

# Diferencias conceptuales entre la teoría de la posibilidad y los conjuntos difusos en la modelación de la incertidumbre

Édgar Rubén Muela Velasco\*

Fecha de envío: 1 de mayo de 2009

Fecha de aceptación: 25 de julio de 2009

## RESUMEN

En el ámbito de la teoría de conjuntos difusos y de la teoría de la posibilidad se han desarrollado muchas aplicaciones para ingeniería sin prestar mucha atención a la semántica involucrada en su uso. Como consecuencia, existe una muy amigable y sólida estructura matemática para combinar conjuntos difusos, aunque frecuentemente se presenta sin asignar a alguna estructura interpretativa. Al hacerlo así se corre el riesgo, por un lado, de confundir su uso, y por otro, de privar a los usuarios de esta técnica, de lineamientos sobre cómo y en qué situaciones es admisible su aplicación. Esta situación lleva irremediablemente al simple desarrollo de operaciones semánticamente sin sentido, dejando los resultados obtenidos sin el soporte de una estructura interpretativa. En efecto, en este documento se presentan explicaciones y ejemplos, que buscan dilucidar y resaltar tales diferencias subyacentes de tal modo que haya mejor uso de los conjuntos difusos en problemas de decisión.

**Palabras clave:** conjuntos difusos, incertidumbre, teoría de la posibilidad, toma de decisiones.

## CONCEPTUAL DIFFERENCES BETWEEN POSSIBILITY THEORY AND FUZZY SETS IN MODELING UNCERTAINTY

### ABSTRACT

Many engineering applications, in the field of fuzzy sets theory and the possibility theory, have been developed without taking account much attention to the semantics involved in its use. As a result, there is a very friendly and robust mathematical structure to combine fuzzy sets, but often this is presented without assigning any interpretative structures. In doing so, it is taken a risk on the one hand, confuse their use, and also, deny the users of this technique of guidelines on how and in which situations is adequate to apply this rule. Inevitably, this situation leads to the development of simple operations, which are semantically meaningless. Then, this paper presents both explanations and examples that seek to explain and highlight the underlying differences, in order to make better use of fuzzy sets in decision making.

**Keywords:** decision-making, fuzzy sets, possibility theory, uncertainty.

\* Ingeniero Eléctrico de la Escuela Politécnica Nacional (Quito-Ecuador). Doctor en Ingeniería Eléctrica del IEE de la Universidad Nacional de San Juan-Argentina. Profesor Asistente en el programa de Ingeniería Eléctrica de la Facultad de Ingeniería de la Universidad de La Salle. Correo electrónico: emuela@unisalle.edu.co

## INTRODUCCIÓN

La incertidumbre es la razón por la cual cualquier tarea de planificación o decisión se hace difícil y, más aún, constituye el motivo para que las decisiones tomadas no sean óptimas en sentido estricto. Aspectos como fluctuación en las tasas de cambio, variaciones en valores sociales y políticos –y por ende en preferencias– o creciente conciencia sobre temas ambientales, regulación gubernamental, avances tecnológicos, regulación y control de la contaminación, costos de fuentes primarias de energía, disponibilidad de materia prima, constituyen áreas importantes de incertidumbre en diferentes problemas de ingeniería. Adicionalmente, si se consideran las interacciones –por lo general muy complejas– entre diferentes fuentes de incertidumbre, se observa la necesidad de generar esquemas de modelación de ésta, de tal manera que fortalezcan los procesos de decisión.

Asimismo, es importante reconocer y comprender las diferentes clases de incertidumbres presentes en cada problema de decisión particular, porque éstas pueden tener consecuencias potencialmente negativas. Por ejemplo, en el área de sistemas de suministro de energía eléctrica, demasiada o muy poca capacidad de generación instalada se traduce en costos más altos; esto constituye, una sobreinversión que provocaría elevación en los costos de la energía para la sociedad, mientras que la subinversión aumentaría el riesgo de energía no suministrada, la cual reflejaría un equivalente monetario para la sociedad. Con base en la información disponible actual, las compañías eléctricas pueden invertir dinero en tecnologías que, en el futuro, podrían operar pobremente debido a las cambiantes circunstancias causadas por nuevos abastecimientos de combustible o nuevas tecnologías competitivas.

