



ARTÍCULO ESPECIAL

La Inteligencia Artificial, un flujo continuo desde su nacimiento hasta ahora

Artificial Intelligence: A Continuous Flow from Its Inception to the Present

Jorge E. SAGULA^a✉

^a Departamento Ciencias Básicas-Universidad Nacional de Luján, Argentina.
Asesor Rectorado, Universidad Nacional de Luján, Argentina.
Equipo COIN (Director), DCB-Universidad Nacional de Luján, Argentina.

INFORMACIÓN DEL ARTÍCULO

Historia del Artículo:

Recibido: 01 01 2024
Aceptado: 01 04 2024

Palabras clave:

Inteligencia Artificial.
Historia; Rumbos.
Evolución;
Interdisciplinas.

Key words:

Artificial Intelligence;
History. Directions;
Evolution;
Interdisciplinarity.

RESUMEN

¿Cómo definir a la Inteligencia Artificial? En forma simple, la Inteligencia Artificial (IA) responde al diseño de sistemas o máquinas que imitan (o simulan) la Inteligencia Humana, en cuanto a la realización de tareas generales o específicas, y que, con el paso del tiempo, pueden evolucionar, en función de la información que han recopilado. Este concepto irrumpe en la ciencia como consecuencia de la publicación del Filósofo y Matemático Alan Turing, "Computer Machinery Intelligence" (1950), en la cual expresa, entre otros conceptos salientes, que, "en alguna medida", las máquinas obtendrían inteligencia y serían capaces de simular razonamientos de un ser humano.

La actualidad de la IA no es casual, sino constituye una cadena causal, por tanto, en este artículo, procederé a construir su historia, a través de algunos de sus más grandes hitos:

- Modelo GPS y HPS (Newell & Simon, décadas del '50 y '60)
- Redes Neuronales (desde Rosenblatt, 1958,)
- Núcleos de Sistemas Expertos (Dendral, Mycin, Prospector)
- Agentes Inteligentes (Sociedad de la Mente, Minsky, 1986)
- Modelos PDP (mediados de la década del '80)
- Neurociencia Cognitiva (fines de la década del '80)
- Proyecto CYC (Northwestern University, fines década del '80)
- Artificial Life (fines de la década del '80)
- Machine Learning (desde Alan Turing hasta... nuestros días)
- Deep Learning (desde década del '90... y continúa)
- Proyecto OLPC (Negroponte, años 2005-2006)
- Deep Reinforcement Learning (desde 2016)
- Evolución de Analítica (desde 2010...)
- IA Generativa (desde 2020, hacia...)

ABSTRACT

How to define Artificial Intelligence? In simple terms, Artificial Intelligence (AI) responds to the design of systems or machines that imitate (or simulate) Human Intelligence, in terms carrying out general or specific tasks, and that, over time, can evolve, based on the information they have collected. This concept bursts into science as a consequence of the publication of the Philosopher and Mathematician Alan Turing, Computer Machinery Intelligence (1950), in which he expresses, among other salient concepts, that, "to some extent", machines would obtain intelligence and they would be able to simulate the reasoning of a human being.

✉ Autor para correspondencia

Correo electrónico: Jorgesagula@gmail.com

<https://doi.org/10.63706/jsibemir.v1i1.3>

e-ISSN: 3087-2367/© 2025 +JS

Este es un artículo Open Access bajo licencia BY-NC-ND
(<http://creativecommons.org/licenses/by-nc-nd/4.0/>)

The current nature of AI is not coincidental, but constitutes a causal chain, therefore, in this article, I Will proceed to build its history, through some of its greatest milestones:

- GPS and HPS Models (Newell & Simon, 1950s and 1960s)
- Neural Nets (from Rosenblatt, 1958,)
- Expert Systems Cores (Dendral, Mycin, Prospector)
- Intelligent Agents (Mind's Society, Minsky, 1986)
- PDP Models (mid-80s)
- Cognitive Neurosciences (late 80's)
- CYC Project (Northwestern University, late 80's)
- Artificial Life (late '80s)
- Machine Learning (from Alan Turing to..... this time)
- Deep Learning (from '90s..... to continue)
- OLPC (Negroponte, 2005-2006)
- Deep Reinforcement Learning (from 2016)
- Analytics Evolution (from 2010....)
- IAG (from 2020, to...)

INTRODUCCIÓN

¿Cómo definir a la Inteligencia Artificial? En forma simple, la Inteligencia Artificial (IA) responde al diseño de sistemas o máquinas que imitan (o simulan) la Inteligencia Humana, en cuanto a la realización de tareas generales o específicas, y que, con el paso del tiempo, pueden evolucionar, en función de la información que han recopilado. Este concepto irrumpe en la ciencia como consecuencia de la publicación del Filósofo y Matemático Alan Turing, "Computer Machinery Intelligence" (1950), en la cual expresa, entre otros conceptos salientes, que, "en alguna medida", las máquinas obtendrían inteligencia y serían capaces de simular razonamientos de un ser humano.

"Hay algoritmos de Inteligencia Artificial que fueron inspirados simulando el cerebro. Pero también hay ingenieros que trabajan con neurocientíficos o gente que estudia el cerebro, como psicólogos, que simulan el cerebro y comprueban si lo conocido por la psicología puede explicar aspectos del funcionamiento del cerebro cuando se lo simula en una computadora", explicó Sánchez-Montañés, haciendo hincapié en que sólo son imitados fragmentos del cerebro.

En el trabajo conjunto desde la visión biológica, con enfoque en Neurociencias e Inteligencia Artificial, es menester realizar una síntesis de los aspectos más salientes en la evolución de la IA, desde el aporte genérico de las Redes Neuronales. Puntualmente, las Redes Neuronales, en alguna forma, pueden remontarse a los trabajos iniciales de McCulloch y Pitts (1943) en lo atinente a Simulación de Mecanismos Mentales; luego, Hebb (1949) definía el Método de Actualización de Pesos Sinápticos (Método Hebbiano), introduciendo el concepto Conexionismo.

