

# Pensamiento estadístico y probabilístico, un puente entre neurociencias e inteligencia artificial

Statistic and Probabilistic thinking,  
a bridge between neuroscience and artificial intelligence

Recepción del artículo: 27/02/2023 • Aceptación para publicación: 18/04/2023 • Publicación: 30/06/2023

● <https://doi.org/10.32870/ecucba.vi20.297>

**Jorge E. Sagula**

Universidad Nacional de Luján. División Matemática y División Estadística,  
Departamento Ciencias Básicas. Luján, Buenos Aires. Argentina.

\*Autor para correspondencia: jsagula@mail.unlu.edu.ar

## Resumen

¿Cuál es el epicentro de este artículo? Es el cerebro humano, en el cual confluye, lo imprescindible, lo prescindible y lo valioso en todos los sentidos, donde nacen las simientes de las ideas, desarrollos y soluciones, con preeminencia en la resolución de conflictos, numerosas veces de características complejas, razón por la cual el cerebro mapea, a través del pensamiento, rotulado con diferentes nombres, teorías básicas y no tan básicas de resolución de incertidumbre; considerando a la Estocástica como una disciplina de amplia vastedad que se ve reflejada en el funcionamiento cerebral. En esta revisión convergen disciplinas centrales como: la Biología, las Neurociencias, corrientes del Pensamiento basado en la Incertidumbre y la Inteligencia Artificial en la simulación de procesos de aprendizaje, mediante modelos bio-inspirados como: Redes Neuronales, Machine Learning, Deep Learning, Aprendizaje por Refuerzo, la Teoría de Agentes y Multiagentes, la Matemática Aplicada y las Teorías de Resolución de Incertidumbre. El propósito es la resolución de conflictos, basados en el Pensamiento Complejo, con un enfoque multimetodológico, ya que se tienen situaciones interdisciplinarias, que requieren soluciones transdisciplinarias. Las distintas concepciones del Cerebro, en el planteo y resolución de problemas con presencia de incertidumbre, en aras de mejorar la toma de decisión inteligente.

**Palabras clave:** Neurociencias, cerebro estadístico, cerebro bayesiano, multimetodologías.

## Abstract

What is the epicenter of this article? It is the human brain, in which the essential, the dispensable and the valuable in all senses come together, where the seeds of ideas, developments and solutions are born, with preeminence in the resolution of conflicts, many times with complex characteristics, reason by which the brain maps, through thought, labeled with different names, basic and not so basic theories of uncertainty resolution; considering Stochastics as a wide-ranging discipline that is reflected in brain functioning. In this review, central disciplines converge such as: Biology, Neurosciences, currents of Thought based on Uncertainty and Artificial Intelligence in the simulation of learning processes, through bio-inspired models such as: Neural Networks, Machine Learning, Deep Learning, Learning by Reinforcement, Agent and Multiagent Theory, Applied Mathematics and Uncertainty Resolution Theories. The purpose is conflict resolution, based on Complex Thought, with a multi-methodological approach, since there are interdisciplinary situations that require transdisciplinary solutions. The different conceptions of the Brain, in the posing and solving of problems with the presence of uncertainty, in order to improve intelligent decision making.

**Keywords:** Neurosciences, statistical brain, bayesian brain, multimethodologies.

## Introducción

En un mundo, como el actual, plagado de situaciones conflictivas, de diversa índole y debidas a múltiples causas, cada vez surgen nuevas corrientes de pensamiento disciplinar, y particionadas como escisiones, frecuentemente más pequeñas.

