INTELIGENCIA ARTIFICIAL Y LA PRÁCTICA DEL COACHING ONTOLÓGICO

Enrique Espinosa Cifuentes, MCOA

Este artículo está dirigido a la comunidad de Coaches Ontológicos en general, entre los cuales hay profesionales que pueden no tener un conocimiento cabal de lo que es la Inteligencia Artificial (IA), su origen, sus características generales, sus modos de operar y sus diversas aplicaciones.

Comenzamos con una breve historia del surgimiento de la IA, seguimos con diversas consideraciones y datos que parecen útiles para entender las implicaciones que puede tener el uso de la IA en la práctica del Coaching Ontológico (CO), y concluimos con una brevísima sección de peligros potenciales de la IA para el ejercicio del coaching y algunas consideraciones finales.

El estudio reflejado en este artículo está lejos de haber concluido y éste es sólo un informe inicial para la comisión de Estudios sobre IA y CO del Centro de Investigaciones sobre Coaching y Ontología (CICO) de la FICOP.

Agradezco las extensas conversaciones que he tenido con mi colega y académico **David Gleiser** sobre este tema. Su conocimiento, reflexiones y conversaciones han sido iluminadoras para mí en diversos aspectos, si bien este artículo no representa necesariamente el pensamiento del mencionado académico.

I. BREVE HISTORIA DE LA INTELIGENCIA ARTIFICIAL

El concepto de inteligencia artificial (IA) se remonta a mediados del siglo XX, aunque sus raíces pueden rastrearse hasta épocas anteriores. La IA como campo de estudio formal comenzó a surgir en la década de 1950, con figuras como Alan Turing y su famoso "Test de Turing", que planteaba la cuestión de si una máquina podía exhibir un comportamiento indistinguible de la inteligencia humana.

El término "inteligencia artificial" se acuñó oficialmente en una conferencia en Dartmouth College en 1956, donde se reunieron pioneros en matemáticas, ciencias de la computación y teoría de la información para explorar cómo las máquinas podrían simular el pensamiento humano.

El progreso en el campo de la inteligencia artificial ha sido significativo desde entonces, aunque con altibajos en términos de avances tecnológicos y momentos de estancamiento conocidos como "inviernos de la IA". A medida que la capacidad de procesamiento

aumentaba y surgían nuevas técnicas y algoritmos, la IA comenzó a aplicarse en diversas áreas, como reconocimiento de patrones, procesamiento de lenguaje natural, robótica, juegos y más.

Hoy en día, la inteligencia artificial se encuentra en una amplia gama de aplicaciones, desde asistentes virtuales hasta sistemas de conducción autónoma, diagnósticos médicos asistidos por IA, predicciones de mercado y mucho más. Utiliza diversas técnicas, como el aprendizaje automático (*machine learning*), las redes neuronales, el procesamiento del lenguaje natural y la visión por computadora, entre otras, para simular procesos cognitivos humanos y realizar tareas que, tradicionalmente, requerirían inteligencia humana.

Aquí hay un breve resumen de los hitos clave en la historia de la IA:

1. **Década de 1940: Teorías iniciales y conceptos:**
    - Durante la Segunda Guerra Mundial, se desarrollaron las primeras teorías sobre máquinas calculadoras y se comenzó a especular sobre la posibilidad de construir máquinas que pudieran simular el pensamiento humano.
2. **Década de 1950: Nacimiento de la Inteligencia Artificial:**
    - En 1950, el matemático y lógico Alan Turing propuso la "Prueba de Turing", un criterio para determinar si una máquina puede exhibir un comportamiento inteligente indistinguible del de un humano. Esta idea sentó las bases para la investigación en IA.
    - En el mismo período, el científico de la computación John McCarthy acuñó el término "inteligencia artificial" y organizó la Conferencia de Dartmouth en 1956, considerada como el punto de partida oficial de la investigación en IA.
3. **Década de 1960: Desarrollos tempranos:**
    - Se desarrollaron programas de lenguaje natural y se experimentó con sistemas expertos, que eran programas diseñados para imitar el razonamiento humano en áreas específicas.
4. **Década de 1970: Críticas y avances en la IA:**
    - A mediados de la década, la IA enfrentó críticas debido a las expectativas exageradas y la falta de avances significativos. Sin embargo, se realizaron avances en áreas como el procesamiento del lenguaje natural y la visión por computadora.
5. **Década de 1980: Sistemas expertos y auge de la IA:**
    - Los sistemas expertos, programas que imitaban el conocimiento y el razonamiento humano en áreas especializadas, experimentaron un auge en esta década. Sin embargo, el entusiasmo inicial fue seguido por una nueva ola de escepticismo debido a las limitaciones tecnológicas de la época.
6. **Década de 1990: Enfoques más pragmáticos:**
    - Se adoptaron enfoques más pragmáticos, y la investigación se centró en aplicaciones prácticas de la IA en lugar de en la creación de una inteligencia general. Surgieron sistemas de aprendizaje automático y redes neuronales.

7. **Década de 2000 en adelante: Auge de la IA y el aprendizaje profundo:**
    - Con el aumento de la potencia computacional y grandes conjuntos de datos, la IA experimentó un renacimiento. El aprendizaje profundo, una forma de aprendizaje automático basada en redes neuronales profundas, se convirtió en una fuerza impulsora en el progreso de la IA.

II. EL TEST DE TURING

Es un test propuesto por el matemático y filósofo británico Alan Turing para evaluar la capacidad de una máquina para exhibir un comportamiento inteligente equivalente o indistinguible del de un ser humano.

La prueba se lleva a cabo en un entorno en el que un humano, el interrogador, mantiene una conversación con dos interlocutores, uno humano y otro una máquina. El interrogador no sabe cuál de los interlocutores es la máquina. Si el interrogador no puede distinguir entre la máquina y el humano, se dice que la máquina ha pasado la prueba de Turing.

La prueba de Turing se ha utilizado como un estándar para medir la inteligencia artificial y la capacidad de una máquina para realizar tareas que requieren inteligencia humana, como el procesamiento de lenguaje natural, la toma de decisiones, el razonamiento y la creatividad.

La prueba de Turing ha sido criticada por ser demasiado subjetiva y por centrarse únicamente en el comportamiento inteligente, sin tener en cuenta otros aspectos de la inteligencia, como la comprensión del mundo o la capacidad de resolver problemas.

