

Classification de végétaux par SVM

M. CHAPRON¹, L. ASSEMAT²,

¹ETIS-ENSEA-UCP, UMR 8051, 6 avenue du ponceau, 95014 Cergy-Pontoise

²INRA, UMR Biologie et Gestion des Adventices, BP 86510, Dijon

chapron@ensea.fr

Résumé – Le travail décrit ici consiste à présenter les méthodes mises en œuvre pour classer les pixels des images couleur dans les classes maïs, adventices et sol dans le cadre de l’agriculture de précision. Les différentes méthodes de classification SVM ont été décrites et testées. Les méthodes de classification linéaires se sont avérées insuffisantes pour classer les pixels en sol/végétation, les méthodes non linéaires et à classes non séparables se sont montrées nettement meilleures tant pour classer les pixels en sol/végétation, puis les pixels de végétation en maïs et en adventices.

Abstract – This paper is concerned with the classification of pixels of color images into maize, weeds and soil in the framework of precision agriculture. The different SVM based classification methods have been described and tested. The linear techniques provide poor results during the classification of pixels into soil and vegetation, the non linear and non separable ones give much better results for classifying the pixels into soil and vegetation as well as classifying the pixels of vegetation into maize and weeds.

1. Introduction

La reconnaissance ou la classification de végétaux [2, 6] est un problème difficile et important en agriculture de précision et particulièrement pour la diminution des intrants chimiques qui créent de plus en plus de pollutions d’origine chimique dans les nappes phréatiques (atrazine). Le développement technologique des caméras, ordinateurs et méthodes de classification/reconnaissance permet d’envisager des applications réelles de réduction d’intrants chimiques tels que les herbicides. En effet, les herbicides peuvent n’être répandus que si la présence des adventices (mauvaises herbes) est nocive pour le rendement de la culture céréalière lors de la compétition entre végétaux. Dans la suite, il sera étudié la densité des mauvaises herbes dans une culture de maïs.

Les étapes du traitement proposé sont d’abord la classification des pixels en deux classes : sol et végétation, puis les pixels de la végétation sont classés à nouveau en deux classes : maïs et adventices. On comparera les résultats obtenus par les méthodes SVM (support vector machine) linéaires, non linéaires et donnera les résultats de classification maïs/adventices avec les SVM non linéaires, non séparables. Sur les images présentées [1, 3, 4, 7, 8, 9, 10], les caractéristiques utilisées pour la classification des végétaux sont les trois composantes rouge, verte et bleu normalisées ou pas. Le formalisme et les méthodes seront d’abord décrits dans le cas général puis adaptés au cas des végétaux.

2. SVM linéairement séparable

Soit un ensemble d’apprentissage A formé de N couples (x_i, y_i) de données et d’étiquettes où x_i est une donnée et y_i l’étiquette associée, x_i appartient à \mathbb{R}^d et y_i à $C = \{-1, 1\}$, l’ensemble des deux classes. L’ensemble A s’écrit comme suit : $A = \{(x_i, y_i), i=1..N\}$. L’objectif des SVM dans le cas linéaire est de calculer un hyperplan qui sépare au mieux les

échantillons des deux classes. Cet hyperplan $f(x)$ est défini par :

$$f(x) = \langle w, x \rangle + b = \sum_{j=1}^d w_j x_j + b = 0 \quad (1)$$

avec $(w, x) \in \mathbb{R}^d \times \mathbb{R}^d$ et $b \in \mathbb{R}$,

Les SVM cherchent à maximiser la distance entre l’hyperplan et les points les plus proches de lui de chaque classe, cette distance est égale à $2/\|w\|$. En conséquence, le problème d’optimisation consiste à maximiser cette distance ou à minimiser son inverse sous les contraintes : $y_i(\langle w, x_i \rangle + b) \geq 1 \quad i=1..N$

Nous ne décrivons pas l’ensemble des équations qui régissent ce modèle qui ne s’est pas avéré le plus performant ; les modèles ci-dessous ont donné des résultats bien meilleurs.

En phase opérationnelle, pour une donnée nouvelle x , $f(x)$ est calculée et en fonction du signe de $f(x)$, x est classée -1 si $f(x)$ est négative et +1 dans le cas contraire. Nous pouvons remarquer que la solution ne dépend pas de la dimension des données (d) mais du nombre d’échantillons et en fait du nombre de vecteurs supports.

