

Inteligencia Artificial Aplicada al Diagnóstico Médico

Edwin Andrés Bernal López, Maestría en Ingeniería – Ingeniería de Sistemas y Computación,
Universidad Nacional de Colombia, Sede Bogotá

Abstract— El presente documento tiene como fin, establecer un entorno general alrededor de las aplicaciones actuales que tiene la Inteligencia Artificial en el diagnóstico médico. El diagnóstico médico apoyado mediante aplicaciones de Inteligencia Artificial se puede ver referenciado desde varias de sus principales técnicas tales como los sistemas expertos (diagnóstico basado en reglas, probabilidades), lógica difusa (diagnóstico basado en clasificación), redes neuronales (diagnóstico basado en entrenamiento y reconocimiento), minería de datos aplicada (diagnóstico mediante el reconocimiento de patrones). Los trabajos que se encuentran recopilados en éste documento se encuentran dentro de los años 1999 – 2005, permitiendo definir las tendencias recientes y sus características principales (campo particular dentro del diagnóstico médico).

Index Terms— Sistemas Expertos, Diagnóstico Médico, Inteligencia Artificial, Agentes Inteligentes, Lógica Difusa, Redes Neuronales.

I. INTRODUCCIÓN

Desde el inicio de la Inteligencia Artificial ubicado aproximadamente a final de la década de los 50, sus técnicas han sido utilizadas y aplicadas en diversas áreas comunes al desempeño cotidiano de las personas, ayudando, reemplazando, simulando las acciones o decisiones tomadas por individuos con ciertas características en particular. Como una de sus principales áreas de aplicación se puede destacar particularmente la medicina, dado que la Inteligencia Artificial logró su mayor impacto inicial en ella a través de los sistemas expertos y específicamente por medio de los sistemas de diagnóstico.

El diagnóstico médico es una tarea que requiere de gran precisión, dada la trascendencia que puede llevar consigo una decisión mal tomada. Por lo tanto dicha actividad es realizada por médicos con una cierta cantidad de experiencia en el área en la que se este realizando el diagnóstico. La Inteligencia Artificial como su mismo significado lo expresa, pretende emular la capacidad natural que posee el hombre en la toma de decisiones de cualquier tipo, imitando tanto su modo de aprendizaje como la manera en que basado en dicho conocimiento puede llegar a tomar decisiones. Para este

propósito se han venido aplicando diferentes ramas de la Inteligencia Artificial dentro de las cuales se pueden destacar los Sistemas Expertos (mencionados anteriormente), las Redes Neuronales, la Minería de Datos, los Agentes Inteligentes.

Éste artículo presentará una exploración histórica general del diagnóstico médico apoyado en la Inteligencia Artificial, mostrando definiciones generales de las áreas de la Inteligencia Artificial involucradas, las tendencias presentadas lo largo del tiempo (utilización de dichas áreas) y las aplicaciones desarrolladas en los últimos años (1999 – 2005), destacando autores, año y área de la Inteligencia Artificial que se utilizó o aplicó en cada caso en particular.

II. CONCEPTOS GENERALES

En ésta sección se establecerá una definición global de algunos de los términos básicos a utilizar a lo largo del documento, presentando las características básicas e importantes, con el fin de unificar los criterios y permitir una mejor comprensión de la idea a desarrollar dentro del resto de contenido del documento.

A. *Inteligencia Artificial*

La Inteligencia Artificial es una combinación de las ciencias computacionales, fisiología y filosofía, reúne varios campos (robótica, sistemas expertos, sistemas inteligentes entre otros), todos los cuales tienen en común la creación de “máquinas” que pueden “pensar” tal y como lo hacen los humanos. La idea de construir una máquina, que pueda ejecutar tareas que parecen necesitar de la inteligencia humana para llevarse a cabo es un atractivo. Las tareas que han sido estudiadas desde este punto de vista incluyen juegos, traducción de idiomas, diagnóstico (médico, de fallas), robótica, suministro de asesoría experta en diversos temas.

Es así como los sistemas de administración de base de datos cada vez más sofisticados, la estructura de datos y el desarrollo de algoritmos de inserción, borrado y locación de datos, así como el intento de crear máquinas capaces de realizar tareas que son pensadas como típicas del ámbito de la inteligencia humana, acuñaron el término Inteligencia Artificial en 1956 [22, 29].

Trabajos teóricos fundamentales fueron el desarrollo de algoritmos matemáticos por Warren McCullock y Walter Pitts, en 1943, necesarios para posibilitar el trabajo de clasificación, o funcionamiento en sentido general, de una red neuronal. En 1949 Donald Hebb desarrolló un algoritmo de aprendizaje para dichas redes neuronales creando, en conjunto con los trabajos de McCullock y Pitts, la escuela creacionista. Esta escuela se considera hoy como el origen de la Inteligencia Artificial, sin embargo se trató poco por muchos años, dando paso al razonamiento simbólico basado en reglas de producción, lo que se conoce como sistemas expertos [28].

B. Diagnóstico Médico

Tal vez el mayor problema en el campo médico es realizar el diagnóstico de una enfermedad, uno de los inconvenientes más importantes en éste proceso es la subjetividad del especialista que lo realiza; este hecho se hace notar en particular en actividades de reconocimiento de patrones, donde la experiencia del profesional esta directamente relacionada con el diagnóstico final, esto es debido al hecho de que el resultado no depende de una solución sistematizada sino de la interpretación de los síntomas del paciente [1].

Brause [29] destaca el hecho de que la mayoría de médicos confrontan durante su formación la tarea de aprender a diagnosticar. En ésta fase ellos tienen que resolver el problema de deducir ciertas enfermedades o formular un tratamiento basado en observaciones o especificaciones de conocimiento. En términos generales el diagnóstico médico es fundamentalmente el proceso de identificar la enfermedad que esta sufriendo un paciente, para de esta manera poder determinar cual es la mejor forma para tratarla; siendo éste uno de los temas más explotados en la ciencia de la computación desde hace ya un tiempo, especialmente en el campo de la Inteligencia Artificial.