El término incertidumbre se ha utilizado de manera general para representar lo *desconocido*, entendi-

do como aquello que no puede resolverse de forma determinista (mecánica clásica), o que sólo puede resolverse a través del tiempo. En Schweppe *et al.* (1989) se define incertidumbre como cantidades o eventos que están más allá del conocimiento previo del centro de decisión. En Paraskevopoulos *et al.* (1991), el origen de la incertidumbre se atribuye a errores en especificación o estimación estadística de relaciones, y suposiciones de variables exógenas.

En un sentido más amplio, la incertidumbre se puede presentar debido a información incompleta, discordancia entre las fuentes de información, imprecisión lingüística o ambigüedad. La información incompleta puede provenir de simplificaciones y aproximaciones que son necesarias para hacer tratables los modelos de estudio. En otras ocasiones, la incertidumbre se refiere a la aleatoriedad en la naturaleza o variabilidad en datos.

Para efectos de este documento, *incertidumbre* se referirá a los factores que afectan las decisiones pero que no se conocen en el momento de realizar la planificación. Estos factores pueden ser de dos clases:

- Variables que entran en el modelo de planificación, es decir, pueden ser especificadas, aproximadas o pronosticadas aunque la resolución real de la incertidumbre pueda ser bastante diferente de su estimación.
- Variables o eventos que no entran en el modelo, puesto que no pueden ser proveídos o pronosticados.

Tradicionalmente, los procesos de planificación utilizan como instrumento fundamental de estudio los mecanismos de pronóstico, herramienta que se puede entender como la mejor estimación posible sobre condiciones futuras, en las cuales las expectativas se integran en función de distribución de la probabili-

dad (Rockafellar y Wets, 1991). Esta definición está estrechamente relacionada con el concepto decisión “óptima”, situación en la cual un centro de decisión optimiza el valor esperado de un atributo sobre un horizonte de tiempo, por ejemplo, maximizar beneficios netos (o minimizar pérdidas netas). Al adoptar este mecanismo, implícitamente se acepta que la imprecisión –cualquiera sea su naturaleza– puede ser equiparada con la aleatoriedad, hipótesis que puede ser discutible (Smets, 1997). En este contexto se habla de incertidumbre “fundamental”, la cual incluye no sólo aquella proveniente de ignorar las ocurrencias futuras de los resultados, sino también la originada por la ausencia de límites definidos claramente en los valores que pueda asumir una variable. Esto sucede porque, en muchas ocasiones, el planificador o el centro de decisión no pueden medir o expresar en una función explícita todos los factores determinantes del proceso de decisión a causa de diferentes motivos, por ejemplo: información incompleta, conocimiento insuficiente, ausencia o imprecisión de modelos, o que el costo necesario para adquirir la información no se vea compensado en una mejora sustancial de resultados. Incluso en algunas ocasiones es necesario recurrir a otra clase de información, a saber: preferencias, experiencia, intuición, ideología, creencias, sentimientos, entre otros datos, información que dado su origen no puede ser presentada en forma precisa y objetiva dentro de un proceso de decisión.

Todos estos antecedentes ponen en evidencia la necesidad de buscar enfoques alternativos que permitan fortalecer los procesos de planificación/decisión, dada la gran cantidad de factores que influyen en el comportamiento de las variables involucradas en el proceso de decisión, y que engloban tanto aspectos cuantitativos como cualitativos.

