

**Zeitschrift:** Geomatik Schweiz : Geoinformation und Landmanagement =  
Géomatique Suisse : géoinformation et gestion du territoire =  
Geomatica Svizzera : geoinformazione e gestione del territorio

**Band:** 113 (2015)

**Heft:** 9

**Artikel:** Télédétection pour l'agriculture de précision par caméra hyperspectrale  
miniature

**Autor:** Constantin, Dragos / Cubero-Castan, M. / Akhtman, Y.

**DOI:** <https://doi.org/10.5169/seals-513918>

### **Nutzungsbedingungen**

Die ETH-Bibliothek ist die Anbieterin der digitalisierten Zeitschriften. Sie besitzt keine Urheberrechte an den Zeitschriften und ist nicht verantwortlich für deren Inhalte. Die Rechte liegen in der Regel bei den Herausgebern beziehungsweise den externen Rechteinhabern. [Siehe Rechtliche Hinweise.](#)

### **Conditions d'utilisation**

L'ETH Library est le fournisseur des revues numérisées. Elle ne détient aucun droit d'auteur sur les revues et n'est pas responsable de leur contenu. En règle générale, les droits sont détenus par les éditeurs ou les détenteurs de droits externes. [Voir Informations légales.](#)

### **Terms of use**

The ETH Library is the provider of the digitised journals. It does not own any copyrights to the journals and is not responsible for their content. The rights usually lie with the publishers or the external rights holders. [See Legal notice.](#)

**Download PDF:** 17.11.2024

**ETH-Bibliothek Zürich, E-Periodica, <https://www.e-periodica.ch>**

# Télédétection pour l'agriculture de précision par caméra hyperspectrale miniature

Un nouveau type de caméra hyperspectrale permet de miniaturiser le système d'acquisition de données, qui peut être installé sur un drone de taille modeste. Dès lors, cette technologie devient accessible au grand public pour de nombreuses applications telles que l'agriculture de précision. Cet article présente la méthodologie de la première campagne de mesure à large échelle sur une exploitation agricole produisant du maïs dans la région centrale du Brésil, ainsi que les premiers résultats.

*Eine neue Art Hyperspektralkamera ermöglicht das Datenerfassungssystem zu miniaturisieren, das in eine relativ kleine Drohne eingebaut werden kann. Damit ist diese Technologie jedermann für zahlreiche Anwendungen zugänglich, wie zum Beispiel für die Präzisionslandwirtschaft. Dieser Beitrag beschreibt die Methode sowie die ersten Resultate der ersten Messkampagne im grossen Massstab auf einem Landwirtschaftsbetrieb, der in der Zentralregion Brasiliens Mais produziert.*

Esiste un nuovo tipo di camera iperspettrale che consente di miniaturizzare il sistema di rilevamento dei dati e che può essere collocata su un drone di modeste dimensioni. A partire da questo momento, questa tecnologia diventa accessibile al grande pubblico per diverse applicazioni come, per esempio, nell'agricoltura di precisione. Quest'articolo presenta i risultati e la metodologia della prima campagna di misurazioni su vasta scala in un'azienda agricola che produce mais nella regione centrale del Brasile.

D. Constantin, M. Cubero-Castan,  
Y. Akhtman, B. Merminod

Depuis de nombreuses années, l'analyse spectrale de la lumière permet d'extraire et d'exploiter l'information spectrale provenant d'une étoile distante de quelques milliards d'années lumière ou d'une boîte de Pétri contenant divers types de bactéries. Que ce soit à partir d'une caméra spectrale satellitaire ou d'un spectromètre de masse dans un laboratoire, l'information spectrale s'avère utile pour un ensemble d'applications allant de la détection à la classification des matériaux [1, 2].

De nos jours, un grand nombre d'études en télédétection utilise des imageurs hyperspectraux (IHS) [3]. Là où l'oeil humain, ou une caméra couleur classique, enregistre la lumière issue ou réfléchiée par un matériau avec trois bandes spec-

trales (rouge, vert et bleu), une caméra hyperspectrale enregistre jusqu'à plusieurs centaines de bandes spectrales. L'ensemble de ces bandes donne beaucoup plus d'information qu'une caméra couleur.

