



Universidad de San Andrés

Escuela de Negocios

Maestría en Gestión de Servicios Tecnológicos y de Telecomunicaciones

***El análisis de datos aplicado a la calidad de servicio en
distribución de energía.***

***Como el uso de técnicas de análisis de datos y modelos
predictivos puede aportar a la eficiencia operativa y calidad de
servicio en empresas de distribución de energía.***

Autor: Martin Rapallini

DNI: 27.777.770

Mentor de Tesis: Alejandro Prince

Ciudad Autónoma de Buenos Aires, 2019

Maestría en Gestión de Servicios Tecnológicos y Telecomunicaciones



El análisis de datos aplicado a la calidad de servicio en distribución de energía.

Como el uso de técnicas de análisis de datos y modelos predictivos puede aportar a la eficiencia operativa y calidad de servicio en empresas de distribución de energía.

Alumno: **Martin Rapallini**
Tutor: **Alejandro Prince**

2019

Ciudad Autónoma de Buenos Aires

Resumen

Está fuera de cualquier discusión la enorme importancia que tiene el suministro de electricidad para la humanidad, que hace confortable la vida cotidiana en los hogares, que mueve efectivamente el comercio y que hace posible el funcionamiento de la industria (Abur et al., 2002; Ramirez Castaño, 2009). El desarrollo de un país depende en gran medida de su grado de industrialización y este a su vez necesita de las fuentes de energía, especialmente de la energía eléctrica (Naguil et al., 2011; Ramirez Castaño, 2009; Rifkin, 2014). Pero a nivel global la red eléctrica sufre de falta de confiabilidad debido a la ausencia de herramientas de monitoreo y diagnóstico eficientes así como de sistemas automatizados (Jaradat, Jarrah, Bouselham, Jararweh, & Al-Ayyoub, 2015). Este problema se acentúa por la focalización del consumo en horarios pico de demanda y regiones específicas (Song, Xiao, & Van Der Schaar, 2014).

Estamos viviendo la revolución de los datos. Las compañías recolectan datos extremadamente detallados y proveen de información y conocimiento a sus clientes, proveedores, aliados e incluso competidores (Brynjolfsson, Hitt, & Kim, 2011) y se evidencia mayor dependencia de este tipo de extracción de conocimiento (Oussous, Benjelloun, Ait Lahcen, & Belfkih, 2018). Esta revolución se materializa en el uso de tecnologías de información en el ámbito corporativo, donde sistemas de gestión de recursos (ERP), suministros (SCM) y clientes (CRM), han probado tener efecto positivo directo las operaciones (McAfee, 2002) y productividad (Aral, Brynjolfsson, & Wu, 2006).

Es por esto que estudiaremos la aplicación de estas técnicas de análisis de grandes volúmenes de datos a la distribución de energía en pos de lograr una mejor calidad de servicio y mayor eficiencia operativa.

Palabras Clave

Big Data, Distribución de Energía, Redes Eléctricas Inteligentes, Big Data, Modelos Predictivos, Calidad de servicio, Eficiencia Operativa.

Agradecimientos

A mi mujer Natalia y mi hija Violeta por la interminable paciencia que me tuvieron en estas largas horas frente a la computadora.

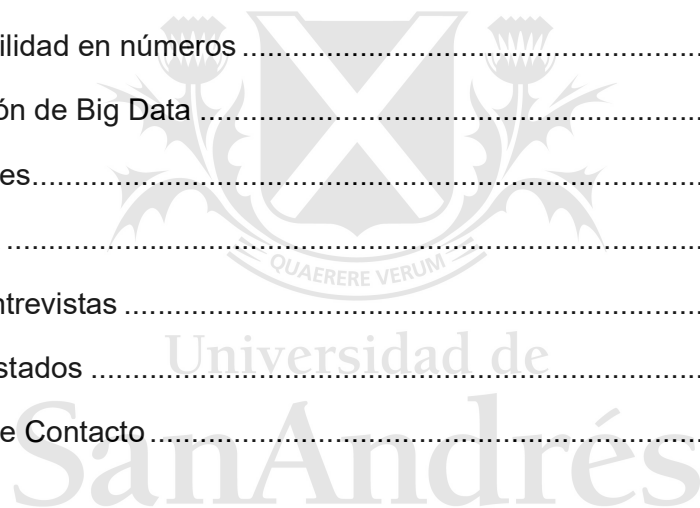
A Alejandro Prince por ser marcar su tiempo y servir de guía y foco para cumplir el objetivo propuesto.

Universidad de
San Andrés

CONTENIDO

1	Introducción	7
1.1	Presentación	7
1.2	Objetivo	8
1.2.1	Metodología	8
1.2.2	Objetivo	9
2	Marco Teórico	10
2.1	Contexto histórico y económico	10
2.1.1	Desarrollo de infraestructuras.....	10
2.1.2	Del paradigma capitalista a los modelos colaborativos	11
2.1.3	Financiación de la infraestructura: modelos tradicionales	14
2.1.4	Financiación de la infraestructura: modelos modernos	18
2.1.5	Efecto del modelo de financiación en la innovación	19
2.1.6	Industria 4.0.....	20
2.1.7	Internet de las Cosas.....	21
2.2	Minería y análisis de datos.....	23
2.2.1	Introducción	23
2.2.2	El valor de la información	24
2.2.3	Definición de Big Data	26
2.2.4	Machine Learning	27
2.2.5	Digital Twins	27
2.2.6	Actores principales	28
2.3	Distribución de energía	29
2.3.1	Introducción	29
2.3.2	Sistemas de potencia	32
2.3.3	Distribución.....	35
2.3.4	Red Eléctrica Inteligente, AMI y AMR.....	36

2.3.5	Microrredes de generación y distribución	37
2.3.6	Calidad de Servicio.....	38
2.3.7	Consumo y gestión de la demanda	39
2.3.8	Pérdidas	41
2.4	Matriz energética Argentina	43
2.4.1	Contexto argentino	43
2.4.2	Regulación.....	45
2.4.3	Subsidios	46
3	Trabajo de Campo	48
3.1	Aplicabilidad	48
3.2	Aplicabilidad en números	51
3.3	Adopción de Big Data	53
4	Conclusiones.....	56
5	Bibliografía	64
6	Anexo I: Entrevistas	79
6.1	Entrevistados	79
6.2	Carta de Contacto.....	80



ILUSTRACIONES

Ilustración 1: Subsidios energéticos en % del total de subsidios: 2005-2014	16
Ilustración 2: Tecnologías de la Industria 4.0	21
Ilustración 3: El proceso de Big Data	24
Ilustración 4: Sistema de Potencia	34
Ilustración 5: Dominios de Redes Eléctricas Inteligentes – IEEE	36
Ilustración 6: Transición hacia la Red Eléctrica Inteligente	37
Ilustración 7: Distribución de picos de demanda en Estados Unidos	41
Ilustración 8: Perdidas en trasmisión y distribución sobre el total generado	42
Ilustración 9: Casos de uso de Big Data	54

TABLAS

Tabla 1: Mapeo de dominios de aplicación, acciones y objetivos	51
Tabla 2: Modelo predictivo: Línea base de cálculo	52
Tabla 3: Modelo predictivo: Supuestos	53
Tabla 4: Modelo Predictivo: Inversión	53
Tabla 5: Modelo Predictivo: Resultado esperado	53
Tabla 6: Mapeo de dominios de aplicación con objetivos	61

1 INTRODUCCIÓN

1.1 PRESENTACIÓN

Según la Agencia Internacional de Energía se espera que el consumo global de energía se incremente dos tercios para el año 2035 (International Energy Agency, 2013). Se trata de un fenómeno global y multidimensional del que nadie está exento y se ve potenciado por el crecimiento de las ciudades, la digitalización en los hogares y proliferación dispositivos electrónicos.

El crecimiento de la demanda trae nuevos desafíos sobre la ya sobrecargada red eléctrica. De no implementarse las medidas adecuadas se verán potenciados los problemas de congestión de la red y degradación de la calidad de la energía transmitida presentes en la matriz energética argentina (Muras, Melamud, Ortolani, Martínez de Vedia, & Einstoss, 2015).

A nivel global, la red eléctrica, sufre de una falta de confiabilidad debido a la ausencia de herramientas de monitoreo y diagnóstico eficientes y de sistemas automatizados (Jaradat et al., 2015). Este problema se acentúa por la focalización del consumo en horarios pico de demanda y regiones específicas (Song et al., 2014).

Internet de las Cosas parece ser la oportunidad, desde el punto de vista tecnológico, de revolucionar la inteligencia en la distribución y consumo de energía. Permitiría realizar un monitoreo de la red, líneas de media tensión y cortes en tiempo real. A partir de la información recolectada sería posible para los expertos revelar aspectos profundos de la problemática que permitan tomar mejores decisiones, mejorar la operación de la red y su eficiencia (Hua, Junguo, & Fantao, 2014).

Estas tecnologías también abren la puerta a un replanteo de las prácticas aplicadas para gestión de la demanda (Song et al., 2014) así como un nuevo desafío de manejar volúmenes de datos hasta 3000 veces mayor al pasar, por ejemplo, de una lectura mensual de un medidor a tomar lecturas de medidores inteligentes cada 15 minutos (IBM, 2012; Jaradat et al., 2015).

Esto nos lleva a preguntarnos cómo se pueden explotar los sistemas ciber-físicos para transformar los hábitos de consumo y mejorar la calidad de servicio. Así mismo ¿Cuál

será el rol de las empresas transportadoras de energía frente a la convergencia de infraestructuras?

El objetivo de esta tesis es hacer un análisis del mercado energético argentino haciendo foco en la distribución de energía de media y baja tensión, para luego evaluar el potencial de aplicación de soluciones tecnológicas que se desarrollan dentro del marco de las Industrias 4.0, en particular los modelos analíticos predictivos y descriptivos y el uso de Big Data. El foco de aplicación estará puesto en lograr mayor eficiencia operativa en la distribución de energía y gestión de la demanda con el fin de impulsar la calidad de servicio.

En un primer capítulo del marco teórico se presentará el contexto histórico y económico en el que se presenta esta problemática.

En el segundo capítulo describiremos las tecnologías como Internet de las Cosas, Big Data, Machine Learning y Analytics que están revolucionando las industrias a nivel global.

En el capítulo tercero del marco teórico se presentarán las bases para el entendimiento de la dinámica de funcionamiento del negocio de distribución de energía para finalmente en el capítulo cuarto ver como aplica esto al mercado eléctrico argentino.

Luego estudiaremos la aplicabilidad de las diferentes técnicas dentro de Big Data y los modelos predictivos al negocio de distribución de energía con el objetivo de lograr una mejor calidad de servicio y mayor eficiencia operativa.

1.2 OBJETIVO

1.2.1 Metodología

Este trabajo se realizó bajo metodología descriptiva tomando información de trabajos de divulgación científica, publicaciones y trabajos de consultoría, así como publicaciones de organismos nacionales e internacionales.

Adicionalmente se realizarán entrevistas a expertos del sector energético, especialistas en nuevas tecnologías y transformación digital y expertos en el campo de Big Data y ciencia de datos.

Como fuente secundaria se utilizarán papers académicos y reportes de organismos nacionales e internacionales que marcan la tendencia y estado del arte a nivel nacional y global en materia de distribución de energía.

1.2.2 Objetivo

El objetivo de este trabajo es demostrar que los modelos analíticos predictivos y descriptivos tienen el potencial de transformar el modelo operativo de las empresas de distribución de energía y así potenciar la eficiencia operativa en pos de una mejor calidad de servicio y el uso eficiente de recursos con su consecuente reducción de costos.

Se trabajará sobre las siguientes preguntas de investigación:

1. ¿Puede el uso intensivo de tecnologías de análisis de datos como Big Data y modelos predictivos aportar a la reducción de costos operativos en empresas de distribución de energía?
2. ¿Puede el uso intensivo de tecnologías de análisis de datos como Big Data y modelos predictivos aportar a mejorar la calidad de servicio en empresas de distribución de energía?
3. ¿Se pueden obtener resultados significativos en mediano corto plazo (2 a 5 años)?
4. Estos modelos de análisis de datos ¿pueden convertirse en punta de lanza para la ampliación del modelo de negocio de las distribuidoras de energía generando nuevas fuentes de ingreso?

2 MARCO TEÓRICO

2.1 CONTEXTO HISTÓRICO Y ECONÓMICO

2.1.1 Desarrollo de infraestructuras

Todos los sistemas de infraestructuras de la historia requirieron de tres elementos interactuando entre sí para que el sistema funcione como un todo, siendo éstos, un medio de comunicación, una fuente de energía y un mecanismo de logística (Rifkin, 2014).

En la Primera Revolución industrial el agua y el vapor permitieron mecanizar la producción (Schwab, 2016). El telégrafo y la imprenta a vapor fueron los medios de comunicación que permitieron conectar y gestionar el complejo sistema ferroviario y fabril, con el carbón como principal fuente de energía y el ferrocarril en el corazón de la logística de distribución en la época (Rifkin, 2014).

Las segunda revolución industrial hizo uso de la energía eléctrica para impulsar la producción en masa (Schwab, 2016) y luego fueron los teléfonos, la radio y TV los medios de comunicación que permitieron conectar una sociedad de consumo dispersa geográficamente organizada en comunidades residenciales suburbanas y dependiente del petróleo como fuente de energía y el automóvil para la logística de media y corta distancia (Rifkin, 2014).

La característica distintiva de estas dos primeras revoluciones fue que las plataformas tecnológicas estaban centralizadas y sometidas a un control jerarquizado. Los combustibles fósiles sólo se encontraban en lugares muy concretos y su traslado exigía una gestión también centralizada con modelos comerciales de integración vertical, lo cual, a su vez, implicaba inversiones de capital muy elevadas para crear las empresas que permitirían su desarrollo (Rifkin, 2014).

Rifkin (2014) y Greenwood (1997), coinciden en observar el surgimiento de una nueva plataforma tecnológica manada desde el corazón mismo de la Segunda Revolución Industrial y producto de la convergencia de las infraestructuras de comunicaciones, energía y logística hacia una infraestructura inteligente perfectamente integrada. Internet de las Cosas es el motor principal de este fenómeno al que dan llamar Tercera Revolución Industrial y que lleva a aumentar la productividad hasta un punto donde el

costo marginal de producir muchos bienes y servicios es casi nulo y éstos se vuelven prácticamente gratuitos (Rifkin, 2014; Rothkopf, 2012).

Por otro lado Klaus Schwab (2016), fundador y presidente ejecutivo del Foro Económico Mundial, considera que la Tercera Revolución Industrial es en realidad el momento en que se produce el boom de la automatización de la producción, apalancada por el uso de la electrónica y las tecnologías de la información desde mediados del siglo pasado. Luego identifica una Cuarta Revolución, casi superponiéndose a la anterior y que se caracteriza por la fusión de tecnologías, diluyendo la línea entre las esferas física, digital y biológica. Este fenómeno coincide con lo que McAfee y Brynjolfsson (2017) llaman la Segunda Era de las Máquinas, aunque éstos últimos ponen énfasis en la automatización del conocimiento gracias a la proliferación del análisis de datos predictivo y en tiempo real, el aprendizaje automatizado e Internet de las Cosas.

Schwab (2016) continua su reflexión al observar que lo que diferencia la Tercera y Cuarta Revolución Industrial es la velocidad, alcance e impacto en los sistemas, la cual no tiene precedente histórico.

En este contexto, sigue siendo la infraestructura energética la más demorada de las tres (Güngör et al., 2011). Aún los costos fijos de creación de una infraestructura colaborativa son elevados frente a los combustibles fósiles y su estructura centralizada. Si bien el crecimiento de las fuentes de energía renovables ya refleja una tendencia de crecimiento exponencial aún falta que el costo baje lo suficiente como para permitir que la organización y distribución entre comunidades y regiones se haga de forma colaborativa (Recalde, Bouille, & Girardin, 2015; Rifkin, 2014).

2.1.2 Del paradigma capitalista a los modelos colaborativos

El poder narrativo de un paradigma está basado en su descripción exhaustiva de la realidad. Una vez aceptado se hace casi imposible cuestionar sus principios básicos ya que parece reflejar el orden natural de las cosas. Esta imposibilidad de considerar explicaciones alternativas conduce a que las mismas se acumulen hasta generar un punto de inflexión en el que el paradigma existente se desmorona y es reemplazado por otro (Kuhn, 2011).

La razón de ser del capitalismo es llevar cada aspecto de la vida humana al ámbito económico para transformarlo en una mercancía que se intercambie en el mercado

como una propiedad. Así es que hoy prácticamente todos los aspectos de nuestra vida diaria están relacionados de algún modo con intercambios comerciales. El mercado nos define (Rifkin, 2014).

Adam Smith (1804) ya sostenía que el mercado actúa de manera muy parecida a como actúan las leyes que rigen la gravedad. Al igual que en la naturaleza, donde para cada acción hay una reacción contraria equivalente, la oferta y la demanda se equilibran mutuamente en un mercado autorregulado. Luego Jean-Baptiste Say extendió este concepto al observar que la actividad económica se auto perpetúa. Según él *“Un producto terminado ofrece, desde ese preciso instante, un mercado a otros productos por todo el monto de su valor [...]; la creación de un producto abre de inmediato un mercado a otros productos”* (Say, 1971).

Generaciones posteriores de economistas neoclásicos refinaron esta ley afirmando que las nuevas tecnologías aumentan la productividad permitiendo que el fabricante produzca más bienes a un costo menor por unidad. El aumento de la oferta de productos más baratos crea su propia demanda y, con ello, obliga a los competidores a inventar tecnologías para aumentar la productividad. Los precios más baratos resultantes hacen que los consumidores dispongan de más dinero sobrante para gastar en otras cosas, lo que da lugar a un nuevo ciclo de competencias entre fabricantes. (Rifkin, 2014)

Estos principios operativos presuponen un mercado competitivo. Si uno o pocos fabricantes crecen más que la competencia y acaban con ella estableciendo un monopolio u oligopolio, el monopolista estará poco obligado o inclinado a introducir nuevas tecnologías que ahorren trabajo para aumentar la productividad, reducir los precios y mantener la competitividad. Sin embargo, a la larga siempre aparecen nuevos actores que rompen el monopolio introduciendo nuevos avances que aumentan la productividad y reducen los precios de unos bienes y servicios similares o alternativos (Rifkin, 2014).

Si imaginamos un escenario donde la lógica operativa del sistema capitalista supera toda expectativa, llevando al sistema a una productividad extrema y en consecuencia a un estado en que la competencia intensa obliga a la introducción de tecnología cada vez más sofisticada impulsando aún más la productividad y reduciendo el coste marginal hasta aproximarse a cero entonces el beneficio, que es el alma del

capitalismo, se acabaría evaporando. En una economía de intercambio, los beneficios proceden de los márgenes, por lo que todo el sistema colapsa. (Rifkin, 2014)

Oskar Lange en 1936, en plena Gran Depresión, se preguntaba si la institución de la propiedad privada seguiría alimentando indefinidamente el progreso económico o si el propio éxito del sistema se convertiría en un obstáculo para su propio crecimiento (Lange, 1937). Según Lange *“cuando mantener el valor del capital ya invertido se convierte en el principal objetivo de los empresarios, el progreso económico cesa o, al menos, se reduce considerablemente [...] Este resultado aún se acentúa más si hay empresas que disfrutan de una posición de monopolio”*. Luego Lange resume que *“la estabilidad del sistema capitalista se ve afectada por la alternancia entre los intentos de detener el progreso económico con el fin de proteger las inversiones antiguas y los tremendos colapsos que se producen cuando esos intentos fracasan.”*

Lange (1937) y Keynes (2010) coincidían en que la economía más eficiente es aquella en la que los consumidores solo pagan por el costo marginal de los productos que adquieren.

