

Deus est machina

» **Sebastián Blanco, Ricardo Morán, Matías Teragni, Gonzalo Zabala**

CAETI, Centro de Altos Estudios en Tecnología Informática, Universidad Abierta Interamericana, Argentina / Gonzalo.Zabala@uai.edu.ar

Introducción

Estimado lector, vamos a comenzar este artículo con una pregunta a sus conocimientos de arte. ¿Podría distinguir el autor de esta obra?

Si tuvo la posibilidad de visitar Países Bajos, o de recorrer algunos museos aquí o en otras partes del mundo, seguramente intuirá que estamos frente a una obra de Rembrandt. Sería magnífico poder acompañar esta mirada con música de Bach de fondo (lamentablemente este soporte nos lo impide). Pero si es conocedor de sus creaciones, lo sorprendería con una obra desconocida que puede escuchar en <https://www.youtube.com/watch?v=QiBM7-5hA6o>. Tan desconocida como el cuadro de Rembrandt que tenemos frente a nuestros ojos. ¿Cómo aparecieron?



Figura 1. The Next Rembrandt. ING Group.

No sería la primera vez que la humanidad encuentra alguna obra perdida de un genial creador. Pero no es este el caso. Tanto la pintura como el tema que suena en el link, **son obras de la inteligencia artificial, es decir, creaciones hechas por máquinas a partir de cierto entrenamiento inicial**. Para saber más sobre el proceso que llevó a la pintura final, los invitamos a visitar <https://www.nextrebrandt.com/>.

Ahora bien, ¿hemos alcanzado tal grado de avance en la inteligencia de las máquinas que nos permite crear entes a su vez creadores? ¿Tienen estas máquinas conciencia de su propia capacidad de crear?

En los últimos años el crecimiento de la inteligencia artificial ha sido exponencial en áreas muy diversas: medicina, procesamiento de imágenes, reconocimiento de lenguaje natural, diagnóstico por imágenes, aeronavegación, electrodomésticos, deporte... La lista es inmensa. Y aunque no lo notemos, el impacto de estos desarrollos ya está presente en nuestra vida cotidiana, en nuestros bolsillos, en esos aparatos imprescindibles que llamamos teléfonos inteligentes (smartphones).

Pero, ¿qué es la inteligencia?

Todos recordamos a aquel compañero de clase al que llamábamos “traga” despectivamente, en un acto de rencor que ocultaba nuestra admiración por su inteligencia. Lo considerábamos inteligente porque era rápido para las matemáticas, se acordaba los verbos y la clasificación de los mamíferos de memoria... Pero era habitual que este mismo compañero no fuera un gran deportista, o tuviera menos habilidades para entablar relaciones con otros. ¿Era verdaderamente inteligente?

Según un diccionario etimológico, inteligencia indica la cualidad del que sabe elegir entre varias opciones. Y la vida nos presenta el permanente desafío de escoger entre un camino y otro, en muchísimos planos distintos. Es por eso que el concepto de inteligencia fue mutando en los últimos años, abarcando áreas más amplias que simplemente la capacidad matemática o memorística. Por ejemplo, la definición del Mainstream Science of Intelligence finaliza señalando que “...es un concepto que refiere a la capacidad de comprender el propio entorno”. No es lo mismo el entorno de un jugador de fútbol que el de un jugador de ajedrez. O el de un publicista que el de un cirujano. Inteligencia en cada uno de esos mundos implica saber elegir cosas muy diversas.

Es así que tenemos muchas definiciones y taxonomías de la inteligencia. Tal vez la más referida en la actualidad es la **teoría de las inteligencias múltiples** de Howard Gardner, en la cual se la diferencia entre diversos tipos como lingüística, musical, social, emocional, espacial y otras. Pero no es la única, y hasta la actualidad la controversia sigue presente.

Por lo tanto, si no tenemos clara idea de qué es la inteligencia, ¿cómo podremos crear una? Parece un terreno infértil. **O tal vez, es la forma que hemos encontrado para comprendernos a nosotros mismos. Crear inteligencia artificial nos obliga a mirar profundamente nuestra propia inteligencia.**

¿A qué se llama Inteligencia Artificial?

Cuando se crearon las primeras computadoras, uno de los primeros desafíos que apasionó a la comunidad fue la posibilidad de crear máquinas inteligentes. Surgieron muchas propuestas distintas, y entre ellas la discusión de qué características debía tener una computadora para ser considerada en esa categoría. Alan Turing, uno de los pioneros en el diseño de computadoras, propuso una mecánica diferente: no definir un conjunto de cualidades a cumplir, sino establecer un test que de alguna manera permita determinar si una computadora está actuando en forma inteligente o no. De alguna forma, Turing reformuló el viejo refrán que dice “si mueve la cola como un perro, ladra como perro, huele como un perro, entonces es un perro”.