Al comenzar las investigaciones en Aprendizaje Automático (Machine Learning) en IA en la década de 1980, a partir de las ideas de Alan Turing en 1950, el objetivo fue desarrollar técnicas de aprendizaje para máquinas, a fin de "generalizar comportamientos e inferencias para un gran conjunto de datos", como "imitación de la forma de aprendizaje del cerebro humano", y sus estrategias se sustentan en Algoritmos basados en Regresión y Algoritmos basados en Árboles de Decisión, precisamente mediante la potencia de técnicas y metodologías "apropiadas" de la Heurística y la Metaheurística. El Aprendizaje Automático se relaciona intrínsecamente con el Aprendizaje Estadístico y la Estadística Inferencial y el Reconocimiento de Patrones, y puede verse como un Método de Inducción de Conocimiento. Se puede implementar Aprendizaje Supervisado (con asistencia humana) y Aprendizaje No Supervisado (sin asistencia humana).

ASPECTOS SALIENTES EN LA HISTORIA DE LA INTELIGENCIA ARTIFICIAL

HACIA LAS REDES NEURONALES

La Inteligencia Artificial (término acuñado por **Alan Turing [1]**), tuvo luego, importantes impulsores, tanto provenientes de universidades como de industrias tecnológicas; así, en el verano de 1956 tuvo lugar una conferencia muy poco convencional, denominada "Dartmouth Summer Research Project on Artificial Intelligence", considerada como el origen de "I+D" en el campo de la Inteligencia Artificial; la conferencia concebida y organizada por **John Mc Carthy [2]** (Dartmouth University) contó con la participación de **Marvin Minsky[3]** (Harvard University), Nathaniel Rochester (IBM Corporation) y Claude Shannon (Bell Telephone Labs); como consecuencia de este proyecto propusieron reunir a un grupo de investigadores interesados en trabajar sobre la idea de "que cada aspecto del aprendizaje y cada característica de la inteligencia podían describirse en procura de crear máquinas que las simulen".

La Inteligencia Artificial (término acuñado por Alan Turing [1]), tuvo luego, importantes impulsores, tanto provenientes de universidades como de industrias tecnológicas; así, en el verano de 1956 tuvo lugar una conferencia muy poco convencional, denominada "Dartmouth Summer Research Project on Artificial Intelligence", considerada como el origen de "I+D" en el campo de la Inteligencia Artificial; la conferencia concebida y organizada por John Mc Carthy [2] (Dartmouth University) contó con la participación de Marvin Minsky[3] (Harvard University), Nathaniel Rochester (IBM Corporation) y Claude Shannon (Bell Telephone Labs); como consecuencia de este proyecto propusieron reunir a un grupo de investigadores interesados en trabajar sobre la idea de "que cada aspecto del aprendizaje y cada característica de la inteligencia podían describirse en procura de crear máquinas que las simulen".

Mc Carthy (1927-2011, Premio Alan Turing (1971)), era Profesor Asistente de Matemática en Dartmouth University; su trabajo se inició en una serie de problemáticas relacionadas con la naturaleza matemática del proceso de pensamiento de la Teoría de las Máquinas de Turing, la velocidad de la capacidad de cálculo de las computadoras, la relación de un modelo del cerebro a su entorno, y el uso del lenguaje artificial; además, fue el creador del Lenguaje LISP y junto con Minsky fue co-creador del MIT-Artificial Intelligence Lab.

Es posible expresar que comienza a despuntar el término Machine Learning (Aprendizaje de Máquina), y una de sus más distinguibles subdisciplinas de la Inteligencia Artificial, desde el pasado reciente, el el Reconocimiento de Patrones, produce un singular enlace desde los Modelos Bio-Inspirados, las Redes Neuronales (McCulloch-Pitts – 1943, Ashby – 1952, Minsky – 1954, Minsky-Selfridge – 1961, Block – 1962, Rosenblatt – 1962, Teuvo Kohonen – 1972, James Anderson – 1972, Hopfield – 1982, Mc Clelland – 1986, Mc Clelland-Rumelhart – 1986, Hopfield-Tank –

1987, Abbruzzese - 1988; - 1988; Grossberg - 1973-1976-1980-1982-1988, Kohonen - 1989, Grossberg-Carpenter - 1987-1988-1990, Kohonen - 1990-1991, como los referentes más destacados), produciendo la evolución a Deep Learning (Geoffrey Hinton, 1986) [4] que, en el contexto de Big Data Science (Big Data, Business Intelligence, Analytics) [5] han realizado innumerables aportes en el tratamiento de la Pandemia iniciada en 2020, pero como la necesidad lo amerita, la migración a una nueva profundización, Deep Reinforcement Learning [6], ya es una disciplina acorde a la Analítica, y más en términos de la proyección a futuro.

Los algoritmos computacionales que se denominan Redes Neurales (para algunos autores, Redes Neuronales Artificiales) están inspiradas en la organización jerárquica de la corteza cerebral; se organizan en una pirámide de capas sucesivas, tal que cada una intenta descubrir irregularidades de mayor profundidad que la capa anterior; cada capa de por sí, puede "descubrir" una parte muy simple de lo que ocurre en forma externa a su contexto; pero, si se unen varias capas, se configura un dispositivo de aprendizaje.

