

Méthode simplifiée pour la cartographie de l'occupation du sol en zone de montagne : cas du bassin versant de la Menoua (Région de l'Ouest-Cameroun)

Matsaguim N.C.A.¹, Tiomo Dongfack E.¹ et Ngoufo R.¹

(1) Département de Géographie, Faculté des Arts, Lettres et Sciences Humaines, Université de Yaoundé I, Cameroun /
e-mail :nguimdoarel@yahoo.fr

DOI : <http://doi.org/10.5281/zenodo.3518832>

Résumé

En matière de cartographie des formes d'occupation du sol, les méthodes de classification d'images en télédétection tendent à se complexifier au fil des années. L'objectif principal de cette étude était de proposer une méthodologie de classification supervisée permettant de combiner différentes fonctions de classification qui soit facilement reproductible. Il s'est agi de l'approche classe par classe qui est une méthode de classification indirecte qui procède par étape successive. Elle s'est avérée bien supérieure aux démarches directes utilisant une seule fonction de classification dans le cas où l'hétérogénéité spatiale à l'échelle locale rend difficile la distinction entre différentes classes au sein de l'image satellitaire utilisée. C'est notamment le cas dans le bassin versant de la Menoua (Ouest-Cameroun) où

l'agriculture est la principale forme d'occupation des sols. Ainsi, l'efficacité de l'approche dépend de l'utilisation de différentes fonctions de classification, de différentes images et de masques à chaque étape selon la classe ciblée. Pour cela, il s'avère nécessaire d'utiliser des néocanaux en plus de l'image multispectrale et de sélectionner les fonctions qui semblent les plus performantes compte tenu du niveau de séparabilité interclasse. Une contrainte importante dans ce choix est la possibilité de pouvoir utiliser un masque. L'approche s'avère plus simple à mettre en œuvre comparativement à d'autres qui ont été proposées tout en garantissant des résultats satisfaisants comme ça été le cas dans la zone d'étude qui a été retenue pour cette étude.

Mots clés : Agriculture, Bassin-versant, Cameroun, Cartographie, Télédétection

Abstract

In remote sensing, the complexity of classification methodologies used to elaborate a cartography of land cover types tend to grow up over the time. The main objective of this study was to propose a supervised classification methodology to combine different classification functions that is easily reproducible. This was the class-by-class approach, which is an indirect classification method that proceeds step by step. It proved to be far superior to direct approaches using a single classification function in the case where spatial heterogeneity at the local scale makes it difficult to distinguish between different classes within the satellite image used. That was the case in the Menoua watershed located in the west region of Cameroun where

agriculture appeared to be the main land cover class. Thus, the precision of the results obtained by using the approach depends on the use of different classification functions, different images and masks at each step depending on the class targeted. For this, it is necessary to use neochannels in addition to the multispectral image and to select the functions that seem to perform best given the level of interclass separability. An important constraint in this choice is the possibility of using a mask. The approach is simpler to implement compared to others that have been proposed while ensuring satisfactory results as was the case in the study area that was selected for this study..

Keywords : Agriculture, Cameroon, Cartography, Remote sensing, Watershed

1. Introduction

Les images satellitaires issues des satellites d'observation de la Terre permettent de disposer des données indirectes dans des régions où ces données

sont absentes. Leurs acquisitions en continu et sur de larges espaces en font un moyen efficace pour le suivi des dynamiques spatiales et temporelles. Ces images trouvent des applications dans de très nombreux

domaines comme celui de l'agriculture où elles permettent d'établir une cartographie des différentes formes d'occupation du sol. La mise à disposition gratuite d'images de résolutions spatiale, radiométrique et temporelle différentes rend actuellement leur utilisation accessible au plus grand nombre. Cependant, si l'accessibilité a été rendue facile, l'extraction de l'information contenue dans ces données sous la forme de cartes ou de statistiques nécessite de recourir à des méthodes de classification d'image. Il est généralement question de regrouper chaque objet présent dans l'image suivant leur degré de similarité.

La segmentation d'une image satellitaire consiste à utiliser un algorithme ou une fonction de classification appropriée pour identifier et nommer les pixels qui représente une caractéristique particulière de l'occupation du sol (Richards J.A. et Jia X., 2006). A cet effet, il existe de nombreuses fonctions de classification (Li M. et al., 2014). Parmi les fonctions de classification les plus citées, il y a : le Maximum de Vraisemblance (ML) dont les performances dépendent principalement de la séparation entre les moyennes des différentes classes définies dans l'espace de décision (Ahmad A. et Quegan S., 2012), la Distance Minimum (MD) conçue comme une alternative au ML lorsque l'opération de classification vise à distinguer différents objets au sein d'une même classe comme par exemple différentes espèces végétales au sein d'une exploitation agricole (Wacker A.G. et Landgrebe D.A., 1972), la Distance de Mahalanobis (MHD) utile lorsque le problème des pixels mixtes se pose (Deer P.J. et Eklund P., 2003), ou le « Support Vector Machines » (SVM) qui se montrerait plus performant que le ML et la fonction des Réseaux de Neurones Artificiels (RNA) (Pal M. et Mather P.M., 2005).

Face à ce nombre important de fonctions de classification, des études comparatives ont été menées (Erbek E.S. et al., 2002 ; Al-Ahmadi F.S. et Hames A.S., 2009 ; Otukey J.R. et Blaschke T., 2010 ; Perumal K. et Bhaskaran R., 2010 ; Hogland J. et al., 2013). Il ressort de ces études que les performances des fonctions de classification dépendent du type d'image utilisé, du site étudié, de la date d'acquisition de l'image qui renvoie aux conditions atmosphériques, et de la définition des zones d'entraînement (Richards J.A. et Jia X., 2006). Une fonction de classification peut se révéler performante sur un site et pas sur un autre, sur une image et pas sur une autre. La cartographie des formes d'occupation du sol repose donc sur le choix de la fonction de classification

la plus appropriée. Cette étape est d'une importance capitale lorsque le site connaît une importante hétérogénéité spatiale des objets à la surface du sol : cas du site qui fait l'objet de ce travail.

