

José Muñoz Pérez

**INTELIGENCIA
COMPUTACIONAL
INSPIRADA EN LA VIDA**

JOSÉ MUÑOZ PÉREZ

INTELIGENCIA COMPUTACIONAL
INSPIRADA EN LA VIDA

SPICUM - UNIVERSIDAD DE MÁLAGA - 2010

Autor: José Muñoz Pérez

Edita: SERVICIO DE PUBLICACIONES DE LA UNIVERSIDAD DE MÁLAGA

Diseño de cubierta y maquetación: María Luisa Cruz. SPICUM

ISBN: 978-84-9747-330-9 (Papel); 978-84-9747-349-1 (Digital PDF)

978-84-9747-350-7 (Digital ePub)

Esta obra se encuentra depositada en el repositorio institucional de la Universidad de Málaga (RIUMA) <http://riuma.uma.es>



Esta obra está sujeta a una licencia Creative Commons:

Reconocimiento - No comercial - SinObraDerivada (cc-by-nc-nd):

[Http://creativecommons.org/licenses/by-nc-nd/3.0/es](http://creativecommons.org/licenses/by-nc-nd/3.0/es)

Cualquier parte de esta obra se puede reproducir sin autorización pero con el reconocimiento y atribución de los autores.

No se puede hacer uso comercial de la obra y no se puede alterar, transformar o hacer obras derivadas.

A mi familia

INDICE

INTELIGENCIA COMPUTACIONAL INSPIRADA EN LA VIDA	6
INTRODUCCIÓN	8
LA COMPUTACIÓN	10
Algoritmos y máquinas de Turing	15
Complejidad computacional	18
Demostraciones con ordenador.....	20
PARADIGMAS DE LA INTELIGENCIA ARTIFICIAL.....	22
INTELIGENCIA COMPUTACIONAL	33
Redes neuronales artificiales	38
Máquinas de vectores soporte	45
Computación evolutiva	47
Computación de colonias de hormigas	53
Computación de enjambres	59
Aprendizaje automático.....	63
Lógica difusa	66
ÁREAS DE APLICACIÓN DE LA IC.....	68
TENDENCIAS DE LA IC	83
RETOS FUTUROS	87
CONCLUSIONES	91
REFERENCIAS	94

INTELIGENCIA COMPUTACIONAL INSPIRADA EN LA VIDA

*Magnífica, excelentísimas e ilustrísimas autoridades,
doctoras y doctores, señoras y señores, con su
venia:*

El desarrollo actual de la mayoría de las disciplinas del saber humano no se hubiera logrado si no hubiera sido por el espectacular avance de la informática en los últimos 40 años. Dicho avance se ha visto muy favorecido por el desarrollo de otras disciplinas como la microelectrónica y las telecomunicaciones. Los ordenadores están facilitando la exploración espacial, el proyecto del "genoma humano", la difusión del conocimiento, y muchas cosas más.

Los mayores impactos se han producido en campos como la educación, investigación, industria, negocios, medicina, genética, telecomunicaciones, transporte, entretenimiento, cine, etc.

Las primeras Facultades de Informática aparecieron en España en los años setenta. Hace 36 años me incorporé como profesor al Colegio Universitario de Málaga. Aún no existían en España Facultades de Informá-

tica. Dos años después me trasladé a la Universidad de Sevilla. Posteriormente, con la creación de la Facultad de Informática en la Universidad de Málaga, me reincorporé a la misma con mucha ilusión y con la suerte de tener excelentes compañeros. Gracias al esfuerzo de todos, de ella han egresado ingenieros informáticos de reconocido prestigio en las tres titulaciones y dicho centro ha estado ocupando las primeras posiciones en el ranking de centros a nivel nacional. Es a este centro al que tengo la gran satisfacción de representar en este acto de inauguración del curso 2010-2011.

La capacidad para evolucionar y adaptarse a los cambios del ambiente ha sido fundamental para los seres vivos y, en particular, para el ser humano.

Por ello, voy a centrar esta lección inaugural en aquellos paradigmas de la Inteligencia Artificial que se han inspirado en la naturaleza, en la vida, es decir, lo que se denomina Inteligencia Computacional. Voy a tratar de mostrar la situación actual de dicha disciplina, su inspiración biológica, los propósitos que persigue, los diferentes enfoques que la dirigen, las ofertas científicas que se están llevando a cabo y las demandas tecnológicas e industriales. Finalmente, indicaré cuáles son las tendencias futuras que se apuntan para afrontar los nuevos retos que están emergiendo en la actualidad.

INTRODUCCIÓN

Durante muchos siglos, la observación de la naturaleza ha permitido al ser humano desarrollar teorías acerca de cómo funcionan o se comportan muchas partes o fenómenos de la misma, como, por ejemplo, las leyes de Newton de la física y el modelo de Kepler de las órbitas planetarias. Sin embargo, la naturaleza no sólo necesita ser observada y explicada sino que se puede utilizar como fuente de inspiración para el diseño y construcción de sistemas, máquinas o artefactos. Por ejemplo, el diseño mecánico de nuevos materiales, como el velcro, que están inspirados en el mundo natural. Además, el desarrollo y el progreso de la informática y de las demás tecnologías han contribuido en gran medida al estudio de la naturaleza y, particularmente, de los sistemas biológicos. Asimismo, la informática se está utilizando para comprender mejor los procesos biológicos y sus funciones mediante modelado y simulación de estos sistemas naturales. Al mismo tiempo, la informática se ha enriquecido con la incorporación de ideas biológicas para conseguir soluciones a muchos de los problemas que se plantean en la actualidad. Como resultado de estas interacciones entre la computación y la biología, surge así, por una parte, la computación bioinspirada, que abarca disciplinas como las redes neuronales artificiales, algoritmos genéticos, sistemas difusos, etc. Por otra parte, surgen mecanismos computacionales inspirados en

mecanismos biológicos o físicos, como la computación cuántica o la computación ADN, que utilizan capacidades de procesar la información propias de los sistemas biológicos y físicos para reemplazar o complementar los actuales ordenadores basados en el silicio. Hay cuatro características de los sistemas biológicos que son importantes para el desarrollo de estas metáforas. La arquitectura se refiere a la forma o estructura del sistema, la funcionalidad se corresponde con su comportamiento, los mecanismos constituyen el funcionamiento conjunto de las partes y la organización se refiere a la forma en la que se expresan las actividades del sistema en la dinámica completa.

Vamos a comenzar haciendo un recorrido por los fundamentos matemáticos de la computación para ver qué tipo de problemas se pueden resolver con un ordenador, qué problemas aborda la inteligencia artificial, y, en particular, qué problemas aborda la Inteligencia Computacional (IC).

LA COMPUTACIÓN

"La mayoría de las ideas fundamentales de la ciencia son esencialmente sencillas y, por regla general, se pueden expresar en un lenguaje comprensible para todos"

Albert Einstein

A principios del siglo XX la fundamentación de las matemáticas acaparó la atención de destacados matemáticos para conseguir que fuera consistente y estuviera exenta de contradicciones y paradojas. Varias escuelas de pensamiento matemático se ocuparon de ello: los formalistas, como David Hilbert (1862-1943), para los que las matemáticas no son ni más ni menos que el lenguaje matemático; los intuicionistas, como L. E. J. Brouwer (1882-1966), que requieren que las demostraciones sean constructivas; los partidarios de la lógica, como Bertrand Russell (1872-1970), para los que la teoría de las matemáticas es una extensión de la lógica, y los platonistas, como Kurt Gödel (1906-1978), que defienden la abstracción y mantienen que los objetos existen necesariamente, independientemente de la mente humana.

El matemático alemán David Hilbert (1862-1943), reconocido como uno de los matemáticos más influyente del siglo XX, propuso de forma explícita un proyecto de investigación con el que pretendía que la matemática

fuese formulada sobre un sistema finito de axiomas escogidos adecuadamente para que fuera consistente, es decir, que cualquier enunciado lógico resultara ser verdadero o falso. De esta forma, dada una representación formal de un enunciado matemático, se podría diseñar un algoritmo (programa) que determinara si el enunciado es verdadero (teorema) o falso (no válido lógicamente). Si tal programa existiera, cualquier conjetura se podría probar o refutar expresándola formalmente y construyendo *mecánicamente* una demostración, de manera que todo el razonamiento matemático se basaría en un fundamento lógico donde todos los enunciados verdaderos serían demostrables, al igual que los falsos, y cada enunciado sería verdadero o falso. Así cualquier teoría matemática estaría formada por un conjunto de axiomas y un conjunto de reglas de inferencia que permitirían generar enunciados verdaderos adicionales a partir de enunciados verdaderos ya establecidos. En teoría, este tipo de demostraciones se podrían realizar con un ordenador ya que dada una representación formal de un enunciado matemático el problema se reduce a diseñar un algoritmo (programa).

El programa de Hilbert debería de incluir una formalización de todas las matemáticas, es decir, todos los enunciados deberían escribirse en un lenguaje formal preciso y manipularse según reglas bien definidas. También tendría que ser completo, es decir, cualquier enunciado cierto se podría demostrar. Asimismo, debería

ser consistente, es decir, exento de contradicciones, y lo suficientemente potente para disponer de un algoritmo que decida la verdad o falsedad de cualquier enunciado matemático.

En un congreso celebrado en 1930, en Königsberg, el joven matemático Kurt Gödel presentó a los matemáticos más destacados del mundo su famoso teorema de incompletitud que establece, sin discusión alguna, lo siguiente: En cualquier formalización consistente de las matemáticas que sea lo bastante fuerte para definir el concepto de números naturales, se pueden construir enunciados que ni se pueden demostrar ni se pueden refutar dentro de ese sistema, es decir, que cualquier sistema que permita definir los números naturales es necesariamente incompleto pues contiene enunciados indecidibles que ni se pueden demostrar ni refutar con los métodos rigurosos de las matemáticas. Por lo tanto, para cualquier sistema formal capaz de producir los teoremas de la aritmética elemental, existen siempre enunciados verdaderos para el entendimiento humano que no se pueden deducir de los axiomas del sistema, es decir, hay cosas que sabemos que son ciertas pero que no podemos probar (enunciados indecidibles). Por lo tanto, no sólo no existen algoritmos que puedan demostrar todos los teoremas en matemáticas sino que además no todos los enunciados son demostrables. De dicho resultado se desprende algo más, que afecta al problema hombre-máquina, y es que la intuición

y la comprensión humanas no pueden reducirse a un conjunto de reglas computacionales ya que el ser humano utiliza métodos válidos de razonamiento matemático que no están formalizados de acuerdo con un sistema de reglas aceptado de antemano.

Desde la antigüedad el hombre ha diseñado artilugios para llevar a cabo algún tipo de cálculo. Uno de los primeros dispositivos mecánicos diseñados por el hombre para realizar cálculo matemático fue el ábaco, cuya historia se remonta a las antiguas civilizaciones griega y romana. Un invento mecánico más reciente fue la Pascalina, inventada por Blaise Pascal (1623-1662) en 1645 que fue la primera máquina sumadora mecánica que funcionaba a base de engranajes y ruedas. Los datos se representaban mediante las posiciones de los engranajes. El primer uso de la Pascalina fue en la Hacienda francesa, debido a que Pascal la diseñó para su padre que era contable en dicha entidad. Pascal construyó más de 50 ejemplares. En el museo de Artes y Oficios de Inglaterra se exponen varios ejemplares originales.

En 1833, el matemático inglés, catedrático de la Universidad de Cambridge, Charles Babbage (1792-1871) diseñó la "Máquina Analítica" que era un artefacto de propósito general capaz de realizar cualquier tipo de cálculo matemático. Es el precedente más cercano desde un punto de vista tecnológico a lo que son los actuales ordenadores, puesto que era programable, lo que

la diferencia de las máquinas calculadoras. La idea de su construcción estaba motivada porque la elaboración de tablas matemáticas era un proceso tedioso y propenso a errores, aunque nunca llegó a construirla debido a que un comité de la Asociación Británica para el Avance de la Ciencia recomendó no construirla y Babbage no tuvo acceso a fondos públicos. Los escépticos le pusieron el sobrenombre de "la locura de Babbage" pues su diseño requería miles de engranajes y mecanismos que cubrirían el área de un campo de fútbol y necesitaría accionarse con una locomotora. La máquina analítica fue construida cien años después de la muerte de Babbage por un equipo de ingenieros en 1989. Algunos lo consideran el padre de los ordenadores modernos.

El primer ordenador digital que incorpora tecnología electrónica es el ENIAC (Electronic Numerical Integrator And Calculator), diseñado en la Universidad de Pensilvania por los ingenieros John Eckert y John Mauchly con objeto de calcular trayectorias balísticas. Esta máquina ocupaba todo un sótano de la Universidad, 8.450 m², tenía más de 18.000 tubos de vacío, consumía 200 KW de energía eléctrica y requería todo un sistema de aire acondicionado. Podía realizar cinco mil operaciones aritméticas por segundo. El proyecto estaba auspiciado por el Departamento de Defensa de los Estados Unidos. A este equipo se integró dos años después el ingeniero y matemático húngaro John von Neumann (1903-1957), uno

de los matemáticos más influyentes del siglo XX, autor de relevantes contribuciones a la informática y considerado el padre de los ordenadores modernos. En 1945 publicó un artículo acerca del almacenamiento de programas. El concepto de programa almacenado permitió la lectura de un programa dentro de la memoria del ordenador y a continuación la ejecución de las instrucciones del mismo sin tener que volver a escribirlas. Aunque en 1944 se construyó Mark I en la Universidad de Harvard, diseñado por Howard H. Aiken, no está considerado como un ordenador electrónico debido a que no era de propósito general y su funcionamiento estaba basado en dispositivos electromecánicos. Un ordenador digital está basado en dispositivos biestables, es decir, que sólo pueden tomar dos valores posibles: 0 ó 1. Presenta la ventaja de poder ejecutar diferentes programas para diferentes problemas, sin necesidad de modificar físicamente la máquina. Los ordenadores actuales se ajustan al modelo propuesto por John von Neumann. Una característica importante de este modelo es que tanto los datos como los programas se almacenan en la memoria antes de ser utilizados.

Algoritmos y máquinas de Turing

La Teoría de la Computación se ocupa de construir un formalismo matemático para razonar sobre la exis-

tencia de *algoritmos efectivos* para *problemas* particulares. Los resultados que se prueben dentro de esta teoría deben ser aplicables a todas las arquitecturas de ordenadores, independientemente de sus parámetros, como pueden ser la velocidad del procesador o el tamaño de la memoria. Para ello tiene como base el concepto de modelo de computación.

