

Segmentation statistique d'images du bois de vigne par champs de Markov triplets

Sonia OUALI¹, Jean-Baptiste COURBOT¹, Romain PIERRON², Olivier HAEBERLE¹

¹IRIMAS, UR 7499, ²LVBE, UR 3391
Université de Haute-Alsace, Mulhouse, France
sonia.ouali@uha.fr

Résumé – Nous allons présenter dans cet article une méthode de champs de Markov triplets qui permet de traiter conjointement le problème de segmentation d'images de bois de vigne atteint d'esca et celui de déconvolution non-stationnaire qui permet d'estimer la profondeur du pathogène dans le bois. Les images sont obtenues avec un microscope de fluorescence dont la fonction d'étalement du point (PSF) est connue. Nous avons comparé nos résultats à ceux obtenus avec des champs de Markov couples. Ces derniers considèrent la PSF constante. Notre modèle fait gagner 5% en taux de classification.

Abstract – We will present in this article a method of triplet Markov fields that allows us to deal jointly with the problem of segmentation of images of vine wood suffering from esca and non-stationary deconvolution which makes it possible to estimate the depth of the pathogen in the wood. The images are obtained using a fluorescence microscope whose point spread function (PSF) is known. We compared our results to those obtained with pairwise Markov fields. The latter considers a constant PSF. Our model gain 5% in classification rate.

1 Introduction

1.1 Contexte et état de l'art

L'esca est une maladie de bois de vigne, elle provoque le dépérissement des ceps conduisant progressivement à leur mort. Pour lutter contre ces maladies, il faut comprendre le comportement des agents pathogènes responsables. Pour ce faire, [12] inoculent des vignes avec des champignons susceptibles de causer l'esca puis observent l'évolution du pathogène au microscope de fluorescence, dans le but de mettre en évidence sa propagation dans le bois.

Nous nous intéressons plus spécifiquement au problème de quantification du pathogène dans le bois, à partir d'images en microscopie de fluorescence (cf. figure 1). Les images sont bruitées, texturées et présentent des zones de flou. On peut distinguer deux différentes causes de flou, *un flou de défocalisation en profondeur* quand le champignon observé n'est pas dans le plan focal et *un flou de bougé* quand l'objectif ou un objet de la scène bougent pendant l'acquisition. Dans de bonnes conditions d'observations, le second peut être négligé, mais pas le premier : nous n'avons aucune garantie que le pathogène soit exclusivement dans le plan focal. Le flou de défocalisation est partiellement connu, car la fonction d'étalement du point (PSF) est connue au niveau instrumental (cf. figure 2). Néanmoins, la profondeur à laquelle le pathogène se situe reste inconnue, elle devra donc être estimée avec sa répartition dans l'image. Ainsi, il est nécessaire de traiter conjointement le problème de déconvolution non-stationnaire et de segmentation.

De nombreuses techniques existent dans le contexte de la




FIGURE 1 – Exemples d'images de pathogène dans du bois de vigne observé en microscopie de fluorescence, en grossissement $\times 10$ à gauche et $\times 40$ à droite. La fluorescence du pathogène apparaît en filaments vert-jaune, tandis que l'autofluorescence du bois apparaît en jaune-brun.

déconvolution/segmentation. Dans [10], l'auteur propose une méthode de déconvolution basée sur la segmentation par champs de Markov. La PSF est considérée spatialement invariante, tout comme dans [3] où la PSF intervient au sein d'un modèle de champs de Markov couples (CMC). Les auteurs dans [13] ont par contre considéré que la PSF est spatialement variante, ce qui est plus réaliste sur les images de microscopie. En effet, en microscopie de fluorescence, le flou varie selon la profondeur [9], [13]. Pour pouvoir travailler avec une PSF continue, [7] considèrent un modèle de PSF constante par zone. Les auteurs dans [17], [16] et [11] proposent des méthodes de déconvolution appliquées à différents types d'images réelles, ultrason, scanner et naturelle. Ces méthodes ont été prouvées performantes sur des images simulées et réelles. Même si les auteurs concluent que leurs méthodes peuvent tout aussi bien être appliquées à des images microscopiques, leurs algorithmes ne prennent pas en considération les particularités de ce genre d'images. Dans notre




