

Soumis le : 07 Juillet 2010
 Forme révisée acceptée le : 07 Juillet 2011
 Email de l'auteur correspondant :
 inyac@yahoo.fr

Approche tribale des SVMs pour la classification des images satellitaires

FIZAZI Hadria*, BENHABIB Wafaa*

*Laboratoire Signal Image Parole, Equipe Imagerie et Decision, Université des Sciences et Technologie d'Oran, BP 1505 El M'naouer, Oran, Algérie.

Résumé

Nous proposons dans cet article une nouvelle approche de classification basée sur un système multi- machines à vecteurs de support dont la gestion sera attribuée à l'algorithme des tribus. La fusion des tribus et des SVMs nous permettra d'effectuer une exploration simultanée de plusieurs résolutions possibles ainsi qu'une gestion et un traitement dynamique de la base d'apprentissage. D'un autre coté, les SVMs apporteront une discrimination sur une base mathématique solide. L'approche proposée a été testée sur la classification d'images satellitaires de la région d'ORAN ouest. Les résultats obtenus seront comparés à ceux des SVMs dits classiques, et ce, en terme de taux de reconnaissance et de qualité d'images obtenues.

Mots Clés : Télé-détection, images satellitaires, classification supervisée, machine à vecteurs de support, SVMs, tribus

1. Introduction

Conçu en 2003 par Clerc, les tribus [1-4] sont une méthode d'optimisation non paramétrée qui tente de modéliser le fonctionnement d'une société tribale. Cet algorithme se base sur le réagencement de l'espace de recherche en différentes tribus composées d'un nombre variable d'agents.

En se basant sur la communication et la coopération entre agents, les tribus effectuent différentes adaptations comportementales et structurelles visant à améliorer les performances individuelles et collectives.

Afin d'adapter cet algorithme à la classification des données nous proposons de considérer les agents comme étant des machines à vecteurs de support. En se basant sur les théories d'apprentissages statistiques, les machines à vecteurs de support ou Support Vector Machines (SVMs) en Anglais [5-16] vont nous permettre d'effectuer une discrimination basée sur une séparation linéaire dans un espace de dimension adéquate.

Ainsi, notre approche tire avantage de la force discriminatoire des SVMs et de l'aspect adaptatif des tribus afin de concevoir un système multi machines à vecteurs de support qui effectue un traitement et une gestion dynamique de la base d'apprentissage, une exploration simultanée de plusieurs résolutions possibles [1-4], ainsi qu'une classification à base mathématique solide.

Dans le but d'évaluer les performances des SVMs tribaux, nous les avons appliqués à la classification supervisée d'images satellitaires de la région d'Oran [Algérie] ouest.

Les résultats obtenus semblent concurrencer les SVMs dits classiques [16] et ce sans l'intégration de nouveaux paramètres.

2. Les Tribus

Les tribus [1-4] (ou the tribes en anglais) est une nouvelle méthode d'optimisation auto adaptative [1] qui s'inspire du fonctionnement d'une société à organisation tribale. La formalisation de cette organisation sociale, passe par la modélisation d'une **structure** et d'un **comportement** tribaux [1-4]. Cette modélisation peut être résumée par les points suivants :

- Notre espace de recherche sera structuré en différentes tribus. Tel que chaque tribu soit caractérisée par un nombre variable 'd'agents' complètement connectés et un 'chef' désigné suivant une fonction objective 'f'.
- Le comportement tribal sera représenté par un mouvement des agents qui vise à améliorer leurs performances et par conséquent à accéder au grade de 'chef'.
- Les différents minima locaux explorés seront échangés par le biais d'un réseau de communication entre 'chefs de tribu'. Voir figure 1.

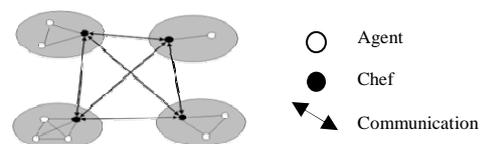


Figure 1. Réseau de communication des tribus.

2.1. Modélisation d'une structure tribale

Les tribus entament leur résolution avec un seul agent qui représente une tribu à lui seul. Cependant, cette structure sera réévaluée automatiquement toutes les ' $NL/2$ ' itérations tel que ' NL ' représente le nombre d'interconnexions entre les agents. ' NL ' peut être estimé suivant la formule suivante [1-4]:

$$NL = \sum_{n=1}^{N_{tribe}} \text{explorerNb}[n]^2 + N_{Tribes} (N_{Tribes} - 1) \quad (1)$$

avec :

- ' N_{Tribes} ' représente le nombre de tribus
- ' $\text{explorerNb}[n]$ ' est le nombre d'agents dans la tribu ' n '.