Capra (2009), planteó “la existencia de soluciones para los principales problemas de nuestro tiempo, algunas muy sencillas, pero que requieren un cambio radical en nuestra percepción, en nuestro pensamiento y en nuestros valores”; también manifestó que “nuestros líderes no sólo son incapaces de percibir la interconexión de los distintos problemas, sino que se niegan a reconocer hasta qué punto lo que ellos llaman soluciones comprometen a las generaciones venideras”. Evidentemente, no sólo es esencial entender el significado del término “problema”, sino también la interpretación que las personas hacen de tal término. Reflexionando adecuadamente, es fácil concluir que no puede anteponerse “un problema a un contexto”, sino contrariamente, pues “un problema está inmerso en un contexto”; entonces, expreso que: “Un problema constituye un obstáculo o dificultad, siempre que exista un individuo con suficiente interés o inteligencia que lo enfrente (lo ha percibido) y tenga la necesidad de resolverlo, reconociendo así el dominio donde está inserto y conociendo perfectamente la situación inicial (o situaciones iniciales) y el objetivo (u objetivos), razón por la cual es necesario encontrar la solución, esto es el camino de transformación de la situación inicial en la situación final”.

Entonces, y desde el punto de visto formativo, se torna cada vez más difícil formar individuos pensantes, capaces de abordar situaciones complejas, pues eso requiere la construcción de Modelos de razonamiento acordes y ad hoc, requiere de pensamiento complejo (Morin, 1990) y este proceso de aprendizaje no se logra ni rápida ni ampliamente, pues es necesario disponer de espacios específicos con formadores, en todos los niveles, no sólo de amplia vastedad de conocimiento sino de mente abierta, capaces de crear en forma continua.

Sin embargo, en atención a la multicausalidad, donde se requieren soluciones tangibles, concretas y

adecuadas para situaciones conflictivas provenientes de distintos ámbitos, no siempre se resuelven en forma adecuada sino además en forma segmentada, no proveyendo soluciones multimetodológicas diseñadas sobre base científica; en tal instancia, es posible cimentarlas a partir de la Ingeniería de Conocimiento, concepto nacido en el seno de la Inteligencia Artificial (IA), en la década de 1960, precisamente, ante la necesidad de resolver problemas, específicamente basados en conocimiento. La Ingeniería de Conocimiento (IC) comprende un conjunto de principios, métodos y herramientas que permiten aplicar el saber científico y el conocimiento heurístico al uso del conocimiento y de sus fuentes mediante ideas útiles al hombre; la IC enfoca y trata el problema de construcción de Sistemas Basados en Conocimiento (SBC), partiendo de procesos tales como adquisición y elicitación, para organizar el conocimiento, luego modelarlo y representarlo en forma entendible por máquina y realizar una implementación efectiva, tanto en SBC como en Sistemas Expertos, Sistemas Inteligentes, Sistemas Tutores Inteligentes, Sistemas Multiagentes. Sistemas Decisionales Inteligentes, entre otros.

## Métodos

Aquí se presenta un estudio descriptivo, donde es imprescindible la investigación documental aunada a la experiencia y el trabajo en la temática. En un estudio descriptivo, la recolección de datos, generalmente es para una investigación inicial donde no se demuestra mediante un experimento, sino que se muestran las relaciones de la información obtenida con el mundo tal cual es, basada en la ciencia. Bickman & Rog (1998), sugieren que los estudios descriptivos pueden responder a preguntas como “qué es” o “qué era”, en tanto que los experimentos responden a preguntas tales como “por qué” o “cómo”.

## Pensamiento Estadístico

El Pensamiento Estadístico es la forma en que la información se ve, se procesa y se convierte en pasos de acción. Es una filosofía de pensamiento, no una forma de realizar cálculos matemáticos.



Figura 1. Fuente. Revista Espacios. Vol. 25, Nº 3, 2004

Herbert G. Wells (Gran Bretaña, 1866-1946), no sólo fue escritor de ciencia ficción, sino que su pensamiento se orientó a imaginar situaciones donde cada ciudadano del futuro debería desarrollar su vida inmerso en la realización de operaciones algebraicas y estadísticas, tales como la determinación de extremos (máximos y mínimos), cotas, y calcular y pensar en promedios, como operaciones primarias. Esto permite evaluar que una persona extra-estadística (o no estadístico) fue capaz de vislumbrar “escenarios plausibles”, previendo la necesidad de utilizar Pensamiento Estadístico como concepto insoslayable del lenguaje ordinario.

El Pensamiento Estadístico conforme a Snee (1993) es “un conjunto de principios y valores que permiten identificar los procesos, caracterizarlos, cuantificarlos, controlar y reducir su variación para implantar acciones de mejora”.