Para el diagnóstico en general y el diagnóstico médico particularmente la integración rápida y fácil de conocimiento que pueda reemplazar al antiguo es un factor fundamental, dado que el diagnóstico médico es un proceso muy complejo, que requiere la recopilación de los datos del paciente, un profundo entendimiento de la literatura médica alrededor del tema y muchos años de experiencia clínica [19], sin embargo un diagnóstico totalmente preciso no puede ser realizado sin antes considerar muchas alternativas. Como resultado de esta incertidumbre las decisiones tomadas por diferentes médicos en diferentes estados del proceso de diagnóstico no siempre son las mismas, porque cada caso particular tiene un proceso de decisión diferente para cada médico así se trate del diagnóstico de el mismo tipo de enfermedad.

C. Sistema Experto

Los sistemas expertos forman parte de las ciencias de la computación y dentro de ésta se ubican en la rama específica de la Inteligencia Artificial. Éste término fue usado por

primera vez por Edward A. Feigenbaum [1977] [20]. Él estipuló que el poder de resolución de un problema en un programa computacional viene del conocimiento de un dominio específico y no solamente de las técnicas de programación y del formalismo que contiene.

Los Sistemas Expertos, se pueden entender según Gholam H [1988] [28, 31] como programas de computación que almacenan conocimiento de expertos humanos en algún área específica y luego permiten usar ese conocimiento, para resolver problemas de una manera muy aproximada a la que el experto utilizaría.

Para esto, se debe tener en cuenta que la principal característica del experto humano viene a ser el conocimiento o habilidades profundas en ese campo concreto, por consiguiente, un Sistema Experto debe ser capaz de representar ese conocimiento profundo, con el objetivo de utilizarlo para resolver problemas, justificar su comportamiento e incorporar nuevos conocimientos. Se podría incluir también el hecho de poder comunicarse en lenguaje natural con las personas, si bien esta capacidad no es tan determinante como las anteriores.

La principal manera de obtención de resultados en un sistema experto es basándose en la generación de reglas, estas se obtienen del experto humano y representan el conocimiento extraído mediante sentencias de la forma SI – ENTONCES. Las reglas pueden ser usadas para realizar operaciones entre los datos, inferir y encontrar la conclusión más apropiada. Por lo tanto se puede concluir que la potencia de un Sistema Experto se basa más que en una gran cantidad de conocimiento, en un formalismo deductivo muy eficaz. La idea que se persigue cuando se construye un Sistema Experto es la de automatizar la labor del experto, partiendo en ocasiones de información insuficiente o incompleta.

Según la clase de problemas hacia los que estén orientados, podemos clasificar principalmente los Sistemas Expertos en diversos tipos entre los que cabe destacar: diagnóstico (médico que es en el que nos vamos a centrar en este documento), pronóstico, planificación, reparación e instrucción.

D. Redes Neuronales

Una Red Neuronal Artificial (RNA) es un modelo que emula una Red Neuronal Biológica. Este concepto es usado para implementar simulaciones de software en procesos paralelos masivos que envuelven el procesamiento de elementos interconectados en una arquitectura de red [31, 33]. Las neuronas artificiales reciben entradas que son equivalentes a los impulsos eléctricos de las dendritas de las neuronas biológicas reciben de otras neuronas. La salida de la neurona artificial, equivale a la señal enviada fuera de la neurona biológica a través de su axón. Estas señales artificiales pueden ser cambiadas del mismo modo en que ocurren los cambios físicos en la sinapsis de la neurona biológica.

E. Lógica Difusa

Esta técnica usa la teoría matemática de grupos difusos, que simula el proceso de razonamiento humano, permitiendo al computador comportarse menos precisa y lógicamente que los computadores convencionales. Esta aproximación es usada particularmente porque la toma de decisiones del mundo real, no siempre esta enmarcada en decisiones del tipo blanco o negro, verdadero o falso. Estas decisiones a menudo involucran áreas de grises o términos de tal vez.

F. Agentes Inteligentes

Al igual que ocurre con la propia definición de la Inteligencia Artificial, se pueden encontrar propuestas en la literatura un gran número de definiciones del concepto de agente, sin que ninguna de ellas haya sido plenamente aceptada por la comunidad científica, siendo quizás la más simple la de Russell (Russell1996), que considera un agente como una entidad que percibe y actúa sobre un entorno, es decir, un Agente Inteligente es un programa de computador que ayuda al usuario con rutinas que pueden ser usadas por otros programas. Basándose en esta definición, se pueden caracterizar distintos agentes de acuerdo a los atributos que posean (y que van a definir su comportamiento) [3] para resolver un determinado problema.

Se dice que un agente esta situado en un entorno y dicho entorno para el agente puede ser la propia red (Internet). Por otra parte en la definición se indica que debe percibir y actuar en dicho entorno. Para dado caso, la percepción se puede ver en el hecho de que el agente va recibiendo e instruyéndose de las peticiones que se hacen, mientras que la acción queda latente cuando el agente muestra información que el mismo ha buscado en la red.

G. Ontologías

Sistemas ontológicos son sistemas de vocabulario que usan dicho vocabulario como concepto fundamental para describir las tareas o el dominio del conocimiento a ser identificado [23]. El vocabulario es usado como base de la comunicación de los expertos y el conocimiento de los ingenieros que pretenden desarrollar un aplicativo implementando dicho conocimiento.

III. EXPLORACIÓN HISTÓRICA GENERAL

Las tendencias que han marcado la historia de la Inteligencia Artificial en el campo médico, especialmente en el diagnóstico de enfermedades, son un buen referente para comprender el porque de los desarrollos presentes en la actualidad, ésta parte del documento hace una breve recopilación de algunos de los desarrollos más importantes, teniendo en cuenta el orden cronológico y el tipo de técnica de Inteligencia Artificial que fue usado en el caso particular.

Para iniciar es importante establecer que el potencial de la Inteligencia Artificial en la medicina ha sido expresado por varios investigadores a través de su historia. Por ejemplo Hoong (1988) [35] resumió el potencial de las técnicas de Inteligencia Artificial en la medicina así:

- Producción de nuevas herramientas para apoyar la toma de decisiones médicas, entrenamiento e investigación.
- Integración de las actividades médicas, computacionales, científico-cognoscitivas.

