




GLOSARIO

AI

- AI -

- AI -



baufest
ARTIFICIAL INTELLIGENCE



Índice

GLOSARIO **AI**

A

Artificial Intelligence (AI) 03

C

Computer Vision 04

D

Data Science 05

Data Analysis 06

Data Engineering 07

Data Mining 07

Deep Learning 08

I

Internet of Things (IoT) 08

M

Machine Learning 09

N

Natural Language Processing (NLP) 10

Natural Language Understanding (NLU) 12

Neural Networks 12

P

Predictive Analytics 13

Prescriptive Analytics 13

R

Reinforcement Learning 16

S

Supervised Learning 18

U

Unsupervised Learning 18


GLOSARIO AI

A.


Artificial Intelligence

¿Qué es Artificial Intelligence?

Es una subdisciplina del campo de la informática, que busca la creación de máquinas que puedan imitar comportamientos inteligentes.



Composición de AI



GLOSARIO AI



Computer Vision

¿Qué es Computer Vision?

Computer Vision es un área de la inteligencia artificial que permite a las computadoras extraer características significativas a partir de medios visuales (imágenes, videos o cualquier otro tipo de entrada visual).

Un algoritmo de computer vision le permite a una computadora reconocer ciertos patrones básicos (como líneas rectas) los cuales luego combina para reconocer patrones más completos (figuras geométricas, un ojo, una silla, etc.). Para esto es necesario entrenar al modelo con un gran volumen de imágenes.

La principal tecnología que utilizan los modelos de Computer Vision para realizar reconocimiento de imágenes es Deep Learning. Dentro de las diferentes arquitecturas de Redes Neuronales existentes, las más adecuadas para esto son las Redes Neuronales Convolucionales (CNN) ya que, mediante el proceso de convolución, puede detectar los patrones antes mencionados.

Para el procesamiento de video, frecuentemente también son utilizadas las Redes Neuronales Recurrentes (RNN) que nos permiten analizar la secuencia de imágenes del video para entender la correlación entre ellas.

Procesamiento de imágenes

Este campo comprende una serie de funciones matemáticas que se realizan sobre las imágenes para transformarlas. Este procesamiento lo realiza sin la aplicación de ningún tipo de Inteligencia Artificial. Sin embargo, algunas de estas funciones involucran algún tipo de modelo “pseudo-inteligente”.

Este último concepto a menudo conduce a una confusión entre el término Computer Vision e Image Processing como si se refirieran a lo mismo. Sin embargo, cabe aclarar que es posible realizar procesamiento avanzado de imágenes y resolver problemas considerablemente complejos sin necesidad de recurrir al uso de Computer Vision. Más aún, existe un debate de a qué se le llama Computer Vision y a qué no, dependiendo de si el proceso involucra Inteligencia Artificial o no.

GLOSARIO AI

D.

Data science

¿Qué es Data Science?

La ciencia de datos (o Data Science) es la ciencia de extraer conocimientos e “insights” accionables a partir de los datos.

A partir de los datos de entrada, éstos se preparan y procesan mediante técnicas de analítica avanzada, con el objeto de encontrar patrones en los mismos. Estos patrones se transforman en predicciones, obteniendo como resultado los “insights” antes mencionados los cuales ayudarán a la toma de decisiones de negocio. A diferencia de Machine Learning, en Data Science el subproducto del proceso no es una pieza de software que tome decisiones a partir de los datos, sino que presenta un Slide Deck a partir del cual se toman las decisiones. Este Slide Deck puede ser una presentación de diapositivas tipo Power Point, un Dashboard de PowerBI o cualquier otra forma de presentación de los insights que permita, a partir de lo hallado, la toma de decisiones.

El campo del Data Science está comprendido por distintos procesos realizados sobre los datos. Entre estos procesos pueden incluirse el Data Mining, Data Analysis, Data Reporting, Data Visualization, entre otros.

El ciclo de vida de un proyecto de Data Science



GLOSARIO AI

Data Analysis

¿Qué es Data Analysis?

Se trata del proceso mediante el que se analizan datos crudos a fin de responder preguntas y llegar a conclusiones prácticas. Muchas de estas técnicas han llegado a automatizarse hasta llegar a ser procesos mecánicos. Para eso, se hace uso de algoritmos que sintetizan la información para que resulte más fácil de digerir por las personas.