A pesar de sus limitaciones, la prueba de Turing sigue siendo una herramienta importante para evaluar el progreso de la IA.

En concreto, la prueba de Turing se puede aplicar a la IA de las siguientes maneras:

- Como un objetivo para el desarrollo de la IA. La prueba de Turing se puede utilizar como un objetivo para el desarrollo de la IA, ya que representa un reto significativo para las máquinas. Si una máquina puede pasar la prueba de Turing, significaría que ha logrado un nivel de inteligencia comparable al de los humanos.
- Como una herramienta para evaluar el rendimiento de la IA. La prueba de Turing se puede utilizar como una herramienta para evaluar el rendimiento de la IA. Si una máquina puede pasar la prueba de Turing, significa que es capaz de mantener una conversación con un humano de forma indistinguible de un humano.

- Como una herramienta para comprender la naturaleza de la inteligencia. La prueba de Turing también puede utilizarse como una herramienta para comprender la naturaleza de la inteligencia. Si una máquina puede pasar la prueba de Turing, significa que las máquinas pueden exhibir un comportamiento inteligente que antes se creía que era exclusivo de los humanos.

  En los últimos años, se han producido avances significativos en el desarrollo de la IA. Algunas máquinas, como el chatbot LaMDA de Google, han sido capaces de pasar pruebas de Turing simplificadas. Sin embargo, aún no se ha logrado que una máquina pase la prueba de Turing completa.

III. ¿QUÉ ENTENDEMOS POR "INTELIGENCIA"?

La "inteligencia" es un concepto complejo y multifacético que puede tener diferentes interpretaciones dependiendo del contexto en el que se utilice. En términos generales, la inteligencia se refiere a la capacidad de aprender, comprender, razonar, adaptarse a nuevas situaciones y resolver problemas de manera efectiva. Es una facultad mental que implica la capacidad de procesar información, aprender de la experiencia, y aplicar ese conocimiento de manera práctica.

La inteligencia no se limita a una única forma de habilidad, y existen diversas teorías y enfoques para comprenderla. Algunos enfoques destacados incluyen:

1. **Inteligencia general (o factor g):** Propuesta por psicólogos como Charles Spearman, esta teoría sugiere que existe una "inteligencia general" que subyace a todas las habilidades cognitivas. Las personas que son buenas en una tarea tienden a ser buenas en otras.
2. **Teoría de las inteligencias múltiples:** Desarrollada por Howard Gardner, esta teoría sugiere que la inteligencia no es una capacidad unitaria, sino que se compone de varias habilidades distintas. Gardner identificó diferentes tipos de inteligencias, como la lingüística, la lógico-matemática, la espacial, la musical, la interpersonal, la intrapersonal, la corporal-kinestésica, la naturalista y la existencial.
3. **Enfoques cognitivos:** Se centran en procesos específicos de pensamiento, como la memoria, el razonamiento lógico, la resolución de problemas y la toma de decisiones.
4. **Inteligencia emocional:** Propuesta por Daniel Goleman, esta teoría se centra en la capacidad de reconocer, entender y gestionar las propias emociones y las emociones de los demás.

La comprensión de la inteligencia es un tema complejo y en constante evolución, y la investigación en psicología y neurociencia continúa explorando sus aspectos más profundos. La inteligencia no se limita a los seres humanos, ya que también se puede discutir en el contexto de la inteligencia artificial, donde las máquinas pueden ser diseñadas para realizar tareas que requieren algún grado de "inteligencia".

IV. ¿POR QUÉ LA IA ES “ARTIFICIAL”?

- La expresión "Inteligencia Artificial" (IA) se refiere a la capacidad de las máquinas para realizar tareas que normalmente requieren inteligencia humana. El término "artificial" se utiliza para denotar que esta inteligencia no es intrínseca o biológica, como la inteligencia humana, sino que es creada y programada por seres humanos.

- La IA busca replicar ciertas funciones cognitivas humanas, como el aprendizaje, la resolución de problemas, el reconocimiento de patrones y la toma de decisiones, utilizando algoritmos y modelos matemáticos. Estas capacidades permiten a las máquinas realizar tareas específicas de manera eficiente, aprender de la experiencia y mejorar su rendimiento con el tiempo.

- La utilización del término "artificial" en este contexto enfatiza que la inteligencia en cuestión no surge de procesos naturales, biológicos o evolutivos, sino que es creada por el ser humano mediante la programación y el diseño de sistemas informáticos. La IA abarca una amplia gama de aplicaciones, desde asistentes virtuales y sistemas de recomendación hasta vehículos autónomos y robots industriales, y continúa siendo un campo de rápido avance en la actualidad.

V. LAS REDES NEURONALES EN LA IA

¿Qué es una red neuronal?

Una red neuronal es un método de la inteligencia artificial que enseña a las computadoras a procesar datos de una manera que está inspirada en la forma en que lo hace el cerebro humano. Se trata de un tipo de proceso de *machine learning* llamado aprendizaje profundo, que utiliza los nodos o las neuronas interconectados en una estructura de capas que se parece al cerebro humano. Crea un sistema adaptable que las computadoras utilizan para aprender de sus errores y mejorar continuamente. De esta forma, las redes neuronales artificiales intentan resolver problemas complicados, como la realización de resúmenes de documentos o el reconocimiento de rostros, con mayor precisión.

¿Por qué son importantes las redes neuronales?

Las redes neuronales pueden ayudar a las computadoras a tomar decisiones inteligentes con asistencia humana limitada. Esto se debe a que pueden aprender y modelar las

relaciones entre los datos de entrada y salida que no son lineales y que son complejos. Por ejemplo, pueden realizar las siguientes tareas.

Hacer generalizaciones y sacar conclusiones

Las redes neuronales pueden comprender datos no estructurados y hacer observaciones generales sin un entrenamiento explícito. Por ejemplo, pueden reconocer que dos oraciones de entrada diferentes tienen un significado similar:

- ¿Puede explicarme cómo hacer el pago?
- ¿Cómo puedo transferir dinero?

Una red neuronal sabría que ambas oraciones significan lo mismo. O sería capaz de reconocer, en términos generales, que Baxter Road es un lugar, pero que Baxter Smith es el nombre de una persona.

¿Para qué se utilizan las redes neuronales?

