



HAL
open science

Caractérisation de textures en imagerie sonar et invariance en rotation

Helene Thomas, Christophe Collet, Koffi Clément Yao, Gilles Burel

► **To cite this version:**

Helene Thomas, Christophe Collet, Koffi Clément Yao, Gilles Burel. Caractérisation de textures en imagerie sonar et invariance en rotation. *Traitement du Signal*, 2000, 17 (1), pp.1-19. hal-03222603

HAL Id: hal-03222603

<https://hal.univ-brest.fr/hal-03222603>

Submitted on 27 Feb 2023

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution 4.0 International License

Classification de textures en imagerie sonar et Invariance en rotation

Sonar Texture Classification and Rotation Invariance

H. Thomas^{#+}, C. Collet[#], K. Yao[#], G. Burel^{*}

[#]Laboratoire GTS (Groupe de Traitement du Signal), Ecole Navale

BP 600 - 29 240 Brest France

^{*}Université de Bretagne Occidentale, LEST-UMR CNRS 6616

6 av. Le Gorgeu, BP 809 - 29 285 Brest France

6 avril 2000

Résumé et mots clés

Les applications civiles et militaires nécessitant l'identification des caractéristiques de la couche superficielle du fond de la mer sont nombreuses : géologie marine, prospection minière, pêche et gestion de la biomasse, cartographie, guerre des mines, chasse aux mines ... Cet article s'intéresse à la cartographie automatique des fonds marins en imagerie sonar haute résolution¹. De nombreuses méthodes d'analyse de textures ont été développées jusqu'à présent, utilisant des approches statistiques, géométriques ou spectrales [14, 45, 7, 44]. Cependant, peu d'entre elles fournissent des attributs caractéristiques robustes vis-à-vis des rotations d'images. Cette propriété est pourtant essentielle dans le cadre de l'étude proposée : elle a pour objectif de faciliter et d'améliorer l'apprentissage du classifieur. Nous présentons dans cet article cinq méthodes de caractérisation, robustes vis-à-vis des rotations d'images. La première méthode est une version étendue de la modélisation AutoRégressive (AR) circulaire initialement proposée par Kashyap et Khotanzad [19], en vue d'en extraire directement un nombre restreint de paramètres caractéristiques significatifs invariants en rotation. Les quatre autres méthodes résultent d'une approche originale qui consiste à appliquer une méthode de traitement d'images à un ensemble de paramètres décrivant une texture, afin de le rendre robuste vis-à-vis des rotations d'images. Les deux premières de ces méthodes consistent à appliquer la Transformation Log-Polaire respectivement aux paramètres issus d'une modélisation autorégressive 2D non-causale et aux paramètres de corrélation associés (nommés paramètres COR). Quant aux deux

¹Les auteurs remercient le GESMA (Groupe d'Etude Sous-Marine de l'Atlantique, Brest) pour la fourniture de données réelles ainsi que pour le financement partiel de cette étude.

⁺H.Thomas est actuellement enseignant-chercheur à l'Ensieta/DER EIA, 2 rue François Verny, 29806 Brest Cedex 9.

dernières méthodes, elles consistent en l'application de la méthode des moments de Zernike respectivement à ces deux ensembles de descripteurs. Des résultats de classification expérimentaux obtenus sur images réelles et sur images tournées artificiellement, ainsi que sur des textures issues de l'album de Brodatz, sont fournis pour souligner les performances de chacune des méthodes.

Mots-clefs : imagerie sonar, textures, classification, invariance en rotation, moments de Zernike, représentation log-polaire

Abstract and keywords

This paper addresses the automatic cartography of sea-bottom by means of high resolution sonar images. Many texture analysis methods have been developed since now, based on statistical, geometrical or spectral modeling[14, 45, 7, 44]. Nevertheless, few of them are robust toward image rotations. The property of rotation invariance is essential in our framework, particularly for obtaining good classification rates. We present in this article five methods for the automatic classification of rotating images, corresponding to four classes of sea-floor : "sand", "ridge", "dune" and "wreck". The first one is an extension of a circular AutoRegressive method, initially proposed by Kashyap et Khotanzad [19], which allows to estimate a reduced number of rotation invariant parameters. The four other methods are based on an original approach, consisting to apply a mathematical transform to a set of parameters describing texture features. Two of them consists in computing the Log-Polar transform to autoregressive (AR) or correlation (COR) parameters. The two others consist in estimating the Zernike moments of autoregressive (AR) or correlation (COR) parameters. Classification rates obtained on sonar images and on Brodatz album are presented and allow to compare the performances of each approach.

key-words : sonar, texture, classification, rotation invariance, Zernike moment, log-polar representation

1 Introduction

Malgré son importance en traitement d'images, la texture ne présente pas de définition précise universelle [45, 14]. On rencontre généralement deux types de définition de la "texture" [45] :

- la première est *déterministe* et fait référence à une répétition spatiale d'un motif de base dans différentes directions. Cette approche structurelle correspond à une vision *macroscopique* des textures ;
- la deuxième est *probabiliste* et cherche à caractériser l'aspect anarchique et homogène qui ne comprend ni de motif localisable, ni de fréquence de répétition principale. Elle correspond à une vision *microscopique*.

Gagalowicz [11] propose une synthèse des deux approches en considérant "la texture comme une structure spatiale constituée de l'organisation de primitives (ou motifs de base) ayant chacune un aspect aléatoire".