Por lo tanto, necesitamos saber qué entendemos por algoritmo efectivo y por problema. Aunque el desarrollo formal de la teoría de la computabilidad se lleva a cabo en el siglo XX, sin embargo la búsqueda de algoritmos efectivos para resolver ciertos problemas se viene realizando desde hace más de 2.000 años. Los matemáticos griegos, pusieron gran énfasis en las técnicas constructivas, como se comprueba en los trabajos de Euclides y Pitágoras. Así, en geometría se plantearon algunos problemas que dejaron sin resolver y que han constituido materia de investigación durante mucho tiempo, como el problema de la cuadratura del círculo: "Dado un círculo, construir un cuadrado con la misma área utilizando regla y compás", o el problema de la trisección de un ángulo: "Dividir un ángulo dado en tres partes iguales mediante regla y un compás". En este contexto, un algoritmo efectivo será aquel que emplee en sus pasos de computación sólo regla y compás. Sin embargo, hoy se sabe que ninguno de estos problemas tiene solución. Por lo tanto, no existe un método de construcción apropiado y así no pueden existir tales algoritmos.

Las raíces de la computación se encuentran en los trabajos de Hilbert, Gödel, Rosser, Kleene, Church, Turing y Post. Ejemplos de modelos de computación son las máquinas de Turing, las máquinas RAM, las máquinas de Post, los algoritmos de Markov, etc. Para dar una definición matemáticamente precisa de algoritmo, Alan Turing ideó un dispositivo imaginario al que denominó Máquina de Computación Lógica [28], pero que ha recibido en su honor el nombre de Máquina de Turing, y definió un algoritmo como cualquier conjunto de instrucciones para dicha máquina. Es un modelo matemático abstracto que formaliza el concepto de algoritmo. Gödel definió un algoritmo como una secuencia de reglas para formar funciones matemáticas complicadas a partir de funciones matemáticas más simples y Church utilizó un formalismo denominado el λ -cálculo. Conforme los investigadores se dieron cuenta de que si algo se podía calcular con una máquina también se podía calcular con otra de ellas se estableció la conocida *Tesis de Church–Turing*:

«Todas las definiciones razonables de algoritmos conocidas hasta el momento son equivalentes y cualquier definición de algoritmo que se llegue a dar será equivalente a las ya conocidas».

Hasta ahora no ha surgido evidencia en contra y se acepta ampliamente dicha tesis.

La cuestión que surge ahora es: ¿Qué problemas se pueden resolver con programas de ordenador? También

se puede formular de forma equivalente: ¿Qué funciones se pueden computar? La respuesta a esta pregunta son las funciones μ -*recursivas*. Es decir, un conjunto reducido de funciones.

Por otra parte, la identificación de los problemas que son computables y los que no lo son tiene un considerable interés pues indica el alcance y los límites de la computabilidad, y por tanto, demuestra los límites teóricos de los ordenadores. Por ejemplo, un problema no computable es el décimo problema de Hilbert cuyo enunciado es: ¿existe un procedimiento efectivo que determine si una ecuación diofántica tiene solución?

Complejidad computacional

A principios de los setenta, S.A. Cook y R. Karp sentaron las bases de la teoría de la complejidad que trata de los recursos requeridos durante el cálculo para resolver un problema dado. La teoría básicamente establece dos clases de problemas, la clase P que contiene todos los problemas que se puede resolver en una máquina de Turing determinística y secuencial en tiempo polinomial, y la clase NP que contiene los problemas que se resuelven en tiempo polinomial en una máquina de Turing no determinística. Hasta el día de hoy todos los algoritmos propuestos para resolver problemas de la cla-

se NP mediante una máquina de Turing determinística requieren un tiempo exponencial, es decir, no se puede encontrar la solución en un tiempo razonable. En la práctica existe problemas que pertenecen a la clase NP , tan sencillos de enunciarlos como el problema del viajante de comercio que consiste en encontrar la ruta más corta que pasa por N ciudades y vuelve a la ciudad original sin pasar dos veces por la misma ciudad. El número de rutas posibles es $N!$, un número inmensamente grande para valores de N superiores a treinta. La principal pregunta, aún sin respuesta, en teoría de la computación se refiere a la relación entre estas dos clases: ¿Es la clase P igual a la clase NP ? Si alguien diseña un algoritmo que resuelva un problema de la clase NP en tiempo polinomial mediante una máquina de Turing determinística entonces demostraría que todos los problemas de la clase NP también se pueden resolver en tiempo polinomial. Después de más de 50 años nadie ha sido capaz de dar una respuesta a dicha cuestión. Como no se ha podido diseñar dicho algoritmo en todo ese tiempo parece que dichas clases son diferentes. Este es uno de los grandes problemas de la matemática que aún no se ha resuelto. El *Instituto de Matemáticas Clay* dedicado a incrementar y diseminar el conocimiento matemático está ofreciendo un premio de un millón de dólares a la primera persona que logre dar una demostración de alguno de los siete problemas del milenio. El primero consiste en demostrar si $P=NP$. Sin embargo, uno de ellos, conocido como la

conjetura de Poincaré, ha sido resuelto por el matemático ruso Grigori Perelman. En el 2002 anunció haberla resuelto a través de dos publicaciones en un portal de Internet y en el año 2006 se le otorgó la medalla *Fields*, considerada como el Nobel de las matemáticas, la cual no aceptó, ni el premio de un millón de dólares, pues estima que no necesita otro reconocimiento adicional a la propia validez de su trabajo.

Demostraciones con ordenador

Por otro lado surge también la siguiente cuestión: ¿Puede ayudarnos un ordenador a realizar demostraciones de enunciados matemáticos que no podemos hacer por nosotros mismos? La respuesta es positiva. En 1852, Augustus De Morgan, profesor de Matemáticas en el *University College* de Londres, escribió a Sir William Rowan Hamilton acerca de un problema que le propuso un alumno, Francis Guthrie. El alumno había observado que era posible colorear los condados de Inglaterra empleando sólo 4 colores de manera que dos condados limítrofes no tuvieran asignados el mismo color. Desde entonces muchos matemáticos trataron de demostrar que cualquier mapa (grafo plano) se puede colorear con tan sólo cuatro colores. No fue hasta 1976 cuando A. Appel y W. Haken demostraron dicha conjetura con la

ayuda de un ordenador. Inicialmente, su demostración no fue aceptada por todos los matemáticos, ya que las pruebas realizadas con ayuda de un ordenador no se podían comprobar manualmente. En el 2005, el teorema fue demostrado por Georges Gonthiers con software de propósito general para la prueba automática de teoremas. El teorema de los cuatro colores se ha destacado también por el gran número de demostraciones falsas que se han realizado a lo largo de la historia. También es cierto que la inmensa mayoría de los mapas se pueden colorear con tres, o menos colores.

En el mundo real se presentan muchos problemas que requieren grandes recursos computacionales, como ocurre en el estudio y predicción del clima, diseño de aviones, simuladores de vuelo, búsqueda de yacimientos petrolíferos, estudio y predicción de tornados, asignación de códigos en estaciones de telefonía móvil, problemas bioinformáticos de genética humana, clasificación de secuencias de proteínas, predicción de estructuras de proteínas, selección de genes, clasificación de *microarrays*, etc., y no se pueden resolver eficientemente con los algoritmos tradicionales. En muchos casos hay que recurrir a la Inteligencia Artificial que, inspirada en la natural, desarrolla técnicas de representación simbólica del conocimiento y sistemas de razonamiento automático.

PARADIGMAS DE LA INTELIGENCIA ARTIFICIAL

"Inteligencia: conócete, acéptate, supérate"

San Agustín

Pocas áreas de investigación han creado tanta popularidad y controversia como la Inteligencia Artificial (IA). Incluso ha llamado la atención de estrellas de cine, como la del popular director de cine Steven Spielberg, que en el año 2001 dirigió la película que lleva por título "Inteligencia Artificial", con gran éxito de taquilla. La IA imita a la inteligencia humana representando el conocimiento disponible del experto humano y utilizando mecanismos de razonamiento simbólico para resolver problemas dentro de un dominio específico.

Aristóteles (384-322 a.C.) fue posiblemente la primera persona en abordar cuestiones de Inteligencia Artificial (IA) cuando trató de explicar y codificar estilos de razonamiento deductivo, conocidos como silogismos. Ramón Llull (1235-1316) desarrolló la *Ars Magna*, un intento optimista de construir una máquina constituida por un conjunto de engranajes que pretendía responder a todas las preguntas. El matemático Gottfried Leibniz (1646-1716) razonaba acerca de la existencia de un álgebra universal que se pueda usar para representar todo

el conocimiento, incluyendo las verdades morales, en un sistema deductivo. En 1854, George Boole desarrolló los fundamentos de la lógica de predicados. En los años cincuenta del pasado siglo, Alan Turing estudió cómo las máquinas se podrían usar para imitar los procesos del cerebro humano [28]. Sus estudios condujeron a una de las primeras publicaciones sobre IA.

Hace 55 años, el 31 de agosto de 1955, Marvin Minsky, John McCarty, Nathan Rochester y Claude Shannon propusieron la celebración de una reunión de dos meses de duración que tuvo lugar en el Dartmouth College durante el verano de 1956, para discutir la conjetura de que todos los aspectos del aprendizaje y de cualquier otra característica de la inteligencia se pueden describir de modo tan preciso que se pueda construir una máquina capaz de simularlos. En dicha reunión se acuñó el término de Inteligencia Artificial (IA) y marca el inicio de la misma. Se pensaba que éste era objetivo factible y que se alcanzaría en unas cuantas décadas. Las previsiones fueron demasiado optimistas. Medio siglo después estamos aún lejos de alcanzar dicho objetivo genérico. Hoy día disponemos de software para la traducción automática de idiomas pero se aproxima poco al nivel humano de traducción. En 1948, con ocasión de la inauguración del ordenador Mark 1 de IBM, Howard Aiken, director del Laboratorio de de Computación de Harvard, dijo que no había

problemas en matemática aplicada que su ordenador no pudiera resolver. Hoy día hay muchos problemas de matemática aplicada que no se pueden resolver ni con un supercomputador. Como dijo Julio Verne, el progreso científico está impulsado por expectativas exageradas. Sin embargo, disponemos ahora de una amplia colección de modelos, metodologías y técnicas que facilitan la resolución de problemas y la realización de tareas de alta complejidad. En 1952, Ashby proponía el objetivo más realista de construir dispositivos que actuasen como “amplificadores” de la inteligencia humana. La inteligencia artificial ha ido evolucionando de forma natural hacia dicho objetivo. El avance de la IA está limitado por los avances en las técnicas de modelado, formalización y programación, y por la evolución de los ordenadores y los dispositivos electromecánicos (robots) en los que se instalan los programas. Las tareas y métodos propios de la IA contemplan la imprecisión, descripciones poco claras e incompletas y con alto grado de dudas y errores potenciales, debidos a su complejidad.

Marvin Minsky, uno de los pioneros de la inteligencia artificial, opinaba en 1977 que dentro de una generación el problema de crear inteligencia artificial habría sido sustancialmente resuelto. Sin embargo, cinco años más tarde afirmaba que el problema de la inteligencia artificial es uno de los más difíciles que haya abordado la

ciencia. La inteligencia humana está dotada de sentido común o de propósito general y no sabemos, decía, como incorporar dicho sentido.

El trabajo de K. Craik [5] titulado *The Nature of Explanation* introduce los fundamentos del *paradigma simbólico* o representacional al interpretar el conocimiento humano en términos de descripciones declarativas y modulares de entidades simbólicas de alto nivel y de reglas de inferencia usadas para manipular dichas descripciones simbólicas. El trabajo de A. Turing de 1950 complementa los fundamentos de este paradigma al proponer un test para medir si un programa se puede, o no, considerar inteligente.

A. Newell y H.A. Simon contribuyeron de forma importante al procesamiento simbólico y vaticinaron en 1967 que podría haber un programa de ajedrez que fuera campeón del mundo, que durante los setenta sería posible duplicar todas las capacidades humanas de manejo de información y de resolución de problemas y que antes de que terminara la década de los ochenta tendríamos capacidad técnica para sustituir todas las organizaciones y funciones humanas por máquinas. Predicciones como éstas, que no se han visto cumplidas, no han ayudado mucho a mantener la consideración inicial de la Inteligencia Artificial. No obstante, ha habido avances tecnológicos que han destacado mucho, sobre todo popularmente, como Deep Blue, un ordenador de

IBM que juega al ajedrez utilizando reglas lógicas y explorando parte del espacio de soluciones. Fue el primer ordenador que venció a un campeón de mundo como Gary Kasparov en una memorable partida el día 10 de febrero de 1996, aunque Kasparov ganó 3 y empató 2 de las siguientes partidas. Posteriormente se mejoró el ordenador Deep Blue y éste consiguió vencer a Gary Kasparov en mayo de 1997. Dicho ordenador era capaz de calcular 200 millones de posiciones por segundo. Sin embargo, aunque el hombre tiene una capacidad de cálculo considerablemente inferior, éste la compensa con su intuición, de la que carece el ordenador. ¿En qué consiste esa misteriosa cualidad que parece imposible atribuir a las máquinas y que llamamos intuición?

Un enfoque diferente de la IA consiste en inspirarse en el funcionamiento del cerebro. Su unidad básica de funcionamiento es la neurona. La interacción entre neuronas y su intercambio de información a través del sistema nervioso posibilita al ser humano la realización de capacidades sorprendentes como el razonamiento, comprensión, memorización, reconocimiento de los objetos de una escena, reconocimiento del habla, etc.

En 1943, Warren McCulloch y Walter Pitts [19] publicaron el trabajo titulado: A logical calculus of the ideas immanent in nervous activity, que señala el comienzo del paradigma conexionista (la neurocomputación). En dicho trabajo se muestra que

incluso las formas más simples de redes neuronales artificiales pueden computar, en principio, funciones aritméticas y lógicas. Dicho paradigma está inspirado en el conocimiento actual que tenemos del funcionamiento del cerebro. Este trabajo junto con las aportaciones de Jonh von Neumann, sienta las bases de la visión cibernética de la IA que busca los fundamentos de la inteligencia en los mecanismos genéticos, moleculares, neuronales, metabólicos y sociales de los que emerge. Norbert Wiener y John von Newmann realizaron trabajos en los que sugerían que la investigación en el diseño de ordenadores inspirados en el cerebro podría ser interesante.