A modo de síntesis, y por tratarse de una temática fundamental en el trabajo conjunto desde la visión biológica, con enfoque en las Neurociencias y la Inteligencia Artificial, es menester realizar una síntesis de los aspectos más salientes en la evolución de la Inteligencia, desde el aporte genérico de las Redes Neurales hasta converger en los nuevos enfoques de los últimos años. Expandiendo lo vertido previamente, las Redes Neurales, en alguna forma, pueden remontarse a los trabajos iniciales de **McCulloch y Pitts (1943) [7]** en lo atinente a Simulación de Mecanismos Mentales; luego, **Hebb (1949) [8]** definió el Método de Actualización de Pesos Sinápticos (Método Hebbiano), introduciendo el concepto Conexionismo, aportando a las Redes Neurales estos conceptos:

- Información en Redes Neurales, almacenada en conexiones (Peso Sináptico).
- La velocidad de aprendizaje en las conexiones es proporcional al producto de valores de activación de las neuronas.
- Los pesos son simétricos.
- En el Proceso de Aprendizaje, se producen modificaciones en las conexiones (Pesos Sinápticos), generando "conjuntos" de células.

Hasta el año 1974, los investigadores de Inteligencia Artificial centraron su atención simultáneamente en dos aspectos: Extensión de la capacidad de computadoras y Movimiento hacia la comprensión de la Inteligencia Humana. Y comenzaron a enfatizar sus acciones en Inteligencia Artificial y Simulación Cognitiva.

Kohonen (1972) concibió una Red Neural, la Memoria Asociativa, presentando una única capa de neuronas fuertemente conexas entre sí y con el mundo exterior, tal que los valores de activación eran lineales y continuos. **Anderson (1972) [9]** concibe una Red Neural, la Memoria Interactiva; desarrolló un Modelo Lineal (Asociador Lineal) correspondiente a un Modelo de Procesamiento Paralelo Distribuido; interesándose en describir Modelos de Redes Neurales y sus correspondientes mecanismos de aprendizaje.

Hopfield (1982) [10] presentó un núcleo de nuevas ideas sobre Redes Neurales, estableciendo estructuras de algoritmos y redes, que se pueden generalizar robustamente; su modelo se implementó en circuitos electrónicos, en 1986. Una Red de Hopfield es similar a la Memoria Asociativa, que ha entrenado un núcleo de ejemplos, tal que un nuevo estímulo podía causar que la Red se fije en la activación de un patrón correspondiente al ejemplo del conjunto de entrenamiento que tiene mayor parecido con el nuevo estímulo.

Hopfield y Tank (1985) [11] aplican las Redes Recurrentes a pro-

blemas complejos de optimización; posteriormente, Hopfield (1987) [12] inició el diseño de algoritmos de aprendizaje y distribuciones de probabilidad en redes tanto hacia adelante como en redes de retroalimentación.

Conforme a la visión biológica de los perceptrones de **Rosenblatt (1958) [13]**, correspondiente a Algoritmos de Aprendizaje Supervisado y No Supervisado, tanto **Mc Clelland (1986)** como **Kohonen (1989)** desarrollaron sus modelos.

Grossberg (1973, 1976, 1980, 1982, 1988) [14, 15, 16, 17, 18] postuló el concepto de "Control de Ganancias para un Grupo de Neuronas", a partir de la idea: "Encendido en el Centro, Apagado alrededor", postulando: "Dado un grupo de neuronas, si una está Excitada, las que están a su alrededor reciben una señal que las hace Inhibidas"; además, construye Redes Neurales con la incorporación de datos neurológicos y principios fisiológicos.

Grossberg y Carpenter (1987-1990) [19, 20] desarrollaron Arquitecturas de Redes Neurales que denominaron ART (Adaptive Resonance Theory) que auto-organizan códigos de reconocimiento de patrones estables en tiempo real en respuesta a secuencias arbitrarias de patrones de entrada; el proceso adaptable de reconocimiento de patrones corresponde a un proceso cognitivo más general para acceder al descubrimiento de hipótesis, verificación, búsqueda, clasificación y aprendizaje.

El Procesamiento Distribuido en Paralelo (o Modelo Conexionista), desarrollado en su máxima expresión por **Mc Clelland y Rumelhart (1986) [21]**, constituye un enfoque moderno del estudio de la memoria y la cognición; en él, se intenta abordar la complejidad del procesamiento cognitivo con una clase de modelos generalizados, con una amplia gama de problemas y tareas, reconociendo que, simultáneamente, se pueden realizar múltiples operaciones cognitivas y que se pueden distribuir mediante una red de procesamiento extensa (Mc Clelland, 1986); de tal forma, el conocimiento se codifica mediante fuerzas de conexión y el aprendizaje ocurre a través de la modificación de tales conexiones.

Los Modelos PDP permiten describir el aprendizaje elemental en una amplia variedad de situaciones, tales como percepción, memoria y habilidades; su generalidad presenta la ventaja de adaptarse a una gran gama de situaciones, con límites exclusivos del propio dominio.

Abbruzzese (1988) implementó una red de McCulloch-Pitts, con el uso de "Transputers" (Tecnología para el Procesamiento Paralelo).

Kohonen (1990) [22] introdujo la idea de Mapa Auto-Organizado, describiendo una Red Neural de dos capas, tal que la capa de entrada estaba totalmente conectada a una Capa de Kohonen; esta estructura tiene la particularidad de aprender a clasificar sin haberle provisto la respuesta correcta para el patrón de entrada.

Alexander (1990) [23] postuló que el entendimiento profundo de diferentes modelos de Procesamiento Mental posibilitaría en el futuro un gran avance en distintas temáticas de Inteligencia Artificial.

Grsdensfors (1995) [24] expresó que las Redes Neurales, la Formación de Conceptos y la Semántica Cognitiva constituían la base de la investigación en Agentes Autónomos y en Visión Artificial; bajo esa concepción, la Inteligencia Artificial tendría un promisorio futuro, orientándose a: Simulación Cognitiva y Desarrollo de Programas Inteligentes.