Mediante las técnicas de data analytics es posible encontrar tendencias y mediciones que de lo contrario habrían sido pasadas por alto dentro de la enorme cantidad de información con la que se suele trabajar. Estos datos pueden usarse para optimizar procesos y aumentar la eficiencia de la empresa.

¿Cuál es la importancia del data analysis?

Es importante porque permite que las empresas optimicen su desempeño. Así, implementarla dentro del modelo de negocios significa que las empresas pueden reducir costos al identificar formas más eficientes de funcionar, así como una cantidad enorme de información.

Una empresa también podría usar data analytics para analizar las preferencias y satisfacción de los clientes y así tomar mejores decisiones de negocios. Todo ello puede hacer que se ofrezca mejores productos y servicios.

El proceso de data analysis

Se trata de un procesamiento que requiere seguir diferentes pasos:

- 1.- El primer paso consiste en determinar los requisitos de información o cómo los datos se encuentran agrupados. Estos podrían dividirse en base a edad, ingresos, género, etc. Todos aquellos valores pueden ser numéricos o separarse por categorías.
- 2.- El segundo paso es el proceso de recolección de datos. Esto podría hacerse por diferentes medios como computadoras, fuentes online, cámaras, fuentes ambientales, personal, etc.
- 3.- Una vez que se obtiene la información, esta debe ser analizada. Ese proceso puede llevarse a cabo en una hoja de cálculos u otro software similar en la que es posible gestionar datos estadísticos.
- 4.- Luego, antes de empezar el análisis de la información, se procede a limpiarla. Esto significa que la data es revisada con cuidado para asegurarse de que no haya errores, duplicados o que no se encuentre incompleta. Este paso ayuda a corregir cualquier falla antes de que sean enviadas al analista de datos.

Data Engineering

Los datos crecen exponencialmente y cada vez son más las empresas que buscan entender, analizar y utilizar el potencial de tal cantidad de información. Tanto Data Scientist como Data Engineering son fundamentales en este sentido. Sin embargo, su función no es la misma. La distinción es simple: mientras los primeros están más orientados a las matemáticas, los segundos tienen una mentalidad más cercana a las Tecnologías de la Información.

¿Qué es Data Engineering o Ingeniería de Datos?

Aunque no se hable tanto de ellos, **los ingenieros de datos** son una parte fundamental en cualquier proceso de **ciencia de datos**. Podríamos definir un data engineer como aquel profesional enfocado en el diseño, desarrollo y mantenimiento de los sistemas de procesamiento de datos dentro de un proyecto de **Big data**.

El objetivo de la **Data Engineering** es construir y mantener las estructuras de datos y las arquitecturas tecnológicas necesarias para el procesamiento, ingestión e implementación a gran escala de aplicaciones que usan datos de manera intensiva. Es decir, diseñan y construyen los repositorios de datos en bruto y, a partir de ahí, recogen, transforman y preparan los datos para analizar. Una vez listos, los data scientists se encargan de poner sus modelos en producción.

En resumen, los data scientists entrenan modelos que extraen conocimiento sobre un problema a tratar a partir de los datos. Lo hacen mediante herramientas matemáticas y conocimientos del dominio de negocio. Pero, **para que sea posible definir y entrenar el modelo es necesario tener disponibles un conjunto de datos válido en el que trabajar**, y esta es la función del data engineer.

Los **data engineers o ingenieros de datos** se especializan **en programación, como en Java, Python o SQL**. Utilizan habilidades avanzadas de programación y de creación de sistemas para **crear soluciones de software**. No solo pueden construir flujos de datos, sino que también pueden combinar diversas tecnologías para crear la mejor solución para la organización.

Data Mining

¿Qué es el Data Mining?

El **Data Mining**, o minería de datos, es el proceso de analizar grandes volúmenes de datos (o Big Data) con el objetivo de descubrir patrones y otros datos relevantes relativos a dichos datos. Si bien el término Data Mining se popularizó en las últimas décadas a raíz del incremento de la capacidad de almacenamiento de base de datos, este concepto se remonta hasta la década del '60, aunque en ese entonces el tamaño de las bases de datos era considerablemente menor que las actuales.