La Teoría en Administración (Deming, 1994) permite sustentar al Pensamiento Estadístico, pues el estadístico desarrolló el Sistema de Conocimiento Profundo, conteniendo la esencia de los tres principios básicos:

1. Todo trabajo ocurre en un sistema de procesos interconectados;
2. La variación existe en todos los procesos;
3. La clave del éxito se alcanza comprendiendo y reduciendo la variación del proceso.

Y está integrado por cuatro partes: la apreciación de un sistema; el conocimiento sobre la variación; la Teoría del Conocimiento y la Psicología.

La División Estadística de la American Society for Quality Control (ASQC) en el año 1994, presentó el proyecto sobre Pensamiento Estadístico en la reunión Tactical Planning Meeting; el objetivo fue que los miembros de tal división, aplicaran el Pensamiento Estadístico en su trabajo para lograr mejores resultados. El primer problema que tuvo el equipo fue que todos tendieron a emplear el término

“Pensamiento Estadístico”; pero hubo variación en quienes constaban como miembros del equipo. Consecuentemente, el primer objetivo fue desarrollar y publicar una definición operacional del Pensamiento Estadístico. Finalmente, en el año 1996, expresaron que “el Pensamiento Estadístico es una filosofía de aprendizaje y acción basada en varios principios fundamentales que tiene como finalidad el logro del mejoramiento del desempeño institucional”. (Quality Press, 1996)

### Pensamiento Probabilístico

El Pensamiento Probabilístico, esencialmente, consiste en tratar de estimar, mediante algunas herramientas lógicas y matemáticas, la probabilidad de que suceda algún resultado específico. En este contexto, el Pensamiento Probabilístico posibilita identificar los resultados más probables; en tal instancia, las decisiones se consideran más precisas y efectivas.

El Pensamiento Probabilístico está fuertemente afectado por el mecanismo de construcción de Modelos Mentales, que constituyen representaciones psicológicas de situaciones reales, imaginarias o hipotéticas, desde las cuales se construyen escenarios en base a marcos referenciales, y que permiten, mediante posteriores mecanismos cognitivos, el planteo y la resolución de problemas, y el proceso de toma de decisiones. Las teorías de representación de la mente permiten que las representaciones de constructos mentales y el uso de las mismas en los procesos de decisión sean posibles, existiendo sustento en la cognición, generando acciones. Se puede postular que “una representación mental es un isomorfismo entre procesos que ocurren en el cerebro y el comportamiento de ciertos aspectos del mundo”. Esta definición de una Teoría de la Representación, permite vincular el concepto de Modelo Mental con la Heurística (del griego “heuriskien”, significa “buscar”); Heurística puede definirse como “conjunto de procedimientos simples, frecuentemente basados en el sentido común, que conforme se supone, permitirán obtener una buena solución a problemas con cierto grado de dificultad, en forma rápida y fácil” (Zanakis *et al.*, 1981).

No es posible hablar de Heurística sin mencionar a Polya (1945).

Definir una teoría de la representación como fue hecho precedentemente, permite vincular el concepto de

Modelo Mental con la Heurística; consecuentemente, las metodologías de resolución se traducen en representaciones mentales (o bien, internas) que cada aprendiz construye en su proceso de razonamiento.

Es menester mencionar que “las representaciones se pueden considerar como poderosas herramientas para la construcción de la comprensión y consecuentemente, para comunicar la información y la comprensión misma” (Greeno *et al.*, 1997).

