

Introducción al razonamiento aproximado: lógica difusa

Autores Carlos Eduardo D'Negri*, Eduardo Luis De Vito**

Instituto de Investigaciones Médicas Alfredo Lanari, Universidad de Buenos Aires.

*Profesional Principal, CONICET

**Investigador Adjunto, Carrera de Investigador Clínico, CONICET

Cuando la única herramienta que tienes es un martillo,
todo comienza a parecer un clavo.

LA Zadeh

Introducción

En el ámbito de la medicina con frecuencia nos hallamos con este planteo: Este paciente presenta un conjunto de signos y de síntomas, ¿qué enfermedad tiene?. Tenemos tan incorporada esta pregunta que no siempre podemos percibir el grado de incertidumbre implícito. Pero todos sabemos que la relación que existe entre los signos y los síntomas y las enfermedades que los producen es variable (existen pacientes con iguales síntomas y diferentes enfermedades).

De hecho, la secuencia de los eventos y los datos disponibles pueden no ser conocidos con exactitud. No aceptar un cierto grado de incertidumbre en la información puede abrir sendos rápidos pero equivocados. El paciente puede administrar datos equívocos, puede no estar seguro de tal o cual afirmación o evocación, puede haber ausencia de información, errores y subjetividad por parte del paciente y de nosotros mismos.

El proceso mental que acerca al diagnóstico es complejo, el concepto probabilidad e incertidumbre están en mayor o menor grado presentes. Para medir la incertidumbre se puede partir de un conjunto grande que incluya todas las posibilidades diagnósticas. Luego debemos construir un subconjunto acotado y asignar un número real que mida el grado de incertidumbre sobre tal o cual diagnóstico. Para ello es necesario recurrir a medidas de probabilidad. La intuición no está excluida de este proceso.

Fuentes de incertidumbre

En términos generales, la fuente de incertidumbre deriva de tres áreas:

- *las deficiencias de la información* (incompleta, errónea, imprecisa),
- *las características propias del mundo real* (no determinista: mismas causas producen efectos diferentes en distintas personas) y
- *las deficiencias de los modelos* que intentan explicarlo (incompleto, inexacto).

El campo de la medicina es ejemplo paradigmático de dominio incierto, aunque todas estas fuentes de incertidumbre pueden darse, y de hecho se dan, en cualquier otro campo de las ciencias naturales, la ingeniería, el derecho, las humanidades y muy especialmente en los problemas de reconocimiento del lenguaje natural (hablado y escrito), donde la información implícita, la multiplicidad, la ambigüedad y la imprecisión, hacen imprescindible el tratamiento de la incertidumbre. En realidad, esta es una necesidad que no solo incumbe a los sistemas expertos y a los problemas de lenguaje natural, sino a todas las ramas de la inteligencia artificial, como el aprendizaje, la visión artificial, la robótica, las interfaces inteligentes, los juegos complejos (no solo los juegos de azar, sino también juegos como el ajedrez, donde no se conocen con certeza las preferencias del contrario), etc. De manera que el tratamiento de la incertidumbre es, junto con la representación del conocimiento y el aprendiza-

je, uno de los problemas fundamentales de la inteligencia artificial.

Tratamiento de la incertidumbre

Los métodos de razonamiento incierto se clasifican en dos grandes grupos: métodos cualitativos y métodos numéricos. Los primeros consisten en que, cuando no hay información suficiente, se hacen suposiciones, que posteriormente podrán ser corregidas al recibir nueva información. Por su naturaleza cualitativa no pueden considerar los distintos grados de certeza o incertidumbre de las hipótesis. Suelen presentar además problemas de incremento exponencial de la cantidad de combinaciones.

En cuanto a los métodos numéricos el primero que surgió fue el tratamiento probabilista. Ya en el siglo XVIII, Bayes y Laplace propusieron la probabilidad como una medida de la creencia personal hace 200 años. Recién con la aparición de las computadoras cobra impulso el tratamiento de la incertidumbre y se desarrolla la inteligencia artificial (alrededor de 1956) cuyos orígenes se remontan al año 1943. En aquella época, los ordenadores habían superado ampliamente la capacidad de cálculo de cualquier ser humano, pero estaban muy lejos del denominado “comportamiento inteligente”. Precisamente por eso la inteligencia artificial se centraba en la resolución de problemas simbólicos. Esta es una de las razones por las que inicialmente no se prestó atención al estudio de la probabilidad como rama o al menos como herramienta de la inteligencia artificial. Sin embargo, al enfrentarse a problemas de diagnóstico médico, era inevitable tener que tratar la incertidumbre, por las razones expuestas más arriba, y en aquellos años la única técnica disponible, aún con todas sus limitaciones, era el método probabilista clásico (a veces llamado *Bayes ingenuo*); con él se construyeron los primeros sistemas de diagnóstico médico que obtuvieron un éxito razonable en problemas que hoy nos parecen pequeños en tamaño.

No obstante, el método probabilista clásico presentaba dos inconvenientes principales:

1. La aplicación del teorema de Bayes “en bruto” requería un **número exponencial de parámetros**, por lo que se hacía necesario introducir hipótesis simplificadoras, que eran básicamente dos: la exclusividad de los diagnósticos y la independencia condicional de los hallazgos. Aun así el número de parámetros seguía siendo

relativamente elevado, sobre todo teniendo en cuenta que raramente había bases de datos a partir de las cuáles se pudieran obtener las probabilidades objetivas, por lo que en la mayor parte de los casos se hacía necesario recurrir a estimaciones subjetivas, poco fiables.

