3. Fusión de datos

3.1 Definición

La fusión de datos (DF: Data fusión) de múltiples fuentes es un compendio de técnicas multidisciplinares, análogas al proceso cognitivo que realizamos los humanos, para integrar los datos de múltiples sensores (sentidos) con el fin de realizar inferencias sobre el mundo exterior, convergiendo en un conjunto de resultados (reacción).

Así la fusión de datos pretende obtener un resultado de mejor calidad, a partir de múltiples sensores, eventualmente heterogéneos, realizando inferencias que pueden no ser posibles a partir de uno solo. Teniendo múltiples aplicaciones tanto en el mundo militar, reconstitución de imágenes, diagnosis médica y en la última década en el mundo del transporte (Klein 2001; Hall y McMullen 2004).

3.2 Niveles de fusión

La Junta de Directores de Laboratorios (JDL: Joint Directors of Laboratories) concibe la fusión como un proceso integral de tratamiento de datos (Hall y McMullen 2004), subdividido en niveles que van desde la captura de los datos hasta el resultado final, incluyendo la interacción de dichos resultados con el receptor y/u operador.

3.2.1 Nivel 0: Pre-proceso de las fuentes

Los datos de las fuentes son habitualmente pre-procesados para una fusión posterior, filtrando datos o alineándolos temporalmente u otras acciones previas.

Este proceso lo lleva a cabo, por lo general, el software asociado a cada uno de los sensores comerciales de forma independiente del resto de sensores. Se puede considerar así una pre-fusión.

Es a este nivel donde cada uno de los sensores aporta sus datos obtenidos de forma independiente del resto.

3.2.2 Nivel 1: Evaluación del objeto

Combinación de los datos de los sensores para obtener posición, velocidad, atributos y características de la entidad**.**

Siendo la entidad, en transporte, por ejemplo un vehiculo, un incidente de trafico o la congestión.

Los algoritmos de este nivel son:

1. Alineación de datos: Ajustes espacio-tiempo y de unidades para posibilitar un procesamiento posterior
2. Correlación Dato/Objeto: Asociación y correlación de datos para cada individuo. Para permitir la correcta agrupación de los datos
3. Estimación de posición, cinemática y otros atributos del objeto: Mediante la combinación de modelos físicos y supuestos estadísticos para la obtención del Vector de Estado.

4. Estimación de la identidad del objeto: Obtención de la entidad mediante métodos paramétricos (Bayes, Dempster-Shafer), no paramétricos (redes neuronales) o de lógica difusa.

3.2.3 Nivel 2: Evaluación de la situación

Interpretación de los resultados del nivel anterior, en nuestro caso si se determina en el paso anterior que las velocidades son bajas podemos interpretar que estamos en un estado de congestión.

Las técnicas más adecuadas para este nivel son la Inteligencia artificial (IA) y el razonamiento automático.

Los algoritmos de este nivel son:

1. Agregación de objetos: Agregar los datos de cada una de las identidades para una visión global de la situación.
2. Interpretación contextual: Tener en cuenta los factores externos al estudio que pueden afectar de forma indirecta (En nuestro caso principalmente los factores climatológicos)
3. Evaluación multiperspectiva: Observación global del problema, desde el exterior e interior.

3.2.4 Nivel 3: Evaluación del futuro

Proyección de futuro de la entidad analizada a partir de la situación actual. Los modelos utilizados para este nivel son la inteligencia artificial, los modelos predictivos, el razonamiento automático y la estimación estadística.

Los algoritmos de este nivel son:

1. Estimación/Agregación de capacidad de fuerza: Agregación de la información de diversos subsistemas para determinar sus interrelaciones y la robustez del sistema.
2. Estimación de implicaciones: Resultados de una hipotética acción sobre el sistema
3. Evaluación multiperspectiva: Análoga al del nivel 2, observación del sistema desde el exterior e interior.

3.2.5 Nivel 4: Proceso refinamiento

Metaproceso que monitoriza todo el proceso de DF para mejorar el rendimiento del proceso en tiempo real, mediante la optimización de la utilización de recursos, la modelización sensorial y la computación de medidas de perfeccionamiento.

Este nivel se considera parcialmente dentro-fuera del proceso de fusión, ya que este refinamiento es necesario para el correcto funcionamiento de la fusión y de las operaciones a la que este destinada la DF.

Los algoritmos de este nivel son:

1. Gestión de la misión: Dirección de los recursos existentes con el fin de obtener los resultados deseados.
2. Predicción de Entidad: Definir que entidades especificas debe reconocer el proceso

3. Requerimientos de las fuentes: Definir la infraestructura necesaria de las fuentes para que puedan identificar las entidades
4. Modelización del rendimiento del sistema: Definir la estructura del sistema de fusión de datos, la relación entre fuentes, los componentes de procesamiento, etc.
5. Control del sistema: Tal como control de multiobjetivos y optimización.

3.2.6 Nivel 5: Refinamiento cognitivo

Mejora del sistema de fusión a partir de la relación Sensor-Procesamiento-Persona. Proyectando modelos en los que la representación de los resultados (ya sean intermedios o finales) permitan al operador identificar posibles errores en el procesamiento, y que este previamente haya podido detectar errores en los datos suministrados por los sensores.