Muchas aplicaciones en la Inteligencia Artificial se han desarrollado con el fin de reforzar el cuidado de la salud y proporcionar mejores métodos para este objetivo particular. Como han expresado muchos estudios tales como (Mahabala, 1992; Manickam y Abidi, 1999); Alexopoulos 1999; Zelic, 1999; Ruseckaite, 1999, Bourlas, 1999), las aplicaciones en Inteligencia Artificial en el campo médico fueron desarrollados para ayudar a los usuarios (particularmente médicos y pacientes), proporcionando diagnósticos y predicciones para evitar complicaciones en las enfermedades.

Aunque estos sistemas están dotados con el conocimiento "humano", ellos nunca reemplazarán la experiencia humana; dado que como el mismo humano, los sistemas exigen frecuentemente supervisión y actualización del conocimiento, por consiguiente, los papeles del especialista (experto) médico y de los doctores continúan siendo importantes para asegurar la validez del sistema.

Los primeros estudios en sistemas médicos inteligentes tales como CASNET, MYCIN, PIP e Internist-I han mostrado la posibilidad de realizar diagnóstico en varios tipos de enfermedades (Shortliffe, 1987). CASNET (Causal ASSociational Networks) se desarrolló a inicios de 1960, fue una herramienta general para construir sistemas expertos para el diagnóstico y tratamiento de enfermedades. La mayoría de las aplicaciones realizadas mediante el uso de CASNET se especializaron en el diagnóstico y tratamiento del glaucoma. MYCIN por su parte se desarrolló a inicios de 1970 y fue diseñado para diagnosticar ciertas infecciones microbianas, además de recomendar el tratamiento con la asignación respectiva de medicamento necesario para tratar la infección. MYCIN tenía varios módulos tales como: explicación, adquisición de conocimiento e interacción. PIP era una abreviación para el Present Illnes Program, se desarrolló en 1970 para simular el comportamiento que debe seguir el especialista al momento de clasificar la historia médica de un paciente, diagnosticándolo o identificándolo dentro de algún cuadro de las enfermedades renales conocidas. El Internist-I se desarrollo a inicios de 1980, su función se centraba en la investigación de métodos heurísticos para tareas de diagnóstico diferencial usadas en la toma de decisiones clínicas (fue usado en diagnóstico de medicina interna).

En los años noventa, se reforzaron los estudios en los sistemas basados en Inteligencia Artificial, utilizando el precepto de desarrollar sistemas basados en las necesidades actuales.

ICHT (Un Sistema basado en Inteligencia Artificial para el Cuidado de la Salud de los niños) se desarrolló para reducir la mortalidad de los niños sobre todo en las áreas rurales (Mahabala, 1992). El éxito de éste sistema radicaba en categorizar las insuficiencias más comunes dentro de la población infantil, tomando en consideración factores de riesgo importantes tales como el control del peso, inmunización, además de hitos en el crecimiento y la nutrición. ICHT utilizó sistemas expertos en el proceso de toma de los datos para la generación de la historia de los pacientes. Otro aplicativo que fue desarrollado fue HERMES (HEpathology Rule-based Medical Expert System) un sistema experto para el pronóstico de las enfermedades crónicas más comunes (Bonfa, 1993). SETH un sistema experto para el tratamiento del envenenamiento por el uso de drogas (Droy, 1993), PROVANES un sistema experto híbrido para los pacientes críticos en anestesiología (Passold 1996) e ISS (Interactive STD Station) para el diagnóstico de las enfermedades de transmisión sexual (Alambrista y Kwon, 1997). Dentro de los sistemas de diagnóstica médico basados en experiencia se puede encontrar un sistema de diagnóstico médico interactivo que es accesible a través de Internet (Manickam y Abidi, 1999), el razonamiento basado en casos (CBR) fue empleado en éste sistema para poder utilizar el conocimiento específico de experiencias previas, problemas o casos, el sistema puede ser usado por los mismos pacientes para diagnosticarse sin tener para hacer una visita frecuente a doctores.

La minería de datos es una técnica de Inteligencia Artificial usada para el descubrimiento de conocimiento en grupos de datos grandes, así ésta se usa para descubrir información que a simple vista se encuentra oculta a los propósitos médicos (Siti Nurul Huda y Miswan, 1999; Siti Fatimah y Rogayah, 1999). Neves (1999) desarrolló sistemas de información que apoyan el diagnóstico, mediante el minado en imágenes médicas.

La lógica difusa es otra rama de las técnicas de inteligencia artificial, basada en la incertidumbre presente en el conocimiento, lo que simula más adecuadamente el razonamiento humano real. Meng (1996) aplico la inferencia correlativa difusa en el diagnóstico médico usándolo con un sistema basado en conocimiento médico llamado Clinaid.

Las Redes Neuronales (RN) una de las técnicas de Inteligencia Artificial más poderosas, tienen la capacidad para aprender de un grupo de datos y de matrices de peso estructuradas para representar los modelos de aprendizaje. RN son redes compuestas de muchas unidades de procesamiento (Sarle, 1999), simulan la función del cerebro humano y la forma de realizar las tareas tal y como el humano lo hace. RN han sido empleadas en varias aplicaciones médicas como en tratamientos de la arteria coronaria (Lippmann, 1995), infartos miocárdicos (Heden 1996), diagnóstico de cáncer (Callejero, 1996; Karkanis, 1999), diagnóstico de pulmonía (Caruana, 1996) y desórdenes cerebrales (Pranckeviciene, 1999).

Karkanis (1999) Realizo una aplicación basada en RN que realizaba inferencias a partir del método de descripción textual

para descubrir las anomalías dentro de imágenes médicas con una exactitud alta.

IV. SISTEMAS DE DIAGNÓSTICO

En esta sección del documento se mostrará de manera general como los sistemas de diagnóstico médico actuales, que se apoyan en técnicas de Inteligencia Artificial, realizan las inferencias necesarias para llegar a una conclusión (detección de la enfermedad) o para ofrecer un apoyo en el diagnóstico dado por el experto en el área. Antes de iniciar con la explicación se establecerá una definición formal del los sistemas de diagnóstico y del problema del diagnóstico en general.