2. El segundo inconveniente grave del modelo era que **las hipótesis eran poco verosímiles, sobre todo la de independencia condicional**. Por estos motivos, la mayor parte de los investigadores estaban de acuerdo en que la probabilidad no era un método adecuado para la inteligencia artificial.

Un paso adelante en el desarrollo de la inteligencia artificial fue la introducción de la programación mediante **reglas**. Así se creó el sistema experto DENDRAL que mostró las ventajas de este nuevo enfoque. Se intentó posteriormente un nuevo sistema llamado MYCIN que pudiera adaptarse al razonamiento mediante **encadenamiento de reglas**. La incapacidad de los métodos probabilistas para encajar en este esquema llevaron a los responsables del proyecto a desarrollar un método propio, consistente en **asignar a cada regla un factor de certeza**. El éxito de MYCIN fue muy grande, pues en un campo tan complejo y tan incierto como el de las enfermedades infecciosas, fue capaz de conseguir diagnósticos y recomendaciones terapéuticas al menos tan buenos como los de los mejores expertos de su especialidad. Sin embargo, ciertas dudas de los propios creadores del MYCIN se vieron lamentablemente corroboradas por el matemático JB Adams, el cual demostró que en el método de combinación convergente de reglas había unas hipótesis implícitas tan fuertes como la independencia condicional exigida por el método probabilista, pero aún más difíciles de justificar.

En este período se produjo la aparición de las **redes bayesianas**, un modelo **probabilista** inspirado en la **causalidad**, cuya virtud principal consiste en que lleva asociado un modelo gráfico en que cada nodo representa una variable y cada enlace representa, generalmente, un mecanismo causal.

Las redes bayesianas experimentaron un extraordinario desarrollo en las décadas del 80 y 90 que ha permitido construir modelos de diagnóstico y algoritmos eficientes para problemas de tamaño considerable, a veces con cientos de variables, o incluso con miles de variables en algunos

problemas de genética. Prácticamente todas las universidades más importantes de Estados Unidos y las empresas punteras de la informática tienen grupos de investigación dedicados a este tema. Microsoft, por ejemplo, creó en 1992 un grupo formado por algunos de los investigadores más prestigiosos del área, especializados en distintos aspectos de la aplicación de las redes bayesianas a la informática; de hecho, la inclusión de estos métodos y modelos en Windows 95/98 y Office 97/2000 ha hecho que las redes bayesianas sean la aplicación de la inteligencia artificial que ha llegado a mayor número de usuarios. Otras empresas líderes de la informática, como Digital, Hewlett-Packard, IBM, Intel, Siemens, SRI, etc., cuentan igualmente con equipos de investigación en este campo.

En paralelo con esta evolución histórica de crisis y resurgimiento de la probabilidad, se desarrolló la *teoría de los conjuntos difusos*, frecuentemente llamada *LOGICA DIFUSA*. La motivación inicial no fue el estudio de la incertidumbre, sino el estudio de la **vaguedad**, que es algo diferente.

La incertidumbre está asociada al **desconocimiento** del valor exacto que pueda tener una variable. La vaguedad está en relación al **conocimiento** del valor de una función (llamada grado de pertenencia) de una variable cuyo **valor exacto se conoce**.

La lógica (del griego logos: la razón, el principio que gobierna al universo): es un conjunto de reglas usadas para generar inferencias creíbles. El modelo aristotélico de razonamiento se basa en el razonamiento exacto, es decir, una lógica dicotómica o binaria que admite dos posibilidades: verdadero-falso (o bien ceros y unos).

Pero el mundo real es diferente. La información que de él obtenemos es incierta e imprecisa. Esto es válido para las ciencias naturales, humanísticas, ingeniería, derecho y, de hecho, par la medicina. La fuente de incertidumbre deriva, a grandes rasgos, de tres áreas: las deficiencias de la información (incompleta errónea imprecisa), las características propias del mundo real (no determinista) y las deficiencias de los modelos que intentan explicarlo (incompleto, inexacto).

En contraposición a la lógica dicotómica o binaria que admite dos posibilidades: verdadero-falso, la lógica multivaluada admite varios valores de verdad posibles. La lógica difusa (fuzzy logic) es una forma de lógica multivariada que intenta cuantificar esa incertidumbre. Ya no hay blancos y negros únicamente sino grises.

Los ejemplos del centavo para ser millonario y de la altura de las personas son muy ilustrativos para la introducción al tema.

La paradoja del centavo para ser millonario es provocadora. Una persona recibe un centavo de peso cada minuto en forma continua. Al cabo de un tiempo, se volverá millonaria (millonaria no es tener un millón de pesos). ¿En cuál fue el centavo que convirtió a esa persona en millonaria? Antes de ese centavo era *casi* millonaria. ¿Puede un centavo dividir al conjunto millonario de los que no lo son?

El ejemplo de la altura de una persona es también muy demostrativo. Una persona que mida 2 metros es claramente una persona alta (le asignamos un grado de pertenencia de 1) y una persona (adulto) que mida 1 metro no es una persona alta en absoluto (es alta en grado 0). De forma intermedia podemos decir que una persona que mida 1.82 es alta con grado 0.78 (el 78% de la gente diría que es alta, por ejemplo) indicando que es “bastante alta” (Figura 1).

