

UNIVERSIDAD TECNICA FEDERICO SANTA MARIA

**MAGISTER EN INNOVACIÓN TECNOLÓGICA Y
EMPREDIMIENTO**

TESIS

**Propuesta de guía práctica para la aplicación de tecnologías machine
learning en las empresas.**

Tesis de Grado presentada por
Ana María González López

Como requisito parcial para optar al grado de
Magíster en Innovación Tecnológica y Emprendimiento

Profesor Guía: Claudio Guillermo Ramirez

Fecha de presentación de su tesina

RESUMEN EJECUTIVO

El machine learning es sin duda una tecnología que ha ido impactando de forma exponencial en los aplicativos cotidianos y empresariales. Es nuestro deber como líderes tecnológicos saber orientar bien los desafíos empresariales y darle soluciones inteligentes. En este presente documento daremos un vistazo a que es el machine learning y cómo podemos aplicar soluciones a los nuevos desafíos empresariales en un mundo completamente real. Para interiorizarse y dar el primer paso, no se requiere de grandes recursos ni expertos en el tema.

La tendencia en los últimos años, indica que algunas compañías apuestan por el Machine Learning (ML) pero lo hacen por el momento y en gran medida en un entorno controlado o de pruebas y sin influir en sus procesos de negocio principales según variados estudios, se concluye que dar el salto a la aplicación en áreas de negocio fundamentales es el gran reto al que deben hacer frente las organizaciones en 2019.

Si bien esta tesina será una guía práctica y que permitirá contextualizar el grado de complejidad para inicializarse, siempre debemos tener presente y como objetivo, las siguientes preguntas:

¿Cómo evolucionar del Machine Learning en pequeña escala a una de mayor alcance?

Esta respuesta se ha ido construyendo y generando una especie de tendencia, la cual podemos resumir en estos 6 siguientes contextos:

1. Disponibilidad de datos bien gobernados. A medida que se avanza en el Machine Learning más se entiende la necesidad de un gobierno del dato. Data Governance ganará relevancia durante 2019 y, gracias a ello, los profesionales podrán ser capaces de conocer bien los orígenes de datos e identificar aquellos que son de calidad y los que no. Las máquinas de aprendizaje se basan en datos de entrenamiento buenos, únicos y confiables, por lo que es imprescindible aplicar una buena política de gobierno del dato.
2. Capacitación de los profesionales de las organizaciones para entender de verdad las posibilidades del Machine Learning. Esto no sólo implica contratar perfiles especializados, sino que conlleva también capacitar a los trabajadores que conocen el negocio para que entiendan las posibilidades y las limitaciones que ofrecen las técnicas de Machine Learning.
3. Desarrollo de nuevos perfiles especialistas en datos. Complementariamente al punto anterior, la ampliación del alcance de Machine Learning, obligará a que las compañías integren en sus equipos nuevos perfiles altamente especializados, no solo el de Científico de Datos, sino, además:
 - a) Interlocutor de negocio con conocimientos de Machine Learning. Se trata de un profesional que viene de las áreas de gestión de una

empresa y toma decisiones estratégicas o tácitas y que, además, cuenta con una formación en analítica suficiente para servir de enlace entre los científicos de datos y las áreas de negocio.

- b) Informático que sepa integrar algoritmos y modelos de ML. Un trabajador que entienda cómo funcionan los algoritmos y conozca cómo implementar los resultados derivados de aplicar esta tecnología en la actividad y procesos de la compañía.
 - c) Ingeniero de Datos. Responsable de suministrar o facilitar eficientemente los datos necesarios a los procesos de aprendizaje. Algo fundamental en grandes organizaciones.
 - d) Especialista Regulatorio en Machine Learning. La entrada en vigor del Reglamento General de Protección de Datos (RGPD) y la implementación de los bancos de pruebas regulatorios o Sandbox en España conllevará la necesidad de contar con un experto en legislación que posea conocimientos sobre el marco regulatorio y ético.
4. Nuevas regulaciones en el sector financiero. El Machine Learning continuará siendo especialmente relevante en el sector financiero en 2019. La aplicación de nuevas normativas en la regulación bancaria, como la PSD2, obligará indirectamente a estos operadores a ir un paso por delante en el tratamiento de datos, antes de que la competencia lo haga por ellos.
5. Aplicación de la sensorización e IoT en el sector industrial. Esta es una de las claves de la futura competitividad de la industria española, que debe comenzar a incorporar sistemas de sensorización e IoT para el mantenimiento de los activos industriales y aplicarlos a modelos predictivos que anticipen el funcionamiento y ciclo de vida de la maquinaria.
6. Creciente importancia de los datos para las Administraciones. Las instituciones públicas empezarán a sistematizar el gran volumen de datos que disponen sobre los ciudadanos (comportamiento, tránsito, uso de espacios públicos...). Se abrirá una brecha entre aquellas administraciones que tomen decisiones en base a las posibilidades de predicción que ofrece esta información o aquellas que lo hagan siguiendo el modo tradicional.

Keywords: Aprendizaje de máquina, aprendizaje automático, Deep Learning, Tecnología, Transformación Digital, Inteligencia Artificial.

Fuente: (Ebanking New)

EXECUTIVE SUMMARY

Machine learning is undoubtedly a technology that has been impacting exponentially on everyday and business applications. It is our duty as technology leaders to know how to guide business challenges well and provide intelligent solutions. In this

document we will take a look at what machine learning is and how we can apply solutions to new business challenges in a completely real world. To internalize and take the first step, it does not require large resources or experts in the field.

The trend in recent years, indicates that some companies are committed to Machine Learning (ML) but do so at the moment and largely in a controlled or testing environment and without influencing their main business processes according to various studies, it concludes that making the leap to the application in fundamental business areas is the great challenge that organizations must face in 2019.

Although this thesis will be a practical guide and that will allow contextualizing the degree of complexity to initialize, we must always keep in mind and as an objective, the following questions:

How to evolve from Machine Learning on a small scale to a larger one?

This response has been constructed and generated a kind of trend, which we can summarize in these 6 following contexts:

1. Availability of well-governed data. As Machine Learning progresses, the need for data governance is more understood. Data Governance will gain relevance during 2019 and, thanks to this, professionals may be able to know the sources of data well and identify those that are of quality and those that are not. Learning machines are based on good, unique and reliable training data, so it is essential to apply a good data governance policy.

2. Training of professional organizations to truly understand the possibilities of Machine Learning. This not only implies hiring specialized profiles, but also involves training workers who know the business to understand the possibilities and limitations offered by Machine Learning techniques.

3. Development of new data specialist profiles. In addition to the previous point, the extension of the scope of Machine Learning, will force companies to integrate into their teams new highly specialized profiles, not only that of Data Scientist, but also:

- a) Business partner with knowledge of Machine Learning. This is a professional who comes from the areas of management of a company and makes strategic or tacit decisions and, in addition, has sufficient analytical training to serve as a link between data scientists and business areas.

- b) Computer scientist who knows how to integrate algorithms and ML models. A worker who understands how algorithms work and knows how to implement the results derived from applying this technology in the company's activity and processes.

- c) Data Engineer. Responsible for providing or efficiently providing the necessary data to the learning processes. Something fundamental in large organizations.

d) Regulatory Specialist in Machine Learning. The entry into force of the General Data Protection Regulation (GDPR) and the implementation of regulatory or Sandbox test benches in Spain will entail the need for a legal expert who has knowledge of the regulatory and ethical framework.

4. New regulations in the financial sector. Machine Learning will continue to be especially relevant in the financial sector in 2019. The application of new regulations in banking regulation, such as PSD2, will indirectly force these operators to go one step ahead in data processing, before the competition Do it for them.

5. Application of sensorization and IoT in the industrial sector. This is one of the keys to the future competitiveness of Spanish industry, which must begin to incorporate sensorization and IoT systems for the maintenance of industrial assets and apply them to predictive models that anticipate the operation and life cycle of machinery.

6. Increasing importance of data for Administrations. Public institutions will begin to systematize the large volume of data they have about citizens (behavior, traffic, use of public spaces ...). A gap will be opened between those administrations that make decisions based on the prediction possibilities offered by this information or those that do so in the traditional way.

Keywords: Machine learning, machine learning, Deep Learning, Technology, Digital Transformation, Artificial Intelligence.

TABLA DE CONTENIDOS

1. INTRODUCCIÓN.	8
2. OBJETIVOS.	9
2.1.- OBJETIVOS GENERALES.	9
2.2.- OBJETIVOS ESPECÍFICOS.	10
3. ALCANCE.	10
4. DESARROLLO.	12
4.2.- DEFINICIÓN DE METODOLOGÍA UTILIZADA:	12
5. DESARROLLO METODOLÓGICO.	12
5.1 MODELOS DE MACHINE LEARNING.	12
5.1.A APRENDIZAJE SUPERVISADO	12
5.1.B APRENDIZAJE NO SUPERVISADO	14
5.1.C APRENDIZAJE DE REFUERZO	15
5.1.D DEEP LEARNING	16
5.2 APLICACIÓN DEL MACHINE LEARNING A LAS NECESIDADES EMPRESARIALES	17
5.2.A ACERCANDO EL MACHINE LEARNING A LAS EMPRESAS	18
¿QUÉ ESTAS TRATANDO DE HACER?	18
6 RESULTADOS OBTENIDOS.	38
6.1 USO PRÁCTICO DE LAS TECNOLOGÍAS DISPONIBLES	38
6.1.1 CLASIFICACIÓN DE IMÁGENES DE CÁMARA DE VIDEO USANDO DEEP LEARNING MEDIANTE MATHWORKS	38
6.1.2 HERRAMIENTAS DE MACHINE LEARNING DE AMAZON	43
6.2 COMPARATIVA DE PERFORMANCE ENTRE LAS PRINCIPALES PLATAFORMAS CLOUD DE MACHINE LEARNING	47
6.3 EXPOSICIÓN DE CASOS	52
7. CONCLUSIONES	55
7.1 DECLARACIONES RESPECTO DE LAS CONCLUSIONES.	57
8. BIBLIOGRAFÍA.	58

TABLA ILUSTRACIONES

ILUSTRACIÓN 1: ESTRUCTURA DE DATOS CORRESPONDIENTE A UN EJEMPLO CANÓNICO DE APRENDIZAJE	11
ILUSTRACIÓN 2: DIAGRAMA DE FLUJO DEL APRENDIZAJE SUPERVISADO	13
ILUSTRACIÓN 3: DIAGRAMA DE FLUJO DEL APRENDIZAJE NO SUPERVISADO	15
ILUSTRACIÓN 4: DIAGRAMA DE FLUJO APRENDIZAJE POR REFUERZO	16
ILUSTRACIÓN 5: CONTEXTO DEL DEEP LEARNING	17
ILUSTRACIÓN 6: INTELIGENCIA ARTIFICIAL	18
ILUSTRACIÓN 7: IMAGEN ANIMALES	19
ILUSTRACIÓN 8: DETECCIÓN DE OBJETO	19
ILUSTRACIÓN 9: DECISIÓN DE ML	19
ILUSTRACIÓN 10: APRENDIZAJE REDES NEURONALES	19
ILUSTRACIÓN 11: CAMINO DE DECISIÓN	20
ILUSTRACIÓN 12: TABLA COMPARATIVA ML VS DL	20
ILUSTRACIÓN 13: GARTNER HERRAMIENTAS ML	24
ILUSTRACIÓN 14: COMPILAR EN MATHWORKS	41
ILUSTRACIÓN 15: IDENTIFICACIÓN 1 IMAGEN CON MATHW	41
ILUSTRACIÓN 16: IDENTIFICACIÓN 2 IMAGEN CON MATHW	42
ILUSTRACIÓN 17: IDENTIFICACIÓN 3 IMAGEN CON MATHW	42
ILUSTRACIÓN 18: IDENTIFICACIÓN 4 IMAGEN CON MATHW	42
ILUSTRACIÓN 19: IDENTIFICACIÓN 5 IMAGEN CON MATHW	43
ILUSTRACIÓN 20: IDENTIFICACIÓN 6 IMAGEN CON MATHW	43
ILUSTRACIÓN 21: AMAZON COMPREHEND	45
ILUSTRACIÓN 22: COMPARATIVA APIS ANALISIS DE IMÁGENES	48
ILUSTRACIÓN 23: COMPARATIVA API PROCESAMIENTO DE VOZ Y TEXTO	49
ILUSTRACIÓN 24: COMPARATIVA DE SERVICIOS CLOUD MACHINE LEARNING	49
TABLA 1: EJEMPLOS PRACTICOS DE ML	20
TABLA 2: TABLA COMPARATIVA DE CML - COMPARATIVA CLOUD MACHINE LEARNIGN	51

1. Introducción.

Nuestro país definió una hoja de ruta para avanzar hacia un desarrollo digital, con una alianza público-privada, formada por representantes del sector público, empresarial, académico y de la sociedad civil.

La transformación digital no es algo que se haga de la noche a la mañana. Se trata de uno de los desafíos más complejos que probablemente enfrentaremos como país, empresas y sociedad, donde no existen recetas ni soluciones conocidas o probadas que faciliten este proceso. Al contrario, son muchos los engranajes que se deben realizar, cambiar y hacer girar coordinada y simultáneamente para llevar a cabo una metamorfosis tan compleja y de tal magnitud como la que requiere la transformación digital. Las organizaciones llevan años inmersas en este proceso, con diferentes velocidades, donde los beneficios no serán evidentes en el corto plazo.

La transformación digital es un proceso complejo que requiere orquestar múltiples cambios al interior de las compañías, comenzando por los sistemas tecnológicos y cambios culturales, e incluyendo también una nueva formación de la fuerza de trabajo, nuevas formas de trabajar y de interactuar con los clientes, nuevos modelos colaborativos, nuevos modelos de negocio, nuevos productos o servicios, entre muchos otros procesos evolutivos que adapten a las empresas a la nueva realidad que implica esta digitalización.

Dada la magnitud e implicancia de este desafío, es que se requiere que el liderazgo de las empresas esté involucrado y comprometido con esta transformación. Es por ello que hoy en todo el mundo podemos observar que son cada vez más los CEO que están liderando personalmente la transformación digital de sus empresas. En el informe CEO Outlook 2018 elaborado por KPMG, que entrevistó a 1.300 CEO de las principales empresas del mundo — incluidas 22 chilenas—, revela en sus resultados esta misma visión.

Si bien la mirada es optimista acerca de las posibilidades que representa la transformación digital, los directivos entrevistados también coinciden en que es uno de los riesgos y desafíos más relevantes para sus empresas en los próximos años. Casi el 100% de los directivos (93% de los chilenos y 95% de los globales) concibe la disrupción tecnológica como una oportunidad y no como una amenaza, donde todos los países muestran tasas superiores al 90%. Asimismo, a la hora de calificarse como disruptores activos o pasivos, la mitad de los CEO globales (54%) se declaran activos: dicen que más que esperar a ser objeto de alguna disrupción por parte de sus competidores, su organización está siendo activamente disruptiva en el sector. Destaca el caso de Estados Unidos, donde el 86% de los CEO se declara activo —y un 81% según declaran ejecutivos en Chile, situarían esta mirada positiva en la banda media alta—, superando con esta percepción a los Países Bajos (38%), Australia e Italia (32%), India y China (30%).

