

# Clasificación borrosa basada en disimilitud para la valoración inicial de desastres

J. Tinguaro Rodríguez, Begoña Vitoriano, Javier Montero

Facultad de Ciencias Matemáticas, Universidad Complutense de Madrid  
{jtrodrig,bvitoriano,javier\_montero}@mat.ucm.es

**Abstract.** En la gestión de desastres y emergencias, es crucial una valoración inicial correcta de las consecuencias de los fenómenos adversos para permitir una toma de decisiones adecuada. Sin embargo, no se requiere que esta valoración inicial sea necesariamente totalmente precisa, por lo que su obtención puede asimilarse con un problema de clasificación borrosa en el que las clases presentan una estructura relevante, que emana de la semántica del contexto y de los requisitos del problema de decisión. Este trabajo propone la consideración de un operador de disimilitud para la introducción de esta estructura en los procesos de aprendizaje y razonamiento de un clasificador borroso, lo que redundará en una mejora de la adaptación del clasificador a las características y los requisitos en términos de toma de decisiones del contexto de la gestión de desastres.

**Keywords:** toma de decisiones, clasificación borrosa, disimilitud, gestión de desastres.

## 1 Introducción

Tras la ocurrencia de un desastre en cualquier lugar del planeta, las agencias y ONG internacionales involucradas en la respuesta a desastres (como OCHA o IFRC) ponen en marcha procesos de análisis orientados a decidir sobre la pertinencia de una operación de ayuda y sobre la existencia o no de condiciones propicias para su realización. Por ello, las decisiones a tomar en un primer momento tienen un carácter estratégico, más centradas en valorar el grado de implicación de la organización en una posible operación de respuesta que en los contenidos específicos de tal operación.

Sin embargo, estas decisiones estratégicas tienen una influencia clave en los subsiguientes procesos de decisión logístico y sobre el terreno, que evalúan la cantidad de ayuda a enviar y cómo será transportada hasta la población afectada (ver [3]). Por esto, el proceso de decisión estratégico tiene lugar en un contexto de urgencia, pues cualquier retraso en esta etapa puede comprometer el prestigio y la reputación de la organización y retrasar la recepción de ayuda por parte de la población afectada.

Por otro lado, la toma de decisiones estratégica depende fuertemente de una valoración correcta de las consecuencias del desastre y las necesidades resultantes de la población afectada. Sin embargo, la información disponible tras el impacto de un desastre suele estar afectada por distintos tipos de *incertidumbre*. Los primeros *reports* suelen ser bastante incompletos, cuando no directamente confusos o contradictorios. Además, cuando existe, la información relevante suele estar expresada lingüís-

ticamente, por lo que puede ser vaga e imprecisa. Esto plantea dificultades para el desarrollo del mencionado proceso de decisión estratégico, en tanto que en este contexto la urgencia de las decisiones choca con la necesidad de una correcta estimación de las consecuencias del desastre, i.e. de las necesidades de la población afectada.

En trabajos anteriores de los autores se propone y describe un sistema de ayuda a la decisión (DSS) centrado en la evaluación de las consecuencias de los desastres con la primera información disponible tras su impacto. Como se discute en [10], este DSS, denominado SEDD (Sistema para la Evaluación y el Diagnóstico de Desastres), constituye uno de los primeros esfuerzos encaminados a proveer a las ONG con herramientas inteligentes para la valoración de consecuencias de los desastres específicamente diseñadas para estas organizaciones. El motor de inferencia de SEDD [9] está basado en procedimientos de aprendizaje automático borroso (ver [4]), y en particular en el uso de un sistema de clasificación basado en reglas borrosas (SCBRB, ver [2]). Además, los SCBRB mejoran el rendimiento de la mayoría de técnicas estadísticas ordinarias y de métodos aprendizaje automático en la labor de proporcionar una valoración simultáneamente interpretable y precisa de las consecuencias de desastres [11].

