

Definición y estudio de un método de consensuado con asignación de pesos dinámico

Josep M^a López Orriols (jmlopez@eia.udg.es)
Josep Lluís de la Rosa i Esteva (pepluis@eia.udg.es)

*Agents Research Lab
Dept. IiA*

Universitat de Girona
Avda. Lluís Santaló S/N
17071 Girona (Spain)

Resumen. En este artículo se procede a la definición y estudio de comportamiento con un método de agregación con asignación de pesos dinámico. Este método se basa en la media ponderada clásica pero en este caso la asignación de pesos será dinámica, según el caso a consensuar. Se define el sistema y se incluyen los resultados de comportamiento dependiendo de los parámetros involucrados.

Palabras Clave: Operadores de Agregación, Fusión de datos, WM, OWA, WOWA, Determinación de Parámetros, Razonamiento Basado en Casos (CBR), Confianza (Trust).

1 Introducción

Los operadores de agregación se usan ampliamente para la fusión de datos en diferentes campos. En inteligencia artificial, éstos se utilizan para la agregación de información proporcionada por diferentes fuentes de información. Algunos de los más empleados (y generalmente suelen ser a la vez los más intuitivos) sistemas de agregación son los de Media Aritmética (Arithmetic Mean o AM), Media Ponderada (Weighted Mean o WM), la Media Ponderada Ordenada (Ordered Weighted Average, OWA) definida por Yager en ([39],[37]), i la Media Ponderada Ordenada Ponderada (Weighted Ordered Weighted Average, WOWA), definida por Torra en ([31],[35]). Todos estos operadores utilizan el concepto de proporcionar un peso asociado a cada fuente de información que indicará su relevancia en el proceso de agregación: cuando más alto sea el peso asignado a la fuente de información, más importancia se le dará en el proceso de agregación. En un sistema OWA, las fuentes de datos son, además, ordenadas, empleando un criterio previo. Finalmente el sistema WOWA es una combinación de los sistemas WM i OWA.

No obstante, a partir de estas definiciones observamos que el grado de eficiencia de la agregación vendrá dada por la asignación de pesos en cada agregación. Por lo tanto la asignación de pesos será el factor que determinará el nivel de eficacia de la agregación. Para este fin existen métodos que tienen por finalidad conseguir la asignación de pesos más eficiente. Alguno de estos casos se pueden hallar en Torra en ([30],[33]), Nettleton y Torra ([27]) y Yager y Filev en ([39]). Pero en estos casos, los parámetros asignados a cada fuente se ajustan para satisfacer la eficiencia en la agregación para un conjunto de ejemplos y, así, estos parámetros serán eficaces para este conjunto de parámetros. De hecho con estos métodos mencionados, si el sistema de fuentes de información variar su fiabilidad (o credibilidad), también deberían variar los pesos asignados a cada fuente, y por lo tanto se debería obtener un nuevo conjunto de datos y recalcular los pesos óptimos.

En este artículo presentamos un sistema de agregación basado en la media ponderada pero con asignación de pesos dinámica: entendemos con este término que dado un nuevo caso de agregación, el sistema recalculará los pesos más adecuados según las experiencias previas con el sistema global, mejorando su asignación a cada fuente de información y ser así más adaptable. Además, el sistema revisará constantemente la eficacia del sistema y adaptará sus criterios de asignación según la variación de la fiabilidad debido a los aciertos de las diferentes fuentes de información.

En la sección 2 presentamos brevemente el concepto de nuestro sistema. En la sección 3 definimos el sistema detallando el algoritmo involucrado y sus fundamentos matemáticos. En la sección 4 presentamos los resultados del sistema según los resultados obtenidos al aplicar nuestro sistema a un entorno de simulación. Finalmente,

presentamos las conclusiones y la propuesta de trabajo futuro.