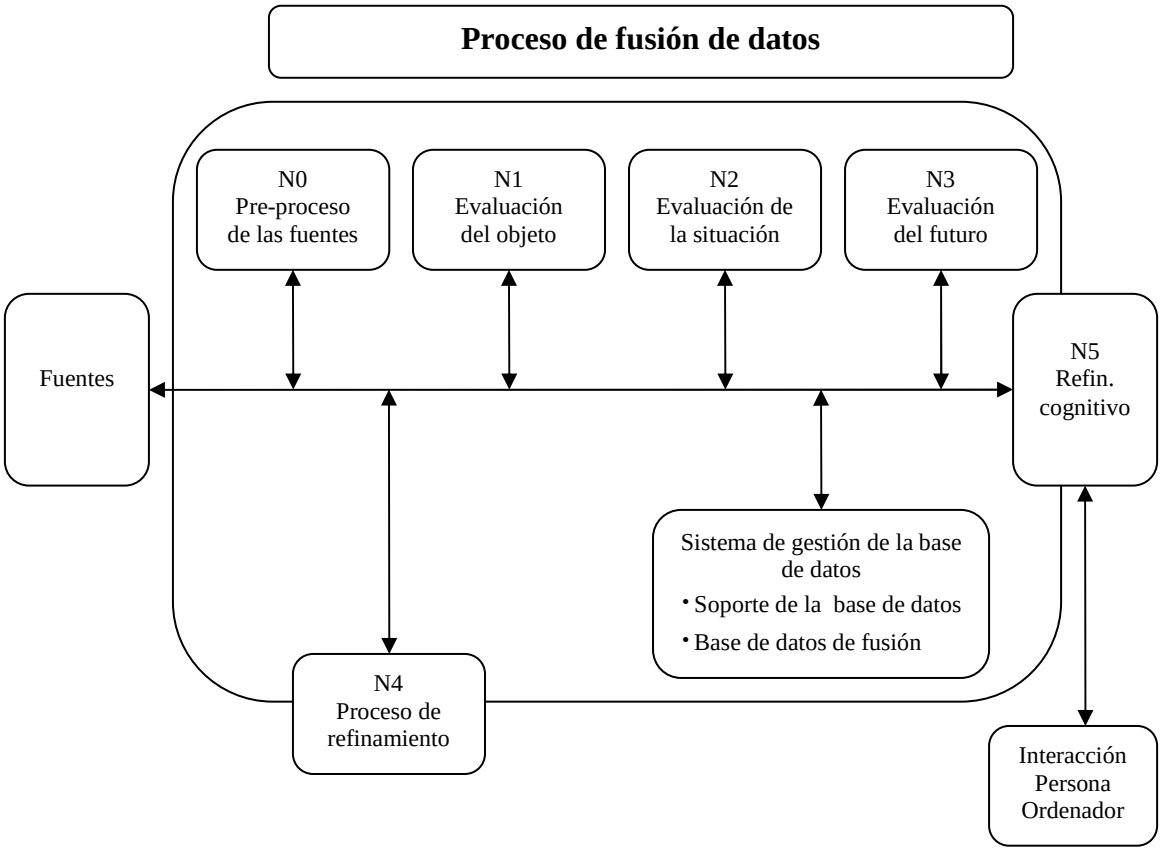

Figura 2: El proceso de fusión de datos. Fuente: Hall y McMullen 2004

Sin considerar que tienen la entidad de los niveles antes mencionados hay que tener en cuenta también:

3.2.7 La gestión de la base de datos

Es un punto clave dada la gran cantidad de datos que se manejan durante el proceso. Para desarrollar esta función será necesario un considerable esfuerzo computacional,

destacando que el software comercial habitual es incapaz de gestionar el problema completo de fusión

3.2.8 Interacción de la persona con el ordenador

Este elemento, considerado externo a la fusión, es importante en el proceso de fusión. Ya que una correcta interfaz del sistema, será clave para el refinamiento cognitivo.

3.3 Técnicas de fusión de datos

En este apartado se procederá a clasificar las diferentes técnicas de fusión de datos y posteriormente a describir con mayor precisión las más utilizadas para así poder elegir de forma más sencilla el operador que mejores características presente para la solución del problema.

Para efectuar todo este proceso se deben definir algunos conceptos base para la correcta comprensión por parte del lector de lo aquí expuesto.

1. x_i: Representan el grado de de credibilidad de la información emitida por la fuente i.
2. I : Intervalo de los valores de x_i.
3. $F(x_i,...,x_n)$: Operador de combinación de la información

3.3.1 Clasificación según su comportamiento

Para no hacer esta clasificación excesivamente complicada vamos a suponer que estamos fusionando dos informaciones (La generalización al caso de más datos es, en general, sencilla), siendo así $x_i = (x, y)$, y por lo general, excepto algún caso muy específico, $I = [0,1]$. Además por la propiedad de semejanza entre el operador y el entorno matemático donde opera, $F(x, y) = [0,1]$.

Tal como plantea Bloch (1996) realizaremos la clasificación en función de su comportamiento, en primer grado según su dependencia del contexto y en segundo término según su constancia a la hora de ser severas, prudentes o indulgentes. Entendiendo bajo estos tres términos lo siguiente:

1. **Severo**: Se aceptará que un operador tiene un comportamiento severo si se comporta de forma **conjuntiva**, es decir:

   $$F(x, y) \leq \min(x, y) \qquad [1]$$

   Así estos operadores representan un consenso entre las partes de información, o sus partes comunes o redundantes. Reduciendo la información más incierta y dando mayor fiabilidad al sensor más restrictivo. Busca así satisfacer simultáneamente los criterios u objetivos de la fusión.

2. **Prudente**: El operador será prudente si se comporta de forma **comprometida**, es decir:

   $$\min(x, y) \leq F(x, y) \leq \max(x, y) \qquad [2]$$

   Los operadores que pertenecen a este grupo proveen una información global, intermedia entre los diferentes valores de los sensores. La redundancia entre

diferentes elementos puede ser tomada en cuenta con algunos tipos de operadores como las Integrales difusas.

3. **Indulgente**: Será indulgente el operador si se comporta de forma **disjunta**, es decir:

$$F(x, y) \geq \max(x, y) \qquad [3]$$

Estos operadores incrementan la certeza que tenemos sobre una información, dando mayor peso específico al sensor que da la información menos incierta. Expresa así, redundancia entre los criterios.

3.3.1.1 Operador Independiente del Contexto con Comportamiento Constante

(Operador ICCC)

La primera clase esta compuesta por los operadores que tienen igual comportamiento, independientemente del valor de la información a fusionar, y que computa dichos datos sin información respecto al exterior o el contexto. Así respetan siempre una y solo una de las siguientes cualidades:

$$\forall(x, y) \in I^2, F(x, y) \leq \min(x, y)$$
$$\forall(x, y) \in I^2, \min(x, y) \leq F(x, y) \leq \max(x, y)$$
$$\forall(x, y) \in I^2, F(x, y) \geq \max(x, y)$$

Las técnicas más conocidas que se comportan de este modo son Bayes, Dempster-Shafer y algunas clases de Lógica difusa.