Une seconde difficulté après le choix de la fonction de classification est liée au niveau de précision recherché. Elle détermine la résolution spatiale de l'image satellitaire à utiliser. A ce sujet, les initiatives de cartographie des types d'occupation du sol à l'échelle de l'Afrique privilégient jusqu'à présent deux approches. La première, moins précise, utilise des données fournies par des satellites à faible résolution spatiale (un kilomètre environ) mais à forte répétitivité (un ou plusieurs passages par jour) pour identifier les principaux biomes africains. Il s'agit par exemple des travaux de Tucker et al. (1985), Kaptué et al. (2011), Verhegghen et al. (2012), Vancutsem et al. (2013), Lambert et al. (2016), Waldner et al. (2016). Ces travaux utilisent des images satellitaires d'une résolution spatiale variant de 100 à 1000 m. Cependant, les cartographies obtenues présentent toutes des erreurs plus ou moins importantes compte tenu de la résolution spatiale de l'image et de l'hétérogénéité spatiale des objets à la surface du sol. La seconde, dans un souci de précision, utilise des données fournies par des satellites à haute résolution spatiale mais à faible répétitivité pour établir la cartographie détaillée du parcellaire agricole par exemple. C'est le cas des travaux de Chen J. et al. (2015) et de Cao X. et al. (2016). Ces auteurs parviennent à cartographier les surfaces cultivées à l'échelle globale pour les années 2000 et 2010 grâce aux images issues du capteur Landsat d'une résolution spatiale de 30 m. En dépit d'une précision de 92%, des erreurs demeurent notamment en zone de montagne, Comme le font remarquer Chen J. et al. (2015), un tel résultat n'a pu être possible que par l'intégration de différentes méthodes de classification car aucune des fonctions de classification (citées plus haut) prises individuellement ne peut assurer une classification de l'occupation du sol satisfaisante sur une surface aussi vaste portant des paysages complexes. Dès lors, dans le cas de figure où l'utilisation de différentes fonctions de classification prises individuellement ne parvient à produire un résultat satisfaisant même sur une surface réduite, il se pose la question de savoir comment les combiner. Chen J. et al. (2015) proposent une méthodologie de combinaison. Cependant celle-ci présente un niveau de complexité relativement important. Cette étude vise à proposer une méthodologie simplifiée de classification supervisée permettant de combiner différentes fonctions de

classification. Il s'agit d'une approche classe par classe qui peut s'avérer nécessaire lorsque l'hétérogénéité spatiale du milieu ne permet pas qu'une fonction de classification se montre performante pour classer les différentes formes d'occupation du sol retenues. C'est notamment le cas dans les zones montagneuses comme celle du bassin versant de la Menoua située sur les Hautes Terres de l'Ouest Cameroun (HTOC).

2. Matériel et Méthodes

2.1.1. Zone d'étude

D'une superficie d'environ 68 200 ha (figure 1), le bassin versant de la Menoua qui s'étend entre 5° et 6° de latitude Nord est un milieu densément peuplé où l'agriculture est la principale activité économique (Ngoufo R., 1992 ; Ngoufo R. et al., 2001 ; Kaffo C., 2005 ; Kaffo C. et Fongang G., 2009 ; Lounang et al., 2014). Du fait de la densité, la superficie moyenne des parcelles agricoles est inférieure à 0,5 ha (MINEPAT, 2013). Sur le plan de la géomorphologie, il s'étend sur trois grands domaines

géomorphologiques d'amont en aval. La partie amont du bassin, de 1 700 m à 2 740 m d'altitude, est celui du mont Bamboutos qui est un massif volcanique aux pentes fortes (Déruelle B. et al., 1991). La partie centrale du bassin versant est une zone de plateaux et fait partie du plateau Bamiléké située entre 1 400 et 1 600 m d'altitude. La partie aval du bassin est une zone de plaine aux pentes faibles à nulles et au relief plat avec une altitude variant de 690 m à 2 740 m. Le réseau hydrographique est particulièrement dense. S'agissant de la géologie des monts Bamboutos, les trachytes et les basaltes sont les formations géologiques les plus répandues (Tématio P. et al., 2004 ; Momo M.N. et al., 2016). Le bassin versant connaît un régime pluviométrique monomodal avec un maximum en juillet-août et un minimum entre décembre et février (Suchel J.-B., 1988 ; 1972 ; Tsalefac M., 1983). La moyenne annuelle des précipitations est d'environ 1900 mm (Kengni L. et al., 2009) et la température moyenne est de 20,5°C à Dschang entre 1970 et 2009 (Matsaguim N.C.A., 2012).

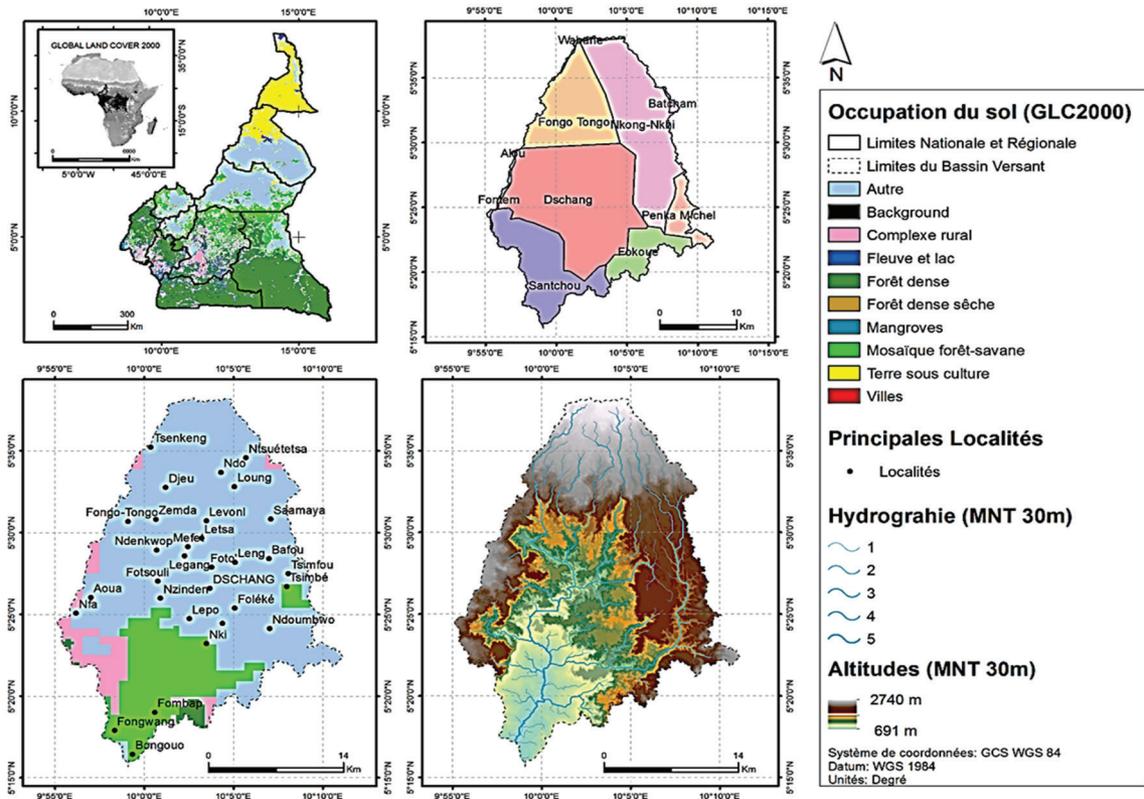


Planche 1 : Localisation du bassin versant de la Menoua (figure 1 : en haut à gauche), arrondissements faisant partie du bassin versant (figure 2 : en haut à droite), formes d'occupation du sol identifiées dans le bassin par le programme Global land cover 2000 (figure 3 : en bas à gauche), altitudes et hydrographie du bassin (figure 4 en bas à droite)

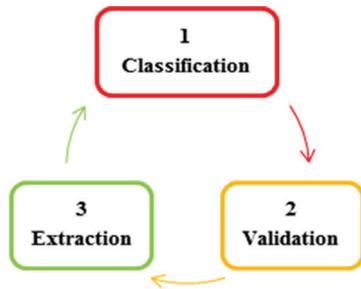


Figure 2 : Les étapes de l'approche de classification classe par classe

2.2. Matériels

L'image satellitaire du capteur Landsat 8 OLI acquise le 18 décembre 2014 sur notre zone d'étude (WRS_PATH = 186 et WRS_ROW = 56) fait partie des principaux matériels utilisés dans le cadre de cette étude. Seules les bandes multispectrales ont été utilisées pour la classification.

