

# MODELOS DE REPRESENTACIÓN DE IMPRECISIÓN E INCERTIDUMBRE EN FUSIÓN DE ALTO NIVEL

Juan Gómez-Romero<sup>1</sup>, Jesús García<sup>2</sup>, José M. Molina<sup>2</sup>

<sup>1</sup> Departamento de Ciencias de la Computación e I.A., CITIC-UGR, jgomez@decsai.ugr.es

<sup>2</sup> Grupo de Inteligencia Artificial Aplicada, Univ. Carlos III de Madrid, {jgherrer@inf, molina@ia}.uc3m.es

## Resumen

Las técnicas de fusión de datos e información procedente de redes de sensores necesitan manejar información incierta e imprecisa, puesto que es habitual enfrentarse a problemas en los que el conocimiento disponible es vago o insuficiente y/o los aparatos de medición están sujetos a fallos. Con el reciente auge de la denominada “fusión de alto nivel”, que tiene como objetivo reconocer la situación observada e identificar posibles riesgos, este problema se ha acentuado, ya que los formalismos que se utilizan habitualmente para construir un modelo simbólico del escenario, como la lógica de primer orden y las ontologías, no proporcionan soporte para este tipo de conocimiento. En este trabajo repasamos varias propuestas recientes para representación y razonamiento con información incierta e imprecisa en fusión de alto nivel. Nos centramos en dos tipos: (a) las que incorporan estos mecanismos en los propios modelos de representación, como las ontologías probabilísticas y difusas y las redes lógicas de Markov; (b) las que extienden el proceso de fusión con una capa de gestión de incertidumbre adicional, como las basadas en argumentación probabilística.

**Palabras Clave:** Ontologías difusas, ontologías probabilísticas, redes lógicas de Markov probabilísticas, argumentación probabilística.

## 1 INTRODUCCIÓN

En el ámbito de las redes de sensores, se denomina fusión al procedimiento por el cual se obtiene una mejor estimación de la situación observada utilizando los datos procedentes de varios sensores, en lugar de uno solo, junto a información relacionada [20]. Históricamente, el concepto de *fusión de información* ha estado asociado a aplicaciones basadas en señales de radar, como por ejemplo, la detección y seguimiento de objetivos móviles en defensa, el control de tráfico aéreo y marítimo o la identificación

de intrusos, que requieren identificar, segmentar y etiquetar de forma consistente los objetos móviles de la escena (*tracking*) a partir de varias fuentes de datos distribuidas. En la actualidad existen numerosas áreas que hacen uso de estas técnicas, como por ejemplo la videovigilancia, que realiza seguimiento de individuos con varias cámaras; la imagen médica, que puede beneficiarse de la capacidad de combinar datos de diferentes sensores o de distinta naturaleza; o la gestión de emergencias en catástrofes naturales, que comparte características con las tareas de comando y control militares.

La fusión de información es un proceso inherente al ser humano: el cerebro realiza continuamente el proceso de interpretar los estímulos recogidos por los sentidos de acuerdo al conocimiento disponible en la memoria para entender qué está ocurriendo en el entorno y actuar consecuentemente. Los métodos de fusión de información tienen como objetivo reproducir esta capacidad de forma automática.

Habitualmente, se distingue entre fusión de información de bajo nivel y de alto nivel. La fusión de bajo nivel aplica técnicas numéricas para estimar propiedades simples de los objetos, representadas como vectores de estado, a partir de múltiples fuentes de datos. Estos métodos numéricos resultan insuficientes cuando los objetos interactúan (mediante oclusiones, uniones o separaciones) y se alteran (por deformaciones), o se producen cambios en el escenario (iluminación). En general, la fusión de bajo nivel no se ocupa de descubrir las relaciones existentes entre los objetos y los posibles efectos de sus acciones, pues se centra en los aspectos individuales de los mismos. En cambio, la fusión de alto nivel busca construir un modelo más complejo del escenario a partir de las observaciones de bajo nivel que describa simbólicamente las relaciones entre los objetos, con el objetivo de comprender la situación, valorar los posibles riesgos y ofrecer conocimiento al usuario para ayudarlo en la toma de decisiones. Esto requiere la construcción de un modelo lógico que extienda a los modelos puramente numéricos y que permita representar el mundo y razonar sobre sus hechos de forma similar a como hacemos los humanos [24]. Así lo refleja el modelo de referencia JDL (*Joint Directors of Laboratories*), que clasifica los procesos de fusión en varios