3.3.1.2 Operador Independiente del Contexto con Comportamiento Variable

(Operador ICCV)

Esta segunda clase, comprende a los operadores que siendo independientes del contexto no lo son del valor de x e y. Así se pueden comportar de forma severa para ciertos valores de credibilidad, mientras lo hace de forma indulgente para otros. Es decir, F respetara más de una de las cualidades presentadas en ICCC.

Las técnicas más conocidas que operan así son algunos tipos de Lógica difusa y de Inteligencia artificial, como los Sistemas expertos (por ejemplo los tipo MYCIN).

3.3.1.3 Operador Dependiente del Contexto

(Operador DC)

La tercera clase incluye los operadores que son dependientes del contexto, es decir no solo dependen de x e y sino también del conocimiento global o características de las fuentes de datos (por ejemplo: conflicto entre fuentes, credibilidad de las fuentes).

Estos operadores son especialmente interesantes para problemas de clasificación, ya que permiten combinar información relacionada con una clase de una forma, e información relacionada con otra clase de forma diferente.

Técnicas conocidas, que se comporten según lo detallado, son algunos tipos de Conjuntos difusos y de Inteligencia artificial, como los Híbridas.

3.3.2 Clasificación según la lógica matemática

D.L. Hall y S.A.H McMullen (2004) clasifican las técnicas de fusión según la lógica matemática utilizada para incorporar la incertidumbre. Este parámetro es la diferencia clave entre las técnicas de Bayes, Dempster-Shafer y Conjuntos difusos. Mientras en la Inteligencia artificial el principal factor diferenciador es la forma de aprendizaje.

Dicha incertidumbre puede ser atribuida a las observaciones o bien a las conclusiones llegadas. Las formas más importantes de incorporarla son la:

3.3.2.1 Probabilística

Es el modelo de lógica matemática más difundido y también el que cuenta con una base teórica más potente, basada en la teoría clásica de la probabilidad. Pero la determinación de las funciones de distribución de probabilidades y de las probabilidades condicionales, a través de métodos empíricos o estocásticos, imponen hipótesis muy restrictivas, poco creíbles en problemas complejos.

Por otro lado esa potencia de la base teórica permite tener poca complejidad computacional.

Las Leyes clásicas de probabilidad y Bayes son las técnicas de fusión con base probabilística.

3.3.2.2 Evidencial

La lógica evidencial define (a diferencia de la probabilidad) probabilidades no aditivas como noción general para la suposición lógica y la probabilidad. La idea es aumentar la lógica proposicional standard considerando un operador que representa el estado de conocimiento que un agente racional tiene del mundo. Las probabilidades son así definidas sobre el universo de operadores de todas las sentencias, y está argumentado que esta es la mejor información disponible para el analista.

Dempster-Shafer y la Teoría evidencial generalizada son las técnicas de fusión con base evidencial.

3.3.2.2 Difusa

La lógica difusa nace en un artículo de L.A. Zadeh publicado en 1965, titulado “Fuzzy Sets”. Aparece como respuesta a la lógica clásica bivalente, permitiendo representar de forma matemática conceptos o conjunto imprecisos. Incluyéndose así en la lógica multivaluada, admitiendo varios valores como verdades posibles.

Los Conjuntos difusos y algunos operadores Híbridos de Inteligencia artificial son las técnicas de fusión con esta base lógica.

3.3.3 Descripción de las técnicas más utilizadas

En este apartado describiremos algunas de las técnicas más utilizadas en la fusión de datos, centrándonos especialmente en las de lógica probabilística, evidencial y difusa. Limitándonos a hacer una introducción a la Inteligencia artificial, por su diversidad de técnicas y complejidad.

3.3.3.1 Bayes

Esta técnica de inferencia, que utiliza la lógica probabilística, está basada en la regla de Bayes, y pertenece así a los algoritmos que usan conocimientos a priori (razonamiento

causa efecto) sobre el espacio de observación para realizar inferencias sobre la identidad de los objetos. La inferencia bayesiana provee un método para calcular la veracidad de la probabilidad condicional o a posteriori (razonamiento efecto causa) de una hipótesis dada (Klein 2001).

Si E es el evento a evaluar, y x_1 y x_2 los elementos de información dados por dos sensores, a partir del Teorema de Bayes obtenemos (Bloch 96):

$$\begin{aligned} p(E \mid x_1, x_2) &= p(E)\frac{p(x_2 \mid E, x_1)p(E \mid x_1)}{p(x_2 \mid x_1)} \\ &= \frac{p(x_2 \mid E, x_1)p(x_1 \mid E)p^2(E)}{p(x_2 \mid x_1)p(x_1)} \\ &= \frac{p(x_2 \mid E, x_1)p(x_1 \mid E)p^2(E)}{p(x_2 \mid x_1)p(x_1)} \\ &= p(x_2 \mid E, x_1)p(x_1 \mid E)\frac{p^2(E)}{p(x_1, x_2)} \end{aligned} \qquad [4]$$

Esta ecuación relativamente compleja, se puede simplificar suponiendo que nuestras fuentes y sus datos son independientes entre ellos. Quedando así:

$$p(E \mid x_1, x_2) = \frac{p(x_2 \mid E)p(x_1 \mid E)p^2(E)}{p(x_1)p(x_2)} \qquad [5]$$

Si deseamos generalizarlo para un número n de elementos de información, obtenemos:

$$p(E \mid x_1, \ldots, x_n) = \frac{p(x_n \mid E, x_1, \ldots, x_{n-1}) \cdots p(x_1 \mid E)p^n(E)}{p(x_1, \ldots, x_n)} \qquad [6]$$

Si esta expresión no depende del orden en que se reciben los elementos de información, podemos simplificar la ecuación [6], ya que dada la complejidad de entrenamiento de las diferentes fuentes resulta conveniente:

$$p(E \mid x_1, \ldots, x_n) = p^2(E)\frac{\prod_{i=1}^{n} p(x_i \mid E)}{\prod_{i=1}^{n} p(x_i)} \qquad [7]$$

Si definimos $\Omega = \{E_1, \ldots, E_r\}$como el conjunto de eventos a evaluar (El Faouzi 2005) podemos tomar la decisión final según los siguientes criterios:

1. Regla de máxima probabilidad a posteriori: El estado más probable es aquel con la mayor probabilidad a posteriori.

$$E_k = \arg\max_{1 \le i \le r} \{p(E_i \mid x_1, \ldots, x_n)\} \qquad [8]$$

2. Regla de máxima probabilidad: El estado más probable es aquel con la mayor función de probabilidad.

$$E_k = \arg\max_{1\le i\le r}\left\{\prod_{j=1}^{n} p(x_j \mid E_i)\right\} \qquad [9]$$

Se trata así de una técnica severa donde el operador es independiente del contexto y del valor de las variables.