La lógica difusa se utiliza cuando la complejidad del proceso en cuestión es muy alta y no existen modelos matemáticos precisos, para procesos altamente no lineales, y cuando se manejan definiciones y conocimiento no estrictamente definido (impreciso o subjetivo). Es importante señalar que, mientras las redes bayesianas y la lógica difusa son temas de gran actualidad, como lo prueba la intensa labor investigadora que se está realizando en cada uno de ellos, el método probabilista clásico y el modelo de factores de certeza se consideran temas “muertos” desde el punto de vista de la investigación.

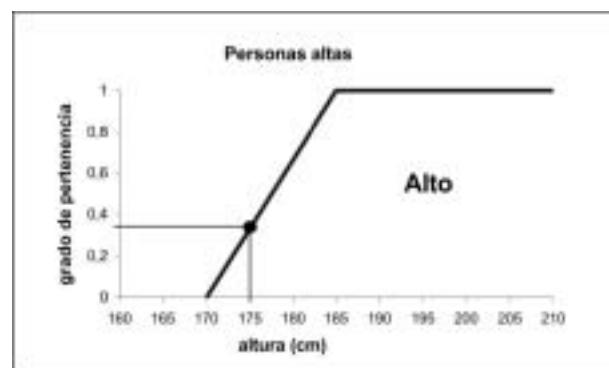


Figura 1: En el conjunto difuso “los hombres altos”. El grado de pertenencia se gradúa entre 0 y 1 (o entre 0 y 100%). En la figura, quienes miden > 185 cm tienen un grado de pertenencia al conjunto de los hombres altos de 100%. El hombre que mide 175 cm pertenece 33% al conjunto de los hombres altos.

¿Qué es la lógica difusa?

There is nothing fuzzy in fuzzy logic.

LA Zadeh

La lógica difusa es una metodología que proporciona una manera simple y elegante de obtener una conclusión a partir de información de entrada vaga, ambigua, imprecisa, con ruido o incompleta. En general la lógica difusa imita como una persona toma decisiones basada en información con las características mencionadas. Una de las ventajas de la lógica difusa es la posibilidad de implementar sistemas basados en ella tanto en hardware como en software o en combinación de ambos.

La lógica difusa es una técnica de la inteligencia computacional que permite trabajar con información con alto grado de imprecisión, en esto se diferencia de la lógica convencional que trabaja con información bien definida y precisa. Es una lógica **multivaluada** que permite valores intermedios para poder definir evaluaciones entre sí/no, verdadero/falso, negro/blanco, caliente/frío, pequeño/grande, cerca/lejos, pocos/muchos, etc.

El concepto de Lógica Difusa fue concebido por **Lofti A. Zaded**, profesor de la Universidad de California en Berkeley, quién disconforme con los conjuntos clásicos (*crisp sets*) que sólo permiten **dos opciones**, la pertenencia o no de un elemento a dicho conjunto, la presentó como una forma de procesar información permitiendo pertenencias parciales a unos conjuntos, que en contraposición a los clásicos los denominó Conjuntos Difusos (*fuzzy sets*).

En la conocida teoría de conjuntos, un elemento pertenece o no a un conjunto. En un conjunto difuso su frontera no está precisamente definida, y el grado de pertenencia entrega un valor entre 0 y 1. El concepto *grado de pertenencia* reemplaza al blanco o negro, es subjetivo y dependiente del dominio. El concepto de conjunto difuso fue expuesto por Zadeh en un artículo del año 1965, hoy clásico en la literatura de la lógica difusa, titulado “*Fuzzy Sets*” y que fue publicado en la revista *Information and Control*. El mismo Zadeh publica en 1971 el artículo, “*Quantitative Fuzzy Semantics*”, en donde introduce los elementos formales que acabarían componiendo el cuerpo de la doctrina de la lógica difusa y sus aplicaciones tal como se conocen en la actualidad. Zadeh dice: “La lógi-

ca difusa trata de copiar la forma en que los humanos toman decisiones. Lo curioso es que, aunque baraja información imprecisa, esta lógica es en cierto modo muy precisa: se puede aparcar un coche en muy poco espacio sin darle al de atrás. Suena a paradójica, pero es así”. El profesor Zadeh menciona que la gente no requiere información numérica precisa del medio que le rodea para desarrollar tareas de control altamente adaptables, por ejemplo conducir un automóvil o caminar por una acera sin chocarse con los postes y las otras personas. Si los controladores convencionales, en esencia realimentados, se pudieran programar para aceptar entradas con ruido e imprecisas ellos podrían trabajar de una manera más eficiente y quizás se podrían implementar más fácilmente.

El hombre, en la búsqueda de la precisión, intentó ajustar el mundo real a modelos matemáticos rígidos y estáticos, como la lógica clásica binaria. Cuando Aristóteles y sus precursores idearon sus teorías de la lógica y de las matemáticas, propusieron la Ley del Centro Excluido que indica que cada asunto debe ser verdad o falso. La hierba es verde o no verde; claramente no puede ser verde y no verde.

Lo que se busca, mediante el empleo de la teoría de los conjuntos difusos es describir y formalizar la realidad, empleando modelos flexibles que interpreten las leyes que rigen el comportamiento humano y las relaciones entre los hombres. Para describir esa realidad incierta, tanto en el orden de lo social como en el de lo natural, es necesario valerse de predicados, que pueden ser nítidos o difusos.

El nuevo punto de vista propuesto por Zadeh choca con siglos de tradición cultural –la lógica binaria de Aristóteles, ser o no ser–, por lo cual hubo resistencia por parte de los científicos, quienes se negaban a aceptar que se trataba de un intento por estudiar científicamente el campo de la vaguedad, permitiendo manipular conceptos del lenguaje cotidiano, lo cual era imposible anteriormente.