Actuellement, la plupart des données hyperspectrales sont acquises par des capteurs à balayage (pushbroom) [4]. La détermination des points d'impact du faisceau au sol exige un géoréférencement direct, donc une plateforme inertielle et une synchronisation fine, ce qui augmente le poids et la complexité. Dans cette étude, les données hyperspectrales sont acquises avec un nouveau capteur développé par la compagnie suisse Gamaaya [5], fondée par des chercheurs du laboratoire de topométrie de l'EPFL.

Dans le contexte particulier de l'agriculture de précision, la télédétection est essentielle pour gérer les parcelles [6]. De plus en plus de solutions sont propo-

sées pour améliorer la gestion des ressources à l'échelle d'une parcelle agricole jusqu'au niveau national de production agro-alimentaire [7]. L'information hyperspectrale permet de déterminer une série d'indices végétaux [8] et d'estimer des paramètres biophysiques liés à tout type de culture agricole [9, 10].

Les méthodes d'apprentissage automatique (machine learning) sont utilisées avec succès en classification et régression dans divers domaines allant de la bioinformatique [11] à la finance [12] en passant par l'automatisation de la conduite automobile [13]. Ces méthodes nécessitent des caractéristiques représentées sous forme de vecteurs, correspondant par définition à des propriétés physiques mesurables, qui dans une image hyperspectrale, sont les différentes bandes spectrales de l'image. Combiner la richesse spectrale des IHS aux algorithmes d'apprentissage automatique a déjà produit beaucoup de résultats prometteurs [14].

Cet article présente la méthodologie et les premiers résultats d'une campagne de mesure à large échelle réalisée avec la nouvelle caméra hyperspectrale miniature. La campagne vise à apporter une aide à la décision pour l'exploitant agricole afin de détecter des problèmes de fertilité et d'estimer le rendement de son exploitation.

Comparaison des systèmes d'acquisition de données hyperspectrales

A l'heure actuelle, la majorité des images hyperspectrales sont acquises à partir de systèmes pushbroom [15]. Ce système




Fig. 1: Système d'acquisition pushbroom utilisant le capteur Headwall.

acquiert l'image hyperspectrale ligne spatiale par ligne spatiale. Ce type d'IHS est utilisé dans de nombreuses études portant sur l'hydrologie, la foresterie, l'agriculture, et bien d'autres domaines [4, 16]. La figure 1 présente un système d'acquisition utilisant cette technologie. Spécifications techniques:

- pushbroom: 1000 pix, 250 bandes spectrales
- plage spectrale: 400–850 nm
- poids 3.5 kg
- taille 23 x 17 x 11 cm
- interface sans-fil
- processeur Intel NUC Core i7
- framegrabber Pleora GigE
- SBG tactical grade IMU/GNSS, synchronisé
- caméra couleur additionnelle pour la génération du modèle 3D terrain

Cette étude fait appel à la nouvelle caméra hyperspectrale instantanée (snapshot) OXI présentée à la figure 3. Comme une caméra numérique ordinaire, le capteur comprend une matrice de pixels. D'autres caméras hyperspectrales comprennent une matrice de pixels exposés aux différentes bandes spectrales successivement par rotation d'un filtre. Ceci ne pose aucun problème pour une scène statique, mais tout mouvement de la caméra survenant entre les multiples expositions doit être compensé pour reconstruire le spectre complet.

Dans la caméra OXI, la séparation des bandes spectrales est réalisée par un traitement optique spécial – déposition ponctuelle et multi-couches – qui expose différents pixels à des bandes différentes selon un motif régulier. Ainsi on obtient le «cube hyperspectral», dont la 3e dimension est la longueur d'onde, avec une densité plus faible, mais de façon



Fig. 3: Caméra hyperspectrale OXI de Gamaya.

instantanée, sans devoir scanner spatialement ou spectralement, ni corriger le mouvement.

