y significativamente más rápido que los métodos informales.	La microsegmentación de riesgos mediante el uso de análisis de Big Data puede llevar a la exclusión financiera. Tasas de endeudamiento elevadas en préstamos digitales, lo que dificulta el reembolso total. Sesgo de género y / o desigualdad en el ingreso por el uso de IA, AA y análisis de Big Data

Traducción propia basada en UNSGSA FinTech Working Group & CCAF (2019).

Universidad de SanAndrés

Anexo XXXVIII. Enfoques Proactivos: Oficinas de Innovación, Sandbox Regulatorio y RegTech

A nivel internacional, algunas autoridades financieras han avanzado en el enfoque proactivo y han establecido iniciativas especiales que facilitan la adopción de innovaciones en tecnología financiera. En general, existen tres tipos de iniciativas facilitadoras.

La primera de ellas son las Oficinas de Innovación (por ejemplo, los Innovation Hubs) que brindan orientación y retroalimentación sobre las implicaciones regulatorias de las innovaciones. Son a menudo el primer paso en el camino de la innovación regulatoria, dado su papel de facilitador del compromiso entre el regulador y el innovador. Pueden mejorar la comprensión de la innovación financiera basada en la tecnología y respaldar las respuestas regulatorias apropiadas. Pueden reducir la incertidumbre regulatoria y señalar una postura pro-innovación. La segunda es la Experimentación Regulatoria (Regulatory Sandbox/Lab) que se trata de un régimen regulatorio especial en donde se flexibilizan algunos aspectos para que las innovaciones se experimenten y prueben en un entorno seguro, con límites y restricciones claras, incluyendo salvaguardas para los consumidores. Y por último lo que se conoce como RegTech que se enfoca en cómo monitorear y hacer cumplir las regulaciones pertinentes. RegTech puede respaldar una entrega más responsable de servicios financieros innovadores. También permite a los reguladores responder rápidamente a los desarrollos del mercado, proteger mejor a los consumidores y mejorar la supervisión institucional. Las soluciones RegTech se están desplegando en economías emergentes y en desarrollo (UNSGSA FinTech Working Group & CCAF, 2019).

Enfrentados a todos estos factores, los reguladores han implementado iniciativas regulatorias que buscan garantizar que la innovación financiera fortalezca sus objetivos de política regulatoria, y mitigue los posibles efectos de los impactos negativos. Todos estos factores generan una dinámica que se puede ver a continuación.

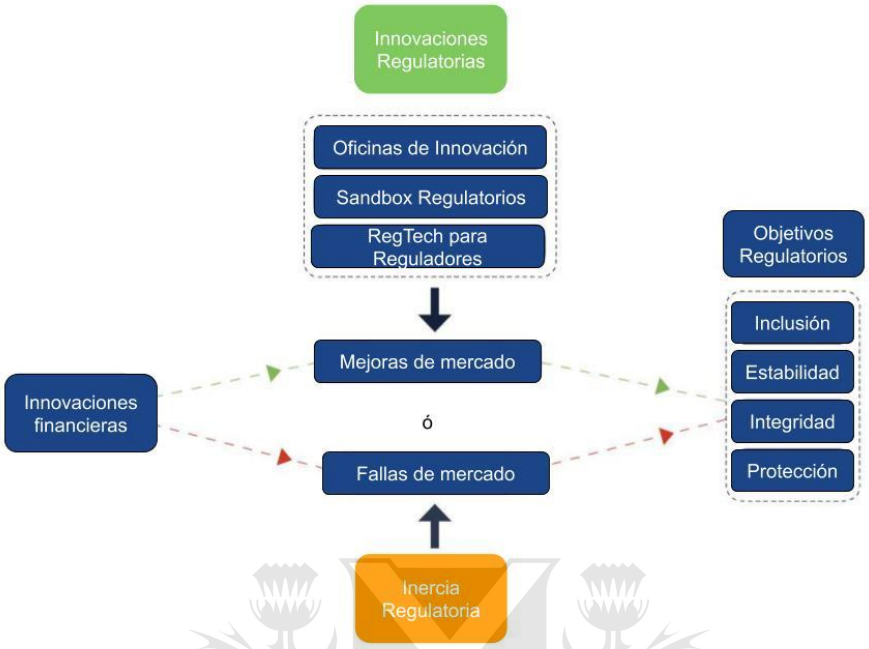

Figura 53. Framework de Innovación Regulatoria

Esta figura muestra la dinámica entre los tipos de iniciativas regulatorias para la innovación, las innovaciones financieras que mejoran o no el mercado y los objetivos regulatorios. Fuente: UNSGSA FinTech Working Group & CCAF (2019). Copyright 2018. Traducción propia.

Las iniciativas innovadoras de regulación se han vuelto cada vez más comunes en todo el mundo en los últimos cinco años. La figura 54 a continuación ilustra los países que han desarrollado tales iniciativas.

Figura 54. Tipos de Iniciativas Innovadoras de Regulación por país

La figura muestra en aquellos países que tienen alguna incitativa de innovación regulatoria el tipo de la misma si es una Oficina de Innovación, UN Sandbox regulatorio o REgtech. Fuente: UNSGSA FinTech Working Group & CCAF (2019). Copyright 2018.