Un sistema de diagnóstico es aquel que computa las soluciones para un problema, usando una descripción del comportamiento observado del sistema bajo diagnóstico. El problema de diagnóstico se presenta si hay una discrepancia entre cómo un sistema se comporta y cómo el sistema debería comportarse, en otras palabras es cuando el comportamiento previsto no corresponde con realidad. La tarea de diagnóstico es descubrir la causa de esta discrepancia. El algoritmo del sistema de diagnóstico determina las causas posibles de esta discrepancia usando un modelo compuesto por el comportamiento y el comportamiento observado [7].

Las soluciones computadas de un problema de diagnóstico representan una explicación para el comportamiento observado. El sistema de diagnóstico explota la información del contexto para solucionar dicho problema. Una explicación distingue dos tipos de observaciones: cubre algunas observaciones, y no contradice otras observaciones. La explicación se restringe a un vocabulario de los candidatos especiales que podrían ser causas de una discrepancia del comportamiento. No se debe estar generalmente interesado en todas las explicaciones posibles, sino solamente en las explicaciones más razonables para el problema de diagnóstico actual. También se desea representar una explicación como solución que sea sencilla de interpretar. Específicamente en dominios médicos, los usuarios están generalmente interesados en la enfermedad, no están interesados en todos los estados actuales de las partes del cuerpo del paciente. Cada uno de estos aspectos influencia la noción particular del diagnóstico que se observa en un sistema dado.

A. El Problema Del Diagnóstico

Para comprender el problema del diagnóstico primero se formulará la inferencia que se debe realizar. Se debe suponer que se está considerando un grupo H de n posibles hipótesis [4].

$$H = \{H_1, H_2, \dots, H_n\}$$

Además de un grupo E con m piezas de evidencia

$$E = \{E_1, E_2, \dots, E_m\}$$

Se asume que todas las hipótesis y piezas de evidencia tienen dos valores lógicos, verdadero o falso. En un mundo determinista, se podrían asumir una relación $C(H, E)$ entre hipótesis y evidencias tal que $c(H_i, E_j)$ signifique que la hipótesis H_i implique a la evidencia E_j . Por lo tanto un diagnóstico o explicación es un grupo de hipótesis que posiblemente se puedan presentar. Dado un grupo de evidencias E' , el problema del diagnóstico determinista es descubrir uno o más diagnósticos $D \subset H$, que pueden explicar la evidencia observada. En términos generales, D podría contener para todos los E_j en E' , una hipótesis H_i tal que $c(H_i, E_j)$. Konomenho[7] propone la siguiente formulación del problema del diagnóstico y desarrollo cubriendo un grupo de algoritmos para encontrar el grupo mínimo de causas que podrían explicar el grupo de observaciones.

En el mundo real, las relaciones alrededor de las hipótesis y las piezas de evidencia son inciertas. La aproximación probabilística es usada para representar esas relaciones como su distribución $p(E'|D, \xi)$ para las evidencias, dando cada posible diagnóstico D en H . Si además se tiene la probabilidad previa $p(D|\xi)$ para cada subgrupo D en H , representado los niveles de prevaletamiento de las hipótesis, se podría aplicar el teorema Bayesiano para calcular la probabilidad posterior de cada diagnóstico, después de observar la evidencia, E' :

$$p(D|E', \xi) = \frac{p(E'|D, \xi) p(D|\xi)}{p(E'|\xi)}$$

En términos generales el problema del diagnóstico es computacionalmente complejo. Porque un paciente puede tener más que una sola enfermedad, n posibles enfermedades, el número de posibles diagnósticos en éste caso es 2^n . Para m piezas de evidencia, la distribución general tiene $2^m - 1$ parámetros independientes dando cada una de las hipótesis, requiriendo $2^n(2^m - 1)$ parámetros independientes en total para obtener todos los diagnósticos. Esta aproximación no es muy práctica para más de dos o tres hipótesis y piezas de evidencia sin algún tipo de simplificación.

B. Diagnóstico Probabilístico

El teorema de Bayes puede ser expresado por medio de una notación que usa el número de componentes de cada una de las variables multidimensionales X e Y , de la siguiente manera:

$$p(Y = y|X = x) = \frac{p(Y_1 = y_1, \dots, Y_m = y_m | X_1 = x_1, \dots, X_n = x_n) p(X_1 = x_1, \dots, X_n = x_n)}{\sum_{y'_1, \dots, y'_m} p(X_1 = x_1, \dots, X_n = x_n | Y_1 = y'_1, \dots, Y_m = y'_m) p(Y_1 = y'_1, \dots, Y_m = y'_m)}$$

Teorema de Bayes

A continuación se va a hacer referencia a la formulación clásica de un problema de diagnóstico utilizando una

terminología habitual en medicina, que es un modelo planteado originalmente por Larraña [24]. Es evidente que la terminología puede trasladarse a otras ramas de la ciencia y de la técnica, en particular a la ingeniería.

La terminología a usar incluye términos como:

- **Hallazgo:** Con el cual se hace referencia a la determinación del valor de una variable predictora X_r . Así por ejemplo x_r (valor de la variable X_r) puede estar representando la existencia de vómitos en un determinado enfermo.
- **Evidencia:** Denota el conjunto de todos los hallazgos para un determinado individuo. Es decir $x = (x_1, \dots, x_n)$ puede estar denotando (si $n = 4$) que el individuo en cuestión es joven, hombre, presenta vómitos y además no tiene antecedentes familiares.
- **Diagnóstico:** Denota el valor que toman las m variables aleatorias Y_1, \dots, Y_m , cada una de las cuales se refiere a una enfermedad.
- **Probabilidad a priori del diagnóstico:** $p(y)$ o $p(Y_1 = y_1, \dots, Y_m = y_m)$, se refiere a la probabilidad de un diagnóstico concreto, cuando no se conoce nada acerca de los hallazgos, es decir, cuando se carece de evidencia.
- **Probabilidad a posteriori de un diagnóstico:** $p(y|x)$ o $p(Y_1 = y_1, \dots, Y_m = y_m | X_1 = x_1, \dots, X_n = x_n)$, es decir, la probabilidad de un diagnóstico concreto cuando se conocen n hallazgos (evidencia).