El capitalismo, que ha ofrecido una narración convincente de la naturaleza humana y un marco organizativo general de la vida cotidiana comercial, social y política de la sociedad durante más de diez generaciones, ya ha alcanzado su apogeo y ha iniciado su lento declive. El procomún colaborativo, según lo rotula Rifkin (2014), o las comunas, como las define Bollier (2014) surgen como una nueva forma de organizar la vida económica, ofreciendo la posibilidad de reducir la diferencia de ingresos, democratizar la economía y crear una sociedad más sostenible desde el punto de vista ecológico. Si el mercado capitalista se basa en el interés personal y está impulsado por el beneficio material, este nuevo modelo está motivado por el interés colaborativo y lo impulsa un deseo profundo de conectar y compartir con los demás. Si el primero fomenta el derecho de propiedad y la búsqueda de autonomía, el segundo promueve la innovación desinteresada, la transparencia y la creación de comunidad (Bollier, 2014; Melville, Christie, Burningham, Way, & Hampshire, 2017; Rifkin, 2014).

A su vez nos hace dejar de pensar en consumidores y productores como entidades separadas para ir hacia el concepto de prosumidores, quienes cumplen ambos roles en simultáneo (Rifkin, 2014; Ritzer, 2010). El término prosumidor es atribuido a Toffler

(1980) aunque también Kottler (1986) lo utilizó posteriormente en el artículo '*Prosumidores: un nuevo tipo de consumidor*'.

Igualmente, muchos autores coinciden en que se debe tener en cuenta la escala del sistema a la hora de evaluar el modelo económico más apropiado (Bollier & Helfrich, 2014) e incluso hay quienes consideran escenarios con prosumidores con objetivos más egoístas, quienes buscan maximizar sus propios beneficios económicos (Kim, Ren, Van Der Schaar, & Lee, 2013).

Aunque esta nueva manera de organizar la economía sea disruptiva, no supondrá una amenaza para los supuestos generales en los que se basan el capitalismo de mercado y su adversario, el socialismo de Estado. La opinión general es que, si bien el espíritu colaborativo extenderá la participación y la creatividad por toda la sociedad y hará más horizontal la forma de organizar la vida institucional en virtualmente todos los campos, acabará siendo asimilado por un mercado capitalista más humano y eficiente. Estamos presenciando la aparición de una economía híbrida, en parte mercado capitalista y en parte procomún colaborativo; dos sistemas que pueden actuar conjuntamente por momentos y en otros competir entre sí. Con un capitalismo más racionalizado y práctico que hallará suficientes vulnerabilidades que explotar, sobre todo como agregador de servicios y soluciones en red (Rifkin, 2014).

2.1.3 Financiación de la infraestructura: modelos tradicionales

Como planteábamos en un comienzo, las grandes transformaciones económicas que se han producido a lo largo de la historia se han basado en el descubrimiento de nuevas formas de energía y nuevos medios de comunicación.

En el siglo XIX, la imprenta a vapor y el telégrafo fueron los medios de comunicación que permitieron conectar y gestionar el complejo sistema ferroviario y fabril, basado en el carbón, que conectaba áreas urbanas densamente pobladas. En el siglo XX, la telefonía y más adelante la radio y la televisión se convirtieron en los medios de comunicación que permitieron conectar y gestionar una época y una sociedad de consumo geográficamente más dispersa y traccionada por el petróleo, el automóvil y las comunidades residenciales suburbanas. Y en el siglo XXI, Internet se está convirtiendo en el medio de comunicación que permite gestionar las fuentes de energía renovables distribuidas y los sistemas de logística y de transporte automatizados en un procomún mundial cada vez más interconectado (Rifkin, 2014).

Las plataformas tecnológicas de la primera y la segunda revoluciones industriales estaban centralizadas y sometidas a un control jerarquizado. La razón era que los combustibles fósiles solo se encontraban en lugares muy concretos y su traslado del subsuelo al consumidor final exigía una gestión centralizada y de integración vertical. A su vez, gestionar la creciente agilización de las transacciones comerciales que las nuevas fuentes de energía hacían posible también exigía unas formas de comunicación centralizadas bajo un control jerarquizado (Rifkin, 2014).

Si pensamos en lo que implica la construcción de las infraestructuras impulsoras de las distintas revoluciones industriales, no podemos dejar de preguntarnos cómo y quién está detrás de su financiación, considerando que el desarrollo de las mismas son el motor y sostén de la economía de un país (Naguil et al., 2011).

En 1930 Harold Hotelling, presidente de la Econometric Society, expuso en la Asamblea General de dicha asociación sobre la relación del bienestar general con los problemas fiscales y con las tarifas de los ferrocarriles y los servicios públicos. En su presentación sostenía que *“el nivel óptimo del bienestar general se logra cuando el precio al que se vende cualquier cosa equivale a su costo marginal”*.

Según su punto de vista, los servicios públicos no dan lugar a competencia, por tratarse de bienes que todo el mundo los necesita y ofrecen la infraestructura para el resto de la actividad económica al mismo tiempo que demandan grandes inversiones de capital. En cuyo caso la competencia implicaría un despilfarro de capital, por lo que sugiere favorecer el monopolio natural. Concluye que los servicios públicos se beneficiarían mucho si sólo pagara el costo marginal de lo que usa y los costos iniciales de crear servicios y bienes públicos salieran de las arcas del Estado y los impuestos, más precisamente, sobre la renta, las sucesiones y los bienes inmuebles, los cuales tienden a aplicarse sobre los más adinerados. (Hotelling, 1938)

Esta visión no era compartida por los partidarios de la libre empresa. Si bien reconocían la carencia de competencia en los servicios públicos y que el costo medio de poner unidades adicionales en el mercado iría bajando gracias a la constancia de la demanda, sostenían que era más acertado cobrar por la reducción del costo medio para que las empresas pudieran recuperar su inversión sin necesidad de que el Estado intervenga en la vida económica del país (Rifkin, 2014). El principal defensor de este punto de vista fue Ronald Coase, quien ofreció un contrapunto a la tesis de

Hotelling. Coincidía en que el precio debía equipararse al costo marginal, pero debiéndose cubrir al mismo tiempo el costo total. Propuso un plan de tarifas en el que quienes usaban el servicio pagaban una cantidad adicional, además del costo marginal, en concepto de gastos de entrega (Coase, 2006).

La postura de Coase fue la que se terminó imponiendo desde lo conceptual, aunque en la práctica no fue tan así (Rifkin, 2014). En los Estados Unidos, más de la mitad de los fondos para subvenciones estatales están destinadas a cuatro sectores: finanzas, servicios y bienes públicos, telecomunicaciones y gas y petróleo. En particular, entre 2008 y 2010, las empresas distribuidoras de gas y electricidad y servicios públicos recibieron más de 31.000 millones de dólares en subsidios, lo que representa un 10,9 % del total de los subsidios (Mcintyre, Gardner, Wilkins, & Phillips, 2011). En la Argentina la carga fiscal de los subsidios muestra un fenómeno similar, aunque mucho más focalizado en el sector energético. Según un informe conjunto de la Asociación Argentina de Presupuesto y el Instituto Argentino de Energía los subsidios a la distribución de gas y electricidad llegaron a representar un 48,8% del total de subsidios en 2010 (26.919,8 millones de pesos) y 71,1 % en 2014 (160.755 millones de pesos) (Muras et al., 2015).



Ilustración 1: Subsidios energéticos en % del total de subsidios: 2005-2014¹

¹ (Muras, Melamud, Ortolani, Martínez de Vedia, & Einstoss, 2015)

La construcción del ferrocarril en Norteamérica de mediados del siglo XIX presenta un modelo de financiación diferente. En 1827 comenzó la construcción del primer ferrocarril y en líneas generales se trató de un comienzo muy irregular cuya eclosión se dio hacia finales de la década de 1840. La inversión total de capital en compañías ferroviarias privadas superó los mil millones de dólares para 1859. Esta inversión creció a ritmo acelerado hasta la depresión de la década de 1870, para entonces ya se habían tendido 113.000 kilómetros de vías. Hacia fines de siglo ya había 320.000 kilómetros conectando grandes ciudades, pueblos pequeños e incluso aldeas a lo largo de Estados Unidos (Chandler, 1977).

Financiar esta infraestructura de transporte exigió dar lugar a una nueva clase de modelo comercial que se dio a llamar la 'sociedad de capital'. Un nuevo modelo de empresa que separaba la propiedad de la gestión y el control. A partir de este momento las empresas estarían dirigidas por gestores profesionales asalariados cuya principal responsabilidad sería obtener beneficios para sus accionistas. En el modelo capitalista se despoja al trabajador de la propiedad de las herramientas que usa para crear los productos y a los inversores de la capacidad de controlar y gestionar la empresa.

El alto costo de capital que suponía la creación de una infraestructura ferroviaria hizo necesario un modelo de empresa que se pudiera organizar en torno una integración vertical que uniera a proveedores y clientes. Las grandes empresas ferroviarias adquirieron propiedades mineras para garantizar el suministro de carbón a sus locomotoras o cadenas de hoteles para hospedar a los pasajeros. Adicionalmente, la gestión de estas grandes empresas resultaba mucho más eficaz si se basaba en un sistema centralizado y jerárquico (Chandler, 1977). Max Weber defendía la postura de que un capitalismo maduro exigiría empresas de integración vertical para crear economías de escala y burocracias corporativas muy racionalizadas, con una gestión centralizada y unos mecanismos de mando jerárquicos (Collins, 1980).

Otro modelo diferente fue el de la construcción de rutas y la producción masiva de automóviles. En este caso, mientras que en casi todo el mundo la construcción de redes viarias se financiaba con dinero público, la industria del automóvil, al menos la estadounidense, estaba financiada totalmente por capital privado de empresas como Ford, General Motors y Chrysler (Rifkin, 2014).

Hoy la industria petrolera sigue siendo la más concentrada del mundo, seguida muy de cerca por la industria de las telecomunicaciones y finalmente la generación y distribución de energía. Prácticamente todos los sectores que dependen de los combustibles fósiles y las telecomunicaciones exigen enormes desembolsos de capital y la integración vertical y economía de escala que les permitan recuperar esas inversiones, viéndose obligadas a dirigir sus actividades mediante procesos de control muy racionalizados.

Las grandes empresas de integración vertical han sido el medio más eficiente para organizar la producción y distribución masiva de bienes y servicios (Bollier & Helfrich, 2014; Rifkin, 2014).

2.1.4 Financiación de la infraestructura: modelos modernos

Según un informe del Programa de Medioambiente de las Naciones Unidas (Rickerson, Laurent, Jacobs, Dietrich, & Hanley, 2012) las tarifas de inyección ("*Feed-in tariff*") de energía verde a la red eléctrica se han convertido en el principal instrumento para fomentar las energías renovables. Se busca de esta forma garantizar un precio por encima del precio del mercado de otras energías durante un período que suele durar entre quince y veinte años y así fomentar la inversión de los ciudadanos en la instalación de sistemas para generar energía eólica, solar, geotérmica o incluso hidráulicas para que viertan el excedente en la red de distribución. Cuantas más personas generan energía renovable, más crece la escala del sector y mayores son las inversiones de los fabricantes para mejorar la eficiencia y la productividad de estas tecnologías y reducir los costos con un fin de estimular el crecimiento de dicho mercado. Esto también permite que el precio de mercado de la electricidad verde se acerque al de la generada por los combustibles fósiles y con energía nuclear.

Según este mismo reporte sesenta y cinco países, más de la mitad de ellos en vías de desarrollo, han instituido primas para incentivar el vertido de energía verde a la red eléctrica. Es una estrategia que ha demostrado ser un instrumento político de mucho peso para aumentar la presencia de energía renovable en la red. Casi dos terceras partes de la capacidad eólica y el 87% de la capacidad fotovoltaica de todo el mundo se deben al estímulo que han supuesto estas primas (Rickerson et al., 2012).

La financiación de estas primas suele basarse en los impuestos o en un leve aumento del precio de la electricidad en la factura mensual de los abonados. En otras palabras, o bien las empresas energéticas trasladan el costo adicional a los consumidores para que financien el cambio a las energías renovables, o bien pagan los contribuyentes por medio de subvenciones públicas que suponen las primas de vertido a la red eléctrica (Rickerson et al., 2012; Rifkin, 2014).

Quienes se oponen a las energías renovables sostienen que los subsidios que reciben estas energías en forma de tarifas de introducción a la red eléctrica mantienen de una manera artificial su curva de crecimiento. Pero si bien esto puede ser cierto, a su vez fomentan la innovación y la competencia que aumentan la eficiencia de estas tecnologías y reducen los costos de instalación y producción. A medida que la energía fotovoltaica se acerca al nivel de la energía convencional, los gobiernos empiezan a reducir las tarifas. Aunque los métodos convencionales no se hallan en su mejor momento, siguen recibiendo muchas más subvenciones que las energías renovables (Rifkin, 2014).

2.1.5 Efecto del modelo de financiación en la innovación

El enorme costo de capital que suponía crear estas matrices de comunicación/energía centralizadas (Naguil et al., 2011) significaba que las nuevas empresas industriales y comerciales, que se basaban en estas plataformas tecnológicas y dependían de ellas, debían crear unas operaciones gigantescas e integradas verticalmente a lo largo de la cadena de valor (Rifkin, 2014).

Summers y DeLong (2001) se oponían a las subvenciones públicas para cubrir los costos iniciales, aduciendo que los defectos de la “*democracia administrativa*”, “*las decisiones tomadas en grupo*” y “*el papeleo burocrático*” agotan la energía empresarial del mercado. Con grandes reservas, consideraban que la mejor manera de proteger la innovación sería favoreciendo monopolios naturales a corto plazo. Basándose en que “*el poder y los beneficios de un monopolio temporal son la recompensa necesaria para que la empresa privada se sienta estimulada adoptar la innovación*”.

Cuando mantener el valor del capital invertido se vuelve el principal objetivo de los empresarios, el progreso económico cesa o se ve severamente afectado. Este

fenómeno es aún más fuerte cuando las empresas gozan de una posición de monopolio (Lange, 1937).

La misma integración vertical que hizo posible el desarrollo de estas infraestructuras también hizo que en cada sector aparecieran algunos líderes que monopolizaban el mercado impidiendo que otras empresas introdujeran innovaciones tecnológicas para reducir el coste marginal y el precio de sus bienes y servicios y lograran una cuota de mercado suficiente para poder competir (DeLong & Summers, 2001).

2.1.6 Industria 4.0

El término Industria 4.0 se hizo públicamente conocido en 2011 en el contexto de una iniciativa con dicho nombre lanzada por empresas, políticos y académicos alemanes con el objetivo de fortalecer la competitividad de la industria manufacturera de dicho país (Hermann, Pentek, & Otto, 2016).

El Gobierno Federal Alemán presentó la Industria 4.0 como una nueva estructura en la cual los sistemas de producción y logística, en la forma de Sistemas de Producción Ciber-Físicos, hacen uso intensivo de las redes de comunicación para lograr un intercambio automatizado de información e integrar los procesos productivos y de negocio (Aiman Kamarul Bahrin, Othman, Hayati Nor Azli, & Farihin Talib, 2016).

Según el Boston Consulting Group (Gerbert et al., 2015) son 9 los avances tecnológicos apuntalan la Industria 4.0, como ser: la integración vertical y horizontal de sistemas, Internet de las Cosas, Ciberseguridad, computación en la nube, big data, simulación, impresión 3D, realidad aumentada y robótica.

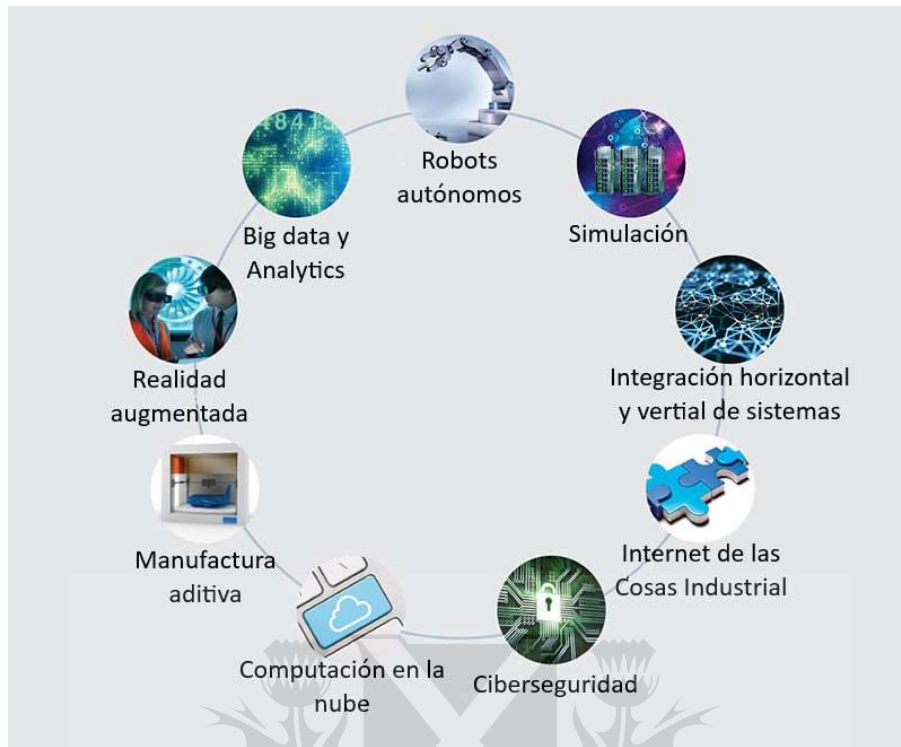


Ilustración 2: Tecnologías de la Industria 4.0²

En otros países fuera de Alemania y Europa en general, se pueden encontrar conceptos análogos bajo el nombre de sistemas ciber-físicos, fábricas inteligentes, manufactura avanzada, internet del todo, internet industrial de las cosas, etc, así como también se encuentran referencias que lo usan indistintamente para referirse a la Cuarta Revolución Industrial (Aiman Kamarul Bahrin et al., 2016; Vaidya, Ambad, & Bhosle, 2018).

2.1.7 Internet de las Cosas

Internet de las Cosas (IdC) es la extensión y expansión de la red de Internet, donde las cosas se conectan unas con otras. Puede ser visto como un nuevo método de procesamiento y adquisición de información donde se combinan tecnologías como la Identificación por Radiofrecuencia (RFID, por sus siglas en inglés), sensores, nanotecnología y elementos inteligentes (Hua et al., 2014). Es considerada la tercera ola de las industrias de la información, precedida por las computadoras personales, Internet y las comunicaciones móviles, y se propagó ampliamente en industrias como

² (Gerbert et al., 2015)

el transporte, defensa, entretenimiento del hogar y monitoreo industrial y ambiental (A. Liu, 2002; D. Liu, Han, & Liu, 2013).

IdC integra el entorno artificial y el medio ambiente natural en una red operativa coherente, permitiendo que cada ser humano y cada objeto se comuniquen buscando sinergias y facilitando interconexiones que optimicen las eficiencias termodinámicas de la sociedad. Su lógica operativa es optimizar la producción horizontal entre iguales, el acceso universal y la inclusión. Es una red diseñada para que sea abierta, distribuida y colaborativa y esto permite que empresas sociales del procomún colaborativo rompan el monopolio de las grandes empresas de integración vertical posibilitando así una producción colaborativa de escala horizontal con un costo marginal cercano a cero (Rifkin, 2014).

El núcleo del sistema operativo del IdC es la integración del Internet de las comunicaciones, el Internet de la energía y el Internet de la logística en una plataforma operativa coherente. Un sistema que busca continuamente maneras de aumentar la eficiencia y la productividad en la obtención de recursos, la producción y distribución de bienes y servicios (Rifkin, 2014).

El IdC se está implementando en sectores industriales y comerciales. Las empresas instalan sensores a lo largo de toda la cadena comercial para supervisar y seguir el flujo de sus bienes y servicios. Por ejemplo, se utilizan sensores que comunican en tiempo real los cambios del consumo de electricidad en empresas y hogares y su impacto en el precio de la electricidad, esto permite a los consumidores programar sus aparatos para que reduzcan el consumo o para que se apaguen durante los períodos de consumo máximo con el fin de evitar los picos del precio de la electricidad o para evitar apagones en la red, incluso en algunos casos reciben una bonificación en la siguiente factura eléctrica.