Es necesario, que la enseñanza de la probabilidad en el sistema escolar, se oriente al desarrollo de Alfabetización Probabilística y Pensamiento Probabilístico, conforme lo expresan Vergara, (Estrella *et al.*, 2020) en su estudio sobre relaciones entre pensamientos proporcional y probabilístico en la toma de decisiones. En cuanto a la Alfabetización Probabilística, Gal (2005) y Sánchez (2009), la vinculan con el Conocimiento Probabilístico elemental de los ciudadanos en su desenvolvimiento cotidiano, refrendando el Pensamiento Estadístico del escritor H. G. Wells. Gal (2005), propone un modelo, en el cual el componente cognitivo incluye los conceptos: (1) Ideas Centrales: variación, aleatoriedad, independencia, predictibilidad, incertidumbre; (2) Cálculo de probabilidades: estimando la probabilidad de ocurrencia de eventos; (3) Idioma: términos y métodos utilizados para comunicarse sobre el azar; (4) Contexto: comprender el papel y las implicaciones de los problemas y mensajes probabilísticos en varios contextos y en el discurso público y personal; y (5) Preguntas críticas: cuestiones sobre las que reflexionar cuando se trata de probabilidades.

Es dable concluir que el Pensamiento Probabilístico puede verse como una línea de pensamiento de mayor complejidad, el Pensamiento Heurístico, no excluyente de tales procesos, pero que constituye una línea metodológica orientada a la Resolución de Problemas, y que precisamente, puede definirse mediante un conjunto de reglas metodológicas, sobre la base de la creatividad, el ingenio y la invención; consecuentemente, parte de la percepción contextual hacia la asimilación y la comprensión del conocimiento en pro de la capacidad en la resolución de problemas.

## Neurociencias

Las Neurociencias cumplen “la compleja e intrincada función” de desentrañar la actividad cerebral en su vinculación con la mente, la conducta y la actividad nerviosa, tanto en el nivel molecular y neuronal como en Redes Neuronales y a niveles conductual y cognitivo.

Las Neurociencias comprenden un conjunto de disciplinas científicas interdisciplinarias y transdisciplinarias que estudian la estructura, las funciones y el desarrollo del Sistema Nervioso, y específicamente, el Cerebro, y fundamentalmente “cómo aprende” “cómo guarda la información”.

Consecuentemente, el estudio de Neurociencias involucra las siguientes áreas: Neuroanatomía, Neuroquímica, Psicoimmunoneuroendocrinología, Neuropsicología (con inclusión del estudio de efectos de lesiones cerebrales), Neurociencia Cognitiva (Pensamiento, Memoria, Atención, Percepción), Psicofisiología, Biología, Física, Electrofisiología, Matemáticas Superiores, Genética, Antropología, Filosofía/Ontología, Bio-Psicología, Farmacología, Paleoneurobiología, Ciencias de la Computación, con énfasis en Inteligencia Artificial, entre otras.

En la década de 1990, la Neurociencia, la Psicología Cognitiva, la Inteligencias Artificial y la Lingüística convergen a la Neurociencia Cognitiva (Neurociencia Computacional), concepto nacido en una conferencia proferida por Eric L. Schwartz, en el año 1985, en California (Estados Unidos), generando el descubrimiento de propiedades y de principios gobernantes de redes neuronales y de neuronas, produciendo una integración.

La Neurociencia Computacional (que se corresponde con la estructura de hardware, explica la cognición) se basa en este orden de conceptos: Neurociencia, Ciencias de la Computación, Matemática, Psicología Experimental y Filosofía. Se trabaja, desde la disciplina, para asumir que los Modelos Mentales se pueden correlacionar con los patrones de impulsos nerviosos en el cerebro.

## Cerebro Estadístico

La Teoría del Cerebro Estadístico deviene en que el cerebro supera a las máquinas, siempre en términos de incertidumbre y probabilidades, optimizando su capacidad de aprendizaje. Los algoritmos que sustentan

a Machine Learning y Deep Learning, su evolución, aún están en forma de desplazamiento Bottom Up (sin capacidad de reflexión) respecto de la capacidad del cerebro. Es importante consignar que el cerebro puede reconocer un patrón, tanto en sonido como imagen, en una fracción de segundo, en tanto que una máquina requiere de un análisis de Big Data y miles, millones de datos. Los algoritmos implementados en redes neurales de aprendizaje llegan a un óptimo de cómputo, estabilizándose, marcando una tendencia en sus datos; en tanto que el cerebro humano logra un registro constante de la incertidumbre asociada a cada nodo de información y procede a actualizarla en cada momento de aprendizaje.