Este trabajo estudia la estructura del problema de clasificación que subyace en la valoración provista por SEDD. En concreto, se analizan las relaciones entre la estructura impuesta en el conjunto de clases y los requisitos del contexto de decisión, mostrando que se alcanza una mejora significativa del comportamiento de SEDD en términos de su adaptación a tales requisitos al considerar e introducir ciertas estructuras en los modelos de clasificación. Como se muestra en [8], en un marco de clasificación supervisada es posible introducir relaciones entre las clases mediante la noción de antagonismo o disimilitud semántica propuesta en [7]. Por tanto, en este trabajo se discute el efecto de diferentes estructuras de disimilitud en términos de su capacidad de adaptación a algunos de los requisitos del contexto de la gestión de desastres.

## 2 La valoración estratégica de la severidad de los desastres como un problema de clasificación con estructura

Considérese la estimación de la variable *número de personas sin hogar*, que mide el número de personas que perdieron su casa como consecuencia de un desastre. Para las ONG, esta cantidad constituye un indicador clave de la magnitud de los esfuerzos que una potencial operación de ayuda debería acometer en materia de alojamientos temporales y gestión de emplazamientos. En la práctica, en una primera etapa, para un decisor de una ONG no es importante distinguir si 50.000 o 70.000 personas quedaron sin hogar, ya que en cualquier caso tal cantidad va a ser considerada *grande* y las decisiones estratégicas a tomar en términos de las acciones subsiguientes y el tamaño y la naturaleza de la operación necesaria van a ser similares.

Así pues, en los primeros momentos tras el impacto de un desastre, los decisores de las ONG valoran la severidad del desastre de una manera cualitativa (más que cuantitativa). Dicho de otro modo, su problema consiste en evaluar, en un contexto de información altamente incierta e imprecisa, la magnitud de las consecuencias de un desastre en relación con los escenarios y decisiones relevantes que pueden surgir de cara a la implementación de una operación de respuesta.

Por este motivo, consideramos que, en lugar de una evaluación numérica precisa, para obtener una valoración inicial que sustente una adecuada toma de decisiones estratégicas es más plausible y realista *clasificar* la severidad de las consecuencias de un desastre en términos de los escenarios relevantes para los decisores de las ONG. Así, el mencionado problema de evaluación de desastres conduce a un problema de clasificación en el que las clases se identifican con los términos lingüísticos que describen esos escenarios relevantes, como *sin víctimas mortales* o *muchos heridos*. Estas etiquetas o clases, valorando la magnitud de diferentes consecuencias relevantes de un desastre, han de ser asignadas sobre la base de una descripción o atributos del desastre dada por la primera información disponible, como el tipo de desastre, su intensidad y las características de la localización afectada (p. ej. su vulnerabilidad, ver [6]).

### 2.1 Estructura del conjunto de clases

Considérese ahora una de las variables a ser evaluadas para la consecución de la mencionada valoración inicial. Por ejemplo, centrémonos en la variable *número de víctimas mortales (CAS)*. Esta variable mide el número de personas que perecieron como consecuencia del impacto del fenómeno adverso. Como se ha explicado, en una primera etapa es posible valorar esta cantidad de manera cualitativa, o lingüística. Por ejemplo, podemos medir la severidad de un escenario, en términos del número de fallecidos, por medio de las etiquetas *sin víctimas mortales*, *muy pocas*, *pocas*, *bastantes* y *muchas*. Estas etiquetas representan las clases en que ha de ser clasificado un escenario de desastre para obtener una valoración inicial de la consecuencia CAS.

El significado particular de estas etiquetas ha de especificarse por medio de intervalos o, más generalmente, mediante subconjuntos borrosos, del rango de la variable numérica subyacente, en este caso los enteros positivos. Además, estos significados han de estar relacionados con los diferentes escenarios relevantes en términos de las decisiones a tomar. Por ejemplo, cada etiqueta puede asociarse con un orden de magnitud creciente en el número de fallecidos, como se muestra en la Tabla 1.