3. SVM non linéaires

Dans le cas fréquent où les données ne sont pas linéairement classifiables, le formalisme des SVM propose de dépasser cette difficulté en projetant les données dans un espace P de dimension supérieure en général à d (dimension de l’espace des données brutes) grâce une fonction non linéaire $\Phi(x)$.

La même procédure d’optimisation que précédemment est appliquée sur les données projetées par $\Phi(x)$ dans P. Dans ce cas, (4) et (5) deviennent respectivement (8) et (9) :

$$\text{Min}_{\alpha^*} \frac{1}{2} \sum_{l,k=1}^N \alpha_l \alpha_k y_l y_k \langle \Phi(x_l), \Phi(y_k) \rangle - \sum_{i=1}^N \alpha_i \quad (2)$$

et $\sum_{i=1}^N \alpha_i y_i = 0$ et $\alpha_i \geq 0, i=1..N$

$$f(x) = \sum_{i=1}^N \alpha_i^* y_i \langle \Phi(x_i), \Phi(x) \rangle + w_0^* \quad (3)$$

La même technique d'optimisation quadratique que ci-dessus a permis d'obtenir α_i^* et w_0^* .

La difficulté ici vient des calculs des produits scalaires $\langle \Phi(x_i), \Phi(x) \rangle$ qui deviennent très longs. Pour outrepasser cette difficulté, il existe des fonctions bilinéaires symétriques positives $K(x,y)$ appelées fonctions à noyau faciles à calculer et qui correspondent à des produits scalaires dans un espace à grande dimension; cette propriété correspond à la condition de Mercer. Le problème d'optimisation (2) dans ce cas devient (4) :

$$\text{Min}_{\alpha^*} \frac{1}{2} \sum_{l,k=1}^N \alpha_l \alpha_k y_l y_k K(x_l, y_k) - \sum_{i=1}^N \alpha_i \quad (4)$$

et $\sum_{i=1}^N \alpha_i y_i = 0$ et $\alpha_i \geq 0, i=1..N$

La solution est l'hyperplan séparateur d'équation :

$$f(x) = \sum_{i=1}^N \alpha_i^* y_i K(x_l, y_k) + w_0^* \quad (5)$$

α_i^* et w_0^* sont obtenus par la même technique d'optimisation quadratique que ci-dessus. Les fonctions à noyau les plus utilisées sont les fonctions polynomiales, à base radiale et sigmoïdes. L'équation correspondant à la fonction à base radiale est :

$$K(x,y) = \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right) \quad (6)$$

σ est donné par l'utilisateur.

Le choix de la fonction noyau à base radiale permet dans nos applications de régulariser les fonctions de décision obtenues.

4. SVM non séparables

Si l'ensemble d'apprentissage A n'est pas séparable, le problème d'optimisation (2) n'a pas de solution, il faut introduire des variables ξ_i de relâchement des contraintes et un hyper paramètre C dans la fonction de coût à minimiser. Le problème d'optimisation devient (7) :

$$\text{Min}_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (7)$$

avec $y_i f(x_i) \geq 1 - \xi_i$ et $\xi_i \geq 0$ pour $i=1..N$

Cette optimisation sous contraintes peut être effectuée en utilisant les multiplicateurs de Lagrange, elle s'écrit :

$$L(w,b,\xi,\alpha,\beta) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \alpha_i [\xi_i - 1 + y_i(w^T x_i + b)] - \sum_{i=1}^N \beta_i \xi_i \quad (8)$$

Les dérivées partielles de L par rapport à w , b , et ξ_i donnent :

$$\frac{\partial L(w,b,\xi,\alpha,\beta)}{\partial w} = w - \sum_{i=1}^N \alpha_i y_i x_i = 0 \quad (9)$$

$$\frac{\partial L(w,b,\xi,\alpha,\beta)}{\partial b} = \sum_{i=1}^N \alpha_i y_i = 0 \quad (10)$$

$$\frac{\partial L(w,b,\xi,\alpha,\beta)}{\partial \xi_i} = C - \alpha_i - \beta_i = 0 \text{ pour } i=1..N \quad (11)$$

$$(9) \text{ donne } w = \sum_{i=1}^N \alpha_i y_i x_i \quad (12)$$

(10) et (12) dans (8) donnent :

$$\text{Min}_{w,b,\xi} L(w,b,\xi,\alpha,\beta) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j \alpha_i \alpha_j x_i^T x_j + \sum_{i=1}^N \alpha_i \quad (13)$$

(13) doit être maximisé par rapport à α et β , β n'apparaît pas dans (13), donc maximisons (13) par rapport à α et qu'il existe β qui vérifie (11), c'est le cas quand $\alpha_i \leq C$ car $\beta_i \geq 0$.