Alexander (1996) junto a su equipo de investigadores, desarrolló una arquitectura general híbrida, con 3 niveles mayores: Sensorización, Cognitivo Neural y Computacional Convencional.

HACIA LA RESOLUCIÓN DE PROBLEMAS

La "Resolución de Problemas" es un proceso artesanal, que

contiene el conocimiento disciplinar, y donde el modelador debe disponer de estas características:

- Intuición + Creatividad para interpretar el contexto.
- Discernir mejor adaptabilidad de contenido matemático.
- Disposición de sentido lúdico para jugar con las variables involucradas.

Los investigadores Herbert Simon, Allen Newell y J. C. Shaw (1957) crean, como desarrollo importante para la IA el modelo GPS (General Problem Solver) **Newell, A.; Shaw, J. C.; Simon, H. A. (1959) [25]**, cuyo objetivo fue la construcción de una máquina capaz de resolver problemas de propósito general, fundamentado en un trabajo previo de Herbert Simon y Allen Newell. El modelo en cuestión estaba estructurado sobre tres subsistemas: Perceptual, Cognitivo y Motor, agregando una cuarta componente: Memoria Externa. Lo saliente de este trabajo fue una incorporación básica en la IA: la separabilidad entre el conocimiento y la estructura de control, aquí particularmente, en términos de las estrategias de resolución. Este Modelo puede considerarse bio-inspirado, pues se aproxima a la Resolución Humana de Problemas; y de allí, que fue base de los Sistemas Expertos, un campo de aplicación desarrollado en la década de 1960, en la irrupción de los Sistemas Basados en Conocimiento (Knowledge Based Systems). **Herbert Simon y Allen Newell (1972) [26]** publican un libro muy significativo sobre la resolución humana de problemas, precisamente en base a lo conceptualizado en su creación del año 1957.

En cuanto a la resolución de problemas, el matemático húngaro **George Polya (1945) [27]** presentó en su primer libro un Modelo de Resolución de Problemas, estructurado en cuatro secciones:

1. "En el salón de clases"
2. "Cómo resolver problemas"
3. "Un breve diccionario de heurística"
4. "Problemas, sugerencias, soluciones"

Y planteó la premisa: "Un gran descubrimiento resuelve un gran problema, pero en la solución de un problema, hay un cierto descubrimiento".

La palabra *Heurística* proviene del griego "*heuriskein*", significa "*buscar*".

Heurística es una técnica que permite incrementar la eficiencia de un proceso de búsqueda, a costa de presentar, aspectos de incompletitud; pero, posibilita mejorar la calidad de los caminos explorados.

Existe una clase general de problemas que formalmente pueden resolverse de acuerdo a estos pasos:

1. Elegir una *acción* entre un conjunto de *posibles acciones*.
2. Realiza la *acción*; por tanto, se modifica la acción inicial.
3. Procede a la evaluación de *nuevas situaciones*.
4. Rechazar las *situaciones desfavorables (o desventajas)*.
5. Si se alcanzó la *situación objetivo*, finalizar; si no, elegir una y repetir los pasos anteriores.

¿Cómo se puede definir Heurística? Conforme **Zanakis y Evans (1981) [28]**, *Heurística* constituye "un conjunto de procedimientos simples, frecuentemente basados en el sentido común, que conforme se supone permitirán obtener una buena solución a problemas difíciles, en forma rápida y fácil".

¿Qué factores, entre otros, justifican emplear heurísticas?

- a. La inexistencia de un método exacto de resolución.
- b. La existencia de métodos muy costosos en tiempo o uso de memoria.
- c. Cuando es innecesaria una solución óptima.
- d. La desconfianza sobre los datos disponibles.

- e. Restricciones en cuanto a períodos de tiempo para resolución.
- f. Cuando es necesario un paso previo en la construcción de otro algoritmo.

Recuerdo, que hace 20 años, alguien me preguntó: "Pero, Heurística es Matemática", y mi respuesta fue: "Se trata de dos palabras diferentes, y, por cierto, con significados distintas"; sin embargo, la Heurística o Know-How es modelable y su esencia capturada por la Matemática construyendo al efecto Modelos para que permitan la Resolución de Problemas cuando no existe un método más directo.

La Heurística, que engloba las técnicas que permiten incrementar la eficiencia de un proceso de búsqueda, y su evolución, la Metaheurística, que corresponde a "un proceso iterativo que conduce una heurística subordinada, combinando diferentes conceptos para explorar y explotar las características que pueda exhibir el espacio de búsqueda" (*Osman & Laporte, 1996*) son naturalmente pilares insustituibles aportantes de metodologías, métodos y/o técnicas para el análisis y procesamiento de *Big Data*, específicamente mediante: Redes Neuronales, Algoritmos Genéticos, Swarm Intelligence (Colonias de Hormigas, Enjambre de Partículas), y otros tantos modelos de búsqueda y aprendizaje en el contexto de la Inteligencia Artificial **Sagula, Jorge E. (2021) [29]**.

Así, puede sintetizarse que *Metaheurística*, significa "Más allá de la heurística" o "Refinamiento de heurística". El término surge en Operation Research impulsado por Fred Glover al introducir el Método Búsqueda Tabú (1988, 1997).

Ciertamente, rápidamente se puede inferir que "la percepción" une a las temáticas (Heurística y Metaheurística) a través de la Interdisciplinariedad, pero "una mejor percepción", permite incrementar el conocimiento y consecuentemente mejorar los modelos que, desde el simbolismo matemático, en su más amplia expresión, posibilitan la construcción de meta-modelos aptos en la resolución de problemas generales y complejos, y, extrapolables en la medida que se conozcan los contextos de aplicación.

