



PROGRAMA DE AÑO SABÁTICO APUNTES:
INTELIGENCIA ARTIFICIAL
CLAVE: ISIC-2010-224

DEPARTAMENTO DE SISTEMAS Y COMPUTACIÓN
INGENIERÍA EN SISTEMAS COMPUTACIONALES
AUTORIZACIÓN AÑO SABÁTICO No. AS-1-038/2023
ELABORADO POR: CARLOS ALBERTO CAMACHO ANDRADE

ZIHUATANEJO GUERRERO, MÉXICO
MARZO DE 2025



ÍNDICE DE CONTENIDO	i
ÍNDICE DE FIGURAS	v
ÍNDICE DE TABLAS	vii
INTRODUCCIÓN	viii
PROPUESTA DE HORAS TEÓRICO-PRÁCTICA POR TEMA/SUBTEMA	ix
1 INTRODUCCIÓN A LA INTELIGENCIA ARTIFICIAL	1
1.1 Introducción a la Inteligencia Artificial	3
1.1.1 Enfoques basados en el comportamiento humano	4
1.1.2 Enfoques basados en el razonamiento	6
1.2 Historia de la Inteligencia Artificial	7
1.2.1 Filosofía (desde el año 428 a.C. hasta el presente)	8
1.2.2 Matemáticas (desde el año 800 al presente)	9
1.2.3 Economía (desde el año 1776 hasta el presente)	11
1.2.4 Neurociencia (desde el año 1861 hasta el presente)	12
1.2.5 Psicología (desde el año 1879 hasta el presente)	13
1.2.6 Ingeniería Computacional (desde el año 1940 hasta el presente)	13
1.2.7 Teoría de Control y cibernética (desde el año 1948 hasta el presente)	14
1.2.8 Lingüística (desde el año 1957 hasta el presente)	14
1.3 Las habilidades cognoscitivas según la psicología. Teorías de la inteligencia (conductismo, Gardner, etc.)	15
1.3.1 Habilidades cognoscitivas según la psicología	15
1.3.2 Teorías de la inteligencia (Conductismo, Gardner, etc.)	17



1.4 El proceso de razonamiento según la lógica (Axiomas, Teoremas, demostración)	25
1.5 El modelo de adquisición del conocimiento según la filosofía	33
1.6 El modelo cognoscitivo	38
1.7 El modelo del agente inteligente, Sistemas Multi Agentes, Sistemas Ubicuos	43
1.8 El papel de la heurística	54
1.8.1 Algoritmos de exploración de alternativas	54
1.8.2 Algoritmo A*	56
1.8.3 Algoritmos de búsqueda local	60
2 REPRESENTACIÓN DEL CONOCIMIENTO, RAZONAMIENTO Y LOS ASPECTOS METODOLÓGICOS EN INTELIGENCIA ARTIFICIAL	62
2.1 Principios y Metodología de la Inteligencia Artificial	65
2.2 Paradigmas de la Inteligencia Artificial	68
2.3 Mapas Conceptuales	70
2.4 Redes Semánticas	72
2.5 Razonamiento Monótono	77
2.6 Conocimiento No-Monótono y otras Lógicas	78
2.7 Razonamiento Probabilístico	81
2.8 Teorema de Bayes	84
2.8.1 Definición	85
3 REGLAS Y BÚSQUEDA	88
3.1 Representación de Conocimiento Mediante Reglas	89
3.2 Métodos de Inferencia en Reglas	90



3.3 Reglas de Producción	91
3.4 Sintaxis de las Reglas de Producción	93
3.5 Semántica de las Reglas de Producción	95
3.6 Arquitectura de un Sistema de Producción (SP) o Sistemas Basados en Reglas, (SBR)	97
3.6.1 Hechos	100
3.6.2 Base de Conocimientos	100
3.6.3 Mecanismo de Control	100
3.7 Espacios de Estados Determinísticos y Espacios No Determinísticos	101
3.8 Búsqueda Sistemática	102
3.8.1 Búsqueda de Metas a Profundidad	103
3.8.2 Búsqueda de Metas en Anchura	103
4 APLICACIONES CON TÉCNICAS DE IA	105
4.1 Robótica	106
4.1.1 Conceptos Básicos	106
4.1.2 Clasificación	106
4.1.3 Desarrollos Actuales y Aplicaciones	109
4.2 Redes Neuronales (RN)	114
4.2.1 Conceptos Básicos	114
4.2.2 Clasificación	117
4.2.3 Desarrollos Actuales y Aplicaciones	121
4.3 Visión Artificial	123



4.3.1 Conceptos Básicos	123
4.3.2 Desarrollos Actuales y Aplicaciones	123
4.4 Lógica Difusa (Fuzzy Logic)	124
4.4.1 Conceptos Básicos	124
4.4.2 Desarrollos Actuales y Aplicaciones	126
4.5 Procesamiento de Lenguaje Natural (PLN)	127
4.5.1 Conceptos Básicos	127
4.5.2 Desarrollos Actuales y Aplicaciones	128
4.6 Sistemas Expertos (SE)	130
4.6.1 Conceptos Básicos	131
4.6.2 Clasificación	132
4.6.3 Desarrollos Actuales y Aplicaciones	130
5 REFERENCIAS BIBLIOGRÁFICAS	136
6 GLOSARIO	139



ÍNDICE DE FIGURAS.

1.1	Estructura de un Agente Inteligente	43
1.2	Diagrama esquemático de un agente reactivo simple	49
1.3	Diagrama esquemático de un agente basado en modelo	50
1.4	Diagrama esquemático de un agente basado en objetivos	51
1.5	Diagrama esquemático de un agente basado en utilidad	52
1.6	Diagrama esquemático de un agente que aprende	52
2.1	Paradigmas de la IAH	69
2.2	Mapa conceptual: mapas conceptuales	70
2.3	Red semántica general	73
2.4	Red semántica: Relaciones entre una familia	73
2.5	Red semántica: Ejemplo de vínculos	74
2.6	Árbol de decisión del problema	86
3.1	Evaluación de los hechos y reglas	95
3.2	Arquitectura de un SBR	98
4.1	Ejemplo de robots poliarticulados	109
4.2	Ejemplo de robots móviles	109
4.3	Ejemplo de robots zoomórficos	110
4.4	Ejemplo de robots zoomórficos	111
4.5	Ejemplo de robots colaborativos	112
4.6	Ejemplo de robots manipuladores móviles	113



4.7	Ejemplo de robots móviles autónomos	113
4.8	Ejemplo de flotas de robots	114
4.9	Estructura de una red neuronal artificial	116
4.10	Estructura de una red neuronal prealimentada	118
4.11	Estructura de una red neuronal recurrente	118
4.12	Red neuronal convolucional para el tratamiento de imágenes	119
4.13	Diferencia entre lógica clásica y difusa	125
4.14	Elementos del PLN	128
4.15	Elementos de un SE	131
4.16	Desarrollo actual de los SE	134



ÍNDICE DE TABLAS.

1.1	Definiciones de la IA, organizadas en cuatro categorías	3
1.2	Conectivas Lingüísticas	26
1.3	Tabla de verdad para la conectiva negación	26
1.4	Tabla de verdad para la conectiva conjunción	27
1.5	Tabla de verdad para la conectiva disyunción	27
1.6	Tabla de verdad para la conectiva implicación	27
1.7	Tabla de verdad para la conectiva implicación	28
1.8	Características del racionalismo y empirismo	37
1.9	Ejemplos de entornos y agentes inteligentes	47
1.10	Comparación algoritmos: exploración alternativa vs búsqueda exhaustiva	55
2.1	Tabla comparativa entre razonamiento monótono y no-monótono	80



INTRODUCCIÓN.

Con esta asignatura se da una Introducción a la Inteligencia Artificial (IA) presentando a los estudiantes, algunos de los métodos más utilizados en las diferentes áreas de la Inteligencia Artificial. Para ello, se introducen las técnicas más comunes de manipulación y representación del conocimiento y se analizan las características de las herramientas disponibles para la construcción de aplicaciones reales, en las diferentes áreas de la IA, con el fin de conformar una actitud científica, crítica y responsable del egresado.

Esta materia está situada como una de las últimas del plan de estudio, debido a que el alumno necesita tener de base el aprendizaje de otras materias que permitan que posea habilidades de estructuras de control, listas, arboles, recursividad, así como, conocimientos de teoría de la probabilidad, autómatas 1 y 2, programación lógica y funcional, programación en lenguajes de alto nivel, conocimientos de estructura y bases de datos.

Esta asignatura aporta al perfil del Ingeniero en Sistemas Computacionales las siguientes habilidades:

- Coordina y participa en equipos multidisciplinarios para la aplicación de soluciones innovadoras en diferentes contextos.
- Diseña, implementa y administra bases de datos optimizando los recursos disponibles, conforme a las normas vigentes de manejo y seguridad de la información.
- Desarrolla y administra software para apoyar la productividad y competitividad de las organizaciones cumpliendo con estándares de calidad.
- Evalúa tecnologías de hardware para soportar aplicaciones de manera efectiva.



PROPUESTA DE HORAS TEÓRICO-PRÁCTICA POR TEMA/SUBTEMA.

Tema / Subtema	Propuesta de horas teórico-práctica
1. Introducción a la Inteligencia Artificial.	8-8
1.1 Introducción a la Inteligencia Artificial	1-0
1.2 Historia de la Inteligencia Artificial	1-0
1.3 Las habilidades cognoscitivas según la psicología. Teorías de la inteligencia (conductismo, Gardner, etc.)	1-0
1.4 El proceso de razonamiento según la lógica (Axiomas, Teoremas, demostración)	1-0
1.5 El modelo de adquisición del conocimiento según la filosofía	1-0
1.6 El modelo cognoscitivo	1-0
1.7 El modelo del agente inteligente, Sistemas Multi Agentes, Sistemas Ubicuos	1-0
1.8 El papel de la heurística	1-8
1.8.1 Algoritmos de exploración de alternativas	
1.8.2 Algoritmo A*	
1.8.3 Algoritmos de búsqueda local	
2. Representación del Conocimiento, Razonamiento y los Aspectos Metodológicos en Inteligencia Artificial.	8-8
2.1 Principios y Metodología de la Inteligencia Artificial	1-0
2.2 Paradigmas de la Inteligencia Artificial	1-0
2.3 Mapas conceptuales	1-0
2.4 Redes semánticas	1-0
2.5 Razonamiento monótono	1-0
2.6 Conocimiento no- monótono y otras lógicas	1-3
2.7 Razonamiento probabilístico	1-2
2.8 Teorema de Bayes	1-3



3. Reglas y Búsqueda.	10-10
3.1 Representación de conocimiento mediante reglas	1-0
3.2 Métodos de Inferencia en reglas	1-0
3.3 Reglas de producción	1-0
3.4 Sintaxis de las reglas de producción.	1-0
3.5 Semántica de las reglas de producción	1-0
3.6 Arquitectura de un sistema de Producción (SP) o sistemas basados en reglas, (SBR)	2-3
3.6.1 Hechos.	
3.6.2 Base de conocimientos	
3.6.3 Mecanismo de control	
3.7 Espacios de estados determinísticos y espacios no determinísticos	1-2
3.8 Búsqueda sistemática	2-5
3.8.1 Búsqueda de metas a profundidad	
3.8.2 Búsqueda de metas en anchura	
4 Aplicaciones con Técnicas de IA.	6-6
4.1 Robótica	1-1
4.1.1 Conceptos básicos	
4.1.2 Clasificación	
4.1.3 Desarrollos actuales y aplicaciones	
4.2 Redes Neuronales (RN)	1-1
4.2.1 Conceptos básicos	
4.2.1 Clasificación	
4.2.3 Desarrollos actuales y aplicaciones	
4.3 Visión artificial	1-1
4.3.1 Conceptos básicos	
4.3.2 Desarrollos actuales y aplicaciones	
4.4 Lógica difusa (Fuzzy Logic)	1-1
4.4.1 Conceptos básicos	
4.4.2 Desarrollos actuales y aplicaciones	
4.5 Procesamiento de Lenguaje Natural (PLN)	1-1
4.5.1 Conceptos básicos	
4.5.2 Desarrollos actuales y aplicaciones	
4.6 Sistemas Expertos (SE)	1-1
4.6.1 Conceptos básicos	
4.6.2 Clasificación	
4.6.3 Desarrollos actuales y aplicaciones	



Tema I

INTRODUCCIÓN A LA INTELIGENCIA ARTIFICIAL.

Competencia Específica: Conocer los conceptos fundamentales de la Inteligencia Artificial, así como el estado del arte de las áreas de la inteligencia artificial.

INTRODUCCIÓN.

Este tema está orientado a la comprensión del origen de la Inteligencia Artificial, los diferentes enfoques y desarrollos creados bajo este concepto, así como el nacimiento del concepto de agente inteligente.





1. Introducción a la Inteligencia Artificial.

Objetivo General: Conocer los fundamentos de la Inteligencia Artificial.

La Inteligencia Artificial (IA) es un campo fascinante que abarca una variedad de temas y enfoques, desde la imitación del comportamiento humano hasta el desarrollo de sistemas autónomos inteligentes. En esta primera sección del temario, se proporciona una introducción integral a los fundamentos de la IA, explorando su historia, bases cognitivas, modelos de adquisición de conocimiento, modelos cognitivos y el papel de los agentes inteligentes. Además, se examina el proceso de razonamiento, incluyendo la lógica y la heurística, así como algoritmos específicos como A* y búsqueda local.

La historia de la Inteligencia Artificial ofrece una perspectiva sobre su evolución desde sus primeros conceptos hasta los avances contemporáneos. Se analizan las habilidades cognitivas según las teorías psicológicas, como el conductismo de Skinner y las teorías de la inteligencia múltiple de Gardner, que influyen en la comprensión de cómo los seres humanos procesan y aplican el conocimiento.

El proceso de razonamiento, basado en la lógica y la demostración de teoremas, proporciona un marco para comprender cómo la IA puede replicar el pensamiento humano. Por otro lado, el modelo de adquisición de conocimiento según la filosofía aborda cuestiones fundamentales sobre la naturaleza del conocimiento y cómo se incorpora a los sistemas inteligentes.

El papel de los agentes inteligentes, los sistemas multiagentes y los sistemas ubicuos resalta la importancia de la interacción y la adaptabilidad en la IA contemporánea. Además, se exploran conceptos clave como la heurística y diversos algoritmos que permiten a los sistemas realizar tareas de manera eficiente y efectiva.



1.1 Introducción a la Inteligencia Artificial (IA).

Existen distintas definiciones de IA de acuerdo a distintos enfoques; algunas de estas definiciones se enfocan a procesos mentales y al razonamiento, mientras que otras a la conducta.

Las definiciones que se presentan en la tabla 1.1 se clasifican de la siguiente manera, en la línea superior las definiciones se enfocan a los procesos mentales y razonamiento, la línea inferior a la conducta, así mismo en la columna izquierda se mide el éxito con base a la forma de actuar del ser humano mientras que la columna derecha se toma como referencia el concepto ideal de inteligencia que se denomina racionalidad (Un sistema es racional si hace lo “correcto”, en función de su conocimiento).

Tabla 1.1 Definiciones de la IA, organizadas en cuatro categorías

Sistemas que piensan como humanos	Sistemas que piensan racionalmente
“El nuevo y excitante esfuerzo de hacer que los computadores piensen...máquinas con mentes, en el más amplio sentido literal”. (Haugeland, 1985).	“El estudio de las facultades mentales mediante el uso de modelos computacionales”. (Charniak y McDermott, 1985).
“La automatización de actividades que vinculamos con procesos de pensamiento humano, actividades como la toma de decisiones, resolución de problemas, aprendizaje...”. (Bellman, 1978).	“El estudio de los cálculos que hacen posible percibir, razonar y actuar”. (Winston, 1992).
Sistemas que actúan como humanos	Sistemas que actúan racionalmente
“El arte de desarrollar máquinas con capacidad para realizar funciones que cuando son realizadas por personas requieren inteligencia”. (Kurzweil, 1990).	“La Inteligencia Computacional es el estudio del diseño de agentes inteligentes”. (Poole et al., 1998).
“El estudio de cómo lograr que los computadores realicen tareas que, por el momento, los humanos hacen mejor”. (Rich y Knight, 1991).	“IA... está relacionada con conductas inteligentes en artefactos”. (Nilsson, 1998)



1.1.1 Enfoques basados en el comportamiento humano.

Pensar como un humano: el enfoque del modelo cognitivo.

Se trata de un método de aprendizaje que consta de varias operaciones mentales que se basan en la experiencia y en el procesamiento de la información que hace el individuo a partir de esta, con el fin de asimilar un conocimiento y dar una respuesta. De esta manera, en la mente, se conectan las ideas ya existentes, es decir, lo que ya uno conoce, con la nueva información para profundizar en la memoria y la capacidad de retención.

El aprendizaje cognitivo no es un método de aprendizaje reciente, sino que se remonta hasta el año 1930, cuando el psicólogo suizo Jean Piaget estableció las bases de la teoría cognitivista, la cual ha ido evolucionando con aportaciones posteriores de otros psicólogos como Vygotsky, Jerome S. Bruner y David P. Ausubel.

Para poder decir que un programa computacional piensa como un humano, es necesario contar con un mecanismo para determinar cómo piensan los humanos. Es necesario penetrar en el funcionamiento de las mentes humanas. Hay dos formas de hacerlo:

1. Mediante introspección (intentando atrapar nuestros propios pensamientos conforme éstos van apareciendo). Una vez que se cuente con una teoría de lo suficientemente precisa sobre cómo trabaja la mente, se podrá expresar esa teoría en la forma de un programa de computación. Si los datos de entrada/salida del programa y los tiempos de reacción son similares a los de un humano existe la evidencia de que algunos de los mecanismos del programa se pueden comparar con los que utilizan los seres humanos. Por ejemplo, Allen Newell y Herbert Simon (1961), desarrollaron el Sistema de Resolución General de Problemas (SRGP), no les bastó con que su programa resolviera correctamente los problemas propuestos, lo que les interesaba era seguir la pista de las etapas de proceso de razonamiento y compararlas con las seguidas por humanos a los que se les enfrentó a los mismos problemas.
2. Mediante experimentos psicológicos. En el campo interdisciplinario de la ciencia cognitiva convergen modelos computacionales de IA y técnicas experimentales de



psicología intentando elaborar teorías precisas y verificables sobre el funcionamiento de la mente humana.

Comportamiento humano: El enfoque de la Prueba de Turing.

La Prueba de Turing, propuesta por Alan Turing (1950), fue diseñada para proveer una definición operacional satisfactoria de inteligencia. Una computadora pasa la Prueba de Turing de Turing si un interrogador humano, después de realizar preguntas escritas, no puede identificar si las respuestas escritas provienen de una persona o de un computador. Para pasar la Prueba de Turing, el computador necesitaría disponer de las siguientes capacidades:

- Procesamiento del Lenguaje Natural, para permitir una comunicación exitosa.
- Representación del Conocimiento, para almacenar que se sabe o escucha.
- Razonamiento Automático, para utilizar la información almacenada y responder a preguntas extrayendo nuevas conclusiones
- Aprendizaje Automático, para adaptarse a nuevas circunstancias, detectar y extrapolar patrones.

La Prueba de Turing evita deliberadamente la interacción física entre interrogador y el computador, porque las simulaciones de interacciones físicas de una persona son innecesarias para la inteligencia. Sin embargo, la llamada Prueba de Turing Global incluye señales de vídeo para que el interrogador pueda probar las habilidades perceptivas del interrogado. Para superar la Prueba de Turing Global, el computador necesitaría las siguientes nuevas capacidades:

- Visión Computacional, para percibir objetos.
- Robótica, para manipular objetos y moverlos.

Estas seis disciplinas componen la mayor parte de la Inteligencia Artificial, y Turing merece ser reconocido por diseñar una prueba que se conserva vigente después de tantos años.



1.1.2 Enfoques basados en el racionamiento.

Pensamiento racional: el enfoque de las leyes del pensamiento.

Aristóteles (filósofo griego) fue uno de los primeros en codificar el proceso de razonamiento, a través de patrones (llamados silogismos) que estructuran argumentos que llevan a conclusiones correctas, siempre que se tengan las suposiciones correctas. Ejemplo de silogismo: Sócrates es un hombre; todos los hombres son mortales; entonces, Sócrates es mortal.

Estas leyes del pensamiento supuestamente gobiernan la manera de operar de la mente; su estudio fue el inicio de un campo llamado lógica.

En el siglo XIX, los estudiosos de la lógica desarrollaron notaciones precisas para declarar los tipos de objetos en el mundo y sus relaciones entre ellos. Para 1965 ya existían programas computacionales que podían resolver, en principio, cualquier problema descrito en notación lógica.

Existen dos obstáculos con este enfoque:

1. No es sencillo tomar conocimiento informal y codificarlo en los términos formales que requiere la notación lógica, especialmente, cuando el conocimiento es ambiguo (entenderse o interpretarse de diversas maneras).
2. Existe una diferencia entre resolver un problema “en principio” y resolverlo “en la práctica”. Incluso problemas con sólo unos pocos de cientos de variables (o hechos) pueden ser exhaustivos en recursos computacionales y agotarlos, a menos que se tenga una guía sobre qué pasos se deben seguir en el razonamiento del problema.

Actuar de forma racional: el enfoque del agente racional.

Un agente es algo que hace algo (agente viene del latín agere, hacer). Un agente inteligente computacional opera automáticamente, están dotados de controles autónomos que perciben su entorno, tiene persistencia en tiempos prolongados, se adapta al cambio, y persigue objetivos.



Un agente racional es aquel que logra el mejor resultado, o cuando hay incertidumbre, el mejor resultado esperado. Un agente racional usa muchas veces la lógica (leyes del pensamiento) para basarse en inferencias y determinar las acciones correctas para lograr los objetivos. Pero la lógica no lo es todo, existen casos donde no se puede llegar a una conclusión basado en inferencias o hay decisiones que no tienen un racional basado en inferencias. Por ejemplo, el retirar la mano de una estufa caliente es un acto de reflejo mucho más eficiente que una respuesta lenta llevada a cabo tras una deliberación cuidadosa.

Todas las capacidades necesarias para pasar la Prueba de Turing permiten a un agente actuar de forma racional. Por lo tanto, es necesario contar con la capacidad para representar el conocimiento y razonar basándose en él, esto permitirá alcanzar decisiones correctas en una amplia gama de situaciones.

Este enfoque de Agente Racional tiene dos ventajas:

1. Es más general que el enfoque que proporcionan las leyes de pensamiento, ya que la lógica basada en inferencias es solo uno de los varios mecanismos posibles para lograr la racionalidad.
2. Es más susceptible al desarrollo científico que los enfoques basados en comportamiento o pensamiento humano, porque la norma de la racionalidad está claramente definida y es de aplicación general.

1.2 Historia de la Inteligencia Artificial.

En este punto se presenta una breve historia de las disciplinas (Filosofía, Matemáticas, Economía, Neurociencia, Psicología, Ingeniería Computacional, Teoría de Control y Cibernética, así como Lingüística) que han contribuido con ideas, puntos de vista y técnicas al desarrollo de la IA.



1.2.1 Filosofía (desde el año 428 a.C. hasta el presente).

Aristóteles (384-322 a.C.), fue el primero en formular un conjunto preciso de leyes que gobernaban la parte racional de la inteligencia. Desarrolló un sistema informal para razonar adecuadamente con silogismos (razonamiento deductivo o inductivo que está formado por dos premisas y una conclusión, es el resultado lógico que se deduce de las dos premisas), que en principio permitía extraer conclusiones mecánicamente, a partir de premisas iniciales.

Ramón Lull (d. 1315), tuvo la idea que el razonamiento útil se podría obtener por medio de medios artificiales.

Thomas Hobbes (1588-1679), propuso que el razonamiento era como como la computación numérica, los humanos suman y restan en sus pensamientos, esto dio inicio a la automatización de la computación.

Leonardo da Vinci (1452-1519), diseñó, no construyó, una calculadora mecánica.

Wilhelm Schickard (1592-1635), construyó en 1623 la primera calculadora conocida.

Blaise Pascal (1623-1662), construyó la calculadora más famosa, la pascalina, escribió que la “máquina aritmética produce efectos que parecen más similares a los pensamientos que a las acciones animales”.

Wilhelm Leibniz (1646-1716), construyó un dispositivo mecánico con el objetivo de llevar a cabo operaciones sobre conceptos en lugar de sobre números, pero su campo de acción era muy limitado.

Descartes (1596-1650), proporciona la primera discusión clara sobre la distinción entre la mente y la materia y los problemas que surgen, uno de los problemas es una concepción puramente física de la mente es que parece dejar poco margen de maniobra al libre albedrío, es decir, si el pensamiento está completamente gobernado por leyes físicas, entonces una piedra podría “decidir” caer en dirección al centro de la Tierra. Descartes fue defensor del **dualismo**, sostenía que una parte de la mente está al margen de la naturaleza, exenta de la influencia de las leyes físicas. Una alternativa al dualismo es el **materialismo**,



que considera que las operaciones del cerebro realizadas de acuerdo a las leyes de la física constituyen la mente.

Francis Bacon (1561-1626), inicio el movimiento empírico (basado en el pensamiento de Aristóteles), nada existe en la mente que no haya pasado antes por los sentidos.

David Hume (1711-1776), propuso lo que se conoce como principio de **inducción**: las reglas generales se obtienen mediante la exposición a asociaciones repetidas entre sus elementos.

Rudolf Carnap (1891-1970), lideró y desarrolló la doctrina del positivismo lógico, sostiene que todo el conocimiento se puede caracterizar mediante teorías lógicas relacionadas, en última instancia, con sentencias de observación que corresponden a estímulos sensoriales. La teoría de confirmación de Carnap y Carl Hempel (1905-1997) intenta explicar cómo el conocimiento se obtiene a partir de la experiencia. El libro de Carnap, *The Logical Structure of the World* (1928), define un procedimiento computacional explícito para la extracción de conocimiento a partir de experiencias primarias. Fue posiblemente la primera teoría en mostrar la mente como un proceso computacional.

1.2.2 Matemáticas (desde el año 800 al presente).

Los filósofos delimitaron las ideas más importantes de la IA, para pasar a una ciencia formal es necesario contar con una formulación matemática en tres áreas fundamentales: lógica, computación y probabilidad.

George Boole (1815-1864), definió la **lógica proposicional** o Booleana.

Gottlob Frege (1848-1925), extendió la lógica de Boole para incluir objetos y relaciones, creó la lógica de primer orden que se utiliza hoy como el sistema más básico de representación del conocimiento.

Alfred Tarski (1902-1983), introdujo una teoría de referencia que enseña como relacionar objetos de una lógica con objetos del mundo real. El paso siguiente consistió en definir los límites de lo que se podía hacer con la lógica y la matemática.



David Hilbert (1862-1943), presentó una lista de 23 problemas que acertadamente predijo ocuparían a los matemáticos durante todo ese siglo, en el último se preguntaba si existe un algoritmo que permita determinar la validez de cualquier proposición lógica en la que aparezcan números naturales (famoso problema de decisión o Entscheidungsproblem).

Kurt Gödel (1906-1978), demostró que existe un procedimiento eficiente para demostrar cualquier aseveración verdadera en la lógica de primer orden de Frege y Russell, sin embargo, con la lógica de primer orden no era posible capturar el principio de inducción matemática necesario para la caracterización de los números naturales. Mediante **su teorema de incompletitud** demostró que en cualquier lenguaje que tuviera la capacidad suficiente para expresar las propiedades de los números naturales, existen aseveraciones verdaderas no decidibles en el sentido de que no es posible decidir su validez mediante ningún algoritmo.