Diferencias entre Data Mining y Big Data

A menudo es fácil confundir los conceptos de Data Mining con el de Big Data. Para aclarar esta confusión podemos pensar al Big Data como el insumo sobre el cual se hace Data Mining. Es decir, Big Data hace referencia a bases de datos de gran volumen, mientras que Data Mining es el proceso que se realiza sobre estas bases.

Deep Learning

¿Qué es Deep Learning?

Deep Learning es una subdisciplina de Machine Learning (que a su vez es un subconjunto de Inteligencia Artificial) la cual utiliza como algoritmos de aprendizaje automático las llamadas Redes Neuronales.

La principal diferencia entre Deep Learning y otras técnicas de Machine Learning (frecuente-mente llamadas Machine Learning Clásico) es que el primero automatiza gran parte del proceso de tratamiento de los datos y feature engineering, logrando una mayor independencia de la intervención humana. Esto le permite lograr una mayor versatilidad, pudiendo ser aplicado a un rango más amplio de problemáticas.

Deep Learning no requiere necesariamente de un conjunto de datos etiquetados (supervised learning). Sin embargo puede, a partir de datos etiquetados, extraer características a partir de datos no estructurados (como, por ejemplo, imágenes). A partir del reconocimiento de estos patrones puede distinguir un conjunto de características que diferencian a un dato de otro. Esto es, por ejemplo, lo que hace Computer Vision.

Una revisión interesante sobre el Deep Learning puede encontrarse en este [artículo](#).



Internet of Things (IoT)

¿Qué es Internet of Things?

El Internet de las Cosas o Internet of Things (IoT) se refiere al conjunto de objetos físicos dotados de sensores, software, capacidad de procesamiento y otras tecnologías, los cuales se conectan e intercambian datos con otros objetos o sistemas a través de una conexión a internet. Estos objetos pueden pertenecer a una amplia variedad de categorías, desde algo tan simple como un electrodoméstico hasta herramientas industriales sofisticadas.

Esta área está en pleno auge en el mundo. Las principales razones tienen que ver con la disminución física del tamaño (y de costo) de los microprocesadores y sensores, lo cual les da una gran versatilidad para colocarlos en una gran cantidad de objetos y dotarlos de esta capacidad de procesamiento y conexión a internet. Los avances en el campo de la Inteligencia Artificial y Machine Learning hicieron que el uso de estos dispositivos se vuelva más frecuente. Son muy utilizados en áreas como automatización de hogares, sistemas embebidos, salud, sistemas de seguridad y monitoreo, por nombrar algunos.

Entre las principales áreas que implementan IoT podemos listar:

- Agricultura
- Construcción
- Salud
- Transporte y Logística
- Energía y Recursos Naturales
- Ciudades Inteligentes

Se estima que para 2025 habrá más de 20.000 millones de dispositivos que utilicen IoT.

M.

Machine Learning

Definición


El Machine Learning (o Aprendizaje Automático) es una disciplina en la cual se programa a una computadora para que, a partir de datos de entrada, reconozca patrones subyacentes en estos datos y aprenda de los mismos para ajustar parámetros libres de un modelo. Este modelo nos permite luego hacer inferencia de distintos tipos sobre nuevos datos, ya sea clasificación, regresión o hasta incluso generación de nuevos datos.

Una forma simplificada de entender lo que hace el campo del Machine Learning es a través del siguiente diagrama.



Lo que nos dice este diagrama es que, a partir de los datos de entrada, se los proporcionamos al algoritmo de Machine Learning, el cual aprende a reconocer patrones, produciendo un modelo. Este modelo es capaz de predecir el resultado de nuevos datos que se le proporcionen aunque nunca antes los haya visto.

Cómo funciona ML



Tipos de ML

El campo del Machine Learning se puede dividir, en grandes rasgos, en 3 categorías: Aprendizaje Supervisado (Supervised Learning), Aprendizaje no Supervisado (Unsupervised Learning) y Aprendizaje Reforzado (Reinforcement Learning).

N.

