

# Un système d'inférence flou pour contribuer à la surveillance de la sismicité.

Laurence CORNEZ <sup>1</sup>, Jean-Denis MULLER <sup>1</sup>, Michaël AUPETIT <sup>2</sup>

<sup>1</sup> CEA LIST, Laboratoire Intelligence Multi-capteurs et Apprentissage, 91191 Gif-sur-Yvette Cedex

<sup>2</sup> CEA-DAM/DASE, BP12, 91680 Bruyères-le-Châtel

[laurence.cornez@cea.fr](mailto:laurence.cornez@cea.fr), [jean-denis.muller@cea.fr](mailto:jean-denis.muller@cea.fr), [michael.aupetit@cea.fr](mailto:michael.aupetit@cea.fr)

**Résumé** – Dans cet article, nous proposons une solution pour classifier des événements sismiques à partir de caractéristiques de haut niveau (c'est-à-dire issues du traitement des signaux sismiques). Cette méthode offre une aide aux analystes pour la validation de la classification des événements. Inspirée à la fois des statistiques et de l'intelligence artificielle, elle permet d'obtenir de très bons taux de reconnaissance tout en offrant aux analystes le cheminement (sous forme de règles) qui a conduit à la classe d'un événement. Ce dernier point est la clé de l'étude car les analystes ont besoin de comprendre le cheminement du classifieur lors de son étiquetage afin de valider ce dernier.

**Abstract** – In this paper, we propose a solution to classify seismic events with respect to different high level features, coming from some processing of the signals associated to seismic events. This method, at the heart of a decision support system, help analysts to check the labels they assign. It is inspired by both statistics and artificial intelligence, and combines high performance and intelligibility. This latter issue is the key point of the study because analysts want to understand the way decisions are taken by the tool they work with.

## 1. Introduction

L'une des missions du CEA DASE (Département Analyse Surveillance Environnement du Commissariat à l'Energie Atomique) est de surveiller la sismicité de la France et en particulier de fournir une alerte aux autorités en cas de séisme susceptible d'être ressenti sur le territoire. Il lui faut donc caractériser les événements sismiques détectés (localisation, magnitude) et les étiqueter (événement naturel, tir de carrière, coup de terrain...) pour produire un bulletin hebdomadaire d'activité sismique.

Nous avons développé un système d'aide à la décision proposant un étiquetage automatique aux analystes sismologues. L'étiquetage automatique est obtenu par un modèle qui apprend les étiquettes des événements passés. En cas de désaccord, l'événement est révisé par l'analyste qui décide ou non de changer l'étiquette de l'événement. Le DASE souhaite proposer des systèmes d'aide à la décision aux analystes afin de leur permettre de vérifier la fiabilité de leur base de données d'événements sismiques. Une telle base de données est nécessaire pour calculer les modèles de propagation et estimer les dommages.

Le système d'aide à la décision proposé doit remplir deux objectifs : être performant, pour que l'analyste puisse avoir confiance en l'étiquette proposée, mais aussi être intelligible, dans le sens où l'analyste souhaite comprendre pourquoi le système identifie telle classe plutôt qu'une autre.

Pour modéliser un tel système d'aide à la décision, il existe plusieurs solutions statistiques ([2],[3]) : régression polychotomique, réseaux de neurones SVM, arbres de décision. Par ailleurs, la théorie des ensembles flous nous offre les arbres de décision flous ([9]) et les systèmes d'inférence flous ([7]). Une précédente étude ([5]) nous indique que les systèmes d'inférence flous construits avec des règles de Sugeno nous permettent d'atteindre le double objectif de performance et d'intelligibilité.

## 2. Le système d'inférence flou

Les systèmes d'inférence flous (FIS) choisis utilisent des règles de Sugeno d'ordre 0 définies dans Jang [7], aussi avons-nous appelé nos modèles des classifieurs de Sugeno. La  $k^{\text{ème}}$  règle de Sugeno est définie par :

- une fonction  $\mu_k$  (la fonction d'appartenance) définie sur l'espace des variables d'entrée et à valeurs dans  $[0,1]$  (le degré d'appartenance),
- un réel positif  $\rho_k$  (le poids de la règle),
- un vecteur unitaire  $z_k$  de l'espace de sortie (la conséquence de la règle).