FIGURE 2 – Plans centraux d’une PSF \mathbf{h}^{3D} typique en microscopie de fluorescence, générée via *PSF generator* [8].

cas, nous recherchons à retrouver du champignon fluorescent et filamentaire sur un fond texturé et auto fluorescent. Ce qui rend la tâche plus difficile, le pathogène n’est pas toujours situé sur le plan focal, il est discontinu et prend des formes différentes selon la coupe du bois (transversale ou longitudinale). Les modèles cités ne sont pas complets pour être appliqués à nos images.

1.2 Modèle de formation d’image

Nous supposons que l’image observée \mathbf{y} résulte d’un champ latent \mathbf{x} représentant les classes d’intensités, qui subit les effets d’une convolution \mathbf{H} . Cette dernière étant variable selon la région de l’image, nous la paramétrons par un second champ latent \mathbf{v} pour avoir le modèle suivant :

$$\mathbf{y} = \mathbf{H}(\mathbf{v}) * \mathbf{x} + \mathbf{b}, \quad (1)$$

où \mathbf{b} est une réalisation de bruit gaussien indépendant, d’écart-type σ_b . Notons que \mathbf{y} est une image couleur, donc $\mathbf{y} \in \mathbb{R}^{S \times B}$ où S est le nombre de pixels de l’image, et B le nombre de couleurs.

$\mathbf{x} \in \mathbb{R}^{S \times B}$ résulte d’une réalisation d’un champ de Markov $\mathbf{z} \in \Omega^S$ dans lequel chaque classe $k \in \Omega$ correspond à une couleur $\boldsymbol{\mu}_k$, *i.e.* $\forall s, \mathbf{x}_s = \boldsymbol{\mu}_{z_s}$. La loi de \mathbf{z} est :

$$p(\mathbf{z}) \propto \exp \left(\alpha \sum_{(s,t) \in \mathcal{C}} \delta(z_s, z_t) \right) \quad (2)$$

Avec α le paramètre de régularisation modulant la « granularité » de \mathbf{z} , et \mathcal{C} l’ensemble des paires de pixels voisins dans l’image. Dans la suite, sans perte de généralité, \mathbf{z} sera à valeurs dans deux classes caractérisant la présence, ou non, de pathogène dans l’image.

L’opérateur $\mathbf{H}(\mathbf{v})$ traduit le fait que la convolution varie dans l’image en fonction du champ latent $\mathbf{v} \in \mathbb{R}^S$. Nous le définissons de sorte à avoir, pour tout site s de l’image :

$$(\mathbf{H}(\mathbf{v}) * \mathbf{x})_s = \left\langle \mathbf{h}_{s, [v_s]}^{3D}, \mathbf{x} \right\rangle \quad (3)$$

\mathbf{h}^{3D} n’est déterminée que sur une grille 3D correspondant aux pixels de l’image 2D et à la profondeur. Nous avons donc $\mathbf{h}_{s, [v_s]}^{3D}$ qui représente la PSF du système, centrée au pixel s , localisée à la profondeur $[v_s]$, *i.e.* la valeur sur la grille la plus proche, verticalement, de v_s .