Natural Language Processing (NLP)

¿Qué es Natural Language Processing?

El Procesamiento del Lenguaje Natural (NLP por sus siglas en inglés) es el campo de estudio que se enfoca en la comprensión mediante ordenador del lenguaje humano. Abarca parte de la Ciencia de Datos, Inteligencia Artificial (Aprendizaje Automático) y la lingüística.

En NLP las computadoras analizan el lenguaje humano, lo interpretan y dan significado para que pueda ser utilizado de manera práctica. Usando NLP podemos hacer tareas como resumen automático de textos, traducción de idiomas, extracción de relaciones, Análisis de sentimiento, reconocimiento del habla y clasificación de artículos por temáticas.

El gran desafío

NLP es considerado uno de los grandes retos de la inteligencia artificial ya que es una de las tareas más complicadas y desafiantes: ¿cómo comprender realmente el significado de un texto? ¿cómo intuir neologismos, ironías, chistes ó poesía? Si la estrategia/algoritmo que utilizamos no sortea esas dificultades de nada nos servirán los resultados obtenidos.

En NLP no es suficiente con comprender meras palabras, se deberá comprender al conjunto de palabras que conforman una oración, y al conjunto de líneas que comprenden un párrafo. Dando un sentido global al análisis del texto/discurso para poder sacar buenas conclusiones. Nuestro lenguaje está lleno de ambigüedades, de palabras con distintas acepciones, giros y diversos significados según el contexto. Esto hace que el NLP sea una de las tareas más difíciles de dominar.



GLOSARIO AI

¿Para qué sirve NLP?

Estos son algunos de los usos más frecuentes:

Resumen de textos: El algoritmo deberá encontrar la idea central de un artículo e ignorar lo que no sea relevante.

ChatBots: deberán ser capaces de mantener una charla fluida con el usuario y responder a sus preguntas de manera automática.

Generación automática de keywords y generación de textos siguiendo un estilo particular

Reconocimiento de Entidades: encontrar Personas, Entidades comerciales o gubernamentales ó Países, Ciudades, marcas...

Análisis de Sentimientos: deberá comprender si un tweet, una review o comentario es positivo ó negativo y en qué magnitud (ó neutro). Muy utilizado en Redes Sociales, en política, opiniones de productos y en motores de recomendación.

Traducción automática de Idiomas

Clasificación automática de textos en categorías pre-existentes ó a partir de textos completos, detectar los temas recurrentes y crear las categorías.

¿Cómo es capaz de entender el lenguaje?

Pues deberemos armar diversos modelos con el lenguaje, crear estructuras y con ellas alimentar algoritmos de machine learning.

Podemos empezar por ejemplo tomando un texto extenso. Utilizaremos Expresiones Regulares para subdividir el texto en palabras. Podemos contar las palabras, su frecuencia. Si hay algún patrón, por ejemplo si siempre después de una palabra X, siempre viene una palabra Y. Podemos analizar como terminan las palabras, por ejemplo "verbos terminados en "ar, er, ir" y descubrir la raíz de la palabra. Podríamos agrupar palabras con significados similares en contraposición a sus palabras antónimas.

Resumiendo, podemos procesar de diversas maneras al lenguaje, sus componentes: gramática, sintaxis e intentar crear estructuras de apoyo que nos servirán como entradas para aplicar Regresión Lineal, Regresión Logística, Naive Bayes, árbol de decisión o Redes Neuronales según el resultado que estemos buscando.



GLOSARIO AI

Natural Language Understanding (NLU)

Son las siglas en inglés de “Natural Language Understanding” y es una rama de NLP. Su fin es capacitar a un sistema tecnológico para comprender el significado e intención que encierra una frase. Debido a la complejidad que encierra la comprensión del lenguaje natural, es uno de los mayores desafíos que experimenta la IA en la actualidad.

El NLU funciona a través de un potente algoritmo de clasificación de aprendizaje automático, análisis estadístico del orden y frecuencia de las palabras y una gran cantidad de datos de capacitación, para comprender la intención que subyace en el mensaje de un usuario.