El cerebro genera permanentemente modelos del contexto en el cual se mueve y, en función de la información que percibe a partir de los sensores humanos, efectúa predicciones sobre el futuro inmediato (en este primer nivel es lo que ocurre en todos los seres humanos, existe una capacidad esencial de supervivencia), y en algunas instancias, en mayores desarrollos, en el futuro mediano.

La hipótesis sobre esta capacidad intrínseca del funcionamiento del cerebro sea de naturaleza estadística fue planteada por el médico y físico Hermann von Helmholtz (1821-1894), en su obra Tratado de Óptica Fisiológica (1867), pues forjó la expresión “Inferencia Inconsciente” en procura de designar este modo de operar; la expresión de mentas destaca el carácter estadístico de tal capacidad, debido a que los estímulos que llegan al cerebro responden a una naturaleza intrínsecamente variable, y además, permiten identificar las regularidades entre una amplia gama de variaciones, hecho que representa la esencia del trabajo estadístico; pero, en medio de esta variabilidad, la identificación de regularidades no puede limitarse a reconocer si una cierta secuencia de eventos se repite idénticamente a los estímulos (Hernández *et al.*, 2021).

### Cerebro Bayesiano

El Cerebro Bayesiano representa un Estadístico Neuronal, surgiendo como un Modelo entre el cerebro pensado como todo lo innato y todo lo adquirido, siendo superior a una máquina; actúa como un Estadístico permanentemente considerando

incertidumbre y probabilidades en términos a optimizar su capacidad de aprendizaje

Conforme a la Teoría del Cerebro Bayesiano, se sostiene que el cerebro permite comprender cómo funciona el mundo, y esto involucra los diferentes escenarios de inmersión. Esta labor se desarrolla en la corteza orbitofrontal. Así, no se percibe el mundo tal como es realmente, sino como el cerebro supone que es; situación que es profundizada mediante los impulsos sensoriales que se reciben de acuerdo a las percepciones del mundo exterior.

La importancia de Thomas Bayes y la formulación de su Teoría del Cerebro Bayesiano reside en que “el cerebro se guía mediante la Teoría de la Probabilidad o Regla de Bayes” (Farias, 2021). Este pensamiento se refleja en las manifestaciones de científicos cognitivos que conjeturaron y lo siguen haciendo, enfáticamente, que el cerebro humano incorpora algoritmos probabilísticos, específicamente bayesianos en todo momento, tanto desde la percepción como en los procesos deliberativos y decisionales.

### Multimetodologías

La profundidad de la complejidad sólo puede analizarse en el contexto de la interdisciplinariedad, en primera instancia, y en la transdisciplinariedad a posteriori; consecuentemente, para un efectivo tratamiento de estos temas es adecuado dirigirse a un enfoque multimetodológico.

La multimetodología se entiende generalmente como el “arte” de ir más allá del uso de una única metodología con el propósito de combinar generalmente varias metodologías, en su totalidad o en parte, y si la situación lo amerita, provenientes de distintos paradigmas, de forma de enfrentar la riqueza del mundo real (Mingers, 1997).

Es necesario enfatizar que multimetodología no se relaciona con un paradigma o una metodología específica, o con una forma específica de combinación de metodologías, sino que supera estas posibilidades, orientándose a vincular, integrar y combinar diferentes metodologías, técnicas y herramientas, desde un mismo paradigma o varios y distintos paradigmas, para responder a conflictos en diferentes situaciones contextuales, y por tanto, inicialmente existe una heurística y una heurística operativa que permite mejorar las capacidades

cognitivas a la hora de definir qué conceptos son necesarios para construir, en modo de convergencia, la integración de metodologías, técnicas y herramientas, aunque los mismos provengan de diferentes ciencias y/o disciplinas, de modo que los sistemas sensoriales humanos juegan un rol esencial para ello, pues la clave está en cómo dirigirlos disponiendo de “la intención de registrar”, y por supuesto “interpretar el contexto”, realimentando la información y el conocimiento, generando conocimiento del conocimiento, refinando el conocimiento, en pos del meta-conocimiento, posibilitando el surgimiento de la Metaheurística (Sagula, 2021).