Nous supposons que \mathbf{v} , qui représente les profondeurs des points observés par rapport à la PSF, est une réalisation d’un




FIGURE 3 – Illustration du processus de formation d’image. \mathbf{x} est une réalisation de champ de Markov où chaque classe est une couleur ; \mathbf{v} est une réalisation de champ gaussien décrivant la profondeur ; et \mathbf{y} est l’image formée par convolution de \mathbf{x} par $\mathbf{H}(\mathbf{v})$ et ajout d’un bruit \mathbf{b} .

champ gaussien de loi :

$$p(\mathbf{v}) \propto \exp \left(-\frac{1}{2} \mathbf{v}^T \boldsymbol{\Sigma}^{-1} \mathbf{v} \right) \quad (4)$$

où $\boldsymbol{\Sigma}$ est une matrice de covariance circulante, dont la base est une fonction de corrélation gaussienne paramétrée par σ_v , son écart-type, et ρ , la portée des corrélations typiques entre pixels¹. Nous avons choisi la modélisation de \mathbf{v} par champ gaussien car tout comme la PSF, il est continu, il permettra donc de bien représenter les variations de \mathbf{h}^{3D} sur l’axe z et aussi pour la facilité et rapidité des calculs avec ce modèle.

Finalement, en considérant (1)(2)(4), la loi du modèle est :

$$\begin{aligned} p(\mathbf{y}, \mathbf{v}, \mathbf{z}) &\propto p(\mathbf{y} | \mathbf{v}, \mathbf{z}) p(\mathbf{z}) p(\mathbf{v}) \\ &\propto \exp \left(-\frac{1}{2\sigma_b^2} \|\mathbf{y} - \mathbf{H}(\mathbf{v}) * \mathbf{x}\|^2 \right) \\ &\times \exp \left(\alpha \sum_{(s,t) \in \mathcal{C}} \delta(z_s, z_t) \right) \exp \left(-\frac{1}{2} \mathbf{v}^T \boldsymbol{\Sigma}^{-1} \mathbf{v} \right), \end{aligned} \quad (5)$$

et l’ensemble des paramètres du modèle est rassemblé dans $\boldsymbol{\Theta} = \{\sigma_b, \boldsymbol{\mu}_0, \boldsymbol{\mu}_1, \alpha, \rho, \sigma_v\}$. Dans la figure 3, nous illustrons le processus de formation des images. Notons que l’ensemble $(\mathbf{x}, \mathbf{v}, \mathbf{y})$ forme un champ de Markov triplet [1] (CMT).

Dans la suite de cet article, nous présentons une méthode qui permet d’estimer conjointement \mathbf{x} , \mathbf{v} et $\boldsymbol{\Theta}$, à partir de la seule connaissance de \mathbf{y} et de \mathbf{h}^{3D} .

2 Méthodologie

Dans cette partie, nous montrons comment estimer \mathbf{x} à partir de l’observation \mathbf{y} seule, sans connaître ni \mathbf{v} , ni $\boldsymbol{\Theta}$. Pour cela, nous étudions d’abord comment estimer chaque élément de $(\mathbf{x}, \mathbf{v}, \boldsymbol{\Theta})$ lorsque les deux autres sont connus.

2.1 Estimations partielles des variables

Estimer \mathbf{x} lorsque \mathbf{v} et $\boldsymbol{\Theta}$ sont connus. Nous nous retrouvons dans le contexte d’une segmentation supervisée dans le cadre

1. Une introduction très complète aux champs de Gauss-Markov peut être trouvée dans [15].

d'un champ de Markov couple [3], qui tient compte d'un flou, ici fixé. Pour cela, nous recourons à un estimateur du maximum a posteriori (MAP) fourni par l'algorithme *iteratives conditional modes* (ICM) [6]. Ainsi nous pouvons estimer

$$\hat{\mathbf{x}}^{\text{MAP}} = \arg \max_{\mathbf{x} \in \Omega^S} p_{\Theta}(\mathbf{x}|\mathbf{y}, \mathbf{v}) \quad (6)$$

Estimer \mathbf{v} lorsque \mathbf{x} et Θ sont connus. Trouver un estimateur similaire au MAP pour \mathbf{v} n'est pas trivial, car \mathbf{v} n'intervient pas linéairement dans la formation d'image (équation (1)) et car c'est une version discrétisée de \mathbf{v} qui doit être prise en compte (équation (3)) dans la convolution. Néanmoins, à \mathbf{x} et Θ fixés, la postérieure $p_{\Theta}(\mathbf{v}|\mathbf{x}, \mathbf{y})$ est accessible via le calcul de la vraisemblance (1) et de l'a priori sur \mathbf{v} (4).