El desafío, conocido como Test de Turing, consiste en lo siguiente: encerramos en una habitación a un ser humano, y en otra a una computadora. En ambos casos nos comunicamos con ellos a través de un teclado y una pantalla, para evitar las dificultades del reconocimiento de habla y síntesis de voz (¡aunque hoy en día esto está solucionado!). El test propone que si un inquisidor humano, con intenciones de determinar quién es quién en cada cuarto, no logra distinguirlo en una cantidad de preguntas o tiempo establecido previamente, entonces puede considerarse que la máquina actuó en forma inteligente. Por ejemplo, la computadora no debe responder cálculos matemáticos rápidamente, porque se revelaría por su poder de cálculo. Por lo tanto, debe “mentirnos” en su tiempo de respuesta. O si le escribimos “Mañana voy a la caza de mi Tía Ana”, debe reírse, indicándonos que tenemos un error de ortografía o un problema psiquiátrico grave. Es decir, debe tener clara la semántica del concepto Tía, y qué cosas son razonables de realizar con una Tía en un estado mental normal.

Por lo tanto, entre otras cosas una máquina para ser considerada inteligente debe tener un buen manejo del lenguaje, una interpretación semántica integral de los símbolos y signos que lo componen. Si lográramos esta capacidad, sólo con ella, el mundo de las computadoras cambiaría radicalmente: los traductores serían más precisos, podríamos charlar con las máquinas, hacer búsquedas en la web más puntuales o que nos clasifiquen las noticias según nuestros intereses... ¿Y esto ya no está presente en nuestros celulares?

Inteligencia artificial fuerte y débil: no es lo mismo ser que parecer

Ahora bien, ¿es lo mismo que una computadora actúe en forma inteligente a que realmente lo sea? ¿Es consciente de su propia inteligencia? ¿Puede aprender y crear, expandiendo los límites de sus conocimientos y habilidades?

Roger Penrose, en su maravilloso libro “La nueva mente del emperador” comentaba:

Durante décadas los defensores de la *Inteligencia Artificial Fuerte (IAF)* han intentado convencernos de que sólo es cuestión de uno o dos siglos (algunos hablan incluso de cincuenta años), para que las computadoras electrónicas hagan todo lo que la mente humana puede hacer. Estimulados por lecturas juveniles de ciencia-ficción y convencidos de que nuestras mentes son simplemente *computadoras hechas de carne* (como Marvin Minsky dijo en cierta ocasión), dan por supuesto que el placer y el dolor, el gusto por la belleza, el sentido del humor, la conciencia y el libre albedrío son cualidades que emergerán de modo natural cuando el comportamiento algorítmico de los robots electrónicos llegue a ser suficientemente complejo.

Los que Penrose llama *defensores de la IAF* son aquellos que consideran que el cerebro humano no es más que un cableado complejo y con una representación analógica de la información (es decir, no hay una transmisión binaria o discreta, sino que, al ser estimulación química, dicha transmisión puede darse en un rango continuo de valores). Por lo tanto, conseguir un cerebro artificial es sólo una cuestión de tiempo. Finalmente podremos desarrollar una máquina que no sólo sea inteligente, sino que tenga consciencia de ello, y que sea capaz de aprender, crear, emocionarse y otras cualidades esencialmente humanas.

Los que consideran posible la simulación de la inteligencia, adhieren a la *Inteligencia Artificial Débil (IAD)*. No tendremos real consciencia, no habrá una cabal comprensión semántica del lenguaje. Simplemente tendremos algoritmos que de alguna forma pueden hacernos creer que realizan estos procesos. Que parecen inteligentes, pero que en realidad no lo son. Un claro ejemplo de esto es el juego propuesto por John Searle, profesor de filosofía norteamericano, conocido como *La habitación china*. Invitamos a buscar el tema en la web para profundizar la discusión.

¿Cuán lejos estamos de esto? ¿A qué número de pregunta llegamos en el test? Veamos cuáles el estado del arte actual, que no es poco...

Redes Neuronales

Entre otras aproximaciones a una arquitectura para simular la inteligencia, la ciencia se lanzó a imitar la estructura organizativa de un cerebro. Luego de muchos años de investigación, y algunos accidentes, sabemos algunas cosas de su funcionamiento como que el cerebro es el principal bastión de nuestras mentes, y que los daños a su estructura física tienen consecuencias directas en la personalidad de los individuos. Pero entender exactamente cómo funciona no es tan trivial.

En 1943 Warren McCulloch, médico y psicólogo, en conjunto con Walter Pitts, matemático, plantearon un modelo hipotético de cómo las neuronas podrían llegar a funcionar, y generaron un pequeño modelo electrónico a modo de ejemplo. El siguiente aporte importante fue de la mano de Donald Hebb en 1949, que identificó que las conexiones entre las neuronas se fortalecen cada vez que son utilizadas. El trabajo de estos pioneros definió las bases estructurales de las redes neuronales modernas.