Spécifications techniques:

- snapshot 2 x 2 Mpix
- poids 250 g
- taille 9 x 6 x 4 cm
- interface sans-fil
- uBlox GNSS intégrés
- 16 bandes VIS (entre 470 nm et 650 nm)
- 25 bandes NIR (entre 600 nm et 900 nm)
- ordinateur x86 intégré

Par rapport à la caméra Headwall, la résolution spectrale plus faible (40 bandes au lieu de 250). Toutefois cet inconvénient est compensé par quelques avantages. D'abord, sa petite taille permet de l'embarquer facilement sur un drone de taille modeste, de type «avion» ou «hélicoptère». De plus, les images à deux dimensions peuvent être traitées selon les principes classiques de la photogrammétrie. L'aérotriangulation réduit fortement les exigences du géoréférencement direct. On peut se passer de plateforme inertielle puisque les orientations des prises de vues sont obtenues de façon indirecte via l'ajustement par faisceaux (bundle adjustment). Quant au calage du bloc, les positions des prises de vues déterminées




Fig. 2: Comparaison de la répartition spatiale et spectrale de l'information sur un capteur de taille 32 x 64 pixels avec 15 bandes: pushbroom à gauche et snapshot à droite.

par GNSS suffisent pour la majorité des applications. La correction géométrique, l'assemblage d'images pour l'orthoprojection et le recalage d'images couleur sont largement facilités.

## Analyse des données

Les données pour cette étude résultent d'une campagne réalisée en Juin 2015 dans la région centrale du Brésil. La scène comprend 17 parcelles, couvrant plusieurs types de sols (argileux, sableux, sable argileux, etc.) et comprenant cinq géotypes de maïs. La taille de l'exploitation agricole est d'environ 2000 ha. Plusieurs vols ont eu lieu avec différentes plateformes pour différentes résolutions spatiales, de 1 cm/pixel avec un drone jusqu'à 50 cm/pixel avec un Cessna 172. Nous allons nous concentrer sur un seul vol réalisé avec le Cessna à une hauteur sur sol de 2000 m.

Trois séries de mesures de terrain sont représentées sur la figure 4.

- Série A = analyse chimique du sol des 17 parcelles agricoles, réalisée en avril 2015, deux mois avant les vols
- Série B = 28 feuilles de maïs récoltées lors de vols (cercles blancs) B1 = analyse visuelle, B2 = analyse chimique en laboratoire
- Série C = Réflectance du sol et de la canopée mesurée avec le spectromètre



Fig. 4: Vue d'ensemble des relevés de terrain: les couleurs représentent la carte de répartition des géotypes, les cercles blancs représentent les mesures sur feuilles et les cercles rouges les mesures au sol.

USB 2000+ d'Ocean Optics (cercles blancs et rouge)

Chaque série de mesure joue un rôle différent. La série A permet d'établir la carte de fertilité du sol. La série B alimente les algorithmes de machine learning pour construire les cartes d'analyse chimique. La série C sert à la calibration radiométrique des données hyperspectrales.

## Méthodologie

Entre les données brutes acquises par la caméra et la carte de décision, la chaîne de traitement comprend cinq étapes: l'acquisition de données, la reconstruction radiométrique, l'orthoprojection des images, la correction atmosphérique et l'analyse des données. La figure 5 donne une vue d'ensemble de la chaîne de traitement.

Le système d'acquisition capture des images hyperspectrales. Un récepteur GPS intégré enregistre la position de chaque prise d'image.

Le pré-traitement consiste à soustraire les effets de distorsion géométrique dus au système optique. De plus, il convertit les données brutes en irradiance par le processus de correction radiométrique.

Dans la troisième étape, on construit une carte hyperspectrale géoréférencée par orthoprojection des données. Un bloc est formé par aérotriangulation, puis calé

grâce aux positions GNSS des prises de vues.

Les mesures C de réflectance du sol permettent de déterminer la correction atmosphérique, puis de transformer la carte hyperspectrale en carte de réflectance.