Las Multimetodologías se justifican en la necesidad de estudiar e investigar “sistemas complejos”, pues éstos son “consecuencia de varias estructuras (o componentes) que se interrelacionan”, y desde la vinculación de sus componentes pues existe información adicional no percibida previamente por el observador; así, esto permite advertir que como fruto de las interacciones entre los componentes se obtienen nuevas propiedades imposibles de explicarse conociendo sólo las propiedades (Propiedades Emergentes) de los elementos aisladamente (García, 2006).

Es evidente que, sin modelar adecuadamente un sistema complejo, en general, se obtendrá no más que una irrelevante aproximación; por tanto, el tratamiento de un tema de esta magnitud, independientemente del área temática de proveniencia, se centra en el tratamiento “multidisciplinario”, pero específicamente de carácter interdisciplinario.

## Inteligencia Artificial

¿Cómo definir a la Inteligencia Artificial? En forma simple, la 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 (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 IA 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 en el siglo XX, en la década del ochenta, Sánchez-Montañés, haciendo hincapié en que sólo son imitados fragmentos del cerebro.

Los algoritmos computacionales que se denominan Redes Neuronales Artificiales (RNA) están inspirados en la organización jerárquica de la corteza cerebral; se organizan en una pirámide de capas sucesivas, en la cual 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 IA, es menester realizar una síntesis de los aspectos más salientes en la evolución de la IA, desde el aporte genérico de las RNA hasta converger en los nuevos enfoques de los últimos años. Puntualmente, las RNA, en alguna forma, pueden remontarse a los trabajos iniciales de McCulloch & 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, aportando a las Redes Neuronales estos conceptos:

- Información en RNA, 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 IA centraron su atención simultáneamente en dos aspectos: Extensión de la capacidad de computadoras y Movimiento hacia la comprensión de la Inteligencia

Humana. Y comienzan a enfatizar sus acciones en IA y Simulación Cognitiva.

**Anderson (1972)** concibe una RNA, la Memoria Interactiva; desarrolló un Modelo Lineal (Asociador Lineal) que corresponde a un Modelo de Procesamiento Paralelo Distribuido; y se interesó en describir Modelos de RNA y sus correspondientes mecanismos de aprendizaje.

**Hopfield (1982)** presentó un núcleo de nuevas ideas sobre RNA, 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 puede 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 & Tank (1985)** aplican las Redes Recurrentes a problemas complejos de optimización; posteriormente, Hopfield (1987) inicia 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), correspondiente a Algoritmos de Aprendizaje Supervisado y No Supervisado, McClelland & cols. (1986) desarrollaron sus modelos.

**Grossberg (1973, 1976, 1980, 1982, 1988)** 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.

**Carpenter & Grossberg (1987, 1990)** desarrollaron Arquitecturas de RNA que denominaron Adaptive Resonance Theory (ART) que autoorganizan 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.

**Kohonen (1988)** concibió una RNA, la Memoria Asociativa, que presenta una única capa de neuronas fuertemente conectadas entre sí y con el mundo exterior, tal que los valores de activación son lineales y continuos.

**Kohonen (1990)** introdujo la idea de Mapa Auto-Organizado, describiendo una RNA de 2 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 & Morton (1990)** postularon que el entendimiento profundo de diferentes modelos de Procesamiento Mental posibilitaría en el futuro un gran avance en distintas temáticas de IA en 1990 y años después, con su equipo de investigación, desarrolló una arquitectura general híbrida, con tres niveles mayores: Sensorización, Cognitivo Neural y Computacional Convencional.

**Gärdenfors (1995)** expresó que las RNA, la Formación de Conceptos y la Semántica Cognitiva constituían la base de la investigación en Agentes Autónomos y en Visión Artificial; de esa forma, la IA tendría un promisorio futuro, orientándose a: Simulación Cognitiva y Desarrollo de Programas Inteligentes.

Cuando comienzan las investigaciones en Aprendizaje Automático (Machine Learning) en el campo de la Inteligencia Artificial en la década de 1980, a partir de las ideas de Alan Turing en 1950, 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).