Alan Turing (1912-1954), demostró que existen algunas funciones que no se pueden calcular mediante la máquina de Turing, ninguna máquina puede decidir en general si un programa dado producirá una respuesta a partir de unas entradas, o si seguirá calculando indefinidamente.

Un problema al no ser decidible ni computable son importantes para comprender el problema de **intratabilidad**, se dice que un problema es intratable si el tiempo necesario para la resolución de casos particulares de dicho problema crece exponencialmente con el tamaño de dicho caso. La diferencia entre crecimiento polinomial y exponencial de la complejidad se destacó por primera vez a mediados de los años 60 (Cobham, 1964; Edmonds, 1965).

Steven Cook (1971) y **Richard Karp (1972)**, propusieron la teoría de la NP-Complejidad, demostraron la existencia de grandes clases de problemas de razonamiento y búsqueda combinatoria canónica que son NP completos.

Además de la lógica y el cálculo, la tercera gran contribución de las matemáticas a la IA es la teoría de la **probabilidad**. El italiano **Gerolamo Cardano (1501-1576)** fue el primero en proponer la idea de la probabilidad, presentándola en términos de los resultados de juegos de apuesta. La probabilidad se convirtió en parte imprescindible de las ciencias



cuantitativas, ayudando en el tratamiento de mediciones con incertidumbre y te teorías incompletas.

Thomas Bayes (1702-1761) propuso una regla para la actualización de probabilidades subjetivas a la luz de nuevas evidencias. La regla de Bayes y el área resultante llamado análisis Bayesiano conforman la base de las propuestas más modernas que abordan el razonamiento incierto en sistemas de IA.

1.2.3 Economía (desde el año 1776 hasta el presente).

La economía no se trata solo de dinero, los economistas estudian cómo la gente toma decisiones que les llevan a obtener los beneficios esperados.

Adam Smith (1723- 1790), fue el primero en tratar la economía como una ciencia, utilizando la idea de que las economías pueden concebirse como un conjunto de agentes individuales que intentan maximizar su propio estado de bienestar económico.

Léon Walras (1834-1910), formalizó el tratamiento matemático del beneficio deseado o utilidad, y fue posteriormente mejorado por Frank Ramsey (1931), John von Neumann y Oskar Morgenstern (1944).

La **teoría de decisión**, que combina la teoría de la probabilidad con la teoría de la utilidad, proporciona un marco completo y formal para la toma de decisiones (económicas o de otra índole) realizadas bajo incertidumbre, lo cual es adecuado para grandes economías, en las que cada agente no necesita prestar atención a las acciones que llevan a cabo el resto de los agentes individualmente. Cuando se trata de pequeñas economías, la situación se asemeja más a la de un juego, las acciones de un jugador pueden afectar significativamente a la utilidad de otro.

Los desarrollos de von Neumann y Morgenstern a partir de la **teoría de juegos**, mostraban el hecho que, en algunos juegos, un agente racional debía actuar en forma aleatoria o, al menos, aleatoria en apariencia con respecto a sus contrincantes.

El campo de la **investigación operativa** persigue el objetivo de como tomar decisiones racionales cuando los resultados de las acciones no son inmediatos y por el contrario se obtienen los resultados de las acciones en forma secuencial.



Richard Bellman (1957), formaliza una clase de problemas de decisión secuencial llamados procesos de decisión de Markov.

Herbert Simon(1916-2001), ganó el premio Nobel en Economía en 1978 por su trabajo, en el que mostró que los modelos basados en satisfacción (se toman decisiones que son suficientemente buenas en lugar de realizar cálculos laboriosos para alcanzar decisiones óptimas) proporcionaban una mejor descripción del comportamiento humano.

1.2.4 Neurociencia (desde el año 1861 hasta el presente).

La Neorociencia es el estudio del sistema neurológico, y en especial del cerebro. La forma exacta en la que en un cerebro se genera el pensamiento es uno de los grandes misterios de la ciencia. Se ha observado durante muchos años que el cerebro está de alguna manera involucrado en los procesos de pensamiento, ya que fuertes golpes en la cabeza pueden ocasionar minusvalía mental.

Paul Broca (1824-1880), mostró que la producción del habla se localizaba en una parte del hemisferio izquierdo; hoy en día conocida como el área de Broca.

Camillo Golgi(1843-1926), en esta época ya se sabía que el cerebro estaba formado por células nerviosas o neuronas, fue el 1873 que Golgi desarrolló una técnica de coloración que permitió la observación de neuronas individuales.

Santiago Ramón y Cajal (1852-1934), utilizó la técnica de Golgi en sus estudios pioneros sobre la estructura neuronal del cerebro.

Hans Berger (1929), desarrolló el electroencefalograma (EEG), el descubrimiento de las imágenes de resonancia magnética funcional (IRMf) proporcionó a los neurólogos imágenes detalladas de la actividad cerebral sin precedentes.

Cerebros y computadoras digitales realizan tareas bastante diferentes y tienen propiedades distintas, estudios mostraron que hay 1000 veces más neuronas en un cerebro humano medio que puertas lógicas en un procesador de una computadora estándar.



1.2.5 Psicología (desde el año 1879 hasta el presente).

Herman von Helmholtz (1821-1894), inició con sus estudios lo que se conoce como psicología científica, aplicó el método científico al estudio de la vista humana.

Wundt abrió el primer laboratorio de psicología experimental en la Universidad de Leipzig, realizó experimentos controlados en la que sus operarios realizaban tareas de percepción o asociación al tiempo que sometían a introspección sus procesos mentales.

William James (1842-1910), en sus obras se muestra la conceptualización del cerebro como un dispositivo de procesamiento de información, característica principal de la **psicología cognitiva**.

El campo de la ciencia cognitiva comenzó en un simposio celebrado en el MIT (Instituto Tecnológico de Massachusetts), en septiembre de 1956, en este simposio se presentaron los artículos The Magic Number Seven de George Miller, Noam Chomsky presentó Three Models of Language, Allen Newell y Herbert Simon presentaron The Logic Theory Machine, estos tres artículos influyentes mostraron cómo se podían utilizar los métodos informáticos para modelar la psicología de la memoria, el lenguaje y el pensamiento lógico.

1.2.6 Ingeniería Computacional (desde el año 1940 hasta el presente).

Para que la IA pueda llegar a ser una realidad se necesitan dos cosas: Inteligencia y un artefacto (computadora).

El equipo de **Alan Turing** construyó en 1940, el primer computador operacional de carácter electromecánico, llamada Heath Robinson. En 1943 desarrolló el Colossus, una máquina potente de propósito general basada en válvulas de vacío.

Konrad Zuse en 1941, construyó el primer computador operacional programable el Z-3.

John Atanasoff junto con su discípulo **Clifford Berry**, entre 1940 y 1942, crearon el primer computador electrónico el ABC.

John Mauchly y John Eckert construyeron el ENIAC (Electronic Numerical Integrator and Computer), se considera el precursor de las computadoras modernas.



Joseph Marie Jacquard (1752-1834), construyó la primera máquina programable que utilizaba tarjetas perforadas para el almacenamiento de la información.

1.2.7 Teoría de Control y cibernética (desde el año 1948 hasta el presente).

Ktesibios de Alejandría (250 a.C.) construyó la primera máquina auto controlada: un reloj de agua con un regulador que mantenía el flujo de agua circulando por él, con un ritmo constante y predecible.

Otros ejemplos de sistemas de control auto regulables y retroalimentados son el motor de vapor, creado por James **Watt (1736-1819)** y el termostato inventado por Cornelius **Drebbel (1572-1633)**, fue también el inventor del submarino.

La figura principal de la **teoría de control** fue **Norbert Wiener (1894-1964)**, trabajó en sistemas de control biológicos y mecánicos vinculados a la cognición, su libro *Cybernetics* (1948), fue un bestseller y rebeló al público las posibilidades de las máquinas con inteligencia artificial.

La teoría de control moderna, especialmente la rama conocida como control óptimo estocástico, tiene como objetivo el diseño de sistemas que maximizan una **función objetivo** en el tiempo, lo cual se asemeja ligeramente a nuestra visión de lo que es la IA; diseño de sistemas que se comportan de forma óptima.

La IA se fundó en parte para escapar de las limitaciones matemáticas de la teoría de control en los años 50. Las herramientas de inferencia lógica y computación permitieron a los investigadores de IA afrontar problema relacionados con el lenguaje, visión y planificación que estaban completamente fuera del punto de mira de la teoría de control.

1.2.8 Lingüística (desde el año 1957 hasta el presente).

B.F. Skinner, en 1957, publicó *Verbal Behavior*, la obra presentaba una visión extensa y detallada desde el enfoque conductista al aprendizaje del lenguaje.

Noam Chomsky, desarrolló la teoría de Chomsky, demostró que la teoría conductista no abordaba el tema de la creatividad en el lenguaje, no explicaba cómo es posible que un niño sea capaz de entender y construir oraciones que nunca antes ha escuchado, en su teoría si



podía explicar lo anterior y a diferencia de las teorías anteriores poseía el formalismo suficiente para permitir su programación.

La Lingüística moderna y la IA, nacieron, al mismo tiempo y maduraron juntas, en un campo híbrido llamado **lingüística computacional o procesamiento del lenguaje natural**.

1.3 Las habilidades cognoscitivas según la psicología. Teorías de la inteligencia (Conductismo, Gardner, etc.).

1.3.1 Habilidades cognoscitivas según la psicología.

Habilidad: Capacidad de una persona para hacer algo correctamente y con facilidad.

Cognoscitivo: Proceso por el cual una persona, a través de la percepción de sus sentidos, capta información integrándola, interpretándola hasta construir conocimiento.

Cognitivo: Es aquello que pertenece o está relacionado al conocimiento, toda la información que se dispone gracias a un proceso de aprendizaje.

Las habilidades cognitivas son aquellas facultades mentales del ser humano relacionadas a comprender el mundo que los rodea y a procesar los **estímulos** que recogen los sentidos de la vista, olfato, tacto, gusto y oído. Según muchos expertos, el conjunto de todas las habilidades cognitivas conforma la inteligencia o capacidad intelectual.

Estas habilidades se utilizan continuamente, sin ser conscientes, y son necesarias para: aprender, prestar atención, memorizar, hablar, leer, razonar, comprender, resolver problemas, establecer relaciones, formular generalizaciones.

El pensamiento humano es el resultado de una serie compleja y abstracta de procesos, que van desde la captación de determinados **estímulos**, su **interpretación**, su **almacenamiento** en la memoria y su traducción a un sistema de valores y conceptos del cual posteriormente emergerá una respuesta.

Las habilidades cognitivas tienen mucho que ver con las nociones de **inteligencia**, de **aprendizaje** y de **experiencia**, gracias a las cuales un individuo puede crecer



cognitivamente y aprender a desempeñar tareas complejas o a prever situaciones futuras en relación con lo vivido.

Así, este tipo de habilidades se corresponde con un conjunto de capacidades intelectuales concretas, que una persona emplea más o menos a lo largo de las diferentes situaciones de su vida, tales como:

- **Previsión.** La capacidad de evaluar las consecuencias o implicaciones de una acción antes de realizarla, pudiendo así desistir de ella si dichas consecuencias fueran inconvenientes o, acaso, atajarlas al haberlas visto venir de antemano. Esta capacidad es clave para la supervivencia del individuo y para su integración en la sociedad.
- **Planificación.** La capacidad de prever a futuro una serie de consecuencias a partir de las acciones emprendidas y por ende trazarse metas y objetivos que se deriven de dichas acciones. Es la capacidad de elegir las consecuencias y de alcanzar propósitos futuros.
- **Evaluación.** La capacidad de juzgar individualmente la conveniencia o el peligro de una acción, o de saber qué tan cerca se está o no de la meta deseada, en fin, de tener consciencia sobre dónde se está y corregir la conducta para llegar al punto deseado o evitar el indeseado.
- **Innovación.** La capacidad de encontrar alternativas o nuevos caminos hacia las metas deseadas, a partir de experiencias pasadas y memorizadas, tomando en consideración la comprensión del mundo que se posee. Esta capacidad es clave, también, para la evolución del pensamiento abstracto y evitar la repetición de fórmulas previas, por exitosas hayan sido.

Tipos de habilidades cognitivas.

En líneas generales se habla de dos tipos de capacidades cognitivas:

1. **Habilidades cognitivas.** Permiten la elaboración del conocimiento, operando directamente sobre la información recabada por los sentidos. Suelen consistir en las siguientes habilidades:
 - **Atención.** Capacidad de captación de detalles y de concentración o foco.
 - **Comprensión.** Capacidad de traducción de lo captado a un lenguaje propio, elaboración interior de lo percibido, clasificación de la realidad, etc.
 - **Elaboración.** Formación de un pensamiento propio como respuesta a lo percibido, es decir, formulación de una respuesta.



- **Recuperación.** Memorización de lo vivido para que sirva de fundamento a futuras experiencias idénticas o similares, pudiendo recuperar lo aprendido incluso sin hallarse en presencia del estímulo en cuestión.
2. **Habilidades metacognitivas.** Aquellas que tienen como objeto no la realidad percibida, sino los **propios procesos cognitivos**, permitiendo así la capacidad de pensar sobre el modo en que se piensa, por decirlo de alguna manera. Así, estas habilidades permiten el control, la explicación y transmisión de conocimiento vivido, así como la formulación de un lenguaje útil para ello y de otros sistemas complejos de representación de las ideas.

Metacognición de la memoria: el conocimiento de la capacidad de la memoria para relacionar y contrastar conocimientos ya almacenados con nuevos conocimientos.

Metacognición de la atención: conocer la capacidad de focalizar la atención en una tarea o situación determinada. Ser conscientes de los factores que dificultan el mantenimiento de la atención ayudan a optimizar esta capacidad.

Metacognición de la comprensión: ser conscientes de la capacidad para comprender uno o varios conceptos y utilizarlos. La comprensión nos permite aprender a aprender.

Metacognición de pensamiento: el conocimiento que tenemos de nuestro propio pensamiento. Esta capacidad nos permite reflexionar sobre cómo y qué pensamos

1.3.2 Teorías de la inteligencia (Conductismo, Gardner, etc.).

1.3.2.1 Conductismo.

El conductismo es una corriente de la psicología que se basa en la observación del comportamiento o conducta del ser que se estudia (humano y animal) y que explica el mismo como un conjunto de relaciones entre estímulos y repuestas. El conductismo es una de las teorías del aprendizaje que se ha mantenido durante más años y de mayor tradición. Aunque no encaja totalmente en los nuevos paradigmas educativos por concebir el aprendizaje como algo mecánico, deshumano y reduccionista, la realidad es que muchos programas actuales se basan en las propuestas conductistas como la descomposición de la



información en unidades, el diseño de actividades que requieren una respuesta y la planificación del refuerzo.

La escuela conductista sugirió que la psicología debería enfocarse solo a aquel comportamiento que fuera observable. En lugar de centrarse en lo que sucede dentro de nuestra mente, el conductismo creía que la psicología y sus investigaciones debían centrarse en las influencias ambientales que causan nuestros comportamientos.

Esta psicología conductual sugiere que el aprendizaje y la conducta son principalmente el resultado de las asociaciones de estímulo y respuesta. Los comportamientos, según la psicología conductista, pueden ser explicados observando estas asociaciones aprendidas en lugar de enfocarse en sucesos internos dentro de la mente humana.

Nacimiento del Conductismo.

El conductismo se estableció como teoría cuando John B. Watson publicó en 1913 el artículo “La psicología como la ve el conductista” en él, este psicólogo expresaba lo siguiente.

"Dame una docena de bebés sanos, bien formados y mi propio mundo específico para criarlos y te garantizo que tomaré a cualquiera al azar y lo entrenaré para que se convierta en cualquier tipo de especialista que pueda seleccionar: médico, abogado, artista, comerciante-jefe y, sí, incluso mendigo y ladrón, independientemente de sus talentos, inclinaciones, tendencias, habilidades, vocaciones y raza de sus antepasados".

John B. Watson, psicólogo

El modelo conductista más estricto, se tenía la creencia de que todos los comportamientos se debían al resultado de una experiencia. Es decir, cualquier persona, independientemente de su genética, podía ser entrenada para actuar de una manera particular con el condicionamiento adecuado.



Tipos de conductismo.

Dentro de la psicología conductista existen dos tipos de condicionamiento, el clásico y el operante.

1. **Condicionamiento clásico:** Se define como una técnica que usa el entrenamiento conductual a través de un estímulo neutro que se empareja con un estímulo natural. Al final, se consigue evocar la misma respuesta ante un estímulo que ocurre naturalmente.
2. **Condicionamiento operante:** A través del operante, las personas establecen una asociación entre un comportamiento y la consecuencia ante ese comportamiento. Según estas teorías conductistas, cuando un resultado deseable sigue a una acción, es más probable que un comportamiento vuelva a ocurrir en el futuro. En cambio, cuando las respuestas van seguidas de resultados adversos, estas tienen menos probabilidades de volver a ocurrir.

Teorías conductistas.

Dentro del modelo conductista existen diferentes visiones del conductismo y su psicología. Entre las más destacadas se encuentran:

- **Watson y el conductismo metodológico:** El psicólogo John B. Watson fue el primero en defender los métodos objetivos del conductismo para el estudio de la psicología. En muchos casos, Watson es conocido como el padre del conductismo, pero en realidad no fue el primero en apostar por las teorías conductistas.
El tipo de conductismo defendido por Watson, se denomina conductismo metodológico y se fundamenta en que toda investigación psicológica debe basarse en la observación y en la experimentación de la conducta. Watson afirmó que para ser verdaderamente científica la Psicología debía centrarse en la conducta manifiesta en lugar de en los estados mentales y conceptos como “conciencia” o “mente”, que no podían ser analizados de forma objetiva.
En un conocido y controvertido experimento Watson y su ayudante Rosalie Rayner consiguieron provocar una fobia a las ratas a un bebé de nueve meses (“el pequeño



Albert”). Para ello emparejaron la presencia de la rata con sonidos fuertes. El caso del pequeño Albert demostró que la conducta humana no sólo es predecible sino también modificable.

- **Skinner y el conductismo radical:** Después de las teorías de Watson, uno de los autores conductistas más conocidos fue Burrhus Frederic Skinner. La teoría conductista de Skinner establecía que los comportamientos observables eran manifestaciones externas de procesos mentales invisibles, pero aun así era más recomendable estudiar los comportamientos que si se podían observar.

Skinner introdujo los conceptos de **refuerzo positivo y negativo**. Se denomina refuerzo positivo al hecho de premiar una conducta dando algo, mientras que el refuerzo negativo consiste en la retirada o la evitación de un evento desagradable. En ambos casos, la intención es la de aumentar la frecuencia e intensidad de aparición de una conducta determinada.

Skinner defendía el conductismo radical, que mantiene que todo el comportamiento es resultado de asociaciones aprendidas entre estímulos y respuestas. El enfoque teórico y metodológico desarrollado por Skinner se conoce como análisis experimental de la conducta y ha sido especialmente eficaz en la educación de niños con discapacidad intelectual y del desarrollo.

- **Thorndike y la ley del efecto:** Edward Thorndike introdujo el principio psicológico conocido como la ley del efecto. De acuerdo con esta teoría conductista, es más probable que las respuestas que producen satisfacción vuelvan a ocurrir en un futuro. En cambio, aquellas respuestas que producían efectos indeseables eran menos probables de que ocurrieran en el futuro.

Thorndike realizó diversos experimentos con animales para estudiar el aprendizaje. Introdujo gatos en “cajas-problema” para observar si conseguían escapar de ellas y de qué modo. En las cajas había varios elementos con los que los gatos podían interactuar, como un botón o una anilla, y sólo el contacto con uno de estos objetos podía hacer que se abriera la puerta de la caja. Al principio los gatos conseguían salir de la caja por ensayo y error, pero a medida que se repetían los intentos cada vez escapaban con más facilidad.



A partir de estos resultados Thorndike formuló la ley del efecto, que afirma que si una conducta tiene un resultado satisfactorio es más probable que se repita, y que si el resultado es insatisfactorio esta probabilidad disminuye. Posteriormente formularía la ley del ejercicio, según la cual los aprendizajes y hábitos que se repiten se ven reforzados y los que no se repiten se debilitan. Los estudios y las obras de Thorndike introdujeron el condicionamiento instrumental. Según este modelo el aprendizaje es consecuencia del reforzamiento o el debilitamiento de la asociación entre una conducta y sus consecuencias.

- **Hull y la teoría del impulso:** Según la teoría conductista del psicólogo Clark Hull, la privación crea necesidades e impulsos que conducen a un comportamiento. Como este comportamiento está orientado a los objetivos, este tipo de acciones son muy importantes para nuestra supervivencia.

1.3.2.2 La Teoría de las Inteligencias Múltiples de Gardner.

La Teoría de las Inteligencias Múltiples fue ideada por el psicólogo estadounidense Howard Gardner como contrapeso al paradigma de una inteligencia única. Gardner propuso que la vida humana requiere del desarrollo de varios tipos de inteligencia, y que cada uno de los cuales engloba una serie de habilidades que, a pesar de involucrar la capacidad de pensamiento abstracto, van más allá de lo que convencionalmente se entiende por "ser listo" o "ser ágil mentalmente" y a pesar de eso son útiles al ayudarnos a afrontar los desafíos siempre cambiantes e imprevisibles a los que nos expone la vida. Gardner no entra en contradicción con la definición científica de la inteligencia, como la "capacidad de solucionar problemas o elaborar bienes valiosos", pero a la vez la replantea de una manera radical y, por qué no decirlo, también polémica. Esto es lo que hace de la Teoría de las Inteligencias Múltiples algo tan interesante.

Más de un tipo de inteligencia.

Para comprender el modo en el que Howard Gardner desarrolla su teoría, lo primero que hay que hacer es conocer la intención inicial de la que parte: poner en duda el concepto de "inteligencia" como un rasgo psicológico homogéneo y unitario. Hay que tener en cuenta



que lo que hasta entonces se entendía como inteligencia estaba íntimamente ligado a lo que se conoce como cociente intelectual (CI), el cual es el resultado ofrecido por la aplicación de tests de inteligencia.

Estos tests, a su vez, han sido desarrollados y perfeccionados durante décadas poniendo énfasis en la necesidad de obtener medidas objetivas de la capacidad intelectual de las personas incluso desde su infancia. Sin embargo, esta medición no está libre de sesgos: ha sido diseñada para adaptarse a las necesidades de la sociedad occidental moderna, caracterizada por una suerte especialización y división del trabajo y por el hecho de dar mucho valor a la capacidad de expresarse verbalmente y de dominar las matemáticas y el razonamiento lógico.

Cuando Gardner publicó su primer libro sobre este tema en el año 1983, el famoso *Frames of Mind: The Theory of Multiple Intelligences*, lo hizo para defender la idea de que la inteligencia no tiene por qué ser una unidad; puede ser entendida como varias habilidades de procesamiento de la información que funcionan de manera paralela e independiente las unas de las otras. Eso significaría que alguien que según los tests de inteligencia tiene un bajo CI, puede ser muy inteligente en otros ámbitos que no son tenidos en cuenta por este tipo de herramientas de psicometría.

En este sentido, Gardner se inspiraba en las teorías de construccionismo social para decir que lo que suele ser llamado "inteligencia" está construido socialmente, y eso significa que no tiene por qué ser un elemento psicológico natural (es decir, no tiene por qué ser algo que existe independientemente de los fenómenos históricos y culturales que influyen en nuestra manera de medir las facultades mentales).

Teoría de las Inteligencias Múltiples.

La historia de la teoría de las Inteligencias Múltiples empieza a finales de los años 70, cuando Howard Gardner y sus colaboradores de la prestigiosa Universidad de Harvard advirtieron que la inteligencia académica (la obtención de titulaciones y méritos educativos; el expediente académico) no es un factor decisivo para conocer la inteligencia de una persona. Desde su punto de vista, era necesario desarrollar un concepto de "inteligencia" más abierto y plural del que se solía utilizar hasta ese momento.



Un buen ejemplo de esta idea se observa en personas que, a pesar de obtener excelentes calificaciones académicas, presentan problemas importantes para relacionarse con otras personas o para manejar otras facetas de su vida. Gardner y sus colaboradores podrían afirmar que Stephen Hawking no posee una mayor inteligencia que Leo Messi, sino que cada uno de ellos ha desarrollado un tipo de inteligencia diferente.

Por otro lado, Howard Gardner señala que existen casos claros en los que personas presentan unas habilidades cognitivas extremadamente desarrolladas, y otras muy poco desarrolladas: es el caso de los savants (El síndrome de savant o síndrome del sabio es una patología extraña en la que las personas con discapacidad en su desarrollo, lesiones o enfermedades cerebrales presentan «islas» espectaculares de habilidad o habilidades de forma extraordinaria, creando una discordancia entre la discapacidad y la «superhabilidad»). Un ejemplo de savant fue Kim Peek, que a pesar de que en general tenía poca habilidad para razonar, era capaz de memorizar mapas y libros enteros, en prácticamente todos sus detalles.

Estos casos excepcionales hicieron que Gardner pensase que la inteligencia no existe, sino que en realidad hay muchas inteligencias independientes.

La investigación de Howard Gardner ha logrado identificar y definir hasta ocho tipos de inteligencia distintas. A continuación, se explicará cada una de las inteligencias propuestas por la Teoría de las Inteligencias Múltiples de Gardner.

- **Musical.** Ayuda a la percepción de la información mediante el oído y el sentido del ritmo. Facilita el aprendizaje de los instrumentos musicales, el canto y la composición de melodías.
- **Verbal.** Ayuda a absorber la información textual y a aprender idiomas. Quienes mejor dominan esta capacidad de comunicar tienen una inteligencia lingüística superior. Profesiones en las cuales destaca este tipo de inteligencia podrían ser políticos, escritores, poetas, periodistas, actores.



- **Interpersonal.** Le permite trabajar eficazmente en equipo y establecer fuertes vínculos sociales. Un tipo desarrollado de este intelecto indica un alto nivel de empatía. Es una inteligencia muy valiosa para las personas que trabajan con grupos numerosos. Su habilidad para detectar y entender las circunstancias y problemas de los demás resulta más sencillo si se posee (y se desarrolla) la inteligencia interpersonal. Profesores, psicólogos, terapeutas, abogados y pedagogos son perfiles que suelen puntuar muy alto en este tipo de inteligencia.
- **Cuerpo-Cinético.** Influye en el tacto y la coordinación. Las personas dominadas por este tipo, según Gardner, necesitan el entorno, el contacto táctil y pausas para moverse libremente. Son especialmente brillantes en este tipo de inteligencia bailarines, actores, deportistas, y hasta cirujanos y creadores plásticos, pues todos ellos tienen que emplear de manera racional sus habilidades físicas.
- **Visual-Espacial.** Responsable de la imaginación y la capacidad de navegar en el espacio. Esta inteligencia ayuda a recordar fácilmente las imágenes, por lo que a estas personas les gusta recibir la información en formato de imagen. Las personas que destacan en este tipo de inteligencia suelen tener capacidades que les permiten idear imágenes mentales, dibujar y detectar detalles, además de un sentido personal por la estética. En esta inteligencia se encuentran pintores, fotógrafos, diseñadores, publicistas, arquitectos, creativos.
- **Lógica y Matemática.** Analiza fácilmente la información y procesa los datos presentados en gráficos, tablas y cuadros. Los científicos, economistas, académicos, ingenieros y matemáticos suelen destacar en esta clase de inteligencia. Asimismo, los ajedrecistas también requieren de capacidad lógica para desarrollar estrategias de juego mejores a las de su oponente, y a su vez anticipar sus movimientos.
- **Intrapersonal.** Responsable de analizar los propios sentimientos, emociones y acciones. Según Gardner, no es raro que las personas con predominio de este intelecto sean introvertidas y se sientan cómodas trabajando y estudiando en reclusión. El psicólogo también cree que la creación de proyectos individuales y la redacción de ensayos reflexivos ayudan a desarrollar el intelecto intrapersonal.