A. Rosenblueth, N. Wiener y J. Bigelow [25], en su trabajo titulado *Behavior, Purpose and Teleology*, introdujeron los fundamentos del *paradigma situado* o *reactivo*, basado en el comportamiento, al interpretar el comportamiento inteligente en términos de un conjunto de mecanismos de realimentación. Se pone énfasis en el hecho de que toda percepción y toda acción están acopladas a través de sensores y efectores concretos. Por ejemplo, un robot que se mueve, gira a la derecha y evita un obstáculo.

En los problemas del mundo real es difícil que dispongamos de forma clara, precisa, completa e inequívoca de todo el conocimiento necesario para su resolución. La mayor parte de los problemas son de naturaleza híbrida,

por lo que su solución tendrá que ser también híbrida. Surge así el *paradigma híbrido*. Es decir, en el control de un robot podremos necesitar técnicas simbólicas, difusas y neuronales. Así, se han realizado múltiples propuestas sobre la integración de los paradigmas simbólicos y conexionistas. En los sistemas neurodifusos se mezclan componentes neuronales y de la lógica difusa.

En la década de los setenta, dominada por el paradigma simbólico, se inicia la explosión de aplicaciones de la IA utilizando sistemas basados en reglas, llamados *Sistemas Expertos* y, posteriormente, *Sistemas Basados en Conocimiento* [21]. Son programas cuyo objetivo es actuar como un experto humano en un área de conocimiento específica para resolver problemas exclusivos de la misma. Utilizan el conocimiento almacenado y algunos métodos de inferencia. Una gran ventaja de estos sistemas es que el usuario con conocimiento limitado puede aprender observando el comportamiento del sistema. Se pueden utilizar en diagnóstico médico, exploración minera o petrolera, diagnóstico de fallos en sistemas eléctricos y centrales nucleares, diseño en ingeniería, planificación y transporte, economía y finanzas, robótica, etc.

El desarrollo de lenguajes de alto nivel como Prolog permitió crear aplicaciones que prometían simular lo que hace un experto humano en diferentes áreas. El Ministerio de Defensa de Estados Unidos consagró la IA y los programas que manipulaban símbolos siguiendo reglas

lógicas como un buen modo de resolver problemas, y sustentó esta opinión con millones de dólares.

El éxito de la IA en aplicaciones a problemas del mundo real venía avalado por:

- Los sistemas expertos desarrollados, como DENDRAL, el primer sistema experto desarrollado en la Universidad de Standford al comienzo de los setenta, cuyo objetivo general fue diseñar un programa de ordenador para determinar estructuras moleculares a partir de datos del espectrógrafo de masas y utilizando conocimiento de expertos. El programa final alcanzó el nivel de eficiencia de un químico experimentado.
- El sistema experto MYCIN desarrollado en la Universidad de Stanford entre 1972 y 1976 para el diagnóstico de enfermedades infecciosas en la sangre. Introdujo la novedad de incorporar factores de incertidumbre.
- En área de la mecánica se desarrolló el sistema DELTA para ayudar al diagnóstico y reparación de locomotoras diesel y eléctricas.
- Uno de los éxitos comerciales a comienzos de los ochenta fue el sistema experto RI para seleccionar componentes de ordenador VAX antes de ponerlo a la venta. Incluía 8.000 reglas

y para su mantenimiento requería más de 30 personas. Supuso un ahorro a la empresa Digital Equipment Corporation (DEC) de más de 20 millones de dólares anuales.

- La empresa British Petroleum (BP) desarrolló un sistema experto con 2.500 reglas llamada GASOIL para ayudar al diseño de refinerías.
- El sistema central de planificación de los procesos de fabricación de la empresa de automóviles FORD (Ford Motor Company) incorpora un sistema de IA que lee e interpreta las instrucciones y usa la información para calcular el tiempo necesario para realizar las tareas. Además, otros factores, como conocimientos ergonómicos, son utilizados por el sistema IA para prevenir asuntos ergonómicos antes de comenzar el montaje de vehículos. El núcleo del Sistema de Gestión Directa del trabajo es la base de conocimiento que utiliza una red semántica para representar toda la información para la planificación del montaje de los automóviles. El sistema está operando desde comienzos de los años noventa y ha demostrado su buen rendimiento y fiabilidad incluso después de miles de cambios en la base de conocimiento debido a la introducción de nuevas herramientas y tecnologías. Recientemente se

ha incorporado un sistema de traducción automática de los manuales de instrucciones en diversos idiomas. Desde que se integró dicho sistema en la fabricación de automóviles se estima que ha supuesto un ahorro de miles de millones de dólares.

Los métodos tradicionales de la IA para resolver los problemas representan los estados del problema mediante símbolos y construyen un conjunto de reglas para describir las transiciones entre los estados del problema. La base de conocimiento se enriquece con un gran número de reglas pero a la vez el tiempo de búsqueda puede ser responsable de la degradación y la deficiencia del sistema de razonamiento. La IA tradicional es muy buena en razonamiento inductivo y en aprendizaje por analogía pero es ineficiente para realizar aprendizaje supervisado. Los modelos de redes neuronales llevan a cabo el aprendizaje supervisado muy bien. A finales de los ochenta el mismo Ministerio de defensa de los Estados Unidos consideró que la IA basada en el enfoque simbólico no había tenido el éxito previsto y apostó por las Redes Neuronales Artificiales para resolver los problemas en este campo. Más de treinta millones de dólares respaldarían tal punto de vista.

Algunas de las características ideales para un sistema de computación son:

- Procesamiento rápido de grandes cantidades de datos de forma masiva y paralela.
- Aprendizaje y “evolución” para adaptarse mejor a los objetivos.
- Manejo robusto de datos con grandes cantidades de ruido.
- Configuración automática en redes y reconfiguración automática cuando parte del sistema se ha dañado o destruido.
- Alto grado de autonomía.

Millones de años de evolución han llevado a que los sistemas biológicos posean características y mecanismos de procesamiento que los diferencian radicalmente de los ordenadores convencionales. Muchos organismos biológicos presentan las propiedades anteriores y por ello han sido fuente de inspiración para desarrollar técnicas y algoritmos eficientes para la resolución de problemas. Con dicha motivación ha emergido como disciplina la Inteligencia Computacional.

INTELIGENCIA COMPUTACIONAL

"Pregúntales a los animales para que te instruyan, a las aves del cielo para que te informen. Te instruirán los reptiles de la tierra, te enseñarán los peces del mar.

Job 12: 7-9

Hay muchos problemas que requieren algoritmos cuyo esfuerzo computacional es tan grande que a pesar de la capacidad de cálculo de los ordenadores actuales se tardaría años en encontrar una solución óptima. Tales problemas se presentan en biología, robótica, aeronáutica, etc. Son problemas de secuenciación, reconocimiento de patrones, visión artificial, percepción, etc. Los organismos biológicos están resolviendo tales problemas todos los días. Por ello, dichos organismos pueden servirnos como fuente de inspiración para resolverlos.

En la década de los 60 y 70 fueron apareciendo progresivamente nuevos enfoques echados en falta en la IA que están inspirados en la naturaleza. Se comenzaron a desarrollar modelos y técnicas en el campo del aprendizaje automático o aprendizaje de máquina, tales como las redes neuronales, inspiradas en el conocimiento actual que tenemos del funcionamiento del cerebro, y la

teoría del aprendizaje estadístico. Se desarrollaron modelos para la representación del conocimiento ambiguo y la imitación de los procesos del pensamiento humano con información vaga e imprecisa mediante un nuevo tipo de lógica, la lógica difusa. Además, se han desarrollado técnicas y algoritmos de computación evolutiva inspirados en los mecanismos de la evolución biológica (selección natural y deriva genética). Asimismo, inspirados en el comportamiento colectivo que emerge en las colonias de hormigas o en enjambre de organismos sociales, como las abejas, a partir del comportamiento individual de los mismos, se han desarrollado nuevas técnicas y algoritmos bajo el paradigma de la inteligencia computacional de enjambres basada en la interacción social. La integración de todas estas técnicas ha llevado a una nueva forma de representación de la inteligencia llamada *Inteligencia Computacional* (IC).

La IC se ocupa de la teoría, diseño, desarrollo y aplicaciones de paradigmas computacionales motivados lingüística y biológicamente, poniendo énfasis en las redes neuronales, algoritmos genéticos, programación evolutiva, sistemas difusos y sistemas inteligentes híbridos. La IC estudia problemas para los que no hay algoritmos efectivos, bien porque no es posible formularlos o porque requieren unos tiempos de ejecución exponenciales (no polinomiales). Una buena parte de la investigación se centra en funciones cognitivas de bajo

nivel, percepción, reconocimiento de objetos, análisis de señales, descubrimiento de estructuras en conjuntos de datos, asociación y control. Los métodos para resolver este tipo de problemas incluyen aprendizaje supervisado y no supervisado mediante sistemas adaptativos, y compaginan, no sólo los enfoques neuronales, difusos o evolutivos, sino también los enfoques probabilísticos y estadísticos, como las redes Bayesianas y los métodos basados en núcleos. Las funciones cognitivas de alto nivel se requieren para resolver problemas que no se pueden resolver mediante estos algoritmos y desarrollan razonamiento, representación compleja del conocimiento, memoria episódica, planificación o comprensión del razonamiento simbólico. Dichos problemas se resuelven mediante la Inteligencia Artificial utilizando métodos de búsqueda, representación simbólica del conocimiento, sistemas expertos, aprendizaje de máquina en dominios simbólicos, lógica y métodos lingüísticos. Hay poco solapamiento entre los problemas resueltos utilizando funciones mentales de alto y bajo nivel. Es posible que en el futuro la IC trate también problemas que requieren cognición de alto nivel que hasta ahora se resuelven utilizando representación simbólica del conocimiento. Las principales áreas donde coinciden funciones cognitivas de alto y bajo nivel son el aprendizaje secuencial, el aprendizaje por refuerzo, el aprendizaje automático y los sistemas de agentes múltiples distribuidos. Todos los sistemas que requieren razonamiento basado en la percep-

ción, tales como los robots, la conducción automática de vehículos y los sistemas autónomos, demandan métodos para resolver problemas cognitivos de alto y bajo nivel y así precisan de la colaboración de ambas comunidades (IA e IC).

La Inteligencia Computacional (IC) es una metodología para el desarrollo de computación que muestra capacidad para aprender y afrontar nuevas situaciones, de manera que el sistema presenta algunos atributos del razonamiento tales como la generalización, descubrimiento, asociación y abstracción.

La IC aplicada es un sistema de métodos e infraestructuras que mejora la inteligencia humana aprendiendo y descubriendo nuevos patrones, relaciones y estructuras complejas en ambientes dinámicos para resolver problemas prácticos. En contraste con la IA clásica centrada en llevar el conocimiento experto al ordenador, la IC aplicada se contempla como una colaboración efectiva entre el ser humano y el ordenador que conduce a mejorar la inteligencia humana.

Los tres factores claves que han contribuido al desarrollo de la inteligencia computacional son:

1. Los problemas y cuestiones no resueltos por la IA tradicional.
2. El rápido incremento de la potencia de los ordenadores ha favorecido la aplicación del aprendizaje de máquina y de los algoritmos evolutivos

puesto que requieren grandes recursos computacionales sin los cuales no se pueden resolver muchos problemas complejos del mundo real.

3. El papel floreciente de los datos. Los métodos de la IC se benefician de la enorme influencia de los datos y la explosión actual de los mismos en el mundo contemporáneo.

Hay muchas diferencias técnicas entre la IA y la IC:

- La fuente de representación de la inteligencia. Mientras que la IA se basa en la representación del conocimiento de los expertos de un cierto dominio, la IC extrae el conocimiento de los datos disponibles. Sin embargo, es el ser humano el que reconoce, interpreta o usa el conocimiento.
- Los mecanismos para el procesamiento de la inteligencia. La IA utiliza métodos de razonamiento simbólico mientras que la IC está basada en métodos numéricos.
- Las interacciones con el ambiente. La IA trata de ajustar el ambiente a las soluciones conocidas, representadas por bases de conocimiento estáticas, mientras que la IC utiliza cualquier oportunidad para aprender del ambiente y crear conocimiento nuevo.

Según la *IEEE Computational Intelligence Society*, la Inteligencia Computacional es uno de los campos de investigación que más se ha desarrollado en los últimos treinta años desde sus pasos iniciales en la dirección de comprender los mecanismos del razonamiento humano hasta los estudios de todos los aspectos de la inteligencia natural y la conducta. El último objetivo de los investigadores en este campo fue la imitación de la naturaleza con tecnologías artificiales replicando los mecanismos básicos de la naturaleza en sistemas de ingeniería. Dichas tecnologías están abordando complicados problemas del mundo real. A continuación vamos a realizar un recorrido por algunos de los paradigmas que configuran la IC.

Redes neuronales artificiales

Una de las disciplinas más populares de la IC son las redes neuronales artificiales que son modelos matemáticos simples que están inspiradas en el conocimiento actual que tenemos sobre el funcionamiento del cerebro. De la misma manera que las neuronas son unidades básicas para procesar la información en el cerebro, las neuronas artificiales son modelos matemáticos simplificados que constituyen las unidades de procedimiento de la información. Además, los principios de organización de las neuronas en el cerebro, los flujos de información

y los mecanismos de aprendizaje y memorización son utilizados en el diseño de redes neuronales artificiales.

En 1949, Donald Hebb, psicólogo de la Universidad de McGill, escribió el libro titulado: *The Organization of Behavior*. En él se diseña la primera ley de aprendizaje para las redes de neuronas artificiales. En 1962, Frank Rosenblatt introdujo y desarrolló una amplia gama de redes neuronales artificiales llamadas *perceptrones* que en principio crearon bastante entusiasmo. La regla de aprendizaje del perceptrón utiliza un ajuste iterativo de pesos cuando la respuesta de la unidad es incorrecta. Permite resolver problemas simples de clasificación mediante aprendizaje automático.

En 1960, Bernard Widrow y su alumno Marcian Hoff desarrollaron una regla de aprendizaje que es muy parecida a la regla de aprendizaje del perceptrón. La similitud de los modelos del psicólogo Rosenblatt y de los ingenieros eléctricos Widrow y Hoff pone en evidencia la interdisciplinariedad de las redes neuronales. Comenzó así la primera edad de oro (las décadas de los cincuenta y sesenta) de las redes neuronales.