2 Fundamentos de nuestro método

En primer lugar, se procede a describir los métodos basados en pesos. El método más simple es el de Promediado Ponderado (Weighted Average Method ó WM) ([34]). En este caso, la agregación se basa en la asignación de pesos a cada fuente de información según la relevancia que se le pretende dar en la agregación. Matemáticamente se expresará como sigue:

$$WM_v(x_1, x_2, \dots, x_n) = \sum_i v_i x_i \quad (1)$$

En donde

$$v = [v_1, v_2, \dots, v_n]$$

$$v_i \in [0, 1]$$

$$\sum_i v_i = 1$$

Y cada v_i tiene el significado implícito de “la importancia asignada a la fuente a ser agregada”. Con fiabilidades más altas le estoy asignando una relevancia más importante a la fuente de información dentro del proceso de agregación.

Otros métodos presentan ciertas variaciones, tales como en ([39],[37]), en donde Yager presenta el método de promediado ponderado ordenado (Ordered Weighting Average ó OWA). En este método se procede a una ordenación de las fuentes de información según criterios preestablecidos para posteriormente proceder a la agregación. Finalmente Tota presenta en ([31],[35]) un método combinación de los dos anteriores, y que se ha denominado WOWA. Podemos considerar, sin embargo, que WM es el método básico mediante el cual se pueden asignar pesos asociados a cada fuente de información.

Para la asignación de estos pesos, existen métodos basados en conjuntos de experiencias previas que se utilizaran para el cálculo de los pesos más adecuados para que se minimice el error en un conjunto de datos dados ([30],[33]). Pero nos hallamos con que el sistema puede variar la fiabilidad de estas fuentes de información, y por tanto es necesario un recalcu de los pesos más adecuados. También podemos intuir que en cada caso a ser agregado la asignación de pesos no ha de ser forzosamente la misma. Siguiendo esta reflexión, observamos que podríamos mejorar la eficacia de nuestro método de agregación si asignamos los pesos según la consulta que efectuamos. Este hecho significa el uso de los pesos más adecuados basándonos en el tipo de consulta a ser agregado. Obviamente, si disponemos de

información sobre el caso a ser agregado podemos efectuar una mejor asignación de pesos.

Un ejemplo simple: preguntemos a tres doctores sobre la probabilidad de que un paciente padezca hepatitis. Después de un examen médico, los doctores concluyen que el paciente sufrirá hepatitis con las siguientes probabilidades:

Doctor Número	Hepatitis probabilidad
1	90%
2	50%
3	20%

Tabla 1

No obstante, podemos saber que el doctor número 1 es de especialidad cardiólogo, y se ha equivocado en diagnósticos de hepatitis anteriores. También sabemos que el doctor número 2 habitualmente realiza buenos diagnósticos pero actualmente, debido a situaciones personales, su eficacia ha mermado considerablemente. Finalmente, el tercer doctor prácticamente siempre realiza buenos diagnósticos de hepatitis, y por tanto será en este caso el más fiable. Estos hechos nos harán variar los pesos asignados a los diferentes doctores. Desafortunadamente, la cantidad de información que necesitamos para poder asignar estos pesos es intratable para un sistema automatizado, y por tanto no es práctico en un sistema real. Pero quizás podríamos hallar algún sistema que nos permita hallar cierta correlación de información con un costo de computación relativamente bajo. Cómo?.

Siguiendo con el ejemplo anterior, podemos observar, basado con experiencias previas con los tres doctores, que cuando el doctor número 1 efectúa un diagnóstico sobre una determinada enfermedad con una probabilidad baja, generalmente suele equivocarse. En este caso estamos extrayendo información “oculta” de una sola fuente de información basada en experiencias previas, por lo tanto este hecho repercutirá en la asignación de pesos y se reducirá el peso del doctor número 1. También podemos haber “detectado” que cuando el doctor número 3 diagnostica una enfermedad determinada con baja probabilidad y el doctor 2 diagnostica también con probabilidad baja, generalmente el doctor número 3 suele tener una fiabilidad baja. Este hecho puede darse, por ejemplo, por los síntomas característicos que puede presentar el paciente y que puede dar lugar a estas situaciones. Con todo esto, la nueva asignación de pesos varía a:

Doctor número	Probabilidad Hepatitis	Pesos Previos	Pesos Modificados
1	90%	0.1	0.4
2	20%	0.2	0.5
3	20%	0.7	0.1

Tabla 2

En las siguientes secciones describimos un sistema que permite esta asignación de pesos de forma dinámica y demostramos empíricamente que de forma global la fiabilidad de la decisión mejora a través del aprendizaje.

3 Descripción del Método

A continuación presentamos brevemente el algoritmo del sistema. Este se basará en los fundamentos del Razonamiento Basado en Casos (Case Based Reasoning concepts ([21],[2]) CBR). Esta técnica se basa en el uso de casos previos memorizados que presenten similitud con los actuales para poder ser empleados como solucionadores de los casos actuales por similitud. Un sistema CBR requiere el cumplimiento de 4 puntos fundamentales: Retrieve, Reuse, Revise i Retain. Observamos que nuestro sistema los cumplirá:

- **RETRIEVE:** recuperará de la memoria los casos semejantes al actual.
- **REUSE:** reutilizará el caso previo como base para la solución al caso actual.
- **REVISE:** revisará si una vez empleado, los resultados han sido satisfactorios o no y si es necesario revisar el caso almacenado.
- **RETAIN:** finalmente se almacenará el nuevo caso obtenido para posteriores consultas.

Observaremos que nuestro sistema cumple dicho ciclo.

3.1 Definición de nuestra Base de Casos.

Será una base de casos simple. De hecho, será el conjunto formado por las fuentes de información que se presentan al sistema y que daremos en mención como “base del caso”, asociados con los pesos asignados a cada fuente en el caso dado, y que le daremos el nombre de “vector de fiabilidades”. Esta fiabilidad del caso NO será el peso de un sistema promediado ponderado (lo cual significaría que obligatoriamente $\sum_i v_i = 1$), sino que la fiabilidad se indicará mediante un parámetro $f \in [0,1]$ para cada fuente, en donde 0 indica fiabilidad baja o nula de la fuente, mientras que 1 indicará fiabilidad total en el conjunto de las fuentes de información.

La base de casos será una matriz en donde, para ‘n’ entradas i ‘m’ casos, su dimensión será (2 x ‘n’) x ‘m’. Gráficamente:




Fig. 1. Matriz de Base de Casos

Mediante la base de casos definida, seguiremos los siguientes pasos en nuestro algoritmo:

1. Punto inicial en el que NO disponemos aún de casos. Pero no podremos iniciar nuestro sistema en el vacío, ya que debemos poder aplicar pesos aún que no dispongamos de suficiente información (experiencia). Inicialmente necesitamos calcular una serie de “pesos base” a aplicar incluso cuando no disponemos de casos. Estos pesos pueden ser calculados a partir de pocos casos, mediante los métodos clásicos de minimización de errores, algoritmos genéticos, etc..., o bien por simple estimación de pesos.
2. Introduciremos la información a ser agregada al sistema.
3. Procedemos a recuperar de la memoria un caso similar previo. La similitud se medirá por medio de la distancia cuadrática entre nuestro vector a ser agregado y las bases de los casos. Extraeremos así, el caso que tiene la distancia mínima entre todos los casos y que es inferior al límite de activación que se ha definido empíricamente.
4. En caso de hallar dicho caso, extraemos el vector de fiabilidades asociado, hallamos su vector normalizado y procedemos a hallar el vector de pesos de agregación mediante la combinación lineal convexa con los pesos base del sistema. Así, si la distancia es cero o próxima a cero, el vector empleado será el vector de fiabilidades del caso registrado, mientras que a medida que nos acercamos al valor de distancia límite de disparo, el vector se acercará más a los pesos base.
5. Si no podemos hallar un caso, emplearemos los pesos base.
6. Procederemos a la agregación.
7. Registraremos la efectividad de los pesos aplicados y los modificamos adecuadamente.