Según varios autores [8, 24], en el planteamiento clásico del diagnóstico se supone que los m diagnósticos posibles son no excluyentes, es decir, pueden ocurrir a la vez, siendo cada uno de ellos dicotómico. Para fijar ideas en relación con el ámbito médico, se puede asumir que cada uno de los m posibles diagnósticos no excluyentes se relaciona con una enfermedad, pudiendo tomar dos valores: 0 (no existencia) y 1 (existencia).

Por lo que se refiere a los n hallazgos o síntomas, se representarán por medio de las n variables aleatorias X_1, \dots, X_n y también se puede asumir que cada variable predictora es dicotómica, con valores 0 y 1. El valor 0 en la variable X_i indica la ausencia del i -ésimo hallazgo o síntoma mientras que el valor 1 indica la presencia del hallazgo o síntoma correspondiente.

	X_1	...	X_n	Y_1	...	Y_m
$(x^{(1)}, y^{(1)})$	$x_1^{(1)}$...	$x_n^{(1)}$	$y_1^{(1)}$...	$y_m^{(1)}$
$(x^{(2)}, y^{(2)})$	$x_1^{(2)}$...	$x_n^{(2)}$	$y_1^{(2)}$...	$y_m^{(2)}$
...
$(x^{(N)}, y^{(N)})$	$x_1^{(N)}$...	$x_n^{(N)}$	$y_1^{(N)}$...	$y_m^{(N)}$

Planteamiento Clásico de Diagnóstico

C. Diagnóstico Difuso

El problema del diagnóstico médico difuso se puede formalizar como sigue. Si se considera $C=\{C_1, C_2, \dots, C_M\}$ como un sistema de M diagnósticos posibles en el contexto de cierto problema médico[9]. C puede ser: una lista de desórdenes, tipos de tejidos finos en una exploración de resonancia magnética (RM) del cerebro, análisis de tipos de células de la sangre. Se llama C un sistema de etiquetas de la clase. Se puede considerar a x como la descripción de un objeto representado mediante vector de verdades n dimensional $x=[x_1, \dots, x_n]^T \in R^n$. Los componentes de x codifican las características, como por ejemplo las medidas y resultados clínicos; detalles de la historia del paciente; parámetros fisiológicos; resultados de pruebas. Un clasificador clásico es considerado como:

$$D: R^n \rightarrow C$$

Esto es, para cada objeto $x \in R^n$, el clasificador especifica una sola etiqueta de la clase que se puede interpretar como el diagnóstico. El diagnóstico difuso se caracteriza por el hecho de que el clasificador confía en los sistemas difusos para solucionar un problema de diagnóstico médico. Los sistemas difusos se pueden utilizar en diversas etapas del diseño del clasificador, y de diversas maneras. Los más evidentes son:

- **Entradas difusas:** En lugar de los valores de la entrada de la original (mediciones) sus versiones difusas pueden ser utilizadas[5]. Por ejemplo, en lugar de un valor 145 mmHg para la presión arterial, se puede utilizar el vector $[0.0, 0.4, 0.6]^T$ que consiste en los grados de pertenencia de ese valor a los sistemas difusos [bajo, medio, alto].
- **Razonamiento difuso:** La puesta en práctica del clasificador se basa en sistemas difusos, por ejemplo en una máquina de inferencia difusa.
- **Clases difusas:** Los patrones clásicos de reconocimiento asumen que las clases son mutuamente exclusivas. Éste, sin embargo, no es generalmente el caso del diagnóstico médico. En lugar, algunos de los desórdenes pueden ocurrir simultáneamente en el mismo paciente, pero con variedad de grados. Por lo tanto, cada paciente puede ser clasificado en más de una clase. Mientras que la entrada difusa y el razonamiento difuso son las técnicas que pueden o pueden no interesar al usuario, las clases difusas tienen un efecto marcado en el diagnóstico médico. En vez de $D(x) \in C$, un clasificador difuso realiza el trazado así:

$$D': R^n \rightarrow [0, 1]^M$$

Es decir $D'(x)=[\mu_1(x), \dots, \mu_M(x)]^T$, donde el $\mu_i(x)$ denota el grado a el cual x pertenece a la clase C_i . [10,5] Este grado se puede interpretar de diversas maneras, de las cuales las más convencionales son:

- **Típicidad** del caso x con respecto al diagnóstico C_i .
- **Severidad** del desorden C_i en x .

- **Soporte** para la hipótesis que en C_i es el diagnóstico adecuado para x , deducido de la evidencia disponible.
- **Probabilidad** de que C_i es el diagnóstico correcto para x .

La decisión difusa $D'(x)$ puede ser difícil de etiquetar un solo conjunto de la clase de C . Usualmente se elige la clase con mayor soporte (conocida como miembro de reglas máximas).

$$D(x) = C_j \in C \iff \mu_j(x) = \max \mu_i(x)$$

D. Diagnóstico usando Razonamiento Basado en Casos

El Razonamiento Basado en Casos usa el conocimiento de experiencias anteriores cuando se enfrenta a nuevos casos. Un caso en términos generales hace referencia a una situación difícil (enfermedad en éste entorno), aunque los casos pueden ser descritos por un vector de atributo-valor, el Razonamiento Basado en Casos generalmente utiliza una estructura de datos jerárquica. Depende de una base de datos en la cual se encuentran los casos previamente analizados, los que han sido diseñados de forma tal que faciliten el reconocimiento de casos similares. Según [34], el Razonamiento Basado en Casos es un proceso que se puede abordar básicamente en cuatro estados:

1. Dado un nuevo caso a resolver, un grupo de casos similares son revisados en la base de datos.
2. Los casos revisados son reutilizados para obtener la solución del nuevo caso. Esto puede ser simplemente mediante la selección de la solución más frecuente usada en casos similares resueltos anteriormente, o si un entorno apropiado de conocimiento o modelo existen, se puede considerar en adaptar las soluciones existentes dentro de la base de datos para éste nuevo caso.
3. La solución para el nuevo caso es entonces revisada por el experto y si no es correcta, se selecciona otra usando el conocimiento del experto. La revisión puede ser guardada y usada para resolver otros casos similares.
4. El nuevo caso, su solución y cualquier información adicional usada para éste caso, puede ser potencialmente usable por lo tanto deben ser integradas en la base de datos.