Los nuevos modelos de negocios, productos y servicios de FinTech plantean dudas sobre si deben regularse y cómo deben ser regulados. Estos problemas son particularmente agudos en las economías emergentes y en desarrollo donde los reguladores a menudo tienen una capacidad y recursos limitados. Las autoridades deben equilibrar cuidadosamente las oportunidades y los riesgos que presenta la innovación financiera para los objetivos regulatorios (UNSGSA FinTech Working Group & CCAF, 2019). En la Figura 54 se puede ver a países de América Latina y África mayoritariamente sin iniciativas formales y/o concretas de Oficinas de Innovación, Sandbox regulatorio o RegTech.

Algunas jurisdicciones han establecido oficinas de innovación como un primer paso en el camino de la innovación regulatoria. Las oficinas de innovación pueden tener diferentes nombres, formas y funciones, pero todas se comprometen y brindan aclaraciones reglamentarias a los proveedores de servicios financieros que buscan ofrecer productos y servicios innovadores. Varios

reguladores también han lanzado aceleradores FinTech. Los aceleradores suelen proporcionar o facilitar la tutoría, espacios de trabajo, consultas con expertos de la industria (incluso sobre regulación), oportunidades de redes y acceso a financiamiento (UNSGSA FinTech Working Group & CCAF, 2019)

Con respecto a los Sandboxes, son ampliamente utilizados en diferentes entornos como el informático, pero la experiencia de ellos en el sector financiero es relativamente reciente (Herrera & Vadillo, 2018). Los *Sandboxes* facilitan un espacio que promueve el diálogo con las empresas y permite entender cómo funcionan estos negocios desde sus primeras etapas. De esta forma se podrían identificar rápidamente los aspectos más complejos y adoptar medidas que maximicen los beneficios que ofrecen las FinTech, en un ambiente protegido y con riesgos controlados.

Por definición, los *Sandboxes* regulatorios son entornos para probar nuevas ideas, por lo que podrían aplicarse en cualquier sector tanto para empresas nuevas como para incumbentes ya reguladas. Pueden facilitar un espacio de experimentación y aprendizaje, abierto a cualquier entidad que ofrezca productos o soluciones técnicas originales, en cualquiera de los segmentos de la industria FinTech. Asimismo, entidades previamente reguladas podrán participar en el *Sandbox* poniendo a prueba y buscando aprobación para productos que previamente no existían o no tenían licencia.

Aunque en la práctica internacional existen diferentes enfoques, en general los parámetros concretos del período de pruebas (duración, productos, clientes, importes, mecanismos de cobertura de pérdidas, entre otros) se determinan caso a caso entre el supervisor y las empresas, teniendo en cuenta las actividades realizadas y sus riesgos. En otros modelos, como por ejemplo el australiano, la autoridad supervisora fija criterios generales, y la participación en el *SandBox* está abierta a cualquier entidad que pueda cumplirlos. Una vez concluidos, a la vista de los resultados obtenidos, los supervisores y reguladores pueden evaluar los riesgos asociados a las nuevas actividades. En caso de que los productos o servicios probados se consideren adecuados para los clientes, se podría proponer una regulación y autorizar su comercialización a gran escala. Por el contrario, si las deficiencias detectadas durante su funcionamiento no son resueltas adecuadamente o se considera que conllevan excesivos riesgos, las autoridades podrían prohibir o limitar dichas actividades. Estos tipos de iniciativas regulatorias ofrecen un entorno en el que las entidades pueden probar productos o servicios novedosos, dentro de un ámbito limitado, antes de ofrecerlos de forma masiva en el mercado, al tiempo que el supervisor puede vigilar su

funcionamiento. Se trata de un enfoque flexible, que permite ofrecer soluciones individualizadas e ir realizando modificaciones o ajustes, por lo que constituye una herramienta idónea para entender el funcionamiento de sectores disruptivos y enormemente dinámicos (Herrera & Vadillo, 2018).

En particular el gobierno del Reino Unido es visto como una referencia de enfoque activo de tipo *Sanbox* ya que se han producido los avances más concretos en la nueva regulación de las Fintech (Herrera & Vadillo, 2018; Rojas 2016). Esta experiencia puede servir de punto de partida para propuestas similares en América Latina y el Caribe. Su puesta en práctica debería tomar en consideración las particularidades de cada mercado y de las entidades que ofrecen servicios financieros en ellos (Herrera & Vadillo, 2018).

La Unión Europea es otro ejemplo de enfoque activo. En 2016 aprobó una directiva (PSD2) que, al igual que en el Reino Unido, obliga a los bancos a abrir su plataforma de APIs para las Fintech en 2017.