Le calcul du degré d'appartenance sur l'espace d'entrée est le produit des degrés d'appartenance selon chacune des dimensions (ceci est la traduction de l'opérateur flou « ET » en logique et de l'indépendance des variables explicatives en probabilité). Le poids de la règle est utilisé pour la prise de décision quand on agrège plusieurs règles floues par une somme pondérée (agrégation floue). Le

classifieur de Sugeno normalisé peut se définir de manière générale par la formule (1).

$$Z(x) = \frac{1}{\sum_{k=1}^{NbRules} \rho_k \mu_k(x)} \sum_{k=1}^{NbRules} \rho_k \mu_k(x) z_k \quad (1)$$

La formule (1) met en avant un cas particulier de mélange d'experts pour lequel, chaque  $\mu_k$  serait une densité de probabilité (en accord avec la mesure de Lebesgue pour les variables quantitatives et la mesure de comptage pour les variables qualitatives) et les vecteurs  $\rho_k$  et  $z_k$  seraient des vecteurs stochastiques. Par ailleurs, en utilisant des fonctions d'appartenance gaussiennes, on peut faire le rapprochement entre le classifieur de Sugeno et les réseaux de fonctions à base radiale (RBF).

La sortie  $Z(x)$  pour un point particulier  $x$  de l'espace d'entrée est un vecteur stochastique : chaque composante peut être vue comme la probabilité d'appartenir à chacune des classes possibles. On affecte à ce point particulier  $x$  la classe qui offre le maximum de probabilité.

### 3. Mise en œuvre des FIS

Nous noterons :  $X=(X_i)_{i=1\dots N} = [X_i^{QT}, X_i^{QL}]_{i=1\dots N}$  un échantillon de la population formé de  $N$  individus caractérisés par  $NbInQT$  variables quantitatives  $X_i^{QT}=(X_{i,l}^{QT})_{l=1\dots NbInQT}$  et une variable qualitative  $X_i^{QL}$  ayant  $NbModes$  modes.

Le classifieur de Sugeno se construit en trois étapes : clustering ; amélioration EM ; et prise en compte de la variable qualitative *date*. Puis, nous verrons que l'introduction d'une nouvelle variable, liée à la connaissance experte, nous permet d'améliorer les performances.

#### 3.1 Etape de clustering

Pour mettre en place le classifieur de Sugeno (formule 2), nous avons à estimer les densités de probabilité de chacune des classes  $(\mu_k)_{k=1\dots NbRules}$ .

$$Z(X_i) = \frac{\sum_{k=1}^{NbClust} z_k \rho_k \mu_k(X_i)}{\sum_{k=1}^{NbClust} \rho_k \mu_k(X_i)} \quad (2)$$

Parmi plusieurs solutions dans la littérature scientifique et guidé par l'étude menée par Gravot [6], nous avons opté pour l'algorithme de Chiu [4] ainsi que pour les valeurs des paramètres de cet algorithme préconisées par Gravot. Cet algorithme opère dans un espace d'entrée engendré uniquement par des variables quantitatives (soit de dimension  $NbInQT$ ). En effet, la recherche de clusters s'effectue par le calcul du potentiel de chaque point et son expression est proche de la densité d'une gaussienne. Nous avons donc initialisé les clusters pour chacune des classes dans l'espace engendré par les seules variables quantitatives. Cet algorithme donne une bonne estimation

du nombre de clusters ( $NbClust$ ) qui ont généré les événements d'une même classe et fournit le centre de chaque gaussienne (en fonction des rayons de voisinage pour le calcul de potentiel et la réduction de potentiel, des seuils d'acceptation du potentiel et de la distance avec les clusters trouvés). Les densités de probabilité  $(\mu_k)_{k=1\dots NbRules}$  nécessaires selon la formule (2) sont définies par la formule (3). Ainsi les clusters trouvés (gaussiennes) par l'algorithme sont au nombre  $NbClust$ . Les paramètres de la  $k^{\text{ème}}$  gaussienne selon la  $l^{\text{ème}}$  variable d'entrée ( $l=1\dots NbInQT$ ) sont notés  $(C_{k,l}, \sigma_{k,l})$  où le centre  $C_{k,l}$  est identifié par l'algorithme et l'écart-type  $\sigma_{k,l}$  est fonction des paramètres de l'algorithme (rayon de voisinage). Les poids  $(\rho_k)$  sont pris identiques au sein d'une même classe et la somme des poids est normalisée à 1.