Le problème initial d'optimisation se réduit à minimiser le critère $\text{Cr}(\alpha)$ suivant :

$$\text{Cr}(\alpha) = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j \alpha_i \alpha_j x_i^T x_j + \sum_{i=1}^N \alpha_i \quad (14)$$

Sous les contraintes :

$$\sum_{i=1}^N \alpha_i y_i = 0 \text{ et } 0 \leq \alpha_i \leq C \text{ pour } i=1..N$$

Remarquons qu'une fois α trouvé, β l'est aussi par (11) :

$$C - \alpha_i = \beta_i \quad \forall i \in \{1..N\}$$

Pour déterminer b , il est utilisé le fait que les conditions de Karash-Kuhn-Tucker correspondant aux multiplicateurs de Lagrange non nuls sont atteintes au point sel du Lagrangien.

Cela implique que les contraintes $\xi_i = 0$ et

$\xi_i - 1 + y_i(w^T x_i + b) = 0$ sont encore vraies, elles donnent avec (12) :

$$b = y_i - w^T x_i = y_i - \sum_{j=1}^N y_j \alpha_j x_j^T x_i \quad (15)$$

La classification non linéaire pour une donnée d'entrée x se fait à partir de l'équation :

$$f(x) = \sum_{i=1}^N y_i \alpha_i k(x_i, x) + b \quad (16)$$

Selon le signe de $f(x)$, x reçoit l'étiquette +1 si $f(x) > 0$ et l'étiquette -1 dans le cas contraire.

5. Résultats

D'abord, les images 1 et 2 présentent les résultats de la séparation linéaire pour classer les pixels en sol et végétation. Les résultats ne sont pas de bonne qualité, ils sont nettement améliorés par les SVM non linéaires image 3. Cette méthode qui utilise en entrée des données vectorielles x composée des valeurs des pixels rouge, vert et bleu

divisées par 255 ainsi leurs valeurs normalisées du rouge et du vert dans un voisinage 7x7 autour du pixel courant. Cela fait 245 composantes dans le vecteur x. En apprentissage, deux échantillons ont été pris sur le sol, deux autres sur les cailloux pour la classe sol ; deux échantillons ont été prélevés sur le maïs et deux autres sur les adventices pour la deuxième classe. La fonction noyau utilisée est la fonction à base radiale. Avec très peu d'échantillons en apprentissage, les résultats sont excellents car ils mettent en évidence des petites plantules uniquement visibles après zoom. Les résultats sur la végétation (classification maïs/mauvaises herbes) apparaissent sur les images 4, 5 et 6 en utilisant le cas non séparable : pour obtenir l'image 5 une SVM non linéaire a été utilisée, pour avoir l'image 6 une SVM non linéaire et non séparable a été mise en œuvre. Dans ce cas aussi très peu d'échantillons ont été pris : 6 sur le maïs autant sur les adventices. Les voisinages utilisés sont aussi 7x7 et les rouge et vert normalisés n'ont pas été pris en compte, les vecteurs données ont donc 147 composantes. Les résultats sont bons dans une végétation complexe à cause de ses multiples chevauchements de feuilles de végétaux. Ces résultats peuvent être améliorés par une méthode segmentation qui reprend ces résultats de classification et fusionne les plus petites régions aux plus grandes qui leur sont connexes. L'utilisation d'espaces colorimétriques différents (teinte, luminance et saturation), Yuv et Lab n'ont pas améliorés les résultats de classification. Dans ce genre de scènes naturelles, les méthodes non linéaires donnent de meilleurs résultats que les méthodes linéaires. A partir de l'image 1, des essais ont été conduits pour distinguer les trois espèces végétales (maïs et deux adventices), les résultats obtenus avec la technique précédente utilisant les mêmes descripteurs et une SVM multi-classe étaient médiocres, ce qui a conduit à ajouter les caractéristiques de texture sur les feuilles des végétaux pour mieux les classer. Les matrices de cooccurrence calculées sur les trois composantes chromatiques et selon les directions horizontale et verticale [5] permettent d'intégrer les signatures texturales des végétaux. Les 4 paramètres utilisés à partir des matrices de cooccurrence ont été l'énergie, l'entropie de Shannon, le max et le contraste. Le tableau ci-dessous synthétise les résultats obtenus sur ces 4 critères, les 3 premières colonnes ont été calculées à partir des 3 composantes rouge, verte et bleue sur les 12 échantillons d'apprentissage avec la direction horizontale pour le calcul des matrices de cooccurrence, les trois colonnes suivantes ont été construites sur le même modèle mais avec la direction verticale pour le calcul des matrices de cooccurrence.