La principal ventaja de la técnica de Bayes para la fusión de datos es que posee un formalismo bien desarrollado, donde la evidencia es tratada como una función de probabilidad. Así usando esta técnica, se pueden expresar conocimientos a priori de forma estocástica para obtener el estado más probable del sistema.

Desde el punto de vista de la aplicación, se necesita una fuerte estimación de las funciones de probabilidad ($p(x_j \mid E_i)$), y de las de las de probabilidad a priori ($p(E_i)$) que modelan el conocimiento aportado por cada una de las fuentes, incluso en caso de total ignorancia. La práctica común es definir $p(E_i)$ como uniforme ($p(E_i) = 1/r$), hecho que no aporta mayor conocimiento, y estimar $p(x_j \mid E_i)$ en función de la credibilidad que tenga cada una de las medidas tomada por los diferentes sensores, usando para ello métodos estadísticos de aprendizaje

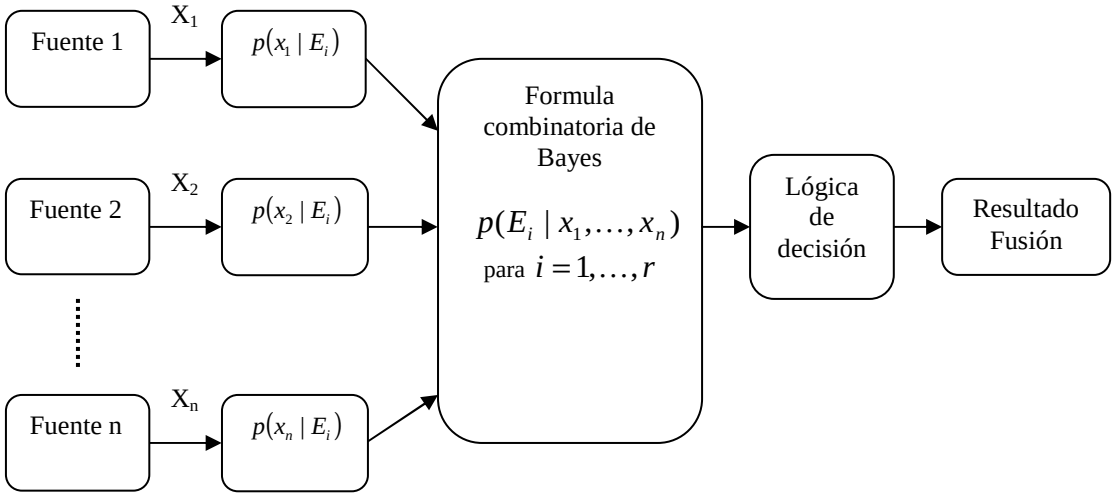

Figura 3: Proceso de fusión con la técnica de Bayes. Fuente: Klein 2001.

.

3.3.3.2 Dempster-Shafer

La inferencia Dempster-Shafer, algoritmo de fusión de datos basado en la lógica evidencial, se utiliza cuando a la suma de informaciones aportada por las fuentes de datos no se les puede asociar el 100% de la probabilidad de certeza. El algoritmo captura y combina la certeza o conocimiento existente usando la regla de Dempster, que encuentra la intersección o conjunción de los eventos identificados por las fuentes de información y sus probabilidades asociadas (Klein 2001).

La información del sensor i está representada por la función de masa (o credibilidad) $m_i \in [0,1]$ que asigna valores a cada uno de los subconjuntos del conjunto de

discernimiento D (conjunto de eventos considerados), ignorando como se dividen estos valores de masa dentro del subconjunto. Además a partir de los valores de masa del conjunto se pueden derivar otras funciones, como la plausibilidad, la credibilidad, la comunalidad o la duda (Bloch 1996).

La combinación se realiza mediante la suma ortogonal de Dempster, que para n fuentes resulta:

$$m(A) = \oplus_{i=1}^{n} m_i(A) = \begin{cases} 0 \text{ si } A = \varnothing \\ \dfrac{1}{1-k} \displaystyle\sum_{B_1 \cap B_2 \cap \ldots \cap B_n = A} m_1(B_1) m_2(B_2) \cdots m_n(B_n) \text{ si } A \neq \varnothing \\ 1 \text{ si } A = D \end{cases} \qquad [10]$$

donde $A, B_1, \ldots, B_n$ son subconjuntos de D y k, que se puede interpretar como la medida de conflicto entre fuentes, resulta:

$$k = \sum m_1(B_1) m_2(B_2) \cdots m_n(B_n) \qquad [11]$$

Altos valores de k representan un grado de conflicto alto entre las fuentes, dando también una indicación de la exhaustividad del conjunto de discernimiento D. Así debe tenerse en cuenta a la hora de evaluar la calidad de la combinación, ya que cuando el valor sea muy alto, la combinación normalizada (Siendo $1-k$ el factor de normalización) tomará decisiones cuestionables que no podrán apoyar conclusiones aceptables (El Faouzi 2005).

Podemos definir además la credibilidad, la plausibilidad y la comunalidad como:

$$Com_i(A) = \sum_{A \subset B} m_i(B) \qquad [12]$$

donde

$$Com(A) = \oplus_{i=1}^{n} Com_i(A) = \frac{1}{1-k} \; Com_1(A) Com_2(A) \cdots Com_n(A) \qquad [13]$$

y

$$Cre(A) = \sum_{B \subset A} m(B) \qquad [14]$$

$$Pl(A) = \sum_{B \cap A = \varnothing} m(B) = 1 - Cre(\overline{A}) \qquad [15]$$

Se puede considerar que $Cre(A)$ y $Pl(A)$ son respectivamente, los límites inferiores y superiores del intervalo de credibilidad $[Cre(A), Pl(A)]$, donde $Cre(A) - Pl(A)$ es la expresión natural de la ignorancia concerniente a A.