Ainsi, nos tribus sont réorganisées en laissant un temps de propagation aux informations [1-2]. Une fois ce temps écoulé, les agents et leurs tribus sont évalués puis restructurés par le biais de suppression et de génération d'agents :

- **La suppression d'agents :**

L'opération de suppression concerne les agents qui n'apportent plus d'informations pertinentes à leurs tribus. En d'autres termes, on supprime le plus mauvais agent de toute tribu contenant au moins un agent ayant amélioré sa meilleure performance. Une fois l'agent supprimé, on redirige ses liens d'information vers son meilleur informateur.

- **La génération d'agents :**

Chaque tribu ne contenant aucun agent qui a amélioré sa meilleure performance génère un nombre d'agents tel que : ' $N_{agent} = \text{Max}(2, [9.5 + 0.124(dim-1)/N_{tribes}])$ ' [1-4]. Les agents générés vont former une nouvelle tribu qui sera reliée à ses tribus génératrices par le biais des *chefs de tribu*.

2.2. Modélisations d'un comportement tribal

A chaque itération, les agents suivent une stratégie de déplacement en considérant leur meilleure position ' \mathbf{p} ' et la meilleure position de leur chef ' \mathbf{g} '.

Le choix de la stratégie à adopter est effectué par le biais d'une description qualitative de leurs deux dernières itérations. Cette description aura pour but de retracer une détérioration (-), un statu quo (=), ou encore une amélioration (+) [1-4].

L'intérêt majeur de ces différentes stratégies est d'effectuer des adaptations comportementales non paramétrées qui suivent l'historique des agents et non pas une configuration fixée au préalable. Tel que :

- **Stratégie du Pivot :**

Cette stratégie est choisie dans le cas où un agent connaît un mauvais comportement (-, -, +, -, =, =). Elle nous permet d'effectuer un déplacement assez large par le biais de deux points. Le premier est situé

dans l'hyper-sphère ' $\text{alea}_{\text{sphère}}(H_p)$ ' qui a pour centre ' \mathbf{p}_i ' et pour rayon ' $\|\mathbf{p} - \mathbf{g}\|$ '. D'un autre côté, le second point va être localisé dans l'hyper-sphère ' $\text{alea}_{\text{sphère}}(H_g)$ ' qui a pour centre ' \mathbf{g}_i ' et pour rayon ' $\|\mathbf{p} - \mathbf{g}\|$ '. Ainsi, les nouvelles coordonnées de l'agent seront mesurées comme suit :

$$\mathbf{x} = c_1 \cdot \text{alea}_{\text{sphère}}(H_p) + c_2 \cdot \text{alea}_{\text{sphère}}(H_g) \quad (2)$$

$$\text{avec: } c_1 = f(\mathbf{p}) / ((f(\mathbf{p}) + f(\mathbf{g})))$$

$$c_2 = f(\mathbf{g}) / ((f(\mathbf{p}) + f(\mathbf{g})))$$

- **Stratégie du Pivot Bruité :**

Dans le cas où un agent connaît un comportement dit '*moyen*' (+, -, +), on lui attribue une stratégie à pivot bruité. Cette stratégie associe un bruit ' b ' à une distribution uniforme localisée dans une hyper-sphère. Ainsi, les nouvelles coordonnées ' x_i ' de la particule ' i ' suivant le pivot bruité seront calculées par la formule suivante :

$$\mathbf{x} = (1 + b)(c_1 \cdot \text{alea}_{\text{sphère}}(H_p) + c_2 \cdot \text{alea}_{\text{sphère}}(H_g)) \quad (3)$$

$$\text{avec: } b = N(0, ((f(\mathbf{p}) - f(\mathbf{g}))) / ((f(\mathbf{p}) + f(\mathbf{g}))))$$

- **Stratégie Locale par Gaussiennes Indépendantes :**

Les agents ayant amélioré leur performances (= +, + +) intensifieront leur recherche dans leur zones d'étude par une stratégie locale à Gaussiennes indépendantes. Cette stratégie génère un point suivant une distribution ' $\text{alea}_{\text{normal}}$ '. Ce point aura pour centre ' $\mathbf{g}_j - x_{ij}$ ' et pour écart type ' $\|g_j - x_{ij}\|$ '. Ainsi, les nouvelles coordonnées de la particule considérée seront estimées comme suit :

$$x_j = \text{alea}_{\text{normal}}(\mathbf{g}_j - x_j, \|g_j - x_j\|) \text{ avec } j \in \{1 \dots \text{dim}\} \quad (4)$$

3. Les machines à vecteurs de support

Les machines à vecteurs de support [5-16] sont des techniques de classification supervisée conçues par V.Vapnik en 1995.