Sin embargo, en 1969 Marvin Minsky y Seymour Papert, en su libro titulado "*Perceptrons*", mostraron las limitaciones del perceptrón simple para aprender. Por ejemplo, el perceptrón no puede aprender la función lógica XOR (disyunción exclusiva). La ola de entusiasmo y grandes descubrimientos que había conducido su in-

vestigación hasta alcanzar esa etapa había iniciado una clara recesión. Ellos realizaron una campaña para desacreditar la investigación en redes neuronales y desviarla a otros paradigmas, como la inteligencia artificial simbólica. Ello supuso que muchos investigadores dirigieran su investigación hacia otros paradigmas de la IA. Así, tuvo lugar una época oscura, la década de los setenta y principios de los ochenta, en la que destacaron los trabajos tempranos de Teuvo Kohonen (1972) de la Universidad Tecnológica de Helsinki. Se desarrollaron las redes neuronales de memoria asociativa. Así mismo, James Anderson (1968 y 1972), de la Universidad de Brown, realizó su investigación en redes de memoria asociativa. Hay que destacar también, los trabajos de Stephen Grossberg (director del Centro de Sistemas Adaptativos de la Universidad de Boston) y sus muchos colaboradores, como Gail Carpenter, con quien desarrolló una teoría de redes neuronales autoorganizativas, llamada teoría de resonancia adaptativa (1985, 1987 y 1990).

John Hopfield del Instituto Tecnológico de California, junto con David Tank, un investigador de AT&T, desarrollaron varias redes neuronales con pesos fijos y activaciones adaptativas que pueden resolver problemas de optimización combinatoria con restricciones, como el problema del viajante (1982, 1984). Su artículo publicado en la revista *Scientific American* ayudó a que se prestara más atención a las redes neuronales. Estos tra-

bajos, junto con todas las conferencias que dio Hopfield por todo el mundo, contribuyeron a despertar gran interés por la investigación en redes neuronales.

La publicación en 1986 de los dos volúmenes titulados: *Parallel Distributed Processing* y editados por David Rumelhart de la Universidad de California (en San Diego) y James McClelland de la Universidad de Carnegie-Mellon [26], tuvo una enorme repercusión en este campo provocando un gran interés por el estudio de las redes neuronales. Se presentó un método general efectivo de entrenamiento de un perceptrón multicapa, llamado regla Delta generalizada que lo convierte en un aproximador universal de funciones. Este método de aprendizaje fue desarrollado de forma independiente por varios investigadores.

En 1987 se celebró en San Diego la primera conferencia abierta sobre redes neuronales (IEEE International Conference on Neural Networks), con más de 1.700 participantes, y se formó la International Neural Network Society (INNS). En 1988 nace la revista *Neural Networks*; le sigue la revista *Neural Computation* en 1989 y la *IEEE Transaction on Neural Networks* en 1990. Posteriormente han ido apareciendo otras muchas y se han creado Institutos de Investigación y programas de formación en Neurocomputación.

Las ventajas de las redes neuronales artificiales sobre los ordenadores clásicos son su capacidad para realizar

tareas mediante aprendizaje adaptativo, construyen su propia organización interna o representación de la información adquirida en su etapa de aprendizaje (autoorganización), son tolerantes a fallos, es decir, se comportan de manera similar a pesar de una destrucción parcial de la red, su arquitectura hardware está orientada a procesamiento masivamente paralelo de la información, y la simplicidad de integración con la tecnología actual (dispositivos ópticos y VLSI). Las redes neuronales se pueden simular en cualquier ordenador.

Las redes neuronales pueden parecerse al cerebro, pero ¿en qué medida y de qué forma? Los mecanismos bioquímicos en la sinopsis sustentan la metáfora del cálculo, produciendo resultados que los investigadores de las redes neuronales afirman que son “como” la suma, la resta y la multiplicación. Los pesos sinápticos de las conexiones entre neuronas se utilizan para almacenar conocimiento y se determinan siguiendo un proceso de aprendizaje (entrenamiento de la red).

Las redes neuronales artificiales se suelen implementar en los ordenadores convencionales y no son una buena imitación de las biológicas como se desprende de la tabla I.

Cerebro	Ordenador
Analógico	Digital
1011 neurona	108 puertas
Masivamente paralelo	Secuencial/paralelo
Entrenado (aprendizaje)	Programado
Neuronas lentas	Conexiones rápidas
Lógica difusa	Lógica precisa
Tolerancia al ruido	Intolerancia al ruido
Tolerancia a fallos	Intolerancia a fallos
Procesamiento sub-simbólico	Procesamiento numérico y simbólico
Memoria direccionable por contenido	Memoria no direccionable
Memoria distribuida	Memoria localizada
Facilidad en reconocimiento de patrones	Dificultad en reconocimiento de patrones

Tabla I. Relación de propiedades del cerebro frente a las del ordenador.

Las redes de neuronas artificiales (RNA) son los enfoques más famosos y ampliamente aplicados del aprendizaje máquina. Presentan las siguientes ventajas: son capaces de encontrar patrones, prototipos y relaciones

en el conjunto de datos disponible, liberando al científico de la búsqueda de un modelo y permitiendo que los datos se expliquen por sí mismos. El proceso de aprendizaje suele ser rápido y no precisa de un conocimiento profundo de la materia. Los algoritmos de aprendizaje son universales y se pueden aplicar a una amplia variedad de problemas prácticos. Requieren pocos parámetros de ajuste que son relativamente fáciles de comprender y seleccionar.

Asimismo, las RNA son *aproximadores universales*, es decir, pueden aproximar cualquier función matemática continua con el grado de precisión que se desee siempre que contemos con un conjunto suficiente de datos y neuronas. Si hay una dependencia no lineal en un conjunto dado de datos se puede capturar utilizando redes neuronales. Este resultado es de gran importancia práctica, puesto que significa que en el caso de que la red neuronal falle es difícil que otra técnica de modelado empírico tenga éxito. Además, las RNA son clasificadores Bayesianos que minimizan las probabilidades de clasificación incorrecta, es decir, implementan la *regla de Bayes*.

Las RNA presentan algunos inconvenientes. Muchos usuarios ven las RNA como piezas mágicas del software que encuentran patrones o perfiles en los datos, o establecen relación entre ellos. La descripción puramente matemática de una red neuronal no es fácil de comprender y se suele contemplar como una caja negra que relaciona entradas con salidas sin dar más información

acerca de la naturaleza de las relaciones. Una solución potencial se puede encontrar añadiendo la interpretación de las redes neuronales con sistemas difusos.

Máquinas de vectores soporte

Las máquinas de vectores soporte (MVS) son un conjunto de métodos de aprendizaje supervisado que se usan para clasificación estadística y análisis de regresión. Fueron desarrolladas por Vladimir Vapnik y su equipo en los laboratorios AT&T. Las MVS proporcionan soluciones con un balance óptimo entre una representación precisa de los datos existentes y el comportamiento con nuevos datos no utilizados en el proceso de entrenamiento. En contraste con las RNA, los resultados del aprendizaje estadístico tienen complejidad óptima para el conjunto dado de datos utilizados en el aprendizaje y puede tener capacidad de generalización si se seleccionan los parámetros adecuados. Las MVS representan el conocimiento aprendido mediante los puntos o patrones más informativos, llamados vectores soporte. Se aplican con éxito para resolver problemas de clasificación, predicción y detección de novedades. Una propiedad importante de las MVS es que la determinación de los parámetros del modelo se lleva a cabo mediante un problema de optimización convexa, con lo cual cualquier

solución que sea mínimo local es también un mínimo global.

En contraste con las RNA que requieren una cantidad significativa de datos para desarrollar el modelo, las MVS proporcionan soluciones a partir de un número reducido de registros. Por ello, son de gran aplicación cuando los datos son costosos como ocurre en el desarrollo de nuevos productos y en análisis de "microarrays" en biotecnología. Asimismo, otra ventaja es que aunque la regla de aprendizaje se desarrolla a partir de un proceso de optimización no lineal, la función objetivo es convexa y así la solución del problema de optimización es relativamente directa. Las MVS permiten el control explícito sobre la complejidad de los modelos desarrollados ajustando algunos parámetros. Además, la teoría del aprendizaje estadístico, en la que están basadas las MVS define una medida de la complejidad del modelo. Según dicha teoría, existe una complejidad óptima basada en el mejor balance entre la capacidad de un modelo sobre datos conocidos y su capacidad de generalización sobre nuevos datos.

Como el fundamento de las MVS son las observaciones más ricas en información, permiten comparar los nuevos datos con los vectores soporte y definir la novedad de dichos datos con respecto a algún criterio. Esta capacidad permite la detección de observaciones atípicas cuando el modelo opera en línea. Asimismo, permiten

condensar un conjunto grande de datos registro en un número reducido de vectores soporte con alto contenido de información. Sin embargo, una desventaja es la dificultad de interpretación que suelen tener los modelos de MVS para los no expertos. Además, el desarrollo de los modelos requiere la selección de parámetros más especializados, incluyendo transformaciones matemáticas complejas llamadas núcleos. Una MVS es una máquina de decisión que no proporciona las probabilidades a posteriori. Una técnica alternativa conocida como la *Máquina de Vectores Relevantes* (MVR), basada en la formulación Bayesiana, proporciona como salida las probabilidades a posteriori.

Computación evolutiva

La evolución biológica se puede contemplar como un proceso de optimización cuyo objetivo es mejorar la capacidad de un organismo o sistema para sobrevivir en ambientes competitivos que cambian dinámicamente. Al hablar de evolución es importante identificar el área en la que se puede definir. Por ejemplo, sistemas de evolución cósmicos, planetarios, orgánicos o desarrollados por el hombre.

Podemos contemplar el proceso de la evolución natural como un algoritmo abstracto que se puede imple-

mentar en un ordenador para crear nuevos artefactos o mejorar las propiedades de los artefactos existentes. La computación evolutiva representa de varias formas los tres grandes procesos de la teoría de la evolución natural:

1. La existencia de una población de individuos que se reproducen siguiendo el proceso de la herencia.
2. La adaptación al ambiente cambia al variar las diferentes propiedades de los individuos.
3. La selección natural mediante la cual los mejores individuos, es decir, los mejor adaptados son los que sobreviven.

La idea central de la computación evolutiva es que la evolución simulada generará individuos que mejorarán su rendimiento de manera similar a como las especies biológicas lo hicieron en millones de años de evolución natural.

La computación evolutiva se ocupa de estudiar los sistemas de resolución de problemas mediante ordenador que usan modelos computacionales de procesos evolutivos, como la selección natural, la supervivencia del mejor adaptado y la reproducción, como componentes fundamentales de tales sistemas. Ella comprende los algoritmos genéticos, estrategias de evolución, programación evolutiva y programación genética.

El primer algoritmo genético fue formulado por Holland [16]. Posteriormente, De Jong [9] demostró que los algoritmos genéticos se pueden utilizar para resolver problemas de optimización de manera que se puedan alcanzar soluciones óptimas. Desde entonces se han realizado muchas modificaciones y mejoras en estos algoritmos.

Las soluciones de ciertos problemas reales se pueden representar mediante un vector N -dimensional (cromosoma) de variables binarias, enteras o reales, una cadena, o cualquier otra estructura, que constituye un individuo de la población, es decir, un punto del espacio de soluciones. Si las variables son binarias el espacio de soluciones tiene 2^N soluciones posibles. Cada una de las características del vector de representación juega el papel de un gen. Así, un cromosoma es una secuencia ordenada de genes. Una función de adecuación (*fitness*), también llamada de aptitud o de evaluación, establece el grado de adecuación de individuos particulares de una población, es decir, el valor de dicha solución. En teoría de control se le llama también función de error y en teoría de juegos función de coste.

El algoritmo genético básico comienza con una población de individuos, que puede ser aleatoria. Mediante un proceso de selección basado en la función de adecuación se eligen aquellos individuos que van a formar parte en la creación de descendientes para la próxima genera-

ción. El *mecanismo de selección* debe de procurar que los individuos mejor valorados tengan más posibilidad de ser seleccionados. El mecanismo de selección más popular es el método de la ruleta donde la probabilidad de selección de un individuo es proporcional a su valor de aptitud. Una vez creada una nueva población se lleva a cabo el proceso de reproducción de nuevos descendientes aplicando el *operador de cruce* o recombinación por el que se generan uno o más descendientes combinando el material genético seleccionado aleatoriamente de dos o más progenitores. Si en la selección se eligen los individuos más adecuados la presión selectiva puede causar una convergencia prematura debido a la diversidad reducida de las nuevas poblaciones.

La *mutación* es el proceso de cambiar aleatoriamente valores de genes de un cromosoma. El objetivo de la mutación es introducir nuevo material genético y así incrementar la diversidad genética. Deberá de aplicarse con cuidado para no distorsionar el material genético en individuos altamente adecuados. Por dicho motivo, la mutación se suele aplicar con probabilidades pequeñas. También se pueden utilizar probabilidades de mutación que sean inversamente proporcionales a la adecuación de los individuos, de forma que los menos adecuados sean mutados con mayores probabilidades. Además, las probabilidades de mutación deberán ser altas al principio para garantizar la exploración y se irán reduciéndose poco a

poco para conseguir la explotación en las generaciones finales. La reproducción se puede aplicar con reemplazamiento, en cuyo caso los individuos generados nuevamente reemplazan a individuos progenitores sólo si la adecuación de los nuevos descendientes es mejor que la de los correspondientes progenitores. La tabla 2 muestra la representación matemática de un sistema genético.

Cromosoma	Palabra binaria, vector, etc.
Gen	Característica del problema
Alelo	Valor de la característica
Loco	Posición en la palabra
Genotipo	Estructura
Fenotipo	Estructura sometida al problema
Individuo	Solución
Generación	Ciclo

Tabla 2. Representación matemática de un sistema genético.

La Computación Evolutiva presenta múltiple ventajas, como las siguientes:

- a) Permite la generación de novedades, es decir, su potencial ilimitado para crear nuevas soluciones en muchos problemas prácticos. Cuando se conoce de antemano la función de aptitud se pueden encontrar soluciones novedosas después de varias etapas evolutivas.
- b) Obtiene modelos robustos pues permite implementar modelos empíricos que se pueden interpretar y son robustos para pequeños cambios del proceso.
- c) Su coste de implementación y mantenimiento es mínimo ya que los modelos robustos se generan con una reducida intervención humana.

