

# Apprentissage d'ensemble d'opérateurs de projection orthogonale pour la détection de nouveauté

Fatma Hamdi\*, Younès Bennani\*

\* LIPN-UMR 7030, Université Paris 13,  
99, av. J-B Clément, 93430 Villetaneuse, France,  
Prénom.Nom@lipn.univ-paris13.fr

**Résumé.** Dans ce papier, nous proposons une approche de détection de nouveauté fondée sur les opérateurs de projection orthogonale et l'idée de double bootstrap (bi- bootstrap). Notre approche appelée Random Subspace Novelty Detection Filter (RS-NDF), combine une technique de rééchantillonnage et l'idée d'apprentissage d'ensemble. RS-NDF est un ensemble de filtres NDF (Novelty Detection Filter), induits à partir d'échantillons bootstrap des données d'apprentissage, en utilisant une sélection aléatoire des variables pour l'apprentissage des filtres. RS-NDF utilise donc un double bootstrap, c'est à dire un rééchantillonnage avec remise sur les observations et un rééchantillonnage sans remise sur les variables. La prédiction est faite par l'agrégation des prédictions de l'ensemble des filtres. RS-NDF présente généralement une importante amélioration des performances par rapport au modèle de base NDF unique. Grâce à son algorithme d'apprentissage en ligne, l'approche RS-NDF est également en mesure de suivre les changements dans les données au fil du temps. Plusieurs métriques de performance montrent que l'approche proposée est plus efficace, robuste et offre de meilleures performances pour la détection de nouveauté comparée aux autres techniques existantes.

## 1 Introduction

Plusieurs travaux de recherche ont été proposés pour le problème de la détection de nouveauté (Markou et Singh, 2003a,b) et (Markou et Singh, 2003c) avec une grande variété d'applications et méthodes. Le but essentiel de la détection de nouveauté consiste à apprendre un modèle ou un ensemble de modèles sur des données disponibles, et l'utiliser après pour identifier les données nouvelles (nouveauté). Les applications typiques de ce problème sont la détection des fraudes, la maintenance préventive, la détection des intrusions dans le réseau, le diagnostic de maladies rares et de nombreux autres domaines. La détection de nouveauté est particulièrement utile quand une classe importante est sous représentée dans les données. L'exemple typique de ce problème est la détection des fraudes où il peut y avoir un intervalle de plusieurs heures entre deux transactions frauduleuses. On distingue trois grandes familles d'approches de détection de nouveauté :

- Les méthodes qui déterminent la nouveauté sans aucune connaissance préalable sur les données. Il s'agit essentiellement d'approches d'apprentissage analogues à la classifica-

## Détection de nouveauté

tion non supervisée. Ces approches traitent les données comme une distribution statique, et cherchent à identifier les points les plus éloignés. Ces points sont considérés comme des valeurs potentiellement aberrantes.

- Un deuxième type de méthodes consiste à modéliser à la fois les données normales et la nouveauté. Ces approches sont analogues à la classification supervisée et nécessitent des données pré-étiquetées.
- Et finalement des méthodes de détection de nouveauté analogues à une tâche de classification semi-supervisée. Le but essentiel est de repérer la nouveauté apportée par des données encore inconnues, en exploitant la connaissance extraite à partir d'un ensemble de données de référence (données d'apprentissage). Les données de référence se limitent à des exemples positifs des données normales ou familières, du fait de la difficulté, voire l'impossibilité dans certains cas, d'identifier a priori ce qui constituerait une nouveauté par rapport aux données déjà connues (ce qui amène au problème de la classification à partir d'une seule classe).

Dans cet article nous proposons une nouvelle technique de détection de nouveauté fondée sur les opérateurs de projection orthogonale utilisées par Kohonen et Oja dans le modèle NDF (Kohonen et Oja, 1976), l'idée du bootstrap ainsi que le paradigme de l'apprentissage ensembliste. Notre approche appelée Random subspace novelty detection filter (*RS - NDF*) est un ensemble de *NDF*, induit à partir d'échantillons bootstrap des données d'apprentissage, en utilisant la sélection aléatoire au niveau des variables. La prédiction est faite en agrégeant les prévisions de l'ensemble. Une caractéristique intéressante du modèle NDF est sa simple mise en œuvre par une architecture de réseau de neurones (Kohonen et Oja, 1976) ainsi que son apprentissage adaptatif et sa robustesse au bruit. Cet article est organisé comme suit : la section 2 introduit les concepts de base de notre modèle Random Subspace Novelty Detection Filter. La section 3 décrit les bases de données de validation et le protocole expérimental ainsi que les résultats obtenus. Une conclusion est présentée dans la section 4.