| Chardon | moyenne | | | | | |
|----------------|----------|-------|-------|-------|-------|-------|
| Energie | 0,052 | 0,043 | 0,045 | 0,061 | 0,053 | 0,052 |
| Entropie | 3,015 | 3,155 | 3,119 | 2,861 | 2,961 | 2,966 |
| Max | 0,091 | 0,056 | 0,070 | 0,109 | 0,075 | 0,060 |
| Contraste | 4,432 | 7,104 | 7,429 | 3,352 | 6,775 | 7,065 |
| | Variance | | | | | |
| Energie | 0,008 | 0,004 | 0,005 | 0,008 | 0,003 | 0,003 |
| Entropie | 0,106 | 0,056 | 0,079 | 0,106 | 0,038 | 0,051 |
| Max | 0,031 | 0,034 | 0,034 | 0,037 | 0,027 | 0,022 |
| Contraste | 4,203 | 5,638 | 6,901 | 2,300 | 2,725 | 3,641 |

| Maïs | moyenne | | | | | |
|----------------|----------|-------|-------|-------|-------|-------|
| Energie | 0,054 | 0,045 | 0,050 | 0,063 | 0,056 | 0,058 |
| Entropie | 2,978 | 3,123 | 3,056 | 2,830 | 2,906 | 2,890 |
| Max | 0,090 | 0,063 | 0,070 | 0,100 | 0,084 | 0,093 |
| Contraste | 2,764 | 3,688 | 4,318 | 2,733 | 3,859 | 4,111 |
| | Variance | | | | | |
| Energie | 0,012 | 0,004 | 0,009 | 0,010 | 0,005 | 0,008 |
| Entropie | 0,173 | 0,064 | 0,139 | 0,138 | 0,073 | 0,101 |
| Max | 0,017 | 0,023 | 0,034 | 0,032 | 0,025 | 0,038 |
| Contraste | 1,652 | 1,718 | 3,045 | 1,563 | 1,105 | 1,257 |
| Advent1 | moyenne | | | | | |
| Energie | 0,060 | 0,050 | 0,046 | 0,062 | 0,053 | 0,054 |
| Entropie | 2,895 | 3,037 | 3,111 | 2,832 | 2,944 | 2,938 |
| Max | 0,105 | 0,085 | 0,069 | 0,101 | 0,068 | 0,075 |
| Contraste | 2,167 | 2,959 | 3,688 | 2,096 | 2,812 | 3,100 |
| | Variance | | | | | |
| Energie | 0,006 | 0,004 | 0,004 | 0,010 | 0,004 | 0,005 |
| Entropie | 0,089 | 0,070 | 0,068 | 0,135 | 0,051 | 0,068 |
| Max | 0,024 | 0,002 | 0,022 | 0,032 | 0,025 | 0,027 |
| Contraste | 0,541 | 0,522 | 0,807 | 0,651 | 1,062 | 0,585 |

TAB. 1 comparaisons des résultats sur les différents critères

La comparaison des nombres de TAB. 1 indique que le critère le plus discriminant est le contraste. Les résultats de classification des végétaux ont été améliorés mais peuvent l'être encore en prenant en compte aussi des descripteurs de formes. Faute de place cette image n'est pas présentée.

6. Conclusion

La méthode SVM non linéaire pour classes non séparables donnent les meilleurs résultats avec très peu d'échantillons de chaque classes (de 4 à 6). L'apprentissage est simple. Les méthodes proposées se sont avérées robustes par rapport aux changements d'échelle. Ces méthodes peuvent être améliorées lors de la classification des végétaux en utilisant en plus des descripteurs de texture et de forme dans les composantes des vecteurs x de données d'entrée utilisés en phases d'apprentissage et opérationnelle. Ces méthodes présentent en outre l'avantage de travailler sur des données de grande dimension.

