Télédétection, 2003, vol. 3, n° 2-3-4, p. 291–307
Droit de photocopie soumis à l'autorisation

© 2003 CONTEMPORARY PUBLISHING INTERNATIONAL
Publié sous l'enseigne *Éditions scientifiques GB*
Imprimé en France

CLASSIFICATION AUTOMATIQUE NEURONALE DE RÉFLECTANCES SATELLITAIRES (NIVEAU L1 B) DE LA COULEUR DE L'OCÉAN

AWA NIANG*[a,d,1], LIDWINE GROSS[b,2], CYRIL MOULIN[c,3] et SYLVIE THIRIA[c,4]

[a] *Laboratoire de physique de l'atmosphère Siméon Fongang, École Supérieure Polytechnique, Université Cheikh Anta Diop de Dakar, B.P. 5085 Dakar Fann, Sénégal.*

[b] *Laboratoire d'océanographie dynamique et de climatologie, Université Pierre et Marie Curie (Paris VI), 4, place Jussieu, 75252 Paris, Cedex 05, France.*

[c] *Laboratoire des sciences du climat et de l'environnement (CEA/CNRS), Centre d'études de Sarclay, 91191 Gif-sur-Yvette, France.*

[d] *Laboratoire d'océanographie dynamique et de climatologie, Université Pierre et Marie Curie, Tour 26, 4e étage, Boîte 100, 4, place Jussieu, 75252 Paris, Cedex 05, France.*
Téléphone : 33 1 44 27 27 05 ; télécopieur : 33 1 44 27 71 59

Courriel [1,2,3,4,5] : awaniang@ucad.sn ; thiria@lodyc.jussieu.fr ; moulin@lsce.saclay.cea.fr ; awa@lodyc.jussieu.fr

(soumis le 2 juillet 2002 ; révisé le 8 novembre 2002 ; accepté le 25 février 2003)

Nous proposons une méthode de classification automatique neuronale de réflectances satellitaires de la couleur de l'océan, mesurées au-dessus de l'atmosphère. Ces réflectances sont le résultat de l'interaction du rayonnement solaire avec les composants du système océan-atmosphère. Pour obtenir la réflectance marine, il faut retirer du signal la contribution de l'atmosphère. Le but de notre classification est d'identifier, sur une image de couleur de l'océan, les pixels contaminés par les nuages et les aérosols. Cette information est d'une grande importance au moment de choisir l'algorithme spécifique de correction atmosphérique, notamment en présence d'aérosols absorbants. La méthode de classification, non dirigée, basée sur les cartes auto-organisatrices de Kohonen, permet de tenir compte directement de l'information multibande fournie par les radiomètres. On associe à chaque pixel d'une image de télédétection un vecteur dont les composantes sont les mesures multibandes de réflectances et un paramètre permettant de décrire la structure spatiale autour du pixel. La première phase de notre méthode permet une estimation de la densité des mesures radiométriques, en produisant un certain nombre de *vecteurs référents*, qui récapitule l'information contenue dans ces mesures. La deuxième phase consiste à identifier les *référents* en utilisant une connaissance experte. La connaissance experte contient quatre classes géophysiques : nuages, mer claire (aérosols marins) et deux types d'aérosols absorbants. Notre méthode est probabiliste et permet de donner, pour chaque pixel, sa probabilité d'appartenance à chaque classe. Les résultats présentés dans cet article résultent d'une étude sur des mesures du radiomètre couleur de l'océan POLDER, dans la région du Cap-Vert, qui présente une variabilité saisonnière importante en termes d'événement aérosols, de couverture nuageuse et de concentration en chlorophylle-a dans l'océan. La méthode peut être généralisée en augmentant le nombre de classes et incluant plus de longueurs d'onde dans le traitement.

Mots-clefs : couleur de l'océan ; télédétection ; classification d'images ; réseaux de neurones.

AUTOMATIC NEURAL CLASSIFICATION OF SATELLITE OCEAN COLOR LEVEL-1B REFLECTANCES SPECTRA

In this paper, we propose an automatic neural classification method of top of the atmosphere ocean colour reflectances. These reflectances result from the interaction of the sun radiant energy with the constituents of the ocean-atmosphere system. To obtain marine reflectance, the atmospheric contribution should be removed using atmospheric correction. The purpose of the classifier we present here is to isolate, on a remotely sensed image, pixels contaminated by clouds, from pixels containing mineral dusts and from pixels only containing marine aerosols. This information is of great importance when choosing the specific atmospheric correction algorithm, according to the presence (or the absence) of various absorbing aerosols.
The method is an unsupervised neural network model and is based on the self organizing maps (called Kohonen maps). It associates to each pixel a vector of information, which can be for example the multi-spectral information, added to structure parameters. The first step of the method gives an estimate of the radiometric measurements density, by producing a set of *referents vectors,* which summarize the information contained in these measurements. The second phase of the method consists of identifying the referent vectors using an expert knowledge. Our expert knowledge consists in 4 subsets of analysed data, coded on the same dimensions that the referent vectors and containing gathered identified geophysical conditions. Our method is a probabilistic method and allows the computation of the probability for each pixel to belong to a class.

---

* Correspondant principal

To illustrate our neural classification, we focused on a specific region of the globe, centered on the Cape Verde region, which presents an important seasonal variability in term of aerosols transport, cloud coverage and ocean chlorophyll *a* concentration. The results presented here arise from a preliminary study on the POLDER radiometer reflectances.
The limitation of four geophysical classes is not inherent to the method, and would be easily suppressed for an operational application. The method can be generalized by including more
wavelengths in the treatment, it is thus adapted to the radiometers of the next generation.

Keywords : ocean color ; remote sensing ; image classification ; neural network.

1. INTRODUCTION

La productivité biologique de l'océan constitue environ 46 % de la production primaire nette annuelle de la biosphère (Field *et al.,* 1998). Elle conditionne toute forme de pêche et a donc un impact alimentaire et économique majeur pour l'humanité.

De plus, cette productivité a une incidence sur le climat. En effet, elle joue un grand rôle dans les échanges physico-chimiques qui ont lieu au niveau de l'interface air-mer, comme l'absorption du dioxyde de carbone (gaz à effet de serre). De plus, elle a un impact sur la température de la mer car elle modifie les propriétés d'absorption des rayons solaires des couches de surface.

L'analyse de la couleur de l'océan permet de mesurer l'intensité de l'activité biologique dans l'océan par des moyens optiques. L'observation de la couleur de l'océan, qui consiste à mesurer la réflectance spectrale marine dans la partie visible du spectre solaire, permet d'obtenir des indications utiles sur la composition de l'eau. Ce sont essentiellement les constituants minéraux et biologiques présents dans les premières couches marines qui sont responsables des propriétés optiques des océans (Apel, 1987). Au large, les mesures de la couleur de l'océan permettent de calculer la quantité de phytoplancton présente dans l'eau**.** Le phytoplancton est optiquement relié à la mesure radiométrique par ses pigments photo-actifs, principalement la chlorophylle-a (*chla*) (Gordon, 1997). Ces mesures servent à nourrir les modèles de production primaire (Morel and André, 1991), qui calculent la façon dont le phytoplancton croît en utilisant certains gaz de l'atmosphère (notamment le dioxyde de carbone).

Depuis une vingtaine d'années, on se sert de capteurs de mesure optiques embarqués sur les satellites pour surveiller l'océan sur une grande échelle. Les radiomètres pour la couleur de l'océan, placés sur des satellites héliosynchrones qui tournent autour de la Terre à environ 800 km d'altitude, mesurent séquentiellement l'énergie radiative qu'émettent des portions d'océan et d'atmosphère en décomposant le spectre de lumière émis par l'utilisation de plusieurs filtres qui isolent certaines longueurs d'onde (habituellement dans le visible et le proche infrarouge). Ils fournissent donc une information multibande. Les mesures sont le résultat de l'interaction du rayonnement solaire avec les composants de l'atmosphère et de l'océan. Si la réaction à l'éclairement incident de chaque élément susceptible d'être observé est connue, on sait alors restituer la composition de l'océan et de l'atmosphère par inversion des lois optiques.

Pour obtenir la réflectance marine (10 à 20 %) de la réflectance totale (Antoine and Morel, 1998 ; Siegel *et al.*, 2000), il faut donc retirer du signal satellitaire la contribution de l'atmosphère par correction atmosphérique. Les méthodes de correction atmosphérique actuelles se heurtent à de nombreuses incertitudes comme la méconnaissance a priori de la nature et de la quantité d'aérosols présents. Dans un premier temps, on cherche à déterminer si la couverture nuageuse permet un traitement de la mesure. Ensuite, si le traitement est possible, on cherche à déterminer quel modèle d'aérosol va être utilisé pour réaliser la correction atmosphérique (Gordon, 1997 ; Mukai *et al.,* 2000).

Nous nous intéressons à la région du globe, centrée sur le Cap-Vert, siège d'une intense activité de pêche du fait de sa fertilité liée à la résurgence mauritanienne (Dupouy and Demarcq, 1987) et qui présente une variabilité saisonnière importante en terme d'événements aérosols et de couverture nuageuse. Les poussières désertiques très abondantes dans la région posent un grand problème pour les corrections atmosphériques. Elles ont une signature spectrale très prononcée et demandent une correction atmosphérique en mode couplé avec l'océan, car elles absorbent la lumière dans les mêmes longueurs d'onde que le phytoplancton (Gordon *et al.,* 1997 ; Chomko and Gordon, 1998). De plus, ces aérosols désertiques peuvent donner lieu à des épaisseurs optiques importantes et être confondues avec les nuages d'eau. Il est donc très important de pouvoir les détecter pour obtenir des valeurs de réflectance marine correctes.

Nous proposons une méthode de classification automatique neuronale, qui permet d'identifier *a priori* la composition des portions d'océan et d'atmosphère (nuages d'eau, types d'aérosols, eau claire). Cette information est d'une grande importance au moment de choisir l'algorithme spécifique de correction atmosphérique, selon la présence (ou l'absence) de différents aérosols

absorbants (c'est le cas des poussières désertiques).