Específicamente, la tecnología del Dataísmo y procesos asociados a las Ciencias de Datos, puede volverse en contra, si no se diseñan y construyen Paradigmas Reales que eviten entrar en "situaciones de pánico", donde se elige entre "lo menos malo y lo malo", en lugar de tomar al menos decisiones "sub-óptimas" o "cercanamente óptimas", sin poder llegar a "soluciones óptimas"; así, se podrían "limar asperezas" entre las teorías que plantean tareas bien diferenciadas.

EVOLUCIÓN DE LAS REDES NEURONALES

Cuando comienzan las investigaciones en Aprendizaje Automático, en el primer nivel en Aprendizaje de Máquina (Machine Learning) en el campo de la Inteligencia Artificial en la década de 1980, el objetivo fue desarrollar técnicas de aprendizaje para máquinas, con el propósito de "generalizar comportamientos e inferencias para un gran conjunto de datos", y esta respuesta es "como imitación de la forma de aprendizaje del cerebro humano", y sus estrategias se sustentan en Algoritmos basados en Regresión y Algoritmos basados en Árboles de Decisión, precisamente mediante la potencia de técnicas y metodologías "apropiadas" de la Heurística y la Metaheurística. El Aprendizaje Automático se relaciona intrínsecamente con el Aprendizaje Estadístico y la Estadística Inferencial y el Reconocimiento de Patrones, y puede verse como un Método de Inducción de Conocimiento. Se puede implementar Aprendizaje Supervisado (con asistencia humana) y Aprendizaje No Supervisado (sin asistencia humana).

El Aprendizaje Profundo (Deep Learning), segundo nivel en Aprendizaje Automático, como avance de Machine Learning, debe su denominación a *Geoffrey Hinton* (Premio Alan Turing,

2018) en 1986, al introducir el Algoritmo **Backpropagation**, empleado para entrenar Redes Neuronales Multicapas (Redes Neuronales Profundas), emulando la percepción humana inspirada en el cerebro y la conexión neuronal. Al efecto, configura parámetros básicos sobre los datos, entrenando a una máquina para que “aprenda” reconociendo patrones utilizando varias capas de procesamiento. Las técnicas utilizadas por Deep Learning mejoran las capacidades de clasificación, reconocimiento, detección y descripción; y sus campos de desarrollo son: Reconocimiento de Patrones, Identificación de Imágenes y Analytics (Predictiva). Sus mayores logros se ubican en: Clasificación de Imágenes, Reconocimiento del Habla, Detección de Objetos y Descripción de Contenidos. En esta temática, atinente a la Resolución de Problemas, tanto la Heurística como la Metaheurística juegan roles esenciales.

El Aprendizaje Profundo por Refuerzo (Deep Reinforcement Learning) desde el trabajo de Deepmind, empresa creada por Demis Hassabis (experto en Neurociencias e Inteligencia Artificial), constituye una Neo-Evolución, un nuevo paradigma, pero desde ideas previas, inspiradas en Alan Turing (1950) y proseguidas por Marvin Minsky (1951, 1968, 1985), proveyendo líneas de transdisciplinariedad entre Machine Learning y Deep Learning, por un lado y la Teoría de Agentes y Multiagentes Inteligentes, por el otro. Mediante Aprendizaje Profundo por Refuerzo, un Agente Inteligente aprende a optimizar un Proceso de Decisión, enfatizando en modelos de aprendizaje no supervisado como resultado de la interdisciplinariedad entre Inteligencia Artificial y Neurociencias.

Los sistemas de Aprendizaje por Refuerzo exploran y adquieren datos sobre el problema por propia iniciativa, diseñando automáticamente estrategias en busca del objetivo.

A efectos que la máquina aprenda, el agente interactúa con “un entorno”, que puede ser el proceso decisión real, o bien, una simulación del mismo. El agente trabaja observando el entorno, y tomando una decisión para comprobar qué efectos produce. Siguiendo un proceso de Aprendizaje por Condicionamiento similar al de los seres humanos, el agente aprenderá qué decisiones son más apropiadas, conforme a la situación, desarrollando estrategias a largo plazo, con el propósito de maximizar los beneficios.

Por cierto, que, todos estos trabajos, como más salientes, permitieron plasmar el futuro, en general, de la Inteligencia Artificial, brindando las ideas que elucubraron y que, con distintos avatares en términos de implementación, llevaron a campos promisorios, que hoy por hoy, siguen alimentando a subdisciplinas tales como Machine Learning, Deep Learning y Deep Reinforcement Learning, en las líneas más vinculadas con las Neurociencias e Inteligencia Artificial **Sagula, Jorge (2021) [30]**.

UN AVANCE IMPORTANTE, LA TEORÍA DE AGENTES Y MULTIAGENTES

La Teoría de Agentes, nació a expensas de las expresiones de **Marvin Minsky (1986) [31]**, al manifestar que “Un Agente es un sistema que puede servir como un ir-entre, debido a que dispone de algunas destrezas especializadas”, y enfatizó que, en tal situación, un Programa Computacional con cierta inteligencia es un Agente. La teoría de agentes comenzó a construir su camino, y mientras algunos creían que “los viejos pilares caían” pues se reemplazaba a la IA Clásica, otros advirtieron que se trataba de otra línea, con multi-enfoques, y por tanto desde otro paradigma.

Genesereth postuló: “Un agente es un programa de aplicación como Software Agent, por caso, componentes de software que se comunican con sus pares intercambiando mensajes en un expresivo lenguaje de comunicación de agentes”.