Enfin, deux types de traitements sont associés à la carte de réflectance: une analyse en composantes principales (ACP) [17] et la construction de cartes de régression utilisant l'algorithme random-forest [18]. L'ACP permet de classer les espèces et de repérer les zones affectées par des maladies à partir des mesures B1, tandis que random-forest, entraîné avec les mesures B2, permet d'estimer les cartes de composition chimique au niveau de la canopée.

## Résultats

Cette campagne de mesure a permis l'établissement de trois types de carte d'aide à la décision pour mieux gérer la ferme, soit l'identification des génotypes, l'identification des problèmes (maladies, nuisibles, etc.) et l'analyse chimique au niveau de la canopée. Ces trois cartes sont détaillées dans les sous-sections suivantes.

### Carte d'identification des génotypes

Pour obtenir cette carte, l'ACP est implémentée sur la carte de réflectance. La première composante étant généralement liée à l'éclaircissement, elle n'est pas prise en compte dans les futurs traitements. Une carte en fausse couleur des trois composantes suivantes (vecteurs propres 2, 3 et 4) sert à visualiser la diversité des espèces, voir la figure 6.

Une analyse qualitative de cette carte couleur permet d'observer une disparité cohérente de l'information. Cette disparité est corrélée avec la localisation des différents génotypes semés (syngenta en jaune, limagrain en rouge et pionner en vert et bleu foncé sur la figure 6).

De plus, quatre zones sont visibles sur la carte, où différents génotypes ont été




Fig. 6: Carte couleur représentant les différents génotypes. 4 champs de test de génotypes ont été détectés et marqués sur l'image.

plantés sur plusieurs type de sol pour tester leur compatibilité. Ces zones sont encadrées en bleu sur la figure 6.

Des variations au sein de chaque parcelle sont principalement dues à des stress environnementaux et à des défauts de calibration des caméras (bandes diagonales).

La grande résolution spectrale du système d'acquisition permet de distinguer les différents génotypes de façon très précise. Les génotypes causent la plus grande variation au sein de l'image, c'est pourquoi on les retrouve sur les premières composantes de l'ACP. Les analyses suivantes se concentrent sur la variation intrinsèque des réflectances au sein des parcelles agricoles.

### Carte d'identification des problèmes

Après l'identification des génotypes, on analyse la variabilité intra-classe au sein de chaque génotype. D'abord on soustrait les variations liées au génotype pour normaliser chaque parcelle. Une seconde ACP donne les variations intra-classe, représentées sur la figure 7.

Les couleurs représentent les différents problèmes rencontrés dans les parcelles: déficience du sol en rouge (deficiencies), sol nu sans maïs en bleu (bare soil), mauvaise herbe sur sol nu en blanc ou en présence de maïs en vert (weeds on soil,

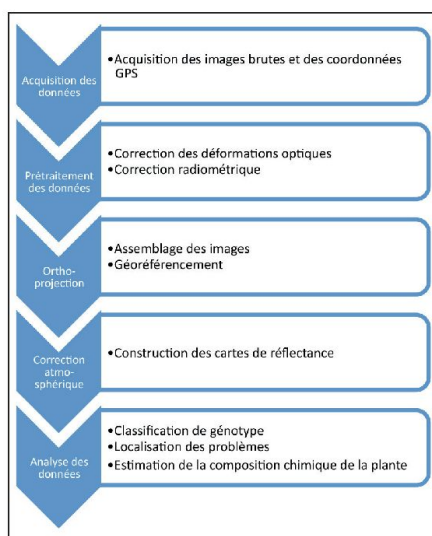


Fig. 5: Vue d'ensemble de la chaîne de traitement.




Fig. 7: Carte d'identification des problèmes rencontrés selon différents couleurs.

weeds in corn) et sans problème identifié en noir (healthy corn).

Cette carte des problèmes correspond assez bien aux observations sur place et aux cartes réalisées pour les mesures A. Par exemple, la carte de capacité d'échange de cations (CTC en portugais), en bas à droite de la figure 7, est un bon indicateur de la fertilité du sol. Une bonne cohérence est observée entre la CTC et la répartition des déficiences du sol.