La fiabilidad de cada fuente de información se obtendrá mediante la diferencia con el valor agregado correcto conocido. Por ejemplo, si la fuente 'i' ofrece el valor x_i y la respuesta correcta conocida es t_i , definiremos su fiabilidad como $r_i = |t_i - x_i|$.

3.2. Fiabilidad – Conversión de pesos.

Tal como hemos definido en nuestra base de casos, cada elemento se asocia con su propio valor de fiabilidad dentro del propio caso. Por definición, este parámetro de fiabilidad es un valor $0 < f_i < 1$ que no necesariamente deberá cumplir, $\sum f_i = 1$. Para poder emplear este vector para una agregación, deberá de ser convertido convenientemente para que cumpla las propiedades típicas de un vector de agregación. Para ello necesitaremos convertir f_i (fiabilidad de la fuente) a w_i (vector de agregación). Para ello, definiremos el mínimo valor del vector (w_m) al que convertiremos el mínimo valor de la fiabilidad (r_m). Posteriormente se convertirá linealmente, tal como es describe a continuación:

$$w_i = a \cdot f_i + b \quad (2)$$

Estableciendo las siguientes condiciones:

$$\begin{cases} m = a \cdot f_m + b \\ 1 = \sum_{i=1}^n (a \cdot f_i + b) = a \cdot \sum_{i=1}^n f_i + n \cdot b \end{cases} \quad (3)$$

A continuación hallamos los valores de a i b :

$$a = \frac{m - \frac{1}{n}}{f_m - \left(\frac{\sum_{i=1}^n f_i}{n} \right)} = \frac{m - \frac{1}{n}}{f_m - \mu_f} \quad (4)$$

$$b = m - f_m \cdot a$$

En donde:

$$\mu_f = \frac{\sum_{i=1}^n f_i}{n} \quad (5)$$

Concretamente, podemos ver que el caso más simple será cuando $w_m = 0$ y $f_m = 0$. En este caso, las

ecuaciones se simplifican a: $a = \frac{1}{\sum_i f_i}$ i $b = 0$

y así: $w_i = \frac{f_i}{\sum_i f_i}$

Deseamos que la ecuación siempre sea monótona creciente. Este hecho es equivalente a que $a > 0$. Se

cumplirá cuando: $\begin{cases} f_m > \mu_f \\ w_m > \frac{1}{n} \end{cases}$ o $\begin{cases} f_m < \mu_f \\ w_m < \frac{1}{n} \end{cases}$ (en

este caso, si f_m es el mínimo valor del vector de fiabilidad, siempre se cumplirá que $f_m < w_m$).

Aquí $a = \frac{m - \frac{1}{n}}{f_m - \frac{\sum_i f_i}{n}}$ i cuando

$f_m = \frac{\sum_i f_i}{n} = \mu_f$ se producirá una indeterminación.

Si $w_m = \frac{1}{n}$, entonces $a = 0$ i $\forall (w_i \in W)(w_i = w_m)$.

4 Proceso de simulación y resultados

Nuestro sistema se ha testado en un entorno de simulación complejo donde se pueden simular una gran variedad de situaciones. En este entorno, a cada proceso de simulación se genera un número determinado de agentes que "opinarán". Así actuarán como fuente de información a ser agregada proporcionando un grado de probabilidad como respuesta a una pregunta planteada a todo el sistema. Por ejemplo: en el caso anterior del apartado 2, los médicos pueden ser interpretados como agentes y la pregunta planteada sería el paciente al ser mostrado a todos ellos para que den su valoración de la probabilidad de que el paciente sufra hepatitis.