Les SVMs trouvent leur racine dans les théories d'apprentissages statistiques avec une discrimination basée sur l'existence d'un séparateur linéaire maximisant la marge, c'est-à-dire, la distance aux plus proches vecteurs dits vecteurs de support.

Afin de contrer la non linéarité des données, les SVMs projettent les données dans un espace caractéristique ' F ' de plus grande dimension. Cette projection sera effectuée par le biais de fonction non linéaire ' $\varphi(x)$ ' tel que ' $\varphi : R^n \rightarrow F$ '. [14-16]. Voir figure 2.

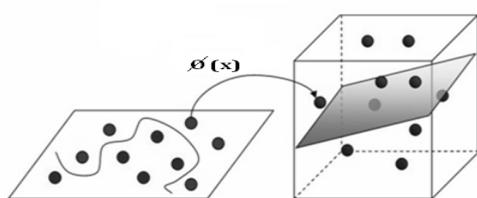


Figure 2. Projection des données dans un espace à dimension supérieure

Cette séparation linéaire entre les données induit une séparation binaire qui peut, cependant être, généralisée par le biais de différentes stratégies.

3.1. SVMs Binaires [8]

En partant d'un ensemble de 'm' vecteurs de données projetés dans un espace caractéristique 'F', les SVMs construisent un séparateur linéaire $h(x)$ caractérisé par un vecteur normal w , un seuil b et une fonction $h(x) = w^t \cdot \phi(x) + b$

Ainsi, dans le cadre d'une classification binaire, la classe $t_i \in \{-1, +1\}$ d'une donnée inconnue 'e' va être définie suivant sa position par rapport au séparateur linéaire 'h(x)', tel que : $t_i = \text{sgn}(w^t \cdot \phi(e) + b)$.

Comme la valeur de la marge est inversement proportionnelle à la norme de w [8-15], la recherche du séparateur linéaire optimal revient au problème d'optimisation suivant :

$$\begin{cases} \text{Min } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i \\ \forall i: t_i \cdot h(\phi(x_i)) \geq 1 - \xi_i \end{cases} \quad (5)$$

avec :

- 'C' est une constante de régularisation
- ' ξ_i ' représente l'erreur non négative

Afin de simplifier les contraintes, le problème d'optimisation est résolu par son dual en utilisant la méthode de Lagrange. Cette méthode permet de retranscrire le problème d'optimisation primal exprimé en (5) par son dual 'Ld' tel que :

$$Ld = \text{Max} \sum_{i=1}^m \alpha_i - \frac{1}{2} \cdot \sum_{i,j=1}^m t_i \cdot t_j \cdot \alpha_i \cdot \alpha_j \cdot \phi(x_i)^t \cdot \phi(x_j) \quad (6)$$

sous les contraintes $\sum_{i=1}^m \alpha_i \cdot t_i = 0$ et $\alpha_i \geq C \quad i = 1..m$

Tel que ' α_i ' représente la contribution de ' x_i ' à la conception du séparateur 'h(x)' d'où, seuls les α_i correspondant aux vecteurs de support sont non nuls.

D'un autre coté la difficulté de calcul au niveau produit scalaire ' $\Phi(x)^t \cdot \Phi(x)$ ' s'accroît avec l'augmentation de la dimension de l'espace de projection.

Afin de palier à cette difficulté, le problème est posé dans l'autre sens, à savoir : Existe-t-il des fonctions $K(x,y)$ qui vérifient l'existence d'une famille ' $\phi(x)$ ' tel que : $K(x,y) = \Phi(x)^t \cdot \Phi(y)$.

Pour cela, il est nécessaire et suffisant d'utiliser des fonctions noyaux qui possèdent les propriétés suivantes [14-15] : $\forall x, y \in \mathbb{R}^n$

- Positivité : $k(x,y) \geq 0$
- Symétrie : $k(x,y) = k(y,x)$
- Inégalité de Cauchy-Schwartz : $|k(x,y)| \leq \|x\| \cdot \|y\|$

Le tableau ci-dessous regroupe les principales fonctions noyaux utilisées dans la littérature [15-16].