## 2 Le principe de notre approche : RS-NDF

### 2.1 Le filtre détecteur de nouveauté de Kohonen et Oja

En 1976, Kohonen et Oja (Kohonen et Oja, 1976) ont proposé un filtre détecteur de nouveauté (*NDF*). C'est un système linéaire adaptatif qui agit, après son apprentissage sur des données de référence, comme un opérateur de projection dans un espace vectoriel orthogonal à l'espace vectoriel engendré par les données de référence. Le modèle *NDF* laisse passer seulement les propriétés nouvelles d'une donnée par rapport à l'ensemble de données de référence déjà apprises ; les propriétés sont dites nouvelles si elles ne sont pas représentées dans les données de référence. Une autre description du filtre est donnée dans (Kohonen et Oja, 1993). Le filtre détecteur de nouveauté peut être implémenté par un réseau récurrent de  $d$  neurones élémentaires, étroitement connectés en forme de boucles rétroactives, ou feedback (Figure 1).

La sortie de chaque neurone est calculée comme une combinaison linéaire de l'entrée  $x_i$  et du feedback qu'il reçoit de la sortie. L'opérateur de transfert est décrit par l'équation suivante :

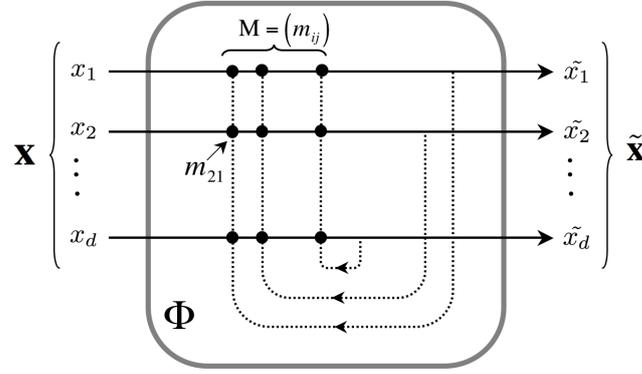


FIG. 1 – L'architecture neuronale du modèle de filtre détecteur de nouveauté NDF

$$\tilde{x}_i = x_i + \sum_j m_{ij} \tilde{x}_j \quad (1)$$

L'équation précédente peut s'écrire sous forme matricielle comme suit :

$$\tilde{\mathbf{x}} = \mathbf{x} + \mathbf{M}\tilde{\mathbf{x}} \quad (2)$$

Les poids des connexions rétroactives  $m_{ij}$  caractérisent l'état interne du réseau. Ils sont initialisés à zéro et, ensuite, mis à jour après la présentation de chaque donnée en entrée du réseau selon une règle d'apprentissage de type anti-Hebbian :

$$\frac{d\mathbf{M}}{dt} = -\alpha \tilde{\mathbf{x}}\tilde{\mathbf{x}}^T \quad (3)$$

où  $\alpha$  est un coefficient positif qui peut être modifié de manière adaptative au cours de l'apprentissage.

La fonction du transfert du réseau  $\Phi \in \mathbb{R}^{d \times d}$  est définie par :

$$\tilde{\mathbf{x}} = (\mathbf{I} - \mathbf{M})^{-1} \mathbf{x} = \Phi \mathbf{x} \quad (4)$$

où  $I$  représente la matrice identité.

L'équation différentiel de  $\Phi$  est obtenue de la manière suivante :

$$\begin{aligned} \frac{d\Phi^{-1}}{dt} &= -\Phi^{-1} \frac{d\Phi}{dt} \Phi^{-1} = -\frac{d\mathbf{M}}{dt} \\ \frac{d\Phi}{dt} &= -\alpha \Phi^2 \mathbf{x}\mathbf{x}^T \Phi^T \Phi \end{aligned} \quad (5)$$

Le théorème de Greville (Greville, 1960) permet de donner une expression récursive pour estimer la fonction de transfert du réseau de la manière suivante :

$$\Phi_k = \Phi_{k-1} - \frac{\tilde{\mathbf{x}}_k \tilde{\mathbf{x}}_k^T}{\|\tilde{\mathbf{x}}_k\|^2} \quad (6)$$