$$\mu_k(X_i) = \frac{\exp\left(-\frac{1}{2} \sum_{l=1}^{NbInQT} \left(\frac{d(X_{i,l}^{QT}, C_{k,l})}{\sigma_{k,l}}\right)^2\right)}{\sqrt{2\pi}^{NbInQT} \prod_{l=1}^{NbInQT} \sigma_{k,l}} \quad (3)$$

Nous avons considéré la base de données 2005 ayant 13774 individus. Pour chacun des événements, nous avons 5 variables de haut niveau (c'est-à-dire issues du traitement des signaux sismiques) : l'*heure* (variable quantitative circulaire à valeurs dans [0 ; 24]), la *latitude* (variable quantitative à valeurs dans [40 ; 52]), la *longitude* (variable quantitative à valeurs dans [-6 ; 11]), la *magnitude* (variable quantitative à valeurs dans [0,7 ; 6,0]) et la *date* (variable qualitative ayant 3 modalités : jour ouvré *D1*, samedi *D2* et dimanche et jour férié *D3*). Les événements sismiques sont répartis en trois catégories : séismes (*EQ*), coups de toit (*RB*), tirs de carrière (*QB*), les explosions marines (*ME*) et les coups de toit suspectés (*SR*). Ces quatre dernières classes sont liées à l'activité humaine.

Pour tester les performances, nous avons construit 5 bases de validation croisée ayant chacune : 3468 (resp. 867) événements en apprentissage (resp. en test). La répartition selon les classes est fournie par le tableau 1.

TAB. 1 : Effectifs de chaque type d'événements selon les bases considérées.

Effectifs	EQ	RB	QB	ME	SR
dans la base 2005	8999	368	3433	499	475
dans une base d'apprentissage	1200	292	1200	396	380
dans une base de test	300	73	300	99	95

Pour chacune des bases de données d'apprentissage, nous avons mis en œuvre l'étape de clustering sur les 4 variables quantitatives. Le nombre de clusters trouvés pour chacune des bases de validation croisée et pour chacune des classes d'événement possible est donné dans le tableau

2. On note que l'algorithme de clustering nous permet d'aboutir à un nombre de clusters entre 36 et 43 (entre 13 et 17 clusters pour la classe des séismes –EQ- et un nombre plus constant pour chacune des autres classes). Les performances obtenues à ce stade sont résumées dans la première ligne du tableau 3 en termes de moyenne et d'écart-types calculés sur les 5 bases de validation croisée en apprentissage et en test. On note que les taux de bien classés ne sont pas satisfaisant comparés aux taux obtenus avec des méthodes de type « boîtes noires » qui sont de l'ordre de 96% [10]. Nous avons donc complété notre modèle afin qu'il puisse prendre en compte la variable qualitative *date*.

TAB. 2 : Nombre de clusters par base de données (BD) de validation croisée et par type d'événements.

Nb clusters	BD1	BD2	BD3	BD4	BD5
EQ	14	17	15	16	13
RB	4	5	5	5	5
QB	12	12	11	12	11
ME	4	6	4	4	4
SR	3	3	3	3	3
Total	37	43	38	40	36

TAB. 3 : Moyennes (moy.) et écart-types (EC) des taux de bien classés (calculés sur les 5 bases de validation croisée) en apprentissage et en test.