Clase	CAS1	CAS2	CAS3	CAS4	CAS5
Etiqueta	Sin víctimas mortales	Muy pocas	Pocas	Bastantes	Muchas
Intervalo	[0,10)	[10,100)	[100,1000)	[1000,10000)	[10.000,+∞)

**Tabla 1.** Clases para la variable *número de víctimas mortales (CAS)*.

Nótese que, en tanto que asociadas a diferentes órdenes de magnitud de las consecuencias, estas etiquetas pueden considerarse ordenadas de menor a mayor nivel de severidad de las consecuencias. Esto es, las clases asociadas a la variable CAS están ordenadas linealmente, i.e.  $CAS_i < CAS_j$  si  $i < j$ . Este supuesto de linealidad de los efectos de un desastre es bastante general, ya que lo que los decisores tratan de valorar en un primer momento es precisamente el orden de severidad de esas consecuencias, o equivalentemente el orden de magnitud de los esfuerzos que una operación de ayuda debería considerar para aliviar esas consecuencias. Estos órdenes de magnitud no son necesariamente potencias de 10 de la variable numérica subyacente, sino que se asocian a los diferentes escenarios

relevantes que pueden surgir, ordenados atendiendo a la gravedad de la crisis humanitaria que implican.

Por tanto, en este marco, las clases no son ítems independientes o no relacionados, sino que conforman una estructura de valuación, en el sentido de [5]. Por ejemplo, no se comete el mismo error cuando se valora un escenario sin fallecidos (*CAS1*) como teniendo *pocas* víctimas mortales (*CAS2*), que cuando el mismo es evaluado como habiendo producido *muchos* fallecidos (*CAS5*). Así pues, el mencionado problema de valoración de la severidad de un desastre puede ser entendido como un problema de clasificación con un conjunto de clases estructurado.

## 2.2 Requisitos del contexto

El conjunto de clases recién introducido para la variable *CAS* en principio se ajusta a una estructura lineal, en tanto que las clases están semánticamente asociadas a diferentes órdenes de magnitud de las consecuencias. Algunas clases están más próximas entre sí que otras, por lo que se pueden distinguir diferentes niveles de error de acuerdo con tal distancia. Sin embargo, nótese que el error cometido al valorar un escenario *CAS1* como *CAS5* es también diferente al cometido cuando un escenario *CAS5* se evalúa como *CAS1*. En el primer caso hay error de sobreestimación mientras que en el segundo lo hay de subestimación. Aunque los dos tipos de error son relevantes, la subestimación de los efectos de un desastre puede acarrear consecuencias mucho más peligrosas que la sobreestimación para el prestigio de la ONG y la población afectada.

Por ello, los decisores de las ONG suelen tender a evitar el riesgo de subestimación, por ejemplo llevando a cabo análisis del peor caso en el escenario bajo estudio. Así, puede requerirse que la valoración inicial de un escenario de desastre sea realizada evitando el riesgo de subestimación. Este requisito, asociado a la toma de decisiones, implica de alguna manera introducir una configuración asimétrica en la estructura lineal de las clases, ya que se cometen errores distintos dependiendo de si un escenario es subestimado o sobreestimado. La estructura del conjunto de clases ha de capturar tanto los aspectos relevantes de la semántica de las clases como los objetivos y requisitos relacionados con el contexto de decisión en que se usa el clasificador.

## 2.3 Estructuras de disimilitud

La asimetría de la estructura lineal del conjunto de clases fuerza a buscar estructuras más generales que las de orden. Aquí se adopta la noción de *estructura de disimilitud* propuesta en [7] para proporcionar una definición formal de la estructura de un conjunto de clases. Estas estructuras se basan en la noción de antagonismo o disimilitud semántica (también propuesta en [7]), que permite modelar relaciones de oposición entre conceptos, y en particular relaciones asimétricas. Por tanto, al adoptar esta noción, en cierto modo se está traduciendo la *distancia* semántica entre dos clases, proveniente de la ordenación lineal de las consecuencias, en un *grado de oposición* entre ellas, que puede ser asimétrico para reflejar los requisitos citados.