Se puede observar que las funciones de masa son muy similares a las de probabilidad, ya que se asigna una evidencia a uno o más subconjuntos del conjunto de proposiciones. Pero con esta técnica se puede asignar evidencia al conjunto de discernimiento D. Es decir la función de masa puede representar explícitamente ambigüedad o ignorancia sobre la observación mediante:

$$Cre(A) + Cre(\overline{A}) + Cre(D) = 1 \qquad [16]$$

mientras que en Bayes no existe esta opción, resultando:

$$p(A) + p(\overline{A}) = 1 \qquad [17]$$

Así podemos considerar que Bayes es un caso particular de la teoría evidencial donde $Cre(D) = 0$.

Si definimos $D = \{E_1, \ldots, E_r\}$ como el conjunto de estados a evaluar podemos tomar la decisión final según los siguientes criterios (El Faouzi 2005):

1. Regla de máxima credibilidad: El estado más probable es aquel con mayor credibilidad

$$E_k = \arg\max_{1 \le i \le r} \{Cre(E_i)\} \qquad [18]$$

2. Regla de máxima plausibilidad: El estado más probable es aquel con mayor plausibilidad

$$E_k = \arg\max_{1 \le i \le r} \{Pl(E_i)\} = \arg\min_{1 \le i \le r} \{Cre(E_i)\} \qquad [19]$$

Se trata así de una técnica severa donde el operador es independiente del contexto y del valor de las variables

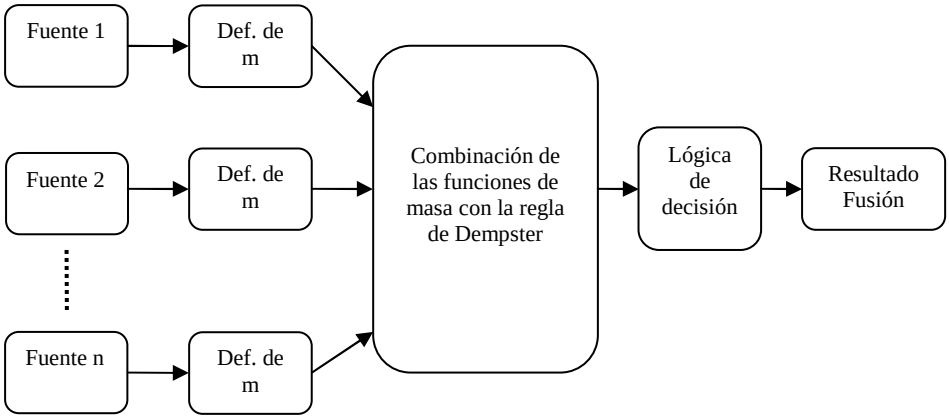

Figura 4: Proceso de fusión con la técnica de Dempster-Shafer. Fuente: Klein 2001.

.

3.3.3.3 Conjuntos difusos

La lógica difusa es efectiva cuando los procesos son difíciles de modelar con paradigmas matemáticos clásicos que requieren límites bien definidos. Por tanto es beneficiosa cuando los límites entre conjuntos de valores no están claramente definidos o existe ocurrencia parcial de un evento. Así en la teoría de Conjuntos difusos formar parte de un conjunto es función del grado Klein 2001.

Estableciendo normas y conjuntos difusos, la lógica difusa crea una base de control que permite a los gestores construir un sistema de control incluso cuando no se ha entendido completamente el comportamiento matemático del proceso. Permitiendo así incorporar la indefinición (o vaguedad) en el proceso de decisión.

Es así una técnica muy útil si existen:

1. Deficiencias en los modelo matemáticos o falta de capacidad para analizar todos los datos
2. Sensores de poca calidad o poco representativos
3. Sistema experto, o un experto, para calibrar el sistema

Mediante su comportamiento podemos clasificar (Bloch 1996) los diferentes operadores que utilizan está técnica en:

1. **Operadores ICC**

   Las tres familias de operadores que se comportan según estos parámetros son: las normas triangulares (T-norma), las conormas triangulares (T-conorma) y los operadores medios.

   Un ejemplo de T-norma es $\min(x, y)$. Así si definimos i como T-norma, que tiene un comportamiento severo:

   $$\forall(x, y) \in I^2, i(x, y) \leq \min(x, y) \qquad [20]$$

   Un ejemplo de T-conorma es $\max(x, y)$. Así si definimos u como T-conorma, que tiene un comportamiento indulgente:

   $$\forall(x, y) \in I^2, u(x, y) \geq \max(x, y) \qquad [21]$$

   Un ejemplo de operador medio es la media aritmética. Así si definimos m como operador medio, que tiene un comportamiento prudente:

   $$\forall(x, y) \in I^2, \min(x, y \leq) m(x, y) \leq \max(x, y) \qquad [22]$$

2. **Operadores ICV**

   El operador que se comporta siguiendo estos parámetros es la Suma ortogonal, tal que:

   $$\sigma(x, y) = \frac{g(x, y)}{g(x, y) + g(1 - x, 1 - y)} \qquad [23]$$

   donde g es creciente, positiva, continua y $g(0,0) = 0$, que supone que σ tenga las mismas características.

   Su comportamiento dependerá, como corresponde a este grupo, de los valores de las variables.

3. **Operadores DC**

   En esta sección se incluyen los operadores que se comportan en función del conflicto entre las fuentes y la fiabilidad de las mismas. Permiten así tener en cuenta que las fuentes aporten informaciones contrapuestas, que haya fuentes más creíbles que otras, y que esta fiabilidad dependa también del evento evaluado por esa fuente, ya que dichas fuentes no podrán evaluar todos los eventos con la misma precisión.

Los operadores dependientes del conflicto se comportaran según la consonancia de las fuentes. Así si son consonantes tienen un comportamiento severo; indulgente cuando son disonantes y prudente en caso de conflicto parcial.