## TOMA DE DECISIONES EN AMBIENTES CON INCERTIDUMBRE

En la teoría de decisión clásica, una decisión se puede caracterizar por un conjunto de alternativas (espacio de decisión), un conjunto de estados de la naturaleza (espacio de estados), una relación que asigna a cada pareja estado-decisión un resultado, y finalmente una función de utilidad que ordena los resultados de acuerdo con su medida de mérito.

Cuando se adopta una decisión bajo certeza, el centro de decisión sabe qué estados de la naturaleza (del sistema analizado) esperar y selecciona aquellas alternativas con los más altos niveles de mérito. Cuando se decide bajo riesgo, no se conoce exactamente qué estado ocurrirá, pero se dispone de información sobre la distribución de probabilidad de los estados. En consecuencia, la decisión se vuelve más difícil. En la realidad, como expresaban Bellman y Zadeh (1970), la mayoría de decisiones en el mundo se realizan en ambientes en los cuales los objetivos, las restricciones, las posibles acciones (espacio de soluciones) y sus consecuencias no se conocen con precisión (información imperfecta).

Con el objeto de tomar decisiones, en ingeniería y ciencia, los sistemas complejos con los que tratan se describen por medio de modelos matemáticos. Un problema fundamental evidente cuando se trata de construir estos modelos, es la necesidad de realizar considerables idealizaciones para obtener un modelo matemático adecuado a partir del problema planteado. Sin embargo, la precisión del modelo determina la validez de sus conclusiones. Una de estas idealizaciones es la consideración de “certidumbre” sobre el conocimiento de las estructuras y parámetros del sistema por modelar. Esta suposición, en

muchos casos, sólo se justifica en la necesidad de modelos más simples y formulaciones más rápidamente solucionables.

Con este antecedente, cuando se desarrolla un modelo de un sistema con incertidumbre, el centro de decisión puede hacer lo siguiente:

- Ignorar la incertidumbre
- Reconocerla implícitamente
- Modelarla explícitamente

En primer lugar, ignorar la incertidumbre produce un modelo determinista del proceso con valores precisos de todos los parámetros. En segunda instancia, reconocerla implícitamente también puede generar un modelo determinista, en el cual los análisis de sensibilidad se utilizan para obtener información de cómo la incertidumbre afecta los resultados. Por último, el centro de decisión puede modelar explícitamente utilizando paradigmas específicos, tales como análisis de intervalos, teoría de probabilidad, teoría de posibilidad o teoría de la evidencia. El paradigma apropiado depende de la naturaleza de la incertidumbre. Por tanto, para un correcto modelado del problema es necesario definir adecuadamente distintos tipos de imperfecciones o limitaciones en la información disponible, así como las principales técnicas disponibles para su representación.

En la mayor parte de situaciones en las que se llevan a cabo procesos de toma de decisiones en el mundo real, la información disponible es de algún modo imperfecta, al no poder ser expresada de manera precisa, cierta, completa y consistente. Así, la imperfección en la información debe ser entendida en su sentido más amplio en el cual la imprecisión, la vaguedad y la incertidumbre son los aspectos más significativos que la caracterizan (Smets, 1997).

La imprecisión o la ambigüedad se presentan por la ausencia de especificidad en la información. Por

ejemplo, cuando se dice que “la potencia de un grupo generador está entre su mínimo técnico y su plena carga”, se puede tener total certeza sobre la veracidad de la afirmación, pero resulta totalmente imprecisa y, por tanto, poco específica. Por el contrario, cuanto más precisa sea una información –como cuando se afirma que “la potencia de un grupo es 101,23 MW”– menor es su veracidad. Zadeh (1973) resume este problema mediante el denominado principio de incompatibilidad, el cual establece que

mientras la complejidad de un sistema aumenta, la habilidad para llegar a sentencias precisas y significativas acerca de su comportamiento disminuye, hasta llegar a un límite más allá del cual la precisión y la relevancia se convierten en características mutuamente exclusivas.