Sin embargo, también presentan inconvenientes, requieren computación intensiva pero, afortunadamente, con el continuo crecimiento de la potencia computacional de los ordenadores, se va reduciendo gradualmente dicho inconveniente. Por otro lado tiene limitaciones en la dimensionalidad. La computación evolutiva no es muy eficiente cuando el espacio de búsqueda es demasiado grande.

Computación de colonias de hormigas

Las hormigas son insectos cuya supervivencia depende principalmente de la cooperación. Aparecieron sobre la tierra hace unos cien millones de años y su población actual se estima en unos 10^{16} individuos. Los etólogos han estudiado los comportamientos emergentes y complejos que surgen en las colonias de hormigas. Su comportamiento no sólo se basa en la recogida de comida y en la construcción de hormigueros, sino también en la división del trabajo, apoyo cooperativo y organización de cementerios. Las hormigas son básicamente agentes de estímulo-respuesta. A pesar de la simplicidad de su conducta individual forman una organización altamente estructurada.

Uno de los primeros comportamientos estudiados por los etólogos fue la capacidad de las hormigas de encontrar el camino más corto entre el hormiguero y la fuente de comida. ¿Cómo encuentran el camino más corto sin ningún mecanismo activo de coordinación? Si observamos un hormiguero vemos como decenas de hormigas van y vienen para buscar comida y llevarla al hormiguero. En principio, las hormigas se pasean aleatoriamente. Cuando una de ellas encuentra comida otras le siguen de cerca. Los investigadores estaban interesados en la manera en la que encuentran el camino desde el punto donde han encontrado la comida hasta el

hormiguero. Generalmente las hormigas eligen el camino más corto posible. Para comprobarlo alejaron la comida del hormiguero y sólo dejaron dos rutas, una corta y otra más larga, como únicos caminos. Después de unos minutos se observó que las hormigas empezaban a regresar casi todas por el camino más corto. En un segundo experimento dejaron sólo el camino largo y encontraron la comida pero cuando le añadieron de nuevo el camino lo fueron utilizando poco a poco mayoritariamente. ¿Cómo lo conseguían? Se ha comprobado que las hormigas durante su marcha van dejando un rastro detrás de ellas en la forma de una sustancia llamada *feromona* y así crean un camino de olor. La hormiga selecciona un camino según la concentración de feromona que encuentra en cada momento. La hormiga que sigue el camino más corto realiza más trayectos que la que sigue uno más largo. Es decir, sigue el camino más corto que terminará siendo el más recorrido. Cuando una hormiga encuentra un buen camino desde la colonia a la fuente de comida es más probable que las demás sigan dicho camino. Ello conduce a que las hormigas sigan mayoritariamente un único camino. ¿Pero qué ocurre cuando toda la comida que había en ese lugar se ha llevado al hormiguero? El olor del camino va desapareciendo porque las feromonas se volatilizan. Si no fuera por ello los caminos encontrados por las primeras hormigas serían demasiado atractivos para ser seguidos por las demás. Desde el punto de vista

computacional dicho proceso de volatilización presenta la ventaja de evitar la convergencia a una solución mínimo local. Por lo tanto, las hormigas utilizan su ambiente como medio de comunicación. Ellas intercambian información depositando feromonas. La información intercambiada tiene alcance local, ya que sólo una hormiga situada en un punto donde se han depositado feromonas tiene una noción de ellas. Es un mecanismo de coordinación indirecta entre agentes o acciones. El principio que se sigue es que el rastro dejado en el ambiente por una acción de un agente estimula el comportamiento de una próxima acción por él mismo u otro agente diferente. Dicho mecanismo de estigmatización observado en insectos sociales es una forma de autoorganización que produce estructuras complejas e inteligentes, sin necesidad de planificación o control, incluso sin comunicación directa entre ellos. Sólo con la colaboración eficiente entre insectos (agentes) muy simples que no tienen ni memoria, ni inteligencia, ni conocimiento, se consigue cierta forma de inteligencia colectiva.

Otro comportamiento que ha atraído la atención de los etólogos es que muchas especies de hormigas, como la *Lasius niger*, retiran los cuerpos de sus compañeras muertas y los amontonan. Resulta que un montón pequeño de cuerpos es suficiente para un cementerio. Ellas transportan los cuerpos al lugar donde ya hay otros cuerpos. Es decir, exhiben el comportamiento de agrupar los cadáveres para formar cementerios. La decisión de

recoger y depositar un cadáver se basa en la información local de la posición actual que ocupa. Es un ejemplo de agrupamiento.

Un comportamiento similar también se ha observado en muchas especies, como la *Leptothorax unifasciatus*, en la manera que tiene la colonia de cuidar de su prole. Las larvas son ordenadas de tal manera que las crías se colocan en anillos concéntricos de forma que las larvas más pequeñas se colocan en el centro y las más grandes en la periferia. Los grupos concéntricos están organizados de forma que las larvas pequeñas reciban menos espacio individual que las más grandes. Aunque este comportamiento todavía no se comprende bien se han realizado modelos matemáticos para simular los comportamientos de agrupación y ordenación de datos.

Las observaciones del comportamiento de las hormigas han inspirado el desarrollo de un gran número de algoritmos basados en colonias de hormigas. A partir de estos estudios se propusieron los primeros modelos algorítmicos, como los desarrollados por Marco Dorigo [10] que se han utilizado principalmente para encontrar la solución óptima, o buenas soluciones, en problemas de optimización definidos sobre espacios de búsqueda discretos. Desde entonces el desarrollo de algoritmos basados en hormigas ha acaparado la atención de muchos investigadores.

La idea de un algoritmo de colonias de hormigas es imitar dicho comportamiento con "hormigas artificiales" que se mueven sobre el grafo que representa el problema que tratamos de resolver. Una hormiga artificial se caracteriza por lo siguiente:

- a) Habita en un mundo artificial discreto, como puede ser un grafo, con sus vértices o nodos y sus aristas;
- b) Sus feromonas se evaporan más rápidamente que en el mundo real
- c) La cantidad de feromona segregada depende de la calidad de la solución encontrada;
- d) En la mayoría de los casos, el rastro de feromona se actualiza después de generada la solución.

Los algoritmos basados en hormigas se basan en poblaciones. Ello posibilita una implementación paralela con el fin de incrementar la eficiencia computacional de dichos algoritmos. La forma más simple de paralelismo es a nivel de colonia. La paralelización funcional para una única colonia se puede llevar a cabo mediante una arquitectura de maestro-esclavo, paralelizando la búsqueda local o paralelizando la construcción de soluciones.

Las técnicas de agrupación o categorización de datos (*clustering*) desempeñan un papel importante en la inteligencia computacional como métodos de

aprendizaje no supervisado. Por ejemplo, en el campo financiero es importante formar grupos de clientes con característica similares como la edad, tipo de trabajo, estado, etc., y obtener el perfil de cada grupo a la hora de otorgar, o no, una hipoteca. Hay que tener en cuenta la dificultad de este tipo de problemas. Si deseamos agrupar 100 pacientes en 5 grupos (*cluster*) diferentes resulta que el número posible de agrupaciones diferentes es del orden de 10^{67} . Por ello, es sumamente importante diseñar métodos que encuentren la agrupación óptima sin necesidad de analizar cada una de las agrupaciones posibles.

Los algoritmos de hormigas se han usado también para resolver problemas de optimización discreta. Por ejemplo, definir rutas de vehículos, ordenar secuencias o definir rutas en redes de computadores. También se han aplicado a problemas de secuenciación de la producción, balance de carga en redes de telecomunicación, asignación de frecuencias o recursos en redes de comunicación, direccionamiento en redes de comunicación, secuenciación de sensores, satisfacción de restricciones, empaquetamiento, recargas nucleares, orientación, secuenciación de la producción, secuenciación de proyectos, circulación en centros comerciales, localización de centros de servicio, ubicación de máquinas, etc.

Las empresas de telecomunicación British Telecommunications y France Telecom han aplicado algoritmos

de hormigas para resolver problemas de bloqueo de la red que surgen cuando se incrementa la carga en la misma. La solución consiste en usar agentes virtuales, cuyo trabajo está basado en comportamientos de hormigas, gracias a cuyos intercambios telefónicos se puede incrementar la capacidad de evitar segmentos sobrecargados en la red.

Computación de enjambres

La inteligencia de enjambres es un comportamiento colectivo de agentes inteligentes en sistemas descentralizados. Aunque no hay control centralizado que dicte el comportamiento de los agentes, las interacciones entre ellos causan la emergencia de un patrón global. La formación de equipos se ha observado en muchas especies de animales e insectos sociales, por ejemplo, formando colonias de hormigas, bandadas de pájaros, bancos de peces, enjambres de abejas, manadas de lobos, etc. Los equipos o grupos suelen estar controlados por un líder en muchos casos. Uno de los primeros estudios de tales sociedades de animales fue realizado por Eugéne N. Marris a comienzos del siglo XX sobre babuinos salvajes. En estas sociedades el comportamiento de los individuos está dictado por una jerarquía social. También es interesante el comportamiento autoorganizado de las especies

que viven en grupos sin que haya un líder identificado. En estos grupos sociales los individuos no tienen conocimiento del comportamiento global del grupo ni tienen información global acerca de su medio ambiente. No obstante, tienen la capacidad de reunirse y moverse juntos basada en interacciones locales entre ellos. A partir de dicha interacción local emergen comportamientos colectivos más complejos, como la exploración del entorno o el guiado del enjambre [23]. Se evitan las colisiones en una bandada de aves al ir igualando cada una su velocidad con las vecinas. Al mismo tiempo, se concentra la bandada al tratar de estar cada ave cerca de sus vecinas. El reclutamiento que hacen ciertas especies de abejas a través de movimientos y danzas es una estrategia de aviso óptima para llevarlas a los sitios donde algunas han encontrado alimentos.

La optimización de enjambres de partículas fue introducida por J. Kennedy y R.C. Eberhart [17] en 1995 y está basada sobre un modelo psicológico-social de influencia y aprendizaje social. En computación, un *enjambre* es un grupo de agentes móviles que se comunican entre sí actuando sobre su entorno local. Los individuos (partículas) de un enjambre siguen un comportamiento muy simple: emular los éxitos de los individuos vecinos. El comportamiento colectivo que emerge es el descubrimiento de regiones óptimas en un espacio de búsqueda de alta dimensión.

Mientras que en los algoritmos genéticos o en las estrategias evolutivas el comportamiento de los individuos influye directamente en el comportamiento de las futuras generaciones, en los enjambres esta influencia es indirecta, ya que los individuos transmiten mensajes generales en lugar de hacerlo por pares. Los mensajes pueden ser de diferentes tipos: químico (feromonas), auditivos (sonidos), danzas (movimientos) o alteración del entorno (por ejemplo, eliminando fuentes de alimentación)

La inteligencia de enjambres se puede contemplar como un método estocástico basado en poblaciones o un enfoque meta-heurístico para resolver problemas de optimización. Es decir, la optimización de enjambres de partículas es un método de optimización global donde las soluciones de un problema de interés se representan como puntos en un espacio N -dimensional. Cada partícula está representada por un vector de posición y un vector de velocidad. Las partículas tienen asignadas unas velocidades iniciales hacia puntos-solución según algún criterio de adecuación o evaluación. En analogía con la computación evolutiva, un enjambre es similar a la población mientras que una partícula es similar a un individuo. En términos simples, la posición de cada partícula se ajusta según su propia experiencia y las de sus vecinas. La nueva posición de una partícula se obtiene sumándole a la posición actual un vector de

velocidad. El vector de velocidad conduce el proceso de optimización y refleja tanto el conocimiento experimental (componente cognitiva) de la partícula como la información intercambiada socialmente con su entorno de partículas (componente social). El flujo de información a través de la red social formada depende del grado de conectividad entre los nodos de la red, de la cantidad de agrupaciones y de la distancia media más corta de un nodo a los otros. Se han desarrollado diferentes estructuras de redes sociales que se han estudiado empíricamente (estructura de estrella, anillo, rueda, pirámide, rejilla, etc.).

Los algoritmos básicos de enjambres de partículas se han aplicado con éxito a un buen número de problemas de optimización. Por ejemplo, se han desarrollado estrategias de búsqueda en Internet inspiradas en el comportamiento de las abejas de la miel para buscar alimentos [30], robots para generar patrones basados en un modelo de orientación espacial de las arañas [18], configuración de las máquinas en una fábrica inspirada en cómo las colonias de avispas coordinan sus actividades individuales y las tareas colectivas para satisfacer las necesidades colectivas [4].

Un aspecto importante para determinar la eficiencia y la precisión de un algoritmo de optimización es el balance entre exploración y explotación. La exploración es la capacidad de un algoritmo de búsqueda para exa-

minar diferentes regiones del espacio de búsqueda con el fin de encontrar una buena solución, un óptimo. Por otro lado, la explotación es la capacidad de un algoritmo para concentrar la búsqueda en una región prometedora con el fin de refinar una solución candidata. Un buen algoritmo para problemas de optimización debe de conjugar de la mejor manera posible estos dos objetivos contrapuestos.

Los resultados obtenidos muestran que estos algoritmos tienen problemas con la convergencia hacia buenas soluciones. Por ello, se han desarrollado múltiples modificaciones para mejorar la velocidad de convergencia y la calidad de las soluciones encontradas. Aunque son algoritmos simples necesitan realizar ajustes de sus parámetros que suelen ser específicos del problema a resolver.

Aprendizaje automático

Una de las características de la inteligencia humana es su capacidad de aprender acerca de los cambios del ambiente para adaptarse a ellos. Los seres humanos mediante aprendizaje adquirimos conocimientos, desarrollamos habilidades para analizar y evaluar el ambiente a través de métodos y técnicas, o por medio de la propia experiencia. Múltiples disciplinas, tales como

las neurociencias, la psicología cognitiva y diferentes ramas de la informática están explorando este complejo fenómeno. El aprendizaje automático y la teoría del aprendizaje estadístico son las que más impacto han tenido sobre la IC.

El aprendizaje automático, también llamado aprendizaje de máquina, permite a los ordenadores aprender a partir de ejemplos, por analogía o por experiencia. Mediante el aprendizaje el sistema mejora con el tiempo y se adapta a los cambios del ambiente. Se han desarrollado varias técnicas de aprendizaje, como el aprendizaje supervisado donde el proceso de aprendizaje está guiado por un profesor, es decir, el sistema utiliza información de una base de datos o generada por un conjunto de sensores para conseguir objetivos, como puede ser el diagnóstico automático de una enfermedad a partir de un conjunto de síntomas o el diagnóstico de posibles averías en automóviles. El objetivo principal de un sistema de aprendizaje es generalizar a partir de su experiencia.