Grandes empresas del campo de las tecnologías de la información como General Electric, Cisco e IBM trabajan activamente en el desarrollo del IdC (Rifkin, 2014). Cisco Systems prevé que para 2022 el *Internet del Todo* supondrá 14,4 billones de dólares de beneficio neto para las empresas del sector privado (Mitchell, Villa, Stewart-Weeks, & Lange, 2013).

Por su parte, General Electric publicó un estudio en noviembre 2012 donde concluye que las mejoras en cuanto a eficiencia y productividad que supondría un Internet

industrial inteligente podrían extenderse a prácticamente todos los sectores económicos 2025 y tener un fuerte impacto en la mitad de la economía mundial (Evans & Annunziata, 2012).

Sólo en los Estados Unidos en 2014 había 58 millones de medidores inteligentes AMI (por su sigla en inglés de Advanced Metering Infrastructure) que proveían información en tiempo real sobre el consumo de electricidad, este valor ascendió a 78,9 millones en 2017 (“Electric power sales, revenue, and energy efficiency Form EIA-861 detailed data files”, 2018). En diez años se espera que todos los edificios de Norteamérica, Europa y otros lugares del mundo estén equipados con contadores inteligentes, así como los dispositivos y aparatos (termostatos, líneas de montaje, equipos de almacenes, televisores, lavadoras, ordenadores, etc) estarán conectados al contador inteligente y a la plataforma de IdC (Merchant, 2013).

2.2 MINERÍA Y ANÁLISIS DE DATOS

2.2.1 Introducción

En el esquema de interconexión de Internet de las Cosas personas, máquinas, recursos naturales, cadenas de producción, redes de logística, hábitos de consumo y prácticamente cualquier otro aspecto de la vida económica y social estarán conectados mediante sensores y programas con la plataforma de IdC, que enviará continuamente cantidades ingentes de datos en cada momento y en tiempo real, las cuales, según Rifkin (2014), serán procesados mediante análisis avanzado y transformados por algoritmos predictivos que se programarán en sistemas automatizados para mejorar la eficiencia, aumentar la productividad y reducir casi a cero el coste marginal de producción y distribución de toda una gama de productos y servicios.

Estamos viviendo la revolución de los datos. Las compañías recolectan datos extremadamente detallados y proveen de información y conocimiento a sus clientes, proveedores, aliados e incluso competidores (Brynjolfsson et al., 2011) y se evidencia mayor dependencia de este tipo de extracción de conocimiento (Oussous et al., 2018). Esta revolución se evidencia en el uso de tecnologías de información en el ámbito corporativo, donde sistemas de gestión de recursos (ERP), suministros (SCM)

y clientes (CRM), han probado tener efecto positivo directo las operaciones (McAfee, 2002) y productividad (Aral et al., 2006).

A las tendencias tecnológicas que potencian el procesamiento de estos grandes volúmenes de datos, como el ya mencionado Internet de las Cosas, se suma la proliferación de servicios de computación en nube y dispositivos inteligentes (Botta, de Donato, Persico, & Pescapé, 2016) y la contante caída de los costos de almacenamiento y procesamiento gracias a los avances tecnológicos (Purcell, 2014).

Dentro del campo general de la ciencia de datos encontramos muchos dominios de conocimiento como ser Big Data, Data Mining, Analytics, Machine Learning o Inteligencia Artificial, por nombrar algunos, y todos ellos con su propósito, metodología y ventajas y desventajas.

En particular nos interesa Big Data y Analytics, ambos relacionados como parte de un mismo proceso de generación, adquisición y almacenamiento y análisis de los datos (Chen, Mao, & Liu, 2014; Gandomi & Haider, 2015).



Ilustración 3: El proceso de Big Data ³

En este marco se trabaja principalmente con frameworks como Hadoop y Spark, que por sus bases en el software libre permitieron la proliferación de herramientas y adaptaciones a la necesidad de los distintos actores (Oussous et al., 2018).

2.2.2 El valor de la información

Existen dos caminos posibles para valorar la información. Desde la perspectiva de quien la emplea para la toma de decisiones estratégicas, o bien desde la perspectiva del cliente a quien será ofrecida.

³ (Gandomi & Haider, 2015)

En el primero de estos casos el enfoque de las teorías modernas es que quien está a cargo de la toma de decisiones intentará determinar, de la forma más certera posible, el curso de las cosas y su estado futuro, a fin de poder tomar decisiones y ejecutar acciones que maximicen el valor obtenido al alcanzar dicho estado (Brynjolfsson et al., 2011), aunque esto sea algo que no es posible saber con certeza. Blackwell (1953) presentó su trabajo seminal en ésta materia, donde buscó determinar un método para describir cuándo un cúmulo de información imperfecta es mejor (más informativa) que otro, en el sentido de que el resultado obtenido a partir de las decisiones tomadas dará mayor retorno. En línea con esto el mismo Blackwell (1953) sugiere que mientras más precisa y acertada es la información, mayor será el aporte a la toma de decisiones y mejorará la performance de la firma. Esta última relación está evidenciada en múltiples trabajos como los de Ayres (2008) y Davenport y Harris (2007) y luego demostrada de forma más empírica por Brynjofsson (2011).

Un trabajo complementario al de Blackwell fue el de Galbraith (1977) quien argumentó que la realización de tareas más complejas requiere el procesamiento de mayor cantidad de información, por lo que la organización debe estar diseñada con esta meta en mente. Reforzando así la importancia y necesidad de sistemas de información verticales (Aral et al., 2006; Hitt, Wu, & Zhou, 2002) y herramientas de analítica de datos (Davenport & Harris, 2007) para gestionar estos grandes volúmenes de información y sus relaciones.

La conclusión a la que llega Brynjolfsson (2011) es que las firmas que adoptan la filosofía de 'toma de decisiones basada en datos' obtienen resultados y productividad entre un 5 y 6% mayor en relación a lo que se esperaría si invirtieran en otras tecnologías de información. Esto es complementario a las conclusiones alcanzadas por Shapiro y Varian (1999) quienes observaron que la información es mucho más valiosa en grandes volúmenes.

Otro aspecto fundamental es el manejo eficiente de estos grandes volúmenes de datos desde la perspectiva del su sanitización, agregación y codificación para garantizar que la información será fácilmente accesible, administrable y almacenada en forma segura (Oussous et al., 2018).

En el caso de la información producida para ser comercializada, DeLong y Summers (2001) expresaban que aquellas empresas que cubren sus costos con los ingresos

que obtienen de sus ventas ya no pueden producir bienes de información que se vendan al costo marginal de producción, porque este será cero. Para que una empresa pueda crear y producir bienes de información debe prever que los va a vender obteniendo un beneficio (DeLong & Summers, 2001).

2.2.3 Definición de Big Data

La rápida y a veces caótica evolución de literatura sobre Big Data ha impedido el desarrollo y consenso de una única definición del término, de hecho, muchos autores han hecho sus definiciones sin que ninguna de éstas prevenga la aparición de otras nuevas (De Mauro, Greco, & Grimaldi, 2016). Esta indefinición suele ser evidencia de la inmadurez de la disciplina.

De Mauro (2016) identifica cuatro grupos en los que se pueden agrupar éstas definiciones, siendo éstos en función de (I) los atributos de la información, (II) las necesidades tecnológicas, (III) los umbrales o límites a vencer y (IV) el impacto social.

A los efectos de éste trabajo y en función de la literatura trabajada para su desarrollo tomaremos de referencia el primero de éstos grupos, el cual se sustenta en el modelo de las “3 Vs” de Laney (2001):

- **Volumen:** Grandes volúmenes de datos se generan continuamente a partir de millones de dispositivos y aplicaciones (Oussous et al., 2018). El International Data Corporation estima que la cantidad de información almacenada en Datacenters y Terminales (PCs, tablets, teléfonos y dispositivos) ascenderá de 33 Zetabytes en 2018 a 175 ZB en 2025 (Reinsel, Gantz, & Rydning, 2018).
- **Velocidad:** Los datos se generan a altas velocidades y debe ser procesados de igual manera para poder extraer información útil y relevante.
- **Variedad:** Una de las principales distinciones que trae el término Big Data es la heterogeneidad estructural, contando al mismo tiempo con combinaciones de datos no estructurados, estructurados y semi-estructurados, lo que trae aparejada una complejidad natural que requiere de algoritmos más avanzados y tecnología más potente (Oussous et al., 2018).

Notablemente, el modelo de Laney, se apoya en el crecimiento tridimensional de Volumen, Velocidad y Variedad, pero no menciona explícitamente el término Big data, sino que años después otros autores (Beyer & Laney, 2012; Chen et al., 2014;

Oussous et al., 2018; Zaslavsky, Perera, & Georgakopoulos, 2013; Zikopoulos, Eaton, DeRoos, Deutsch, & Lapis, 2012) lo referencian y otros tantos, según indica De Mauro (2016), extienden dicho modelo con características adicionales como Valor (desarrollado anteriormente), Veracidad, Complejidad, Continuidad, Inmutabilidad, etc. Siendo de todos estos la Veracidad el que pareciera predominar en importancia.

Otra definición, particularmente sencilla, es la dada por Mayer-Schönberger (2013) quien dice que Big Data es la capacidad de la sociedad para aprovechar la información de formas novedosas y así obtener datos reveladores o bienes y servicios de valor significativo.

2.2.4 Machine Learning

Machine Learning es el campo de investigación que enfoca en el estudio de la teoría, performance, y propiedades de los algoritmos y sistemas de aprendizaje automatizado (J. Qiu, Wu, Ding, Xu, & Feng, 2016).

Su objetivo es el descubrimiento de información que pueda ser transformada en conocimiento y permita mayor inteligencia en la toma de decisiones (Oussous et al., 2018).

Generalmente se lo divide en 3 subdominios en función del método de aprendizaje, aprendizaje supervisado, no supervisado y por refuerzo.

El primer caso corresponde al entrenamiento por medio de datos previamente etiquetados y resultados esperados, el objetivo es que las máquinas aprendan a hacer el trabajo ya hecho.

En contraste, en el no supervisado, se provee grandes cantidades de datos de entrada que conforman características de un mismo objeto y la finalidad es que aprendan a determinar qué es a partir de la información recopilada.

El tercer subdominio es el de los algoritmos por refuerzo, donde la máquina aprende en base a prueba y error, identificando los patrones de éxito y perfeccionando el método de detección (J. Qiu et al., 2016).

2.2.5 Digital Twins

El concepto de Digital Twins, si bien es muy reciente, promete ser una herramienta para la simulación clave para la optimización de entornos complejos.

Bacchiaga (2017) simplifica su definición al explicarlo como una réplica digital en tiempo real de un dispositivo físico. Aunque el término original surge de un documento de la NASA donde se busca lograr simulaciones de alta fidelidad de los trasbordadores espaciales para así poder realizar experimentos en entornos controlados, más económicos y de menor riesgo (Glaessgen & Stargel, 2012).

Las Digital Twins terminan siendo la integración de Internet de las Cosas, Inteligencia Artificial, Machine Learning y analítics para crear modelos de simulación digital (“Azure Digital Twins | Microsoft Azure”, 2019).

2.2.6 Actores principales

El mercado de servicios profesionales y plataformas para la implementación de proyectos de analítica de datos se encuentra densamente poblado. Tan solo indagar en la cantidad de proveedores disponibles podemos encontrar más de 1500 (“Top Big Data Analytics Companies - Reviews 2019 | GoodFirms”, 2019) proveedores de los cuales al menos 45 son grandes empresas tecnológicas, que brindan servicios profesionales y cuentan con más de 10.000 empleados.

Solo por nombrar algunos de los más grandes proveedores que cuentan con plataformas propias y servicios de consultoría tenemos empresas de la talla de: Amazon Web Services, EMC, Google, HP Enterprise, IBM, Microsoft, Oracle, SAP, Teradata y VMWARE (“Top 13 Best Big Data Companies of 2019”, 2019; Verma, 2018). Así como las grandes consultoras: Gartner, Boston Consulting Group, Accenture, PricewaterhouseCoopers, Capgemini, Wipro, Aegis, Globant, EY (“47 Bigdata Analytics Consulting Companies - Compare Reviews, Features, Pricing in 2019”, 2018).

Oussous et al. (2018) hace un exhaustivo trabajo de relevamiento del ecosistema de Big Data y las principales tecnologías disponibles para su desarrollo. En el mismo deja en claro que Hadoop sienta las bases para todos los desarrollos de cada uno de los jugadores claves de este ecosistema.

A su vez el trabajo de Dresner Advisory Services (2017) sobre el mercado de Big Data remarca el protagonismo de Spark, MapReduce y Yarn como los tres principales frameworks utilizados.

2.3 DISTRIBUCIÓN DE ENERGÍA

2.3.1 Introducción

La productividad, según la Real Academia Española⁴ se define como la “*relación entre lo producido y los medios empleados, tales como mano de obra, materiales, energía*”.

El nivel óptimo de productividad se daría cuando el costo de producir una unidad adicional de un producto o servicio se aproximase a cero, aunque esto signifique llegar a una contradicción en el modelo capitalista. La fuerza motriz del sistema es el crecimiento de la productividad debido a un aumento de las eficiencias termodinámicas, reduciendo los costos de producción y el precio de los productos y servicios con el fin de atraer a más compradores. La meta es el punto donde el costo marginal es casi nulo, donde los beneficios se evaporan, el intercambio cesa y el sistema capitalista muere (Rifkin, 2014).

Tradicionalmente los economistas median la productividad según dos factores: el capital físico y el rendimiento laboral. Pero Robert Solow -premio Nobel de economía en 1987 por su teoría del crecimiento- estudió a fondo la era industrial y vio que éstos dos factores solo explicaban un 14% del crecimiento económico, mientras que el otro 86% resultaba una incógnita.

Robert Ayres ha vuelto a examinar el crecimiento económico del período industrial mediante un análisis basado en tres factores: el capital físico, el rendimiento laboral y la eficiencia termodinámica del uso de energía. Observando que el aumento de la eficiencia termodinámica con que la energía y las materias primas se convierten en trabajo útil explica la mayor parte del aumento de la productividad y del crecimiento en las economías industriales que quedaba por explicar. Revelando que el factor que faltaba era justamente la energía (R. U. Ayres & Ayres, 2010).

Al examinar las dos primeras revoluciones industriales vemos que los aumentos de la productividad y del crecimiento fueron posibles gracias a la matriz de comunicación/energía y a la infraestructura correspondiente que conformaban la plataforma tecnológica de uso general en la que se basaban las empresas. Por ejemplo, Henry Ford no podría haber alcanzado los espectaculares avances en la eficiencia y la productividad debidos al uso de herramientas eléctricas sin una red de

⁴ (Real Academia Española, s/f, p. <http://dle.rae.es/srv/search?m=30&w=productividad>)

suministro eléctrico. Para tener éxito en una economía de mercado integrada, las empresas necesitan de infraestructuras que, al ser bienes públicos, exigen la participación del estado.

En los Estados Unidos, la eficiencia energética agregada (la proporción entre el trabajo útil y el trabajo potencial que se puede extraer de los materiales) creció a ritmo constante entre 1900 y 1980, en paralelo al desarrollo de las infraestructuras del país, hasta estabilizarse en torno al 13% a finales de 1990 (R. U. Ayres & Warr, 2009). A pesar de este aumento significativo en la eficiencia, que luego se tradujo en productividad y crecimiento, casi el 87% de la energía que se había utilizado en la Segunda Revolución Industrial se había perdido durante el transporte (Laitner, Nadel, Elliott, Sachs, & Khan, 2012).

Desde su formulación, la ley de Moore se ha observado en una gran variedad de tecnologías informáticas. La capacidad de almacenamiento de los discos duros creció de manera exponencial y la capacidad de las redes informáticas sigue una curva aún más pronunciada: la velocidad de acceso a internet de usuarios finales se incrementa un %50 cada año - Ley de Nielsen - (Nielsen, 2014) y a su vez la cantidad de datos que se pueden transmitir por una red de fibra óptica se duplica cada nueve meses – Ley de Butter - (Robinson, 2000).

Pero donde más se habla hoy de crecimiento exponencial es en el sector de las energías renovables. Muchos de los actores principales en este sector proceden de la informática y de Internet y aplican sus conocimientos a este nuevo paradigma energético. Esta afinidad entre ambos campos se debe a dos factores principales.

Por un lado, la capacidad de captación de energías renovables está siguiendo su propia curva de crecimiento exponencial en los casos de la energía solar y eólica y se espera que las sucedan la bioenergía, la energía geotérmica y la energía hidráulica. Los elevados costos iniciales para investigar, desarrollar y sacar al mercado cada nueva tecnología se asemejan a los de la industria informática en sus comienzos (Rifkin, 2014).

Por otra parte, al igual que sucedió con el Internet de las comunicaciones, con un costo inicial muy elevado para crear la infraestructura y un costo marginal mínimo para producir y distribuir información, el costo inicial de construir un Internet de la

energía también es considerable y el costo marginal de producir cada unidad de energía solar o eólica es casi nulo.

Las tecnologías de Internet y de las energías renovables están empezando a fusionarse para crear un Internet de la energía que cambiará el modo de generar y distribuir energía en la sociedad. Personas produciendo su propia energía renovable en hogares, oficinas y fábricas y compartiéndola en un Internet de la energía del mismo modo que hoy generan y comparten información.

La generación de energías renovables ha demostrado tener un comportamiento similar al que se ha dado en el campo de la informática. No sólo desde la perspectiva del crecimiento sino también desde su impacto en la sociedad si consideramos el inmenso potencial del Sol como fuente de energía.

Cada 88 minutos la tierra recibe la misma cantidad de energía que consume la humanidad en un año (Naam, 2011). Pero la energía solar supone solo el 0,2% del total de la energía actual porque, hasta hace poco, su captación y distribución era muy cara. Según un estudio realizado por el Departamento de Energía de Estados Unidos, la capacidad de captar energía solar se duplica siguiendo la misma ley que Moore enunció para los circuitos integrados y el precio de las células fotovoltaicas tiende a reducirse en un 20% cada vez que se dobla la capacidad. Los precios de las células fotovoltaicas han llegado a caer de 60 dólares/vatio en 1976 a 0,66 dólares/vatio en 2013 (SunShot U.S. Department of Energy, 2012; Wesoff, 2013) a su vez, durante los últimos veinte años, la capacidad solar instalada se ha ido doblando cada dos años en un proceso de crecimiento que parece no tener fin (Brisbourne, 2012; Miller, Clark, & Shao, 2011).

Si esta tendencia continúa al ritmo actual de aceleración exponencial en 2020 el precio de la energía solar será comparable al precio medio de la electricidad de hoy y en 2030 costará la mitad de lo que hoy cuesta la electricidad generada con carbón (Naam, 2011).

En 2013 en Alemania el 23% de la electricidad era verde y se espera que este porcentaje llegue al 35% para 2020 (Hockenos, 2012). Incluso, llega a darse un fenómeno muy particular en horas del día en que la generación de energía eólica y solar llega a superar la demanda y esto se traduce en precios negativos. Este

fenómeno también se produce en otras partes del mundo como Sicilia y Texas (Vasagar, 2013).

Por su parte, con la energía eólica se da una situación similar. El viento es omnipresente y sopla en todas partes, aunque su fuerza y frecuencia puedan variar. Según un estudio de la Universidad de Stanford de la capacidad eólica mundial, si se captara el 20 % del viento disponible se podría generar siete veces más electricidad de la que consume actualmente la economía mundial (Archer, 2005). La capacidad eólica ha ido creciendo exponencialmente desde principios de los noventa y en muchos países ha logrado estar a la altura de la electricidad generada con combustibles fósiles y energía nuclear. En los últimos 25 años el rendimiento de las turbinas eólicas se ha multiplicado por 100 y la capacidad media por generador ha crecido más de 1.000 %, reduciendo a su vez los costos de producción, instalación y mantenimiento. Alcanzando un índice de crecimiento de más del 30 % anual entre 1998 y 2007, lo que equivale a doblar la capacidad cada dos años y medio (Rechsteiner, 2008).