Ainsi, on constate une bonne cohérence des mesures spectrales par rapport aux relevés de terrain.

## Cartes d'analyse chimique au niveau de la canopée

Pour la dernière étape, on estime les cartes d'analyse chimique sur l'ensemble de l'exploitation agricole à partir de la carte de réflectance. Avec les mesures

de terrain B2 pour information initiale, la méthode d'apprentissage automatique random-forest interpole les mesures spectrales. Trois éléments chimiques ont été analysés en particulier: l'azote (N), le potassium (K) et le phosphore (P). Ces indices sont liés à la formation du grain et à la vitalité de la plante, donc à la récolte à venir. Leur disponibilité est importante pour un exploitant agricole.

Les cartes de régression issues de random-forest sont représentées à la figure 8. On constate que les zones déficitaires, en azote ou en potassium principalement, sont corrélées avec les zones identifiées dans la sous-section précédente comme déficiente en nutriments au niveau du sol (zones rouges de la fig. 7).

Les cartes ainsi obtenues présentent un écart-type relatif d'environ 5 %, calculé entre les mesures de laboratoire et les estimations de random-forest. Cepen-

dant, compte tenu du faible nombre de mesures en laboratoire (env. 30), généraliser ces cartes à l'exploitation entière est hasardeux. De plus, on remarque des variations liées à un défaut de la calibration atmosphérique, présent notamment dans la carte d'identification des géotypes (fig. 6). Néanmoins, ces cartes correspondent plutôt bien aux analyses chimiques du sol (mesures A) et monte le potentiel de la méthode.

## Conclusion

Cette campagne fut la première à grande échelle réalisée avec la nouvelle caméra hyperspectrale instantanée. Le principal objectif fut d'analyser la pertinence des informations récoltées en les comparant avec des mesures de terrain. Avec une résolution au sol assez fine (50 cm/pixel), on a pu établir des cartes d'identification des géotypes semés et des problèmes de croissance végétale. Bien que le nombre de points de contrôle soit petit, les algorithmes d'apprentissage automatique ont généré des cartes d'analyse chimique de la canopée qui correspondent plutôt bien aux analyses du sol réalisées en laboratoire.

Les travaux futurs doivent se concentrer sur une amélioration des traitements de correction radiométrique et atmosphérique, ainsi que sur la construction d'une plus large série de mesures au sol afin d'améliorer la précision des cartes d'analyse chimique.

### Bibliographie:

- [1] D. Manolakis, et al., «Hyperspectral image processing for automatic target detection applications», Lincoln Laboratory Journal, 2003.
- [2] J. B. Campbell, Introduction to remote sensing, CRC Press, 2002.
- [3] «Hyperspectral Remote Sensing», Special issue of Remote Sensing, 2012.
- [4] Y. Akhtman, et al. «Télédétection multi-échelle des lacs depuis un aéronef ultraléger motorisé», Géomatique Suisse, vol. 9, num. 395-398, 2014.
- [5] Gamaya SA, <http://gamaya.com/#products>.