La méthode est basée sur les cartes auto-organisatrices de Kohonen (*Self Organizing Map SOM*) (Kohonen, 1988). Nous avons utilisé une variante probabiliste, PRSOM (*Probabilistic Self Organizing Map*) (Anouar *et al.*, 1997), de l'algorithme initial pour constituer notre classifieur.

Notre réseau de neurones utilise l'information spectrale contenue dans les différentes bandes spectrales et un paramètre de structure pour classifier chaque pixel individuellement. On obtient des classes spectrales, basées uniquement sur l'information numérique des données. Les classes sont ensuite associées, par une expertise, à des classes d'information utile. Dans cette étude, nous avons limité notre expertise à quatre classes géophysiques. Cette limitation, qui n'est pas inhérente à la méthode, sera facilement levée au moment d'une mise en œuvre opérationnelle. Les performances du classifieur sont évaluées par des tests sur plusieurs images à différentes périodes de l'année.

Les cartes auto-organisatrices ou cartes topologiques sont bien adaptées pour les problèmes de classification et ont été utilisées avec succès pour analyser des données de couleur de l'océan des radiomètres SeaWiFS et OCTS (Yacoub *et al.*, 2000 ; Ainsworth and Jones, 1999).

Les résultats présentés dans cet article sont issus d'une étude sur les données du radiomètre POLDER-1 (*POLarization and Directionality of the Earth's Reflectance)* du CNES (Deschamps *et al.*, 1994) qui était embarqué sur le satellite ADEOS-1 (*ADvanced Earth Observation Satellite*).

La méthode proposée est très générale et permet de traiter l'information multibande des capteurs de façon totalement corrélée. Elle est tout à fait reproductible sur tout type de radiomètre et peut être généralisée en incluant plus de longueurs d'onde dans le traitement. Elle est donc adaptée aux radiomètres de la prochaine génération (MODIS, MERIS, GLI, etc.), car ceux-ci échantillonnent le spectre du visible dans de plus en plus de bandes spectrales, fournissant pour chaque mesure un vecteur d'information de dimension importante. Toute cette information devrait servir à améliorer la correction atmosphérique et permettre la restitution de nouveaux pigments phytoplanctoniques, ce qui mènerait à l'identification des espèces de phytoplancton observées.

2. NATURE DES DONNÉES UTILISÉES

Afin d'illustrer notre méthode de classification neuronale, nous avons étudié une seule région du globe, centrée sur le Cap-Vert. Les aérosols troposphériques présents dans cette zone sont de plusieurs natures :

– il y a naturellement un fond d'aérosols marins, aérosols non absorbants pour lesquels le traitement classique de la correction atmosphérique fonctionne (Gordon, 1997),

– il peut y avoir quelques aérosols carbonés générés par des feux sur le continent africain,

– il y a en grande majorité des poussières provenant du Sahara qui présentent une grande variabilité spatiale et temporelle (Moulin *et al.*, 1997) ; ces poussières désertiques ont une signature spectrale très prononcée (elles absorbent dans le « bleu ») ; elles peuvent donner lieu à des épaisseurs optiques importantes et donc à un signal très brillant.

Les images que nous avons utilisées sont fournies par le radiomètre POLDER-1. Elles ont une taille de 500 × 500 pixels, soit environ 3 000 km × 3 500 km. En raison de notre problématique liée à la couleur de l'océan, nous ne nous sommes pas intéressé aux pixels situés sur la terre. Nous les avons rejetés en utilisant le masque de terre géographique fourni par la chaîne de traitement POLDER. Nous avons échantillonné plusieurs évènements aérosols ainsi qu'une partie de la variabilité saisonnière de l'éclairement solaire, en sélectionnant plusieurs dates : le 29 janvier 1997 (orbite 5080), le 7 mars 1997 (orbite 6023), le 8 juin 1997 (orbite 8180) (figure 1 a, b, c).

Le radiomètre POLDER-1 (Deschamps *et al.,* 1994) mesure l'énergie radiative de la Terre dans neuf bandes spectrales (centrées sur 443, 490, 565, 670, 763, 765, 865 et 910 nm) et il a la particularité de disposer de filtres polarisants pour trois de ces canaux (443, 670 et 865 nm). Le radiomètre possède une autre caractéristique importante : muni d'une grille CCD (*Charged Coupled Device*), il permet, par recouvrement, d'observer un même endroit sous plusieurs géométries de visée différentes. On a alors une information directionnelle sur l'image observée en fonction des géométries de visée (θ_s,θ_v,ϕ) respectivement : l'angle zénithal solaire, l'angle zénithal de visée, la différence azimutal entre le plan du soleil et le plan du satellite.

Pour caractériser le flux d'énergie renvoyé par une surface éclairée, on utilise des grandeurs sans dimension : les réflectances. La réflectance directionnelle pour une longueur d'onde λ, $\rho(\lambda,\theta_v,\phi)$ représente le taux d'énergie renvoyé, $L(\lambda,\theta_v,\phi)$ $(W.m^{-2}.sr^{-1}.nm^{-1})$, dans une direction (θ_v,ϕ), étant donné un éclairement incident diffus $E_0(\lambda)$ $(W.m^{-2}.nm^{-1})$ (Antoine and Morel, 1998).

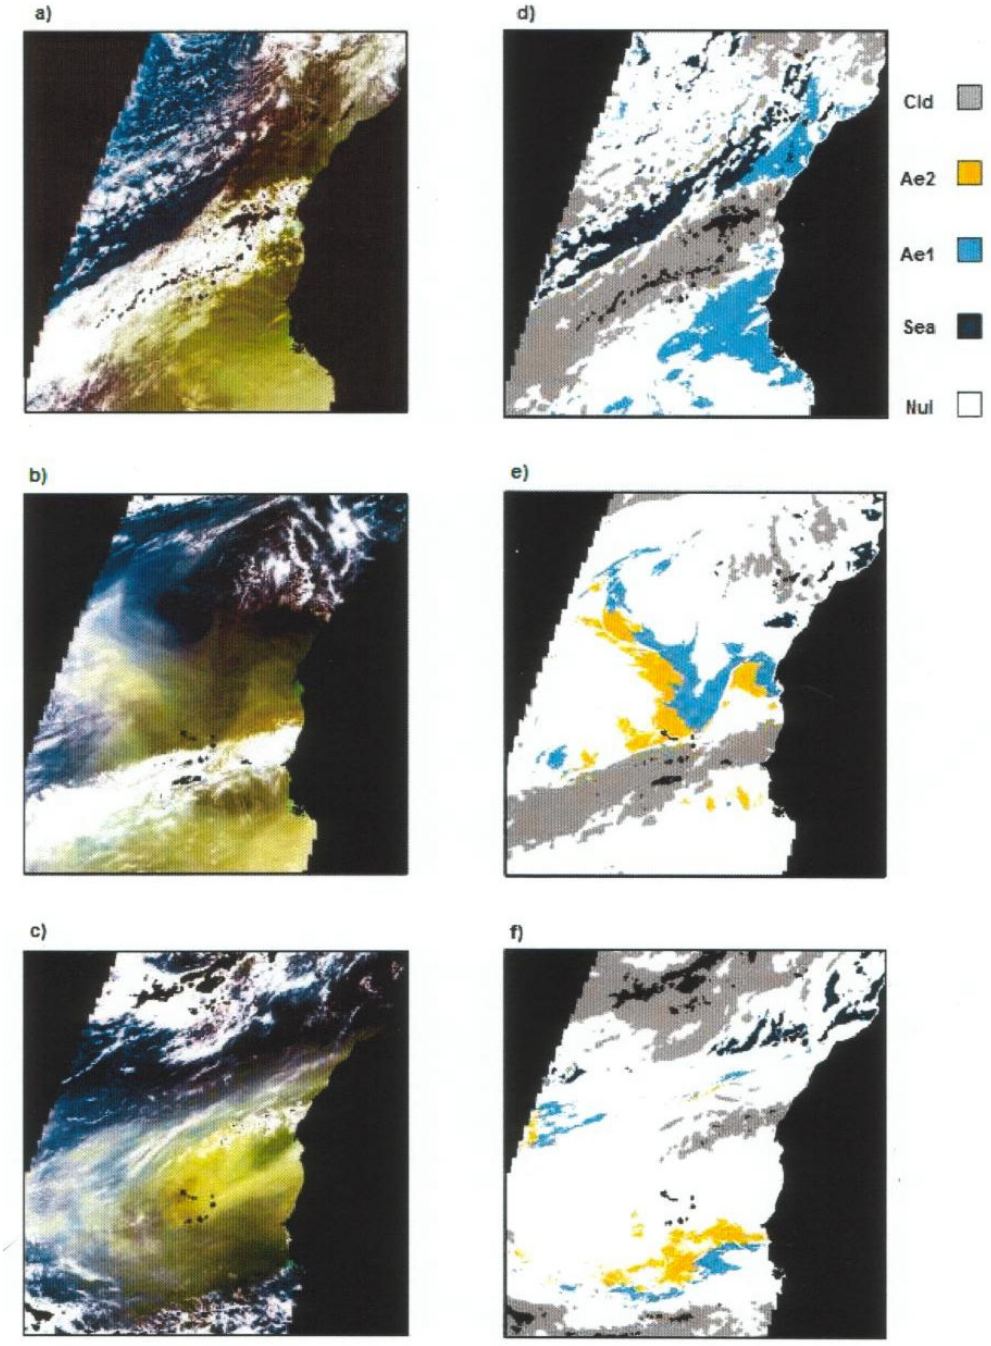


FIGURE 1 Les trois images POLDER utilisées. a à c : composition colorée RVB (rouge-vert-bleu) des orbites 5080, 6023, 8180 ; le canal à 865 nm code le rouge, le canal à 565 nm code le vert et le canal à 443 nm code le bleu ; d à f : les images des mêmes orbites étiquetées par l'expert. Sea représente la classe « Mer », Ae1 la classe « Aérosols 1 », Ae2 la classe « Aérosols 2 », Cld la classe « Nuages » et Nul les pixels non étiquetés. *The three POLDER images. a to c : RGB compostion of orbit 5080, 6023 and 8180 respectively ; the 865 nm channel coding the red, 565 nm coding the green , and 443nm coding the blue ; d to f : Expert's labelled pixels . Sea is for "Sea", Ae1 for "Aerosols 1", Ae2 for "Aerosols 2" Cld for "Clouds"and Nul is for no-labelled pixels.*

Pour un éclairement incident directionnel qui se fait sous un angle θ_s, on définit la réflectance bidirectionnelle $\rho(\lambda,\theta_v,\phi)$ par :

$$\rho(\lambda,\theta_v,\phi) = \frac{\pi L(\lambda,\theta_v,\phi)}{E_0(\lambda)\cos(\theta_s)} \quad (1)$$

Nous avons traité cinq réflectances bidirectionnelles non polarisées $\rho(\lambda,\theta_v,\phi)$ (équation 1) aux longueurs d'onde de 443, 490, 565, 670 et 865 nm. Pour cette première étude nous nous sommes contentés de faire une classification sur les réflectances à angles de visée minimum ($\min(\theta_v)$). Le problème de la directionnalité des mesures n'a donc pas été directement traité durant cette expérience. Cette condition de visée minimise les effets de diffusions multiples sur le signal. On a donc le moins d'interactions optiques possibles des éléments de l'océan et de l'atmosphère avec leur contribution respective sur le signal est découplée au maximum.