La presencia de parecidos parciales genera la existencia de grados de verdad parciales que dan lugar a la vaguedad en los conceptos. Usualmente, la vaguedad aparece en afirmaciones de uso común en el lenguaje hablado, tanto en la vida cotidiana como en ambientes más técnicos o científicos (considerados generalmente más precisos). Por ejemplo, cuando se expresa que “deben parar las unidades de generación arrancados cuya potencia esté *aproximadamente* entre 100 y 220 MW”, no se tiene completa certeza acerca de si un grupo que genere 95 MW debe o no parar, aunque sí se sabe que la pertenencia al conjunto de grupos que deben parar será mayor para un grupo que genere 98 MW. En este ejemplo, la vaguedad en la información se hace patente pues admite diferentes grados de verdad parciales en cuanto a la pertenencia de los grupos arrancados al conjunto de grupos que deben parar.

La incertidumbre concierne al estado de conocimiento acerca de la certeza de un suceso. Así, la certeza puede ser, por ejemplo, verdadera o falsa, pero el conocimiento puede no permitir decidir entre ve-

racidad o falsedad del suceso. Existen varias formas usualmente frecuentes de expresar la incertidumbre en el lenguaje hablado. Una muy habitual es considerar probabilidades (generalmente subjetivas), como cuando se afirma: “Es probable que la demanda del sistema se reduzca el próximo año en un 5%”, o considerar posibilidades como: “Es posible que en el próximo año la demanda del sistema caiga en un 5%”. En ellas hay diferencias semánticas importantes que dan lugar a distintas formas de entender la incertidumbre. Mientras que la primera refleja una certidumbre (certeza) basada en análisis estadísticos, la segunda puede reflejar la inexistencia de impedimentos conocidos a que reduzca la demanda.

Finalmente, no debe confundirse la incertidumbre de una información con grados de verdad parciales. No es lo mismo asegurar por un lado que “el sistema eléctrico en una zona está disponible con probabilidad o certeza de 0,2” (medida de probabilidad), y por otro afirmar que “el sistema eléctrico en una zona está disponible con grado de certeza parcial 0,2 (medida de posibilidad)”. En el primer caso, el sistema está o no indisponible en la zona, aunque es muy probable (o posible) que no lo esté ya que su grado de certidumbre es 0,2. En el segundo, se tiene la certidumbre que la indisponibilidad parcial producirá ciertas molestias a los clientes que demanden electricidad en la zona (siendo el valor 0,2 interpretable, por ejemplo, como el grado de molestia), ya que el sistema está “ligeramente” indisponible (por ejemplo, por el fallo de algún transformador de la zona).

## TEORÍA DE LA POSIBILIDAD Y TEORÍA DE CONJUNTOS DIFUSOS

La teoría de la posibilidad es una aplicación importante de la teoría de conjuntos difusos introducida por Zadeh (1978), la cual permite modelar la imprecisión y la incertidumbre en la información en un mismo marco teórico. Por tanto, en primer lugar es

necesario dar una explicación general de la teoría de conjuntos difusos con el propósito de entender cómo funciona esta teoría en el manejo de la incertidumbre. Por ejemplo, dada la siguiente sentencia, “El Sahara es un desierto”, evidentemente toda la gente estaría de acuerdo en decir que eso es cierto. Supóngase que se quita un grano de arena. Si se vuelve a formular la pregunta, se continuaría diciendo que es cierto. Si se continúa así, quitando grano a grano, y se reitera la pregunta, llegaría un momento en que no habría más arena y el Sahara ya no sería un desierto. En ese punto, si se hace la pregunta, la respuesta debiera ser falso. No obstante, ¿en qué momento se produce, exactamente, el cambio del “sí” al “no”? Evidentemente, un desierto no deja de serlo cuando se le quita un particular grano de arena. Es más real afirmar que a medida que el Sahara pierde arena, la afirmación que es un desierto va haciéndose menos verdad y al quitar el último grano, la verdad desaparece por completo.