Los CEO no sólo manifiestan una mirada optimista sobre la tecnología, sino también en cómo se encuentran preparados para asumir este desafío. A nivel global,

mayoritariamente declaran sentirse preparados para liderar este cambio. Pero en Chile el resultado es menos de la mitad (33% de CEO chilenos entrevistados) del resultado global (71%).

La transformación digital implicará para nuestro país y empresas no solamente una simple adopción de nuevas tecnologías, sino un cambio profundo en los modelos de negocio y cultura.

Fuentes: (Diario Financiero)

2. Objetivos.

2.1.- Objetivos Generales.

Desarrollar una guía práctica que permita la comprensión conceptual de la tecnología de learning Machine por parte de no especialistas, ayudando a contribuir con su desarrollo en las empresas Chilenas.

Tomando en consideración, que uno de los conceptos que abarca gran parte de la Transformación digital es el renombrado Machine learning el cual su adopción se encuentra en plena expansión, ya que un 47% de las grandes empresas ya está invirtiendo en esta tecnología y otro 40% espera hacerlo en los próximos dos años. De hecho, sólo la supera el análisis de datos, con una inversión actual en el 54% de estas compañías, según el estudio realizado por Cloudera, plataforma de machine learning y análisis de datos optimizada para la nube, entre 200 grandes corporaciones de España, Francia, Alemania y Reino Unido.

Sin embargo, aún existen barreras para el desarrollo del machine learning, el primer problema es la falta de concienciación de los líderes. Y es que la causa principal que hace que el machine learning se resista es un aspecto de percepciones, ya que los negocios aún no confían en la capacidad de las máquinas de reemplazar al ser humano en la toma de decisiones". En este sentido el 79% cree que las personas toman mejores decisiones.

Por otra parte no hay una visión clara de en qué consiste y qué beneficios ofrece. El 89% de los gerentes tiene un conocimiento básico, aunque sólo la mitad sabe cómo funciona o recuerda casos de éxito. Los que toman las decisiones lo asocian con elementos de inteligencia artificial y automatización: el 44% apunta que tiene que ver con algoritmos computacionales, otros que es el proceso de crear sistemas independientes de la intervención humana, y un tercer bloque lo asocia a la inteligencia artificial.

Finalmente, hay una falta esencial de talento que dificulta que esta tecnología se extienda a una mayor velocidad. Menos de una de cada tres compañías cuenta con un equipo estable de científicos de datos con habilidades en machine learning.

Además, sólo un 52% de ellos se mantiene actualizado con noticias relevantes y específicas del sector de las tecnologías de la información.

2.2.- Objetivos específicos.

Facilitar la implementación de tecnología Learning Machine en distintas industrias y aplicaciones, mediante el uso de una guía práctica.

3. Alcance.

El aprendizaje automático o Machine Learning se engloba dentro de las disciplinas de la Inteligencia Artificial. Es un método científico que nos permite usar los ordenadores y otros dispositivos con capacidad computacional para que aprendan a extraer los patrones y relaciones que hay en nuestros datos por sí solos.

Esos patrones se pueden usar luego para predecir comportamientos y en la toma de decisiones.

Hasta la llegada del Machine Learning, la automatización del análisis en la toma de decisiones requería siempre de un experto humano capaz de descubrir algunas reglas más o menos ajustadas. El experto, basándose en los datos, intentaba descubrir cuáles eran los distintos patrones que nos permitían resolver el problema. Formulaba un conjunto de reglas más o menos exactas y dichas reglas eran específicamente programadas por ingenieros de software. El conjunto resultaba en un modelo más o menos próximo a la realidad, que se usaba para estimar lo que iba a ocurrir en un nuevo caso o en el futuro y en eso se basaba la toma de decisiones. Este sistema de toma de decisiones presenta varios problemas:

- Escasez de expertos: A menudo nos puede ser difícil encontrar expertos formados en el dominio de nuestro problema.
- Desarrollo automatizado: Una vez los expertos han detectado las reglas, éstas deben ser automatizadas e integradas en nuestros sistemas para poder aplicarlas a grandes volúmenes de datos automáticamente. Dicho trabajo involucra a ingenieros de software, que deben entender y programar dichas reglas. En ocasiones, la transmisión de información entre el experto y el ingeniero de software da lugar a errores y requiere un tiempo considerable de implementación.
- Renovación de los modelos: La producción de una solución de este tipo acostumbra a ser lenta y costosa, y los modelos son difíciles de adaptar cuando los datos evolucionan y sus reglas cambian.
- Escalabilidad: El volumen y la complejidad de los problemas que podemos solucionar con este método es limitado.

A medida que el volumen y la complejidad de los datos han ido creciendo, se ha hecho absolutamente necesario el uso del Machine Learning. Incluso en ficheros con pocos datos, cuando el número de propiedades que se manejan empieza a

crecer nos es difícil detectar los posibles patrones que los relacionan. En la Figura 1 vemos uno de los ejemplos canónicos que se utilizan para describir cómo hacer aprendizaje automático. El fichero describe algunas propiedades de un tipo de flores, el iris, y el objetivo del problema es predecir la especie a la que pertenece cada ejemplar según sus características. Como se puede ver, a pesar de que el número de campos no es muy elevado, a simple vista es muy difícil detectar las reglas que determinan dicha clasificación.

longitud sépalo	anchura sépalo	longitud pétalo	anchura pétalo	especie
5.1	3.5	1.4	0.2	Iris-setosa
6.5	3.0	5.5	1.8	Iris-virginica
4.7	3.2	1.3	0.2	Iris-setosa
5.8	2.8	5.1	2.4	Iris-virginica
5.2	2.7	3.9	1.4	Iris-versicolor
5.4	3.9	1.7	0.4	Iris-setosa
5.7	2.8	4.5	1.3	Iris-versicolor
6.3	3.3	4.7	1.6	Iris-versicolor
4.9	2.4	3.3	1.0	Iris-versicolor
6.0	2.2	5.0	1.5	Iris-virginica
6.9	3.2	5.7	2.3	Iris-virginica
5.0	2.0	3.5	1.0	Iris-versicolor

ILUSTRACIÓN 1: ESTRUCTURA DE DATOS CORRESPONDIENTE A UN EJEMPLO CANÓNICO DE APRENDIZAJE

Figura 1: Estructura de datos correspondiente a un ejemplo canónico de aprendizaje automatizado. Cada fila corresponde a un ejemplar de iris y sus las columnas contienen las medidas de sépalo y pétalo y la especie a la que pertenece el ejemplar. Existen reglas muy claras que nos permiten catalogar dichas flores en su especie a partir de sus medidas, pero para los humanos es difícil detectar dichas relaciones, aún cuando el número de propiedades involucradas no es muy alto, como en este caso.

Cuando la complejidad aumenta, los ordenadores superan en capacidad de análisis a los expertos humanos y evitan la necesidad de programar explícitamente soluciones a medida. De esta forma, hemos pasado de la toma de decisiones dirigida por expertos a la toma de decisiones dirigida por datos.

Los ingredientes imprescindibles para cualquier solución de Machine Learning son dos: los datos y los modelos de Machine Learning. Por eso, a continuación, hablaremos de cómo debemos preparar los datos para poderlos usar en el Machine Learning. Luego presentaremos un ejemplo de modelo de Machine Learning para la clasificación y regresión. Continuando, trataremos otros tipos de problemas no supervisados y discutiremos los algoritmos que usan para aprender. Veremos casos prácticos de cada tipo de aprendizaje y descubriremos qué modelo se ajusta mejor a cada problema y qué nuevas informaciones nos proporciona.

Por supuesto, el contenido de este documento no abarca el proceso completo necesario para integrar un sistema de aprendizaje automático en nuestra empresa. Aún así, intentaremos dar las herramientas suficientes para que puedan entender

cómo funcionan algunas soluciones de Machine Learning y en qué problemas nos pueden ser de gran ayuda.

Dado que el aprendizaje automático persigue lograr que las máquinas consigan extraer patrones de los datos, el primer paso será proporcionar dichos datos en un formato que las máquinas puedan usar para aprender de ellos.

4. Desarrollo.

4.2.- Definición de metodología utilizada:

Investigación Bibliográfica y documental de modelos machine learning existentes, estudio y análisis comparado, exposición de casos, mediante un proceso sistemático y secuencial de recolección, selección, clasificación, evaluación y análisis de contenido del material empírico impreso y gráfico, físico y/o virtual que servirá de fuente teórica, conceptual y/o metodológica para esta construcción de tesina.

Los criterios de selección de esta investigación Bibliográfica y documental son de **pertinencia**, es decir que las fuentes consultadas son acordes con el objeto de investigación y con sus objetivos, y criterio de **actualidad**, las cuales, implican que las fuentes consultadas son lo suficientemente actuales como para asegurar que reflejan los últimos avances de la disciplina, los más recientes hallazgos de la ciencia y/o los antecedentes empíricos más pertinentes referidos a sucesos ocurridos en el pasado reciente o en el presente.

5. Desarrollo Metodológico.

5.1 Modelos de Machine learning.

Las técnicas de machine learning son requeridas para mejorar la precisión de los modelos predictivos. Dependiendo de la naturaleza del problema empresarial que se está atendiendo, existen diferentes enfoques basados en el tipo y volumen de los datos. En esta sección, discutimos las categorías del machine learning.

5.1.a Aprendizaje supervisado

El aprendizaje supervisado comienza típicamente con un conjunto establecido de datos y una cierta comprensión de cómo se clasifican estos datos. El aprendizaje supervisado tiene la intención de encontrar patrones en datos que se pueden aplicar a un proceso de analítica. Estos datos tienen características

etiquetadas que definen el significado de los datos. Por ejemplo, se puede crear una aplicación de machine learning con base en imágenes y descripciones escritas que distinga entre millones de animales.

En los algoritmos de aprendizaje supervisado se genera un modelo predictivo, basado en datos de entrada y salida. La palabra clave “supervisado” viene de la idea de tener un conjunto de datos previamente etiquetado y clasificado, es decir, tener un conjunto de muestra el cual ya se sabe a qué grupo, valor o categoría pertenecen los ejemplos. Con este grupo de datos, el cual llamamos datos de entrenamiento, se realiza el ajuste al modelo inicial planteado. De esta forma es como el algoritmo va “aprendiendo” a clasificar las muestras de entrada comparando el resultado del modelo, y la etiqueta real de la muestra, realizando las compensaciones respectivas al modelo de acuerdo a cada error en la estimación del resultado. Por ejemplo, el aprendizaje supervisado ha sido utilizado para la programación de vehículos autónomos. Algunos métodos y algoritmos que podemos implementar son los siguientes:

- K vecinos más próximos (K-nearest neighbors)
- Redes neuronales artificiales (Artificial neural networks)
- Máquinas de vectores de soporte (Support vector machines)
- Clasificador Bayesiano ingenuo (Naïve Bayes classifier)
- Árboles de decisión (Decision trees)
- Regresión logística (Logistic regression)




ILUSTRACIÓN 2: DIAGRAMA DE FLUJO DEL APRENDIZAJE SUPERVISADO

5.1.b Aprendizaje no supervisado

El aprendizaje no supervisado se utiliza cuando el problema requiere una cantidad masiva de datos sin etiquetar. Por ejemplo, las aplicaciones de redes sociales, tales como Twitter, Instagram y Snapchat, tienen grandes cantidades de datos sin etiquetar. La comprensión del significado detrás de estos datos requiere algoritmos que clasifican los datos con base en los patrones o clústeres que encuentra. El aprendizaje no supervisado lleva a cabo un proceso iterativo, analizando datos sin la intervención humana. Se utiliza con la tecnología de detección de spam en e-mails. Existen demasiadas variables en los e-mails legítimos y de spam para que un analista etiquete una cantidad masiva de e-mail no solicitado. En su lugar, se utilizan los clasificadores de machine learning basados en clustering y asociación para identificar e-mails no deseados.

Los algoritmos de aprendizaje no supervisado trabajan de forma muy similar a los supervisados, con la diferencia de que éstos solo ajustan su modelo predictivo tomando en cuenta los datos de entrada, sin importar los de salida. Es decir, a diferencia del supervisado, los datos de entrada no están clasificados ni etiquetados, y no son necesarias estas características para entrenar el modelo. Dentro de este tipo de algoritmos, el agrupamiento o clustering en inglés, es el más utilizado, ya que particiona los datos en grupos que posean características similares entre sí. Una aplicación de estos métodos es la compresión de imágenes. Entre los principales algoritmos de tipo no supervisado destacan:

- K-medias (K-means)
- Mezcla de Gaussianas (Gaussian mixtures)
- Agrupamiento jerárquico (Hierarchical clustering)
- Mapas auto-organizados (Self-organizing maps)




ILUSTRACIÓN 3: DIAGRAMA DE FLUJO DEL APRENDIZAJE NO SUPERVISADO

5.1.c Aprendizaje de refuerzo

El aprendizaje de refuerzo es un modelo de aprendizaje conductual. El algoritmo recibe retroalimentación del análisis de datos, conduciendo al usuario hacia el mejor resultado. El aprendizaje de refuerzo difiere de otros tipos de aprendizaje supervisado, porque el sistema no está entrenado con el conjunto de datos de ejemplo. Más bien, el sistema aprende a través de la prueba y el error. Por lo tanto, una secuencia de decisiones exitosas dará lugar a que el proceso sea reforzado, ya que mejor solución dicho problema.

Los algoritmos de aprendizaje por refuerzo definen modelos y funciones enfocadas en maximizar una medida de “recompensas”, basados en “acciones” y al ambiente en el que el agente inteligente se desempeñará. Este algoritmo es el más apegado a la psicología conductista de los humanos, ya que es un modelo acción-recompensa, que busca que el algoritmo se ajuste a la mejor “recompensa” dada por el ambiente, y sus acciones por tomar están sujetas a estas recompensas. Este tipo de métodos pueden usarse para hacer que los robots aprendan a realizar diferentes tareas. Entre los algoritmos más utilizados podemos nombrar:

- Programación dinámica (Dynamic programming)
- Q-learning
- SARSA

MODELO DE APRENDIZAJE POR REFUERZO



ILUSTRACIÓN 4: DIAGRAMA DE FLUJO APRENDIZAJE POR REFUERZO

5.1.d Deep learning

El deep learning es un método específico de machine learning que incorpora las redes neuronales en capas sucesivas para aprender de los datos de manera iterativa. El deep learning es especialmente útil cuando se trata de aprender patrones de datos no estructurados. Las redes neuronales complejas de deep learning están diseñadas para emular cómo funciona el cerebro humano, así que las computadoras pueden ser entrenadas para negociar con abstracciones y problemas mal definidos. Un niño promedio con cinco años de edad puede reconocer fácilmente la diferencia entre el rostro de su maestro y el rostro del guardia que ayuda a cruzar la calle. Por el contrario, la computadora necesita de mucho trabajo para averiguar quién es quién. Las redes neuronales y el deep learning se utilizan a menudo en el reconocimiento de imágenes, voz y aplicaciones de visión de computadora.