Nous avons rejeté les pixels contaminés par la réflexion spéculaire du rayonnement solaire sur la surface de la mer (effet *glitter*). Puis, les réflectances ont été corrigées de l'absorption de l'ozone et de la diffusion Rayleigh, car ces composantes, qui sont quasiment constantes sur le signal (Chomko and Gordon, 1998) diminuent la dynamique des spectres et ne concernent pas notre classification

Pour faciliter la classification, nous avons ajouté une information de contexte à l'information multibande. Cette information est représentée par l'écart type des réflectances à 670 nm (longueur d'onde pour laquelle les aérosols sahariens et les nuages d'eau liquide donnent un signal élevé), calculé sur une région centrée sur chaque pixel (masque 3 × 3 pixels soit 18 km × 21 km. Cet écart type (noté dans la suite s_{670}) est couramment employé comme mesure de l'homogénéité spatiale des structures observées. Les nuages d'eau liquide sont optiquement inhomogènes sur plusieurs kilomètres carrés, et sont associés à des écarts types élevés. Les nuages d'aérosols sont relativement homogènes et donc associés à des écarts types faibles (Moulin *et al.,* 2001 ; Bréon and Colzy, 1999).

Chaque pixel d'une image POLDER est donc représenté par un vecteur de dimension six (les cinq réflectances et l'écart type à 670 nm). Nous noterons par la suite *D*, qui est l'ensemble de données généré par cette succession d'opérations sur les trois images POLDER. Pour l'apprentissage de notre réseau de neurones, nous devons utiliser un sous-ensemble représentatif de *D* que nous appelons base d'apprentissage. Cette base est obtenue par échantillonnage des trois images, en prenant 1 pixel sur 10. La méthode doit ensuite être testée sur des données qui n'ont pas été utilisées pendant l'apprentissage. Nous testerons notre méthode sur chacune des trois images puisque 9 pixels sur 10 de chaque image n'ont pas été utilisés pour l'apprentissage.

Nous disposons également de mesures de réflectance sur les mêmes dates qui ont été réparties par un expert scientifique du transfert radiatif de l'atmosphère sur quatre ensembles de mesures (figure 1 d, e, f). Ces quatre types de mesures ont été constitués en utilisant les produits de la chaîne de traitement POLDER (version opérationnelle de mars 2000). Trois d'entre eux représentent des domaines de variation de l'épaisseur optique des aérosols à 865 nm, $s_a(865)$, calculée lors de la correction atmosphérique (l'épaisseur optique sert à paramétrer l'extinction de la lumière sur tout son trajet). Cela permet de séparer les aérosols marins des poussières. Le dernier est le résultat des tests qui déterminent l'épaisseur de la couche nuageuse. Ces quatre ensembles sont :

– « Mer » (Sea) qui compte 15 451 mesures et qui correspond à la condition suivante : $t_a(865) < 0{,}1$;

– « Aérosols 1 » (Ae1) qui comporte 61 462 mesures et qui correspond à des pixels pour lesquels $0{,}5 < t_a(865) < 0{,}75$;

– « Aérosols 2 » (Ae2) qui comporte 9 341 mesures et qui correspond à des pixels pour lesquels $0{,}75 < t_a(865)$;

– « Nuages » (Cld) qui correspond à des pixels pour lesquels la couverture nuageuse est importante (81 999 mesures).

Nous précisons que ce que nous appelons type de mesure ne correspond pas directement à des types d'aérosols. En effet, les ensembles expertisés ont été fabriqués sur les valeurs de l'épaisseur optique des aérosols seulement, chaque ensemble peut donc contenir des mesures générées par des aérosols de nature différente.

3. MÉTHODOLOGIE

3.1. Cartes auto-organisatrices (SOM)

L'algorithme des cartes auto-organisatrices (ou cartes topologiques) de Kohonen est l'un des modèles neuronaux de l'apprentissage non dirigée, les plus anciens. Un grand nombre de résultats théoriques explicitent les liens entre ce modèle et les méthodes statistiques de classification automatique, d'analyse en composantes

principales non linéaires et d'approximation de fonction densité.

L'algorithme proposé par Kohonen est un algorithme d'auto-organisation qui projette l'espace des données, de grande dimension, sur un espace de faible dimension (en général 1, 2 ou 3) appelé « carte topologique » et notée *C*. Le principe de ce modèle consiste à partitionner de très grands ensembles d'observations en groupements similaires. Les groupements réalisés possèdent la particularité d'avoir une structure de voisinage qui peut être matérialisée par une carte topologique (Kohonen, 1988).

3.1.1. Architecture

Une carte de Kohonen est un réseau de neurones constitué de deux couches totalement connectées entre elles (figure 2).

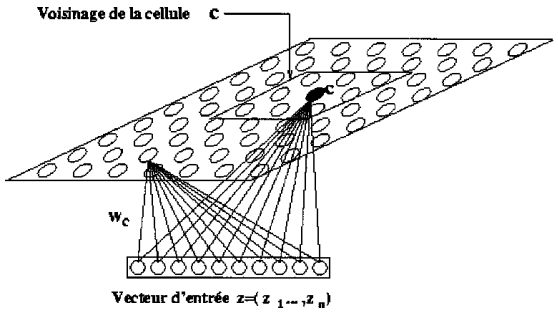


FIGURE 2 Carte topologique : treillis régulier de dimension 2 muni d'un système de voisinage et entièrement connecté à la couche d'entrée. *Architecture of a two dimensional Self-Organizing Map.*

La couche d'entrée sert uniquement à présenter au réseau les données à traiter. Les états des tous ses neurones sont forcés aux valeurs des signaux d'entrée. Dans notre cas, les données d'entrée sont des vecteurs de dimension n = 6.

La seconde couche appelée « carte topologique » est un treillis régulier à deux ou trois dimensions dont chacun des nœuds est un neurone. Le choix de la géométrie de la carte est fait *a priori*. Les liens entre les neurones de *C* se font par une structure de graphe non orienté, qui induit une distance discrète d sur *C*. Pour toute paire de neurones (c,r) de *C*, d(c,r) est définie comme la longueur du plus court chemin entre c et r sur le graphe de *C*. Pour chaque neurone c, cette distance permet de définir la notion de voisinage (zone d'influence autour de chaque neurone). C'est cette notion de voisinage qui introduit les contraintes topologiques dans la représentation finale.

Afin de gérer la taille du voisinage, on utilise une fonction noyau $K^{h(t)}$ qui est régie par un paramètre h(t), appelé température, que nous faisons décroître à chaque cycle de l'apprentissage, et par la distance d. Pour deux neurones c et r, on a :

$$K^{h(t)}(\delta(c,r)) = \exp\left(-0{,}5\,\frac{\delta(c,r)}{h(t)}\right) \qquad (2)$$

Le voisinage est d'autant plus faible que la distance entre les deux neurones est plus grande et l'influence exercée par le voisinage diminue avec la température.

3.1.2. Apprentissage

Si nous identifions par (w_c) le vecteur des connexions ou vecteur de poids reliant la couche d'entrée au neurone c du treillis, l'ensemble des (w_c) constitue les paramètres de SOM qui sont estimés pendant la phase de d'apprentissage. L'apprentissage se fait en un nombre de cycles prédéfinis, un cycle correspondant à la présentation de l'ensemble des observations au réseau.

L'apprentissage se fait en deux étapes. La première étape est une étape d'affectation au cours de laquelle chaque donnée z présentée en entrée va être affectée à un neurone de la carte (neurone gagnant). Le choix du gagnant est effectué par une fonction d'affectation χ :

$$\chi\,(z) = \arg\min_{c} \| z - w_c \|^2 \qquad (3)$$

Une fois le neurone gagnant déterminé, l'observation lui sera associée et appartiendra à la classe du gagnant.

La deuxième étape est l'étape d'adaptation pendant laquelle les neurones modifient leur poids.

L'auto-organisation permet l'adaptation des poids uniquement dans la région la plus « active » de la carte c'est-à-dire dans le voisinage du neurone gagnant.

La mise à jour de la ième composante du poids w_c est calculée de la façon suivante :

$$w_{ci}^{t+1} = w_{ci}^{t} + \alpha(t) * K^{h(t)}(\delta(c,g)) * (z_i - w_{ci}^{t}) \quad \text{si} \quad K^{h(t)}(\delta(c,g)) > 0{,}001 \qquad (4a)$$

$$w_{ci}^{t+1} = w_{ci}^{t} \text{ si } K^{h(t)}(\mathrm{d}(c,g)) \le 0{,}001 \qquad (4b)$$

où $\alpha(t)$ est le pas d'apprentissage qui décroît à chaque cycle.