El Razonamiento Basado en Casos ofrece una variedad de herramientas para el análisis de los datos. Los casos no solamente son almacenados, también son analizados para obtener las características más representativas y así compararlas de éste modo con los casos que se estén analizando. Con el fin de que la organización jerárquica de los datos pueda incorporar mecanismos de explicación adicionales.

Cuando es aplicado el Razonamiento Basado en Casos al análisis de datos médicos se tienen que identificar una gran cantidad de preguntas no triviales, incluyendo el nivel de similaridad usado en las medidas, la vigencia de los casos antiguos (dado que el conocimiento médico cambia con

marcada rapidez), como son ejecutadas las diferentes soluciones (tratamientos, acciones) por los diferentes médicos.

Muchos sistemas de Razonamiento Basado en Casos han sido usados, adaptados o implementados para dar soporte a los diagnósticos y al análisis de datos en medicina. Algunos ejemplos incluyen sistemas para ayudar al diagnóstico en cardiología (Reategui), Diagnostico médico (López y Plaza), detección de enfermedades coronarias del miocardio (Hadad), consejos de tratamiento en enfermería (Yearwood y Wilkinson). Otros ejemplos incluyen sistemas para ayudar al pronóstico del cáncer (Mariuzzi), tomografías asistidas por el computador (Khann).

E. Diagnóstico basado en Redes Neuronales

Se destacarán dos tipos de Redes Neuronales Artificiales: con aprendizaje supervisado o con aprendizaje sin supervisión y para cada tipo de ellas se mostraran las características más relevantes.

1) Aprendizaje Supervisado

En el aprendizaje supervisado existen diversos modos mediante los cuales las redes pueden aprender, pero probablemente el más representativo es el aplicado en las redes neuronales multicapa. Este tipo de redes son estructuras computacionales que se componen de elementos de procesamiento interconectados también conocidos como nodos, organizados en una arquitectura jerárquica de varias capas. En general para obtener un resultado, se computa el peso sumado de las entradas y se filtra a través de una función, para de esta manera obtener la salida (las salidas de una capa sirven como entradas de su siguiente capa). Para obtener el valor de la salida de una instancia seleccionada, los valores de sus atributos son almacenados en los nodos de entrada de la red. En cada paso, las salidas de los elementos procesados del nivel mayor son computados, hasta que el resultado es obtenido y almacenado en la capa de salida de la red.

En una Red Neuronal de éste tipo, el número de nodos de la capa de entrada y de la capa de salida son dependientes y están directamente relacionados con el número, tipo de atributos y clase de la tarea de clasificación.

Los pesos que son asociados con cada nodo son determinados por las instancias de entrenamiento. El algoritmo más popular de aprendizaje para éste tipo de redes es el de "backpropagation". El cual inicialmente asigna a los pesos un valor arbitrario y luego considera una o muchas instancias de entrenamiento a la vez que ajusta los pesos, así el error es minimizado (como error se puede entender la diferencia entre el valor esperado y el valor obtenido de los nodos en el nivel de salida). Este paso de entrenamiento es repetido hasta que el error de clasificación alrededor de todas las instancias de entrenamiento decaiga hasta el umbral especificado para el caso.

A menudo, se usa una sola capa oculta y el número de nodos tiene que ser previamente definido por el usuario o determinado a través del aprendizaje. Incrementar el número de nodos en una capa oculta permite más flexibilidad de modelamiento, pero puede llegar a causar problemas con los datos. El problema de determinar la arquitectura adecuada, junto con la alta complejidad del aprendizaje, son dos de las limitaciones de éste tipo de Redes Neuronales Artificiales. Otra dificultad común, es la necesidad de una apropiada preparación de los datos, una recomendación común es que todas las entradas sean clasificadas en el rango de 0 a 1, lo cual requiere normalización y codificación de los atributos de entrada.

Para tareas de análisis de datos, la limitación más seria es la falta de capacidades de expansión: los pesos inducidos en conjunto con la arquitectura de la red, usualmente no tienen una interpretación obvia y generalmente se dificulta o es casi imposible explicar porque determinada decisión fue encontrada. Recientemente se han hecho muchas propuestas para solucionar esta limitación. Una primera propuesta esta basada en hacer una reducción de las conexiones entre los nodos para obtener suficiente precisión en esa explicación, pero en términos de la arquitectura esto significaría una reducción considerable de la complejidad de la Red Neuronal. Otra solución es representar la red neuronal con un grupo de reglas simbólicas. [21]

A pesar de las limitaciones citadas anteriormente las redes neuronales multicapa ofrecen una precisión predictiva igual o superior a la obtenida por métodos de aproximación estadística u otros métodos, además han sido ampliamente usadas en el sector médico para el análisis de datos y en el diagnóstico. Diferentes ejemplos de redes Neuronales con aprendizaje supervisado incluyen la Red Neuronal basada en Resonancia Adaptativa (Hopfield) cuyos estudios en medicina incluyen clasificación de arritmias cardíacas, tratamiento y selección de depresión en pacientes, además de poderse usar para extraer reglas simbólicas.

2) Aprendizaje no Supervisado

Éste tipo de aprendizaje esta representado por instancias sin clasificación y apunta a identificar grupos con similares valores en sus atributos; la red neuronal más común es la red de Kohonen denominada SOM. Esta red consiste en una capa de nodos de salida, donde un nodo de salida esta totalmente conectado con los nodos de la capa de entrada. Cada enlace tiene asociado un peso, no hay conexiones específicas entre los nodos de la capa de salida[36].