De la complejidad surgen cosas complejas

¿Qué es una red neuronal? Como indica su nombre, una red neuronal no es más que un conjunto de neuronas conectadas. Y cuando decimos neuronas nos referimos a una cajita sumamente sencilla, que en función de ciertos valores que lee, puede encenderse o no. (En realidad, es más parecido a un dimmer que a una tecla de luz, dado que los valores que toma no son sólo binarios, sino que puede tomar valores intermedios).

Pero estas cajitas por sí mismas no pueden resolver problemas interesantes. Si fuera fácil determinar la mejor jugada de Go, no hubiera sido noticia cuando la computadora de Google venció a Lee Sedol hace un par de años. Es razonable que un problema complejo, necesite una solución compleja.

Las redes neuronales están compuestas de cosas simples, pero su construcción las transforma en elementos complejos. Imagínese, estimado lector, que usted tuviera delante suyo una mesa que

tiene tres filas de tres clavos cada una y se le diera la tarea de describir con lujo de detalle lo que usted ve a otra persona que lo escucha por teléfono. En principio, esto no suena difícil, solo haría falta describir a los clavos, y la distancia entre ellos, pero ¿que tal si además tenemos tramos de hilo atados entre cada par de clavos? De repente tenemos que describir los clavos, su disposición, y a cada hilo que está conectando un par de clavos. Complicando aún más la situación, ¿que tal si le digo que los hilos son de distintos tamaños, colores y materiales? Si tenemos todo en cuenta, la descripción de todo el ensamblado le llevará varios minutos, y probablemente le sea difícil a su interlocutor imaginarse exactamente lo que usted está viendo.

Este ejemplo, levemente forzado, es bastante cercano a la estructura de una red neuronal. En lugar de clavos, tenemos neuronas, que se agrupan en capas y en lugar de hilos tenemos conexiones entre las neuronas. Como regla general, todas las neuronas de cada capa están conectadas con todas las neuronas de la capa siguiente, y esa conexión tiene un peso asociado, es decir, un determinado valor de influencia en la entrada de la neurona siguiente.




Figura 2. Ejemplo de redes neuronales. Ilustración de Mcstrother. Recuperado de https://es.wikipedia.org/wiki/Archivo:Single_layer_ann.svg

¿Cómo funciona una red neuronal?

Dentro de una red neuronal, la primera capa de neuronas se llama de Entrada, y la última de Salida. Todas las demás se llaman capas escondidas, ya que a la hora de usar una red neuronal no tenemos forma de saber siquiera si existen capas entre la entrada y la salida. Cada neurona de la capa de entrada representa un dato individual, como por ejemplo, un conjunto de píxeles en una imagen que nos interesa analizar. Cada neurona en la capa de salida representa una respuesta posible. En el caso que estamos analizando como ejemplo, si estamos intentando reconocer en esa imagen fotos de números de un dígito, nuestra capa de entrada tendrá una neurona por píxel, y nuestra capa de salida tendrá 10 neuronas (una para cada dígito entre el 0 y el 9).

Cada neurona a su vez tiene un nivel de activación. Podemos pensar que cada una cuenta con un número entre 0% y 100% (al igual que el dimmer que nos permite regular la intensidad de la luz del living). El valor que adopta cada neurona depende de los valores de todas las neuronas de la capa inmediatamente anterior, y los pesos de las conexiones que tiene contra cada una de ellas. En particular los niveles de activación de la capa de entrada dependerán de los datos que se desean analizar, y los de la capa de salida pueden ser interpretados como la probabilidad de que la respuesta correcta sea el valor representado por esa neurona.




Figura 3. Pequeña red entrenada para devolver x xor y

Siendo un poquito más formal, podemos decir que la activación de una neurona es la suma de cada neurona anterior, multiplicada por el peso que tiene la conexión. Por ejemplo, para la red que dibujamos recién, podemos decir:

$$N_{2,1} = N_{1,1} * P_1 + N_{1,2} * P_2$$

Eso es todo. No hay algoritmos complejos ni mágicos. Una vez que tenemos nuestra red lo único que hacen falta es un par de sumas y multiplicaciones. Aunque intentando ser honesto existe una pequeña cosa más. Entre capas se aplican funciones no lineales. No se aplica una función predefinida, sino que se busca una que se ajuste al problema que queremos resolver. Estas funciones son lo que permite que nuestra red neuronal tome decisiones complejas. De no ser así, todos nuestros resultados serían aburridamente lineales .

Un poco de matrices

La ecuación que vimos recién puede ser simplificada si representamos a cada capa de neuronas, y al conjunto de pesos entre ellas como matrices (un conjunto de números ordenados en dos dimensiones). Los matemáticos estudiaron hace bastante distintos operadores entre matrices, y en particular, el conjunto completo de sumas y multiplicaciones se puede resumir con el producto de matrices, simplificando todas las cuentas entre dos capas en un simple (y aplicando luego la función no lineal).