En fin d'apprentissage, les poids de chaque neurone convergent vers des valeurs telles qu'un neurone ne sera plus actif que pour un sous-ensemble bien déterminé d'observations de la base d'apprentissage. Chaque neurone c a « capté » un

sous-ensemble de données Z_c\{ z_i, i= 1…p). p est la cardinalité du neurone.

Ainsi chaque neurone c représente un sous-ensemble de données à l'aide d'un *vecteur référent* r_{wc}. Le vecteur référent r_{wc} n'est autre que le vecteur poids w_c, arrivant au neurone c en fin d'apprentissage.

L'apprentissage effectué par les cartes auto-organisatrices cherche à ce que ces vecteurs référents captent au mieux la densité de probabilité sous-jacente aux observations. Le réseau va approximer les relations de voisinage existant entre les différents sous-ensembles de l'ensemble des données d'apprentissage. Il impose que deux neurones c et r « voisins » par rapport à la topologie discrète de la carte, soient associés à deux vecteurs référents r_{wc} et r_{wr} « proches » par rapport à la distance euclidienne sur *D*. Un groupe de neurones voisins sur la carte représente donc des ensembles de données voisins dans l'espace des données.

La carte de Kohonen en fin d'apprentissage est un résumé ordonné des données étudiées et on peut parler de quantification vectorielle de l'ensemble *D*. Le choix de la forme et de la dimension du treillis se fait a priori et dépend de l'idée que l'on se fait de la complexité du processus qui a généré les données.

Nous avons utilisé une variante probabiliste de l'algorithme SOM pour constituer notre classifieur.

3.2. Cartes auto-organisées probabilistes (PRSOM)

La différence entre les algorithmes de cartes auto-organisatrices présentées précédemment et le modèle PRSOM réside dans le fait que PRSOM associe à chaque neurone c de la carte une fonction densité normale f_c (Anouar *et al.*, 1997 ; Thiria *et al.*,1997), la notion de voisinage permettant d'introduire un ensemble de mélanges de gaussiennes.

Chaque fonction de densité est complètement définie par son vecteur moyen (vecteur référent r_{wc} d'ordre n) ainsi que par sa matrice de variance-covariance S_c, qui est une matrice carrée d'ordre n définie positive. Dans le cadre du modèle PRSOM, on se limite à la famille de matrices diagonales définie par $S_c = s_c^2$ I, où I est la matrice unité. Ces fonctions ont pour expression :

$$f_c(z) = \frac{1}{(2\pi)^{n/2}\,\sigma_c^n} \exp\left(-\frac{\| z - w_c \|^2}{2\,\sigma_c^2}\right) \qquad (5)$$

Ainsi, dans le modèle PRSOM, à chaque neurone c de la carte, on attribue le vecteur moyen r_{wc} et la variance s_c. L'ensemble des paramètres r_{wc} et s_c constitue les paramètres de PRSOM et doit être estimé durant la phase d'apprentissage.

Si l'on fait l'hypothèse que la distribution sous-jacente aux données est un mélange de lois gaussiennes, le modèle PRSOM va permettre d'estimer les paramètres de ce mélange. Le réseau de neurones correspondant au modèle PRSOM possède une architecture à trois couches : la couche d'entrée sert à la présentation des observations d'entrée, la carte *C* présentée pour le modèle SOM est dupliquée et donne naissance à deux cartes semblables C_1 et C_2 qui présentent la même topologie que la carte *C*. On notera par c_1 (respectivement c_2) un neurone de la couche C_1 (respectivement C_2).

Ce modèle, introduit par Luttrel (1994), suppose qu'un phénomène de propagation probabiliste, dans les deux sens, se réalise à travers les trois couches du réseau. Ainsi, dans le sens qui va de la carte vers l'espace des données, cette propagation est décrite par les probabilités $p(c_1/c_2)$ et $p(z/c_1, c_2)$. De plus, on suppose que ce modèle vérifie la propriété (dite de Markov) :

$$p(c_2/z,c_1) = p(c_2,c_1) \text{ et } p(z/c_1,c_2) = p(z/c_1) \qquad (6)$$

Il devient possible d'exprimer la probabilité de chaque observation z sous la forme :

$$p(z) = \sum_{c2} p(c_2) p_{c2}(z) \text{ où}$$

$$p_{c2}(z) = p(z/c_2) = \sum_{c1} p(c_1/c_2) p(z/c_1) \qquad (7)$$

La densité de probabilité est entièrement déterminée par l'architecture du réseau qui permet de donner une expression à la densité conditionnelle $p(c_1/c_2)$, en utilisant les relations de voisinages sur la carte et la densité conditionnelle des observations $p(z/c_1)$.

En effet, chaque neurone représente une loi normale qui permet d'exprimer la densité conditionnelle des observations $p(z/c_1) = f_{c1}(z, r_{wc1}, \sigma_{c1})$.

Si l'on fait l'hypothèse que les relations de voisinages permettent de définir :

$$p(c_1/c_2) = \frac{1}{T_{c2}} K^{h(t)}(\delta(c_1,c_2)) \text{ avec}$$

$$T_{c2} = \sum_r K^{h(t)}(\delta(c_2,r)) \qquad (8)$$

les densités de probabilités a posteriori des observations peuvent s'exprimer en fonction des distributions gaussiennes des différents neurones :

$$p c_2(z) = \frac{1}{T_{c2}} \sum_{r \in c_1} K^{h(t)}(\delta(c_2,r))\, f_r(z, r_{wr}, \sigma_r) \qquad (9)$$

Ainsi, $pc_2(z)$ apparaît comme un mélange local de densités gaussiennes qui fait intervenir tous les neurones de la carte. L'algorithme PRSOM permet de maximiser la vraisemblance classifiante de l'ensemble d'apprentissage. C'est une méthode de classification dynamique qui se fait en deux étapes, itérativement jusqu'à la convergence, soit les étapes d'affectation et d'adaptation.

Dans l'étape d'affectation, lorsqu'une donnée est présentée au réseau, PRSOM calcule l'activation produite par la donnée dans la fonction densité de chaque neurone. La fonction d'affectation (équation 10) permet de sélectionner le neurone gagnant :

$$\chi(z) = \arg\min_{c_2} pc_2 \qquad (10)$$

Dans l'étape d'adaptation, les paramètres de PRSOM ne sont pas modifiés de façon adaptative tout au long du traitement, comme dans SOM. À la fin de chaque cycle, PRSOM calcule globalement la moyenne et la variance de chaque neurone de telle façon que la loi normale qui lui est associée recouvre la mixture de densité définie par lui même et ses voisins (Dreyfus *et al.*, 2002). Il n'utilise pas de pas d'apprentissage, seule la température h(t) règle l'importance du voisinage.

3.3. Classification

La première étape de la classification consiste à résumer l'information contenue dans l'ensemble d'apprentissage en produisant des référents (vecteurs permettant de résumer l'information) codés sur les mêmes dimensions que les données traitées.

Pour réaliser cette étape nous avons employé une carte topologique probabiliste à deux dimensions de 20×20 neurones. Cette carte va fournir 400 vecteurs référents permettant de résumer les centaines de milliers de spectres contenus dans *D*. Pour limiter les temps de calculs, l'apprentissage a été réalisé en utilisant un ensemble de mesures *D* qui sous-échantillonne *D* en ne gardant qu'un pixel sur dix.

3.3.1. Classification ascendante hiérarchique

À la fin de l'apprentissage, le problème est d'identifier les différentes classes (400) fabriquées d'une manière automatique par l'apprentissage de la carte topologique. Il s'agit de la deuxième étape de la classification, qui consiste à faire ressortir un certain nombre de types de mesures. Cette étape ne peut évidemment se faire qu'en utilisant des connaissances a priori sur les types de mesures que l'on cherche. Nous allons présenter une méthode qui utilise des ensembles de données expertisées. Nous ne chercherons qu'à retrouver les quatre types proposés par notre expert (« Mer », « Aérosol 1 », « Aérosol 2 », « Nuages »).

Notre but est donc d'obtenir quatre classes de référents et de pouvoir attribuer à chacune un nom, que nous appellerons étiquette.

Pour cela, on effectue le regroupement des référents en quatre classes de manière automatique en utilisant une méthode de classification ascendante hiérarchique (CAH) qui permet d'agglomérer plusieurs petites classes en quelques classes de taille plus importante (Jain and Dubes, 1988). Nous utilisons cet algorithme pour regrouper les neurones issus de notre carte topologique.

À partir de singletons, la CAH compose des classes dont la taille est de plus en plus importante. Ainsi, au départ, on assimile chaque neurone (référent) à un singleton. La CAH choisissant les deux classes les plus proches pour les regrouper, il faut donc une mesure de dissimilarité entre les classes. Comme PRSOM donne une estimation de la variance des neurones (singletons) comme mesure de dissimilarité, nous avons utilisé le critère de Ward, qui permet de minimiser la perte de variance intra-classe (Saporta, 1990).

Avant de mettre en œuvre cette CAH, nous avons effectué un codage des mesures qui renforce l'information spectrale. Ce codage doit permettre que l'intensité des mesures ne prenne pas le pas sur leur forme, ce qui est important si l'on veut bien exploiter l'information multibande. Le codage effectué est le suivant : soit $\tilde{\rho}(\lambda)$ les réflectances des référents (les 5 premières composantes du vecteurs référent r_w), on calcule d'abord la pente des pseudo-spectres de réflectances des référents en chaque l_m (m = 1 à 4) :

$$\Delta\tilde{\rho}(\lambda_m) = 100\,\frac{\tilde{\rho}(\lambda_{m+1}) - \tilde{\rho}(\lambda_m)}{\lambda_{m+1} - \lambda_m} \qquad (11)$$

où l_m est la longueur d'onde exprimé en nanomètres ;

on calcule aussi la norme $\|\tilde{\rho}\|$ des spectres de réflectances pour garder une trace de leur intensité.

On associe alors à chaque neurone un vecteur à six composantes :

– la norme de son spectre $\|\tilde{\rho}\|$;
– les quatre pentes de son spectre aux longueurs d'onde de 443, 490, 565 et 670 nm ;
– le pseudo-écart type $\tilde{\sigma}_{670}$ (la sixième composante de son vecteur référent).