Como se verá en la próxima sección, las estructuras de disimilitud proporcionan un método fácil y efectivo para introducir relaciones entre clases en los modelos de clasificación, permitiendo distinguir entre *excepciones significativas* y simples *con-*

traejemplos a una regla de clasificación. Esto conduce a la aparición de un grado de confianza *negativo* en las reglas, i.e., a un marco de clasificación bipolar (ver [8]).

Así pues, denótese por  $\zeta = \{C_1, \dots, C_N\}$  el conjunto de clases en consideración. Como se explica en [7], es posible obtener una estructura de disimilitud sobre este conjunto mediante una *matriz de disimilitud*  $\Delta = (d_{ij})_{N \times N}$ , tal que el valor  $d_{ij} \in [0,1]$  expresa el grado en que la clase  $C_j$  es opuesta o disimilar a la clase  $C_i$ ,  $i, j = 1, \dots, N_C$ .

De este modo, la matriz  $\Delta^I = 0$  representa una situación en que ninguna clase es opuesta a las demás. En el otro extremo,  $\Delta^{III} = 1 - Id$  describe una situación en que todas las clases son totalmente opuestas entre sí. Como se verá a continuación, estas matrices permiten representar algunos de los requisitos del contexto de aplicación *dentro* de los modelos de clasificación. Por tanto, existe un amplio rango de posibilidades entre estos casos extremos para la modelización de diferentes condiciones de oposición. La elección de una matriz particular dependerá por supuesto de los requisitos semánticos específicos que hayan de cumplirse.

### 3 Una metodología bipolar para SEDD

Tal y como se describe en [9,11], la metodología de SCBRB de SEDD no considera explícitamente ninguna estructura en el conjunto de clases. Por ello, en esta sección se ilustran las ideas anteriores adaptando la metodología de SEDD al caso estructurado. Para este fin, se adopta la metodología de clasificación bipolar propuesta en [8].

#### 3.1 Nociones básicas sobre SEDD

En primer lugar, SEDD puede ser entendido como un SCBRB. Como tal, las reglas que guían la clasificación han de ser aprendidas a partir de un conjunto de ejemplos de entrenamiento, y el proceso de inferencia que asigna una clase a una nueva instancia precisa que esa instancia sea descrita en los mismos términos que los ejemplos de entrenamiento. La muestra de entrenamiento de SEDD es la base de datos EM-DAT. Las variables de EM-DAT con interés para este estudio se muestran en la Tabla 2. Las variables *MAG* y *HDI* se toman como explicativas para la variable dependiente *CAS*.

Variable	Descripción
MAG (Magnitud)	<i>Intensidad</i> del fenómeno adverso: grados en la escala Richter para terremotos, etc.
HDI	Índice de Desarrollo Humano: una estimación de la vulnerabilidad del país afectado.
CAS (Fallecidos)	Número de víctimas mortales producidas por el desastre.

**Table 2.** Variables de EM-DAT relevantes para este estudio.

En segundo lugar, debe aplicarse un procedimiento de aprendizaje para extraer las reglas de los datos. Denotemos por  $X_1, \dots, X_n$  los  $n$  atributos usados para describir un desastre, y supongamos que se dispone de un conjunto de  $m$  ejemplos de entrenamiento  $(x_1^p, \dots, x_n^p; C^p)$  como muestra de aprendizaje, donde para cada  $p = 1, \dots, m$ ,  $C^p$  es una de las clases en  $\zeta = \{C_1, \dots, C_N\}$ . Supongamos también que se dispone de una matriz de disimilitud  $\Delta = (d_{ij})_{N \times N}$  modelando las relaciones de oposición entre las