niveles dentro de estos dos grupos [31]: (1) fusión de bajo nivel: extracción de características de la señal (nivel 0, o  $L0$ ) e identificación de objetos ( $L1$ ); (2) fusión de alto nivel: reconocimiento de situaciones ( $L2$ ), evaluación de amenazas ( $L3$ ) y mejora del proceso ( $L4$ ).

Uno de los problemas fundamentales que se plantea en fusión es el tratamiento de la información incierta y/o imprecisa. Por una parte, es habitual que los datos disponibles no sean completamente fiables, bien porque los sensores pueden proporcionar valores erróneos o bien porque existen circunstancias externas al sistema que afectan a su adquisición y procesamiento, como por ejemplo las condiciones meteorológicas en los radares marítimos. Por otra parte, el conocimiento experto necesario para interpretar una situación normalmente se expresa en términos imprecisos, como cuando se establece en un puerto la norma de que un barco no identificado no puede estar *demasiado cerca* de un carguero. Las personas somos capaces de gestionar apropiadamente ambos tipos de información y agregarlas de manera eficaz para obtener conclusiones razonables en un tiempo reducido. Los métodos de fusión, por su parte, necesitan formalismos adecuados que permitan representar imprecisión y incertidumbre.

En la literatura existen diversas propuestas para dotar a los métodos de fusión de alto nivel de la capacidad de procesar información incierta e imprecisa. Podemos clasificar estas aproximaciones en dos grupos:

- Extensiones de modelos simbólicos que ofrecen soporte para la imprecisión y la incertidumbre. Entre otros, destacan las ontologías difusas, las ontologías probabilísticas y las redes lógicas de Markov.
- Extensiones del proceso de fusión para dotarlo de una capa adicional que permita la gestión de imprecisión e incertidumbre, como por ejemplo la argumentación probabilística.

En este artículo estudiaremos las nociones de imprecisión e incertidumbre en el contexto de la fusión de información y revisaremos varias propuestas de modelos para su gestión en fusión de alto nivel. Además, discutiremos las ventajas y desventajas de ambos tipos de aproximaciones en diferentes ámbitos de aplicación. El objetivo fundamental es proporcionar una visión general de esta área y presentar diversas conclusiones obtenidas por nuestro grupo de investigación.

La siguiente sección trata los conceptos de imprecisión e incertidumbre y su importancia en el ámbito de la fusión. La sección 3 se centra en las propuestas que extienden directamente a los modelos simbólicos, mientras que la sección 4 explica cómo se puede implementar una capa de abstracción superior en el proceso de fusión. Finalmente, en la sección 5 exponemos algunas ideas sobre la evaluación de las distintas aproximaciones. Para terminar, resumimos las conclusiones alcanzadas y anticipamos algunas líneas de trabajo futuro.

## 2 IMPRECISIÓN E INCERTIDUMBRE EN FUSIÓN DE INFORMACIÓN

La incertidumbre y la imprecisión son dos características relacionadas pero diferentes de la información imperfecta. A continuación resumimos las diferencias fundamentales, que han sido tratadas por numerosos autores [11, 22, 34], y su importancia en fusión.