En particular, este mecanismo no sólo nos permite trabajar con muchas cuentas de forma muy simple, sino que presenta otras ventajas. Nuestras computadoras son muy buenas haciendo estas operaciones entre matrices. Muchos de los problemas que resuelve la informática terminan en el fondo siendo conjuntos de operaciones matriciales. Esto significa que a diferencia de árboles de decisiones complejos, u otros algoritmos que pueden servir para generar inteligencia artificial, una vez construida una red neuronal su uso es sumamente eficiente.

El truco para generar una buena red neuronal está en cómo la definimos exactamente, es decir, qué capas armamos, cuántas neuronas tienen, qué valores le damos a los pesos (conexiones) y qué funciones no lineales utilizamos para determinar el valor de excitación de cada neurona. Y para entender exactamente cómo se consigue eso, vamos a introducir algunos conceptos esenciales.

Machine Learning

Machine Learning (ML) o aprendizaje automático es un campo de las Ciencias de la Computación que utiliza técnicas estadísticas para proveer a los sistemas computacionales, sin ser explícitamente programados, la habilidad de “aprender” automáticamente con datos la resolución de un problema.

En la programación clásica, se definen y ejecutan reglas para que dado un conjunto de datos, se obtenga una solución. En ML, las reglas son la incógnita. Esto significa que lo que se busca (en forma aproximada) es qué hace que los datos entrantes se conviertan en la solución que nosotros tenemos o intuimos. Al encontrarlos, decimos que la máquina aprende. En el mejor de los casos, encontramos representaciones y patrones que nos brindan resultados que jamás habíamos pensado. Ahí es cuando la máquina entra al servicio de aumentar la mente humana.

Lo difícil de ML es **entender y representar el problema** mediante elección de los datos de entrada, salida y qué algoritmos estadísticos se aproximarán a encontrar la correspondencia entre ambos conjuntos.

Para resolver problemas con ML, es necesario concientizarse acerca de:

- » El entorno de aprendizaje en el que se modelará la solución: supervisado, no supervisado y por refuerzo.
- » Los tipos de algoritmos que ML provee y para qué se utilizan.
- » Herramientas disponibles

Si al aplicar ML, **existe un conocimiento a priori**, es decir, dada una entrada de datos determinada se conoce un conjunto significativo de resultados que se pueden alcanzar para obtener un aprendizaje satisfactorio, se dice que el entorno de aprendizaje es **supervisado**.

Ejemplo: Deseamos crear un programa que reconozca letras. Ante la imagen de una letra al azar como entrada, la máquina aplicará una función que relacione dicha letra con todas las imágenes de letras que conoce de antemano para determinar con cuál corresponde. Incluso se puede contar con más de una imagen por letra. Por fortuna, la humanidad cada vez tiene más conocimiento para entrenar a los sistemas de aprendizaje supervisado: desde imágenes provenientes de tomografías o rayos X en donde los médicos definen que existe una enfermedad o no, hasta imágenes de estrellas ya clasificadas por astrónomos. Mientras ese conocimiento sea más grande, más confiable será la función que determine si una persona se encuentra sana o qué tipo de estrella apareció en un telescopio.

¿Pero qué pasa cuando no existe ese conocimiento a priori? Ahí es donde entra el **aprendizaje no supervisado**.

Hay situaciones en las que poseemos un conjunto de datos aleatorios que si bien representan objetivamente una parte de la realidad, no sabemos o no tenemos una hipótesis acerca de su significancia y/o utilidad. Esos datos serán el input para que una máquina los procese, encuentre patrones, organice y represente a los mismos de alguna forma. Dichos patrones son evaluados por un ser humano para definir si sirven para explicar un fenómeno, para encontrar una solución ante un problema o para otorgarle un significado distinto. Es importante destacar que las correlaciones no necesariamente implican una relación causal pero pueden servir como punto de partida para profundizar en una investigación o búsqueda de soluciones.

Ejemplo: A mediados del siglo XIX, en Viena se observó que las parturientas atendidas por estudiantes de medicina y médicos de la sala de disección tenían una tasa significativamente más elevada de mortalidad que las atendidas por comadronas. Sobre esa observación y sin conocimiento a priori, la comunidad médica aprendió más sobre las infecciones que producían los médicos por haber tocado material cadavérico y la necesidad de asepsia. Sólo con analizar datos sobre la tasa de mortalidad y quiénes realizaban el trabajo de parto se llegó a la conclusión de mejorar un procedimiento médico. Hoy en día, bajo la forma de aprendizaje no supervisado, patrones menos evidentes pueden encontrarse con facilidad gracias a los conjuntos de datos enormes de dominio público y el poder de cómputo disponible para ejecutar los algoritmos.