Los operadores dependientes de la fiabilidad de las fuentes permitirán asignar valores numéricos a nuestros conocimientos sobre cada una de las fuentes.

Clasificación según el comportamiento del operador	Técnica de fusión	Lógica matemática	Operador matemático específico	Comportamiento del operador específico
(Operador ICCC)	**Bayes**	Probabilística	Producto de probabilidades	Severo
	Conjuntos difusos	Difusa	T-noma T-conorma Medio	Severo Indulgente Prudente
	Dempster-Shafer	Evidencial	Suma ortogonal	Severo
(Operador ICCV)	**Conjuntos difusos**	Difusa	Suma simétrica	Los tres comportamientos son posibles según los valores a combinar
	Sistemas expertos		Combinación de factores de certeza	Severo (si x, y > 0) Prudente (en resto de casos) Indulgente (si x ,y < 0)
(Operador DC)	**Conjuntos difusos**	Difusa	Operador dependiente del conflicto	Severo si las fuentes son consonantes Prudente si el conflicto es parcial Indulgente si las fuentes son disonantes
	Conjuntos difusos	Difusa	Operador dependiente de la fiabilidad de la fuente	

Tabla 5: Clasificación de los operadores según su comportamiento. Fuente: Bloch 1996.

3.3.3.4 Inteligencia artificial

Se denomina Inteligencia artificial (IA) a la ciencia que desarrolla técnicas para que las máquinas puedan imitar las formas de comprensión, razonamiento y aprendizaje humano.

Para alcanzar este propósito existen dos vías. La denominada IA convencional, que se caracterizan por el formalismo y su base estadística, donde se incluyen:

1. Sistemas expertos: Sistemas diseñados para actuar como un experto humano en un dominio particular o área de conocimiento. En este sentido, pueden considerarse como intermediarios entre el experto humano, que transmite su conocimiento al sistema, y el usuario que lo utiliza para resolver un problema con la eficacia del experto. El Sistema Experto utilizará para ello el conocimiento que tenga almacenado y algunos métodos de inferencia. Simultáneamente, el usuario puede aprender observando el comportamiento del sistema, es decir, los sistemas expertos se pueden considerar al mismo tiempo como un medio de ejecución y transmisión del conocimiento (monografías.com 2007)
2. Red bayesiana: Modelo basado en la ya analizada técnica de Bayes

La otra vía es la IA computacional, que implica el aprendizaje iterativo basándose en datos empíricos, donde se incluyen:

1. Redes neuronales: Son un paradigma de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso de los animales. Se trata de un sistema de interconexión de neuronas en una red que colabora para producir un estímulo de salida
2. Sistemas difusos: Modelo basado en la ya analizada técnica de Conjuntos difusos.

También existen los modelos Híbridos que fusionan varias técnicas de IA, aprovechando las características más apropiadas de cada una de ellas para una mejor solución del problema.

3.4 Utilidad de la fusión de datos de múltiples fuentes

La fusión de datos de múltiples fuentes aparece como respuesta a la posibilidad de aumentar el número de sensores, y así mejorar el resultado de problemas complejos, como la restitución de imágenes, la diagnosis medica, la detección de la congestión de carreteras, de incidentes en carretera o del tiempo de viaje.

Uno de los principales objetivos de la fusión de datos es combinar la información obtenida a través de las diferentes fuentes para tomar una mejor decisión, realizando para ello una reducción de la imprecisión e incertidumbre e incrementando la robustez (Bloch 1996).

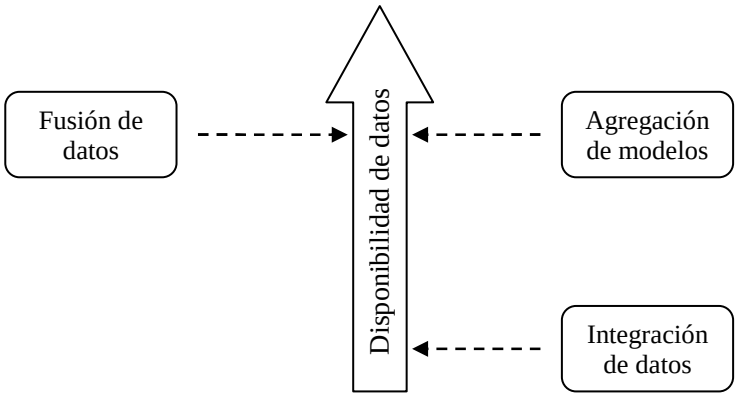

Figura 5: La fusión de datos como vía alternativa. Fuente: El Faouzi 2005

Así como muestra El Faouzi (2005), la fusión es una vía alternativa a la agregación de modelos, que sigue la senda abierta por la integración de datos. La primera, como muestran Hall y McMullen (2004), es más robusta que la segunda, ya que en la agregación los modelos compiten entre ellos con fuentes propias, mientras que en la fusión las fuentes se complementan y son redundantes. Por otra parte la integración de datos utiliza una única fuente principal, usando otra como apoyo o validación.

3.4.1 Ventajas y limitaciones

A la hora de implementar un sistema de fusión de datos, debemos tener en cuenta cuales son los puntos fuertes del proceso así como sus limitaciones ya que, como se mostraba en el Nivel 4, una correcta planificación de la DF nos permitirá optimizar su rendimiento.

Por ejemplo, los resultados de Nahum y Pokoski (1980) muestran de forma cualitativa como la fusión de datos de múltiples fuentes aumenta la posibilidad de clasificar correctamente los datos, frente a un número menor de fuentes. También nos permite observar que:

1. La combinación de datos de fuentes poco fiables (P_N<0,5) no aporta ninguna mejora. Así la primera premisa para la fusión será que los datos tengan una fiabilidad aceptable.
2. La combinación de datos de fuentes muy precisas (P_N>0,95) no aporta ninguna mejora significativa. Así si nuestros sensores son muy precisos no tiene sentido invertir tal esfuerzo.
3. El aumento del número de sensores mejora la precisión del sistema si bien, esta mejora se vuelve casi imperceptible a partir del octavo a décimo sensor. Hay que tener en cuenta que esta perdida de interés en un mayor número de sensores no será real, si el nuevo sensor aporta datos no redundantes.