## Détection de nouveauté

où  $\mathbf{x}_k = [x_1, x_2, \dots, x_d]^T$  est un vecteur de la matrice des données de référence, chaque  $x_i$  est un vecteur de  $n$  diensions. Pendant la phase d'apprentissage, Le modèle *NDF* s'habitue aux données présentées en entrée. Une fois l'apprentissage terminé, si une des donnée de références ou une de leurs combinaisons linéaires est présentée à l'entrée du modèle, la sortie correspondante sera nulle. D'autre part, si une donnée n'appartenant pas à l'espace formé par les données de référence est choisie comme entrée, la sortie correspondante ne sera pas nulle et elle peut être vue comme représentative des variables nouvelles extraites à partir de la donnée d'entrée vis-à-vis des données de référence qui ont été déjà apprises.

Une extension du modèle de base NDF proposée par (Kassab et al., 2005), (Kassab et Frederic, 2009) est le modèle d'apprentissage incrémental ILoNDF. Cette extension a été guidée par des réflexions sur le problème du modèle NDF. L'adaptation qui a été envisagée est directement liée au fait que l'apprentissage du modèle est guidé uniquement par la nouveauté : L'adaptation de l'état interne du modèle NDF décrite par la formule précédente ne considère que les variables représentant la nouveauté qu'apportent les données d'entrée. Donc pour faire participer toutes les variables des données d'entrée au processus d'apprentissage, la stratégie adaptée, consiste à introduire la matrice identité à chaque étape de l'apprentissage et de projeter les données d'entrée à la fois sur la matrice identité et sur la matrice du filtre. La nouvelle règle d'apprentissage s'écrit sous la forme suivante :

$$\Phi_k = \mathbf{I} + \Phi_{k-1} - \frac{\tilde{\mathbf{x}}_k \tilde{\mathbf{x}}_k^T}{\|\tilde{\mathbf{x}}_k\|^2} \quad (7)$$

Où  $\tilde{\mathbf{x}}_k = (\mathbf{I} + \Phi_{k-1})\mathbf{x}_k$  et  $\Phi_0$  est une matrice nulle.

Dans notre travail, nous avons utilisé cette nouvelle règle d'apprentissage. Pour le problème de détection de nouveauté, deux proportions peuvent être calculées :

- *La proportion de nouveauté* : C'est une mesure qui permet de quantifier la nouveauté apportée par une donnée par rapport à un ensemble de données déjà apprises par le filtre.

$$N_{\mathbf{x}_i} = \frac{\|\tilde{\mathbf{x}}_i\|}{L \times \|\mathbf{x}_i\|} \quad (8)$$

où  $L$  est le nombre d'exemples utilisés pour l'apprentissage.

- *La proportion d'habitation* : C'est un indicateur de similarité d'un exemple vis-à-vis des données précédemment apprises :

$$H_{\mathbf{x}_i} = 1 - N_{\mathbf{x}_i} \quad (9)$$

Cette proportion pourrait être considérée comme le score de classification d'un exemple  $x_i$ . Elle indique la probabilité que  $x_i$  appartient à la nouvelle classe. Il est également possible de calculer un vecteur  $P_\Phi$  qui représente les exemples utilisés pour l'apprentissage. Ainsi, le score de classification des données d'entrée peut être calculé de la façon suivante :

$$P_\Phi = \sum_{f \in F} H_f \vec{u}_f \quad (10)$$

où  $\vec{u}_f$  est le vecteur unité associé à chaque variable  $f$  dans  $F$  (l'ensemble des variables) et  $H_f$  est la proportion d'habitude d'une variable  $f$  calculée comme suit :

$$H_f = 1 - \frac{\|\Phi \vec{u}_f\|}{n \times \|\vec{u}_f\|} \quad (11)$$

Le vecteur  $P_\Phi$  est défini comme un vecteur de poids. Les composantes de  $P_\Phi$  représentent la proportion d'habitude de chaque variable dans l'espace des données.