2.3. Méthodes de traitement

2.3.1. L'approche de classification classe par classe

La méthode de traitement utilisée dans le cadre de cette étude s'inspire de celle de classification binaire et de celle hiérarchique décrite par Chen J. et al. (2015). L'approche binaire consiste à regrouper les pixels de l'image en deux classes distinctes (Richards J.A. et Jia X., 2006). Elle présente le désavantage d'être peu appropriée lorsque la classification concerne plus de deux classes. Nous avons utilisé une approche dite classe par classe qui consiste à reprendre l'opération de classification sur la même image (ou pas) en prenant le soin de masquer la classe qui aura été correctement classifiée lors de la classification précédente. Il peut s'agir de plusieurs classes. C'est là l'une des différences fondamentales avec l'approche binaire classique. La seconde différence fondamentale repose sur le fait qu'il est possible d'utiliser une fonction de classification différente à chaque étape. Le choix de la fonction de classification utilisée dépendra de la performance des différentes fonctions après chaque opération de classification. Il s'agit dès lors d'une démarche par étape telle que l'illustre la figure 2.

Contrairement à l'approche hiérarchique (Chen J. et al., 2015), l'approche de classification classe par classe présente l'avantage d'être plus simple à mettre en œuvre tout en garantissant au final un niveau de précision assez élevé dans des contextes de très forte

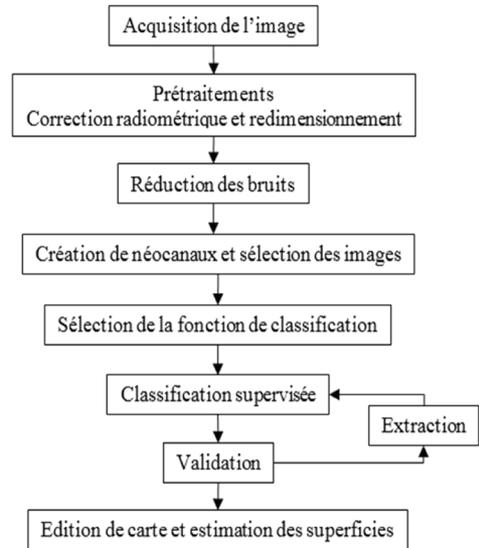


Figure 3 : Chaîne de traitement de l'image satellitaire

hétérogénéité spatiale. Toutefois, elle requiert que l'opération de validation pour la matrice de confusion s'intéresse uniquement à la précision individuelle et non globale. Ainsi, le critère de validation n'est plus l'indice de Kappa, mais les erreurs de commission et d'omission (Richards J.A. et Jia X., 2006).

2.3.2. Etapes de traitement de l'image Landsat 8

La figure 3 présente la chaîne de traitement suivie pour la classification de l'image. L'image originale a ainsi été prétraitée afin de corriger les erreurs dues aux conditions atmosphériques et géométriques. Par la suite, il a été créé un certain nombre d'images de synthèse appelées néocanaux. Il s'agit d'images obtenues à partir d'opérations algébriques effectuées sur l'image prétraitée et qui permettent de clairement mettre en évidence certaines caractéristiques de l'image (Richards J.A. et Jia X., 2006). La phase de création de néocanaux a conduit à la constitution de quatre groupes d'images. Le premier correspond à l'Image multispectrale corrigée (IMC_IMG). Le deuxième comprend les images issues des opérations de transformation (PCA_IMG) et (MNF_IMG). Le troisième est constitué d'indices de végétation et d'humidité (VEG_IMG). Le quatrième groupe d'image est celui qui cherche à distinguer la végétation des surfaces artificielles. Une fois ces néocanaux créés, nous avons procédé à la sélection des groupes d'images qui seront utilisés lors de la phase de classification.

Tableau 1 : Coefficient de séparabilité des ROIs par image et par paire de classe

Paires de classes d'objets	MNF_IMG	PCA_IMG	IMC_IMG	VEG_IMG	Ratio_IMG
Bâtiments et Sols Bétonnés	1,493	1,493	1,393	1,278	1,184
Cultures et Sols Bétonnés	1,564	1,564	1,531	1,363	1,171
Cultures et Végétation Naturelle	1,767	1,767	1,713	1,454	1,590
Bâtiments et Cultures	1,865	1,865	1,825	1,863	1,808
Cultures et Sols Nus	1,895	1,895	1,851	1,796	1,775
Sols Bétonnés et Eau	1,917	1,917	1,899	1,886	1,963
Bâtiments et Sols Nus	1,946	1,947	1,893	1,839	1,699
Sols Bétonnés et Sols Nus	1,956	1,956	1,925	1,835	1,765
Sols Bétonnés et Végétation Naturelle	1,982	1,982	1,976	1,893	1,944
Bâtiments et Eau	1,992	1,992	1,986	1,973	1,990
Bâtiments et Végétation Naturelle	1,996	1,996	1,994	1,999	1,999
Cultures et Eau	1,999	1,999	1,999	1,975	1,975
Végétation Naturelle et Eau	1,999	1,999	1,999	1,999	1,999
Sols Nus et Végétation Naturelle	1,999	1,999	1,999	1,999	1,999
Sols Nus et Eau	1,999	1,999	1,999	1,991	1,994
Moyenne	1,892	1,892	1,866	1,810	1,791
Ecart-type	0,162	0,162	0,185	0,242	0,280

Le choix entre l'un de ces groupes d'images a reposé sur l'analyse d'un indice permettant de juger de la séparabilité interclasse appelé « ROI Separability » et le calcul de deux paramètres statistiques à savoir: la moyenne et l'écart-type. Ces indices sont obtenus à partir du logiciel ENVI version 5.1. Les catégories d'images retenues pour effectuer la classification sont celles qui ont eu la moyenne la plus élevée et l'écart-type le plus faible, ce qui traduit une séparabilité interclasse relativement élevée et stable dans l'ensemble. Cependant, par défaut, l'image IMC_IMG a été utilisée. Pour la classification, 6 classes principales de formes d'occupation du sol ont été retenues. Il s'agit des bâtiments, sols artificiels (asphalte et béton), sols nus, cultures annuelles, végétation naturelle (forêts et autres), eau libre (cours d'eau et retenues artificielle/naturelles). Le tableau 1 présente les valeurs obtenues à la suite du calcul du « ROI separability » sur les quatre catégories d'images. L'ordre des paires de classes, ainsi que celui entre les différentes catégories d'images est croissant et obéit à celui de la catégorie d'image dont les paramètres statistiques remplissent le critère de sélection. Les groupes d'images MNF_IMG, PCA_IMG et IMC_IMG sont celles qui assurent une meilleure séparabilité des objets et probablement assureront une meilleure classification.