El algoritmo de aprendizaje inicialmente pone los pesos en algún valor arbitrario. En cada paso de aprendizaje, una instancia es presentada a la red, el nodo de salida resultante es elegido con base en la instancia del atributo y teniendo en cuenta el valor del peso presente en dicho nodo. Los pesos del nodo elegido y de los nodos vecinos son actualizados de acuerdo a sus pesos actuales y a los valores de sus atributos. El

análisis basado en SOM es soportado adicionalmente por métodos de visualización que muestran como los patrones de los nodos de salida dependen de los datos de entrada. Así SOM podría no ser usado para identificar instancias similares, pero puede por ejemplo ayudar a detectar y analizar cambios de tiempo en los datos de entrada. Algunos ejemplos de SOM incluyen el análisis de datos en oftalmología, análisis de bases de datos de enfermedades cancerígenas.

V. APLICACIONES

Para entender de manera adecuada la exploración que se realizó a través de las diferentes aplicaciones de la Inteligencia Artificial en el diagnóstico médico se presentará un esquema descriptivo en la figura 1.

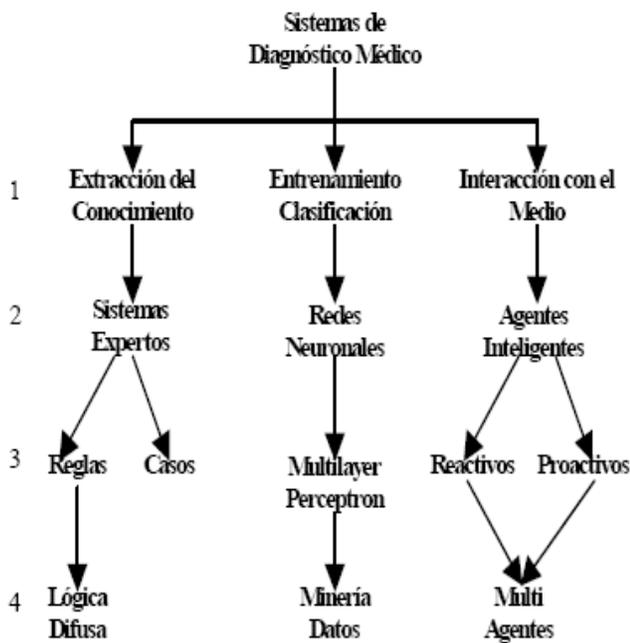


Fig. 1. Composición cronológica (izquierda a derecha) de las aplicaciones al diagnóstico médico usando métodos de Inteligencia Artificial.

- 1) Principio General (Basadas en);
- 2) Rama específica de la IA;
- 3) Clasificación dentro de la Rama;
- 4) Aplicación.

En la siguiente página en la tabla I se mostrarán algunos de los desarrollos que se han realizado en los últimos años, resaltando el año en que se culminó el proyecto, su(s) desarrollador(es) y el tipo de aplicación de la Inteligencia Artificial que se aplicó.

VI. CONCLUSIONES

El diagnóstico médico apoyado en Inteligencia Artificial a lo largo de la historia ha presentado una serie de tendencias marcadas por las apariciones de técnicas nuevas en éste

campo, instaurando olas que marcan los desarrollos realizados para esta época, tal fue el caso de los sistemas expertos a inicios de los 60.

Con las técnicas actuales de la inteligencia artificial el campo del diagnóstico médico abordado problemas más complejos y con una fiabilidad más alta en la obtención de los resultados, bien en sea utilizando los métodos clásicos de diagnóstico por probabilidades o los métodos más recientes como los usados en la minería de datos.

La identificación de un tipo específico de enfermedad es mucho más precisa y sencilla en la actualidad, puesto que muchos de los sistemas de diagnóstico que se aplican hoy en día, poseen una gran cantidad de conocimiento (plasmado generalmente como bases de datos), además del hecho que este conocimiento es útil para el reconocimiento de enfermedades que presenten características comunes y de ésta manera ampliar la base de conocimiento presente.

REFERENCIAS

- [1] A. Abu Hanna, P. J. F. Lucas. AI and Statical Approaches, Methods of Information in Medicine, June 2001, Pages 6-11.
- [2] Allen D. Malony and B. Robert Helm, A theory and architecture for automating performance diagnosis, Future Generation Computer Systems, Volume 18, Issue 1, September 2001, Pages 189-200.
- [3] [3] Armengol E., Palaudaries A., Plaza E (2001); Individual Prognosis of Diabetes Long-Term Risks: A CBR Approach. Methods of Information in Medicine Journal, 40, pp. 46-52.
- [4] Botti, C. Carrascosa, V. Julian, J. Soler. The ARTIS Agent Architecture: Modelling Agents in Hard Real-Time Environments. Proceedings of the MAAMAW'99. Lecture Notes In Computer Science, vol. 1647. Springer
- [5] Bonnie Kaplan, Evaluating informatics applications--clinical decision support systems literature review, International Journal of Medical Informatics, Volume 64, Issue 1, November 2001, Pages 15-37.
- [6] Cignoli R., Esteva F., Godo L., Torrens A. (2000); Basic fuzzy logic is the logic of continuous t-norms and their residua. Soft Computing. 4, pp. 106-112
- [7] David Rozier, A strategy for diagnosing complex multiple-fault situations with a higher accuracy/cost ratio, Engineering Applications of Artificial Intelligence, Volume 14, Issue 2, April 2001, Pages 217-227.
- [8] E.J Keogh, M Pazzani. Learning Bayesian Classifiers. Proceedings of the 7th International Workshop on Artificial Intelligence and Statistics, 1999, Pages 225-230.
- [9] Friedrich Steimann, On the use and usefulness of fuzzy sets in medical IA, Artificial Intelligence in Medicine, July 2001, Pages 131-137.
- [10] James P. Delgrande, Torsten Schaub, and Hans Tompits. Domainspecific preferences for causal reasoning and planning. In D. Dubois and C. Welty, editors, 9th International Conference on Knowledge Representation and Reasoning (KR2004), Delta Whistler Resort, Canada, 2004.
- [11] S. Chen, B. Mulgrew, and P. M. Grant, "A clustering technique for digital communications channel equalization using radial basis function networks," *IEEE Trans. Neural Networks*, vol. 4, pp. 570-578, July 1993.
- [12] Joan Alfrede Letian Gradually intrusive argumentative agents for medical diagnosis, Journal of Medical Informatics, October 2000, Pages 65 - 77.
- [13] John F Roddick, Peter Flue, Warwick J Graco, Exploratory Medical Knowledge Discovery, Artificial Intelligence in Medicine, March 2003.
- [14] John L Nelson, Antonio Moreno, The application of agent technology to health care, AgentCities Work Group of health Care, July 2003..
- [15] Kononenho I, Machine Learning for Medical Diagnosis perspective, Artificial Intelligence in Medicine, July 2001, Pages 89-109.