Otra forma popular de aprendizaje es el **aprendizaje por refuerzo**, que establece un **proceso iterativo** en donde se busca **maximizar recompensas para aumentar la probabilidad de una decisión** que nos acerque al cumplimiento de un objetivo.

Ejemplo: Imaginemos que tenemos que salir campeones de fútbol. El proceso iterativo se compone de una serie de partidos en donde la recompensa sea ganar cada uno de ellos. Por cada partido es vital elegir quiénes jugarán, por lo tanto se define que el sistema sea alimentado en forma rudimentaria con los datos de cuántos goles convierten por partido los delanteros y conozca a priori cuándo un partido se ganó o no para retroalimentarse por cada ciclo. Cuando nuestro equipo gane un partido, el sistema refuerza la decisión aumentando la probabilidad de volver a convocarlos. Cuando nuestro equipo pierda un partido, el sistema refuerza la decisión aumentando la probabilidad de elegir a otros delanteros.

Para ir desde un conjunto de datos caótico que describe al problema hacia el aprendizaje de la representación de la solución es necesario elegir correctamente los algoritmos que Machine Learning provee. Depende del investigador considerar qué **características** significativas (o features) tienen que tratar los mismos. Además se deben elegir algoritmos lo bastante flexibles para representar el patrón pero con la menor cantidad de ruido para reducir su falsabilidad. En líneas generales, los algoritmos corresponden a las siguientes categorías:

- » Agrupamiento (Clustering): Se utilizan para **descubrir cómo están estructurados los datos**.
- » Clasificación: Sirven para **identificar a qué conjunto de categorías pertenece una nueva observación**, sobre la base de un conjunto de datos de formación que contiene observaciones cuya categoría de miembros es conocida.

- » Detección de anomalías: Sirven para **identificar datos que salen de un patrón esperado** en un conjunto.
- » Regresión: Se utilizan para **predecir** valores estimando las relaciones que existen en un conjunto de datos.
- » Reducción de dimensionalidad: Sirven para **reducir el número de variables aleatorias** para tratar de optimizar el proceso de aprendizaje.

Es importante destacar que existen frameworks que facilitan la aplicación de estos algoritmos. Uno muy conocido y utilizado por las grandes compañías es **TensorFlow** desarrollado por Google. También se encuentran disponibles otros como **Keras** (de más alto nivel), MATLAB, Caffe2, Microsoft Cognitive Toolkit, MXNet, Theano, PyTorch, Chainer, PaddlePaddle, etc. Google, Amazon, Microsoft, NVIDIA entre otras compañías, proveen servicios en la nube para facilitar el procesamiento con estos algoritmos.

La cantidad de recursos educativos sobre Machine Learning se encuentra en crecimiento; varias universidades publican sus cursos. Google ofrece un curso en Español que pudo ser traducido gracias a ML. En Inglés pueden buscar las clases de Martin Görner o el libro gratuito de Vishal Maini. Muchas organizaciones también comparten públicamente datos reales para practicar aprendizaje automático. El motor gráfico Unity incorpora librerías para aplicar de una forma más atractiva aprendizaje automático en videojuegos.

Deep Learning

Deep Learning (DL) o aprendizaje profundo es un subconjunto dentro del campo de estudio de Machine Learning que empezó a ganar popularidad en la última década. Esto se debe a que tenemos computadoras más rápidas y conjuntos de datos más grandes. La evolución de las placas de video brindó un buen soporte ante los procesos paralelizables. El aprendizaje profundo consiste básicamente en **utilizar redes neuronales para obtener representaciones más abstractas**. Deep Learning se destaca en encontrar funciones para obtener correspondencias en conjuntos de datos complejos como imágenes, video, texto, etc. De hecho, las redes neuronales son conocidas como aproximadores de funciones porque son capaces de aprender cualquier función con una red neuronal de una sola capa. Esto hace que la performance se incremente a medida que se lo alimenta con más datos.

Queda a criterio del investigador, cuándo usar DL y cuándo usar los algoritmos clásicos de ML. En líneas generales, se podría resumir de la siguiente manera: Deep Learning necesita conjuntos de datos enormes y mucho tiempo de entrenamiento a diferencia de Machine Learning. Sin embargo, ML posee más formas de clasificación de datos. Por otro lado Deep Learning no permite elegir qué características tratarán los algoritmos: esto acorta el tiempo de planteamiento y modelado de la solución a costa de tener un modelo más difícil de debuguear y personalizar debido a que funciona como una caja negra.