En nuestro entorno se presenta a todo el sistema un número determinado de cuestiones a ser evaluadas por medio de la agregación (ciclo de agregación). A cada ciclo presentado al sistema, este aprenderá, dado que disponemos de la respuesta correcta o bien información sobre si la

respuesta obtenida finalmente es inferior o superior a esta. Mediante este proceso el sistema puede ajustar su base de casos.

4.1 Diferentes métodos de agregación

Dado que el sistema presentará un vector de agregación diferente según el caso a ser agregado, este hecho ofrece la posibilidad de abrir nuevos métodos de agregación menos rígidos que los tradicionales de asignación de pesos estáticos.

4.1.1. Dos métodos de toma de decisión: Clásico i Best

- *Método de agregación Clásico:* en este caso la agregación se computa empleando el método clásico. Cada fuente de información tiene asignado su propio peso y la agregación se obtendrá por medio del método tradicional de WM.
- *Método Best:* En este caso cada fuente de información dispone de su propio peso, pero la decisión final de la agregación consistirá en la selección de la fuente que tiene el peso más alto, o sea, el más fiable.

4.1.2 Diferentes métodos de aprendizaje: Normal i Cualitativo

- *Aprendizaje Normal:* En este caso necesitaremos conocer el valor agregado correcto. Este valor es proporcionado al sistema para proceder al aprendizaje.
- *Aprendizaje Cualitativo:* No conocemos el valor correcto final, sino que sabemos que el valor correcto es superior o inferior al obtenido. Esta tendencia es la que se utilizará para el aprendizaje del sistema.

5 Resultados de la Simulación i comportamiento

A continuación procedemos al estudio de la evolución de los resultados obtenidos para nuestro sistema. Las diferentes simulaciones se han realizado sobre un sistema de 10 agentes con características asignadas aleatoriamente al inicio de cada simulación.

5.1 Respuesta de un sistema con Aprendizaje Clásico

A continuación se muestra una respuesta típica de un sistema con un proceso de consensado tipo Normal:




Fig. 2. Respuesta típica Método Clásico.

Número de reglas generadas: 103. Observamos como gradualmente el sistema mejora su respuesta de agregación, aunque el incremento total de valor no es muy elevado (recordemos que cada valor de error es el resultado del promediado del error de 100 agregaciones sobre preguntas “aleatorias”). Observamos algunos cambios abruptos en el proceso de aprendizaje (ciclo 23). Este hecho es debido a la inclusión de reglas de gran significación en promedio global del testado de las 100 reglas.

5.2 Respuesta con agregación Best

Evolución de respuesta típica de tipo Best:




Fig. 3. Respuesta típica método Best.

Número de reglas generadas: 102. Como observamos, la respuesta es mejor que en el caso de agregación Normal: este hecho es debido a que seleccionamos en cada caso de decisión la fuente de información más fiable.

5.3 Respuesta de aprendizajes Normal i Cualitativo

En los casos anteriores se conoce los valores correctos previamente y se proporciona al sistema

de agregación. Pero también es posible el aprendizaje si no disponemos de tales valores correctos y solamente disponemos de una orientación, esto es, si sabemos que el valor correcto es superior o inferior al obtenido por la agregación. Observamos como la respuesta en es más suave y lenta, debido al ajuste gradual, ya que el aprendizaje es en este caso por “tanteo” sobre los diferentes parámetros de la fiabilidad.

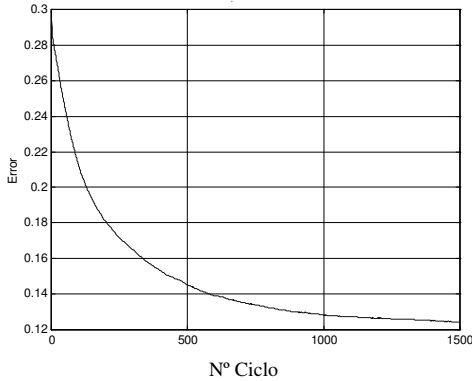


Fig. 4. Respuesta típica aprendizaje Cualitativo con agregación Clásico.