Según comenta Zadeh: “En Occidente la acogida fue menos positiva. En Asia aceptan que el mundo no es blanco o negro, verdad o mentira. En Occidente todo es A o B”. Por este motivo es en Asia (Japón en especial) donde más aplicaciones tecnológicas se realizan a partir de la lógica difusa.

Zadeh(1978), distingue entre los términos *vague* y *fuzzy*. Por ejemplo, “Juan regresará en unos pocos minutos” sería *fuzzy* (impreciso, pero informativo), mientras que “Juan regresará alguna vez” sería *vague* (ambiguo, no informativo). En el primer caso hay información que puede servir de soporte para una decisión y en el segundo no. En español se les ha bautizado con el nombre de conjuntos *borrosos* o *difusos*. Algunas asociaciones de estudiosos del tema en nuestro país han preferido no dar ninguna traducción al término, llamándole lógica *fuzzy*. Probablemente, Zadeh está queriendo señalar una estructura “blanda”, “suave”, “ligera”, no rígida (*crispy*) en su definición, pero no por ello vaga o ambigua. Quizás, menos preocupado del análisis cuantitativo exacto y, por el contrario, más atento a la aceptación de la imprecisión en el mundo real, especialmente, en la percepción y el pensamiento humanos, y al cálculo “blando” (*soft computing*).

Una aplicación de la metodología

Además del ejemplo del centavo millonario y de los hombres altos, los casos del entrenador de básquetbol y de la propina para el mozo inician sobre la aplicabilidad de la metodología.

El ejemplo del entrenador de básquetbol es también interesante. Un entrenador desea seleccionar candidatos para su equipo. Las condiciones son: altura y buen encestador. La solución clásica es: altura > 185 cm y de 16 tiros al arco se debe encestar al menos 13 (13/16). Se obtienen los siguientes resultados (Tabla 1).

La solución clásica tomaría a los candidatos F e I. Se puede observar, sin embargo, que el candidato E tuvo 16 aciertos. La solución utilizando conjuntos difusos es diferente. Se definen números difusos para cada variable y se hace una combinación por lógica difusa. El candidato exitoso es el que reúne los criterios estatura alta y encestador bueno (Tabla 2).

Utilizando lógica difusa se logra la selección con discriminación entre los candidatos (ranking valorado) como se observa en la tabla 3. Esto evita dejar fuera del equipo a un gran encestador que mide 183 cm. Tal como haría el entrenador. Se observa que en lugar de la decisión “se rechaza” o “se acepta” (cero o uno), hay graduaciones intermedias.

El caso de la propina para el mozo es otro ejemplo concreto que permite ver cómo funcionan los diferentes componentes y como se articulan. Sea

Tabla 1: Entrenador de básquetbol, solución clásica

Candidato	Estatura (cm)	Aciertos (16 tiros)	Solución clásica
A	167	12	0
B	169	6	0
C	175	15	0
D	179	12	0
E	183	16	0
F	186	13	1
G	187	12	0
H	190	10	0
I	200	13	1

Tabla 2: Entrenador de básquetbol, solución según los conjuntos difusos.

Candidato	Estatura (cm)	Aciertos (16 tiros)	Lógica difusa
A	167	12	0
B	169	6	0
C	175	15	0.33
D	179	12	0.50
E	183	16	0.87
F	186	13	0.75
G	187	12	0.5
H	190	10	0
I	200	13	0.75

Tabla 3: Entrenador de básquetbol, ranking valorado.

Candidato	Estatura (cm)	Aciertos (16 tiros)	Lógica clásica	Lógica difusa
E	183	16	0	0.87
F	186	13	1	0.75
J	200	13	1	0.75
D	179	12	0	0.5
G	187	12	0	0.5
C	175	15	0	0.33
A	167	12	0	0
B	169	6	0	0
H	190	10	0	0

el caso entonces de determinar qué propina deberíamos darle al mozo de un restaurant según la calidad de su atención y la calidad de la comida también. Si nos centramos en la atención solamente nuestro criterio sería:

1. si la atención es pobre, entonces la propina es baja.
2. si la atención es buena, entonces la propina es la promedio.
3. si la atención es excelente, entonces la propina es generosa.

Por otro lado, si nos centramos en la comida diríamos:

1. si la comida es mediocre, entonces la propina es baja.
2. si la comida es deliciosa, entonces la propina es generosa.

Ahora, nuestra decisión ha de incluir ambos aspectos para definir una propina única, y un posible criterio podría ser:

1. si la atención es pobre y la comida es mediocre, entonces la propina es baja.
2. si la atención es buena, entonces la propina es la promedio.
3. si la atención es excelente y la comida es deliciosa, entonces la propina es generosa.

Estas tres reglas son el núcleo de la solución. Como puede observarse, hay variables (atención, comida) que tienen un atributo o valor difuso (pobre, mediocre, excelente, etc.) y aunque calificamos la atención y la comida con un número que naturalmente ubicaríamos en el rango 0 a 10 (podríamos elegir otro) lo que nos interesa para tomar la decisión es saber **cuán** pobre o **cuán** excelente, por ejemplo, es la calificación que hemos puesto. Para ello necesitamos tener bien definida una asociación entre la calificación y el concepto “difuso” que estamos manejando. Esta asociación de la que hablamos es lo que en matemática se llama función y define el “grado de pertenencia” de esa calificación al concepto (conjunto difuso) pobre, buena, generosa, etc. Esa función, como podrán imaginarse, es clave y si algún defecto quisiéramos achacarle a la lógica difusa ese sería el de no proveer ella misma tal función. Pero, y ello es lo sorprendente de este método de razonamiento aproximado, su grado de convergencia a la toma de la decisión correcta es muy tolerante a la imprecisión con que pueda definirse esa función. Naturalmente, ésta ha de conservar un patrón de forma del que no debería apartarse significativamente.