Uno de los papeles que desempeña el NLU en los chatbots es la mejora en la experiencia del usuario: los chatbots que emplean NLU mantienen una conversación más fluida, sin tener la necesidad de usar respuestas preestablecidas como en el caso del NLP. Este tipo de tecnología es usada en sectores como los restaurantes de comida rápida, ya que permite gestionar pedidos, promociones, etc., y resolver los problemas que tenga el cliente de forma más eficiente que con otros sistemas.

Los asistentes virtuales configurados con NLU pueden aprender nuevas habilidades a partir de la interacción con los usuarios. Esta aplicación es especialmente útil para la atención al cliente debido a que, a medida que el chatbot mantiene conversaciones con los compradores, su nivel de respuesta mejora.

La aplicación de NLU y NLP en chatbots como soluciones empresariales son el fruto de la transformación digital ocasionada por la cuarta revolución industrial. Conocer el papel que desempeñan, es fundamental para el éxito del negocio.

Neural Networks

Las Redes Neuronales (o **Neural Networks**) son un tipo de arquitectura de Machine Learning. El campo del Machine Learning que utiliza redes neuronales es llamado Deep Learning.

Las Redes Neuronales están formadas por entidades más pequeñas llamadas perceptrón, con los cuales se intentaba emular el comportamiento de las neuronas dentro de nuestro cerebro (aunque hoy en día todavía no se sabe con certeza cómo funcionan). Básicamente, reciben una (o varias) entrada(s) de dato(s), realizan un procesamiento simple del mismo y devuelven una salida. La combinación de estos perceptrones forma las redes neuronales.

Dependiendo de cómo se organicen estos perceptrones dentro de las redes neuronales se pueden definir distintas arquitecturas de redes. Más aún, mediante la combinación de las distintas operaciones que se realizan dentro de los perceptrones, podemos diseñar Redes Neuronales que sean óptimas para distintas tareas, como las Redes Neuronales Convolucionales (CNN) o las Redes Neuronales Recurrentes (RNN).

GLOSARIO **AI**

Redes Neuronales Convolucionales (CNN)

Este tipo de redes neuronales son mayormente utilizadas para Computer Vision. Su nombre hace referencia a una operación que realiza sobre diferentes porciones de una imagen (dicha operación se llama convolución). Mediante esta operación la red aprende a reconocer ciertos patrones en la imagen (cada vez más complejos). La combinación de estos patrones permite reconocer luego el contenido de la imagen, permitiendo su clasificación.

Redes Neuronales Recurrentes (RNN)

Las RNN son utilizadas mayormente para analizar y comprender texto. Para su aprendizaje no solo utilizan la información de la palabra que están identificando, sino también las anteriores, permitiendo comprender el significado de dicha palabra en el contexto en el que se está utilizando. Un ejemplo de estos algoritmos es el llamado LSTM (o Long Short Term Memory), el cual utiliza los datos previos para ayudar a comprender el contexto del dato.

P.

Predictive Analytics

¿Qué es Predictive Analytics?

Predictive Analytics (análisis predictivo) es el área que trata los diversos aspectos de las técnicas estadísticas, incluidos el modelado predictivo, la extracción de datos (data mining), el aprendizaje automático (machine learning), y el análisis de datos actuales e históricos para hacer predicciones de futuro.

Las organizaciones empresariales hoy trabajan en un entorno de constantes amenazas que llegan desde cualquier lugar, competidores, condiciones de mercado inciertas, etc. Es ante estas situaciones donde las empresas pueden confiar en modelos predictivos para explotar los patrones en datos transaccionales e históricos con el fin de pronosticar el futuro con un cierto grado de precisión. Desarrollar un modelo de Predictive Analytics ayuda a evaluar los riesgos usando un determinado conjunto de condiciones y ayuda a las organizaciones a moverse en un territorio desconocido para tomar las decisiones correctas.

Las empresas no sólo tienen que confiar en la intuición de sus profesionales, sino que también deben tomar decisiones basadas en datos para obtener más información sobre sus clientes, las condiciones del mercado y demás áreas que puedan afectar al negocio. La analítica predictiva se utiliza en una amplia gama de sectores, desde banca, seguros, marketing, análisis de riesgo crediticio, industria manufacturera, cuidado de la salud, gobiernos y toda una serie de verticales.