clases en  $\zeta$ . Para todo  $i = 1, \dots, n$  denotemos por  $A_{i1}, \dots, A_{ic_i}$  las  $c_i$  etiquetas lingüísticas definidas para cada atributo  $X_i$ , de manera que  $\mu_{A_{ij}}(x_i) \in [0, 1]$  representa el grado en que el valor  $x_i$  verifica la etiqueta  $A_{ij}$ . Una premisa  $A$  de una regla viene dada por la combinación de una etiqueta  $A_{ij}$  de cada atributo, i.e.  $A = A_{i1j_1} \times \dots \times A_{nj_n}$ . El grado de compatibilidad entre una premisa  $A$  y un patrón  $x = (x_1, \dots, x_n)$  se suele obtener mediante una t-norma  $T$ , i.e.  $\mu_A(x) = T(\mu_{A_{i1j_1}}(x_1), \dots, \mu_{A_{nj_n}}(x_n))$ .

En estas condiciones, siguiendo [8], una regla con premisa  $A$  y consecuente una clase  $C_j \in \zeta$  se evalúa mediante un par de grados de confianza

$$r_j^+(A) = \frac{\sum_{p=1, \dots, m / C^p = C_j} \mu_A(x^p)}{\sum_{p=1}^m \mu_A(x^p)}, \quad r_j^-(A) = \frac{\sum_{p=1}^m \mu_A(x^p) \cdot \mu_{\Delta C_j}(C^p)}{\sum_{p=1}^m \mu_A(x^p)}$$

donde  $\mu_{\Delta C_j}(C_i) = d_{ji}$ . Nótese que  $r^+, r^- \in [0, 1]$  y que se cumple que  $r^+ + r^- \leq 1$ .

Como se explica en [8],  $r_j^+(A)$  y  $r_j^-(A)$  estiman respectivamente la proporción de ejemplos positivos y excepciones significativas de la regla  $A \Rightarrow C_j$  sobre el total de ejemplos que cumplen la premisa  $A$ . Por tanto, la estructura de disimilitud se introduce en la evaluación de las reglas por medio del grado de confianza negativo. Es posible usar diferentes procedimientos (ver por ejemplo [1]) para obtener el conjunto de premisas  $A$  para el que se han de formar reglas.

Por último, se ha de aplicar un método de razonamiento borroso (ver [2]) para evaluar un escenario de desastre  $x = (x_1, \dots, x_n)$  bajo estudio. Siguiendo [8], aquí se aplicará el método de razonamiento VA1 (veracidad aditiva unidimensional), que calcula el grado de veracidad  $t_j(A) = \max\{r_j^+(A) - r_j^-(A), 0\}$  para las  $R$  reglas  $R^q : A^q \Rightarrow C_j$  disponibles, y computa un grado de evidencia  $t_j(x)$  para la clasificación del escenario  $x$  en cada clase  $C_j$  como

$$t_j(x) = \frac{\sum_{q=1, \dots, R} \mu_{A^q}(x) \cdot t_j(A^q)}{\sum_{q=1, \dots, R} \mu_{A^q}(x)}$$

Así pues, el vector  $t(x) = (t_1(x), \dots, t_N(x))$  constituye el output final de SEDD, valorando el grado de evidencia para cada clase o nivel de consecuencias. Si es preciso facilitar una predicción nítida, se asigna el escenario  $x$  a la clase con máxima evidencia, i.e. a la clase  $C_h$  tal que  $t_h(x) = \max_j t_j(x)$ .

### 3.2 Estructuras de disimilitud para la valoración de desastres

Aquí se ilustra el efecto de diferentes estructuras de disimilitud en la valoración provista por SEDD para el caso de terremotos. Por tanto, se tiene  $n=2$  y  $N=5$  (se usan las clases descritas en la Tabla 1 para la variable dependiente CAS). La muestra de entrenamiento contiene  $m=386$  ejemplos. Como el número máximo de premisas es pequeño ( $5 \cdot 5=25$ ), se adopta un método de aprendizaje basado en retículo, i.e. se

generan reglas para todas las posibles premisas, aunque se considera un umbral ( $\delta=0.01$ ) sobre el soporte de las reglas. Las matrices de disimilitud que se usarán son

$$\Delta_0 \equiv 0, \Delta_1 = 1 - Id, \Delta_{RL} = \begin{pmatrix} 0 & 0.2 & 0.2 & 0.5 & 1 \\ 0 & 0 & 0.2 & 0.5 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix}, \Delta_{TA} = \begin{pmatrix} 0 & 1 & 1 & 1 & 1 \\ 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix}.$$