La incertidumbre se refiere a la falta de seguridad por parte del observador en la veracidad de una afirmación. Por ejemplo, la posición de un objeto proporcionada por un radar es un valor preciso de latitud y longitud, pero puede existir cierta duda sobre su exactitud, debido a la imprecisión del sensor, a su tasa de fallo o a otras circunstancias. En cualquier caso, se podría comparar la posición real del objeto y determinar si la estimación inicial era cierta o no. Así, en teoría de la incertidumbre, una aserción no es verdadera o falsa, sino que existen ciertas expectativas de que lo sea. Generalmente, esta incertidumbre se debe a la falta de un conocimiento absoluto sobre los hechos y las leyes que rigen el mundo observado. Dubois distingue tres tipos de incertidumbre según su origen [12]: aleatoria, cuando resulta de un proceso estocástico, como por ejemplo lanzar un dado; epistémica, cuando se debe a ignorancia; e inconsistente, cuando representa un conflicto entre varias fuentes. Existen diversos marcos teóricos para modelar esta incertidumbre en forma de probabilidad, posibilidad o creencia [28], siendo de los más destacados en fusión de información las redes bayesianas [23], la teoría de Dempster-Shafer [27] y la argumentación probabilística [14].

Una afirmación imprecisa es aquella que no es completamente verdadera o falsa, sino que su veracidad puede medirse con un grado. Por ejemplo, podemos decir que un objeto es grande. De este modo, “grande” es un predicado impreciso cuyo grado de verdad refleja el tamaño del objeto. Si el objeto supera cierto umbral máximo preestablecido, el grado de la afirmación será 1, mientras que si es inferior a un umbral mínimo, será 0. En cualquier situación intermedia, el grado de cumplimiento vendrá dado por una función dependiente del tamaño. Este tipo de enunciados son muy frecuentes en lenguaje natural, especialmente cuando se trata de enunciar percepciones subjetivas y de tipo lingüístico. El principal formalismo para representación de incertidumbre es la Lógica Difusa [34, 17]. En el ámbito de la fusión de información, la Lógica Difusa se ha utilizado en numerosas aplicaciones: agregación de información, toma de decisiones, inferencia y razonamiento, etc.

## 3 MODELOS SIMBÓLICOS CON IMPRECISIÓN E INCERTIDUMBRE

En fusión de alto nivel se han utilizado diferentes formalismos simbólicos para la representación del escenario

observado y la información adicional disponible [32]. Entre ellos, destacan las ontologías [18, 19]. Una ontología es una especificación formal de los conceptos, relaciones, instancias y restricciones de un dominio utilizando un lenguaje basado en una Lógica de Descripciones (*Description Logic*, DL) [1]. Este tipo de representaciones se han consolidado en la actualidad como el formalismo de representación en Web Semántica, y son la base del estándar para ontologías web OWL [33]. La principal ventaja de las DLs es que generan modelos decidibles (esto es, la inferencia siempre termina en tiempo finito), mientras que los modelos basados en Lógica de Primer Orden son más expresivos, pero también semi-decidibles (no se garantiza que la inferencia termine en tiempo finito para sentencias que no son ciertas).

Las ontologías no permiten gestionar directamente información imprecisa o incierta, por lo que se han propuesto diferentes variaciones y extensiones que introducen constructores adecuados para representar este tipo de conocimiento [21]. Las diferentes aproximaciones posibles han sido estudiadas por el grupo de trabajo en incertidumbre en Web Semántica auspiciado por la organización de estandarización W3C<sup>1</sup>. En esta sección proponemos dos con interés para la fusión de alto nivel, como son las ontologías probabilísticas y las ontologías difusas. También incluimos las redes lógicas de Markov, que si bien no se pueden clasificar como formalismos basados en ontologías, comparten ciertas características con éstas por resultar de la combinación de la Lógica de Primer Orden, las redes semánticas y los modelos probabilísticos.

### 3.1. ONTOLOGÍAS PROBABILÍSTICAS

Una de las propuestas más relevantes para representación de incertidumbre con ontologías es PR-OWL 2, una extensión del lenguaje OWL basada en redes bayesianas [9]. PR-OWL 2 permite asociar un grado de certeza a los axiomas de instancias; en concreto, a los axiomas de pertenencia a clase –que declaran que una instancia es miembro de una clase– y de relación –que establecen que dos instancias están relacionadas. En la actualidad no existe ningún razonador que proporcione soporte para realizar inferencia con PR-OWL 2, pero es posible transformar la ontología probabilística resultante en una red probabilística y procesarla con la herramienta UnBBayes<sup>2</sup>. PR-OWL 2 ha sido utilizado en problemas de fusión de alto nivel en el dominio marítimo con interesantes resultados [8].