## 2.2 L'algorithme RS-NDF

Notre approche est basée sur la coopération d'un ensemble de  $NDF$  calculés sur plusieurs échantillons. Ces derniers sont obtenus par un double bootstrap (Un tirage aléatoire avec remise sur les données et un tirage aléatoire sans remise pour les variables). La prédiction est faite en agrégeant les prévisions de l'ensemble. L'idée de base de notre algorithme  $RS - NDF$  combine donc les opérateurs de projection orthogonale utilisées par Kohonen et Oja dans le modèle NDF (Kohonen et Oja, 1976), la technique de bootstrap et le principe de l'apprentissage d'ensemble.

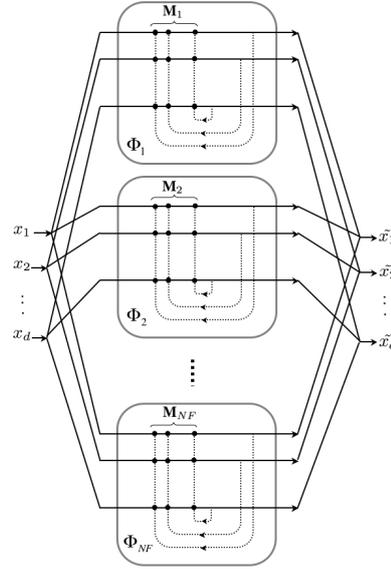


FIG. 2 – L'architecture neuronale du modèle RS-NDF

Pour déterminer le seuil de détection de chaque filtre, nous avons appliqué les règles suivantes (Kassab et al., 2005), (Kassab et Frederic, 2009) :

- Les scores (sorties du filtre) attribués aux données d'apprentissage peuvent être utilisés comme un bon indicateur des scores de données qui peuvent être positives et qui sont faciles à détecter car elles sont fortement similaires aux données d'apprentissage. Par

## Détection de nouveauté

conséquent, la moyenne de ces scores peut être admise comme une limite supérieure pour le seuil de détection.

- Les scores attribués aux données disponibles pour l'apprentissage avant leur utilisation, peuvent être utilisés comme un bon indicateur des scores de données qui sont positives mais qui sont moins faciles à détecter. Par conséquent, la moyenne de ces scores peut être admise comme une limite inférieure pour le seuil de détection.

L'algorithme d'apprentissage *RS – NDF* est le suivant :

---

**Algorithme 1** : Random Subspace Novelty Detection Filter

---

**Entrées :**

$sD = x_1, x_2, \dots, x_L$  ensemble de données d'apprentissage.

$sT = x_1, x_2, \dots, x_M$  ensemble de données de test.

$F = f_1, f_2, \dots, f_n$  ensemble de variables.

$NF$  nombre de filtres.

$\Phi_0$  la matrice initial.

**Sorties :**

$NF$  filtres ( $\Phi_i$ ).

$NF$  vecteurs qui représentent les classes cibles ( $Pv_i$ ).

$D$  matrice de détection de nouveauté.

**Begin**

**for**  $i = 1$  jusqu'à  $NF$  **do**

    Un tirage aléatoire avec remise sur les données d'apprentissage.

    Un tirage aléatoire sans remise sur les variables.

    Appliquer RS-NDF  $\Phi_i$  avec les variables choisies aléatoirement (formule 7)

**end for**

**for**  $i = 1$  jusqu'à  $M$  **do**

**for**  $k = 1$  jusqu'à  $NF$  **do**

        Calculer la proportion d'habituation  $H_{\mathbf{x}_i}$  ( formule 9)

        pour  $\mathbf{x}_i \in sT$  en utilisant le filtre  $\Phi_k$ .

**end for**

    Agréger les prédictions de l'ensemble des filtres et mettre la prédiction finale dans  $D$ .

**end for**

**End**

---

## 3 Validation

### 3.1 Description des base de données

Pour démontrer l'efficacité de la méthode proposée, nous l'avons testé sur huit jeux de données en utilisant la validation croisée (10 fois). La description de données est résumée dans le tableau 1. Les différents jeux de données (Asuncion et Newman, 2007) sont disponibles sur <http://archive.ics.uci.edu/ml/datasets.html>.

Pour notre expérimentation, nous avons adapté les différentes bases de données utilisées au contexte de la détection de nouveauté et l'apprentissage à partir d'une seule classe. Une classe a été choisie aléatoirement dans chaque base de données. Cette classe a été considérée comme étant la classe nouveauté. Les autres classes restantes sont fusionnées pour obtenir la classe normale de l'apprentissage.