Las redes neuronales están presentes en varios casos de uso en muchos sectores, como los siguientes:

- Diagnóstico médico mediante la clasificación de imágenes médicas
- Marketing orientado mediante el filtrado de redes sociales y el análisis de datos de comportamiento
- predicciones financieras mediante el procesamiento de datos históricos de instrumentos financieros
- Previsión de la carga eléctrica y la demanda de energía
- Proceso y control de calidad
- Identificación de compuestos químicos

A continuación, presentamos cuatro de las aplicaciones más importantes de las redes neuronales.

Visión artificial

La visión artificial es la capacidad que tienen las computadoras para extraer información y conocimientos de imágenes y videos. Con las redes neuronales, las computadoras pueden distinguir y reconocer imágenes de forma similar a los humanos. La visión artificial tiene varias aplicaciones, como las siguientes:

- Reconocimiento visual en los vehículos autónomos para que puedan reconocer las señales de tráfico y a otros usuarios del camino

- Moderación de contenido para eliminar de forma automática los contenidos inseguros o inapropiados de los archivos de imágenes y videos
- Reconocimiento facial para identificar rostros y reconocer atributos como ojos abiertos, gafas y vello facial
- Etiquetado de imágenes para identificar logotipos de marcas, ropa, equipos de seguridad y otros detalles de la imagen

Reconocimiento de voz

Las redes neuronales pueden analizar el habla humana a pesar de los diferentes patrones de habla, el tono, el idioma y el acento. Los asistentes virtuales como Amazon Alexa y el *software* de transcripción automática utilizan el reconocimiento de voz para realizar tareas como las siguientes:

- Asistir a los agentes de los centros de llamadas y clasificar las llamadas de forma automática
- Convertir las conversaciones clínicas en documentación en tiempo real
- Subtitular con precisión videos y grabaciones de reuniones para aumentar el alcance del contenido

Procesamiento de lenguaje natural

El procesamiento de lenguaje natural (PLN) es la capacidad de procesar texto natural creado por humanos. Las redes neuronales ayudan a las computadoras a obtener información y significado a partir de los datos y los documentos de texto. El PLN está presente en varios casos de uso, entre los que se incluyen los siguientes:

- *Chatbots* y agentes virtuales automatizados
- Organización y clasificación automáticas de datos escritos
- Análisis de inteligencia empresarial de documentos con formato largo, como *emails* y formularios
- Indexación de frases clave que indican sentimientos, como los comentarios positivos y negativos en las redes sociales
- Resumen de documentos y producción de artículos para un tema determinado

Motores de recomendaciones

Las redes neuronales pueden hacer un seguimiento de la actividad del usuario para elaborar recomendaciones personalizadas. También pueden analizar todo el comportamiento de los usuarios y descubrir productos o servicios nuevos que interesen a

un usuario específico. Por ejemplo, Curalate, una empresa emergente con sede en Filadelfia, ayuda a las marcas a convertir las publicaciones en las redes sociales en ventas. Las marcas utilizan el servicio de etiquetado inteligente de productos (IPT) de Curalate para automatizar la recopilación y la selección del contenido social que generan los usuarios. El IPT utiliza las redes neuronales para encontrar y recomendar de forma automática productos relevantes para la actividad del usuario en las redes sociales. Los consumidores no tienen que buscar en los catálogos en línea para encontrar un producto específico a partir de una imagen en las redes sociales. En cambio, pueden utilizar el etiquetado automático de productos de Curalate para comprar el producto con facilidad.

¿Cómo funcionan las redes neuronales?

El cerebro humano es lo que inspira la arquitectura de las redes neuronales. Las células del cerebro humano, llamadas neuronas, forman una red compleja y con un alto nivel de interconexión y se envían señales eléctricas entre sí para ayudar a los humanos a procesar la información. De manera similar, una red neuronal artificial está formada por neuronas artificiales que trabajan juntas para resolver un problema. Las neuronas artificiales son módulos de *software*, llamados nodos, y las redes neuronales artificiales son programas de *software* o algoritmos que, en esencia, utilizan sistemas informáticos para resolver cálculos matemáticos.

Arquitectura de una red neuronal simple

Una red neuronal básica tiene neuronas artificiales interconectadas en tres capas:

Capa de entrada

La información del mundo exterior entra en la red neuronal artificial desde la capa de entrada. Los nodos de entrada procesan los datos, los analizan o los clasifican y los pasan a la siguiente capa.

Capa oculta

Las capas ocultas toman su entrada de la capa de entrada o de otras capas ocultas. Las redes neuronales artificiales pueden tener una gran cantidad de capas ocultas. Cada capa oculta analiza la salida de la capa anterior, la procesa aún más y la pasa a la siguiente capa.

Capa de salida

La capa de salida proporciona el resultado final de todo el procesamiento de datos que realiza la red neuronal artificial. Puede tener uno o varios nodos. Por ejemplo, si tenemos un problema de clasificación binaria (sí/no), la capa de salida tendrá un nodo de salida que dará como resultado 1 o 0. Sin embargo, si tenemos un problema de clasificación multiclase, la capa de salida puede estar formada por más de un nodo de salida.

Arquitectura de una red neuronal profunda

Las redes neuronales profundas, o redes de aprendizaje profundo, tienen varias capas ocultas con millones de neuronas artificiales conectadas entre sí. Un número, denominado peso, representa las conexiones entre un nodo y otro. El peso es un número positivo si un nodo estimula a otro, o negativo si un nodo suprime a otro. Los nodos con valores de peso más altos tienen mayor influencia en los demás nodos.
En teoría, las redes neuronales profundas pueden asignar cualquier tipo de entrada a cualquier tipo de salida. Sin embargo, también necesitan mucho más entrenamiento en comparación con otros métodos de *machine learning*. Necesitan millones de ejemplos de datos de entrenamiento en lugar de los cientos o miles que podría necesitar una red más simple.