Otra aproximación es la realizada en [16], donde se propone PRONTO, un razonador para una extensión probabilística de la DL  $\mathcal{SHJF}$ , que tiene una expresividad similar a OWL 2. Una propiedad interesante de la lógica de PRONTO es que, a diferencia de las redes bayesianas,

permite describir conocimiento impreciso de forma declarativa sin necesidad de especificar distribuciones de probabilidad. Aunque PRONTO incluye diversas optimizaciones para mejorar la eficiencia y la escalabilidad del razonador, su utilidad en problemas reales aún no ha sido completamente contrastada.

### 3.2. ONTOLOGÍAS DIFUSAS

Las ontologías difusas combinan las DLs con la Lógica Difusa de forma que los conceptos denotan conjuntos difusos de instancias y las propiedades denotan relaciones binarias difusas. De esta manera, una instancia pertenece a un concepto en un grado en  $[0, 1]$  y un par de instancias pertenecen a una relación con un grado en  $[0, 1]$ . Los axiomas también se extienden al caso difuso; por ejemplo, dados dos conceptos difusos, un axioma de subsunción difuso establece una relación de inclusión difusa entre ambos. En la literatura se han propuesto diferentes DLs difusas, cada una incluyendo diferentes constructores. Entre ellos, destacamos la inclusión general de conceptos, los conjuntos aproximados, los tipos de datos o los operadores de agregación (ver por ejemplo [5, 7]). Estos nuevos constructores suelen expresarse con una nueva sintaxis, pero también existe la posibilidad de utilizar un lenguaje de ontología para crear un meta-modelo de representación [6]. En la mayoría de los casos, la interpretación de la ontología difusa depende de la familia de operadores difusos considerados (Zadeh, Gödel, etc.), lo que da lugar a diferentes representaciones con diferentes propiedades [2].

Las DLs difusas requieren nuevos algoritmos de razonamiento para realizar inferencias teniendo en cuenta los nuevos constructores. Existen dos aproximaciones básicas a este problema: (1) diseñar un nuevo algoritmo de razonamiento; (2) desarrollar un proceso que permita reducir la ontología difusa a una ontología no difusa que conserve la misma semántica y utilizar un motor de inferencia existente. *fuzzyDL* es una propuesta basada en la primera estrategia [4], mientras que *DeLorean* es el principal ejemplo de la segunda [3]. *fuzzyDL* tiene la ventaja de que permite operar directamente con la ontología difusa y aplicar optimizaciones directamente relacionadas con la representación original. Sin embargo, el esfuerzo necesario para su desarrollo es mucho mayor, lo que explica su reducido uso fuera del mundo académico. Por su parte, *DeLorean* permite explotar los beneficios de los razonadores y los lenguajes estándar, pero introduce cierta sobrecarga al realizar el proceso de transformación entre la representación difusa y la no difusa. En ambos casos, bajo ciertas condiciones que se dan con cierta frecuencia, estas desventajas pueden mitigarse. Por lo tanto, se puede esperar que próximamente sean utilizados más intensamente en aplicaciones de fusión de alto nivel.

<sup>1</sup> <http://www.w3.org/2005/Incubator/urw3/>

<sup>2</sup> <http://unbbayes.sourceforge.net/>

### 3.3. REDES LÓGICAS DE MARKOV

Las redes lógicas de Markov (*Markov logic networks*, MLNs), son una extensión de la lógica de primer orden con razonamiento probabilístico [25]. En lugar de asumir que una base de conocimiento (formada por un conjunto de fórmulas) es cierta o no bajo una determinada interpretación, se asocia un valor de probabilidad a los dominios (o ‘mundos’) que no satisfacen todas las fórmulas. Para calcular este valor, se asocia a cada fórmula un peso que denota cómo es de relevante para la satisfacción de la base de conocimiento. Este peso tiene un impacto directo en la asignación de probabilidades a los mundos: si un mundo satisface una fórmula con un peso alto, será más probable que otro que no.