La CAH est alors effectuée sur ces référents codés et on dispose en sortie de quatre classes statistiques, notées L_k (k = 1,..4), uniquement basées sur les informations spectrales.

L'affectation des étiquettes se fait alors en utilisant une matrice de confusion qui permet de croiser, sur l'ensemble des mesures expertisées, les types donnés par l'expert et les classes issues du regroupement des neurones.

3.3.2. Probabilités

À la fin de PRSOM + CAH, chaque neurone de C possède une classe. Les ensembles des référents r_{wk} notés C_k, ayant la même étiquette (ou classe) L_k (k = 1,..4), correspondent à différentes fonctions de densité qui approxime la densité de probabilité de la classe L_k. On peut alors calculer la probabilité a posteriori $p(r_w/z)$ pour chaque observation z d'appartenir à r_w et donc la probabilité $p(L_k/z)$ d'une observation z d'appartenir à la classe L_k. En identifiant N au nombre d'observations et n_{rw} au nombre d'observations captées par un référent r_w, la probabilité a priori $p(r_w)$ de r_w peut être estimée par n_{rw}/N. La loi de Bayes permet de calculer la probabilité $p(r_w/z)$ (Dreyfus *et al.*, 2002) :

$$p(r_w/z) = \frac{p(r_w)\, p_{rw}(z)}{p(z)} = \frac{n_{rw} p_{rw}(z)}{\sum_j n_{rwj} p_{rwj}(z)} \qquad (12)$$

où $p_{rw}(z)$ est calculée pendant la phase d'apprentissage. La somme au dénominateur est effectuée sur l'ensemble des référents.

Étant donné qu'une classe est composée par une ensemble de neurones, la probabilité a posteriori est calculée par une sommation sur les neurones de classe L_k :

$$p(L_k/z) = \sum_{r_w \in C_k} p(r_w/z) = \frac{\sum_{r_w \in C_k} n_{rw} p_{rw}(z)}{\sum_{r_w \in C_k} n_{rwj} p_{rwj}(z)} \qquad (13)$$

Un pixel est assigné à l'étiquette de plus forte probabilité.

4. RÉSULTATS EXPÉRIMENTAUX

La carte topologique probabiliste de 20×20 neurones, que nous avons employée, nous a fournis 400 vecteurs référents, qui ont été regroupés en quatre classes par la CAH. Ces quatre classes ont ensuite été identifiées grâce aux mesures expertisées.

4.1. Les 400 vecteurs référents

L'échantillonnage réalisé par les 400 neurones (vecteurs référents) nous a semblé suffisamment représentatif ; chaque référent représente en moyenne 109 mesures, au maximum 560 et au minimum 13. Le critère de contraste de la carte topologique correspondante est de 0,73, ce qui veut dire que les mesures sont assez bien réparties sur l'ensemble des référents.

Cette carte topologique permet d'affecter, à chaque mesure de *D*, un des 400 référents. Nous avons effectué cette affectation à tous les pixels des trois images de *D*.

On peut donc représenter ces images sur 400 niveaux de gris, ou sur une échelle de couleur. Les trois images de *D* partitionnées par la carte topologique sont présentées sur la figure 3 a, b, c. On peut considérer qu'il s'agit d'images tests car 90 % des pixels de ces images n'ont pas participé à l'apprentissage. Sur ces images, nous avons ordonné les référents sur leur valeur à 865 nm, de manière à ce que l'échelle de couleur fournisse une information lisible. Sur la figure 3, on montre que la partition des pixels ainsi obtenue possède une grande finesse. On est donc capable de discerner un grand nombre de conditions d'observation.

4.2. Les quatre classes obtenues après CAH

Nous avons comparé les caractéristiques des quatre classes obtenues après la CAH, aux quatre types de mesures fournis par l'expert. Sur la figure 4, on montre l'allure des spectres de réflectances des quatre types de mesures expertisées.

Dans notre cas, le type « Mer » (Sea) ne semble contenir que des aérosols marins, car les réflectances correspondantes sont fortes dans le bleu et très faibles dans le rouge.

Le second type, « Aérosols 1 » (Ae1), laisse apparaître deux sous-ensembles de mesures dont les variations spectrales sont différentes. Le premier sous-ensemble a une signature spectrale bleue et correspond donc à des aérosols marins de plus forte épaisseur optique que dans l'ensemble « Mer ». Ce premier sous-ensemble contient seulement 1,63 % des données de type « Aérosols 1». Le deuxième sous-ensemble, composé de spectres assez neutres, est essentiellement constitué de poussières sahariennes.

Le troisième type expertisé, appelé « Aérosols 2 » (Ae2), contient des poussières sahariennes d'épaisseur optique forte.

Le dernier type, appelé « Nuages » ou (Cld : Clouds) contient des spectres d'intensité variée et sans coloration spectrale.

Sur la figure 5, on montre également que la différence entre le type « Mer » et les autres types peut se faire au moyen de l'information multidimensionnelle. En revanche, les types « Aérosols 1 » ou « Aérosols 2 » et le type « Nuages » peuvent être discernés surtout grâce aux valeurs de s_{670}.

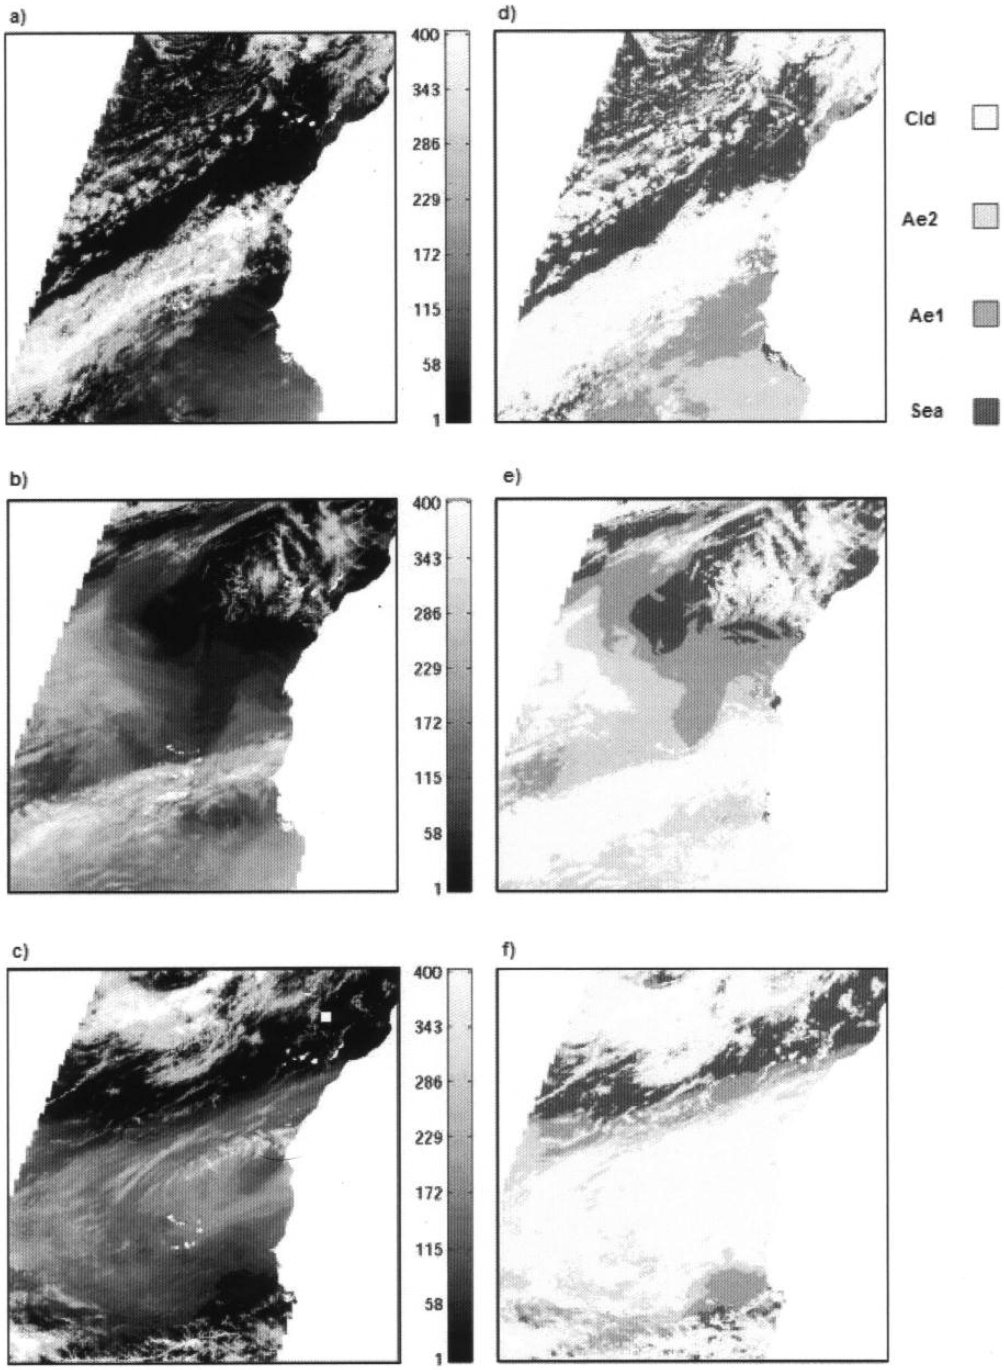


FIGURE 3 Partition des images POLDER. a à c : partitions des images par les 400 référents après PRSOM ; tous les pixels de même niveau de gris sont assignés au même référent ; en comparant avec les images RVB de la figure 1 on se rend compte la partition en 400 classes est représentative de l'ensemble des mesures ; d à f : classification des images en quatre classes après PRSOM+CAH. Sea représente la classe 1 identifiée « Mer », Ae1 la classe 2 ou « Aérosols 1 », Ae2 la classe 3 ou « Aérosols 2 », Cld la classe 4 « Nuages ». *Clustering of the three images. a to c : clustering using the 400 referent vectors* r_w. *; all the pixels which have the same gray-level belong to the same* r_w *; d to f : the PRSOM + CAH clustering in four classes; sea is for classe 1 "Sea", Ae1 is for classe 2 or "Aerosols 1", Ae2 is for classe 3 or "Aerosols 2", Cld is for classe 4 or "Clouds".*