- [16] Kornel Papik, Bela Molnar, Rainer Schaefer, Janos Feher, Application of Neural Networks in medicine, November 1999, Pages 538-546.
- [17] Lenka Lhotska, Vladimir Marik and Tomas Vlcek, Medical applications of enhanced rule-based expert systems, International Journal of Medical Informatics, Volume 63, Issues 1-2, September 2001, Pages 61-75.
- [18] Ludmila I. Kuncheva, Friedrich Steiman, Fuzzy Diagnosis, Artificial Intelligence in Medicine, March 1999, 121-128.
- [19] M. Mahfouf, M.F. Abbod, D.A. Linkens, A survey of fuzzy logic monitoring and control utilisation in medicine, Artificial Intelligence in Medicine, August 2001, Pages 27-42.
- [20] M. Seidel, C. Breslin, R. M. Christley, G. Gettinby, S. W. J. Reid and C. W. Revie, Comparing diagnoses from expert systems and human experts, Agricultural Systems and Medical Systems, Volume 76, Issue 2, May 2003, Pages 527-538.
- [21] Margarita Sordo, Introduction to Neural Networks in Health Care, OpenClinical, October 2002.
- [22] Matjaz Kukar, Transductive reliability estimation for medical diagnosis, Artificial Intelligence in Medicine, September 2003, Pages 81-106.
- [23] Mingsheng Ying, Knowledge transformation and fusion in diagnostic systems, Artificial Intelligence, Volume 163, Issue 1, March 2005, Pages 1-45.
- [24] Natalya Fridman Noy, Carole D Hafner, The Ontology design, The American Association of Artificial Intelligence, January 1999, Pages 53 - 74.
- [25] Pedro Larrañaga Iñiqui Inza, Bayesian Classifiers International Journal of Medical Informatics, May 2000. Pages 1-17.
- [26] Peter Kokol, Spela Hleb Babic, Lenka Lhotska and Olga Stepankova, Intelligent medical systems - preface, International Journal of Medical Informatics, Volume 63, Issues 1-2, September 2001, Pages 1-4.
- [27] Rosa M. Vicari, Cecilia Flores, Andre M. Silvestre, A multi - agent intelligence environment for medical knowledge, Artificial Intelligence in Medicine, February 2003, Pages 335-366.
- [28] Robin Cowan, Expert systems: aspects of and limitations to the codifiability of knowledge, Research Policy, Volume 30, Issue 9, December 2001, Pages 1355-1372.
- [29] Rüdiger W. Brause, Medical Analysis and diagnosis by neural networks, Lecture Notes in Computer Science, September 2001.
- [30] Stefania Montani and Riccardo Bellazzi, Supporting decisions in medical applications: the knowledge management perspective, International Journal of Medical Informatics, Volume 68, Issues 1-3, 18 December 2002, Pages 79-90.
- [31] Shu-Hsien Liao, Expert system methodologies and applications—a decade review from 1995 to 2004, Expert Systems with Applications, Volume 28, Issue 1, January 2005, Pages 93-103.
- [32] T. Alsinet, C. Ansotegui, R. Bejar, C. Fernandez, and F. Manyá. Automated monitoring of medical protocols: a secure and distributed architecture. Artificial Intelligence in Medicine, 27:367{392, 2003.
- [33] Ulbricht C, Dorffner G, Lee A. Neural Networks of Recognizing Patterns in Cardiocograms. Artificial Intelligence in medicine, July 1999.
- [34] Vilma L Pantel, José F Arocha. A primer on Aspects of Cognition for Medical Informatics. Journal of the American Medical Informatics Association , Volume 8, Issue 4, August 2000, Pages 324-343.
- [35] Werner Horn, AI in medicine on its way from knowledge-intensive to data-intensive systems, Artificial Intelligence in Medicine, Volume 23, Issue 1, August 2001, Pages 5-12.
- [36] Yoichi Hayashi , Rudy Setiono, Combining neural network predictions for medical diagnosis, Computers in Biology and Medicine, November 2001, Pages 237-246.

TABLA I
APLICACIONES RECIENTES TECNICAS INTELIGENCIA ARTIFICIAL EN
DIAGNÓSTICO

Año	Título/Autor	Tipo de Aplicación	Publicación
1999	Leon and Luque (Expert System for diagnosis of viral illness)	Basado en Reglas	IEEE Transactions
2000	Mockler, R. J., Dologite, D. G., & Gartenfeld, M. E. (Medical decision making and learning)	Basado en Reglas	CAI. Cybernetics and Systems: An International Journal
2001	Tunez, S., Aguila, I. M., & Marin, R. (An expertise model for therapy and diagnostic using abductive reasoning.)	Basado en Reglas	Cybernetics and Systems: An International Journal.
2003	Meesad, P., & Yen, G. G. (Combined numerical linguistic knowledge representation and its application to medical diagnosis)	Lógica Difusa	IEEE Transactions on Systems, Man, and Cybernetics—Part A: Systems and Humans,
2004	Wang, Qu, Liu and Cheng (A self-learning expert system for diagnosis in traditional Chinese medicine.)	Redes Neuronales	Expert Systems with Applications
2004	Yan, H., Jiang, Y., Zheng, J., Fu, B., Xiao, S., & Peng, C. (The internet-based knowledge acquisition and management method to construct large-scale distributed medical expert system.)	Agentes Inteligentes	Computer Methods and Programs in Biomedicine
2004	Yang, Han, Kim (Integration of ART-Kohoene neural network and case-based reasoning for intelligent fault diagnosis)	Redes Neuronales	Computer Methods and Programs in Biomedicine
2004	Li, W., Tasi, Y. P., Tasi, & Chiu, C. L. (The experimental study of the expert system for diagnosing)	Redes Neuronales	Cybernetics and Systems: An International Journal.