

# **LA CUARTA REVOLUCION INDUSTRIAL EN EL SECTOR ELECTRICO**

**TESIS MBA 2013**

AUTOR: PABLO L. NUÑEZ  
TUTOR: PABLO ROCCATAGLIATA

## AGRADECIMIENTOS

A mi esposa Agustina que me acompañó y soportó en todo este proceso de descubrimiento y aprendizaje.

A Martin Piñeiro y Pablo Roccatagliata por ayudarme y guiarme en la elección y desarrollo del tema.

A mi familia que siempre me apoya y motiva a seguir evolucionando.

A todos los que ayudaron y contribuyeron con información, datos, etc. para poder concretar este trabajo.

## RESUMEN

Es notable la gran velocidad a la que han evolucionado las distintas industrias. Las telecomunicaciones con las permanentes evoluciones tecnológicas de red. La tecnología de los dispositivos, con teléfonos inteligentes de enorme capacidad de procesamiento y que generan, por la interacción de los usuarios, el flujo de enormes cantidades de información valiosa. La permanente evolución de la informática en todos sus frentes.

Todo evoluciona de forma sinérgica. Porque el que no evoluciona, el que no se transforma, el que no se adapta, sencillamente pierde competitividad, y probablemente desaparezca.

La industria eléctrica, también enfrenta sus propios desafíos evolutivos. Las energías renovables, los nuevos tipos de consumo, la demanda creciente de energía, la gestión de activos, la gestión operativa, etc.

Para afrontar estos desafíos, el sector eléctrico, debe apalancarse en las herramientas adecuadas, incorporando tecnología, abrazando la transformación digital, explotando justamente la evolución de los otros sectores.

¿Cuál es el mejor camino para que esta industria logre una transformación digital exitosa?  
¿Cuáles son esas nuevas tecnologías y herramientas que le permitirán abordar dicho proceso?

El propósito de este trabajo es el de identificar las necesidades elementales de los actores más relevantes del sector eléctrico, con foco en la distribución de energía, para identificar cuáles estrategias tecnológicas pueden aplicarse y como esta tecnología se puede potenciar con aplicaciones de inteligencia artificial, logrando una verdadera evolución en todo sentido para el sector.

Es la llamada industria 4.0 la que concatena campos y disciplinas que permite a industrias “pesadas” como la eléctrica, lograr eficiencias, ampliar funcionalidades, desde los elementos o activos primarios, como ser los transformadores, hasta componentes distribuidos en toda la red, como los son los medidores inteligentes. Lógicamente en un marco estratégico que permita recorrer ese proceso, hacia lo que se denomina redes inteligentes, de manera adecuada en términos económicos y de sustentabilidad.

## PALABRAS CLAVES

- Inteligencia Artificial (IA)
- Aprendizaje automático
- Machine Learning (ML)
- Industria Eléctrica
- Redes eléctricas inteligentes
- Pérdidas técnicas (TL). Pérdidas no técnicas (NTL)
- Transformación digital

## INDICE

AGRADECIMIENTOS .....	2
RESUMEN .....	3
PALABRAS CLAVES .....	4
INDICE .....	5
INTRODUCCION.....	7
CAPITULO I. EL SECTOR ELECTRICO .....	10
Introducción.....	10
Cadena de valor .....	11
Esquema de tecnologías para la gestión .....	12
CAPITULO II. INTELIGENCIA ARTIFICIAL.....	15
Definición.....	17
La modelización .....	18
Redes neuronales artificiales .....	19
Aprendizaje profundo o deep learning.....	21
Paradigmas del aprendizaje.....	24
Las analíticas .....	30
¿Cuándo no usar el aprendizaje automático? .....	33
¿Cuándo usar el aprendizaje automático? .....	35
Abordaje de un proyecto con aprendizaje automático .....	36
CAPITULO III. LOS TRANSFORMADORES.....	38
Proceso de fabricación .....	39
Un nuevo modelo de negocio .....	43
Incorporando tecnología. El monitoreo de la condición térmica. ....	47
<i>Arquitectura de la solución</i> .....	48
<i>Beneficios estimados</i> .....	51
<i>Introduciendo el aprendizaje automático</i> .....	52
Aprendizaje automático en la predicción del índice de salud del transformador .....	52
<i>Cálculo del índice de salud del aislamiento</i> .....	54
<i>Métodos para computación HI</i> .....	55
<i>Muestra y estructura de Datos</i> .....	56
<i>Aplicando la metodología</i> .....	57
<i>Resultados por modelado de clasificador de funciones completas</i> .....	61
<i>Análisis de los resultados</i> .....	62
<i>Conclusiones</i> .....	64
CAPITULO IV. REDES ELECTRICAS INTELIGENTES .....	64

Modelo conceptual para las REI.....	66
Planificación de despliegue de una REI.....	67
Perspectiva sobre las pérdidas en la red .....	69
Definición de pérdidas .....	70
Criterios de medición de las pérdidas .....	72
Pérdidas técnicas.....	74
<i>Evaluación de las TL</i> .....	77
<i>Dimensionamiento de las TL</i> .....	78
<i>Mitigación de las TL</i> .....	79
Pérdidas no técnicas .....	80
<i>Evaluación de las NTL</i> .....	84
<i>Mitigación de las NTL</i> .....	85
<i>Aprendizaje automático para la detección de las NTL</i> .....	87
<i>Desafíos para mejorar los modelos en la detección de las NTL</i> .....	91
<i>Selección óptima de características</i> .....	91
<i>Desequilibrio de las clases</i> .....	91
<i>Errores en los datos y en las etiquetas de las clases</i> .....	92
<i>Conclusiones sobre las NTL y el aprendizaje automático</i> .....	93
CAPITULO V. CONCLUSION .....	94
BIBLIOGRAFIA.....	98
ANEXO I. Introducción a las redes neuronales .....	102

## INTRODUCCION

El mundo se encuentra en un permanente dinamismo, principalmente el mundo de los negocios, debido a la evolución permanente de las telecomunicaciones y la irrupción de nuevas tecnologías (por ejemplo: cloud computing, internet of things, data mining, inteligencia artificial, entre otros) que permiten recolectar, almacenar y analizar un enorme volumen de datos en muy corto tiempo, casi en tiempo real, lo cual hace factible la automatización e integración de todos los procesos de creación de valor, de principio a fin de la cadena productiva.

Estos cambios son conocidos como “Industria 4.0”, expresión que hace referencia a la cuarta revolución industrial, que se enfoca en digitalizar los activos físicos de principio a fin de la cadena e integrarlos en un ecosistema virtual formados por todos los actores de la cadena de valor; a diferencia de la tercera revolución industrial que se basó en la automatización de algunas máquinas y procesos.

La transformación digital se puede definir como la integración de las nuevas tecnologías en todas las áreas de una empresa para cambiar su forma de funcionar. El objetivo es optimizar los procesos, mejorar su competitividad y ofrecer un nuevo valor añadido a sus clientes. (ttandem.com, 16).

Ahora bien, ¿qué provocó la irrupción de la digitalización en las empresas? Esto es multifactorial aunque los factores más generales se relacionan con caída de ventas y la aparición de productos/servicios sustitutos, hasta la necesidad de agilizar procesos y estructuras. Los ciclos de vida de los productos se han acortado.

Actualmente, con la incorporación de metodologías ágiles en los procesos de desarrollo, el usuario “es parte” de la construcción del producto o servicio, con fuerte interacción con los equipos de diseño, desarrollo y testing. Las metodologías más tradicionales sujetas a contratos preestablecidos, rígidos en alcance por el marco contractual, van perdiendo sentido en esta dinámica de necesidades cambiantes de los usuarios. Con estos frameworks de trabajo, el usuario es parte del diseño, la experiencia de usuario se construye con el usuario, y detrás de esto todas las interfaces. Por eso los servicios o productos son cada vez más intuitivos, y por esa razón es que se acorta el tiempo de adopción, acortando el ciclo de vida de los productos.

Agregando a esto el foco en la mejora continua, todo tiende a ser más veloz y desafiante.

Para que el proceso sea eficaz las organizaciones deben tener en claro dónde están paradas y hacia dónde desean ir. Deben construir su visión. Deben entender el por qué, luego el para qué, entender quienes impactan y a quienes impactan, y así determinar el qué. Este mapa conceptual o técnica de planificación estratégica lo introdujo Gojko Adzic dentro del ecosistema de frameworks ágiles y ha tenido grandes repercusiones en la comunidad de desarrollo de software.

Las preguntas entonces a responder por los actores del sector eléctrico, ¿Quieren ser más eficientes, reducir costos y mejorar procesos? ¿Quieren salir al mercado con servicios y modelos de negocio totalmente nuevos? ¿Quieren mejorar la experiencia de los clientes? Entrar en el nuevo ecosistema no debe pensarse como un objetivo con inicio y fin, sino como un proceso iterativo de mejora continua, en el que se pueda tener feedback de los clientes para hacer cambios y mejoras.

Al igual que las personas, las empresas ahora también pueden ser nativo digitales. Airbnb y Uber encontraron en la intermediación de servicios un nicho sumamente atractivo. Wilobank, nació como un banco 100% digital en 2018, presentándose en sociedad un sábado, día no laborable, dando una señal muy fuerte en una industria muy regulada, obteniendo la primera licencia del Banco Central a una Fintech de esta naturaleza. Otro dato, hoy la empresa argentina de mayor valoración bursátil es Mercado Libre, por encima de otras compañías nacionales tradicionales de extensa trayectoria.

De acuerdo con una encuesta de Gartner a 396 líderes de 30 compañías, el 50% de los CEOs esperan que sus industrias sean transformadas de manera sustancial por la digitalización.

La transformación digital (Cisco, 2017) trata de:

- Crear nuevas experiencias para los clientes y así provocar mayor lealtad e incrementar ingresos...en 2016 Gartner observó que 9 de 10 compañías competirán principalmente en el rubro de experiencia del cliente.
- Transformar procesos y modelos de negocio y así ayudar a las empresas a responder más rápido ante los cambios del mercado y elevar la eficiencia de sus operaciones...la disfunción digital desplazará aproximadamente a 4 de las 10 principales empresas establecidas por la industria en los próximos 5 años.
- Potenciar la eficiencia del personal y la innovación y así impulsar la productividad, además de ayudar a atraer y retener talento...Gallup descubrió que aproximadamente el



87% de los empleados están desmotivados. Cuando las compañías atienden esta insatisfacción y la reducen al 10%, sus ganancias por acción aumentan un 50%.

La cuarta revolución industrial 4.0, es una nueva era que da un salto cuantitativo y cualitativo en la organización y gestión de cadenas de valor. Esta nueva etapa de la industria apuesta por una mayor automatización, conectividad y globalización. Se observa que la interrelación entre distintas áreas, como Productos, Procesos y Modelos de Negocio, ha penetrado en el mundo industrial trayendo consigo a IoT, el mundo de Big Data y Analytics, Inteligencia Artificial.

Se podrá ver que estos campos no son exclusivos de las industrias del conocimiento o de compañías nativas digitales, sino que son aplicables a todo tipo de industrias, incluso a las más tradicionales donde es hasta difícil observar la aplicación práctica de lo digital.

Se vive en una revolución que consiste en la fusión de los planos físico y digital favoreciendo la presentación de la información en un formato comprensible para todos los usuarios promoviendo la colaboración reforzada y el uso compartido de datos apoyándose en la automatización de los procesos de mantenimiento y la inteligencia artificial.

La Industria 4.0 se caracteriza por la mayor rapidez en proporcionar resultados visibles y el grado en el que afecta a los usuarios. Se trata de Internet como base de interconexión y las implicaciones que esto supone en cuanto a la facilidad de acceso a la información, la identidad digital, privacidad, seguridad, etc. Cabe esperar que la Industria 4.0 impacte de alguna forma en la sociedad, economía y política. Nos proporciona más información casi instantánea, lo que nos vuelve más informados y más exigentes. Las decisiones se toman de forma más rápida y eficiente.

El gran reto para las empresas no está en lo tecnológico, la mayor dificultad está en saber gestionar adecuadamente el cambio a la industria 4.0 y saber aprovechar al máximo las nuevas oportunidades que ofrece este concepto insertando nuevas tecnologías y capacidades digitales en activos legados.

Es importante comprender el grado de avance tecnológico de las compañías de distribución eléctrica para poder así definir lineamientos y estrategias específicas en el abordaje de las ineficiencias y/o pérdidas o bien, de las innovaciones propuestas por esa revolución. Incorporar tecnología suele ser costoso por lo que resulta mandatorio establecer un plan

tecnológico que tenga coherencia en cuanto a las inversiones necesarias y el estado económico-financiero de la compañía.

En el desarrollo del presente trabajo se podrá ver como todos estos conceptos, propios de dicha revolución cruza de manera transversal a un sector de características industriales como el sector eléctrico. Desde incorporar tecnología de y en los componentes, hasta aplicar Inteligencia Artificial buscando mejorar procesos, lograr optimizaciones, e incluso re diseñar modelos de negocio.

El trabajo tendrá una introducción teorica sobre esta cuarta revolución industrial, para luego recorrer conceptos propios de la Inteligencia Artificial, buscando demostrar mediante casos de uso aplicados, resultados muy propocios en la adopción de este tipo de disciplinas.

El trabajo es de carácter puramente investigativo sobre la recolección de datos secundarios recopilados de ensayos e investigaciones previas, articulados para demostrar como la industria 4.0 puede revolucionar el sector eléctrico en todas sus dimensiones.

## **CAPITULO I. EL SECTOR ELECTRICO**

### **Introducción**

No es posible imaginarse la vida sin electricidad. No existiría prácticamente ninguna de las herramientas que hoy son vitales para el desarrollo de actividades cotidianas, ya sea personales o de trabajo. En cierta forma, al forma de vida umana depende de ella.

En función a esto, es que desde los primeros despliegues de redes de distribución de energía, la demanda del lado usuario o consumidor no ha parado de crecer. El mundo crece en población, crece en demandas asociadas a casos de uso, por ende crece la demanda energética.

Cualquier actividad que se desarrolle requiere alguna cantidad de energía, en forma de materias primas junto con enormes cantidades de energía eléctrica que a su vez esta proviene de un elevado gasto de materias primas como el carbón, el gas o el petróleo. El desarrollo de las sociedades industriales durante el siglo XX ha estado íntimamente ligado a la disponibilidad de energía a bajo precio.

La relación entre crecimiento económico y consumo de energía es preciso. Implica un enorme desafío cubrir la necesidad energética de los 7.500 millones de habitantes que se esperan para el 2025.

Casi ningún país es autosuficiente en cuestiones de energía. La política reflejada en la matriz energética de cada país, es la que va determinando este balance.

El suministro eléctrico actual está aún muy ligado a los combustibles fósiles y a la energía nuclear aunque, paulatinamente y progresivamente, se está comenzando a escalar el uso de las energías renovables.

Existe una concepción muy naturalizada que la implementación de energías renovables representa inversiones que no justifican su retorno. En este sentido, será importante no solo adecuar los esquemas de inversión y subsidios sino que además será importante destacar el impacto de todas estas energías en términos de medioambiente.

Se observa que este proceso puede ser gradual. No es reemplazar un sistema de generación por otro, eso sí es inviable en términos de inversión, sino que es encontrar el proceso o camino de transformación. Un proceso que de manera gradual y planificada vaya incorporando cuestiones de generación distribuida, y así poder comenzar a equilibrar el suministro de energía de diferentes fuentes.

Todo esto solo es posible en términos prácticos si se incorpora tecnología e inteligencia en la red que permita justamente gestionar esta generación, en todas sus formas y orígenes.

### **Cadena de valor**

**Gráfico 1:** Cadena de valor Sector Eléctrico. Por Grupo Energía de Bogotá.



La cadena de valor involucra actividades que implican la necesidad de infraestructura pesada: costosas centrales de generación, grandes estructuras metálicas, largos tendidos de cable, etc., sus componentes son costosos, y su mantenimiento también.

Es básicamente la etapa de distribución donde se encuentran las mayores oportunidades de gestión por ende, donde más propenso es incorporar tecnología para lograr transformaciones tecnológicas reales.

### Esquema de tecnologías para la gestión

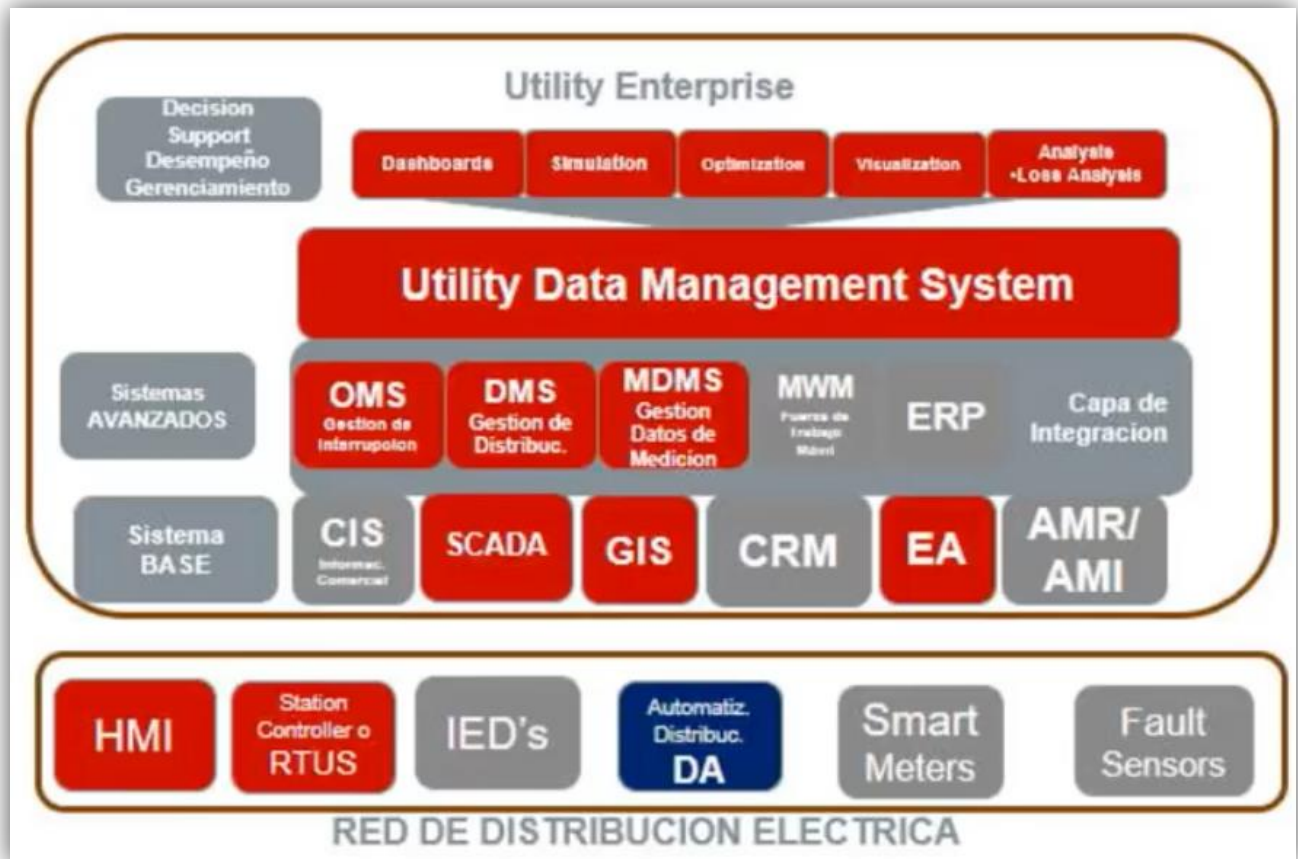
Como se mencionó, son las compañías de distribución las más propensas a incorporar tecnologías en todas sus capas de gestión. Un framework característico para una compañía de distribución moderna se puede estructurar en un esquema de capas.

Una capa inferior asociada a los elementos o “fierros”: subestaciones de potencia, redes de media tensión, subestaciones de distribución, alimentadores de baja tensión, medidores de los usuarios.

Luego, una primera capa de tecnologías que aplican a las diferentes partes de la capa anterior. Una subestación puede integrar IEDs (dispositivos electrónicos inteligentes, son dispositivos con capacidad de procesamiento y capacidad de transmisión. Ej.: relés, controladores, medidores) y puede presentar la información en una interfaz HMI para su control. También están los automatizadores de distribución (que son sensores o

reconectores), medidores inteligentes y sensores de falla, todos elementos asociados a inteligencia en la medición y en su visualización.

**Gráfico 2:** Framework operativo de una compañía de distribución eléctrica. Por Ing. Will Medina (2019).



La capa siguiente es de sistemas que integran este framework. Están los sistemas básicos y avanzados.

Dentro de los sistemas básicos están los elementos esenciales como los sistemas SCADA (Supervisory Control And Data Acquisition / Control Supervisor y Adquisición de Datos) que son programas de software que se utilizan para gestionar y controlar sistemas remotos o locales mediante el uso de una interfaz gráfica que comunica al usuario con el programa.

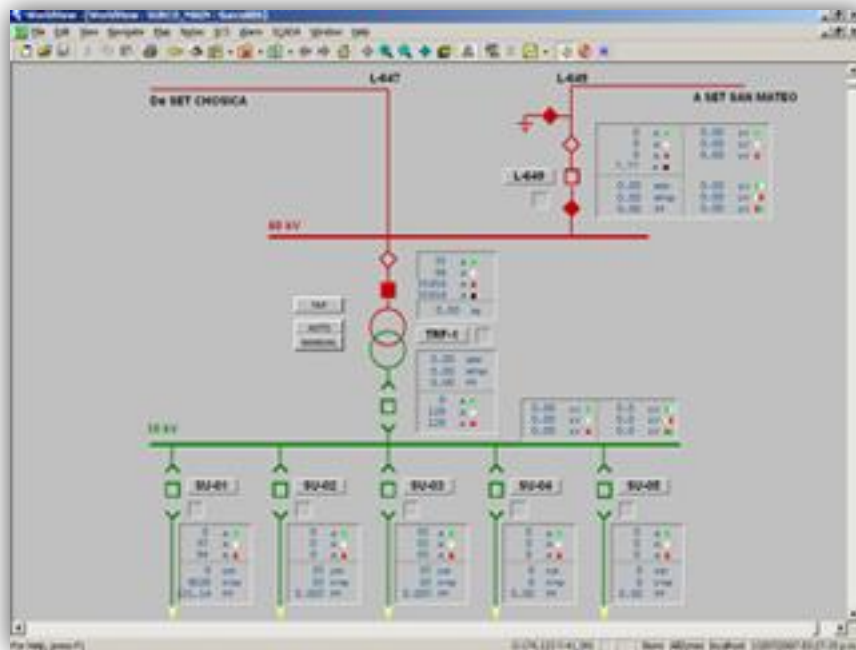
Los sistemas SCADA cuentan con una estructura básica que parte de sus controladores lógicos programables (PLC) o unidades de terminal remotas (RTU), es decir, de microordenadores que se comunican con múltiples objetos, ya sean máquinas, dispositivos, sensores o HMI. SCADA procesa, distribuye y enseña los datos, permitiendo a los

operadores y otros trabajadores a realizar un análisis de los datos para facilitar la toma de decisiones.

Por ejemplo, los sistemas SCADA muestran rápidamente a un operario una lista de productos que están presentando errores. Esto hace que el operario pause la operación y vea los datos del programa mediante una HMI para identificar la causa del inconveniente. Posteriormente, el operario revisa los datos y descubre que una de las máquinas no está funcionando de forma adecuada.

En resumen, estos sistemas no solo comunican los problemas, sino que también ayudan a solucionarlo rápidamente, evitando pérdidas.

**Gráfico 3:** Interfaz de usuario HMI ejemplo. Por ABB (2019).



En esta capa base, están además elementos como el CRM y CIS que son plataformas de relacionamiento con el cliente y el GIS, que es la plataforma de geo posicionamiento que permite llevar control y visualización geo referenciado de elementos de la red, clientes, etc. También existen los sistemas AMI que son los sistemas ligados a la medición (la evolución de los sistemas de medición remota).

Luego en un nivel siguiente están los sistemas avanzados, que obtienen información de los sistemas base y generan valor incremental a la operación o gestión. En este nivel se cuenta

con elementos relevantes en cuanto a sus prestaciones como el OMS (sistema de gestión de fallas).

El SCADA al integrarse con los sistemas comerciales (CRM y CIS) y de geo posicionamiento, nutre de información al OMS, el cual utiliza el estado más actualizado de la red y un motor de predicción avanzado para predecir y responder a fallos de suministro de una forma más informada y eficiente.

Por ejemplo, OMS toma el reclamo de un cliente al contact center (desde el CRM) y como el OMS “conoce” la topología de la red (por el GIS), puede determinar cuál es el dispositivo o elemento que está fallando. Luego el OMS puede comunicar al SCADA donde es el punto de falla, y este ser visualizado en el dashboard por el equipo de operaciones para que actúe sobre la falla. Este flujo es automático, y sucede en segundos.

En esta nivel también están los elementos como el DMS (que permite flujos de carga en línea y traslados de carga en alimentadores más complejos) y el MDM (que utilizando la información de medición de los medidores inteligentes permite validar y estimar la información de millones de clientes).

Luego a un nivel superior está el nivel de decisión y de desempeño de la compañía.

Hasta aquí se repasó algo de la coyuntura del sector, retos futuros, la cadena de valor actual y un framework de gestión característico de una compañía con el aspiracional a ser un jugador líder en la distribución de energía.

Ahora se avanzará hacia una introducción inicial a un campo de la industria 4.0 puede considerarse como un acelerador en términos de evolución tecnológica para la industria de la electricidad, y que sin duda apalancará fuertemente eficiencias en la gestión de las compañías del sector, generando mejoras sustanciales en la experiencia de usuario de los usuarios. Este campo es el de la Inteligencia Artificial y más específicamente el subcampo del aprendizaje automático.

## **CAPITULO II. INTELIGENCIA ARTIFICIAL**

En 1997 Gary Kasparov fue derrotado en una serie de partidas de ajedrez por una máquina llamada Deeper Blue (su versión anterior Deep Blue había sido derrotada por Kasparov el año anterior). Ambas eran supercomputadoras desarrolladas por IBM para jugar al ajedrez. Deeper Blue fue la primera que venció a un campeón del mundo vigente. Era una

computadora de procesamiento paralelo masivo capaz de calcular 200 millones de posiciones por segundo, dos veces más rápido que la versión de 1996.

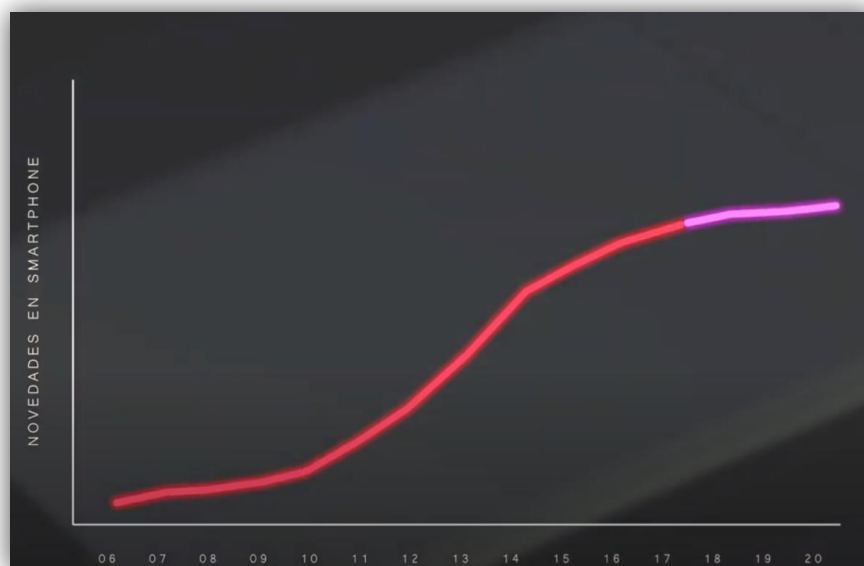
Por primera vez un ordenador lograba dominar en un campo ligado estrechamente a la habilidad cognitiva humana.

En 2015 Google le gana al campeón mundial de GO del mundo. En este caso no fue “fuerza bruta” como con Deep Blue, sino que fue posible gracias a nuevas técnicas y algoritmos descubiertos en la última década que llevaron el campo de la inteligencia artificial a una nueva era: la 4ta revolución.