Esto presenta un nuevo paradigma de generación de energía. Los precios negativos alteran todo el sector energético y prolonga los tiempos necesarios para la amortización de centrales térmicas, siendo que sus tiempos de mayor utilización se reducen a aquellos en los que no haya viento o sol porque las energías renovables invaden la red (Morison, 2012).

El mundo tiene una fuerte dependencia de la energía eléctrica. Es difícil imaginar lo que sucedería si esta materia prima esencial para mover el desarrollo de los países llegase a faltar. Está fuera de cualquier discusión la enorme importancia que tiene el suministro de electricidad para la humanidad, que hace confortable la vida cotidiana en los hogares, que mueve efectivamente el comercio y que hace posible el funcionamiento de la industria (Abur et al., 2002; Ramirez Castaño, 2009). El desarrollo de un país depende de su grado de industrialización y este a su vez necesita de las fuentes de energía, especialmente de la energía eléctrica (Naguil et al., 2011; Ramirez Castaño, 2009; Rifkin, 2014).

2.3.2 Sistemas de potencia

Un sistema eléctrico de potencia tiene como finalidad la producción de energía eléctrica en los centros de generación (centrales térmicas, hidráulicas, nucleares, etc)

y transportarla hasta los centros de consumo (ciudades, poblados, centros industriales, turísticos, etc). Para ello, es necesario disponer de la capacidad de generación suficiente y entregarla con eficiencia y de una manera segura al consumidor final (Ramirez Castaño, 2009; Rojas Blasco, 2005).

Al describir un sistema eléctrico de potencia se puede seccionar de diferentes maneras, una primera forma de clasificación es en función de su etapa en el proceso de generación y transporte y en consecuencia el modelo de negocios que la gobierna. Aquí se identifican las etapas de generación, transmisión, distribución y utilización de energía eléctrica.

Esto se puede pensar de forma análoga a la producción de bienes, distribución y venta mayorista, distribución y venta minorista y consumo, pero a diferencia de los bienes de consumo, la energía fluye por la red respetando concretas leyes de la física y estableciendo una estrecha interdependencia entre las distintas vías de transporte, de modo que cualquier perturbación en la red genera efectos colaterales en los demás caminos alternativos de la red. Solo las redes de gas presentan características similares (Abur et al., 2002).

Otra clasificación se hace considerando los niveles de tensión de la red. Principalmente por estos niveles inciden en forma proporcional en las distancias a las que se puede transportar dicha energía. En términos generales se puede decir que una línea de 220 kilovoltios (kV) puede transportar electricidad unos 220 km, mientras que una de 25 kV puede recorrer 25 km (“¿Qué diferencia hay entre alta, media y baja tensión?”, 2018; Rojas Blasco, 2005).

De esta forma se distinguen las líneas de **baja tensión**, generalmente por debajo de los 1000 voltios (V), **media tensión**, entre 1 y 36 kV y **alta tensión** para sistemas de hasta 300 kV. Por encima de los 300 kV se las suele considerar líneas de **muy alta tensión**. Esos valores pueden variar para cada país y más adelante se verá el caso particular de la Argentina.

La elevación del voltaje también permite transportar mayor cantidad de electricidad. De modo que, cuando hablamos de la diferencia entre alta tensión, media tensión y baja tensión, nos referimos al potencial de electricidad que puede transportar una instalación eléctrica, es decir, el voltaje.

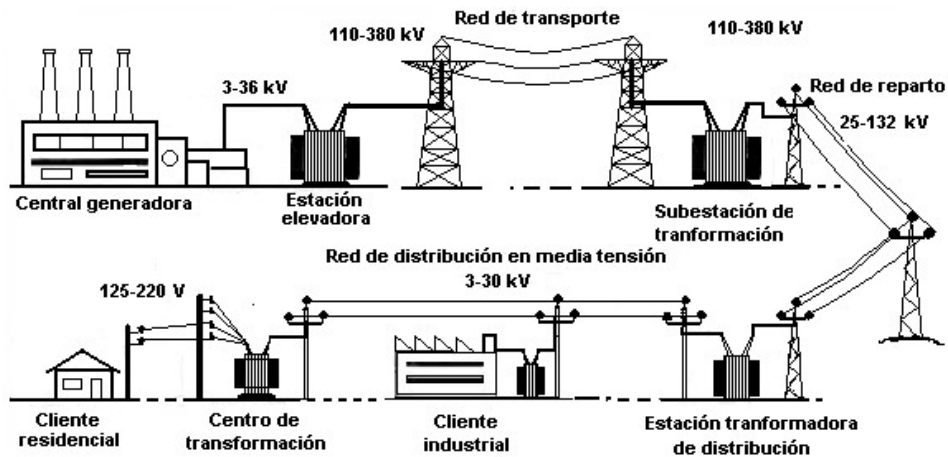


Ilustración 4: Sistema de Potencia ⁵

Estos dos enfoques nos inducen a una tercer forma, más detallada, de seccionar el sistema donde consideramos los puntos de transformación de la energía en su camino hasta el consumidor (Rojas Blasco, 2005):

- **Producción:** Como mencionamos anteriormente, es donde diferentes tipos de centrales generadoras (hidráulicas, térmicas, nucleares, solares, eólicas, etc) inyectan energía al sistema. Funcionan por medio de alternadores que generan tensiones de 3 a 36 kV.
- **Estación Elevadora:** Dedicada a elevar la tensión desde el valor de generación hasta el de transporte. Normalmente se ubican próximas a las centrales de generación y elevan la tensión entre 66 y 380 kV.
- **Red de Transporte o Transmisión:** Corresponde a la red de alcance nacional que une los grandes centros de interconexión del país con los centros de consumo. Su misión es el transporte de potencias a grandes distancias y utiliza tensiones generalmente entre los 110 y 380 kV.
- **Subestaciones de transformación o Estaciones transformadoras:** Su misión es reducir la tensión del transporte e interconexión a tensiones de reparto y se encuentran en los grandes centros de consumo.
- **Redes de reparto:** Son redes que, a partir de las subestaciones de transformación, reparten la energía hasta llegar a las estaciones transformadoras de distribución. Manejan tensiones entre los 25 y 132 kV.

⁵ ("Red de distribución de energía eléctrica", 2019)

- **Estaciones transformadoras de distribución o Subestaciones de distribución:** También se las suele llamar subestaciones de transformación y hacen el siguiente salto de la red de reparto a la de distribución.
- **Red de distribución de Media Tensión (MT):** Son redes con una topología mallada y cubren la superficie de los centros de consumo. Manejan tensiones entre los 3 y 30 kV.
- **Centros de Transformación (CT):** Reducen la tensión de media a baja y se encuentran distribuidos en todas las áreas de consumo.
- **Red de distribución de Baja Tensión (BT):** Son redes que parten de los CT y alimentan directamente a los receptores. Manejan las tensiones ya conocidas como 220/127 V o 380/220 V.

2.3.3 Distribución

Bajo los criterios descriptos anteriormente la distribución de energía comienza en la subestación de transformación, al hacer el paso de alta a media tensión y acercarse a los centros de consumo, ya sean urbanos, rurales o turísticos.

Aproximadamente las 2/3 partes de la inversión total del sistema de potencia están dedicados a la distribución por lo que es considerado el gigante invisible del sistema. Esto implica un trabajo cuidadoso de planeamiento, diseño y construcción, así como de operación del sistema de distribución. Requiere manejar grandes volúmenes de información y tomar numerosas decisiones, lo cual es una tarea compleja, pero de gran trascendencia (Ramírez Castaño, 2009).

El planeamiento del sistema de distribución es a su vez influenciado por los planes de desarrollo comunitarios, industriales y municipales, el uso de la tierra, factores geográficos, datos históricos, crecimiento de la población, densidad de carga y, a medida que nos acercamos a la implementación de Redes Eléctricas Inteligentes, se suman las fuentes de energía alternativas (Ramírez Castaño, 2009).

En su planificación se deben considerar diferentes variables en función de una clasificación multidimensional condicionada por su construcción, si son aéreas o subterráneas, su ubicación geográfica, si son urbanas, rurales, suburbanas o turísticas, el nivel de consumo y si se trata de cargas comerciales, industriales, residenciales o de alumbrado.

Todo este diseño se ve estresado cuando se agregan los factores de riesgo como ser los consumidores electrodependientes donde se debe garantizar la continuidad del servicio.

2.3.4 Red Eléctrica Inteligente, AMI y AMR

La Red Eléctrica Inteligente (REI) o “Smart Grid” es un tipo más nuevo y moderno de red eléctrica el cual está altamente integrado con tecnologías avanzadas de medición, tecnologías de información, analítica de datos, control automatizado, tecnologías de generación y distribución e infraestructuras de red (Hua et al., 2014; Jiang, Wang, Wang, Gao, & Zhang, 2016; Naguil et al., 2011).

En Junio de 2009 en los Estados Unidos publicó el “ieeep2030” que consiste en una serie de principios de interoperabilidad y estándares a través de los cuales se promueven las tecnologías de IdC para su aplicación en REI (Hua et al., 2014). En éste se establece un modelo conceptual de 7 áreas clave: generación, transmisión, distribución, clientes, operaciones, mercados y los proveedores de servicios.



Ilustración 5: Dominios de Redes Eléctricas Inteligentes – IEEE⁶

Uno de los principales componentes de las REI son la redes AMI (Sistema de Medición Avanzada, Advanced Metering Infrastructure) y AMR (Lectura de medidores automatizada, Automated Meter Reading) los cuales reemplazan lectores

⁶ (“Domains - IEEE Smart Grid”, s/f)

analógicos por sistemas computarizados que reportan el consumo por medios digitales (McLaughlin, Podkuiko, & McDaniel, 2010). Estas tecnologías, junto con las políticas de gestión de la demanda que veremos más adelante son los pilares fundamentales para la construcción de una red eléctrica bajo el modelo de prosumidores (Lo & Ansari, 2012) y como bien remarca Jaradat (2015) estos componentes son los que, por el gran volumen de información que manejan, introducen el concepto de Big Data al Smart Grid al introducir variables de velocidad, volumen y variedad en la gestión de la información.

La transición hacia una Red Eléctrica Inteligente representa un cambio drástico de paradigma para una distribuidora tradicional. La Ilustración 6 resume sólo algunos de estos cambios.

Estado Actual	Distribuidora Moderna
Análogica / Electromecánica	Digital / Microprocesadores
Centralizada (Generadores)	Distribuida (Generación)
Reactiva (Propensa a fallas y apagones)	Proactiva
Manual (Restauración en campo)	Semiautomatizada (Autocuración)
Tarifa única / estática	Mantenimiento basado en performance y estado
El consumidor no elige	Tarifa dinámica
Comunicación unidireccional	Múltiples productos
Algunos sensores	Bidireccional / Integrada
Trasparencia limitada con clientes y reguladores	Monitoreo ubicuo
Control limitado del flujo de energía	Trasparencia con clientes y reguladores
Fiabilidad estimada	Sistemas de control omnipresentes
Estándares Proprietarios	Estándares Abiertos

Ilustración 6: Transición hacia la Red Eléctrica Inteligente ⁷

2.3.5 Microrredes de generación y distribución

Alemania afronta la transición a fuentes de energía renovable de dos maneras: una convencional, que se basa en implementar el Internet de las cosas de arriba hacia abajo; la otra es horizontal, donde muchas ciudades están dotando de microcentrales a sus edificios, instalando microrredes de distribución de electricidad y fomentan el

⁷ (Jelinek & Ilic, 2000)

transporte con vehículos eléctricos (“Energiewende - Germany’s energy transformation”, 2012).

En India, donde hay 400 millones de personas sin electricidad, también se está replicando el esquema de microrredes eléctricas. A principios de 2012 la empresa Gram Power, dirigida por un empresario social de 22 años llamado Yashraj Khaitan y su colega Jacob Dickinson, instaló la primera microrred eléctrica inteligente de la India en la diminuta aldea de Khareda Lakshmipura. La electricidad de esta microrred está generada por una subestación conformada por un pequeño grupo de paneles fotovoltaicos y unas baterías que liberan electricidad de noche o cuando el tiempo está nublado. Una computadora envía datos a las oficinas que la empresa tiene en Jaipur y un tendido de cables transporta la electricidad verde a las casas del pueblo donde da servicio a sus más de 200 habitantes. Cada casa cuenta con un contador inteligente con sistema de prepago, indicador de consumo y el costo correspondiente según el momento del día (Pidd, 2012).

Estas microrredes eléctricas locales también se pueden conectar entre sí para crear redes regionales que, con el tiempo, se conectarán a las redes nacionales transformando la estructura eléctrica centralizada en una red eléctrica distribuida, colaborativa y de escala horizontal (“Microgrids key to the Smart Grid’s evolution”, 2010; Naguil et al., 2011) (Power Engineering International, 2010).

2.3.6 Calidad de Servicio

Desde la liberación de los mercados eléctricos, la electricidad ha pasado de ser un servicio a convertirse en un producto, y como tal tiene que superar mínimos criterios de calidad en pro de garantizar la satisfacción del cliente (Sumper, Sudrià, Ramírez, Villafáfila, & Chindris, 2005).

Las dos principales partes implicadas en la calidad del suministro son la compañía eléctrica que, a los efectos de considerar la calidad, abarca el conjunto desde la generación, transporte y distribución (o lo que definimos anteriormente como sistema de potencia) y el cliente o consumidor final (Sumper et al., 2005).

Múltiples autores (Baeza G, Rodríguez P, & Hernández S, 2003; Ramírez Castaño & Cano Plata, 2006; Sumper et al., 2005) coinciden en que la calidad del suministro del lado del sistema de potencia se divide en 3 partes:

- **Calidad comercial:** donde se engloba la calidad de servicio al cliente en relación con las diferentes transacciones entre el cliente y la compañía, como ser facturación, atención, lectura, etc.
- **Continuidad del suministro:** cuantificada por la cantidad y duración de las interrupciones.
- **Calidad de la onda eléctrica:** cuantificada por los valores que representan las características técnicas de la alimentación.

Desde el punto de vista del cliente, la calidad de servicio se ve condicionada por los factores de fiabilidad de la instalación y el nivel de compatibilidad de los aparatos y máquinas que posee. En este último punto se busca insensibilizarlos de perturbaciones provenientes de la red o al menos tener cierto nivel de compatibilidad con las mismas, lo cual queda en manos del diseño de éste (Sumper et al., 2005).

2.3.7 Consumo y gestión de la demanda

Siguiendo las tendencias actuales, para el 2030 se espera que la demanda de energía global aumente un %60 (Rickerson et al., 2012) lo que supondría un verdadero desafío para distribuidoras y generadoras y no se tomas las medidas necesarias a tiempo.

La gestión de la demanda refiere a la reducción deliberada de la carga durante los períodos de mayor estrés del sistema. Estos períodos pueden deberse a altos picos de demanda, a precios más elevados de generación (Enernoc, 2012) o a fluctuaciones producidas en la generación proveniente de energías renovables (Gao et al., 2014; Kärkkäinen, 2008; Stimmel, 2016) .

Siendo que tanto la reducción del consumo como la inyección de mayor energía en la red pueden ser herramientas mitigantes del desbalance de oferta-demanda, la gestión de la demanda puede ser la herramienta para restablecer el equilibrio sin necesidad de invertir en nueva infraestructura de generación, transmisión y distribución (Enernoc, 2009), con los altos costos que ello acarrea.

Cuando la curva de demanda crece durante el día en forma previsible, es deseable responder la curvatura de carga diaria con la generación de más bajos costos variables que esté disponible (Abur et al., 2002). Aunque, a su vez, la integración de energías renovables supone un verdadero desafío técnico, financiero y administrativo debido a su variabilidad como fuente de generación (Hossain, 1993; Sovacool, 2009; Stimmel, 2016)

Las principales categorías dentro de las estrategias de gestión de la demanda (en inglés “Demand Response”) son:

- **Eficiencia energética:** refiere a cambios permanentes en el equipamiento y mejoras de diseño al sistema. Si bien sus resultados son permanentes, los gastos de capital pueden ser muy elevados (Gao et al., 2014)
- **Control directo de carga:** en este esquema, se permite a la distribuidora controlar remotamente la operación de ciertos dispositivos del hogar en función de un acuerdo previo con el cliente. Este esquema presenta serios problemas en su implementación debido a la preocupación de la privacidad de los usuarios (Mohsenian-Rad, Wong, Jatskevich, Schober, & Leon-Garcia, 2010).
- **Política de precios:** considera modelos de tarifa dinámica en función de demanda pico, horario de uso o incluso tarifa dinámica. Siendo éstos esquemas los que están ganando mayor protagonismo (Gao et al., 2014; Song et al., 2014).

Un estudio realizado por EnelX, anteriormente conocida como Enernoc, muestra que un %10 de los picos de demanda ocurren en %1 de las horas del año en muchos sitios de Estados Unidos. Esto se traduce en que sólo entre 50 y 100 horas al año la demanda está por encima del %90 de la capacidad del sistema.

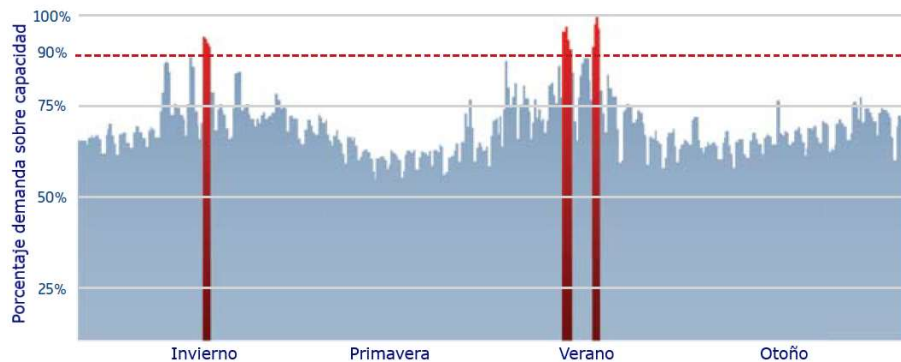


Ilustración 7: Distribución de picos de demanda en Estados Unidos ⁸

El impacto potencial de este tipo de enfoques puede tener efectos significativos en la industria. Un estudio del Brattle Group realizado en 2007 (Faruqui, Hledik, Newell, & Pfeifenberger, 2007) estableció que utilizando las mejores tecnologías disponibles a la época se podía obtener una reducción del %22,9 de la demanda pico en los Estados Unidos. Mientras que incluso utilizando tecnologías de bajo costo esa reducción podía alcanzar un %11 de la demanda. Dicho estudio también concluye que, considerando los índices de penetración, sería más realista pensar en un %5 de reducción lo que se traduce en 3 mil millones de dólares por año de ahorro en el mercado eléctrico de Estados Unidos.

2.3.8 Pérdidas

Así como la distribución es donde confluye la mayor parte de la inversión del sistema de potencia, también es donde se producen los porcentajes más grandes de pérdidas de energía. Éstas corresponden a pérdidas físicas en los conductores y transformadores de los sistemas de transmisión y distribución o bien se trata de pérdidas no técnicas o 'pérdidas negras', que corresponden a energía no facturada por fraude, descalibración de contadores, errores en los procesos de facturación, etc. (Ramirez Castaño, 2009).

Las pérdidas en un sistema eléctrico pueden ser tanto de energía como de potencia. El costo económico para las empresas corresponde al costo marginal de producir y transportar esa energía adicional desde las plantas generadoras, o puntos de compra de energía, hasta el punto donde se disipa, a través de los sistemas de transmisión, subtransmisión y distribución.

⁸ (Enernoc, 2009)

En el caso de las pérdidas de potencia es el costo marginal de inversión de capital requerido para generar y transmitir esa potencia adicional a través del sistema. Como éste dimensionamiento se hace para condiciones de demanda pico del sistema, el valor económico de las pérdidas de potencia depende de la coincidencia entre el pico de la carga considerada y el pico de la demanda total del sistema (Ramirez Castaño, 2009).