Ainsi, nous pouvons utiliser une méthode de Metropolis-Hastings (MH) qui permet, itérativement, de faire des propositions \mathbf{v}^* , d'évaluer leur loi a posteriori, et de les retenir ou non dans la chaîne de Markov ainsi formée. Nous reportons ici les étapes principales de l'algorithme MH [5].

À une étape t de l'algorithme MH, la proposition faite est une perturbation de l'état actuel $\mathbf{v}^{(t)}$:

$$\mathbf{v}^{\text{proposition}} = \mathbf{v}^{(t)} + \epsilon \mathbf{v}^{\text{perturbation}} \quad (7)$$

où $\mathbf{v}^{\text{perturbation}}$ suit une loi normale multivariée, de même paramètres que \mathbf{v} (4), et $\epsilon > 0$ définit l'amplitude de la perturbation.

Ensuite, les propositions sont acceptées avec une probabilité

$$\min \left(1, \frac{p_{\Theta}(\mathbf{v}^{\text{proposition}}|\mathbf{x}, \mathbf{y})}{p_{\Theta}(\mathbf{v}^{(t)}|\mathbf{x}, \mathbf{y})} \right). \quad (8)$$

Si la proposition n'est pas acceptée, alors $\mathbf{v}^{(t+1)} = \mathbf{v}^{(t)}$. L'ensemble, répété suffisamment, forme une chaîne de Markov dont l'état stationnaire fournit :

$$\mathbf{v}^{\text{MH}} \sim p_{\Theta}(\mathbf{v}|\mathbf{x}, \mathbf{y}) \quad (9)$$

Estimer Θ lorsque \mathbf{v} et \mathbf{x} sont connus. Nous nous intéressons ici spécifiquement à l'estimation des paramètres inconnus du modèle, dans le cas où des données complètes sur les champs \mathbf{x} et \mathbf{v} sont disponibles. Les valeurs de μ , σ_b , et σ_v s'obtiennent directement avec les estimateurs du maximum de vraisemblance avec $(\mathbf{x}, \mathbf{y}, \mathbf{v})$. La granularité α , est obtenu par un maximum de vraisemblance approché proposé dans [4]. Enfin, le paramètre ρ est obtenu par une méthode des moindres carrés permettant d'ajuster une fonction gaussienne au corrélogramme de \mathbf{v} [2].

2.2 Segmentation non supervisée

Nous nous intéressons maintenant à l'estimation conjointe de \mathbf{x} , \mathbf{v} , et Θ à partir de l'observation \mathbf{y} et sachant \mathbf{h}^{3D} . À partir des méthodes décrites plus haut, nous proposons un algorithme d'estimation alternée, qui va proposer successivement des valeurs de \mathbf{x} , \mathbf{v} , et Θ en considérant les deux autres fixées. Cette procédure est décrite dans l'algorithme 1.

3 Résultats numériques

Paramètres algorithmiques. Les algorithmes sont stochastiques, donc ils convergent « en moyenne ». Ainsi, nous les

Algorithme 1 Segmentation/déconvolution non supervisée par champ de Markov triplet

Données nécessaires : \mathbf{y} , \mathbf{H} , paramètres algorithmiques

Estimations : $\hat{\mathbf{x}}$, $\hat{\mathbf{v}}$, $\hat{\Theta}$

Initialisation : proposer un jeu de valeurs $\mathbf{x}^{(0)}$, $\mathbf{v}^{(0)}$ et $\Theta^{(0)}$.