Para ilustrar y comparar visualmente el efecto de cada matriz  $\Delta$ , se computa el resultado del clasificador VA1 correspondiente en un mallado de puntos del espacio de entrada de los atributos *MAG* y *HDI*, obteniendo una representación gráfica de las fronteras de clase producidas por cada estructura de disimilitud. También, se computan dos medidas de error para medir el rendimiento de los diferentes clasificadores: 1) %CC representa la tasa de clasificaciones correctas obtenidas sobre la muestra de aprendizaje; 2) para medir tanto la desviación de las predicciones a la clase real como el riesgo de subestimación, se computa el coste promedio AVCOST de las predicciones sobre la muestra de entrenamiento, donde el coste de clasificar un ejemplo de la clase  $i$  en la clase  $j$  viene dado por  $COST_{ij} = j - i$  si  $i \leq j$  y  $COST_{ij} = 2 \cdot (i - j)$  si  $i > j$ .

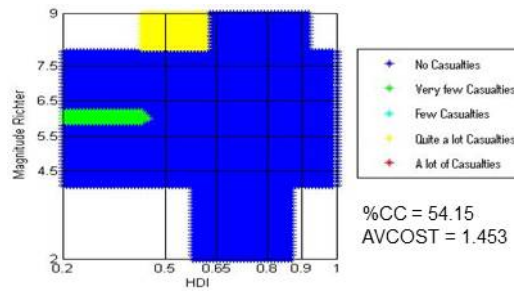


Fig. 1. Resultados del clasificador con  $\Delta_0 \equiv 0$ .

**No oposición.**

Comencemos suponiendo que no existe oposición entre las clases, i.e.  $\Delta_0 \equiv 0$ . En este caso,  $r_j^-(A) = 0$  para toda premisa  $A$  y consecuente  $C_j$ , por lo que  $t_j(A) = r_j^+(A)$  para todas las reglas  $A \Rightarrow C_j$ . Por tanto, este caso corresponde a un marco de clasificación no estructurada, en el que se obtiene un clasificador borroso estándar, idéntico al usado por SEDD en [9]. Al no asumir ninguna estructura, el clasificador resultante trata las clases como ítems independientes, por lo que este estará sesgado hacia las clases con mayor proporción de ejemplos de entrenamiento. Esto se visualiza claramente en la Fig. 1, en la que se muestra el resultado del clasificador sobre el mallado. Una gran parte del espacio de entrada se asigna a la clase más baja, *CASI= sin víctimas mortales*, i.e. aquella con mayor proporción (54.4%) de ejemplos de entrenamiento. Esto conlleva un fuerte riesgo de subestimación de las consecuencias. Además, el comportamiento del clasificador no es suave o gradual, en tanto que las predicciones presentan saltos bruscos.

**Oposición total.**

Analicemos ahora el otro caso extremo, dado por la matriz  $\Delta_1 = 1 - Id$ , en el que todas las clases son totalmente opuestas entre sí. Nótese que ahora se tiene  $r_j^-(A) = 1 - r_j^+(A)$ , por lo que  $t_j(A) = \max\{2r_j^+(A) - 1, 0\}$ . En tanto que las clases se encuentran igualmente relacionadas entre sí, se obtiene un sesgo semejante al anterior, aunque ahora una regla  $A \Rightarrow C_j$  obtendrá  $t_j(A) = 0$  a menos que  $r_j^+(A) > 0.5$ , i.e. a menos que más de la mitad de los ejemplos compatibles con la premisa  $A$  pertenezcan a la clase  $C_j$ . Si ninguna clase cumple esta condición, entonces  $t_j(A) = 0$  para todo  $j$ . Por ello, una instancia  $x$  puede quedar sin clasificar si ninguna de las reglas activadas tiene veracidad positiva. Esto se observa claramente en la Fig. 2, pues la mitad del espacio de entrada queda sin clasificar, y la otra mitad se asigna de nuevo a la clase mayoritaria CAS1, la única que alcanza el umbral 0.5 en algunas premisas. En cierta medida, este clasificador puede ser asociado con un requisito de no proporcionar una valoración a menos que sea posible establecer predicciones con amplio soporte. Nótese que el 43.78% y el 38.86% de los  $m = 386$  ejemplos de entrenamiento quedan sin clasificar y bien clasificados respectivamente. Esto arroja una tasa de error de 17.36% (la anterior era 45.85%), aunque al precio de no clasificar casi media muestra. También, el coste promedio es significativamente menor al quedar sin clasificar gran parte de los ejemplos de las clases altas.