En el caso de América Latina el que ha dado el primer paso en cuanto a regulación abierta a la innovación es México. El 9 de marzo de 2018, el Poder Ejecutivo, a través de la Secretaría de Hacienda y Crédito Público (SHCP) y la Comisión Nacional Bancaria y de Valores (CNBV), el Congreso de la Unión y el Banco de México, con la participación de múltiples emprendedores y de la banca, se promulgó la Ley para las Instituciones de Tecnología Financiera, la primera ley especializada en la materia a nivel regional. Esta Ley tiene como principios la promoción de la inclusión financiera y la competencia, la protección del consumidor, la preservación de la estabilidad financiera y la prevención de las operaciones ilícitas. De acuerdo con la Ley Fintech de México, un "Modelo Novedoso" es aquel que para la prestación de un servicio financiero utilice herramientas o medios tecnológicos con modalidades distintas a las existentes en el mercado al momento en que se otorgue la autorización. Las empresas innovadoras deberán obtener autorización para que, mediante Modelos Novedosos, lleven a cabo alguna actividad que requiere de autorización, registro o concesión de conformidad con la Ley. La autorización tendrá una vigencia de no mayor a dos años, la cual señalará las excepciones y condicionantes al cumplimiento de los requisitos y obligaciones establecidos en las leyes financieras respectivas, así como los términos y condiciones para la prestación de los servicios. Las entidades financieras también podrán solicitar autorización para operar con Modelos Novedosos, mediante autorizaciones temporales similares a las otorgadas a empresas innovadoras; sin embargo, las

autorizaciones para entidades financieras no podrán tener una vigencia mayor a un año. Las sociedades autorizadas para operar de forma temporal deberán entregar a las autoridades financieras reportes que contengan las operaciones realizadas, el número de clientes, las situaciones de riesgo experimentadas y demás información (López & Martínez, 2018).

Según el reporte realizado por el BID y Finnovista "Fintech en América Latina 2018: crecimiento y consolidación", la importancia que cobra la regulación en el desarrollo del ecosistema se evidencia en que solo un 9% considera que actualmente no se necesita una regulación específica mientras que un 35% considera que si es necesario y un 35% considera que la regulación actual es adecuada, lo que refleja el progreso alcanzado en ciertas jurisdicciones en materia de regulación. En este sentido, el informe resalta avances logrados gracias al diálogo entre reguladores y la industria para propiciar la búsqueda de un marco favorable para la innovación.

Con respecto a Argentina, en 2016, el BCRA formó una mesa de innovación financiera con la participación de los Bancos tradicionales, Fintech, redes de cajeros, tarjetas de crédito y consultoras. En noviembre de 2016, el Congreso aprobó la "Ley de Emprendedores" mediante la cual se regularizan (en la órbita de control de la CNV) las plataformas de financiación colectiva (crowdfunding). Luego, el BCRA habilitó para que los Bancos puedan usar servicios en la nube y la implementación del código QR para realizar pagos y la mejora del DEBIN. En enero de 2017, permitió a los Bancos tener participaciones en las empresas Fintech y optó por dejar operar a las empresas Fintech siempre que no realicen intermediación financiera. Aunque con algunos esfuerzos, todavía la regulación en Argentina está lejos de ejemplos como Gran Bretaña o México.

Particularmente para IA y AA, dado el potencial de estas tecnologías y las implicaciones tanto positivas como negativas que se han estado analizando en el presente trabajo, los reguladores tendrán un papel importante que desempeñar en la supervisión del desarrollo de los procesos de AA de las entidades bancarias (Jagtiani, Vermilyea & Wall, 2018). La implementación de modelos de AA debe realizarse con cuidado, ya que la filosofía dinámica implícita aún no puede ser manejada adecuadamente por la regulación estática actual y la gobernanza interna. Las autoridades deberían dedicar equipos para analizar estos enfoques y comenzar a experimentar por sí mismos. Existe una gran posibilidad de materialización del riesgo dependiendo de los modelos elegidos. Incluso si todos los modelos utilizados son muy conocidos en las estadísticas no paramétricas, esta dinámica debe entenderse claramente para el uso que proporcionan. Además, es necesario

establecer especificaciones e indicadores de objetivos para evitar grandes aproximaciones y malos resultados (Guégan & Hassani, 2018).

La digitalización también desafía las leyes de la propiedad; nuevos desarrollos tecnológicos construidos sobre conocimiento previo, o por la convergencia de varias tecnologías conocidas, reabren la discusión sobre los derechos de propiedad y sobre la efectividad de instrumentos como patentes y registros de marcas (Estevadeordal et al., 2018). Esto también lo plantea la OECD (2016) ya que concluye que las nuevas TIC (entre las que se incluye la inteligencia artificial y *machine learning*) podrían plantear serias preocupaciones relacionadas con la privacidad, la protección del consumidor, competencia e impuestos y que los marcos regulatorios existentes pueden ser inadecuadas para algunos de los nuevos retos.

Los requisitos de transparencia pueden extenderse a los procesos y algoritmos subyacentes a las decisiones automatizadas. Estos requisitos de transparencia podrían entrar en conflicto con los derechos de propiedad intelectual existentes y los procesos y algoritmos en el núcleo de ciertas operaciones de negocio (OECD, 2016).

Contrariamente a todas las iniciativas que se están llevando a cabo, King (2018) establece que lo que se necesita es que se diseñe una regulación digital nativa desde cero, se coloque junto al sistema anterior y se remplace gradualmente. Y propone que debe basarse en un experimento llevado a cabo en Reino Unido por la Autoridad de Conducta Financiera, y consta que las reglas se emitan como código de computadora.