Ahora bien, tal función puede provenir de nuestra intuición o del resultado de una encuesta, por ejemplo. Tomemos el caso del concepto “pobre”. Seleccionando solo a mozos que se caracterizaran por dar un servicio de escasa calidad y calificando uno mismo sus distintos niveles de atención y consultando a un grupo de personas sobre si llamarían pobre a cada uno de esos servicios nos podríamos encontrar con que 7 de cada 10 personas llama pobre a una atención a la que yo le pondría 4, y que 2 de cada 10 llamaría pobre a una atención de 5.

Pero 10 de 10 coincidirían que una calificación de 3 denota un servicio pobre. De esta manera se va conformando un perfil de lo que sería el grado de pertenencia al concepto “pobre” que iría desde 0 (todos coinciden en que la calificación **no es** la de un pobre servicio) hasta 1 (todos coinciden en que la calificación **es** la de un pobre servicio) barriendo todos los valores que van del 0 al 10 en la calificación.

Una vez definidas todas las funciones asociadas a los conceptos difusos aparece el tema de cómo interpretar los operadores lógicos “y” (AND), “o” (OR), “no” (NOT) y el de implicación “si... entonces”. Recordemos las tablas de verdad de la lógica binaria (Tabla 4).

Pero esta nueva lógica ya no se limita a solo dos valores de verdad, sino a un continuo de valores entre 0 y 1. La pregunta es ¿qué función de ese continuo reproduciría la tabla de verdad de AND? Una posible es la función “mínimo” (de los dos valores que toman A y B para esa calificación). Del mismo modo OR se correspondería con “máximo” y NOT con los valores de 1-A. Observemos la tabla para los nuevos operadores que operan sobre un dominio ahora continuo (Tabla 5).

Traduzcamos estas tablas a gráficos para ambas lógicas permitiéndonos en el caso de la multivaluada una variación continua en forma de triángulo para A y B (Figura 2).

Ahora nos queda por ver la implicación. Es una estructura del tipo:

Si x es A entonces y es B

o bien:

$$p \rightarrow q$$

Entonces a “x es A”, se le llama el antecedente (p) y a “y es B”, se le llama el consecuente (q). Por ejemplo: Si la atención es buena (ante-

Tabla 4: Propina del mozo; donde 0 denota falso y 1 verdadero para las proposiciones A y B.

A	B	A and B	A	B	A or B	A	not A
0	0	0	0	0	0	0	1
0	1	0	0	1	1	1	0
1	0	0	1	0	1	1	0
1	1	1	1	1	1	1	0
AND			OR			NOT	

Tabla 5: Propina del mozo; los nuevos operadores que operan sobre un dominio ahora continuo.

A	B	min(A,B)	A	B	max(A,B)	A	1 - A
0	0	0	0	0	0	0	1
0	1	0	0	1	1	1	0
1	0	0	1	0	1	1	0
1	1	1	1	1	1	1	0
AND			OR			NOT	

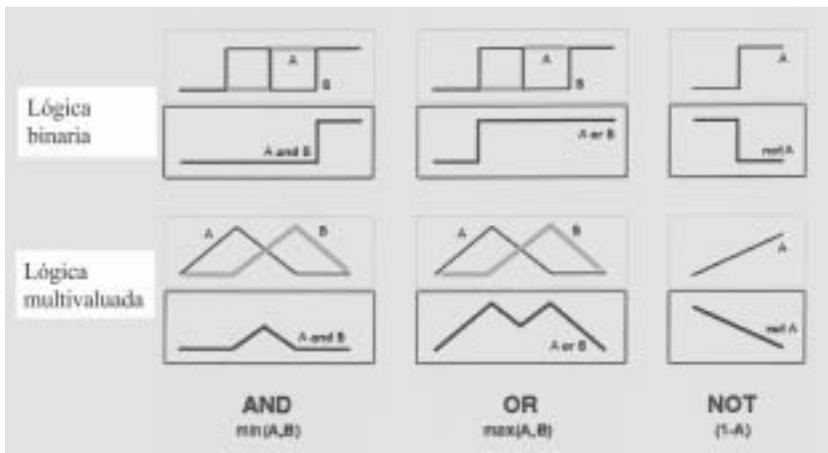


Figura 2: Propina del mozo. Representación gráfica de las tablas 4 (lógica binaria) y 5 (lógica multivaluada).

cedente) entonces la propina es la promedio (consecuente).

En la lógica binaria si p es verdadero q es verdadera o si p es falso q es falsa. La salida q siempre será 1 o 0. En lógica difusa el antecedente y el consecuente son conjuntos difusos entonces impondremos que si p es verdadero con un valor entre 0 y 1 q también lo será pero solo hasta el valor de p. Esto se refleja en un truncamiento de q (recordemos que q es un conjunto difuso) y la adecuada para llevar a cabo esto sería la función “mínimo”.

De ningún modo las funciones que hemos elegido como nuevos operadores lógicos han de ser las únicas, de hecho hay otras posibles, pero las que vimos son las clásicas y las más utilizadas.

En el gráfico siguiente (figura 3) ilustramos una implicación en particular de nuestro ejemplo y de paso observamos las tres etapas por las que fuimos pasando,

- 1) fusificación del input (determinación de las funciones de pertenencia)

- 2) aplicación del operador OR
- 3) efecto de la implicación sobre la función difusa del output.