Le choix des fonctions de classification à utiliser lors de l'étape de classification s'est appuyé sur la définition d'un critère de sélection permettant de juger la performance globale de chacune. Seules celles qui remplissaient ce critère ont été retenues. Pour cela, nous avons distingué 2 groupes de fonctions de classification supervisée ; celles qui utilisent comme critère de classification la distance ou l'écart-type et celles qui utilisent un seuil de probabilité. Pour le premier groupe de fonctions de classification, nous avons retenu un écart-type égal à 1,000 ; tandis que pour le second groupe, nous avons retenu le seuil de probabilité de 90%. La fonction de classification retenue a été celle qui possède le Pourcentage de Pixels Non Classifié (PPNC) le plus bas et l'indice de Kappa le plus élevé en ce qui concerne la précision de la classification. Parmi toutes les fonctions de classification supervisée proposées dans le logiciel ENVI 5.1, soit 9 au total, les fonctions SVM (Support Vector Machines) et RNA (Réseaux de Neurones Artificiels) sont celles qui remplissent le critère de sélection. Leur précision est plus importante sur le groupe d'image PCA_IMG et MNF_IMG respectivement comparativement à l'image IMC_IMG. Cependant, nous avons retenu la fonction RNA, car elle présente cet avantage sur la fonction SVM qu'elle permet d'utiliser des masques ; ce qui est indispensable pour l'application de l'approche classe par classe.

Tableau 2 : Résultats de la matrice de confusion pour la végétation naturelle

Classes	Commission (%)	Omission (%)	P Précision (%)	U Précision (%)
Bâtiments	68,02	27,65	72,35	31,98
Cultures	22,26	46,96	53,04	77,74
Sols Nus	51,91	4,65	95,35	48,09
Eau	69,81	0	100	30,19
Sols Bétonnés	33,15	77,31	22,69	66,85
Végétation Naturelle	0,07	1,54	98,46	99,93

Tableau 3 : Résultats de la matrice de confusion pour les sols nus

Classes	Commission (%)	Omission (%)	P Précision (%)	U Précision (%)
Bâtiments	61,55	19,33	80,67	38,45
Cultures	3,69	51,17	48,83	96,31
Sols Nus	45,76	6,98	93,02	54,24
Eau	5,13	22,92	77,08	94,87
Sols Bétonnés	21,52	63,61	36,39	78,48

3. Résultats

3.1 Extraction des différentes classes

La fonction RNA a été utilisée avec un critère de sélection de 0,5 pour permettre un pourcentage de pixels classifiés supérieur à 80%. Les différentes classes d'occupation du sol dans notre zone d'étude ont été extraites les unes après les autres suivant une procédure en cinq étapes. L'erreur de commission et l'erreur d'omission ont été utilisées comme critère de validation. Ce sont ces deux types d'erreurs qui permettent de déduire le niveau de précision de chacune des classes (tableaux 2-6). Idéalement, une classe est jugée classée de façon satisfaisante lorsque chacune de ces erreurs (Commission (%) et Omission (%)) est proche de 0. Idéalement, une classe est jugée classée de façon satisfaisante lorsque chacune de ces erreurs est proche de 0. Nous avons recherché sur chacune des trois groupes d'images retenues celle qui donnait le meilleur résultat.

1^{ère} étape – extraction de la végétation naturelle sur l'image MNF_IMG

Parmi ces trois groupes d'images, l'image MNF_IMG a permis de classer la végétation naturelle avec des niveaux d'erreurs de commission et d'omission quasiment nuls (tableau 2). Cela permet d'obtenir des niveaux de précision de 98,46% pour le premier type de précision ou « Producer's accuracy » que nous avons dénommé (P Précision), et de 99,93% pour le second type de précision ou « User accuracy » que nous avons

dénommé (U Précision). Cette image donne un excellent résultat dans la détection de la végétation naturelle. La classe de la végétation naturelle extraite est présentée à la figure 4. Il est à noter que les six premières bandes de cette image ont été utilisées. Dans notre zone d'étude, cette végétation naturelle recouvre principalement la flore se développant sur les sols hydromorphes des fonds de vallées. Cette image permet également de distinguer les cultures, mais sa faible capacité quant à distinguer l'eau et les sols nus la rend inadéquate pour distinguer les cultures. La végétation naturelle a donc été extraite de l'image classifiée puis utilisée comme masque lors de la deuxième étape.

2^e étape – Extraction des sols nus sur l'image IMC_IMG

L'image IMC_IMG s'est révélée être la plus appropriée pour extraire les sols nus comme l'indique le tableau 3. Elle semble également appropriée pour discerner l'eau, mais à l'examen de l'image classifiée, nous avons observé une importante source d'erreur dans la partie aval du bassin versant (figure 1). Les zones d'ombres du fait du relief sont classées comme étant de l'eau. En utilisant l'image multispectrale, il s'est avéré particulièrement difficile de distinguer les sols nus des cultures et de l'eau. Cette difficulté à distinguer avec une bonne précision les sols nus des cultures, même après avoir masqué la végétation naturelle pourrait s'expliquer si l'on tient compte du calendrier agricole local qui a un impact important

Tableau 4 : Résultats de la matrice de confusion pour l'eau

Classes	Commission (%)	Omission (%)	P Précision (%)	U Précision (%)
Bâtiments	58,00	14,90	85,10	42,00
Cultures	0,00	54,67	45,33	100,00
Eau	1,19	13,54	86,46	98,81
Sols Bétonnés	19,06	56,03	43,97	80,94

Tableau 5 : Résultats de la matrice de confusion pour les cultures

Classes	Commission (%)	Omission (%)	P Précision (%)	U Précision (%)
Bâtiments	55,12	16,31	83,69	44,88
Cultures	1,56	11,68	88,32	98,44
Sols Bétonnés	2,45	47,50	52,50	97,55

Tableau 6 : Résultats de la matrice de confusion pour les Bâtiments et les sols bétonnés

Classes	Commission (%)	Omission (%)	P Précision (%)	U Précision (%)
Bâtiments	29,99	26,52	73,48	70,01
Sols Bétonnés	10,05	11,70	88,30	89,95

sur les états de surface. En effet, le mois de décembre marque la fin de la seconde saison culturale et le début de la troisième qui est principalement consacrée aux cultures maraichères. La couverture végétale des sols cultivés est minimale et sa réflectance est alors proche de celle des sols nus.

De plus, dans la mesure où les cultures maraichères sont exigeantes en eau, elles sont pratiquées préférentiellement dans les zones inondables aux abords des cours d'eaux. En outre, le mois de décembre marque le début de la saison sèche à l'échelle locale (Tsalefac M., 1983 ; Kaffo C., 2005; Kaffo C. et Fongang G., 2009 ; Lounang et al., 2014).

L'extraction des bandes du visible de l'image multispectrale au moment de la classification nous a donc permis de réduire significativement les erreurs de commission, Il a été possible d'obtenir une classe des sols nus avec une très faible erreur d'omission, mais en revanche une importante erreur de commission. La précision est cependant légèrement meilleure que celle obtenue à la première étape (tableau 2). La classe des sols nus extraite est présentée à la figure 4.