Méthode	apprentissage		test	
	moy.	EC	moy.	EC
Clustering (sans <i>date</i> )	72,72	0,76	72,32	2,67
Clustering (avec <i>date</i> )	73,35	0,78	72,87	2,73
Clustering + EM (sans <i>date</i> )	91,47	0,46	91,03	0,64
Clustering + EM (avec <i>date</i> )	92,17	0,44	91,58	0,86
Clustering +EM +distance à la côte (avec <i>date</i> )	93,55	0,31	93,15	0,87

### 3.2 Introduction de la variable qualitative

Pour que le classifieur puisse prendre en compte la variable qualitative, nous avons estimé sur chaque cluster la probabilité de chacune de ses modalités selon la formule (4).

$$p_k(m|X) = \frac{\sum_{X_i \in c} 1_{X_i^{QL} = m} \mu_k(X_i)}{\sum_{X_i \in c} \mu_k(X_i)} \quad (4)$$

Cette estimation nous permet d'obtenir la probabilité de la modalité de la variable qualitative prise par l'individu  $i$  dans le  $k^{\text{ème}}$  cluster (formule 5), et le modèle écrit précédemment en (2) se transforme en le modèle (6).

$$p_k(X_i^{QL}) = \sum_{m=1}^{NbModes} p_k(m|X) 1_{X_i^{QL} = m} \quad (5)$$

$$Z(X_i) = \frac{\sum_{k=1}^{NbClust} z_k \rho_k \mu_k(X_i) p_k(X_i^{QL})}{\sum_{k=1}^{NbClust} \rho_k \mu_k(X_i) p_k(X_i^{QL})} \quad (6)$$

Les performances obtenues avec ce nouveau classifieur sont indiqués dans la deuxième ligne du tableau 3. Avec ce nouveau modèle, les performances sont peu améliorées. Dans le meilleur des cas (avec la deuxième base de validation croisée, en utilisant le modèle avec *date* et amélioration EM), nous avons obtenu 76,36% de bien classés en test.

La figure 1 permet de visualiser les clusters obtenus pour la classe QB (ellipses dont les valeurs des petits et grands axes sont les valeurs obtenues pour les écarts-types selon les dimensions latitude d'une part et longitude d'autre part) et l'étiquette des individus QB qui ont été mal classés par le classifieur généré par la deuxième base de validation croisée. On note que les clusters obtenus ne couvrent pas correctement l'espace géographique (les clusters se situent uniquement sur l'est de la France) et il y a une certaine superposition des projections des clusters sur le plan géographique. Ainsi est-il raisonnable d'envisager d'améliorer les positions des clusters ainsi que leur écart-type pour tenter de mieux recouvrir l'espace et diminuer le taux de mal classés.

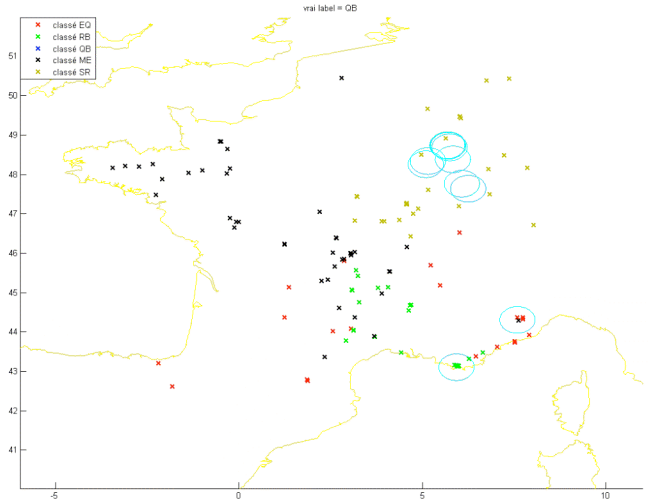


FIG. 1 : Position géographique des clusters obtenus pour les individus étiquetés QB et étiquette des individus mal classés par le FIS obtenu après l'étape de clustering et ajout de la variable *date* sur la deuxième base de validation croisée.

### 3.3 Amélioration des clusters par EM

Puisque l'algorithme de clustering choisi conserve des largeurs de clusters égales tout au long de l'algorithme,

les clusters trouvés ne sont pas assez performants (voir figure 1). Pour améliorer le classifieur obtenu, nous avons mis en œuvre l'algorithme EM (Expectation-Maximization) sur les paramètres du mélange de gaussiennes 0 pour chaque classe. Une description de cet algorithme est faite par Bilmes [1] pour un cas similaire. Avec cet algorithme, nous calculons itérativement (50 itérations) les nouveaux paramètres de chaque gaussienne  $(C_{k,l}, \sigma_{k,l})_{l=1..NbInQT}$  ainsi que leur poids  $\rho_k$ . Chaque cluster trouvé par cet algorithme représente une règle interprétable par les analystes.