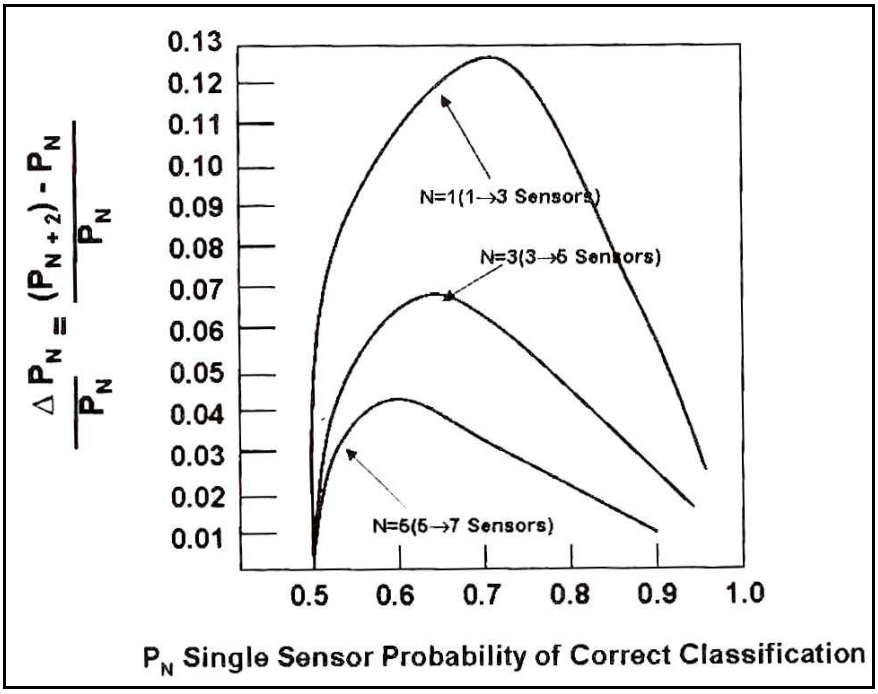

Figura 6: Relación del número de fuentes con el rendimiento del sistema. Fuente: Nahum y Pokoski

Así las ventajas de la fusión de datos de múltiples fuentes son:

1. Robustez operacional: Ya que un sensor puede aportar información cuando los otros no están operativos o solo parcialmente operativos.
2. Cobertura espacial extendida: La correcta fusión de los datos de los sensores distribuidos por el espacio dan una mejor resolución que uno solo de ellos.
3. Cobertura temporal extendida: Un sensor puede obtener información cuando otros no o de forma más continua.
4. Aumento fiabilidad: Un buen proceso de fusión puede confirmar la veracidad de una información, dada la inherente redundancia de los datos de las fuentes.
5. Reducción ambigüedad: La fusión de la información de múltiples sensores permite reducir el numero de hipótesis a realizar
6. Mejora de detección: Una correcta fusión facilita la detección de un suceso, gracias a la redundancia de los datos.

Y sus limitaciones:

1. Calidad y número de sensores: Como hemos visto anteriormente, la calidad del sensor y su número determinará de forma importante la calidad del resultado final de la DF.

2. Imposibilidad de corregir errores de base: El proceso de DF no puede corregir errores en el pre-procesamiento de los datos. Es decir no hay corrección aguas arriba de la inferencia, si bien el Nivel 4 procederá a un refinamiento de los resultados, pero ya a partir del nivel 1.

3. La calidad de la información sobre los sensores: Si la información que tenemos sobre los sensores (su rendimiento, datos que pueden aportar) es pobre o incorrecta, también lo serán los resultados de la DF.

4. Inexistencia del algoritmo de DF ideal: Cada algoritmo tiene sus fortalezas y debilidades debiendo el gestor elegir el más apropiado para el fin deseado.

5. Falta de datos de entrenamiento: Nunca habrá suficientes datos para entrenar al sistema, es decir los recursos son limitados.

6. Dificultad de cuantificación del rendimiento: No existen parámetros claros y globales para determinar si un sistema de DF es mejor que otro. Queda así en manos del gestor una correcta valoración

7. Dinamismo del proceso: Es imposible analizar el proceso como algo estático, siendo así difícil de valorar su rendimiento de forma generalizada, ya que dependerá de su grado de aprendizaje y de los datos disponibles en ese momento.

Ventajas	Limitaciones
1. Robustez operacional 2. Cobertura espacial extendida 3. Cobertura temporal extendida 4. Aumento fiabilidad 5. Reducción ambigüedad 6. Mejora de detección	1. Calidad y numero de sensores 2. Imposibilidad de corregir errores de base 3. La calidad de la información sobre los sensores 4. Inexistencia del algoritmo de DF ideal 5. Falta de datos de entrenamiento 6. Dificultad de cuantificación del rendimiento 7. Dinamismo del proceso

Tabla 6: Resumen de Ventajas y limitaciones

También hay que considerar el esfuerzo de cálculo y memoria que supone la gestión de un sistema de múltiples fuentes de datos y su consiguiente fusión. Si bien, según Hall y McMullen (2004), la mayor parte del esfuerzo se emplea en la gestión de los datos.

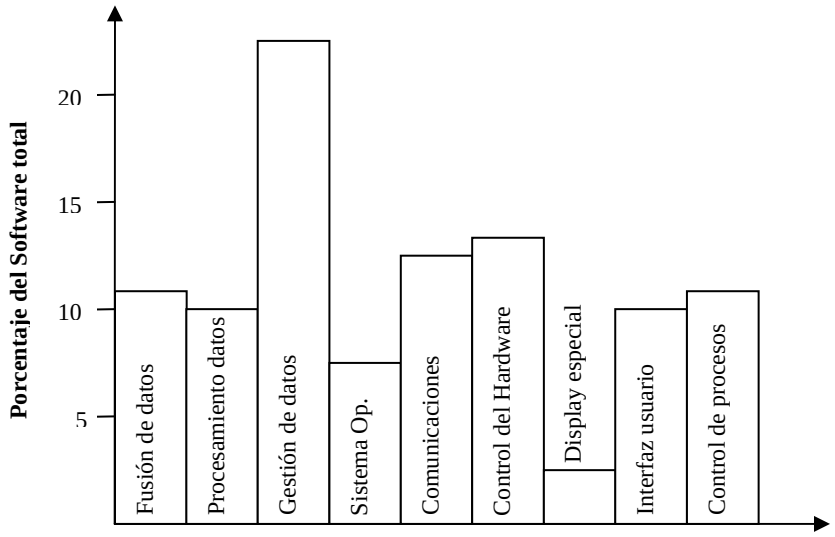

Figura 7: Perfil del software requerido para un sistema de fusión de datos. Fuente: Hall y McMulen