Por otro lado, con el aprendizaje no supervisado se trata de que el ordenador descubra propiedades de los datos, descubra patrones o prototipos realizando agrupaciones de datos en términos de sus similitudes.

El aprendizaje por refuerzo se centra en la cuestión de cómo un agente autónomo o robot que siente y

actúa en su entorno puede aprender a elegir acciones óptimas para alcanzar sus objetivos. Mediante los sensores observa los estados de su entorno y a partir de un conjunto de acciones puede alterar dichos estados. El aprendizaje por refuerzo recoge como información de entrada la retroalimentación que obtiene del mundo exterior como respuesta a sus acciones y usa una estrategia de premio-castigo para aprender una función, la cual permitirá tomar decisiones en el futuro sobre las acciones a tomar según la percepción de su entorno. Las aplicaciones del aprendizaje por refuerzo son múltiples, desde robots móviles que aprenden a salir de un laberinto, programas de ajedrez que aprenden cuáles son las mejores secuencias de movimientos para ganar un juego o un brazo robótico que aprende cómo mover las articulaciones para lograr los movimientos deseados, como los que tienen lugar en las intervenciones quirúrgicas.

La teoría del aprendizaje computacional permite el aprendizaje del sistema a partir de un número reducido de datos muestrales y suministra las bases teóricas para extraer patrones y relaciones entre ellos, realizando un balance entre la complejidad y el rendimiento del sistema. Dicha teoría describe dos maneras claves de aprendizaje predictivo de gran importancia práctica. La primera es el método inductivo-deductivo en el que el modelo se desarrolla a partir de los datos disponibles

como resultado de un proceso de aprendizaje inductivo, es decir, progresando desde los casos particulares a la relación general capturada por el modelo. El modelo obtenido se aplica a la predicción sobre nuevos datos utilizando la deducción, es decir, progresando de lo general a lo particular.

Lógica difusa

El ser humano utiliza gran cantidad de información que es imprecisa y vaga. Cuando decimos, por ejemplo, “muchas personas utilizan hoy día Internet en Andalucía”, estamos suministrando una información imprecisa. ¿Qué proporción de personas utilizan Internet? Para operar con este tipo de información Lotfi Zadeh [36] desarrolló en 1965 la teoría de los conjuntos difusos y la lógica difusa con el título provocativo de “Conjuntos Difusos”. Realmente, la lógica difusa no es difusa. Básicamente, es una lógica precisa basada en el razonamiento aproximado e impreciso. Estas nuevas ideas fueron furiosamente cuestionadas al principio por parte de algunas autoridades académicas, especialmente en Estados Unidos. Sin embargo, varias empresas japonesas como Sony, Hitachi y Nissan vienen desarrollando aplicaciones industriales muy interesantes en varios campos desde los años setenta. El apoyo industrial ha desempeñado

un papel crucial para la supervivencia de este campo de investigación emergente. Esta historia de los sistemas difusos muestra que cuando los éxitos de las aplicaciones industriales hablan, incluso los científicos más arrogantes las escuchan.

En general, un elemento pertenece, o no, a un conjunto. En los conjuntos difusos un elemento pertenece a un conjunto con cierto grado de pertenencia. La lógica difusa permite llevar a cabo razonamientos con dichos factores inciertos para inferir nuevos hechos con un grado de certeza asociado con cada hecho. El conocimiento se distribuye entre las reglas y las funciones de pertenencia. La lógica difusa permite un modelado del sentido común.

Utilizar la lógica difusa conlleva muchos beneficios. Los sistemas difusos convierten problemas complejos en problemas más simples utilizando el razonamiento aproximado. El razonamiento basado en la lógica difusa es más parecido al humano y es menos propenso a errores. Se puede representar adecuadamente la incertidumbre y la no linealidad de los sistemas complejos. Generalmente, la incertidumbre del sistema se captura mediante el diseño de los conjuntos difusos y la no linealidad mediante las reglas difusas. La adquisición de conocimiento en los sistemas difusos es fácil, más fiable y menos ambigua que en los sistemas expertos clásicos. Asimismo, dichos sistemas son más robustos que

los clásicos frente a la información imprecisa y son de fácil interpretación.

ÁREAS DE APLICACIÓN DE LA IC

"La inteligencia consiste no solo en el conocimiento, sino también en la destreza de aplicar los conocimientos en la práctica"

Aristóteles

Los modelos y las técnicas de la IC se han aplicado en múltiples áreas de las ciencias de la tierra y del medio ambiente [7], relacionadas sobre todo con el clima, los océanos y la hidrología. Las redes neuronales se han aplicado a la meteorología por satélite y oceanografía para reconocimiento de patrones y clasificación; en climatología para desarrollar modelos numéricos del tiempo atmosférico, analizar el cambio climático prediciendo la evolución de la temperatura en diferentes puntos de los océanos, y en hidrología para predecir precipitaciones, desbordamientos de ríos e inundaciones, por su capacidad de proporcionar diversas familias de modelos no lineales, efectivos y flexibles, conducidos por los datos. Todas estas aplicaciones del aprendizaje predictivo tienen un alto valor social, humanitario y económico.

Los sistemas difusos se están aplicando en múltiples campos. En los sistemas de transporte se han utilizado controladores difusos predictivos para la operación automática de trenes en el sistema suburbano de la ciudad japonesa de Sendai, implementadas por Hitachi en julio de 1987. Dichos controladores se basan en 6 objetivos ambiguos: seguridad, confort, ahorro energético, velocidad, tiempo transcurrido y precisión en la parada. Los conjuntos difusos diseñados utilizan variables lingüísticas como, "bueno", "malo", "muy bueno", "muy malo" y "valor intermedio" con funciones de pertenencia triangulares, trapezoidales y sigmoidales. El sistema trata de mantener el confort de los pasajeros en los momentos de aceleración y desaceleración. Lo más asombroso de esta aplicación es que la tremenda complejidad del control de los trenes suburbanos esté capturada por sólo nueve reglas. El tren suburbano se mueve tan suavemente que los pasajeros que van de pie no necesitan agarrarse. Una pecera puede viajar las 8.4 millas de la ruta y parar en las 16 estaciones sin derramarse una gota de agua.

Asimismo, se han aplicado al control de procesos industriales, como el control de hornos de cemento construidos en Dinamarca a principio de los ochenta. Empresas como Otis, Hitachi y Mitsubishi han desarrollado ascensores cuyos dispositivos emplean lógica difusa para ajustar el nivel de tráfico. En la industria

del automóvil algunas empresas han desarrollado sistemas difusos en la fabricación de coches, como Nissan y Subaru. La empresa Matsushita Electric ha desarrollado sistemas difusos en sus máquinas de lavado automático de vehículos. Empresas, como Canon, han desarrollado cámaras fotográficas con enfoque difuso. El enfoque automático de una cámara utiliza señales de infrarrojos o ultrasonidos para determinar la distancia al objeto. Si hubiera dos o más objetos presentes en la escena tal sistema podría dar lugar a confusión. Canon resolvió el problema de la presencia de varios objetos en la escena utilizando lógica difusa para tener en cuenta a todos ellos. En 1990, Matsushita utilizó lógica difusa para desarrollar un estabilizador de imagen digital en las cámaras de vídeo comparando cada par de fotogramas para ver cuánto se habían desplazado y ajustarlo convenientemente.

También se han desarrollado sistemas difusos en diferentes áreas del diagnóstico médico. Ejemplos típicos son el control del oxígeno inspirado o de la anestesia durante una intervención quirúrgica y la toma de decisiones médicas mediante lógica difusa en cuidados intensivos, enfermedades coronarias, etc.

En Internet también se han utilizado sistemas difusos, por ejemplo, para mejorar los motores de búsqueda Web o para el modelado difuso de los usuarios, que será una de las grandes aplicaciones en el futuro.

La bioinformática acapara muchas de las aplicaciones actuales de la IC. En concreto, la expresión genética, selección informativa y discriminativa de genes, clasificación de secuencias de proteínas, composición de fragmentos de ADN, predicción de estructuras de proteínas, clasificación de "microarrays" y genética humana. Por otro lado, también hay notorias aplicaciones en los campos de la salud, fabricación, diseño industrial, transporte, cadenas de suministro, análisis de mercados, análisis financiero, vigilancia y control en centrales nucleares, exploración espacial y entretenimiento.

La expresión genética es el proceso por medio del cual la información codificada de un gen se convierte en estructuras que operan en la célula. Pero no todos los genes se expresan al mismo tiempo ni en todas las células. Hay sólo un grupo de genes que se expresan en todas las células del organismo. Se han propuesto múltiples enfoques desde la IC para abordar dichos problemas, utilizando redes neuronales, algoritmos genéticos y Análisis de Componentes Principales. En 2002, Yuhui et al. [34] propusieron un nuevo enfoque para el análisis de datos de expresión génica utilizando redes neuronales de agrupaciones asociativas que evalúan similitudes entre pares de muestras genéticas a través de interacciones de un grupo de muestras de genes. Han demostrado su robustez en un conjunto de datos de leucemia que son de alta dimensionalidad (7.129 genes) alcanzando

un 98.61% de precisión. Asimismo, se han propuesto otros algoritmos para el análisis de datos de expresión genética basados en árboles autoorganizativos y redes neuronales autoorganizativas con aprendizaje no supervisado.

La clasificación de secuencias de proteínas es una tarea crucial en la interpretación de datos genómicos. Destacamos aquí los dos algoritmos propuestos en 2008 por Busa-Fekete y colaboradores [2] basados en la representación de datos similares de proteínas mediante árboles binarios ponderados. La clasificación de secuencias de proteínas en familias es una herramienta importante en la anotación de propiedades estructurales y funcionales. Mohamed et al. [20] han presentado un sistema de clasificación utilizando técnicas de reconocimiento de patrones para crear una representación vectorial de una secuencia de proteínas y entonces clasificar la secuencia en un número dado de familias.

La selección de genes que tienen distintos niveles de actividad para favorecer el desarrollo de cánceres ha emergido como un objetivo fundamental del análisis de datos en IC. Sin embargo, con muchos miles de genes a elegir de, a lo sumo una cuantas decenas de conjuntos de medidas disponibles, el análisis diferencial constituye un gran reto. Recientemente, Zang y colaboradores [37] han desarrollado Máquinas de Vectores Soporte para selección genética, clasificación de cánceres y

clasificación funcional de genes. El diagnóstico preciso y la clasificación son asuntos clave para el tratamiento óptimo de pacientes con cáncer. Varios estudios han demostrado que la clasificación del cáncer se puede estimar con gran precisión a partir de *microarrays* de expresión genética utilizando redes de neuronas artificiales y, en particular, redes neuronales probabilísticas. Fogel [12] ha resaltado las ventajas de acoplar las redes neuronales con la computación evolutiva para predicción y descubrimiento de clases en *microarrays*. Chu y colaboradores [3] han utilizado Redes Neuronales Difusas en tres conjuntos de datos de expresión genética bien conocidos (linfoma, tumor y cáncer de hígado) alcanzando una precisión del 100% utilizando un número mucho menor de genes que en los trabajos previamente publicados.

La predicción de estructuras de proteínas es uno de los objetivos más importantes perseguidos en bioinformática. Su objetivo es predecir la estructura tridimensional de las proteínas a partir de sus secuencias de aminoácidos que es de gran importancia en medicina y farmacología para el diseño de medicamentos y también en biotecnología para el diseño de enzimas. La utilización de algoritmos genéticos permite una reducción significativa del número de estructuras potencialmente exploradas. Sin embargo, la complejidad del problema permanece prohibitiva requiriendo el uso de computación paralela. El conocimiento de las estructuras de proteínas es crucial para determinar la función de una proteína y sus interacciones con el ADN, ARN y las enzimas. Se ha

puesto de manifiesto que los métodos de aprendizaje automático con varios esquemas de codificación y clasificación mejoran la precisión de la predicción de la estructura de proteínas.

Uno de los objetivos de la epidemiología genética es la identificación de genes asociados con enfermedades. Para ello hay que desarrollar técnicas que tengan en cuenta la importancia de las interacciones entre factores genéticos y factores ambientales en la etiología de enfermedades tales como la hipertensión. Este reto se debe en parte a las limitaciones de los métodos estadísticos paramétricos para detectar efectos que son dependientes sólo, o parcialmente, de las interacciones. Recientemente, Ritchie y colaboradores [24] han propuesto una red neuronal de programación genética para mejorar la identificación de combinaciones gen-ambiente asociadas con un riesgo de enfermedad. Los estudios empíricos llevados a cabo han puesto de manifiesto la excelente capacidad de la red para la identificación en las interacciones gen-gen y gen-ambiente.

La demanda creciente de productos alimenticios más saludables ha favorecido las aplicaciones de las redes neuronales en el campo de la microbiología predictiva para modelar el crecimiento microbiano a lo largo del tiempo [14], así como para predecir parámetros de crecimiento y ver cómo dicho crecimiento se ve afectado por procesos bioquímicos extrínsecos y por condiciones ambientales.

Las tareas para la invención de nuevos productos suelen ser: identificación de clientes y requisitos empresariales para los nuevos productos, caracterización de productos, diseño óptimo del nuevo producto y validación del diseño. La computación evolutiva y las máquinas de vectores soporte son apropiadas para resolver problemas de este tipo. Las máquinas de vectores soporte son capaces de lograr modelos a partir de pequeños registros de datos que es lo usual en el desarrollo de nuevos productos. Ellas permiten desarrollar modelos para la toma de decisiones críticas en las primeras fases de la invención.

La computación evolutiva es muy eficiente para generar estructuras de diferentes sistemas físicos como circuitos electrónicos generados automáticamente y sistemas ópticos. Los algoritmos genéticos y las estrategias evolutivas se han utilizado en numerosas aplicaciones para el diseño óptimo de piezas de automóvil, alas de aviones, formulaciones óptimas de detergentes, etc. Recientemente, la inteligencia de enjambres ha mostrado su capacidad para el diseño óptimo en problemas industriales con alto nivel de ruido.