En MadeByGoogle del 2016, Google realizó una fuerte declaración de intención, anunciaba en cierta forma un cambio de filosofía donde dejaban de enfocarse en los dispositivos para centrarse en la IA como estrategia core de desarrollo (el paso del Mobile First al IA First le llamaron).

La ley de Moore expresa que aproximadamente cada dos años se duplica el número de transistores en un microprocesador. En la actualidad es cada vez más difícil introducir innovaciones de hardware que realmente tengan valor e impacto en los usuarios.

**Gráfico 4:** Ley de Moore 2020. Por Carlos Santana Vega (2019)



Para Google esto es una oportunidad. Porque al estabilizar el dispositivo y no tener tantos cambios evolutivos, esto permite a los desarrollares tener mayor claridad a la hora de



desarrollar aplicaciones. Define una nueva estrategia que viene de la intersección entre el hardware + el software + IA.

Esto permitirá volver a levantar la curva, de hecho Google ya ha logrado incorporar en muchos de sus dispositivos funcionalidades de machine learning (x ejemplo, en el Google pixel el modo retrato en las fotos no se realiza a partir de la doble cámara sino mediante el desenfoque del fondo que se realiza a partir de SW y machine learning).

### **Definición**

IA es la subdisciplina del campo del campo de la informática que busca la creación de máquinas que puedan imitar comportamientos inteligentes.

La IA permite automatizar lo que no se puede expresar. Esto se debe a que permite expresar deseos con ejemplos y objetivos en lugar de instrucciones explícitas, lo que significa que puede automatizar más allá de la expresión humana.

Estos comportamientos pueden ser muy diversos: conducir, analizar patrones, reconocer voces, reconocer caras, o ganar a juegos. Cada vez se reúnen más evidencias que demuestran que estas máquinas logran en ciertas áreas mejores rendimientos que los humanos. Esto no implica que las maquinas sean más capaces que los humanos ya que una maquina con un excelente desempeño en un campo de acción probablemente cuando se ponga a funcionar en otro campo no logre buenos resultados.

Así surge una primera clasificación de IA: débiles y fuertes. Las débiles se refieren a aquellos sistemas que pueden cumplir con un conjunto muy limitado de tareas. Las fuertes hacen referencia a esas IAs que son capaces de aplicarse a una gran variedad de problemas y dominios diferentes. Actualmente todas las IA en el mundo pertenecen al grupo de las débiles.

Hay múltiples formas de hacer IA, un ejemplo es a través de machine learning. En machine learning se busca como dotar a las máquinas de capacidad de aprendizaje. Dentro del machine learning existen diferentes técnicas que sirven para cubrir diferentes tipos de aplicación: árbol de decisión, modelos de clasificación, modelos de regresión, técnicas de clusterización, y la de mayor fama, las redes neuronales.

## La modelización

De manera simplificada se puede afirmar que la evolución de la especie humana se dió a partir de la capacidad de detectar patrones y usarlos a su favor. La ciencia le permitió al ser humano explotar su capacidad de observar el mundo de manera simplificada reconstruyendo la realidad a través de modelos.

Un modelo es una reconstrucción conceptual simplificada de una realidad más compleja. A través de esta reconstrucción el ser humano es capaz de entender mejor dicha realidad y poder utilizarla a su favor. Un modelo busca el equilibrio entre aproximarse a representar correctamente una realidad y ser simple para poder utilizarse. Los modelos probabilísticos son modelos en los que se utiliza la probabilidad como parte del modelo, y esto permite comprimir en base a probabilidades mucho de la variabilidad de la realidad, siendo más fácil gestionar la información que se recibe del entorno.

A partir de los datos es posible construir modelos que mejor se aproximen a una realidad a estudiar, con estos modelos se puede ajustar dicha realidad para probar nuevos escenarios, rebobinar para encontrar el origen de ciertos fenómenos o adelantarla para hacer predicciones de que ocurrirá en el futuro.

Hay 3 elementos que son relevantes en todo este campo: los datos, los parámetros y el error.

Los datos es la forma de tomar de contacto con la realidad, las mediciones que se realizan de esa realidad. A partir de estos es de donde se extrae toda la información para construir un modelo. Típicamente los datos son multidimensionales (ej.: conjunto de datos donde cada registro es una persona, cada una de las propiedades de una persona representa una dimensión por sí misma. Cada uno de estos atributos hace que la persona esté representada como un punto en un espacio multidimensional). El único aliado para lidiar con estos espacios multidimensionales son las matemáticas.

El otro concepto es el de parámetro. Los parámetros son los valores que se pueden modificar para contar con la flexibilidad necesaria para ajustarse a los datos. Los parámetros son como palancas de los algoritmos que se optimizan para lograr optimizar una función objetivo.

En machine learning la tarea es encontrar aquellos algoritmos que sean capaces a partir de los datos de aprender cuales son los valores óptimos de estos parámetros. Para lograr esto es necesario un tercer elemento esencial que es el error.

Lo que no se mide no se puede mejorar por ende siempre es necesario definir una función de error que indique como un modelo se ajusta o no a los datos. En el aprendizaje supervisado esta función de error se computa a partir de los datos de salida suministrados.

En el aprendizaje no supervisado se computa en base a los datos de entrada. La señal de error es de vital importancia ya que es la que permitirá reajustar los parámetros del modelo en un proceso denominado de optimización llamado de entrenamiento o de ajuste del modelo. El modelo fundamental más utilizado en machine learning es el de regresión lineal.


### **Redes neuronales artificiales**

Es una familia de algoritmos de machine learning muy potente que permite modelar comportamientos inteligentes. La complejidad de estos sistemas emerge de la interacción de muchas partes más simples trabajando conjuntamente. En esta temática a cada una de estas partes se las denomina neurona.

La neurona es entonces la unidad básica de procesamiento que se puede encontrar dentro de una red neuronal. Similar a las neuronas biológicas estas neuronas tienen conexiones de entrada a través de los que reciben estímulos externos (los valores de entrada). Con estos valores la neurona realizará un cálculo interno y generará un valor de salida. En definitiva, la neurona es una función matemática.

Internamente la neurona utiliza todos los valores de entrada para realizar una suma ponderada de ellos. La ponderación de cada una de las entradas viene dada por el peso que se le otorga a cada una de las conexiones de entrada. Es decir cada conexión que llega a la neurona tendrá asociado un valor que servirá para definir con que intensidad cada variable de entrada afecta a la neurona. Intuitivamente es posible asociar estos pesos a los parámetros del modelo y serán los valores que se pueden ajustar para que la red neuronal pueda funcionar.


**Gráfico 5:** Diagrama de una neurona con 3 entradas. Por Carlos Santana Vega (2019).



Como se observa, lo que hace una neurona internamente es básicamente un modelo de regresión lineal.

Como se observó anteriormente, en el modelo de regresión lineal se cuenta con un término independiente que sirve para mover verticalmente a la recta. En la neurona también se tiene ese término que da control para mover a esa función. A ese valor se lo denomina sesgo (BIAS) y se representa como otra conexión a la neurona pero en el que la variable siempre está asignada a 1 y que se puede controlar manipulando el parámetro de sesgo.

**Gráfico 6:** Diagrama de una neurona completa con el parámetro de sesgo. Por Carlos Santana Vega (2019)



De esta forma la neurona se comporta así como un modelo de regresión lineal. En el anexo I se puede ver un ejemplo práctico de cómo trabaja una neurona y como se comienza a componer una red neuronal.

Al trabajar en la clasificación de datos, dependiendo los casos de uso, probablemente se encuentren distribuciones simples que mediante el uso de una neurona se puedan resolver. Ahora, a medida que los casos de uso se complejizan es posible que el uso de una neurona no sea suficiente.

El ordenamiento de esas neuronas en distintas capas, donde las capas previas van incorporando conocimiento de mayor complejidad a las capas siguientes, de manera jerarquizada, constituye una red neuronal. A mayor capas añadidas, más complejo el conocimiento generado. Esta profundidad en la cantidad de capas es lo que da nombre al aprendizaje profundo o deep learning.

### **Aprendizaje profundo o deep learning**

El deep learning cambia la forma de pensar acerca de la representación de los problemas que se resuelven con la analítica. Se pasa de decirle a la computadora cómo resolver un problema a entrenarla para que resuelva el problema mismo.

Un enfoque tradicional de la analítica consiste en utilizar los datos que se tienen a mano para diseñar características a fin de obtener nuevas variables, luego seleccionar un modelo analítico y finalmente calcular los parámetros (o los valores desconocidos) de ese modelo. Estas técnicas pueden producir sistemas predictivos que no generalizan bien porque la integridad y la corrección dependen de la calidad del modelo y sus características.

El nuevo enfoque con el aprendizaje profundo consiste en reemplazar la formulación y especificación del modelo con caracterizaciones (o capas) jerárquicas que aprendan a reconocer características latentes de los datos de las regularidades en las capas.

La promesa del deep learning es generar sistemas predictivos que generalicen bien, se adapten bien, mejoren continuamente conforme lleguen nuevos datos y sean más dinámicos que los sistemas predictivos basados en reglas de negocios estrictas. Ya no necesita ajustar un modelo. En su lugar, se entrena la tarea. Ahora bien, esta arquitectura tiene sentido si es posible entrenarla de manera automática para que justamente logre aprender. El algoritmo utilizado para esto se denomina backpropagation. La

retropropagación es el algoritmo de aprendizaje supervisado de redes neuronales más popular.

Si bien el diseño de las capas de entrada y salida de una red neuronal a menudo es sencillo, el diseño de las capas ocultas es un arte. Diseñar y entrenar una red neuronal requiere elegir el número y los tipos de nodos, capas, tasas de aprendizaje, datos de entrenamiento y conjuntos de pruebas.

Considerando que las neuronas artificiales en esencia se comportan como un modelo de regresión lineal, una red neuronal lo que realiza desde un punto de vista matemático es concatenar diferentes operaciones de regresión lineal. Se puede comprobar que el efecto de sumar muchas operaciones de regresión lineal (rectas) equivale a haber realizado una única operación que da como resultado una recta. Así toda la estructura colapsa hasta ser equivalente a una única neurona.

Para conseguir que la red no colapse, es necesario que la suma de las neuronas no dé una recta, para eso se debe aplicar a cada neurona alguna mecánica que distorsione la propia recta. Esto se consigue mediante el uso de las funciones de activación la cual distorsiona el valor de salida añadiéndole deformaciones no lineales. Como se verá luego, la función de activación sigmoidea se utiliza con bastante frecuencia.


Las redes neuronales profundas aprenden capas jerárquicas de representación de la entrada para realizar el reconocimiento de patrones. Cuando el problema exhibe propiedades no lineales, las redes profundas son computacionalmente más atractivas que las redes neuronales clásicas.

Una observación sobre el comportamiento de estas redes es que a medida que las redes neuronales crecen y se entrenan con más y más datos, su rendimiento continúa aumentando. Esto generalmente es diferente de otras técnicas de aprendizaje automático que alcanzan una meseta en el rendimiento.

El aprendizaje profundo es la primera clase de algoritmos que es escalable. El rendimiento sigue mejorando a medida que se les proporciona más datos (Andrew NG, 2015).

Ahora bien, las técnicas básicas detrás de Deep Learning existen desde hace décadas, ¿por qué están tomando relevancia hoy?

**Gráfico 7:** Rendimientos de diferentes técnicas de ML. Por Jason Brownelee (2016).



En los ejes verticales del diagrama se puede ver el rendimiento de un algoritmo (por ejemplo, su precisión de predicción) y en los ejes horizontales se puede ver la cantidad de datos que se le han proporcionado.

También se puede ver que el rendimiento de los algoritmos de aprendizaje tradicionales (regresión logística, SVM, etc.) aumenta al principio con un aumento de la cantidad de datos, pero que se estabiliza en un cierto nivel y deja de mejorar su rendimiento.

La cuestión es que se han acumulado grandes cantidades de datos en las últimas décadas que los algoritmos de aprendizaje tradicionales no pueden aprovechar. Es ahí donde entra en juego el Deep Learning.

Las redes neuronales grandes son cada vez mejores a medida que se agregan más datos. Las tres fuerzas principales que mejoran las redes neuronales son: datos, cálculo, algoritmos.

Obtener una mejor precisión con algoritmos de aprendizaje profundo se debe a una mejor red neuronal, más potencia de cálculo o grandes cantidades de datos. Eventualmente, llegará a un cierto punto en el que no haya suficientes datos o donde ya no se puede mejorar el algoritmo porque tomará demasiado tiempo entrenarlo (Ivan Vasilev, 2012).

Si no se cuenta con suficientes datos, realmente no importa si se utilizan algoritmos tradicionales o de aprendizaje profundo, pero sí importa qué tan bien se haya ajustado el modelo al objetivo de predicción actual. Entonces, si no se cuenta con grandes cantidades de datos, a menudo depende de las habilidades de diseño para conseguir una alta precisión del modelo.

Los avances recientes en el desarrollo de algoritmos se deben principalmente a que se ejecutan mucho más rápido que antes, lo que permite utilizar cada vez más datos. Por ejemplo, se produjo un gran avance al cambiar la función de activación, de una función Sigmoide a una función de unidad lineal rectificada.

Las otras razones por las que el cálculo rápido es importante son porque el proceso de entrenamiento de redes neuronales es muy iterativo.

Algo interesante de este campo es que no se están desarrollando modelos para que hagan algo determinado, sino que se están desarrollando modelos para que aprendan a hacer ese algo determinado. Eso dispara una serie de oportunidades infinitas.

### **Paradigmas del aprendizaje**

Inspirados en el cerebro, en el campo de la IA se han desarrollado conceptos muy importantes. Uno de estos conceptos es el de los paradigmas del aprendizaje que son los mecanismos que permiten procesar toda información nueva que se percibe para luego transformarla en conocimiento. Saber cómo funcionan estos mecanismos es fundamental en el campo del machine learning.

Todos los algoritmos y técnicas dentro de este campo se clasifican en 3 grandes grupos según el paradigma de aprendizaje que estén aplicando:

- Aprendizaje supervisado
- Aprendizaje no supervisado
- Aprendizaje por refuerzo

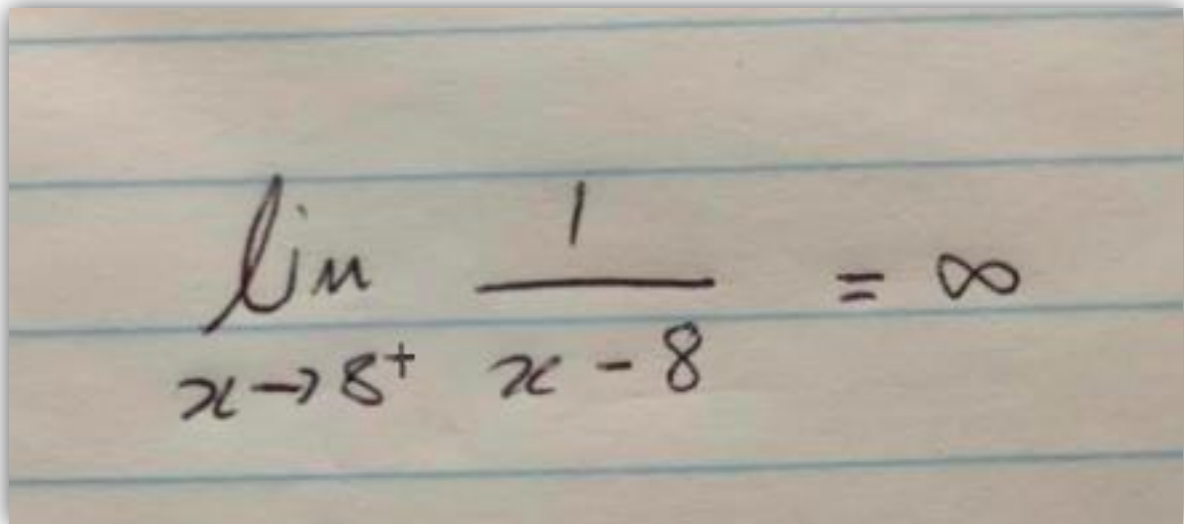
Cuando se habla de Aprendizaje Supervisado se refiere a un tipo de aprendizaje que se basa en descubrir la relación existente entre una variable de entrada y una variable de salida o bien el aprendizaje surge de enseñarle a estos algoritmos cual es el resultado que se quiere obtener ante un determinado o conjunto de valores de entrada (datos de entrenamiento), y esto se logra luego de mostrarle muchas veces ejemplos de modo tal que el algoritmo luego pueda determinar el valor de salida ante un valor de entrada semejante (datos de test) a los ejemplos. La clave de este tipo de aprendizaje es que mediante la “observación” es posible generalizar el conocimiento.



La validación en el contexto del aprendizaje automático (ML) y la IA es uno de los conceptos más importantes.

En la siguiente ecuación se puede ver un planteo y una solución. Se supone que no se cuenta ni con ejemplos adicionales, ni con ninguna regla explícita que explique cómo funciona el cálculo del planteo, por lo que solo es posible intentar detectar patrones en la ecuación:

**Gráfico 8:** Ecuación matemática de límite para representación del ejemplo. Por Cassie Kozyrkov (2020)


$$\lim_{x \rightarrow 8^+} \frac{1}{x-8} = \infty$$

El objetivo de un algoritmo de aprendizaje es encontrar un patrón de datos que pueda convertirse en una receta ("modelo") que guíe con éxito desde la entrada a la izquierda del "=" hasta la salida en el lado derecho. Eso es precisamente lo que sucede durante los pasos de entrenamiento y ajuste de un proyecto de IA aplicado.

El entrenamiento se trata de construir una receta con patrones de los ejemplos disponibles.

**Gráfico 9:** Ecuación matemática de límite para representación del ejemplo. Por Cassie Kozyrkov (2020)

$$\lim_{x \rightarrow 8^+} \frac{1}{x-8} = \infty$$

Turn it on its side!

Observando el ejemplo nuevamente, ¿es posible ver algún patrón en la ecuación? Si, tomando el 8 del denominador, luego girándolo de lado se obtiene la respuesta.

Esa receta funciona correctamente en el ejemplo. Y aquí es posible dejar el modelo, aunque casi por intuición natural debería probarse otro ejemplo que ayude a verificar la correcta solución del ejemplo. Como se mencionó, la validación es fundamental en el aprendizaje automático. La validación crea una oportunidad segura y de bajo riesgo para probar la receta.

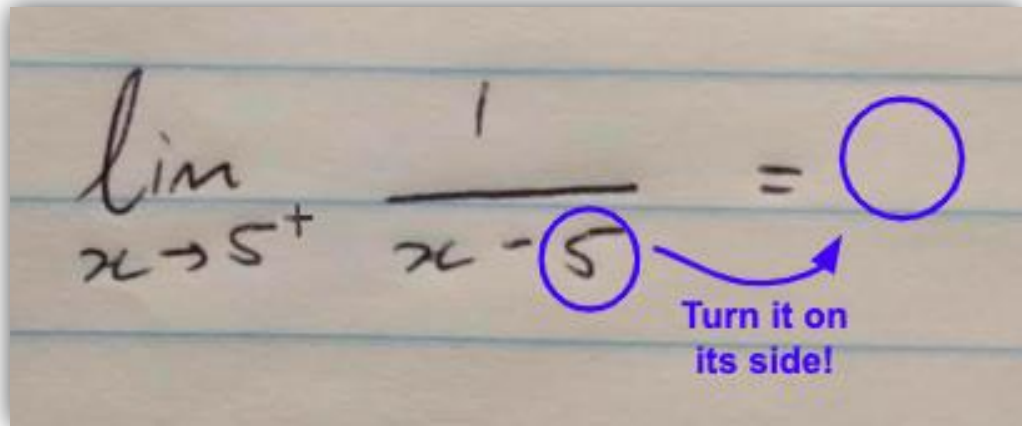
Procediendo con la validación, si se aplica el modelo anterior a la siguiente ecuación:

**Gráfico 10:** Ecuación matemática de límite para representación del ejemplo. Por Cassie Kozyrkov (2020).

$$\lim_{x \rightarrow 5^+} \frac{1}{x-5} =$$

Replicando la lógica anterior:

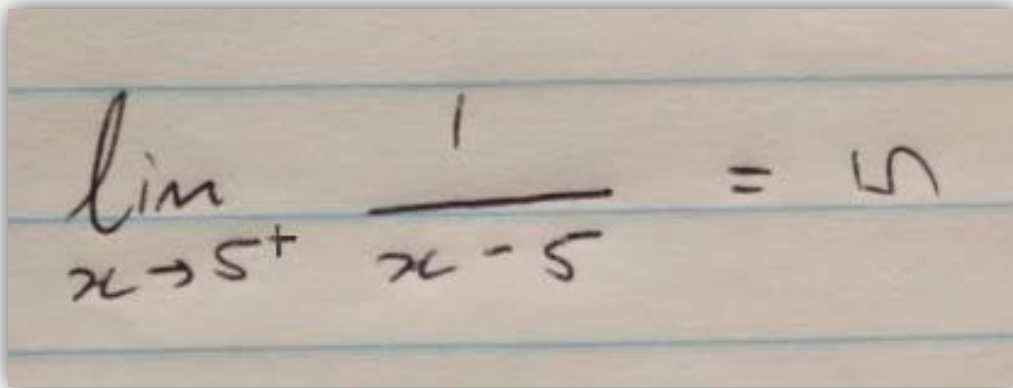
**Gráfico 11:** Ecuación matemática de límite para representación del ejemplo. Por Cassie Kozyrkov (2020)


$$\lim_{x \rightarrow 5^+} \frac{1}{x-5} = \text{circle}$$

Turn it on its side!

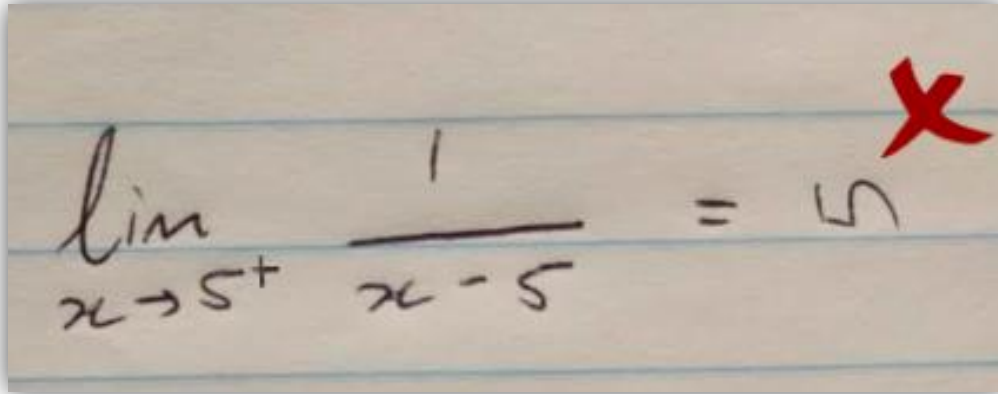
Entonces, girando el 5 de lado se obtiene la respuesta:

**Gráfico 12:** Ecuación matemática de límite para representación del ejemplo. Por Cassie Kozyrkov (2020)


$$\lim_{x \rightarrow 5^+} \frac{1}{x-5} = 5$$

Se valida entonces la performance del modelo con la respuesta correcta:

**Gráfico 13:** Ecuación matemática de límite para representación del ejemplo. Por Cassie Kozyrkov (2020)


$$\lim_{x \rightarrow 5^+} \frac{1}{x-5} = 5$$

Y es incorrecto. El resultado no es el esperado, así no funciona la matemática.

¿Ahora bien, cómo se debería seguir? Se podría volver al entrenamiento y buscar nuevos patrones en los datos iniciales o se podría retroceder aún más y considerar ajustar los datos con los que se está trabajando hasta encontrar un patrón que funciona correctamente en todos los ejemplos de validación dados.

Lo siguiente debería ser ir a la fase prueba. Todo proyecto de machine learning aplicado necesita validación y pruebas (y entrenamiento).

Ahora bien, si se pidiera leer 1000 mails y clasificarlos en correo deseado y spam. Seguramente alguien podría leer los mails y así discriminar que correo quedó dentro de cada clasificación. Ahora, ¿sería posible que se pueda explicar el patrón utilizado para esa clasificación? Es difícil.


Entonces, si se le otorga a un algoritmo de aprendizaje supervisado muchos ejemplos de correos junto a su clasificación, este seguramente aprenderá cuales son las características que hacen que un correo sea o no sea spam.

¿Qué tan difícil sería aprender a detectar si una persona va a sufrir o no de depresión a partir de su cuenta de Instagram? Esto se puede lograr mostrándole a un algoritmo de aprendizaje supervisado muchas galerías de fotos indicando en cada caso si tiene o no la persona de la foto depresión. En 2016 un algoritmo lo logró con un porcentaje de efectividad mayor al de los doctores.

El aprendizaje no supervisado es el paradigma que permite producir conocimiento únicamente de los datos que se proporcionan en la entrada sin necesidad de explicarle al sistema que resultado se quiere obtener.

Este caso cuesta comprenderlo. Suponiendo que un grupo de científicos se adentra a una nueva civilización que no conocen y de la cual no se cuenta con ninguna información previa. Este grupo encuentra un papel con una serie de símbolos que parecen representar un idioma desconocido como el siguiente:

**Gráfico 14:** Lamina con símbolos para representación del ejemplo. Por Carlos Santana Vega (2019)



De observar el papel parece ser que hay más de un idioma diferente. Si bien, no es posible reconocer ninguno de los símbolos, si es posible identificar cual símbolo pertenece a uno u otro lenguaje.

**Gráfico 15:** Lamina con símbolos para representación del ejemplo. Por Carlos Santana Vega (2019)



Esta “forma” de resolver el problema anterior se denomina clusterización. En este caso se observa que sin ninguna supervisión en la respuesta fue posible generar un tipo de conocimiento a partir de los símbolos que se toman de entrada. La dificultad que presenta este tipo de algoritmo es que no se cuenta con ningún ejemplo de respuesta de modo tal de saber si el algoritmo está actuando de manera correcta. Una ventaja de este modelo es que los conjuntos de datos para entrenar son menos costosos de conseguir.

En el caso de aprendizaje supervisado es necesario etiquetar los datos de entrenamiento de modo de contar con el dato de entrada y de salida. Esto típicamente lo realiza un humano. Por otro lado estas bases de datos tienden a superar los 100.000 ejemplos, por eso es más costoso (también en términos de procesamiento).

Es el aprendizaje no supervisado el paradigma que según la comunidad científica puede determinar el futuro del machine learning. Lo que hace el aprendizaje no supervisado es buscar patrones de similitud en el conjunto de datos de entrada.