- **Naturalista.** Responsable de la capacidad de estudiar y comprender la naturaleza, el medio ambiente. Esta inteligencia, según el autor de la teoría, se potencia con la investigación y la experimentación.

Gardner afirma que todas las personas son dueñas de cada una de las ocho clases de inteligencia, aunque cada cual destaca más en unas que en otras, no siendo ninguna de las ocho más importantes o valiosas que las demás. Generalmente, se requiere dominar gran parte de ellas para enfrentarnos a la vida, independientemente de la profesión que se ejerza.

A fin de cuentas, la mayoría de trabajos precisan del uso de la mayoría de tipos de inteligencia.

La educación que se enseña en las aulas se empeña en ofrecer contenidos y procedimientos enfocados a evaluar los dos primeros tipos de inteligencia: verbal y lógico-matemática. No obstante, esto resulta totalmente insuficiente en el proyecto de educar a los alumnos en plenitud de sus potencialidades. La necesidad de un cambio en el paradigma educativo fue llevado a debate gracias a la Teoría de las Inteligencias Múltiples que propuso Howard Gardner.

1.4 El proceso de razonamiento según la lógica (Axiomas, Teoremas, Demostración).

Razonar es la actividad mental que permite lograr la estructuración y la organización de las ideas para llegar a una conclusión. Cuando una persona razona, desarrolla un razonamiento.

La lógica, por su parte, es la ciencia dedicada a la exposición de las formas, los métodos y los principios del conocimiento científico. Algo lógico, en este sentido, es aquello que respeta estas reglas y cuyas consecuencias resultan justificadas, válidas o naturales.

Al realizar razonamientos se emplean sentencias que están conectadas entre sí por conectivas lingüísticas. La lógica proposicional se ocupa del estudio de las conectivas lingüísticas entre proposiciones. Una proposición es una sentencia que puede ser verdadera (*V*) o falsa (*F*). El principal interés en relación con la lógica proposicional es dejar establecido el papel que juegan las conectivas lingüísticas y sus conectivos lógicos asociados en relación con los conceptos de verdad y demostración.



Las conectivas lingüísticas permiten construir proposiciones compuestas a partir de otras más simples. Así, si los símbolos p y q representan proposiciones genéricas, las conectivas lingüísticas más empleadas son las que aparecen en la tabla 1.2.

Tabla 1.2 Conectivas Lingüísticas.

Conectiva Lingüística	Conectiva Lógica	Símbolo	Se escribe
no p	Negación	$\neg$	$\neg p$
p y q	Conjunción	$\wedge$	$p \wedge q$
p o q	Disyunción	$\vee$	$p \vee q$
Si p entonces q	Implicación	$\rightarrow$	$p \rightarrow q$
p si y solo si q	Equivalencia	$\leftrightarrow$	$p \leftrightarrow q$

Negación.

El significado de la conectiva lógica negación, reside en que la proposición $\neg p$ es verdadera en el caso de que p sea falsa y recíprocamente que $\neg p$ es falsa cuando p es verdadera. En la tabla 1.3, se presenta la tabla de verdad de la conectiva lógica de negación.

Tabla 1.3 Tabla de verdad para la conectiva negación.

p	$\neg p$
v	f
f	v

Conjunción.

La sentencia es verdadera sólo cuando p y q son verdaderas simultáneamente. La tabla de verdad correspondiente a esta conectiva se presenta en la tabla 1.4.



Tabla 1.4 Tabla de verdad para la conectiva conjunción.

p	p	$p \wedge q$
v	v	v
v	f	f
f	v	f
f	f	f

Disyunción.

Para que la sentencia sea verdadera basta que una de sus premisas (p,q) o ambas lo sean.

La tabla de verdad correspondiente a esta conectiva se presenta en la tabla 1.5.

Tabla 1.5 Tabla de verdad para la conectiva disyunción.

p	p	$p \vee q$
v	v	v
v	f	v
f	v	v
f	f	v

Implicación.

La sentencia es falsa, cuando q es falsa, en los demás casos la sentencia es verdadera. La tabla de verdad correspondiente a esta conectiva se presenta en la tabla 1.6.

Tabla 1.6 Tabla de verdad para la conectiva implicación.

p	p	$p \rightarrow q$
v	v	v
v	f	f
f	v	v
f	f	v



Equivalencia.

La sentencia es verdadera, cuando p y q tienen el mismo valor. La tabla de verdad correspondiente a esta conectiva se presenta en la tabla 1.7.

Tabla 1.7 Tabla de verdad para la conectiva implicación.

p	p	$p \leftrightarrow q$
v	v	v
v	f	f
f	v	f
f	f	v

Axioma.

En el mundo del saber y del conocimiento, se conoce como axioma a cualquier proposición o premisa que se considera autoevidente, es decir, obvia, fácilmente demostrables, y que sirve de fundamento para un cuerpo de teorías y razonamientos deductivos, ejemplo: es martes, los martes tengo clases de IA.

Teorema.

Un teorema es un enunciado que puede ser demostrado como verdadero mediante operaciones matemáticas y argumentos lógicos. En matemática, un teorema es una proposición teórica, enunciado o fórmula que incorpora una verdad, axioma o postulado que es comprobada por otros conjuntos de teorías o fórmulas. Un teorema también es una regla o ley que se expresa en forma de ecuaciones y / o fórmulas matemáticas.

En lógica, un teorema es una proposición deducida por premisas y asimilaciones de un sistema siendo ideas o creencias generalmente aceptadas como verdaderas, ejemplo: el teorema de Pitágoras.

La diferencia entre un teorema y un axioma o postulado es que el primero es una verdad comprobable en cambio un axioma es una verdad que se asume como tal pero que no ha sido comprobada. Axioma es un concepto más antiguo y sinónimo del concepto moderno postulado.



Demostración.

En el lenguaje de la lógica el proceso demostrativo consiste básicamente en que, a partir de unas proposiciones dadas que llamadas premisas o hipótesis, se obtiene otra proposición que se llamará conclusión o tesis, mediante la aplicación de unas reglas lógicas.

Las reglas lógicas que validan el proceso demostrativo se denominan reglas de validez y se reducen a las siguientes:

- Regla de validez 1: Los axiomas pueden figurar en cualquier paso de una demostración, cuando se necesiten. Igualmente ocurre con los teoremas ya probados.
- Regla de validez 2: Si en una demostración figura $P \rightarrow Q$ y en la misma demostración también figura P , entonces, en dicha demostración también se puede concluir Q . Esta regla universal se conoce con el nombre del Modus Ponendo Pones ó Modus Ponens.
- Regla de validez 3: Si dos proposiciones son equivalentes, se puede sustituir la una por la otra en cualquier parte de una demostración. Esta regla se conoce con el nombre de sustitución por equivalencia.

Para probar que una proposición determinada (conclusión) se deduce (demuestra) a partir de las premisas dadas, se aplican reiteradamente las tres reglas señaladas, partiendo de las premisas y generando nuevas proposiciones, el número de veces necesario hasta obtener la conclusión.

Un **razonamiento lógico**, en definitiva, es un proceso mental que implica la aplicación de la lógica. Mediante esta clase de razonamiento, se puede partir de **una o de varias premisas** para arribar a una **conclusión** que puede determinarse como **verdadera, falsa o posible**.

El razonamiento lógico se puede iniciar con una **observación** (es decir, una experiencia) o una hipótesis. El proceso **mental** de análisis puede **desarrollarse** de distintas maneras y convertirse en un razonamiento **inductivo**, un razonamiento **deductivo**, etc. Según la clase



de razonamiento empleada, la conclusión tendrá mayor o menor posibilidad de resultar válida.

La **conclusión** encuentra su base en las **premisas** iniciales: el razonamiento lógico es el camino que vincula ambas partes. El resultado del razonamiento tendrá un cierto grado de probabilidad en cuanto a su veracidad, siempre que los razonamientos lógicos sean válidos.

Razonamiento Deductivo.

El razonamiento **deductivo**, es lo que proviene de la deducción (el método lógico que lleva desde lo general o universal hasta lo particular).

Se conoce como **razonamiento deductivo**, por lo tanto, a la actividad de la mente que permite inferir necesariamente una conclusión a partir de una serie de premisas. Esto quiere decir que, partiendo de lo general, se llega a lo particular.

Para comprender el concepto de razonamiento deductivo, se deben tener presentes los siguientes conceptos:

- **Argumento:** se trata de una razón o prueba que permite efectuar la justificación o la refutación de algo, para afirmar que es verdadero o falso. En otras palabras, es un discurso que tiene un objetivo muy claro, y permite expresar un razonamiento de manera oral o escrita.
- **Proposición:** tanto en lógica como en filosofía, es cada una de las entidades que portan los valores de verdad (o sea que indican en qué grado una declaración es verdadera; para la lógica clásica bivalente, solamente se puede hablar de «verdadero» o «falso»).
- **Premisa:** la lógica define este concepto como cualquier proposición que se encuentre antes de la conclusión. Cabe señalar que, si el argumento es válido, entonces el conjunto de premisas implica la conclusión, aunque esto no hace que una proposición sea o no una premisa, sino que es su puesto en el argumento lo que cuenta.



- **Conclusión:** desde el punto de vista de la lógica, es una proposición que se encuentra en la última parte de un argumento, después de las premisas. Del mismo modo que la premisa, para que una proposición reciba el rol de conclusión no importa si el argumento es válido, sino que basta con que ésta se encuentre en último lugar.
- **Axioma:** se trata de una proposición que se toma como evidente, para la cual no se exige una demostración previa.
- **Reglas de inferencia:** también conocidas como reglas de transformación, son formas lógicas o funciones que toman premisas para analizar su sintaxis y arrojar una o más conclusiones.

Con base a lo anterior, se observa la definición **formal** de razonamiento deductivo: se trata de una secuencia de fórmulas bien definidas, entre las cuales se designa la última como la conclusión de todo el argumento y el resto pueden ser axiomas o premisas, o también inferencias directas que partan de reglas de inferencia.

Tipos de razonamiento deductivo.

Una vez definido el concepto de razonamiento deductivo, es importante mencionar que existen varios tipos de razonamiento deductivo, entre ellos silogismo, modus ponens, modus tollens, silogismo hipotético y silogismo disyuntivo. Cada uno de estos tipos de razonamiento tiene una estructura única y sirve a un propósito específico en el razonamiento lógico.

Silogismo.

En el razonamiento deductivo, un silogismo consta de una conclusión y dos premisas. La conclusión se extrae de las dos premisas. Por ejemplo:

Premisa 1: Todos los seres humanos son mortales.

Premisa 2: Sócrates es humano.

Conclusión: Por lo tanto, Sócrates es mortal.



Silogismo hipotético.

Un silogismo hipotético es un argumento lógico que consta de dos enunciados condicionales y un enunciado condicional para la conclusión. Por ejemplo:

Premisa 1: Si llueve, el suelo estará mojado.

Premisa 2: Si el suelo está mojado, la hierba estará resbaladiza.

Conclusión: Por lo tanto, si llueve, la hierba estará resbaladiza.

Silogismo disyuntivo.

El silogismo disyuntivo es un argumento deductivo que consiste en una afirmación disyuntiva y la negación de uno de los disyuntos. La conclusión es la afirmación del otro disyunto. Por ejemplo:

Premisa 1: o hace sol o llueve.

Premisa 2: No llueve.

Conclusión: Por lo tanto, es soleado.

Modus Ponens.

El modus ponens es una forma de razonamiento deductivo en el que se afirma el antecedente de un enunciado condicional y después se afirma el consecuente. Por ejemplo:

Premisa 1: Si llueve, las calles están mojadas.

Premisa 2: Está lloviendo.

Conclusión: Por lo tanto, las calles están mojadas.

Modus Tollens.

El modus tollens es una forma de razonamiento deductivo en el que primero se niega el antecedente y luego se refuta el consecuente de una afirmación condicional. Por ejemplo:

Premisa 1: Si llueve, las calles están mojadas.



Premisa 2: Las calles no están mojadas.

Conclusión: Por lo tanto, no llueve.

1.5 El modelo de adquisición del conocimiento según la filosofía.

Según la RAE (Real Academia Española),

Conocimiento, acción y efecto de conocer. Entendimiento, inteligencia, razón natural. Noción, saber o noticia elemental de algo.

La filosofía, es el conjunto de saberes que busca establecer, de manera racional, los principios más generales que organizan y orientan el conocimiento de la realidad, así como el sentido del obrar humano.

Concepto de Filosofía según los principales Filósofos.

Pitágoras de Samos (582-500 a.C.): “La filosofía es un afán de saber libre y desinteresado”.

Sócrates (469-399 a. C.): “La filosofía es un afán que siente el hombre por saber de sí mismo” (“Conócete a ti mismo”). “La filosofía es el amor permanente a la sabiduría y la búsqueda de la verdad de las cosas; pues la sabiduría misma es patrimonio de los dioses”. “Filosofía es la búsqueda de la verdad como medida de lo que el hombre debe hacer y como norma para su conducta”.

Platón (427-347 a. C.): “La filosofía es la ciencia de la razón de las cosas”. “La filosofía es la más alta ascensión de la personalidad y la sociedad humana por medio de la sabiduría”.

Aristóteles (384-322 a.C.): “Todo lo que sobre este punto nos proponemos decir ahora, es que la ciencia que se llama Filosofía es, según la idea que generalmente se tiene de ella, el estudio de las primeras causas y de los principios. La filosofía es la ciencia del ser en tanto que ser”.

Descartes, Renato (1596-1650): “Esta palabra filosofía, significa el estudio de la sabiduría, y por sabiduría se entiende no sólo la prudencia en la acción, sino también



un conocimiento perfecto de todas las cosas que el hombre puede conocer, tanto para orientar la conducta de su vida y conservar su salud como para la invención de todas las artes”.

Teoría del Conocimiento.

El conocimiento humano, se considera como la capacidad que posee el individuo de trascender en el objeto o hecho que busca conocer; es decir, es un proceso cognitivo donde el sujeto observa, analiza y comprende lo que se encuentra a su alrededor y que desconoce.

La Teoría del conocimiento es una rama de la filosofía, centrada en el estudio del conocimiento humano. Dependiendo de la perspectiva académica específica, este término puede considerarse sinónimo de la **gnoseología**, dedicada al estudio de la naturaleza del conocimiento, su origen y sus límites.

En otros casos puede usarse como sinónimo a la **epistemología**, que se centra en el estudio de las circunstancias históricas, psicológicas o sociológicas en las que se obtiene el conocimiento, así como las estrategias empleadas para justificarlo o invalidarlo.

En su mayoría señalan dos grandes teorías que intentan explicar el origen del conocimiento y sus elementos. Estas son: la teoría del conocimiento del **racionalismo** y la teoría del conocimiento del **empirismo**, son de estas que luego salen todos los tipos de saberes existentes, aunque otros añaden una tercera que es el **fenomenalismo** (una combinación de las anteriores).

Teoría del conocimiento del racionalismo.

El racionalismo es una corriente filosófica que surgió a finales del siglo XVII, defiende la primacía de la razón como fuente de conocimiento. El racionalismo establece que el hombre no es capaz de descubrir la verdad de los objetos e identificarlos por sí solo. La persona sin conocimiento solo ve cosas y deforma la realidad de lo que se ve. Por ello, necesita hacer uso de la razón para poder crear ideas y ser capaz de relacionar lo visto con lo que ha vivido.



Para los racionalistas, los sentidos no son una fuente válida de conocimiento ya que son posibles de ser engañados. Esta es una de las principales razones por las que se dio la oposición entre racionalistas y empiristas.

En resumen, señala que, el hombre no aprende de la experiencia, necesita hacer uso de las ideas, el pensamiento y conceptos para poder llegar a éste. Descartes sostenía que “la verdad no está en lo que vemos, sino más bien en lo que pensamos de ello”.

Entre los principales representantes del racionalismo se destacan:

- René Descartes (1596-1650). Fue un filósofo, matemático y físico francés y el primer racionalista moderno. Sentó las bases del racionalismo con su obra *Discurso del método* y sus aportes fueron de gran influencia para la filosofía, las matemáticas y la física. Una de sus frases más célebres es: “pienso, luego existo”.
- Baruch Spinoza (1652-1677). Fue un filósofo neerlandés que se destacó por plantear la relación entre la razón y las pasiones. Spinoza consideraba a las pasiones como un tipo de afecto, por lo que eran una idea de la razón. Su concepto de la pasión se relaciona con la filosofía griega del estoicismo en la que los sentimientos podían ser controlados por la fuerza de voluntad del individuo.
- Blaise Pascal (1623-1662). Fue un matemático, físico y filósofo francés que se destacó por sus aportes, como la máquina aritmética, sus nuevas teorías acerca del vacío y el *Tratado del equilibrio de los líquidos*. Desde la filosofía sostuvo que las religiones (o la necesidad de creer) no eran más que una forma de manifestación de la ansiedad infinita del ser humano.
- Gottfried Leibniz (1646-1716). Fue un polímata (capacidad de alcanzar la excelencia en varias áreas del conocimiento), filósofo y político alemán que se destacó por su gran cantidad de aportes, como el cálculo diferencial matemático, el lenguaje binario (que resultó a futuro la base del lenguaje de programación) o la dinámica como parte de la física que estudia el movimiento. Afirmaba que ningún hecho se producía sin una razón suficiente para que así sea.



Características principales.

En resumen, entre las características principales de la teoría del conocimiento racionalista se mencionan las siguientes:

- Hace uso de la razón.
- No se centra en la experiencia.
- Se basa en el pensamiento y no en el objeto del saber.

Teoría del conocimiento del empirismo.

El empirismo es una corriente filosófica que surgió en Inglaterra entre los siglos XVI y XVIII como oposición al racionalismo. Sostiene la idea de la experiencia como única fuente de conocimiento. Es decir, que el individuo aprende en contacto con la realidad, sus hechos y objetos, por eso también se le llama materialista.

Para el empirismo, todo el conocimiento proviene de la experiencia sensorial y la razón solo tiene la función de ordenar lógicamente el material proporcionado por los sentidos.

Los principales referentes del empirismo son:

- Francis Bacon (1561-1626): fue el primero en plantear que el conocimiento científico debe basarse en la experiencia. En ese sentido, estableció las bases metodológicas de la ciencia al afirmar que ésta debe basarse en la observación y la experimentación y el método inductivo.
- John Locke (1632-1704): médico y filósofo nacido en Inglaterra, fue el primero en desarrollar teóricamente la teoría empirista.
- George Berkeley (1685-1753): obispo y filósofo irlandés que desarrolló una corriente filosófica basada en el empirismo, llamada inmaterialismo o idealismos subjetivo.
- David Hume (1711-1776): economista, historiador, filósofo y sociólogo escocés. Fue el representante más importante del empirismo al profundizar en todos los aspectos de la teoría y sistematizar sus argumentos.



Características principales.

En resumen, entre las características principales de la teoría del conocimiento empirista destacan las siguientes:

- Se basa en la experiencia como fuente principal.
- Es objetiva, por lo que solo toma en cuenta lo que ve, su realidad.
- Se opone a lo fantástico, lo mágico, lo que no se puede comprobar.
- Hace uso de los sentidos para percibir la realidad y adquirir el saber de ello.

La tabla 1.8 presenta las características entre las principales teorías del conocimiento, racionalismo y empirismo.

Tabla 1.8 Características del racionalismo y empirismo.

Racionalismo	Empirismo
La fuente de nuestros conocimientos claros y distintos (evidentes) reside en la razón.	La fuente de nuestros conocimientos fuertes y vivaces es la experiencia.
Conocemos la realidad a través de las ideas (subjetividad como clave de bóveda del pensamiento moderno).	Conocemos la realidad a través de las percepciones (impresiones e ideas).
Afirmación de la existencia de ideas innatas: yo, infinito, perfección, causalidad.	Negación de la existencia de ideas innatas: nuestra mente es una “tabula rasa”.
Desconfianza de la información de los sentidos.	Confianza absoluta en la información de los sentidos.
Las Matemáticas son el modelo de conocimiento cierto y evidente. Valor de la intuición y la deducción.	La Física como modelo del funcionamiento de la mente humana. Valor de la inducción.
Papel fundamental de la “intuición intelectual” en el proceso del conocimiento.	Intuición entendida como conocimiento sensorial.
Es posible un conocimiento cierto y evidente de la realidad (Metafísica: Yo-pensamiento, Dios-infinito y mundo-extensión).	Es imposible un conocimiento “seguro” o dogmático de la realidad: crítica de la metafísica como conocimiento. Defensa del escepticismo y el fenomenismo.



Teoría del conocimiento del fenomenalismo o idealismo.

El fenomenalismo es una teoría a medio camino entre la racionalista y la empírica ya que considera el uso de la razón y de la experiencia importantes, pero en procesos diferentes.

Kant, Immanuel Kant (1724-1804), fue un pensador alemán ampliamente considerado como uno de los filósofos más importantes de todos los tiempos. Entre sus obras más famosas de filosofía crítica se encuentra *Crítica de la razón pura*, que cuestionó el predominio del empirismo y el racionalismo en el pensamiento ilustrado y cambió el enfoque de la filosofía hacia una examinación de conceptos y categorías generales, estableció que los objetos no pueden conocerse como son en sí mismos, sino que solo pueden conocerse como son percibidos a través de los sentidos.

Kant consideró que los objetos llegan a nuestra conciencia con la experiencia y ahí actúa la razón para ordenarlo y conocerlo.

Características principales.

Entre las características principales de la teoría del fenomenalismo se encuentran:

- Utiliza tanto la razón como la experiencia.
- Considera como punto de partida el mundo exterior.
- Establece que no se puede conocer las cosas como son realmente, si no como las percibimos.

1.6 El modelo cognoscitivo.

El concepto de cognición (del latín: cognoscere, “conocer”) hace referencia a la facultad de los seres de procesar información a partir de la percepción, el conocimiento adquirido (experiencia) y características subjetivas que permiten valorar y considerar ciertos aspectos en comparación de otros.

El enfoque cognitivo ha insistido sobre cómo los individuos representan el mundo en que viven y cómo reciben información, actuando de acuerdo con ella. Se considera que los sujetos son elaboradores o procesadores de la información.



Los procesos cognoscitivos en términos de aprendizaje se dan por niveles de complejidad ya sea en relación con el **desarrollo (edad)** o con los **niveles de complejidad** en una tarea.

En **términos del desarrollo**, las teorías de Piaget o de Vigotsky definen una serie de características según ciclos de vida de los individuos y según la complejidad de las tareas, los enfoques computacionales representacionales, definen una serie de procesos y subprocesos subyacentes a la solución de problemas y a la toma de decisiones.

Características de desarrollo del niño.

Durante el proceso evolutivo del niño, Piaget diferenció cuatro etapas de desarrollo cognoscitivo:

1. Periodo sensoriomotor (de 0 a 2 años).

En esta etapa, el niño interacciona con el medio a través de los reflejos innatos que va modificando y perfeccionando por ensayo y error. Según detecta que sus acciones modifican el entorno, se despierta en él una clara intención exploradora (por ejemplo: gatea para alcanzar un objeto que le llama la atención) e, incluso, es capaz de anticiparse a los hechos (por ej., tira un juguete de la nada para captar la atención de sus padres).

2. Periodo preoperatorio (de 2 a 7 años).

Es en esta etapa cuando el pequeño desarrolla la capacidad de representación. El niño crea imágenes mentales de la realidad, imita las acciones de los adultos y sus iguales, muestra claros signos de juego simbólico y sus competencias lingüísticas mejoran notablemente.

3. Periodo de las operaciones concretas (de 8 a 12 años).

Lo más característico de esta fase del desarrollo es que el niño utiliza la lógica para hacer sus inferencias sobre los sucesos y realidades. Esto se debe a que sus conocimientos anteriores se han organizado en estructuras más complejas, unificadas. Por ejemplo: un niño prepúber deduce por sí mismo que si cambias el agua de un tazón a un vaso alargado, la cantidad de agua es la misma, aunque en el segundo recipiente aparentemente parezca que hay más cantidad. En el estado anterior habría incurrido al error.



4. Periodo de las operaciones formales (de 12 a 16 años).

Es en la adolescencia cuando el niño desarrolla una operación compleja: el razonamiento hipotético deductivo. Esto significa que el adolescente, ante un problema, analiza todas las premisas y valora diferentes hipótesis sobre su causalidad o efecto. En el anterior estado de desarrollo el niño hacía inferencias sobre la experiencia real. Ahora, los problemas pueden presentarse de manera figurada, sin necesidad de que el adolescente tenga ninguna experiencia sobre el hecho. En esta etapa también es característica la metacognición: la capacidad de poder reflexionar sobre nuestro propio razonamiento.

En **relación con la complejidad** como se estructura un conocimiento se pueden definir 4 grandes procesos básicos: conceptualización, interpretación, transferencia, creatividad.

1. Conceptualización se refiere a la manera como se define un concepto en relación con una experiencia asociada o con otro concepto en una proposición o estructura conceptual.
2. La interpretación se refiere a la manera como un concepto o conjunto de conceptos o proposiciones toma significados en relación con un contexto lingüístico o discursivo o en relación con un fenómeno. Dentro de la interpretación se juegan procesos cognoscitivos como la deducción, la inferencia, el análisis, la síntesis y diferentes modalidades de categorización.
3. La transferencia se refiere a la manera como se aplica un conocimiento a la solución de problemas surgidos en contextos diferentes a aquellos en donde se dio la situación de aprendizaje.
4. La creatividad se refiere a la manera como se reestructura o se proponen estructuras diferentes a las aprendidas.

La Teoría del Desarrollo Cognitivo de Piaget ha sido una influencia duradera en el campo de la psicología del desarrollo. Su enfoque en los estados del desarrollo, la asimilación y la acomodación, los esquemas y la importancia del juego ha proporcionado una base sólida



para comprender cómo los niños adquieren conocimientos y desarrollan habilidades cognitivas. Aunque la teoría ha sido objeto de debate y ha recibido críticas, su impacto en nuestra comprensión del crecimiento intelectual sigue siendo significativo. La obra de Piaget nos recuerda la importancia de comprender y apreciar la forma en que los individuos construyen y organizan su conocimiento a medida que crecen y se desarrollan.

Tipologías de aprendizaje cognitivo.

Tras la aparición de las primeras teorías, han surgido nuevos estudios que han permitido desarrollar varias tipologías de aprendizaje cognitivo.

1. Aprendizaje explícito e implícito. El aprendizaje explícito se caracteriza por la intención de aprender una nueva habilidad o proceso de manera consciente, por tanto, precisa de un esfuerzo de atención constante para llegar a ese aprendizaje. Por ejemplo, es lo que sucede cuando se quiere aprender más sobre alguna materia de tu sector y se decide leer un libro o un artículo sobre ello.

En cambio, el aprendizaje implícito rompe las reglas del método anterior, dado que se adquiere el conocimiento sin ser consciente de ello. En este sentido, seguro que alguna vez se ha leído un libro, escuchado un podcast o llevado a cabo alguna tarea que, sin quererlo, ha contribuido a que se adquieran nuevas capacidades por el mero hecho de ejecutar funciones de manera automática.

2. Aprendizaje significativo. David Ausubel, psicólogo norteamericano, con sus nuevas aportaciones, consolidó el aprendizaje significativo dentro del marco de la teoría cognoscitiva. De acuerdo con esta perspectiva, existe una relación entre la nueva información adquirida y los pensamientos previos de cada persona, y a partir de esta se forma una conexión que finalizará en el nuevo aprendizaje.