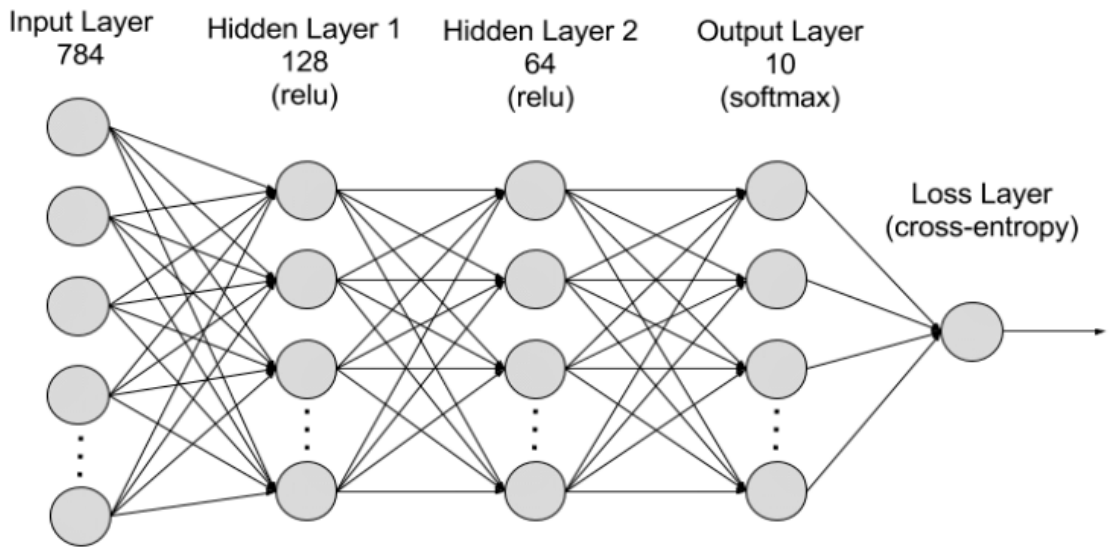

¿Cuáles son los tipos de redes neuronales?

Las redes neuronales artificiales pueden clasificarse en función de cómo fluyen los datos desde el nodo de entrada hasta el nodo de salida. A continuación, se indican varios ejemplos:

Redes neuronales pre alimentadas

Las redes neuronales pre alimentadas procesan los datos en una dirección, desde el nodo de entrada hasta el nodo de salida. Todos los nodos de una capa están conectados a todos

los nodos de la capa siguiente. Una red pre alimentada utiliza un proceso de retroalimentación para mejorar las predicciones a lo largo del tiempo.

Algoritmo de retropropagación

Las redes neuronales artificiales aprenden de forma continua mediante el uso de bucles de retroalimentación correctivos para mejorar su análisis predictivo. En pocas palabras, puede pensar en los datos que fluyen desde el nodo de entrada hasta el nodo de salida a través de muchos caminos diferentes en la red neuronal. Solo un camino es el correcto: el que asigna el nodo de entrada al nodo de salida correcto. Para encontrar este camino, la red neuronal utiliza un bucle de retroalimentación que funciona de la siguiente manera:

1. Cada nodo intenta adivinar el siguiente nodo de la ruta.
2. Se comprueba si la suposición es correcta. Los nodos asignan valores de peso más altos a las rutas que conducen a más suposiciones correctas y valores de peso más bajos a las rutas de los nodos que conducen a suposiciones incorrectas.
3. Para el siguiente punto de datos, los nodos realizan una predicción nueva con las trayectorias de mayor peso y luego repiten el paso 1.

Redes neuronales convolucionales

Las capas ocultas de las redes neuronales convolucionales realizan funciones matemáticas específicas, como la síntesis o el filtrado, denominadas convoluciones. Son muy útiles para la clasificación de imágenes porque pueden extraer características relevantes de las imágenes que son útiles para el reconocimiento y la clasificación de imágenes. La forma nueva es más fácil de procesar sin perder características que son fundamentales para hacer una buena predicción. Cada capa oculta extrae y procesa diferentes características de la imagen, como los bordes, el color y la profundidad.

¿Cómo entrenar las redes neuronales?

El entrenamiento de redes neuronales es el proceso de enseñar a una red neuronal a realizar una tarea. En principio, las redes neuronales aprenden procesando varios conjuntos grandes de datos etiquetados o sin etiquetar. Debido a que utilizan estos ejemplos, pueden procesar entradas desconocidas con mayor precisión.

Aprendizaje supervisado

En el aprendizaje supervisado, los científicos de datos proporcionan a las redes neuronales artificiales conjuntos de datos etiquetados que ofrecen la respuesta correcta por adelantado. Por ejemplo, una red de aprendizaje profundo que se entrena sobre el reconocimiento facial, en un principio, procesa cientos de miles de imágenes de rostros humanos, con varios términos relacionados con el origen étnico, el país o la emoción que describen a cada imagen.

La red neuronal aumenta lentamente el conocimiento a partir de estos conjuntos de datos, que proporcionan la respuesta correcta por adelantado. Una vez que se entrena la red, comienza a adivinar el origen étnico o la emoción de una imagen nueva de un rostro humano que nunca antes ha procesado.

¿Qué es el aprendizaje profundo en el contexto de las redes neuronales?

La inteligencia artificial es el campo de las ciencias de la computación que investiga métodos para dar a las máquinas la capacidad de realizar tareas que requieren inteligencia humana. El *machine learning* es una técnica de inteligencia artificial que otorga a las computadoras acceso a conjuntos de datos muy grandes y les enseña a aprender de estos datos. El *software* de *machine learning* encuentra patrones en los datos existentes y los aplica a datos nuevos para tomar decisiones inteligentes. El aprendizaje profundo es un subconjunto del *machine learning* que utiliza las redes de aprendizaje profundo para procesar los datos.

Comparación entre *machine learning* y aprendizaje profundo

Los métodos tradicionales de *machine learning* requieren la intervención humana para que el *software* de *machine learning* funcione suficientemente bien. Un científico de datos determina de forma manual el conjunto de características relevantes que el *software* debe analizar. Esto limita la capacidad del *software*, lo que hace que su creación y administración sean tediosas.

Por otro lado, en el aprendizaje profundo, el científico de datos solo proporciona datos sin procesar al *software*. La red de aprendizaje profundo obtiene las características por sí misma y aprende de forma más independiente. Puede analizar conjuntos de datos no estructurados como documentos de texto, identificar qué atributos de los datos deben priorizarse y resolver problemas más complejos.

Por ejemplo, si se entrenara un *software* de *machine learning* para identificar la imagen de una mascota de forma correcta, debería seguir estos pasos:

- Encontrar y etiquetar de forma manual miles de imágenes de mascotas, como gatos, perros, caballos, hámsters, loros, etc.
- Indicar al *software* de *machine learning* qué características debe buscar para poder identificar la imagen mediante la eliminación. Por ejemplo, podría contar el número de patas, comprobar la forma de los ojos, la forma de las orejas, la cola, el pelo, etc.
- Evaluar y cambiar de forma manual los conjuntos de datos etiquetados para mejorar la precisión del *software*. Por ejemplo, si su conjunto de entrenamiento cuenta con demasiadas fotos de gatos negros, el *software* identificará de forma correcta a un gato negro pero no a uno blanco.