Ejemplo: Detección de rostros

Si nosotros quisiéramos detectar un rostro de una foto deberíamos considerar el color de su piel, qué parte se muestra del rostro, la iluminación ambiente, cómo está orientado, etc. Esto hace que desde la programación tradicional tengamos que definir un conjunto de reglas muy amplio para

determinar si es una cara. Desde ML tradicional, habría que definir qué características hacen a un rostro y encontrar/diseñar un algoritmo que satisfaga el requerimiento con el menor margen de error posible. Deep Learning salta este proceso y trata de buscar la mejor función de aproximación mediante una red neuronal. Sin embargo, hacer que una red neuronal estándar decida si un conjunto de píxeles es un rostro por ver cuánto se aproxima a una imagen de referencia con millones de rostros promediados, no sería un buen punto de partida para encontrar una solución. Uno estaría encontrando una aproximación a una referencia difuminada y eso no es eficaz. Por fortuna, el problema se puede dividir jerárquicamente en varios más pequeños: encontrar bordes (nivel bajo), encontrar partes de la cara como el ojo, la nariz, etc. (nivel medio) y encontrar similitudes con caras más completas (nivel alto). Esta división puede ser contemplada en una red neuronal que tenga **varias capas**, de ahí el nombre aprendizaje profundo.




Figura 4. Aprendizaje de características más abstractas. Imagen de NVIDIA.

Esta forma de encarar el problema con capas va de la mano con experimentos científicos de 1950 en donde Hubel y Wiesel descubrieron que las redes neuronales biológicas del córtex visual de los gatos poseen una jerarquía de neuronas que se van activando. Se pudo ver la importancia de este tipo de redes cuando en la década del setenta y ochenta se desarrolló el algoritmo de **retropropagación**. El mismo permite que las capas intermedias de la red se organicen y ajusten a sí mismas con el fin de reducir errores ante datos nuevos.

Por fortuna, existen varios tipos de redes neuronales que se utilizan en DL: convolucionales (utilizadas en visión artificial o para crear imágenes según el estilo de un artista), recurrentes (utilizadas en procesamiento de lenguaje o para componer música), etc. El aprendizaje profundo no sólo es agregar capas sino diseñar funciones de activación, hiperparámetros (parámetros establecidos antes del entrenamiento) y topologías de redes que nos proporcionen distintas formas de representación en varios dominios. En palabras de Alan Kay: “Un punto de vista equivale a 80 puntos de coeficiente intelectual”.

El aprendizaje profundo no sólo es útil para la clasificación sino también para la generación de información. Dada una imagen borrosa y/o con baja resolución, se puede utilizar redes neuronales del tipo generative adversarial para reconstruirla con mayor nitidez y resolución. Comienzan también a usarse para generar imágenes fotorrealistas.

Uno de los avances recientes más importantes en Inteligencia Artificial proviene de la empresa Deepmind, que consiste en combinar técnicas de aprendizaje profundo con aprendizaje por refuerzo (**Deep Reinforcement Learning**) para tratar problemas complejos como la toma de decisiones en ambientes lúdicos. Esto permitió generar una IA que pudo ganarle al campeón mundial de GO por 4 a 1. A pesar de ser un juego estudiado por milenios cuyo número de jugadas es mayor a la cantidad de átomos en el Universo, la IA logró sorprender a la comunidad internacional proponiendo una forma distinta de jugar.

Tanto Machine Learning como Deep Learning llegaron para quedarse y modificarán las próximas décadas de manera exponencial en forma transversal a todos los sectores (salud, transporte, arte, producción, educación, comunicación y un gran etcétera). Aprender e invertir en soluciones basadas en Inteligencia Artificial será un gran acierto para el futuro.

De muestra basta un set de botones...

Probablemente uno de los primeros casos de computadoras imitando el comportamiento humano corresponda al programa Eliza, creado entre 1964 y 1966 en el MIT. Eliza era lo que se conoce comúnmente como un *chatbot*, un programa capaz de llevar adelante una conversación con una persona como si fuera un ser humano, normalmente mediante interfaces de texto. Eliza tenía la característica singular de parodiar a un psicoterapeuta y sus respuestas eran tan convincentes para la época que muchas personas estaban convencidas de que del otro lado de la comunicación había una persona real respondiendo sus mensajes. Sin embargo, el programa Eliza no era capaz de entender la conversación, su algoritmo sencillamente buscaba palabras claves en los mensajes y aplicaba reglas de transformación del texto para producir una respuesta, comúnmente en la forma de una pregunta que reflejaba los dichos del “paciente”. Hoy en día hay múltiples sitios web que permiten “hablar” con Eliza, por ejemplo: <http://www.deixilabs.com/> (en español).

El desarrollo de chatbots continuó durante años incorporando técnicas de inteligencia artificial más sofisticadas. Así es como actualmente podemos conversar con Cleverbot en <http://www.cleverbot.com/> (en inglés). A diferencia de Eliza, Cleverbot usa un mecanismo de aprendizaje a partir del cual sus respuestas se basan en parte o en su totalidad en conversaciones previas con otros usuarios. Básicamente, Cleverbot no entiende las frases que produce pero sabe reconocer patrones y buscar en su base de datos cómo respondería una persona real a una frase determinada. De esta forma, es capaz de enriquecer su repertorio de respuestas a medida que más usuarios conversan con él pero, dado que aprende de la gente con la que interactúa, sus respuestas pueden ser inapropiadas o directamente ofensivas.