Anexo XXXIX. Desafíos Potenciales según encuesta Baker & McKenzie

La implementación de soluciones de IA además de oportunidades puede traer riesgos asociados y también presentan desafíos para los incumbentes de la industria financiera. El resultado de la encuesta de Baker & McKenzie realizada con Euromoney ha identificado los desafíos potenciales de IA tanto operativos como tecnológicos (Budworth, 2018) y son un excelente resumen de lo hasta ahora planteado. Los principales obstáculos que se identifican en este estudio son la escasez de habilidades especializadas para operar o mantener la tecnología, la integración humano–máquina, el *management* de los directores, las restricciones regulatorias, la privacidad de los datos, la ciberseguridad, la escasez de habilidades analíticas, el costo de los sistemas de IA, la identificación y la mitigación de todo riesgo legal material, y preocupaciones éticas. A continuación, se presenta el resumen del estudio realizado donde se muestran estos obstáculos tanto para pequeñas como para grandes compañías.

QUAERERE VERUM
Universidad de
SanAndrés

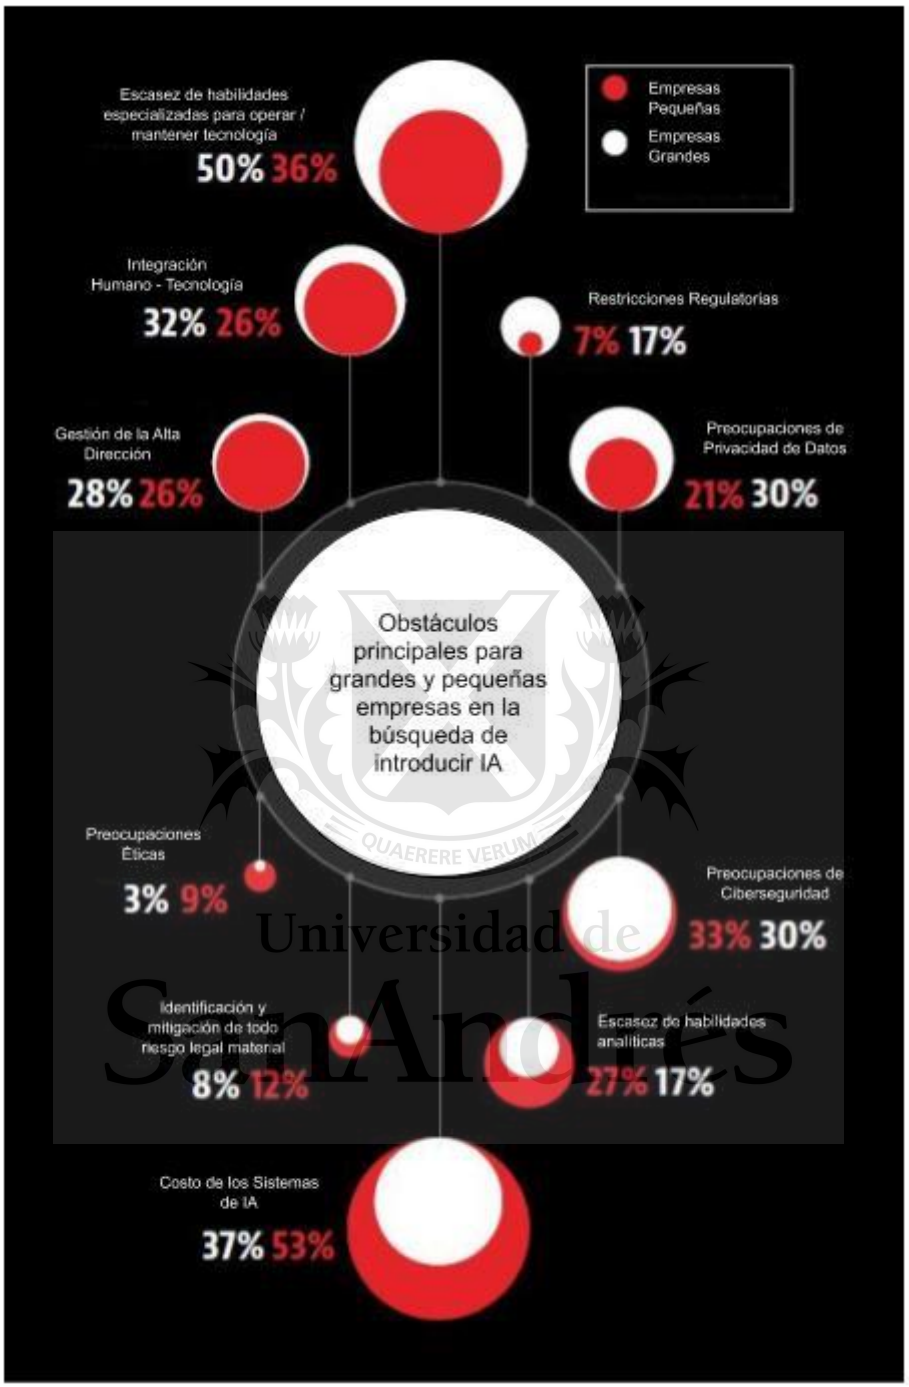

Figura 55. Obstáculos para introducir IA en pequeñas y grandes empresas del Sistema Financiero

La figura muestra en porcentajes (%) los diferentes desafíos y el resultado de la encuesta para grandes y pequeñas empresas. Fuente: GHOSTS IN THE MACHINE: Artificial intelligence, risks and regulation in financial markets (Budworth, 2018). Recuperado de: www.euromoneythoughtleadership.com/ghostsinthemachine. Copyright 2018. Traducción propia.