ILUSTRACIÓN 5: CONTEXTO DEL DEEP LEARNING

5.2 Aplicación del machine learning a las necesidades empresariales

El machine learning ofrece un valor potencial a las empresas que tratan de aprovechar el big data y les ayuda a comprender mejor los cambios sutiles en el comportamiento, las preferencias o la satisfacción del cliente. Los líderes de negocios están empezando a descubrir que muchas cosas que están sucediendo dentro de sus organizaciones e industrias no pueden ser entendidas a través de una consulta. No son las preguntas que sabe, pero son los patrones ocultos y las anomalías escondidas en los datos lo que pueden ayudarlo o dañarlo.

La ventaja del machine learning es que es posible aprovechar algoritmos y modelos para predecir resultados. El truco es asegurarse de que los científicos de datos que realizan el trabajo usen los algoritmos correctos, asimilando los datos más apropiados (que sean precisos y limpios) y utilizando los mejores modelos de rendimiento. Si todos estos elementos se reúnen, es posible entrenar continuamente al modelo y aprender de los resultados al aprender de los datos. La automatización de este proceso de modelado, entrenamiento del modelo y pruebas conduce a predicciones precisas para dar soporte a los cambios empresariales.




ILUSTRACIÓN 6: INTELIGENCIA ARTIFICIAL

5.2.a Acercando el Machine learnign a las empresas

¿Qué estas tratando de hacer?

Algunos proyectos son más adecuados para el aprendizaje automático (ML) o las técnicas de aprendizaje profundo (DL) .

Aquí presentamos 6 tareas comunes:

- Predecir una salida
- Identificar objetos
- Moverse físicamente o en una simulación.
- Descubrir tendencias
- Mejorar imágenes o señales
- Responde al discurso o al texto

Si bien una sola tarea podría ser más adecuada para el aprendizaje automático, su aplicación completa podría incluir múltiples pasos que, en conjunto, son más adecuados para el aprendizaje profundo.

Una tarea importante para la empresa es decidir utilizar el Machine learning o el Deep Learnign, el cual tiene sus características de funcionamiento según el tipo de dato y el resultado esperado.

Por ejemplo, si queremos identificar que animales estamos observando en la figura 7,, nosotros como humanos, hemos aprendido a través del tiempo a identificar los caracteres de los gatos y de los perros, pero aun así podemos cometer un error en su categorización. Bueno el ML también puede adoptar un error al enseñar de forma incorrecta las características de lo queremos catalogar o aprender a identificar.




ILUSTRACIÓN 7: IMAGEN ANIMALES

Este es un ejemplo de cómo las características o etiquetas que se entregan al ML logra entender un patrón para identificar en una imagen un reconocimiento o detección de objeto.




ILUSTRACIÓN 8: DETECCIÓN DE OBJETO

Quando queremos resolver un problema de ML, seguimos el flujo específico, cargamos las imágenes, y luego damos estructura al modelo a seguir, creamos y estructuramos el modelo que describe o predice al objeto. Y por otro lado con DP da un esquema el cual puede predecir el objeto a detectar.



ILUSTRACIÓN 9: DECISIÓN DE ML




ILUSTRACIÓN 10: APRENDIZAJE REDES NEURONALES

El DP es un subtítulo del ML y su uso dependerá del Hardware y datos a utilizar.




ILUSTRACIÓN 11: CAMINO DE DECISIÓN

	Machine Learning	Deep Learning
Training dataset	Small	Large
Choose your own features	Yes	No
# of classifiers available	Many	Few
Training time	Short	Long


ILUSTRACIÓN 12: TABLA COMPARATIVA ML VS DL

A continuación, damos algunos ejemplos prácticos de soluciones basados en Machine Learning o Deep Learning

TABLA 1: EJEMPLOS PRACTICOS DE ML

Tareas PREDICE una salida basada en datos históricos y actuales Ejemplo: utilice datos de sensores en tiempo real de un motor para predecir la vida útil restante de la maquinaria en rotación. El ejemplo de estimación de vida útil remanente basada en similitud utiliza regresión lineal. Aplicaciones: Mantenimiento predictivo, trading financiero, sistemas de recomendación. Entrada: datos del sensor, datos financieros con marca de tiempo, datos numéricos Algoritmos comunes: regresión lineal, árboles de decisión, máquinas	
--	--

de vectores de soporte (SVM), redes neuronales, reglas de asociación
Enfoque típico: el aprendizaje automático es más común.



Tareas

IDENTIFICAR objetos o acciones en datos de imagen, video y señal

Ejemplo: crear una aplicación de visión artificial que pueda detectar vehículos. El ejemplo de Detección de objetos usando un aprendizaje más rápido de R-CNN utiliza una red neuronal convolucional.

Aplicaciones: asistencia avanzada para el conductor (ADAS) con detección de objetos, robótica, percepción de visión computarizada para el reconocimiento de imágenes, detección de actividad, biometría de voz (huella de voz)

Entrada: Imágenes, videos, señales.

Algoritmos comunes: CNNs, clustering, Viola-Jones

Enfoque típico: el aprendizaje profundo es más común



Tareas

MUEVE un objeto físicamente o en una simulación.


Ejemplo: realice una planificación de ruta robótica para aprender la mejor ruta posible hacia un destino. El envío de intercambio de archivos de aprendizaje de refuerzo (Q-Learning) utiliza una red Q profunda.

Aplicaciones: Sistemas de control, robótica en la fabricación, automóviles autodirigidos, drones, videojuegos.

Entrada: modelos matemáticos, datos de sensores, videos, datos lidar

Algoritmos comunes: aprendizaje por refuerzo (redes Q profundas), redes neuronales artificiales (ANN), CNN, redes neuronales recurrentes (RNN)

Enfoque típico: el aprendizaje profundo es más común



Tareas

Descubrir tendencias, sentimientos, fraudes o amenazas.

Ejemplo: Determine cuántos temas están presentes en los datos de texto. El ejemplo Analizar datos de texto usando modelos de temas utiliza el modelo de tema de asignación de Dirichlet latente (LDA).

Aplicaciones: Procesamiento de lenguaje natural para registros de seguridad, investigación de mercado o médica, análisis de sentimientos, ciberseguridad, resumen de documentos.


Entrada: transmisión de datos de texto, datos de texto estático

Algoritmos comunes: RNN, regresión lineal, SVM, Bayes ingenuo, asignación de Dirichlet

Topic 1



Topic 2





Topic 3



Topic 4



latente, análisis semántico latente, word2vec Enfoque típico: el aprendizaje automático es más común.	
Tareas MEJORAR las imágenes y señales Ejemplo: crear imágenes de alta resolución a partir de imágenes de baja resolución. El ejemplo de súper resolución de una sola imagen que usa Deep Learning utiliza una red neuronal de súper resolución (VDSR) muy profunda. Aplicaciones: Mejora la resolución de la imagen, denoise señales en audio. Entrada: Imágenes y datos de señal. Algoritmos comunes: LSTM, CNNs, red neuronal VDSR Enfoque típico: el aprendizaje profundo es más común	
Tareas RESPONDE a los comandos de voz o texto basados en el contexto y las rutinas aprendidas Ejemplo: reconocer automáticamente los comandos hablados como "on", "off", "stop" y "go". El ejemplo de Reconocimiento de comando de voz usando Aprendizaje profundo usa una CNN. Aplicaciones: llamadas de atención al cliente, dispositivos inteligentes, asistentes virtuales, traducción automática y dictado. Entrada: Datos acústicos, datos de texto. Algoritmos comunes: RNNs (algoritmos LSTM en particular), CNNs, word2vec Enfoque típico: ninguno de los dos es más común	

Fuentes: (Mathworks) (Miriadax, s.f.) (learning) (principiantes)

5.2.c Instrumentos que facilitan el uso de ML en la empresa

En esta sección revisaremos el Cuadrante Mágico con el cual se evalúa a los proveedores de plataformas de ciencia de datos y aprendizaje automático (ML). Estos son productos de software que permiten a científicos expertos en datos, científicos de datos ciudadanos y desarrolladores de aplicaciones crear, implementar y administrar sus propios modelos analíticos avanzados.

Definimos una plataforma de ciencia de datos como:

Una aplicación de software cohesiva que ofrece una mezcla de componentes básicos para crear todo tipo de soluciones de ciencia de datos, y para incorporar esas soluciones en procesos de negocios, infraestructura y productos circundantes.




ILUSTRACIÓN 13: GARTNER HERRAMIENTAS ML

Ahora vamos a analizar a los principales competidores:

Fortalezas y precauciones de los proveedores

A) ALTERYX

Alteryx tiene su sede en Irvine, California, EE. UU. Ofrece cuatro productos de software, que comprenden su plataforma de ciencia de datos. La plataforma de análisis de Alteryx incluye Alteryx Connect, Alteryx Designer, Alteryx Server y Alteryx Promote.

Alteryx ha pasado de ser un Líder a un Challenger manteniendo su posición de Habilidad para Ejecutar, pero demostrando menos visión en relación con muchos otros proveedores en este Cuadrante Mágico. Sin embargo, el énfasis de Alteryx en hacer que la ciencia de la información sea accesible para los científicos de datos ciudadanos y otros a lo largo del proceso analítico de extremo a extremo está resonando en el mercado. Su enfoque proporciona una extensión natural para una base de clientes enfocada en la preparación de datos pero lista para dar el siguiente paso hacia la ciencia de datos. La falta de innovación, en relación con otros, también contribuye a la nueva posición de Alteryx como Challenger.

Fortalezas

- **Habilitación colaborativa de una amplia base de usuarios:** el enfoque sin código de Alteryx es atractivo para un amplio espectro de usuarios, desde analistas de negocios y datos hasta científicos de datos ciudadanos. Un enfoque en la facilidad de uso y la cohesión de su plataforma permite la colaboración entre los usuarios.
- **Canalización de extremo a extremo:** Alteryx se ha centrado en ofrecer una plataforma completa de ciencia de datos de extremo a extremo. Ha añadido dos nuevos productos a su plataforma. Alteryx Connect se centra en las conexiones de datos, el descubrimiento de datos y las conexiones sociales. Alteryx Promote incorpora la adquisición Yhat de Alteryx y se enfoca en la operacionalización del contenido analítico.
- **Ejecución de marketing:** el enfoque de Alteryx en abordar el proceso analítico de extremo a extremo lo posiciona de manera fácil y clara como un proveedor de una plataforma integral. La propuesta de valor de Alteryx es clara y resonante.
- **Gran experiencia del cliente:** Alteryx obtuvo un puntaje en el primer cuartil de la experiencia del cliente en la encuesta de clientes de referencia. Las puntuaciones fueron consistentemente altas para la experiencia general del cliente, los planes para realizar inversiones adicionales, la inclusión de mejoras en los productos y las funciones solicitadas en versiones posteriores y las capacidades generales del producto.

Precauciones

- **Preparación de datos heredada y percepción del mercado:** aunque Alteryx ha creado una marca sólida al proporcionar la preparación de datos de autoservicio, muchos clientes potenciales no están familiarizados con la creación de modelos y las capacidades de operacionalización proporcionadas.

A pesar del progreso, la reputación "heredada" de la compañía continúa ocultando su propuesta de valor total.

- Innovación: los puntajes de innovación de Alteryx fueron bajos, en relación con otros proveedores en este Cuadrante Mágico. Alteryx no es un proveedor destacado en términos de automatización, aprendizaje profundo o Internet de las cosas (IoT).
- Entendimiento del mercado: Alteryx obtuvo un puntaje por debajo del promedio para el entendimiento del mercado. Se dirige principalmente a los científicos de datos ciudadanos y a los científicos de datos de nivel de entrada, y no atiende de manera significativa a los científicos expertos en datos de vanguardia o centrados en el código.

B) DATABRICKS

Databricks tiene su sede en San Francisco, EE. UU. Su plataforma de análisis unificado basada en Apache Spark combina capacidades de ingeniería de datos y ciencia de datos que utilizan una variedad de lenguajes de código abierto. Además de Spark, la plataforma proporciona características patentadas de seguridad, confiabilidad, operatividad, rendimiento y habilitación en tiempo real en los servicios web de Amazon (AWS). Azure Databricks, que estuvo disponible generalmente en marzo de 2018, es un servicio integrado dentro de Microsoft Azure que proporciona una plataforma basada en Apache Spark de alto rendimiento optimizada para Azure.

Databricks sigue siendo un Visionario al proporcionar soporte para el ciclo de vida analítico de extremo a extremo, entornos de nube híbrida y accesibilidad para una amplia variedad de usuarios. Un enfoque en la innovación y una oferta de productos consistentemente sólida y completa han permitido a Databricks mejorar su posición tanto para la Capacidad de Ejecución como para la Integridad de la Visión.

Fortalezas

- Innovación: la amplitud y la facilidad de integración de código abierto, las capacidades de transmisión de IoT y las capacidades de operacionalización son diferenciadores clave para Databricks. Su plataforma se extiende a las capacidades de código abierto al proporcionar el marco necesario para la escalabilidad, el rendimiento y la operatividad de la empresa de extremo a extremo. Databricks Delta, lanzado en octubre de 2017, proporciona un servicio en la nube administrado para la administración de datos unificados con soporte para análisis de secuencias y ML. MLflow, lanzado en junio de 2018, incluye soporte para experimentación, reproducibilidad y despliegue. El Tiempo de ejecución de Databricks para aprendizaje automático ofrece clústeres preconfigurados para un aprendizaje profundo.
- Asociación con Microsoft: Azure Databricks ha ganado rápidamente fuerza dentro de la comunidad de Azure. Azure Databricks agrega una escala global a la efectiva estrategia de marketing y ventas de Databricks. Incluye un espacio de trabajo interactivo y colaborativo para la colaboración entre científicos de

- datos, ingenieros de datos y analistas de negocios, capacidad de entorno de Spark con un solo clic para lanzar, e integración con los componentes de Azure.
- **Apreciación del cliente:** los clientes de referencia encuestados obtuvieron los puntajes de Databricks en el cuartil superior tanto para la experiencia del cliente como para las operaciones. Databricks recibió los puntajes generales más altos tanto por la experiencia general del proveedor como por la calidad de la documentación.

Precauciones

- **Precios y negociación de contratos:** aunque Databricks reduce el costo total de propiedad (TCO) de Spark para cargas comparables, los clientes de referencia de Databricks lo calificaron en el cuartil inferior para la experiencia de evaluación y negociación de contratos y para precios predecibles y controlables. Los clientes expresaron su preocupación por los precios y el valor recibido, en relación con la inversión.
- **Solución de problemas y depuración:** los clientes de referencia de Databricks indicaron dificultades para solucionar errores y depurar aplicaciones. Les gustaría mejorar las ayudas de depuración, así como asistencia para navegar por los errores de Spark.
- **Monitoreo y administración de costos:** los clientes de referencia indicaron la necesidad de mejorar las capacidades para monitorear y administrar los costos entre diferentes grupos de usuarios y administrar cuentas. Databricks recibió el segundo puntaje general más bajo en costos de software continuos predecibles y controlables.

C) DATAIKU

Dataiku tiene su sede en la ciudad de Nueva York, EE. UU., Y tiene una oficina principal en París, Francia. Ofrece Data Science Studio (DSS) con un enfoque en la colaboración interdisciplinaria y la facilidad de uso.