Deep Learning (Aprendizaje Profundo), 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 Neurales Multicapas (Redes Neurales 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 muchas 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 (Sagula, 2021).

El Aprendizaje Profundo por Refuerzo constituye una Neo-Evolución, un nuevo paradigma, pero desde ideas previas, inspiradas en Alan Turing (1950) y proseguidas por (Minsky, 1986), que si bien como uno de los pioneros de la IA tuvo grandes aportes, la referencia citada conduce al nacimiento de los Agentes Inteligentes; el Aprendizaje Profundo por Refuerzo, es consecuencia de la transdisciplinariedad entre Machine Learning y Deep Learning, por un lado y la Teoría de Agentes y Multiagentes Inteligentes, por el otro, y en esta instancia, un Agente Inteligente aprende a optimizar un Proceso de Decisión.

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 elucubrarón y que, con distintos avatares en términos de implementación, llevaron a campos promisorios, que hoy por hoy, siguen alimentando a sub-disciplinas tales como Machine Learning, Deep Learning y Deep Reinforcement Learning, en las líneas más vinculadas con las Neurociencias e Inteligencia Artificial (Sagula, 2021).

### Neurociencias e Inteligencia Artificial

Así las cosas, las diferentes tecnologías están produciendo cambios en nuestra cotidianeidad, y por supuesto en este contexto, no escapa a la consideración la IA, por un lado, y por otro, las Neurociencias, particularmente la IA en la Educación y las Neurociencias en Educación (Neuroeducación), vienen ganando territorio a paso firme, tanto en cuanto a la mejora de los procesos cognitivos como a la potenciación como metodologías de soporte del aprendizaje, y en cuanto al aprendizaje propiamente dicho.

Esta fusión, la Neuro-IA, es un refinamiento de la convergencia a la Neurociencia Cognitiva (Neurociencia Computacional) desde las Neurociencias, la Psicología Cognitiva, la Inteligencia Artificial y la Lingüística, generando 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 a favor de asumir la correlación entre los modelos mentales y los patrones de impulsos nerviosos en el cerebro.

### Conclusiones

En este artículo, producto generador de la Conferencia “Pensamiento Estocástico, un puente entre Neurociencias e Inteligencia Artificial” surgen 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 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.