En el ejemplo de la propina tenemos tres opciones de satisfacción que darán lugar a tres categorías de propina diferente: baja, promedio o generosa. Estos tres conjuntos difusos quedarán afectados por la calificación que yo le ponga a la atención y a la comida. Como esa calificación puede llegar a poner en acción más de una de las reglas simultáneamente tendremos que incluir los tres posibles *outputs* en uno general que adopte el criterio, para cada valor de la propina, del máximo valor en ese punto de los *outputs*. Es decir, les aplicamos el operador OR. No necesariamente ha de ser el único criterio de agregación.

Como la propina ha de ser un número bien definido deberemos defusificar la función de pertenencia que hemos obtenido para ésta y que tiene la peculiaridad de ir modificando su forma a medida que vamos cambiando las calificaciones. Un criterio puede ser el de la centroide, es decir aquel valor de la propina que reparte áreas iguales a ambos lados. Tampoco en este caso hay un criterio único pero es el más aceptado y es el que adoptamos nosotros.

A continuación mostramos el gráfico de nuestro sistema de inferencia de la propina congelado en las calificaciones que se muestran (3.07 para la atención y 8.5 para la comida) y que dieron por resultado una propina del 13% de lo consumido (Figura 4).

También podemos ver el gráfico tridimensional resultante ya que hay dos variables independientes, la atención y la comida y una dependiente que es la propina. Como podrá apreciarse dista mucho de ser una simple superficie plana (relación lineal entre las variables) (Figura 5).

Algunas verdades de la lógica difusa

1. Es conceptualmente fácil de entender porque los conceptos matemáticos que maneja son fáciles de entender.
2. Es flexible. Se puede ir incrementando su complejidad sin necesidad de reelaborar todo desde el principio.
3. Es tolerante a los datos imprecisos. Los incorpora de por sí dentro de su filosofía.
4. Puede modelar funciones no lineales de arbitraria complejidad. Cualquier conjunto de datos de input-output puede ser modelado por ella. Este proceso puede facilitarse a través de técnicas adaptativas como ANFIS (Adaptive Neuro-Fuzzy Inference Systems).

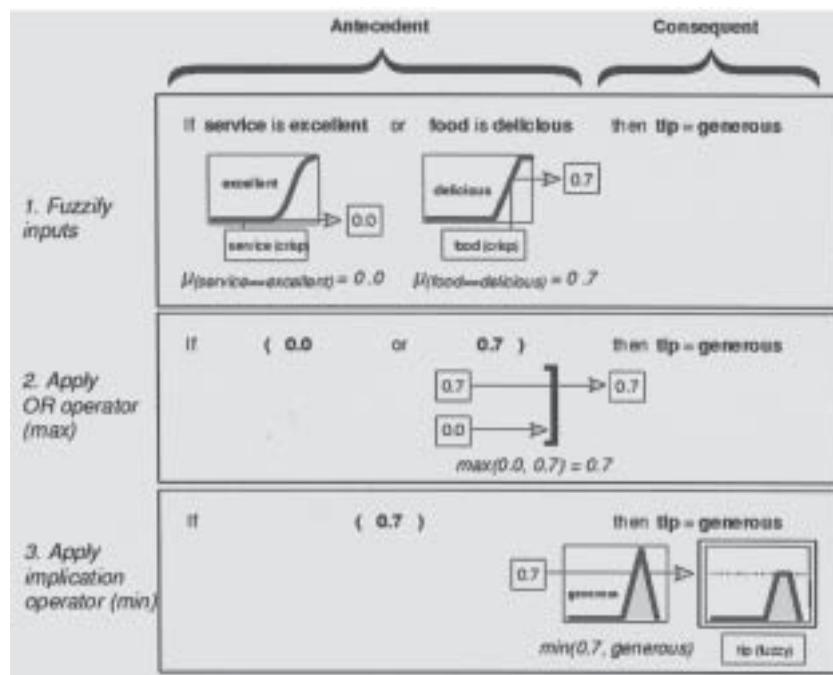


Figura 3: Ejemplo que involucra un caso similar de inferencia de propina (obtenido del tutorial del programa MATLAB 6.0 de MATHWORKS inc)

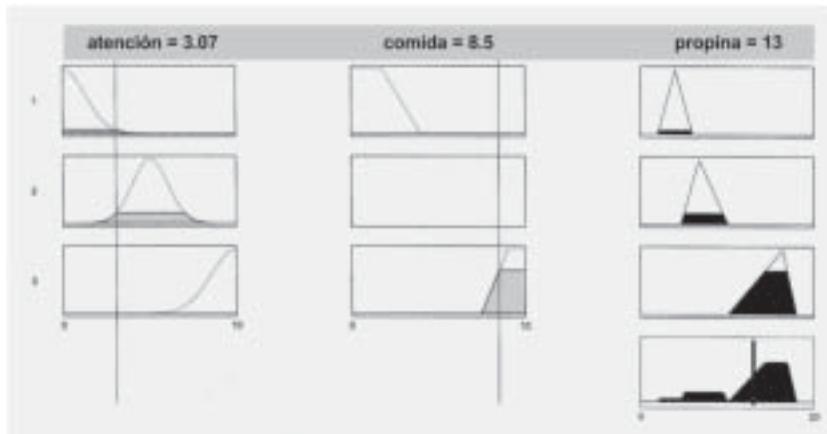


Figura 4: La propina del mozo. Calificaciones que se muestran (3.07 para la atención y 8.5 para la comida) y que dieron por resultado una propina del 13% de lo consumido.