- En el aprendizaje profundo, sin embargo, las redes neuronales procesarían todas las imágenes y determinarían de forma automática que necesitan analizar primero el número de patas y la forma de la cara, y mirar las colas en último lugar para identificar con éxito el animal en la imagen.

¿Cuáles son los servicios de aprendizaje profundo en AWS?

Los servicios de aprendizaje profundo de AWS aprovechan la potencia de la computación en la nube de modo que sea posible escalar las redes neuronales de aprendizaje profundo a un costo menor, así como optimizarlas para que sean más rápidas. También puede utilizar servicios de AWS como estos para administrar por completo las aplicaciones específicas de aprendizaje profundo:

- Amazon Rekognition permite agregar características de visión artificial entrenadas previamente o personalizables a la aplicación.
- Amazon Transcribe permite reconocer y transcribir de forma automática el habla con precisión.
- Amazon Lex para crear chatbots inteligentes que comprendan la intención, mantengan el contexto conversacional y automaticen tareas simples en muchos idiomas.

VI. CÓMO ES EL ANÁLISIS DE SENTIMIENTOS MEDIANTE LA INTELIGENCIA ARTIFICIAL

El análisis de sentimientos mediante la inteligencia artificial es un proceso que implica utilizar algoritmos y técnicas de procesamiento de lenguaje natural (NLP, por sus siglas en inglés) para identificar, extraer y evaluar la polaridad emocional (positiva, negativa o neutra) de un texto, ya sea una opinión, un comentario, un *tweet*, una reseña, entre otros.

Aquí hay un resumen de cómo se lleva a cabo este análisis:

1. **Preprocesamiento de texto:** Antes de analizar el sentimiento, es crucial limpiar y preparar el texto. Esto puede incluir eliminar signos de puntuación, stopwords (palabras comunes que no aportan significado), lematización o derivación de palabras (para reducir las palabras a su forma base), y normalización de texto (como convertir texto a minúsculas).

2. **Modelos de Machine Learning:** Se utilizan modelos de aprendizaje automático, como máquinas de vectores de soporte (SVM), redes neuronales, modelos de lenguaje como BERT, entre otros, entrenados con conjuntos de datos etiquetados previamente con sentimientos asociados a textos. Estos modelos aprenden patrones lingüísticos para identificar la polaridad emocional en nuevos textos.

3. **Extracción de características:** Se extraen características relevantes del texto, como palabras clave, n-gramas (secuencias de palabras), estructura gramatical y contexto, para ayudar al modelo a comprender el tono y la intención del mensaje.

4. **Clasificación de sentimientos:** Una vez que el modelo ha sido entrenado con datos etiquetados, puede clasificar el sentimiento del texto en categorías como positivo, negativo o neutral. Esto se logra asignando una puntuación de probabilidad a cada clase.

5. **Evaluación y mejora:** Se evalúa la precisión del modelo utilizando conjuntos de datos de prueba y validación. Se ajustan los hiper parámetros y se realiza un ajuste fino del modelo para mejorar su capacidad predictiva.

6. **Aplicaciones:** El análisis de sentimientos se aplica en diversas áreas, como la inteligencia empresarial para comprender la percepción de los clientes sobre productos o servicios, en redes sociales para monitorear opiniones públicas, en la detección de crisis de reputación, entre otros.

Es importante tener en cuenta que, aunque los modelos de análisis de sentimientos han avanzado significativamente, el procesamiento del lenguaje natural y la comprensión del contexto humano aún presentan desafíos, lo que puede llevar a interpretaciones erróneas en ciertos casos. Por lo tanto, el análisis de sentimientos mediante inteligencia artificial es una herramienta útil pero no perfecta, y puede requerir ajustes y revisión humana en ciertos escenarios para obtener resultados precisos y confiables.

VII. MODELOS DE LENGUAJE DE GRAN TAMAÑO

¿Qué son los modelos de lenguaje de gran tamaño?

Los modelos de lenguaje de gran tamaño o *large lenguaje models* (LLM) en inglés, son modelos de aprendizaje profundo muy grandes que se pre entrenan con grandes cantidades de datos. El transformador subyacente es un conjunto de redes neuronales que consta de un codificador y un decodificador con capacidades de auto atención. El codificador y el decodificador extraen significados de una secuencia de texto y comprenden las relaciones entre las palabras y las frases que contiene.

Los transformadores LLM son capaces de entrenarse sin supervisión, aunque una explicación más precisa es que los transformadores llevan a cabo un autoaprendizaje. Es a través de este proceso que los transformadores aprenden a entender la gramática, los idiomas y los conocimientos básicos.

A diferencia de las redes neuronales recurrentes (RNN) anteriores que procesaban las entradas de forma secuencial, los transformadores procesan secuencias enteras en

paralelo. Esto permite a los científicos de datos utilizar las GPU para entrenar LLM basados en transformadores, lo que reduce significativamente el tiempo de entrenamiento.

La arquitectura de las redes neuronales del transformador permite el uso de modelos muy grandes, a menudo con cientos de miles de millones de parámetros. Estos modelos a gran escala pueden incorporar cantidades masivas de datos, a menudo de Internet, pero también de fuentes como Common Crawl, que comprende más de 50 000 millones de páginas web, y Wikipedia, que tiene aproximadamente 57 millones de páginas.

¿Por qué son importantes los modelos de lenguaje de gran tamaño?

Los modelos de lenguaje de gran tamaño son increíblemente flexibles. Un modelo puede realizar tareas completamente diferentes, como responder preguntas, resumir documentos, traducir idiomas y completar oraciones. Los LLM tienen el potencial de alterar la creación de contenido y la forma en que las personas utilizan los motores de búsqueda y los asistentes virtuales.

Si bien no son perfectos, los LLM están demostrando una notable capacidad para hacer predicciones basadas en un número relativamente pequeño de indicaciones o entradas. Los LLM se pueden utilizar en la IA generativa para producir contenido basado en indicaciones de entrada en lenguaje humano.