La lógica continua reconoce que la realidad no tiene por qué ser sólo cierta o falsa, sino que puede haber grados de verdad. Dicho de otra forma, los elementos de un conjunto no tienen por qué estar completamente dentro o completamente fuera del mismo; es posible la pertenencia parcial, un grado de pertenencia, de un elemento a un conjunto dado.

La teoría de conjuntos difusos marcó un quiebre importante en la visión del modelado de la información imperfecta y sirvió para incluir a la teoría de conjuntos tradicional como un caso particular de la teoría de conjuntos difusos.

En la teoría clásica de conjuntos, si se llama  $\Omega$  al universo de situaciones en discurso (conjunto completo) y dado un subconjunto  $A$  de  $\Omega$ , cada elemento  $x \in \Omega$  satisface la condición de  $x \in A$  o la alternativa  $x \notin A$ . El subconjunto  $A$  está representado por la aplicación  $f: \Omega \rightarrow \{0,1\}$

## SEMÁNTICA EN EL USO DE CONJUNTOS DIFUSOS

$$f_A(x) = \begin{cases} 1 & x \in A \\ 0 & x \notin A \end{cases}$$

donde  $f_A$  es la *función característica* del conjunto clásico  $A$ , también llamado conjunto rígido (*crisp*).

En términos de los conjuntos difusos se generaliza dicha función. Dado el conjunto completo  $\Omega$ , un conjunto difuso  $\tilde{A}$  es un conjunto de pares ordenados<sup>1</sup>:

$$\tilde{A} = \{x \in \Omega, \mu_{\tilde{A}}(x)\}$$

donde  $\mu_{\tilde{A}}: \Omega \rightarrow M$  corresponde a la función de pertenencia o membresía de los puntos  $x \in \Omega$ , que indica los distintos grados de pertenencia  $\mu_{\tilde{A}}(x)$  agrupados de forma ordenada en el conjunto de pertenencia  $M$ , normalmente acotado entre  $[0,1]$ . Mediante esta función se define completamente un conjunto difuso, donde  $x$  pertenece a  $\tilde{A}$  con cierto grado.

Un conjunto difuso se representa matemáticamente de dos formas:

- Universo de discurso discreto:

$$\tilde{A} = \sum_{i=1}^N \frac{\mu_{\tilde{A}}(x_i)}{x_i} \quad x_i \in \Omega$$

- Universo de discurso continuo

$$\tilde{A} = \int_x \frac{\mu_{\tilde{A}}(x)}{x} \quad x \in \Omega$$

En Dubois y Prade (1997) se señala que los conjuntos difusos parecen ser relevantes para tres tipos de tareas conducidas con base en el manejo de información, cuando los grados de membresía o pertenencia desempeñan un papel significativo, a saber: análisis y clasificación de datos, problemas de toma de decisiones y razonamiento aproximado. Por supuesto, este tipo de clasificación no es restrictivo, dado que, por ejemplo, no se menciona explícitamente modelación y control difuso. Sin embargo, estas tres tareas básicas han sido investigadas por muchos científicos, los cuales han desarrollado una correspondencia (y aprovechamiento) de tres semánticas o significados de las funciones de membresía, respectivamente en términos de similitud, preferencia e incertidumbre. Luego, si se define un grado de membresía  $\mu_F(u)$  de un elemento  $u$  en un conjunto difuso  $F$  definido sobre un conjunto referencial  $U$ . A continuación se describen tales semánticas.

La similitud es la más antigua de las interpretaciones de un grado de membresía. En ésta  $\mu_F(u)$  representa el grado de proximidad de  $u$  al elemento prototipo de  $F$ . Tal interpretación remite a un trabajo seminal de Zadeh *et ál.* (1966), en el cual se argumenta la aplicabilidad del concepto de conjunto difuso en la clasificación de patrones. Esta visión es particularmente adecuada en el análisis de conglomerados (clústeres), análisis de regresión o estudios semejantes, en los cuales el problema sea abstraer una representación a partir de un conjunto de datos por medio del aprovechamiento o explotación de la proximidad entre piezas de información. Asimismo, funciona en técnicas de control difuso, en las cuales los grados de similitud –entre la situación actual (o en curso) y una definida como típica (prototipo)– constituyen la base para mecanismos de interpolación.