El objetivo europeo de alcanzar el 20% de suministro de energía procedente de fuentes renovables para el año 2020 proporciona una importante continuidad en el desarrollo de la energía eólica para los próximos años. Se espera que hasta el 16% de la electricidad generada en Europa pueda proceder del viento. En este escenario

de alta integración de la energía eólica, la predicción de la velocidad del viento en parques eólicos juega un papel fundamental, tanto para los productores como para la gestión de la red. La utilización de técnicas de la IC es crucial para la predicción a corto plazo de la velocidad del viento.

La IC se ha aplicado también en los sistemas de vigilancia y diagnóstico que operan en las centrales nucleares. Se ha utilizado como técnicas de análisis de ruidos, validación de sensores y supervisión en línea, regulación de medidas de diagnóstico y vigilancia, mejora de la eficiencia continua de la central nuclear, identificación de paso, sistemas de supervisión y diagnóstico, etc. El papel de la IC en la industria de la energía nuclear está en constante transición debido a los objetivos operativos de las centrales, las necesidades futuras y los requisitos regulatorios. El artículo de R.E. Uhrig y J.W. Hines [29] recoge aplicaciones de la IC en este campo.

Determinar la secuenciación óptima es la actividad más destacada en las cadenas de suministro. Incluye la carga de vehículos y la ruta a seguir, selección de la empresa de transporte, minimización del tiempo de reabastecimiento, gestión de inventarios, etc. La computación evolutiva y la inteligencia de enjambres se han aplicado con gran eficiencia a problemas de secuenciación óptima con alta dimensionalidad.

Las redes neuronales, la computación evolutiva y los sistemas difusos tienen capacidades únicas para el análisis de mercados financieros. Por ejemplo, las redes autoorganizativas detectan por aprendizaje los grupos de nuevos clientes y sus perfiles. La computación evolutiva genera modelos productivos para gestionar la relación de clientes. La lógica difusa permite cuantificar la conducta de los clientes que es crítica para el análisis de los datos. Los agentes inteligentes también se pueden utilizar en el análisis de mercados simulando las respuestas de los clientes a nuevos productos y las fluctuaciones de los precios.

Las redes neuronales y la programación genética permiten el uso de modelos de predicción para múltiples indicadores financieros derivados de datos pasados. Los agentes inteligentes pueden generar conductas emergentes basadas en respuestas de agentes económicos. La computación evolutiva se ha aplicado a una amplia área de optimización de carteras de valores diferentes.

La IC desempeña un papel significativo en las áreas del diagnóstico médico, supervisión sanitaria y construcción de sistemas consultores sanitarios. Las redes neuronales tienen grandes aplicaciones en diagnóstico médico por su capacidad para el reconocimiento de patrones. Por ejemplo, en la detección de tumores o de micro-calcificaciones.

Se han desarrollado redes neuronales para la resolución de problemas de optimización sobre grafos [13] que son NP difíciles y que se han aplicado a múltiples problemas, como la asignación de códigos en estaciones de telefonía móvil.

Algunas aplicaciones de tiempo libre están centradas en el diseño de juegos inteligentes, juegos para la gimnasia mental que permiten, por ejemplo, contrarrestar la degradación de las capacidades cognitivas con la edad. Las redes neuronales están en la base de las capacidades de aprendizaje de los juegos diseñados y los agentes inteligentes ofrecen un marco de trabajo para definir los personajes del juego. La industria de los videojuegos genera actualmente más dinero que el cine y la música juntos. Se estima que en 2009 obtuvo unos beneficios de 57.000 millones de dólares y sus perspectivas de crecimiento siguen siendo buenas. La ley de Moore sobre el incremento de la velocidad de los procesadores a lo largo del tiempo también puede aplicarse al desarrollo de videojuegos, que parecen duplicar su complejidad cada 18 meses. El futuro de los juegos no pasa por tener más resolución de pantalla, porque ya es muy buena, ni por lograr una gran capacidad de memoria, porque ya es la adecuada, sino por incorporar técnicas de inteligencia artificial para hacer los juegos mucho más interesantes. Se trata de modelar el comportamiento de jugadores no humanos mediante técnicas de búsqueda de rutas,

máquinas de estados difusas e inteligencia emergente que permiten obtener una serie de criaturas, como el popular Tamagotchi, que son capaces de ir aprendiendo en función de las decisiones del jugador y al mismo tiempo evolucionar de forma acorde a estas acciones y a su aprendizaje. Las técnicas más utilizadas aquí son las redes neuronales y los algoritmos genéticos que proporcionan al jugador la sensación de que la evolución de estas criaturas es real y no simulada por estar inspiradas en la naturaleza.

Por otro lado, muchas empresas, como Microsoft, tiene como retos el desarrollo de líneas de investigación de la IA, tales como el desarrollo de interfaces inteligentes que permitan mejorar la interacción hombre-máquina, sistemas que permitan conversar libremente con el ordenador prescindiendo del teclado y del ratón, nuevas técnicas de navegación, etc. En la línea del aprendizaje computacional se pretende la clasificación y agrupación de textos y documentos según su contenido para la gestión del conocimiento y la búsqueda inteligente en Internet. El proyecto de la Web semántica trata de dotar a Internet de inteligencia, también llamado "cerebro global", que no es otra cosa que organizar el caos de información reinante en Internet. Se espera que en un futuro la red sea capaz de autoorganizarse y de aprender de la interacción con los usuarios.

Los nuevos sistemas de seguridad y vigilancia evolucionan hacia tecnologías inteligentes totalmente inte-

gradas que se adaptan a cada necesidad y cada infraestructura, reduciendo costes de personal y ofreciendo un óptimo resultado. Los dispositivos de grabación cuentan con avanzados sistemas de control que permiten su activación por detección de movimiento, grabando 360 grados y con grabación nocturna a través de focos infrarrojos en condiciones desfavorables. Mediante análisis de imágenes se pueden detectar bultos o elementos sospechosos y enviar alarmas a otros dispositivos de comprobación, incluso algunos ofrecen la posibilidad del reconocimiento facial y obtener una ficha completa de la persona. La integración de todos los sistemas de seguridad sobre una misma red incrementaría los niveles de seguridad ya que se crean conexiones entre dispositivos que completan un resultado óptimo.

Las redes neuronales y los sistemas difusos se han aplicado con éxito para el diseño de sistemas de detección de intrusiones en redes informáticas e Internet [22] con el fin de detectar ataques, virus o actividades maliciosas en ordenadores o servidores informáticos.

Se han desarrollado modelos coevolutivos y cooperativos para el diseño de redes neuronales artificiales basados en la coevolución de varias especies de subredes que deben cooperar para generar redes que resuelvan problemas dados, como el diagnóstico de ciertas enfermedades de corazón [15].

Recientemente, las técnicas de IC están recibiendo creciente atención en el área de modelado, control y optimización de las centrales eléctricas [27]. Los estabilizadores de sistemas de energía eléctrica mejoran el comportamiento de dichos sistemas. Se han utilizado técnicas de optimización de enjambres de partículas y algoritmos para el diseño de estabilizadores óptimos [8]

El proyecto ANTS (Autonomous NanoTechnology Swarm) es uno de los recientes desarrollos de la NASA en el que cientos de pequeñas naves espaciales autónomas e interactivas, de peso ligero, son capaces de desplegarse con el fin de emprender exploraciones, suministrar apoyo y asegurar la supervivencia en el espacio. La arquitectura ANTS está inspirada por el éxito de las colonias de insectos sociales. Dicho éxito se basa en la división de las tareas dentro de la colonia. Por una parte, los individuos especialistas, generalmente superan a los generalistas dentro de sus especialidades y, por otra parte, el grupo de especialistas suele superar también al grupo de generalistas cuando hay una interacción social eficiente y una buena coordinación. Utilizan un concepto de software llamado funciones de base neuronal (NBF) que tiende un puente entre las funciones de alto y bajo nivel y crea inteligencia competente de verdadero comportamiento autónomo. El sistema NBF simplificará mucho el desarrollo de sistemas remotos autónomos. Un sistema neuronal de nivel inferior (HLNS) proporciona seguridad a la función

del sistema primario mientras que un sistema neuronal de alto nivel (LLNS) suministra un comportamiento determinado, como resolución de problemas, planificación o secuenciación para alcanzar objetivos. Estos dos sistemas interactúan con un tercer sistema, un Interfaz Neuronal en Evolución (ENI) que permite al sistema de inteligencia artificial situarlo en un contexto del mundo real.

Ahora nos surge la siguiente cuestión: ¿por qué se han desarrollado tantas técnicas y algoritmos diferentes en la IC? Los teoremas de “no hay almuerzo gratis” (no free lunch, [31], [32]) justifican dicha diversidad pues establecen que dos algoritmos cualesquiera son equivalentes cuando su comportamiento medio de todos los problemas posibles que resuelven es el mismo. En concreto, si se considera, por ejemplo, la clase de todos los problemas de optimización o de aprendizaje automático supervisado, todos los algoritmos en promedio tendrán la misma eficiencia o rendimiento. Si para un problema determinado el algoritmo A supera al B, seguramente existirá otro problema en el que el algoritmo B supera al A. Esta cuestión destaca la necesidad de explotar el conocimiento específico de un problema a la hora de diseñar los algoritmos. Recientemente, D. H. Wolpert y W. G. Macready [33] han puesto de manifiesto que en coevolución algunos algoritmos tienen mejor comportamiento que otros promediando sobre todos los problemas posibles. Sin embargo, en los escenarios coevolutivos en-

contrados en la biología, donde no hay un campeón, se sigue verificando el teorema.

TENDENCIAS DE LA IC

"Hacer lo mejor en este momento nos coloca en el mejor lugar para el siguiente"

Oprah Winfrey

El primer congreso internacional sobre Inteligencia Computacional organizado por *The Institute of Electrical and Electronics Engineers* (IEEE) de Estados Unidos tuvo lugar en Orlando (Florida) en el año 1994. El pasado mes de julio ha tenido lugar la celebración de dicho congreso internacional en Barcelona. En este evento han concurrido la Conferencia Internacional de Redes Neuronales (IJCNN 2010), la Conferencia Internacional sobre Sistemas Difusos (FUZZ-IEEE 2010) y el Congreso Internacional sobre Computación Evolutiva (IEEE CEC 2010). En él se han presentado los nuevos retos y las tendencias actuales de la investigación en dicho campo. La siguiente Conferencia Internacional Conjunta de Redes Neuronales Artificiales se va a celebrar el próximo año en San José (California) y sus áreas de interés son el reconocimiento de patrones (habla, escritura, imágenes, visión y vídeo), predicción

en series de tiempo, minería de datos (marketing, redes sociales y tasado de créditos), procesamiento de textos y bioinformática (diagnóstico, pronóstico y descubrimiento de medicamentos).

En este apartado vamos a estimar las tendencias futuras en el campo de la IC aplicada. Por una parte, el crecimiento continuo de la potencia computacional de los ordenadores, y por otra el desarrollo de otras disciplinas, tales como las nanotecnologías y la computación cuántica van a favorecer el desarrollo de nuevas técnicas y modelos de la IC. Por analogía con la economía, la investigación futura en este campo vendrá determinada por un balance entre la oferta y la demanda, es decir, entre las tecnologías disponibles y los proyectos de innovación, y las necesidades industriales esperadas. El modelo de investigación conducido por la oferta es el que representa el *modus operandi* académico, persigue la perpetuación de las ideas científicas en la sociedad a través de un creciente número de publicaciones en revistas académicas y congresos. El modelo de investigación conducido por la demanda atiende las necesidades industriales actuales y las esperadas. A pesar de la multitud de nuevos enfoques prometedores, se estima que el paradigma de la *Computación con Palabras* va a ser uno de los más prometedores por su potencial creador. Los ordenadores están basados en cálculos numéricos y manipulación simbólica mientras que los seres huma-

nos basan su proceso de pensamiento en palabras del lenguaje natural. La idea que subyace en la computación con palabras es la de cerrar la brecha entre el razonamiento automático y el humano utilizando modelos matemáticos para las semánticas del lenguaje natural. La computación con palabras se basa en el concepto de conjunto difuso y la lógica difusa. Esta nueva tecnología nos permitirá extender las capacidades de la lógica difusa para definir sentencias de procesos automáticos expresadas en el lenguaje natural y obtener conclusiones significativas y aceptables para el ser humano. Dicha tendencia viene avalada también porque la adquisición precisa de información suele ser demasiado costosa y el poder expresivo de las palabras es más grande que el poder expresivo de los números.

Los *Sistemas Inmunes Artificiales* (SIA) son otro tipo de algoritmos de la IC que son adaptativos y están inspirados en el sistema inmunológico. El sistema inmunológico existe para proteger a nuestro organismo de agentes peligrosos o dañinos, tales como bacterias, virus u otras formas de vida extrañas, llamadas patógenos. Para distinguir estos agentes de los suyos nuestro cuerpo utiliza unos detectores especiales llamados linfocitos. Los SIA se comenzaron a desarrollar en los años noventa por la creciente necesidad de mejorar la seguridad en los ordenadores. Los algoritmos de selección positiva detectan las intrusiones buscando

patrones específicos de intrusos y los algoritmos de selección negativa detectan las intrusiones como desviaciones de sus propios agentes. Los algoritmos de selección clonada se basan en el mecanismo de proliferación de células de reconocimiento. El algoritmo más popular se llama CLONALG [6] y es muy parecido a un algoritmo evolutivo pero se diferencia en que la reproducción de las células inmunes es proporcional a su afinidad con el antígeno detectado y la tasa de mutación de las células es inversamente proporcional a la afinidad. Sus ventajas son que el tamaño de la población se ajusta dinámicamente, tiene la capacidad de mantener soluciones óptimas locales y dispone de un criterio de parada definido.

Por otro lado, manejar condiciones de operación que vayan cambiando es uno de los mayores desafíos en las aplicaciones del mundo real. Los verdaderos sistemas inteligentes deberán estar en evolución y ser capaces de adaptarse y aprender. Las posibles soluciones pasan por tres métodos, los sistemas adaptativos, la computación evolutiva y los *Sistemas Inteligentes en Evolución* (SIE). El concepto de sistemas inteligentes en evolución se ha establecido recientemente [1] como una sinergia entre los sistemas convencionales, las redes neuronales y los sistemas difusos. Proporcionan estructuras para representación de la información y métodos para el aprendizaje automático en tiempo real. Los SIE son

estructuras auto-adaptativas con capacidades para aprender y resumir. La forma más desarrollada de SIE son los sistemas difusos en evolución. Se basan en el modelo de Takagi-Sugeno que es muy apropiado para identificación estructural y paramétrica. Dicho modelo se basa en la suposición de que los datos se pueden descomponer en grupos difusos. Dentro de cada grupo se define un modelo lineal cuyos parámetros se pueden actualizar fácilmente. La ventaja de estos modelos es que pueden representar sistemas no lineales de manera flexible y efectiva en muchas aplicaciones prácticas.