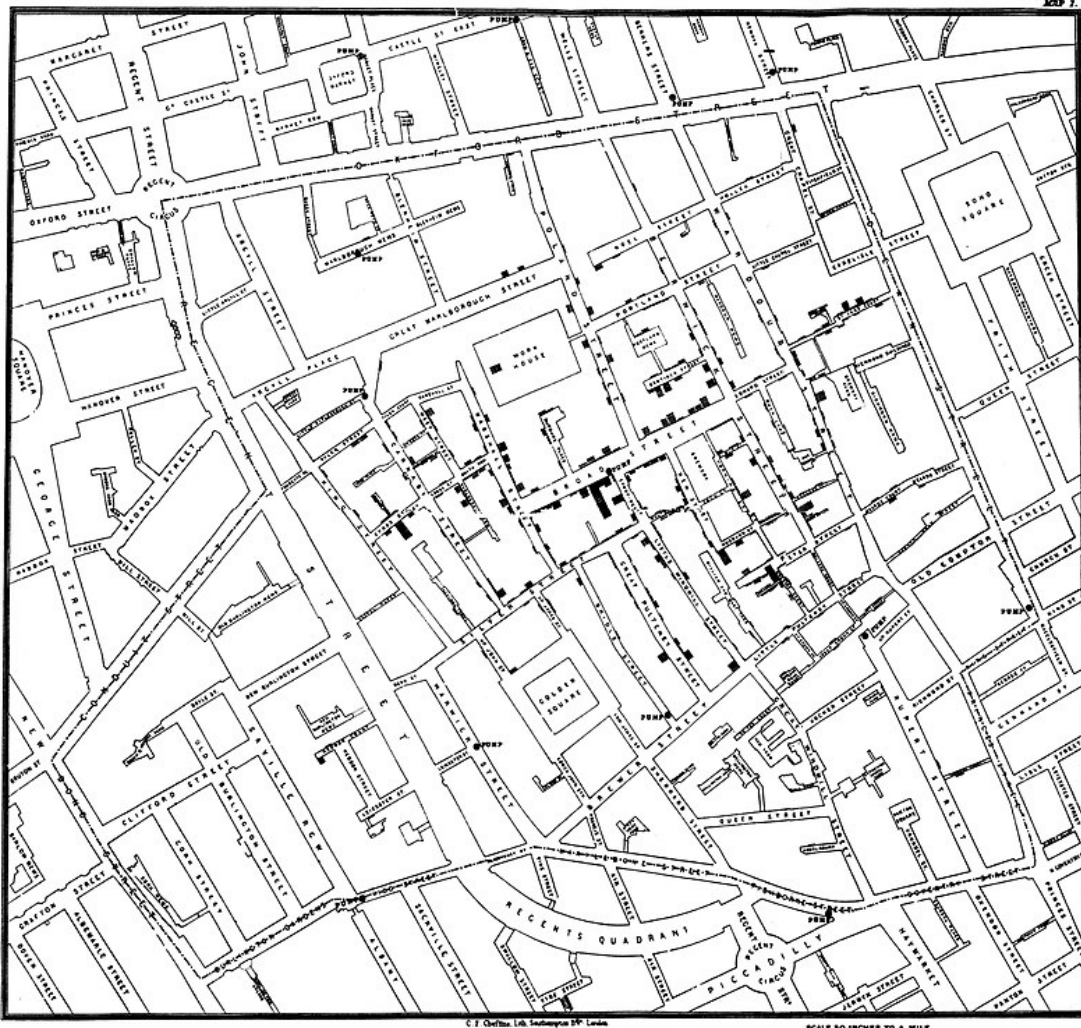
Cuando se habla de una silla, es fácil saber lo que es una silla, pero en la realidad existen múltiples variantes asociadas a este concepto, aunque el cerebro humano reconoce de manera automática una silla. Actualmente, los algoritmos están aprendiendo a reconocer estas estructuras conceptuales (denominadas espacios latentes). Una vez que se construye un espacio de este tipo la máquina consigue capacidades interesantes tales como saber si una cosa es similar a otra cosa.

“el aprendizaje no supervisado es la llave a la verdadera IA” (Yann LeCun)

## **Las analíticas**


El mapa de muertes de John Snow durante el brote de cólera de 1854 en Londres inspiró a la profesión médica a reconsiderar la superstición de que la enfermedad era causada por el aire tóxico, y comenzar a considerar la importancia del agua potable. Para eso, Snow mapeó los casos detectados y los superpuso en un mapa observando su solapamiento con las redes de distribución de agua.

**Gráfico 16:** Mapa que muestra los grupos de casos de cólera en la epidemia de Londres de 1854. Por John Snow (1855)



"La dama de la lámpara", Florence Nightingale, por su heroica compasión como enfermera, también fue una pionera en análisis. Su ingeniosa infografía durante la Guerra de Crimea salvó muchas vidas al identificar la falta de higiene como la principal causa de muertes en hospitales e impulsando a su gobierno a considerar seriamente las cuestiones asociadas a lo sanitario.

**Gráfico 17:** Diagrama de área polar que muestra el número de muertes por enfermedades prevenibles (en azul), por heridas (en rojo) y otras causas (en negro). Por Florence Nightingale (1855)



Los datos reflejan realidades y cuando estos son correctamente interpretados y representados, pueden modificar la aprehensión de esa realidad. La era del conjunto de datos despegó cuando el valor de la información comenzó a afirmarse en un número creciente de campos, lo que condujo a la invención de la computadora. "Computadora" comenzó como una profesión humana, con sus profesionales realizando cálculos y procesando datos manualmente para extraer su valor.

La belleza de los datos es lo que permite formarse una opinión sobre algo mejor que la nada. Ver la información, e inspirarse a hacer nuevas preguntas, siguiendo los pasos de Florence Nightingale y John Snow. De eso se trata la disciplina de análisis: inspirar modelos e hipótesis a través de la exploración (Cassie Kozyrkov).

A principios del siglo XX, el deseo de tomar mejores decisiones bajo incertidumbre llevó al nacimiento de una profesión paralela: las estadísticas. La estadística ayuda a evaluar si es lógico comportarse como si un fenómeno también se aplicara más allá de su conjunto de datos actual.

La división de datos es una idea simple. Si solo se tiene un conjunto de datos, se debe elegir entre análisis (inspiración no comprobable) y estadísticas (conclusiones rigurosas). Esto se consigue dividiendo el conjunto de datos en dos partes.



La era de dos conjuntos de datos reemplaza la tensión analítica-estadística con el trabajo en equipo coordinado entre dos razas diferentes de especialistas en datos. Los analistas usan un conjunto de datos para ayudar a formular sus preguntas, luego los estadísticos usan el otro conjunto de datos para brindar respuestas rigurosas.

La era de dos conjuntos de datos es un desarrollo bastante nuevo que va de la mano con un mejor hardware de procesamiento, menores costos de almacenamiento y la capacidad de compartir información recopilada a través de Internet.

De hecho, las innovaciones tecnológicas que condujeron a la era de dos conjuntos de datos rápidamente marcaron el comienzo de la siguiente fase, una era de tres conjuntos de datos que sería el aprendizaje automático.

¿Cómo saber que "información" de análisis es más digna de prueba? Si se tuviera un tercer conjunto de datos, se podría utilizar para una prueba. Este proceso de selección se llama validación; está en el corazón de lo que hace que el aprendizaje automático funcione. Cualquier solución que funcione mejor en validación se convierte en candidato para la prueba estadística adecuada.

Es por eso que el aprendizaje automático es una revolución de los conjuntos de datos, no solo de los datos.

ML / AI, análisis y estadísticas. El término general que los abarca a todos se llama ciencia de datos, la disciplina de hacer que los datos sean útiles.

### **¿Cuándo no usar el aprendizaje automático?**

Considerese el siguiente conjunto de datos de un ensayo clínico:

**Gráfico 18:** Tabla con día y dosis, para representación del ejemplo. Por Cassie Kozyrkov (2018)

## Treatment schedule

1	→	28mg
2	→	17mg
3	→	92mg
4	→	41mg
5	→	9mg
...		
60	→	86mg



Es de suponer que estos puntos de datos trazan la relación entre el día de tratamiento ("característica" de entrada) y la dosis correcta de alguna cura milagrosa en miligramos ("predicción de salida") que un paciente debe recibir durante el transcurso de 60 días.

Ahora asumiendo el tratamiento de un paciente en el día 2. ¿Qué dosis debería aplicarse?

**Gráfico 19:** Tabla con día y dosis, para representación del ejemplo. Por Cassie Kozyrkov (2018)

1	→	28mg
2	→	17mg
3	→	92mg
4	→	41mg
5	→	9mg
...		
60	→	86mg

2 → ?



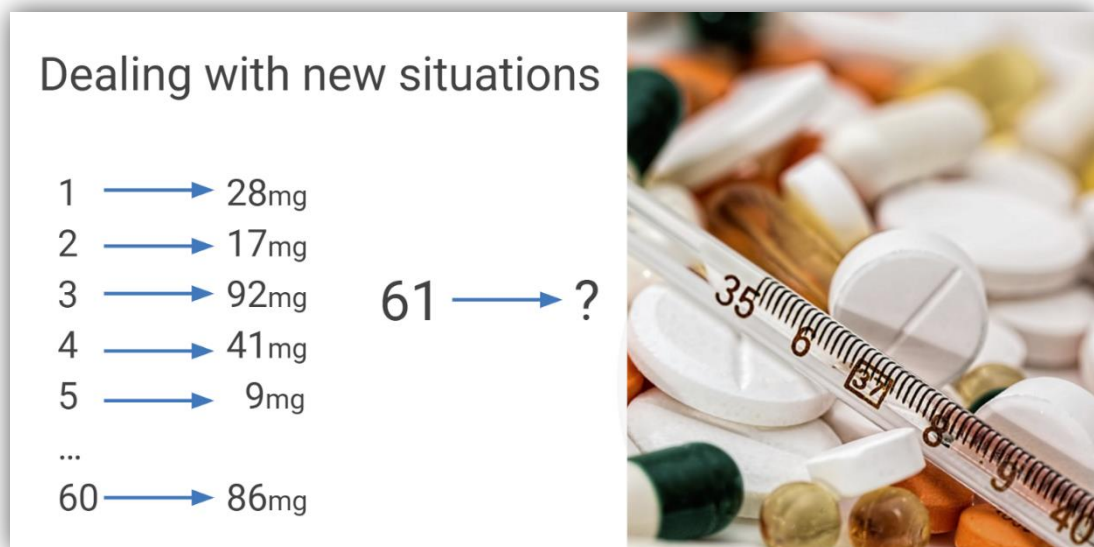
17mg. ¿Y el día 4? 41mg.

Ahora bien, ¿cómo se debería desarrollar software para generar las dosis correctas en los días 1 a 5? ¿Es posible utilizar aprendizaje automático? En otras palabras, ¿es posible encontrar patrones en estos datos e intentar convertirlos en una receta ("modelo") para pasar de entradas a salidas?

La respuesta es no. Lo que se debe hacer es desarrollar un software que haga exactamente lo que está haciendo: buscar la respuesta en una tabla. De esa manera, se obtendrá la respuesta correcta el 100% del tiempo durante los 60 días. No hay necesidad de patrones y tampoco hay necesidad de aprendizaje automático.

Entonces, ¿qué tipo de situación requiere aprendizaje automático?

**Gráfico 20:** Tabla con día y dosis, para representación del ejemplo. Por Cassie Kozyrkov (2018)



Asumiendo es el día 61. ¿Cuál es la respuesta correcta en este caso? Bueno, se observa que no hay datos para el día 61, por lo que no hay forma de buscar la respuesta allí.

Si no hay un patrón que conecte las entradas con las salidas, no es posible. Es necesario encontrar un patrón útil, el cual se pueda intentar aplicar al día 61 para tratar de predecir o adivinar la respuesta correcta. El patrón debe ser relevante más allá del día 60.

Pero si hay un patrón y si este patrón es relevante para la nueva situación, entonces se podría encontrar el patrón en los datos antiguos, hacer una receta basada en él y luego usar esa receta para tener éxito en el día 61 y más allá. Encontrar patrones y usarlos es de lo que se trata el aprendizaje automático.

### ¿Cuándo usar el aprendizaje automático?

En el aprendizaje automático aplicado, se busca aprender. Una solución no es buena si no puede manejar nuevos ejemplos que nunca ha visto antes. No ejemplos disruptivamente

nuevos que rompen todas las reglas de un universo estacionario, sino ligeros giros en el tema aprendido.

No es memorizar, es generalizar a nuevas situaciones. Ese es el poder del aprendizaje automático.

Si no se ha visto esta combinación exacta de valores de entrada antes (Día 61), ¿cuál es la respuesta de salida correcta? Bueno, tal vez sea posible convertir viejos patrones en una receta que haga una suposición aproximada.

El aprendizaje automático es un enfoque para automatizar decisiones repetidas que implica encontrar patrones algorítmicamente en los datos y usarlos para hacer recetas que traten correctamente los datos nuevos.0

### **Abordaje de un proyecto con aprendizaje automático**

Un desafío importante está en cómo desarrollar proyectos de aprendizaje automático. Andrew NG, en su libro *Machine Learning Yearning*, propone unos seis conceptos para establecer la dirección técnica de un proyecto de aprendizaje automático.

#### *Concepto 1: Iterar, iterar, iterar...*

Es crucial iterar rápidamente ya que el aprendizaje automático es un proceso iterativo. En lugar de pensar en cómo construir el sistema perfecto para un problema, se debe construir un prototipo simple lo más rápido posible. Es difícil adivinar el rumbo correctamente al principio.

Se debería construir un primer prototipo en solo unos días y luego aparecerán pistas que mostrarán la dirección más prometedora para mejorar el rendimiento de ese prototipo. En la próxima iteración, se mejorará el sistema en función de una de estas pistas y se creará la próxima versión del mismo. Se hará esto una y otra vez.

Cuanto más rápido se pueda iterar, más progreso se hará.

#### *Concepto 2: utilizar una sola métrica de evaluación*

Este concepto se basa en el anterior y la explicación sobre por qué se debería elegir una métrica de evaluación única es muy simple: permite evaluar rápidamente el algoritmo y, por

lo tanto, iterar más rápido. El uso de múltiples métricas de evaluación simplemente hace que sea más difícil comparar algoritmos.

*Concepto 3: el análisis de error es crucial*

El análisis de errores es el proceso de mirar ejemplos en los que la salida del algoritmo es incorrecta. Por ejemplo, suponiendo que se cuenta con un detector de gatos que confunde aves con gatos y que ya se tiene algunas ideas sobre cómo resolver ese problema.

Con un análisis de error adecuado, se puede estimar cuánto una idea de mejora realmente incrementa el rendimiento del sistema, sin invertir tiempo en implementar esta idea y darse cuenta que no era crucial para el sistema. Esto permite decidir qué idea es la mejor para enfocar los recursos. Si solo el 9% de las imágenes mal clasificadas son aves, no importa cuánto se mejore el rendimiento del algoritmo en las imágenes de aves, ya que no mejorará más del 9% el error.

*Concepto 4: definir una tasa de error óptima*

Suponiendo que se está desarrollando un sistema que convierte voz a texto. Luego, se descubre que el 19% de los archivos de audio que se espera que los usuarios envíen, tienen ruidos de fondo tan dominantes que incluso los humanos no pueden reconocer lo que se dijo allí. Si ese es el caso, se sabe que incluso el mejor sistema probablemente tendría un error de alrededor del 19%. Por el contrario, si se trabaja en un problema con una tasa de error óptima de casi 0%, puede esperarse que el sistema funcione igual de bien.

Pero, ¿cómo puede saberse cuál es la tasa de error óptima? Para las tareas en las que los humanos son buenos, se puede comparar el rendimiento del sistema con el de los humanos, lo que da una estimación de la tasa de error óptima. En otros casos, en general es difícil definir una tasa óptima, que son las razones por las que se debe trabajar en problemas que los humanos pueden resolver bien.

*Concepto 5: trabajar en problemas que los humanos pueden resolver bien*

Se recomienda trabajar en problemas de aprendizaje automático que los humanos pueden hacer bien por sí mismos. Algunos ejemplos son el reconocimiento de voz, la clasificación de imágenes, la detección de objetos, etc. Esto tiene varias razones.

Primero, es más fácil obtener o crear un conjunto de datos etiquetado, porque es sencillo para las personas proporcionar etiquetas de alta precisión para su algoritmo de aprendizaje si pueden resolver el problema por sí mismas.

En segundo lugar, se puede utilizar el rendimiento humano como la tasa de error óptima que desea alcanzar con el algoritmo. Definir un error óptimo razonable y alcanzable ayuda a acelerar el progreso del equipo. También ayuda a detectar si el algoritmo sufre un alto sesgo o varianza.

Tercero, se pueden hacer análisis de errores basados en la intuición humana. Si se está construyendo, por ejemplo, un sistema de reconocimiento de voz y el modelo clasifica erróneamente su entrada, se puede intentar comprender qué información usaría un humano para obtener la transcripción correcta, y usar esto para modificar el algoritmo de aprendizaje en consecuencia.

#### *Concepto 6: Cómo dividir su conjunto de datos*

Se recomienda la siguiente división de datos:

- Conjunto de entrenamiento: con estos datos se entrena el algoritmo.
- Conjunto de desarrollo: este conjunto está ahí para hacer ajustes de hiperparámetros, para seleccionar y crear características adecuadas y para hacer análisis de errores. Básicamente está ahí para tomar decisiones sobre el algoritmo.
- Conjunto de pruebas: el conjunto de pruebas se utiliza para evaluar el rendimiento del sistema, pero no para tomar decisiones.

El conjunto de desarrollo y el conjunto de prueba permiten evaluar rápidamente qué tan bien está funcionando el algoritmo. Su propósito es guiar hacia los cambios más importantes que deben realizarse en el sistema.

Se deben elegir ejemplos de conjuntos de pruebas que reflejen lo que desea realizarse bien más adelante en realidad, en lugar de los datos que se utilizaron para el entrenamiento.

## **CAPITULO III. LOS TRANSFORMADORES**

Los transformadores se encuentran desplegados prácticamente en toda la red de energía, en las etapas de generación, transporte y distribución, en todas sus etapas. En la etapa de

generación están los transformadores elevadores. En la etapa de distribución, transformadores reductores y de distribución. De acuerdo al tipo de transformador estos pueden ser de menor tamaño y relativamente económicos (transformadores de distribución) o de gran tamaño y muy costosos (elevadores).

Los transformadores son el corazón de la Red. Cumplen una función vital y cualquier tipo de indisponibilidad o afectación, ya sea por su incorrecto funcionamiento o falla, tiene un fuerte impacto en los usuarios.

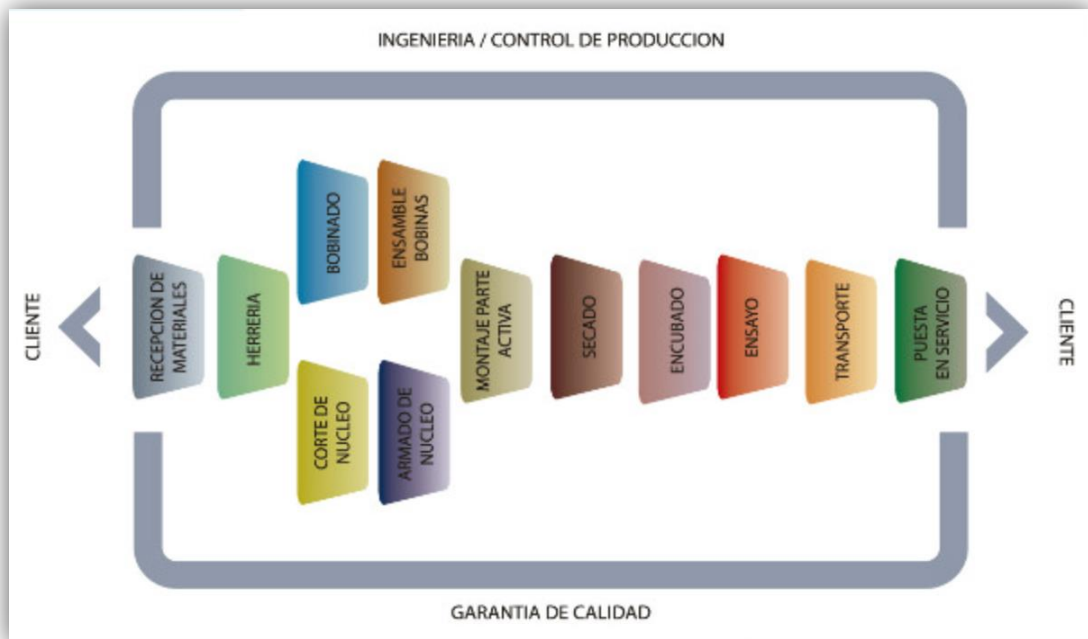
Ahora bien, técnicamente, ¿qué es un transformador? Es una máquina eléctrica que transforma energía, es decir, cambia los valores de entrada en otros valores de salida, para facilitar el uso de la electricidad de acuerdo a los fines que sea destinada.

El funcionamiento se basa en el principio de inducción electromagnética. Esto significa que una bobina de material conductor inmersa en un campo magnético variable es capaz de generar en sus extremos una tensión alterna. Este campo magnético es producido por una segunda bobina de cobre, sometida a una tensión alterna, arrollada sobre un núcleo de hierro silicio, el cual hace de enlace entre las dos bobinas.

La importancia de los transformadores radica en las ventajas que presentan para la transmisión de energía eléctrica. Como se detalló anteriormente, la energía se produce en grandes centros de generación, donde se obtienen tensiones medias, luego a través de transformadores elevadores, se aumenta la tensión y se reduce la intensidad, lo cual representa menor sección de conductores, menores pérdidas, torres de suspensión más livianas, etc. Este nivel de alta tensión, recorre grandes extensiones (etapa de transmisión) hasta que llega a una zona donde se utilizará la energía. Allí se hace circular a través de transformadores reductores, para reducir tensión y por último se pasa a través de transformadores de distribución, para llevar la energía a domicilios particulares y pequeñas industrias.

### **Proceso de fabricación**

**Gráfico 21:** Proceso de fabricación de transformadores de media y alta tensión. Por Tadeo Czerweny brochure (2019).



El proceso de fabricación sigue una secuencia en serie característico de una línea de montaje.

En líneas generales el proceso sigue las siguientes etapas:

- Corte de silicio.
- Armado de núcleos
- Fabricación de bobinados
- Preparación de aislaciones
- Montaje de núcleo, bobinas y aislación
- Preparación de componente externos
- Ensamble
- Pintura
- Encubado
- Laboratorio y ensayo
- Transporte
- Puesta en servicio

Una estructura organizacional típica de un fabricante de transformadores consta de dos grandes frentes: el proceso fabril y el resto. Cuenta con un sector de producción, en el que gira toda la organización, un sector de servicios (enfocado en la innovación e I+D), un sector



de ventas, con vendedores de un grado alto de especialización técnica, y las típicas áreas de staff de cualquier organización. Los desafíos principales de innovación se asocian lógicamente a cuestiones de producto y en cómo lograr eficiencia operativa junto a la mejora continúa.

En el aspecto comercial los modelos de negocio son generalmente rígidos en esencia se basan en la venta del activo. Las nuevas tecnologías dan espacio a nuevas funcionalidades que permiten a los fabricantes re pensar su propuesta de valor no solo en términos de producto sino que también en términos de servicio, con foco en la oferta: vender el activo y un servicio recurrente. Esto fortalece los indicadores asociados a la valuación de los proyectos de venta e incrementa el valor de la compañía.

Ahora bien, para materializar la propuesta de valor se debe identificar el beneficio diferencial. Levantar una operación digital industrial implica insertar nuevas capacidades y tecnologías. Los transformadores pueden ser la puerta de entrada para incorporar este tipo de soluciones, que ayuden a ciertos actores del sector eléctrico a adoptar nuevas tecnologías que les permita evolucionar la gestión, prácticas de mantenimiento, optimizar inversiones, lograr eficiencias y porque no, establecer nuevos modelos de negocio comerciales.

Uno de los valores corporativos de Tadeo Czerweny, uno de los fabricantes más importantes de Argentina y de la Región, es la satisfacción del cliente. Menciona en su declaración “es nuestra meta procurar superar las expectativas del cliente respecto de la solución de sus necesidades”. Un sector target para los fabricantes es la empresa de distribución. Es preciso recordar que es en la red de distribución donde se encuentran la gran mayoría de los transformadores.

Entre los dolores más significativos de las compañías de distribución están las pérdidas técnicas, las pérdidas no técnicas, el costo operativo, los altos niveles de inversión, entre otros.

El fabricante si quiere cumplir con su misión debe pensar en entregarle al distribuidor no solo un producto de calidad, sino que debe pensar una propuesta de valor, que ayude a su cliente a diferenciarse de la competencia. En este diseño de la propuesta de valor está el desafío, quizá no debe pensarse en un producto sino que se debe pensar en un servicio.

Las redes de distribución actuales se diseñan según la geo localización de la demanda, es decir, la red se despliega para atender la necesidad de abastecimiento eléctrico en determinadas regiones o áreas, sea rurales, urbanas o industrial. El diseño generalmente se realiza asumiendo ciertos coeficientes de seguridad, asumiendo que las áreas de necesidad son dinámicas (pueden crecer de acuerdo al crecimiento poblacional en una región, por ejemplo).

El diseño de la red implica para cada elemento de la misma una distribución de la carga que se genera. De acuerdo a lo antes mencionado, es muy común que se excedan periódicamente las capacidades de carga de los transformadores de la red. Luego se podrá ver que esto también puede ser consecuencia de otros factores, externos al diseño de red.

Este desbalance o desajuste de carga, produce un funcionamiento “fuera de punto” de la máquina, y puede provocar un envejecimiento acelerado y también fallas, por ejemplo del aislamiento.

Ahora bien, conociendo esta casuística un fabricante puede pensar su propuesta de valor no solo en el producto sino que también puede complementarla con un servicio de monitoreo por ejemplo. Este monitoreo podría tener un efecto importante en las tareas de mantenimiento y quizá pueda evolucionar el tipo de mantenimiento reactivo hacia un mantenimiento predictivo.

Preservar el estado de salud del transformador es clave. Para eso, se debe cuidar la condición del transformador y el funcionamiento integral de la red, que puede afectar la salud del equipo.

Anormalidades del sistema, la carga excesiva, la conmutación y las condiciones ambientales contribuyen al envejecimiento acelerado del transformador y pueden conducir a la falla repentina de los mismos. Algunas de estas fallas pueden causar un daño irreversible, reduciendo su vida útil.

Las fallas en los transformadores de potencia también pueden provocar interrupciones no planificadas, de fuerte impacto económico para el proveedor de energía como para los usuarios que tienen una dependencia de negocio de dicho suministro. Una falla de provisión de la energía causa múltiples preocupaciones para una empresa de servicio eléctrico, que van desde el costo de reemplazo, el tiempo de entrega para adquirir un nuevo transformador, el costo para programar una interrupción y, en algunos casos, el costo de

limpieza ambiental asociado con un derrame de aceite (los grandes transformadores de potencia generalmente se encuentran sumergidos en aceite). Es por ello, que resulta de gran beneficio monitorear continuamente estos activos para asegurar una operación efectiva y confiable del sistema.

Se han desarrollado varias técnicas de monitoreo sobre transformadores. Una técnica es una solución de monitoreo basada en pruebas periódicas fuera de línea para detectar problemas incipientes. Estas pruebas fuera de línea solo pueden emplearse después de una interrupción del transformador o durante el mantenimiento programado. Este método es costoso y requiere mucho trabajo.

La tendencia actual en la industria energética es pasar del monitoreo basado en pruebas a un sistema de monitoreo basado en la condición. La técnica basada en la condición puede proporcionar información sobre el transformador en tiempo real y procesar la información para determinar cualquier acción correctiva que pueda ser necesaria para proteger el transformador de una sobrecarga. El monitoreo basado en la condición contiene una amplia gama de métodos, incluida la detección de descargas parciales y la degradación del aislamiento, el diagnóstico de deformaciones del devanado, el monitoreo de la evolución del gas disuelto y la evaluación del estado térmico del transformador.

Para lograr esto se deben conjugar varios elementos: hardware, conectividad, data (para construir modelos de comportamiento) y aprendizaje automático, que permita mediante el análisis de los datos y la comunicación bidireccional, analizar y actuar de manera reactiva y predictiva. Todos campos de la industria 4.0

Luego se detallarán algunas modalidades de aplicación para comprender mejor las posibilidades de monitoreo junto a la aplicación de campos propios de esta 4ta revolución.

### **Un nuevo modelo de negocio**

Para lograr la transformación es necesario identificar e implementar la mejora tecnológica, y para eso es fundamental encontrar el modelo de negocio acorde a esa evolución.

Un abordaje interesante hacia esa definición lo propone la metodología de Lean Analytics donde existe un fuerte marco metodológico hacia la definición de métricas, de modo de entender cuál es el problema a resolver, desarrollando algo a continuación, comprobando si lo que se ha desarrollado es suficientemente bueno y, luego, validar con los usuarios para salir a buscar las inversiones necesarias para ese desarrollo.

Lean Analytic propone 5 etapas: empatía, adhesión, viralidad, ingresos y escala, que reflejan fielmente lo que aconsejan otros seguidores de los principios de Lean Startup.

En primer lugar, es necesario la empatía. Es necesario entender lo que piensan los integrantes del segmento de mercado objetivo, asegurar de que se está resolviendo un problema que realmente le preocupa al cliente y que se llevará adelante de forma tal que se pueda monetizar por ello. Los fabricantes de transformadores suman años de experiencia, y vigencia, cuentan con equipos comerciales con alto conocimiento de los clientes en términos técnicos y relacionales. En esta etapa es fundamental apoyarse en este equipo para detectar estos insights.

En segundo lugar, es necesaria la adhesión, que se consigue desarrollando un buen producto. Se debe averiguar si es posible desarrollar una solución para el problema detectado. Antes que escalar, es necesario lograr adhesión, clientes que usen el servicio, que lo puedan probar.

Tercero, es necesario viralizar. Una vez desarrollado un producto o servicio que genere adhesión, es el momento de utilizar la recomendación. Así pueden probarse los procesos de adquisición y de delivery de la solución. La viralidad es también una fuerza multiplicadora de la inversión que se realice en promoción.