Anexo XL. Etapas de la Disrupción de los Servicios Financieros

La disrupción en los servicios financieros se ha dado en cuatro etapas o fases hasta llegar a la actualidad. La primera fase ocurrió con la llegada de Internet, y fue amplificada por las redes sociales. Si bien muchos bancos lo negaron en el momento de la burbuja de "las punto com", Internet cambió para siempre la forma en que los clientes accedían a su banco y su dinero. Esto les dio control y opciones que no estaban disponibles previamente. Los clientes fueron empujados a un entorno donde podían acceder a su dinero como lo deseaban, cuando lo deseaban. A medida que mejoraba la capacidad de la banca por Internet, el impulso para visitar la sucursal comenzó a disminuir y los clientes comenzaron a confiar en el nuevo canal como su punto de acceso principal con el banco para las transacciones diarias. En tan solo 10 años, pasó del 50 al 60 por ciento las transacciones realizadas en el mostrador en la sucursal, al 95 por ciento de las transacciones diarias realizadas a través del móvil, Internet, centro de llamadas y cajeros automáticos. En la parte posterior de esta primera fase, paralelamente al inicio de la segunda fase, fue el surgimiento de las redes sociales. La segunda fase se da con la aparición de los teléfonos inteligentes, como el iPhone y el teléfono habilitado para Android de Google. La tercera fase implica la convergencia del teléfono móvil con la tarjeta de crédito / débito. Y por último la cuarta fase, donde se trata de que la banca ya no sea un lugar al que los clientes van, sino algo que los clientes simplemente hacen. La mejor manera de ofrecer productos y servicios bancarios es que el banco sea omnipresente, donde y cuando un cliente necesite la utilidad de un banco (King, 2013).

Figura 56. Fases de la Disrupción en los servicios Financieros.

La figura muestra las 4 fases según King (2013).

Anexo XLI. Análisis Entrevistas Resumen Amenazas de los Bancos

Tabla 13. Resultados relacionados a la identificación de Amenazas que los Bancos tradicionales privados

Entrevistado	***Amenazas***
Virginia Martini Zanetti	Desintermediación financiera Grandes empresas como Mercado Libre
Nicolas Martins	Se debe utilizar estas técnicas para hacer frente a Fintech y grandes tecnológicas, riesgo de quedar relegado, como un negocio B2B
Eduardo U. Peralta	Comoditización sin diferenciación Pérdida de Clientes
Fernando Turri	Sin identificación de Amenazas
Leonardo Aranda y Juan Pablo Bruzzo	Sin identificación de Amenazas
Florencia Vidal	Fintechs, en Argentina son más de 133 que impactan un campo muy diverso
Marcelo Héctor González	A corto plazo puede haber pérdida de empleo
Hernán Borré	Sin identificación de Amenazas
Ignacio Carballo	Problemas de márgenes y de acceso a los clientes Perdidas de oportunidades en mercados no cubiertos por los Bancos Fintech más agiles para la adopción de tecnologías Redistribución de los márgenes de ganancia para aquellos que no se actualicen de manera rápida, la amenaza para las Bancas no es el fenómeno de las Fintech sino de la desagregación de los servicios financieros Grandes Empresas Tecnológicas (Google, Amazon, Facebooke, Apple, Tencent, Wechat, Microsoft, IBM...) Pérdidas de empleos
Carlos A. Giménez	Sin identificación de Amenazas
Juan Martín Maglione	Perdida de Marketshare por parte de las empresas que ya han adoptado estas tecnologias
Guillermo Marchionni	Los Bancos recién empiezan a percibir la amenaza de nuevos competidores (grandes tecnológicas como Mercado Libre, Amazon, etc.) muy volcadas a la experiencia de cliente
Ignacio Perrone	Sin identificación de Amenazas
Alejandro Bolaños (SAS) Juan Luis Nugoli(SAS)	Gran mercado disponible para competidores debido a la no bancarización

Ana Hidalgo…(SAS)	Fintech y grandes tecnológicas Fintech más agiles para la adopción de tecnologías
Maria de las Mercedes Noriega	Fintechs
Wenceslao Cova	Sin identificación de Amenazas

Elaboración propia a partir de las entrevistas llevadas a cabo para el trabajo de campo del presente trabajo.

Universidad de SanAndrés

Anexo XLII. Análisis Entrevistas Resumen Fortalezas de los Bancos

Tabla 14. Resultados relacionados a la identificación de Fortalezas que los Bancos tradicionales privados tienen a la hora de implementar soluciones de IA y AA.

Entrevistado	***Fortalezas de los Bancos Tradicionales***
Virginia Martini Zanetti	Recursos Datos Productos y Servicios
Nicolas Martins	Sin identificación de fortalezas
Eduardo U. Peralta	Datos Acceso a recursos
Fernando Turri	Poder adquisitivo Acceso a Infraestructura, Recursos
Leonardo Aranda y Juan Pablo Bruzzo	Acceso a fondeo Red de sucursales
Florencia Vidal	Sin identificación de fortalezas
Hernán Borré	Sin identificación de fortalezas
Ignacio Carballo	Espalda de los Bancos Adaptación de los Bancos a los anteriores cambios tecnológicos
Carlos A. Giménez	Datos de los Bancos
Juan Martín Maglione	Poder adquisitivo Acceso a Infraestructura, Recursos
Guillermo Marchionni	Sin identificación de fortalezas
Ignacio Perrone	Adaptación de los Bancos a los anteriores cambios tecnológicos Acceso a Infraestructura, a recursos y a proveedores
Marcelo Héctor González	Sin identificación de fortalezas
Alejandro Bolaños (SAS) Juan Luis Nugoli (SAS) Andrea Hidalgo (SAS)	Datos de los Bancos
Wenceslao Cova (IBM)	Datos de los Bancos
Maria de las Mercedes Noriega (IBM)	Acceso a recursos

Elaboración propia a partir de las entrevistas llevadas a cabo para el trabajo de campo del presente trabajo.