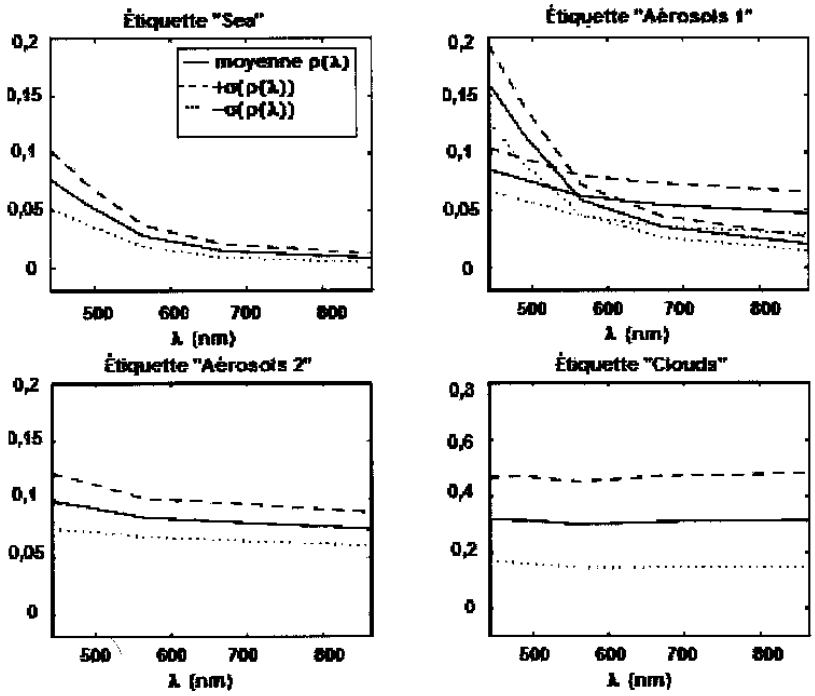


FIGURE 4 Les spectres de réflectances des quatre types de mesures radiométriques expertisées. Les lignes pleines représentent les spectres moyens $\rho(\lambda)$ et les lignes discontinues $\rho(\lambda) \pm \sigma(\lambda)$; $\sigma(\lambda)$ étant l'écart type des spectres. *The reflectance spectra for the four expert's labelled class: the mean spectrum* $\rho(\lambda)$ *(solid lines) surrounded by more or less 1 standard deviation* $\rho(\lambda) \pm \sigma(\lambda)$ *(dash lines).*

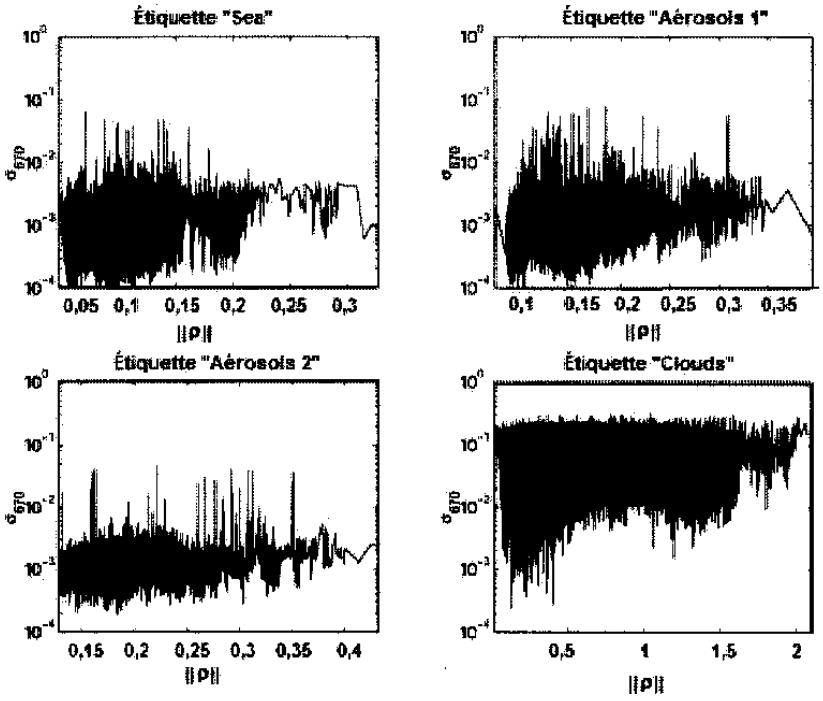


FIGURE 5 Graphe des écarts types σ_{670} en fonction de l'intensité des spectres de réflectances des quatre types de mesures radiométriques expertisées. *Values of* σ_{670} *versus the reflectance spectra intensity, for the four expert's labelled class.*

Si l'on représente les ensembles de neurones obtenus après la CAH, d'une manière similaire à celle avec laquelle nous avons présenté les données expertes, on peut observer (figures 6 et 7) que les spectres de réflectance associés aux neurones d'une certaine classe (1, 2, 3 et 4) présentent les mêmes caractéristiques que les données expertisées (« Mer », « Aérosols 1 », « Aérosols 2 », « Nuages ») (figures 4 et 5).

Notons que la classe 2 ne présente plus deux modes spectraux distincts, contrairement aux mesures appelées « Aérosols 1 ». Ce résultat est certainement dû au codage utilisé pour effectuer la CAH car chaque classe présente maintenant un comportement spectral bien déterminé.

4.3. Classification des pixels

Chaque pixel d'une image de D est affecté à un neurone et prend donc la classe (1, 2, 3 ou 4) de ce neurone. Sur la figure 3 d, e, f, on montre les résultats de cette classification en quatre classes sur les trois images.

On peut également identifier les quatre classes de pixels des trois images, en les comparant aux quatre classes des pixels expertisées (figure 1 d, e, f) à l'aide d'une matrice de confusion.

La matrice de confusion est représentée sur le tableau 1. Chaque ligne du tableau 1 détaille le taux de participation d'un type de mesures expertisées dans chacune des quatre classes de la CAH (sur chaque ligne la somme des taux est égale à 100 %).

La classe 1 est clairement identifiable aux mesures « Mer » car 98,98 % des mesures se placent dans cette classe. Tous les neurones de cette classe prennent donc l'étiquette « Mer ».

Les mesures « Nuages » sont à 96,13 % dans la classe 4. Aussi nous attribuons à chaque neurone de cette classe, l'étiquette « Nuages ».

Les mesures « Aérosols 1 » se répartissent sur les classes 1, 2 et 3, mais se placent principalement dans la classe 2 (65,38 %). Nous affectons tous les neurones de cette classe 2 de l'étiquette « Aérosols 1 », même si les mesures de types aérosols 1 contiennent des sous catégories du point de vue de notre classifieur.

La classe 3 comprend des pixels de type « Aérosols 1 », « Nuages » et principalement « Aérosols 2 » (65,02 %) et nous l'identifierons donc « Aérosols 2 ». Notons toutefois que 29,7 % des mesures « Aérosols 2 » se placent dans la classe 4 que nous avons identifiée « Nuages ».

Nous pouvons penser que les classes générées par la CAH représentent bien les quatre types de mesures mises en évidence par l'expert. Moins de 1 % des pixels « Mer » et moins de 4 % des pixels « Nuages » ont été mal classés. Les classes 1 (« Mer ») et 4 (« Nuages ») ont donc été bien identifiées. Il demeure une certaine confusion en ce qui concerne les aérosols. En effet, près de 30 % des pixels « Aérosols 2 » ont été placés dans la classe 4.

4.4. Probabilités

Sur la figure 8, on montre (en rouge) les pixels dont la probabilité d'appartenance à une classe (calculée par l'équation 13) est inférieure à 0,75. Ces pixels apparaissent principalement aux limites des classes et correspondent à des zones de transition d'une classe à l'autre. Certains de ces pixels ont une probabilité légèrement supérieure à 0,5 pour une classe et légèrement inférieure à 0,5 pour la classe voisine, ce qui correspond à une certaine indétermination pour la classe de ce pixel. La probabilité peut être utilisée pour contrôler la classification et mettre en évidence les pixels de classe incertaine.

On peut comparer visuellement cette classification avec les images RVB de la figure 1 a, b, c. Il semble que les pixels contaminés par les nuages ont bien été classifiés « Nuages », ce qui est un résultat très positif, pour faciliter le traitement de la couleur de l'océan. Cependant, certains pixels « jaunes » sur les images RVB des orbites 6023 et 8180 , supposés être des pixels contaminés par des poussières sahariennes ont été aussi classifiés « Nuages ». Ces pixels sont représentés (figure 3, b c) par quelques vecteurs référents de classe (parmi les 400) différente de celle des vecteurs référents représentants les nuages. C'est durant le regroupement en quatre classes que ces deux types ont été confondus.

Nous notons également que ces pixels n'ont pas été étiquetés par l'expertise (figure 1 d, e, f). Nous pensons qu'il s'agit d'une autre classe d'aérosols (différente des classes « Aérosols 1 » et « Aérosols 2 »). Pour illustrer ceci, nous avons effectué la CAH pour obtenir sept classes. L'image obtenue pour l'orbite 6023 est représentée sur la figure 9 sur laquelle nous voyons bien apparaître la séparation des nuages et de la troisième classe d'aérosols.