TAB. 1 – Description des bases

Base de données	Dimension	Taille	Taille de la classe nouvelle
Glass	9	214	70
Ionosphere	34	351	225
Oil	48	937	41
Spectf	44	187	15
Waveform	21	5000	1647
WDBC	30	569	212
Wine	13	178	59
Yeast	8	1484	244

### 3.2 Les mesures de performances et le protocole expérimental

Pour évaluer notre approche, nous avons calculé plusieurs métriques de performance. La plupart de ces dernières se concentrent sur la capacité des classifieurs à identifier correctement les observations de chaque classes. Ces différentes métriques sont obtenues à partir d'une matrice de confusion et qui sont les suivantes :  $Acc-$ ,  $Acc+$ ,  $Precision$ ,  $Fmesure$ ,  $G-mean$  et  $AUC$ . Le tableau 2 présente la matrice de confusion pour la classification binaire, où  $VP$  sont les vrais positifs,  $FP$  les faux positifs,  $FN$  les faux négatifs, et  $VN$  les vrais négatifs.

TAB. 2 – Matrice de confusion pour la classification binaire.

	Classe Positive Prédite	Classe Negative Prédite
Classe Positive Réelle	VP	FN
Class Negative Réelle	FP	VN

$$TauxdeVraisNgative(Acc-) = \frac{VN}{VN + FP} \quad (12)$$

$$TauxdeVraispositive(Acc+)(Rappel) = \frac{VP}{VP + FN} \quad (13)$$

$$Precision = \frac{VP}{VP + FP} \quad (14)$$

$$Fmesure = \frac{2 * Precision * Rappel}{Precision + Rappel} \quad (15)$$

$$G-mean = (Acc- * Acc+)^{1/2} \quad (16)$$

Nous avons aussi utilisé l'aire sous la courbe ROC (AUC) (Peterson, 1997). La courbe ROC est une représentation graphique du compromis entre le taux de faux négatifs et le taux de faux

## Détection de nouveauté

positifs. Il existe plusieurs méthodes pour estimer l'aire sous la courbe ROC. Dans le cas de la classification binaire, le  $AUC$  est définie comme suit :

$$AUC = \frac{Acc- + Acc+}{2} \quad (17)$$

Nous avons utilisé toutes ces mesures pour comparer notre méthode  $RS - NDF$  avec des approches couramment utilisées pour le problème d'apprentissage à partir d'une seule classe pour la détection de nouveauté. Les résultats de ces différents indicateurs de performance sont obtenus suite à une validation croisée.

Les algorithmes sélectionnés sont : L'analyse en composantes principales ( $ACP$ ) (Jolliffe, 1986), les Séparateurs à Vastes Marges ( $SVM$ ) (Scholkopf et al., 1999), Le Perceptron Multi-couches auto-associatif ( $MLP$ ) (Rumelhart et al., 1986) et le modèle de base  $NDF$ .

### 3.3 Résultats

Pour chaque base de données, les cinq approches ont été testées et leurs résultats ont été évalués en termes des différentes mesures de performances citées. Le tableau 3 montre les performances des différents algorithmes sur la base  $Vin$ .

TAB. 3 – Comparaison des Performances sur la base de données  $Vin$

	$Acc-$	$Acc+$ ( <i>Rappel</i> )	$Prec$	$F-$ <i>measure</i>	$AUC_b$	$G-$ <i>mean</i>
MLP	0,78	0,68	0,83	0,81	0,73	0,73
ACP	0,60	0,69	0,80	0,68	0,65	0,64
SVM-1C	0,68	0,76	0,81	0,73	0,72	0,71
NDF	0,84	0,78	0,88	0,86	0,81	0,81
RS-NDF	<b>0,87</b>	<b>0,85</b>	<b>0,92</b>	<b>0,89</b>	<b>0,86</b>	<b>0,86</b>

À partir des résultats obtenus, notre approche  $RS - NDF$  montre un fonctionnement meilleur par rapport à toutes les autres méthodes :  $MLP$ ,  $ACP$ ,  $SVM - 1C$  et  $NDF$ . Cette amélioration a touché les différents critères d'évaluation.