Universidad de SanAndrés

Anexo XLIII. Análisis Entrevistas Resumen Promesas y Oportunidades

Tabla 15. Resultados relacionados a la identificación de las Oportunidades que representa de IA y AA en los Bancos tradicionales privados

Entrevistados	***Oportunidades***
Virginia Martini Zanetti	Reducción de Costos Mayor calidad en los servicios Mejor experiencia de clientes
Nicolas Martins	Hoy se explota sólo el 10% de lo que se puede hacer Optimización de Procesos (deficientes u obsoletos) Ahorro de Costos Procesamiento de mayores volúmenes de datos y con la experiencia, modelos más profundos Ofrecer servicios similares o mejores a los que ofrecen las Fintech
Eduardo U. Peralta	Reducción de Costos Aumento de Productividad Personalización de productos y servicios
Fernando Turri	Acarrea eficiencia Reducción de costos Aumento de productividad Reasignar costos a mejores actividades para atender mejor a los clientes, a darle una mejor experiencia y un mayor valor. Procesamiento de Datos Mejora la Experiencia de Clientes
Leonardo Aranda y Juan Pablo Bruzzo	Ahorro de Costos Inclusión Financiera Nuevos productos/Servicios a clientes Infraestructura (Smartphones) existente Colaboración Fintech y Bancos
Florencia Vidal	Alianzas Fintech con Bancos
Marcelo Héctor González	Optimización de procesos internos Aumento del Marketshare
Hernán Borré	Mejora las condiciones laborales y mejora la calidad de vida
Ignacio Carballo	La tendencia en el mundo de los principales Bancos tradicionales que han afrontado una digitalización como BBVA, marcan la agenda de los temas Reducción de Costos Aumento de Servicios Financieros Mejora de la calidad de los servicios financieros hoy muy atada a una estructura masiva y de mucha burocracia Millenials que no solamente son clientes, sino que empiezan a ser líderes de las entidades bancrias Colaboración Fintech y Bancos

Entrevistados	*Oportunidades*
Carlos A. Giménez	Reducción de Costos Optimización de procesos Mejora la Calidad de Vida
Juan Martín Maglione	Incremento del Revenue Reducción de Costos Aumento de la Calidad Optimización de tiempos
Guillermo Marchionni	Demanda personalizada por parte de los usuarios Identificación por parte de los Bancos de la necesidad de cambio Colaboración con las Fintech, muchas veces es más fácil integrar una Fintech que hacer un desarrollo tecnológico Los reguladores en Latinoamérica están adoptando una postura de "dejar hacer" priorizando inclusión financiera
Ignacio Perrone	Reducción de Costos Colaboración de Bancos con Fintech Reducción de Costos
Alejandro Bolaños Juan Luis Nugoli Ana Hidalgo	Reducción de Costos Aumento de Productividad
Wenceslao Cova	Reducción de costos Mejora en la atención de clientes
María de las Mercedes Nogueira	Reducción de constos Personalización de Servicios

Elaboración propia a partir de las entrevistas llevadas a cabo para el trabajo de campo del presente trabajo.

Anexo XLIV. Análisis Entrevistas Resumen Aplicaciones

Tabla 16. Resultados relacionados a la identificación de Aplicaciones de IA y AA en los Bancos tradicionales privados

Entrevistados	***Aplicaciones***
Virginia Martini Zanetti	Credit Scoring Prevención de fraude Prevención de lavado de dinero Personalización de productos y servicios
Nicolás Martins	Riesgo Crediticio (con modelos de caja blanca, árboles de clasificación y enjambre de árboles) Prevención de Fraude, en tiempo real Prevención de lavado de dinero Automatización de Ofertas de Negocio Pronósticos de Ventas People Analytics, para desarrollo de carrera, evaluaciones, entre otros. Marketing
Eduardo U. Peralta	Campañas más asertivas Retención de Clientes Entendimiento del verdadero riesgo y una mejor definición de límites crediticios Análisis de Propensión de Compras Análisis de Propensión de Pagos o cancelación de deuda Personalización de servicios, ofrecer servicios en forma personal y no masivamente Robo Asesores
Fernando Turri	En todos los procesos donde hay datos y toma de decisión Personalización de ofertas, en tiempo real Credit Scoring Gestión de Efectivo Gestión de Cajeros Automáticos
Leonardo Aranda y Juan Pablo Bruzzo	En toda la Cadena de Valor Optimización de procesos, pasar de procesos más tradicionales (punto de contacto fisico) a procesos más digitales Análisis de Comportamiento de Clientes Adquisición de Clientes Credit Scoring Atención de Clientes, Asistentes virtuales Comunicación con los clientes
Florencia Vidal	Análisis de Comportamiento de Clientes Personalización de Servicios
Marcelo Héctor González	Aseguramiento de Crédito y gestión de riesgos Monitoreo de prevención de lavado de dinero