Este modelo propone un método de aprendizaje activo que despierte el interés de los estudiantes, como es el caso de la gamificación, para que así puedan comprender los conocimientos. Un claro ejemplo de aprendizaje significativo es cuando un profesional lleva a cabo una capacitación adicional de negociación y, al tener que liderar una negociación, ve cómo puede poner en práctica lo aprendido, de manera que atribuye un sentido personal a los conocimientos adquiridos.



3. Aprendizaje por descubrimiento. Esta teoría, desarrollada por el psicólogo y pedagogo estadounidense Jerome Bruner en los años 60, estudia la influencia del entorno sobre el aprendizaje, es decir, cómo se descubren las cosas por uno mismo al seleccionar y organizar los estímulos del ambiente. Por ejemplo, si en el trabajo se debe utilizar una herramienta específica que hasta entonces no se había empleado y, por tanto, se buscan las instrucciones de uso, se aprenderá por descubrimiento las características del mecanismo.
4. Aprendizaje experimental. Como su propio nombre indica, este aprendizaje se basa en las experiencias vividas en distintos ámbitos. Estas vivencias permiten descubrir qué falla y qué funciona, de manera que se aprenden las lecciones según lo acontecido. Sin embargo, es importante que estos acontecimientos siempre estén bien estructurados y desarrollados bajo los objetivos marcados. Por ejemplo, el aprender andar en bicicleta, seguro hubo varias caídas, así como nuevos intentos.
5. Aprendizaje cooperativo y colaborativo.
Dentro del aprendizaje cognitivo, se encuentran dos métodos que promueven el aprendizaje grupal: el aprendizaje cooperativo y el colaborativo.
Por un lado, el aprendizaje cooperativo está cada vez más presente en el entorno laboral, ya que es un método que fomenta el aprendizaje a través del trabajo, la colaboración y la socialización con los miembros de un grupo. En este modelo, todos los componentes del grupo son vistos de manera igual y el profesor tiene un papel activo, ya que ejerce de guía durante todo el proceso.
Por otro lado, si bien el aprendizaje colaborativo es bastante similar, presenta alguna diferencia. Por ejemplo, en este modelo se buscan los puntos fuertes de cada miembro del equipo y solo se acude al profesor en el caso de enfrentarse a una dificultad.
6. Aprendizaje por observación. El aprendizaje por observación es uno de los componentes esenciales de la teoría cognitiva social. Esta teoría parte de una situación que se da, al menos, entre dos personas: uno de los sujetos se convierte en el modelo referente, mientras que el otro se dedica a observar y a aprender de su comportamiento.

1.7 El modelo del agente inteligente, Sistemas Multi Agentes, Sistemas Ubicuos.

En el desarrollo constante de la inteligencia artificial, los agentes inteligentes cobran cada vez más relevancia en el ámbito tecnológico, y es que, su extrema utilidad en los numerosos aspectos del mundo real, hacen de esta entidad autónoma un sistema que se aplicará cada vez más, y seremos testigos de sus grandes ventajas cuando experimentemos los beneficios que aportan a la humanidad.

En inteligencia artificial, un agente inteligente es un sistema perceptivo capaz de interpretar y procesar la información que recibe de su entorno, actuando en consecuencia de acuerdo a los datos que recoge y procesa. La forma de actuar de esta entidad es lógica y racional basándose en las reacciones del comportamiento normal de un sistema en concreto. Utiliza sensores para recibir información y actuadores para ejercer sus funciones, ver Figura 1.1.




Figura 1.1 Estructura de un Agente Inteligente.

Un agente inteligente funciona mediante la obtención constante de datos percibidos del entorno en el que se encuentra. De acuerdo a los datos obtenidos, la entidad inteligente tiene un comportamiento u otro. Además, debido a que posee autonomía propia, puede asignarse nuevas reglas para continuar su crecimiento como sistema intelectual.



Características de los agentes inteligentes.

Algunas de las características que en la literatura se suelen atribuir a los agentes en mayor o menor grado para resolver problemas particulares y que han sido descritos por autores tales como Franklin y Graesser [Franklin1996], y Nwana [Nwana1996], éstas son:

- Continuidad Temporal: se considera un agente un proceso sin fin, ejecutándose continuamente y desarrollando su función.
- Autonomía: un agente es completamente autónomo si es capaz de actuar basándose en su experiencia. El agente es capaz de adaptarse, aunque el entorno cambie severamente. Por otra parte, una definición menos estricta de autonomía sería cuando el agente percibe el entorno. Sociabilidad: este atributo permite a un agente comunicar con otros agentes o incluso con otras entidades.
- Racionalidad: el agente siempre realiza «lo correcto» a partir de los datos que percibe del entorno.
- Reactividad: un agente actúa como resultado de cambios en su entorno. En este caso, un agente percibe el entorno y esos cambios dirigen el comportamiento del agente.
- Pro-actividad: un agente es pro-activo cuando es capaz de controlar sus propios objetivos a pesar de cambios en el entorno.
- Adaptabilidad: está relacionado con el aprendizaje que un agente es capaz de realizar y si puede cambiar su comportamiento basándose en ese aprendizaje.
- Movilidad: capacidad de un agente de trasladarse a través de una red telemática.
- Veracidad: asunción de que un agente no comunica información falsa a propósito.
- Benevolencia: asunción de que un agente está dispuesto a ayudar a otros agentes si esto no entra en conflicto con sus propios objetivos.

Características de los agentes inteligentes.

- El agente tiene capacidad de raciocinio.
- El agente aprende por sí mismo en función de la información que recibe y guarda.
- Puede interactuar con el entorno que le rodea.



- Tiene la capacidad de cooperar con otros agentes para cumplir una labor en concreto.
- Un agente puede tomar decisiones propias y obrar según su criterio.
- El comportamiento de un agente es determinado de acuerdo a la información percibida del entorno.
- Si el agente tiene una secuencia de actuaciones, es debido a la captación continua de información de la cual es sensible.

Ambiente de los agentes inteligentes.

Los Agentes y entornos del ambiente están íntimamente relacionados, a continuación, se describen algunos tipos de ambientes:

- Accesibles y no accesibles. Si el aparato sensorial de un agente le permite tener acceso al estado total de un ambiente, se dice que este es accesible a tal agente. Un agente es realmente accesible si los sensores detectan todos los aspectos relevantes a la elección de una acción. Los ambientes accesibles son cómodos, puesto que no es necesario que el agente mantenga un estado interno para estar al tanto de lo que sucede en el mundo.
- Deterministas y no deterministas. Si el estado siguiente de un ambiente se determina completamente mediante el estado actual y las acciones escogidas por los agentes, se dice que el ambiente es determinista. En principio, un agente no tiene por qué preocuparse sobre la incertidumbre en un ambiente accesible y determinista. Pero si el ambiente es inaccesible, entonces podría parecer que es no determinista. Lo anterior es especialmente válido cuando el ambiente es complejo, dificultando el estar al tanto de todos los aspectos inaccesibles. Por ello, es más conveniente calificar el que un ambiente sea determinista o no determinista considerando el punto de vista el agente.
- Episódicos y no episódicos. En un ambiente episódico, la experiencia del agente se divide en “episodio” cada episodio consta de un agente que percibe y actúa. la calidad de su actuación dependerá del episodio mismo, dado que los episodios subsecuentes no dependerán de las acciones producidas en episodios anteriores. Los



ambientes episódicos son más sencillos puesto que el agente no tiene que pensar por adelantado.

- Estáticos y dinámicos. Si existe la posibilidad de que el ambiente sufra modificaciones mientras el agente se encuentra deliberando, se dice que tal ambiente se comporta en forma dinámica en relación con el ambiente; de lo contrario, se dice que es estático. Es más fácil trabajar con ambientes estáticos puesto que el agente no tiene que observar lo que sucede en el mundo al mismo tiempo que decide sobre el curso de una acción, ni tampoco tiene que preocuparse por el paso del tiempo. Si el ambiente no cambia con el paso del tiempo, pero si se modifica la calificación asignada al desempeño de un agente, se dice que el ambiente es semidinámico.
- Discretos y continuos. Si existe una cantidad limitada de percepciones y acciones distintas y claramente discernibles, se dice que el ambiente es discreto. El ajedrez es discreto: existe una cantidad fija de posibles jugadas en cada ronda. La conducción de un taxi es continua: la velocidad y la ubicación del taxi junto con los demás vehículos se extiende a través de un rango de valores continuos

Las características del entorno influyen en el diseño del agente, por ejemplo: Si el entorno es accesible el agente no necesita un estado interno. Si el entorno es episódico el agente no tiene que preocuparse del impacto de sus decisiones. Si el entorno es dinámico el agente tiene que seguir observando mientras razona.

En la tabla 1.9 se presentan algunos ejemplos de entornos y sus características:



Tabla 1.9 Ejemplos de entornos y agentes inteligentes.

Ambiente	Accesible	Determinista	Episodio	Estático	Discreto
Ajedrez con reloj	Si	Si	No	Semi	Si
Ajedrez sin reloj	Si	Si	No	Si	Si
Poquer	No	No	No	Si	Si
Conducir un taxi	No	No	No	No	No
Sistema de diagnóstico medico	No	No	No	No	No
Sistema de análisis de imágenes	Si	SI	Si	Semi	No
Robot clasificador de partes	No	No	Si	No	No
Robot clasificador de partes	No	No	No	No	No
Asesor de inglés interactivo	No	No	No	No	Si

Principales aplicaciones de los agentes inteligentes.

Los agentes inteligentes y, en general, la inteligencia artificial, hace tiempo que dejaron de ser una utopía de las películas y novelas de ciencia ficción para pasar a ser una realidad que forma parte de la vida cotidiana. Actualmente, algunas de las funciones que realizan los agentes inteligentes serían:

- Representación virtual. Su funcionalidad es comunicarse en lenguaje natural con los usuarios de un determinado servicio, supliendo las labores de un comercial o del personal de atención al cliente. Casi todas las empresas optan por este tipo de agentes virtuales en el primer contacto del cliente para la resolución de problemas a través de sus webs o aplicaciones móviles.
- Asistentes personales. Ofrecen la asistencia que podría facilitar un ayudante o secretario personal, pero de manera virtual. Tienen funcionalidades de agenda o de asesoramiento financiero.
- Negociación en mercados electrónicos. Recopila toda la información necesaria, aprende cómo está la oferta y realiza una oferta en nombre del usuario.



- **Búsqueda de información.** Gracias a esta funcionalidad, es posible rastrear las redes en busca de la información que se les ha ordenado buscar. Aprenden de los hábitos del usuario y, por ello, son capaces de ofrecer las sugerencias que consideran que le pueden interesar a través del correo electrónico facilitado. El ejemplo más claro de este tipo de agente es Google News.
- **Agente secreto o espía.** Por medio de esta utilidad es posible detectar cualquier cambio en una determinada página web en la que el usuario esté interesado. Una vez detectada la URL (Uniform Resource Locator, Localizador de Recursos Uniforme) que interesa monitorear, es posible utilizar recursos como Visual Ping para recibir por correo electrónico el aviso de cualquier cambio que se produzca en la web solicitada. Esta es una función muy usada por el mundo empresarial para estar informados de los cambios que se producen en las compañías de la competencia.
- **Asistentes de voz.** Por medio del procesamiento de lenguajes naturales (PLN), estos asistentes interpretan las órdenes de voz y responden a ellas para poner la música deseada, encender las luces de la casa cuando es preciso o recordar ciertas actividades. Ejemplos de este tipo de asistentes que funcionan con agentes inteligentes son Google Home o Amazon Echo.
- **Mapas e indicaciones.** Tanto en el caso de Google Maps como en Apple Maps, es la inteligencia artificial quién lee muchos puntos de datos para poder facilitar información en tiempo real sobre el estado del tráfico y la mejor ruta a seguir.

Tipos de agentes inteligentes.

Los agentes inteligentes se clasifican en 6 tipos diferentes, donde cada uno distingue su utilidad y características que lo definen:

1. **Agente de reactivo simple** (Acción depende de la percepción y el estado actual):
Cuando una percepción en concreto coincide con una regla programada, el agente

responde según la forma en que fue predispuesto. Este accionar se conoce como condición-acción, ver figura 1.2.




Figura 1.2 Diagrama esquemático de un agente reactivo simple.

2. Agente reactivo basado en modelo (Estado actual depende de la historia de estados), ver figura 1.3. Este tipo de agente permite simular su acción de respuesta y sus diversas interacciones en un entorno preparado. De esta forma se estudia su comportamiento y sus efectos en el espacio de actuación.

La actualización del estado interno requiere dos tipos de conocimiento codificado:

- Conocimiento acerca de la forma en que el mundo cambia, independientemente de las acciones del agente.
- Conocimiento acerca de la forma en que el mundo cambia con motivo de la acción del agente.




Figura 1.3 Diagrama esquemático de un agente basado en modelo.

3. Agente basado en objetivos (Acción depende de que se trata de hacer). Combina características del agente reactivo simple y agente reactivo basado en modelo. En este caso, este tipo de agente tiene un objetivo en concreto, por lo tanto, está programado para buscar la vía óptima y planificar un conjunto de acciones para cumplir dicho propósito. La figura 1.4 presenta este tipo de agente.

Razonando acerca de acciones:

- Un agente reflejo solo actúa basado en conocimientos calculados (reglas).
- La búsqueda y la planificación ayudan a razonar acerca de qué acción logra el objetivo.
- El agente es menos eficiente pero más adaptativo y flexible.




Figura 1.4 Diagrama esquemático de un agente basado en objetivos.

4. Agente basado en utilidad, ver figura 1.5, (Acción depende de que tan útil es para alcanzar el objetivo). Este agente tiene varios propósitos como sistema inteligente, además, posee una herramienta para medir el valor de su comportamiento en el cumplimiento de sus metas establecidas. Sus estándares de conducta garantizan alta calidad en sus acciones:

- Las metas no bastan para generar una conducta de alta calidad.
- Las metas permiten establecer una distinción entre estados “felices” e “infelices”.
- Si se prefiere un estado en lugar de otro, se dice que ese estado ofrece mayor “utilidad” al agente.




Figura 1.5 Diagrama esquemático de un agente basado en utilidad.

5. Agente que aprende, ver figura 1.6. Es un tipo de agente que busca aprender de sus acciones mientras se encuentra en funcionamiento. Es un sistema altamente complejo, ya que está programado para interactuar con el mundo real, además de tener preestablecidas varias metas a alcanzar. Posee en su interior un elemento que indica el éxito de la entidad, y tiene la capacidad de interactuar en entornos que no conoce.




Figura 1.6 Diagrama esquemático de un agente que aprende.



- La distinción más importante entre el elemento de aprendizaje y el elemento de actuación es que el primero está responsabilizado de hacer mejoras y el segundo se responsabiliza de la selección de acciones externas.
 - El elemento de aprendizaje se realimenta con las críticas sobre la actuación del agente y determina cómo se debe modificar el elemento de actuación para proporcionar mejores resultados en el futuro.
 - El diseño del elemento de aprendizaje depende mucho del diseño del elemento de actuación.
 - Cuando se intenta diseñar un agente que tenga capacidad de aprender, la primera cuestión a solucionar no es ¿cómo se puede enseñar a aprender?, sino ¿qué tipo de elemento de actuación necesita el agente para llevar a cabo su objetivo, cuando haya aprendido cómo hacerlo?
 - La crítica indica al elemento de aprendizaje qué tal lo está haciendo el agente con respecto a un nivel de actuación fijo.
 - La crítica es necesaria porque las percepciones por si mismas no prevén una indicación del éxito del agente.
 - El generador de problemas es responsable de sugerir acciones que lo guiarían hacia experiencias nuevas e informativas.
6. Agente de consulta: Se dedica a responder consultas por parte de las personas que interactúan con este sistema. Tiene la peculiaridad de crear varios agentes, y dividir la pregunta del usuario en varias tareas para su respectiva solución. Además, en caso de que los agentes asignados no sean capaces de responder con exactitud la incógnita enviada, se crearán más agentes y se buscarán en más bases de datos para ofrecer una resolución completa de la problemática.



1.8 El papel de la heurística.

1.8.1 Algoritmos de exploración de alternativas.

Los algoritmos de exploración de alternativas son métodos utilizados en inteligencia artificial para buscar soluciones en espacios de búsqueda complejos y de gran tamaño. Estos algoritmos se caracterizan por explorar el espacio de búsqueda de manera no exhaustiva, es decir, no evalúan todas las posibles soluciones, sino que utilizan estrategias heurísticas o reglas para determinar qué caminos son más prometedores y enfocarse en ellos.

Son importantes en la resolución de problemas en inteligencia artificial por varias razones:

1. **Eficiencia.** Los algoritmos de exploración alternativa permiten buscar soluciones de manera más eficiente que los métodos de búsqueda exhaustiva, especialmente en espacios de búsqueda grandes o infinitos.
2. **Escalabilidad.** Estos algoritmos son capaces de manejar problemas con un gran número de estados posibles, lo que los hace adecuados para aplicaciones complejas en la vida real, como la planificación de rutas en sistemas de navegación o la optimización en problemas de producción y logística.
3. **Adaptabilidad.** Los algoritmos de exploración alternativa pueden adaptarse a diferentes tipos de problemas y contextos, ya que pueden incorporar heurísticas específicas para guiar la búsqueda hacia soluciones prometedoras.
4. **Capacidad de encontrar soluciones aproximadas.** Aunque no garantizan encontrar la solución óptima, estos algoritmos pueden proporcionar soluciones aproximadas en un tiempo razonable, lo que los hace útiles en situaciones donde encontrar la solución óptima es computacionalmente costoso o imposible.

En la tabla 1.10 se presentan las diferencias con base a varias características de los algoritmos de exploración alternativa y algoritmos de búsqueda exhaustiva.

Tabla 1.10 Comparación algoritmos: exploración alternativa vs búsqueda exhaustiva.

	Algoritmos de exploración alternativa	Algoritmos de búsqueda exhaustiva
Objetivo	Encontrar una solución "buena" a un problema, no necesariamente la óptima.	Encontrar la solución óptima a un problema, evaluando todas las posibilidades.
Estrategia	Exploran un subconjunto del espacio de búsqueda, guiados por heurísticas o estrategias de selección.	Exploran todo el espacio de búsqueda de forma sistemática.
Ventajas	Más eficientes que la búsqueda exhaustiva. Pueden encontrar soluciones "buenas" en tiempos razonables. Útiles para problemas con grandes espacios de búsqueda.	Encuentran la solución óptima al problema. Útiles para problemas con espacios de búsqueda pequeños.
Desventajas	No garantizan encontrar la solución óptima. La calidad de la solución depende de la heurística o estrategia utilizada.	Pueden ser computacionalmente costosos o incluso inviables para grandes espacios de búsqueda. No siempre es necesario encontrar la solución óptima.
Analogía	Exploración alternativa: Buscar un tesoro en una isla grande usando un mapa y pistas.	Búsqueda exhaustiva: Buscar un tesoro en una isla pequeña excavando cada centímetro de tierra.

Algunos algoritmos básicos de exploración alternativa son:

- Búsqueda en profundidad: Encontrar el camino más corto entre dos ciudades en un mapa. Este tema se profundizará en el subtema 3.8.1.
- Búsqueda en amplitud o anchura: Encontrar una solución a un problema de ajedrez. Este tema se profundizará en el subtema 3.8.2.
- Algoritmo A*: Encontrar la ruta más rápida entre dos puntos.



Entre algunos ejemplos concretos de aplicaciones de algoritmos de exploración alternativa en la vida real y en inteligencia artificial se encuentran:

- La planificación de rutas en sistemas de navegación.
- La resolución de problemas en juegos de estrategia, aprendizaje automático.
- La optimización en problemas de producción y logística, finanzas entre otros.

1.8.2 Algoritmo A*.

El algoritmo A* se define como un método de búsqueda heurística diseñado para encontrar la ruta más corta entre dos puntos en un espacio de búsqueda. Lo que lo hace particularmente efectivo es su capacidad para combinar la búsqueda en anchura con una función de evaluación heurística. Es una herramienta poderosa que se aplica en diversos campos como la robótica, la inteligencia artificial, la planificación de rutas y los videojuegos.

En términos simples, el algoritmo A* utiliza información heurística para estimar qué tan prometedores son los nodos en el espacio de búsqueda, lo que le permite priorizar la exploración de aquellos que tienen más probabilidades de conducir a la solución óptima. Esta combinación de búsqueda exhaustiva y heurística lo convierte en una herramienta poderosa para resolver problemas como el del viajero de comercio de manera eficiente y efectiva.

Un algoritmo de búsqueda admisible es el que garantice el hallazgo de una ruta óptima entre el nodo de inicio y el nodo meta, si es que ella existe. En la búsqueda A* una heurística admisible es una que no sobreestima la distancia remanente entre el nodo presente y el nodo meta. Por ejemplo, siempre una ruta real entre dos ciudades es algo mayor y a lo sumo igual a la distancia en línea recta tomada de un mapa. Esta última distancia es así una heurística admisible pues en todo caso es "optimista", lo cual coincide con la definición.

Una heurística admisible.



La restricción consiste en escoger en una función h que nunca sobrestima el costo que implica alcanzar la meta. A tal h se le conoce como heurística admisible. Por naturaleza, este tipo de heurística es optimista pues consideran que el costo para resolver un problema siempre es inferior a lo que en realidad es. Este optimismo se transfiere a la función f . Si h es aceptable, $f(n)$ nunca sobrestimara el costo real de la mejor solución que pase por n , en la búsqueda preferente por lo mejor, en la que se utiliza f como la función de evaluación y una función h aceptable se le conoce como búsqueda A^* .

Funcionamiento.

A^* funciona evaluando dos valores para cada nodo del espacio de búsqueda:

- $g(n)$: La distancia real recorrida desde el nodo inicial hasta el nodo actual.
- $h(n)$: La distancia estimada desde el nodo actual hasta el nodo final. Esta distancia se calcula utilizando una función heurística.


El algoritmo A^* elige el siguiente nodo a explorar en función de la función de evaluación.

$$f(n) = g(n) + h(n).$$

El nodo con la menor puntuación $f(n)$ es el que tiene mayor probabilidad de estar en el camino más corto.



Ejemplo:



Costos Heurísticos.

$h(A) = 5$	$h(D) = 5$	$h(G) = 4$	$h(J) = 3$	$h(M) = 2$
$h(B) = 5$	$h(E) = 4$	$h(H) = 3$	$h(K) = 3$	
$h(C) = 4$	$h(F) = 3$	$h(I) = 2$	$h(L) = 4$	

Solución

Lista cerrada	Vértice	Lista abierta
$g(A) = 0$	A	$F(B) = g(B) + h(B) = 3 + 5 + 0 = 8$
	A	$F(C) = g(C) + h(C) = 5 + 4 + 0 = 9$
	A	$F(D) = g(D) + h(D) = 2 + 5 + 0 = 7$
$g(D) = 2$	D	$F(C) = g(C) + h(C) = 2 + 4 + 2 = 8$
	D	$F(F) = g(F) + h(F) = 1 + 3 + 2 = 6$
	D	$F(G) = g(G) + h(G) = 5 + 4 + 2 = 11$
$g(F) = 3$	F	$F(B) = g(B) + h(B) = 2 + 5 + 3 = 10$
	F	$F(C) = g(C) + h(C) = 4 + 4 + 3 = 11$
	F	$F(E) = g(E) + h(E) = 2 + 4 + 3 = 9$
	F	$F(G) = g(G) + h(G) = 2 + 4 + 3 = 9$
	F	$F(H) = g(H) + h(H) = 1 + 3 + 3 = 7$
	F	$F(I) = g(I) + h(I) = 2 + 2 + 3 = 7$
	F	$F(J) = g(J) + h(J) = 5 + 3 + 3 = 11$



$g(H) = 4$

H $F(E) = g(E) + h(E) = 4 + 4 + 4 = 12$

H $F(I) = g(I) + h(I) = 4 + 2 + 4 = 10$

H $F(K) = g(K) + h(K) = 2 + 3 + 4 = 9$

H $F(L) = g(L) + h(L) = 1 + 4 + 4 = 9$

$g(I) = 5$

I $F(E) = g(E) + h(E) = 3 + 4 + 5 = 12$

I $F(G) = g(G) + h(G) = 3 + 4 + 5 = 12$

I $F(J) = g(J) + h(J) = 3 + 3 + 5 = 11$

I $F(K) = g(K) + h(K) = 2 + 3 + 5 = 10$

I $F(L) = g(L) + h(L) = 6 + 4 + 5 = 15$

I $F(E) = g(E) + h(E) = 1 + 2 + 5 = 8$

$g(B) = 3$

B $F(C) = g(C) + h(C) = 2 + 4 + 3 = 9$

B $F(E) = g(E) + h(E) = 3 + 4 + 3 = 9$

$g(C) = 4$

C $F(E) = g(E) + h(E) = 3 + 4 + 4 = 11$

C $F(G) = g(G) + h(G) = 3 + 4 + 4 = 11$

$g(M) = 6$


M $F(J) = g(J) + h(J) = 5 + 3 + 6 = 14$

M $F(L) = g(F) + h(F) = 4 + 4 + 6 = 14$

M $F(N) = g(N) + h(N) = 2 + 0 + 6 = 8$

$g(N) = 8$

ruta óptima = A $\xrightarrow{2}$ B $\xrightarrow{1}$ F $\xrightarrow{2}$ I $\xrightarrow{1}$ M $\xrightarrow{2}$ N





1.8.3 Algoritmos de búsqueda local.

Algoritmos de búsqueda local son estrategias de optimización que buscan mejorar una solución dada en un espacio de búsqueda, sin necesidad de explorar todos los caminos posibles. Estos algoritmos son eficientes y ahorrativos en términos de memoria y tiempo, pero pueden quedar atrapados en óptimos locales. Este tipo de algoritmo se caracteriza por operar iterativamente, realizando pequeños cambios en la solución actual para mejorarla gradualmente.

En lugar de explorar todo el espacio de búsqueda de posibles soluciones, como lo hacen algunos algoritmos de búsqueda exhaustiva, los algoritmos de búsqueda local comienzan con una solución inicial y luego exploran su vecindad inmediata para encontrar una solución mejor. Este proceso se repite hasta que ya no se pueda mejorar la solución actual, momento en el que se considera que el algoritmo ha convergido a una solución aceptable. Los algoritmos de búsqueda local son particularmente útiles cuando el espacio de búsqueda es grande y la solución óptima no es conocida o no es práctico buscarla exhaustivamente.

Algunas características principales de los algoritmos de búsqueda local son:

1. **Funcionamiento.** Los algoritmos de búsqueda local se centran en mejorar la solución actual, explorando el entorno inmediato de la solución actual. Esto contrasta con los algoritmos de búsqueda informada, que exploran el espacio de búsqueda de manera sistemática.
2. **Paisaje de Estados.** Es el conjunto de soluciones posibles en un problema de búsqueda local. Este concepto ayuda a comprender mejor la búsqueda local.
3. **Entorno.** Es el conjunto de soluciones vecinas a la solución actual. Los algoritmos de búsqueda local exploran el entorno de la solución actual para encontrar soluciones mejoradas.
4. **Algoritmos básicos.** Algunos algoritmos básicos de búsqueda local incluyen el algoritmo de búsqueda local del mejor y el algoritmo de búsqueda local del primer mejor.



5. Limitaciones. Los algoritmos de búsqueda local pueden quedar atrapados en óptimos locales, lo que significa que pueden encontrar soluciones localmente óptimas, pero no necesariamente la solución global más óptima.