Noyau	Forme générique	Paramètre :
Laplacien	$K(x,y) = \exp(-\ x-y\ /\delta)$	δ : Ecart type
Gaussien	$K(x,y) = \exp(-\ x-y\ ^2/2\delta^2)$	δ : Ecart type
Polynomial	$K(x,y) = (x \cdot y + 1)^p$	p : Ordre

Tableau 1. Différents types de noyaux.

L'utilisation de fonctions noyaux nous permet de simplifier le problème d'optimisation comme suit:

$$Ld = \text{Max} \sum_{i=1}^m \alpha_i - \frac{1}{2} \cdot \sum_{i,j=1}^m t_i \cdot t_j \cdot \alpha_i \cdot \alpha_j \cdot K(x_i, x_j) \quad (7)$$

sous les contraintes $\sum_{i=1}^m \alpha_i \cdot t_i = 0$ et $\alpha_i \geq C \quad i = 1..m$

3.2. SVMs multi-classes [11]

Les SVMs sont par leurs natures binaires [16]. Cependant, l'utilisation de différentes stratégies a permis d'étendre leur utilisation à la classification multi classes. Ces stratégies sont basées sur la multiplication du nombre de classifieurs binaires dont la gestion peut être effectuée suivant : [11][16]

- La Stratégie Un Contre Un (UCU)
Elle consiste à concevoir tous les classifieurs binaires envisageables en considérant chaque classe contre une autre. L'affectation suivra la classe la plus plébiscitée par les classifieurs (K Classe => K(K-1)/2 Classifieur)
- La stratégie Un Contre Tous (UCT)
L'approche un contre tous consiste à opposer chaque classe 'i' aux 'k-1' autres classes. Ainsi, l'affectation suivra le classifieur présentant une marge maximale (K Classes => K Classifieurs)

4. Approche Tribale des SVMs

Plusieurs approches ont été proposées dans le cadre de la fusion entre différents classifieurs [17-20]. Cependant, dans notre cas nous proposons de gérer les classifieurs avec

l'algorithme des tribus. Ce dernier, présente l'avantage d'être auto adaptatif. Ainsi, notre approche est basée sur l'agrégation de plusieurs classifieurs, tel que :

- On génère d'abord N bases. A partir de la base d'apprentissage initiale B .
- On entraîne N machines SVMs : $SVM_1, SVM_2, \dots, SVM_N$ pour chacune de ces bases.

La gestion de ces différentes machines sera effectuée par l'algorithme des tribus. Ce dernier, nous permettra d'améliorer les performances en utilisant les adaptations structurelles et comportementales. Tel que : Voir figure 3

- Les agents représentent des machines à vecteurs de support miniaturisées contenant pour chaque classe ' j ', des vecteurs représentant ' u_j ' de dimension ' dim '. Ainsi, la position ' x_i ' d'un agent ' i ' représente des candidats d'images classifiées.
- La fonction objectif représente les performances individuelles ou encore le taux de classification ' TC ' généré par chaque machine ($f=TC$). Ainsi, chaque agent aura pour but de maximiser son taux de classification personnelle.
- La classification des données sera déterminée par un système de vote ou chaque machine à vecteurs de support élira une classe d'affectation. Au final, chaque donnée sera affectée à la classe la plus plébiscitée.

Ainsi, ce système de classification devra passer par une phase d'apprentissage et une phase de classification en considérant un apprentissage multi-machines à vecteurs de support [17].

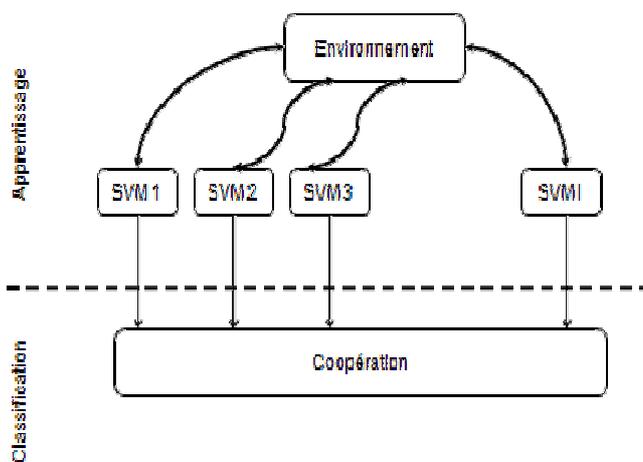


Figure 3. Schéma général de l'approche SVMs/tribus

4.1. La phase d'apprentissage

Suivant les différentes adaptations structurelles et comportementales, notre espace de recherche évoluera

jusqu'au réagencement de la base d'apprentissage suivant l'algorithme des tribus. Cette structure multi-machines à vecteurs de support nous permettra de:

- gérer dynamiquement la base d'apprentissage
- traiter la base d'apprentissage

4.2. La phase de classification

La classification des données sera déterminée par un système de vote ou chaque machine à vecteurs de support élira une classe d'affectation. Au final, chaque donnée sera affectée à sa classe la plus plébiscitée. Ce type d'affectation nous permettra d'intégrer les différentes connaissances distribuées entre les agents [17], et ce, de manière à:

- explorer et intégrer plusieurs résolutions possibles
- effectuer une discrimination à base mathématique

5. Mise en Œuvre et Résultats

Nous avons appliqué notre approche à la classification supervisée du contenu de trois différentes prises de vues satellitaires de type LANDSAT5 TM de la région d'ORAN ouest. Ces images, datées du 5 Mars 1995, nous ont été fournies par le Centre National des Techniques Spatiales (CNTS) d'Arzew -ALGERIE-. Voir figure 4.

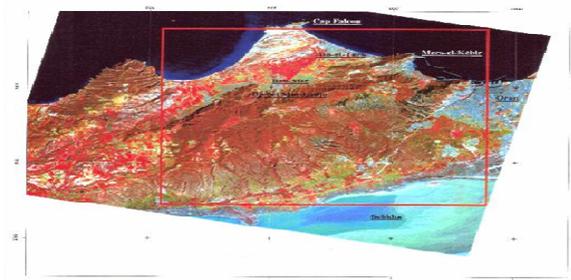


Figure 4. Zone d'étude.

Sur chacune de nos images tests, nous avons construit un fichier d'échantillonnage et un autre d'évaluation, contenant respectivement des valeurs radiométriques et des coordonnées de pixels appartenant à différentes classes. Voir figure 5.

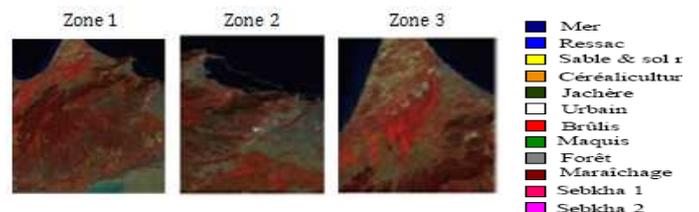


Figure 5. Les images tests.

La construction de ces fichiers et l'évaluation des résultats ont été effectuées en se basant sur la photo-interprétation à la place de l'enquête sur le terrain. Cette dernière, n'ayant pas été effectuée au moment de

l'acquisition de l'image. La photo-interprétation a été basée sur nos connaissances thématiques.

Ainsi, suivant leurs réflectances spectrales, les différentes classes constituant notre scène ont été identifiées. Dans la figure ci-dessous, nous avons donné un exemple d'interprétation pour la 'zone 1' qui englobe la totalité de la région.

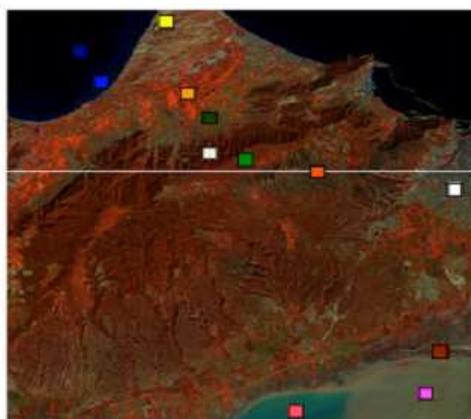


Figure 6. Exemple d'interprétation basée sur la réflectance

Une fois nos fichiers d'apprentissage et de validation construits, les seuls paramètres à fixer restent ceux des SVMs puisque les tribus sont non paramétrées.

Ainsi, nous avons appliqué notre algorithme suivant une étude préalable [16] et des considérations pratiques. Tel que :

- En raison du nombre de machines à vecteurs de support à gérer et du nombre de classifieurs à estimer, nous avons opté pour la stratégie de classification « un contre tous » qui permet de gérer un nombre minimal de classifieurs.
- Suivant une étude préalable [16] nous avons opté pour le noyau Laplacien qui a démontré les meilleures performances en termes de classification d'images satellitaires.
- Le compromis C a été fixé à la valeur conseillée dans la littérature tel que $C=500$ [16] et une décomposition = 1 échantillon / classe.