Cuarto, es necesario crecer en ingresos. Llegado este punto, se debe pensar en monetizar el producto o servicio. Eso no significa que hasta ese momento se haya ofrecido de forma gratuita sino que en etapas anteriores se habrá puesto más el foco en el crecimiento que en los ingresos. Se habrán ofrecido pruebas gratuitas, try & buy, etc. Pero es el momento de maximizar y optimizar los ingresos.

Quinto, es necesario escalar. Una vez que comiencen a llegar los ingresos, será el momento de buscar el crecimiento del mercado más que el crecimiento del propio negocio en particular. Es necesario conseguir más clientes de nuevos mercados verticales, de sitios diferentes para aumentar la base de clientes.

El fabricante de transformadores, debe complementar su negocio core con valor agregado. Ese valor añadido reformula la propuesta de valor vigente hacia un nuevo modelo de negocio. Por eso, más allá de la historia y vigencia de los fabricantes en el mercado, en estos contextos de evolución, en cierto punto estos se comportan como start ups que deben metodológicamente trabajar para descubrir justamente ese modelo.

La siguiente cuestión está en determinar ¿en qué negocio se sitúa el fabricante?, ¿cómo gana dinero? Muchas compañías pueden desarrollar un producto y resolver todas las cuestiones técnicas, algunas pueden atraer a la audiencia necesaria (e incluso una gran audiencia), pero pocas hacen dinero. Incluso gigantes como Twitter o Facebook siguen intentando diferentes métodos de conseguir dinero de sus millones de usuarios.

Solo hay unos cuantos modelos de negocio fundamentales. Lo más interesante es que todos ellos comparten algunas características. En primer lugar, su intención es crecer (Paul Graham dice que el foco en el crecimiento es el atributo definitivo para cualquier compañía). Y, en segundo lugar, que ese crecimiento se consiga con uno de los «motores de crecimiento» de Eric Ries: un incremento bien en la adhesión, bien en la viralidad o bien en los ingresos.

Cada modelo de negocio necesita maximizar el impulso de estos tres motores para florecer. Sergio Zyman, CMO (Chief of Marketing Operations, jefe de Operaciones de Marketing) en Coca-Cola, dijo una vez que el marketing consiste en vender más cosas a más gente, más a menudo y por más dinero, de forma más eficiente.

El crecimiento de los negocios vendrá, por tanto, de la mejora de alguna de las siguientes cinco variables:

- Más cosas, significa añadir productos o servicios, preferiblemente aquellos que quieren los clientes para no despilfarrar tiempo desarrollando cosas que no querrán comprar o utilizar. Este es el caso que aplica para el fabricante además de vender el activo, vende un servicio.
- Más gente, significa añadir usuarios, de forma ideal gracias a la viralidad o el boca a boca, pero también con publicidad.
- Más a menudo, implica adhesión, un churn reducido (así no abandonarán el producto) y un uso repetido (así lo utilizarán más frecuentemente). Esto es la recurrencia.
- Más dinero, significa aumentar las ventas y maximizar el precio que pagan los clientes.
- De forma más eficiente, implica reducir el gasto asociado con la entrega del producto y con la atención al cliente, pero también disminuir el costo de adquisición de los clientes.

Los modelos de negocio consisten en conseguir que la gente se comporte como el oferente del servicio desea, a cambio de algo. Pero no todo el mundo es igual. Un fabricante de transformadores provee un activo, lo produce. Ahora con esta visión evolutiva pasa a ser

además un proveedor de SaaS (software as a service) que con un pequeño costo incremental por cada nuevo usuario, le permite ir a un modelo freemium, modelo comúnmente utilizado en el mundo del gaming.

El fabricante solo podrá predecir con exactitud sus ingresos si comprende el uso que hace del producto cada uno de sus segmentos. Las startups disponen de un amplio abanico de métodos de pago y de modelos de incentivos entre los que elegir: freemium, prueba gratis, pago por adelantado, descuentos, financiación por publicidad, etc. La elección tendrá que encajar con el tipo de segmentación de usuarios que se esté realizando, con el tiempo que tarde un usuario en convertirse en usuario de pago, con la facilidad de uso del servicio y con el precio de costo que los usuarios de paso le supongan al negocio.

Una empresa SaaS ofrece software bajo demanda, normalmente disponible a través de un sitio web de la propia empresa. Salesforce, Gmail, Basecamp y Asana son buenos ejemplos de conocidos productos SaaS. La mayoría de los proveedores SaaS obtienen sus ingresos a partir de las suscripciones (mensuales o anuales) que pagan sus usuarios. Algunos cobran dependiendo del consumo que hacen los usuarios, por almacenamiento, por ancho de banda, por ciclos de computación, aunque, hoy en día, ese tipo de cobro suele estar limitado a las empresas de computación en la nube que ofrecen infraestructuras como servicio (IaaS) y plataformas como servicio (PaaS).

Muchos de estos proveedores ofrecen su servicio mediante un modelo con diferentes niveles de pago, en el que la cuota mensual es mayor o menor según alguna de las dimensiones de la aplicación. Puede tratarse del número de proyectos en los que se puede trabajar en una herramienta de gestión de proyectos, o el número de clientes en un CRM.

Para las empresas que estructuran así su servicio, siempre supone un reto encontrar los niveles y los precios adecuados a cada nivel. Además, dedican un esfuerzo considerable a intentar que sus usuarios suban de un nivel a otro superior, más lucrativo. Actualmente, el costo incremental de conseguir un nuevo cliente es prácticamente despreciable, por lo que muchos de los proveedores SaaS utilizan un modelo freemium para la adquisición de clientes.

En este modelo, los clientes pueden comenzar utilizando una versión gratuita y restringida del servicio, pero la empresa confía en que consuman todos los recursos gratuitos y paguen por más capacidad. Dropbox, por ejemplo, ofrece unos pocos gigabytes de almacenamiento

gratuito para sus clientes y, a la vez, hace todo lo posible para que los clientes consuman ese almacenamiento lo antes posible y pasen al modelo de pago.

El fabricante puede así establecer un fee de venta por el activo y luego una suscripción mensual de acceso al dashboard de monitoreo del transformador. Puede establecer un modelo freemium con la vista de determinados parámetros de manera gratuita y otros parámetros pasando a la modalidad de pago. También se pueden definir paquetes que de manera incremental vaya habilitando funciones como análisis de correlación, o incluso la vista de reportes, incrementando así el valor de la suscripción total.

### **Incorporando tecnología. El monitoreo de la condición térmica.**

Un desafío importante para las compañías de distribución tienen que ver con anticipar la demanda, no quizá relacionada a la unitaria por usuario sino más bien a la causada por el crecimiento o movimiento poblacional. Suponiendo que surge un emprendimiento urbano de tamaño relevante al lado de una zona urbana establecida. Para el abastecimiento de esta nueva zona la compañía de distribución desplegará subestaciones y transformadores, junto al tendido de cables, para brindar esa cobertura. Este nuevo anexo de red provocará una afectación en la demanda el cual genera inevitablemente un desbalance de carga general de red, recargando algunos puntos neurálgicos (transformadores).

Los desbalances de carga producen un funcionamiento incorrecto de los transformadores afectados, generalmente debido a la sobrecarga. Un transformador operando en sobrecarga un largo periodo puede deteriorarse, acortar su vida útil, salir de servicio, etc. Un componente físico del equipo afectado por esta sobrecarga suele ser el aislamiento.

Una clara señal de advertencia de desbalances en la red se puede obtener de medir parámetros de funcionamiento sobre el transformador. Obteniendo mediciones de temperatura del transformador es posible calcular parámetros como el factor de aceleración del envejecimiento en el aislamiento, por ejemplo.

Es importante mantener el funcionamiento del transformador siempre dentro de los parámetros normales de funcionamiento. Un hardware adecuado para solucionar esta problemática pueden ser los relés térmicos de protección, perteneciente a la familia de dispositivos IDEs (primera capa de tecnologías en el framework de gestión).

Los relés térmicos de protección son componentes que, ante un eventual comportamiento fuera de los límites térmicos, se “abren” aislando del sistema el transformador en mal funcionamiento de modo tal de aislarlo del resto y preservar su integridad. Los relés actualmente utilizados realizan funciones de protección y monitoreo a la vez, es decir, pueden accionar a partir de la comparación de temperaturas y valores de pérdida contra parámetros preestablecidos. El relé generalmente se programa para que más allá de accionar y auto preservarse, emita una notificación al sistema SCADA para registro del incidente y ubicación.

Un modelo que implementó CenterPoint, compañía de distribución en USA, fue mediante la construcción de un perfil de comportamiento sujeto a variaciones de parámetros en un lapso de dos horas, tiempo suficiente para que antes una eventual falla en los parámetros iniciales, conociendo el efecto de esa variación debido al comportamiento registrado, el operador pueda redistribuir las cargas dentro de la red y enviar personal de campo para solucionar el desperfecto sobre el transformador en cuestión.

### ***Arquitectura de la solución***

El diseño del sistema de monitoreo implica el uso de módulos de adquisición de datos (DAQ) para cada transformador de distribución de modo de tener lecturas individuales por transformador.

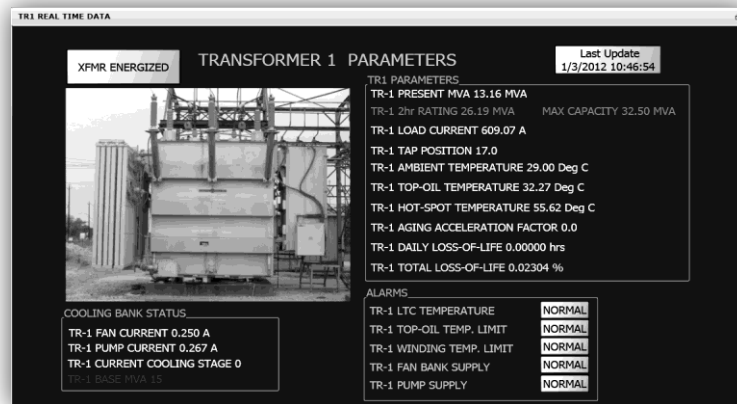
Los módulos DAQ se colocan junto a los transformadores de distribución. A dichos módulos DAQ se conectan detectores de temperatura de resistencia (RTD) del transformador y sensores de temperatura ambiente. Estos RTD se utilizan para medir la temperatura del aceite superior y la del núcleo. Además, el módulo DAQ recibe lecturas de la corriente y el voltaje de carga del transformador.

Los módulos DAQ se conectan al controlador de automatización. El controlador calcula la capacidad de carga del transformador en tiempo real, el factor de envejecimiento del aislamiento y los valores de pérdida de vida por hora y por día del transformador.

La computadora de la subestación se conecta al controlador de automatización para levantar los datos monitoreados y disponibilizarlos en una interfaz de usuario donde es posible ver parámetros de performance y de estado de todos los transformadores de la subestación en tiempo real. Estos datos se transmiten al centro de control para la gestión integral de la red.

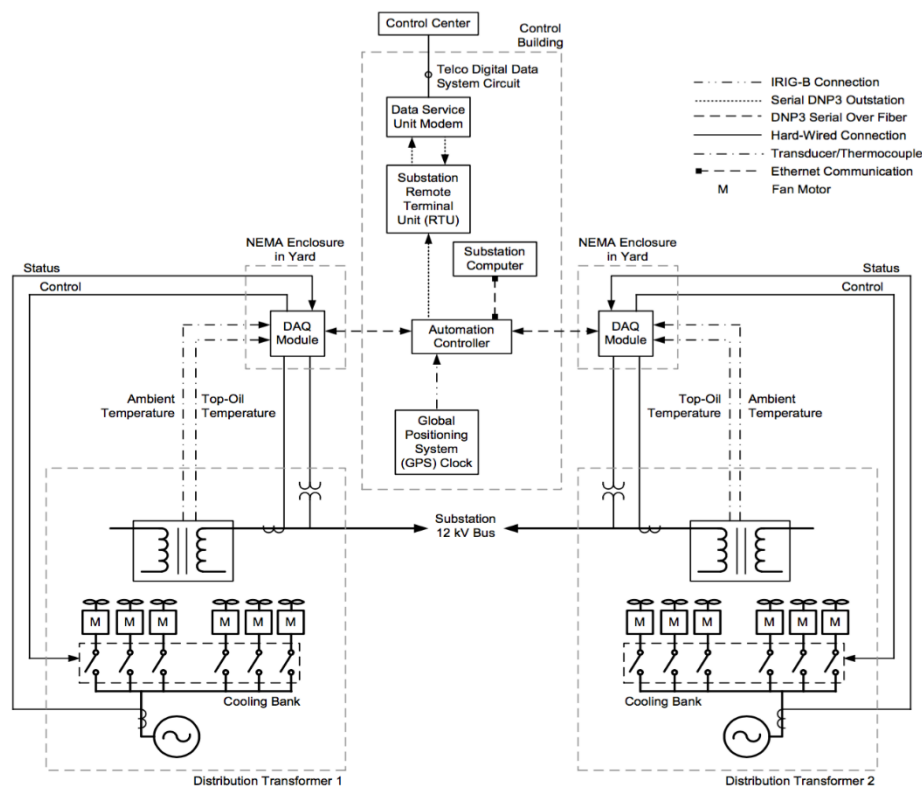


**Gráfico 22:** Dashboard de centro de control. Por Walter Castillo (2012)



La arquitectura se representa del flujo de información bidireccional con los componentes físicos.

**Gráfico 23:** Arquitectura de solución end to end. Por Walter Castillo (2012)



Esta arquitectura, más allá de su diseño técnico, tiene rasgos muy vinculados a la industria 4.0. Contiene elementos que además de medir, pueden accionar. Todo se encuentra conectado de modo bidireccional (en un sentido para levantar datos, en el otro sentido para accionar y abrir un rule por ejemplo). La cantidad de información que se levanta es enorme y se registra de manera permanente, para que desde el control central que es donde se

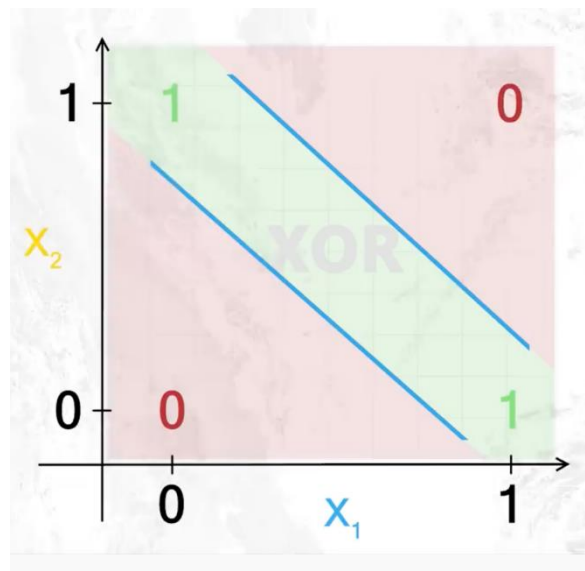
encuentra el cerebro que orchestra todo el ecosistema se pueda, mediante modelos algorítmicos no solo reaccionar ante eventuales fallas sino que además de esto construir comportamientos que ayuden a predecir.

Como se detalló anteriormente en el framework de tecnologías de un distribuidor, es el SCADA el sistema que procesa, distribuye y enseña los datos, permitiendo a los operadores y otros trabajadores a realizar un análisis de los datos para facilitar la toma de decisiones.

Es sobre este sistema que deben integrarse los algoritmos de aprendizaje antes repasados.

El modelo atrás de este ejemplo es el de una puerta lógica XOR. Donde las variables de entrada son la temperatura ambiente y la temperatura de aceite. Y donde se utiliza una red neuronal con dos neuronas para trazar dos rectas que separen las áreas de correcto e incorrecto funcionamiento a través de umbrales de mínima y máxima.

**Gráfico 24:** Diagrama lógico de una puerta XOR. Por Carlos Santana Vega (2019)



Esta lógica programada en el SCADA con datos de entrenamiento permite construir un algoritmo de aprendizaje que acciona sobre los IDEs, manteniendo el transformador dentro de los parámetros especificados, alargando la vida útil del mismo, reduciendo inspecciones programadas, y abriendo el circuito ante fallas imprevistas preservando siempre su funcionamiento.

Con esta técnica de monitoreo se pasa de un método basado en un perfil de carga típico a uno basado en la carga real. Parámetros históricos vs. parámetros medidos en tiempo real o predictivos.

Se pueden detectar anomalías en la capacidad de carga del transformador y programar mantenimiento selectivo. También permite monitorear el estado de salud del transformador, anticipando acciones correctivas que mantienen al transformador siempre o la mayor cantidad de tiempo posible, dentro de los parámetros normales de funcionamiento permitiendo al distribuidor administrar mejor los activos de la subestación al aumentar considerablemente el tiempo medio entre el mantenimiento, evitar interrupciones inesperadas debido a fallas del transformador y, lo que es más importante, reducir el riesgo de exponer el transformador a condiciones de funcionamiento anormales.

### ***Beneficios estimados***

Según la Comisión Federal de Electricidad (CFE, 1999) de México, la estadística de fallas de transformadores de potencia indica que 49% de las fallas se refieren a problemas de aislamiento en devanados, 26% a boquillas, 10% al cambiador de derivaciones, 3% a explosiones con incendio, 2% al núcleo y 10% a otras causas.

En términos económicos, y operativos, existen una serie de beneficios concretos, para las compañías de distribución al incorporar monitoreo con técnicas de Machine Learning detrás. En cierta forma, estos beneficios son argumentos para los fabricantes de transformadores a la hora de repensar su modelo de negocio, como se observaba antes, de un modelo de venta de activo a uno de venta SaaS o PaaS.

Los beneficios son los siguientes:

- Reducción de costos de inspección y mantenimiento. Se estima una reducción de gasto en mantenimiento en el orden del 30% anual.
- Reducción de la tasa de fallas esperada. Se estima un ahorro anual en el orden del 50% por efecto de la reducción de fallas.
- Reducción en el costo de la energía no generada. Se estima un beneficio anual por potencia adicional generada del orden del 60%.
- Reducción de energía contractual no entregada. Se estima un beneficio anual de un 58%.
- Reducción de sobrecarga y envejecimiento. Considera el diferimiento de costos de capital por reemplazo. Este es uno de los factores más relevantes a la hora de medir el beneficio del monitoreo. Este tipo de beneficio se estima con un impacto en el orden del 90% en ahorro.

- Existen otros beneficios que tienen una incidencia menor en términos económico pero que aportan valor a la solución: mejora la confiabilidad del sistema, mejora la seguridad del personal, mejora la planificación de mantenimiento etc.

### ***Introduciendo el aprendizaje automático***

De manera conceptual y general es posible establecer para este caso de aplicación un abordaje de proyecto de Machine Learning donde se puede construir un algoritmo que frente a determinados datos de entrada, a través del aprendizaje automático, brinde datos de salida esperados.

Suponiendo que se quiere probar la respuesta frente a cambios en el perfil de carga. Teóricamente se debería observar que a medida que las temperaturas y la carga actual en el transformador se acercan al límite, el algoritmo determina si se requiere una reducción de la carga dependiendo de las etapas de enfriamiento. Suponiendo ausencia de enfriamiento adicional; el algoritmo debería predecir cantidad de carga que debe eliminarse para evitar que el transformador envejezca más rápidamente.

Otra prueba puede ser basada en una contingencia, debido a una falla de uno de dos transformadores de una subestación. Suponiendo ambos transformadores con carga máxima y la temperatura ambiente más alta. Al comenzar la prueba ambos equipos deberían funcionar según los parámetros establecidos. Luego, al forzar la falla de uno de los equipos transformador 1, toda la carga debería ir al 2. Debería suceder que el algoritmo, transcurrido un tiempo ejecute una acción de enfriamiento en el equipo 2. Al volver a funcionar el equipo 1 se re balancean las cargas no de manera inmediata sino que de manera gradual sujeto a cómo va estabilizándose la temperatura del aceite del equipo 2, de modo tal de mantener siempre los parámetros en los umbrales establecidos.

Se podrá ver luego en el caso siguiente una propuesta en detalle de como planificar un proyecto de Machine Learning y el desarrollo de un modelo de aprendizaje profundo aplicado, para entender justamente los pasos a seguir, metodología y herramientas para avanzar en la construcción de un modelo propicio.

### **Aprendizaje automático en la predicción del índice de salud del transformador**

De la misma forma en que un médico analiza los diferentes síntomas en un ser humano para comprender la enfermedad y sugerir la cura, con las técnicas de monitoreo de la

condición, mediante la medición de diferentes parámetros internos y externos asociados al transformador es posible predecir su estado operativo buscando tomar una decisión adecuada de ajuste, reemplazo, mantenimiento, etc.

Este caso busca establecer una base de uso del aprendizaje automático (ML) hacia la predicción de la condición general del estado del aislamiento de los transformadores de distribución de media tensión en función de los resultados de sus pruebas de aceite.

Antes de continuar, Kozyrkov, Head of Decision Intelligence de Google propone 12 pasos de marco procedural para aplicar IA:

Paso 0: Verificación de la realidad y configuración

Paso 1: Definir los objetivos

Paso 2: Obtener acceso a los datos

Paso 3: Dividir los datos

Paso 4: Explorar los datos

Paso 5: Preparar las herramientas

Paso 6: Usar las herramientas para entrenar algunos modelos

Paso 7: Depurar, analizar y ajustar

Paso 8: Validar los modelos

Paso 9: Probar el modelo

Paso 10: Producir el sistema

Paso 11: Ejecutar experimentos

Paso 12: Monitorear y mantener para siempre

El siguiente procedimiento tiene como objetivo imitar un escenario realista de cómo una compañía de distribución se beneficiaría del uso de diferentes herramientas de Machine Learning para comprender el índice de salud del aislamiento de sus transformadores.

Para validar el enfoque detallado a continuación, es necesario primero construir escenarios diferentes de entrenamiento y de prueba de datos con varias herramientas de reconocimiento de patrones para clasificar la condición de salud del transformador en función del conjunto completo de características de prueba de entrada. Luego, utilizar las mismas herramientas de reconocimiento de patrones junto con los tres escenarios de entrenamiento / prueba para un número reducido de características de prueba (paso 3).

Uno de los principales parámetros que definen el funcionamiento y la planificación de una red de servicios eléctricos es la condición de salud de los transformadores que la componen. Según su estado de salud, los ingenieros del field service pueden predecir la vida útil restante del transformador.

Esto puede beneficiar a las compañías de distribución para preparar un plan financiero adecuado para estimar el costo futuro de mantenimiento y reemplazo de las unidades de transformadores.

Se han realizado importantes investigaciones para ayudar a las empresas de servicios públicos a reducir sus costos de mantenimiento de activos. Esta área de investigación se conoce comúnmente como la práctica de gestión de activos de transformadores (TAM). TAM define un conjunto estratégico de actividades futuras de mantenimiento y reemplazo para el activo del transformador de servicios públicos basado en métodos de prueba de diagnóstico de la condición de salud del transformador.

El objetivo final de TAM es garantizar la confiabilidad del sistema de energía dentro de una plataforma económica. Hay dos métodos de prueba de diagnóstico: de monitoreo de condición (CM) y evaluación de condición (CA). CM se refiere a todas las pruebas eléctricas, químicas y físicas que se utilizan colectivamente para las herramientas de CA que determinan la condición de salud del transformador.

Tener conocimiento del historial del transformador (historial de carga y falla), índice de riesgo asociado (basado en la carga que alimenta), la condición de salud actual y todos los costos financieros relacionados (mantenimiento, operación y falla) resultarían en un plan de gestión de riesgo económico con decisiones posteriores adecuadas.

### ***Cálculo del índice de salud del aislamiento***

La condición de salud del transformador se rige por su condición de aislamiento de papel y aceite. Analizar las muestras de aceite del transformador sería más ventajoso que probar otros componentes del transformador (relación de espiras, resistencia del devanado, reactancia de fuga, etc.) para la detección de fallas y la esperanza de vida.

Teniendo en cuenta el estado de salud de todos los componentes del transformador, el estado de salud general se puede definir utilizando el índice de salud (HI). El índice de salud

es un factor de índice único que combina observaciones operativas, inspecciones de campo y pruebas de laboratorio para ayudar en el ciclo TAM.

La condición de aislamiento es una parte vital del cálculo de HI que podría ser suficiente cuando hay datos limitados disponibles para el registro y diseño del servicio del transformador. Comprender la condición del aislamiento requeriría un análisis exhaustivo de la muestra de aceite del transformador mediante pruebas de laboratorio eléctricas, químicas y físicas.

Todas las pruebas de laboratorio de aislamiento de aceite realizadas pertenecen a una de las tres principales categorías de prueba, que son las pruebas de gases disueltos (DGA), de calidad del aceite (OQA) y de furano (FFA).

Las pruebas DGA generalmente se realizan para la detección de fallas internas del transformador (eléctricas y / o térmicas). La de calidad del aceite OQA se determina probando el voltaje de descomposición del aceite (BDV), la acidez, el contenido de agua, la tensión interfacial (IFT), el factor de disipación dieléctrica (DDF) y el color. Finalmente, la medición de furano FFA determina el grado de degradación del aislamiento del papel mediante la determinación del contenido de furano en el aceite del transformador. El furano es un compuesto químico que se disuelve en el aceite aislante al romperse la cadena de celulosa del material de papel. La prueba de furano es un fuerte indicador del envejecimiento del aislamiento del papel del transformador.

Colectivamente, las pruebas de laboratorio en gases disueltos, aceite y calidad del papel se utilizan para calcular el valor de HI.

### ***Métodos para computación HI***

Existen varios estudios fundados en diferentes métodos de IA para la predicción del HI.

Un modelo utilizado es el neuro-borroso (neuro-difuso, o neuro-fuzzy) que se refiere a combinaciones de redes neuronales artificiales y lógica difusa. Este tipo de modelos arrojó resultados de predicción de más del 50%.

Mediante el uso de redes neuronales de regresión general, se utilizaron seis entradas clave, incluido el gas combustible disuelto total del petróleo, el contenido de furano, la resistencia dieléctrica, la acidez, el contenido de agua y el factor de disipación. Se alcanzó un 83% de éxito en la predicción de la condición de salud del transformador.

Mediante otro modelo de aprendizaje supervisado, denominado máquinas de vectores de soporte (SVM) se logró una tasa de clasificación del 87.8%. SVM clasifica las instancias mediante la construcción de un conjunto de hiperplanos para separar las categorías de clase.

Como se observa, se prevé un futuro prometedor para el uso de Machine Learning en el campo TAM. La predicción de la HI del activo del transformador, mediante este tipo de técnicas, tendrá un impacto sustancial en la estrategia financiera de la compañía de servicios públicos en los planes de mantenimiento de activos.

### ***Muestra y estructura de Datos***

En un estudio realizado por Alhaytham Alqudsi & Ayman El-Hag en el 2019, se estudió con parámetros reales el cálculo de índice de salud mediante modelos de Machine Learning.

En dicho estudio se consideraron bases de datos de muestras de aceite de transformadores de dos compañías de distribución. Las dos compañías se denominan Util1 y Util2. En total, se obtuvieron 730 muestras de aceites de transformador de Util1, y 327 muestras de aceites de transformador de Util2. Los transformadores de ambas bases de datos corresponden a transformadores de distribución de media tensión.

Luego, para el cálculo de HI se considera la siguiente ecuación (eq1):

$$HI = \frac{(\beta_{DGA} \times \alpha_{DGA}) + (\beta_{OQA} \times \alpha_{OQA}) + (\beta_{FFA} \times \alpha_{FFA})}{4 \times (\alpha_{DGA} + \alpha_{OQA} + \alpha_{FFA})} \times 100\%.$$

Ref: Alhaytham Alqudsi & Ayman El-Hag

Se calculan tres factores cuantitativos relacionados con las pruebas DGA, OQA y FFA (denotadas por  $\beta$ ). Los factores  $\beta$  son valores discretos que varían de 1 a 5 (o 1 a 4 para  $\beta_{OQA}$ ) con el orden ascendente de los valores que indican un estado deteriorado de la salud del transformador. Luego, los tres factores se multiplicarán por sus pesos asociados (denotados por  $\alpha$ ) para producir finalmente el factor de valor HI y se agrega cuantificablemente a las otras características de prueba.