Formalmente, una MLN  $L$  junto a un conjunto finito de constantes  $C$  define una red o campo aleatorio de Markov  $M_{L,C}$  que modela la distribución de probabilidad asociada a los posibles mundos. Esta red  $M_{L,C}$  se construye creando un nodo por cada átomo sin variables libres, un arco entre dos nodos por cada ocurrencia de los átomos en la misma fórmula de  $L$  y una función característica  $f_i$  por cada posible instanciación de  $F_i$  que toma valor 1 si la fórmula es cierta y 0 si es falsa. A partir de esta transformación, se opera con la red lógica como se haría con una red de Markov habitual.

Un ejemplo notable de aplicación de MLNs en fusión de información y reconocimiento de situaciones puede encontrarse en [30]. En este trabajo se utilizan las MLNs como formalismo para la representación de eventos afectados por imprecisión relevantes para la vigilancia marítima. Las MLNs permiten construir eventos complejos a partir de evidencias más simples, de forma que es posible consultar la probabilidad de una fórmula arbitraria, incluso si sólo se disponen de observaciones parciales. El principal problema es que es necesario asignar pesos iniciales a las fórmulas de la MLN, aunque los autores afirman que este proceso podría automatizarse mediante técnicas de aprendizaje automático. Entre las principales ventajas de este formalismo, destaca la facilidad con la que puede introducirse conocimiento previo y contextual en el sistema, de forma similar a como ocurre con las ontologías probabilísticas y difusas descritas anteriormente, y la capacidad para razonador incluso en situaciones en las que se dispone de pocos datos o estos son poco fiables.

## 4 EXTENSIONES AL PROCESO DE FUSIÓN

Una alternativa a los modelos extendidos anteriores consiste en utilizar un formalismo simbólico para el conocimiento sobre los objetos, como por ejemplo ontologías clásicas, y después delegar las tareas de fusión de alto nivel a una etapa de procesamiento posterior, en lugar de insertar directamente la representación de imprecisión e incertidumbre en el propio modelo. De esta forma, el

razonamiento típicamente deductivo que se realiza con los formalismos basados en lógica se complementa con una capa de razonamiento abductivo, que se ocupa de construir un conjunto de hipótesis que explican los datos y de seleccionar aquella que es más probable [15].

Uno de los paradigmas que ha sido utilizado para razonamiento abductivo es la teoría de argumentación basada en creencias (*Belief-based Argumentation System*, BAS), una generalización de la argumentación probabilística (*Probabilistic Argumentation System*, PAS) [14]. El PAS combina la lógica con la teoría de probabilidades para construir hipótesis sobre un dominio basadas en el conocimiento incierto, poco fiable, incompleto y/o contradictorio disponible. Esencialmente, cada hipótesis tiene asociados varios argumentos a favor o en contra, y cada argumento es una combinación de postulados con una probabilidad calculada a priori. De esa forma, el grado de veracidad de la hipótesis se obtiene combinando las probabilidades de los argumentos.

En fusión de información no es habitual disponer de una distribución definida para la probabilidad a priori  $P(A)$  de un supuesto  $A$ , por lo que se suelen reemplazar por creencias subjetivas (*beliefs*) del tipo  $Bel(A)$ . Asimismo, normalmente se utilizan medidas sub-aditivas, de forma que la expresión  $P(A) = 1 - P(\neg A)$  tiene la forma  $Bel(A) + Bel(\neg A) \leq 1$ . Por otra parte, por la propia naturaleza de los problemas es difícil plantear un conjunto de hipótesis exhaustivo. En consecuencia, se suele admitir que la creencia en hipótesis vacía  $Bel(\emptyset)$  —esto es, ninguna de las hipótesis predefinidas— puede ser distinta de cero. Por estos motivos, en el BAS se recurre al TBM (*transferable belief model*) [29], una teoría basada en la teoría de Dempster-Shafer (DS), como formalismo para el cálculo con valores de incertidumbre. EL TBM propone usar la regla de agregación DS no normalizada para obtener la creencia en una hipótesis mediante combinación de los valores de creencia en los argumentos a favor y en contra de la misma. La creencia en cada uno de los argumentos se calcula a partir de las creencias en los supuestos asociados al argumento, que son una función de los valores obtenidos por los sensores. Se puede encontrar una descripción completa del BAS en [26].