3^e étape – Extraction de l'eau sur l'image PCA_IMG

L'image PCA_IMG s'est avérée appropriée pour distinguer l'eau des cultures. La classification menée sur l'image PCA_IMG sur laquelle la végétation naturelle et les sols nus ont été masquées permet d'obtenir les niveaux de précision les plus élevés

pour l'eau (tableau 4). L'erreur de commission est négligeable, mais l'erreur d'omission reste supérieure à 10%. Toutefois, il faut relever que s'agissant de la distinction entre l'eau et les sols bétonnés dans la partie aval du bassin versant, elle est limitée et la classification surestime les sols bétonnés le long du lit du cours d'eau. La classe de l'eau extraite est présentée à la figure 4.

4^e étape - Extraction des cultures sur l'image IMC_IMG

Sur l'image multispectrale IMC_IMG, l'utilisation des bandes 4, 5, 6 et 7 pour classifier les cultures donne des niveaux de précision de l'ordre de 88 à 98% (tableau 5). Tout particulièrement, l'erreur de commission est négligeable. L'erreur d'omission s'explique par la difficulté à distinguer les cultures des anciens bâtiments dans la partie aval du bassin versant. Sa topographie est marquée par une dénivellation de près de 700 m d'altitude entre le plateau Bamiléké et la plaine des Mbos (planche 1). Cette topographie est à l'origine d'une humidité de l'air importante en toute saison (Suchel J.-B., 1988). Les conditions topographique et climatique dans cette partie du bassin versant de la Menoua semblent expliquer pourquoi les erreurs y sont les plus fréquentes. Cependant, l'utilisation du masque combinant la végétation naturelle, les sols nus et l'eau permet d'améliorer la distinction. La classe des cultures extraite est présentée à la figure 4.

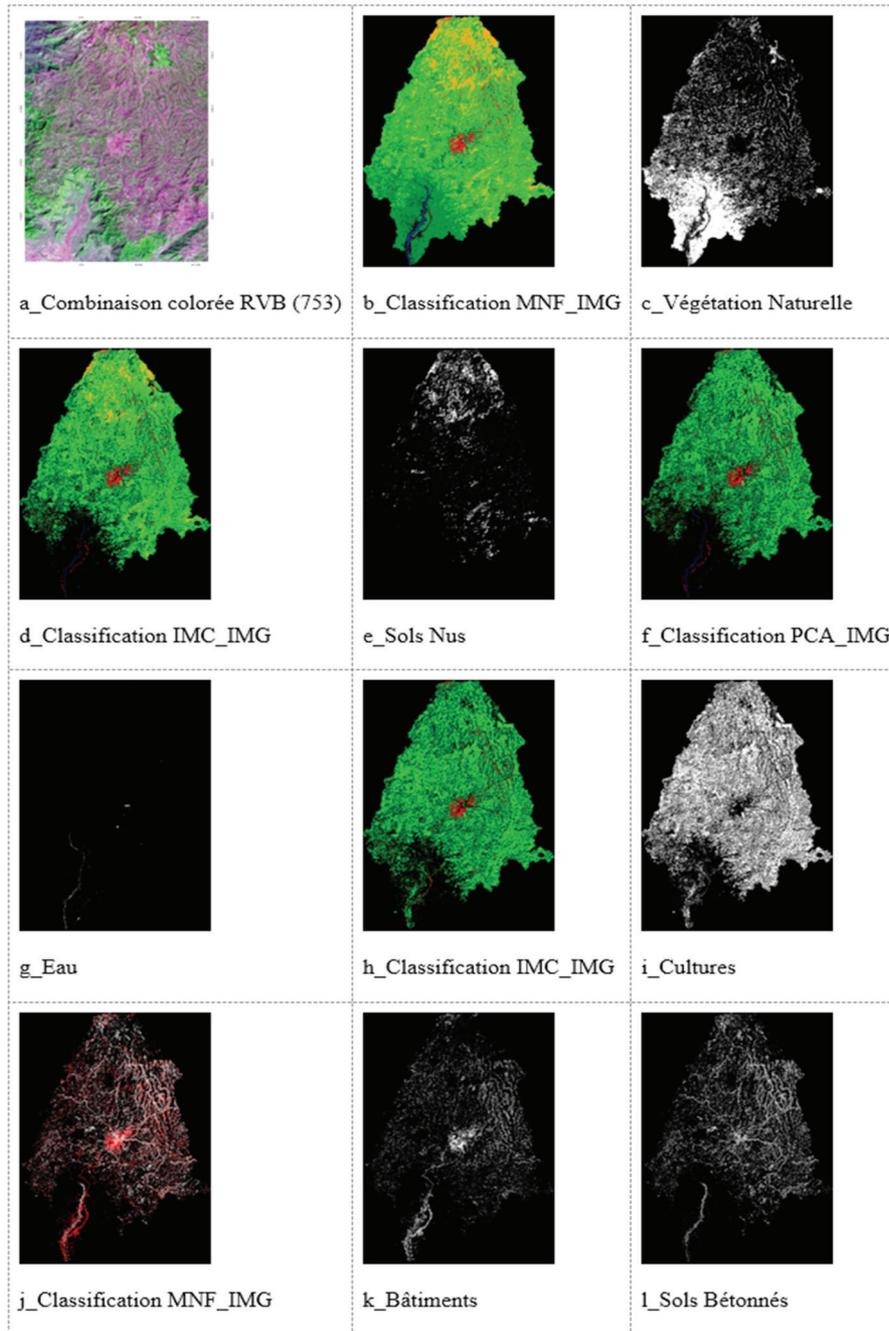


Photo 1 : Extraction des différentes classes à partir des différentes images classifiées

5^e étape – Extraction des bâtiments et des sols bétonnés sur l'image MNF_IMG

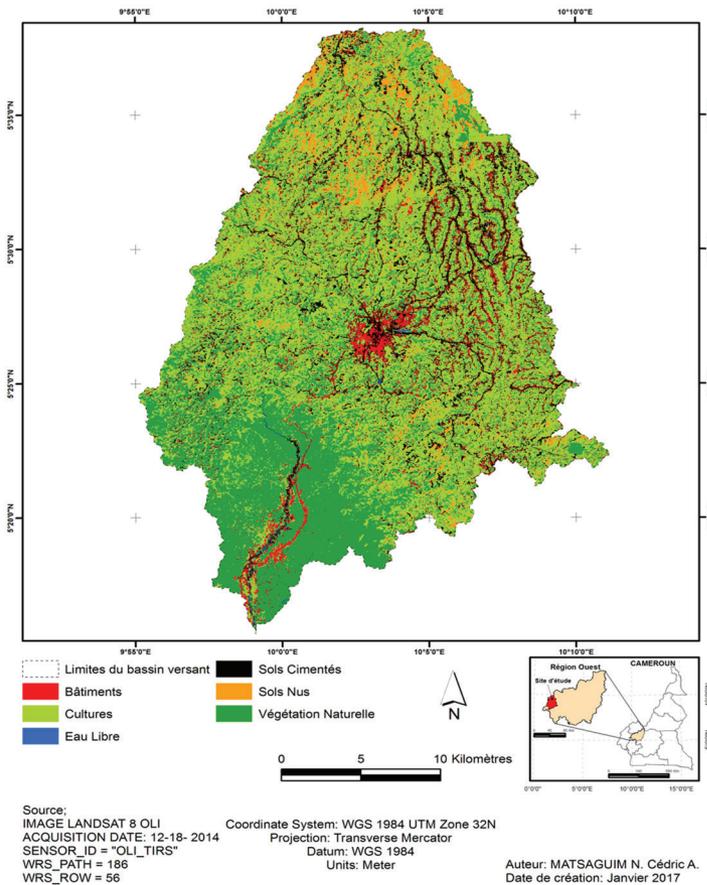
La confusion qui existe entre les bâtiments et les sols bétonnés rend la distinction entre ces deux classes difficile en dépit de l'utilisation des masques. Grâce aux bandes 6, 5 et 7 de l'image MNF_IMG, nous