Nombre de reglas generadas = 109.

5.4 Respuesta de agregación Best i con aprendizaje Cualitativo

La respuesta obtenida al unir el método de agregación Best con un método de aprendizaje Cualitativo es la siguiente:

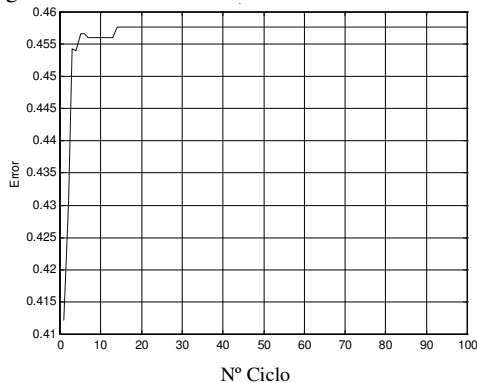


Fig. 5. Respuesta agregación Best y aprendizaje Cualitativo.

Observamos que el sistema no evoluciona satisfactoriamente. Este hecho es debido a la combinación de la agregación Best y el aprendizaje Cualitativo, donde la información de la mejor fuente de información obliga al ajuste de todos los pesos del resto de fuentes de información. Este método solamente convergirá bajo condiciones muy estrictas.

6 Conclusiones y trabajo futuro

En este documento hemos mostrado un ejemplo de nuevo método de agregación. Este sistema evoluciona e intenta generar una mejor agregación basándose en la información proporcionada al sistema con experiencias previas. Nuestro sistema extrae información de una forma simple y con un bajo coste de computación por medio del uso de experiencias previas y se demuestra, empíricamente, que el sistema incrementa la eficacia en cada nuevo caso expuesto al sistema.

Con este método siempre es necesario que las fuentes manifiesten un mínimo de fiabilidad para que el sistema pueda general resultados mínimamente certeros. En caso contrario nos hallaremos en el caso de agregar fuentes de información aleatorias, hecho que no tiene ningún sentido dado que el resultado final será así también aleatorio. Además, podemos esperar que, en conjunto, el valor obtenido de la agregación será más fiable que la más fiable de las fuentes. Con el método de aprendizaje del que disponemos, el sistema se adapta a la fiabilidad de las fuentes de información.

El entorno de uso del sistema ha de ser un universo fino de especialización de los expertos. Por ejemplo, y recuperando el caso de los médicos anterior, si intentamos consensuar la decisión de diagnóstico de hepatitis en concreto, con nuestro sistema ésta será más eficiente que si intentamos ejecutar decisiones para cualquier tipo de enfermedad. Por lo tanto, nuestro universo de decisión centrado en el diagnóstico de hepatitis será más eficaz que en un universo de diagnóstico general, en donde la correlación de datos será más difícil o bien inexistente.

Sin duda, el trabajo futuro ha de conducir a extender la influencia de los diferentes parámetros en el sistema de agregación, como por ejemplo la influencia del número de fuentes a agregar o bien la variación de los parámetros de aprendizaje. Un estudio más amplio permitiría mejoras la eficiencia del sistema y un mejor entendimiento del mismo.

Referencias

- [1] “Connectives and quantifiers in fuzzy sets”, *Fuzzy Sets Syst.*, vol 40, pp. 39-75, 1991.
- [2] A.Aamodt, E.Plaza; “Case-Based Reasoning Foundatioual Issues, Methodological Variations and System Approaches”; *AI Comunicarions*. IOS Press, Vol.7:1, pp.39-59, 1994.