En [13] se describe un ejemplo de esta aproximación para un problema de control de tráfico y vigilancia marítima en un puerto. En este trabajo se propone una arquitectura en dos capas para un sistema de fusión de alto nivel que se basa en conocimiento sobre el contexto para detectar anomalías en el tráfico marítimo y evaluar si estas suponen un riesgo para la seguridad. La capa inferior utiliza una ontología para representar de manera formal las entradas procedentes de los radares y otros sensores. Mediante razonamiento deductivo, en esta capa se clasifican los objetos y se detectan las situaciones que no se ajustan al modelo de normalidad del puerto, basado en las normativas de navegación aplicables. La capa superior aplica el BAS para calcular el nivel de amenaza que supone la

aparición de comportamientos anómalos, discerniéndolos de aquellos que se deben a imprecisiones y errores en las observaciones.

La implementación llevada a cabo<sup>3</sup> considera únicamente dos hipótesis (amenaza, no amenaza) y propone varios argumentos a favor y en contra, cada uno con varios supuestos asociados. Así por ejemplo, un argumento a favor de la hipótesis amenaza relacionado con la velocidad de un barco se representa como la conjunción de tres supuestos: (1) el barco está dentro del área de navegación  $X$ ; (2) la velocidad del barco es mayor que  $Y$ ; (3) la velocidad máxima en  $X$  es  $Y$ . La creencia en los supuestos (1) y (2) es una función de la distancia del barco a los límites del área  $X$  y de la diferencia de la velocidad del barco respecto a la velocidad máxima  $Y$ , respectivamente. Los resultados muestran que así se reduce el número de falsas alarmas respecto a las aproximaciones basadas solamente en ontologías, al tiempo que se facilita la incorporación de conocimiento sobre el contexto del problema.

## 5 EVALUACIÓN

Evaluar cuantitativamente las ventajas de las aproximaciones basadas en extensiones probabilísticas y difusas de los modelos de representación respecto a las basadas en añadir una etapa más al proceso de fusión resulta complicado. Las propuestas existentes suelen ocuparse de problemas en dominios diferentes entre los que no es posible realizar una comparación. Por otra parte, la mayor parte de las implementaciones desarrolladas no se encuentran disponibles públicamente. En general, se puede afirmar que la segunda aproximación añade flexibilidad al sistema y reduce el coste computacional que conlleva el razonamiento ontológico extendido con imprecisión e incertidumbre. Sin embargo, la introducción de una capa más de procesamiento elimina en parte la ventaja de utilizar un único formalismo para la creación del modelo simbólico de la escena y requiere cálculos adicionales que también introducen sobrecarga computacional, en especial si se utiliza la regla de combinación de Dempster-Shafer directamente como en el caso presentado.

Por este motivo, en los últimos dos años se han producido varios avances destinados a la construcción de un marco común para la evaluación de sistemas de fusión de alto nivel que trabajan con imprecisión e incertidumbre. En 2011 se formó el grupo de trabajo ETUR-WG (*Evaluation of Techniques for Uncertainty Representation Working Group*), auspiciado por la Sociedad Internacional de Fusión de Información (ISIF), para tratar este problema. ETUR-WG ha desarrollado una meta-ontología denominada URREF (*Uncertainty Representation and Reasoning Evaluation Framework*) que describe varios conceptos básicos de estos sistemas y diversos criterios de compara-

ción, la mayor parte de ellos de tipo cualitativo [10]. Este trabajo se encuentra aún en un estado inicial, pero se espera que sirva como base para futuras evaluaciones más estandarizadas.