Nous avons obtenu par cet algorithme de nouveaux paramètres pour les mélanges de gaussiennes obtenus sur l'espace engendré par les 4 variables quantitatives. Les performances associées sont indiquées dans la troisième ligne du tableau 3. Avec ces paramètres, nous notons une amélioration de plus de 18% et les taux de bien classés obtenus sur chaque base de validation croisée sont assez proches (l'écart-type sur les 5 taux de bien classés sont de 0,5). Nous avons pour finir introduit la variable *date* dans ce nouveau modèle. Les performances obtenues sont indiquées dans la quatrième ligne du tableau 3. Cet ajout nous permet d'améliorer de 0,5 points les performances, ce qui est peu satisfaisant. Dans le meilleur des cas (avec la deuxième base de validation croisée, en utilisant le modèle avec *date* et amélioration EM), nous avons obtenu 92,39% de bien classés en test.

La figure 2 permet de visualiser les clusters (ellipses dont les valeurs des petits et grands axes sont les valeurs obtenues pour les écarts-types selon les dimensions latitude d'une part et longitude d'autre part) obtenus pour la classe QB et l'étiquette des individus QB qui ont été mal classés par le meilleur classifieur généré.

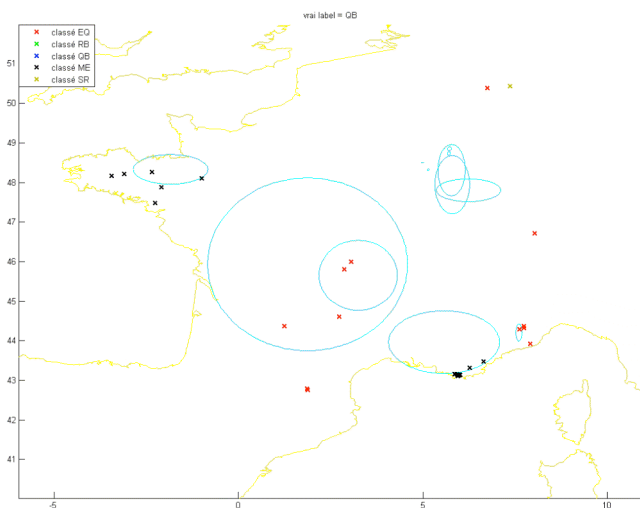


FIG. 2 : Position géographique des clusters obtenus pour les individus étiquetés QB et étiquette des individus mal classés par le FIS obtenu après l'étape d'amélioration EM et ajout de la variable *date* sur la deuxième base de validation croisée.

On note sur cette figure que les clusters sont géographiquement mieux répartis, que certains sont très spécialisés (leur projection sur le plan géographique est

une ellipse très petite) mais surtout que sur les 19 événements QB et qui sont étiquetés par le classifieur comme ME (explosions marines), 6 sont localisés dans des zones terrestres (Finistère). Cette constatation nous a conduits à introduire dans le modèle une nouvelle variable qui tienne compte de l'appartenance à une zone maritime ou terrestre.

### 3.4 Introduction d'une nouvelle variable liée à la connaissance experte

Cette variable est calculée en fonction des variables *latitude* et *longitude* de chaque événement sismique et de l'ensemble des coordonnées des points définissant le polygone « continent » (partie continentale de l'Europe comprise entre -6 et 11° de longitude et 40 et 52° de latitude) ainsi que les polygones définissant les 4 îles majeures : Corse, Sardaigne, Majorque et Grande-Bretagne (UK). La distance est signée. Les valeurs positives (resp. négatives) correspondent à des événements terrestres (resp. maritimes).