Si bien hubo muchísimos aportes, uno de los más importantes se debió a **Jennings & Wooldridge (1996) [32]**, planteando que “Un **Agente** es un sistema de software con ciertas propiedades: **Autonomía**, pues opera sin la directa acción humana, disponiendo de una forma de control sobre sus acciones y el estado interno; **Capacidad Social**, un agente interactúa con otros agentes y/o con personas, mediante algún expresivo lenguaje de comunicación de agentes; **Reactividad**, dado que un agente percibe su ambiente y responde en tiempo y forma a cambios que ocurren en tal ambiente; **Proactividad**, pues un agente no actúa simplemente en respuesta a su ambiente, sino que además dispone de la capacidad de exhibir el comportamiento de una meta dirigida, tomando la iniciativa”.

En la década de 1990 comenzaron a realizarse desarrollos e implementaciones de Agentes, así: Agentes de Interfaz (Interface Agents) son programas que emplean técnicas de Inteligencia Artificial para proveer asistencia a un usuario. Los Agentes cambian radicalmente la experiencia actual del usuario, mediante la metáfora que un Agente puede actuar como un Asistente Personal. Los Agentes adquieren su competencia aprendiendo del usuario como también de otros agentes que asisten a otros usuarios.

Un Agente de Aprendizaje adquiere su competencia mediante diferentes fuentes: (1) Observando cómo el usuario ejecuta sus acciones; (2) Aprendiendo del usuario directamente e indirectamente “en un ida y vuelta”; (3) Puede aprender desde ejemplos provistos explícitamente por el usuario; (4) Adquiriendo competencia preguntando a otros agentes que asisten a otros usuarios con idéntico propósito.

Los agentes pueden aprender desde la experiencia donde los agentes son buenas fuentes para las sugerencias, pudiendo aprender a confiar en agentes que han provisto acciones recomendadas que el usuario valoró en forma apreciada.

A mediados de la década de 1990 surge un nuevo concepto, la evolución de los Agentes, los **Sistemas Multiagentes**, por supuesto, con un sinnúmero de definiciones, pero, de las cuales destaco a Tokoro (1996) quien expresó “los Sistemas Multi-Agentes son sistemas computacionales, donde agentes semi-autónomos interactúan o trabajan juntos con el objetivo de ejecutar algún conjunto de metas; estos sistemas pueden involucrar agentes homogéneos o heterogéneos, o bien, actividades específicas de los agentes tanto con metas diferentes o comunes, y pueden o no, involucrar la participación de personas”.

A fines del siglo XX, surge el concepto de Agente Pedagógicos Animados, tal que se ocupaban de desarrollar el monitoreo de actividades de resolución de problemas realizadas por estudiantes, interviniendo con explicaciones en contextos apropiados.

Cuando los estudiantes llegaban a impasses, los agentes tomaban el control de la interacción, proveyendo asistencia apropiada. El control de interacciones en forma dinámica de complejas resoluciones de problemas, en ese contexto, requería agentes animados que tomen decisiones en el tiempo, en cuanto a cuando intervenir, cómo seleccionar el contenido, con qué nivel presentar sugerencias y mediante qué medios brindar consejos. En tanto, los aprendices están comprometidos activamente en las actividades de representación de problemas, los ambientes de aprendizaje deben monitorear su progreso, posibilitando realimentación, contribuyendo al logro de los objetivos del aprendizaje, tanto eficiente como efectivo.

Hay un sin número de derivaciones y aplicaciones basadas en la teoría de agentes y multiagentes, y destacando en este último caso, los sistemas colaborativos y los sistemas cooperativos, y

fundamentalmente, las agencias, y los tipos de agencias.

Siguiendo un proceso de Aprendizaje por Condicionamiento similar al de los seres humanos, un agente aprenderá qué decisiones son más apropiadas conforme a la situación, desarrollando estrategias a largo plazo que maximicen los beneficios.

CONVERGENCIA MULTIDISCIPLINAR E INTERDISCIPLINAR

Así las cosas, las diferentes tecnologías están produciendo cambios en nuestra cotidianidad, y por supuesto en este contexto, no escapa a la consideración que la Inteligencia Artificial que irrumpe en la ciencia y la tecnología a mediados del siglo XX, desde distintos enfoques, provistos por Ingenieros, Físicos, Matemáticos, Biofísicos, Biólogos, Médicos, Filósofos, Psicólogos y otros especialistas, lo hace por necesidad, por la necesidad manifiesta de encontrar respuestas en el contexto de la Resolución de Problemas, cuyos referentes fueron George Pólya, Allen Newell, Herbert Simon y J. C. Shaw, en el contexto de la Matemática y de la Inteligencia Artificial en el siglo XX, pero no solamente desde el conocimiento, representado por la Ingeniería de Conocimiento (teoría forjada en el siglo XX, década del '60, desde el Modelo GPS [Newell, Simon, Shaw] y en carácter de metodología global para el diseño, modelado e implementación de los Sistemas Basados en Conocimiento), sino desde el Modelado, a partir de los Modelos Bio-Inspirados, y allí, investigaciones en distintos campos en la década del '40 en el siglo XX, centradas en el funcionamiento de mecanismo mentales dieron, en primera instancia, resultados en el campo computacional mediante las Redes Neuronales desde fines de la década del '50 en el mismo siglo, a los cuales siguieron los Algoritmos Genéticos y hacia la década del '90 se comenzó a trabajar en Artificial Life, particularmente en Modelado de Colonias de Abejas y Colonias de Hormigas, debido a los indicios dejados por **Marvin Minsky (1986)** y además, cuando los científicos humanos, y nuevamente, merced al desarrollo tecnológico, se fueron acercando cada vez más a los trabajos específicos en el desarrollo cerebral, y por eso las Neurociencias (Camillo Golgi y Santiago Ramón y Cajal, recibieron el Premio Nobel a comienzos del siglo XX por sus trabajos en el tema) comienzan a cobrar fuerza, la fuerza del peso sináptico, la fuerza de las conexiones neuronales, las imbricadas conexiones que producen mejoras en numerosas áreas, enfáticamente, la Inteligencia Artificial en la Educación y las Neurociencias en Educación (Neuroeducación), vienen ganando terreno a paso firme, tanto en lo inherente a la mejora de los procesos cognitivos como a la potenciación como metodologías de soporte del aprendizaje, y en cuanto al aprendizaje propiamente dicho. La Neurociencia Computacional (campo multidisciplinar que congrega a la Biofísica, las Neurociencias, las Ciencias Cognitivas, la Ingeniería, las Ciencias de la Computación, con énfasis en Inteligencia Artificial, la Lingüística y la Matemática para estudiar y entender el funcionamiento del cerebro y poder efectuar su traslación a formas virtuales), con el objetivo de generar el descubrimiento de propiedades características y de propiedades gobernantes tanto de neuronas como de redes neuronales, produciendo una integración. La Neurociencia Cognitiva se basa en este orden de conceptos: Neurociencias, Ciencias de la Computación, Matemática, Psicología Experimental y Filosofía con el objeto de asumir la correlación entre los modelos mentales y los patrones de impulsos nerviosos en el cerebro. Y su transferencia, la Neurociencia Cognitiva Computacional nos permite avanzar cada día más...; esta fusión, que también algunos denominan Neuro-IA, se traduce en un refinamiento de la convergencia entre la Inteligencia Artificial y la Neurociencia Cognitiva.