Les tableaux 4 et 5 montrent respectivement les performances de  $RS - NDF$  et les différents algorithmes utilisés sur la base  $Ionosphere$  et la base  $Glass$ . Ces résultats montrent encore une fois que notre approche dépasse le  $MLP$ ,  $ACP$  et  $SVM - 1C$  avec toutes les mesures de performances utilisées seulement pour l' $Acc-$ , notre approche donne un résultat légèrement inférieur à celui de  $NDF$  pour la base  $ionosphere$  et à  $MLP$ ,  $SVM - 1C$  et  $ACP$  pour la base  $Glass$ .

TAB. 4 – Comparaison des Performances sur la base de données  $Ionosphere$

	$Acc-$	$Acc+$ ( <i>Rappel</i> )	$Prec$	$F-$ <i>measure</i>	$AUC_b$	$G-$ <i>mean</i>
MLP	0,63	0,64	0,50	0,55	0,64	0,64
ACP	0,64	0,55	0,45	0,52	0,59	0,59
1-SVM	0,66	0,56	0,45	0,54	0,61	0,60
NDF	<b>0,90</b>	0,61	0,57	0,70	0,76	0,74
RS-NDF	0,87	<b>0,74</b>	<b>0,65</b>	<b>0,74</b>	<b>0,80</b>	<b>0,80</b>

TAB. 5 – Comparaison des Performances sur la base de données Glass

	<i>Acc-</i>	<i>Acc+</i> ( <i>Rappel</i> )	<i>Prec</i>	<i>F-</i> <i>measure</i>	<i>AUC<sub>b</sub></i>	<i>G-</i> <i>mean</i>
MLP	<b>0,96</b>	0,49	0,49	0,65	0,73	0,69
ACP	<b>0,96</b>	0,43	0,46	0,62	0,69	0,64
1-SVM	0,89	0,54	0,80	0,84	0,72	0,69
NDF	0,82	0,69	0,84	0,83	0,75	0,75
RS-NDF	0,87	<b>0,84</b>	<b>0,93</b>	<b>0,90</b>	<b>0,86</b>	<b>0,85</b>

Dans ces tableaux, nous avons montré l'amélioration apportée par notre approche *RS – NDF* par rapport aux méthodes utilisées. Les résultats sont également confirmés par une inspection visuelle. En effet les figures 3 et 4 représentent les performances obtenues (avec les 6 critères d'évaluation) sur les 8 bases de données testées. En regardant les graphiques des quatre radars (figure 3), certaines conclusions peuvent être tirées. En général *RS – NDF* donne de meilleurs résultats par rapport aux autres méthodes et avec tous les critères de performances utilisés. Dans le pire des cas, les résultats obtenus par *NDF*, *ACP*, *MLP* et *SVM – 1C* sont légèrement supérieurs aux résultats de notre approche. Pour la base de données *Waveform*, *RS – NDF* dépasse les autres algorithmes en utilisant la *Precision*, *F – mesure*, *G – mean* et *AUC*. La *precision* est définie comme le pourcentage d'exemples correctement étiquetés comme positif. Nous pouvons donc conclure que notre approche classe les exemples positifs mieux que les autres méthodes. Aussi pour les critères *G – mean*, et *AUC*, *RS – NDF* donne de meilleurs résultats comparé à *NDF*, *MLP*, *ACP* et *SVM – 1C*.

Par ailleurs, les graphiques des radars des bases de données *Vin*, *Yeast*, *WDBC* et *Spectf* (figure 5) confirment les bonnes performances de notre approche *RS – NDF*. En effet les valeurs de *AUC* montrent que notre approche est en mesure de donner des résultats intéressants. Cette mesure de performance est une représentation quantitative de la courbe ROC. La courbe ROC est largement utilisée pour l'évaluation des classificateurs, c'est un outil de visualisation, organisation et sélection des algorithmes tout en se basant sur le compromis entre les vrais positifs et les faux négatifs.

La figure 4 montre le radar de la mesure *Acc+* qui représente la capacité des modèles à détecter la classe nouveauté. Nous avons choisi cette métrique pour montrer la bonne capacité de *RS – NDF* à détecter la classe nouveauté. Ainsi, nous pouvons voir clairement que notre approche donne de meilleurs résultats comparé aux autres méthodes.