## 6 CONCLUSIONES Y TRABAJO FUTURO

En este trabajo hemos revisado varias aproximaciones para la gestión de información imprecisa e incierta en fusión de alto nivel. En general, no resulta fácil decidir qué aproximación es más apropiada en cada problema, aunque existen algunas propuestas para unificar los criterios de evaluación. En la mayor parte de las ocasiones, esta elección dependerá de los sistemas previos y la experiencia acumulada. De cualquier modo, es necesario continuar investigando en estas líneas, de manera que se pueda disponer de un catálogo de soluciones como ocurre en muchos problemas de fusión de bajo nivel. Un aspecto fundamental que se debe someter a estudio es la complejidad computacional de las propuestas. Los problemas de fusión suelen requerir procesamiento en tiempo real y los modelos simbólicos presentados en este artículo añaden un procesamiento adicional significativo.

### Agradecimientos

Este trabajo ha sido financiado por la Junta de Andalucía (P11-TIC-7460), la Comunidad de Madrid (S2009/TIC-1485) y el Ministerio de Economía y Competitividad de España (TEC2012-37832-C02-01, TEC2011-28626-C02-02, TIN2012-30939).

### Referencias

- [1] F. Baader, I. Horrocks, U. Sattler: Description Logics. En: *Handbook of Knowledge Representation*, Elsevier, 2008.
- [2] F. Bobillo, M. Delgado, J. Gómez-Romero, U. Straccia: Joining Gödel and Zadeh Fuzzy Logics in Fuzzy Description Logics. *International Journal of Uncertainty, Fuzziness and Knowledge-based Systems* 20 (4), pp. 475-508, 2012.
- [3] F. Bobillo, M. Delgado, J. Gómez-Romero: DeLorean: A Reasoner for Fuzzy OWL 2. *Expert Systems with Applications* 39 (1), pp. 258-272, 2012.
- [4] F. Bobillo, U. Straccia: fuzzyDL: An Expressive Fuzzy Description Logic Reasoner. En: *Proc. of the 17th IEEE Int. Conf. on Fuzzy Systems (FUZZ-IEEE 2008)*, pp. 923-930, Hong Kong (China), 2008.
- [5] F. Bobillo, U. Straccia: Fuzzy Description Logics with General T-norms and Datatypes. *Fuzzy Sets and Systems* 160 (23), pp. 3382-3402, 2009.

<sup>3</sup><http://www.giaa.inf.uc3m.es/miembros/jgomez/simulator/HarborSimulator.html>