Le modèle s'écrit alors selon la formule (6) où  $dist(X_i)$  est la distance à la côte et  $\mu$  est une fonction d'appartenance de type sigmoïde spécifique à la classe définie par  $z_k$ . En fait, selon la classe codée par la règle  $k$ , la fonction d'appartenance considérée est :

- pour la classe EQ : la fonction constante 1
- pour la classe ME : une sigmoïde inverse
- pour toutes les autres classes : une sigmoïde.

$$Z(X_i) = \frac{\sum_{k=1}^{NbClust} z_k \rho_k \mu_k(X_i) p_k(X_i^{QL}) \mu(dist(X_i))}{\sum_{k=1}^{NbClust} \rho_k \mu_k(X_i) p_k(X_i^{QL}) \mu(dist(X_i))} \quad (6)$$

On note que cette distance n'est pas apprise mais intervient dans le classement d'un événement sismique. Le paramètre de raideur de la sigmoïde peut-être précisé lors d'un dialogue avec un analyste. Il a été fixé pour le moment à 30 de manière arbitraire. La courbe bleue a pour équation (7) et la courbe verte a pour équation (8).

$$y = \frac{1}{1 + \exp(-30 * x)} \quad (7)$$

$$y = \frac{1}{1 + \exp(30 * x)} \quad (8)$$

Les performances obtenues en incluant dans le précédent système d'inférence flou la nouvelle variable *distance à la côte* sont indiquées dans la dernière ligne du tableau 3. On note que l'introduction de cette variable permet un gain moyen de 1,5% sur les taux de bien classés.

La figure 3 permet de visualiser les clusters obtenus pour la classe QB et l'étiquette des individus QB qui ont été mal classés par ce nouveau classifieur. La visualisation des individus mal classés dans le plan latitude-longitude montrent que les individus QB étiquetés ME à tort ne sont désormais plus situés dans des zones terrestres.

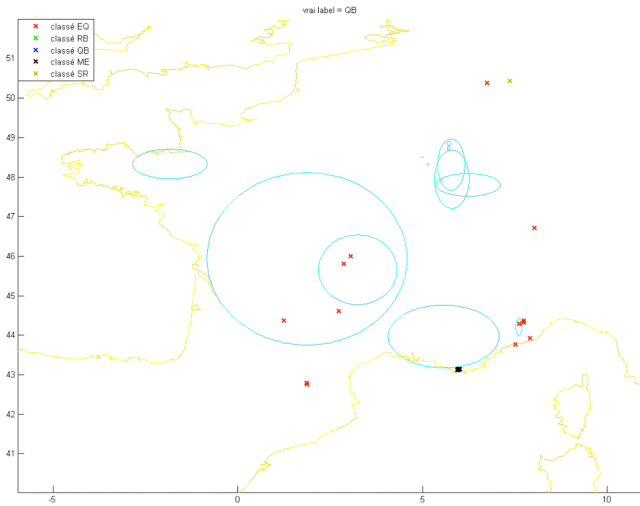


FIG. 3 : Position géographique des clusters obtenus pour les individus étiquetés QB et étiquette des individus mal classés par le FIS obtenu après l'étape d'amélioration EM, ajout de la variable *date* et *distance à la côte* sur la deuxième base de validation croisée.

#### 4. Interface graphique proposée pour le système d'inférence flou

Les systèmes d'inférence flous ont l'avantage par ailleurs de fournir des interfaces graphiques retranscrivant aisément certaines des règles de type « Si-alors » utilisées par les analystes. Pour un exemple *EX* particulier, les règles présentées à l'analyste sont celles dont l'activation dépasse 0.005. L'activation est définie par la formule (9).

$$\frac{\mu_k(EX)p_k(EX^{QL})\mu(dist(EX))}{\sum_{k=1}^{NbClust} \mu_k(EX)p_k(EX^{QL})\mu(dist(EX))} \quad (9)$$