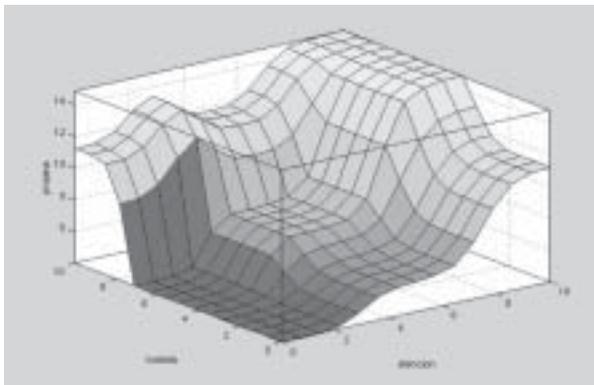


Figura 5: Propina del mozo. Gráfico tridimensional con dos variables independientes (atención y comida) y una variable dependiente (propina)

5. Puede ser construida aprovechando la experiencia de los expertos en el tema. En contraste con las redes neuronales no necesita entrenamiento ni constituye un bloque impenetrable y se construye directamente a partir del conocimiento de los expertos en el tema.
6. Puede combinarse con técnicas de control convencionales. No necesariamente reemplaza métodos de control convencionales. Puede incluso aumentarlos y simplificarlos.
7. Está basada en el lenguaje natural. Se apoya en las características de la comunicación humana coloquial.
8. Es estable, fácilmente ajustable y puede ser validada. No es fuertemente dependiente de variaciones de las funciones de pertenencia, y fácilmente puede ponerse a prueba y modificarse si es preciso.

La tabla 6 esquematiza algunas diferencias entre los conjuntos clásicos y los difusos.

Aplicaciones

El empleo del control difuso es recomendable:

- Para procesos muy complejos, cuando no hay un modelo matemático simple.
- Para procesos altamente no lineales.
- Si el procesamiento del (lingüísticamente formulado) conocimiento experto puede ser desempeñado.

El empleo del control difuso no es una buena idea si:

- El control convencional teóricamente rinde un resultado satisfactorio.
- Existe un modelo matemático fácilmente soluble y adecuado.

En la industria

Esta técnica se ha empleado con bastante éxito en la industria, principalmente en Japón. A continuación se citan algunos ejemplos de su aplicación:

- Sistemas de control de acondicionadores de aire
- Sistemas de foco automático en cámaras fotográficas
- Optimización de sistemas de control industriales
- Sistemas de reconocimiento de escritura

Tabla 6: Diferencias entre conjunto clásicos y difusos.

Conjuntos clásicos	Conjuntos difusos
Solo hay dos opciones. El elemento pertenece o no a un conjunto	Los elementos no tienen criterios de membresía precisamente definidos Admite grados de pertenencia
Blanco o negro	Gama de grises
Cero o uno	Infinitos números entre cero y uno
Refinidos con la realidad cotidiana y el lenguaje coloquial	Permite formalizar conceptos tales como alto, bajo, frío, rápido. Los conjuntos difusos permiten representar mejor ciertos tipos de incertidumbre

- Mejora en la eficiencia del uso de combustible en motores.
- Sistemas expertos del conocimiento (simular el comportamiento de un experto humano).
- Bases de datos difusas: Almacenar y consultar información imprecisa. Para este punto, por ejemplo, existe el lenguaje FSQL.
- Modelado con red neuronal y lógica difusa de un sistema experto para permitir decidir a personas inexpertas sobre la recuperabilidad de los edificios y viviendas luego de un fuerte sismo.
- la agencia del espacio de la NASA se dedica a aplicar la lógica difusa para las maniobras complejas.

En la medicina

En medicina, especialmente en medicina oriental, la mayoría de los conceptos médicos son difusos. La naturaleza imprecisa de los conceptos médicos y sus relaciones requiere el uso de una “lógica difusa”. La misma define entidades médicamente inexactas como fuzzy sets y permite un enfoque lingüístico que puede ser trasladado a los textos.

Sistema neuro-difuso desarrollado en el Lab. de Bioingeniería de la Facultad de Ingeniería de la Universidad Nacional de Mar del Plata para detectar:

- evaluación del envejecimiento arterial a partir de señales e distensión de la arteria empleando registros incruentos
- clasificación de registro para evaluar costos institucionales de diabéticos internados.

Aplicación de la geometría estocástica en proceso digital de imágenes (en la Universidad de Valen-

cia). Se aborda el problema de la segmentación del árbol vascular retiniano en imágenes de fondo de ojo dentro del contexto de la Teoría de Conjuntos Difusos. A partir de tres métodos de segmentación se han generado funciones de pertenencia a vaso en lugar de auténticas segmentaciones. De esta manera el árbol vascular pasa a ser un conjunto difuso y el objetivo es asociar al difuso un conjunto nítido (crisp) que sea representativo, es decir, una segmentación, en definitiva.

El problema de asociar un conjunto nítido representativo a un difuso (en inglés defuzzification) es muy debatido en el mundo de los difusos y en este artículo se ha intentado abordar mediante el concepto de promedio de un conjunto difuso. La Teoría de Conjuntos Compactos Aleatorios aporta distintas definiciones de conjunto medio que son directamente aplicables en el contexto difuso.

Los campos médicos que han sido estudiados desde el punto de vista de la lógica difusa han sido clasificados según Mahfour y col. en cuatro categorías: 1) Disciplinas conservadoras, 2) medicina invasiva, 3) disciplinas médicas definidas regionalmente, 4) Procesado de imágenes y señales.