sommes parvenus à une distinction acceptable entre ces deux classes (tableau 6). En général, la confusion intervient entre les zones d'urbanisation récente et les sols bétonnés autant dans la partie amont du bassin versant que dans sa partie aval. Les classes des bâtiments et des sols bétonnés extraites sont présentées à la figure 4.

Tableau 7 : Statistiques de l'occupation du sol dans le bassin versant de la Menoua en 2014

N° Classes	Noms des classes	Superficie (ha)	P Précision (%)	U Précision (%)	Site (%)
1	Bâtiments	4813	73,48	70,01	7,06
2	Cultures	33369	88,32	98,44	48,93
2	Sols Bétonnés	7091	88,30	89,95	10,40
4	Sols Nus	3543	93,02	54,24	5,20
5	Végétation Naturelle	19343	98,46	99,93	28,35
6	Eau	101	86,46	98,81	0,15
	Total	68263			100
	Moyenne		88,01	85,23	

Occupation du sol dans le bassin versant de la Menoua
Classification numérique à partir de l'Image Landsat 8



Carte 1 : Occupation du sol dans le bassin versant de la Menoua en décembre 2014

3.2 Recomposition de l'image classifiée, validation et interprétation

Une fois les différentes classes extraites les unes après les autres, nous les avons recombinaées afin de

reconstituer l'image entière. La carte 1 présente le résultat final de la classification supervisée. Son degré de précision générale est en moyenne de 88% pour l'erreur de commission et de 85% pour celui d'omission (tableau 7). Autrement dit, pour l'ensemble des classes retenues, l'erreur moyenne de commission est de 12% et celle d'omission est de 15%. Toutefois, il est possible de discerner sur le tableau 7 les classes les mieux classifiées et celles qui le sont moins. L'approche adoptée nous permet d'obtenir un résultat assez satisfaisant compte tenu de l'hétérogénéité spatiale du milieu.

Il nous est possible de procéder à une interprétation des résultats de la classification. Le bassin versant de la Menoua est principalement dominé par les cultures (plus de 70% de sa superficie est mis en valeur (tableau 7). Les cultures ou terres agricoles recouvrent à elles seules environ 49 % du bassin versant, soit quasiment la moitié de l'espace disponible. L'essentiel du couvert végétal naturel se concentre dans sa partie aval. La végétation naturelle ne subsiste plus que dans les fonds de vallées, notamment dans ses parties centrale et amont (carte 1).

Toutefois, elle est également menacée de disparition à cause du développement des cultures maraichères. Cette activité se pratique préférentiellement dans

Tableau 8 : Degré de précision obtenu en utilisant individuellement les fonctions de classification Distance Minimum (MD) et Distance de Mahalanobis (MHD)

N° Classes	Noms des classes	MD		MHD	
		P Précision (%)	U Précision (%)	P Précision (%)	U Précision (%)
1	Bâtiments	75,11	55,03	33,39	22,01
2	Cultures	24,56	41,1	56,02	64,95
2	Sols Bétonnés	29,13	71,04	48,17	55,06
4	Sols Nus	86,53	11,09	93,54	60,89
5	Végétation Naturelle	89,5	89,05	89,28	98,01
6	Eau	17,06	48,01	0	0
	Moyenne		52,55		50,15

Tableau 9 : Degré de précision obtenu en utilisant individuellement les fonctions de classification Maximum de Vraisemblance (ML) et Support Vector Machine (SVM)

N° Classes	Noms des classes	ML		SVM	
		P Précision (%)	U Précision (%)	P Précision (%)	U Précision (%)
1	Bâtiments	82,44	22,56	79,98	34,32
2	Cultures	38,38	33,04	36,01	46,89
2	Sols Bétonnés	33,85	76,89	33,2	85,95
4	Sols Nus	93,88	92,99	94,99	33,02
5	Végétation Naturelle	16,95	100	88,95	87,97
6	Eau	80,01	97,73	94,26	85,06
	Moyenne		70,54		62,20

les zones de fonds de vallées afin de faire face aux problèmes d'eau que connaît la région tant du fait de sa disponibilité que de celui de son utilisation (Dongmo J.-L., 1986 ; Kaffo C. et Fongang G., 2009 ; Tsalefac M., 2011).

4. Discussion

4.1. Comparaison avec les résultats obtenus à partir des fonctions de classification utilisant la distance comme critère de classification

La précision moyenne de notre résultat est de l'ordre de 85% si nous retenons comme indicateur de précision le « User Accuracy » comme le suggère Richards J.A. et Jia X. (2006). Cependant, durant l'étape de classification, nous avons pu distinguer trois principales sources de confusion entre les classes en dépit de l'utilisation des masques. La première apparaît entre les bâtiments, les sols bétonnés et les sols nus. Leurs réflectances sont assez comparables du fait de la présence dans la zone d'étude de bâtiments anciens et de bâtiments récents. La deuxième apparaît entre les sols bétonnés et l'eau précisément dans la partie aval du bassin versant du

fait des conditions atmosphériques qui n'ont pu être totalement éliminées lors de la phase de prétraitement. La troisième source de confusion apparaît entre les cultures, l'eau et les sols nus. Compte tenu de la période d'acquisition de l'image, les sols nus sont la classe qui a été la moins bien classée.

En comparant nos résultats avec ceux obtenus en utilisant individuellement l'une des fonctions de classification prenant en compte la distance comme critère de regroupement, nos résultats sont nettement supérieurs. Nous ne présentons ici que les résultats de la validation obtenus pour les fonctions MD et MHD car, ce sont elles qui donnent les meilleurs résultats dans cette catégorie. Nous pouvons constater en examinant le tableau 8 que la précision des résultats obtenus avec ces fonctions est seulement de l'ordre de 50% (U Précision). En dehors de la végétation naturelle qui obtient des degrés de précision de plus ou moins 90%, toutes les autres classes ont des degrés de précision insatisfaisants. Cela signifie que les erreurs en termes de commission ou d'omission y sont assez importantes. Le cas de la distinction des surfaces d'eau est le plus

Tableau 10 : Degré de précision obtenu en utilisant individuellement la fonction de classification des Réseaux de Neurones Artificiels (RNA)

N° Classes	Noms des classes	P Précision (%)	U Précision (%)
1	Bâtiments	75,56	39,98
2	Cultures	27,03	51,91
2	Sols Bétonnés	50,01	86,05
4	Sols Nus	93,98	50,00
5	Végétation Naturelle	93,01	87,19
6	Eau	92,17	81,21
	Moyenne	71,96	66,06

évident. Cela est dû à la grande confusion qui existe entre cette classe et celle de cultures notamment dans la partie aval du bassin versant.