El valor HI oscila entre 0% y 100%, siendo el 100% un transformador en la condición más saludable posible. Una vez que se calcula el HI, la muestra de datos se clasifica en una de tres condiciones de salud clases de condición, que son: Malo (B), justo (F) y bueno (G).

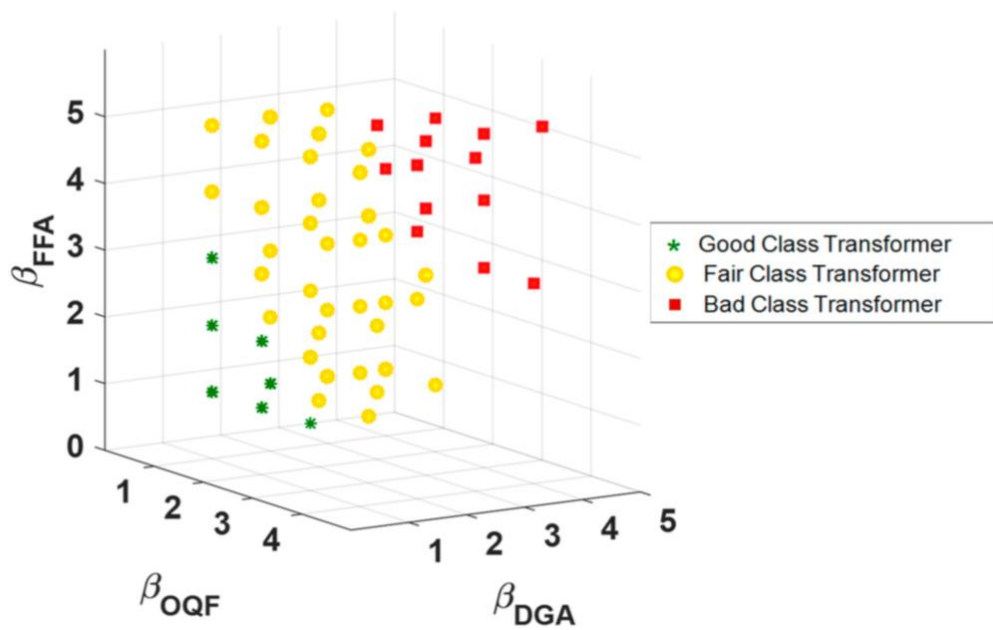


**Gráfico 25:** Rango de valores del HI de las clases de condiciones de salud y el número de muestras. Por Alhaytham Alqudsi & Ayman El-Hag (2019)

Data Group	Good (G), HI > 85%	Fair (F), 50% < HI ≤ 85%	Bad (B), HI ≤ 50%
Util1	496	206	28
Util2	238	84	5
Total from Util1 and Util2	734	290	33

Para tener una mejor visualización de las 10 variables de entrada y cómo se relacionan con la condición de salud de los datos del transformador, se representa un gráfico tridimensional de los datos utilizando los factores  $\beta$  de la ecuación (eq1). Como se puede ver, existe una diferencia clara y distinta entre las tres clases de muestras de datos influenciados por los tres factores  $\beta$ .

**Gráfico 26:** Representación 3D de las variables de entrada  $\beta_{DGA}$ ,  $\beta_{OQA}$  y  $\beta_{FFA}$ . Por Alhaytham Alqudsi & Ayman El-Hag (2019)



**Aplicando la metodología**

La evaluación de la condición del transformador requiere el análisis de datos sustanciales, cuyas instancias representan transformadores investigados y cuyas características representan variables medidas para predecir la condición HI del transformador.

Un modelo de reconocimiento de patrones puede ser entrenado en el conjunto de datos para que los algoritmos de aprendizaje puedan operar más rápido y más efectivamente; en otras palabras, se reducen los costos y se mejora la precisión del aprendizaje.

La metodología presentada en el estudio de Alhaytham Alqudsi & Ayman El-Hag se basa en la selección de características y la clasificación de patrones para evaluar el HI de los transformadores de potencia. Machine Learning ayuda a obtener información sobre las propiedades de las dependencias de datos y la importancia de los atributos individuales en el conjunto de datos.

La clasificación es una técnica de Machine Learning utilizada para asignar etiquetas (clases) a instancias de entrada no etiquetadas basadas en características discriminantes. Las etiquetas de clase en este estudio son las tres clases de condición de salud. Las técnicas de selección de características determinan las características importantes a incluir en el proceso de clasificación de una recopilación de datos en particular.

En el presente estudio se utilizaron 10 características, como se ilustró anteriormente. Todo el proceso de aplicación de estas técnicas de Machine Learning para predecir la clase de datos invisibles consta de las fases típicas de entrenamiento y pruebas (paso 9).

Considerando un problema de clasificación binaria con clases positivas (P) y negativas (N) (es decir, un problema de dos clases). Como una generalización para tales problemas de clasificación de múltiples clases, la medida de precisión de clasificación general se evalúa en términos de la cantidad de muestras clasificadas verdadera y falsamente. En consecuencia, se construye una matriz de confusión (métrica para encontrar la precisión y exactitud del modelo) para registrar la frecuencia de muestras verdaderamente positivas (TP), verdaderamente negativas (TN), falsamente positivas (FP) y falsamente negativas (FN). En el siguiente gráfico se muestra una matriz de confusión para problemas de clasificación binaria, en la que la clase es P o N.

**Gráfico 27:** Matriz de confusión de problemas de clasificación binaria. Por Alhaytham Alqudsi & Ayman El-Hag (2019)

		Classified as	
		P	N
Really is	P	TP	FN
	N	FP	TN

La medida de precisión de clasificación general se calcula mediante la siguiente ecuación (eq2):

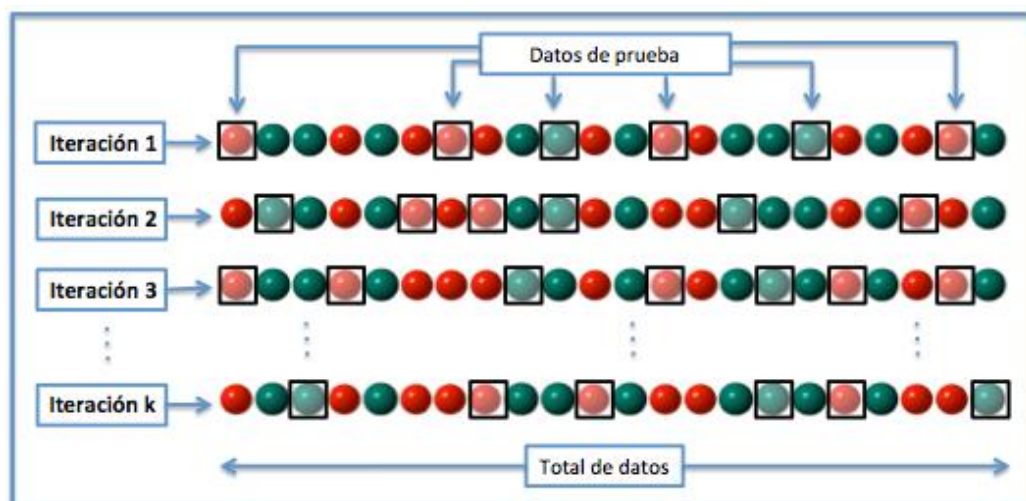
$$Accuracy Rate = \frac{TP + TN}{TP + FP + TN + FN}$$

Para validar el modelo de clasificación, se utiliza la técnica de validación cruzada k-fold.

La validación cruzada o cross-validation es una técnica utilizada para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre datos de entrenamiento y prueba. Consiste en repetir y calcular la media aritmética obtenida de las medidas de evaluación sobre diferentes particiones. Se utiliza en entornos donde el objetivo principal es la predicción y se quiere estimar la precisión de un modelo que se llevará a cabo a la práctica. (Wikipedia)

La validación cruzada k-fold consiste al dividir aleatoriamente el conjunto de datos de entrenamiento y el conjunto de datos de prueba. Para cada división la función de aproximación se ajusta a partir de los datos de entrenamiento y calcula los valores de salida para el conjunto de datos de prueba. El resultado final corresponde a la media aritmética de los valores obtenidos para las diferentes divisiones. La ventaja de este método es que la división de datos entrenamiento-prueba no depende del número de iteraciones. Pero, en cambio, con este método hay algunas muestras que quedan sin evaluar y otras que se evalúan más de una vez, es decir, los subconjuntos de prueba y entrenamiento se pueden solapar.

**Gráfico 28:** Funcionamiento de la validación cruzada k-fold. Por Francisco Parra (2017)



La selección de características es el proceso de seleccionar un subconjunto de características relevantes, de alta calidad y no redundantes para construir modelos de aprendizaje, con una precisión mejorada. Es importante seleccionar las características apropiadas para basar la clasificación en ellas.

En el estudio desarrollado, se utilizó el método de regresión gradual para determinar cuál de las 10 características de la prueba de aceite serán lo suficientemente adecuadas como para predecir el valor de HI con la ausencia de las menos significativas.

El objetivo subyacente de la regresión gradual (PCR) es, a través de una serie de pruebas (pruebas  $f$ , pruebas  $t$ ) encontrar un conjunto de variables independientes que influyan significativamente en la variable dependiente. Esto se realiza mediante iteración.

En el libro “An Introduction to Statistical Learning” (Gareth James, Daniela Witten, Trevor Hastie, Robert Tibshirani) se presenta este enfoque implicando la identificación de combinaciones lineales o direcciones que mejor representan los predictores  $X_1, \dots, X_p$ .

Estas direcciones se identifican de manera no supervisada, ya que la respuesta  $Y$  no se utiliza para ayudar a determinar las direcciones de los componentes principales. Es decir, la respuesta no supervisa la identificación de los componentes principales. En consecuencia, la regresión gradual tiene un inconveniente: no hay garantía de que las instrucciones que mejor explican los predictores también sean las mejores direcciones para predecir la respuesta.

Una alternativa supervisada que mitiga la falencia de regresión gradual es el enfoque de mínimos cuadrados parciales (PLS). Al igual que PCR, PLS es un método de reducción de dimensiones, que primero identifica los cuadrados de un nuevo conjunto de características  $Z_1, \dots, Z_M$  que son combinaciones lineales de las características originales, y luego ajusta un modelo lineal a través de mínimos cuadrados utilizando estas  $M$  nuevas características.

Pero a diferencia de la PCR, PLS identifica estas nuevas características de forma supervisada, es decir, utiliza la respuesta  $Y$  para identificar nuevas características que no solo se aproximan bien a las características antiguas, sino que también están relacionadas con la respuesta. Hablando en términos generales, el enfoque PLS intenta encontrar direcciones que ayuden a explicar tanto la respuesta como los predictores.

Los clasificadores utilizados en el estudio fueron los siguientes: Bosque aleatorio (RForest), Arbol de decisión (J48), Máquinas de vectores de soporte (SVM), Redes neuronales artificiales (ANN), One Rule (OneR), Vecino k-más cercano (kNN), Regresión logística multinomial (MLR) y Naive Bayes (NB).

### **Resultados por modelado de clasificador de funciones completas**

Se utilizaron los ocho tipos de clasificadores antes mencionados para clasificar la condición de salud del transformador como B, F o G.

Se diseñaron diferentes escenarios de entrenamiento y prueba para el estudio. Para un escenario de entrenamiento / prueba, Tr-Util1, Ts-Util1, el clasificador sería entrenado en datos de Util1 y probado usando los datos no utilizados de Util1. De manera similar es el caso con un escenario de entrenamiento / prueba, Tr-Util2, Ts-Util2.

Para validar la naturaleza generalizada de los clasificadores, un escenario de entrenamiento / prueba, Tr-Util1, Ts-Util2, haría que el clasificador se capacitara en datos de Util1 y se probara en diferentes datos de Util2.

Se realizó una evaluación del rendimiento de los clasificadores de características completas y de características reducidas mediante la tasa de precisión obtenida según la eq2. La tasa de precisión media (MAR) se muestra en los resultados presentados, que es básicamente el valor promedio obtenido para la tasa de precisión para 10 ensayos.

Para comprender mejor como se obtienen los resultados, se considera el siguiente ejemplo. Al aplicar el escenario de entrenamiento / prueba Tr-Util1, Ts-Util1 con el clasificador de RF, la matriz de confusión indicará la frecuencia de muestras de datos clasificadas verdadera y falsamente. En el gráfico 29, se muestra la matriz de confusión obtenida para el escenario Tr-Util1, Ts-Util1 usando el clasificador RForest. Como se puede ver, el 99.2% (492 de 496) para la clase G de transformadores se clasificaron correctamente. Del mismo modo, el 94,2% y el 68% de las muestras de datos se clasificaron correctamente como las clases F y B, respectivamente. La tasa de precisión se calculó utilizando la ecuación (eq3) como:

$$Accuracy Rate = \frac{TG+TF+TB}{TG+TF+TB+FG+FF+FB} = \frac{492+194+19}{492+194+19+13+3+9} \times 100\% = 96.58\%$$

donde TG, TF y TB son las muestras de datos verdaderamente clasificadas en las clases G, F y B, respectivamente, y FG, FF y FB son las muestras de datos falsamente clasificadas en las clases G, F y B, respectivamente. Se realizó la misma simulación 10 veces y se observó el MAR. El gráfico 30 muestra una tabla resumen de los resultados MAR obtenidos para ocho tipos de clasificadores con los tres escenarios de entrenamiento / prueba.

**Gráfico 29:** Matriz de confusión para el escenario Tr-Util 1, Tr-Util 1 utilizando RForest. Por Alhaytham Alqudsi & Ayman El-Hag (2019)

		Classified as		
		G	F	B
Really is	G	492	4	0
	F	9	194	3
	B	0	9	19

**Gráfico 30:** Resultados de la tasa de precisión media de todas las funciones para los 8 tipos de clasificadores con los 3 escenarios de entrenamiento/prueba. Por Alhaytham Alqudsi & Ayman El-Hag (2019)

Training/Testing Scenario	NB	MLR	ANN	SVM	kNN	OneR	J48	RF
<i>Tr-Util1, Ts-Util1</i>	92.6%	95.5%	94.9%	92.6%	93.0%	86.7%	95.6%	96.6%
<i>Tr-Util2, Ts-Util2</i>	93.3%	94.8%	92.7%	86.9%	94.5%	85%	98.2%	96.6%
<i>Tr-Util1, Ts-Util2</i>	90.2%	95.4%	95.4%	85.6%	87.8%	85.9%	95.1%	93.6%

### **Análisis de los resultados**

Como se puede observar, sobre los resultados generales de MAR obtenidos para los modelos de clasificador de características completas todos fueron superiores al 85%. Todos los modelos de aprendizaje utilizados dieron una precisión media por encima del 85%.

El mayor error de clasificación se observó para las muestras de clase B. Aunque muchas muestras de datos que realmente pertenecen a la clase B se clasificaron erróneamente, siempre se clasificaron erróneamente como pertenecientes a la clase F en lugar de a la clase G.

Este tipo de error es de riesgo mínimo en el sentido de que los clasificadores nunca darían una información engañosa de que el transformador se encuentra en una excelente condición de salud mientras realmente se encuentra en la peor condición de salud.

En el gráfico 31 se muestran ejemplos de las matrices de confusión obtenidas en las que un número significativo de las muestras B se clasificaron erróneamente como muestras F. La clasificación errónea en la mayoría de los casos se atribuye al hecho de que un número limitado de muestras de aceite de transformador de la clase B están disponibles para entrenamiento (solo 33 muestras en total).

**Gráfico 31:** Matriz de confusión para (a) el escenario Tr-Util1, Ts-Util1 usando el clasificador kNN, (b) el escenario Tr-Util1 y Util2, Ts-Util1 y Util2 usando el ANN. Por Alhaytham Alqudsi & Ayman El-Hag (2019)

<b>(a)</b>				
		<b>Classified as</b>		
		<b>G</b>	<b>F</b>	<b>B</b>
<b>Really is</b>	<b>G</b>	483	13	0
	<b>F</b>	22	181	3
	<b>B</b>	0	13	15

<b>(b)</b>				
		<b>Classified as</b>		
		<b>G</b>	<b>F</b>	<b>B</b>
<b>Really is</b>	<b>G</b>	719	15	0
	<b>F</b>	20	262	8
	<b>B</b>	0	17	16

Para las restantes clases de condiciones de salud, la tasa de precisión fue alta y aceptable para la mayoría de las simulaciones. La mayoría de los clasificadores tuvieron un buen desempeño al distinguir entre una muestra F y una muestra G. Esto se atribuye principalmente al hecho de que hay un número significativo de muestras disponibles de ambas clases para los datos de entrenamiento.

Uno de los escenarios de entrenamiento / prueba extremadamente importantes sería el de Tr-Util1, Ts-Util2. Se observó que la mayoría de los clasificadores para este escenario particular no se desempeñaron tan bien como en los otros escenarios de entrenamiento / prueba. Este rendimiento inferior se atribuye principalmente al hecho de que el entrenamiento del clasificador se realizó con datos de una compañía y las pruebas se realizaron con datos completamente invisibles de otra compañía.

Aún así, los resultados de MAR obtenidos son excelentes dados los datos de prueba nunca vistos anteriormente. Los clasificadores MLR y ANN fueron los mejores clasificadores, lo que resultó en un MAR del 95.4%. Estos excelentes resultados respaldan la naturaleza generalizada del enfoque propuesto de tal manera que una compañía de distribución puede utilizar clasificadores pre modelados para sus propias muestras de aceite de transformador.

### **Conclusiones**

El caso presentado fue desarrollado para validar el enfoque del uso de Machine Learning (a través de herramientas de clasificación de patrones) para el problema del índice de salud. El rendimiento de los clasificadores puede verse que es muy bueno.

Los resultados promedio para todos los valores MAR fueron en general muy superiores al 85%.

Repasando el estudio y su principales conclusiones se puede ver como alentadoras todas las posibilidades que ofrece el Machine Learning y la incorporación de tecnología en los procesos de monitoreo para el estado de salud de los transformadores.

Es importante destacar todo el espectro de acciones que pueden llevarse adelante desde el lugar del fabricante de transformadores, con el solo hecho de dar algunos pasos hacia una transformación digital. Desde revalidar sus modelos de negocio, hasta incorporar inteligencia artificial para lograr eficiencias destacadas.

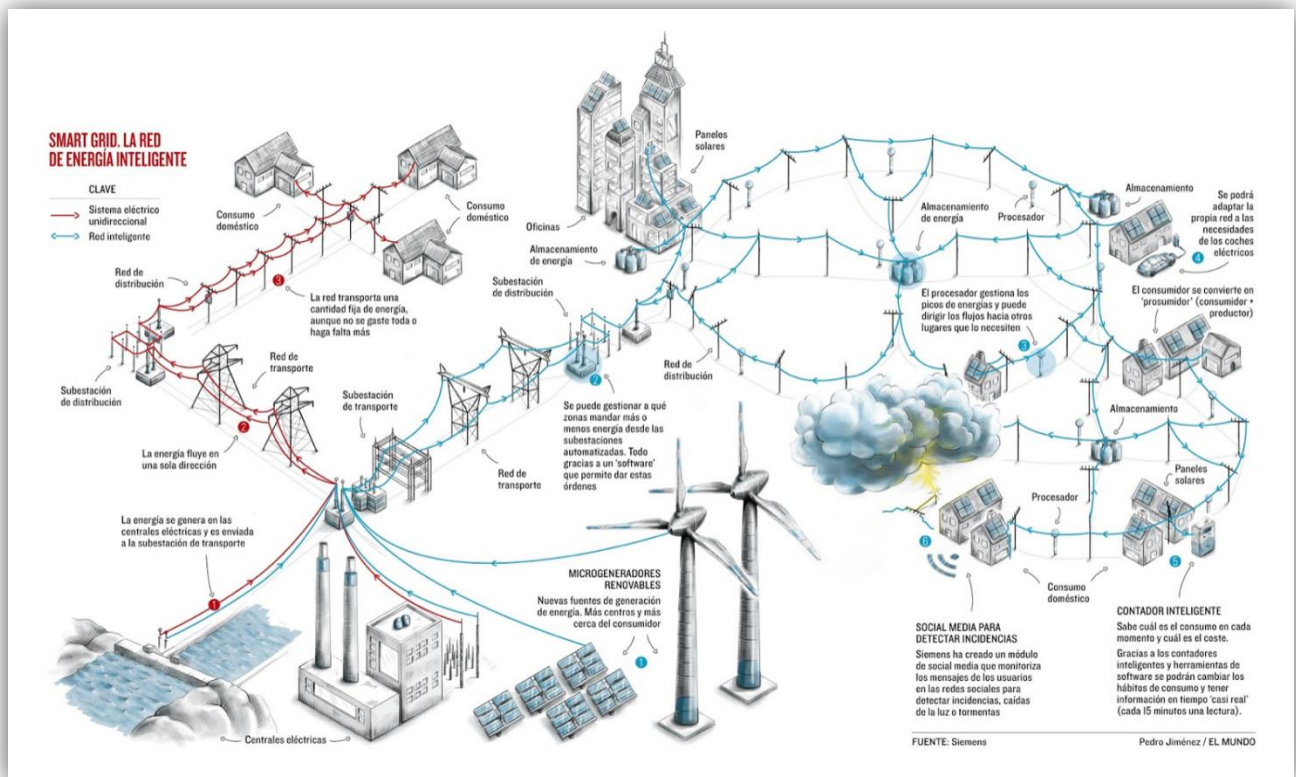
Como se puede ver, lo importante en el campo del Machine Learning es encontrar la metodología (los 12 pasos), y seguirlos de manera rigurosa. Luego también será importante encontrar el modelo adecuado, seleccionar los datos correctos y entrenar el modelo. Sin duda un enorme desafío pero de importante retorno.

## **CAPITULO IV. REDES ELECTRICAS INTELIGENTES**

Las redes eléctricas inteligentes (REI), según la definición de la Asociación Electrotécnica Argentina (AEA, 2013), son la conjunción de la red eléctrica tradicional con tecnologías modernas de la información y comunicaciones. Otros organismos, como el Departamento de Energía estadounidense, tienen una visión más amplia de las REI, ya que incluyen bajo esta definición a los sistemas de generación distribuida y a las micro redes.

**Gráfico 32:** Diagrama ejemplo de una red de energía inteligente. Por Pedro Jimenez (2015).





Una red inteligente es una red evolucionada que gestiona la demanda de electricidad de forma sostenible, fiable y económica, basada en una infraestructura avanzada, y adaptada para facilitar la integración de todos sus componentes (ABB, 2014).

El sistema eléctrico actual se construyó hace muchos años, y es una de las primeras infraestructuras de las que depende la sociedad moderna para su funcionamiento.

La evolución de las redes eléctricas es hacia las redes inteligentes, porque suministrarán más electricidad (demanda creciente como se observó anteriormente), de forma más confiable y segura. Y con factibilidad de incorporar nuevas fuentes de generación (de energías limpias).

Las redes inteligentes, por su arquitectura y diseño, permite responder a la demanda y equilibrar el consumo eléctrico con la generación. Permite a su vez incorporar nuevas tecnologías de almacenamiento, crucial para la incorporación de autos autónomos por ejemplo.

Los sistemas eléctricos sufrirán una importante evolución, en cuestiones de fiabilidad, de reducción de pérdidas, y reducción de costos de mantenimiento, entre otros. La red, al

incorporar la gestión permitirá mejorar el control y sobre todo la velocidad de respuesta a eventos predeterminados.

Las redes inteligentes son la evolución de los sistemas eléctricos, al estar diseñadas para satisfacer cuatro principales requisitos: capacidad, fiabilidad, eficiencia y sustentabilidad.

La solución, que se detallará a continuación requiere que las compañías de distribución de energía cuenten con información relacionada con la conectividad de transformador y con modelos de conectividad actualizados de cada transformador de distribución a su línea y fase de alimentación en función del estado de funcionamiento de la red de distribución, y de la información del control de supervisión, del sistema de adquisición de datos (SCADA) y del sistema de gestión de distribución (DMS).

Al día de hoy, las millonarias inversiones realizadas en los países más desarrollados están enfocadas en la automatización en la distribución, la lectura remota de los medidores de energía y la implantación de generadores de energía basados en fuentes renovables.

Sin embargo, aún no se ha avanzado lo suficiente en las cuestiones relativas al manejo dinámico, e inteligente, de la demanda, o el almacenamiento de energía en grandes cantidades y por periodos prolongados de tiempo. En el caso de los países en vías de desarrollo y, en particular, de Latinoamérica, el panorama de las REI está más rezagado, pero hay una tendencia positiva a fomentar la implementación de proyectos afines a esta temática. Para poder entender el panorama actual y el escenario de los próximos años es necesario, en primer lugar, describir la idea de una REI a través del desarrollo de un modelo conceptual.

### **Modelo conceptual para las REI**

El Instituto Nacional de Normas y Tecnología ('National Institute of Standards and Technology', NIST) de Estados Unidos ha promovido un esquema conceptual para las REI que sirve de base para su caracterización, uso, comportamiento, requerimientos y estándares. Se trata de un esquema conceptual de alto nivel que define a las REI como un conjunto de sistemas (denominados "dominios") relacionados por flujos de energía e información bidireccionales.

No se trata de un diagrama de diseño sino que es un esquema que define actores y vínculos para identificar los tipos de interacción entre los dominios. Los dominios identificados en este modelo son:

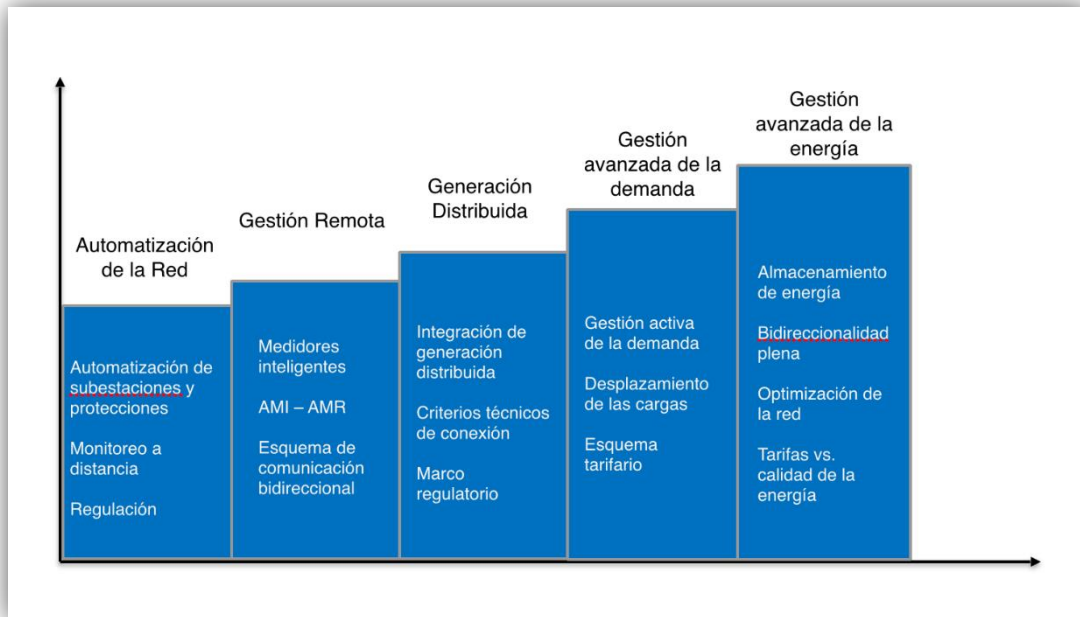
- **Usuarios:** son los usuarios finales de la energía eléctrica (residenciales, comerciales e industriales). En este nuevo mapa ellos pueden consumir, generar, almacenar y hasta gestionar el uso de la energía.
- **Distribución:** son las compañías de distribución. Su función es la de distribuir la energía hacia el cliente, sumando ahora en el marco de las REI la posibilidad de traerla también desde el cliente.
- **Transmisión:** son las compañías encargadas de transportar la energía en grandes volúmenes y distancias, desde la generación a los entornos de consumo. En el marco de las REI también pueden almacenar y/o generar energía.
- **Generación:** se refiere a los generadores de energía eléctrica en grandes volúmenes: represas hidroeléctricas, centrales térmicas, nucleares, parques eólicos, etc. También a este nivel se espera que se pueda almacenar energía para su posterior consumo.
- **Operaciones:** son los que gestionan y administran la provisión de energía. Su función es garantizar el óptimo funcionamiento de la red, y también planificar, establecer contingencias, medir consumos, etc.
- **Mercados:** los actores del mercado eléctrico, donde se establecen los precios de la energía y se gestiona la oferta y la demanda.