Los LLM son grandes, muy grandes. Pueden considerar miles de millones de parámetros y tienen muchos usos posibles. A continuación, se indican varios ejemplos:

- El modelo GPT-3 de OpenAI tiene 175 000 millones de parámetros. Su primo, ChatGPT, puede identificar patrones a partir de datos y generar resultados naturales y legibles. Si bien no sabemos el tamaño de Claude 2, puede aceptar entradas con hasta 100 000 tokens en cada indicación, lo que significa que puede funcionar en cientos de páginas de documentación técnica o, incluso, en un libro completo.
- El modelo Jurassic-1 de AI21 Labs tiene 178 000 millones de parámetros y un vocabulario simbólico de partes de 250 000 palabras y capacidades de conversación similares.
- El modelo Command de Cohere tiene capacidades similares y puede funcionar en más de 100 idiomas diferentes.
- El Paradigm de LightOn ofrece modelos básicos con capacidades declaradas que superan las del GPT-3. Todos estos LLM vienen con las API que permiten a los desarrolladores crear aplicaciones únicas de IA generativa.

¿Cómo funcionan los modelos de lenguaje de gran tamaño?

Un factor clave en el funcionamiento de los LLM es la forma en que representan las palabras. Las formas anteriores de *machine learning* utilizaban una tabla numérica para representar cada palabra. Sin embargo, esta forma de representación no podía reconocer las relaciones entre las palabras, como las palabras con significados similares. Esta limitación se superó mediante el uso de vectores multidimensionales, también denominados incrustaciones de palabras, para representar palabras de modo que las palabras con significados contextuales similares u otras relaciones estén cerca unas de otras en el espacio vectorial.

Al utilizar incrustaciones de palabras, los transformadores pueden pre procesar el texto como representaciones numéricas a través del codificador y comprender el contexto de palabras y frases con significados similares, así como otras relaciones entre palabras, como las partes del discurso. Entonces es posible que los LLM apliquen este conocimiento del idioma a través del decodificador para producir un resultado único.

¿Qué son las aplicaciones de modelos de lenguaje de gran tamaño?

Hay muchas aplicaciones prácticas para los LLM.

Redacción de textos publicitarios

Además de GPT-3 y ChatGPT, Claude, Llama 2, Cohere Command y Jurassic pueden escribir copias originales. AI21 Wordspice sugiere cambios en las oraciones originales para mejorar el estilo y la voz.

Respuesta a la base de conocimientos

La técnica, que a menudo se denomina procesamiento del lenguaje natural intensivo en conocimiento (KI-NLP), se refiere a los LLM que pueden responder a preguntas específicas a partir de la información en los archivos digitales. Un ejemplo es la capacidad de AI21 Studio Playground para responder a preguntas de conocimiento general.

Clasificación de textos

Mediante la agrupación en clústeres, los LLM pueden clasificar textos con significados o sentimientos similares. Los usos incluyen medir la opinión de los clientes, determinar la relación entre los textos y buscar documentos.

Generación de código

Los LLM dominan la generación de código a partir de indicaciones en lenguaje natural. Algunos ejemplos incluyen Amazon CodeWhisperer y el Codex de Open AI utilizado en GitHub Copilot, que puede codificar en Python, JavaScript, Ruby y varios otros lenguajes de programación. Otras aplicaciones de codificación incluyen la creación de consultas SQL, la escritura de comandos shell y el diseño de sitios web.

Generación de texto

Al igual que la generación de código, la generación de texto puede completar oraciones incompletas, escribir la documentación del producto o, como Alexa Create, escribir un cuento infantil corto.

¿Cómo se entrenan los modelos de lenguaje de gran tamaño?

Las redes neuronales basadas en transformadores son muy grandes. Estas redes contienen varios nodos y capas. Cada nodo de una capa tiene conexiones con todos los nodos de la capa subsiguiente, cada uno de los cuales tiene un peso y un sesgo. Los pesos y los sesgos, junto con las incrustaciones, se conocen como parámetros del modelo. Las grandes redes neuronales basadas en transformadores pueden tener miles y miles de millones de parámetros. El tamaño del modelo generalmente se determina mediante una relación empírica entre el tamaño del modelo, la cantidad de parámetros y el tamaño de los datos de entrenamiento.

El entrenamiento se lleva a cabo mediante un gran corpus de datos de alta calidad. Durante el entrenamiento, el modelo ajusta, de forma iterativa, los valores de los parámetros hasta que predice correctamente el siguiente token a partir de la secuencia anterior de tokens de entrada. Lo hace mediante técnicas de aprendizaje autónomo que enseñan al modelo a ajustar los parámetros para maximizar la probabilidad de los siguientes tokens en los ejemplos de entrenamiento.

Una vez entrenados, los LLM se pueden adaptar fácilmente para realizar múltiples tareas mediante conjuntos relativamente pequeños de datos supervisados, un proceso que se conoce como ajuste fino.

Existen tres modelos de aprendizaje comunes:

- Aprendizaje de disparo cero: los LLM básicos pueden responder a una amplia gama de solicitudes sin entrenamiento explícito, a menudo a través de indicaciones, aunque la precisión de las respuestas varía.
- Aprendizaje de pocos disparos: al proporcionar algunos ejemplos de entrenamiento relevantes, el rendimiento del modelo fundacional mejora de manera significativa en esa área específica.
- Ajuste fino: se trata de una extensión del aprendizaje de pocos disparos en la que los científicos de datos entrenan un modelo fundacional para ajustar sus parámetros con datos adicionales relevantes para la aplicación específica.

¿Cuál es el futuro de los LLM?

La introducción de modelos de lenguaje de gran tamaño, como ChatGPT, Claude 2 y Llama 2, que pueden responder preguntas y generar texto, apunta a interesantes posibilidades en el futuro. De forma lenta pero segura, los LLM están logrando un

rendimiento similar al humano. El éxito inmediato de estos LLM demuestra un gran interés en los LLM de tipo robótico que emulan y, en algunos contextos, superan al cerebro humano. A continuación, se mencionan algunas reflexiones sobre el futuro de los LLM:

Mayores capacidades

Por impresionantes que sean, el nivel tecnológico actual no es perfecto y los LLM no son infalibles. Sin embargo, las versiones más recientes mejorarán la precisión y las capacidades a medida que los desarrolladores aprendan a mejorar su rendimiento y, al mismo tiempo, reducir los sesgos y eliminar las respuestas incorrectas.