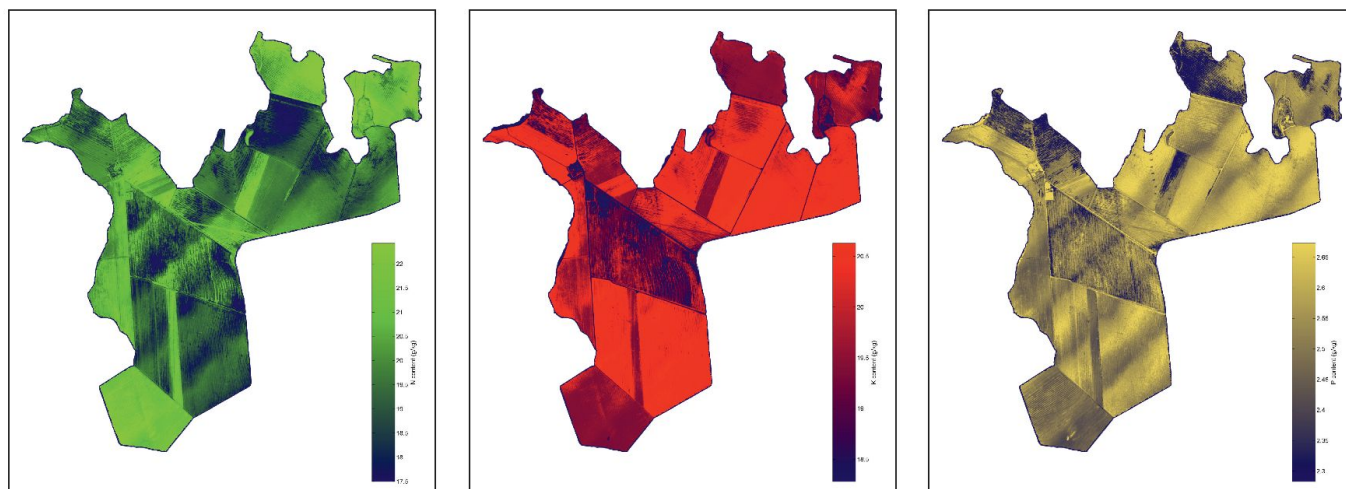


Fig. 8: Cartes de répartition au sein des feuilles de maïs de l'azote (N) en vert, du potassium (K) en rouge et du phosphore (P) en jaune, basées sur l'algorithme de random-forest.

- [6] D. J. Mulla, «Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps,» *Biosyst. Eng.*, vol. 114, no. 4, pp. 358–371, Apr. 2013.
- [7] M. E. Schaepman, et al., «Earth system science related imaging spectroscopy: An assessment» *The 3rd Airborne Imaging Spectrometer Data Analysis Workshop*, JPL Publication, vol. 87-30, 1987.
- [8] Publications of Zarco Tejada.
- [9] D. Haboudane, et al., Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote sensing of environment*, 2004. 90 (3): p. 337-352.
- [10] A.J. Berjón, et al., Retrieval of biophysical vegetation parameters using simultaneous inversion of high resolution remote sensing imagery constrained by a vegetation index, *Precision Agriculture*, 14:541–557, 2013.
- [11] P. Larrañaga, et al., «Machine learning in bioinformatics.», *Brief Bioinform.* 2006 Mar; 7 (1) 86-112.
- [12] L. Alessi, and C. Detken, Identifying Excessive Credit Growth and Leverage (August 8, 2014). ECB Working Paper No. 1723. Available at SSRN: <http://ssrn.com/abstract=2477735>.
- [13] D. M. Stavens, «Learning to Drive: Perception for Autonomous Cars», PhD Dissertation, May 2011.
- [14] G. Camps-Valls, «Machine learning in remote sensing data processing», *Machine Learning for Signal Processing*, 2009. MLSP 2009. IEEE International Workshop on , vol. 1, no. 6, pp. 1-4 Sept. 2009.
- [15] Gordon Petrie, «Airborne Pushbroom Line Scanners An Alternative to Digital Frame Cameras», *Geoinformatique journal*, janv.-fév. 2005.
- [16] K. Staenz, «Terrestrial Imaging Spectroscopy Some Future Perspectives.» In *Proceedings of 6th EARSeL Workshop on Imaging Spectroscopy*, Tel-Aviv, Israel, pp. 16-19. 2009.
- [17] I.T. Jolliffe, «Principal Component Analysis», *Springer Series in Statistics*, 2nd ed., Springer, NY, XXIX, 487 p. 28, 2002.
- [18] L. Breiman, «Random Forests». *Machine Learning* 45 (1): 5–32, 2001.

Dragos Constantin  
M. Cubero-Castan, Y. Akhtman,  
B. Merminod  
EPF Lausanne  
CH-1015 Lausanne  
dragos.constantin@epfl.ch