### **Planificación de despliegue de una REI**

Transformar una red eléctrica tradicional en una REI es un proceso que demandará planificación, tiempo e inversiones. Además, implica una variedad de acciones que se deben pensar bajo una secuencia lógica incremental. Es clave dar los pasos adecuados, buscando maximizar el aporte de valor de esa próxima implementación, buscando el mejor ROI.

Patricio Donato, investigador del Conicet, propone un modelo de etapas que refleja esta implementación progresiva.

**Gráfico 33:** Hoja de ruta para la evolución de la red. Por Patricio Donato (2016)



### *Automatización de la red*

El primer paso para implementar una REI es el de adecuar el sistema eléctrico actual pensando en las exigencias futuras. En este sentido un posible curso de acción puede ser el de automatizar todas las subestaciones de distribución y las protecciones, tanto en baja como en media tensión, incluyendo herramientas de monitoreo remoto

Otro punto relevante a trabajar tiene que ver con la regulación. Es necesario trabajar los aspectos regulatorios que fomenten la implementación de estas tecnologías.

### *Gestión remota*

Consiste en la implementación masiva de medidores inteligentes, los cuales brindarán a la compañía de distribución el monitoreo remoto de performance y consumos. A su vez también le darán al usuario final esa misma información de consumo en tiempo real, de modo de poder accionar sobre ese comportamiento.

Con este elemento se materializa un primer gran aporte de las REI, que es el de bidireccionalidad de la información a partir de la conectividad, y comunicación entre el proveedor y el usuario.

Es un paso fundamental para las siguientes etapas, donde esa información de consumo en tiempo real permitirá establecer nuevos modelos tarifarios, nuevas ofertas, e incluso nuevos comportamientos de consumo.

### *Generación distribuida*

Con una correcta gestión de red, interconectada, se podrán incorporar generadores distribuidos en puntos estratégicos de la Red. Esto significa acercar la generación de energía al usuario para que de manera segura, también comience a gestionarla (generando energía mediante paneles solares, volviendo a insertar esa energía a la red para consumo de otros usuarios por ejemplo). La energía deja de viajar en un sentido unidireccional (al consumidor) para darle bidireccionalidad al flujo, convirtiendo a los consumidores en productores (prosumidores). Para esto es importante medir, para entender balances y flujos de carga, y también significa o implica adaptar los sistemas de protección.

Como en la fase anterior, será necesario trabajar en las cuestiones regulatorias para viabilizar esto.

### *Gestión avanzada de la demanda*

En este punto, la red eléctrica ya se encuentra fuertemente automatizada, con comunicación bidireccional entre proveedores y usuarios y con sistemas de generación de energía de baja potencia distribuidos inyectando energía en la red de baja tensión.

El paso siguiente es hacia la gestión de la demanda encontrando los modelos de oferta o planes optimizados para cada tipo de perfil de consumo de los usuarios. Es establecer el modelo de bandas horarias donde en momentos de baja demanda el precio de la energía consumida es menor, por ejemplo.

### *Gestión avanzada de la energía*

Aquí ya toma relevancia cuestiones como el almacenamiento de energía en grandes volúmenes y largos periodos de tiempo, la bidireccionalidad plena de energía en todos los niveles de tensión y la implementación de esquemas tarifarios no solo dinámicos, sino que estén vinculados a la calidad de la energía consumida.

Si bien en todos estos aspectos entran en juego cuestiones tecnológicas, el desarrollo de sistemas de almacenamiento de energía es uno de los más demandantes en este sentido.

### **Perspectiva sobre las pérdidas en la red**

La reducción de las pérdidas de distribución representa un problema específico para cada distribuidor, debido a niveles heterogéneos de pérdidas tanto técnicas (TL) como no

técnicas (NTL), pero también debido a diferencias en la definición, medición o regulación de las pérdidas. La mitigación de TL y NTL requiere enfoques diferentes y específicos para cada distribuidor.

Con respecto a las redes de distribución, las pérdidas anuales de electricidad son en promedio de aproximadamente 2 a 12% en los países de la Unión Europea, según el Documento de posición de ERGEG sobre el tratamiento de pérdidas por parte de los operadores de red. Al mismo tiempo, la Directiva Europea de Eficiencia Energética (Art. 15.2) requiere que todos los Estados miembros evalúen el potencial de eficiencia energética y especifiquen medidas para mejorarla. La reducción de pérdidas se convierte en una apuesta real para todos los países europeos.

Los últimos desarrollos en tecnologías traen varias soluciones prometedoras que contribuyen a una mejora completa del proceso. Por ejemplo, el despliegue de medición inteligente y la disponibilidad de nuevos sensores hacen potencialmente disponible una gran cantidad de datos operativos en la red; las técnicas de minería de datos y TI hacen posible administrar un volumen tan grande de datos para evaluar y localizar pérdidas; y se están investigando muchas pistas interesantes para reducir las pérdidas, ya sea basadas en nuevos componentes o en un modo de operación innovador.

### **Definición de pérdidas**

Las pérdidas de la red de distribución pueden definirse en términos generales como la diferencia entre la energía eléctrica que ingresa a la red de distribución, desde generadores embebidos o redes aguas arriba / mismo nivel / aguas abajo, y la energía eléctrica que sale de ella, para fines de consumo y debidamente explicada, en términos porcentuales para un período particular.

Las pérdidas de la red de distribución se desglosan convencionalmente en dos categorías: pérdidas técnicas y no técnicas.

Se excluye de las pérdidas técnicas, a la energía consumida por los equipos de red, ya que es energía consumida, no energía disipada, y puede contabilizarse adecuadamente, ya sea medida o estimada.

Tampoco se considera pérdida a los consumos facturados pero no pagados, ya que en este caso la energía consumida es contabilizada adecuadamente por los operadores de distribución y puede separarse del balance de energía física.

Aunque la definición general de pérdidas presentada anteriormente se refiere al equilibrio físico, la realidad es que depende del contexto regulatorio y de los datos disponibles.

En la siguiente tabla se resume la clasificación de pérdidas según un esquema de niveles establecido por un equipo de trabajo del grupo Enel.

**Gráfico 34:** Clasificación de pérdidas por nivel. Por el Grupo de Trabajo en Reducción de Pérdidas de EnEl (2015)

Level 1	Level 2	Level 3	Components of Level 3
Losses	Technical Losses	Fixed Losses	<ul style="list-style-type: none"> <li>• Hysteresis losses</li> <li>• Eddy current losses</li> <li>• Dielectric losses</li> </ul>
		Variable Losses	<ul style="list-style-type: none"> <li>• Ohmic losses</li> </ul>
		Network Services	<ul style="list-style-type: none"> <li>• Uncontracted consumptions of network equipment</li> </ul>
	Non-Technical Losses	Network equipment issues	<ul style="list-style-type: none"> <li>• Theft and fraud</li> <li>• Measurement errors</li> </ul>
		Network information issues	<ul style="list-style-type: none"> <li>• Missing or unregistered connection points</li> <li>• Incorrect location or energization status of connection points</li> <li>• Incorrect information of measurement equipment</li> </ul>
		Energy data processing issues	<ul style="list-style-type: none"> <li>• Estimation of unmetered consumptions</li> <li>• Estimation of consumptions between meter readings and calculations</li> <li>• Estimation of technical losses</li> <li>• Estimation of detected issues</li> <li>• Other energy data processing issues</li> </ul>

El objetivo de mostrar el esquema de pérdidas estructurado de esta manera se centra en comprender y equalizar definiciones (de pérdidas) y criterios de modo tal de poder definir una metodología de medición acorde.

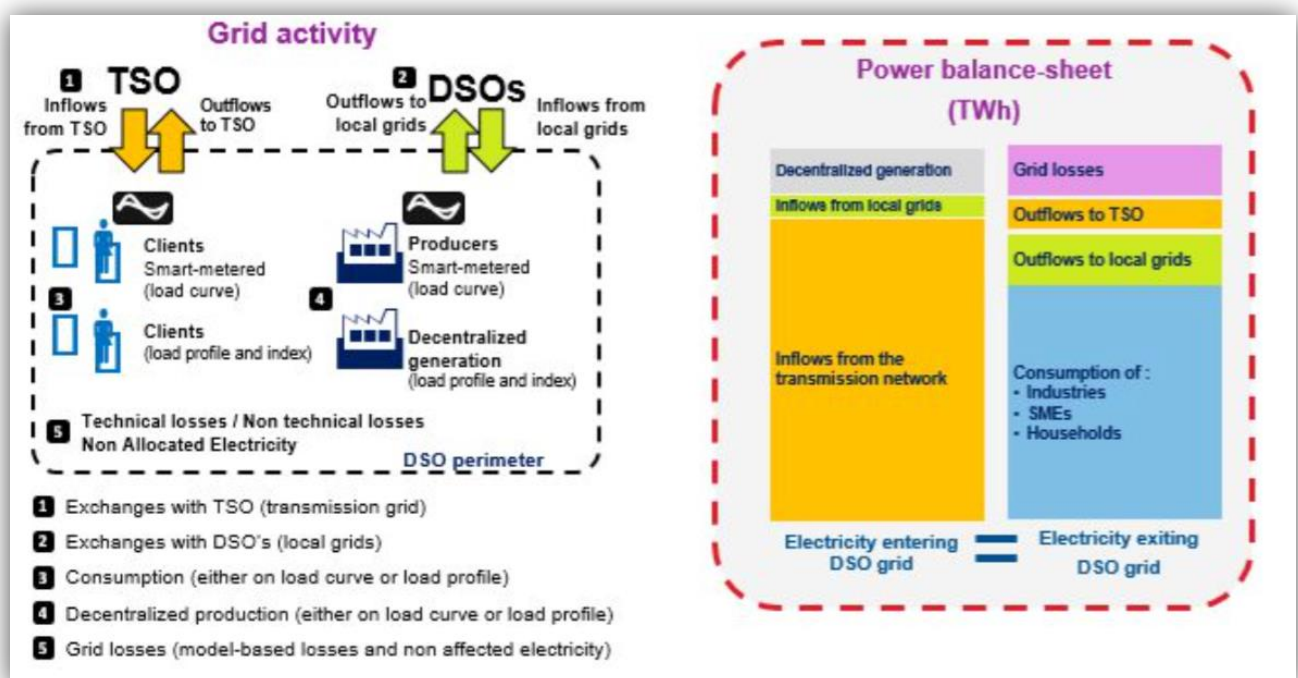
Una vez identificado claramente el método de medición de estas pérdidas según la visión de cada nivel es posible establecer los mecanismos de mitigación adecuados.

Identificar, medir, mitigar. Recorriendo este flujo de trabajo es posible encontrar la real generación de valor de estos modelos que justifica la incorporación de distintos campos de la industria 4.0: tecnología, biga data e IA.

### Criterios de medición de las pérdidas

Las pérdidas de la red de distribución se definen como la diferencia entre la energía que entra y sale de una red eléctrica.

**Gráfico 35:** Criterios de medición de pérdidas. Por el Grupo de Trabajo en Reducción de Pérdidas de EnEl (2015)



Las pérdidas prácticas se calculan directamente a partir del balance energético, ya sea financiero (con una diferencia global entre los volúmenes contables) o físico con las mediciones de red.

ENERGÍAS DE ENTRADA = Todos los flujos eléctricos que ingresan a la red.

Mediciones de red sin formato o, si está disponible, energías contraídas entre la compañía de transporte y la de distribución (o entre 2 de distribución)



ENERGÍAS DE SALIDA = Todos los flujos eléctricos que salen de la red con fines de consumo.

Las energías se contabilizarán adecuadamente con mediciones sin procesar o con energías facturadas, incluidas las estimaciones de energía (valores faltantes, flujos no medidos)

PÉRDIDAS Globales = Siguiendo esta definición, las pérdidas pueden constituir un balance de energía específico en el proceso de liquidación, con todas las energías no atribuidas a ningún actor.

Es importante a la hora de efectuar las mediciones ecualizar período de cálculo y área de red para el cálculo. En esto se podrá ver cómo mejora las condiciones de medición la incorporación de los medidores inteligentes (etapa 2 de despliegue de las REI).

En los medidores convencionales, la energía considerada en el balance energético no es una medida exacta, sino que se interpola o, en cualquier caso, se elabora. El primer beneficio de los medidores inteligentes es una mejora de la precisión y frecuencia de medición, especialmente con un sincronismo de todas las energías en un período de medición exacto. Además, los medidores inteligentes también permiten una reducción de costos del proceso operativo de medición.

Es posible elaborar métodos de medición específicos y prácticos para los 3 niveles:

- Estimación de pérdidas globales (Nivel 1): mediante el balance energético
- Distribución de pérdidas técnicas / no técnicas (Nivel 2): mediante el modelo de pérdidas técnicas (TL)
- Pérdidas detalladas por origen (Nivel 3): mediante KPIs y analytics

Estos diferentes métodos de medición demuestran ser compatibles e incluso complementarios, con la posibilidad de combinarlos. Esto permite un enfoque más preciso en las pérdidas, proporcionando cierta información sobre los principales factores de pérdidas. Esto puede ayudar a encontrar la mejor manera de controlarlos.

Los medidores inteligentes tienen un impacto importante en la medición de pérdidas para los 3 niveles de pérdidas definidos:

- Facilitando y mejorando la medición de energía, tanto para clientes finales / productores como para equipos de red, incluyendo una mayor precisión de consumo.

- Ayudando en la limitación de las incertidumbres y anomalías de la red y del proceso.

A través de enfoques rigurosos, los métodos de medición pueden considerarse como una base importante de un enfoque global de redes inteligentes.

Ahora bien, a continuación se detallará un enfoque en la identificación, medición y mitigación de las pérdidas con foco en el nivel 2, es decir en las pérdidas técnicas y no técnicas, con un mayor grado de detalle a las pérdidas no técnicas.

### **Pérdidas técnicas**

Las pérdidas técnicas en los sistemas de energía ocurren naturalmente, ya que consisten en la disipación de energía en los componentes del sistema eléctrico, como líneas, transformadores, conexiones, sistemas de medición y otros equipos que transportan energía hacia y desde los clientes. Las pérdidas técnicas también se denominan "Pérdidas físicas", ya que se refieren a la energía transformada en calor y ruido al distribuir electricidad y, por lo tanto, a la pérdida física. Esta disipación de energía cuesta dinero a los clientes y contribuye a las emisiones de carbono.

Las pérdidas técnicas se producen como resultado directo de las características físicas de los equipos eléctricos utilizados en las redes de distribución. Dependen del diseño de la red eléctrica, los niveles de voltaje y transformación y la longitud de las líneas eléctricas.

Las pérdidas técnicas se relacionan con la inversión en equipos (líneas, transformadores) y señales a largo plazo (compromiso entre los costos de inversión y los gastos operativos). También se relacionan con la planificación eficiente y el diseño de redes de distribución.

Las pérdidas técnicas se pueden dividir aún más, en:

#### *Pérdidas Variables (relacionadas con la carga)*

Todos los conductores, ya sean bobinas en transformadores, alambres de aluminio o cobre en líneas aéreas o cables, fusibles o equipos de medición, tienen una resistencia eléctrica interna que hace que se calienten cuando transportan corriente eléctrica.

Dado que las pérdidas de energía derivadas de la disipación de calor al medio ambiente varían con la corriente que fluye a través de los conductores en las redes eléctricas, estas pérdidas se denominan "pérdidas variables". Estas pérdidas también suelen denominarse "pérdidas óhmicas".

Como resultado de las pérdidas variables que cambian a medida que los flujos de energía aumentan y disminuyen (proporcionalmente al cuadrado de la corriente), las redes de transmisión experimentan un menor nivel de pérdidas porque a voltajes más altos se requiere una corriente más baja para transmitir la misma cantidad de energía eléctrica.

Por el contrario, las redes de distribución (a voltajes más bajos) están sujetas a un mayor nivel de pérdidas. Factores adicionales como el efecto del desequilibrio de la red, el factor de potencia y la calidad de la potencia también pueden tener un impacto en las pérdidas variables, ya que influyen en el valor de las corrientes que fluyen a través de los conductores.

Además, las pérdidas variables también dependen de la longitud y la sección transversal del conductor, ya que varían en proporción a la resistencia. La resistencia de un conductor disminuye a medida que aumenta su área de sección transversal. Por lo tanto, el efecto de las pérdidas se reduce con cables de mayor tamaño. Un principio similar también se aplica a las pérdidas variables en los transformadores, donde el área de la sección transversal de los devanados y los materiales utilizados en ellos influyen en las pérdidas variables.

Las conexiones inadecuadas entre el equipo de red y los conductores deteriorados también pueden ser una fuente de este tipo de pérdidas, ya que pueden causar la aparición de puntos calientes debido a un aumento en la resistencia equivalente.

En general, las pérdidas variables contribuyen aproximadamente entre dos tercios y tres cuartos de las pérdidas técnicas del sistema eléctrico total. En esencia, las medidas para reducir las pérdidas variables pueden clasificarse en dos factores de influencia principales (flujos de energía y resistencia) y cómo se aplican en el sistema global: su objetivo es reducir los flujos de energía del sistema o disminuir la resistencia de las rutas de transporte. Una reducción en los niveles de utilización de los activos de la red puede contribuir a disminuir tanto la corriente como la resistencia. Sin embargo, aumentar la capacidad de la red conduce a mayores inversiones de capital. Esto lleva a una compensación directa entre el costo de las pérdidas y el gasto de capital. Se ha sugerido que la tasa de utilización promedio óptima en una red de distribución que considera el costo de las pérdidas en su diseño podría ser tan baja como 30%.

*Pérdidas fijas*

Parte de la energía eléctrica es disipada por los componentes y equipos de la red, como los transformadores o los conductores, como resultado de estar conectados a la red y "en vivo" (energizados). Incluso si no se entrega energía a los clientes, el sistema tiene pérdidas solo porque está energizado eléctricamente. Estas pérdidas toman la forma de calor y ruido y se denominan "pérdidas fijas" o "pérdidas sin carga", porque son independientes de la cantidad de energía eléctrica que suministra la red.

La energización de los transformadores es responsable de la mayoría de las pérdidas fijas. Estas pérdidas ocurren en el núcleo de los transformadores y se denominan "pérdidas de núcleo" o "pérdidas de hierro". Se sabe que existen dos tipos de pérdidas centrales:

- Las "pérdidas por histéresis" son pérdidas derivadas de la inversión de la polaridad magnética del acero en los núcleos de los transformadores en cada ciclo de CA. Esto hace que el material pulse (que emite un zumbido) y se caliente.
- Las "pérdidas por corrientes parásitas" son pérdidas derivadas de la circulación de corrientes inducidas en partes conductoras que no son devanados de cobre, como el cuerpo de hierro o el núcleo de acero del transformador.

Además de la ineficiencia del transformador, otra fuente de pérdidas fijas es el aislamiento eléctrico en los equipos de red. Las imperfecciones en el aislamiento eléctrico conducen al flujo de corrientes infinitesimales a través de ellos en transformadores, líneas, cables y otros equipos de red. Este tipo de pérdidas fijas se denominan "pérdidas dieléctricas" o "pérdidas de corriente de fuga".

Las pérdidas de corona, un caso particular de este tipo de pérdidas, ocurren en alto voltaje y principalmente en líneas de alto voltaje adicional. Varían con el nivel de voltaje, el diámetro físico del cable y con las condiciones climáticas como la lluvia y la niebla. Las pérdidas de corona pueden generar ruido audible y de radiofrecuencia y, a menudo, se ve como un resplandor en el aire adyacente a los conductores. En general, contribuyen a un porcentaje muy pequeño de las pérdidas fijas globales.

Si bien las pérdidas fijas no cambian con la corriente, dependen del voltaje aplicado. Sin embargo, como el voltaje aplicado es relativamente estable mientras el equipo de red está energizado, son esencialmente fijos. Por lo tanto, las pérdidas fijas son una función de la propia red y dependen principalmente de la cantidad de componentes energizados. A este respecto, las medidas para reducir las pérdidas fijas apuntan principalmente a reducir el

número de componentes energizados o aumentar su eficiencia. En general, las pérdidas fijas contribuyen aproximadamente entre un cuarto y un tercio de las pérdidas técnicas totales en las redes de distribución.

### *Servicios de red*

Además del equipo responsable de la disipación de energía como pérdidas fijas y variables, otros equipos conectados a la red pueden consumir energía. En esta sección, solo se incluyen los consumos a los que no es posible establecer un contrato. El control de red y los elementos de medición instalados a lo largo de líneas o medidores eléctricos en las instalaciones del cliente, ya sean mecánicos o electrónicos, son ejemplos de consumos no contratados.

La separación de este tipo de consumo de red de las pérdidas técnicas relacionadas con la disipación de energía permite excluirlos de algunos puntos de referencia internacionales en relación con la parte de pérdidas fijas y variables. De hecho, el consumo de pérdidas debido al equipo de red tiene un componente fijo (por ejemplo, para uso permanente) y un componente variable (por ejemplo, dependiendo de los dispositivos de comunicación de acuerdo con la frecuencia y los volúmenes de datos).

Siempre que un contrato sea posible y efectivo en equipos de red (por ejemplo, servicios auxiliares, capacidades de almacenamiento futuras), su consumo se excluye de las pérdidas y se considera como consumo normal. La consideración de si existe o no un contrato detrás de este consumo se justifica con el contexto regulatorio y la fuente de datos frecuentemente utilizados para el cálculo de pérdidas (sistema de facturación).

### ***Evaluación de las TL***

Repasando, las pérdidas totales en cualquier red consisten en pérdidas técnicas (TL) y pérdidas no técnicas (NTL) y se definen como la diferencia entre la energía de entrada general a la red y el consumo de energía general en la red.

No es posible una medición separada de TL en redes, especialmente en redes de bajo voltaje (LV), donde NTL tiende a ser especialmente alto.

El cálculo o estimación de TL utilizando información detallada de la red bajo consideración es posible. La información disponible para varias redes depende de los niveles de voltaje

(con más información generalmente disponible para redes de mayor voltaje) y del país (más información general está disponible en países desarrollados).


Hay varias razones por las que uno puede querer reducir el TL. Reducir costos, por marco político o regulatorio son algunos casos.

Por ejemplo, la Directiva de eficiencia energética de la UE de 2012 que estableció un conjunto de medidas vinculantes con respecto a la eficiencia energética. Los requisitos descritos en la directiva incluyen, entre otros, un aumento del 20% en la eficiencia energética para 2020 en toda la cadena de valor. Más recientemente, el “Paquete de energía de invierno” de 2016, propuesto por primera vez por la UE el 30 de noviembre de 2016, incluye un objetivo más estricto del 30%, junto con medidas para garantizar que se cumpla el nuevo objetivo.

### ***Dimensionamiento de las TL***

Separar las contribuciones de pérdidas técnicas y no técnicas es difícil. Por lo tanto, las comparaciones de pérdidas en el mundo generalmente se basan en pérdidas totales (y no directamente en TL, que siempre son más bajas).

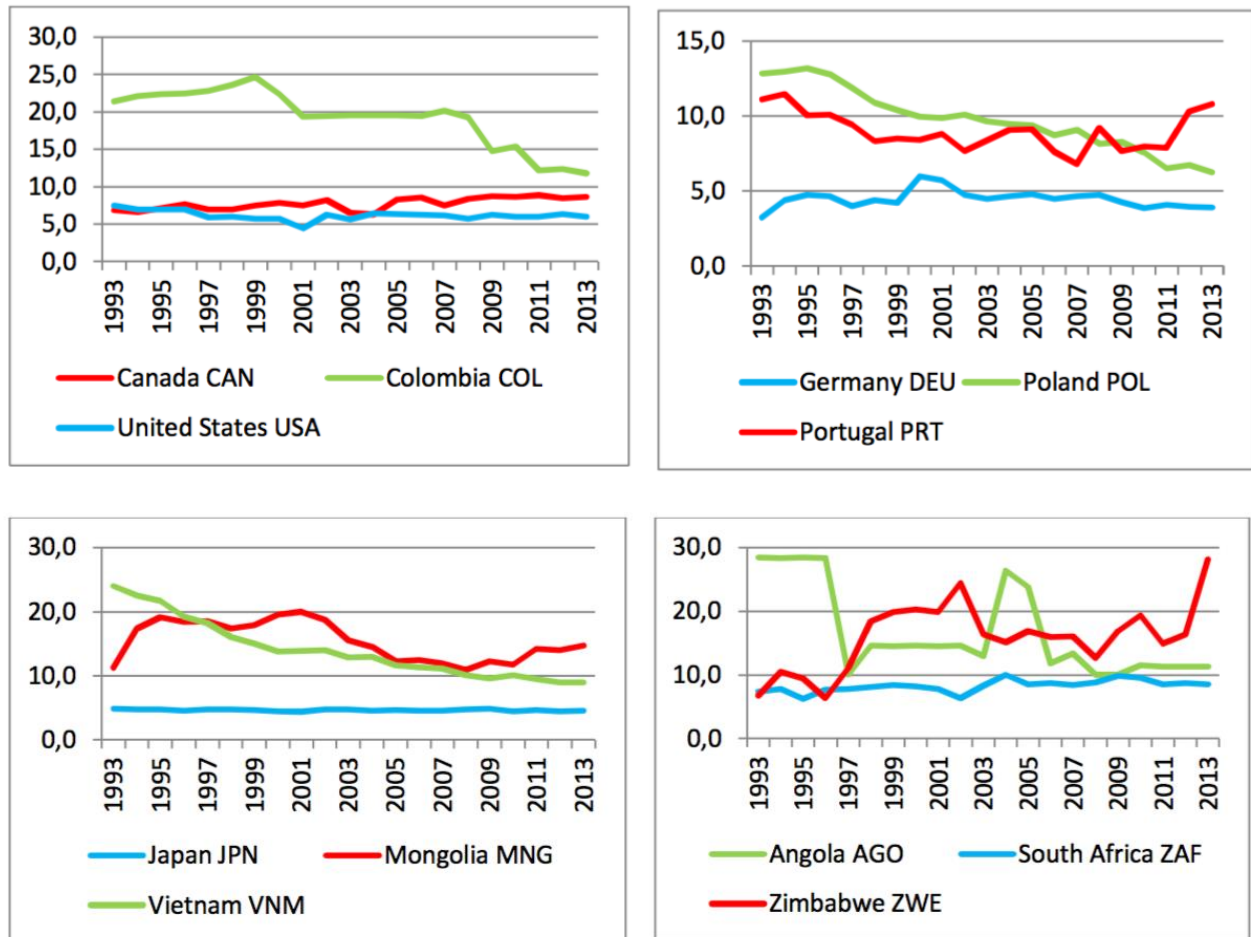
**Gráfico 36:** Evolución de pérdidas en el mundo 1993-2003. Por el Banco Mundial (2003)



El promedio mundial es ligeramente superior al 8% del consumo total de energía eléctrica en 2013. Aunque se observa que la tendencia de pérdidas tiende a disminuir en todo el mundo en general.

Las tendencias en las pérdidas en los países desarrollados, donde las pérdidas son generalmente bajas, se muestran más o menos estables durante el período dado. Las mayores disminuciones, y a veces los mayores aumentos, se observan en países en desarrollo, como Colombia y Zimbabwe, respectivamente.

**Gráfico 37:** Evolución del nivel de pérdidas en los sistemas de transmisión y distribución en operadores de todo el mundo. Por el Banco Mundial (2003)



### **Mitigación de las TL**

Las TL se puede mitigar de varias maneras. Las pérdidas fijas, como las pérdidas en el núcleo de los transformadores, se pueden reducir, por ejemplo, utilizando transformadores más eficientes. Sin embargo, no pueden ser erradicados.

Las pérdidas variables contribuyen más que las pérdidas fijas a la cantidad total del sistema de potencia TL. Esto también significa que la mayoría de los esfuerzos en la reducción de TL se concentran en la reducción de pérdidas variables.

Hay varias medidas posibles para abordar las TL. El reemplazo de componentes, control de alimentación, la gestión de Red, son algunas de las técnicas comúnmente utilizadas.

El enfoque de red inteligente ayuda a localizar las disfunciones de la red y, por lo tanto, contribuye a mejorar la optimización de los componentes. Y ofrece principalmente nuevas posibilidades para la gestión de la red y el control de alimentación.

Desde el punto de vista técnico-económico es importante comparar los costos y los beneficios de la medida a largo plazo.