Tipos de algoritmos de búsqueda local.

- Búsqueda por Mejor Mejora.
- Búsqueda de Primer Mejora.
- Búsqueda Tabú.
- Recocido Simulado.

Algunas aplicaciones de búsqueda local.

- Planificación de rutas.
- Asignación de recursos.
- Optimización de diseño.
- Resolución de problemas de satisfacción de restricciones.



Tema II

REPRESENTACIÓN DEL CONOCIMIENTO, RAZONAMIENTO Y LOS ASPECTOS METODOLÓGICOS EN INTELIGENCIA ARTIFICIAL.

Competencia Específica: Representar el conocimiento por medio de un sistema basado en conocimiento.

INTRODUCCIÓN.

En este tema se revisan las herramientas utilizadas para representar el conocimiento: mapa mental, red semántica, lógica de predicados.





2. Representación del Conocimiento, Razonamiento y los Aspectos Metodológicos en Inteligencia Artificial.

Representación del Conocimiento y Razonamiento.

Definición: La representación del conocimiento y el razonamiento es un área de la inteligencia artificial que tiene como objetivo fundamental representar el conocimiento de una manera que facilite la inferencia. Esto es, sacar conclusiones a partir de dicho conocimiento.

Adquisición del Conocimiento: Se llama adquisición de conocimiento al proceso de, por un lado, agregar nuevos saberes a una base de conocimiento y por otro lado, refinar o mejorar el conocimiento adquirido previamente. A la adquisición de conocimiento, se la suele asociar con algún propósito, por caso, ampliar las capacidades de un sistema o mejorar su rendimiento en alguna tarea específica. La adquisición de conocimiento, también es creación orientada a objetivos y refinamiento del conocimiento. Puede consistir en hechos, reglas, conceptos, procedimientos, fórmulas, relaciones, estadísticas u otra información útil.

Construcción de la Base de Conocimiento: El conocimiento es una comprensión teórica o práctica de una materia o un dominio. También la suma de lo que se conoce actualmente se denomina conocimiento y tenerlo, es tener poder. Aquellos que poseen conocimiento se llaman expertos. Cualquiera que tenga un conocimiento profundo (tanto de hechos como de reglas) y una sólida experiencia práctica en un dominio en particular, puede ser considerado un experto. Su área de dominio también puede ser limitada. En general, se describe a un experto como una persona hábil que está capacitado para hacer cosas que otras personas no pueden.



Características de la Representación de Conocimiento:

Una buena representación del conocimiento cubre seis características básicas:

1. Cobertura: significa que la representación del conocimiento cubre la información a lo ancho y en lo profundo. Sin una cobertura amplia, la representación del conocimiento no puede determinar nada ni resolver ambigüedades.
2. Ser comprensible por humanos. La representación del conocimiento es aceptada como un lenguaje natural, por lo que la lógica debería fluir de manera libre. Debería estar en condiciones de soportar la modularidad y jerarquía de clases (Ejemplo, los osos polares son osos, que, primero, son animales).
3. Consistencia. Si Pedro cerró la puerta, el acto también puede ser interpretado como que la puerta fue cerrada por Pedro. Si es consistente, la representación del conocimiento puede eliminar el conocimiento tanto redundante como conflictivo.
4. Eficiencia
5. Facilidad de modificación y actualización
6. Soporte de la actividad inteligente que usa la base de conocimiento

Alrededor de los años 70's se plantea un nuevo enfoque, se construyeron sistemas basados en el conocimiento (KBS Knowledge Based Systems), estos sistemas reunían mucha información de un dominio específico, donde hubiera un experto que pudiera indicar como manipular la información disponible por medio de reglas simples del tipo "si A – entonces B". Estos "Sistemas Expertos" se llaman así por la pretensión de simular el comportamiento de un experto humano, en un área muy técnica y específica.

Para poder operar con el conocimiento es necesario representarlo y poder hacer un modelo del mundo sobre el cual se quieren hacer inferencias.

Surgen así distintos métodos de representación del conocimiento en forma simbólica, como:

- La lógica de primer orden
- Los frames (marcos o planillas)
- Las redes semánticas



- Los objetos

2.1 Principios y Metodología de la Inteligencia Artificial (IA).

Principios de la IA.

- Inteligencia Artificial “justa”: Las aplicaciones de la tecnología de IA deben dar resultados justos, sin impactos discriminatorios en relación con la raza, el origen étnico, la religión, el género, la orientación sexual, la discapacidad o cualquier otra condición personal.
- “Transparente y explicable”: El objetivo es que los usuarios tengan el conocimiento que están interactuando con un sistema de IA, qué datos suyos se usan y para qué.
- “Centrada en las personas”: La IA debe estar al servicio de la sociedad y generar beneficios tangibles para las personas, cuyos derechos humanos no pueden verse vulnerados.
- “Privacidad y seguridad desde el diseño”: Las políticas de privacidad y seguridad son de especial relevancia para preservar los datos tanto personales como anónimos y agregados.
- “Trabajando con socios y terceros”: la IA se compromete a verificar la lógica y los datos utilizados por los proveedores.

Metodologías de la IA.

- Machine Learning o Aprendizaje Automático. El Machine Learning es la rama de la ciencia que busca el desarrollo de técnicas que permitan a los ordenadores aprender por sí mismos.
- Fuzzy Logic o Lógica Difusa. Esta técnica incide en lo relativo de un escenario observado como posición diferencial. Es un tipo de lógica que toma dos valores al azar, contextualizados y relacionados entre sí.
- Vida Artificial. Consiste en el estudio de la vida y de los entornos artificiales que muestran cualidades propias de los seres vivos en entornos de simulación.



- **Sistemas Expertos.** Hace referencia a un sistema de información que se basa en el conocimiento de un área de aplicación de gran complejidad y muy específica. Sirve como asistente consultor y experto para los usuarios de su interfaz. Se recurre a la IA cuando se considera útil incorporar a un sistema de ordenadores un conocimiento o comportamiento ante los eventos que serían más propios de un ser humano.
- **Data Mining o Minería de Datos.** Esta técnica consiste en la extracción discriminada de información que se encuentra implícita en los datos manejados. Dicha información, desconocida previamente, se destina a ser utilizada en algún otro proceso.
- **Redes Bayesianas.** También conocidas como redes de creencia, estas redes son un modelo probabilístico multivariado, que relaciona un conjunto de variables de tipo aleatorio usando un grafo dirigido para indicar una influencia casual de manera explícita.
- **Ingeniería del Conocimiento.** Consiste en generar un nuevo conocimiento que no existía previamente. Se hace a partir de la información que se contiene en bases de datos de documentos y mediante el cruce de contenido de los archivos.
- **Redes Neuronales Artificiales.** Estas redes son un paradigma del aprendizaje y los procesamiento automático, inspirado todo ello en el modo en que funciona el sistema nervioso de los animales. Consiste en un sistema de interconexión de neuronas en una red que colaboran entre ellas para crear una respuesta de salida.
- **Sistemas Reactivos.** Estos son sistemas de aplicación crítica, y un fallo o error puede acarrear consecuencias graves. Al punto de poner en riesgo las vidas humanas o el resultado de importantes inversiones económicas.
- **Sistemas Basados en Reglas.** Consisten en modelos de representación del conocimiento que se usan de manera amplia. Son apropiados para escenarios en los que el conocimiento que se necesita representar surge de manera natural en una estructura de reglas.



- **Razonamiento Basado en Casos.** Es un proceso para solucionar cuestiones basándose en soluciones de problemáticas anteriores. El razonamiento que se basa en casos se sirve de analogías para los nuevos razonamientos.
- **Técnicas de Representación de Conocimiento.** Es un sistema que sirve para analizar el modo de pensar de manera formal. Se usa un entorno de símbolos para la representación de un dominio de discurso, junto a las funciones que puedan inferir sobre los objetos procesados.
- **Redes Semánticas.** Son maneras de representación del conocimiento lingüístico para las que los conceptos y las interrelaciones entre ellos se representan mediante grafos. Son utilizadas para la representación de mapas conceptuales y mentales, entre otras funciones.
- **Lingüística Computacional.** Es un campo multidisciplinar de la lingüística aplicada en la informática. Se sirve de los sistemas informáticos para el estudio y el tratamiento del lenguaje. Para ello, se intenta modelar de manera lógica el lenguaje natural desde un punto de vista programable.
- **Procesamiento del Lenguaje Natural.** Es una disciplina de la rama de la ingeniería para la lingüística computacional. Se utiliza para la formulación e investigación de mecanismos de eficacia informática para servicios de comunicación entre las personas o entre ellas y las máquinas usando lenguajes naturales.



2.2 Paradigmas de la Inteligencia Artificial.

La inteligencia artificial es una disciplina que ha experimentado un gran desarrollo en los últimos años, la cual ha sido aplicada en una amplia variedad de campos, desde los sistemas de reconocimiento de voz hasta los chatbots, la IA está presente en casi todas las áreas de nuestra vida. Sin embargo, para comprender cómo ha evolucionado la inteligencia artificial, es importante entender los diferentes paradigmas que han surgido a lo largo del tiempo y cómo han contribuido a desarrollo.

Existen varios paradigmas en la IA que definen la forma de representar los conocimientos y como estos son utilizados para lograr un determinado objetivo, tales como:

- **Inteligencia Artificial Simbólica (IAS).** Esta rama de la IA tiene como objetivo representar explícitamente el conocimiento humano de forma declarativa (hechos y reglas). Las aplicaciones de la IAS corresponden a aplicaciones donde el ambiente es conocido y existe precisión en los datos. Esta aproximación ha tenido muchos éxitos, fundamentalmente con los llamados Sistemas Expertos, sin embargo, las dificultades encontradas en este paradigma son muchas y muchos investigadores plantean que éstas no tienen solución. Por ejemplo, el conocimiento llamado “sentido común” es muy difícil de representar simbólicamente.
- **Inteligencia Artificial Conexionista (IAC).** Estos modelos copian el paralelismo masivo de las neuronas para procesar información o datos. La IAC se inspira en la estructura neuronal del cerebro para implementar sistemas con capacidad de reconocer patrones, clasificar, aprender, etc. A partir de la interconexión de unidades elementales, llamadas neuronas, se obtienen las llamadas Redes Neuronales Artificiales (RNA), las que presentan un comportamiento emergente. La IAC se aplica en situaciones donde existe imprecisión, principalmente desde el punto de vista del raciocinio (o sea, no se conoce con exactitud cómo se resuelve el problema).
- **Inteligencia Artificial Evolutiva (IAE).** Esta surgió al final de los años 60, cuando se comenzó a estudiar la incorporación de mecanismos de selección natural para la

solución de problemas. Como resultado se crearon una serie de algoritmos que, basados en la Teoría de la Evolución de Charles Darwin, conducen una búsqueda estocástica de la solución de un problema, haciendo evolucionar a un conjunto de estructuras y seleccionando de modo repetido, las más adecuadas. La IAE es preferentemente utilizada cuando el ambiente es desconocido.

- **Inteligencia Artificial Híbrida (IAH).** La IAH involucra a más de uno de los paradigmas anteriores para resolver problemas. En la figura 2.1, se muestran los tres paradigmas anteriores, como vértices de un triángulo.




Figura 2.1 Paradigmas de la IAH.

Las aplicaciones de la IAS corresponden a aplicaciones donde el ambiente es conocido y existe precisión en los datos. La IAC se aplica en situaciones donde existe imprecisión, principalmente desde el punto de vista del raciocinio (o sea, no se conoce con exactitud cómo se resuelve el problema). Por último, la IAE es preferentemente utilizada cuando el ambiente es desconocido.

- **Inteligencia Artificial Distribuida (IAD).** La IAD se basa en el modularidad, pues su funcionamiento depende de un conjunto de partes (o módulos) que trabajan de modo cooperativo para resolver un determinado problema.
- **Inteligencia Artificial Monolítica (IAM).** La IAM contempla sistemas no modulares como, por ejemplo, los Sistemas Expertos. Por su parte, la IAD se basa en el modularidad, pues su funcionamiento depende de un conjunto de partes (o

módulos) que trabajan de modo cooperativo para resolver un determinado problema. Su carácter modular está directamente ligado al concepto de Agentes.

2.3 Mapas Conceptuales.

Los mapas conceptuales son artefactos para la organización y representación del conocimiento. Tienen su origen en las teorías sobre la psicología del aprendizaje de David Ausubel enunciadas en los años 60.

Su objetivo es representar relaciones entre conceptos en forma de proposiciones. Los conceptos están incluidos en cajas o círculos, mientras que las relaciones entre ellos se explicitan mediante líneas que unen sus cajas respectivas. Las líneas, a su vez, tienen palabras asociadas que describen cuál es la naturaleza de la relación que liga los conceptos.

Los mapas conceptuales se estructuran en forma jerárquica en la que los conceptos más generales están en la raíz del árbol y a medida que vamos descendiendo por el mismo nos vamos encontrando con conceptos más específicos.

Un mapa conceptual es, por tanto, un recurso esquemático para representar un conjunto de significados conceptuales incluidos en una estructura de proposiciones que tiene por objeto representar las relaciones significativas entre los conceptos del contenido (externo) y del conocimiento del sujeto, ver figura 2.2.




Figura 2.2 Mapa conceptual: mapas conceptuales.



Características de un mapa conceptual.

- Los mapas conceptuales deben ser simples, mostrar claramente las relaciones entre conceptos y/o proposiciones.
- Van de lo general a lo específico, las ideas más generales o inclusivas, ocupan el ápice o parte superior de la estructura y las más específicas y los ejemplos la parte inferior.
- Deben ser vistosos.
- Los conceptos, que nunca se repiten van adentro de los óvalos y las palabras de enlace se ubican cerca de las líneas de la relación.
- Para las palabras de enlace se pueden utilizar verbos, preposiciones, conjunciones, u otro tipo de nexo conceptual, las palabras de enlace le dan sentido al mapa.
- Si la idea principal puede ser dividida en dos o más conceptos iguales estos conceptos deben ir en la misma línea o altura.

Ventajas de los mapas conceptuales.

- Aprendizaje significativo. El aprendizaje significativo ocurre cuando una persona consciente y explícitamente vincula esos nuevos conceptos a otros que ya posee. Cuando se produce ese aprendizaje significativo, se produce una serie de cambios en nuestra estructura cognitiva, modificando los conceptos existentes, y formando nuevos enlaces entre ellos. Esto es porque dicho aprendizaje dura más y es mejor que la simple memorización: los nuevos conceptos tardan más tiempo en olvidarse, y se aplican más fácilmente en la resolución de problemas.
- Aprendizaje activo. Cuando se realiza un mapa conceptual, se obliga a relacionar, a jugar con los conceptos, a aprender con el contenido. No es una simple memorización; se debe prestar atención a la relación entre los conceptos. Es un proceso activo.



El mapa conceptual puede tener varios propósitos.

- Generar ideas.
- Diseñar una estructura compleja (textos largos, hipermedia, páginas web grandes).
- Comunicar ideas complejas.
- Contribuir al aprendizaje integrando explícitamente conocimientos nuevos y antiguos.
- Evaluar la comprensión o diagnosticar la incomprensión.
- Explorar el conocimiento previo y los errores de concepto.

2.4 Redes Semánticas.

Una red semántica es una técnica clásica de representación de la Inteligencia Artificial utilizada para información relativa a las proposiciones. A una red semántica también se le llama red de proposiciones [Stillings, 1987]. Una proposición es una frase verdadera o falsa, como “todos los perros son mamíferos” y “un triángulo tiene tres lados”. Son formas de conocimiento declarativo porque establecen hechos. En términos matemáticos, una red semántica es una gráfica rotulada y con dirección. Una proposición siempre es verdadera o falsa y se le llama atómica porque su veracidad ya no puede dividirse más, el término atómica se emplea en el sentido clásico de objeto indivisible.

Las redes semánticas se desarrollaron para la Inteligencia Artificial como una forma de **representar la memoria y la comprensión del lenguaje del ser humano** [Quillian, 1968]. Quillian las utilizó para analizar el significado de palabras en frases. Desde entonces se han aplicado a muchos de los problemas relacionados con la representación del conocimiento. La estructura de una red semántica se muestra gráficamente en términos de nodos y los arcos que los conectan. A los nodos suele denominárseles como objetos y a los arcos como vínculos o bordes.

Los vínculos de una red semántica se utilizan para expresar relaciones. Por lo general, los nodos se utilizan para representar **objetos físicos, conceptos o situaciones**. En la figura 2.3 se muestra una red ordinaria, en realidad una gráfica con dirección, donde los vínculos

indican las rutas de una línea aérea entre ciudades. Los nodos son los círculos, los vínculos, las líneas que los conectan y las flechas muestran la dirección en que pueden volar los aviones, de aquí el término de grafica con dirección.




Figura 2.3 Red semántica general.

En la figura 2.4, los vínculos muestran las relaciones entre los miembros de una familia, las relaciones son de gran importancia en las redes semánticas porque proporcionan la estructura básica para la organización del conocimiento. Sin relaciones, el conocimiento es una simple colección de hechos inconexos. Con ellas, el conocimiento es una estructura cohesiva a partir de la cual puede inferirse conocimiento adicional. Por ejemplo, en la figura 2.4 se puede inferir que Ana y Memo son los abuelos de Juan, aunque no haya un vínculo explícito rotulado “abuelo de”.




Figura 2.4 Red semántica: Relaciones entre una familia.

A las redes semánticas a veces se les denomina **redes asociativas** porque los nodos están asociados o relacionados con otros nodos. De hecho, el trabajo original de Quillian modeló la memoria humana como una red asociativa en la cual los conceptos eran los nodos y los vínculos formaban las conexiones entre ellos. De acuerdo con este modelo, cuando un nodo de concepto se estimula al leer las palabras de una frase, sus vínculos con otros nodos se activan en un patrón de dispersión. Si otro nodo recibe activación suficiente, el concepto sería forzado dentro de la mente consciente. Por ejemplo, aunque se conozcan miles de palabras, sólo se está pensando en las palabras específicas de la frase que se lee.

Dos tipos de vínculos utilizados con frecuencia son **ES-UN** y **UN-TIPO-DE** [Winston, 1984]. La figura 2.5 es un ejemplo de una red semántica que utiliza estos vínculos; en esta figura **ES-UN** significa “es un caso de” y se refiere a un **miembro específico** de una clase. Una clase está relacionada con el concepto matemático de conjunto, que alude a un grupo de objetos.




Figura 2.5 Red semántica: Ejemplo de vínculos.

El vínculo **UN-TIPO-DE** se utiliza aquí para **relacionar** una clase con otra. No se usa para relacionar un individuo específico porque esa es la función de ES-UN, UN-TIPO-DE relaciona una clase individual con una clase padre a la que pertenece una clase hijo.



Desde otro punto de vista, el **UN-TIPO-DE** relaciona nodos **genéricos** con nodos genéricos, mientras **ES-UN** relaciona un caso o un **individuo** con una clase genérica.

En la figura 2.5 las clases más generales se encuentran en la parte superior y las más específicas en la base. La clase más general, a la que señala una flecha UN-TIPO-DE, se le denomina **superclase**; si ésta tiene un vínculo UN-TIPO-DE apuntando a otro nodo, entonces también es una clase de la superclase a la que señala el vínculo UN-TIPO-DE. Otra forma de expresarlo es que un vínculo UN-TIPO-DE señale de una **subclase** a una clase. El vínculo **SON** se usa algunas veces para UN-TIPO-DE y se lee como el verbo “son”.

Los objetos de una clase tienen uno o más **atributos** en común y cada atributo tiene un valor. La combinación de atributo y valor es una **propiedad**. Por ejemplo, un dirigible tiene atributos de tamaño, peso, forma, color, etc. El valor del atributo de forma es elipsoidal. En otras palabras, un dirigible tiene una forma elipsoidal como una de sus propiedades. Como Goodyear es un dirigible y los dirigibles tienen forma elipsoidal, entonces Goodyear es elipsoidal. También se pueden encontrar otros tipos de vínculos en las redes semánticas. El vínculo **ES** define un valor. Por ejemplo, cualquier aeronave presidencial de Estados Unidos **ES** el Fuerza Aérea 1. Si el presidente está en un CD-9, entonces Fuerza Aérea 1 **ES** un DC-9. El vínculo **CAUSA** expresa conocimiento causal. Por ejemplo, el aire caliente **CAUSA** que el globo se eleve.

A la duplicación de las características de un nodo por parte de un descendiente se le llama **herencia**. A menos que haya más evidencias específicas de lo contrario, se supone que todos los miembros de una clase heredarán todas las propiedades de las superclases. Por ejemplo, los globos tienen una forma redonda. Sin embargo, como la clase dirigible tiene un vínculo que señala a la forma elipsoidal, ésta tiene precedencia. La herencia es una herramienta muy útil en la representación del conocimiento porque elimina la necesidad de repetir características comunes. Los vínculos y la herencia proporcionan medios muy



eficientes de representación del conocimiento porque muchas relaciones complejas pueden mostrarse con pocos nodos y vínculos.

Dificultades con redes semánticas.

Aunque las redes semánticas pueden ser muy útiles en la representación del conocimiento, tiene limitantes, como la falta de estándares para asignación de nombres a los vínculos. Esto hace difícil entender para qué se diseñó realmente la red y si fue diseñada de una forma congruente. Un problema complementario al asignar nombre a los vínculos es el nombre de los nodos. Si un nodo se rotula “silla”, ¿Representa

una silla específica

la clase de todas las sillas el concepto de una silla

el nombre del cerro de la Silla

o algo más? Para que una red semántica represente conocimiento **definitivo** (es decir, conocimiento que puede definirse), deben definirse con rigor los nombres de vínculos y nodos.

Otro problema es la explosión combinatoria de la **búsqueda de nodos**, sobre todo si la respuesta a una consulta es negativa. Para que una consulta produzca un resultado negativo, tendrían que buscarse **muchos o todos** los vínculos de la red. El número de vínculos es la factorial del número de nodos menos uno, si están todos conectados. Aunque no todas las representaciones necesitarán este grado de conectividad, existe la posibilidad de que surja una explosión combinatoria.

Las redes semánticas fueron propuestas originalmente como modelos de la memoria asociativa humana, en la que un nodo tiene vínculos con otros y la recuperación de la información ocurre debido a una dispersión de la activación de los nodos. No obstante, el cerebro humano también debe disponer de otros mecanismos, porque no le toma mucho tiempo responder la consulta: ¿hay un equipo de fútbol en Plutón? Hay alrededor de 10^{10} neuronas en el cerebro humano y alrededor de 10^{15} vínculos. Si todo el conocimiento estuviera representado por una red semántica, tomaría demasiado tiempo responder



consultas negativas como en el caso de la consulta del fútbol, porque todas las búsquedas incluyen 10^{15} vínculos.

2.5 Razonamiento Monótono.

Sistema que permite obtener nuevos conocimientos (conclusiones) a partir de una serie de conocimientos previos (premisas, se denomina premisa a cada una de las proposiciones de un razonamiento que dan lugar a la consecuencia o conclusión de dicho razonamiento).

Se dice que un sistema de razonamiento es monótono cuando un aumento de las premisas nunca puede hacer disminuir el conjunto de conclusiones, es decir, para cualesquiera conjuntos de premisas BC y β y cualquier conclusión α se cumple:

$$\text{Si } BC \models \alpha, \text{ entonces } BC \wedge \beta \models \alpha$$

Donde:

$\models$ Implicación

$\wedge$ Operador lógico Y

La aparición de nuevas premisas nunca supone la desaparición de ninguna de las conclusiones previas.

La característica del **monotonismo** es que el conjunto de sentencias implicadas sólo puede aumentar (pero no cambiar) al añadirse información a la base de conocimiento. Las lógicas **no monótonas**, que violan la propiedad de monotonismo, modelan una característica propia del razonamiento humano: cambiar de opinión.

Para cualquier sentencia α y β , por ejemplo, supongamos que la base de conocimiento contiene una aserción adicional β , se nos dice que hay exactamente 8 hoyos en el escenario. Este conocimiento podría ayudar al agente a obtener conclusiones adicionales, pero no puede invalidar ninguna conclusión α ya inferida (como la conclusión de que no hay un hoyo en la casilla $[1, 2]$).



El monotonismo permite que las reglas de inferencia se puedan aplicar siempre que se hallen premisas aplicables en la base del conocimiento; la conclusión de la regla debe permanecer sin hacer caso de qué más hay en la base del conocimiento.

La lógica de predicados al ser un formalismo de razonamiento monótono, no resulta muy adecuada para ciertos dominios del mundo real, en los cuales las verdades pueden cambiar con el paso del tiempo.

Tanto los humanos como los autómatas deben extraer conclusiones que son verdad en los mejores modelos de los hechos que se han tenido en cuenta, hay diversos conceptos de lo que es mejor en sistemas diferentes, muchos implican la minimización de algo, a medida que se agregan nuevos hechos, algunas de las anteriores conclusiones no sobreviven, por este motivo, el razonamiento que permitió arribar a esas conclusiones que han decaído, se denomina no-monótono.

2.6 Conocimiento No-Monótono y otras Lógicas.

El razonamiento no-monótono es un tipo de razonamiento lógico que permite que las conclusiones se debiliten o se refuten a medida que se agrega nueva información. Este tipo de razonamiento es más flexible que el razonamiento monótono y puede manejar información incompleta, inconsistente o incierta.

Características del razonamiento no-monótono.

- Las conclusiones son probabilísticas: Las conclusiones del razonamiento no monótono no son siempre ciertas, sino que tienen un cierto grado de probabilidad.
- Las conclusiones son provisionales: Las conclusiones pueden cambiar a medida que se adquiere nueva información.
- Las reglas pueden ser no-monótonas: Las reglas que se utilizan en el razonamiento no monótono pueden cambiar su significado a medida que se agrega nueva información.



La razón para usar el razonamiento no-monótono es la necesidad de desarrollar sistemas inteligentes capaces de manejar la incertidumbre y la información incompleta de manera efectiva si son comparados con el razonamiento monótono.

Algunos usos son:

- Actualización de creencias. A medida que se adquiere nueva información, es importante que los sistemas sean capaces de actualizar sus creencias y revisar sus conclusiones previas en función de esta nueva evidencia. El razonamiento no-monótono permite esta actualización dinámica de creencias, lo que mejora la capacidad de los sistemas para adaptarse a cambios en su entorno.
- Inferencia por anulación. En muchos casos, las conclusiones a las que llegan los sistemas pueden ser refutadas o invalidadas por nueva información. El razonamiento no-monótono permite realizar inferencias que son provisionales y pueden ser revisadas o anuladas si se presentan nuevos datos que las contradicen.
- Resolución de conflictos de información. En entornos donde se manejan múltiples fuentes de información, es común que existan conflictos o inconsistencias entre los datos disponibles. El razonamiento no-monótono proporciona herramientas y técnicas para resolver estos conflictos y determinar las conclusiones más adecuadas dadas las circunstancias.

Tipos de razonamiento no-monótono

- Razonamiento por defecto: Conclusiones basadas en información incompleta.
- Razonamiento abductivo: Se utiliza para generar explicaciones posibles para un conjunto de observaciones.
- Revisión de creencias: Se utiliza para actualizar las creencias existentes a medida que se adquiere nueva información.



Aplicaciones del razonamiento no-monótono

- **Diagnóstico médico:** Los médicos utilizan el razonamiento no-monótono para diagnosticar enfermedades a partir de síntomas, pruebas y la historia clínica del paciente.
- **Resolución de problemas:** El razonamiento no-monótono se puede utilizar para resolver problemas complejos que requieren considerar diferentes posibilidades y escenarios.
- **Inteligencia artificial:** El razonamiento no-monótono es un componente importante de la inteligencia artificial, ya que permite a los sistemas inteligentes aprender y adaptarse a nueva información.