Nous avons appliqué notre approche sur les différentes images tests. Les résultats obtenus ont été comparés à ceux des SVMs dits classiques [16], et ce, en considérant la même base de validation.

5.1. Classification de la Zone 1

L'application des SVMs et des SVMs tribaux à la classification de la 'zone 1' a démontré que la diminution de l'écart type Laplacien augmente les performances des SVMs et des SVMs tribaux. Voir tableau 2.

Test	Paramètres	SVM Tribaux	SVM Classique
1	$\sigma = 0.1$	TR = 83.43 %	TR = 75.29 %
2	$\sigma = 0.5$	TR = 82.35 %	TR = 74.87 %
3	$\sigma = 01$	TR = 79.97 %	TR = 74.45 %

Tableau 2. Résultats obtenus pour la Zone 1

En se basant sur les images obtenues (Voir figure 7), on peut noter une nette amélioration de la reconnaissance de la classe Sebkha2 pour les différents tests effectués par l'approche proposée.

Il est aussi important de noter que les SVMs Tribaux avec ' $\sigma = 1$ ' ont donné lieu à une surestimation de la classe Sebkha2 avec des confusions Sebkha2/Urbain et Sebkha2/Sable. Ces confusions s'atténuent avec la diminution de l'écart type.

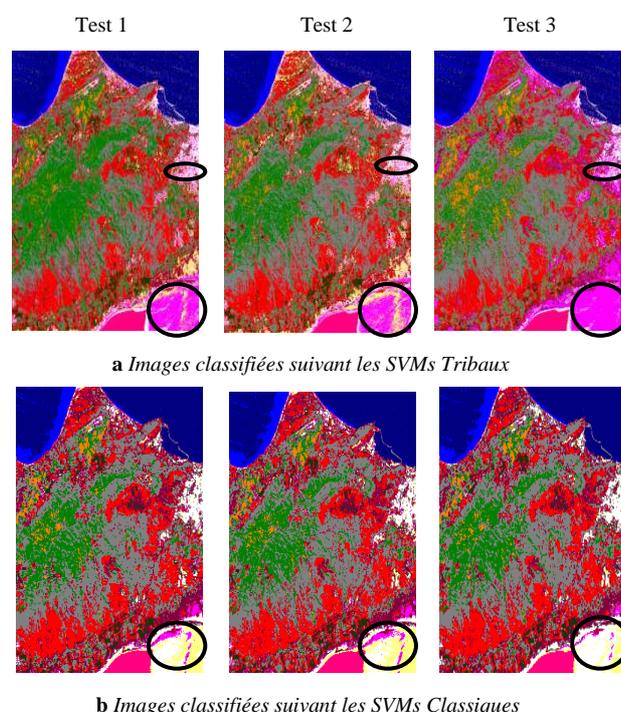


Figure 7. Images classifiées -Zone 1-

5.2. Classification de la Zone 2

Le rapport entre l'écart type Laplacien et le taux de reconnaissance semble se confirmer au niveau de la 'zone 2' tel que la diminution l'écart type Laplacien augmente les performances des SVMs et des SVMs tribaux. Voir tableau 3.

Test	Paramètres	SVM Tribaux	SVM Classique
1	$\sigma = 0.1$	TR = 95.88 %	TR = 84.59 %
2	$\sigma = 0.5$	TR = 92.35 %	TR = 82.09 %
3	$\sigma = 01$	TR = 90.89 %	TR = 79.34%

Tableau 3. Résultats obtenus pour la Zone 2

D'un autre coté, on remarque bien que l'approche proposée a eu pour effet d'augmenter le taux de reconnaissance, et ce, en diminuant la surestimation de la classe jachère ainsi que les confusions mer/urbain. Voir figure 8.

Ainsi, les SVMs tribaux ont amélioré les performances des SVMs pour les différents tests effectués.