La aparición de Dataiku en el cuadrante Challengers se debe principalmente a su fuerte ejecución y capacidades de fortalecimiento en relación con la escalabilidad. Un enfoque en las capacidades de análisis en tiempo real y la expansión de la amplitud de sus casos de uso podría llevar a Dataiku al cuadrante de líderes. La facilidad de uso y la colaboración entre los roles de ciencia de datos y entre equipos de ciencia de datos siguen siendo dos de los principales activos de su plataforma. En 2018, Dataiku se ha ejecutado muy bien en relación con su visión y ha proporcionado capacidades que hacen de DSS una plataforma más madura.

Fortalezas

- **Colaboración en roles de ciencia de datos:** desde su inicio, el trabajo en equipo ha sido el núcleo de la plataforma DSS de Dataiku. Desde ingenieros de datos a científicos de datos, expertos en la materia y científicos de datos ciudadanos, todos los roles principales involucrados en el desarrollo de modelos de ML tienen su lugar en la plataforma. Ofrece varios puntos finales de interfaz de usuario, todos apuntando al mismo núcleo de ejecución, lo que lo convierte en una de las ofertas más coherentes en este Cuadrante Mágico.

- **Facilidad de uso:** las cualidades de Dataiku más destacadas por los clientes son que su plataforma es relativamente fácil de aprender y que proporciona un camino rápido hacia la productividad. Las capacidades de ML automatizadas y la posibilidad explícita de entregar rápidamente modelos interpretables también contribuyen a la sensación intuitiva de la plataforma y a la corta curva de aprendizaje. Esta calidad accesible no impide que los expertos y científicos de datos experimentados utilicen capacidades de desarrollo tipo notebook que puedan complementar la productividad general del equipo.
- **Capacidades de operacionalización:** la operacionalización es el área en la que DSS ha hecho el mayor progreso en el último año. Dataiku ahora incluye la gestión y supervisión de modelos como opciones de implementación flexibles. La visión de la tubería del proceso de la ciencia de la información lógica y la coherencia en torno a los diversos roles a lo largo de ese proceso, forman una base sólida para capacidades de operacionalización más completas.

Precauciones

- **Escalabilidad de los modelos en producción:** a pesar de las capacidades de operacionalización de modelos recientemente mejoradas de Dataiku, algunos clientes aún buscan una experiencia más fluida y menos manual con mejores funciones de visualización para que los modelos entren en producción. Los clientes de referencia informaron que incluso las nuevas capacidades de implementación del modelo no siempre se entregan como se anuncia.
- **Precio y licencias:** los clientes de Dataiku a menudo reportan una experiencia de ventas subóptima, algunos consideran que la compañía es costosa, algunos lamentan la falta de visibilidad de precios y otros se sienten frustrados por las estructuras de precios engorrosas. Se sabe que la confusión sobre los precios y las licencias de Dataiku retrasa el ciclo de ventas.
- **Streaming y el IoT:** Al estar centrado en la facilidad de uso y la colaboración entre roles, el DSS de Dataiku parece ser el preferido de las organizaciones centradas en el servicio. Esto también podría explicarse por el hecho de que Dataiku no ofrece capacidades y funciones de IoT sólidas, incluso si ha demostrado que su plataforma puede operar en entornos exigentes e informáticos.

D) GOOGLE

Google, una subsidiaria de Alphabet, tiene su sede en Mountain View, California, EE. UU. Las ofertas de su plataforma ML principal incluyen Cloud ML Engine, Cloud AutoML, el código abierto TensorFlow y el recientemente anunciado BigQuery ML. Sus componentes ML requieren otros componentes de Google para las capacidades de extremo a extremo, como Google Cloud Dataprep, Google Datalab, Google BigQuery, Google Cloud Dataflow, Google Cloud Dataproc, Google Data Studio, Kubeflow y Google Kubernetes Engine. La mayoría de estos componentes requieren la presencia de Google Cloud Platform (GCP). Las siguientes herramientas de ML no estaban disponibles en general en el punto de corte para una inclusión completa en esta evaluación: Cloud AutoML, Google Data Studio, Kubeflow Pipelines, AI Hub y BigQuery ML. Como tal, estas herramientas no se pudieron incluir en la calificación de

Habilidad para Ejecutar, pero sí contribuyeron a la posición de Google para la Integridad de la Visión.

Fortalezas

- Amplia gama de ofertas: Google ofrece un rico ecosistema de productos y soluciones de inteligencia artificial, que van desde el hardware (Unidad de Procesamiento de Tensor [TPU]) y el crowdsourcing (Kaggle) hasta los componentes ML de clase mundial para procesar datos no estructurados como imágenes, videos y texto. Google también es uno de los pioneros del ML automatizado (con Cloud AutoML). Sobresale aún más con su oferta de código abierto TensorFlow de código abierto para redes neuronales profundas.
- Escalabilidad y velocidad: la mayoría de los componentes ML de Google están diseñados para ejecutarse a gran escala en su entorno público de alto rendimiento, GCP. Ofrece un entorno totalmente gestionado en el que ML puede implementarse a escala, que en este momento compiten con otras compañías. TensorFlow y Kubernetes de Google son las opciones más populares para muchas nuevas empresas de AI y para los equipos universitarios de vanguardia de AI y ciencia de datos.
- Orientado a los desarrolladores: con Cloud AutoML y la mayoría de sus otras herramientas, Google ofrece una solución de software de alta calidad para los científicos que no trabajan con datos, especialmente los desarrolladores de software. Los usuarios de GCP familiarizados con las herramientas de GCP tendrán cada vez menos razones para buscar capacidades de ML en otros lugares. Las cosas mejorarán aún más con la incorporación de las próximas capacidades de AutoML y la funcionalidad local (como las de Kubeflow con sede en Kubernetes).

Precauciones

- Falta de una oferta de ML a extremo, coherente y fácil de usar: la tercera ventaja mencionada anteriormente también representa el mayor inconveniente para dos grandes grupos de constituyentes de la ciencia de datos: científicos de datos centrales que no están familiarizados con el PCG y (aún más) así los científicos de datos ciudadanos orientados a los negocios. Para esos usuarios, la curva de aprendizaje de algunas herramientas de Google puede ser pronunciada. Está muy fragmentado y fácilmente se vuelve abrumador, especialmente para los muchos científicos de datos informales que dedican solo del 15% al 20% de su tiempo en proyectos de ML clave.
- Capacidades locales actualmente limitadas: los usuarios que requieren capacidades locales completas solo pueden usar el TensorFlow de fuente abierta y el Kubeflow basado en Kubernetes de Google. Sin embargo, la mayoría de las otras herramientas de desarrollo y componentes de ML precompilados residen completamente en la nube y, por lo tanto, son menos adecuadas para las muchas organizaciones que prefieren llevar a cabo las capacidades de ML en las instalaciones.
- Instrumentalización, reutilización y transparencia de proyectos de bajo nivel: incluso los desarrolladores de GCP encontrarán poco apoyo para la creación y reutilización de tuberías de ML largas. La cadena de herramientas y los

conceptos simplemente todavía no permiten la noción de proyectos de LD de extremo a extremo. Google también hace un uso intensivo del arsenal de código abierto de los componentes de ML, pero ofrece poco o ningún soporte de gestión de proyectos coherente. Las nuevas tuberías de Kubeflow de Google pueden abordar algunas de estas deficiencias, pero no se pudo evaluar ya que su anuncio se produjo después de la fecha límite para este Cuadrante Mágico.

E) H2O.AI

H2O.ai tiene su sede en Mountain View, California, EE. UU. Y ofrece el Aprendizaje automático de fuente abierta H2O (H2O, Sparkling Water y H2O4GPU) de código abierto y un producto comercial llamado H2O Driverless AI. La fuerza principal de H2O son sus componentes ML de alto rendimiento, que están estrechamente integrados en varias plataformas de la competencia evaluadas en este Cuadrante Mágico.

H2O.ai ha perdido algo de terreno en términos de capacidad de ejecución en relación con otros proveedores en este Cuadrante Mágico, en gran parte debido a puntuaciones comparativamente bajas de clientes de referencia para varias capacidades críticas. Aunque la Integridad de la Visión de H2O.ai aún es sólida, los competidores se están poniendo al día en varias áreas clave de innovación. Esto ha dado lugar a su nuevo estatus como Visionario.

Fortalezas

- Componentes ML de alto rendimiento: Los componentes ML de código abierto de H2O.ai son efectivamente un estándar de la industria, con muchas otras plataformas que los integran (por ejemplo, los de Alteryx, Dataiku, Domino, IBM, KNIME, RapidMiner y TIBCO Software). Los componentes de H2O.ai están altamente optimizados y paralelos para configuraciones multinúcleo y multinodo de CPU. H2O4GPU ofrece una capa de software para una aceleración de GPU significativa.
- Innovación: Con su capa de aprendizaje profundo (Deep Water), su capa GPU y sus capacidades de automatización (H2O Driverless AI), H2O.ai supera a la mayoría de sus competidores en el empleo de capacidades de tecnología de vanguardia. Ningún otro proveedor en este Cuadrante Mágico obtuvo calificaciones más altas de los clientes de referencia en el área de la hoja de ruta del producto y la visión futura.
- Automatización: con su producto comercial, H2O Driverless AI, H2O.ai estableció una posición de primer nivel en el dominio de ML automatizado, siendo rivalizado solo por unos pocos seleccionados. El producto proporciona ingeniería de características automatizada, selección de modelos y ajuste de hiperparámetros. La inteligencia artificial sin controlador es altamente escalable, pero también muy informática, y exporta la canalización completa como objetos MOJO / POJO o como canalización de puntuación Python. H2O.ai también ofrece una versión de código abierto de ciencia de datos aumentada y ML, llamada AutoML, que parece mucho menos potente, pero que se puede usar desde su plataforma de software de código abierto.

Precauciones

- Curva de aprendizaje empinada para los no desarrolladores para utilizar la oferta de código abierto: la versión de código abierto de H2O sigue siendo muy centrada en las computadoras portátiles y, por lo tanto, está más dirigida a los desarrolladores expertos en ciencia de datos y a los científicos de datos pesados en codificación. La usabilidad se mejora cuando hay una interfaz de apuntar y hacer clic, como con las ofertas de KNIME y RapidMiner. El producto H2O Driverless AI de H2O.ai es mucho más sencillo de usar, pero es un producto distinto de su oferta de código abierto.
- Poca interoperabilidad nativa entre H2O Driverless AI y la plataforma de código abierto: la línea de productos de código abierto de H2O.ai no es totalmente interoperable con H2O Driverless AI, que es un impedimento para la posible colaboración de usuarios empresariales con habilidades diferentes.
- Falta de algunas capacidades del producto: los clientes de referencia encuestados de H2O.ai identificaron deficiencias en capacidades críticas como la plataforma, el proyecto y la gestión de modelos, y una falta significativa de funciones para el acceso y preparación de datos, en comparación con otras plataformas en este Cuadrante Mágico. H2O.ai mantuvo excelentes marcas solo en las categorías de capacidad crítica de ML, rendimiento y entrega.

F) KNIME

KNIME tiene su sede en Zurich, Suiza. Proporciona la plataforma de análisis KNIME de forma totalmente abierta de forma gratuita, mientras que el servidor KNIME, una extensión comercial, ofrece funciones más avanzadas, como las capacidades de equipo, automatización y despliegue.

KNIME sigue siendo un Líder en este Cuadrante Mágico. Esto se debe en gran parte a las fuertes evaluaciones de sus clientes, su oferta de productos competitivos y su visión, que es una de las más equilibradas en este mercado.

Fortalezas

- Ejecución y visión bien equilibradas: con una gran cantidad de funciones bien integradas, KNIME mantiene su reputación de ser la “navaja del ejército suizo” del mercado. Su plataforma de análisis gratuita y de código abierto de KNIME cubre el 85% de las capacidades críticas, y las de KNIME. La visión y la hoja de ruta son tan buenas o mejores que las de la mayoría de sus competidores.
- Sofisticación con una combinación clara de productos y un bajo costo total de propiedad: incluso con funciones avanzadas como la automatización ML, la nube híbrida, la gestión de nuevos modelos (KNIME Model Process Factory) y la implementación, la segmentación de productos de KNIME ha sido clara y simple durante muchos años. Esta simplicidad no impide que los científicos de datos exploten funciones analíticas avanzadas (como el aprendizaje profundo), simplemente hace que ese poder sea accesible también para los científicos de datos ciudadanos.
- Facilidad de uso para aquellos con habilidades intermedias: la plataforma de KNIME aborda muy bien el espectro de habilidades de los usuarios intermedios, y KNIME recientemente comenzó a poner mayor énfasis en dos de los otros segmentos de habilidades. Los usuarios menos cualificados apreciarán las

ofertas de ML automatizadas incluidas en el servidor KNIME. Los desarrolladores apreciarán la próxima integración Python de KNIME, que les ofrecerá una integración bidireccional a través de la capacidad de llamar a la API KNIME desde Python / Jupyter para utilizar muchos de los miles de módulos y soluciones KNIME.

- Baja barrera de entrada y TCO: como en años anteriores, los clientes de referencia identificaron sus principales razones para seleccionar la plataforma KNIME como su bajo TCO, costos predecibles y relación calidad-precio.

Precauciones

- Rendimiento y escalabilidad: aunque KNIME ha dado pasos importantes para mejorar su rendimiento y escalabilidad, estas capacidades siguen siendo, con mucho, la principal preocupación de los clientes en términos de capacidades generales del producto. KNIME recibió una de las puntuaciones generales más bajas de las referencias de clientes en esta categoría.
- Visibilidad limitada como plataforma moderna de ciencia de datos: KNIME no tiene reputación de ofrecer una plataforma de ciencia de datos de vanguardia. Esto se debe mucho más a su estrategia de marketing conservadora y al enfoque pasivo de salida al mercado que a sus capacidades reales. Las limitaciones de rendimiento y la reputación de ser una herramienta de escritorio también contribuyen a que la plataforma a veces se pase por alto para implementaciones de ciencia de datos a gran escala.
- Tracción limitada en el dominio de IoT: el análisis en tiempo real y las capacidades vinculadas a los datos de IoT a menudo requieren una cantidad significativa de inversión en desarrollo. A pesar de tener una amplitud decente de casos de uso, el enfoque de KNIME parece no haber sido en industrias centradas en los activos (que representan la mayor parte del trabajo de IoT). A medida que el mercado evoluciona para abarcar múltiples fuentes de datos, esta falta de enfoque podría afectar la visión de la compañía.
- Equipo relativamente pequeño: Gartner tiene reservas sobre la estrategia de KNIME de tener un equipo relativamente pequeño de menos de 60 equivalentes a tiempo completo. Dada la creciente complejidad de la pila ML, es poco probable que un equipo pequeño pueda hacer frente a la innovación masiva que está transformando este mercado.

G) MATHWORKS

MathWorks tiene su sede en Natick, Massachusetts, EE. UU. Sus dos productos principales son MATLAB y Simulink, pero solo MATLAB cumplió con los criterios de inclusión para este Cuadrante Mágico.