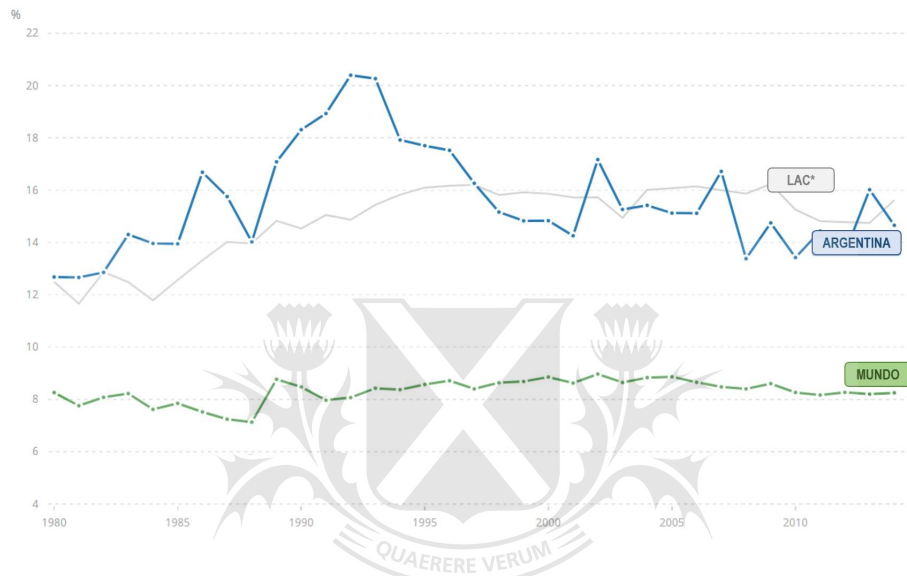


Ilustración 8: Pérdidas en transmisión y distribución sobre el total generado⁹

En la India de los 174 gigawatts generados al año un tercio se disipa a través de los conductores y equipamiento de la red de distribución o bien es robado por los usuarios. Es por esto por lo que el gobierno de Nueva Delhi decidió implementar medidores prepagos que han demostrado gran potencial como modeladores de la demanda, ya sea para disminuir en particular las pérdidas por robos o bien para llevar conciencia de uso a los clientes de menores recursos y ofrecer una solución holística en contraposición a, por ejemplo, la distribución de productos de bajo consumo como luminaria LED (Pidd, 2012).

En el caso de Colombia, en la década 1980, el sector eléctrico vio con mucha preocupación que las pérdidas de energía alcanzaban el %30 de la generación total, lo que en consecuencia generaba perjuicios económicos para las empresas distribuidoras y una pesada carga financiera, pues obligaba la realización de inversiones adicionales en generación para satisfacer la demanda real más el

⁹ ("Electric power transmission and distribution losses (% of output) | Data", 2014)

suministro de pérdidas. Esto sucedía principalmente porque las redes de distribución para entonces eran obsoletas, con altos niveles de sobrecarga y topologías inadecuadas.

El sector eléctrico colombiano se vio obligado a aplazar los proyectos de generación y de transmisión pendientes y emprender un gigantesco plan de recuperación de pérdidas a nivel de distribución, dando inicio entonces a la remodelación de la mayoría de las redes existentes, con todo el despliegue de recursos humanos, técnicos y económicos que puede implicar esta misión. Adicionalmente, en la década de 1990, se aprobó la Ley Eléctrica impulsando la reorganización del sector, abriendo un mercado de libre competencia, estableciendo una clasificación de usuarios (regulados y no regulados) y sentando las bases para eliminar los monopolios. Se creó la Comisión Reguladora de Energía y Gas (CREG) y la superintendencia de Servicios Públicos (SSP) y se firmó el Código Eléctrico Colombiano y el Código de Distribución.

Las empresas de energía aún continúan con el plan de recuperación de pérdidas y tiene como principal objetivo aumentar la eficiencia en el planeamiento, diseño, construcción y operación de las redes para cumplir con las metas impuestas por la CREG y la SSP, las cuales apuntan al mejoramiento de los índices de confiabilidad, como ser la duración y la frecuencia de las interrupciones al usuario, obligando entonces a las empresas distribuidoras y comercializadoras a compensar a los abonados por los perjuicios económicos causados cuando se sobrepasan éstas metas (Ramirez Castaño, 2009).

Similar a lo que ocurre en el mercado eléctrico argentino.

2.4 MATRIZ ENERGÉTICA ARGENTINA

2.4.1 Contexto argentino

Hacia fines de la década del '40 las empresas de servicio público de electricidad, en su mayoría privadas, no prestaban un servicio acorde a los requerimientos de los usuarios, lo que llevó a la intervención del Estado que decidió tomar a su cargo la prestación de los servicios (Suazo, 2002).

Este proceso se extendió por más de 30 años. El primer paso fue en 1957 con la agrupación de las empresas provinciales que pasaron a formar parte de Agua y Energía Eléctrica (AYEE). Luego, en 1958, las distribuidoras de Buenos Aires se constituyeron en la empresa de Servicios Eléctricos del Gran Buenos Aires (SEGBA), primero como sociedad mixta y finalmente en 1961 como empresa estatal y a la que se integró la Compañía Italo-Argentina de electricidad, concretándose dicho proceso recién en 1980. Adicionalmente, se establecieron otras sociedades de estado con el propósito de llevar adelante proyectos nucleoeléctricos e hidroeléctricos como fueron la Comisión Nacional de Energía Atómica (1950), la Comisión Mixta de Salto Grande (1946) e Hidronor (1967) y Yacyretá (1973) (Suazo, 2002).

Este escenario permitió que en los '70 y gran parte de los '80 se alcance un adecuado equilibrio entre oferta y demanda con alto grado de inversiones, las cuales se fueron reduciendo hacia fines de los '80. A pesar de éstas inversiones, la calidad de servicio seguía sin ser satisfactoria ni estaba a la altura del nivel de inversión realizado, posiblemente por mala elección de tecnologías a utilizar y baja capacidad de control de cumplimiento de contratos, como ser el caso de Yacyretá (Suazo, 2002).

El contexto político, económico y social del país, junto con el sobredimensionamiento del rol del Estado, dio lugar dificultades crecientes en la gestión, serios problemas de financiamiento y provocando el posterior deterioro del servicio en términos de eficiencia y calidad de servicio (Suazo, 2002).

Este contexto llevó a que a fines de los '80 el Estado deba plantearse la reestructuración del sector, apalancando este proceso con la Ley de Emergencia Económica (N° 23.697), la Ley de Reforma del Estado (N° 23.696) y la Ley de Marco Eléctrico (N° 24.065). Abriendo el juego a la competencia, tomando el Estado un rol de control y desregulación. Esto incrementó considerablemente las inversiones, lo que permitió reducir al mínimo las pérdidas no técnicas y elevar considerablemente los niveles de calidad de servicio técnico y comercial (Suazo, 2002).

El siguiente punto de inflexión fueron los sucesos económicos, sociales y políticos tras la salida de la convertibilidad a finales de 2001 y la Ley de Emergencia Económica N° 25.561 sancionada en Enero de 2002 (Muras et al., 2015) las cuales alteraron las reglas de juego vulnerando la seguridad jurídica en al que se sustentaba el sector ("Sector Eléctrico Argentino", s/f; Suazo, 2002).

2.4.2 Regulación

El Marco Regulatorio Eléctrico estatuido en Argentina a partir de la Ley Marco 24.065/92 estableció nuevas reglas de juego para el sector eléctrico, las cuales ponían foco en la búsqueda de la competencia. Hizo efectiva la privatización de las unidades de negocio de generación, transporte y distribución de las ex empresas nacionales SEGBA, AYEE e Hidronor a partir de 1992 y de las empresas provinciales a partir de 1995.

El objetivo era reemplazar el modelo de monopolio estatal verticalmente integrado y de gestión centralizada por un sistema competitivo basado en el mercado y con planificación indicativa, con este nuevo rol el Estado deja de intervenir en la gestión y planificación de las empresas para circunscribirse al establecimiento de políticas e instrumentos, definición de aspectos referidos a la preservación del medio ambiente y la planificación indicativa del sector para contar con información fehaciente sobre las problemáticas del mercado eléctrico (“Sector Eléctrico Argentino”, s/f; Suazo, 2002).

La legislación dispuso que la generación sea una actividad de interés general, aunque afectada a un servicio público, mientras que el transporte y distribución sean servicios públicos regulados por el Ente Regulador (ENRE) en términos de tarifas y calidad de servicio al ser considerados como monopólicos.

La organización comercial del Mercado Eléctrico Mayorista (MEM), sobre la que se estructura el conjunto de transacciones de energía eléctrica que se realizan a través del Sistema Argentino de Interconexión (SADI), se compone de un *mercado a término* con contratos por cantidades, precios y condiciones libremente pactadas entre vendedores y compradores, y un *mercado spot*, con precios sancionados en función del costo económico de producción, representado por el *costo marginal de corto plazo* medido en el *nodo mercado*¹⁰.

El Sistema de Medición Comercial (SMEC) se encarga de medir los intercambios de Energía Eléctrica entre los distintos Agentes del Mercado Eléctrico Mayorista. Esta información se utiliza para la confección de los partes diarios post-operativos, partes

¹⁰ Nodo Mercado (o Mercado): Nodo que se define como referencia para el cálculo de precios, transacciones y cargos de Transporte. Se ubica en la barra 500 kV de la Estación Transformadora Ezeiza por representar en la puesta en marcha del MEM el centro de carga del sistema.

semanales de demanda, y la posterior transacción económica mensual. Los datos registrados en los medidores son recolectados en forma automática una vez al día (“CAMMESA - SMEC”, 2018).

El Ente Nacional Regulador de la Electricidad (ENRE) es un organismo autárquico encargado de regular la actividad eléctrica y de controlar que las empresas del sector, tanto generadoras como transportistas y distribuidoras, cumplan con las obligaciones establecidas dentro del Marco Regulatorio y los Contratos de Concesión (“¿Qué es el E.N.R.E.?”, s/f).

El Decreto 351/79 (Instalaciones Eléctricas, 1979) establece los lineamientos generales para instalaciones eléctricas y es donde, entre otras cosas, se establece que en la Argentina se considera Alta tensión a aquellas por encima de los 33 kV, mientras que baja tensión corresponde a valores por debajo de 1 kV.

El Sistema Argentino de Interconexión (SADI) está organizado por regiones: GBA (Gran Buenos Aires), Litoral (Entre Ríos y Santa Fe), Provincia de Buenos Aires (sin el Gran Buenos Aires), NOA (Santiago del Estero, Tucumán, Salta, Catamarca y La Rioja), Centro (Córdoba y San Luis), Cuyo (San Juan y Mendoza), Comahue (La Pampa, Neuquén y Río Negro), Patagonia (Chubut; Santa Cruz; Tierra del Fuego, Antártida e islas).

El transporte de la electricidad a través del SADI se realiza mediante dos subsistemas que lo componen, el Sistema de Transporte de Energía Eléctrica de Alta Tensión (STAT) y el Sistema Troncal (ST). El Sistema de Alta Tensión (STAT) opera a 500 kV (500.000 volts) y 220 kV (200.000 volts), y transporta la electricidad de una región del país a otra. El Sistema Troncal (ST) transporta la electricidad dentro de una misma región entre plantas generadoras y distribuidores operando a 132, 220 y 66 kV, según las necesidades (132.000 volts, 220.000 volts y 66.000 volts).

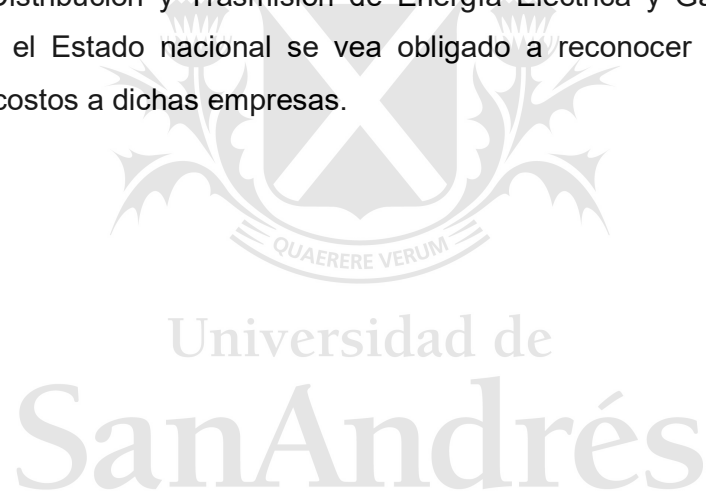
2.4.3 Subsidios

Los subsidios energéticos constituyen un fenómeno relativamente nuevo en el contexto energético argentino. En los últimos 25 años se aprecia que fueron muy reducidos hasta 2003, donde se transformaron en un fenómeno de magnitud considerable y fuertemente creciente hasta el presente. Tienen su origen en un conjunto de medidas adoptadas por el gobierno argentino tras los episodios

económicos, sociales y políticos tras la salida de la convertibilidad en 2001 (Muras et al., 2015).

La Ley de Emergencia Económica N° 25.561, sancionada en Enero de 2002, dispuso pesificar las tarifas de los servicios públicos de gas y electricidad de su valor original en dólares a un tipo de cambio de 1 peso por cada dólar, revocando a su vez todas las disposiciones relativas a ajustes de precio y mecanismos de indexación previstos en los contratos vigentes. En ese marco el Estado nacional debió hacerse cargo de los mayores costos de los productos energéticos que fue necesario importar para afrontar el crecimiento de la demanda interna (Muras et al., 2015).

La combinación de ingresos parcialmente congelados y costos crecientes provocó un progresivo deterioro de la situación patrimonial y caída de los resultados para las empresas de Distribución y Trasmisión de Energía Eléctrica y Gas Natural. Esto resultó en que el Estado nacional se vea obligado a reconocer y compensar el incremento de costos a dichas empresas.



3 TRABAJO DE CAMPO

3.1 APLICABILIDAD

Gracias a las tecnologías en torno a las REI, el volumen de datos generados en el sector eléctrico ha crecido abismalmente en los últimos años y se ha diversificado la forma en la que llegan estos datos, sus fuentes, ubicaciones e incluso la velocidad a la que llega y debe ser procesada.

Como ya vimos en “2.3.4. Red Eléctrica Inteligente, AMI y AMR”, para un entorno REI es crucial manejar en tiempo real el consumo de energía y realizar el monitoreo de las operaciones, lo que requiere interconectar medidores inteligentes, sensores, los centros de control y otras infraestructuras.

En los sistemas tradicionales la predicción se hace considerando el sistema como un todo pero, bajo el nuevo paradigma de REI, podría realizarse por cada medidor, transformador y alimentador.

Siguiendo los supuestos del trabajo de Stimmel (2016), Energetics Incorporated para la Oficina de Política Energética y Análisis de Sistemas (2016) y las referencias hechas por Akhavan-Hejazi y Mohsenian-Rad (2018) sobre los usos que se podría dar a la información obtenida por estas técnicas de medición avanzadas se pueden identificar los siguientes dominios de aplicación:

- **Balance de energético:** Por medio del análisis de históricos de consumo sería posible estimar y anticipar la demanda futura con mayor precisión (Balar, Malviya, Prasad, & Gangurde, 2013; Jaradat et al., 2015; Jiang et al., 2016; Kwac & Rajagopal, 2016).
- **Campañas de respuesta a la demanda:** A partir de la identificación de patrones de consumo es posible determinar rápidamente quienes estarían dispuestos a participar en un evento de Respuesta a la Demanda, ya sea bajando el consumo o aportando energía a la red, y cuál sería el costo-beneficio asociado a cada candidato a fin de seleccionarlos de forma más eficiente (Arguelles & Iglesias, s/f; Borgeson, Flora, Kwac, Tan, & Rajagopal, 2015; Damström & Gerlitz, 2016; Kwac & Rajagopal, 2016; Z. Liu, Wierman, Chen, Razon, & Chen, 2013; Song et al., 2014; Stimmel, 2016).

- **Predicción del precio de la energía:** En entornos de tarifa dinámica, las predicciones granulares por cliente se podrían agregar a fin de determinar y predecir la carga completa del sistema sobre regiones completas. Obteniendo así mayor precisión en la estimación y usar esto para la toma de decisiones en la compra de energía (Gama & Rodrigues, 2007; Jiang et al., 2016; Song et al., 2014). Aunque Gustavo Denicolay (entrevista personal, 7 de mayo, 2019) considera en esta materia que *“Si lo que hay que predecir es la suma agregada del consumo de energía en una región, con decenas de miles de usuarios residenciales, por propiedades estadísticas de esa suma, esto es más fácil que predecir el comportamiento individual de cada usuario”*.
- **Detección de fallas en el suministro:** Mejorar la detección y evaluación de fallas a partir del cruce de información interna (estado de equipamiento e información de consumo en tiempo real) con información externa como estado del clima, redes sociales, otros servicios, embotellamientos, etc. (Hossein Akhavan-Hejazi & Mohsenian-Rad, 2018; Kezunovic, Xie, & Grijalva, 2013; Vasilic & Kezunovic, 2005).
- **Planificación Operativa:** Refiere a la planificación de las operaciones, la cual depende de factores diversos como el clima, la carga de la red, las condiciones de generación y como éstas cambiaran en los próximos minutos, horas o días (H. Akhavan-Hejazi & Mohsenian-Rad, 2018; Dall’Anese, Baker, & Summers, 2017; Dall’Anese, Dhople, Johnson, & Giannakis, 2015; Kezunovic et al., 2013).
- **Predicción de fallas e incremento de vida útil del equipamiento:** A partir de los trabajos realizados para la predicción de fallas en turbinas de viento utilizando información de temperatura de aceite, velocidad de rotación y energía de salida (Feng, Qiu, Crabtree, Long, & Tavner, 2013; Y. Qiu, Feng, Sun, Zhang, & Infield, 2016; Y. Qiu et al., 2012) Kezunovic et al. (2013) consideran que son extrapolables al equipamiento utilizado en redes de potencia. Asimismo los entrevistados Crivelli (Tomás Crivelli, entrevista personal, 1ro de mayo, 2019), Denicolay (Gustavo Denicolay, entrevista personal, 7 de mayo, 2019) y Giraudo (Hernan Giraudo, entrevista personal, 30 de abril, 2019) coinciden en que esta extrapolación es viable por medio de

la aplicación de técnicas aprendizaje por refuerzo (vistas en “2.2.4. Machine Learning”)

- **Reducción de pérdidas no-técnicas:** A partir de la detección de anomalías en el consumo y cruce de información entre potencia entregada y facturada, es posible la detección de pérdidas no-técnicas como el hurto de energía (Stimmel, 2016). Esto es coincidente con los aportes de la entrevista realizada a Sabrina Rossello (entrevista personal, 17 de mayo, 2019) y los trabajos realizados por el área de Inteligencia de Datos de Edenor (principal distribuidora de energía de Argentina) para tal fin.
- **Prevención de fallas en cascada:** Un sistema de monitoreo en tiempo real de toda la red permitiría a los operadores anticipar eventuales cortes masivos y sus efectos en cascada que, por el desborde de carga en la periferia del punto de falla, suelen hacer más grave el problema inicial (Energetics Incorporated, 2016). Adicionalmente, como plantea Tomas Crivelli (entrevista personal, 1ro de mayo, 2019), el uso de Digital Twins permitiría la simulación escenarios para la detección de puntos de falla.

En el cuadro siguiente se evalúa la relación entre los dominios de aplicabilidad propuestos, las acciones de análisis de datos necesarias y el cumplimiento de los objetivos planteados.