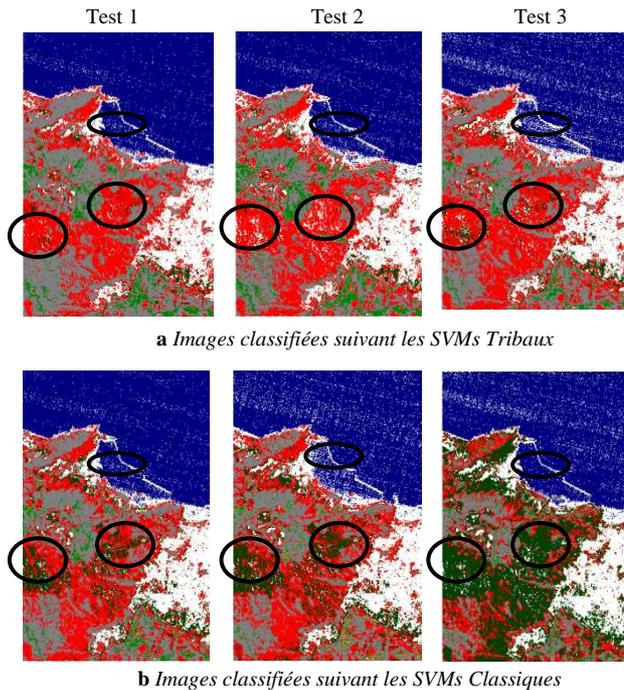


Figure 8. Images classifiées -Zone 2-

5.3. Classification de la Zone 3

Pour la 'zone 3' le rapport entre l'écart type Laplacien et le taux de reconnaissance reste identique pour les SVMs classiques et les SVMs tribaux. Voir tableau 4.

D'un autre coté, les SVMs tribaux démontrent toujours de meilleures performances que les SVMs classiques, et ce, pour les différents tests effectués.

Test	Paramètres	SVM Tribaux	SVM Classique
1	$\sigma = 0.1$	TR = 95.22%	TR = 83.51%
2	$\sigma = 0.5$	TR = 92.35 %	TR = 79.81 %
3	$\sigma = 01$	TR = 84.70 %	TR = 71.22 %

Tableau 4. Résultats obtenus pour la Zone 3

Ainsi, comme on peut le noter au niveau des images ci-dessous (Voir figure 9), une classification par les SVMs classiques engendre une surestimation de classe brulis ainsi que des confusions Mer/Ressac, Urbain/Mer et Brulis/Foret.

En se basant sur les images obtenues par les SVMs tribaux, on peut noter une nette amélioration de la reconnaissance au niveau des classes forêt, mer, ressac, sable ainsi qu'une diminution de la surestimation de la classe brulis.

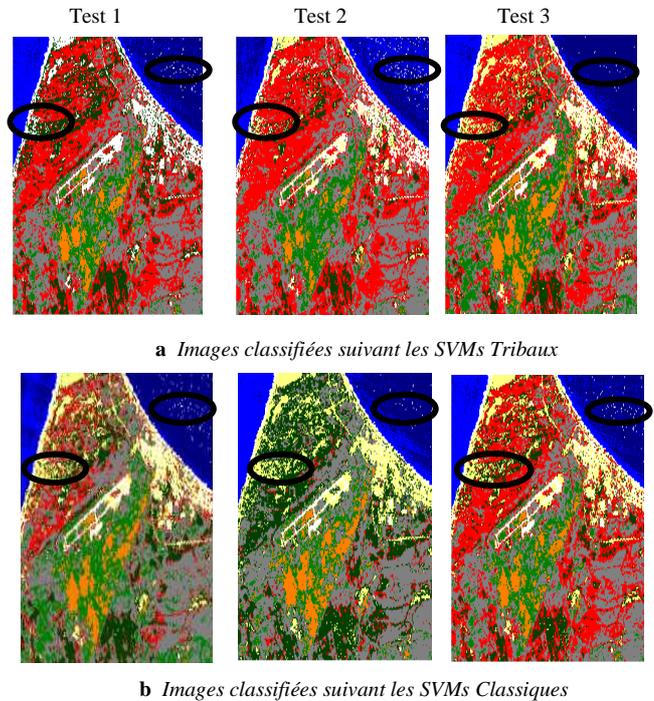


Figure 9. Images classifiées -Zone 3-

6. Conclusion

Nous avons présenté un système multi-machines à vecteurs de support géré par les tribus, un algorithme non paramétré et complètement adaptatif.

Nous avons ainsi intégré la notion de coopération entre agents à la classification SVMs et ce sans l'intégration de nouveaux paramètres à la classification SVMs.

Les différents tests effectués sur la classification de différentes prises de vues satellitaires de la région d'ORAN ouest ont démontré que les SVMs tribaux améliorent de manière significative les performances des SVMs dits classiques.