## 4 Conclusion

Dans cet article, nous avons proposé une nouvelle approche adaptée au problème de l'apprentissage à partir d'une seule classe pour des applications de détection de nouveauté. L'approche est basée sur les opérateurs de projection orthogonale, la technique de bootstrap et le principe de l'apprentissage d'ensemble. L'approche proposée *RS – NDF* est un ensemble de *NDF*, induit à partir d'échantillons bootstrap sur les données et une sélection aléatoire des variables dans le processus d'induction du modèle de base *NDF*. La prédiction a été faite en agrégeant les prévisions de l'ensemble. Les mesures de performance telles que la précision, le rappel, le taux de faux positifs, le taux de faux négatifs, *F-mesure* et l'*AUC* sont calculées à travers une validation croisée sur des bases de données accessibles au public. Des amélio-

## Détection de nouveauté

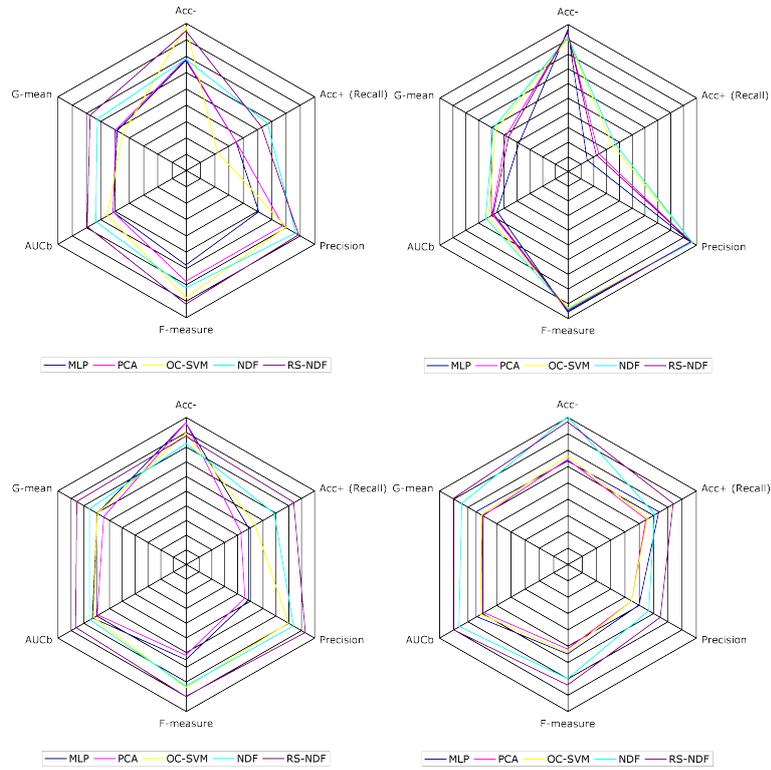


FIG. 3 – Radars des bases : Waveform, Oil, Glass et Ionosphere

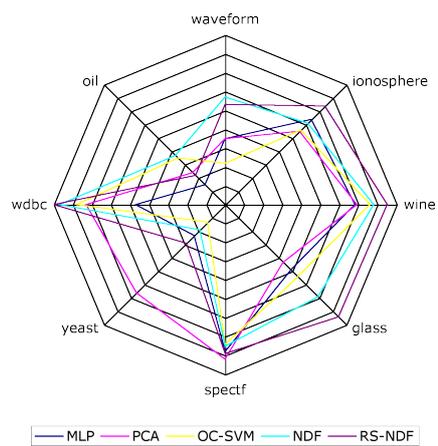


FIG. 4 – La mesure Acc+ sur les différentes base de données

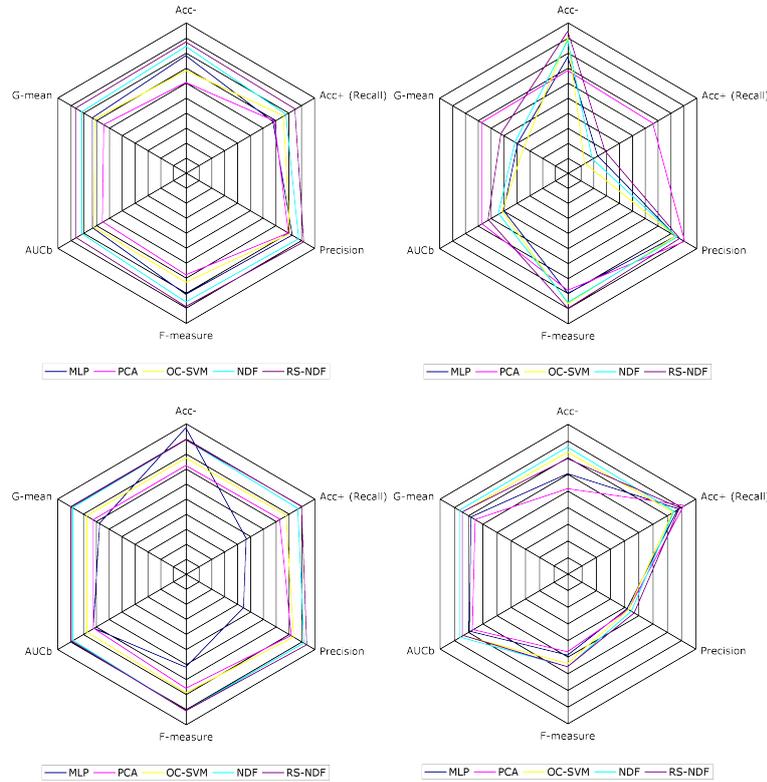


FIG. 5 – Radars des bases : Vin, Yeast, WDBC et Spectf

rations significatives dans la précision ont été obtenues en utilisant notre méthode. L'approche RS-NDF présente généralement une amélioration substantielle des performances par rapport aux algorithmes existants. Grâce à un algorithme d'apprentissage en ligne, l'approche RS-NDF est également en mesure de suivre les changements dans les données au fil du temps.

## Références

- Asuncion, A. et D. J. Newman (2007). Uci : Machine learning repository.
- Greville, T. N. E. (1960). Some applications of the pseudoinverse of a matrix. *SIAM Rev*, 15–22.
- Jolliffe, I. (1986). *Principal Component Analysis*. Springer Verlag.
- Kassab, R. et A. Frederic (2009). Incremental data-driven learning of a novelty detection model for one-class classification problem with application to high-dimensional noisy data. *Machine Learning*.

## Détection de nouveauté

- Kassab, R., L. Jean-Charle, et N. Emmanuel. (2005). Novelty detection for modeling users profile. *The 18th International FLAIRS Conference*.
- Kohonen, T. et E. Oja (1976). Fast adaptative formation of orthogonalizing filters and associative memory in reccurent networks of neuron-like elements. *Biological Cybernetics 21*, 85 – 95.