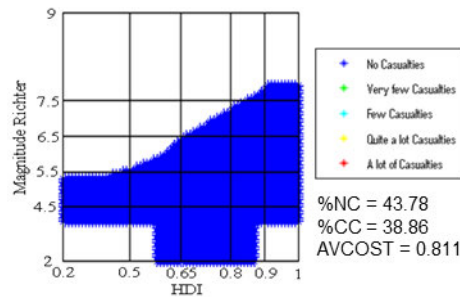


Fig. 2. Resultados del clasificador con  $\Delta_1 \equiv 1 - Id$ .

### Orden lineal asimétrico restringido.

Para reproducir la semántica de orden lineal asociada a las clases, se toma la matriz  $\Delta_{RL}$ . Esta matriz induce una estructura en la que las clases superiores son gradualmente más disimilares a las dos clases inferiores, CAS1 y CAS2, pero no simétricamente, i.e. las inferiores no son disimilares a las superiores. De este modo, las clases CAS1 y CAS2 obtienen una veracidad más baja en presencia de las superiores, precisando una mayor evidencia para ser predichas, representando la estructura lineal junto al requisito de no subestimación. En tanto que este riesgo es menor o puede ser ignorado para las clases superiores, las clases CAS3-CAS5 no son opuestas entre sí, por lo que compiten libremente como en el caso  $\Delta \equiv 0$ . El comportamiento de este clasificador indica ahora transiciones más suaves entre clases alejadas, y una mayor parte del espacio de entrada es asignado a clases más altas, ver Fig. 3. Además, se obtiene una tasa de clasificaciones más alta (%CC=55.18) que en el caso estándar, y se alcanza asimismo un coste promedio sensiblemente más bajo.

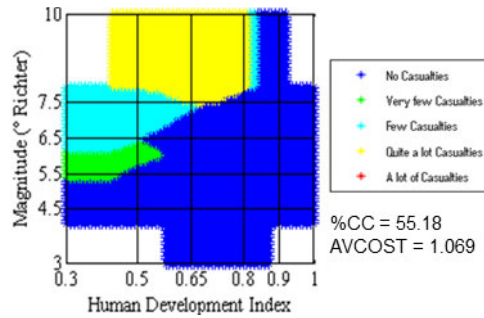


Fig. 3. Resultados del clasificador con  $\Delta \equiv \Delta_{RL}$ .




Fig. 4. Resultados del clasificador con  $\Delta = \Delta_{PE}$ .