El cambio de MathWorks desde el cuadrante Challengers al cuadrante de visionarios se debe esencialmente a la notable fortaleza de la compañía en relación con las necesidades cada vez más exigentes de las industrias centradas en los activos. Para atender a este mercado en crecimiento, MathWorks ha fortalecido la coherencia de la plataforma MATLAB para su audiencia centrada en la ingeniería al integrar a la perfección la funcionalidad avanzada para el tratamiento de fuentes de datos no convencionales (imágenes, video y datos de IoT). Aunque MathWorks se enfoca en industrias

centradas en activos, también tiene clientes en el sector de servicios financieros.

Fortalezas

- Coherencia y facilidad de uso de la plataforma: Construido desde una perspectiva de ingeniería, MATLAB ofrece una experiencia perfecta, con la operacionalización como un paso totalmente integrado. Enfocado principalmente en aplicaciones industriales, MathWorks toma en cuenta las experiencias del personal de campo y los expertos en la materia a través de un enfoque de "ingeniero ciudadano" destinado a democratizar el despliegue de su plataforma. El apoyo para esta comunidad también se asegura a través de un rico ecosistema comunitario.
- Preparación de los datos: en su flujo de trabajo analítico, MATLAB no separa de manera explícita el ML y las técnicas de aprendizaje profundo, ya que los algoritmos se consideran adecuados para resolver problemas específicos. Por lo tanto, la plataforma de MathWorks ofrece sofisticadas capacidades de preparación y etiquetado de datos para los datos que se utilizarán para crear modelos de aprendizaje profundo.
- Funcionalidad avanzada: MathWorks ha integrado en MATLAB una gama de técnicas avanzadas que se pueden usar en casos de uso complejos. Algunos ejemplos son las experiencias de notebook interpretadas (a través de MATLAB Live Editor), los modelos pre-entrenados de aprendizaje profundo, el análisis integrado en tiempo real, las capacidades de transmisión y las técnicas de simulación (a través de modelos digitales-gemelos).

Precauciones

- Falta de enfoque en organizaciones centradas en el servicio: aunque nada impide que los no ingenieros utilicen MATLAB, la visión de MathWorks para la ciencia de la información no se centra en el marketing, las ventas o el servicio al cliente. Los equipos de ciencia de datos cuyo enfoque principal es marketing, ventas o servicio al cliente deben buscar plataformas alternativas.
- Soporte completo de la plataforma en la nube: MATLAB ofrece un soporte sólido para AWS y Microsoft Azure, pero aún carece de soporte completo para GCP. Si bien los entornos como el TensorFlow generalizado son compatibles con MATLAB, los equipos de ciencia de la información que dependen de la estrecha integración entre TensorFlow y GCP podrían no beneficiarse del rendimiento que se suele demostrar en los marcos de Google.
- Capacidades de AutoML: MathWorks ha mejorado considerablemente su acceso a bibliotecas y entornos de código abierto en la última versión de MATLAB. Sin embargo, en comparación con algunos de sus competidores más visionarios, MathWorks aún carece de una clara visión de integración en relación con las capacidades de AutoML.

H) MICROSOFT

Microsoft tiene su sede en Redmond, Washington, EE. UU. Proporciona una serie de productos de software para la ciencia de datos y ML. En la nube, ofrece Azure Machine Learning (incluido Azure Machine Learning Studio),

Azure Data Factory, Azure HDInsight, Azure Databricks y Power BI. Para cargas de trabajo locales, Microsoft ofrece Servidor de aprendizaje automático. Solo Azure Machine Learning cumplió con los criterios de inclusión para este Cuadrante Mágico, aunque las ofertas más amplias de Microsoft influyeron en nuestras evaluaciones de las capacidades ampliadas de Azure Machine Learning y la Completeness of Vision de Microsoft.

Microsoft sigue siendo un Visionario, habiendo mantenido un fuerte compromiso con la amplitud y facilidad de integración de la tecnología de código abierto y la excelencia en relación con el aprendizaje profundo. Azure Machine Learning no es una opción para los muchos equipos de ciencia de datos y casos de uso que requieren un producto estrictamente local.

Fortalezas

- Enfoque de infraestructura en la nube: aunque sigue habiendo un número significativo de devotos locales, más organizaciones están migrando a la nube y enfoques híbridos a la ciencia de datos. El enfoque en la nube de primera clase de Microsoft con Azure Machine Learning proporciona un entorno de alto rendimiento totalmente gestionado. La plataforma en la nube también ofrece ventajas en términos de ajuste de rendimiento, escalabilidad y compatibilidad ágil para la tecnología de código abierto.
- Amplia oferta de componentes y socios: el ecosistema de Azure ofrece una amplia gama de componentes para casos de uso de la ciencia de la información como el análisis de secuencias (Azure Stream Analytics), el IoT (Azure IoT Hub) y el aprendizaje profundo (Microsoft Cognitive Toolkit y varios marcos de código abierto). Azure Databricks ofrece a los clientes de Microsoft soporte de primera clase para Apache Spark e integración con las herramientas de Azure, y varios clientes de referencia elogiaron el escalado automático y la optimización del rendimiento de la plataforma.
- Soporte para diversas personas dedicadas a la ciencia de la información: el servicio Azure Machine Learning ofrece un enfoque centrado en el código para científicos expertos en datos, y Azure Machine Learning Studio ofrece una GUI altamente calificada para científicos de datos ciudadanos. Azure Cognitive Services ofrece una funcionalidad sólida y modelos pre-entrenados para desarrolladores. Los expertos en datos e ingenieros de datos serán atraídos por la oferta de Azure Databricks. Una mayor integración con Power BI ofrece ML de nivel de entrada a las masas de analistas de negocios.

Precauciones

- Aplicabilidad solo en la nube: el enfoque solo en la nube de Microsoft con Azure Machine Learning continúa limitando ciertas capacidades y reduce el atractivo del producto para algunos equipos de ciencia de datos. El servicio Azure Machine Learning, un producto híbrido para crear y desplegar modelos en las instalaciones, en la nube y en el borde, se lanzó en diciembre de 2018, después de la fecha límite para su inclusión en esta evaluación.
- Automatización y aumento: Microsoft necesita mantenerse al día con los innovadores en la automatización y asistencia con las tareas de la ciencia de datos. Se necesitarán características nuevas y mejoradas para mantener una

posición competitiva en el mercado de la ciencia de la información ciudadana en rápido movimiento y para atraer a los expertos en datos que los científicos utilizan el ML automatizado para acelerar su trabajo. Las nuevas capacidades de ML automatizadas en el servicio Azure Machine Learning se lanzaron en diciembre de 2018, después del período de evaluación para este Cuadrante Mágico.

- Coherencia: aunque el ecosistema de Azure ofrece diversas herramientas y enfoques para la ciencia de datos, muchos usuarios encuentran la cantidad de componentes abrumadora y se sienten frustrados por la experiencia general del usuario.

I) SAS

SAS tiene su sede en Cary, Carolina del Norte, EE. UU. Ofrece muchos productos de software para análisis y ciencia de datos. Para este Cuadrante Mágico, evaluamos SAS Enterprise Miner (EM) y SAS Visual Data Mining and Machine Learning (VDMML).

SAS mantiene su estado de larga data como líder. Si bien la compañía enfrenta amenazas en múltiples frentes de otros grandes proveedores, interruptores maduros y soluciones de código abierto, mantiene una fuerte presencia en el mercado. Completeness of Vision de SAS pertenece a la misma clase que muchos competidores altamente innovadores, pero la compañía se está quedando atrás en áreas clave como el aprendizaje profundo y las contribuciones a la comunidad de código abierto. Su capacidad de ejecución se ve obstaculizada por costos altos y, a veces, impredecibles, que hacen que los clientes existentes y potenciales exploren otras opciones. Al igual que otros veteranos del mercado de la ciencia de la información, además de centrarse en nuevos clientes, SAS está asumiendo el reto de apoyar a los clientes y usuarios heredados mientras se adapta a un panorama que cambia rápidamente.

Fortalezas

- Presencia en el mercado y marca de confianza: la larga presencia en el mercado de SAS y su considerable capacidad de permanencia le han ganado mucho respeto por parte de los clientes. Muchos clientes de referencia elogiaron la calidad, estabilidad y confiabilidad de sus productos. Esa solidez podría haber sido a costa de algunos avances (como la rápida adopción de capacidades de código abierto), pero no ha impedido que SAS innovara y se mantuviera a la par con muchos de sus competidores más nuevos.
- Robustez de SAS EM: la fiabilidad de SAS EM en todo el ciclo de vida de la analítica y la ciencia de la información es reconocida en todo el mercado. Desde la ingestión y preparación de datos hasta la producción y el despliegue de modelos, la plataforma continúa brindando resultados confiables. SAS está bien situado para replicar esa extraordinaria fuerza local en un entorno de múltiples nubes.
- Interfaz y capacidades de interacción de datos de SAS VDMML: SAS VDMML recibió excelentes puntajes para la interfaz de usuario y la exploración y

visualización de datos. También recibió fuertes puntajes para la preparación de datos, automatización y aumento. SAS VDMML hace un llamamiento a los científicos de datos ciudadanos, así como a los científicos y desarrolladores de datos centrados en el código.

- Excelencia operativa: la infraestructura global de soporte de SAS es incomparable. Los clientes eligen SAS por sus sólidas capacidades de plataforma de nivel empresarial, que van desde la exploración hasta el modelado y la implementación. SAS también ofrece una importante experiencia analítica y de la industria, en la que los clientes confían. Los clientes de referencia dieron puntajes altos a la documentación de SAS, al soporte de clientes y analíticas, y al servicio y soporte en general.

Precauciones

- Precios y ejecución de ventas: los clientes de referencia de SAS obtuvieron puntajes por la evaluación de productos y la experiencia de negociación de contratos que se encontraban en el cuartil inferior. Además, los precios de SAS siguen siendo una preocupación para los clientes existentes y potenciales: los clientes de Gartner a menudo investigan alternativas menos costosas. Las plataformas gratuitas de ciencia de datos de código abierto se utilizan cada vez más, junto con los productos de SAS, como una forma de controlar los costos, especialmente para nuevos proyectos.
- Coherencia: el complemento completo de productos de SAS es complejo y, a menudo, confuso. Al ofrecer dos plataformas que no son totalmente interoperables y que tienen numerosos componentes adicionales disponibles, aumenta la confusión y la complejidad en términos de administración, implementación y uso de los productos de SAS. La coexistencia de SAS Viya y SAS 9 perpetúa la percepción de una falta de cohesión. Si bien SAS ha avanzado en este sentido, la migración aún se percibe como un problema para aquellos que desean explotar las capacidades de Viya pero actualmente no están en esa arquitectura.
- Interfaz anticuada de SAS EM: SAS EM no ha estado al día con los tiempos y, aunque sigue vigente, tiene una interfaz de usuario con fecha. Su interfaz de usuario contrasta con las de los competidores modernos, que son más intuitivos y más limpios. SAS VDMML ofrece una UI mucho más moderna, que representa la dirección futura de SAS.
- Flexibilidad y soporte adicional para el código abierto: en su última versión, SAS ha agregado más herramientas y soporte para el código abierto, pero a los clientes les gustaría ver que tanto SAS EM como VDMML continúen extendiendo el soporte de primera clase para herramientas de código abierto, bibliotecas y marcos SAS también debe continuar mejorando el soporte para Docker y la contenedorización.

J) SOFTWARE TIBCO

TIBCO Software tiene su sede en Palo Alto, California, EE. UU. A través de la adquisición de reportes empresariales y proveedores de plataformas de BI modernas (Jaspersoft y Spotfire), proveedores de plataformas de análisis descriptivo y predictivo (Statistica y Alpine Data) y un proveedor de análisis

de secuencias (StreamBase Systems) , TIBCO ha construido una plataforma analítica completa y potente.

TIBCO ha pasado del cuadrante Challengers al cuadrante de líderes, gracias a una estrategia de integración bien orquestada que contribuye a su capacidad de ejecución, y sus esfuerzos para mantener el ritmo de la tasa de innovación en este mercado que cambia rápidamente. TIBCO tiene una habilidad distintiva para servir a industrias centradas en activos. Además de contar con capacidades de desarrollo e implementación de extremo a extremo, TIBCO aborda con éxito el dominio de IoT de IoT de ciencia de datos desatendidos, en parte como resultado de sus raíces centradas en el proceso.

Fortalezas

- Consolidación exitosa: en una sola plataforma, TIBCO reúne potentes capacidades de visualización, análisis descriptivo sólido y funciones de análisis predictivo visionario (de Statistica y Alpine Data, ahora con el nombre de Spotfire Data Science). Al mismo tiempo, TIBCO ha mantenido la extensibilidad necesaria de su plataforma a los entornos de código abierto. El código de fuente abierta, por ejemplo, puede desarrollarse dentro de la plataforma o en un entorno externo y luego integrarse sin problemas en el flujo de trabajo del flujo de datos de Data Science.
- “Inteligencia conectada” e IoT: además de un sólido conjunto de conectores y API para datos de máquina, captura de datos en tiempo real y puntuación de modelos, TIBCO ha invertido en IoT edge analytics para brindar a los desarrolladores herramientas para distribuir y monitorear modelos en dispositivos de borde y pasarelas. Además, la combinación de TIBCO Streaming y Statistica es un sólido diferenciador para la estrategia de inteligencia conectada de TIBCO.
- Proceso de ciencia de datos de extremo a extremo: la facilidad de uso general de la plataforma TIBCO (a menudo elogiada por los clientes de referencia) no debe eclipsar la sofisticación y la integridad de su funcionalidad. Los flujos de trabajo visuales que abarcan todo el proceso de la ciencia de datos, desde la ingestión de datos hasta la gestión de modelos, proporcionan una base sólida para la colaboración efectiva de todos los roles (científicos de datos, analistas de negocios, científicos de datos ciudadanos, ingenieros de procesos, etc.).

Precauciones

- Rendimiento y estabilidad: algunos clientes de referencia identificaron casos en los que el rendimiento de la plataforma de TIBCO era subóptimo, y observaron que esto ralentizaba temporalmente su proceso de desarrollo. La próxima integración mejorada con servicios de nube externos, junto con el desarrollo de flujos de trabajo analíticos híbridos, podría aliviar este problema.
- Gestión de datos: TIBCO ofrece sólidas capacidades de visualización y acceso a los datos, pero las capacidades automatizadas y más integradas de preparación y gestión de datos deberían ser parte integral de la plataforma, dado su amplio alcance. Esperamos que TIBCO invierta en esta importante funcionalidad para su próximo lanzamiento.
- Enfoque de operacionalización incompleta: las capacidades de implementación y administración de modelos de TIBCO han mejorado mucho en el último año,

pero aún quedan muchas brechas. Dada la fortaleza de TIBCO en una amplia gama de industrias, las capacidades de operacionalización del modelo más allá del despliegue, es decir, para el proceso completo de gobernanza y ciencia de la información para los modelos en producción, serán cruciales.

Fuente: (Platforms, s.f.)

6 Resultados Obtenidos.

A continuación, daremos ejemplos de usos practicas con ejemplos específicos.