CONCLUSIONES

Es importante considerar una frase proferida por Sánchez-Montañés, en la década de 1990, pero con alto valor en la actualidad: "Hay algoritmos de Inteligencia Artificial que fueron inspirados simulando el cerebro; pero, también, hay ingenieros que trabajan con neurocientíficos y psicólogos, simulando el cerebro y comprobando si lo conocido por la psicología puede explicar aspectos del funcionamiento del cerebro cuando se lo simula en una computadora". Además, el investigador, hizo hincapié en que sólo son imitados fragmentos del cerebro.

En la actualidad tanto el Proyecto Brain (USA), cuyo ideólogo fue Rafael Yuste como el Proyecto Blue Brain (Europa), cuyo ideólogo fue Henry Markram, no han podido, aún, alcanzar los logros ansiados.

Numerosos conceptos de fines del siglo XX, en la escalada histórica de la IA, reflejan varios aspectos de la realidad actual, a modo de ejemplo: (1) Los Sistemas de Aprendizaje Cooperativo brindan a los usuarios accesos a ideas y conceptos de otros individuos, permitiendo intercambio, discusión, negociación, defensa y síntesis desde distintos puntos de vista; (2) Los Sistemas de Aprendizaje Cooperativo son mediadores en el refuerzo de la cooperación entre aprendices, maestros, familiares y otros actores involucrados en el proceso educativo; así, el Aprendizaje Cooperativo soportado computacionalmente, se define como "un ambiente en el cual el conocimiento es intercambiado en forma de documentos electrónicos".

He aquí un claro ejemplo de la relevancia de temas que en el pasado fueron nuevos aportes y que provocaron el pensamiento y la generación de nuevos paradigmas, y siempre bajo la inspiración humana.

Esta es una rápida vista de la historia de la Inteligencia Artificial, donde no sólo lo que se mula es la inteligencia, sino el aprendizaje y el conocimiento, cuyos orígenes transcurrieron en distintos momentos temporales, pero ante la necesidad de avanzar, sin retroceder, a través de muchos hitos y muy significativos, han permitido llegar a esta instancia, un nuevo nivel, el momento actual, impulsado con fuerza en la década 2020, por Open-AI y varias empresas más, algunas de ellas afines, otras no tanto, la Era de la Inteligencia Artificial Generativa, donde parece prevalecer la inmediatez, la instantaneidad, pero, nada es casual, todo es causal..., jamás pueden olvidarse estas palabras y su orden.

Por supuesto que los niveles esperados van rumbo a la Hiper-Conectividad, pero, si no se trabaja interdisciplinariamente, esos espacios no son, sólo de alto nivel de complejidad, sino que se tornan ilusorios, en algunos aspectos.

Debajo de los grandes logros actuales, existe un alto nivel de Matemática, Estadística y Probabilidad, sin las cuales los algoritmos no podrían ser diseñados. Conforme a ello, es posible concluir, por ejemplo, que "El Pensamiento Estocástico, es un puente entre Neurociencias e Inteligencia Artificial" surgiendo conceptos provenientes de distintas disciplinas, desde la Biología, en términos de la comprensión del ser humano, en su máxima expresión, particularizando en el Cerebro, en su amplia expresión, para estudiar su configuración, sus procesos, la convergencia y la optimización de procesos, modelos mentales, razonamiento y aprendizaje, desde distintas concepciones del Cerebro, en el planteo y la resolución de problemas con presencia de incertidumbre, en aras de mejorar la toma de decisión inteligente, desde la Inteligencia Artificial en la simulación de procesos de aprendizaje mediante modelos bio-inspirados, principalmente, tales como Redes Neuronales, Machine Learning, Deep Learning y Aprendizaje Profundo por Refuerzo, amén de la Teoría de Agentes y Multiagentes. Es muy importante la Matemática Aplicada y precisamente, las Teorías de Resolución de Incertidumbre, pues todo hace a la resolución de conflictos,

basados en el Pensamiento Complejo, y para ello, es necesario un enfoque multimetodológico, pues en sí mismo se tienen situaciones interdisciplinarias, y frecuentemente, son la base de situaciones que requieren soluciones provenientes de la transdisciplinariedad, y por supuesto, desde las Neurociencias, disciplina de la integración desde el funcionamiento del Sistema Nervioso, capaz de cambiar, los paradigmas clásicos en cuanto a la visión de todo. Es natural, entonces, que, en Nuestra Vida, debemos transitar numerosos puentes, pero, éste en particular, contribuye a mejorar los procesos de aprendizaje en procura de la toma de decisiones de carácter inteligente.