– Utilización de la lógica difusa en control y monitoreo en ciencias médicas

Especialidades médicas diversas, clínicas y quirúrgicas, odontología, identificación mediante dientes, neuromedicina y psiquiatría, procesamiento de imágenes y señales, análisis e interpretación de datos de laboratorio, ciencias médicas básicas, salud pública

– Técnicas de control difuso

Controladores básicos, reglas basadas en configuraciones de bucles abiertos (administración de

oxígeno de los respiradores, dosis de insulina en diabéticos, administración de drogas en anestesia general) y cerrados con capacidad de aprendizaje por experiencia propia (administración y control de relajantes musculares y control simultáneo de presión arterial y nivel de relajación, estimulación muscular para lograr movimientos en enfermedades neurológicas). Sistemas híbridos (neurales, genéticos y wavelets) que combinan redes neurales y algoritmos genéticos.

– *Técnicas difusas para análisis de datos biomédicos*

Técnicas diagnósticas funcionales por imágenes para daño cerebral y respuesta a tratamientos. Análisis de actividad celular de membranas excitables con mínimo ruido de fondo. Clasificación en el campo de la psicología, forense, datos de laboratorio y cáncer de mama. Identificación por medio de sistemas expertos.

Conclusiones

En la lógica clásica solo hay dos posibilidades: verdadero o falso. Por tal motivo se dice que la lógica usual es bivalente o binaria. Pero existen otras lógicas que admiten un tercer valor posible (lógica trivaluada) e incluso múltiple valores como verdad (lógica multivaluada). La lógica difusa es un tipo de lógica multivaluada y se caracteriza por querer cuantificar esta incertidumbre. La lógica borrosa o difusa se basa en el principio de “*Todo es cuestión de grado*”.

Las decisiones médicas tienen efecto en la calidad de la atención médica, y también en los costos de atención. La secuencia lógica del pensamiento médico permite elegir, con una valoración de riesgo-beneficio, la mejor alternativa para el paciente y el conjunto. Este tipo de decisiones pertenecen al dominio de la lógica difusa. Con muy contadas excepciones, los “puntos de corte” y la clasificación según escalas nominales son *construcciones*. La vida real no es binaria, es difusa.

El hemisferio izquierdo del cerebro humano se utiliza para procesos lógicos, tales como leer y hablar, mientras el hemisferio derecho es para mecanismos intuitivos y emocionales así como procesamiento inconsciente de información. Los ordenadores convencionales imitan la parte izquierda, mientras que la Lógica Difusa representa el papel

de la derecha. Al trabajar con lógica difusa estamos imitando la vida real.

En ajedrez por ejemplo, los jugadores realizan conclusiones instantáneas, que a un ordenador convencional le llevaría horas calcular. Este razonamiento tan avanzado es producto de la conjunción de esfuerzos de ambas partes del cerebro.

La lógica difusa está enlazada con la inteligencia artificial y las redes neurales, áreas en desarrollo pero en estado embrionario aún. A medida que vayan aumentando las aplicaciones de la lógica borrosa y sus campos de aplicación se irá implantando en los currículums académicos.

Este artículo intentó acercar a sus lectores una herramienta de pensamiento diferente (de hecho utilizada) que quizá pueda ayudar a resolver, o al menos a enfocar, algunos problemas médicos. Cuando un problema requiere la utilización de lógica binaria, hay que utilizar lógica binaria, pero cuando requiere de lógica multivaluada, hay que utilizar lógica multivaluada. Es deseable disponer de múltiples herramientas, porque si nuestra única herramienta es un martillo, todo nos parecerá un clavo.

Lecturas sugeridas

- Algorri ME, Flores-Mangas F. Classification of Anatomical Structures in MR Brain Images Using Fuzzy Parameters. *IEEE Transactions on Biomedical Engineering* 2004; 51: 1599-1608.
- Hervás Abellán JG, Ruiz Merino R, Fabregat López F, Álvarez Gómez JA. Control automático de infusión de bloqueantes neuromusculares: perspectivas desde la lógica borrosa (fuzzy lógica). En “*Relajantes Musculares en Anestesia y Terapia Intensiva*” (2e) (eds. J.A. Álvarez Gómez, F. González Miranda y R. Bustamante Bozzo), pp.147-163. Arán Ediciones, 2000.
- Mahfouf M, Abbod MF, Linkens DA. A Survey of Fuzzy Logic Monitoring and Control Utilization in Medicine. *Artificial Intelligence in Medicine* 2001; 21: 27-42.
- Morillas Raya A. Introducción al análisis de datos difusos. <http://www.eumed.net/libros/2006b/amr/00.htm>.
- Nguyen HP, Kreinovich V. Fuzzy Logic and its Applications in Medicine. *International Journal of Medical Informatics* 2001; 62: 165-173.
- Nieto JJ, Torres A. Midpoints for Fuzzy Sets and their Application in Medicine. *Artificial Intelligence in Medicine* 2003; 27: 81-101.
- Perry R. Detección de Fraude en telecomunicaciones. Conferencia. XXII Taller de Ingeniería de Sistemas, Entrenador de basketball, Santiago de Chile, 13 al 16 de Julio de 1999.
- Torres A, Nieto JJ. Fuzzy Logic in Medicine and Bioinformatics. *Journal of Biomedicine and Biotechnology* 2006; vol: rev: 1-7.
- Zadeh LA. Fuzzy Sets. *Information Control* 1965; 8: 338-353.