4.2. Comparaison avec les résultats obtenus à partir des fonctions de classification utilisant un seuil de probabilité comme critère de classification

La comparaison de nos résultats avec ceux obtenus en utilisant individuellement l'une des fonctions de classification prenant en compte un seuil de probabilité comme critère de regroupement, permet également de constater que notre approche par étape donne de bien meilleurs résultats. Nous ne présentons ici que les résultats de la validation obtenus pour les fonctions ML et SVM. En effet, ce sont elles qui donnent les meilleurs résultats dans cette catégorie. L'on peut constater en examinant le tableau 9 que la précision des résultats obtenus avec ces fonctions est de l'ordre de 60 à 70% (U Précision). La fonction ML semble donner les meilleurs résultats. Cependant, il est important de constater qu'elle n'est véritablement performante que sur deux classes à savoir: les sols nus et l'eau en raison du fait qu'ici, les deux indicateurs de précision sont assez élevés. Le cas de la végétation naturelle est trompeur car si les erreurs d'omission sont nulles, celles de commission sont trop importantes. En ce qui concerne la fonction SVM, la végétation naturelle et l'eau sont les classes qui sont les plus précises.

4.3. Comparaison avec les résultats obtenus à partir de la fonction de classification des Réseaux de Neurones Artificiels (RNA)

Il est également intéressant de comparer notre résultat avec celui obtenu par une approche directe utilisant la fonction de classification RNA. Rappelons que c'est cette fonction qui a été utilisée dans notre approche classe par classe. Toutefois, il faudrait noter qu'il

aurait été tout à fait possible d'utiliser différentes fonctions à chaque étape de la classification. Dans le cas d'une approche directe, nous pouvons constater en examinant le tableau 10 que la précision des résultats obtenus avec cette fonction est d'environ 66% (U Précision). Par conséquent en procédant par une approche indirecte, notre approche permet une amélioration significative du degré de précision générale de la classification en utilisant les mêmes images et les zones d'entraînement pour l'étape de classification et les mêmes zones de test pour celle de la validation.

5. Conclusion

En définitive, la démarche de classification adoptée dans le cadre de ce travail nous a permis d'améliorer significativement les résultats obtenus par une méthode directe utilisant une seule fonction de classification. Elle présente l'avantage d'être simple à mettre en œuvre comparativement à la méthode hiérarchique développée par Chen J. et al., (2015). Elle est donc facilement reproductible par tous sans pour autant que cette relative simplicité n'implique une perte en précision. Comme nous l'avons indiqué dans la méthodologie, cette précision dépend premièrement de la définition de critères de sélection des fonctions de classification mais également de la définition des zones d'entraînement et de test. Cette étape est fondamentale. De même, il peut s'avérer utile d'utiliser différentes images lors du processus de classification selon le type d'objet que nous souhaitons distinguer. En contrepartie de la relative simplicité, l'approche présente le désavantage d'être fastidieuse en termes de temps d'analyse. En effet, elle requiert de nombreuses répétitions et peut s'avérer très longue dans le cas où le nombre de classes à définir est très important ; une vingtaine ou plus par exemple. Elle montre tout son intérêt tout particulièrement dans le

cas où l'hétérogénéité spatiale à l'échelle locale rend difficile la distinction entre différentes classes dans le cas d'une approche directe.

Bibliographie

Ahmad, A., Quegan, S. (2012). Analysis of Maximum Likelihood Classification on Multispectral Data, *Applied Mathematical Sciences*, Vol. 6, No.129, 6425 – 6436.

Al-Ahmedi, F.S., Hames, A.S. (2009). Comparison of Four Classification Methods to Extract Land Use and Land Cover from Raw Satellite Images for Some Remote Arid Areas, Kingdom of Saudi Arabia, JKAU; *Earth Sci.*, Vol. 20, No.1, 167-191.

Cao, X., Chen, X.H., Zhang, W.W., Liao, A.P., Chen, L.J., Chen, Z.G., Chen, J. (2016). Global cultivated land mapping at 30 m spatial resolution, *Science China Earth Sciences*, Vol. 59, 2275–2284. DOI: 10.1007/s11430-015-8291-2

Chen, J., Chen, J., Liao, A.P., Cao, X., Chen, L.J., Chen, X.H., He, C.Y., Han, G., Peng, S., Lu, M., Zhang, W.W., Tong, X.H., Mills, J. (2015). Global land cover mapping at 30 m resolution: A POK-based operational approach, *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 103, 7-27. DOI: 10.1016/j.isprsjprs.2014.09.002

Deer, P.J., Eklund, P. (2003). A study of parameter values for a Mahalanobis Distance fuzzy classifier, *Fuzzy Sets and Systems*, Vol. 137, 191 – 213.

Déruelle, B., Moreau, C., Nkoumbou, C., Kambou, R., Lissom, J., Njonfang, E., Ghogomu, R.T., Nono, A. (1991). The Cameroon Line: a review, in: Kampunzu, A.B., Lubala, R.T. (eds.), *Magmatism in Extensional Structural Settings The Phanerozoic African Plate*, Berlin, *Springer*, 274–327.

Dongmo, J.L. (1986). Aménagement et mise en valeur des grands bas-fonds aux sols hydromorphes en Pays Bamiléké, in: Kadomura, H. (ed.), *Geomorphology and Environmental Changes in Tropical Africa, Cameroun*, 95–106.

Dongmo, J.L. (1981). Le dynamisme Bamiléké (Cameroun). Volume I : la maîtrise de l'espace agraire, Yaoundé, *CEPER*.

Dongmo, J.L. (n.d.). Typologie de l'agriculture camerounaise. Essai d'application à l'Afrique noire de la méthode statistico-graphique du professeur Kostrowicki, 19-40.

Dubreuil, V. (1993). Télédétection et cartographie

à petite échelle des paysages de la France de l'ouest, *Mappemonde*, Vol. 2, 18-21.

Erbek, E.S., Özkan, C., Taberner, M. (2002). Comparison of maximum likelihood classification method with supervised artificial neural network algorithms for land use activities, *INT. J. REMOTE SENSING*, Vol. 25, No.9, 1733–1748. DOI: 10.1080/0143116031000150077

Hogland, J., Billor, N., Anderson, N. (2013). Comparison of standard maximum likelihood classification and polytomous logistic regression used in remote sensing, *European Journal of Remote Sensing*, Vol. 4, 623-640. DOI: 10.5721/EuJRS20134637

Kaffo, C., Fongang, G. (2009). Les enjeux agricoles et sociétaux de l'eau sur les monts Bamboutos (Cameroun), *Cahiers Agricultures*, Vol. 18, No.1, 17-25.

Kaffo, C. (2005). Cultures maraîchères dans les montagnes du Cameroun occidental, *Cahiers Agricultures*, Vol. 14, No.6, 517-524.