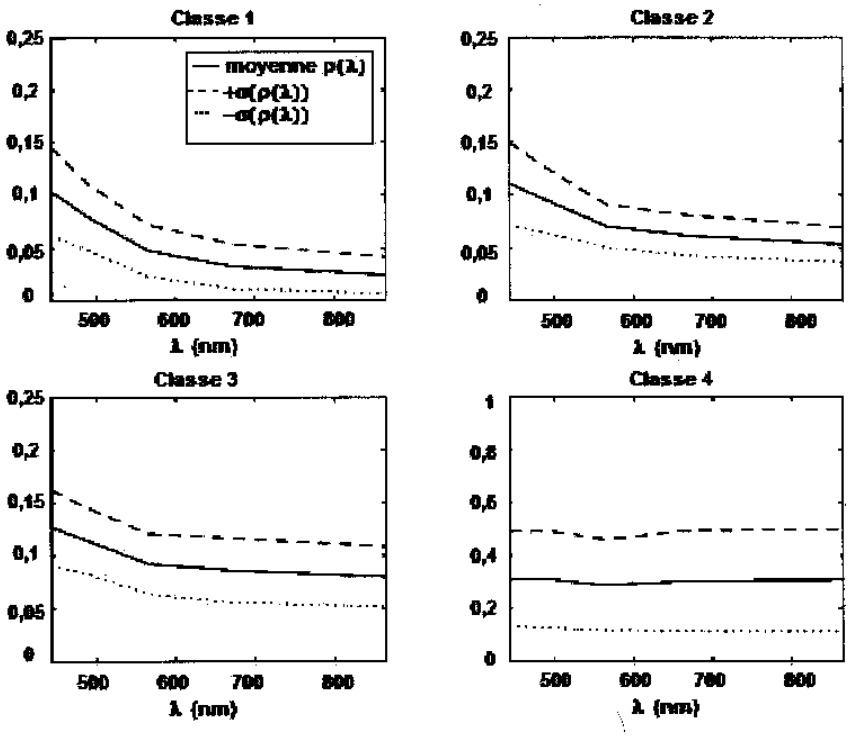


FIGURE 6 Les spectres de réflectances des quatre classes obtenues après PRSOM + CAH. Les lignes pleines représentent les spectres moyens (représenté par $\rho(\lambda)$ et les lignes discontinues $\rho(\lambda) \pm \sigma(\lambda)$; $\rho(\lambda)$ étant l'écart type des spectres. *Reflectance spectra of the* ρ_w *labelled using the CAH + PRSOM method.*

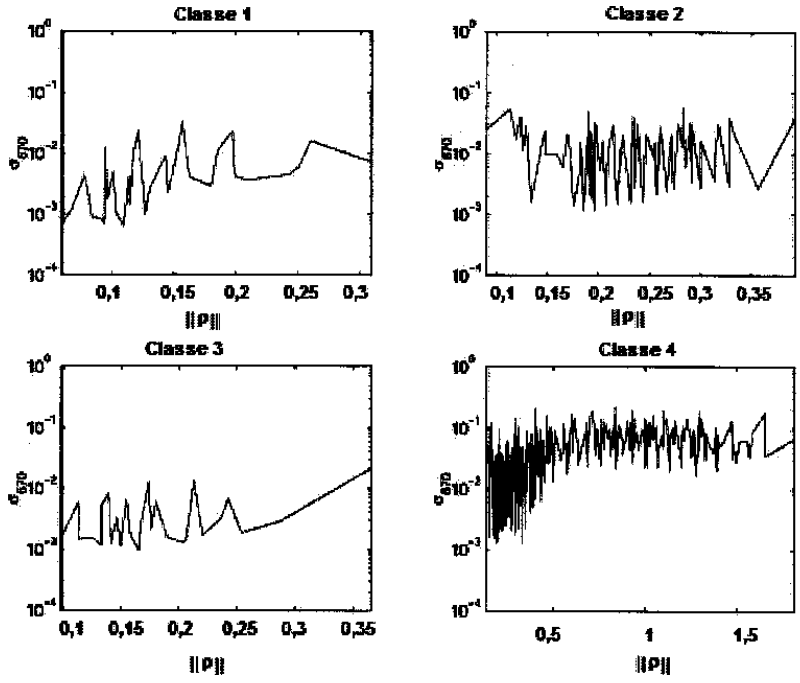


FIGURE 7 Graphe des écarts types σ_{670} en fonction de l'intensité des spectres de réflectances pour les quatre classes obtenues après PRSOM + CAH. *Values of the labelled* ρ_w*'s* σ_{670} *versus the reflectance spectra intensity.*

TABLEAU 1 Matrice de confusion entre les ensembles de mesures expertisées et les quatre classes déterminées par la méthode de classification. Les taux de participation sont exprimés en pourcentages. La somme sur chaque ligne est égale à 100 %. *Confusion matrix showing the amounts of the pixels classified by the expertness (lines), spread by the neural method in each class (columns). The matrix have been made so that the sum of the amounts on each line is equal to 100.*

	Les quatre classes de PRSOM + CAH			
	Classe 1	Classe 2	Classe 3	Classe 4
Les quatre classes de l'expert				
Mer	98,98	00,98	00,04	0
Aérosols 1	1695	65,38	16,28	01,39
Aérosols2	00,01	05,27	65,02	29,70
Nuages	00,46	00,17	03,24	96,13

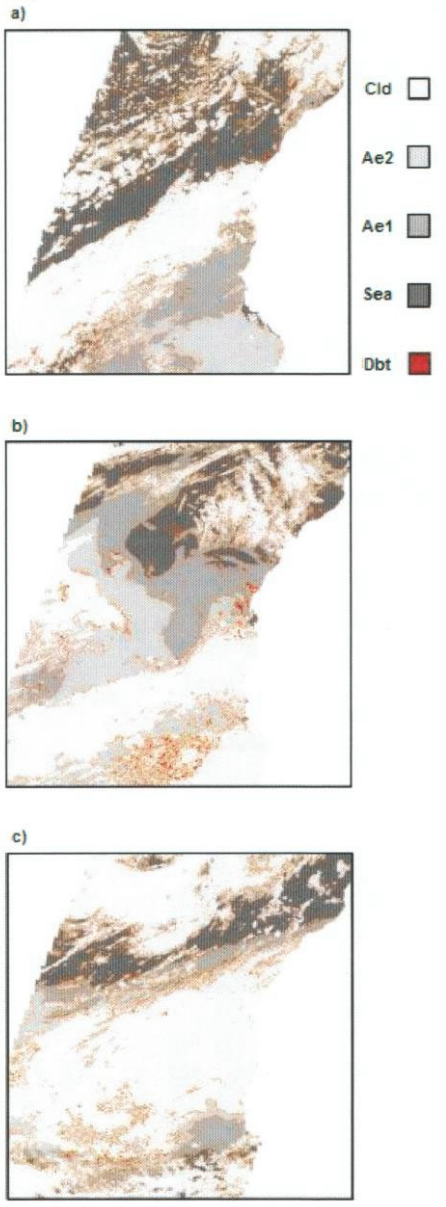


FIGURE 8 Images POLDER labellisées en quatre classes par PRSOM+CAH et représentation des probabilités des pixels d'appartenir aux quatre classes. a) orbite 5080, b) orbite 6023, c) orbite 8180. « Dbt » indique les pixels dont la probabilité est inférieure à 0,75 (en rouge). *Sea représente la classe « Mer », Ae1 la classe « Aérosols 1 », Ae2 la classe « Aérosols 2 », Cld la classe « Nuages ». The results of the labelled topological PRSOM map on the three POLDER images: same as figure 3 d, e and f but showing the pixels for which the highest probability* $p(L_k/z)$ *is smaller than 0,75 ("Dbt" pixels).*

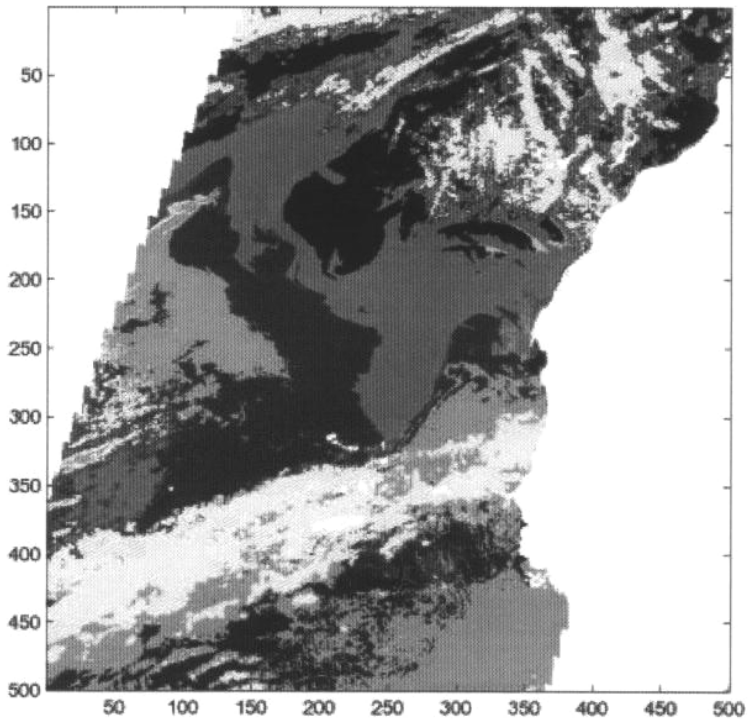


FIGURE 9 Image POLDER de l'orbite 6023 étiquetée en sept classes par PRSOM+CAH . *POLDER image (#6023 orbit) labelled in seven classes by PRSOM + CAH method.*

5. DISCUSSION

La méthode de classification automatique que nous avons présentée ici permet d'extraire, grâce à 400 vecteurs référents, l'information multibande contenue dans les images POLDER (figure 3 a, b, c). Ces 400 vecteurs peuvent ensuite été regroupés par la CAH. Le codage que nous avons utilisé (section 3) permet de renforcer l'information spectrale et donc d'améliorer la classification. La classification automatique (PRSOM + CAH) peut être aussi détaillée que l'on veut (nombre de classes désirées variable) mais on rencontre un problème d'interprétation des classes. L'utilisation d'un expert s'avère nécessaire.

Nous avons choisi de regrouper les 400 neurones en quatre classes que nous avons identifiées en les comparant aux quatre classes géophysiques fournies par un expert du transfert radiatif. Ainsi, 263 des 400 neurones ont été identifiés comme étant des nuages. Cela était prévisible, si on considère le grand nombre de pixels contaminés par les nuages sur les images POLDER utilisées. Les 137 neurones restants ont été utilisés pour classifier les aérosols : 34 neurones ont été étiquetés « Mer » (ou aérosols marins), 29 « Aérosol 1 » et 74 « Aérosol 2 ».