Références

- [1] Y. Cooren, M. Clerc, et P. Siarry, "Nouvelle stratégie de déplacement des particules implémentée dans TRIBES, algorithme d'optimisation par essaim particulaire sans paramètres", Conférence d'Optimisation par Essaim Particulaire. OEP 2007, Paris, Avril, 2007.
- [2] Y. Cooren, M. Clerc, et P. Siarry, "Amélioration de TRIBES, un algorithme d'optimisation par essais particuliers sans paramètres", Conférence FRANCORO - ROADEF 2007, Grenoble, Février, 2007.
- [3] A. Nakib, Y. Cooren, H. Oulhadj, et P. Siarry "Magnetic Resonance Image Segmentation Based on two-Dimensional Exponential

- [4] *Entropy and a Parameter Free PSO*. Artificial Evolution. Springer Berlin / Heidelberg, Volume 4926. Pages 50-61, 2008
- [5] Y. Cooren, M. Clerc, et P. Siarry, “*Performance evaluation of TRIBES, an adaptive particle swarm optimization algorithm*” Swarm Intelligence, Springer New York, Volume 3, Number 2 / juin 2009. Pages 149-178.
- [6] V. N. Vapnik, “*Statistical Learning Theory*”. Wiley Edition. New York, 1998.
- [7] F. Lauer et G. Bloch, journées identification et modélisation expérimentale JIME. « *Méthodes SVM pour l'identification* ». Centre de Recherche en Automatique de Nancy, 2000.
- [8] M. Massih, « *Apprentissage automatique et recherche de l'information : Application à l'extraction d'information de surface et au résumé de texte* ». Thèse de doctorat de l'université de Paris 6, 2001.
- [9] A. Cornuejols, « *Une nouvelle méthode d'apprentissage : Les SVM. Séparateurs à vaste marge* ». Bulletin de l'AFIA, No 51, Juin 2002.
- [10] M. Devy, « *Une introduction aux méthodes à vecteurs de support et autres algorithmes à noyau* ». Assemblée Générale du GdR ISIS, Dourdan, 2003.
- [11] J. Callut « *Implémentation efficace des supports vector machines pour la classification* ». Mémoire présenté en vue de l'obtention du grade de Maître en Informatique. Université libre de Bruxelles. département informatique, 2003.
- [12] Y. Guermeur, « *SVM multi-classes, théorie et application* ». Département de formation doctorale en informatique, Ecole doctorale IAEM Lorraine, 2007.
- [13] F. Moutarde, « *Brève introduction aux SVMs* ». Ecole des mines de Paris, 2007.
- [14] A. Fahed, « *Les séparateurs à vaste marge (SVM)* ». Master TIS HEUDIASYC, Université de Technologies de Compiègne (UTC), Centre de recherche Royallieu, Cadre B. Apprentissage Statistique de la Classification. ENS Cachan - Antenne de Bretagne, France.
- [15] V. N. Vapnik. “*The nature of statistical learning theory*”. Springer-Verlag, New York, USA, 1995.
- [16] Z. Zidelmal.Amirou, A. Amirou, M. Djeddi, et N. Djouaher « *Application des SVMs basés sur l'algorithme SMO pour la détection d'anomalies cardiaques* », 4th International Conference: Sciences of Electronic, Technologies of Information and Telecommunications. March 25-29, 2007, Tunisie.
- [17] H. Fizazi Izabatene, W. Benhabib, et S. Ghardaoui, “*Contribution of Kernels on the SVM Performance*”. Journal of Applied Science, ISSN 1812-5654. Volume 10, Issue: 10, pages 831-836, 2010.
- [18] J. Laumônier, « *Méthode d'apprentissage de la coordination multiagent : application au transport intelligent* », Thèse de Ph.D. Département d'informatique et de génie logiciel, Université Laval, Juin 2008, Québec.
- [19] C. Desjardins, J. Laumônier, et B. Chaib-Draa, « *Learning Agents for Collaborative Driving* ». Multi-Agent Systems for Traffic and Transportation Engineering. Pages 240-260, 2010.
- [20] A. Saidane, H. Akdag, et I.Truck, « *Une Approche SMA de l'Agrégation et de la Coopération des Classifieurs* », 3th International Conference: Sciences of Electronic, Technologies of Information and Telecommunications. March 2005 – Tunisie.
- [21] G. Forestier, P. Gançarski, et C. Wemmert, “*Collaborative clustering with background knowledge*”. Data & Knowledge Engineering, pp 211--228, Vol. 69, 2010.