6.1 Uso práctico de las tecnologías disponibles

El objetivo de este apartado es demostrar los usos prácticos y fáciles de las tecnologías anteriormente analizadas.

A continuación, daremos una solución practica para clasificar imágenes de Webcam usando aprendizaje profundo.

6.1.1 Clasificación de imágenes de cámara de video usando Deep Learning mediante MATHWORKS

Para este caso, utilizaremos Mathworks de Matlab, la plataforma amigable y que permite realizar tareas y proyectos a un analista con nociones básicas de programación, los requisitos primarios son:

- Tener conocimientos sobre Software MATLAB R2019a y Programación C++
- MATLAB Support Package for USB Webcams: El paquete de soporte de MATLAB® web compatible con clase de video USB (UVC) a MATLAB. Esto incluye cámaras web que pueden estar integradas en computadoras portátiles u otros dispositivos, así como aquellas que se conectan a su computadora a través del puerto USB. Este paquete de soporte es funcional para R2014a y más allá.
- Deep Learning Toolbox Model for GoogLeNet Network: GoogLeNet es un modelo pre-entrenado que ha sido entrenado en un subconjunto de la base de datos ImageNet que se utiliza en el desafío de reconocimiento visual a gran escala de ImageNet (ILSVRC). El modelo está entrenado en más de un millón de imágenes, tiene 144 capas y puede clasificar las imágenes en 1000 categorías de objetos (por ejemplo, teclado, ratón, lápiz y muchos animales).

A continuación, dejaremos un extracto de código que permite identificar objetos, el lenguaje de programación es C++.

```

%% Classify Webcam Images Using Deep Learning
% This example shows how to classify images from a webcam in real time using the pretrained deep
convolutional neural network GoogLeNet.
%% Use MATLAB(R), a simple webcam, and a deep neural network to identify % objects in your
surroundings. This example uses GoogLeNet, a pretrained % deep convolutional neural network (CNN
or ConvNet) that has been trained % on over a million images and can classify images into 1000
object % categories (such as keyboard, coffee mug, pencil, and many animals). You % can download
GoogLeNet and use MATLAB to continuously process the camera % images in real time.
%% GoogLeNet has learned rich feature representations for a wide range of % images. It takes the
image as input and provides a label for the object % in the image and the probabilities for each
of the object categories. You % can experiment with objects in your surroundings to see how
accurately % GoogLeNet classifies images. To learn more about the network's object %
classification, you can show the scores for the top five classes in real % time, instead of just
the final class decision.
%% Load Camera and Pretrained Network
% Connect to the camera and load a pretrained GoogLeNet network. You can % use any pretrained
network at this step. The example requires MATLAB % Support Package for USB Webcams, and Deep
Learning Toolbox(TM) Model _for % GoogLeNet Network_. If you do not have the required support
packages % installed, then the software provides a download link.
camera = webcam;
net = googlenet;

%% % If you want to run the example again, first run the command |clear % camera| where |camera|
is the connection to the webcam. Otherwise, you % see an error because you cannot create another
connection to the same% webcam. %% Classify Snapshot from Camera % To classify an image, you must
resize it to the input size of the % network. Get the first two elements of the |InputSize|
property of the % image input layer of the network. The image input layer is the first % layer of
the network.

inputSize = net.Layers(1).InputSize(1:2)

%% % Display the image from the camera with the predicted label and its % probability. You must
resize the image to the input size of the network % before calling |classify|.
figure
im = snapshot(camera);
image(im)
im = imresize(im,inputSize);
[label,score] = classify(net,im);
title([char(label),num2str(max(score),2)]);

%% Continuously Classify Images from Camera % To classify images from the camera continuously,
include the previous % steps inside a loop. Run the loop while the figure is open. To stop the
% live prediction, simply close the figure. Use |drawnow| at the end of % each iteration to update
the figure.
h = figure;

while ishandle(h)
    im = snapshot(camera);
    image(im)
    im = imresize(im,inputSize);
    [label,score] = classify(net,im);
    title([char(label), num2str(max(score),2)]);
    drawnow
end

%% Display Top Predictions % The predicted classes can change rapidly. Therefore, it can be
helpful to % display the top predictions together. You can display the top five % predictions and
their probabilities by plotting the classes with the % highest prediction scores.
%% % Classify a snapshot from the camera. Display the image from the camera % with the predicted
label and its probability. Display a histogram of the % probabilities of the top five predictions
by using the |score| output of % the |classify| function.

%% % Create the figure window. First, resize the window to have twice the % width, and create two
subplots.
h = figure;
h.Position(3) = 2*h.Position(3);
ax1 = subplot(1,2,1);
ax2 = subplot(1,2,2);

%% % In the left subplot, display the image and classification together.
im = snapshot(camera);

```

```

%%
% Display the top five predictions as a histogram.
barh(ax2,scoreTop)
xlim(ax2,[0 1])
title(ax2,'Top 5')
xlabel(ax2,'Probability')
yticklabels(ax2,classNamesTop)
ax2.YAxisLocation = 'right';

%% Continuously Classify Images and Display Top Predictions
% To classify images from the camera continuously and display the top
% predictions, include the previous steps inside a loop. Run the loop while
% the figure is open. To stop the live prediction, simply close the figure.
% Use |drawnow| at the end of each iteration to update the figure.

%%
% Create the figure window. First resize the window, to have twice the
% width, and create two subplots. To prevent the axes from resizing, set
% |ActivePositionProperty| to |'position'|.
h = figure;
h.Position(3) = 2*h.Position(3);
ax1 = subplot(1,2,1);
ax2 = subplot(1,2,2);
ax2.ActivePositionProperty = 'position';

%%
% Continuously display and classify images together with a histogram of the
% top five predictions.
while ishandle(h)
    % Display and classify the image

    im = snapshot(camera);
    image(ax1,im)
    im = imresize(im,inputSize);
    [label,score] = classify(net,im);
    title(ax1,{char(label),num2str(max(score),2)});

    % Select the top five predictions
    [~,idx] = sort(score,'descend');
    idx = idx(5:-1:1);
    scoreTop = score(idx);
    classNamesTop = string(classes(idx));

    % Plot the histogram
    barh(ax2,scoreTop)
    title(ax2,'Top 5')
    xlabel(ax2,'Probability')
    xlim(ax2,[0 1])
    yticklabels(ax2,classNamesTop)
    ax2.YAxisLocation = 'right';

    drawnow
end

```

Fuente: (Using)

El resultado del compilado es el que se muestra a continuación:




ILUSTRACIÓN 14: COMPILAR EN MATHWORKS




ILUSTRACIÓN 15: IDENTIFICACIÓN 1 IMAGEN CON MATHW




ILUSTRACIÓN 16: IDENTIFICACIÓN 2 IMAGEN CON MATHW




ILUSTRACIÓN 17: IDENTIFICACIÓN 3 IMAGEN CON MATHW




ILUSTRACIÓN 18: IDENTIFICACIÓN 4 IMAGEN CON MATHW




ILUSTRACIÓN 19: IDENTIFICACIÓN 5 IMAGEN CON MATHW




ILUSTRACIÓN 20: IDENTIFICACIÓN 6 IMAGEN CON MATHW

Como vemos, la imagen que captura una simple webcam, nos permite identificar con margen de error aceptable, objetos particulares, dentro de una zona delimitada. En este caso el pre-entrenamiento que tiene GoogLeNet, nos permite de forma fácil y rápida, utilizar el banco de resultados de imágenes ya tratadas, para que como usuarios consumamos dicho entrenamiento libre, para uso particular.

6.1.2 Herramientas de Machine Learning de Amazon

A continuación, revisaremos una de las soluciones de un monstruo de las tecnologías y de los servicios que prestan, ya cuentan con servicios pre entrenados los cuales tienen sus desarrollos específicos con sus resultados específicos, por lo que nosotros como usuarios, solo debemos cargar el servicio que más se acerque a nuestras necesidades, entre toda la solución Machine Learning encontramos:

- Amazon SageMaker
- Amazon Comprehend
- AWS DeepLens

- Amazon Lex
- Machine Learning
- Amazon Polly
- Rekognition
- Amazon Transcribe
- Amazon Translate
- Amazon Personalize
- Amazon Forecast
- Amazon Textract
- AWS DeepRacer

Describiremos brevemente alguna de ellas y lo acompañaremos de ejemplos de caso de uso.

Amazon Comprehend

Amazon Comprehend utiliza el procesamiento del lenguaje natural (PNL) para extraer información sobre el contenido de los documentos. Procesa cualquier archivo de texto en formato UTF-8. Desarrolla ideas al reconocer, entidades, frases clave, lenguaje, sentimientos y otros elementos comunes en un documento. Se usa generalmente para crear nuevos productos basados en la comprensión de la estructura de los documentos. Por ejemplo, se puede buscar en las fuentes de redes sociales menciones de productos o escanear un repositorio de documentos completo.

Se puede trabajar con uno o más documentos a la vez para evaluar su contenido y obtener información sobre ellos. Algunas de las ideas que Amazon Comprehend desarrolla sobre un documento incluyen:

- ✓ Entidades: devuelve una lista de entidades, como personas, lugares y ubicaciones, identificadas en un documento.
- ✓ Frases clave: extrae frases clave que aparecen en un documento. Por ejemplo, un documento sobre un juego de baloncesto puede devolver los nombres de los equipos, el nombre del lugar y el puntaje final.
- ✓ Idioma: identifica el idioma dominante en un documento. Puede identificar 100 idiomas.
- ✓ Sentimiento: determina el sentimiento emocional de un documento. El sentimiento puede ser positivo, neutral, negativo o mixto.

El funcionamiento de esta solución, se describe en la siguiente grafica.




ILUSTRACIÓN 21: AMAZON COMPREHEND

Algunos Ejemplos de aplicación:

Los siguientes ejemplos muestran cómo puede utilizar las operaciones de Amazon Comprehend en sus aplicaciones.

Ejemplo 1: descubra cómo se sienten los clientes acerca de sus productos

Si su empresa publica un catálogo, esta aplicación le dice qué piensan los clientes sobre sus productos. Se puede complementar cada comentario de los clientes y enviar a la operación DetectSentiment y le informará si los clientes se sienten positivos, negativos, neutrales o mezclados con respecto a un producto.

Ejemplo 2: descubre lo que es importante para tus clientes

Usando el modelado de temas de Amazon Comprehend se puede descubrir los temas de los que hablan sus clientes en sus foros y tableros de mensajes, luego usando la detección de entidades para determinar las personas, los lugares y las cosas que asocian con el tema. Finalmente, usando el análisis de sentimientos para determinar cómo se sienten sus clientes sobre un tema.

Amazon Rekognition

Amazon Rekognition permite añadir fácilmente el análisis de imagen y vídeo en sus aplicaciones. Solo tiene que proporcionar una imagen o un vídeo a la API de Amazon Rekognition y el servicio podrá identificar objetos, personas, texto, escenas y actividades. Asimismo, puede detectar cualquier contenido inadecuado. Amazon Rekognition también proporciona un análisis y reconocimiento facial de alta precisión. Puede detectar, analizar y comparar rostros para una amplia variedad de casos de uso, como la verificación de usuarios, catalogación, contabilización de personas y seguridad pública.

Utiliza la misma tecnología de aprendizaje profundo probada y altamente escalable desarrollada por los científicos de visión artificial de Amazon para analizar miles de millones de imágenes al día. No requiere experiencia en aprendizaje automático. Amazon Rekognition dispone de una API sencilla y fácil de usar que puede analizar rápidamente cualquier archivo de imagen o vídeo almacenado en Amazon S3.

Amazon Rekognition siempre aprende a partir de datos nuevos y continuamente están añadiendo nuevas etiquetas y características de reconocimiento facial al servicio.

Entre los casos de uso comunes de Amazon Rekognition se incluyen los siguientes:

- **Biblioteca de imágenes y vídeo que permiten realizar búsquedas** – permite realizar búsquedas en las imágenes y vídeos almacenados para que pueda detectar los objetos y las escenas que aparecen en ellos.
- **Verificación del usuario basada en el rostro** – permite que sus aplicaciones confirmen las identidades de los usuarios comparando su imagen en vivo con una imagen de referencia.
- **Análisis de emociones y datos demográficos:** - detecta emociones, como felicidad, tristeza o sorpresa, y datos demográficos, como el sexo, en las imágenes faciales. Amazon Rekognition puede analizar imágenes y enviar los atributos de emoción y demográficos a Amazon Redshift para realizar informes periódicos sobre tendencias; por ejemplo, en establecimientos comerciales y situaciones similares. Tenga en cuenta que las predicciones de expresiones emocionales se basan únicamente en la apariencia física del rostro de una persona. No es indicativo del estado emocional interno y Rekognition no debe utilizarse para tomar dicha decisión.
- **Reconocimiento facial** – puede buscar imágenes, vídeos almacenados y vídeos en streaming para detectar rostros que coincidan con los almacenados en un contenedor conocido como colección de rostros. Una colección de rostros es un índice de rostros que usted posee y administra. La identificación de personas en función de su rostro es un proceso que consta de dos pasos principales en Amazon Rekognition:
 1. Indexar las caras, 2. Buscar las caras
- **Detección de contenido no seguro:** puede detectar contenido violento y contenido para adultos en imágenes y vídeos almacenados. Los desarrolladores pueden usar los metadatos devueltos para filtrar contenido inadecuado en función de las necesidades del negocio. Además de marcar una imagen en función de la presencia de contenido para adultos. La API también devuelve una lista jerárquica de etiquetas con puntuaciones de confianza. Estas etiquetas indican categorías específicas de contenido no seguro, lo que permite filtrar con amplio detalle y administrar grandes volúmenes de contenido generado por los usuarios (UGC); por ejemplo, sitios de citas y redes sociales, plataformas de intercambio de datos, blogs y foros, aplicaciones para niños, sitios de comercio electrónico y servicios de entretenimiento y de publicidad online.
- **Reconocimiento de famosos:** puede reconocer famosos en las imágenes y vídeos proporcionados. Es capaz de reconocer miles de famosos de una serie de categorías, como política, deportes, negocios, ocio y medios de comunicación.

- **Detección de texto:** la característica Texto en imágenes de Amazon Rekognition permite reconocer y extraer contenido de texto de las imágenes. Es compatible con la mayoría de las fuentes, incluso las que son muy estilizadas. En las aplicaciones para compartir imágenes y de redes sociales, puede usarlo para habilitar la búsqueda visual basada en un índice de imágenes que contienen las mismas palabras clave. En las aplicaciones multimedia y de entretenimiento, puede catalogar vídeos en función del texto pertinente que aparece en pantalla, como anuncios, noticias, resultados deportivos y subtítulos. Finalmente, en las aplicaciones de seguridad pública, puede identificar vehículos basándose en los números de matrícula de las imágenes tomadas por las cámaras situadas en la vía pública.

6.2 Comparativa de performance entre las principales plataformas Cloud de Machine Learning

El aprendizaje automático como servicio (MLaaS) es una definición general de varias plataformas basadas en la nube que cubren la mayoría de los problemas de infraestructura, como el preprocesamiento de datos, la capacitación de modelos y la evaluación de modelos, con más predicciones. Los resultados de predicción se pueden vincular con su infraestructura de TI interna a través de las API REST.