Kaptué, T.A.T., Roujean, J.L., De Jong, S.M. (2011). Comparison and relative quality assessment of the GLC2000, GLOBCOVER, MODIS and ECOCLIMAP land cover data sets at the African continental scale, *International Journal of Applied Earth Observation and Geoinformation*, Vol. 13, 207–219.

Kengni, L., Tekoudjou, H., Tematio, P., Pamo, Tedongkeng, E., Tankou, C.M., Lucas, Y., Probst, J.L. (2009). Rainfall Variability along the Southern Flank of the Bambouto Mountain (West-Cameroon), *Journal of the Cameroon academy of sciences*, Vol. 8, No.1, 45-52.

Lambert, M.-J., Waldner, F., Defourny, P. (2016). Cropland Mapping over Sahelian and Sudanian Agrosystems: A Knowledge-Based Approach Using PROBA-V Time Series at 100-m, *Remote Sensing*, Vol. 8, 232. DOI:10.3390/rs8030232

Li M., Zang, S., Zhang, B., Li, S., Wu, C. (2014). A Review of Remote Sensing Image Classification Techniques: the Role of Spatio-contextual Information, *European Journal of Remote Sensing*, Vol. 47, 389-411. DOI: 10.5721/EuJRS20144723

Loungang, Tchatchouang, F.C., Djamfa, R.C., Youta, Hapi, J., Tchawa, P., Grozavu, A. (2014). Expansion des cultures de contre-saison, changements d'utilisation du sol et les implications environnementales dans les paysanneries de l'ouest-Cameroun, *SCIENTIFIC ANNALS OF "AI. I. CUZA" UNIVERSITY OF IAȘI*, Vol. LX, No.2, 41-57. <http://dx.doi.org/10.15551/scigeo.v60i2.316>.

- Matsaguim, Nguimdo, C.A. (2012).** Variabilité climatique et adaptation de l'agriculture vivrière de subsistance dans le groupement Foto de l'arrondissement de Dschang (hautes terres de l'ouest-Cameroun), *Mémoire de Master géographie, Université de Yaoundé I.*
- MINEPAT (2013).** Document de stratégie de développement du secteur rural. Etat des lieux et diagnostic du secteur rural au Cameroun, Cameroun.
- Momoa, M.N., Yemefack, M., Tematio, P., Beauvais, A., Ambrosi, J.-P. (2016).** Distribution of duricrusted bauxites and laterites on the Bamiléké plateau (West Cameroon): Constraints from GIS mapping and geochemistry, *Catena*, Vol. 140, 15-23. <http://dx.doi.org/10.1016/j.catena.2016.01.010>
- Ngoufo, R., Tsalefac, M., Kuété, M. (2001).** Les monts Bamboutos (Sud-Ouest du Cameroun) face à la déprise caféière : les enjeux socio-économiques d'une montagne tropicale humide, *Espaces Tropicaux*, No.160, 519-530.
- Ngoufo, R. (1992).** The Bamboutos Mountains: Environmental and rural land use in West Cameroon, *Mountain Research and Development*, Vol. 12, No.4, 349-356.
- Otukei, J.R., Blaschke, T. (2010).** Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms, *International Journal of Applied Earth Observation and Geoinformation*, Vol. 12S, S27-S31. DOI:10.1016/j.jag.2009.11.002
- Pal, M., Mather, P.M. (2005).** Support vector machines for classification in remote sensing, *International Journal of Remote Sensing*, Vol. 26, No.5, 1007-1011. DOI: 10.1080/01431160512331314083
- Perumal, K., Bhaskaran, R. (2010).** Supervised classification performance of multispectral images, *Journal of Computing*, Vol. 2, Issue 2, 124-129.
- Richards, J.A., Jia, X. (2006).** Remote Sensing Digital Image Analysis. An introduction, 4th edition, *Springer-Verlag Berlin Heidelberg.*
- Suchel, J.B. (1988).** Les climats du Cameroun, *Thèse d'Etat*, Université de Bordeaux III.
- Suchel, J.B. (1972).** La répartition des pluies et les régimes pluviométriques au Cameroun, *Travaux et documents de géographie tropicale*, No.5, 287 p.
- Tematio, P., Kengni, L., Bitom, D., Hodson, M., Fopoussi, J.C., Leumbe, O., Mpakam, H.G., Tsozue, D. (2004).** Soils and their distribution on Bambouto volcanic mountain, West Cameroon highland, Central Africa, *Journal of African Earth Sciences*, Vol. 39, 447-457. DOI:10.1016/j.jafrearsci.2004.07.020
- Tchawa, P. (1993).** La dégradation des sols dans le Bamiléké méridional, conditions naturelles et facteurs anthropiques. *Cahiers d'outre-mer*, Vol. 46, No.181, 75-10.
- Tsalefac, M. (2011).** L'aménagement des bas-fonds sur les hautes terres de l'ouest du Cameroun : un exemple d'adaptation planifiée à la variabilité climatique actuelle, *Association Internationale de Climatologie*, Vol. 14, 579-584.
- Tsalefac, M. (1983).** Ambiance climatique des Hautes Terres de l'Ouest du Cameroun, *Thèse de doctorat de 3ème cycle*, Université de Yaoundé.
- Tucker, C.J., Townshend, J.R.G., Goff, T.E. (1985).** Africa land-cover classification using satellite data, *Science*, vol. 227, No.4685, 369-375.
- Valet, S. (2004).** Effet de la sécheresse sur les associations culturales vivrières de l'Ouest-Cameroun, *Sècheresse*, Vol. 11, No.4, 239-247.
- Valet, S. (1999).** L'aménagement traditionnel des versants et le maintien des cultures associées traditionnelles : cas de l'Ouest-Cameroun. *Colloque International " L'Homme et l'Erosion "* IRD, CIRAD, 12-15/12/1999. Yaoundé, Cameroun, 37-68.
- Vancutsem, C., Marinho, E., Kayitakire, F., See, L., Fritz, S. (2013).** Harmonizing and combining existing land cover/land use datasets for cropland area monitoring at the African continental scale, *Remote Sensing*, Vol. 5, 19-41. DOI: 10.3390/rs5010019
- Verhegghen, A., Mayaux, P., de Wasseige, C., Defourny, P. (2012).** Mapping Congo Basin vegetation types from 300 m and 1 km multi-sensor time series for carbon stocks and forest areas estimation, *Biogeosciences*, Vol. 9, 5061-5079. DOI: 10.5194/bg-9-5061-2012
- Wacker, A.G., Landgrebe, D.A. (1972).** Minimum Distance Classification in Remote Sensing, *LARS Technical Reports*, Paper 25. <http://docs.lib.purdue.edu/larstech/25>
- Waldner, F., Fritz, S., Di Gregorio, A., Plotnikov, D., Bartalev, S., Kussul, N., Gong, P., Thenkabail, P., Hazeu, G., Klein, I., Löw, F., Miettinen, J., Dadhwal, V.K., Lamarche, C., Bontemps, S., Defourny, P. (2016).** A Unified Cropland Layer at 250 m for Global Agriculture Monitoring, *Data*, Vol. 1, No.3, 1-13. DOI:10.3390/data1010003