3.5 Aplicación de la fusión de datos a la ingeniería del transporte

La fusión de datos aparece a finales de los años 80 del siglo anterior con fines claramente militares, como se puede apreciar en la bibliografía. El Departamento estadounidense de Defensa apoya así este nuevo compendio de técnicas con el fin de obtener beneficios en el campo militar y en el aerospacial, para mejorar la fiabilidad y precisión de las operaciones de la agencia espacial NASA.

Posteriormente, en el campo civil, los estamentos (universidad, empresa, estados) relacionados con la robótica, la climatología y el procesamiento de imágenes han mostrado mucho interés en la fusión de datos, provocando un rápido desarrollo de este nueva ciencia.

Por otra parte con la aparición de los Sistemas Inteligentes de Transporte (ITS) y los Sistemas Avanzados de Información al Viajero (ATIS) ha nacido, a principio de los 90, el interés de la ingeniería del transporte por dichas técnicas. Así los ITS han permitido diversificar las fuentes para la obtención de datos sobre el estado de la red viaria con costes aceptables, haciendo posible la fusión de datos de múltiples fuentes. Y los ATIS y la gran expansión de los sistemas de navegación GPS entre los usuarios, han hecho que tal esfuerzo tenga un gran efecto positivo en la información disponible, no solo por parte de los gestores sino también de los usuarios.

La fusión de datos en el campo de la ingeniería del transporte ha sido implementada con el fin de obtener:

1. Mayor fiabilidad de los resultados
2. Mayor robustez del sistema
3. Mayor cobertura espacial y/o temporal
4. Mayor precisión de los resultados
5. Menores costes de operación

Siendo, en todos los casos conocidos, alcanzados dichos objetivos en mayor o menor medida, siempre mejorando las técnicas habituales utilizadas con anterioridad.

Los primeros autores que se interesan por la fusión de datos aplicada al cálculo del tiempo de viaje, lo hacen en los años 90.

Desde EE.UU. Palacharla y Nelson (1999) estudian la aplicación de la lógica difusa a la estimación del cálculo de viaje, valorando que sistema híbrido resulta más interesante, si el de los conjuntos difusos sobre una red neural o el de los mismos conjuntos en un sistema experto. Obtienen como resultado que el primer sistema híbrido es más preciso incrementando ambos la calidad del resultado obtenido con técnicas habituales.

Por esta vía de los sistemas híbridos tipo lógica difusa - red neural continúan los estudios del Ministerio austriaco de Tráfico, Innovación y Tecnología (bm vit) que en 2006 presenta un proyecto, ya en proceso de pruebas, de obtención de tiempos de viaje y de la saturación de la red viaria a partir de múltiples fuentes (espiras inductivas, láser, coches flotantes (sensores ubicados en los taxis)). La técnica utilizada en este caso es conocida como ANFIS (Redes Neurales Adaptables con Inferencia Difusa) y los resultados obtenidos presentan una mejora del 50% en el número de errores detectados.

También con un sistema basado en ANFIS obtiene Sazi Murat (2006) tiempos de espera en intersecciones señalizadas obteniendo resultados mejores que el HCM (Highway Capacity Manual principalmente en situaciones de sobresaturación.

Por otra parte Weizhong Zheng, Lee y Shi, investigadores de Singapur y China, han realizado predicciones de flujos de tráfico mediante inferencia bayesiana sobre estructura neural a partir de una única fuente, obteniendo resultados superiores que redes neurales simples en el 85% de los casos.

Desde Francia se ha apostado por sistema de fusión de datos más sencillos desde el punto de vista conceptual. Así El Faouzi y sus colaboradores (2000 y 2005) han optado por la inferencia evidencial de Dempster-Shafer que consideran una generalización de la teoría de Bayes. Obteniendo con el primer método resultados superiores al de Bayes y al de técnicas habituales en una vía de Toulouse, a partir de lectura de matrículas y de espiras inductivas.

Aparte, los operadores de autopistas franceses AREA, ASF. ESCOTA y SAPN están ya utilizando o estudiando sistemas de fusión de datos para el cálculo de tiempos de viaje en sus vías (AREA 2006; Guiol y Schwab 2006; Ferré).

Suecia y Escocia a través de sus direcciones generales de tráfico SRA (Sweden Road Administration) y Transport Scottland están estudiando detalladamente, desde 2001, la implantación de la fusión de datos para la obtención de tiempos de viaje. Escocia utiliza en sus pruebas (en la A1 en los alrededores de Edimburgo) hasta 4 fuentes (telefonía móvil, espiras inductivas, coche flotante y lectura de matrículas) donde destacan por su fiabilidad la telefonía móvil y la lectura de matrículas (Peterson 2006; Scott 2006).

En Alemania dgg, empresa perteneciente al grupo T-Systems, ha desarrollado un software capaz de inferir difusamente sobre las variables del tráfico para la obtención del estado de congestión, utilizando además dominios de definición dinámicos. Ahora están estudiando evolucionar dicho software para obtener las demoras debidas a la congestión, utilizando para ello información proporcionada por las espiras inductivas y coches flotantes.

Por su parte, en Holanda, van Lint, Hoogendoorn y van Zuylen (2005) utilizan redes neurales para la predicción de tiempos de viaje con datos faltantes, obteniendo resultados satisfactorios a pesar de la falta de datos.

Park y Lee (2004), ambos coreanos, han obtenido tiempos de viaje en ambiente urbano mediante la implementación de redes neurales e inferencia bayesiana, ambos de forma independiente, a partir de espiras inductivas y coche flotante. Considerando en ambos casos prometedores los resultados.