Dominios	Acción necesaria	Objetivo
Campañas de respuesta a la demanda	Segmentación por patrones de consumo. Estimación de alta granularidad de beneficio potencial de cada cliente.	<div style="background-color: #4a86e8; color: white; padding: 5px; text-align: center; border-radius: 10px;">Calidad de Servicio</div> <div style="background-color: #5499c7; color: white; padding: 5px; text-align: center; border-radius: 10px; margin-top: 5px;">Nuevos Mod. de Negocios</div>
Balance energético	Segmentación natural e identificación de patrones de consumo. Predicción de generación necesaria.	<div style="background-color: #4a86e8; color: white; padding: 5px; text-align: center; border-radius: 10px;">Calidad de Servicio</div> <div style="background-color: #f1c232; color: white; padding: 5px; text-align: center; border-radius: 10px; margin-top: 5px;">Eficiencia Operativa</div> <div style="background-color: #5499c7; color: white; padding: 5px; text-align: center; border-radius: 10px; margin-top: 5px;">Nuevos Mod. de Negocios</div>

Dominios	Acción necesaria	Objetivo
Predicción del precio de la energía¹¹	Predicción de alta granularidad	<div style="background-color: #FFC000; padding: 5px; text-align: center;">Eficiencia Operativa</div> <div style="background-color: #4CAF50; padding: 5px; text-align: center; margin-top: 5px;">Nuevos Mod. de Negocios</div>
Detección de fallas en el suministro	Correlación de información externa e interna	<div style="background-color: #FFC000; padding: 5px; text-align: center;">Eficiencia Operativa</div> <div style="background-color: #2196F3; padding: 5px; text-align: center; margin-top: 5px;">Calidad de Servicio</div>
Planificación operativa	Correlación de información externa e interna	<div style="background-color: #FFC000; padding: 5px; text-align: center;">Eficiencia Operativa</div> <div style="background-color: #2196F3; padding: 5px; text-align: center; margin-top: 5px;">Calidad de Servicio</div>
Predicción de fallas e incremento de vida útil de equipamiento.	Monitoreo en tiempo real. Registro de fallas y etiquetado de datos.	<div style="background-color: #FFC000; padding: 5px; text-align: center;">Eficiencia Operativa</div> <div style="background-color: #2196F3; padding: 5px; text-align: center; margin-top: 5px;">Calidad de Servicio</div>
Reducción de pérdidas no-técnicas	Análisis de anomalías de comportamiento	<div style="background-color: #FFC000; padding: 5px; text-align: center;">Eficiencia Operativa</div>
Prevención de fallas en cascada	Monitoreo en tiempo real	<div style="background-color: #2196F3; padding: 5px; text-align: center;">Calidad de Servicio</div>

Tabla 1: Mapeo de dominios de aplicación, acciones y objetivos

3.2 APLICABILIDAD EN NÚMEROS

Al explorar la bibliografía disponible se encuentra múltiples casos donde la aplicación de técnicas de análisis de datos dio resultados favorables y concretos o bien se estima que podría darlos.

Por ejemplo, según Stimmel (2016), tomando de referencia una distribuidora de tamaño mediano en Europa, con tan sólo mejorar un %0,1 la predicción de oferta y

¹¹ En entornos de tarifa dinámica

demanda, permitiría ahorrar 3 millones de dólares de costos operativos para compensar el mercado desbalanceado.

Modelo de Mantenimiento Preventivo

En las realizadas para el trabajo de campo se pudo relevar un ejercicio hecho por la empresa Edenor, la cual tiene aproximadamente 3.000.000 de clientes en el área metropolitana de Buenos Aires.

En dicho ejercicio se propuso migrar a un modelo de mantenimiento predictivo en el cual se realiza la priorización de actividades de mantenimiento según la probabilidad de falla y criticidad de activos para alimentadores, transformadores de potencia y subestaciones.

Se tomaron como períodos de referencia las multas de los semestres 50 y 51 (correspondiente al período septiembre 2017 a agosto 2018) con sus correspondientes semestres sendero (43 y 44) que establecen la línea base para el cálculo de calidad de servicio.

Esto se contrastó con el SAIDI (“System Average Interruption Duration Index”) que mide el tiempo de la duración de la interrupción y está relacionado con la ubicación de falla, la intensidad y los recursos disponibles para la reposición como: cuadrillas, vehículos, materiales, medios de comunicación, además las vías de acceso, la longitud de redes, etc.

Tabla 2: Modelo predictivo: Línea base de cálculo

Multas semestres 50 y 51 con calidad de servicio actual	
Total multas semestres 50 y 51 con valores de calidad de servicio de semestres 43 y 44	2.329.523.921 ARS
SAIDI por Tensión	
SAIDI Total (Período: mar.18-ago.18)	13,35 hrs/cliente
SAIDI AT (Período: mar.18-ago.18)	0,05 hrs/cliente
SAIDI MT (Período: mar.18-ago.18)	8,16 hrs/cliente
SAIDI BT (Período: mar.18-ago.18)	5,13 hrs/cliente
Multas alcanzadas por modelo de mto. predictivo	
Multas alcanzadas por modelo de mto. predictivo	1.434.431.730,57 ARS
Multas alcanzadas por modelo de mto. predictivo	66.653.384,65 USD

En función de esto se establecieron supuestos de tasa de cambio, algo propio del contexto inflacionario argentino y expectativa de funcionamiento del modelo en función del nivel de optimismo sobre éste.

Tabla 3: Modelo predictivo: Supuestos

Tasa de cambio		
Tasa de cambio promedio semestres 43 y 44	21,52	ARS/USD
Tasa de cambio ene-mar 2019	40,00	ARS/USD
Calidad de servicio		
Reducción de SAIDI/SAIFI por modelo (bajo)	5,0%	%
Reducción de SAIDI/SAIFI por modelo (medio)	7,5%	%
Reducción de SAIDI/SAIFI por modelo (alto)	10,0%	%

También se cuenta con valores de inversión necesarios para la construcción y mantenimiento del modelo reflejados en la Tabla 4, donde se contempla los costos de capital y la cantidad de empleados (FTE, Full Time Employee) requeridos.

Tabla 4: Modelo Predictivo: Inversión

Impacto total		
FTEs requerido	2,00	FTEs
Costo Empresa (anual)	1.600.000	ARS/año
Años de desarrollo	2,00	años
CapEx - Inversión Total		
CapEx Total (ARS)	6,40	M ARS
CapEx Total (USD)	0,16	M USD

Al ejecutar dicho modelo y con el supuesto de cumplimiento de los diferentes niveles de confiabilidad del modelo vemos que hasta en el modelo más optimista el resultado supera ampliamente la inversión requerida.

Tabla 5: Modelo Predictivo: Resultado esperado

Impacto total		
Impacto bajo	3,33	MUSD/año
Impacto medio	5,00	MUSD/año
Impacto alto	6,67	MUSD/año

3.3 ADOPCIÓN DE BIG DATA

Según el estudio de mercado de Dresner Advisory Services sobre Big Data Analytics el uso de esta tecnología en las organizaciones alcanzó un nuevo récord de adopción en 2018 llegando al %59, con solo un %10 de entrevistados que declararon no tener planes de implementar Big Data. Esto muestra un marcado crecimiento con respecto al 17% alcanzado en 2015 donde comenzó el estudio (Dresner Advisory Services, LLC, 2018).

Este mismo estudio destaca como principal caso de uso la optimización de almacenes de datos, pero remarca el alto crecimiento, desde 2017, del uso para análisis de

comportamiento clientes y mantenimiento predictivo, ambos superando el %50 de respuestas que lo indican como algo muy importante o crítico.

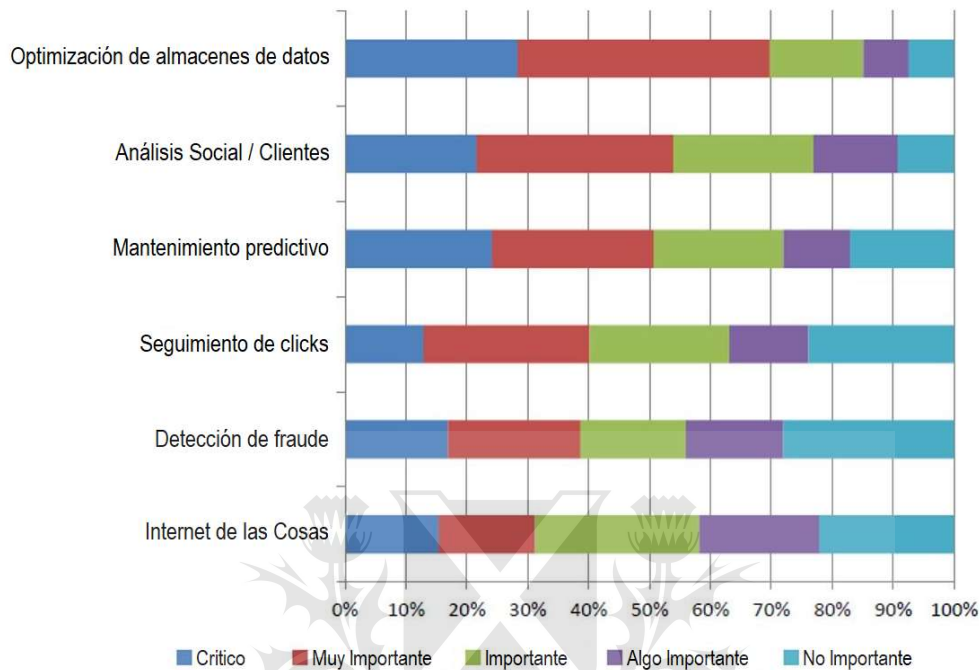


Ilustración 9: Casos de uso de Big Data¹²

En el mismo estudio también aparece la detección de fraudes como uno de los principales casos de uso que también es caso de interés de nuestra investigación.

Según una encuesta de NewVantage Venture Partners (2017), Big Data está aportando mayor valor en la reducción de costos (%49,2 de los encuestados) y en la creación de oportunidades para la innovación y disrupción (%44,3 de los encuestados), aunque esto se debe considerar yuxtaposición con lo observado por el informe de McKinsey Analytics (2018) donde se detecta que, mientras las inversiones están en crecimiento, aún no demuestran los retornos de inversión esperados. Aún resulta difícil moverse de casos de uso específicos hacia una cultura organizacional que utilice Big Data para las decisiones del día a día.

Esto último en parte puede estar explicado por la alta tasa de falla de los proyectos, que según Gartner (Goasduff, 2015) preveía que para 2017 un %60 no llegaría a

¹² (Dresner Advisory Services, LLC, 2017)

superar la fase de piloto y experimentación, predicción que no sólo se cumplió sino que fue altamente superada, alcanzando un %85 (Asay, 2017).

Esto va en concordancia con la opinión del entrevistado Alan Lerner (Entrevista personal, 30 de abril, 2019) quien observa que entre el %70 y %80 de los proyectos de este tipo fracasa. Entendiendo como fracaso el no cumplimiento de cualquiera de las variables de éxito estipuladas para el proyecto, ya sea presupuesto, tiempo o resultados.

También se debe notar que las empresas de servicios públicos no son precisamente famosas por la rápida adopción de nuevas tecnologías como pueden ser las infraestructuras de nube o software como servicio. Esto al menos comparado con empresas de telecomunicaciones o mismo la aplicación en automatización industrial que podían ser identificadas como industrias extrapolables (St John, 2017).

Según una encuesta realizada para el Harvard Business Review (Bean & Davenport, 2019) el %40,3 de los entrevistados consideró que la alineación hacia proyectos de inteligencia de datos era deficiente y un %24 que el cambio cultural es uno de los principales desafíos. Aunque por su parte otro informe de NewVantage Partners indica que %95 de los entrevistados identificó como principal obstáculo los cambios culturales (personas y procesos) (NewVantage Partners LLC, 2019).

A su vez, la discusión sobre la tercerización de servicios y la identificación de procesos centrales (Barthélemy, 2003) está llegando también a la empresas de distribución de energía, cuestionando si éstas, al igual que los bancos, aseguradoras o servicios de salud, deberían desarrollar su propio software con foco centrado en el cliente y siendo esta la base para el desarrollo de herramientas de análisis de datos (Guerster, 2017).

Pero a su vez, al compararlo con otras industrias se deben tener en cuenta sus diferencias fundamentales. Mientras la mayoría de las industrias tiene como principal objetivo la obtención de ganancias, las distribuidoras deben articular esto con la calidad de servicio, estabilidad y confiabilidad (Stimmel, 2016) lo que representa un freno a la experimentación.

4 CONCLUSIONES

Comenzamos este trabajo analizando cómo las diferentes revoluciones científicas e industriales fueron alterando el panorama mundial de la mano de las tres tecnologías necesarias para el desarrollo. Así, vimos como los cambios de paradigma en la energía, las comunicaciones y la logística fueron los motores impulsores detrás de cada una de las revoluciones industriales.

La máquina de vapor y el carbón como fuente de energía, el telégrafo como medio de comunicación y el ferrocarril como sistema de transporte y logística en la primera revolución industrial dieron aceleración a lo que se vendría luego con la energía eléctrica, el teléfono, el petróleo y el automóvil. Más adelante la automatización, la electrónica y las tecnologías de información terminaron de romper con los paradigmas tradicionales para llevar a la humanidad desde sistemas de gestión centralizados y modelos comerciales de integración vertical y con altas inversiones de capital hacia nuevos modelos de negocios con estructuras distribuidas y colaborativas.

A partir de los aportes de Güngör et al. (2011) vimos como la infraestructura energética es la más rezagada en éste sentido, explicado en parte por los altos costos fijos de dicha infraestructura frente a los combustibles fósiles y, como mencionamos en el capítulo 3.3 sobre Adopción de Big Data, por la naturaleza del negocio de distribución de energía, el cual se encuentra focalizado en la estabilidad y confiabilidad de la red en lugar de la generación de beneficios, alineado esto a que se trata de un servicio público y se debe garantizar su suministro.

También se puede observar en la literatura analizada que esta situación ya se encuentra transitando su propio proceso de cambio, apalancado por el surgimiento de Internet de las Cosas como plataforma integradora de la energía, la logística y las comunicaciones y el Smart Grid como su principal materialización en el mercado energético. Este proceso se va acelerando, en función de los temas tratados en “2.3 Distribución de energía” por la caída de los costos de las energías renovables, la implementación de microrredes de generación, así como la desregulación del sector.

En este sentido, la distribución de energía, esta viviendo una doble transformación, por un lado la descentralización impulsada por Internet de las Cosas y las desregulación de los mercados y por el otro la ‘Segunda Era de las Máquinas’ de la

que hablan McAfee y Brynjolfsson (2017), caracterizada por la automatización del conocimiento y que se materializa en el uso de modelos predictivos, análisis de datos en tiempo real y aprendizaje automatizado.

También vimos, en el capítulo 2.1.2, como estamos presenciando la aparición de una economía híbrida, en parte mercado capitalista y en parte procomún colaborativo. Dos sistemas que por momentos pueden actuar conjuntamente y en otros competir entre sí (Rifkin, 2014). Llevando a un capitalismo más racionalizado y práctico que funcione como agregador de servicios y soluciones en red, lo que podría ser un anticipo del futuro rol de las distribuidoras de energía, facilitando a los clientes la transición hacia el rol de prosumidores.

Esta transición pareciera estar fuertemente relacionada con dos fenómenos tratados en los capítulos 2.1.3 y 2.1.4 sobre financiación de la infraestructura y el uso de subsidios (y su aplicación en Argentina vista en 2.4.3) y por el concepto de valor de la información, visto en 2.2.2. Vimos cómo la desregulación, el ingreso de nuevos actores ante la oportunidad de generación distribuida y la proliferación de técnicas de análisis de datos para el perfilado de clientes, su agrupamiento y la predicción de comportamiento, así como el valor intrínseco de esta información, parecieran ser la puerta a la generación de nuevos modelos de negocios para las empresas distribuidoras de energía que hasta ahora veían muy acotado su margen de acción.

También vimos como Internet de las Cosas representa una nueva plataforma tecnológica en la que convergen las comunicaciones, energía y logística y tiene el potencial de convertirse en un nuevo motor transformador de todas las industrias a partir del boom de la automatización de la producción y su apoyo en las tecnologías de información.

El punto de intersección de todas estas innovaciones termina siendo formalizado en lo que en Alemania bautizaron en 2011 como la Industria 4.0 y luego otros países agruparon dentro del concepto de sistemas ciber-físicos. En este marco de trabajo se integran, entre otras tecnologías, Big Data, computación en nube e Internet Industrial de las Cosas. Así es como, por lo expuesto en el capítulo “2.1.7 Internet de las Cosas”, se empiezan a generar ingentes volúmenes de datos y, en consecuencia, se va construyendo la infraestructura necesaria para la transmisión y procesamiento de esa

información por medio de técnicas de minería y análisis de datos (descriptas en el capítulo 2.2).

Lo esencial y revolucionario de este proceso y que a su vez conforma el universo de Big Data es el **volumen** de información manejada.

En el caso de la distribución de energía hablamos de pasar de una lectura bimestral (como sucede en Argentina y otros países) a posiblemente, como sugiere la bibliografía, una lectura cada 15 minutos. Esto supondría contar con 5.500 veces más lecturas para analizar y procesar, pero a su vez la oportunidad contextualizar esa información por horario, clima o factores sociales, lo que se traduce en la necesidad de coleccionar esta **variedad** de datos, que antes podía no tener valor, para relacionarla y extraer información. Y esto nos lleva naturalmente a otra de las variables de Big Data que es la **velocidad** con la que se debe procesar este nuevo volumen de datos para obtener información relevante y poder tomar decisiones a tiempo.

También distinguimos un paso más en el tratamiento de la información, conocido como Machine Learning, o aprendizaje de máquina. Cuyo objetivo es el descubrimiento automatizado de información que pueda ser transformada en conocimiento y permita mayor inteligencia en la toma de decisiones.

Aquí identificamos 3 subdominios separados en función del modelo de aprendizaje.

Un primer subdominio de entrenamiento por medio de datos previamente etiquetados y resultados esperados donde el objetivo es que las máquinas aprendan a hacer el trabajo ya hecho y automatizar la producción.

Un segundo subdominio de aprendizaje no supervisado, donde se provee grandes cantidades de datos de entrada que conforman características de un mismo objeto y la finalidad es que aprendan a determinar qué es a partir de la información recopilada.

Y un tercer subdominio de aprendizaje por refuerzo, donde la máquina aprende en base a prueba y error, identificando los patrones de éxito y perfeccionando el método de detección.

En el capítulo 2.3 vimos el funcionamiento general de los sistemas de potencia y sus puntos de estrés, para luego en 2.4 hacer foco en el las redes de distribución n

Argentina y el complejo contexto en que se desarrollaron éstas infraestructuras con un ejemplo extrapolable a otros países de Latinoamérica y seguramente del mundo.

En el capítulo 3 analizamos la aplicabilidad de Big Data a la distribución de energía en función de las iniciativas vistas en otras partes del mundo y las investigaciones académicas hechas en la materia. De este trabajo se pudieron identificar varios dominios de aplicación, con sus respectivos objetivos y accionables:

- **Balance energético:** Por medio del análisis de históricos de consumo y cruce de variables, hacer una estimación de demanda y generación futura para anticipar inversiones y mecanismos preventivos de respuesta. Si bien esto hoy en día se hace, por ejemplo, correlacionando la temperatura con los valores esperados de demanda, se podría aumentar la cantidad de variables a observar para mejorar el modelo predictivo.

Accionables:

1. Segmentación natural e identificación de patrones de consumo
2. Detección de variable adicionales
3. Predicción de generación de energía necesaria

- **Campañas de respuesta a la demanda:** en las cuales se busca identificar posibles clientes dispuestos a participar de un evento de Respuesta a la Demanda, solicitándoles la reducción del consumo para mitigar picos de consumo.

Accionables:

1. Segmentación por patrones de consumo
2. Estimación de alta granularidad del beneficio potencial por cada cliente
3. Elección del mejor set de candidatos para la campaña ante un evento dado

- **Predicción del precio de la energía:** En entornos donde ya se encuentra implementada la tarifa dinámica al consumo y generación (no es el caso de la Argentina) un análisis granular permitiría tomar decisiones en tiempo real sobre

a quién sería más conveniente comprar la energía y en qué casos sería preferible ejecutar campañas de respuesta a la demanda.

Accionables:

1. Segmentación de patrones de consumo
 2. Estimación de alta granularidad de costos y beneficios
- **Planificación operativa:** Refiere a la planificación de las operaciones, la cual depende de factores diversos como el clima, la carga de la red, las condiciones de generación y como éstas cambiaran en los próximos minutos, horas o días.