El peligro de desarrollar chatbots que aprendan de sus interacciones con los usuarios quedó ejemplificado en el fiasco publicitario que significó el chatbot “Tay”, desarrollado por Microsoft para la plataforma Twitter. Tay estaba diseñado para imitar los patrones de lenguaje de una adolescente de 19 años e incorporaba un mecanismo de aprendizaje similar al de chatbot. Dado que no tenía programado un entendimiento sobre el comportamiento inapropiado, en menos de 1 día de interacción con usuarios de Twitter se encontraba respondiendo con mensajes racistas y de contenido sexual. Luego de 16 horas de su lanzamiento Microsoft desactivó la cuenta en lo que representó un fracaso de imagen pública.

La famosa asistente virtual de iOS, Siri, es un gran ejemplo de la integración de un conjunto de tecnologías de inteligencia artificial para alcanzar un comportamiento similar al de un ser humano. Desde el reconocimiento de la voz, pasando por el procesamiento del lenguaje natural, hasta la síntesis de voz, Siri implementa algoritmos de inteligencia artificial sofisticados para poder responder preguntas, hacer recomendaciones basadas en los gustos del usuario, y realizar acciones a pedido del usuario. Actualmente, otras empresas como Google, Microsoft, y Amazon han desarrollado asistentes virtuales similares a Siri en sus prestaciones.

No todos los programas capaces de aprender tienen que ser tan sofisticados como Siri. Un programa que alcanzó una alta popularidad (y que el lector probablemente recuerde) es el juego online Akinator, que todavía está disponible en <http://es.akinator.com/>. Este juego simula ser un “genio” capaz de adivinar qué personaje, real o ficticio, el usuario está pensando. Para ello, el genio hace una serie de preguntas sencillas que pueden responderse con alguna de las siguientes opciones: Sí, No, No lo sé, Probablemente, y Probablemente no. Por medio de las preguntas el programa va acortando su árbol de búsqueda hasta hallar la respuesta correcta. En caso de no encontrarla, el programa pregunta al usuario cuál era el personaje y lo añade a su base de datos. De esta forma tan simple, Akinator es capaz de aprender nuevos personajes a medida que más usuarios participan en el juego.

El área de investigación en inteligencia artificial que más promete impactar en la vida de las personas probablemente sea el desarrollo de vehículos autónomos. Estos vehículos (comúnmente automóviles) tienen la capacidad de percibir el ambiente que les rodea mediante múltiples sensores, reconocer e interpretar las características de este ambiente (léase obstáculos, señalización, peatones, etc.), identificar la ruta a seguir, y moverse sin necesidad de un conductor humano. Esto que, hasta hace unos años parecía una promesa sacada de literatura de ciencia ficción, está cada vez más cerca de convertirse en una realidad cotidiana. Ya podemos encontrar empresas (como Google, BMW, Mercedes Benz, entre otras) que están empezando a probar sus vehículos autónomos en diferentes ciudades del mundo. Sin embargo, no todo es color de rosa. El desarrollo de estos dispositivos plantea un conjunto de dilemas éticos relacionados con la toma de decisiones en situaciones críticas y en quién recae la responsabilidad de las mismas. Si un vehículo autónomo participa de un accidente, ¿Se puede culpar a la inteligencia artificial? ¿O acaso deberían hacerse responsables los programadores que desarrollaron dicha inteligencia? Si bien esto puede parecer un ejercicio puramente hipotético, estas situaciones inevitables ya están empezando a suceder. En marzo de 2018, un vehículo autónomo de la empresa Uber atropelló a una mujer en Arizona. Lamentablemente la mujer falleció como resultado del accidente y Uber decidió suspender las pruebas. Casos como este demuestran el peligro de llevar adelante el progreso tecnológico por el progreso mismo, sin considerar la importancia de las cuestiones éticas involucradas.

Queda todavía un largo camino por recorrer, pero si estos problemas se resuelven satisfactoriamente el pronóstico es muy alentador. Se cree que la proliferación de los vehículos autónomos permitiría minimizar significativamente los accidentes fatales al eliminar casi por completo el factor humano en las decisiones de tránsito.