Répéter : (itération $t + 1$) :

$$\text{Estimer } \mathbf{x}^{(t+1)} = \arg \max_{\mathbf{x} \in \Omega^S} p_{\Theta^{(t)}}(\mathbf{x}|\mathbf{y}, \mathbf{v}^{(t)}). \quad (6)$$

$$\text{Simuler } \mathbf{v}^{(t+1)} \sim p_{\Theta^{(t)}}(\mathbf{v}|\mathbf{y}, \mathbf{x}^{(t+1)}). \quad (9)$$

Estimer $\Theta^{(t+1)}$ à partir de \mathbf{y} , $\mathbf{x}^{(t+1)}$, $\mathbf{v}^{(t+1)}$.

Jusqu'à : Observer une convergence de $\{\mathbf{x}^{(t)}\}$.

stoppons lorsque le résultat de la dernière itération dévie suffisamment peu (moins de 5%) de la moyenne des 10 dernières itérations.

ϵ définit l'amplitude de la perturbation pour les propositions faites dans Metropolis-Hastings. Une valeur faible produira un fort taux d'acceptation mais une faible prise de risque, et donc une convergence lente ; à l'inverse, une valeur trop élevée peut produire des propositions trop invraisemblables pour être acceptées. Parfois, quand la nature de la distribution cible est connue, une valeur optimale de ϵ est proposée, comme dans le cas d'une loi a posteriori gaussienne en dimension d pour laquelle $\epsilon = 2.38/\sqrt{d}$ [14]. Nous ne sommes néanmoins pas, dans ce cas pour $p_{\Theta}(\mathbf{v}|\mathbf{x}, \mathbf{y})$ notamment à cause de $\mathbf{H}(\mathbf{v})$ et de la discrétisation qui y intervient (3). Nous prenons donc une valeur de ϵ qui donne, empiriquement, le meilleur compromis.

Données synthétiques. Nous fixons $\alpha = 0.6$, $\sigma_v = 1$ et $\rho = 15$ pour simuler des réalisations de \mathbf{x} , \mathbf{v} . Ces valeurs nous permettent d'obtenir des champs homogènes et une bonne distribution des classes contrôlée par α et de flou contrôlée par σ_v et ρ . Nous fixons μ et faisons varier σ_b pour étudier le comportement de la segmentation en fonction du bruit. Nous étudions également le comportement d'une méthode qui considère la PSF invariante dans l'image, *i.e.* en prenant pour \mathbf{v} une valeur scalaire fixée et en adaptant l'algorithme 1. Cela correspond donc à une segmentation par champs de Markov couples [3].

Les résultats sont reportés en figure 5 et un exemple de segmentation sur l'image de la figure 3 est donné en figure 4. Ces résultats mettent en évidence que tenir compte de la PSF sans tenir compte de sa variabilité n'est pas suffisant pour fournir de bons résultats. À l'inverse, tenir compte d'un flou de défocalisation variable dans l'image permet de faire gagner au minimum 5% en terme de taux de classification, et ce pour n'importe quelle valeur de σ_b .

Données réelles. Nous traitons ici des images acquises au microscope de fluorescence à champ large, avec objectif à air 40x (cf. figure 1). Les résultats sont reportés en figure 6. Le modèle permet l'extraction du pathogène même quand ce dernier ne se situe pas dans le plan focal. Comme nous pouvons le remarquer, la profondeur du pathogène est variable mais cela n'a pas empêché le modèle de le retrouver. On constate aussi que le modèle distingue bien le champignon de l'auto-fluorescence du bois observée en bas de \mathbf{y} .




FIGURE 4 – Exemples de résultats obtenus avec CMC (à gauche) et CMT (à droite) de l'image y (figure 3). Les taux indiqués correspondent au taux d'erreur entre les estimations et la vraie réalisation z .




FIGURE 5 – Synthèse des taux d'erreur obtenus en fonction de σ_b , où chaque point correspond à la moyenne de 10 réalisations différentes.