Entrevistados	*Aplicaciones*
	Gestión de inversiones Actividades de trading Actividades de Engagement con los clientes
Hernán Borré	Detección de Fraude Credit Scoring
Ignacio Carballo	*Sin mención a Casos de uso específicos*
Carlos A. Giménez	Detección de Fraude Credit Scoring Recomendaciones de Servicios para Upselling o Croselling
Juan Martín Maglione	Scoring personalizado Segmentación de Clientes, por algoritmos que toman variables psicográficas Generación de nuevos productos y servicios Gestión de Cobranzas Atención a Clientes (Centros de atención) Automatización de procesos de Backoffice
Guillermo Marchionni	Atención personalizada de clientes en Contact Centre Gestión de Cobranzas y Mora Asistentes virtuales
Ignacio Perrone	Chatbot (como punta de iceberg) Análisis de riesgo de créditos Robo – Asesores
Alejandro Bolaños Juan Luis Nugoli Ana Hidalgo	En todas las áreas donde hay datos y deben tomarse deciones, Marketing, Riegos Personalización Optimización de capital Detección de fraude Credit Scoring Gestión de efectivo ATM´s
Wenceslao Cova	Asistentes Virtuales Análisis de Información desestructurada Análisis de Imágenes Análisis de Personalidad para áreas de RRHH
Maria de las Mercedes Nogueira	Análisis de datos no estructurados, redes sociales

Elaboración propia a partir de las entrevistas llevadas a cabo para el trabajo de campo del presente trabajo.

Anexo XLV. Análisis Entrevistas Resumen Barreras y Desafíos

Tabla 17. Resultados relacionados a la identificación de Barreras y Desafíos que los Bancos tradicionales privados tienen a la hora de implementar soluciones de IA y AA

Entrevistado	***Barreras y Desafíos***
Virginia Martini Zanetti	Cultura de los Bancos Falta de agilidad en los proyectos Falta de toma de decisiones orientada a Datos
Nicolas Martins	Regulación Implementación de modelos de caja negra (Deep learning, redes neuronales) para casos de uso regulado Falta de Conocimiento de los equipos de Tecnología para gestionar ambientes en la nube, herramientas de open source Forma de abordaje de Proyectos en cascada, no Agile Análisis de alternativas y toma de decisiones por experiencia y no a través de los datos (cultura *Data Driven*)
Eduardo U. Peralta	Transformación Digital Cultura organizacional, esquemas mentales comenzando por la alta dirección y mandos medios para propagar el cambio Cambios en los cimientos de las instituciones financieras
Fernando Turri	Culturales del cliente para adopción de nuevos productos y de los empleados Escaso Capital humano Estructura de Datos
Leonardo Aranda y Juan Pablo Bruzzo	Transformación Digital de los Bancos, por ejemplo, alta de clientes con papeles Falta de información que no sea financiera Perdida de información por contactos en puntos físicos (sucursales) Regulaciones que impiden casos de uso como por ejemplo *Scoring* por la opacidad de los algoritmos Inercia muy fuerte de la cultura actual de los Bancos (procesos, sistemas, personas)
Florencia Vidal	Complejidad del Análisis de los Datos para analizarlos y procesarlos Facilidad de Cambios, por ejemplo, rapidez y agilidad de las Fintech Estructuras grandes Procesos corporativos, con tomadores de decisiones alejados Cultura organizacional en general Talento - Capital Humano
Marcelo Héctor González	Integración de estas tecnologías con los Sistemas *Legacy* heredados de los Bancos Regulaciones por ejemplo la de Europa que está en contra del almacenamiento de información Contexto político, social y económico del país Estructura, por ejemplo, las Fintech son más agiles y chicas La Dinámica de trabajo y los procesos organizacionales
Hernán Borré	Estructura de Datos Generar una cultura Data Driven Falta de conocimiento en estas nuevas tecnologías