Un ejemplo impactante de la potencialidad de las computadoras para el aprendizaje de disciplinas que antes creíamos exclusivas del ser humano es AlphaZero, un programa informático capaz de jugar al go, al ajedrez, y al shogi. AlphaZero fue desarrollado por DeepMind, una división dentro de Google dedicada a la investigación en inteligencia artificial. Lo que hace que AlphaZero sea tan impresionante es que, a diferencia de su antecesor AlphaGo, fue entrenado exclusivamente jugando contra sí mismo, sin acceso a una base de datos de partidas históricas, ni libros de aperturas, ni tablas de finales. Es decir, AlphaZero tuvo que aprender a jugar por sí solo sin ayuda del desarrollo humano en la materia. En tan sólo 24 horas de entrenamiento, AlphaZero desarrolló un nivel en los tres juegos superior a los mejores campeones del mundo, venciendo a los programas Stockfish en ajedrez, Elmo en shogi, y a AlphaGo en go (éste último ya había vencido en 2015 al campeón del mundo humano Lee Sedol) Para los aficionados al juego de ajedrez, algunas partidas contra Stockfish están publicadas en youtube. Las reacciones de los grandes maestros están divididas. El

gran maestro Peter Nielsen, por ejemplo, declaró: “Siempre me he preguntado cómo sería si una raza superior aterrizará en la tierra y nos enseñara cómo juegan ellos al ajedrez, y ahora siento que ya lo sé”. Otros campeones, a pesar de reconocer el desempeño de AlphaZero, desestiman la importancia del logro. El gran maestro Hikaru Nakamura declaró en una entrevista: “No doy demasiada credibilidad a los resultados simplemente porque, hasta donde yo sé, AlphaZero estaba usando el súper ordenador de Google y Stockfish no utiliza ese hardware”.

Conclusiones

Tenemos la enorme fortuna de ser testigos de cambios en la tecnología que están modificando profundamente muchos aspectos de la sociedad. El futuro llegó hace rato...

Probablemente es en el mundo del trabajo donde podemos ver más claramente las huellas de este cambio. Una de las preocupaciones que ensombrecen los beneficios de la IA es el número de personas que pueden ser reemplazadas en sus labores por estas tecnologías: operadores de call center, operarios de fábricas, redactores de noticias, y muchísimos otros. ¿Es la primera vez que ocurre esto en la humanidad? Seguramente no. La revolución industrial también presentó alternativas artificiales a tareas humanas. Y así como hubo un impacto en el trabajo, también presentó nuevas oportunidades, y especialmente, mejores condiciones laborales. ¿Podemos imaginar nuevas formas de trabajar? ¿Menor cantidad de horas? ¿Qué ocurrirá cuando la mayor parte de la producción se encuentre automatizada? (y hablamos de producción no sólo de objetos materiales, sino también de servicios) ¿Tendremos un alto porcentaje de la humanidad desocupado, fuera del sistema? ¿Qué ocurrirá con la distribución de la riqueza? ¿Y si finalmente logramos vencer la condena bíblica en la expulsión del paraíso, que nos obligó a “ganar el pan con el sudor de nuestra frente”? (El otro castigo ya lo solucionamos gracias a la anestesia peridural...) En síntesis, ¿a qué llamaremos trabajo dentro de 50 años?

Por otro lado, la capacidad de cálculo ultrarrápida sumado a una memoria casi infinita nos ha permitido encarar desde los comienzos de la computación problemas que son humanamente inalcanzables. El problema que hemos tenido es que necesariamente debíamos tener una comprensión cabal del mismo para poder introducirlo desde un programa dentro de la máquina. Ahora que pueden aprender solas, ¿podremos resolver cuestiones que siempre nos tuvieron en jaque? (Ver el problema del viajante). ¿Serán estas máquinas mejor que los humanos en uno, dos, miles, todos los aspectos? ¿Cuál sería el problema de que esto fuera así?

¿Y si logramos conectar nuestros cerebros a esta enorme capacidad de aprendizaje, cálculo y memoria? Hoy por hoy, cuando no recordamos algo, desenfundamos nuestros teléfonos inteligentes y en cuestión de segundos ya tenemos la respuesta. Estamos hiperconectados. ¿Podremos hacer más transparente esta conexión? ¿Podremos “pensar” nuestra consulta a Google y recibir la respuesta directamente en nuestro cerebro? ¿Nos convertiremos en superhombres, con una única mente fusionada en todo el Universo? ¿Quién controlará los contenidos de esa gran supermente? ¿Se acercarán a nosotros todas las respuestas, todos los conocimientos, o sólo aquellos que las grandes corporaciones determinen como válidos?

Esto es sólo el comienzo. Impactante. Y es tan amplio el abanico de posibilidades, que se hace imposible imaginar el futuro. Todo un palo, ya lo ves...

Bibliografía

- » Gibney, E. (2016). "Google AI algorithm masters ancient game of Go". In *Nature News*, 529(7587), 445.
- » Michalski, R. S., Carbonell, J. G. & Mitchell, T. M. (eds.) (2013). *Machine learning: An artificial intelligence approach*. Springer Science & Business Media.
- » Penrose, R. (1991). *La nueva mente del emperador*. Grijalbo Mondadori.
- » Russell, S. J., Norvig, P., & Davis, E. (2010). *Artificial intelligence: a modern approach* (3rd ed). Upper Saddle River: Prentice Hall.