Avec ce choix, 95% des exemples de la base de données activent au plus 6 règles et 5% entre 7 et 10 règles sur les 43 règles qui composent notre meilleur système (voir table 2). La figure 4 présente l'interface mise en place. Pour chacune des règles (en ligne) nous avons, de gauche à droite, son poids, l'ellipse formée par le produit des gaussiennes selon la *latitude* et la *longitude* (les paramètres de l'ellipse sont directement liés aux écart-types de ces gaussiennes), les gaussiennes selon l'*heure* et la *magnitude*, la probabilité de chaque modalité de la variable *date*. Dans chacun de ces graphiques, la position de *EX* est matérialisée soit par un point, une ligne ou un triangle vert. Plus leur position sera proche du centre des gaussiennes plus la gaussienne sera activée (et la quantité de rouge importante) et donc plus *EX* aura des chances d'avoir été engendré par la règle (adéquation). L'activation de la règle par *EX* est représentée par une jauge dans le dernier graphique de la ligne. Chaque règle permet de conclure à un seul type d'événement (cf. graphique *CLASS*). Le dernier graphique en bas représente l'agrégation des sorties de chaque règle comme somme pondérée des sorties par le degré d'activation de la règle. La longueur de chaque bâton nous donne la probabilité pour que *EX* soit un événement *EQ*, *RB*, *QB*, *ME* ou *SR*. Elles transcrivent les valeurs

calculées par (6). Ici, le système conclue à un séisme (*EQ*) avec une probabilité de 0,94.

Par ailleurs, avec cette interface, les analystes visualisent l'adéquation de l'événement à chacune des règles qui composent le système et sont en mesure de pouvoir approuver ou non chacune des règles utilisées ainsi que la conclusion du système. Cette interface nous permet de répondre à l'exigence d'intelligibilité qui nous avait été demandée.

#### 5. Conclusion

Le système proposé permet d'apprendre rapidement un nombre réduit de règles en respectant l'espace d'entrée hybride constitué de variables quantitatives et qualitatives. Par ailleurs, le système peut être amélioré en injectant de la connaissance experte. Ainsi, nous obtenons un taux d'événements bien classés de 94%. Ce taux est satisfaisant car similaire à ceux obtenus avec des méthodes de types boîtes noires [10]. Enfin, nous avons développé une interface graphique afin de présenter à l'analyste les principales règles mises en jeu dans le classement d'un événement particulier. Cette interface, qui répond à l'exigence d'intelligibilité, a été acceptée par les analystes qui apprécient en outre son aspect synthétique. Cette interface est désormais passée en phase opérationnelle au CEA DASE.

#### Références

- [1] J. Bilmes. A Gentle Tutorial of the EM Algorithm and its applications to Parameter Estimation for Gaussian Mixture and Hidden Markov Models, *International Computer Science Institute*, 1998.
- [2] C. Bishop. *Neural Networks for Pattern Recognition*, Oxford: Clarenton Press, 1995.
- [3] L. Breiman, J.H. Freiman, R.A. Olsen and C.J. Stone. *Classification and Regression Trees*, Chapman and Hall, 1984.
- [4] S. Chiu. Fuzzy Model Identification Based on Cluster Estimation, *Journal of Intelligent and Fuzzy Systems*, Volume 2, pp.267-278, 1994.
- [5] L. Cornez. Discrimination automatique à base de connaissances expertes d'événements sismiques (Mémoire de thèse). SUPAERO, 2007.
- [6] F. Gravot, J.-D. Muller et S. Muller. Efficient neuro-fuzzy rule generation by parametrized gradient descent for seismic event discrimination. International Joint Conference on Neural Networks (IJCNN-99), p. 4294-4299, (Washington, USA), 10th july - 16th july 1999.
- [7] J-S.R. Jang, C.T. Sun and E. Mizutani. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*, Prentice Hall Upper Saddle River, NJ, 1997.