Les spectres des neurones de nos quatre classes et ceux des quatre classes géophysiques présentent les mêmes caractéristiques particulièrement pour la mer et les nuages.
La projection des neurones sur chacune des trois images donne une bonne identification des pixels Mer et des pixels contaminés par les nuages. Les résultats sont cohérents si on compare les images obtenues aux images RVB. Tous les pixels contaminés ont été classifiés « Nuages ». Cette détection des nuages est très importante pour les chaînes de traitement des mesures de couleur de l'océan.

Il demeure une certaine confusion entre les deux types d'aérosols de poussières et certains aérosols de très fortes épaisseurs optiques ont été confondus avec les nuages.

L'augmentation du nombre de classes de la CAH, permet de séparer ces aérosols des nuages. Dans les épaisseurs optiques, des détails qui semblent cohérents avec la RVB sont apparus, mais il faudrait pouvoir identifier ces aérosols à l'aide d'une expertise plus fine que celle dont nous disposions Il serait intéressant de pouvoir interpréter physiquement les spectres correspondants pour essayer de les caractériser. Nous précisons encore que les types de mesures dont nous disposons ne sont pas vraiment des

types d'aérosols. Les ensembles expertisés peuvent contenir des mesures générées par des aérosols de nature différente.

Pour chaque pixel, nous avons ensuite calculé sa probabilité d'appartenir à l'une des quatre classes. Les pixels situés aux limites entre les classes ont des probabilités inférieures à 0,75 en général et , pour certains, des probabilités légèrement supérieures à 0,5. Cela est cohérent si on considère la taille des pixels (6 km × 7 km) qui peuvent contenir deux ou plusieurs types de mesures. Notre méthode donne donc leur probabilité d'appartenir à chacun de ces types de mesures.

6. CONCLUSION

La méthode de classification automatique sur carte topologique (PRSOM) que nous avons utilisée permet de représenter l'espace des mesures radiométriques par un certain nombre de vecteurs référents (ou neurones). L'avantage de PRSOM est de fournir une information probabiliste sur les référents et de permettre d'estimer la probabilité de chaque pixel d'appartenir à une classe.

Comme ces neurones sont en relativement petit nombre (quelques centaines), on peut les classer en se servant d'une classification ascendante hiérarchique (CAH) qui tient compte de toute l'information spectrale. Cette méthode se distingue alors des analyses des chaînes de traitement opérationnelles (voir Bréon et Colzy, 1999, pour les nuages, et Gordon, 1997, pour les aérosols). On peut également choisir d'analyser physiquement les différents spectres des neurones affectés aux classes.

Nous avons montré un exemple de regroupement des pixels par forme de spectre de réflectances. Le problème majeur est d'interpréter correctement les résultats de classification obtenus. On peut obtenir un nombre de classes variable en fonction de l'expertise dont on dispose. Les regroupements de mesures peuvent ensuite être visualisés et identifiés par des mesures expertisées (par exemple grâce à des matrices de confusion). Cette manière de procéder donnerait de très bons résultats avec l'utilisation d'une expertise plus fine.

Notre expérience nous a permis d'obtenir une bonne détection des pixels de « Mer claire » (aérosols marins) et de « Nuages ». Concernant les aérosols de poussières, le manque de précision des mesures expertisées ne nous a pas permis d'obtenir de meilleurs résultats. Mais nous avons montré que toute l'information spectrale concernant ces aérosols était contenue dans nos référents, le problème étant de les identifier.

Les nuages présentent une grande dispersion et il serait intéressant de construire d'abord un classifieur pour détecter les pixels contaminés par les nuages et les séparer des autres. Un second classifieur dédié aux aérosols pourrait ensuite être développé.

Cette méthode pourrait être mise en œuvre dans les chaînes de traitement couleur de l'océan pour remplacer les tests classiquement appliqués pour la détection des nuages.

Les prochaines étapes de la conception de ce classifieur seront probablement les suivantes :

– étendre géographiquement les ensembles de mesures étudiés ;

– aborder le problème de la directionnalité, en ajoutant l'angle de visée du radiomètre (q_v) comme variable du problème, et en ajoutant probablement une dimension à la carte topologique (ce qui donnerait une carte 3D) de manière à pouvoir traiter cette variable ;

– augmenter le nombre et la précision des mesures expertisées ;

– utiliser des mesures *in situ* pour valider les résultats de cette classification.

Il serait par la suite intéressant d'utiliser les résultats obtenus pour appliquer une méthode de classique de correction atmosphérique en fonction des différents types d'aérosols identifiés pour juger des éventuelles améliorations apportées par la méthode proposée.

Remerciements

Ce travail a été soutenu par le Centre national des études spatiales (convention n° 794/CNES/98/7118), une bourse d'excellence de l'Agence universitaire de la Francophonie (AUF), une bourse d'Échanges scientifiques de courte durée de l'Institut de recherche et de développement (IRD), la Direction générale des recherches de la Commission européenne (NAOC, n° de contrat Evg1-ct-2000-00034) et de l'Aérospatiale (Cannes, France). Nous remercions Michel Crépon et Yves Dandonneau (du Laboratoire d'océanographie dynamique et de climatologie, de l'Université Pierre et Curie, Paris, France) des discussions stimulantes.

Références bibliographiques

Ainsworth, E. J. and Jones, S. F. (1999) Radiance spectra classification from the Ocean Color and Temperature Scanner on ADEOS. IEEE. Transactions on Geoscience and Remote Sensing, vol. 37, n°3, p. 1645-1656.

Anouar, F., Badran, F. and Thiria, S. (1997) Self Organized Map, A Probabilitic Approach. *In* Proceeding of Workshop on self Organized Maps. Helsinki University of Technology, Espoo, Finland, June 4-6, p. 339-344.

Antoine, D. and Morel, A. (1998) Relative importance of multiple scattering by air molecules and aerosols in forming the atmospheric path radiance in the visible and near-infrared

parts of the spectrum. Applied Optics, vol. 37, n°12, p. 2245-2259.

Apel, J. R. (1987) Principles of Ocean Physics. Academic Press, New York, 634 p.

Bréon, F. M. and Colzy, S. (1999) Cloud detection from the spaceborn POLDER instrument and validation against surface synoptic observations. Journal of Applied Meteorology, vol. 38, p. 777-785.

Chomko, R. M. and Gordon, H. R. (1998) Atmospheric correction of ocean color imagery : use of the Junge power-law aerosol size distribution with variable refractive index to handle aerosol absorption. Applied Optics, vol. 37, n°24, p. 5560-5572.

Deschamps, P. Y., Bréon, F. M., Leroy, M., Podaire, A., Bricaud, A., Buriez, J. C. and Sèze, G. (1994) The POLDER mission : instrument characteristics and scientific objectives. IEEE Transactions on Geoscience and Remote Sensing, vol. 32, n°3, p. 598-615.

Dreyfus, G., Martinez, J. M., Samuelides, M., Gordon, M. B., Badran, F., Thiria, S. and Hérault, L. (2002) Réseaux de neurones : méthodologie et applications. Éditions Eyrolles, Paris, 386 p.

Dupouy, C. and Demarcq, H. (1987) CZCS as an aid for understandingmadalities of the phytoplancton productivity during upwelling off Senegal. Advances in Space Research, vol. 37, n°2, p. 63-67.

Field, C. B., Behrenfeld, M. J., Randerson, J. T. and Falkowski, P. (1998) Primary production of the biosphere : integrating terrestrial and oceanic components. Science, vol. 281, p. 237-240.

Gordon, H. R. (1997) Atmospheric correction of ocean color imagery in the Earth Observing System Era. Journal of Geophysical Research, vol. 102, n° D14, p. 17081-17106.

Gordon, H. R., Du, T. and Zhang, T. (1997) Remote sensing of ocean color and aerosol properties resolving the issue of aerosols absorption. Applied Optics, vol. 36, n°33, p. 8670-8684.

Jain, A. K. and Dubes, R. C. (1988) Algorithms for clustering data. Advanced Reference Series, Prentice Hall, Englewood Cliffs (N.J.), 320 p.

Kohonen, T. (1988) Self organizing and associative memory. Springer-Verlag, Berlin, 312 p.

Luttrel, S. P. (1994) A Bayesian analysis of self-organizing maps. Neural Computation, vol. 6, n°5, p. 767-794.

Morel, A. and André, J.M. (1991) Pigment distribution and primary production in the western Mediterranean as derived and modeled from coastal zone color scanner observations. Journal of Geophysical Research, vol. 96, p. 12685-12698.

Moulin, C., Lambert, C. E., Dulac, F. and Dayan, U. (1997) Control of Atmospheric Export of Dust from North Africa by the North Atlantic Oscillation. Nature, vol. 387, p. 691-694.

Moulin, C., Gordon, H. R., Chomko, R., Banzo, V. F. and Evans, R. H. (2001) Atmospheric correction of Ocean Color imagery through thick layers of saharan dust. Geophysical Research Letter, vol. 28, p. 5-8.

Mukai, S., Sano, I. and Okada, Y. (2000) Atmospheric correction for ocean color data given by ADEOS/OCTS and POLDER. Advances in Space Research, vol. 25, n°5, p. 1025-1028.

Saporta, G. (1990) Probabilités, analyse des données et statistique. Éditions Technip, Paris, 494 p.

Siegel, D.A., Wang, M., Maritorena, S. and Robinson, W. (2000) Atmospheric Correction of Satellite Ocean Color Imagery : The Black Pixel Assumption. Applied Optics, vol. 39, n°21, p. 3582-3591.

Thiria, S., Lechevalier, Y., Gascuel, O. et Canu, S. (1997) Statistique et méthodes neuronales. Éditions Dunod, Paris, 336 p.

Yacoub, M., Frayssinet, D., Badran, F.and Thiria, S. (2000) Clustering and Classification based on Expert knowledge Propagation Using Probabilistic Self Organizing Map : Application to geophysics. *In* Data Analysis, Classification and Applications, Springer Verlag, Heidelberg, 527 p.