- [6] F. Bobillo, U. Straccia: Fuzzy ontology representation using OWL 2. *International Journal of Approximate Reasoning* 52 (7), pp. 1073-1094, 2011.
- [7] F. Bobillo, U. Straccia: Aggregation Operators for Fuzzy Ontologies. *Applied Soft Computing* 13 (9), pp. 3816-3830, 2013.
- [8] R.N. Carvalho, R. Haberlin, P.C.G. Costa, K.B. Laskey, K.C. Chang: Modeling a probabilistic ontology for maritime domain awareness. En: *Proc. of the 14<sup>th</sup> Int. Conf. on Information Fusion*, Chicago (USA), 2011.
- [9] R.N. Carvalho, K.B. Laskey, P.C.G. Costa: PR-OWL 2.0 – Bridging the gap to OWL semantics. En: *Uncertainty Reasoning for the Semantic Web II*, Springer, pp. 1-18, 2013.
- [10] P.C.G. Costa, K.B. Laskey, E. Blasch, A.-L. Jusselme: Towards unbiased evaluation of uncertainty reasoning: the URREF ontology. En: *Proc. of the 15<sup>th</sup> Int. Conf. on Information Fusion*, Singapore, pp. 2301-2308, 2012.
- [11] D. Dubois, H. Prade: Possibility theory, probability theory and multiple-valued logics: a clarification. *Annals of Mathematics and Artificial Intelligence* 32 (1-4), pp. 35–66, 2001.
- [12] D. Dubois. Uncertainty theories: A unified view. En: *Summer course on Soft Computing and Statistics*, Lisboa (Portugal), 2009.
- [13] J. García, J. Gómez-Romero, M.A. Patricio, J.M. Molina, G. Rogova: On the representation and exploitation of context knowledge in a harbor surveillance scenario. En: *Proc. of the 14<sup>th</sup> Int. Conf. on Information Fusion*, Chicago (USA), 2011.
- [14] R. Haenni, J. Kohlas, N. Lehmann: Probabilistic Argumentation Systems. En: *Handbook of Defeasible Reasoning and Uncertainty Management Systems* Vol. 5. Kluwer, 2001.
- [15] J. Josephson: On the logical form of abduction. En: *AAAI Spring Symposium Series: Automated Abduction*, pp. 140-144, Stanford (USA), 1990.
- [16] P. Klinov, B. Parsia: Pronto: a probabilistic Description Logic reasoner. En: *Uncertainty Reasoning for the Semantic Web II*, Springer, pp. 59-79, 2013.
- [17] G.J. Klir, B. Yuan: *Fuzzy Sets and Fuzzy Logic: Theory and Applications*. Addison Wesley, 1995.
- [18] M. Kokar, C. Matheus, K. Baclawski: Ontology-based situation awareness. *Information Fusion* 10, pp. 83-98, 2009.
- [19] E.G. Little, G. Rogova: Designing ontologies for higher level fusion. *Information Fusion* 10, pp. 70-82, 2009.
- [20] J. Llinas, D.L. Hall: Multisensor data fusion. En: *Handbook of multisensor data fusion*. CRC Press, pp. 1-14, 2009.
- [21] T. Lukasiewicz, U. Straccia: Managing uncertainty and vagueness in Description Logics for the Semantic Web. *Journal of Web Semantics* 6 (4), pp. 291-308, 2008.
- [22] A. Motro, P. Smets: *Uncertainty management in information systems. From Needs to Solutions*. Springer, 1997.
- [23] J. Pearl: *Probabilistic reasoning in intelligent systems: networks of plausible inference*. Morgan Kaufmann, 1988.
- [24] A. Pinz, H. Bischof, W. Kropatsch, G. Schweighofer, Y. Haxhimusa, A. Opelt, A. Ion: Representations for cognitive vision. *Electronic Letters on Computer Vision and Image Analysis* 7 (2), pp. 35–61, 2008.
- [25] M. Richardson, P. Domingos: Markov logic networks. *Machine Learning* 62, pp. 107-136, 2006.
- [26] G. Rogova, P. Scott, C. Lollett, R. Mudiyanur: Reasoning about situations in the early post-disaster response environment. En: *Proc. of the 9<sup>th</sup> Int. Conf. on Information Fusion*, Florencia (Italia), 2006.
- [27] G. Shafer: *The Mathematical Theory of Evidence*. Princeton University Press, 1976.
- [28] F.K.J. Sheridan: A survey of techniques for inference under uncertainty. *Artificial Intelligence Review* 5 (1-2), pp. 89–119, 1991.
- [29] P. Smets, R. Kennes: The transferable belief model. *Artificial Intelligence* 66, pp. 191-243, 1994.
- [30] L. Snidaro, I. Visentini, K. Bryan: Fusing uncertain knowledge and evidence for maritime situational awareness via Markov Logic Networks. *Information Fusion* (En Prensa), 2013.
- [31] A.N. Steinberg, C.L. Bowman: Revisions to the JDL data fusion model. En: *Handbook of Multisensor Data Fusion*, CRC Press, pp. 45–68, 2009.
- [32] A.N. Steinberg, G. Rogova: Situation and context in data fusion and natural language understanding. En: *Proc. of the 11<sup>th</sup> Int. Conf. on Information Fusion*, Colonia (Alemania), 2008.
- [33] W3C OWL Working Group: *OWL 2 Web Ontology Language Document Overview*, 2009. Online: <http://www.w3.org/TR/owl2-overview/>. Acceso: octubre 2013.
- [34] L.A. Zadeh. Fuzzy sets: *Information and Control* 8 (3), pp. 338–353, 1965.