<sup>1</sup> De aquí en adelante el símbolo “~” sobre un conjunto representa la versión difusa de éste.

En otro caso, si  $F$  representa un conjunto de objetos o valores de una variable de decisión  $x$ , y  $\mu_F(u)$  representa una intensidad en la preferencia a favor del objeto  $u$ , o la factibilidad de seleccionar  $u$  como un valor  $x$ , entonces el conjunto difuso representa criterios o restricciones flexibles, es decir, un grado de preferencia. Esta interpretación fue propuesta por Bellman y Zadeh (1970), la cual ha dado lugar a abundante literatura en optimización difusa, especialmente en programación lineal difusa y análisis de decisión.

Finalmente, si  $\mu_F(u)$  representa el grado de posibilidad que un parámetro ambiguo  $x$  tome el valor  $u$ , dado que lo único que se conoce es que “ $x$  pertenece a  $F$ ”, en este contexto se habla de grados de incertidumbre sobre el valor que  $x$  pueda tomar, en el cual los valores comprendidos por el soporte de  $F$  se excluyen mutuamente, y los grados de membresía ordenan los valores de  $u$  en términos de su plausibilidad. Esta interpretación fue propuesta por Zadeh, 1978, en la cual se introduce la teoría de la posibilidad y la teoría del razonamiento aproximado. Tal visión se ha utilizado en sistemas expertos e inteligencia artificial.

## DIFERENCIAS ENTRE LA TEORÍA DE CONJUNTOS DIFUSOS Y LA TEORÍA DE LA POSIBILIDAD

La teoría de la posibilidad plantea una hipótesis matemática dedicada al manejo de información incompleta, imprecisa o ambigua en una forma flexible, formal y sistemática, tal como fue propuesta por Zadeh en 1978, como extensión de su teoría de conjuntos difusos y lógica difusa.

En ese contexto, la incertidumbre de un evento se representa con dos parámetros, en lugar de uno, a saber: *medida de posibilidad* y *medida de necesidad*. La *posibilidad* de un evento evalúa la ausencia de

asombro (*indiferencia*) por la ocurrencia de un hecho, mientras que la *necesidad* evalúa el grado de *aceptación* del hecho como cierto.

Así como en probabilidad un evento tiene adherido una distribución de probabilidad, en teoría de posibilidad un evento tiene adherido una distribución de posibilidad. En efecto, Zadeh consideró que la distribución de posibilidad  $\pi$ , definida por la función de membresía  $\mu_{\tilde{A}}$  de un conjunto difuso  $\tilde{A}$ . Sin embargo, *esto no significa que los conceptos de conjunto difuso y distribución de posibilidad sean lo mismo*.

Para clarificar la diferencia de estos conceptos, supóngase que se tiene la expresión “ $X$  es  $\tilde{A}$ ”, donde  $X$  es una variable y  $\tilde{A}$  es un conjunto difuso (etiqueta) con función de membresía  $\mu_{\tilde{A}}$ . Por un lado, la expresión “ $X$  es  $\tilde{A}$ ” puede darse en un contexto en el cual el valor de  $X$  es conocido precisamente, y lo que se trata de hacer consiste en estimar la cantidad en la cual este valor es compatible con la etiqueta  $\tilde{A}$  (cuyo significado es, obviamente, dependiente del contexto). En este caso, el interés se centra en la naturaleza *suave* y *gradual* de la caracterización establecida por la sentencia “ $X$  es  $\tilde{A}$ ”.