Accionables:

1. Correlación de información interna y externa
 2. Aprendizaje automatizado aplicado a la logística
- **Predicción de fallas y mantenimiento preventivo:** Aplicar monitoreo en tiempo real del equipamiento para luego, por medio de aprendizaje automatizado, hacer detección automatizada de fallas.

Accionables:

1. Monitoreo en tiempo real de equipamiento
 2. Registro de fallas y etiquetado de datos
- **Reducción de pérdidas no-técnicas:** A partir de la detección de anomalías en el consumo y cruce de información entre potencia entregada y facturada, es posible la detección de robo de energía.

Accionables:

1. Detección de anomalías de comportamiento
- **Prevención de fallas en cascada:** por medio de monitoreo en tiempo real de toda la red sería posible anticipar eventuales cortes masivos y sus efectos en cascada que, por el desborde de carga en la periferia del punto de falla, suelen hacer más grave el problema.

Accionables:

1. Monitoreo en tiempo real
2. Implementación de Digital Twins

A su vez fue posible cruzar estos casos de uso con las dimensiones de reducción de costos operativos y calidad de servicios abordadas en las preguntas de investigación, así como la posibilidad de creación de nuevos modelos de negocios:

Aplicaciones	Objetivo
Campañas de respuesta a la demanda	<div style="display: flex; justify-content: space-around; align-items: center;"> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #4a86e8; color: white; text-align: center;">Calidad de Servicio</div> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #76b82a; color: white; text-align: center;">Nuevos Mod. de Negocios</div> </div>
Balance energético	<div style="display: flex; justify-content: space-around; align-items: center;"> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #4a86e8; color: white; text-align: center;">Calidad de Servicio</div> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #f1c232; color: white; text-align: center;">Eficiencia Operativa</div> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #76b82a; color: white; text-align: center;">Nuevos Mod. de Negocios</div> </div>
Predicción del precio de la energía	<div style="display: flex; justify-content: space-around; align-items: center;"> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #f1c232; color: white; text-align: center;">Eficiencia Operativa</div> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #76b82a; color: white; text-align: center;">Nuevos Mod. de Negocios</div> </div>
Detección de fallas en el suministro	<div style="display: flex; justify-content: space-around; align-items: center;"> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #f1c232; color: white; text-align: center;">Eficiencia Operativa</div> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #4a86e8; color: white; text-align: center;">Calidad de Servicio</div> </div>
Planificación operativa	<div style="display: flex; justify-content: space-around; align-items: center;"> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #f1c232; color: white; text-align: center;">Eficiencia Operativa</div> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #4a86e8; color: white; text-align: center;">Calidad de Servicio</div> </div>
Predicción de fallas e incremento de vida útil de equipamiento.	<div style="display: flex; justify-content: space-around; align-items: center;"> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #f1c232; color: white; text-align: center;">Eficiencia Operativa</div> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #4a86e8; color: white; text-align: center;">Calidad de Servicio</div> </div>
Reducción de pérdidas no-técnicas	<div style="display: flex; justify-content: center; align-items: center;"> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #f1c232; color: white; text-align: center;">Eficiencia Operativa</div> </div>
Prevención de fallas en cascada	<div style="display: flex; justify-content: center; align-items: center;"> <div style="border: 1px solid black; border-radius: 10px; padding: 5px; background-color: #4a86e8; color: white; text-align: center;">Calidad de Servicio</div> </div>

Tabla 6: Mapeo de dominios de aplicación con objetivos

Entendiendo la calidad de servicio en distribución de energía como la calidad comercial, donde se engloba la relación con el cliente a partir de sus transacciones con la compañía (facturación, atención, lectura), la continuidad del suministro, donde se cuantifica la cantidad y duración de las interrupciones, y la calidad de la onda eléctrica, donde se cuantifican valores que representan a las características técnicas de la alimentación.

Es por esto por lo que, al analizar la aplicabilidad, y a fin de contestar las preguntas e investigación, nos quedamos con casos de uso que sean extrapolables de otras industrias donde hayan sido implementados de forma exitosa.

Estos casos los vimos en el capítulo 3.3, al evaluar la adopción de Big Data. A partir de los resultados obtenidos se pudo observar coincidencia los casos de uso del 'análisis de comportamiento de clientes', 'el mantenimiento predictivo', 'la detección de fraude' e 'internet de las cosas' ya que todos ellos aparecer todos tanto en la literatura analizada y las entrevistas como en los casos de uso más comunes de Big Data.

En particular el ejercicio hecho en el capítulo 3.2 sobre un modelo de mantenimiento preventivo mostro como por una inversión de \$160.000 dólares a 2 años se podría obtener, en el modelo más pesimista, un ahorro de \$3.300.000 dólares por la reducción de un %5 de las multas por cortes de suministro, teniendo esto un doble impacto en los objetivos de calidad de servicio y eficiencia operativa.

Igualmente, si bien el supuesto de la obtención de beneficios en el mediano plazo parece estar alineado con los resultados obtenidos a lo largo de esta investigación, el alto riesgo de fracasos detectado hace notar de la necesidad de un análisis más enfocado la evaluación del éxito en sí de dichos proyectos que a si los tiempos son razonables o no.

Finalmente, con respecto a la pregunta de investigación planteada sobre la generación de nuevos modelos de negocios, si bien no se puede llegar a una respuesta concluyente por la inmadurez de la industria en esta materia, el camino parece estar marcado por la explotación de la información por su valor intrínseco, como se ve en otras industrias, permitiendo así a las distribuidoras de energía ampliar su oferta de productos y servicios, siempre y cuando la regulación se los permita.

Este resultado, si bien no es concluyente, está alineado con la opinión de los expertos consultados, quienes teorizaron sobre los posibles usos de la información; como ser el despliegue de servicios over-the-top, o bien en el aprovechamiento de la infraestructura existente para desplegar otro tipo de sensores que sirvan de agregadores de información (Tomás Crivelli, entrevista personal, 1ro de mayo, 2019).

Con todo lo expuesto creemos haber contestado todas las preguntas de investigación planteadas habiendo cubierto las dimensiones de calidad de servicio, eficiencia operativa, nuevas oportunidades de negocio y tiempos establecidos. Seguiremos investigando el tema y agradecemos nuevamente a todos los entrevistados y quien aportaron material para éste trabajo.



Universidad de
San Andrés

5 BIBLIOGRAFÍA

47 Bigdata Analytics Consulting Companies - Compare Reviews, Features, Pricing in 2019. (2018, septiembre 27). Recuperado el 19 de mayo de 2019, de PAT RESEARCH: B2B Reviews, Buying Guides & Best Practices website: <https://www.predictiveanalyticstoday.com/bigdata-analytics-consulting-companies/>

Abur, A., Alvarado, F., Alvarez Bel, C., Cañizares, C., Cidras Pidre, J., Conejo Navarro, A., ... others. (2002). *Análisis y operación de sistemas de energía eléctrica*. McGraw-Hill.

Aiman Kamarul Bahrin, M., Othman, F., Hayati Nor Azli, N., & Farihin Talib, M. (2016). Industry 4.0: A review on industrial automation and robotic. *Jurnal Teknologi*, 78. <https://doi.org/10.11113/jt.v78.9285>

Akhavan-Hejazi, H., & Mohsenian-Rad, H. (2018). Energy Storage Planning in Active Distribution Grids: A Chance-Constrained Optimization With Non-Parametric Probability Functions. *IEEE Transactions on Smart Grid*, 9(3), 1972–1985. <https://doi.org/10.1109/TSG.2016.2604286>

Akhavan-Hejazi, Hossein, & Mohsenian-Rad, H. (2018). Power systems big data analytics: An assessment of paradigm shift barriers and prospects. *Energy Reports*, 4, 91–100. <https://doi.org/10.1016/j.egyr.2017.11.002>

Aral, S., Brynjolfsson, E., & Wu, D. J. (2006). Which came first, IT or Productivity? The virtuous cycle of investment and use in Enterprise Systems. *International Conference on Information Systems*, 1–22.

Archer, C. L. (2005). Evaluation of global wind power. *Journal of Geophysical Research*, 110(D12), D12110. <https://doi.org/10.1029/2004JD005462>

Arguelles, D., & Iglesias, R. (s/f). *Visual Filtering of Large Energy Consumption Datasets by Leveraging Usage Clusters*.

Asay, M. (2017, noviembre 10). 85% of big data projects fail, but your developers can help yours succeed. Recuperado el 2 de junio de 2019, de TechRepublic website: <https://www.techrepublic.com/article/85-of-big-data-projects-fail-but-your-developers-can-help-yours-succeed/>

- Ayres, I. (2008). *Super Crunchers: How Anything Can Be Predicted*. Hachette UK.
- Ayres, R. U., & Ayres, E. H. (2010). *Crossing the Energy Divide: Moving from Fossil Fuel Dependence to a Clean-Energy Future*. New Jersey: Wharton School Publishing.
- Ayres, R. U., & Warr, B. (2009). *The Economic Growth Engine: How Useful Work Creates Material Prosperity*. Northampton, MA: Edward Elgar Publishing.
- Azure Digital Twins | Microsoft Azure. (2019). Recuperado el 3 de junio de 2019, de Microsoft Azure website: <https://azure.microsoft.com/en-us/services/digital-twins/>
- Bacchiega, G. (2017, junio). *Embedded digital twin*. Data & Analytics. Recuperado de <https://www.slideshare.net/gbacchiega/embedded-digital-twin-76567196>
- Baeza G, R., Rodríguez P, J., & Hernández S, J. L. (2003). Evaluación de confiabilidad de sistemas de distribución eléctrica en desregulación. *Revista Facultad de Ingeniería - Universidad de Tarapacá*, 11(1), 33–39. <https://doi.org/10.4067/S0718-13372003000100005>
- Balar, A., Malviya, N., Prasad, S., & Gangurde, A. (2013). Forecasting consumer behavior with innovative value proposition for organizations using big data analytics. *2013 IEEE International Conference on Computational Intelligence and Computing Research*, 1–4. IEEE.
- Barthélemy, J. (2003). The seven deadly sins of outsourcing. *Academy of Management Perspectives*, 17(2), 87–98. <https://doi.org/10.5465/ame.2003.10025203>
- Bean, R., & Davenport, T. H. (2019, febrero 5). Companies Are Failing in Their Efforts to Become Data-Driven. *Harvard Business Review*. Recuperado de <https://hbr.org/2019/02/companies-are-failing-in-their-efforts-to-become-data-driven>
- Beyer, M. A., & Laney, D. (2012). The importance of ‘big data’: a definition. *Stamford, CT: Gartner*, 2014–2018.
- Blackwell, D. (1953). Equivalent Comparisons of Experiments. *The Annals of Mathematical Statistics*, 24(2), 265–272. Recuperado de JSTOR.
- Bollier, D. (2014). *Think Like a Commoner: A Short Introduction to the Life of the Commons*. New Society Publishers.

Bollier, D., & Helfrich, S. (2014). *The Wealth of the Commons: A World Beyond Market and State*. Levellers Press.

Borgeson, S., Flora, J. A., Kwac, J., Tan, C.-W., & Rajagopal, R. (2015). Learning from Hourly Household Energy Consumption: Extracting, Visualizing and Interpreting Household Smart Meter Data. En A. Marcus (Ed.), *Design, User Experience, and Usability: Interactive Experience Design* (pp. 337–345). Springer International Publishing.

Botta, A., de Donato, W., Persico, V., & Pescapé, A. (2016). Integration of Cloud computing and Internet of Things: A survey. *Future Generation Computer Systems*, 56, 684–700. <https://doi.org/10.1016/j.future.2015.09.021>

Brisbourne, N. (2012). *Solar power—a case study in exponential growth*.

Brynjolfsson, E., Hitt, L. M., & Kim, H. H. (2011). *Strength in Numbers: How Does Data-Driven Decisionmaking Affect Firm Performance?* (SSRN Scholarly Paper Núm. ID 1819486). Recuperado de Social Science Research Network website: <https://papers.ssrn.com/abstract=1819486>

CAMMESA - SMEC. (2018). Recuperado el 1 de diciembre de 2018, de CAMMESA website: <http://portalweb.cammesa.com/pages/smec.aspx>

Carl, S., & Varian, H. (1999). Information rules: A strategic guide to the network economy. *Harvard Business School Press, Boston*.

Chandler, A. D. Jr. (1977). *The Visible Hand: The Managerial Revolution in American Business*. *Belknap Press of Harvard University Press*, 608.

Chen, M., Mao, S., & Liu, Y. (2014). Big Data: A Survey. *Mobile Networks and Applications*, 19(2), 171–209. <https://doi.org/10.1007/s11036-013-0489-0>

Coase, R. H. (2006). The Marginal Cost Controversy. En C. Tombazos & X. Yang, *Increasing Returns and Inframarginal Economics* (Vol. 3, pp. 29–46). https://doi.org/10.1142/9789812774255_0002

Collins, R. (1980). Weber's Last Theory of Capitalism: A Systematization. *American Sociological Review*, 45(6), 925. <https://doi.org/10.2307/2094910>

Dall'Anese, E., Baker, K., & Summers, T. (2017). Chance-Constrained AC Optimal Power Flow for Distribution Systems With Renewables. *IEEE Transactions on Power Systems*, 32(5), 3427–3438. <https://doi.org/10.1109/TPWRS.2017.2656080>

Dall'Anese, E., Dhople, S. V., Johnson, B. B., & Giannakis, G. B. (2015). Optimal Dispatch of Residential Photovoltaic Inverters Under Forecasting Uncertainties. *IEEE Journal of Photovoltaics*, 5(1), 350–359. <https://doi.org/10.1109/JPHOTOV.2014.2364125>

Damström, J., & Gerlitz, C. (2016). *Classification of power consumption patterns for swedish households using k-means*.

Davenport, T. H., & Harris, J. G. (2007). *Competing on Analytics: The New Science of Winning*. Harvard Business Press.

De Mauro, A., Greco, M., & Grimaldi, M. (2016). A formal definition of Big Data based on its essential features. *Library Review*, 65(3), 122–135. <https://doi.org/10.1108/LR-06-2015-0061>

DeLong, J. B., & Summers, L. H. (2001). The 'new economy' : background, historical perspective, questions, and speculations. *Economic Review*, (Q IV), 29–59. <https://doi.org/Article>

Domains - IEEE Smart Grid. (s/f). Recuperado el 13 de mayo de 2019, de <https://smartgrid.ieee.org/domains>

Dresner Advisory Services, LLC. (2017). *Big Data Analytic Market Study* (p. 94). Recuperado de https://www.microstrategy.com/getmedia/cd052225-be60-49fd-ab1c-4984ebc3cde9/Dresner-Report-Big_Data_Analytic_Market_Study-WisdomofCrowdsSeries-2017.pdf

Dresner Advisory Services, LLC. (2018). *Big Data Analytic Market Study* (p. 97). Recuperado de <https://www.globenewswire.com/news-release/2018/12/20/1670374/0/en/Dresner-Advisory-Services-Publishes-2018-Big-Data-Analytics-Market-Study.html>

Electric power sales, revenue, and energy efficiency Form EIA-861 detailed data files. (2018, octubre 12). Recuperado el 10 de febrero de 2019, de U.S. Energy Information Administration (EIA) website: <https://www.eia.gov/electricity/data/eia861/>

Electric power transmission and distribution losses (% of output) | Data. (2014). Recuperado el 23 de abril de 2019, de The World Bank - Data website: <https://data.worldbank.org/indicator/EG.ELC.LOSS.ZS?contextual=aggregate&end=2014&locations=AR-1W&start=1980&view=chart>

Energetics Incorporated. (2016). *Smart Grid Technologies: Innovation Pathway Study* (Núm. DE-BP0004706). Recuperado de Office of Energy Policy and Systems Analysis website:

<https://www.energy.gov/sites/prod/files/2017/01/f34/Innovation%20Pathway%20Study--Smart%20Grid%20Technologies.pdf>

Energiewende - Germany's energy transformation. (2012). Recuperado el 7 de diciembre de 2018, de The Economist website: <https://www.economist.com/europe/2012/07/28/energiewende>

Enernoc. (2009). *Demand Response : A Multi-Purpose Resource For Utilities and Grid Operators - White Paper*. 10–12.

Enernoc. (2012). *Designing a Successful Commercial and Industrial Demand Response Program*. 1–8.

Evans, P. C., & Annunziata, M. (2012). *Industrial Internet*. 1–37.

Faruqui, A., Hledik, R., Newell, S., & Pfeifenberger, H. (2007). The Power of 5 Percent. *The Electricity Journal*, 20(8), 68–77. <https://doi.org/10.1016/j.tej.2007.08.003>

Feng, Y., Qiu, Y., Crabtree, C. J., Long, H., & Tavner, P. J. (2013). Monitoring wind turbine gearboxes. *Wind Energy*, 16(5), 728–740. <https://doi.org/10.1002/we.1521>

Galbraith, J. R. (1977). *Organization design*. Addison-Wesley Pub. Co.

Gama, J., & Rodrigues, P. P. (2007). Stream-Based Electricity Load Forecast. En J. N. Kok, J. Koronacki, R. Lopez de Mantaras, S. Matwin, D. Mladenič, & A. Skowron (Eds.), *Knowledge Discovery in Databases: PKDD 2007* (pp. 446–453). Springer Berlin Heidelberg.

Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *International Journal of Information Management*, 35(2), 137–144. <https://doi.org/10.1016/j.ijinfomgt.2014.10.007>

Gao, B., Zhang, W., Tang, Y., Hu, M., Zhu, M., & Zhan, H. (2014). Game-Theoretic Energy Management for Residential Users with Dischargeable Plug-in Electric Vehicles. *Energies*, 7, 7499–7518. <https://doi.org/10.3390/en7117499>

Gerbert, P., Lorenz, M., Rüßmann, M., Waldner, M., Justus, J., Pascal, E., & Harnisch, M. (2015, septiembre 4). Industry 4.0: The Future of Productivity and Growth in Manufacturing Industries. Recuperado el 5 de febrero de 2019, de <https://www.bcg.com> website: https://www.bcg.com/publications/2015/engineered_products_project_business_industry_4_future_productivity_growth_manufacturing_industries.aspx

Glaessgen, E., & Stargel, D. (2012). The Digital Twin Paradigm for Future NASA and U.S. Air Force Vehicles. *53rd AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics and Materials Conference* & *20th AIAA/ASME/AHS Adaptive Structures Conference* & *14th AIAA*. Presentado en 53rd AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics and Materials Conference & 20th AIAA/ASME/AHS Adaptive Structures Conference & 14th AIAA, Honolulu, Hawaii. <https://doi.org/10.2514/6.2012-1818>

Goasduff, L. (2015, septiembre 15). Gartner Says Business Intelligence and Analytics Leaders Must Focus on Mindsets and Culture to Kick Start Advanced Analytics [Press Release]. Recuperado el 2 de junio de 2019, de Gartner website: <https://www.gartner.com/en/newsroom/press-releases/2015-09-15-gartner-says-business-intelligence-and-analytics-leaders-must-focus-on-mindsets-and-culture-to-kick-start-advanced-analytics>

Greenwood, J. (1997). *The Third Industrial Revolution: Technology, Productivity, and Income Inequality* (American Enterprise Institute, Ed.).