Entrenamiento audiovisual

Si bien los desarrolladores entrenan a la mayoría de los LLM con texto, algunos han empezado a entrenar modelos con entrada de video y audio. Este tipo de entrenamiento debería conducir a un desarrollo de modelos más rápido y abrir nuevas posibilidades en términos de uso de LLM para vehículos autónomos.

Transformación del lugar de trabajo

Los LLM son un factor disruptivo que cambiará el lugar de trabajo. Es probable que los LLM reduzcan las tareas monótonas y repetitivas de la misma manera que lo hicieron los robots con las tareas de fabricación repetitivas. Las posibilidades incluyen tareas administrativas repetitivas, *chatbots* de servicio al cliente y redacción automatizada y simple de textos publicitarios.

IA conversacional

Sin duda, los LLM mejorarán el rendimiento de los asistentes virtuales automatizados como Alexa, Google Assistant y Siri. Podrán interpretar mejor la intención del usuario y responder a comandos sofisticados.

¿Cómo puede ayudar AWS con los LLM?

AWS ofrece varias posibilidades para los desarrolladores de modelos de lenguaje de gran tamaño. Amazon Bedrock es la forma más fácil de crear y escalar aplicaciones de IA generativa con modelos de lenguaje de gran tamaño (LLM). Amazon Bedrock es un servicio totalmente administrado que permite que los LLM de Amazon y de las principales *startups* de IA estén disponibles a través de una API, de modo que pueda elegir entre varios LLM para encontrar el que mejor se adapte a su caso de uso.

Amazon SageMaker JumpStart es un centro de *machine learning* con modelos fundacionales, algoritmos integrados y soluciones de ML pre integradas que puede implementar con unos pocos clics. Con SageMaker JumpStart puede acceder a modelos

previamente entrenados, incluidos los modelos fundacionales, para realizar tareas como el resumen de artículos y la generación de imágenes. Los modelos pre entrenados se pueden personalizar completamente para su caso de uso con sus datos, y puede implementarlos fácilmente en producción con la interfaz de usuario o el SDK.

VIII. GLOSARIO

He aquí algunos términos claves relacionados con al IA:

Inteligencia artificial generativa

La inteligencia artificial generativa se refiere a sistemas o modelos de inteligencia artificial (IA) que tienen la capacidad de generar contenido nuevo y original, como imágenes, texto, música, o incluso videos. Estos modelos utilizan técnicas avanzadas de aprendizaje profundo, como las redes neuronales generativas, para aprender patrones a partir de conjuntos de datos y luego generar datos nuevos que comparten características similares.

Uno de los enfoques más conocidos en este ámbito es el uso de Redes Neuronales Generativas Adversarias (GAN, por sus siglas en inglés). En un sistema GAN, hay dos redes neuronales trabajando en conjunto: el generador y el discriminador. El generador crea datos sintéticos, mientras que el discriminador evalúa la autenticidad de estos datos. Ambas redes mejoran continuamente a medida que compiten entre sí, lo que lleva a la generación de datos cada vez más realistas.

La inteligencia artificial generativa se aplica en diversas áreas, como la creación de imágenes realistas, la producción de texto creativo, la síntesis de música y la generación de contenido multimedia en general. Sin embargo, también plantea desafíos éticos y preocupaciones relacionadas con la capacidad de crear contenido engañoso o manipulado.

Algoritmo

Un algoritmo es un conjunto ordenado de instrucciones o reglas precisas y finitas que se utilizan para realizar una tarea específica o resolver un problema. Los algoritmos son utilizados en matemáticas, ciencias de la computación, programación y diversas áreas para definir paso a paso cómo realizar una tarea o resolver un problema de manera sistemática.

En resumen, un algoritmo es una secuencia lógica y detallada de pasos que se siguen para realizar una tarea o alcanzar un resultado deseado. Los algoritmos son fundamentales en el mundo de la computación, ya que son la base para la creación de programas informáticos y el funcionamiento de sistemas automatizados.

Transformador o *transformer*

En el contexto de la IA, un transformador es un tipo de arquitectura de red neuronal que se utiliza para procesar datos secuenciales. Los transformadores son capaces de aprender el contexto y las relaciones entre los elementos de una secuencia, lo que los hace muy adecuados para tareas como el procesamiento del lenguaje natural (NLP), la traducción automática y la visión artificial.

Los transformadores se componen de una serie de capas de atención, cada una de las cuales está compuesta por una matriz de pesos. Estas matrices de pesos se utilizan para calcular la importancia de cada elemento de la secuencia. La atención permite a los transformadores centrarse en los elementos más relevantes de una secuencia, lo que les permite aprender patrones y relaciones complejos.

Los transformadores se han utilizado con éxito en una amplia gama de tareas de IA, incluyendo:

- Procesamiento del lenguaje natural: Los transformadores se utilizan para tareas de NLP como la traducción automática, la generación de texto, la comprensión del lenguaje natural y la respuesta a preguntas.
- Traducción automática: Los transformadores han revolucionado el campo de la traducción automática, logrando una precisión sin precedentes.
- Visión artificial: Los transformadores se utilizan para tareas de visión artificial como la clasificación de imágenes, la detección de objetos y la comprensión del lenguaje corporal.

Los transformadores son una tecnología de IA muy potente que tiene el potencial de revolucionar una amplia gama de aplicaciones.

Aquí hay algunos ejemplos específicos de cómo se utilizan los transformadores en la IA:

- En el caso de la traducción automática, los transformadores se utilizan para aprender las relaciones entre las palabras en dos idiomas. Esto les permite traducir texto de un idioma a otro de manera precisa y fluida.
- En el caso de la generación de texto, los transformadores se utilizan para generar texto nuevo que sea coherente con el texto existente. Esto se puede utilizar para crear contenido creativo, como poemas, historias o guiones.
- En el caso de la comprensión del lenguaje natural, los transformadores se utilizan para entender el significado del lenguaje humano. Esto se puede utilizar para responder a preguntas, resumir textos o generar respuestas a consultas.

Los transformadores son una tecnología de IA muy prometedora que tiene el potencial de revolucionar una amplia gama de aplicaciones.

IX. ALGUNAS APLICACIONES PRÁCTICAS DE LA IA

Principales aplicaciones prácticas de **la Inteligencia Artificial**

- **Asistentes personales virtuales**

Conviviremos con chatbots interactivos que podrán sugerirnos productos, restaurantes, hoteles, servicios, espectáculos, según nuestro historial de búsquedas.