Sin embargo, en otras ocasiones “ $X$  es  $\tilde{A}$ ” podría representar lo único o todo lo que se conoce sobre el valor de  $X$ , es decir, en este caso no se conoce con precisión el valor de  $X$ . Esto corresponde a un escenario de información incompleta (invadida de incertidumbre e imprecisión), situación en la cual sólo se puede *ordenar* los valores posibles de  $X$  de acuerdo con su nivel de plausibilidad o posibilidad. Cuando un conjunto difuso se utiliza para representar lo que se conoce sobre el valor de una variable, entonces el grado o nivel de membresía asignado a un valor “ $x$ ” expresa el nivel de posibilidad que éste sea el verdadero valor de la variable  $X$ . En este caso, el conjunto difuso se interpreta como una distribución de posibilidad  $\pi_{\tilde{A}} : \Omega \rightarrow [0,1]$ , la cual expresa varios

*matices* de plausibilidad en los valores posibles de la variable desconocida  $X$  a través del conocimiento que se tiene de lo *admisible, factible, creíble o posible* sobre la ocurrencia de dichos valores. Por ejemplo, si  $\mu_{\tilde{A}}(x)$  *cuantifica la pertenencia* de la demanda eléctrica  $x$  al conjunto de “demandas altas”, mientras que  $\pi_{\tilde{A}}(x)$  *cuantifica la posibilidad* que la demanda eléctrica sea  $x$  –sabiendo que la demanda pertenece al conjunto de “demandas altas”– el principio de Zadeh postula la siguiente igualdad:

$$\mu_{\tilde{A}}(x) = \pi_{\tilde{A}}(x) \quad \forall x \geq 0$$

Dada la coincidencia numérica entre las funciones de pertenencia y las distribuciones de posibilidad, en adelante se habla indistintamente de conjuntos difusos o distribuciones de posibilidad. Sin embargo, es importante distinguir que la interpretación de cada una de estas funciones es sustancialmente diferente, pues resulta útil expresar en algunas ocasiones la anterior igualdad como:

$$\mu(\tilde{A} / x) = \pi(x / \tilde{A}) \quad \forall x \geq 0$$

Efectivamente, esta nueva igualdad permite aclarar la confusión entre los conceptos de función de pertenencia y de distribución de posibilidad. La primera supone conocido el valor de la demanda y se obtiene el grado de pertenencia al conjunto de “demandas altas”. La segunda supone conocido que la demanda es alta y obtiene el grado de posibilidad que demanda cada valor de la variable. Por tanto, la coincidencia entre estas dos funciones es simplemente numérica y no conceptual.

En conclusión, cuando se utilizan conjuntos difusos en el contexto de la teoría de la posibilidad se está modelando la incertidumbre y ella se relaciona fundamentalmente con variables desconocidas o “incontrolables”, en las cuales no existe información completa o consistente sobre el valor que dichas

variables puedan “tomar” dentro de la restricción. En este contexto se habla de la plausibilidad que la variable en cuestión adopte algún valor específico. Nótese que, en este caso, se enfoca en la ocurrencia de situaciones adversas de la variable incierta; por tanto, el centro de decisión buscará protegerse de tales situaciones.

Por otro lado, cuando se desea explotar aspectos flexibles o de preferencia sobre factores de un problema de decisión, esta situación se relaciona con variables “controlables”, en las cuales se considera que es posible tomar ventaja de la relajación en los requerimientos de una restricción con base en el control que se tiene sobre la variable involucrada. Se habla entonces sobre grados de preferencia en el valor que se puede *asignar* a una variable. Nótese que, contrario a la semántica anterior, en este caso las restricciones se saturan (se satisfacen) en el sentido favorable a los objetivos que se persiguen, puesto que la situación de interés es la ampliación del “área” de soluciones factibles por medio de una ligera violación de los requerimientos. En ocasiones, esta situación incluso permite conseguir mayores niveles de logro en cuanto a los atributos de decisión (optimización).