REFERENCIAS BIBLIOGRÁFICAS

1. Turing A. Computing Machinery and Intelligence. *Mind*. 1950 Oct;LIX(236):433-60.
2. Alandete D. John McCarthy, el arranque de la inteligencia artificial. *El País*. 2011 Oct 27. Available from: https://elpais.com/diario/2011/10/27/necrologicas/1319666402_850215.html
3. Sampedro J. Marvin Minsky, cerebro de la inteligencia artificial. *El País*. 2016 Jan 26. Available from: https://elpais.com/elpais/2016/01/26/ciencia/1453809513_840043.html
4. Heroes of Deep Learning: Geoffrey Hinton. *DeepLearning.AI*. 2022 Jul 15. Available from: <https://www.deeplearning.ai/hodl-geoffrey-hinton>
5. De La Iglesia ED. Diferencias entre Big Data, Business Analytics y Business Intelligence. *Big Data International Campus*. 2024 Jul 23. Available from: <https://www.campusbigdata.com/big-data-blog/item/148-diferencias-entre-big-data-business-analytics-y-business-intelligence>
6. Torres J. A gentle introduction to Deep Reinforcement Learning. *Medium*. 2021 Dec 14. Available from: <https://towardsdatascience.com/drl-01-a-gentle-introduction-to-deep-reinforcement-learning-405b79866bf4>
7. McCulloch WS, Pitts W. A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bull Math Biophys*. 1943;5:115-33.
8. Hebb DO. *The Organization of Behavior*. New York: John Wiley; 1949.
9. Anderson JA. A Simple Neural Network Generating an Interactive Memory. *Math Biosci*. 1972;14:197-220.
10. Hopfield JJ. Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proc Natl Acad Sci U S A*. 1982;79:2554-8.
11. Hopfield JJ, Tank DW. Neural Computation of Decisions in Optimization Problems. *Biol Cybern*. 1985;52:141-52.
12. Hopfield JJ. Learning Algorithms and Probability Distributions in Feed Forward and Feed-Back Networks. *Proc Natl Acad Sci U S A*. 1987;84:8429-33.
13. Rosenblatt F. The Perceptron: a Probabilistic Model for Information Storage and Organization in the Brain. *Psychol Rev*. 1958;65(6):386-408.
14. Grossberg S. Contour Enhancement, Short-Term Memory, and Constancies in Reverberating Neural Networks. *Stud Appl Math*. 1973;52(3):213-57.
15. Grossberg S. Adaptive Pattern Classification and Universal Recoding: Part I. Parallel Development and Coding of Neural Feature Detectors. *Biol Cybern*. 1976;23:121-34.
16. Grossberg S. How Does the Brain Build a Cognitive Code? *Psychol Rev*. 1980;87:1-51.
17. Grossberg S. *Studies of Mind and Brain*. Dordrecht: Reidel Press; 1982.
18. Grossberg S. *Neural Networks and Natural Intelligence*. Cambridge, MA: The MIT Press; 1988.
19. Carpenter SA, Grossberg S. The ART of Adaptive Pattern Recognition by a Self-Organizational Neural Network. *Computer*. 1987 Mar;20(3):77-87.
20. Carpenter SA, Grossberg S. ART 3: Self-Organizational of Distributed Pattern Recognition Codes in Neural Networks. In: Proceedings of the International Neural Networks Conference; 1990 Jul 9-13; Paris, France. Dordrecht: Kluwer Academic Publishers; 1990. p. 801-4.
21. McClelland JL, Rumelhart DE, the PDP Research Group. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Vol. 2. Psychological and Biological Models*. Cambridge, MA: MIT Press/Bradford Books; 1986.
22. Kohonen T. The Self-Organizing Map. *Proc IEEE*. 1990 Sep;78(9):1464-80.
23. Aleksander I, Morton H. The Cognitive Challenge for Neural Architectures. In: Proceedings of the International Neural Networks Conference; 1990 Jul 9-13; Paris, France.
24. Gärdenfors P. In *Cognitive Science and Information Technology*. Wearn Y, editor. Uppsala: Swedish Science Press; 1995. p. 68-72.
25. Newell A, Shaw JC, Simon HA. Report on a general problem-solving program. In: Proceedings of the International Conference on Information Processing; 1959; Paris, France. p. 256-64.
26. Newell A, Simon HA. *Human Problem Solving*. Englewood Cliffs, NJ: Prentice-Hall; 1972.
27. Polya G. *How to Solve It?* Princeton University Press; 1945.
28. Zanakis SH, Evans JR. Heuristic "optimization": Why, when, and how to use it. *Interfaces*. 1981;11(5):84-91.
29. Sagula JE. Visión de la Educación Matemática en Convergencia con la Inteligencia Artificial en Contextos Complejos (Tiempos de Pandemia) (desde Big Data a Machine Learning). In: Memorias del I SEM-V-Tomo I (I Simposio de Educación Matemática-Virtual); 2020 Aug 13-14; Luján, Provincia de Buenos Aires, Argentina. Luján: Universidad Nacional de Luján; 2021 Oct. p. 1-10. ISBN 978-987-3941-61-0.
30. Sagula J. La importancia creciente de la Heurística y la Metaheurística en la Resolución de Problemas. In: Memorias del II SEM-V-Tomo I; 2021 May 13-14; Luján, Buenos Aires, Argentina. Luján: Universidad Nacional de Luján; 2021 Dec. p. 1-10. ISBN 978-987-3941-66-5.
31. Minsky M. *The Society of Mind*. New York: Simon & Schuster; 1986.
32. Jennings N, Wooldridge M. Software Agents. *IEE Rev*. 1996 Jan;42(1):17-20.