- **Climáticas**

Flotas de drones capaces de plantar mil millones de árboles al año para combatir la deforestación, vehículos submarinos no tripulados para detectar fugas en oleoductos, edificios inteligentes diseñados para reducir el consumo energético, etc.

- **Agrícolas**

Plataformas específicas que, por medio de análisis predictivos, mejoran los rendimientos agrícolas y advierten de impactos ambientales adversos.

- **Finanzas**

Las tecnologías inteligentes pueden ayudar a los bancos a detectar el fraude, predecir patrones del mercado y aconsejar operaciones a sus clientes.

- **Educación**

Permite saber si un estudiante está a punto de cancelar su registro, sugerir nuevos cursos o crear ofertas personalizadas para optimizar el aprendizaje.

- **Comercial**

Posibilita hacer pronósticos de ventas y elegir el producto adecuado para recomendárselo al cliente. Empresas como Amazon utilizan robots para identificar si un libro tendrá o no éxito, incluso antes de su lanzamiento.

- **Logística y transporte**

Será útil a la hora de evitar colisiones o atascos y también para optimizar el tráfico. Tesla ha desarrollado un sistema gracias al cual, cuando uno de sus coches transita una ruta por primera vez, comparte la información con el resto.

- **Sanidad**

Ya existen chatbots que nos preguntan por nuestros síntomas para realizar un diagnóstico. La recolección de datos genera patrones que ayudan a identificar factores genéticos susceptibles de desarrollar una enfermedad.

X. ALGUNOS PELIGROS DE SER COACHEADO POR IA

La inteligencia artificial (IA) está revolucionando muchos campos, incluido el coaching. Los coaches de IA utilizan algoritmos para analizar los datos de los clientes y proporcionarles retroalimentación y consejos personalizados. Sin embargo, existen algunos peligros potenciales asociados con el coaching de IA.

Prejuicio

Los algoritmos de IA están entrenados en datos, y estos datos pueden reflejar los prejuicios de las personas que los recopilan. Por lo tanto, es posible que los coaches de IA proporcionen retroalimentación sesgada a los clientes.

Falta de empatía

Los coaches de IA no tienen la misma capacidad de empatía que los coaches humanos. Esto puede dificultar que los coaches de IA entiendan las necesidades y motivaciones de los clientes.

Falta de flexibilidad

Los coaches de IA están limitados por los datos en los que están entrenados. Esto puede dificultar que los coaches de IA se adapten a las necesidades cambiantes de los clientes.

Costo

Los coaches de IA pueden ser costosos de desarrollar y mantener. Esto puede limitar la disponibilidad de coaches de IA para las personas que los necesitan.

Privacidad

Los coaches de IA necesitan recopilar datos sobre los clientes para funcionar. Esto plantea preocupaciones de privacidad sobre cómo se utilizan estos datos.

A continuación se presentan algunos consejos para mitigar los peligros potenciales del coaching de IA:

- Elija un coach de IA que sea transparente sobre sus datos de entrenamiento y algoritmos.
- Busque un coach de IA que pueda proporcionar retroalimentación personalizada que se adapte a sus necesidades individuales.
- Sea consciente de las limitaciones de los coaches de IA y esté preparado para trabajar con ellos para desarrollar un plan de coaching que funcione para usted.

En general, el coaching de IA tiene el potencial de ser una herramienta valiosa para el desarrollo personal y profesional. Sin embargo, es importante ser consciente de los peligros potenciales asociados con esta tecnología antes de comprometerse con ella.

XI. UNA APRECIACIÓN PRELIMINAR SOBRE la IA y el COACHING ONTOLÓGICO

Una síntesis reflexiva sobre el uso de la IA en la práctica del Coaching Ontológico

La inteligencia artificial (IA) se ha consolidado como una herramienta innovadora y poderosa en diversos campos profesionales, y difícilmente el coaching ontológico sea la excepción. Como otras herramientas creadas por los seres humanos, ésta seguramente llegará a ser tan “normal” en las tareas de nuestra cultura global que llegará a ser usada automáticamente y sin mayor reflexión por los coaches ontológicos.

En la práctica del coaching ontológico, que se enfoca en el cambio personal y transformacional, la IA podría servir para potenciar y enriquecer el proceso de acompañamiento a los clientes.

Se sugiere que la IA en el ámbito del coaching ontológico “ofrece una gama de posibilidades fascinantes” (ChatGPT). A través de algoritmos avanzados, análisis de datos y aprendizaje automático, las plataformas de IA pueden procesar grandes cantidades de información para identificar patrones, tendencias y áreas de oportunidad. Esto permitiría a los coaches ontológicos acceder a perspectivas más profundas y precisas sobre sus clientes, generando así un análisis más completo y personalizado de sus necesidades, desafíos y potencialidades.

Desde la automatización de tareas administrativas hasta la elaboración de perfiles psicológicos más detallados, la IA puede brindar herramientas que agilizan el trabajo del coach ontológico, liberándolo para concentrarse en aspectos más humanos y estratégicos de la interacción con sus clientes. Además, la inteligencia artificial facilita la recopilación de datos relevantes que pueden servir como base para diseñar estrategias de acompañamiento más efectivas y adaptadas a las necesidades individuales de cada persona.

Se ha sugerido que ser coacheado por una máquina dotada de IA podría evitar los sesgos personales, culturales, emocionales y otros del coach humano y de esta manera servir al coachee de una manera más "objetiva".

Sin embargo, es importante tener en cuenta que la inteligencia artificial no reemplaza la empatía, la intuición ni la habilidad humana para conectar a un nivel emocional con los clientes. La esencia del coaching ontológico sigue siendo la relación genuina entre el coach y el coachee, basada en la confianza, el respeto y la comprensión. Si entendemos a una conversación de coaching como "una danza (*conversare*) entre dos almas, la del coach y la del coachee", queda en duda hasta qué punto la conversación con una máquina podría constituir una danza tal.

En resumen, la integración de la inteligencia artificial en el coaching ontológico puede representar una oportunidad para mejorar la calidad y eficacia de las sesiones, proporcionando herramientas analíticas y de apoyo que complementan la labor del coach, permitiéndole una mayor profundidad en el acompañamiento hacia el crecimiento y desarrollo personal de sus clientes.