RETOS FUTUROS

"Procuremos más ser padres de nuestro porvenir que hijos de nuestro pasado"

Miguel de Unamuno

¿Cuál debería ser el gran reto para la IC en el siglo XXI? Esta cuestión fue materia de un panel de discusión en el Congreso Mundial sobre IC celebrado en Anchorage (Alaska) en 1998. La conclusión fue construir una rata artificial, un animal que puede sobrevivir en un entorno hostil. Los pasos intermedios requerirán resolver problemas de percepción, tales como el reconocimiento de obje-

tos, análisis visual y auditivo de escenas, orientación espacial, memoria, aprendizaje, control del comportamiento y algún tipo de razonamiento y planificación.

El cerebro humano está muy bien especializado en análisis de patrones naturales, de escenas visuales y auditivas, control de los movimientos corporales y pasar de las percepciones a las acciones. Además, es flexible, es decir, puede resolver el mismo problema de diferentes maneras. A pesar de los grandes progresos en sistemas artificiales de IC que llevan a cabo funciones cognitivas de bajo nivel estamos lejos de las naturales y la situación es aún peor para las funciones cognitivas de más alto nivel que involucran estructuras de conocimiento complejas para la comprensión del lenguaje, razonamiento, resolución de problemas o planificación.

Un reto futuro para los investigadores en IC consistirá en desarrollar sistemas de representación y recuperación del conocimiento más eficientes inspirados en la memoria asociativa del cerebro o utilizando diferentes representaciones del conocimiento para diferentes propósitos. Hasta ahora sólo es posible en dominios restringidos, tales como el reconocimiento de patrones específicos (imágenes, caracteres manuscritos, caras, etc.), identificación de objetos, procesamiento de grandes cantidades de información numérica, control de alta precisión y razonamiento en dominios restringidos. Se precisan métodos muy especializados para alcanzar buenos resultados.

Otro de los retos más importantes en investigación es el desarrollo de metodologías, conceptos y técnicas para el diseño de sistemas inteligentes con un alto nivel de flexibilidad y autonomía, de manera que los sistemas puedan evolucionar su estructura y el conocimiento del ambiente y, en última instancia, evolucionar su inteligencia. Es decir, el sistema debe ser capaz de evolucionar, desarrollarse, autoevaluarse y mejorar por sí mismo. Las redes de sensores inalámbricas, la inteligencia ambiente asistida, controladores inteligentes, agentes inteligentes, sistemas robóticos autónomos, etc., son algunas de las áreas de implementación de dicha tecnología.

Los algoritmos de la IC requieren grandes recursos computacionales debido a la complejidad de los problemas que pretenden resolver. La computación cuántica podrá tener en un futuro cercano efectos importantes sobre la complejidad de los algoritmos puesto que permitirá un crecimiento exponencial del paralelismo y resolver así problemas de complejidad exponencial en tiempo polinomial.

La capacidad para evolucionar y adaptarse a un ambiente cambiante es fundamental para el ser humano y los demás organismos vivos. Hasta ahora hemos tratado de construir agentes inteligentes que tratan de emular las facultades del ser humano pero también debemos de empezar a desarrollar sistemas inteligentes que también evolucionen autónomamente.

Como señala el profesor Zadeh [36] de la Universidad de California, la facultad humana para realizar tareas físicas y mentales, como la conducción de un automóvil sin llevar a cabo medidas ni computaciones, y la capacidad para razonar, conversar y tomar decisiones racionales en un ambiente con información imprecisa, incierta e incompleta, son extraordinarias. Un objetivo de la inteligencia humana es la mecanización de dichas capacidades propias de ella. Dicho objetivo es difícil de alcanzar. Sin embargo, si se llegase a conseguir no sería utilizando extensiones de las técnicas convencionales, ya que éstas no son suficientes.

El futuro de la ciencia depende de la colaboración entre grupos de investigación y científicos distribuidos por todo el mundo. Un gran reto sería crear una comunidad virtual de IC que incorpore científicos, educadores, estudiantes y público en general interesados en esta disciplina. Ello nos permitiría compartir datos, software, recursos computacionales, material educativo, ofertas de trabajo y, sobre todo, el encuentro con personas, como en las redes sociales. La inteligencia con sabiduría será el objetivo final de la IC orientada al ser humano.

CONCLUSIONES

El enfoque tradicional de utilizar la información de expertos en un dominio específico para generar los datos con el objetivo de extraer información valiosa ha permitido el desarrollo de los sistemas expertos. Sin embargo, la explosión de datos, entre otras razones, que ha tenido lugar en muchas disciplinas nos ha llevado a desarrollar otros enfoques diferentes.

La naturaleza ha sido la gran fuente de inspiración para el desarrollo de la IC. Por una parte, el conocimiento actual que tenemos del funcionamiento del cerebro, de las características de la inteligencia humana, del comportamiento individual y colectivo de ciertos seres vivos, y por otra parte los principios de la evolución natural, la genética y la selección natural, nos han permitido desarrollar técnicas y algoritmos para resolver una gran variedad de problemas complejos del mundo real para los que no se dispone de algoritmos convencionales efectivos. Las técnicas y los algoritmos de la IC se están aplicando con éxito en casi todos los campos del conocimiento humano.

Actualmente, se trata de ver cómo introducir el comportamiento evolutivo en los sistemas inteligentes, es decir, cómo construir sistemas que evolucionen de forma autónoma. Ello va a requerir la capacidad de saber equilibrar el proceso de aprendizaje con el proceso

de cambio, respetando el conocimiento acumulado en el pasado.

El espectacular desarrollo del conocimiento y de las tecnologías de la información y las comunicaciones gracias al trabajo en equipo y la cooperación de todos nos ha llevado a uno nuevo problema, la gestión de dicho conocimiento expandido por todas partes a través de las redes informáticas y al alcance de casi todo el mundo. Al mismo tiempo, el mundo en su globalidad se ha hecho mucho más complejo. Dicha complejidad hace muchas veces sentirnos, nosotros mismos y las organizaciones, incapacitados para descifrar los problemas derivados de la propia complejidad, incluso para afrontar todos los problemas que se nos vienen encima. La escasez de recursos se agrava con los problemas ecológicos generados por el gran desarrollo industrial. Muchas de las pautas de solución de los seres humanos se nos han quedado obsoletas. La velocidad de los cambios y la lentitud de las respuestas de las organizaciones nos hacen pensar en la necesidad de construir organizaciones inteligentes con capacidad de responder de forma rápida y eficiente a los problemas que se presenten, como terremotos, inundaciones, incendios, etc. La inteligencia individual ha sido superada por la inteligencia colectiva puesta de manifiesto por el desarrollo tecnológico. Los sistemas inteligentes basados en inteligencia colectiva podrán servir de apoyo a muchas organizaciones en el futuro.

Muchos científicos, como el profesor Edward A. Feigenbaum [11] de la Universidad de Stanford, piensan que la IC es el "destino manifiesto" de la informática, es decir, el objetivo, el destino y la frontera final. Más que cualquier otro campo de la ciencia, los conceptos y métodos de la informática son centrales para desentrañar y comprender uno de los más grandes misterios de nuestra existencia, la naturaleza de la inteligencia.

REFERENCIAS

- [1] Angelov P., D. P. Filev y N. Kasabov. *Evolving Intelligence Systems: Methodology and Applications*. John Wiley and Sons, New Jersey, 2010.
- [2] Busa-Fekete, R., A. Kocsor y S. Pongor. *Tree-Based Algorithms for Protein Classification*. *Studies in Computational Intelligence*, 94: 165–182, 2008.
- [3] Chu, F., W. Xie, y L. Wang. *Gene selection and cancer classification using a fuzzy neural network*. In: *Proc. IEEE Annual Meeting of Fuzzy Information*, pages 555–559, 2004.
- [4] Cicirello V.A. y S.F. Smith. *Wasp Niests for Self-Configurable Factories*. In *Proceeding of the Fifth International conference on Autonomous Agents*, pages 473-480, 2001.
- [5] Craik K. *The Nature of Explanation*. Cambridge University Press, Cambridge, 1943.
- [6] De Castro L. y F.J. von Zuben. *The clonal selection algorithm with engineering applications*. *Proc. GECCO Workshop on Artif. Immune Syst. Their Appl.*, pages 36-37, 2000.
- [7] Cherkassky V., V. Krasnopolky, D.P. Solomatine y J. Valdes. *Computational intelligence in earth sciences and environmental applications: Issues and challenges*. *Neural Networks*, 19: 113-121, 2006.
- [8] Das T.K., G.K. Venayaganmoorthy y U.O. Aliyu. "Bio-

inspired Algorithms for the Dising of Multiple Optimal Power System Stabilizers: SPPO and BFA". IEEE on Transactions on Industry Applications, 4(5): 1445-1457, 2008.

- [9] De Jong K. An analysis of the behavior of a Class of Genetic Adaptive Systems. Ph. D. thesis, Department of Computer and Communication Sciences, University of Michigan, Ann Arbor, (1975).
- [10] Dorigo M. Optimization, Learning and Natural Algorithms. PhD thesis, Politecnico di Milano, 1992.
- [11] Feigenbaum E.A. Some Challenges and Grand Challenges for Computational Intelligence. Journal of the ACM, 50(1): 32-40, 2003.
- [12] Fogel, G.B. Gene expression analysis using methods of computational intelligence. Pharmaceutical Discovery, 5(8): 12-18, 2005.
- [13] Galán-Marín G. y J. Muñoz-Pérez. Design and Analysis of Maximum Hopfield Networks. IEEE Transactions on Neural Networks, 12(2): 329-339, 2001.
- [14] García-Gimeno, R.M., C. Hervás-Martínez, R. Rodríguez-Pérez y G. Zurera-Cosano. Modelling the growth of leuconostoc mesenteroides by artificial neural networks. International Journal of Food Microbiology, 133: 317-332, 2005.
- [15] García-Pedrazas, N., C. Hervás-Martínez y J. Muñoz-Pérez. COVNET: A Cooperative Coevolutionary Model for Evolving

- Artificial Neural Networks. IEEE Transaction on Neural Networks, 14(3): 575-596, 2003.
- [16] Holland J.H. Adaptation in Neural and Artificial Systems. The University of Michigan Press. Ann Arbor, Mich., 1975; reprinted as a second edition (1992), MIT Press, Cambridge, Mass.
- [17] Kennedy J. y R.C. Eberhart. Particle Swarm Optimization. In Proceeding of the IEEE International Joint Conference on Neural Networks, pages 1942-1948. IEEE Press, 1995.
- [18] Krink T. y F. Vollrath. Virtual spiders guide robotic control design. IEEE Intelligent Systems, 14(5): 77-84, 1999.
- [19] McCulloch W.S. y W. Pitts. A Logical Calculus of the ideas Immanent in Nervous Activity. Bulletin of Mathematical Biophysics, 5: 115-133, 1943.
- [20] Mohamed, S., Rubin, D. y Marwala, T.: Multi-class Protein Sequence Classification Using Fuzzy ARTMAP. In: Proc. IEEE Intl. Conf. on Systems, Man, and Cybernetics, pages 1676-1681, 2006.
- [21] Palma Méndez J.T. y R. Martín Morales. Inteligencia Artificial. Técnicas, Métodos y Aplicaciones. McGraw-Hill, Madrid, 2008
- [22] Palomo, E.J., E. Domínguez, R. M. Luque y J. Muñoz. An Intrusion Detection System base on Hierarchical Self-organization. Journal of Information Assurance and Security, 4: 209-216, 2009.

- [23] Reynolds C.W. Flocks, Herds y Schools: A Distributed Behavioural Model. *Computers Graphics*, 21 (4): 25-34, 1987.
- [24] Ritchie, M.D., A. A. Motsinger, W. S. Bush, C. S. Coffey y J. H. Moore. Genetic programming neural networks: A powerful bioinformatics tool for human genetics. *Applied Soft Computing*, 7: 471-479 (2007)
- [25] Rosenblueth A., N. Wiener y J. Bigelow. Behavior, Purpose and Teleology. *Philosophy of Science*, 10, 1943.
- [26] Rumelhart D.E., G.E. Hinton y R.J. Williams. «Learning internal representations by error propagation». En *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol. 1. The MIT Press, Cambridge, MA, 1986.
- [27] Saxena D., S.N. Singh y K.S. Verma. Application of computational intelligence in emerging power systems. *International Journal of Engineering, Science and Technology*, 2(3):1-7, 2010.
- [28] Turing A.M. Computing Machinery and Intelligence. *Mind*, 59: 433-460, 1950.
- [29] Uhrig R.E. y J. W. Hines. Computational Intelligence in Nuclear Engineering. *Nuclear Engineering and Technology*, 37(2): 127-138, 2005.
- [30] Walker R.L. Honeybee Search Strategies: Adaptive Exploration on an Information Ecosystem. In *Proceeding*

of the IEEE Congress on Evolutionary Computation, pages 1209-1216, 2004.

- [31] Wolpert D. H. The lack of a priori distributions between learning algorithms. *Neural Computation*, 8(7): 1341-1390 (1996).
- [32] Wolpert D. H y W. G. Macready. No free lunch theorems for optimization. *IEEE Trans. on Evolutionary Computation*,. 1(1): 62-82, 1997.
- [33] Wolpert D. H y W. G. Macready. Coevolutionary free lunches. *IEEE Trans. on Evolutionary Computation*, 9(6): 721-735, 2005.
- [34] Yuhui Y., C. Lihui, A. Goh y A.Wong. Clustering gene data via associative clustering neural network. In: *Proc. 9th Intl. Conf. on Information Processing*, pages, 2228–2232, 2002.
- [35] Zadeh L. Fuzzy sets. *Information and Control*, 8(3):338-353, 1965.
- [35] Zadeh L. Toward human level machine intelligence – Is achievable? The need for a paradigm shift. *IEEE Computational Intelligence Magazine*, 3(3): 11-22, 2008.
- [36] Zhang J., R. Lee y Wang, Y.J.: Support vector machine classifications for microarray expression data set. In: *Proc. 5th Intl. Conf. on Computational Intelligence and Multimedia Applications*, pages, 67–71, 2003.