Références

- [1] C. Burges, a tutorial on support vector machines for pattern recognition, Data mining and knowledge discovery, 2, 121-167, 1998
- [2] M. Chapron, L. Assemat, P. Boissard, P. Huet, Weed and corn recognition using 2D and 3D data fusion, Third ECPA, 2001.
- [3] A. Cornuéjols, une nouvelle méthode d'apprentissage : les SVM. Séparateurs à vaste marge, bulletin de l'AFIA, no 51, juin 2002
- [4] N. Cristianini, J. Shawe-Taylor, an introduction to support vector machines, Cambridge 2000,

Herbrich (02) : *Learning kernel classifiers*. MIT Press, 2002.

[5] R.M. Harralick et al, textural features for image classification, IEEE transactions on systems, man and cybernetics, vol 3, nb 6, p 610-621

[6] A.G. Manh, G. Rabatel, L. Assemat, M.J. Aldon, In field classification of weed leaves by machine vision using deformable templates, Third ECPA, 2001.

[7] B. Schölkopf, C. Burges, A. Smola, advances in kernel methods, MIT press, 1998

[8] B. Schölkopf, A. J. Smola, learning with kernels, MIT press, 2002

[9] Smola, Bartlett, Schölkopf & Schuurmans (00) : *Advances in large margin classifiers*. MIT Press, 2000.

[10] Vapnik *The nature of statistical learning*. Springer-Verlag, 1995.



Image 1- Image originale

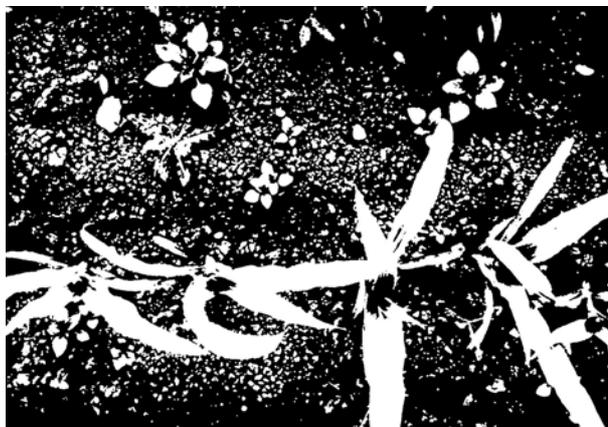


Image 2- Classification sol/végétation



Image 3- Classification sol/végétation



Image 4- Image originale

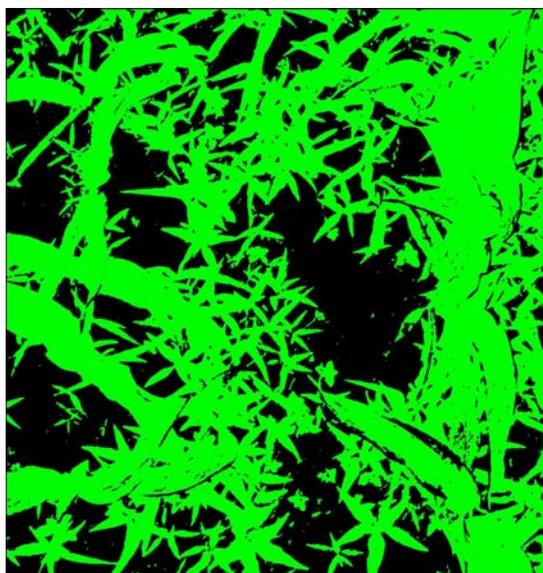


Image 5- Classification sol/végétation

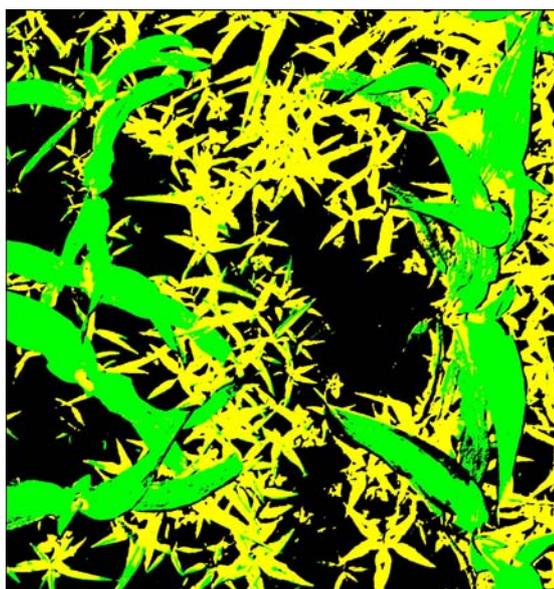


Image 6- Classification maïs/adventices