En la tabla 2,1 se presenta una comparativa entre el razonamiento monótono y no-monótono.

Tabla 2.1 Tabla comparativa entre razonamiento monótono y no-monótono.

Criterio	Razonamiento Monótono	Razonamiento No-Monótono
Definición	Tipo de razonamiento lógico donde las conclusiones siempre se fortalecen a medida que se agrega nueva información.	Tipo de razonamiento lógico donde las conclusiones no siempre se fortalecen, y pueden debilitarse o incluso refutarse con la adición de nueva información.
Características	Conclusiones válidas. Conclusiones acumulativas. Reglas monótonas.	Conclusiones probabilísticas. Conclusiones provisionales. Reglas no monótonas.
Ejemplos	Sistemas de expertos. Bases de datos. Motores de búsqueda.	Diagnóstico médico. Resolución de problemas. Inteligencia artificial.
Ventajas	Simplicidad y facilidad de implementación. Certeza en las conclusiones. Adecuado para información completa y consistente.	Flexibilidad para manejar información incompleta, inconsistente o incierta. Capacidad para aprender y adaptarse a nueva información. Más realista y aplicable a situaciones del mundo real.



Desventajas	No puede manejar información incompleta, inconsistente o incierta. No puede manejar el cambio de creencias. Puede ser menos eficiente que el razonamiento monótono.	Más complejo de implementar. Requiere técnicas más sofisticadas para llegar a conclusiones. Las conclusiones pueden ser menos ciertas que en el razonamiento monótono.
-------------	--	---

2.7 Razonamiento Probabilístico.

El razonamiento probabilístico es un enfoque de la toma de decisiones y la inferencia que se basa en la teoría de la probabilidad. En lugar de depender únicamente de la lógica clásica, que se basa en premisas verdaderas o falsas, el razonamiento probabilístico permite manejar la incertidumbre al asignar probabilidades a diferentes eventos o conclusiones.

Definición de probabilidad:

- Verosimilitud o fundada apariencia de verdad.
- Cualidad de probable (que se verificará o sucederá).
- Es un proceso aleatorio, razón entre el número de casos favorables y el número de casos posibles.
- Medida de la incertidumbre de un evento. Un valor entre 0 y 1.

La probabilidad es la base del razonamiento probabilístico y se basa en:

- Eventos: Sucesos que pueden ocurrir o no.
- Conjuntos de eventos: Colecciones de eventos.

Las conclusiones resultantes del razonamiento probabilístico, se derivan de la evaluación de la probabilidad de que ciertos eventos ocurran. Esto implica utilizar evidencia y datos disponibles para calcular la probabilidad de que una determinada hipótesis sea verdadera o falsa. Las conclusiones pueden ser más flexibles y estar sujetas a revisión a medida que se adquiere nueva información.

Para resolver problemas usando el razonamiento probabilístico se pueden usar diferentes teoremas de probabilidad. Entre ellos están:



- Teorema de la suma.
- Teorema del producto.
- Teorema de Bayes.

El razonamiento probabilístico se aplica en una amplia variedad de campos, incluyendo la inteligencia artificial, la estadística, la medicina, la ingeniería y la toma de decisiones en general. Al considerar la incertidumbre y la variabilidad inherente en muchos problemas del mundo real, el razonamiento probabilístico proporciona un marco sólido para modelar y abordar estas situaciones de manera más realista y efectiva.

Existen diferentes herramientas que permiten llegar a conclusiones basadas en probabilidad, estas son:

- Inferencia estadística.
- Aprendizaje automático.
- Toma de decisiones bajo incertidumbre.
- Inteligencia artificial.

Ejemplo.

Suponga que está a punto de decidir dónde trabajar después de graduarse de la universidad. Tienes dos opciones: la primera ofrece un salario mucho más alto, pero implica mudarte a una ciudad diferente, lo que conlleva mayores gastos y estar separado de su familia. Además, al ser un trabajo bien remunerado, hay una gran competencia por él. La segunda opción paga menos, pero lo suficiente para vivir en la ciudad actual, con todas las ventajas que eso conlleva. Además, debido a la escasez de personas con su perfil, tiene más probabilidades de ser aceptado.

¿Qué opción elegiría? Utiliza el teorema de sumas de probabilidades para justificar su decisión.

Opción A: trabajar en una ciudad diferente (se asigna a cada opción un valor entre 0-1):



Pros:

- Mayor salario (probabilidad 0.9).
- Oportunidad de trabajar en una empresa prestigiosa (probabilidad 0.7).
- Posibilidad de adquirir nuevas habilidades y experiencias (probabilidad 0.8).

Contras:

- Mayor costo de vida (probabilidad 0.8).
- Lejos de la familia y amigos (probabilidad 0.9).
- Mayor competencia para el puesto (probabilidad 0.6).

Opción B: Trabajar en tu ciudad (se asigna a cada opción un valor entre 0-1):

Pros:

- Menor costo de vida (probabilidad 0.7).
- Cercanía a la familia y amigos (probabilidad 0.9).
- Mayor facilidad para adaptarse al entorno (probabilidad 0.9).

Contras:

- Menor salario (probabilidad 0.3).
- Oportunidades limitadas de crecimiento profesional (probabilidad 0.2).
- Menor posibilidad de adquirir nuevas habilidades y experiencias (probabilidad 0.4).

Probabilidad de éxito si se trabaja en la ciudad diferente:

$$\begin{aligned}P(A) &= P(\text{ProsA}) * P(\text{no ContrásA}) \\P(A) &= 0.9 * (1 - 0.8) * (1 - 0.9) * (1 - 0.6) \\P(A) &= 0.081\end{aligned}$$

Probabilidad de éxito si se trabaja en tu ciudad:

$$\begin{aligned}P(B) &= P(\text{ProsB}) * P(\text{no ContrásB}) \\P(B) &= 0.7 * (1 - 0.3) * (1 - 0.2) * (1 - 0.4) \\P(B) &= 0.42\end{aligned}$$

Calcular la probabilidad total de éxito:

$$\begin{aligned}P(\text{éxito}) &= P(A) + P(B) \\P(\text{éxito}) &= 0.081 + 0.42 \\P(\text{éxito}) &= 0.501\end{aligned}$$



Probabilidad de éxito al trabajar en la ciudad diferente:

$$P(A|\text{éxito}) = P(A) / P(\text{éxito})$$

$$P(A|\text{éxito}) = 0.081 / 0.501$$

$$P(A|\text{éxito}) = 0.162$$

$$P(A|\text{éxito}) = 16.2\%$$

Probabilidad de éxito al trabajar en tu ciudad:

$$P(B|\text{éxito}) = P(B) / P(\text{éxito})$$

$$P(B|\text{éxito}) = 0.42 / 0.501$$

$$P(B|\text{éxito}) = 0.838$$

$$P(B|\text{éxito}) = 83.8\%$$

Interpretación.

En este caso, aunque la opción 1 ofrece un salario más alto, los gastos adicionales y la alta competencia pueden afectar significativamente la utilidad esperada. Por otro lado, la opción 2 puede ofrecer una mayor estabilidad y calidad de vida al evitar los gastos adicionales y tener una mayor probabilidad de ser aceptado. Con base a este análisis, la opción de trabajar en tu ciudad tiene una probabilidad de éxito mayor (83.8%) que la opción de trabajar en la ciudad diferente (16.2%).

2.8 Teorema de Bayes.

El Teorema de Bayes lleva el nombre de Thomas Bayes, un matemático y teólogo británico del siglo XVIII, aunque no fue el primero en formularlo. Ese crédito corresponde al matemático francés Pierre-Simon Laplace, quien enunció formalmente el teorema en el mismo siglo.

Bayes sentó las bases del teorema en un artículo publicado en 1763, donde presentó una nueva forma de calcular probabilidades. Sin embargo, no fue hasta 1812 que Laplace extrajo y demostró formalmente el teorema, utilizándolo para calcular la probabilidad de que un cuerpo celeste fuera un cometa.



A pesar de no ser el primero, el teorema lleva el nombre de Bayes debido a su trabajo pionero en el campo de la probabilidad inversa y la inferencia estadística. Su artículo de 1763 sirvió como punto de partida para el desarrollo de la inferencia bayesiana, una rama fundamental de la estadística. Aunque formulado por Laplace, el Teorema de Bayes se atribuye a Bayes en reconocimiento a su contribución fundamental al área de la probabilidad y la estadística. Hoy en día, es una herramienta esencial en diversos campos, desde la estadística hasta la inteligencia artificial.

2.8.1 Definición

El Teorema de Bayes es un principio fundamental de la teoría de la probabilidad que relaciona las probabilidades condicionales y las probabilidades a priori de un evento. Permite calcular la probabilidad de que ocurra un evento **A** dado que se ha observado otro evento **B**. En otras palabras, el teorema proporciona una forma de actualizar o revisar las creencias sobre un evento **A** a partir de la información obtenida por la evidencia **B**.

El teorema de Bayes se expresa mediante la siguiente fórmula:

$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)}$$

P(A|B): La probabilidad posterior de A dado B. Es la probabilidad de que el evento A ocurra después de haber observado que el evento B ha ocurrido.

P(B|A): La probabilidad condicional de B dado A. Es la probabilidad de que el evento B ocurra si sabemos que el evento A ha ocurrido.

P(A): La probabilidad previa de A. Es la probabilidad de que el evento A ocurra antes de tener en cuenta la nueva evidencia.

P(B): La probabilidad de B. Es la probabilidad de que el evento B ocurra independientemente de A.

Ejemplo.

Tres máquinas A, B, C realizan respectivamente el 10%, 30% y 60% del total de las piezas producidas en una fábrica, los porcentajes de producción defectuosa de las máquinas son

del 1%, 3% y 5% respectivamente. Si se selecciona al azar una pieza de la producción y resulta ser defectuosa ¿Cuál es la probabilidad de haber sido producida por la máquina A?

En este caso de la fórmula original se cambiará la letra, en este caso como se busca la probabilidad de una pieza defectuosa sea de cierta máquina se utilizará la letra D (Defectuosa), quedando la fórmula de la siguiente manera:

$$P(A|D) = \frac{P(D|A) * P(A)}{P(D)}$$

La figura 2.6 muestra el árbol de decisión formado con los datos recabados.

D = Defectuosa.

ND = No Defectuosa.

Como se busca la probabilidad de una pieza defectuosa, se obtiene la probabilidad en este caso para cada máquina de piezas defectuosas.




Figura 2.6 Árbol de decisión del problema.

Se obtiene la probabilidad total defectuosa sumando las probabilidades defectuosas de cada máquina:

$$P(D) = P(D|A) + P(D|B) + P(D|C) = 0.001 + 0.009 + 0.03 = 0.04$$



Se obtiene la probabilidad de que la pieza defectuosa sea de la máquina A.

$$P(A|D) = \frac{P(D|A) * P(A)}{P(D)}$$

$$P(A|D) = \frac{0.01 * 0.1}{0.04}$$

$$P(A|D) = 0.025$$

$$P(A|D) = 0.025 * 100 = 2.5$$

La probabilidad de que la pieza defectuosa haya sido fabricada por la máquina A es de 2.5%.

Como ejercicio propuesto obtenga ¿Cuál es la probabilidad de haber sido producida por la máquina C?.



Tema III

REGLAS Y BÚSQUEDA

Competencia Específica: Resolver problemas en base a técnicas de búsqueda en espacio de estado.

INTRODUCCIÓN.

En este tema se abordan las principales técnicas de búsqueda (primero en anchura, primero en profundidad), se busca solucionar problemas con la implementación de estas técnicas de búsqueda.



3.1 Representación de Conocimiento Mediante Reglas.

Es importante saber que la representación del conocimiento es la forma en que los sistemas de IA almacenan, organizan y utilizan la información sobre el universo para razonar y tomar decisiones. Esto puede incluir datos, hechos, y relaciones entre ellos. El propósito de **representar el conocimiento** es la comprensión y manipulación de información compleja, permitiendo que las computadoras realicen inferencias y resuelvan problemas.

Para poder representar el conocimiento, las **reglas** y la **búsqueda** son dos conceptos fundamentales utilizados para modelar y resolver problemas de manera eficiente. Estos enfoques son ampliamente utilizados para representar el conocimiento y encontrar soluciones óptimas en diversos dominios.

Un ejemplo sencillo de regla podría ser: **Si llueve, entonces lleva un paraguas.**

En esta regla, "llueve" es la **premisa** y "lleva un paraguas" es la **conclusión**. Indica que si la condición "llueve" se cumple, entonces se debe llevar un paraguas.

Las reglas de producción pueden ser utilizadas en diferentes sistemas de IA, como sistemas expertos, sistemas basados en reglas y sistemas de inferencia. Estos sistemas utilizan las reglas para realizar tareas como diagnósticos médicos, tomar decisiones, control de procesos, entre otros.

La representación de conocimiento mediante reglas tiene ventajas y desventajas. Algunas de las ventajas son:

- **Expresividad:** Las reglas permiten capturar conocimiento de manera explícita, lo que facilita su comprensión y modificación.
- **Razonamiento transparente:** Dado que las reglas son comprensibles para los seres humanos, el proceso de razonamiento realizado por los sistemas basados en reglas puede ser entendido y verificado.
- **Flexibilidad:** Las reglas pueden ser modificadas o actualizadas fácilmente, lo que permite adaptar el conocimiento a medida que se adquiere nueva información.



Sin embargo, también existen desafíos y limitaciones en la representación de conocimiento mediante reglas, como:

- **Combinatoriedad:** A medida que aumenta la complejidad de los dominios de conocimiento, el número de reglas puede crecer exponencialmente, lo que dificulta su mantenimiento y gestión.
- **Ambigüedad:** Algunas situaciones pueden presentar ambigüedad o incertidumbre, lo que puede llevar a conflictos o contradicciones entre reglas.
- **Dificultad en la adquisición de conocimiento:** El proceso de adquirir conocimiento y codificarlo en reglas puede requerir la participación de expertos humanos y ser laborioso.

En resumen, las reglas y la búsqueda son conceptos clave en la Inteligencia Artificial para representar conocimiento y encontrar soluciones óptimas. La combinación de reglas para el razonamiento y la búsqueda para la exploración de posibilidades permite abordar problemas complejos de manera eficiente. Estos enfoques desempeñan un papel fundamental en el desarrollo de sistemas de IA capaces de tomar decisiones inteligentes y resolver problemas en diversos dominios.

3.2 Métodos de Inferencia en Reglas.

En el campo de la IA, los métodos de inferencia de reglas son una parte fundamental para realizar razonamiento y toma de decisiones basadas en el conocimiento codificado en forma de reglas. Estos métodos permiten extraer conclusiones lógicas a partir de premisas o condiciones establecidas en las reglas, proporcionando una forma sistemática de inferir nueva información o acciones a partir del conocimiento existente.

Los métodos de inferencia de reglas se utilizan en diversos sistemas de IA, como sistemas expertos, sistemas basados en reglas y sistemas de razonamiento. Estos sistemas se basan en reglas que establecen relaciones entre diferentes conceptos y condiciones, y los métodos de inferencia de reglas permiten evaluar y aplicar estas reglas para resolver problemas en un dominio específico.



Existen diferentes enfoques y técnicas para la inferencia de reglas en la IA, que van desde métodos simples hasta enfoques más avanzados.

Algunos de los métodos comunes son:

- Inferencia hacia adelante (forward chaining). El sistema utiliza las reglas existentes y los hechos conocidos para generar nuevas conclusiones de manera progresiva.
- Inferencia hacia atrás (backward chaining). El sistema comienza con una meta o conclusión deseada y trabaja hacia atrás para determinar qué reglas y hechos son necesarios para alcanzar esa meta.

Estos métodos de inferencia de reglas son especialmente útiles cuando se trata de problemas con un gran número de reglas y condiciones, ya que permiten realizar un razonamiento eficiente y sistemático. Además, los métodos de inferencia de reglas pueden manejar la incertidumbre y la lógica difusa al utilizar técnicas como la lógica difusa o la teoría de la evidencia.

3.3 Reglas de Producción.

Las reglas de producción son una forma de representar el conocimiento de manera estructurada y lógica. Son como pequeñas instrucciones que le decimos a una computadora: “Si se cumple esta condición, entonces haz esto”, el IF-Then que hemos aprendido desde el inicio de nuestro camino en programación que permiten que una computadora o un sistema pueda razonar y tomar decisiones basadas en datos. La simplicidad de las reglas las convierte en una herramienta esencial en el desarrollo de sistemas expertos y otros sistemas basados en conocimiento.

Una regla de producción es una declaración lógica que consta de los siguientes componentes:

- Condición (también llamada antecedente o premisa): Describe el escenario o situación que debe cumplirse.



- **Acción** (también llamada consecuente o conclusión): Es la respuesta o resultado que se ejecuta si la condición se cumple.

Generalmente una regla de producción tiene la estructura de las relaciones SI –
ENTONCES:

SI <premisa> ENTONCES <consecuencia>

Así, la premisa debe ser verdadera para que la regla se active. Puede ser simple como “el cielo está nublado” o Compuesta como “el cielo está nublado” Y “hace frío”. Si la premisa se cumple, entonces la consecuencia es una acción que se ejecuta. De igual forma que las premisas, las consecuencias pueden ser una acción simple como “lleva paraguas” o una acción más compleja que involucre otras reglas.

Ejemplos:

Regla Médica:

SI una persona tiene fiebre, tos y dificultad para respirar, ENTONCES diagnosticar posible COVID-19.

Regla de un Sistema Experto para Configuración de Equipos:

SI la impresora está fuera de línea ENTONCES verificar la conexión USB.

Regla de un Juego:

SI el jugador tiene tres cartas iguales ENTONCES puede bajarlas a la mesa.

Principalmente existen dos tipos de reglas de producción:

1. Reglas de Forward Chaining (Encadenamiento hacia adelante): El sistema comienza con los hechos iniciales y aplica reglas para inferir nuevos hechos hasta llegar a una conclusión.

Ejemplo:



- Hecho: "Juan es un hombre."
- Regla: SI una persona es un hombre, ENTONCES es un ser humano.
- Conclusión: "Juan es un ser humano."

2. Reglas de Backward Chaining (Encadenamiento hacia atrás): El sistema comienza con una hipótesis o conclusión y trabaja hacia atrás para ver si los hechos la apoyan.

Ejemplo:

- Hipótesis: "Juan es un ser humano."
- Regla: SI una persona es un ser humano, ENTONCES es un hombre o una mujer.
- Verificación: Confirmamos que "Juan es un hombre", lo que soporta la hipótesis inicial.

Al terminar el subtema 3.6 se recomienda revisar el complemento educacional 3.2 Aprendizaje basado en estudio de caso, se explica a detalle el funcionamiento de un sistema basado en reglas con encadenamiento hacia adelante y hacia atrás.

3.4 Sintaxis de las Reglas de Producción.

Al entender la sintaxis de las reglas, no solo se aprende a escribirlas correctamente, sino que también se podrán adquirir las herramientas para expresar conocimiento de manera correcta dentro de un sistema de inteligencia artificial, permitiendo que este realice inferencias lógicas y, eventualmente, tome decisiones fundamentadas.

Aunque ya se ha mencionado, se presenta la estructura general de las reglas de producción:

SI <condiciones> ENTONCES <acciones>

De lo anterior se pueden deducir dos elementos básicos:

1. Condición (IF). Expresiones booleanas que determinan si la regla puede detonarse. Puede contener cualquiera de estos componentes.

Expresión lógica:



- Combina variables.
- Constantes.
- Operadores lógicos (AND, OR, NOT) para formar una proposición que puede ser verdadera o falsa.

Variables:

- Representan entidades del dominio del problema.

Constantes:

- Valores fijos.

Operadores lógicos:

- Permiten combinar múltiples condiciones.

2. Acción (THEN). Operaciones o conclusiones que se llevan a cabo si la condición se cumple. Pueden ser del tipo:

Aserción:

- Afirmación de un nuevo hecho.

Modificación:

- Cambio del valor de una variable en la base de hechos.

Llamada a procedimiento:

- Ejecución de un procedimiento externo.

La sintaxis formal de las reglas de producción puede variar ligeramente dependiendo del lenguaje o herramienta utilizada. Sin embargo, la estructura básica es siempre la misma.

Notación general

REGLA <nombre_regla>:

SI <condición1> AND/OR/NOT <condición2> ... AND/OR/NOT <condición_n>

ENTONCES <acción1>, <acción2>, ... <acción_m>

3.5 Semántica de las Reglas de Producción.

El objetivo principal de la semántica de las reglas de producción es garantizar que el motor de inferencia sepa cómo interpretar los hechos y las reglas para hacer inferencias correctas basadas en la lógica del sistema. Para ellos es indispensable la evaluación semántica de las condiciones con respecto a la base de hechos, que es el conjunto de información conocida en ese momento.

En la figura 3.1 se presenta el proceso de evaluación, cuando una nueva entrada o hecho se añade a la base de hechos, el sistema compara el hecho con las condiciones de las reglas de producción. Si una o más reglas tienen condiciones que son satisfechas por los hechos actuales, esas reglas son candidatas para ejecutarse.




Figura 3.1 Evaluación de los hechos y reglas.

Tipos de encadenamiento en la interpretación semántica.

Como se explicó en el subtema 3.3, existen dos tipos de reglas de producción Forward Chaining (Encadenamiento hacia adelante) y Backward Chaining (Encadenamiento hacia atrás) por lo que la interpretación semántica de las reglas cambia:

Encadenamiento hacia adelante.

- El motor de inferencia evalúa todas las reglas cuyas condiciones coinciden con los hechos actuales.



- Si las condiciones son verdaderas, el sistema "dispara" la regla, añadiendo un nuevo hecho a la base de hechos.
- A medida que se añaden más hechos, se vuelven a evaluar las reglas, permitiendo encadenar inferencias.

Ejemplo:

Hecho inicial: temperatura = 39°C.

Regla 1: SI temperatura > 38°C ENTONCES fiebre.

Regla 2: SI fiebre Y tos ENTONCES diagnóstico = gripe.

Hecho adicional: tos.

Primero, se evalúa la Regla 1 y se infiere "fiebre". Luego, se evalúa la Regla 2 con los hechos "fiebre" y "tos", y se llega al diagnóstico "gripe".

Encadenamiento hacia atrás.

- El motor de inferencia identifica una meta o conclusión deseada.
- Luego, busca reglas que puedan derivar esa conclusión, evaluando si las condiciones de esas reglas se pueden cumplir con los hechos disponibles.
- Si los hechos necesarios para cumplir la condición de una regla no están presentes, el sistema buscará más reglas que puedan generar esos hechos.

Ejemplo:

Meta: diagnóstico = gripe.

Regla: SI fiebre Y tos ENTONCES diagnóstico = gripe.

Hechos: temperatura = 39°C.

El sistema busca hechos que validen la condición "fiebre" y "tos". Encuentra "fiebre" (por la Regla 1), y luego solicita si hay tos. Si se confirma, se concluye que la meta "gripe" es verdadera.



Resolución de conflictos.

Ahora ¿qué pasa cuando varias reglas pueden detonarse al mismo tiempo? Aquí el sistema necesita decidir cuál ejecutar primero. A este problema se le conoce como resolución de conflictos y existen varias estrategias para resolverlos:

- **Prioridad:** Algunas reglas tienen prioridad sobre otras. Las reglas más importantes se ejecutan primero.
- **Especificidad:** Las reglas con más condiciones (más específicas) se disparan antes que las más generales.
- **Recencia:** Las reglas que se basan en hechos más recientes son ejecutadas primero.
- **Longitud de la cadena de reglas:** En sistemas con encadenamiento hacia atrás, se prefieren las reglas que proporcionan soluciones en el menor número de pasos.

Ejemplo de resolución de conflictos:

Regla 1: SI fiebre ENTONCES tomar paracetamol.

Regla 2: SI fiebre Y tos ENTONCES ir al médico.

Hechos: fiebre, tos.

La Regla 2 tiene más condiciones y es más específica, por lo que se dispara primero.

La semántica de las reglas de producción es clave para entender cómo un sistema de producción toma decisiones, evalúa condiciones y genera conclusiones. Comprender el funcionamiento semántico de los procesos de encadenamiento, la resolución de conflictos y la actualización de hechos permite diseñar sistemas de inferencia más eficientes.

3.6 Arquitecturas de un Sistema de Producción (SP) o Sistemas Basados en Reglas (SBR).

En el campo de la Inteligencia Artificial (IA), las arquitecturas de un sistema de producción (SP) o sistemas basados en reglas (SBR) son ampliamente utilizadas para representar y utilizar el conocimiento en el razonamiento y la toma de decisiones automatizadas. Estas arquitecturas constan de componentes clave, que incluyen los hechos, la base de conocimientos y el mecanismo de control, que trabajan en conjunto para facilitar el funcionamiento y la efectividad del sistema.

La figura 3.2 presenta la arquitectura de un sistema basado en reglas.




Figura 3.2 Arquitectura de un SBR.

Componentes Básicos de un SBR.

1. Base de hechos.

Es un conjunto de hechos o datos que representan el estado actual del sistema. Esta memoria es dinámica y cambia conforme se ejecutan las reglas.

Ejemplo:

Si es un sistema médico, los hechos podrían ser síntomas del paciente:

- “Fiebre”.
- “Tos”.
- “Dolor de Cabeza”.



2. Conjunto de Reglas de producción.

Las reglas de producción consisten en una condición (SI) y una acción (ENTONCES). Estas reglas determinan cómo modificar la base de hechos.

Ejemplo:

Consideremos un sistema experto para diagnosticar enfermedades. Una regla podría ser:

SI temperatura > 38°C ENTONCES fiebre.

3. Motor de inferencia.

Es el componente que evalúa las reglas y las dispara cuando las condiciones son verdaderas. El motor puede trabajar en dos modos principales: encadenamiento hacia adelante (forward chaining) o encadenamiento hacia atrás (backward chaining).

4. Interfaz de usuario.

Permite al usuario interactuar con el sistema, proporcionando información y recibiendo resultados.

Flujo de trabajo de un sistema de Producción.

El flujo de trabajo en un sistema de producción sigue un ciclo de evaluación y ejecución de reglas, generando así nuevas inferencias hasta que se llegue a una solución o no haya más reglas que disparar.

Evaluación de condiciones.

El motor de inferencia evalúa si las condiciones de las reglas son verdaderas respecto a la base de hechos actual.

Disparo de reglas.

Si la condición de una regla es verdadera, se dispara la regla y se ejecuta la acción correspondiente.



Actualización de la base de hechos

Se añaden o modifican hechos en la base de hechos según lo indicado por la regla disparada.

Reevaluación.

Tras la actualización, el ciclo comienza nuevamente.

3.6.1 Hechos.

Los hechos son declaraciones que representan el estado actual o la información relevante del dominio en el que opera el sistema de producción. Estos hechos pueden ser valores de variables, estados de objetos o cualquier otra información importante para el razonamiento y la toma de decisiones. Los hechos se utilizan como entradas para las reglas de producción, que se evalúan y aplican en función de estos hechos.

3.6.2 Base de Conocimientos.

La base de conocimientos es donde se almacenan y organizan las reglas de producción. Esta base de conocimientos contiene todas las reglas necesarias para el sistema de producción y proporciona el conocimiento e instrucciones para tomar decisiones o realizar acciones. Las reglas de producción se definen y estructuran en la base de conocimientos de acuerdo con la sintaxis y la semántica adecuadas.