**Literatura citada**

- Capra, F. (2009). *La trama de la vida: Una nueva perspectiva de los sistemas vivos*. Ed. Anagrama.
- Morin, E. (1990). *Introducción al Pensamiento Complejo*. GEDISA.
- Bickman, L. y Rog, D. (1998). *Handbook of Applied Social Research Methods*. Thousand Oaks, Ca: Sage Publications. 580 pp.
- Snee, R. D. (1993). What's Missing in Statistical Education? *The American Statistician*, 47(2), 149–154. <https://doi.org/10.2307/2685201>
- Deming, W. E. (1994). *The New Economics*. Boston. Quality Press (1996). *Glossary and Tables for Statistical Quality Control*. ASQ Quality Press.
- Polya, G. (1945). *How to Solve It?* Princeton University.
- Zanakis, S. H. y Evans, J. R. (1981). Heuristic "optimization": Why, when, and how to use it. *Interfaces*, 11(5), 84-91.
- Greeno, J. G. y Hall, R. P. (1997). Practicing Representation: Learning with and about representational forms. *Phi Delta Kappan*, 78 (5), 361-367.
- Vergara, A., Estrella, S. y Vidal-Szabó, P. (2020). Relaciones entre pensamiento proporcional y pensamiento probabilístico en situaciones de toma de decisiones. *Revista Latinoamericana de Investigación en Matemática Educativa*, 23(1), 7-36.
- Gal, I. (2005). Towards "probability literacy" for all citizens: building blocks and instructional dilemmas. En *Exploring Probability in School. Challenges for Teaching An Learning*. Ed. Jones, G. Springer.
- Sánchez, E. (2009). La probabilidad en el programa de estudio de matemáticas de la secundaria en México. *Educación Matemática*, 21(2), 39-77.
- Helmholtz, H. (1867). *Handbuch der physiologischen Optik*. Leopold Voss, Leipzig.
- Hernández, N., Duarte, A., Ost, G., Fraiman, R., Galves, A., & Vargas, C. D. (2021). Retrieving the structure of probabilistic sequences of auditory stimuli from EEG data. *Scientific Reports*, 11(1), 3520.
- Fariás, I. (2021). *Thomas Bayes y el Cerebro Bayesiano*. Psicoactiva. Recuperado de <https://www.p psicoactiva.com/blog/thomas-bayes-y-el-cerebro-bayesiano/>
- Mingers, J. (1997). *Multi-Paradigm Multimethodology*. John Wiley & Sons, England.
- García, R. (2006). *Sistemas Complejos*. GEDISA.
- Turing, A. (1950). Computing Machinery and Intelligence. *Mind*, 59, 433-460.
- McClulloch, W. S. y Pitts, W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of mathematical biophysics*, 5, 115-133.
- Morris, R. G. (1949). D.O. Hebb: The Organization of Behavior. *Brain Research Bulletin*, 50. [doi.org/10.1016/S0361-9230\(99\)00182-3](https://doi.org/10.1016/S0361-9230(99)00182-3).
- Anderson, J. A. (1972). A Simple Neural Network Generating on Interactive Memory Mathematical. *Biosciences* 14, 197-220.
- Hopfield, J. J. (1982). Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences. USA*, 79, 2554-2558.
- Hopfield, J. J. y Tank, D. W. (1985). Neural Computation of Decisions in Optimization Problems. *Biological Cybernetics*, 52, 141-152.
- Hopfield, J. J. (1987). Learning Algorithms and Probability Distributions in Feed-Forward and Feed-Back Networks. *Proceedings of the National Academy of Sciences. USA*, 84, 8429.
- Rosenblatt, F. (1958). The Perceptron: a Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, 65 (6) 386-408.
- McClelland, J. L., Rumelhart, D. E. y the PDP Research Group (1986). *Parallel Distributed Processing Explorations in the Microstructure of Cognition Psychological and Biological Models*. Cambridge, MA, MIT Press/Bradford Books.
- Grossberg, S. (1973). Contour Enhancement, Short-Term Memory, and Constancies in Reverberating Neural Networks. *Studies in Applied Mathematics*, 52 (3) 213-257.
- Grossberg, S. (1982). *Studies of Mind and Brain*. Dordrecht, Holland: Reidel Press.

- Grossberg, S. (1988). *Neural Networks and Natural Intelligence*. Cambridge, MA: The MIT Press.
- Carpenter, S. A. y Grossberg, S. (1987). The ART of Adaptive Pattern Recognition by a Self-Organizational Neural Network. *Computer*, 77-87.
- Carpenter, S. A. y Grossberg, S. (1990). ART 3: Self-Organizational of Distributed Pattern Recognition Codes in Neural Networks. International Neural Networks Conference July 9-13, 1990, Palais des Congres-Paris, 2, 801-804. Dordrecht, Holland: Kluwer Academic Publishers.
- Kohonen, T. (1988). *Self-Organization and Associative Memory*. (3ª Ed.). New York, Springer-Verlag.
- Kohonen, T. (1990). The Self-Organization Map. *Proceedings of the IEEE*, 78 (9) 1464-1480.
- Aleksander, I. y Morton, H. (1990). *The Cognitive Challenge For Neural Architectures*. INNC.
- Gärdenfors, P. (1995). In *Cognitive Science and Information Technology*. Ed. Y. Wearn, *Swedish Science Press*, 68-72.
- Sagula, Jorge E. (2021). La importancia creciente de la Heurística y la Metaheurística en la Resolución de Problemas. En *Memorias del II SEM-V-Tomo I*. Universidad Nacional de Luján. Luján, Buenos Aires, Argentina; 13-14 mayo'2021. ISBN 978-987-3941-66-5. EDUNLU.
- Minsky, M. (1986). *The Society of Mind*. New York, Simon & Schuster.