## APLICACIÓN DE LA DIFERENCIACIÓN

Entre los ejemplos de la distinción expuesta –aplicados a los sistemas de suministro de energía– se pueden presentar respectivamente, por una parte, la restricción de balance de demanda-carga y, por otra, la restricción de reserva en un sistema de potencia.

En el primer caso, la demanda es una variable incontrolable o incierta (pronosticada), en cuyo caso el planificador tendrá el interés de prepararse para situaciones adversas, es decir, aquellas en las que la variable tome los mayores valores dentro de la distribución de posibilidad asociada con la demanda. En

el segundo caso, el nivel de reserva constituye una variable controlable por el planificador, y por tanto buscará tomar ventaja de la posibilidad de relajación (disminución) del requerimiento de reserva con el objeto de obtener valores más satisfactorios en el logro de los atributos.

Un ejemplo muy pertinente de aplicación de lo presentado en este documento se puede encontrar en Muela *et ál.* (2007).

## CONCLUSIONES

En la literatura relacionada con la aplicación de conjuntos difusos a sistemas de suministro de energía, pocos trabajos abordan explícitamente la diferencia-

ción aquí expuesta. De allí se deduce que el tema no se considera en absoluto o poca importancia se le da. Situación que, en cambio, desde la perspectiva del autor –tal como se mostró con ejemplos en este documento– es de relevancia debido a la gran necesidad de una interpretación y análisis adecuados a partir de los resultados obtenidos, en especial para la implementación práctica señalada.

Por ello es imprescindible que en cualquier propuesta de investigación que pretenda modelar la incertidumbre por medio de conjuntos difusos, se deba establecer de antemano tal interpretación y asimismo haya una clara diferenciación con respecto a otros usos que puedan tener los conjuntos difusos para determinado problema analizado.

## REFERENCIAS

- Bellman, R. y Zadeh, L.A. Decision-Making in Fuzzy Environment. En *Management Science*, Vol. 17, N.º 4, December 1970, pp. B-141-164, 1970.
- Dubois, D. y Prade, H. The three semantics of fuzzy sets. En *Fuzzy Sets and Systems*, 90, 1997, pp. 141-150.
- Muela, E.; Schweickardt, G. y Garces, F. Fuzzy Possibilistic Model for Medium-Term Power Generation Planning with Environmental Criteria. En *Energy Policy*, 2007, Vol. 35, issue 11, pp. 5643-5655.
- Paraskevopoulos, D.; Karakitsos, E. y Rustem, B. (1991) Robust Capacity Planning Under Uncertainty. *Management Science*, Vol. 37, No. 7, July, pp. 787-800.
- Rockafellar, R. T. y Wets R. Scenarios and Policy Aggregation in Optimization Under Uncertainty. En *Mathematics of Operations Research* archive. Vol. 16, N.º 1, pp. 119-147, February, 1991.
- Schweppe, F.; Merrill, H. M. y Burke, W. (1989) Least Cost Planning: Issues and Methods. En *Proceedings of the IEEE*, Vol. 77, No. 6, pp. 899-907.
- Smets, P. Imperfect information: Imprecision–Uncertainty. En *Uncertainty Management in Information Systems. From Needs to Solutions*, A. Motro and P. Smets, Eds.: Kluwer Academic, 1997, pp. 225-254.
- Zadeh, L. A. Fuzzy Sets as a Basis for a Theory of Possibility. En *Fuzzy Sets and Systems*, vol. 1, pp. 3-28, 1978.
- Zadeh, L. A. Outline of a New Approach to the Analysis of Complex Systems and Decision Processes. En *IEEE Transactions on System, Man and Cybernetics*, 1, 28-44. 1973.
- Zadeh, L.A.; Bellman, R. y Kalaba, L. Abstraction and Pattern Classification. *Math. Anal. Appl.*, vol. 13, pp. 1-7, January 1966.