- [3] Ashwin Ram and Juan Carlos Santamaría, "Continuous Case-Based Reasoning", Proceedings of the AAAI-93 workshop on Case-Based Reasoning, pp. 86-93, Washington, DC, July, 1993.
- [4] C.H. Tzeng, "A mathematical formulation of uncertain information", *Annals of Mathematics an Artificial Intelligence* 4, pp. 69-88, 1991.
- [5] D.Dubois and H.Prade, "A review of fuzzy set aggregated connectives", *Inform.Sci.*, vol.36,pp.85-121, 1985.
- [6] Daniel E. O'Leary, "Knowledge Acquisition from Multiple Experts: An Empirical Study", *Management Science / Vol. 44, No. 8, August 1998.*
- [7] David W. Aha. "*Case Based Learning Algorithms*", Proceedings of the 1991 DARPA Case-Based Reasoning Workshop, distributed by Morgan Kaufmann Publishers, Inc.
- [8] De la Rosa J.L. and A. Delgado. "fuzzy evaluation of Information Received from other Systems", *IPMU'92*, pp. 769-778, Palma de Mallorca, July 6-10, 1992.
- [9] De la Rosa J.L., I.Serra and J.Aguilar-Martin, "Outline of a Heuristic Protocol among Cooperant Expert Systems", *IEEE Conference on Systems, Man and Cybernetics*, Vol. 1, pp905-910, Chicago, October 18-21, 1992.
- [10]De la Rosa J.L., J. Aguilar-Martin and I.Serra. "Applying a Heuristic Cooperation Framework to Expert Control", *IEEE Internation Symposium on Intelligent Control*, pp. 617-620, Chicago, August 25-27, 1993.
- [11]De la Rosa, J. Ll., "Heuristics for Cooperation of Expert Systems. Application to Process Control", Ph.D. Thesis. ISBN: 84-605-0275-9, 1994.
- [12]Delgado, M., Verdegay,J.L., Vila, M.A. "On Aggregated Operations of Linguistic Labels", *Intenational Journal of Intelligent Systems*, 8, 351-370, 1993.
- [13]Dubois, D., Prade, H., "A review of fuzzy set aggregated connectives", *Inform. Sci.*, vol.36, pp.85-121, 1985.
- [14]E.H. Shortlife, and B.G. Buchanan, "A model of inexact reasoning in medicine", *Math. Biosci.*, vol. 23, pp. 351-379, 1975.
- [15]Gordon,J. and E.H. Shortlife, "Rule-Based Expert Systems: The MYCIN experiments of the Stanford Euristic Programming Project", *B.G. Buchanan and E.H. Shortlife (Eds.)*, Reading, Massachussets: Addison-Wesley, 1984.
- [16]Hall & Llinas, "Handbook of multisensor data fusion", The Electrical Engineering and apploed signal Processing Series, CRC Press, 2001.
- [17]J. Kitteler, A. Hojjatoleslami, "Weighting factors in multiple expert fusion", Proceedings of the British Machine Vision Conference, 1997, pp.41-50.
- [18]J. Mira & M.Ali, Pádraig Cunningham, "CBR: Strengths and Weaknesses", Proceedings of 11th. Internatuional conference on Industrial and Engineering Applications of Artificial Intelligence and Expert Systems, eds A.P. del Pobil, J. Mira & M.Ali, Lecture Notes in Artificial Intelligence 1416, Vol. 2, pp517-523, Springer Verlag, 1998
- [19]Keeny, Ralph L., Raiffa, Howard, *Decisions with Multiple Objectives: Preferencies and Value Tradeoffs*, Cambridge University Press, 1993.
- [20]L. Lam, and C.Y. Suen: "Combination of multiple classifier decisions for optical character recognition in Handbook of character recognition and document image analysis" (World Scientific Publishing Company, 1997), pp.79 – 101.
- [21]López de Mántaras,R and Plaza, E. "*Case-Based Reasoning: An Overview.*", IIIA- Artificial Intelligence Research Institute, CSIC-Spanish National Research Council 1995.
- [22]M. Al Abidi et al, "Combination of information in the framework of possibility theory", *Data Fusion in Robotics and Machine Intelligence*,. Eds. New York: Academic, 1992.
- [23]M. O'Hagan, "Aggregating template rule antecedents in real-time expert systems with fuzzy set logic", *Proceeding 22nd Annual IEE Asilomar Conf. On Signals, Systems and Computers*, Pacific Grove, CA, 1988.
- [24]M.C. Fairhurst and A.F.R. Rahman, "Enhancing consensus in multiple expert decision fusion", *IEE Proc. – Vis. Image Signal Process*, Vol. 147, No. 1, February 2000.
- [25]Montaner, M., López, B., de la Rosa, J. Ll., "Opinion-Based Filtering Through Trust". In Proceedings of the 6th International Workshop on Cooperative Information Agents (CIA'02). Matthias Klusch, Sascha Ossowski and Onn Shehory (Eds.), Lecture Notes in AI N°2446. Springer-Verlag Berlin Heidelberg, pp. 164-178, Madrid (Spain). 18-20 September, 2002.
- [26]Murofushi, T., Sugeno, M., "Fuzzy t-conorm integral with respect to fuzzy measures: generalization of Sugeno