GLOSARIO AI

Cuando usamos el análisis predictivo estamos más interesados en obtener los eventos del futuro que del pasado o el presente. La precisión de Predictive Analytics depende en gran medida de la cantidad y facilidad de uso de los datos y también del nivel de análisis y la calidad de los supuestos. En un nivel más detallado, Predictive Analytics puede considerarse como una relación de puntuaciones para cada elemento organizacional individual. El área de Predictive Analytics es diferente del forecasting (o pronósticos) en el sentido de que con Predictive Analytics se aprende de los datos para predecir el futuro, de modo que las organizaciones puedan tomar mejores decisiones.

En el entorno competitivo actual las empresas tienen que ir más allá de averiguar qué ha sucedido e intentar dar una evaluación correcta de lo que sucederá en el futuro. Aunque Predictive Analytics lleva bastante tiempo siendo utilizado, ha sido recientemente cuando está teniendo influencia mucho más importante gracias a las siguientes razones:

- La disponibilidad de sistemas informáticos mucho más rápidos y baratos.
- Software disponible para desplegar y mantener.
- La necesidad de una ventaja competitiva real.

Debido a los desarrollos que estamos viendo, está claro que Predictive Analytics no forma parte del área exclusivo de los matemáticos y estadísticos, se trata de una tecnología que se ha difundido llegando a influenciar prácticamente todas las áreas de las empresas. Hoy los analistas de negocio y los responsables en la toma de decisiones están explorando este campo para obtener más información sobre cómo piensa el cliente.

Predictive Analytics se ha ido desarrollado lentamente en los últimos 50 años, pero es ahora cuando estamos asistiendo a un gran salto en el número de empresas que lo utilizan. Debido al crecimiento incesante de Big Data, la presión de la competencia y la necesidad de tomar decisiones basadas en datos es imperativo que las organizaciones utilicen Predictive Analytics. Las técnicas basadas en el modelado predictivo han demostrado que ayudan a trabajar de forma simplificada y a obtener los resultados según el marco específico.

Pasos en el proceso de predictive analytics

- **Definir el proyecto:** este es el primer paso del modelo de Predictive Analytics. Aquí tendrá una definición clara del resultado del proyecto, los objetivos de negocio, el alcance del esfuerzo, la identificación de conjuntos de datos y más tareas.
- **Recopilación de datos:** este es el segundo paso del proceso en el que se extraerán los datos de múltiples fuentes, se preparará el modelo de análisis predictivo y se proporcionará una descripción completa de todo el proceso.
- **Analizar los datos:** este es el proceso que incluye varios pasos: inspección, limpieza, modelado de los datos. Sin estas tareas sería imposible descubrir el objetivo y permitir llegar a una conclusión.

GLOSARIO AI

- **Implementar las estadísticas:** Aquí se trabajará para validar los supuestos e hipótesis y probarlos utilizando los modelos estadísticos estándar.
- **Modelado de datos:** este es el proceso que proporciona la capacidad de crear modelos predictivos automáticos del futuro. También se puede crear un conjunto de modelos y elegir el óptimo.
- **Despliegue del modelo:** este es el paso en el que implementarán los resultados analíticos en las operaciones comerciales cotidianas, lo que ayudará a obtener resultados, informes y el resultado de las decisiones automatizadas.
- **Supervisión del modelo:** Los modelos son revisados para asegurar que el desempeño de este vaya en la dirección correcta.

Prescriptive Analytics

La Analítica Prescriptiva **es un método que optimiza una secuencia de decisiones con el fin de alcanzar un resultado deseado** para cada escenario posible. Esta tendencia es la tercera y final fase de BA (Business Analytics) , categoría que también incluye a Descriptive Analytics y Predictive Analytics.

La mejor forma de entenderla es destacando sus diferencias al interior de BA. El primer nivel corresponde a Descriptive Analytics, que observa los comportamientos históricos del negocio para entender su desempeño y encontrar las razones detrás de un éxito o un fracaso. Este tipo de análisis post-mortem es el que más se realiza actualmente en compañías de todo tipo de tamaños y rubros.