Los servicios de Amazon Machine Learning, Azure Machine Learning, Google Cloud AI e IBM Watson son cuatro servicios líderes de MLaaS en la nube que permiten una rápida capacitación e implementación de modelos.

En este artículo, primero daremos una descripción general de las principales plataformas de aprendizaje automático como servicio de Amazon, Google, Microsoft e IBM, y seguiremos comparando las API de aprendizaje automático que estos proveedores admiten. Tenga en cuenta que esta descripción general no pretende proporcionar instrucciones exhaustivas sobre cuándo y cómo usar estas plataformas, sino más bien qué buscar antes de comenzar a leer su documentación.

En la siguiente sección mostraremos una comparativa de las principales plataformas, y que a mi parecer son las que mejores funcionalidades tienen y de más fácil uso. Identificaremos su performance según tipo solución o enfoque de solución.

En las siguientes gráficas, pondremos sobre la mesa el análisis de funcionalidades de las 4 siguientes compañías con sus plataformas de Machine Learning: AMAZON, GOOGLE, MICROSOFT e IBM.

Las API no requieren experiencia en aprendizaje automático en absoluto. Actualmente, las API de estos cuatro proveedores se pueden dividir ampliamente en tres grandes grupos:

- 1) Reconocimiento de texto, traducción y análisis textual
- 2) Reconocimiento de imagen + video y análisis relacionado
- 3) Otro, que incluye servicios específicos no categorizados

Análisis de performance en imágenes.

En esta grafica se muestran las principales funciones que se pueden desarrollar con ML y las funcionalidades que entrega cada plataforma según características, como vemos la mas completa es Google, quien permite realizar mas funciones por ende soluciones a partir de su API.

	Amazon	Microsoft	Google	IBM
Object Detection	✓	✓	✓	✓
Scene Detection	✓	✓	✓	✗
Face Detection	✓	✓	✓	✓
Face Recognition (person face identification)	✓	✓	✗	✗
Facial Analysis	✓	✓	✓	✓
Inappropriate Content Detection	✓	✓	✓	✓
Celebrity Recognition	✓	✓	✓	✗
Text Recognition	✓	✓	✓	✓
Written Text Recognition	✗	✓	✓	✗
Search for Similar Images on Web	✗	✗	✓	✗
Logo Detection	✗	✗	✓	✗
Landmark Detection	✗	✓	✓	✗
Food Recognition	✗	✗	✗	✓
Dominant Colors Detection	✗	✓	✓	✗

ILUSTRACIÓN 22: COMPARATIVA APIS ANALISIS DE IMÁGENES

Análisis de performance en voz y texto.

Esta grafica muestra las principales funciones respecto al análisis de voz y texto, como vemos el vendor que cuenta con más funcionalidades es Microsoft, quien sugiere la lista más rica de características. Sin embargo, las funciones más críticas están disponibles en todos los proveedores.

	Amazon	Microsoft	Google	IBM
Speech Recognition (Speech into Text)	✓	✓	✓	✓
Text into Speech Conversion	✓	✓	✓	✓
Entities Extraction	✓	✓	✓	✓
Key Phrase Extraction	✓	✓	✓	✓
Language Recognition	100+ languages	120 languages	120+ languages	60+ languages
Topics Extraction	✓	✓	✓	✓
Spell Check	✗	✓	✗	✗
Autocompletion	✗	✓	✗	✗
Voice Verification	✓	✓	✗	✗
Intention Analysis	✓	✓	✓	✓
Metadata Extraction	✗	✗	✗	✓
Relations Analysis	✗	✓	✗	✓
Sentiment Analysis	✓	✓	✓	✓
Personality Analysis	✗	✗	✗	✓
Syntax Analysis	✗	✓	✓	✓
Tagging Parts of Speech	✗	✓	✓	✗
Filtering Inappropriate Content	✗	✓	✓	✗
Low-quality Audio Handling	✓	✓	✓	✓
Translation	6 languages	60+ languages	100+ languages	21 languages
Chatbot Toolset	✓	✓	✓	✓

ILUSTRACIÓN 23: COMPARATIVA API PROCESAMIENTO DE VOZ Y TEXTO

Análisis de performance servicio análisis predictivo

La grafica muestra los principales servicios de aprendizaje automático para tareas de análisis predictivo personalizado, la que presenta mayores funcionalidades es Microsoft. Si está buscando una interfaz de drag and drop, primero consulte Microsoft ML Studio. En términos de plataformas para modelado personalizado, los cuatro proveedores anteriores sugieren productos similares

	Amazon	Microsoft	Google	IBM
Automated and semi-automated ML services				
	Amazon ML	Microsoft Azure ML Studio	Cloud AutoML	IBM Watson ML Model Builder
Classification	✓	✓	✓	✓
Regression	✓	✓	✓	✓
Clustering	✓	✓	✗	✗
Anomaly detection	✗	✓	✗	✗
Recommendation	✗	✓	✓	✗
Ranking	✗	✓	✗	✗
Platforms for custom modeling				
	Amazon SageMaker	Azure ML Services	Google ML Engine	IBM Watson ML Studio
Built-in algorithms	✓	✗	✓	✓
Supported frameworks	TensorFlow, MXNet, Keras, Gluon, Pytorch, Caffe2, Chainer, Torch	TensorFlow, scikit-learn, Microsoft Cognitive Toolkit, Spark ML	TensorFlow, scikit-learn, XGBoost, Keras	TensorFlow, Spark MLlib, scikit-learn, XGBoost, PyTorch, IBM SPSS, PMML

ILUSTRACIÓN 24: COMPARATIVA DE SERVICIOS CLOUD MACHINE LEARNING

Fuentes: (Service) (Comparing Machine Learning as a Service: Amazon)

Por último, en la siguiente tabla, mostraremos a modo general las principales diferencias de performance de las 4 principales entidades competidoras en ML.

Tabla 2: Tabla comparativa de CML - COMPARATIVA CLOUD MACHINE LEARNIGN				
	Amazon Machine Learning	Google Cloud Machine Learning	IBM Watson Machine Learning	Microsoft Azure Machine Learning
Resumen	Plataforma en gran medida automatizada que aplica algoritmos de aprendizaje automático a los datos almacenados en la popular plataforma de servicios web de Amazon	Ofrece a los usuarios acceso a algoritmos de última generación utilizados por Google en búsquedas y otras aplicaciones líderes de la industria. Los usuarios también pueden construir sus modelos.	Más enfocado en llevar modelos a producción a través de conectores API REST	Ofrece una larga lista de algoritmos predefinidos que los usuarios pueden aplicar a sus propios datos. Menos automatizado que otras opciones.
Interfase	Consola de aprendizaje automático de Amazon Interfaz de línea de comandos de Amazon	Interfaz de línea de comando usando GCloud Mi-Engine para controlar procesos de Tensorflow	- El software de análisis gráfico IBM SPSS se puede utilizar como interfaz - Los conectores API permiten a los usuarios crear modelos en aplicaciones de ciencia de datos de terceros	- Estudio de aprendizaje automático de arrastrar y soltar azul. - Paquetes para codificación R y python
Algoritmos y métodos de modelamiento	Los usuarios pueden llevar sus datos a algoritmos preconstruidos que incluyen: • regresión • clasificación binaria • clasificación multiclase	Los usuarios pueden construir sus propios modelos desde cero o usar modelos preentrenados que admitan estas aplicaciones: • análisis de video • análisis de imagen • reconocimiento de voz • análisis de texto • Traducción	Los usuarios pueden construir sus propios algoritmos en cualquier idioma a través de conectores API REST. Los enlaces a la biblioteca MLib de algoritmos de aprendizaje automático de apache spark se planifican a través de la plataforma de banco de trabajo con experiencia en ciencia de datos de IBM. (implementación actualmente en una versión beta cerrada)	Los usuarios pueden llevar sus datos a algoritmos prescritos, que incluyen: • árbol de decisión reforzado escalable • sistemas de recomendación bayesianos • redes neuronales profundas • selvas de decesión • clasificación • El servicio también admite estos algoritmos: • clasificación multiclase y binaria • agrupación de regresión
Algoritmo automático sugerido	Si	Si	No	No
Requisitos de ubicaciones de datos	Los datos deben estar en la tienda de servicios web de Amazon antes de ser utilizados en el servicio de aprendizaje automático.	Los datos deben almacenarse y los modelos deben organizarse en Google Cloud Storage	Los datos deben almacenarse y los modelos deben almacenarse en IBM Bluemix	Se pueden importar pequeños conjuntos de datos de terceros como AWS, pero los conjuntos más grandes que un par de gigabytes deben vivir en Azure.
Precios	Para análisis de datos y construcción de modelos \$ 0,42 por hora tarifas de predicción \$ 0,10 por mil predicciones por lotes, redondeadas a los siguientes mil \$ 0,0001 por predicción en tiempo real, redondeadas al centavo más cercano, más un cargo por capacidad reservada de \$ 0,0001 por hora por cada 10 MB de memoria anticipada	- Para capacitación modelo: \$ 0,49 por hora, por unidad de capacitación de aprendizaje automático (una medida de recursos informáticos) en los EE. UU. \$ 0,54 en Europa y Asia - Tarifas de predicción: \$ 0,10 por mil y predicciones, más \$ 0,4 por nodo hora en los EE. UU. \$ 0,11 / 0,44 en Europa y Asia - Los precios varían significativamente para las llamadas de API a modelos	- \$ 10,00 por instancia de servicio (ejecutando 20 modelos cada uno) - Para análisis y construcción de modelos \$ 0,45 por hora de cómputo - Tarifas de predicción: \$ 0,5 por mil predicciones en tiempo real o por lotes - Hay disponible una versión gratuita con una instancia de servicio que admite hasta dos modelos, 5,000 predicciones por	- \$ 9,99 por usuario, por mes para el estudio de aprendizaje de máquina azul, más \$ 1,00 por hora de experimentación de estudio (una medida del recurso informático) - Una versión gratuita con capacidades limitadas también está disponible para desarrollo y uso personal. - Las aplicaciones de análisis predictivo se pueden implementar como

		preentrenados, según las características utilizadas.	mes y cinco horas de tiempo de cálculo	servicios web a un precio escalonado de \$ 100, \$ 10000 y \$ 10000 por mes
Extras	Tarifas adicionales por datos almacenados en el servicio web de amazon facturados por separado	Se requiere cuenta de la plataforma google cloud	Se requiere experiencia en IBM SPSS modeler o Data Science para crear nuevos modelos. Cuenta Bluemix requerida	Serequiere una cuenta azul con la versión paga: la gratuita solo requiere una cuenta de microsoft
Otras Consideraciones	Incluye una herramienta de transformación automática de datos	Muy poca abstracción significa que los codificadores obtienen el control, pero los usuarios menos técnicos pueden enfrentar una curva de aprendizaje.	El servicio está orientado principalmente a crear aplicaciones respaldadas por el aprendizaje automático a través de conexiones API	La interfaz visual puede dar a los usuarios una visión limitada de cómo funcionan los modelos bajo el capó

Fuente: (Machine learning platforms comparison: Amazon) (Azure, s.f.) (Amazon, s.f.) (Google, s.f.)

6.3 Exposición de casos

A continuación, presentaremos casos de éxito de empresas Chilenas que ya están trabajando con ML.

6.3.1 DART: previniendo la ceguera en la diabetes

“Hay más de 1,5 millones de personas con diabetes que se deben hacer el examen de fondo de ojo anualmente; pero la cobertura de esa prueba sólo llega al 25%. Si se lograra atender a todos, nadie perdería la visión”, sentencia José Tomás Arenas, cofundador y CEO de DART.

Este emprendimiento chileno, provee una atención remota, donde el paciente se toma una foto digital, que es analizada por un modelo de Deep learning -entrenado en base a conocimiento de expertos- para filtrar los casos con sospechas y derivar a un especialista. “Desarrollamos un software en la Nube que, usando inteligencia artificial, es capaz de interpretar exámenes de retina y detectar de manera precoz y automatizada la presencia de signos de ceguera por diabetes, o retinopatía diabética, logrando que la capacidad de cobertura sea infinita”, revela José Tomas.

DART ha atendido a más de 100 mil pacientes y se plantearon el desafío de que cada año pasen por la plataforma entre 500 mil y un millón de personas. “La tecnología es un vehículo para resolver un problema real”, asegura.

Actualmente, experimentan para llevar ese mismo *know how* y adaptarlo a la detección y apoyo de diagnóstico en otras enfermedades, como la neumonía a través de la radiografía de tórax o los tumores en resonancias.

6.3.2 AIRA: agilidad en Recursos Humanos

En otro ámbito, la IA también ha logrado mejorar la eficiencia del área de Recursos Humanos. La empresa Chilena AIRA ha desarrollado un sistema, capaz de publicar avisos de empleo en diversos portales, para leer y clasificar CVs de

forma automática con procesamiento de lenguaje natural, y luego aplicar pruebas psicométricas y entrevistas en video a los perfiles más aptos para el cargo. En esta última etapa aplican *emotion analytics*, que “interpreta las emociones que transmiten los postulantes, a través de su nivel de atención y expresividad facial”, explica Gonzalo Sanzana, CEO de la compañía.

“Es un 10x en recursos humanos. Lo que demora 30 días, con AIRA Recruiter sólo toma 3, y lo que tarda 20 horas hombre, con AIRA sólo toma 2”, asegura Gonzalo, destacando que su asistente virtual permite revisar cientos de currículums, validar antecedentes, entrevistar y reducir los tiempos de selección antes de llegar a la contratación.

Por otro lado, también tienen AIRA Mobile Assistant, un asistente de voz que apoya 24/7 a los colaboradores que ya forman parte de la empresa, para resolver dudas como solicitud de vacaciones; y AIRA Outplacement, que apoya a los trabajadores más allá del último día con asistencia full digital, para mejorar el CV y entrenarlos para futuras entrevistas presenciales.

“Nuestra principal misión es hacernos cargo del colaborador en todo su ciclo de vida, para ayudarlo antes, durante y después. Y eso lo hemos logrado gracias a la inteligencia artificial, pero siempre entendiendo que la tecnología es un medio para entregar una solución, y no un fin en sí mismo”, enfatiza Sanzana. Actualmente, AIRA tiene clientes en el sector financiero, retail y minero, entre otros; y están escalando comercialmente en Perú y México.

6.3.3 The Not Company: hacia una alimentación sustentable

“Democratizar la comida saludable”, ese es el concepto que tres jóvenes chilenos quisieron plasmar en The Not Company. Este emprendimiento, certificado como Empresa B, nace en 2016 con el objetivo de crear lácteos y embutidos fabricados 100% con productos vegetales.

La idea, explica su cofundador Matías Muchnick, no es obtener un producto para vegetarianos, sino entregar alimentos que logren replicar el sabor, textura y aroma de los tradicionales; pero sin las consecuencias negativas para la salud y el medioambiente, ya que no contienen aditivos ni conservantes, y además optimizan los recursos de energía, agua y tierra.