**Análisis del peor escenario.**

Finalmente, consideremos un requisito de aversión total al riesgo de subestimación. Para este fin, se toma la matriz de disimilitud  $\Delta_{TA}$ , que conduce a una estructura en que cada clase es opuesta a las clases inferiores a ella, pero no recíprocamente. Por tanto, en este marco no se considera de manera explícita una estructura lineal, sino solo un supuesto de tota asimetría entre las clases inferiores y superiores. Por tanto, cuanto más bajo es el índice de la clase, más difícil será predecirla. En este sentido, la matriz  $\Delta_2$  encaja con el requisito de un análisis del peor caso en el escenario bajo estudio. En consecuencia, como se observa en la Fig. 4, la clase CAS5 aparece por primera vez en los resultados del clasificador, y se obtienen transiciones incluso más suaves entre las predicciones que en el caso anterior, pudiéndose trazar una recta en el espacio de entrada que pase, ordenadamente, por todas las clases. Más significativamente, este clasificador permite distinguir una clara tendencia en las consecuencias, de manera que peores efectos se asocian con valores de HDI más bajos (por tanto una vulnerabilidad mayor) y mayores intensidades de los terremotos. Aunque esta tendencia es lógicamente esperable, ninguno de los clasificadores anteriores pudo reflejarla tan claramente. Además, este clasificador consigue una reducción del riesgo de subestimación, como se desprende de su coste promedio más bajo (AVCOST=0.968), que podría ser más importante atendiendo a que la tasa de clasificaciones correctas es más baja que en el caso anterior (%CC=50.52), con el consiguiente aumento de costes no nulos.

## 4 Conclusiones

Al considerar la producción de una valoración inicial de las consecuencias de desastres como un problema de clasificación estructurado, la estructura del conjunto de clases adquiere una fuerte relación con las características semánticas y los requisitos de los decisores del contexto de la gestión de desastres. Por ello, una adecuada caracterización de tales estructuras redundaría en una mejor adaptación del clasificador a esas características y requisitos. En este trabajo se ha mostrado que la introducción de un operador de disimilitud en el conjunto de clases permite la consideración de diversas estructuras y su introducción en los procesos de aprendizaje y razonamiento del clasificador, obteniéndose con ello una mejora significativa de la precisión y la adaptación de los clasificadores a los requisitos en términos de toma de decisiones del contexto de la gestión de desastres.

## Referencias

1. Casillas J, Cordón O, Herrera F (2002) COR: A Methodology to Improve Ad Hoc Data-Driven Linguistic Rule Learning Methods by Inducing Cooperation Among Rules. *IEEE Trans. on Systems, Man and Cybernetics-Part B: Cybernetics* 32 (4): 526- 537
2. Cordón, O., del Jesús, M. J., Herrera, F. (1999) A proposal on reasoning methods in fuzzy rule-based classification systems, *International Journal of Approximate Reasoning*, 20 (1) 21-45
3. Drabek, T. E., Hoetmer, G. J. (1991) *Emergency management: principles and practice for local government*, International City Management Association, Washington DC
4. Hullermeier, E. (2005) Fuzzy methods in machine learning and data mining: Status and prospects, *Fuzzy Sets and Systems*, 156 (3) 387-406
5. Montero, J., Gomez, D., Bustince, H. (2007) On the relevance of some families of fuzzy Sets, *Fuzzy Sets and Systems*, 158 (22) 2429-2442
6. Morrow, B. H. (1999) Identifying and mapping community vulnerability, *Disasters*, 23 (1) 1-18
7. Rodríguez JT, Franco CA, Vitoriano B, Montero J (2011) An axiomatic approach to the notion of semantic antagonism, *Procs IFSA-AFSS'11 FT104-1/6*
8. Rodríguez, J. T., Vitoriano, B., Montero, J. (2011) Rule-based classification by means of bipolar criteria. 2011 *IEEE SSCI-MCDM* 197-204
9. Rodríguez, J. T., Vitoriano, B., Montero, J. (2012) A general methodology for data-based rule building and its application to natural disaster management, *Computers & Operations Research*, 39 (4) 863-873
10. Rodríguez, J. T., Vitoriano, B., Montero, J., Omaña, A. (2008) A decision support tool for humanitarian operations in natural disaster relief, *Computational Intelligence in Decision and Control*, 1 805-810
11. Rodríguez, J. T., Vitoriano, B., Montero, J., Kecman V. (2011) A disaster-severity assessment DSS comparative analysis. *OR Spectrum* 33(3) 451-479
12. Wallace, W. A., De Balogh, F. (1985) *Decision Support Systems for Disaster Management*, *Public Administration Review*, 45 134-146