



Université Lille Nord de France  
Pôle de Recherche  
et d'Enseignement Supérieur

## Ecole doctorale régionale Sciences Pour l'Ingénieur Lille Nord-de-France - 072



**Titre : Dématriçage et démélange conjoints de vidéos hyperspectrales**

**Financement prévu : 50% Région**

**Cofinancement éventuel : 50% ULCO**

**(Co)-Directeur de thèse : Gilles Roussel**

**E-mail : gilles.roussel@univ-littoral.fr**

**Encadrants : Matthieu Puigt**

**E-mail : matthieu.puigt@univ-littoral.fr**

**Laboratoire : LISIC (Laboratoire d'Informatique Signal et Image de la Côte d'Opale, EA 4491)**

**Equipe : Specifi**

### Description

Durant ces dernières décennies, l'imagerie visible/infra-rouge puis multi-spectrale ont permis de grandes avancées, par exemple en génie industriel ou en génie de l'environnement. Le développement plus récent de caméras hyperspectrales (HS) – observant la même image à plusieurs centaines voire milliers de longueurs d'ondes – permet d'imaginer de nouveaux systèmes d'observations pour lesquelles de nouvelles méthodes de traitement de données, à la frontière entre traitement du signal et de l'image et intelligence artificielle, doivent être proposées.

Dans le cadre de cette thèse, nous nous intéressons en particulier aux vidéos HS. Celles-ci fournissent des séquences temporelles de cubes de données HS (big data). Mais pour maintenir des coûts matériels raisonnables, ces caméras n'acquièrent pas forcément toutes les informations qu'elles sont censées saisir. Un post-traitement, nommé "dématriçage" est alors nécessaire pour reconstruire un cube de données à chaque prise d'image de la vidéo. Par ailleurs, dans chaque pixel de chaque image de la vidéo hyperspectrale, le spectre observé peut être considéré comme un mélange de spectres de matériaux purs présents dans le pixel. Dans le cadre de cette thèse, nous souhaitons estimer de tels spectres, à partir de séquences vidéos partiellement observées, pour réaliser le dématriçage des vidéos HS.

D'un point de vue applicatif, nous nous intéresserons à la surveillance d'environnements naturels, humains ou industriels.

## Références bibliographiques

1. **F. Yahaya, M. Puigt, G. Delmaire, G. Roussel**, *How to apply random projections to nonnegative matrix factorization with missing entries?*, in Proc. EUSIPCO, A Coruña, Spain, September 2-6, 2019.
2. **C. Dorffer, M. Puigt, G. Delmaire, G. Roussel**, *Informed Nonnegative Matrix Factorization Methods for Mobile Sensor Network Calibration*, IEEE Transactions on Signal and Information Processing over Networks, Volume 4, Issue 4, pp. 667-682, December 2018. IF: 3.153
3. **G. Delmaire, M. Omdivar, M. Puigt**, F. Ledoux, **A. Limem, G. Roussel**, D. Courcot, *Informed Weighted Non-negative Matrix Factorization Using  $\alpha\beta$ -Divergence Applied to Source Apportionment*, Entropy, Volume 21, Issue 3, Article number 253, special issue on "Information Theory Applications in Signal Processing", March 2019. IF: 2.419
4. **C. Dorffer, M. Puigt, G. Delmaire, G. Roussel**, *Fast nonnegative matrix factorization and completion using Nesterov iterations*, in Proc. of LVA/ICA'17, Springer International Publishing AG, vol. LNCS 10179, pp. 26-35, Grenoble, France, February 21-24, 2017.
5. **A. Limem, G. Delmaire, M. Puigt, G. Roussel**, D. Courcot, *Non-negative matrix factorization under equality constraints—a study of industrial source identification*, Applied Numerical Mathematics (APNUM), Volume 85, pp. 1-15, November 2014. IF: 1.678
6. Tsagakatakis, G., Bloemen, M., Geelen, B., Jayapala, M., & Tsakalides, P. (2018). Graph and Rank Regularized Matrix Recovery for Snapshot Spectral Image Demosaicing. *IEEE Transactions on Computational Imaging*, 5(2), 301-316.
7. Bioucas-Dias, J. M., Plaza, A., Dobigeon, N., Parente, M., Du, Q., Gader, P., & Chanussot, J. (2012). Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches. *IEEE journal of selected topics in applied earth observations and remote sensing*, 5(2), 354-379.
8. Zhang, X., Sun, Y., Zhang, J., Wu, P., & Jiao, L. (2018). Hyperspectral unmixing via deep convolutional neural networks. *IEEE Geoscience and Remote Sensing Letters*, 15(11), 1755-1759.
9. Tochon, G., Pauwels, D., Dalla Mura, M., & Chanussot, J. (2016, August). Unmixing-based gas plume tracking in LWIR hyperspectral video sequences. In *2016 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)* (pp. 1-5). IEEE.
10. Lee, D. D., & Seung, H. S. (1999). Learning the parts of objects by non-negative matrix factorization. *Nature*, 401(6755), 788.
11. Virtanen, T. (2007). Monaural sound source separation by nonnegative matrix factorization with temporal continuity and sparseness criteria. *IEEE TASLP*, 15(3), 1066-1074.
12. Ma, W. K., Bioucas-Dias, J. M., Chan, T. H., Gillis, N., Gader, P., Plaza, A. J., ... & Chi, C. Y. (2014). A signal processing perspective on hyperspectral unmixing: Insights from remote sensing. *IEEE Signal Processing Magazine*, 31(1), 67-81.
13. Limem, A., Delmaire, G., Puigt, M., Roussel, G., & Courcot, D. (2014). Non-negative matrix factorization under equality constraints—a study of industrial source identification. *Applied Numerical Mathematics*, 85, 1-15.
14. Yang, J., & Leskovec, J. (2013, February). Overlapping community detection at scale: a nonnegative matrix factorization approach. In *Proc. of the sixth ACM intl. conf. on Web search and data mining* (pp. 587-596). ACM.
15. Dorffer, C., Puigt, M., Delmaire, G., & Roussel, G. (2018, December). Informed Nonnegative Matrix Factorization Methods for Mobile Sensor Network Calibration. *IEEE TSIPN*, 4(4):667-682.



16. Limem, A., Delmaire, G., Puigt, M., Roussel, G., & Courcot, D. (2014). Non-negative matrix factorization under equality constraints—a study of industrial source identification. *Applied Numerical Mathematics*, 85, 1-15.
17. Seichepine, N., Essid, S., Févotte, C., & Cappé, O. (2014). Soft nonnegative matrix co-factorization. *IEEE Transactions on Signal Processing*, 62(22), 5940-5949.
18. Liu, J., Wang, C., Gao, J., & Han, J. (2013, May). Multi-view clustering via joint nonnegative matrix factorization. In *Proceedings of the 2013 SIAM International Conference on Data Mining* (pp. 252-260). Society for Industrial and Applied Mathematics.
19. Wang, Y. X., & Zhang, Y. J. (2012). Nonnegative matrix factorization: A comprehensive review. *IEEE Transactions on Knowledge and Data Engineering*, 25(6), 1336-1353.
20. Trigeorgis, G., Bousmalis, K., Zafeiriou, S., & Schuller, B. W. (2017). A deep matrix factorization method for learning attribute representations. *IEEE TPAMI*, 39(3), 417-429.