“Analizamos los alimentos a nivel molecular y descubrimos qué hace, por ejemplo, que la leche tenga ese sabor, textura, color y nutrientes”, explica Matías. Ese trabajo lo hace Giuseppe, el algoritmo de IA desarrollado por The Not Company, capaz de indicar qué plantas se deben combinar. “Lo interesante de Giuseppe es que está basado en tecnologías de aprendizaje, entonces después de cada formulación logra acercarse de manera más certera al gusto objetivo, ya sea mayonesa, leche, yogurt o chocolate”, agrega.

A fin de cuentas, para Matías la tecnología es un habilitador: “nos permite generar soluciones exponencialmente mejores. Las capacidades de procesamiento y de aprendizaje se acotan mucho cuando sólo hay inteligencia humana en el proceso; con IA ampliamos las capacidades de cómputo”, asegura el cofundador de The Not Company.

6.3.4 Cornershop

Es un servicio on-demand de despacho a domicilio de alimentos para el mercado latinoamericano. Con cobertura en Santiago de Chile y el D.F en México, la empresa promete abastecer a sus usuarios dentro de 90 minutos y, así “entregar tiempo libre a las personas”, destaca Sánchez. En su presentación, el data scientist explicó cómo el machine learning ha contribuido al éxito del negocio.

Sánchez comenzó explicando Big Data, calificándolo como “un problema. El problema de tener muchísima información”, aunque explicando que si se usa bien, esa data puede originar muchos beneficios y “predecir el futuro”. A su juicio, uno de los grandes desafíos es el almacenamiento de los datos y cómo hacemos cálculos básicos, por lo que se requiere un cambio de infraestructura tecnológica importante. “La solución: buscar cómo se puede separar una tarea y luego levantar varias máquinas que hagan los cálculos sobre distintas partes del conjunto de datos. Esa es la solución al big data”, analizó el experto.

Machine learning para la toma de decisiones

Respecto de machine learning, Matías Sánchez aclaró que el concepto corresponde a métodos para que los computadores aprendan de un conjunto de datos y obtengan una conclusión o generen conocimiento a partir de un problema. Ejemplificó con que, en el caso de las personas, equivale a que un niño asocie la imagen de un animal que nunca ha visto -por ejemplo, un perro- con la denominación que le puede dar su padre del mismo: “eso es un perro”. “Machine learning hace eso. Encuentra una función que, dado cierto input, deducirá una respuesta”, explica el experto.

Hoy en día, diversas empresas e industrias utilizan machine learning. Una de ellas es Netflix, con las recomendaciones de series y películas entregadas al usuario. “Una máquina aprende de tus gustos, sabe qué películas ve gente similar a ti, cuáles aún no ves, y en base a ello te recomienda”, agrega Sánchez. Los fabricantes de automóviles también obtienen provecho del machine learning, con autos que perciben a través de sensores y luego, toman decisiones. Las bolsas de valores también pueden anticipar el valor de una acción.

En el caso de Cornershop, el machine learning ha sido de utilidad para mejorar la precisión con que la operación se lleva a cabo. Han utilizado machine learning para predecir cuánto tiempo se demorará la empresa en completar un pedido (de manera hacer una promesa confiable a los clientes), identificar cuándo tienen que comenzar a trabajar en una orden y predecir qué tan ocupados estarán los *shoppers* en el futuro.

En cuanto a los conocimientos requeridos para llevar los datos a un nivel avanzado como el del machine learning, Sánchez explicó que los denominados data scientists deben contar con tres habilidades fundamentales: experiencia en ciencias de la computación, conocimiento de al menos dos lenguajes de programación, de modelos matemáticos complejos y experiencia del área o industria en la cual se desempeñará.

7. Conclusiones

Como pudo verse en la etapa de desarrollo, y gracias al desarrollo metodológico utilizado, he podido crear una guía que permite interiorizar sobre la tecnología a cualquier persona, con o sin conocimientos técnicos, que es lo primordial, ya que esto facilitará la comprensión, por ende, las ganas de tecnologizar las operaciones en las empresas.

Como verás al principio, el asunto resulta sorprendente. Una persona entra en la página web de su tienda de ropa preferida y, sin haber capturado ningún dato en ese momento, en el primer plano de la pantalla se muestra la prenda que ha perseguido durante días, el atuendo que cumple a la perfección con las características deseadas (talla, material, color y precio). Cuando esto ocurre, no falta quien afirme: “¡Qué suerte, como si el sitio supiera qué buscaba!”. En realidad, la fortuna no interviene en una situación así. Detrás de este tipo de experiencias (replicables en dominios tan diversos como la salud, el gobierno, las finanzas, el transporte, entre otros) se encontrará una innovación impulsada por la analítica: Machine Learning. Machine Learning puede definirse como un método analítico que permite que un sistema, por sí mismo —sin intervención humana y en forma automatizada—, aprenda a descubrir patrones, tendencias y relaciones en los datos, y gracias a dicho conocimiento, en cada interacción con información nueva se ofrecen mejores perspectivas. Esta competencia inherente para aprender de los datos, que sitúa a Machine Learning como una expresión de la Inteligencia Artificial, hoy todavía puede asombrar a algunos individuos; sin embargo, es una función analítica que ya determina múltiples aspectos de nuestra vida.

De acuerdo con algunas estimaciones, a escala global, todos los días se generan alrededor de 2.5 trillones de bytes de información. Para guardar semejante cúmulo de datos en discos Blue-ray, se necesitarían 10 millones de unidades, las cuales, si se apilaran, alcanzarían una altura equivalente a cuatro Torres Eiffel. Todos contribuimos con la construcción de este impresionante arsenal de información, algo que hacemos a través de computadoras y dispositivos móviles conectados a Internet, sensores instalados en objetos y lugares (de variada naturaleza y uso cotidiano), plataformas digitales en las que interactuamos (como redes sociales y páginas web), entre otras vías. Asimismo, este gigantesco flujo de datos no tiene un carácter homogéneo, ya que nuestros aportes ahora incluyen texto, audio, fotografía y video. Gracias al poder analítico de Machine Learning, los trillones de bytes son algo más que una espectacular acumulación. Un sistema con capacidades de Machine Learning sigue la huella digital que va dejando un usuario en sus actividades (en una tienda virtual o en un servicio de banca en línea, por ejemplo), la cual analiza para descubrir pautas y con el tiempo aprende de dichos descubrimientos; una habilidad que le permitirá presentar recomendaciones, descubrir insights, prevenir riesgos, proyectar escenarios y resaltar anomalías, entre otras funciones. Por eso, para muchas industrias del mundo, Machine Learning se está convirtiendo en un factor que detona una profunda innovación, dado que su aplicación contribuye a mejorar procesos, generar nuevas oportunidades de

negocio (antes imperceptibles o cuya detección no era sencilla) y definir nuevos parámetros empresariales (por ejemplo, la forma en que se consigue la satisfacción del cliente). Todo esto desde la propia solución tecnológica, sin que una instancia humana tenga que estudiar los datos, valorarlos y generar una respuesta.

Entre los sectores que ya aprovechan esta innovación analítica, vale la pena destacar casos como:

- **Servicios financieros:** gracias a las soluciones de Machine Learning, las empresas detectan insights en la información de sus clientes y sus operaciones. Esto les permite –en forma automatizada, sin la intervención de un equipo de ejecutivos– recomendar productos financieros al usuario indicado y en el momento preciso (por ejemplo, una oportunidad de inversión), detectar a clientes con un alto perfil de riesgo, descubrir operaciones anómalas que podrían esconder fraudes, entre otras posibilidades.
- **Atención de la salud:** en combinación con sensores o dispositivos en prendas de vestir (los llamados wearables devices), un sistema con capacidades de Machine Learning puede monitorear y valorar el estado de salud de una persona en tiempo real, y si detecta una irregularidad, tomar una acción en forma automática –como sugerir una visita al doctor. La innovación también ayuda en el análisis de los datos de los pacientes: identifica instantáneamente tendencias y anomalías, lo que contribuye con la realización de mejores diagnósticos.
- **Ventas y mercadotecnia:** Machine Learning es el elemento que hace posible la personalización de una experiencia de compra, ya que a partir del análisis de compras previas (mercancías preferidas, gasto promedio, medio de pago recurrente, etc.), puede hacer recomendaciones con alto potencial de éxito. Este conocimiento del cliente también ayuda a implementar campañas de marketing con gran nivel de precisión.
- **Gobierno:** al ser una entidad que debe atender múltiples responsabilidades críticas (seguridad pública, salud, educación, infraestructura, finanzas, entre otras), las autoridades necesitan soluciones que revelen insights en forma sencilla y veloz. Con el respaldo de Machine Learning, un gobierno puede analizar su gigantesco cúmulo de datos, y detectar ágilmente áreas o funciones cuya mejora debe ser prioritaria –de esta forma, los recursos públicos se invierten en los ámbitos correctos, aquellos que realmente mejoran la vida de la ciudadanía y evitan procesos lentos y burocráticos para, por ejemplo, descubrir qué zona de una población necesita más apoyo en materia de seguridad.
- **Transporte:** en una industria que no debe prescindir de la agilidad, Machine Learning se está volviendo el recurso ideal para descubrir nuevos niveles de eficiencia. Utilizando esta innovación, las compañías del rubro analizan sus operaciones de negocio y rápidamente detectan rutas más eficaces, lo que incrementa la rentabilidad de sus procesos (tiempos de entrega más cortos, con menor consumo de combustible, menor riesgo de desperfectos y menor desgaste de las unidades).

Fuente: (SAAS: Machine Learning)

7.1 Declaraciones respecto de las conclusiones.

Gracias a los avances en Machine Learning, dichas industrias están descubriendo un nuevo campo de oportunidades. Lo mismo podría hacer la economía Chilena en su conjunto. Para mantener su competitividad en el contexto global y asegurar operaciones exitosas en casa, las empresas Chilenas pueden fortalecer su posición a través de esta innovación, diseñando estrategias basadas en datos confiables y que aprovechan este poder de analítica automatizada. Esto evita depender de intuiciones o supuestos, y especialmente garantiza que todas las acciones –de manera inmediata– están alineadas a objetivos de negocio (rentabilidad, incremento de ventas, satisfacción del usuario, entre otras). Es hora de llevar las sorpresas a otro nivel. En específico: asombrarnos con lo que el poder analítico de Machine Learning puede hacer por nuestra vida y nuestros negocios.

8. Bibliografía.

- Amazon, s. m. (s.f.). <https://aws.amazon.com/es/machine-learning/>.
- Azure, M. L. (s.f.). https://azure.microsoft.com/es-mx/free/machine-learning/search/?&ef_id=Cj0KCQiAtf_tBRDtARIsAlbAKE09F5vMphutg0XSLgCeSV4QQNliWH55Y2FTxkCNnJBxBpkqsgc7drMaAvjCEALw_wcB:G:s&OCID=AID2000064_SEM_EyEBnAEE&MarinID=EyEBnAEE_324585965025_machine%20learning_e_c__6711.
- Comparing Machine Learning as a Service: Amazon, M. A. (s.f.). <https://www.altexsoft.com/blog/datascience/comparing-machine-learning-as-a-service-amazon-microsoft-azure-google-cloud-ai-ibm-watson/>.
- Diario Financiero, I. t. (s.f.). <https://www.df.cl/noticias/opinion/columnistas/cristian-bastian/el-camino-de-la-transformacion-digital/2018-06-14/185309.html>.
- Ebanking New, S. t. (s.f.). <http://www.ebankingnews.com/noticias/seis-tendencias-que-determinaran-el-crecimiento-del-machine-learning-en-2019-0044182>.
- Google, s. M. (s.f.). https://cloud.google.com/ml-engine/?utm_source=google&utm_medium=cpc&utm_campaign=latam-CL-all-es-dr-bkws-all-all-trial-b-dr-1007178-LUAC0009198&utm_content=text-ad-none-none-DEV_c-CRE_355624424769-ADGP_BKWS+%7C+Multi+~+Solutions+%7C+Machine+Learning-KWI.
- https://www.ibm.com/ar-es/analytics/machine-learning?cm_mmc=Search_Google_-_Hybrid+Cloud_Data+Science_-_LA_ISA_-_machine%20learning_e&cm_mmca1=000036UL&cm_mmca2=10009788&cm_mmca7=1003325&cm_mmca8=kwd-59020306&cm_mmca9=Cj0KCQiAtf_tBRDtARIsAlbAKE1kauXX0SfZW. (s.f.). https://www.ibm.com/ar-es/analytics/machine-learning?cm_mmc=Search_Google_-_Hybrid+Cloud_Data+Science_-_LA_ISA_-_machine%20learning_e&cm_mmca1=000036UL&cm_mmca2=10009788&cm_mmca7=1003325&cm_mmca8=kwd-59020306&cm_mmca9=Cj0KCQiAtf_tBRDtARIsAlbAKE1kauXX0SfZW.
- learning, I. C. (s.f.). https://www.ibm.com/ar-es/analytics/machine-learning?cm_mmc=Search_Google_-_Hybrid+Cloud_Data+Science_-_LA_ISA_-_machine%20learning_e&cm_mmca1=000036UL&cm_mmca2=10009788&cm_mmca7=1003325&cm_mmca8=kwd-59020306&cm_mmca9=Cj0KCQiAtf_tBRDtARIsAlbAKE1kauXX0SfZW.
- Learning, M. C. (s.f.). <https://la.mathworks.com/help/deeplearning/examples/classify-images-from-webcam-using-deep-learning.html#d117e12969>. Obtenido de <https://la.mathworks.com/help/deeplearning/examples/classify-images-from-webcam-using-deep-learning.html#d117e12969>.

Machine learning platforms comparison: Amazon, A. G. (s.f.).
<https://searchbusinessanalytics.techtarget.com/feature/Machine-learning-platforms-comparison-Amazon-Azure-Google-IBM>.

Mathworks, A. M. (s.f.). <https://la.mathworks.com/campaigns/offers/deep-learning-vs-machine-learning-algorithm.html>.

Miriadax, C. d. (s.f.). <https://miriadax.net/web/introduccion-al-machine-learning-8-edicion/>.

Platforms, G. M. (s.f.). <https://www.gartner.com/doc/reprints?id=1-65WC001&ct=190128&st=sb>.

principiantes, I. L. (s.f.). <https://www.ibm.com/downloads/cas/GB8ZMQZ3>.

SAAS: Machine Learning, u. e. (s.f.). <https://www.sas.com/content/dam/SAS/documents/product-collateral/industry-overview/es/machine-learning-109075.pdf>.

Service, C. M. (s.f.). <https://www.kdnuggets.com/2018/01/mlaas-amazon-microsoft-azure-google-cloud-ai.html>.

Using, M. C. (s.f.). <https://la.mathworks.com/help/deeplearning/examples/classify-images-from-webcam-using-deep-learning.html#d117e12969>.

TITULO DE LA TESIS:

Propuesta de guía práctica para la aplicación de tecnologías machine learning en las empresas.

AUTOR: Ana Maria Gonzalez Lopez

TRABAJO DE TESIS, presentado en cumplimiento parcial de los requisitos para el Grado de Magíster en Innovación Tecnológica y Emprendimiento de la Universidad Técnica Federico Santa María.

Sr. Claudio Ramirez.

Sr. Nombre Correferente Ex.

Sr. Nombre Correferente Int.

Valparaíso, Chile. Noviembre de 2017