Entrevistado	*Barreras y Desafíos*
Ignacio Carballo	En Argentina, barreras de implementación por contexto nacional. Estructuras organizacionales grandes, lentas, burocráticas, transnacionalizadas Procesos de autorizaciones poco flexibles No pueden competir con las Fintech en agilidad
Carlos A. Giménez	Depende de los Casos de Uso - Modelos de Interpretabilidad para los casos de uso auditables Enfoque de las auditorías para cumplir las regulaciones El estado de la transformación digital de los bancos acompañada de la transformación cultural Evolución de los perfiles, incorporación de *Skills* diferentes y mantenerlos Falta generar una cultura *Data Driven*, donde las decisiones se tomen apalancadas por datos Necesidad de Cambios de Cultura en la parte técnica, salir de la cultura de la base de datos relacional Implementación de soluciones ágiles Paradigmas de formas de trabajo, fricciones entre formas de trabajar diferentes por las incorporaciones de nuevos recursos a las organizaciones
Juan Martín Maglione	Desconfianza en IA sobre que puede hacer mejor ciertas actividades Cambio de seteo mental de determinístico a probabilístico Procesos actuales de los Bancos Regulación Falta de Cultura Organizacional tendiente a "sentirse" Nativos Digitales Cultura organizacional con alta y media dirección que debe cambiar Falta de entendimiento de los clientes Digitales Metodologías de trabajo, trabajo por silos Falta de *Deployments* más rápidos y próximos Iniciativas cortas con pruebas y *feedback* rápidos Arquitectura de Datos actual Capital Humano
Guillermo Marchionni	Cultura Organizacional Intolerancia a Fallas, hoy se tratan las iniciativas con prueba y error, algo muy difícil para los Bancos Estructura de Datos obsoletas Capital Humano
Ignacio Perrone	Cultura Organizacional Capital Humano
Alejandro Bolaños	Cambio Estructural
Juan Luis Nugoli	Entrenamiento de personas
Ana Hidalgo	Cultura organizacional al momento de conectar sistemas *legacy*, la gente que maneja estas tecnologías y tiene que involucrarse en proyectos más dinámicos Regulaciones, confidencialidad de los datos Desconfianza de la tecnología Implementación de soluciones ágiles y cortas Proyectos faraónicos que acarrean fracasos estrepitosos Metodologías no agiles Intolerancia a Fallas Falta de integración de datos Falta de gobierno Cultura orientada a no compartir información
Wenceslao Cova	Estructura Organizacional - Falta un área transversal que vele por los proyectos de IA y AA Gestión de Datos

Entrevistado	*Barreras y Desafíos*
María de las Mercedes Nogueira	Cultura Organizacional Falta de Agilidad

Elaboración propia a partir de las entrevistas llevadas a cabo para el trabajo de campo del presente trabajo.

Universidad de SanAndrés

Anexo XLVI. Análisis Entrevistas Resumen Riesgos

Tabla 18. Resultados relacionados a la identificación de Riesgos de soluciones de IA y AA en los Bancos tradicionales privados.

Entrevistado	***Riesgos Identificados***
Virgina Martini Zanetti	Protección de datos personales Ciberseguridad
Nicolas Martins	Protección de Datos Personales Sesgos algorítmicos, hay herramientas para detectar la discriminación positiva o negativa Ciberseguridad
Eduardo U. Peralta	No identificó riesgos
Fernando Turri	No identificó riesgos
Juan Pablo Bruzzo y Leonardo Aranda	Privacidad de Datos Transparencia de Decisiones Sesgos algorítmicos
Florencia Vidal	Falta de Marco Regulatorio
Marcelo Héctor González	Privacidad de Datos Transparencia de las decisiones
Hernán Borré	Sesgos algorítmicos
Ignacio Carballo	Sesgos Algorítmicos que profundicen las aristas más negativas del sistema financiero actual Privacidad de Datos Ciberseguridad Profundización de la exclusión financiera y diferencias de oportunidades, marginalización para economías emergentes. Falta de marcos regulatorios
Carlos A. Jiménez	Sesgos algorítmicos en modelos supervisados Transparencia de Decisiones
Juan Martín Maglione	Sesgos algorítmicos
Guillermo Marchionni	Transparencia de Decisiones
Ignacio Perrone	Privacidad de Datos Sesgos algorítmicos Ciberseguridad
Alejandro Bolaños (SAS) José Luis Nugoli (SAS) Ana Hidalgo (SAS)	Sin identificación de riesgos

Wenceslao Cova	No identificó Riesgos
María de las Mercedes Noriega	Privacidad de Datos Sesgos algorítmicos

Elaboración propia a partir de las entrevistas llevadas a cabo para el trabajo de campo del presente trabajo.

QUAERERE VERUM
Universidad de
SanAndrés

Anexo XLVII. Análisis Entrevistas Resumen Perspectiva de Adopción

Tabla 19. Resultados relacionados a estado de Adopción de soluciones de IA y AA en los Bancos tradicionales privados

Entrevistado	***Adopción de IA y AA en los Bancos***
Virginia Martini Zanetti	Mediano
Nicolas Martins	Corto - Mediano Plazo (de 1 a 5 años)
Eduardo U. Peralta	Mediano Plazo
Fernando Turri	Corto - Mediano
Leonardo Aranda y Juan Pablo Bruzzo	Hay "sobrepromesas" de lo que la IA puede hacer Corto Plazo de las soluciones disponibles, pero a través de Spin-off
Florencia Vidal	Largo Plazo
Marcelo Héctor González	Muy Largo Plazo. Los bancos esperan a que haya un caso de éxito avasallante para implementar, no son *early adopters* en general.
Hernán Borré	Largo Plazo
Ignacio Carballo	Largo Plazo
Carlos A. Jiménez	Largo Plazo. Implementación de soluciones que estén dentro del marco regulatorio.
Juan Martín Maglione	Largo Plazo
Guillermo Marchionni (Digital Bank Latam)	Largo Plazo. En la actualidad implementaciones muy incipientes.
Ignacio Perrone	Largo plazo
Alejandro Bolaños (SAS) José Luis Nugoli (SAS) Ana Hidalgo (SAS)	Mediano Plazo, está en etapa conceptual
Wenceslao Cova (IBM)	Corto Plazo
Maria de las Mercedes Norgueira Canella (IBM)	Mediano

Elaboración propia basada en las entrevistas llevadas a cabo dentro del trabajo de campo realizado para esta investigación.