De hecho, la decisión de inversión tendrá que tener en cuenta todos los impactos técnico-económicos, como los costos de inversión (inversión inicial y reemplazo final), pero también los gastos operativos, incluidas las pérdidas técnicas, y la evaluación de la calidad de la red durante toda la vida útil del equipo. .

En los países en desarrollo, el objetivo es lograr la construcción o el refuerzo de la red (por ejemplo, sobre el hito de la electrificación del 90%) con un costo global optimizado donde el costo de pérdida es insignificante frente al costo de no calidad

En los países desarrollados, se supone que la red es más eficiente o de "buena calidad", y se verá cómo se puede "actualizar" la red. Las pérdidas se convierten en un problema que, sin embargo, sigue siendo secundario en comparación con los criterios relacionados con la calidad del servicio u obligaciones como la integración de las energías renovables.

En todas las situaciones, es crucial evaluar el rendimiento de la red (red de bajo voltaje): esta información contribuirá a la gestión de la red y la implementación futura de redes inteligentes.

Si bien las pérdidas técnicas juegan un papel importante a la hora de evaluar la implementación de redes inteligentes, no son el tipo de pérdidas a atacar mediante técnicas de Machine Learning, ya que típicamente responden a técnicas asociadas a los componentes y a la gestión remota.

A continuación se podrá ver en detalle el impacto de las NTL, donde si es posible encontrar enfoques interesantes de estrategia de mitigación sobre todo mediante el uso de herramientas de Machine Learning.

### **Pérdidas no técnicas**

Además de las pérdidas técnicas, no toda la energía entregada a través de la red de distribución y consumida por los usuarios finales puede medirse o contabilizarse



adecuadamente. Estas pérdidas adicionales también se presentan como "energía perdida". Esta proporción no contabilizada de las pérdidas se conoce como pérdidas no técnicas. Estas pérdidas también se conocen como "pérdidas negras" o "pérdidas comerciales", ya que son socializadas y no son cargadas directamente por proveedores o compañías de distribución.

Las pérdidas no técnicas se relacionan principalmente con flujos de energía no identificados, mal asignados e inexactos. En esencia, representan la cantidad de energía que se entrega pero que no se tiene en cuenta. Es importante separar las pérdidas no técnicas de dos casos: energía contabilizada pero no facturada, o energía facturada pero que no se pagan las facturas. En ambos casos, se conoce la entidad que consume la energía. Sin embargo, en el caso de pérdidas no técnicas, el usuario final es desconocido, o la cantidad de energía que se consume es incierta.

Las pérdidas no técnicas son causadas por acciones externas al sistema de energía. Se refieren a la energía perdida que no está directamente relacionada con el transporte de electricidad y se produce independientemente de las características técnicas físicas de la red (pérdidas técnicas).

Las pérdidas no técnicas también se pueden ver como una carga no detectada de clientes que las empresas de servicios públicos no conocen. Cuando se conecta una carga no identificada al sistema, las pérdidas reales aumentan mientras que las pérdidas esperadas por las compañías de distribución seguirán siendo las mismas. El aumento de las pérdidas se reflejará en las cuentas la compañía y los costos se transferirán a los clientes como cargos de distribución.

Hay una amplia gama de situaciones que crean pérdidas no técnicas. En todos los casos, el culpable es un bajo nivel de gestión de la utilidad que opera la red. Las pérdidas no técnicas generalmente están relacionadas con el proceso de gestión de clientes y se pueden dividir en las siguientes categorías:

#### *Problemas de equipos de red*

La amplia variedad de factores relacionados con los problemas del equipo de red que contribuyen a las pérdidas no técnicas se pueden clasificar de acuerdo con las siguientes causas principales:


- *Robo y fraude*

Hay varias formas en que la electricidad puede extraerse de la red ilegalmente. Se estima que el robo y el fraude representan la mayoría de las pérdidas no técnicas en los sistemas de energía. Son desafíos importantes para la industria eléctrica y requieren un esfuerzo concertado de una variedad de partes interesadas poder mitigarlas. Además del robo y el fraude, hay aspectos de seguridad serios a considerar. Es difícil medir el alcance exacto de este tipo de pérdidas, ya que es probable que una gran proporción no se detecte.

El robo se define como cualquier extracción ilegal de electricidad para uso que no sea habilitado donde cualquier punto de medición o sistema de medición esté registrado por un proveedor. Puede ocurrir donde se realiza una conexión no autorizada a la red o donde se produce una reconexión ilegal (por ejemplo, después de una desconexión formal). A veces también puede ocurrir donde el proceso de conexión es incompleto.

El fraude es la extracción ilegal de electricidad dentro de los límites de la propiedad de un cliente. Todos los clientes medidos compran electricidad a un proveedor y están asociados a un punto de medidor registrado. El fraude ocurre como resultado de una manipulación ilegal e intencionada del medidor, al manipular o evitar el medidor. En ambos casos, el objetivo es hacer que el medidor registre una cantidad menor de energía de la que realmente se consume.

**Gráfico 38:** Imágenes de conexiones fraudulentas a la red eléctrica. Por el Grupo de Trabajo en Reducción de Pérdidas de EnEI (2015)



**Fuente:** Enel Foundation

Acciones como las que se observan pueden tener serias implicaciones de seguridad. Por ejemplo, para evitar un medidor del tipo que se muestra a la izquierda de la figura, se omite todo el medidor, que incluye el dispositivo de corriente residual (RCD), dejando la instalación desprotegida. Las conexiones ilegales a la red también tienen una protección inadecuada.

Los flujos de energía adicionales debido a conexiones ilegales también pueden provocar que el equipo de la red se sobreestime, lo que puede provocar un sobrecalentamiento o incluso la explosión de este equipo, lo que puede causar lesiones a las personas.

- *Errores de medición*

Las pérdidas no técnicas debidas a errores de medición se definen como la diferencia entre la cantidad de energía realmente entregada a través del medidor y la cantidad registrada por el medidor o leída de él. Pueden ocurrir por errores en la lectura manual o automática del medidor, equipo de medición defectuoso, etc.

*Problemas de información de red*

Las situaciones surgen donde la energía se entrega y consume, pero no se registra con precisión debido a imprecisiones en la base de datos de la red de distribución, lo que se

convierte en energía perdida. Las razones típicas de datos de consumo inexactos o faltantes debido a este tipo de pérdidas no técnicas incluyen puntos de conexión faltantes o no registrados, ubicación incorrecta o estado de activación de los puntos de conexión, información incorrecta del equipo de medición.

#### *Problemas de procesamiento de datos energéticos*

Pueden producirse imprecisiones al procesar datos de energía para la evaluación de pérdidas, a menudo relacionadas con errores en la estimación de la energía consumida o producida. Estos errores que surgen en los cálculos contribuyen a pérdidas no técnicas y pueden ocurrir debido a estimación de consumos no medidos, estimación de consumos entre lecturas de medidor y cálculos, estimación de pérdidas técnicas, estimación de problemas detectados, etc.

#### *Otros problemas de procesamiento de datos energéticos*

Otros problemas de procesamiento de datos de energía pueden dar lugar a errores de cálculo y errores de mantenimiento de registros, lo que contribuye al aumento de las pérdidas no técnicas.

Como estos errores de cálculo y errores resultan del proceso de estimación de pérdidas y no de los consumos iniciales en la red, este tipo de pérdidas no técnicas a menudo se denominan pérdidas "internas" o "administrativas" por diferencia con los otros tipos de pérdidas no técnicas llamadas pérdidas "externas" o "clientes".

#### ***Evaluación de las NTL***

Las pérdidas no técnicas se calculan como la diferencia entre las pérdidas globales (cálculo de la definición del nivel 1) y pérdidas técnicas.

Es por ello que las NTL estimadas pueden incluir algunas incertidumbres derivadas de la evaluación de pérdidas técnicas.

El nivel de pérdidas puede variar incluso dentro del mismo país, dependiendo de la región. Separar las pérdidas técnicas (TL) y NTL no siempre es una tarea fácil, de ahí el hecho de que TL y NTL a menudo se combinan, en algunos casos las pérdidas de transmisión y distribución también se combinan.

**Gráfico 39:** Estimación de NTL en el mundo. Por el European Regulator Group (2015)

Europe	<ul style="list-style-type: none"> <li>• Total distribution losses range from 2.3% (Sweden) to 11.8% (Poland), with Romania (13.5%) and Turkey (19% due to theft alone) being outliers.</li> <li>• An example of an extreme outlier is a village in Romania which had total losses of 84%; these were subsequently reduced to 26.1% (9.7% of which were TL).</li> </ul>
Asia	<ul style="list-style-type: none"> <li>• India: total losses vary significantly between utilities and between estimates – 11% to 58%.</li> <li>• Pakistan: &gt; 30% total losses.</li> <li>• Bangladesh: &gt; 20% total losses.</li> <li>• Indonesia: 7% losses due to theft.</li> <li>• Malaysian peninsular: estimates vary from 11-15% (NTL only or total T&amp;D losses).</li> <li>• Thailand's public system has total T&amp;D losses of about 11%.</li> </ul>
North & Central America	<ul style="list-style-type: none"> <li>• While the presence of NTL, particularly energy theft, is well known in Mexico, the actual percentage loss has not been published. The annual cost is estimated to be \$475 million.</li> <li>• The USA also has NTL and again the percentage is not known, but annual costs likely run into the billions of \$.</li> </ul>
South America	<ul style="list-style-type: none"> <li>• Brazil: an estimated value of 7.3% - 25% of the energy supplied to the distribution systems is lost to NTL.</li> <li>• Chile: one utility reduced its total losses to 5% from 22%.</li> </ul>
Middle East & Africa	<ul style="list-style-type: none"> <li>• Sub-Sahara: only 50% of electricity usage is paid for; Botswana is the best performing (10%).</li> <li>• As much as 7% of energy produced in South Africa is through to be lost to theft alone.</li> <li>• Over 50% of the business customers of one South Africa utility were found to have bypassed their meters.</li> <li>• Senegal: 21% total losses.</li> <li>• Uganda loses about \$30 million per year to electricity theft.</li> <li>• Jordan: total distribution losses are in the 12-14% range.</li> </ul>

### ***Mitigación de las NTL***

La mitigación de NTL resulta de una combinación de varias acciones complementarias. Las medidas exactas empleadas deben decidirse de acuerdo con el nivel de pérdidas experimentadas por el distribuidor y de acuerdo con sus circunstancias.

Las condiciones socioeconómicas son claves para decidir qué medidas de mitigación de NTL emplear:

- En las áreas tradicionales donde las típicas metodologías (inspecciones, normalizaciones y el cómo) son suficientes para controlar efectivamente el nivel de fraude y robo. Las medidas de mitigación incluyen inspecciones más productivas al mejorar la focalización de campañas, el equilibrio energético, la minería de datos y otros equipos y medidas relacionadas con el proceso.

- En áreas complejas donde se necesita el apoyo de la policía para llevar a cabo medidas tradicionales de mitigación de fraude y robo. Por lo general, estas son áreas en las que la metodología tradicional aplicada para la mitigación de NTL tiene una corta vida efectiva, debido a la reincidencia inmediata de robo y fraude. En estas áreas, se necesitan instalaciones más robustas para evitar fraudes y robos.
- Las medidas de mitigación incluyen soluciones técnicas antirrobo, como medidores prepagos y lectura remota de medidores, cajas de medidores blindados, tubos blindados para conexiones (hasta la parte superior del poste), conexiones coaxiales o incluso cables blindados, medición dividida en la parte superior del poste y alarmas remotas para cajas de medidores.
- En áreas de riesgo que generalmente están delimitadas estrictamente (por ejemplo, barrios marginales) en las que el contexto social dificulta o incluso impide el acceso a las instalaciones para inspeccionar o resolver cualquier tipo de anomalía. En estas áreas, ni las soluciones tradicionales ni las más robustas son efectivas, y las pérdidas pueden crecer sin control.

Cabe destacar el impacto de la regulación en el desarrollo de redes inteligentes. Por ejemplo, en el Reino Unido, la compañía de distribución no tiene acceso a los medidores del cliente (solo el minorista tiene acceso), y el minorista no necesariamente tiene acceso a la medición en las subestaciones secundarias (medidores de verificación / observación / supervisión) como están distribución de equipos de empresas. En tales casos, la regulación hace que sea difícil o imposible para las empresas de servicios públicos para utilizar mejor la información generada por las redes inteligentes, ya que se divide entre dos empresas diferentes.

En los países en desarrollo, las presiones sociales, como la resistencia de la comunidad a medidas como la implementación de medidores inteligentes o divididos, pueden dificultar la reducción de NTL. En esencia, la tecnología no se puede utilizar para resolver problemas sociales, por lo que el problema del robo de electricidad y el fraude se convierte en un problema social, en lugar de un problema de la compañía de distribución (a pesar de que la compañía tiene que lidiar con la pérdida de ingresos y, por lo tanto, es muy difícil situación difícil).

Los hallazgos clave sobre NTL y su mitigación pueden resumirse en el uso de tecnologías inteligentes en esta aplicación es que, en principio, son muy buenas para abordar NTL. Sin

embargo, para que tengan éxito, los procesos comerciales y la financiación deben estar establecidos dentro de la compañía de distribución y adaptarse correctamente a apoyar adecuadamente esto, y las condiciones reglamentarias y socioeconómicas generales del país deben poder para apoyar las tecnologías inteligentes y su uso no alivia la necesidad de buscar también medidas no técnicas (tradicionales) como el fomento de buenas relaciones con los clientes, compromisos regulares con la comunidad, aplicación de la ley y similares.

Actualmente y con muchas fuerza, es sobre el campo de la IA, específicamente en el subcampo del aprendizaje automático, donde se apalancarán todas estas acciones de mitigación mediante el uso de algunos de sus algoritmos aplicados.

### ***Aprendizaje automático para la detección de las NTL***

El aprendizaje automático también ha permitido grandes avances en el área de la ingeniería eléctrica. En los últimos años se han estado desarrollando diferentes algoritmos para la detección del robo de electricidad con el propósito de reducir las pérdidas no técnicas y a la vez, incrementar los beneficios de las compañías.

Un caso de aplicación es mediante el uso de redes neuronales artificiales. Las redes neuronales artificiales son muy empleadas para modelar datos no lineales. Por tal motivo han sido empleadas en el desarrollo de diferentes modelos para la detección del fraude eléctrico, para clasificar un conjunto de clientes en consumidores de comportamiento normal versus consumidores con irregular consumo (Muniz, 2009).

El objetivo es mejorar la precisión de las predicciones en la detección del robo. Para esto se propone una metodología modular para el diseño de un modelo basado en aprendizaje automático.

Un primer módulo de pre procesamiento y normalización de los datos, que corresponde a una de las fases del proceso KDD (descubrimiento de Conocimiento en Bases de Datos o KDD) y se refiere al proceso de identificar patrones válidos, novedosos, potencialmente útiles y principalmente entendibles). Luego un módulo de filtrado de los datos y otro módulo de clasificación, empleados para aumentar la robustez de la salida o resultado del modelo.

Los datos utilizados para el caso de estudio fueron recopilados de una compañía de distribución brasileña. El conjunto de datos consistió en aproximadamente de 3.700

clientes seleccionados de manera aleatoria con irregularidades y aproximadamente 7.500 clientes con comportamiento de consumo normal. Del 100% de los datos se consideró un 75% de las muestras para la fase de entrenamiento y el restante 25% para las fases de validación y prueba.

Los datos se dividieron en 10 subconjuntos disjuntos de tamaño similar para evitar sobreajuste en los datos de entrenamiento y una incorrecta generalización del resultado. Los resultados mostraron que el modelo que obtuvo la menor precisión fue el que aplicó los dos primeros módulos de normalización y filtrado, logrando una precisión del 49%, mientras que el modelo que luego incorporó el módulo de clasificación consiguió una precisión del 62%. El modelo empleado por la compañía tenía una precisión del 32%.

En un segundo estudio (Costa, 2013), se tomó una base de datos de aproximadamente 22.000 clientes y se consideraron 14 características o parámetros de cada clientes, como ser histórico de inspecciones, geo localización, consumo promedio, indicador de fraude, entre otros. Se aplicó un enfoque similar al descrito anteriormente aplicando los 3 módulos y se obtuvo un 65% de precisión en el modelo predictivo. La compañía bajo su modelo tenía precisión del orden del 40%.

Si se comparan los resultados de ambos estudios se puede ver una leve diferencia. Esto puede ser debido a los tamaños del conjunto de datos de entrenamiento y también a los atributos o características de entrada seleccionada, ya que algunas características describen mejor el problema o están más relacionadas con la salida, de manera que mejoran el aprendizaje del algoritmo y aumenta su efectividad.

Otro estudio (Nizar, 2008), utilizó una base de datos con los perfiles de carga de aproximadamente 1.500 clientes comerciales, para un período de un año, de una compañía eléctrica de Malasia.

Se agruparon los datos de acuerdo al comportamiento de consumo por día tipo de la semana con el fin de seleccionar los perfiles más representativos, como medio de referencia para la clasificación.

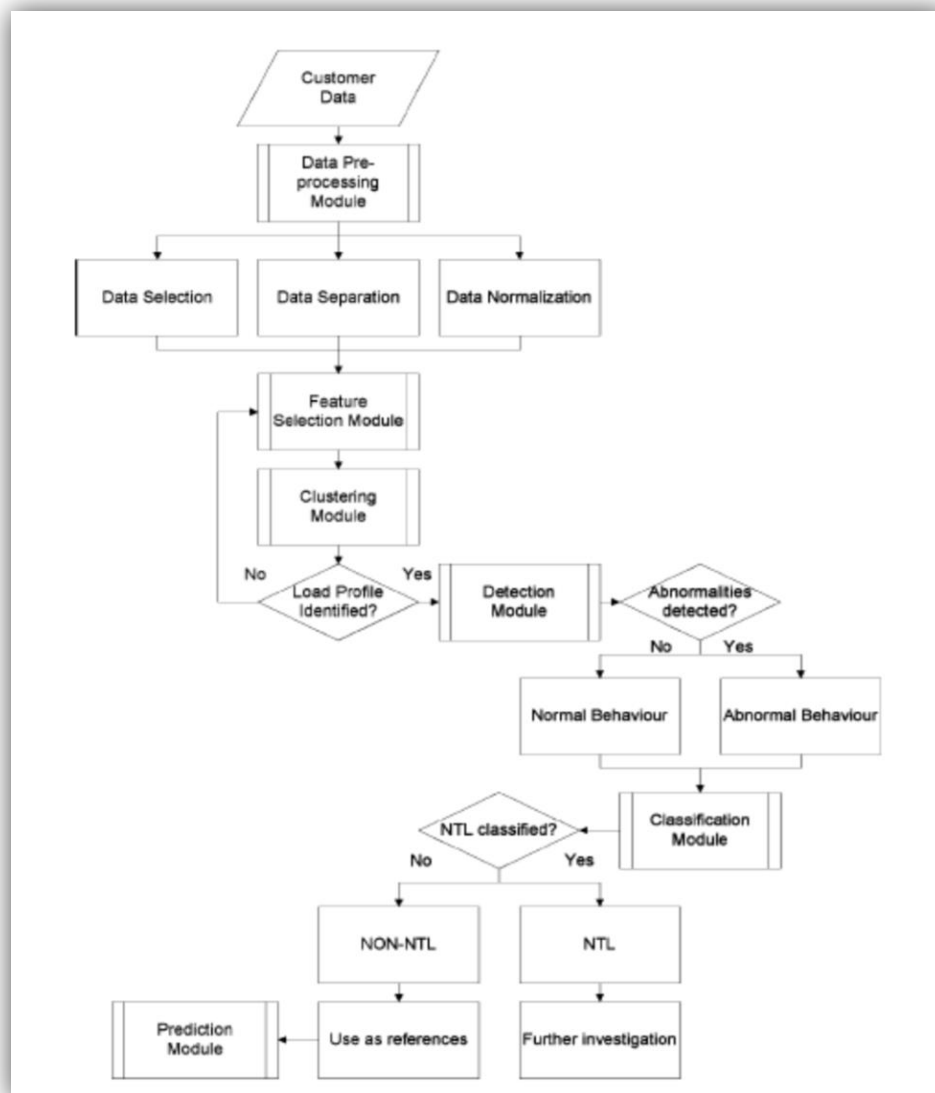
La técnica de agrupamiento empleada fue C-means, que es un método de agrupamiento que permite que un dato pueda pertenecer a más de un grupo con cierto grado de pertenencia. Este algoritmo se basa en la optimización de una función objetivo e intenta



encontrar una buena partición mediante la búsqueda de los prototipos y las funciones de pertenencia que minimizan la función objetivo.

En el estudio realizado por Nizar fue interesante el modelo para extraer los patrones de consumo mediante un flujo de decisión que permitió entender cuáles patrones tenían mayor sentido de correlación.

**Gráfico 40:** diagrama en flujo para extraer patrones de consumo que presentan una alta correlación con las actividades de fraude. Por Nizar (2008)



En el modelo empleado se evaluaron dos funciones de activación diferentes, la sigmoide y la función gaussiana (RBF). Es importante recordar que la función de activación distorsiona el valor de salida añadiéndole deformaciones no lineales, de modo tal de no obtener como

resultado una recta no representativa. La función que mejor desempeño tuvo fue la sigmoide con una precisión del 54%.

En otro estudio (H. Song, 2016) se utilizó un tipo de red neuronal cuyo objetivo era el de predecir el consumo de electricidad a partir de la exploración de los registros históricos de consumo y el análisis de factores potenciales relacionados con el uso de la electricidad. Para el estudio se utilizaron datos históricos de consumo por un año recolectados de medidores inteligentes de una compañía de Australia. La métrica de evaluación empleada para validar la calidad del modelo fue la raíz media cuadrática (RMSE), por tratarse de una tarea de regresión. La media cuadrática es muy útil para calcular la media de variables que toman valores negativos y positivos. Se suele utilizar cuando el símbolo de la variable no es importante y lo que interesa es el valor absoluto del elemento. Por ejemplo, para calcular la media de errores de medida. El error de predicción arrojado fue de 0.0492.

En un último estudio (Verdu. 2004) se utilizó un modelo de red no supervisado competitivo denominado mapa auto-organizado de Kohonen (SOM). Por ser un modelo no supervisado no se observan indicios de si la red neuronal se encuentra operando correcta o incorrectamente, ya que no dispone de ninguna salida objetivo hacia la cual la red neuronal pueda tender.

La red auto-organizada debe descubrir rasgos comunes, regularidades, correlaciones o categorías en los datos de entrada, e incorporarlos a su estructura interna de conexiones. Se dice, por tanto, que las neuronas deben auto-organizarse en función de los estímulos (datos) procedentes del exterior.

En el aprendizaje competitivo las neuronas compiten unas con otras con el objetivo de llevar a cabo una tarea determinada. La idea es que cuando se presente a la red una serie de datos de entrada, sólo una de las neuronas de salida (o un grupo de vecinas) se active. Por tanto, las neuronas compiten por activarse.

En dicho estudio se utilizó SOM para agrupar los clientes de perfiles de carga similares a partir de datos históricos de consumo. El propósito del enfoque es detectar clientes fraudulentos a través del comportamiento detectado en sus perfiles semanales de carga durante en un intervalo de un año. La curva de carga se construye con los datos registrados de los medidores inteligentes.

### ***Desafíos para mejorar los modelos en la detección de las NTL***

Hay dos cuestiones relevantes a la hora de evaluar el desempeño de un modelo de detección de pérdidas no técnicas. Por un lado el modelo de aprendizaje automático seleccionado. Por otro lado, es importante considerar algunas cuestiones propias del proceso de construcción de conocimiento como ser la selección óptima de características, el desequilibrio de las clases, los errores en los datos, los errores en las etiquetas de las clases, etc.

### ***Selección óptima de características***

La selección de características es de las primeras etapas y más importante del proceso KDD. Es un proceso determinante en el aprendizaje de los algoritmos supervisados, y tiene un impacto significativo en el rendimiento y la precisión de un clasificador para la detección de NTL.

En los estudios repasados se encontró, mediante herramientas estadísticas de análisis de correlación, que existen variables con grado de correlación alto, de ciertas características con la variable de interés y que la elección óptima de las mismas no solo facilita el aprendizaje del modelo, sino que también aumenta significativamente su desempeño y precisión, justamente en la detección del fraude.

Aplicando técnicas estadísticas se seleccionan varios grupos de características desde la base de datos, luego se analizan y se combinan bajo ciertos criterios cruzando similitud, geo localización, infraestructura desplegada, etc. y luego se evalúa su impacto en el desempeño del modelo.

De este análisis de correlación por ejemplo se pudo ver que en los clientes fraudulentos, las variables que más fuerte se correlacionan son el perfil de consumo y zona geográfica. Los clientes que cometen fraude presentan comportamientos similares, del mismo modo que existen zonas geográficas propensas a que suceda el fraude, y también perfiles de consumo que reflejan esa correlación. Y en parte tiene sentido, las zonas marginales o de escasos recursos presentan una predisposición clara al robo de energía.

### ***Desequilibrio de las clases***

El desequilibrio de las clases describe la cantidad desigual de etiquetas de clases que contiene un conjunto de ejemplos respecto a otro. Es un problema que surge por la

asimetría entre las clases de acuerdo a su importancia, típicamente cuando los datos asociados a la clase relevante son relativamente pequeños en relación con otras clases quizá menos relevantes. Es un problema frecuente en el aprendizaje automático.

En general, en las bases de datos de las compañías de distribución, el porcentaje de clientes que cometen fraude suele ser menor que la de los clientes que no cometen, lo que refleja esta desigualdad entre las clases que puede afectar de manera relevante el comportamiento del modelo.

Esto puede dificultar el aprendizaje de cualquier modelo debido a que aprende de una clase mayoritaria (clientes honestos), sobre la que no sería lógico hacer funcionar el modelo. No se quiere detectar clientes honestos, sino detectar clientes fraudulentos.

Es así como, un desequilibrio de clases no corregido, disminuye su performance y puede generar falsos positivos que se traducen en visitas o inspecciones técnicas a clientes que nos presentan ningún tipo de comportamiento negativo, incurriendo en costos innecesarios.

Existen algunos métodos para corregir este inconveniente, como ser el método de muestreo o estratificación, el método de ajuste de los costos o pesos, entre otros.

### ***Errores en los datos y en las etiquetas de las clases***

Luego de la selección de los datos es necesario, previo al entrenamiento realizar el etiquetado de los mismos. Para este tipo de estudios, suelen utilizarse datos extraídos en campo por el equipo de field service, lo que hace que estos datos puedan contener cierto grado de error.

La gestión y control del error, como se repasó anteriormente, es un desafío relevante en el aprendizaje automático supervisado ya que no gestionarlo de manera correcta puede complicar el aprendizaje de los algoritmos para distinguir entre las clases.

Para compensar los errores en la distribución de las etiquetas se suelen analizar los datos mediante modelos de aprendizaje no supervisados con el objetivo de encontrar información sobre su estructura y de las etiquetas de las clases más confiables, ya que es propio de estos algoritmos descubrir patrones similares en los datos y agruparlos en un mismo conjunto.

Por otro lado, para reducir los errores en los datos del conjunto de entrenamiento se suelen emplear los datos provistos por los medidores inteligentes ya que tienen un grado de confiabilidad mayor.

Los medidores inteligentes, son un elemento fundamental en la evolución a redes inteligentes, ya que no solo provee datos de mayor confiabilidad, sino que además los provee en tiempo real.

También debido al monitoreo es posible establecer mecanismos de alarmas para determinados tipos de comportamiento de usuarios, que no solo ayuden en la detección del fraude, sino que además mejore el aprendizaje de los modelos para distinguir entre las clases.

### ***Conclusiones sobre las NTL y el aprendizaje automático***

El robo eléctrico representa una seria preocupación para muchas compañías eléctricas a nivel global, ya que es una de las principales fuentes de pérdidas no técnicas muy relevantes por sobre las pérdidas técnicas.

Es foco de las compañías de distribución detectar estas pérdidas y mitigarlas. Para ello es fundamental detectar estas pérdidas en tiempo real y actuar de manera sistemática.

Es por ello, que las compañías de distribución tienen como objetivo estratégico evolucionar sus redes a redes inteligentes, en parte por la necesidad de detectar pérdidas y en parte para acompañar las nuevas demandas al sector.