El siguiente paso es Predictive Analytics: ¿qué va a pasar en el futuro, con base en esta información histórica, estas reglas de comportamiento y estos algoritmos predictivos? La analítica predictiva intenta determinar el futuro probable de un escenario o un evento particular, para así ayudar a las organizaciones a tomar mejores decisiones.

Un paso más allá está **Prescriptive Analytics**. Este método no solo anticipa qué pasará y cuándo pasará, sino también por qué. A diferencia de la predictiva, la Analítica Prescriptiva imagina los múltiples escenarios posibles, con las múltiples variables que pueden afectarlos, y sugiere la mejor decisión no solo para un momento específico, sino que tomando en cuenta cuál es la meta final que se quiere conseguir.



GLOSARIO AI

Otra característica que define a Prescriptive Analytics es que recibe e integra información de forma constante. Esto le permite re-predecir y re-prescribir cada vez que el escenario se vea afectado por una nueva variable, con esto mejora la precisión de cada predicción y asegura que se estará tomando la mejor decisión, aún cuando la situación cambie. En el ejemplo del escalador, Prescriptive Analytics sumaría a su análisis en cada paso el desgaste muscular, las variables climáticas o incluso el ánimo del sujeto en su afán por tocar la cima.



R.

Reinforcement Learning

¿Qué es Reinforcement Learning?


El Aprendizaje Reforzado (o Reinforcement Learning) es un subgrupo de **Machine Learning**. Este tipo de modelos se basan en el aprendizaje por prueba y error a través de un sistema de recompensa y castigo.

GLOSARIO AI

En los modelos de Reinforcement Learning podemos distinguir distintos elementos:

- Agente: Es una pieza de software que tomará las decisiones para intentar llegar a la solución.
- Entorno: Es el medio ambiente donde se encuentra el problema que queremos resolver. A menudo es representado con un modelo matemático.
- Intérprete: Es otra pieza de software que evaluará el efecto que tuvo la acción realizada por el agente sobre el entorno.

- El proceso básico de Reinforcement Learning



El **agente** toma el estado del **entorno** y contempla todas las posibles decisiones que puede tomar. En función de esto toma una decisión y realiza una **acción**. Consecuentemente, el **entorno** se verá modificado por dicha acción. Luego, el **intérprete** analiza cómo se modificó el **entorno** como producto de la **acción** tomada por el **agente**. En función de este resultado, el **intérprete** le va a asignar a esa **acción** una **valoración**, de acuerdo con si ésta ayudó a acercarse (**recompensa**) o a alejarse (**castigo**) de la solución. En una siguiente iteración, el **agente** realiza una acción sobre el nuevo **entorno** modificado. Dicha acción la tomará teniendo en cuenta si en las iteraciones anteriores ese camino contribuyó a la solución o no. En otras palabras, el agente elegirá ir por el camino que más recompensa le dé.

GLOSARIO AI

S.

Supervised Learning

¿Qué es Supervised Learning?

Se llama Supervised Learning (o aprendizaje supervisado) al tipo de aprendizaje automático (o Machine Learning) que mapea datos de entrada a datos de salida, a través del entrenamiento de un modelo a partir de ejemplos de pares entrada/salida.

Modelos SL

Entre los modelos de Aprendizaje Supervisado más comunes que podemos encontrar tenemos:

- Regresión Lineal
- Regresión Logística
- Support Vector Machines
- Árboles de decisión
- K-nearest neighbors
- Naive Bayes
- Linear Discriminant Analysis
- Redes Neuronales

U.

Unsupervised Learning

¿Qué es Unsupervised Learning?

En este tipo de aprendizaje automático, a diferencia del Supervised Learning, no contamos con los valores de salida del conjunto de datos de entrenamiento.

Una aplicación de este tipo de aprendizaje es, por ejemplo, intentar encontrar patrones de similitud entre los datos para realizar un agrupamiento (o clustering) de objetos que el algoritmo encuentra como “similares”.

Un ejemplo común de este tipo de aprendizaje son los sistemas de recomendación, los cuales buscan entre los datos de entrada del cliente (por ejemplo, qué tipo de productos consumió recientemente) para recomendar aquellos productos que tendrían mayores probabilidades de resultar de relevancia para los clientes.



baufest
ARTIFICIAL INTELLIGENCE