- integral and Choquet integral”, *Fuzzy Sets and Systems*, 42:1 ; 57-71, 1991.
- [27] Nettleton, D. and Torra, V., “A Comparison of Active Set Method and Genetic Algorithm Approaches for Learning Weighting Vectors in Some Aggregated Operators”, *International Journal of Intelligent Systems*, Vol. 16, 1069-1083 (2001).
- [28] Rees, J., Koehler, G., (1999), Brainstorming, Negotiating and Learning in group Decision Support Systems: An Evolutionary Approach. *Proceedings of the 32th Hawaii International Conference on System Sciences*.
- [29] T.K. Ho, J.J. Hull, and S.N. Srihari, “Decision combination in multiple classifier systems”, *IEE Trans. Pattern Ana. Mach. Intell.* 1994, 16, (1), pp. 66-75.
- [30] Torra, V. “On the Learning of Weights in Some Aggregated Operators: The Weighted Mean and OWA operators”, *Mathware & Soft Computing* 6 (1999) 249-265.
- [31] Torra, V. “The weighted OWA operator”, *International Journal of Intelligent Systems*, 12 153-166, 1997.
- [32] Torra, V., “The WOWA operator and the interpolation function W^* : Chen and Otto’s interpolation revised”, *Fuzzy Sets and Systems*, 1998.
- [33] Torra, V., “Learning Weights for the quasi-weighted means”, *IEEE Trans on Fuzzy Systems*, Oct. 2002, vol. 10:5.
- [41] *Systems, Man and Cybernetics*, 18, 183-190, 1988.
- [34] Torra, V., “On the Integration of Numerical Information: From the Arithmetic Mean to Fuzzy Integrals”, *Report de recerca, Universitat Rovira I Virgili*, DEI-RR-98-010. Octubre, 1998.
- [35] V. Torra, “ On some relationships between the WOWA operator and the Choquet integral”. *Proceeding of the Seventh Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems*. Paris, France, 1997.
- [36] Yager, R. R., “Families of OWA operators”, *Fuzzy sets and systems*, 59 125-148, 1993.
- [37] Yager, R. R., “On ordered averaging aggregated operators in multi-criteria decision making”, *IEEE Trans. On SMC*, 18 183-190, Jan-Feb 1988
- [38] Yager, R.R., “On the Aggregated of Priorized Belief Structures”, *IEEE Transactions on Systems, Man, and Cybernetics- Part Z: Systems and humans*, Vo. 26, No. 6, November 1996.
- [39] Yager, R.R., Filev, D.P., “Induced Ordered Weighted Averaging Operators”, *Systems, Man and Cybernetics*. Vol. 29, Num. 2, 141-150, 1999.
- [40] Yager, R.R., “On Ordered Weighted Averaging Aggregated Operators in Multicriteria Decision Making”, *IEEE Transactions on*