Guerster, J. (2017, febrero 17). Without Their Own Software, Can Utilities Survive? Recuperado el 1 de junio de 2019, de <https://www.greentechmedia.com/articles/read/without-their-own-software-can-utilities-survive>

Güngör, V. C., Sahin, D., Kocak, T., Ergüt, S., Buccella, C., Cecati, C., & Hancke, G. P. (2011). Smart grid technologies: Communication technologies and standards. *IEEE Transactions on Industrial Informatics*. <https://doi.org/10.1109/TII.2011.2166794>

- Hermann, M., Pentek, T., & Otto, B. (2016). Design principles for industrie 4.0 scenarios. *System Sciences (HICSS), 2016 49th Hawaii International Conference on*, 3928–3937. IEEE.
- Hitt, L. M., Wu, D. J., & Zhou, X. (2002). Investment in Enterprise Resource Planning: Business Impact and Productivity Measures. *Journal of Management Information Systems*, 19(1), 71–98. <https://doi.org/10.1080/07421222.2002.11045716>
- Hossain, J. (1993). Grid integration of renewables in developing countries. *Energy Policy*, 21(8), 868–874. [https://doi.org/10.1016/0301-4215\(93\)90171-B](https://doi.org/10.1016/0301-4215(93)90171-B)
- Hotelling, H. (1938). The General Welfare in Relation to Problems of Taxation and of Railway and Utility Rates. *Econometrica*, 6(3), 242. <https://doi.org/10.2307/1907054>
- Hua, L., Junguo, Z., & Fantao, L. (2014). Internet of Things Technology and its Applications in Smart Grid. *TELKOMNIKA Indonesian Journal of Electrical Engineering*, 12(2), 940–946.
- IBM. (2012). *Managing big data for smart grids and smart meters*. 8. <https://doi.org/IMW14628-USEN-00>
- Instalaciones Eléctricas. , Pub. L. No. Decreto N° 351, 351/79 (1979).
- International Energy Agency. (2013). *World Energy Outlook 2013*. <https://doi.org/10.1787/weo-2013-en>
- Jaradat, M., Jarrah, M., Bousselham, A., Jararweh, Y., & Al-Ayyoub, M. (2015). The Internet of Energy: Smart Sensor Networks and Big Data Management for Smart Grid. *Procedia Computer Science*, 56, 592–597. <https://doi.org/10.1016/j.procs.2015.07.250>
- Jelinek, M., & Ilic, M. (2000). A Strategic Framework for Electric Energy: Technology and Institutional Factors and IT in a Deregulated Environment. *Proceedings of the NSF/DOE/EPRI sponsored Workshop on Research Needs in Complex Interactive Networks, Arlington, VA*.
- Jiang, H., Wang, K., Wang, Y., Gao, M., & Zhang, Y. (2016). Energy big data: A survey. *IEEE Access*, 4, 3844–3861. <https://doi.org/10.1109/ACCESS.2016.2580581>

- Kärkkäinen, S. (2008). *Integration of Demand Side Management , Distributed Generation , Renewable Energy Sources and Energy Storages Participants* (Núm. 1). Recuperado de International Energy Agency website: <https://cleanenergysolutions.org/es/resources/integration-demand-side-management-distributed-generation-renewable-energy-sources-energy>
- Keynes, J. M. (2010). *Essays in persuasion* (New ed). Basingstoke ; New York: Palgrave Macmillan.
- Kezunovic, M., Xie, L., & Grijalva, S. (2013). The role of big data in improving power system operation and protection. *2013 IREP Symposium Bulk Power System Dynamics and Control - IX Optimization, Security and Control of the Emerging Power Grid*, 1–9. <https://doi.org/10.1109/IREP.2013.6629368>
- Kim, B. G., Ren, S., Van Der Schaar, M., & Lee, J. W. (2013). Tiered billing scheme for residential load scheduling with bidirectional energy trading. *Proceedings - IEEE INFOCOM*. <https://doi.org/10.1109/INFOCOM.2013.6567157>
- Kotler, P. (1986). Prosumers: A New Type of Consumer. *The Futurist*, 20, 24–28.
- Kuhn, S. T. (2011). *La estructura de las revoluciones científicas*. Fondo de Cultura Económica.
- Kwac, J., & Rajagopal, R. (2016). Data-Driven Targeting of Customers for Demand Response. *IEEE Transactions on Smart Grid*, 7(5), 2199–2207. <https://doi.org/10.1109/TSG.2015.2480841>
- Laitner, J. A., Nadel, S., Elliott, R. N., Sachs, H., & Khan, S. (2012). *The long-term energy efficiency potential: what the evidence suggests* (Núm. E121; pp. 1–88). Recuperado de American Council for an Energy-Efficient Economy website: <http://www.aceee.org/research-report/e121>
- Laney, D. (2001). 3-D data management: controlling data volume, velocity and variety. *META group research note*, 6(70), 1.
- Lange, O. (1937). On the Economic Theory of Socialism: Part Two. *The Review of Economic Studies, Ltd.*, 2(4).
- Liu, A. (2002). Status and development prospect of internet of things. *Internet of Things Technologies*, 2(1), 69–73.

- Liu, D., Han, X., & Liu, X. (2013). Monitoring dispatching system based on Port's Internet of Things. *Indonesian Journal of Electrical Engineering and Computer Science*, 11(1), 151–157.
- Liu, Z., Wierman, A., Chen, Y., Razon, B., & Chen, N. (2013). Data center demand response: Avoiding the coincident peak via workload shifting and local generation. *Performance Evaluation*, 70(10), 770–791.
- Lo, C. H., & Ansari, N. (2012). The progressive smart grid system from both power and communications aspects. *IEEE Communications Surveys and Tutorials*. <https://doi.org/10.1109/SURV.2011.072811.00089>
- Mayer-Schönberger, V., & Cukier, K. (2013). *Big Data: A Revolution that Will Transform how We Live, Work, and Think*. Houghton Mifflin Harcourt.
- McAfee, A. (2002). The impact of enterprise information technology adoption on operational performance: An empirical investigation. *Production and Operations Management*, 11(1), 33–53. <https://doi.org/10.1111/j.1937-5956.2002.tb00183.x>
- McAfee, A., & Brynjolfsson, E. (2017). *Machine, Platform, Crowd: Harnessing Our Digital Future* (W.W. Norton, Ed.).
- Mcintyre, R. S., Gardner, M., Wilkins, R. J., & Phillips, R. (2011). Corporate Taxpayers Corporate Tax Dodgers 2008-10. *Citizens for Tax Justice & Institute on Taxation and Economic Policy*, (November), 71.
- McKinsey Analytics. (2018). *Analytics comes of age*. Recuperado de <https://www.mckinsey.com/~media/McKinsey/Business%20Functions/McKinsey%20Analytics/Our%20Insights/Analytics%20comes%20of%20age/Analytics-comes-of-age.ashx>
- McLaughlin, S., Podkuiko, D., & McDaniel, P. (2010). Energy Theft in the Advanced Metering Infrastructure. En E. Rome & R. Bloomfield (Eds.), *Critical Information Infrastructures Security* (pp. 176–187). Springer Berlin Heidelberg.
- Melville, E., Christie, I., Burningham, K., Way, C., & Hampshire, P. (2017). The electric commons: A qualitative study of community accountability. *Energy Policy*, 106, 12–21. <https://doi.org/10.1016/j.enpol.2017.03.035>

Merchant, B. (2013). *With a Trillion Sensors, the Internet of Things Would Be the “Biggest Business in the History of Electronics”*. Recuperado de <http://motherboard.vice.com/blog/the-internet-of-things-could-be-the-biggest-business-in-the-history-of-electronics>

Microgrids key to the Smart Grid's evolution. (2010, enero 4). Recuperado el 27 de noviembre de 2018, de <https://www.powerengineeringint.com/articles/print/volume-18/issue-4/power-report/microgrids-key-to-the-smart-grids-evolution.html>

Miller, N., Clark, K., & Shao, M. (2011). Frequency responsive wind plant controls: Impacts on grid performance. *Power and Energy Society General Meeting, 2011 IEEE*, 1–8. IEEE.

Mitchell, S., Villa, N., Stewart-Weeks, M., & Lange, A. (2013). The Internet of Everything for Cities. *Cisco*, 1–21.

Mohsenian-Rad, A.-H., Wong, V. W., Jatskevich, J., Schober, R., & Leon-Garcia, A. (2010). Autonomous demand-side management based on game-theoretic energy consumption scheduling for the future smart grid. *IEEE transactions on Smart Grid*, 1(3), 320–331.

Morison, R. (2012). *Renewables Make German Power Market Design Defunct, Utility Says*.

Muras, R., Melamud, A., Ortolani, N., Martínez de Vedia, R., & Einstoss, A. (2015). *Los subsidios energéticos en argentina* (p. 108). Asociación Argentina de Presupuesto (ASAP) e Instituto Argentino de la Energía “Gral. Mosconi” (IAE).

Naam, R. (2011). *Smaller, cheaper, faster: Does Moore's law apply to solar cells?* Recuperado de <http://blogs.scientificamerican.com/guest-blog/smaller-cheaper-faster-does-moores-law-apply-to-solar-cells/>

Naguil, J. L., Szewczuk, O., Bahamode, P. J., Orue, J. L., Calafiore, C. A., & Samela, A. (2011). Redes eléctricas inteligentes en Argentina. *Tercer Congreso Iberoamericano “Hidrogeno y fuentes Sustentables De Energía”, 16–134*, 1–5. Rio Gallegos, Santa Cruz, Argentina: Universidad Tecnológica Nacional, Facultad Regional de Santa Cruz.

NewVantage Partners LLC. (2017). *Big Data Business Impact: Achieving Business Results through Innovation and Disruption*. Recuperado de <https://newvantage.com/wp-content/uploads/2018/12/Big-Data-Executive-Survey-2019-Findings.pdf>

NewVantage Partners LLC. (2019). *Data and Innovation: How Big Data and AI are Accelerating Business Transformation*. Recuperado de <https://newvantage.com/wp-content/uploads/2018/12/Big-Data-Executive-Survey-2019-Findings.pdf>

Oussous, A., Benjelloun, F.-Z., Ait Lahcen, A., & Belfkih, S. (2018). Big Data technologies: A survey. *Journal of King Saud University - Computer and Information Sciences*, 30(4), 431–448. <https://doi.org/10.1016/j.jksuci.2017.06.001>

Pidd, H. (2012, septiembre). Indian blackout held no fear for small hamlet where the power stayed on. Recuperado el 7 de diciembre de 2018, de The Guardian website: <https://www.theguardian.com/world/2012/sep/10/india-hamlet-where-power-stayed-on>

Purcell, B. M. (2014). Big data using cloud computing. *Journal of Technology Research*, 5, 9.

Qiu, J., Wu, Q., Ding, G., Xu, Y., & Feng, S. (2016). A survey of machine learning for big data processing. *EURASIP Journal on Advances in Signal Processing*, 2016(1), 67. <https://doi.org/10.1186/s13634-016-0355-x>

Qiu, Y., Feng, Y., Sun, J., Zhang, W., & Infield, D. (2016). Applying thermophysics for wind turbine drivetrain fault diagnosis using SCADA data. *IET Renewable Power Generation*, 10(5), 661–668.

Qiu, Y., Feng, Y., Tavner, P., Richardson, P., Erdos, G., & Chen, B. (2012). Wind turbine SCADA alarm analysis for improving reliability. *Wind Energy*, 15(8), 951–966. <https://doi.org/10.1002/we.513>

¿Qué diferencia hay entre alta, media y baja tensión? (2018, junio 21). Recuperado el 20 de abril de 2019, de Electra Caldense Distribución website: <https://electracaldensedistribucion.com/es/que-diferencia-hay-entre-alta-media-y-baja-tension/>

¿Qué es el E.N.R.E.? [Gobierno]. (s/f). Recuperado el 18 de mayo de 2019, de Ente Nacional Regulador de la Electricidad website: <http://www.enre.gov.ar/web/web.nsf/EnreDef?openpage>

Ramirez Castaño, S. (2009). *Redes de Distribución de Energía* (Tercera). Recuperado de <http://bdigital.unal.edu.co/3393/>

Ramírez Castaño, S., & Cano Plata, E. A. (2006). *Calidad de Servicio en Energía Eléctrica*. Recuperado de <http://bdigital.unal.edu.co/5073/>

Real Academia Española. (s/f). *Productividad*. Recuperado de <http://dle.rae.es/?id=UH8mXZv>

Recalde, M. Y., Bouille, D. H., & Girardin, L. O. (2015). Limitaciones para el desarrollo de energías renovables en argentina. *Problemas del Desarrollo*, 46(183), 89–115. <https://doi.org/10.1016/j.rpd.2015.10.005>

Rechsteiner, R. (2008). Wind power in context—A clean revolution in the energy sector. *Energy Watch Group*, (December), 11–13.

Red de distribución de energía eléctrica. (2019). En *Wikipedia, la enciclopedia libre*. Recuperado de https://es.wikipedia.org/w/index.php?title=Red_de_distribuci%C3%B3n_de_energ%C3%ADa_el%C3%A9ctrica&oldid=114106367

Reinsel, D., Gantz, J., & Rydning, J. (2018). *The Digitization of the World from Edge to Core*. 28.

Rickerson, W., Laurent, C., Jacobs, D., Dietrich, C., & Hanley, C. (2012). *Feed-in Tariffs as a Policy Instrument for Promoting Renewable Energies and Green Economies in Developing Countries* (p. 122). United Nations Environment Programme.

Rifkin, J. (2014). *La sociedad de coste marginal cero*. Buenos Aires: Paidós.

Ritzer, G. (2010). Focusing on the Prosumer. En B. Blättel-Mink & K.-U. Hellmann (Eds.), *Prosumer Revisited: Zur Aktualität einer Debatte* (pp. 61–79). https://doi.org/10.1007/978-3-531-91998-0_3

Rojas Blasco, J. (2005). *Análisis de los requisitos de hardware de un sistema para la lectura remota automática de contadores* (Universidad de Sevilla). Recuperado de <http://bibing.us.es/proyectos/abreproy/10963/direccion/>

Rothkopf, D. (2012). The Third Industrial Revolution. *Foreign Policy*, (196), 88,87.

Say, J.-B. (1971). *A Treatise on Political Economy*. <https://doi.org/10.1017/CBO9781107415324.004>

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

Sector Eléctrico Argentino. (s/f). Recuperado el 1 de junio de 2019, de Edenor Empresa - Acerca de Edenor website: https://www.edenor.com/cms/SP/EMP/RI/SEC_contexto.html

Smith, A. (1804). *An Inquiry Into the Nature and Causes of the Wealth of Nations*. Recuperado de <https://books.google.com.ar/books?id=jUBFAAAAYAAJ>

Song, L., Xiao, Y., & Van Der Schaar, M. (2014). Demand side management in smart grids using a repeated game framework. *IEEE Journal on Selected Areas in Communications*, 32(7), 1412–1424. <https://doi.org/10.1109/JSAC.2014.2332119>

Sovacool, B. K. (2009). The intermittency of wind, solar, and renewable electricity generators: Technical barrier or rhetorical excuse? *Utilities Policy*, 17(3–4), 288–296. <https://doi.org/10.1016/j.jup.2008.07.001>

St John, J. (2017, abril 13). Tracking the (Slow) Adoption Curves for Software in the Utility and Energy Industries | GTM Squared. Recuperado el 17 de mayo de 2019, de <https://www.greentechmedia.com/squared/dispatches-from-the-grid-edge/tracking-the-slow-adoption-curves-for-software-in-the-utility-and-energy-in>

Stimmel, C. L. (2016). *Big data analytics strategies for the smart grid*. Auerbach Publications.

Suazo, D. (2002). *El proceso de reestructuración y el esquema regulatorio del sector eléctrico argentino. Expectativas, reflexiones y perspectivas*. Recuperado de <http://www.adeera.com.ar/newsroom/archivosinformes/EI%20Sector%20EI%20C3%A9ctrico%20Argentino%20.pdf>

Sumper, A., Sudrià, A., Ramírez, R., Villafáfila, R., & Chindris, M. (2005). Índices de continuidad en redes de distribución y su mejora. *9º Congreso HISPANO LUSO Ingeniería Eléctrica (9CHLIE)*, 6.

SunShot U.S. Department of Energy. (2012). SunShot Vision Study. *U.S. Department of Energy*, (February), 69–96. <https://doi.org/SunShot>, Energy Efficiency and Renewable Energy, U.S. Department of Energy. NREL Report No. BK5200-47927; DOE/GO-102012-3037

Toffler, A. (1980). *The Third Wave*. Morrow.

Top 13 Best Big Data Companies of 2019. (2019). Recuperado el 19 de mayo de 2019, de <https://www.softwaretestinghelp.com/big-data-companies/>

Top Big Data Analytics Companies - Reviews 2019 | GoodFirms. (2019). Recuperado el 19 de mayo de 2019, de <https://www.goodfirms.co/big-data-analytics>

Vaidya, S., Ambad, P., & Bhosle, S. (2018). Industry 4.0 – A Glimpse. *Procedia Manufacturing*, 20, 233–238. <https://doi.org/10.1016/j.promfg.2018.02.034>

Vasagar, J. (2013). *German farmers reap benefits of harvesting renewable energy*.

Vasilic, S., & Kezunovic, M. (2005). Fuzzy ART neural network algorithm for classifying the power system faults. *IEEE Transactions on Power Delivery*, 20(2), 1306–1314. <https://doi.org/10.1109/TPWRD.2004.834676>

Verma, A. (2018, junio 26). Top 10 Big Data Companies to Target in 2019 [Updated]. Recuperado el 19 de mayo de 2019, de Whizlabs Blog website: <https://www.whizlabs.com/blog/big-data-companies-list/>

Wesoff, E. (2013, mayo 31). Flywheel Energy Storage Lives On at Beacon Power. Recuperado el 7 de diciembre de 2018, de <https://www.greentechmedia.com/articles/read/flywheel-energy-storage-lives-on-at-beacon-power>

Zaslavsky, A., Perera, C., & Georgakopoulos, D. (2013). *Sensing as a Service and Big Data*. 8.

Zikopoulos, P. C., Eaton, C., DeRoos, D., Deutsch, T., & Lapis, G. (2012). *Understanding big data: Analytics for enterprise class hadoop and streaming data*. McGraw-hill New York.



Universidad de
San Andrés

6 ANEXO I: ENTREVISTAS

6.1 ENTREVISTADOS

- **Luis Lenkiewicz:** CIO en Edenor. Principal distribuidora de energía de la Argentina.
- **Sabrina Roselló:** Subgerente de Inteligencia de Datos en Edenor.
- **Tomas Crivelli:** Doctor en Ingeniería, Especialista en Machine Learning.
- **Antonio Vazquez Brust:** Máster en Ciencias aplicadas informática urbana. Docente y especialista en Big Data con aplicación en proyectos urbanos.
- **Enrique Hoffman:** Docente, consultor y especialista en calidad, operaciones y procesos.
- **Martín Chiappe:** Analytics Manager at Deloitte - Deep Learning & Artificial Intelligence en Udacity
- **Hernan Giraud:** Director de ventas de SAS, Master en Data Mining y Descubrimiento del Conocimiento. Profesor de Minería de Datos.
- **Gustavo Denicolay:** MBA. Profesor UBA, ITBA y Austral de Big Data y Data Mining. Egresado ESLAI.
- **David Castiglione:** MBA. Profesor UDESA, UADE.
- **Alan Lerner:** Magister Technology and Telecommunications Service Management en UDESA. Director en consultoría de KPMG. Profesor UDESA, FCE-UBA, UADE

6.2 CARTA DE CONTACTO

Estimado xxxxx,

Le escribo porque estoy realizando mi tesis de maestría sobre el uso de análisis de datos aplicado a la calidad de servicio en distribución de energía. Esto es, el uso de herramientas como Big Data y modelos predictivos para reducir costos operativos y mejorar la calidad de servicio poniendo foco en la predicción de fallas, la reducción de la duración media y frecuencia de cortes de suministro y una mejor calidad de atención.

Como objetivo secundario propongo evaluar si esta información permitiría generar nuevas fuentes de ingreso o modelos de negocios a las empresas del sector.

Le agradecería se tome unos minutos para contestar las siguientes preguntas:

- ¿Usted cree que el uso intensivo de las nuevas tecnologías, específicamente Big Data y Analytics, puede aportar a la reducción de costos operativos y mejora de la calidad de servicio en servicios públicos, y en particular a la distribución de energía?
- ¿Está de acuerdo con la hipótesis planteada de que se verían resultados significativos en el mediano plazo (2 a 5 años)?
- ¿Ve posibilidades en la diversificación del modelo de negocios de las empresas de servicios públicos a partir de este tipo de iniciativas?

Cualquier otra reflexión adicional que considere pertinente al tema de investigación será bienvenida.

Muchas Gracias

Martin Rapallini