4 Conclusion

Nous avons proposé dans cet article un méthode de déconvolution/segmentation basée sur les CMT. Elle permet de représenter une image de pathogène dans du bois de vigne, observée avec un microscope de fluorescence et en présence d'un flou variable.

Ce modèle nous permet d'estimer conjointement la présence de pathogène et la profondeur à laquelle il se situe, et donc le flou de défocalisation associé.

Dans de futurs travaux, nous nous intéresserons aux développements algorithmiques possibles à partir de ce modèle, par exemple sur les interactions possibles entre les estimations de x et de v , ainsi qu'à l'estimation additionnelle de la PSF.

Remerciements Les auteurs tiennent à remercier B.Colicchio (IRIMAS) pour son aide lors de l'acquisition d'images réelles.

Références

- [1] D. Benboudjema and W. Pieczynski. Unsupervised statistical segmentation of nonstationary images using triplet Markov fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(8) :1367–1378, 2007.
- [2] ON. Bjornstad and W. Falck. Nonparametric spatial covariance functions : estimation and testing. *Environmental and Ecological Statistics*, 8(1) :53–70, 2001.
- [3] J.-B. Courbot and V. Mazet. Pairwise and hidden Markov random fields in image segmentation. In *2020 28th European Signal Processing Conference (EUSIPCO)*, pages 2458–2462, 2021.




FIGURE 6 – Résultats de segmentation sur données réelles. La zone rouge dans \hat{v} représente les régions où h^{3D} est plus large donc les zones où le pathogène subit un flou de défocalisation. Ce qui est s'avère vrai dans y

- [4] AA. Farag et al. A unified framework for map estimation in remote sensing image segmentation. *IEEE Transactions on Geoscience and Remote Sensing*, 43(7) :1617–1634, 2005.
- [5] A. Gelman et al. Bayesian data analysis. 2013.
- [6] S. Geman and D. Geman. Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6(6) :721–741, 1984.
- [7] S. Ben Hadj and L. Blanc-Féraud. Restauration d'image dégradée par un flou spatialement variant. In *GRETSI*, 2011.
- [8] H. Kirshner et al. 3-d PSF fitting for fluorescence microscopy : implementation and localization application. *Journal of microscopy*, 249(1) :13–25, 2013.
- [9] E. Maalouf. *Contribution to fluorescence microscopy, 3D thick samples deconvolution and depth-variant PSF*. PhD thesis, Université de Haute Alsace-Mulhouse, 2010.
- [10] M. Mignotte. A segmentation-based regularization term for image deconvolution. *IEEE Transactions on Image Processing*, 15(7) :1973–1984, 2006.
- [11] L. Yuan others. Progressive inter-scale and intra-scale non-blind image deconvolution. *Acm Transactions on Graphics (TOG)*, 27(3) :1–10, 2008.
- [12] R. Pierron et al. Deciphering the niches of colonisation of vitis vinifera l. by the esca-associated fungus phaeoacremonium aleophilum using a gfp marked strain and cutting systems. *PLoS One*, 10(6) :e0126851, 2015.
- [13] C. Preza et al. Depth-variant maximum-likelihood restoration for three-dimensional fluorescence microscopy. *JOSA A*, 21(9) :1593–1601, 2004.
- [14] GO. Roberts et al. Optimal scaling for various Metropolis-Hastings algorithms. *Statistical science*, 16(4) :351–367, 2001.
- [15] H. Rue and L. Held. *Gaussian Markov random fields : theory and applications*. Chapman and Hall/CRC, 2005.
- [16] C. Vacar and J.-F. Giovannelli. Unsupervised joint deconvolution and segmentation method for textured images : a Bayesian approach and an advanced sampling algorithm. *EURASIP Journal on Advances in Signal Processing*, 2019(1) :1–17, 2019.
- [17] N. Zhao et al. Joint segmentation and deconvolution of ultrasound images using a hierarchical Bayesian model based on generalized Gaussian priors. *IEEE transactions on Image Processing*, 25(8) :3736–3750, 2016.