3.6.3 Mecanismo de Control.

El mecanismo de control es responsable de gestionar el proceso de inferencia y la aplicación de las reglas de producción. Este mecanismo determina qué reglas deben evaluarse y aplicarse en función de los hechos presentes en un momento dado. Puede utilizar diferentes estrategias de control, como la inferencia hacia adelante (forward chaining) o la inferencia hacia atrás (backward chaining), para guiar el razonamiento y tomar decisiones basadas en el conocimiento almacenado en la base de conocimientos.



3.7 Espacios de Estados Determinísticos y Espacios No Determinísticos.

En el ámbito de la Inteligencia Artificial y la teoría de la computación, se utilizan los conceptos de espacios de estados determinísticos y espacios no determinísticos para describir el comportamiento y la evolución de un sistema. Estos conceptos son fundamentales para comprender cómo se modela y representa el conocimiento en los sistemas inteligentes.

Espacios de estados determinísticos:

Un espacio de estados determinístico es aquel en el que el estado siguiente de un sistema está completamente determinado por el estado actual y las acciones que se toman. En otras palabras, dadas las mismas condiciones iniciales y las mismas acciones, el sistema siempre llegará al mismo estado siguiente. Este tipo de espacios de estados se caracterizan por su predictibilidad y la ausencia de incertidumbre en la evolución del sistema.

En un espacio de estados determinístico, se pueden utilizar algoritmos de búsqueda, como el algoritmo de búsqueda en anchura o el algoritmo de búsqueda en profundidad, para encontrar soluciones óptimas o satisfactorias para un problema dado. Estos algoritmos exploran el espacio de estados de manera sistemática, evaluando las acciones y los estados sucesivos de forma determinística.

Espacios de estados no determinísticos:

En contraste, un espacio de estados no determinístico es aquel en el que el estado siguiente de un sistema no está completamente determinado por el estado actual y las acciones que se toman. En este tipo de espacios de estados, puede haber múltiples resultados posibles para una acción determinada, lo que introduce incertidumbre en la evolución del sistema.

En un espacio de estados no determinístico, se requiere un enfoque diferente para modelar y representar el conocimiento. Se utilizan técnicas como la lógica difusa, la teoría de la probabilidad o la teoría de la toma de decisiones para lidiar con la incertidumbre y la toma de decisiones en presencia de múltiples resultados posibles.

En estos espacios de estados no determinísticos, los algoritmos de búsqueda tradicionales pueden no ser suficientes para encontrar soluciones óptimas. Se pueden utilizar algoritmos



de búsqueda informados, como el algoritmo A* o el algoritmo de búsqueda con adversarios minimax, que consideran la incertidumbre y evalúan las acciones en función de la probabilidad de alcanzar un estado objetivo o de maximizar un resultado esperado.

3.8 Búsqueda Sistemática.

La búsqueda sistemática es un enfoque clave en la resolución de problemas en el campo de la Inteligencia Artificial. Se utiliza para explorar de manera ordenada y exhaustiva un espacio de soluciones en busca de una solución óptima o satisfactoria. En lugar de depender de la intuición o la suerte, la búsqueda sistemática se basa en algoritmos y reglas bien definidas para guiar la exploración del espacio de soluciones.

La búsqueda sistemática implica la evaluación y expansión de sucesivos nodos en el espacio de soluciones. Para lograr esto, se utilizan diferentes estrategias de búsqueda, como la búsqueda en anchura, la búsqueda en profundidad, la búsqueda por costo uniforme y la búsqueda A*, entre otras. Cada estrategia tiene sus propias ventajas y desventajas, y la elección de la estrategia adecuada depende del problema específico y de las restricciones del entorno.

Durante la búsqueda sistemática, se utilizan reglas y heurísticas para determinar qué nodos explorar a continuación y en qué orden. Estas reglas pueden basarse en el conocimiento del dominio, la estructura del problema o la evaluación de las soluciones parciales. A medida que se exploran los nodos, se verifica si se ha alcanzado una solución deseada o se continúa la búsqueda hasta agotar todas las posibilidades.

La búsqueda sistemática es ampliamente utilizada en diversas aplicaciones de la IA, como la planificación de rutas, la resolución de problemas de lógica y la toma de decisiones en entornos complejos. Al seguir un enfoque estructurado y metódico, la búsqueda sistemática permite encontrar soluciones factibles y, en muchos casos, óptimas, contribuyendo así a la automatización y la eficiencia en diversas áreas.



3.8.1 Búsqueda de Metas a Profundidad.

La búsqueda de metas a profundidad es una estrategia utilizada en la búsqueda sistemática que se centra en explorar el espacio de soluciones de manera más profunda antes de expandirse hacia otras áreas. En lugar de expandirse horizontalmente hacia los sucesores de un nodo, esta estrategia se adentra verticalmente en un camino específico hasta llegar a un punto en el que ya no hay más nodos sucesores por explorar.

La búsqueda de metas a profundidad utiliza una estructura de datos llamada pila, que sigue el principio de "último en entrar, primero en salir" (LIFO). Esto significa que los nodos sucesores se agregan a la pila y se exploran en el orden inverso al que se agregaron. Esta estrategia permite explorar un camino específico en profundidad antes de retroceder y explorar otros caminos.

Una ventaja de la búsqueda de metas a profundidad es que puede encontrar soluciones rápidamente en espacios de soluciones grandes. Sin embargo, no garantiza encontrar la solución óptima, ya que puede quedarse atrapada en un camino no óptimo antes de explorar otras alternativas.

En el complemento educacional 3.3 Aprendizaje basado en problemas, se explica a detalle el funcionamiento de la búsqueda a profundidad y anchura.

3.8.2 Búsqueda de Metas en Anchura.

La búsqueda de metas en anchura es otra estrategia utilizada en la búsqueda sistemática, pero a diferencia de la búsqueda de metas a profundidad, se explora el espacio de soluciones de manera más amplia antes de profundizar en cada nivel. En esta estrategia, se exploran todos los sucesores de un nodo antes de pasar a explorar los sucesores de los nodos vecinos.

Para implementar la búsqueda de metas en anchura, se utiliza una estructura de datos llamada cola, que sigue el principio de "primero en entrar, primero en salir" (FIFO). Esta



estrategia garantiza que se encuentre la solución óptima si existe, pero puede ser más costosa en términos de memoria y tiempo computacional cuando el espacio de soluciones es muy amplio.

En el complemento educacional 3.3 Aprendizaje basado en problemas, se explica a detalle el funcionamiento de la búsqueda a profundidad y anchura.



Tema IV

APLICACIONES CON TÉCNICAS DE IA

Competencia Específica: Conocer las áreas de la IA y sus aplicaciones actuales, identificando oportunidades de desarrollo de soluciones en su entorno.

INTRODUCCIÓN.

En este tema se clasifican las diferentes áreas de la IA, en cada una de ellas se presenta la situación actual y se analizan problemas que pueden tener solución con el uso de la IA.





4.1 Robótica.

4.1.1 Concepto Básicos.

La robótica es una disciplina que se dedica al diseño, operación, fabricación, estudio y aplicación de autómatas o robots. Para lograrlo, integra conocimientos de ingeniería mecánica, ingeniería eléctrica, ingeniería electrónica, ingeniería biomédica y ciencias de la computación, entre otras áreas. La robótica simboliza el pináculo del progreso tecnológico y del diseño de herramientas. Su objetivo es crear dispositivos capaces de realizar numerosas tareas que hoy en día realiza el ser humano, pero de manera más eficiente y rápida, o en condiciones y entornos que serían inaccesibles para las personas.

La robótica representa la cumbre en la trayectoria de desarrollo tecnológico, es decir, del diseño de herramientas. Su cometido es construir una herramienta que pueda desempeñar muchas de las labores que actualmente desempeña el ser humano, de manera más eficiente y rápida, o en condiciones y ambientes que al ser humano le serían inaccesibles.

La palabra robot proviene del vocablo checo robota, que significa literalmente “esclavo”. Fue puesto en circulación por el escritor checo Karel Capek (1890-1938) con su novela R.U.R. (Robots Universales Rossum) de 1920.

Igualmente, la palabra robótica, entendida como disciplina, fue acuñada por Isaac Asimov (1920-1992). Este escritor de Ciencia Ficción fue uno de los más célebres cultores del futuro imaginario robotizado.

4.1.2 Clasificación.

La clasificación de la robótica puede variar según el enfoque y el contexto, dentro de las cuales se puede encontrar:

Según la aplicación:

- Robótica industrial: Se centra en la automatización de procesos en entornos de fabricación y producción.
- Robótica de servicio: Diseñada para interactuar con humanos y realizar tareas en entornos no estructurados, como la robótica médica, la robótica doméstica y la robótica de asistencia.



Según el grado de autonomía:

- Robots autónomos: Pueden realizar tareas sin intervención humana.
- Robots semiautónomos: Requieren alguna forma de intervención humana para completar tareas o tomar decisiones.

Según la estructura:

- Robots móviles: Diseñados para moverse en su entorno, como robots terrestres, aéreos o acuáticos.
- Robots estacionarios: Permanecen en un solo lugar y realizan tareas específicas en ese lugar.

Según la morfología:

- Robots con forma humanoide: Tienen una apariencia y estructura similar a la humana.
- Robots con forma no humanoide: Tienen formas y estructuras diversas, adaptadas a su función específica.

Según la complejidad de las tareas:

- Robots simples: Diseñados para realizar tareas repetitivas y relativamente simples.
- Robots complejos: Capaces de realizar una variedad de tareas complejas y adaptarse a entornos cambiantes.

Según el entorno de trabajo:

- Robótica espacial: Diseñada para operar en entornos espaciales, como en la exploración planetaria.
- Robótica submarina: Diseñada para operar en entornos submarinos, como la exploración oceánica y la industria offshore.

Otra clasificación es la época o generación en la que se desarrollaron, existen cuatro tipologías de robot:

1. Robots de primera generación, son los robots más básicos (manipuladores): están destinados a la manipulación y cuentan con sistemas mecánicos que pueden funcionar de dos maneras: por secuencia fija o variable.
2. Robots de segunda generación, son robots que aprenden. Es decir, cuentan con un sistema de aprendizaje que consiste en repetir una secuencia de movimientos



previamente realizada y programada por un operario (o sea, un ser humano) que indique, por un lado, el proceso y, por otro, la ejecución del mismo.

3. Robots de tercera generación, robots con control sensorizado, el operario es sustituido por un ordenador. De esta manera, el ordenador determina los movimientos y ejecuta las órdenes de programación.
4. Robots de cuarta generación, robots inteligentes, son los más avanzados y los que se utilizan desde hace varios años en las empresas más pioneras. En este tipo de robots se hace uso del IoT y la Inteligencia Artificial. Se trata de robots inteligentes: poseen un número mayor de sensores y existe una doble dirección de información, por lo que el ordenador es capaz de recibir información en tiempo real y puede adelantarse a sus necesidades.

También se pueden clasificar con base a la arquitectura del robot, la arquitectura, es definida por el tipo de configuración general del Robot, puede ser metamórfica. El concepto de metamorfismo, de reciente aparición, se ha introducido para incrementar la flexibilidad funcional de un robot a través del cambio de su configuración por el propio robot. La subdivisión de los robots, con base en su arquitectura, se hace en los siguientes grupos: Poliarticulados, Móviles, Zoomórficos e Híbridos.

- Poliarticulados. En este grupo están los robots de muy diversa forma y configuración cuya característica común es la de ser básicamente sedentarios (aunque excepcionalmente pueden ser guiados para efectuar desplazamientos limitados) y estar estructurados para mover sus elementos terminales en un determinado espacio de trabajo según uno o más sistemas de coordenadas y con un número limitado de grados de libertad. En este grupo se encuentran los manipuladores, los Robots industriales, los robots cartesianos y se emplean cuando es preciso abarcar una zona de trabajo relativamente amplia o alargada, actuar sobre objetos con un plano de simetría vertical o reducir el espacio ocupado en el suelo. Tienen muchas piezas móviles. La figura 4.1 muestra un ejemplo de este tipo de robots.



Figura 4.1 Ejemplo de robots poliarticulados.

- **Móviles.** Son de tipo rodante o automotor (ver figura 4.2). Son robots con gran capacidad de desplazamiento, basadas en carros o plataformas y dotados de un sistema locomotor de tipo rodante. Siguen su camino por telemando o guiándose por la información recibida de su entorno a través de sus sensores. Estos robots aseguran el transporte de piezas de un punto a otro de una cadena de fabricación, guiados mediante pistas materializadas a través de la radiación electromagnética de circuitos empotrados en el suelo, o a través de bandas detectadas fotoeléctricamente, pueden incluso llegar a sortear obstáculos y están dotados de un nivel relativamente elevado de inteligencia.



Figura 4.2 Ejemplo de robots móviles.

- **Zoomórficos.** Imitan la forma de algunos animales. Los Robots zoomórficos, que considerados en sentido no restrictivo podrían incluir también a los androides, constituyen una clase caracterizada principalmente por sus sistemas de locomoción que imitan a los diversos seres vivos. A pesar de la disparidad morfológica de sus

posibles sistemas de locomoción es conveniente agrupar a los robots zoomórficos en dos categorías principales: caminadores y no caminadores. El grupo de los robots zoomórficos no caminadores está muy poco evolucionado. Los experimentados efectuados en Japón basados en segmentos cilíndricos biselados acoplados axialmente entre sí y dotados de un movimiento relativo de rotación. Los robots zoomórficos caminadores múltiples son muy numerosos y están siendo experimentados en diversos laboratorios con vistas al desarrollo posterior de verdaderos vehículos terrenos, piloteando o autónomos, capaces de evolucionar en superficies muy accidentadas. Las aplicaciones de estos robots serán interesantes en el campo de la exploración espacial y en el estudio de los volcanes. La figura 4.3 muestra un ejemplo de este tipo de robots.



Figura 4.3 Ejemplo de robots zoomórficos.

- Antropomórficos. Imitan la forma del ser humano. Son robots que intentan reproducir total o parcialmente la forma y el comportamiento cinemática del ser humano. Actualmente los androides son todavía dispositivos muy poco evolucionados y sin utilidad práctica, y destinados, fundamentalmente, al estudio y experimentación. Uno de los aspectos más complejos de estos robots, y sobre el que se centra la mayoría de los trabajos, es el de la locomoción bípeda. En este caso, el principal problema es controlar dinámicamente y coordinadamente en el tiempo real el proceso y mantener simultáneamente el equilibrio del robot. La figura 4.4 muestra un ejemplo de este tipo de robots.



Figura 4.4 Ejemplo de robots zoomórficos.

4.1.3 Desarrollos Actuales y Aplicaciones.

Los robots son utilizados en una diversidad de aplicaciones, desde robots tortugas en los salones de clases, robots soldadores en la industria automotriz, hasta brazos teleoperados en el transbordador espacial. Cada robot lleva consigo su problemática propia y sus soluciones afines; no obstante que mucha gente considera que la automatización de procesos a través de robots está en sus inicios, es un hecho innegable que la introducción de la tecnología robótica en la industria, ya ha causado un gran impacto.

La perspectiva para el sector de la robótica viene marcada por una serie de tendencias que harán que los robots móviles autónomos sean más accesibles para un mayor número de industrias, innovación tecnológica, robots más inteligentes y nuevos escenarios.

Inteligencia Artificial.

La IA ha sido tema central, uno de los ejes de la robótica móvil y de la automatización (además de la navegación y el procesamiento de grandes cantidades de datos), es el desarrollo de software que permite ofrecer soluciones más adaptadas a las necesidades de cada industria. En este sentido, la Inteligencia Artificial, aporta una mayor conectividad humano-robot, más autonomía y complejidad en las tareas que ejecutan, y más capacidad de colaboración.

Robots Colaborativos.

La mayoría de las industrias, independientemente de su naturaleza (centros de distribución, fábricas, almacenes, centros logísticos), cuentan con espacios de trabajo en los que intervienen tanto robots como personas. Por ello, la robótica colaborativa es más demandada que nunca, ya que garantiza la seguridad en este tipo de escenarios y facilita el despliegue de robots móviles sin necesidad de modificar la infraestructura. La figura 4.5 muestra un ejemplo de este tipo de robots.



Figura 4.5 Ejemplo de robots colaborativos.

Robótica en el Sector de la Logística.

La escasez de mano de obra y la alta competitividad por la globalización del sector, ponen de manifiesto la urgente necesidad de agilizar los procesos productivos de entornos logísticos. Los robots manipuladores móviles (ver figura 4.6) realizan tareas de transporte de mercancías, manipulación de piezas, control de stock o alimentación de líneas de producción de manera autónoma, constante y rápida, sin interrupción.



Figura 4.6 Ejemplo de robots manipuladores móviles.

Nuevos Roles para los Robots.

La evolución de la IA es precisamente lo que posibilita que haya robots móviles autónomos asumiendo nuevos roles, más allá de la automatización tradicional. Los robots saldrán de los almacenes para aumentar su presencia en espacios públicos y entornos exteriores más desestructurados donde previsiblemente ejecutarán tareas más inteligentes. La figura 4.7 muestra un ejemplo de este tipo de robots.



Figura 4.7 Ejemplo de robots móviles autónomos.

Flotas de Robots.

Termina la etapa en la que las compañías incorporaban a sus procesos de trabajo únicamente 1 o 2 AMR (Robots Móviles Autónomos), dejando atrás el escepticismo sobre el valor que realmente éstos podían aportar. Actualmente la apuesta en automatización, se orienta hacia el despliegue de grandes flotas de robots que supongan un verdadero impulso para la productividad. La figura 4.8 muestra un ejemplo de este tipo de robots.



Figura 4.8 Ejemplo de flotas de robots.

4.2. Redes Neuronales (RN).

4.2.1 Conceptos Básicos.

Existen numerosas formas de definir a las redes neuronales; desde las definiciones cortas y genéricas hasta las que intentan explicar más detalladamente qué son las redes neuronales. Por ejemplo:

1. Una nueva forma de computación, inspirada en modelos biológicos.
2. Un modelo matemático compuesto por un gran número de elementos procesales organizados en niveles.
3. Un sistema de computación compuesto por un gran número de elementos simples, elementos de procesos muy interconectados, los cuales procesan información por medio de su estado dinámico como respuesta a entradas externas.



4. Redes neuronales artificiales son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico.

Las RN fueron originalmente una simulación abstracta de los sistemas nerviosos biológicos, formados por un conjunto de unidades llamadas neuronas o nodo conectadas unas con otras. Estas conexiones tienen una gran semejanza con las dendritas y los axones en los sistemas nerviosos biológicos.

Una red neuronal es un modelo matemático que se compone de nodos interconectados, llamados neuronas artificiales. Estas neuronas están organizadas en capas y se comunican entre sí a través de conexiones, que se representan mediante pesos. Los datos ingresan a la red en la capa de entrada, se procesan a través de las capas ocultas y se obtiene un resultado en la capa de salida.

En términos generales, el primer modelo de red neuronal fue propuesto en 1943 por McCulloch y Pitts en términos de un modelo computacional de actividad nerviosa. El modelo de McCulloch-Pitts es un modelo binario, y cada neurona tiene un escalón o umbral prefijado. Este primer modelo sirvió de ejemplo para los modelos posteriores de Jhon Von Neumann, Marvin Minsky, Frank Rosenblatt, y muchos otros.

Lo que hace que las redes neuronales sean increíbles es su capacidad para aprender y adaptarse a partir de los datos. Durante el proceso de entrenamiento, la red ajusta los pesos de las conexiones para optimizar su rendimiento en una tarea específica. Esto se logra mediante el algoritmo de retro propagación, que utiliza el gradiente descendente para minimizar el error entre las salidas predichas y las salidas deseadas.

De la misma manera que funciona el cerebro humano, las redes neuronales artificiales más avanzadas cuentan con cientos de miles de unidades de procesamiento interconectadas por nodos. Las mismas reciben, procesan y transmiten la información, como nuestras neuronas.

Dentro de esas unidades de procesamiento, la información recibida se analiza de acuerdo a parámetros establecidos que le permiten obtener y transmitir un resultado hacia la próxima unidad.

Una red neuronal es un método de la inteligencia artificial que enseña a las computadoras a procesar datos de una manera que está inspirada en la forma en que lo hace el cerebro humano. Se trata de un tipo de proceso de machine learning llamado aprendizaje profundo, que utiliza los nodos o las neuronas interconectados en una estructura de capas que se parece al cerebro humano. Crea un sistema adaptable que las computadoras utilizan para aprender de sus errores y mejorar continuamente. De esta forma, las redes neuronales artificiales intentan resolver problemas complicados, como la realización de resúmenes de documentos o el reconocimiento de rostros, con mayor precisión. La figura 4.9 muestra la estructura de una red neuronal artificial.




Figura 4.9 Estructura de una red neuronal artificial.

Entre sus ventajas se encuentran.

Debido a su constitución y a sus fundamentos, las redes neuronales artificiales presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante. Esto



hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas. Entre las ventajas se incluyen:

- **Aprendizaje Adaptativo.** Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.
- **Auto-organización.** Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.
- **Tolerancia a fallos.** La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.
- **Operación en tiempo real.** Los cómputos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.
- **Fácil inserción dentro de la tecnología existente.** Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilitará la integración modular en los sistemas existentes.

4.2.2. Clasificación.

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

Redes neuronales prealimentadas (Feedforward).

Las redes neuronales prealimentadas procesan los datos en una dirección, desde el nodo de entrada hasta el nodo de salida. Todos los nodos de una capa están conectados a todos los nodos de la capa siguiente. Una red prealimentada utiliza un proceso de retroalimentación para mejorar las predicciones a lo largo del tiempo. La figura 4.10 muestra una red neuronal prealimentada.




Figura 4.10 Estructura de una red neuronal prealimentada.

Redes neuronales recurrentes (FeedBack).

En las redes recurrentes, la información puede recorrer también ciclos de feedback, volviendo atrás a través de las capas. La **retroalimentación** permite que el sistema desarrolle una memoria. Este tipo de redes se usan, por ejemplo, para el reconocimiento de voz, la traducción y el reconocimiento de texto manuscrito. Una red neuronal recurrente se compone de tres capas y la capa oculta o hidden layer está conectada tanto en dirección a la capa de entrada como a la de salida. La figura 4.11 muestra una red neuronal recurrente.




Figura 4.11 Estructura de una red neuronal recurrente.

Redes neuronales convolucionales (ConvNets).

Estas redes son una subcategoría de las redes de muchas capas; en concreto, han de tener al menos cinco. En cada una de ellas se realiza un reconocimiento de patrones cuyo resultado se transmite a la siguiente capa. Este tipo de redes neuronales son útiles en variadas aplicaciones dentro del machine learning, sin embargo, donde ha conseguido revolucionar el estado del arte es en la visión artificial y el procesamiento de imágenes. Lo que caracteriza a este tipo de redes es que es capaz de aprender en las primeras capas una serie de características básicas de la imagen, como son líneas o formas más o menos simples (ver figura 4.12). En posteriores fases aprende a discriminar entre elementos más complejos, como ojos u orejas. Finalmente, en capas más profundas son capaces de diferenciar objetos complejos, como personas, perros, gatos o coches.




Figura 4.12 Red neuronal convolucional para el tratamiento de imágenes.

Mecanismos de Aprendizaje.

Los datos de entrada se procesan a través de la red neuronal con el propósito de lograr una salida. Una red neuronal debe aprender a calcular la salida correcta para cada constelación (arreglo o vector) de entrada en el conjunto de ejemplos. Este proceso de aprendizaje se denomina: proceso de entrenamiento o acondicionamiento. El conjunto de datos (o



conjunto de ejemplos) sobre el cual este proceso se basa es, por ende, llamado: conjunto de datos de entrenamiento.

Si la topología de la red y las diferentes funciones de cada neurona (entrada, activación y salida) no pueden cambiar durante el aprendizaje, mientras que los pesos sobre cada una de las conexiones si pueden hacerlo; el aprendizaje de una red neuronal significa: adaptación de los pesos.

En otras palabras, el aprendizaje es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el mismo se reducen a la destrucción, modificación y creación de conexiones entre las neuronas. En los sistemas biológicos existe una continua destrucción y creación de conexiones entre las neuronas. En los modelos de redes neuronales artificiales, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero. De la misma manera, una conexión se destruye cuando su peso pasa a ser cero.

Hay dos métodos de aprendizaje importantes que pueden distinguirse:

- **Aprendizaje supervisado.** El aprendizaje supervisado se caracteriza porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (supervisor, maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor controla la salida de la red y en caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida obtenida se aproxime a la deseada.
- **Aprendizaje no supervisado.** Las redes con aprendizaje no supervisado (también conocido como autosupervisado) no requieren influencia externa para ajustar los pesos de las conexiones entre sus neuronas. La red no recibe ninguna información por parte del entorno que le indique si la salida generada en respuesta a una determinada entrada es o no correcta. Estas redes deben encontrar las características, regularidades, correlaciones o categorías que se puedan establecer entre los datos que se presenten en su entrada. Existen varias posibilidades en



cuanto a la interpretación de la salida de estas redes, que dependen de su estructura y del algoritmo de aprendizaje empleado.

4.2.3. Desarrollos Actuales y Aplicaciones.

Las redes neuronales están presentes en varios casos de uso en muchos sectores, entre ellos se encuentran:

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

Entre las aplicaciones más importantes se encuentran:

1. Visión artificial: La visión artificial es la capacidad que tienen las computadoras para extraer información y conocimientos de imágenes y videos. Con las redes neuronales, las computadoras pueden distinguir y reconocer imágenes de forma similar a los humanos. La visión artificial tiene varias aplicaciones, como las siguientes:
 - Reconocimiento visual en los vehículos autónomos para que puedan reconocer las señales de tráfico y a otros usuarios del camino.
 - Moderación de contenido para eliminar de forma automática los contenidos inseguros o inapropiados de los archivos de imágenes y videos.
 - Reconocimiento facial para identificar rostros y reconocer atributos como ojos abiertos, gafas y vello facial.



- Etiquetado de imágenes para identificar logotipos de marcas, ropa, equipos de seguridad y otros detalles de la imagen.
2. Reconocimiento de voz: Las redes neuronales pueden analizar el habla humana a pesar de los diferentes patrones de habla, el tono, el idioma y el acento. Los asistentes virtuales como Amazon Alexa y el software de transcripción automática utilizan el reconocimiento de voz para realizar tareas como las siguientes:
- Asistir a los agentes de los centros de llamadas y clasificar las llamadas de forma automática.
 - Convertir las conversaciones clínicas en documentación en tiempo real.
 - Subtitular con precisión videos y grabaciones de reuniones para aumentar el alcance del contenido.
3. Procesamiento de lenguaje natural: Es la capacidad de procesar texto natural creado por humanos. Las redes neuronales ayudan a las computadoras a obtener información y significado a partir de los datos y los documentos de texto. El procesamiento de lenguaje natural está presente en varios casos de uso, entre los que se incluyen los siguientes:
- Chatbots y agentes virtuales automatizados.
 - Organización y clasificación automáticas de datos escritos.
 - Análisis de inteligencia empresarial de documentos con formato largo, como emails y formularios.
 - Indexación de frases clave que indican sentimientos, como los comentarios positivos y negativos en las redes sociales.
 - Resumen de documentos y producción de artículos para un tema determinado.
4. Motores de recomendaciones: Las redes neuronales pueden hacer un seguimiento de la actividad del usuario para elaborar recomendaciones personalizadas. También pueden analizar todo el comportamiento de los usuarios y descubrir productos o servicios nuevos que interesen a un usuario específico.



4.3. Visión Artificial.

4.3.1 Conceptos Básicos.

La visión artificial es un campo de la IA que permite que las computadoras y los sistemas obtengan información significativa de imágenes digitales, videos y otras entradas visuales, y tomen acciones o hagan recomendaciones basadas en esa información. Si la IA permite que las computadoras piensen, la visión artificial les permite ver, observar y comprender.