- Kohonen, T. et E. Oja (1993). Self-organization and associative memory. *3rd ed. Springer, Berlin*.
- Markou, M. et S. Singh (2003a). Novelty detection : a review - part 1 : statistical approaches. *Signal Processing 83*, 2481–2497.
- Markou, M. et S. Singh (2003b). Novelty detection : a review - part 2 : neural network based approaches. *Signal Processing 83*, 2499 – 2521.
- Markou, M. et S. Singh (2003c). Novelty detection in learning systems. *Neural Computing 39*, 157 –195.
- Peterson, B. A. (1997). the use of the area under the roc curve in the evaluation of machine learning algorithms. *Pattern Recogn*, 1145–1159.
- Rumelhart, D. E., G. E. Hinton, et et R. J Williams (1986). Learning internal representation by error propagation. *Parallel Distributed Processing : Explorations in the microstructures of cognition 65*, 318–362.
- Scholkopf, B., J. Platt, J. Shawe-Taylor, A. J. Smola, et R. C. Williamson (1999). Estimating the support of a high-dimensional distribution. *Neural Computation*, 318– 362.

## Summary

In this paper we propose a novelty detection framework based on the orthogonal projection operators and the bootstrap idea. Our approach called Random Subspace Novelty Detection Filter (*RS-NDF*) combines the sampling technique and the ensemble idea. *RS-NDF* is an ensemble of *NDF*, induced from bootstrap samples of the training data, using random feature selection in the *NDF* induction process. Prediction is made by aggregating the predictions of the ensemble. *RS-NDF* generally exhibits a substantial performance improvement over the single *NDF*. Thanks to an online learning algorithm, the *RS-NDF* approach is also able to track changes in data over time. The *RS-NDF* method is compared to single *NDF* and other novelty detection methods with tenfold cross-validation experiments on publicly available datasets, where the method superiority is demonstrated. Performance metrics such as precision and recall, false positive rate and false negative rate, F-measure, AUC and G-mean are computed. The proposed approach is shown to improve the prediction accuracy of the novelty detection, and have favorable performance compared to the existing algorithms.