La incorporación de esta tecnología en las redes de distribución y los avances en el campo de las TICs han permitido el despliegue de diversos modelos para la detección de NTL, como son los modelos basados en estimación de estado y modelos basados en aprendizaje automático.

En la revisión de los estudios realizados se pudo ver con datos reales, que mediante la aplicación de algoritmos de aprendizaje automático, es posible encontrar modelos predictivos para la detección de fraude en el robo de energía, los cuales resultaron interesantes y de mucho valor potencial para las compañías de distribución.

Es fundamental medir. Medir para poder accionar. De manera automática o diseñando un modelo de aprendizaje automático que aprenda de los datos, medidos. Es por ello que no

se debe dejar de resaltar y destacar, una y otra vez, la importancia de aplicar inteligencia a la red implementando alguna modalidad de monitoreo remoto complementado por el uso de medidores inteligentes.

## CAPITULO V. CONCLUSION

La revolución industrial 4.0 trae a escena una serie de desafíos que todas las industrias y sectores deberán afrontar. La transformación digital es obligatoria para las compañías que quieran sobrevivir y mantenerse competitivas. Ahora bien, esa transformación debe ser planificada e inteligente, soportada por un plan estratégico que aborde tecnología, conectividad, desarrollo de sistemas, y hasta nuevos modelos de negocio.

Incorporar tecnología y conocimientos además de ser vital para la evolución de las prestaciones de producto o servicios, es necesario para mantener los aspectos de competitividad en el mapa de gestión. Atrás de todas estas herramientas, de todos estos procesos aparecen nuevas necesidades de los usuarios, nuevos comportamientos que deben ser atendidos de forma integral, con nuevos productos y servicios pero también con nuevos modelos de negocio. Es fundamental adaptarse.

El sector eléctrico cuenta con tecnología y conocimiento disponible para afrontar el desafío. Se deberá pensar la estrategia adecuada para cada tramo de la cadena de valor. Los desafíos en la etapa de generación no son los mismos que en la etapa de distribución o comercialización. Cada etapa deberá diseñar su propio plan.

Es en la etapa de distribución donde las oportunidades de transformación son más relevantes, por el impacto de las tecnologías disponibles a implementar y por las eficiencias introducidas mediante la aplicación de técnicas de machine learning, entre otras razones. Desde la cadena de valor, según la etapa, se deberá trabajar en estrategias adecuadas para evolucionar y lograr esa transformación de modo exitoso.

Cuanto más actores participantes de la cadena de valor se sumen a esa evolución, el éxito será de mayor probabilidad. Los fabricantes de transformadores, como actores relevantes de este ecosistema, pueden abordar esta evolución implementando técnicas de monitoreo de parámetros, como ser temperatura, estado de salud, etc. Estas técnicas de monitoreo son posibles incorporando tecnología y conectividad, es decir apoyado en los campos propios de la Industria 4.0. Y es esto lo que habilita al fabricante a re pensar su modelo de

negocio, orientada a servicio, logrando así también beneficios de carácter económico financieros además de los operativos.

Todo esta transformación se potencia a partir de la implementación de machine learning basadas en los distintos tipos de aprendizaje mediante el uso de diferentes técnicas. En este sentido es fundamental construir las métricas adecuadas para entender el impacto de estos modelos aplicados. También es importante planificar de forma metodológica y procedural como abordar y aplicar aprendizaje automático de modo tal de no incurrir en soluciones inadecuadas, no rentables.

Es importante para poder explotar al máximo todas estas herramientas de machine learning contar con datos reales. Datos que sirvan para que los modelos aprendan. En este sentido es necesario sumar infraestructura de medición, no solo en los transformadores, sino que también en diferentes instancias de la red. Reunir datos, ordenarlos y estructurarlos en conjuntos de datos permitirá perfeccionar los modelos de aprendizaje y hacerlos precisos.

Ahora bien, el despliegue de toda esa infraestructura de medición debe ser parte de un plan global evolutivo hacia las redes eléctricas inteligentes: “una red evolucionada que gestiona la demanda de electricidad de forma sostenible, fiable y económica, basada en una infraestructura avanzada, y adaptada para facilitar la integración de todos sus componentes”. O bien, “aquella que puede integrar de forma eficiente el comportamiento y las acciones de todos los usuarios conectados a ella, de tal forma que se asegure un sistema energético sostenible y eficiente”.

Las redes eléctricas inteligentes y la mejora de los sistemas de generación distribuida resultarán esenciales para la masificación de tecnologías más verdes como el vehículo eléctrico y las energías renovables. El coche eléctrico y las energías renovables son dos de las grandes apuestas para lograr economías con menores emisiones de carbono. Sin embargo, ninguna de ellas podrá prosperar ampliamente si las redes eléctricas de las que dependen no experimentan su propia revolución.

Es clave pensar las etapas para la implementación de esta evolución, pensando en una visión a futuro que atienda estos nuevos tipos de consumo pero que también solucione problemáticas de fondo y de fuerte impacto como las pérdidas de la red, técnicas y no técnicas. Identificar y mitigar estas pérdidas, identificando a su vez efectos positivos de esta evolución, como ser la optimización del costo operativo y la gestión inteligente de los activos de red, entre otros, es necesario para mejorar el resultado económico-financiero y

así poder justificar o bien conseguir las inversiones necesarias para afrontar este tipo de despliegues de tecnología.

En desarrollo de software se utiliza un concepto que viene del Japon antiguo: Shu-Ha-Ri. Habla de 3 etapas de aprendizaje: el Shu, siguiendo las buenas prácticas. Esto es corregir, optimizar lo existente. El Ha, adaptando las reglas, a la nueva realidad: a las nuevas demandas, nuevas necesidades. Y el Ri, innovando, evolucionando.

La transformación digital exitosa es factible si se piensa como un proceso, volcado a un plan estratégico integral con un cuadro de situación actual, y un punto de partida con problemáticas y puntos de dolor claros. También considerando las tecnologías disponibles y su adecuación al plan en cuanto a inversión y timing. Por último, considerando todos los avances en materia de Inteligencia Artificial para potenciar y acelerar dicho proceso.

Si todo esto se articula de manera inteligente es altamente probable que la transformación sea exitosa.

Algunos insights finales:

- Según un estudio del Foro Económico Mundial en colaboración con Accenture, la transformación digital del sector eléctrico puede ahorrar hasta 1,2 billones de euros a nivel mundial entre 2016 y 2025. (El avance de la economía digital, Accenture).
- Asimismo, en un artículo publicado por McKinsey, tres de sus consultores aseguran que la digitalización ofrece la posibilidad de mejorar el funcionamiento de la infraestructura eléctrica a lo largo de toda la cadena de valor y suministro. Según el texto, las estimaciones más conservadoras sugieren que una optimización digital puede mejorar la rentabilidad de las redes entre un 20% y un 30%. (McKinsey)
- Un "futuro de prosumidores (productores/consumidores)", así es cómo el director del Instituto para Energías Sostenibles de la Universidad de Boston (EEUU), Peter Fox-Penner ha bautizado el concepto de las redes inteligentes en un artículo en Harvard Business Review en español. En el texto, el experto afirma que "la explosión de dispositivos digitales inteligentes conectados a internet ha creado una nueva forma de eficiencia energética con el control inmediato sobre los equipos". (technologyreview.es)



- Según Fox-Penner, "antes, la mejora se limitaba a cambiar el dispositivo A por el B, más eficiente que el primero. B, sin embargo, funcionaba exactamente igual que A [...]. Ahora, el dispositivo B se puede controlar de forma remota con software que estudia el horario de precios de la electricidad y decide si es más barato activarlo en el momento o esperar a otra hora". (technologyreview.es)
- El impacto de estos avances ya se puede comprobar a pequeña escala. Apple ya ha pedido licencias para comercializar parte de su excedente energético en Estados Unidos. (technologyreview.es)
- En Australia, ya está en marcha la conversión de dos barrios residenciales en plantas energéticas virtuales, de modo que la producción fotovoltaica de los residentes alimenta la red nacional del país. (technologyreview.es)
- En Alemania, la empresa Sonnenbatterie lanzó en enero del año pasado una plataforma para la compra-venta de energía renovable entre particulares, "el Airbnb energético", según su CEO. (technologyreview.es)

La cuarta revolución, la de la Industria 4.0, está ocurriendo a gran escala y a toda velocidad. El sector eléctrico cuenta con las herramientas y condiciones dadas para afrontar este desafío y así evolucionar.

## BIBLIOGRAFIA

### Libros

- The Hundred-Page Machine Learning Book. *Andiy Burkov*. 2019
- LEAN Analytics. *Alistair Croll & Benjamin Yoskovitz*. 2013
- Machine Learning Yearning. *Andrew NG*. 2018

### Papers & Artículos

- Reduction of Technical and Non-Technical Losses in Distribution Networks. *Working Group on Losses Reduction CIRED*. Final report 20/11/2017
- Implementation of a Transformer Monitoring Solution Per IEEE C57.91-1995 Using an Automation Controller. *Walter A. Castillo, Rekha T. Jagaduri and Prasanna Muralimanohar*. 2012
- Distribution Transformer Health Monitoring and Predictive Asset Maintenance. *Prasenjit Shil, Ameren; Tom Anderson, SAS Institute Inc*. 2016
- Achieving High Performance with Theft Analytics Leveraging smart grid deployments to enhance revenue protection. *Accenture*. 2012
- Magazine Electricity today Transmission & distribution. Second Quarter 2016 Volume 29, No. 2
- Transformación digital industrial. Reinventando para ganar en Industria 4.0. *Maximillian Schroeck, Anne Kwan, Jon Kawamura, Cristina Stefanita, y Deepak Sharma. Deloitte Insight*. 2019
- Application of Machine Learning in Transformer Health Index Prediction. *Alhaytham Alqudsi and Ayman El-Hag*. 2019
- Overview of the status of smart metering systems in Argentina and future perspectives. *Patricio G. Donato, Ignacio Carugati, Jorge Strack, Sebastián Maestri, Carlos Orallo, Matías Hadad, Marcos Funes*. 2016
- Redes inteligentes. La evolución de las redes eléctricas digitales. *Patricio Donato*. 2016

- Irregularity Detection on Low Tension Electric Installations by Neural Network Ensembles. *C. Muniz. y. otros.* 2009.
- Fraud Detection In Electric Power Distribution Networks Using An Ann- Based Knowledge-Discovery Process. *B. Costa. y. otros.* 2013.
- Multivariate Electricity Consumption Prediction with Extreme Learning Machine. *A. Q. y. F. S. H. Song.* 2016.
- Power Utility Nontechnical Loss Analysis With Extreme Learning Machine Method. *A. Nizar y otros.* 2008.
- Characterization and Identification of Electrical Customers Through the Use of Self-Organizing Maps and Daily Load Parameters. *S. Verdu y otros.* 2004.
- Brochure institucional Tadeo Czerweny

### **Blogs**

- Towards Data Science. *Cassie Kozyrkov.* Head of Decision Intelligence, Google.
- Machine Learning Mastery. *Jason Brownlee.* Masters and PhD degree in Artificial Intelligence
- AWS Machine Learning Blog
- Dot CSV. *Carlos Santana Vega.* Machine Learning Educator. Owner of the AI/ML educational

### **Gráficos**

- Gráfico 1: extraído de sección de Preguntas Frecuentes de la web de Grupo Energía de Bogotá.
- Gráfico 2: extraído de la presentación “Smart Grid: Sistemas de medición inteligente y confiabilidad del sistema eléctrico” en el Capítulo de Ingeniería Eléctrica. Consejo Departamental de Lima – CIP en 2019
- Gráfico 3: print de pantalla de interfaz HMI compartido por equipo de desarrollo ABB de cliente confidencial.

- Gráfico 4, 5, 6, 14, 15, 23, 24, 42, 43, 45, 47, 48, 49, 50: extraído de material del curso de Machine Learning de Carlos Santana Vega.
- Gráfico 7: publicación “What is Deep Learning?” de Jason Brownlee del blog Machine Learning Mastery.
- Gráfico 8, 9, 10, 11, 12 y 13: publicación “Training, validation, and test phases in AI — explained in a way you’ll never forget” de Cassie Kozyrkov del blog towards Data Science.
- Gráfico 16, 17: publicación “AI = “Automated Inspiration”” de Cassie Kozyrkov del blog towards Data Science.
- Gráfico 18, 19, 20: publicación “The ultimate guide to starting AI” de Cassie Kozyrkov del blog towards Data Science.
- Gráfico 21: brochure comercial Tadeo Czerweny.
- Gráfico 22, 23: paper “Implementation of a Transformer Monitoring Solution Per IEEE C57.91-1995 Using an Automation Controller”.
- Gráfico 25, 26, 27, 29, 30, 31: paper “Application of Machine Learning in Transformer Health Index Prediction”.
- Gráfico 28: extraído del artículo “Estadística y Machine Learning con R” de Francisco Parra.
- Gráfico 32: extraído del artículo “El cliente productor de Luz de Siemens” por Maria Climent de El Mundo.
- Gráfico 33: Del paper “Redes inteligentes. La evolución de las redes eléctricas digitales” de Patricio Donato, Investigador del Conicet.
- Gráfico 34, 35, 36, 37, 38, 39: Del trabajo realizado por el grupo de trabajo formado por colaboradores de todo el mundo para la reducción de pérdidas en redes eléctricas, encomendado por el grupo EnEl y presentado en el CIRED 2015.
- Gráfico 40: del paper “Power Utility Nontechnical Loss Analysis With Extreme Learning Machine Method” de A. Nizar

- Gráfico 41, 42, 44, 46: de mi propia autoría con la finalidad de representar el caso de aplicación

## ANEXO I. Introducción a las redes neuronales

Yendo a un ejemplo, para que un transformador funcione de forma correcta varios de sus parámetros deben funcionar dentro de ciertos valores. Considerando dos parámetros: temperatura del aceite (T) y nivel de carga (NC).

Si la temperatura y el nivel de carga están ok, el transformador va a funcionar correctamente. Si no es así, el transformador presentará un incorrecto desempeño que seguramente afectará su vida útil.

Se utilizará una neurona para modelar esto. Ambas variables (temperatura y nivel de carga) serán variables binarias o sea su valor puede ser 0 o 1. Esto indicara si se encuentra en un valor correcto de temperatura (T=1) y si está en un nivel de carga adecuado (NC=1).

**Gráfico 41:** Tabla de activación de dos variables Temperatura y Nivel de Carga. Por Pablo Nuñez (2020)

	1	0
<b>Temp. X1</b>	T ok	T no ok
<b>Nivel de carga X2</b>	NC ok	NC no ok

De igual forma la variable de salida que se quiere modelar es una que indique si el funcionamiento del transformador es correcto o no.

**Gráfico 42:** Tabla de resultados para salida. Por Pablo Nuñez (2020)

	1	0
<b>Funcionamiento Y</b>	Bien	Mal

La neurona tal como funciona ahora mismo actúa como un modelo de regresión lineal y presenta resultados numéricos continuos y no una variable binaria.

Lo que se suele hacer es evaluar el resultado de la regresión lineal y si el valor supera un cierto umbral se le asigna a la salida el valor 1 y si es inferior a ese umbral el valor 0. Como en la neurona se cuenta con el término de sesgo es posible asignarle un valor equivalente al opuesto del umbral y así reescribir las fórmulas de manera sencilla.

**Gráfico 43:** Expresión matemática de la recta adecuada al modelo. Por Carlos Santana Vega (2019).

$$\text{BIAS} = - \text{UMBRAL}$$

$$WX + b \leq 0 \rightarrow Y = 0$$

$$WX + b > 0 \rightarrow Y = 1$$

Ahora el valor de la salida dependerá de si el cómputo de nuestra neurona es menor o mayor que 0. Se procede a modelar según lo visto hasta el momento.

**Gráfico 44:** Tabla de resultados, target y término independiente optimizados. Por Pablo Nuñez(2020)

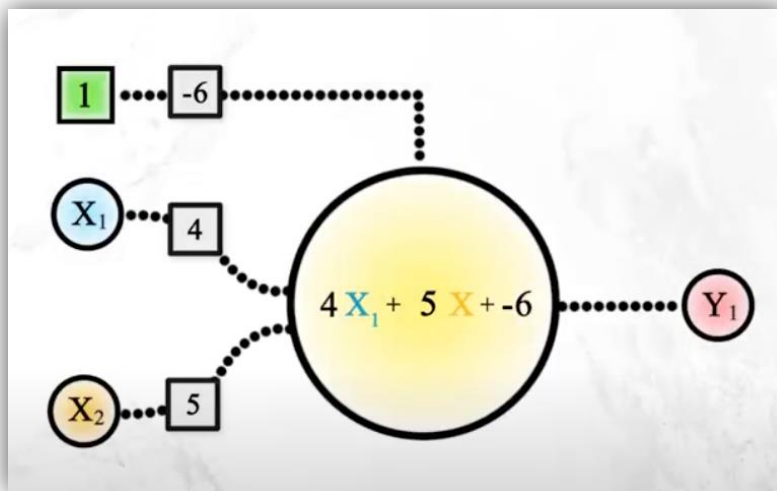
X1	X2	Target	Y
T no ok	NC no ok	Mal	-6
T ok	NC no ok	Mal	-2
T no ok	NC ok	Mal	-1
T ok	NC ok	Bien	3

Se puede ver que para que la variable de salida sea 1, ambos parámetros de temperatura y nivel de carga deben estar activados (en 1), es decir que ambos parámetros deben estar en valores correctos de funcionamiento. Cualquier otra combinación hará que el

transformador funcione mal. En la misma tabla se puede visualizar el resultado de la neurona para cada combinación de variable. Visto así lo que se debería hacer es variar el valor de los parámetros, tanto el peso de las conexiones como el sesgo, hasta encontrar la combinación perfecta que modele la mejor performance del transformador.

Si se siguen probando diferentes combinaciones se puede ver como el resultado va variando (según signos arrojados en columna Y). Finalmente es posible encontrar una combinación como la de la gráfica, en la que todas las combinaciones de variables consiguen el resultado esperado (observar los signos).

**Gráfico 45:** Diagrama de una neurona con las variables reflejadas. Por Carlos Santana Vega (2019).



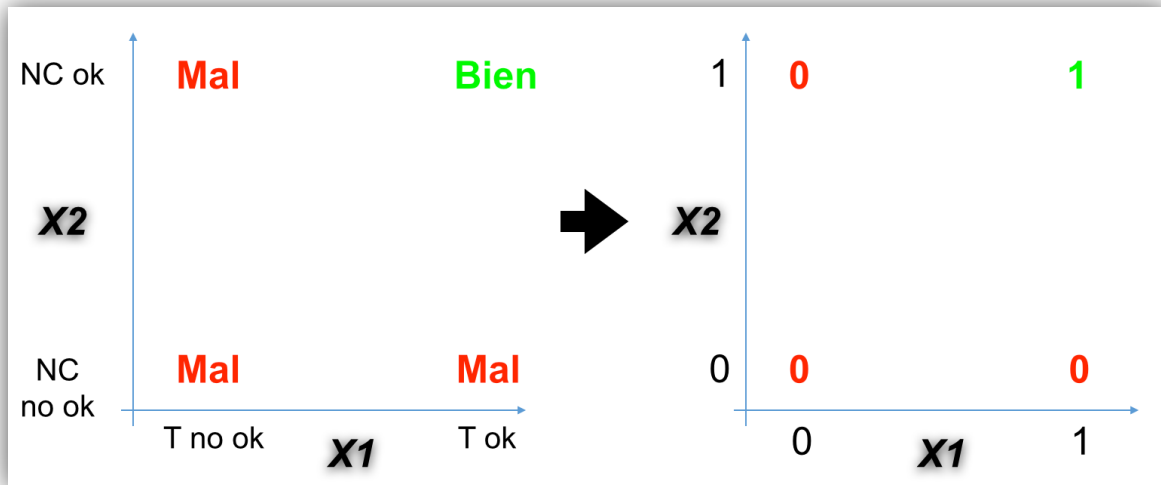
Se puede ver que con estos parámetros solo es posible conseguir una respuesta positiva, o sea valor 1 en la salida cuando ambas variables de entrada están activadas.

Así se logra utilizar la neurona para codificar información en el comportamiento correcto de un transformador.

Llevando la tabla a un diagrama de ejes y luego a un diagrama "informático" se obtiene una puerta lógica AND.

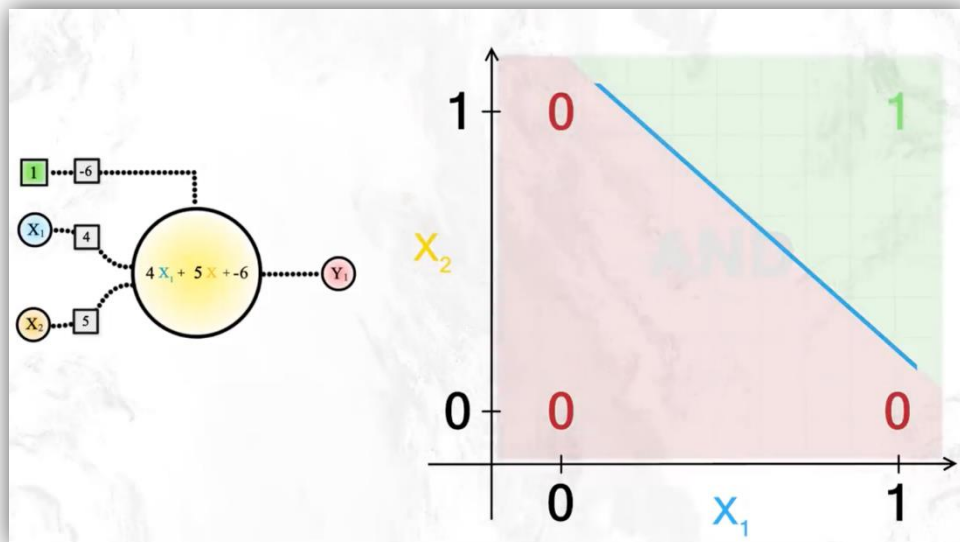
**Gráfico 46:** modelo de una puerta lógica AND. Por Pablo Nuñez (2020)





Si sobre esta gráfica ahora se visualiza la recta de regresión definida por la neurona se observa lo siguiente

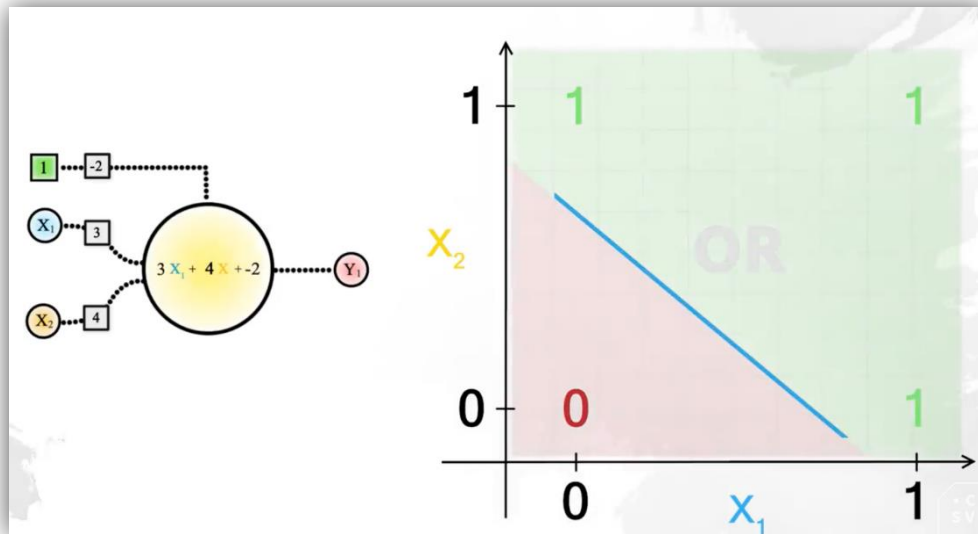
**Gráfico 47:** Gráfica que representa la recta de regresión definida por la neurona. Por Carlos Santana Vega (2019).



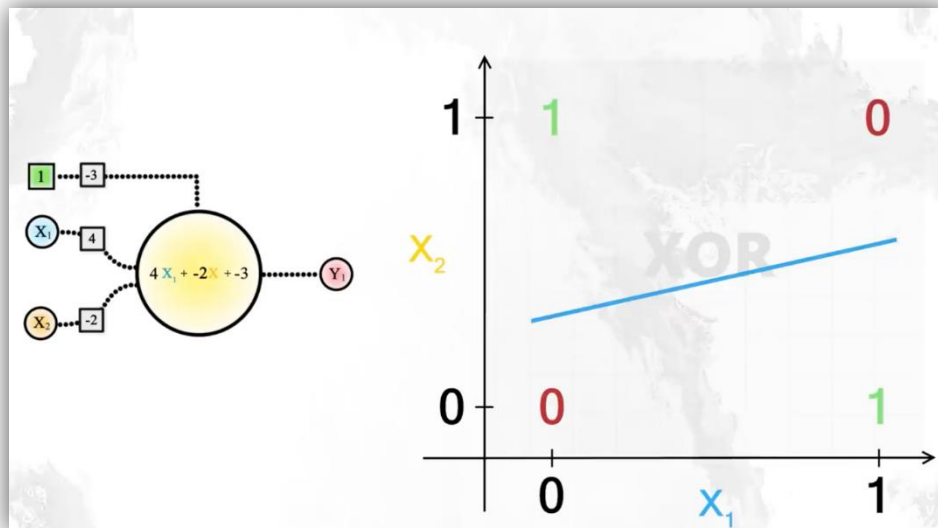
La combinación de parámetros que se obtuvo antes, ha trazado una recta que separa los puntos de la gráfica en dos grupos diferentes. Por tanto otra manera de entender este problema es la de encontrar aquellos valores de nuestros parámetros que tracen una frontera entre las dos clases que se desea clasificar.

Existen otros tipos de puertas lógicas, como la OR y lo XOR.

**Gráfico 48:** Gráfica de puerta lógica OR. Por Carlos Santana Vega (2019).



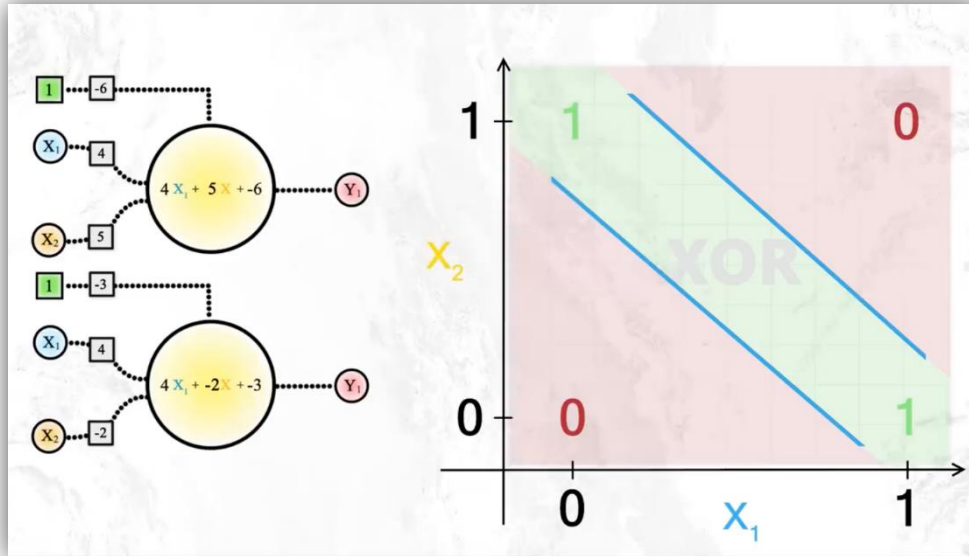
**Gráfico 49:** Gráfica de puerta lógica XOR. Por Carlos Santana Vega (2019).



Como se puede ver no es posible encontrar la recta que separe ambas fronteras. Se trata de una limitación propia de usar una única neurona para codificar este modelo. Es imposible separar linealmente ambas clases.

La solución a este problema se consigue agregando una segunda neurona.

**Gráfico 50:** Diagrama de dos neuronas. Por Carlos Santana Vega (2019).



Ahora con dos neuronas se tendrían dos rectas que separaran ambos grupos.

Esta limitación de las neuronas de poder resolver el problema de la puerta XOR se conoce desde hace muchos años e ilustra muy bien la necesidad de combinar varias neuronas para poder conseguir modelos más complejos. Muchas neuronas funcionando juntas es lo que se conoce como redes neuronales.