La visión artificial funciona de manera muy similar a la visión humana, excepto que los humanos tienen una ventaja. La vista humana tiene la ventaja de las experiencias y los contextos aprendidos para diferenciar entre los objetos, qué tan lejos están, si se están moviendo o si hay algo mal en una imagen.

La visión artificial es una tecnología que utilizan las máquinas para reconocer automáticamente las imágenes y describirlas de manera precisa y eficiente. Hoy en día, los sistemas informáticos tienen acceso a un gran volumen de imágenes y datos de video procedentes o creados por teléfonos inteligentes, cámaras de tráfico, sistemas de seguridad y otros dispositivos. Las aplicaciones de visión artificial utilizan inteligencia artificial y el machine learning para procesar estos datos con precisión para la identificación de objetos y el reconocimiento facial, así como para la clasificación, la recomendación, el monitoreo y la detección.

4.3.2. Desarrollo Actuales y Aplicaciones.

La visión artificial es una de las áreas en el machine learning donde los conceptos fundamentales ya se están integrando en los principales productos que se utilizan día a día, como son:

- Visión artificial en coches autónomos: Permite a los coches autónomos dar sentido a su entorno. Las cámaras capturan vídeo desde diferentes ángulos alrededor del coche y lo transmiten al software de visión artificial, que luego procesa las imágenes en tiempo real para encontrar los extremos de las carreteras, leer las señales de tráfico, detectar otros coches, objetos y peatones. El coche autónomo



puede orientarse en calles y carreteras, evitar chocar con obstáculos y conducir con seguridad a sus pasajeros hasta su destino.

- **Reconocimiento facial:** Los algoritmos de la visión artificial detectan los rasgos faciales en las imágenes y los comparan con las bases de datos de los perfiles de las caras. Los dispositivos de consumo utilizan el reconocimiento facial para autenticar las identidades de sus propietarios. Las aplicaciones de medios sociales utilizan el reconocimiento facial para detectar y etiquetar a los usuarios. Los organismos encargados de hacer cumplir la ley también recurren a la tecnología de reconocimiento facial para identificar a las personas que cometen algún delito.
- **Realidad aumentada y realidad mixta:** Esta tecnología permite que dispositivos informáticos como teléfonos inteligentes, tabletas y gafas inteligentes se superpongan e incrusten objetos virtuales en imágenes del mundo real. Utilizando la visión artificial, los equipos de realidad aumentada detectan objetos en el mundo real para determinar las ubicaciones en la pantalla de un dispositivo y colocar un objeto virtual. Por ejemplo, detectar planos de mesas, paredes y pisos, para establecer la profundidad y las dimensiones de los objetos para transformarlos en objetos virtuales en el mundo físico.

4.4. Lógica Difusa (Fuzzy Logic).

4.4.1. Conceptos Básicos.

Fuzzy Logic (FL) es un método de razonamiento que se asemeja al razonamiento humano (lógica clásica). Este enfoque es similar a cómo los humanos realizan la toma de decisiones, involucra todas las posibilidades intermedias entre SÍ y NO (lógica difusa). La lógica difusa fue inventada por Lotfi Zadeh quien observó que, a diferencia de las computadoras, los humanos tienen un rango diferente de posibilidades entre SÍ y NO. La figura 4.13 muestra la diferencia entre la lógica clásica y difusa.




Figura 4.13 Diferencia entre lógica clásica y difusa.

La lógica difusa tiene varios tipos y extensiones, cada uno con sus propias características y aplicaciones. Algunos de los tipos más comunes son:

- **Lógica Difusa Tipo-1:** Es el tipo más básico de lógica difusa, donde las funciones de membresía son definidas de manera tradicional. Cada variable lingüística tiene una función de membresía que asigna un grado de pertenencia a cada valor en su conjunto de valores. Este tipo se utiliza ampliamente en una variedad de aplicaciones.
- **Lógica Difusa Tipo-2:** En este tipo, las funciones de membresía pueden ser más complejas, permitiendo la incertidumbre en la propia definición de la función de membresía. Esto proporciona una mayor flexibilidad en la modelización de la incertidumbre, pero también puede requerir un mayor esfuerzo computacional.
- **Lógica Difusa Intervalar:** En lugar de asignar un valor de pertenencia a un conjunto difuso, la lógica difusa intervalar asigna un intervalo de valores de pertenencia. Esto permite modelar la incertidumbre de una manera más precisa, especialmente cuando los límites de los conjuntos difusos no son exactos.
- **Lógica Difusa Generalizada:** Este tipo extiende la lógica difusa tradicional para manejar diferentes tipos de incertidumbre, como la incertidumbre epistémica y la incertidumbre aleatoria. Se utiliza en situaciones donde la incertidumbre es más compleja y requiere un modelado más sofisticado.
- **Lógica Difusa Multi-valorada:** En lugar de tener conjuntos difusos con valores de pertenencia en el rango de $[0, 1]$, la lógica difusa multi-valorada permite conjuntos



con grados de pertenencia en un rango más amplio, como $[0, n]$, donde n es un número entero positivo.

4.4.2. Desarrollos Actuales y Aplicaciones.

La lógica difusa ha experimentado muchos desarrollos y aplicaciones en diversas áreas desde su concepción. Algunos de los desarrollos actuales y aplicaciones notables incluyen:

- **Sistemas de Control Difuso:** Los sistemas de control difuso son ampliamente utilizados en diversas industrias, como la automotriz, la electrónica, la robótica y la automatización industrial. Estos sistemas permiten controlar sistemas complejos en los que las entradas y salidas no son precisas o están sujetas a variaciones. Por ejemplo, los sistemas de control difuso se utilizan en sistemas de climatización, control de velocidad en vehículos, control de procesos industriales.
- **Sistemas de Soporte a la Decisión:** La lógica difusa se utiliza en sistemas de soporte a la decisión para modelar y resolver problemas complejos en los que la información disponible es incompleta o incierta. Por ejemplo, en sistemas de diagnóstico médico, sistemas de evaluación crediticia, sistemas de gestión de inventario.
- **Sistemas de Reconocimiento de Patrones y Minería de Datos:** La lógica difusa se utiliza en aplicaciones de reconocimiento de patrones y minería de datos para modelar relaciones complejas entre variables y extraer información útil de grandes conjuntos de datos. Por ejemplo, en sistemas de reconocimiento facial, sistemas de recomendación, análisis de sentimientos.
- **Aplicaciones en Robótica y Automatización:** La lógica difusa se utiliza en robótica y automatización para modelar el comportamiento de robots y sistemas automatizados en entornos complejos y variables. Por ejemplo, en sistemas de navegación de robots, sistemas de control de tráfico aéreo, sistemas de control de tráfico vehicular.
- **Aplicaciones en Ingeniería de Software:** La lógica difusa se utiliza en ingeniería de software para modelar y gestionar la incertidumbre en el desarrollo de sistemas



software. Por ejemplo, en sistemas de recomendación de calidad de software, sistemas de detección de errores.

4.5. Procesamiento de Lenguaje Natural (PLN).

4.5.1. Conceptos Básicos.

Procesamiento de Lenguaje Natural, rama de la inteligencia artificial que analiza, entiende y genera los lenguajes que los humanos usan naturalmente para relacionarse con la computadora.

Lingüística, es la disciplina que se ocupa del estudio científico del lenguaje.

Lenguaje formal, es un lenguaje artificial o sea creado por el hombre que está formado por símbolos y formulas y que tiene como objetivo fundamental formalizar la programación de computadoras o representar simbólicamente un conocimiento.

El procesamiento de lenguaje natural, combina la lingüística computacional (modelado del lenguaje humano basado en reglas) con modelos estadísticos y de aprendizaje automático para permitir que las computadoras y los dispositivos digitales reconozcan, comprendan y generen texto y voz.

El PLN se encuentra en el centro de las aplicaciones y dispositivos que pueden:

- Traducir texto de un idioma a otro.
- Responder a comandos escritos o hablados.
- Reconocer o autenticar a los usuarios en función de la voz.
- Resumir grandes volúmenes de texto.
- Evaluar la intención o el sentimiento del texto o voz.
- Generar texto o gráficos u otro contenido bajo demanda.

El procesamiento de lenguaje natural combina el lenguaje de los ordenadores con el aprendizaje automático (figura 4.14), y la Inteligencia Artificial, para procesar el lenguaje humano de forma similar a cómo lo hacen las personas.

Los elementos del lenguaje a simular son:

- **Análisis morfológico:** El texto se fragmenta en palabras, asignándoles información sobre su categoría gramatical (sustantivo, verbo, adjetivo, etc.) y su significado.
- **Análisis sintáctico:** Se analiza la estructura de las oraciones para determinar las relaciones entre las palabras y cómo se construye el significado a nivel de frase.
- **Análisis semántico:** Se determina el significado de palabras y oraciones en el contexto del texto. Para ello, se utilizan técnicas como la semántica léxica.
- **Análisis pragmático:** Va más allá del significado literal, se analiza el contexto del texto. De esta forma, se puede comprender la intención del autor y el sentido completo del mensaje.




Figura 4.14 Elementos del PLN.

4.5.2. Desarrollos Actuales y Aplicaciones.

El procesamiento del lenguaje natural es la fuerza impulsora detrás de la inteligencia artificial en muchas aplicaciones modernas del mundo real. Estos son algunos ejemplos:

- **Agentes virtuales.** Los agentes virtuales, como Siri de Apple y Alexa de Amazon, utilizan el reconocimiento de voz para reconocer patrones en los comandos de voz y la generación de lenguaje natural para responder con la acción adecuada o comentarios útiles.



- Herramientas conversacionales. Los chatbots son herramientas que responden a palabras clave que han identificado en los mensajes de un usuario. El objetivo de estos sistemas es que logren ofrecer respuestas útiles a las solicitudes de las personas con las que interactúan de forma rápida, precisa y dentro de ciertos límites temáticos.

La ventaja que ofrecen estos recursos tecnológicos es que tienen la capacidad de aprender a partir de nuevas interacciones y de perfeccionar el tipo de respuestas que ofrecen según el nivel de sofisticación de cada uno. Además, son muy útiles para atender consultas sencillas pero comunes.

- Autocorrección de texto El sistema identifica cuando una palabra ha sido mal escrita. En muchos casos, se puede activar la función de autocompletar o autocorregir en el equipo de cómputo para hacer la escritura más ágil y con menos errores. Además, los programas tienen cada vez más diccionarios integrados en uno o más idiomas. Lo genial de estos sistemas es que pueden alimentarse y aprender según lo permita el usuario, porque agregan o eliminan palabras al diccionario dependiendo de sus hábitos para un trabajo más eficiente.
- Análisis de sentimiento en las redes sociales: El PLN se ha convertido en una herramienta comercial esencial para descubrir insights de datos ocultos de los canales de redes sociales. El análisis de sentimientos puede analizar el lenguaje utilizado en las publicaciones en redes sociales, respuestas, reseñas y más para extraer actitudes y emociones en respuesta a productos, promociones y eventos: información que las empresas pueden usar en diseños de productos, campañas publicitarias y más.
- Traductores de texto Los traductores de texto son herramientas que se nutren de forma importante de los sistemas de PLN. Esto se debe a que el mensaje de un texto no solo puede interpretarse de forma literal y palabra por palabra, sino que requiere la comprensión de arreglos de lenguaje más complejos, como expresiones, usos cotidianos y regionalismos. Esto exige que los traductores sepan procesar más información que solo caracteres.



- Detección de spam en el correo electrónico. Los PLN son herramientas ideales para encontrar patrones a lo largo de grandes volúmenes de información. Las palabras clave son las que permiten que el sistema de un correo electrónico logre clasificar ciertos mensajes como no deseados, además de realizar un análisis de seguridad en búsqueda de software que tiene potencial de dañar un dispositivo o robar información sensible. Es lo que también posibilita que ya puedas clasificar tu correo en favorito, publicidad o social, tal como lo hace Gmail para una mejor gestión de tus mensajes
- Síntesis de voz. Además de utilizarse para las instrucciones de voz a un asistente virtual, los sistemas de PLN son la tecnología que está detrás de los motores de reconocimiento de voz que se utilizan para hacer dictados de texto en computadores.
- Resultados de búsquedas El procesamiento de lenguaje natural ha cambiado el resultado de las búsquedas, ha logrado una mejor comprensión del modo en que nos comunicamos y cómo se relacionan ciertos términos. No se trata solamente de la popularidad de una palabra, sino también de lo que se desea eliminar de los resultados.

Por otro lado, ya es posible que los motores de búsqueda comprendan mejor la intención de las consultas. Lo notas cuando te equivocas en una letra o quizá en la escritura de un nombre, pues no sabes cómo se escribe del todo; entonces, el buscador te corrige o muestra la escritura correcta (con la opción de presentar los resultados con el término o frase que se ingresó originalmente).

4.6. Sistemas Expertos (SE).

4.6.1. Conceptos Básicos.

Los SE son programas informáticos que tienen el objetivo de solucionar un problema concreto y utilizan la inteligencia artificial para simular el razonamiento de un ser humano. Se denominan sistemas expertos porque estos programas imitan la toma de decisiones de un profesionalista en la materia.

Actualmente, se consideran dentro del global de la Inteligencia Artificial. Se crearon durante la década de los 60 (aunque alcanzaron su mayor popularidad en los años posteriores) y fueron uno de los primeros sistemas de Inteligencia Artificial utilizados con éxito. El primer sistema experto fue desarrollado en 1967 por Edward Feigenbaum y Joshua Lederberg, con la finalidad de analizar compuestos químicos.

Los elementos que conforman un SE (figura 4.15) son:

- Base de conocimientos: Es allí donde se almacena la información, es decir, el conocimiento experto sobre un tema específico. Algunos de estos componentes son hechos, reglas heurísticas y relaciones entre conceptos relevantes asociados al problema que el sistema experto está diseñado para resolver.
- Motor de inferencia: Es la herramienta que aplica las reglas lógicas y de razonamiento sobre la información almacenada en la base de conocimientos. Luego crea conclusiones lógicas o recomendaciones basadas en ese análisis.
- Interfaz de usuario: Es el “lugar” donde los usuarios interactúan con el sistema, es decir, realizan consultas, brindan información e incluso, exploran el paso a paso del razonamiento por detrás de la toma de decisión del sistema experto.




Figura 4.15 Elementos de un SE.



4.6.2 Clasificación.

El Motor de Inferencias, es un programa de control cuya función es seleccionar las reglas posibles a satisfacer el problema, para ello se vale de ciertas estrategias de control sistemáticas o de estrategias heurísticas.

- Reglas previamente establecidas (RBR, del inglés Rule Based Reasoning) o encadenamiento hacia atrás: Estos comienzan con una hipótesis o posible solución y luego buscan una evidencia que la apoye. Para ello, aplica reglas heurísticas respaldadas generalmente en la lógica difusa para su evaluación y aplicación.
- Basados en casos (CBR, del inglés Case Based Reasoning) o encadenamiento hacia delante: Este tipo comienza con datos disponibles y los utiliza para generar nuevas conclusiones. Por medio de este razonamiento, la solución llega después de analizar un problema similar planteado con anterioridad y adaptarlo al nuevo.
- Basados en redes bayesianas: Fundamentados en la estadística y en el teorema de Bayes, son utilizados, sobre todo, para la predicción, clasificación o el diagnóstico de enfermedades y en medicina.

Los sistemas expertos actuales, suelen integrar capacidades de aprendizaje automático, como el machine o el deep learning. Esto les permite mejorar el rendimiento y sacar el máximo partido a la experiencia acumulada, hace al sistema experto más experto.

Entre las ventajas que ofrecen está la capacidad analítica y deductiva de una gran cantidad de información de forma muy rápida, lo que ahorra un tiempo muy valioso en la toma de decisiones.

4.6.3. Desarrollos Actuales y Aplicaciones.

Los sistemas expertos continúan evolucionando y encontrando nuevas aplicaciones en una variedad de campos (figura 4.16). Aquí hay algunos desarrollos actuales y aplicaciones destacadas:



- **Medicina y diagnóstico médico:** Los sistemas expertos son utilizados en medicina para ayudar en el diagnóstico de enfermedades, la interpretación de imágenes médicas (como radiografías y resonancias magnéticas) y el diseño de planes de tratamiento personalizados. Estos sistemas pueden ayudar a los médicos a tomar decisiones más precisas y rápidas.
- **Servicio al cliente y soporte técnico:** En la industria de servicios, los sistemas expertos se utilizan para proporcionar soporte técnico automatizado y asistencia al cliente. Estos sistemas pueden responder preguntas comunes, solucionar problemas técnicos y guiar a los usuarios a través de procesos complejos paso a paso.
- **Finanzas y análisis de inversiones:** Los sistemas expertos son utilizados en finanzas para el análisis de inversiones, la gestión de carteras y la evaluación de riesgos. Estos sistemas pueden analizar grandes cantidades de datos financieros, identificar tendencias y patrones, y tomar decisiones de inversión basadas en reglas predefinidas y análisis predictivo.
- **Manufactura y control de procesos:** En la industria manufacturera, los sistemas expertos son utilizados para el control de procesos, el mantenimiento predictivo y la optimización de la producción. Estos sistemas pueden monitorear continuamente el rendimiento de los equipos, predecir fallos y realizar ajustes automáticos para maximizar la eficiencia y la calidad del producto.
- **Educación y tutoría inteligente:** Los sistemas expertos se utilizan en educación para proporcionar tutoría personalizada y apoyo académico a los estudiantes. Estos sistemas pueden adaptarse al estilo de aprendizaje y al ritmo de cada estudiante, ofreciendo explicaciones claras, ejercicios de práctica y retroalimentación inmediata.
- **Recursos humanos y selección de personal:** En el ámbito de recursos humanos, los sistemas expertos son utilizados para la selección de personal, la evaluación de candidatos y la planificación de la fuerza laboral. Estos sistemas pueden analizar currículos, realizar entrevistas virtuales y recomendar candidatos que mejor se ajusten a los requisitos del puesto.



Figura 4.16 Desarrollo actual de los SE.



REFERENCIAS BIBLIOGRÁFICAS



Referencias Bibliográficas.

Aprendizaje cognitivo: qué es, proceso, beneficios y ejemplos. (n.d.). Becas-santander.com. Retrieved October 5, 2023, from <https://www.becas-santander.com/es/blog/aprendizaje-cognitivo.html>.

Completo, V. mi P. (s/f). *Inteligencia Artificial*. Blogspot.com. Recuperado el 1 de abril de 2025, de <https://inteligenciaartificial-isc.blogspot.com/p/unidad-4.html>

Conocimiento Monótono y No Monótono. (s/f). Prezi.com. Recuperado el 20 de marzo de 2025, de <https://prezi.com/knfibt3mfqzt/conocimiento-monotono-y-no-monotono/>

Diferencia Entre Razonamiento Monotono y No Monotono. (s/f). Scribd. Recuperado el 20 de marzo de 2025, de <https://es.scribd.com/doc/135305758/Diferencia-Entre-Razonamiento-Monotono-y-No-Monotono>

Enrique Súcar, E. M. /. (s/f). *Reglas de Producción*. Inaoep.mx. Recuperado el 8 de abril de 2025, de <https://ccc.inaoep.mx/~esucar/Clases-ia/Laminas2014/reglas.pdf>.

Espínola, J. P. S. (s/f). *Razonamiento - Concepto, tipos y características*. Recuperado el 20 de marzo de 2025, de <https://concepto.de/razonamiento/>

Galende Hernández, M., Rey, M. I., Fuente Aparicio, M. J. de la, & Sáinz Palmero, G. I. (2018). *Relevancia, Precisión e Interpretabilidad en Sistemas Basados en Reglas*. Difusas. F. Herrera et.

García Leal, O., & Pedroza Cabrera, F. (2011). *Sistemas basados en conocimiento: Una alternativa poco explorada en psicología*. *Journal of Behavior Health & Social Issues*, 3(1), 5. <https://doi.org/10.5460/jbhsi.v3.1.27672>

Gutierrez, J. M. (s/f). *Sistemas Expertos Basados en Reglas*. Unican.es. Recuperado el 8 de abril de 2025, de <https://personales.unican.es/gutierjm/cursos/expertos/reglas.pdf>

Inteligencia artificial. (n.d.). Koala-soft.com. Retrieved October 5, 2023, from <https://www.koala-soft.com/introduccion-a-la-inteligencia-artificial>

Introducción a la Inteligencia artificial. (n.d.). Usal.es. Retrieved October 5, 2023, from <https://bisite.usal.es/es/blog/formacion/19/01/10/inteligencia-artificial-cursos-bisite>



- Modi, A. (2021, February 17). *Una introducción rápida a la inteligencia artificial (IA) y sus componentes*. Cynoteck; Cynoteck Technology Solutions. <https://cynoteck.com/es/blog-post/what-is-artificial-intelligence/>
- Moya-Rodríguez, J. L., Becerra-Ferreiro, A. M., & Chagoyén-Méndez, C. A. (2012). Utilización de Sistemas Basados en Reglas y en Casos para diseñar transmisiones por tornillo sinfín. *Ingeniería mecánica*, 15(1), 01–09. http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1815-59442012000100001
- Pastene, E. (2019, August 27). *[Apuntes de IA] ¿Qué es la IA? - Enrique Pastene*. Medium. <https://medium.com/@enriquepastene/apuntes-de-ia-qu%C3%A9-es-la-ia-e8c085ad8011>
- Rojas, M. R. F. (s/f). *Lógica no Monotónica Un nuevo Modelo Inferencial para Aplicaciones Informáticas*. Umsa.bo. Recuperado el 20 de marzo de 2025, de http://revistasbolivianas.umsa.bo/pdf/rpgi/n1/n1_a19.pdf
- Sistemas Expertos –. (s/f). betovaldez. Recuperado el 8 de abril de 2025, de <https://betovaldez.wordpress.com/category/sistemas-expertos/>
- Sistemas expertos – acervo para el mejoramiento del aprendizaje de alumnos de ingeniería, en *Inteligencia Artificial*. (s/f). Unam.mx. Recuperado el 1 de abril de 2025, de https://virtual.cuautitlan.unam.mx/intar/?page_id=200
- Sistemas expertos basados en reglas: una introducción. (s/f). Toolify.ai. Recuperado el 8 de abril de 2025, de <https://www.toolify.ai/es/ai-news-es/sistemas-expertos-basados-en-reglas-una-introduccion-2545003>
- Sistemas expertos, guía completa: para qué sirven y clasificación. (2024, septiembre 17). *Innovación Digital 360*. <https://www.innovaciondigital360.com/i-a/sistemas-expertos-que-son-su-clasificacion-como-funcionan-y-para-que-se-utilizan/>
- Solano, J. G. (s/f). *Razonamiento monotono*. SlideShare. Recuperado el 20 de marzo de 2025, de <https://es.slideshare.net/slideshow/razonamiento-monotono/67409940>
- Skills, A. (2023, noviembre 21). *¿Cuáles son las mejores maneras de utilizar el razonamiento no monótono para la información incompleta o inconsistente?* LinkedIn.com; [www.linkedin.com. https://es.linkedin.com/advice/1/what-best-ways-use-non-monotonic-reasoning-incomplete-1uckf?lang=es&lang=es](https://es.linkedin.com/advice/1/what-best-ways-use-non-monotonic-reasoning-incomplete-1uckf?lang=es&lang=es)



(S/f-b). Upv.es. Recuperado el 8 de abril de 2025, de
https://personales.upv.es/ccarrasc/extdoc/Ejercicios_sbr.pdf

Tema 60 - Sistemas basados en el conocimiento. (2015, febrero 26). Oposinet.
<https://www.oposinet.com/temario-de-informatica/temario-1-informatica/tema-60-sistemas-basados-en-el-conocimiento/>

¿Qué Es la Inteligencia Artificial? (n.d.). Trend Micro. Retrieved October 5, 2023, from
https://www.trendmicro.com/es_mx/what-is/machine-learning/artificial-intelligence.html

Universidad Autónoma del Estado de Hidalgo. (s/f). *Vista de Componentes de un sistema experto*. Edu.mx. Recuperado el 8 de abril de 2025, de
<https://repository.uaeh.edu.mx/revistas/index.php/huejutla/article/view/1021/4813>

Universidad de Guanajuato. (2023, June 12). *Clase digital 1. Introducción a la Inteligencia Artificial en la educación*. Recursos Educativos Abiertos; Sistema Universitario de Multimodalidad Educativo (SUME) - Universidad de Guanajuato.
<https://blogs.ugto.mx/rea/clase-digital-1-introduccion-a-la-inteligencia-artificial-en-la-educacion/>

(N.d.). Wwww.Uv.Mx. Retrieved October 5, 2023, from
<https://www.uv.mx/personal/edbenitez/files/2010/09/CursoIA10-I-1.pdf>



GLOSARIO

Aprendizaje Automático (Machine Learning).

Subcampo de la IA que permite a las máquinas aprender a partir de datos sin ser programadas explícitamente.

Aprendizaje Profundo (Deep Learning).

Tipo de aprendizaje automático basado en redes neuronales artificiales con muchas capas, que permite reconocer patrones complejos en grandes cantidades de datos.

Red Neuronal Artificial.

Modelo computacional inspirado en el cerebro humano que se usa para reconocer patrones y clasificar datos.

Algoritmo.

Conjunto de reglas o instrucciones que una máquina sigue para resolver un problema.

Datos de Entrenamiento.

Conjunto de datos usados para enseñar a un modelo de IA a realizar una tarea.

Dataset (Conjunto de Datos).

Colección estructurada de datos, generalmente dividida en entrenamiento, validación y prueba.

Inteligencia Artificial (IA).

Campo de la informática que busca crear sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como el razonamiento, aprendizaje o percepción.

IA Generativa.

Modelos que pueden crear contenido nuevo como texto, imágenes, música, etc., como lo hace ChatGPT o DALL·E.



Inferencia.

Proceso en el que un modelo ya entrenado realiza predicciones o toma decisiones basadas en nuevos datos.

Modelo de Lenguaje.

Sistema de IA entrenado para comprender y generar lenguaje humano.

NLP (Procesamiento del Lenguaje Natural).

Rama de la IA que se enfoca en la interacción entre las computadoras y el lenguaje humano.

Prompt.

Instrucción o entrada que se le da a un modelo de lenguaje para que genere una respuesta.

Regresión / Clasificación.

Tareas comunes de machine learning. La regresión predice valores numéricos; la clasificación categoriza en clases.

Reforzamiento (Reinforcement Learning).

Tipo de aprendizaje donde un agente aprende tomando decisiones y recibiendo recompensas o penalizaciones.

Sesgo Algorítmico.

Cuando un modelo de IA produce resultados injustos o parciales debido a los datos con los que fue entrenado.

Sistema Experto.

Tipo de programa de inteligencia artificial que simula el conocimiento y la capacidad de razonamiento de un experto humano en un área específica.

Sobreajuste (Overfitting).

Cuando un modelo aprende demasiado bien los datos de entrenamiento, incluyendo el ruido, y falla al generalizar con nuevos datos.



Subajuste (Underfitting).

Cuando un modelo no es lo suficientemente complejo como para capturar los patrones de los datos.

Supervisado / No Supervisado.

Aprendizaje supervisado usa datos etiquetados; el no supervisado trabaja con datos sin etiquetar para encontrar patrones.

Token.

Fragmento de texto que representa una unidad básica para modelos de lenguaje (puede ser una palabra, parte de una palabra o un símbolo).

Visión por Computadora (Computer Vision).

Disciplina que enseña a las máquinas a interpretar y comprender imágenes o videos.