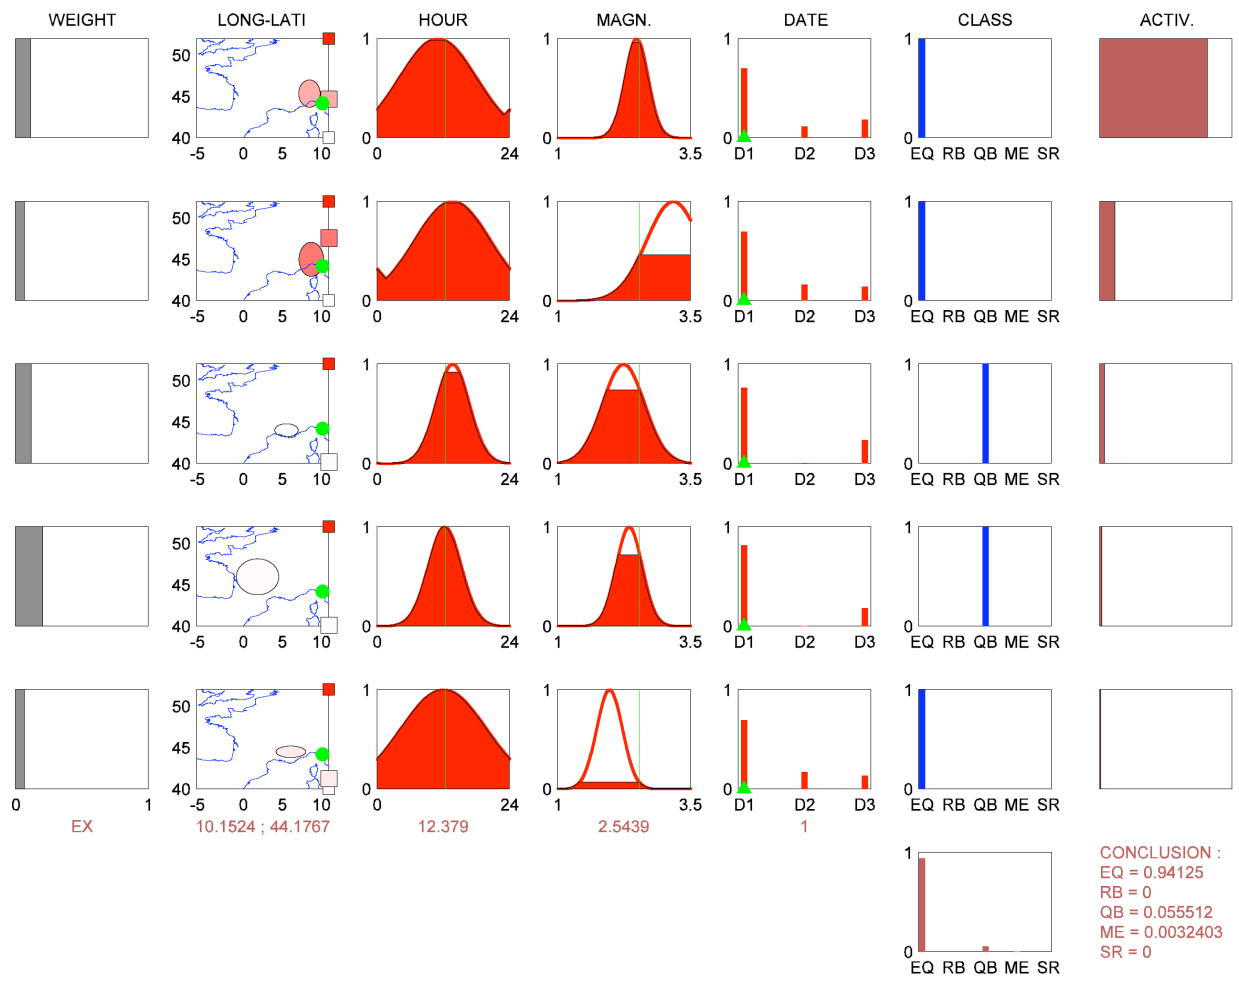


FIG. 4 : Interface graphique correspondant au FIS proposé.

- [8] M. Jordan and L. Xu., Convergence Results for the EM Approach to Mixtures of Experts Architectures, *Massachusetts Institute of Technology*, 1993.
- [9] C. Marsala. *Apprentissage inductif en présence de données imprécises : construction et utilisation d'arbres de décision flous*. Université Paris 6, 1998.
- [10] D. Mercier, P. Gaillard, M. Aupetit, C. Maillard, R. Quach et J.-D. Muller. How to help seismic analysts to verify the French seismic bulletin? *Engineering Applications of Artificial Intelligence*, Elsevier Science Ltd., vol. 19, pp. 797-807, 2006.