Intuitivement, un certain nombre de propriétés lui sont reconnues [44] : 1) la texture a une propriété contextuelle (elle est liée à la notion de région) ; 2) la texture implique une variation spatiale des niveaux de gris ; 3) la texture peut être perçue à différentes échelles ou à différents niveaux de résolution. Enfin, la texture d'une image possède des qualités visuelles qui jouent un rôle très important pour son analyse [35, 44] : l'uniformité, la densité, la finesse, la rugosité, la régularité, la linéarité, la directionnalité, le contraste, la granularité... Tamura *et al.* [35] ont proposé une méthode d'analyse de texture basée uniquement sur la quantification de certains de ces attributs visuels. La perception d'une texture peut donc prendre des aspects très différents, ce qui explique en partie pourquoi il n'y a pas une méthode unique de représentation de texture qui soit adéquate pour une variété de textures.

De bonnes revues de synthèse et/ou de comparaison sont fournies par Haralick [14], Wechsler [45] et Connors et Harlow [7]. Selon Tuceryan et Jain [44] les différentes méthodes d'analyse de texture peuvent se répartir en quatre catégories :

1. les méthodes statistiques, basées sur la définition stochastique de la texture, englobent les statistiques d'ordre 1 [23], les matrices de cooccurrence [15, 25], la fonction d'autocorrélation [4, 44], les matrices des longueurs de plage [9], l'intégration curvilinéaire [32]... ;
2. les méthodes géométriques doivent leur existence à une définition déterministe de la texture : la texture est composée de primitives (éléments de texture) que l'on peut extraire et qui possèdent certaines propriétés géométriques. Deux types de méthodes s'y rattachent : les polygones de Voronoï [43] et les méthodes structurelles ;
3. les méthodes basées sur des modélisations sont utilisées non seulement pour analyser des textures mais aussi pour rendre possible leur synthèse. Elles se répartissent en deux groupes : les modèles de champs aléatoires markoviens [8] et les méthodes fractales [30] ;
4. enfin, les méthodes de traitement du signal désignent les filtres appliqués dans le domaine spatial, incluant les moments [47, 42], les filtres de Gabor [37] ainsi que les ondelettes [5].

1.1 Descripteurs

L'analyse de texture est présente dès que l'on veut classifier ou même segmenter des images qui possèdent des textures marquées. C'est pourquoi de nombreux domaines d'application, outre le domaine marin lié à l'imagerie

sonar, font appel à des méthodes d'analyse de texture : imagerie radar [23], imagerie satellitale SPOT [28], imagerie médicale [33]...

Toutes les méthodes d'analyse de la texture ne sont pas équivalentes. Les méthodes basées sur le calcul d'attributs texturaux (matrices de cooccurrences, isosegments ou *Run Lengths...*) ne sont pas réversibles : elles ne permettent pas de reconstruire une image en utilisant uniquement les paramètres extraits par ces méthodes, ce qui implique une perte d'informations pertinentes. De plus, une sélection empirique des paramètres à retenir est souvent nécessaire pour rendre ces grandeurs acceptables pour le classifieur.

A l'inverse des méthodes précédentes, les modèles autorégressifs (AR) 2D permettent de s'affranchir de ces inconvénients en proposant un ensemble de paramètres qui décrit efficacement les dépendances spatiales entre les pixels d'une image. De plus, ces modèles rendent possible la synthèse d'images à partir des seuls paramètres extraits qui sont en outre en nombre restreint et très discriminants, qualité due à leur capacité à générer des images. Cette démarche séduisante a été utilisée avec succès sur les images naturelles de Brodatz [18, 26, 2].

Cependant, les paramètres extraits avec de tels modèles ne sont pas robustes vis-à-vis des rotations d'images, or cette propriété est fondamentale car elle facilite et améliore l'apprentissage d'un classifieur. Nous présentons alors une première méthode [40], basée sur la modélisation AR circulaire, inspirée de [19]. Parallèlement, nous proposons une autre approche, originale, qui consiste à introduire deux techniques de traitement d'images (les Moments de Zernike et la méthode Log-Polaire) pour rendre invariants en rotation les paramètres issus d'une modélisation AR 2D ainsi que les paramètres de corrélation associés, tout en conservant leur degré de pertinence.

1.2 Classifieur

Le classifieur retenu est un réseau de neurones "Perceptron MultiCouches" (PMC). Depuis de nombreuses années, les réseaux de neurones connaissent un regain d'intérêt. Leur champ d'application est très vaste et concerne aussi bien la segmentation que la classification, l'optimisation ou la prédiction. Une de leurs caractéristiques les plus importantes est incontestablement leur capacité d'apprentissage et de généralisation. Cette dernière leur permet d'appréhender des problèmes difficiles à modéliser, le travail de modélisation explicite étant remplacé par la constitution d'une base d'apprentissage (aspect supervisé de l'approche). De plus la non-linéarité intrinsèque aux réseaux neuronaux leur confère une forte robustesse et la capacité à traiter des signaux fortement bruités, ce qui est une des caractéristiques des images sonar qui présentent un fort bruit de chatoiement (*i.e.* bruit de speckle), lié à la réflexion spéculaire de l'onde acoustique. Pour toutes ces raisons, nous proposons d'utiliser les réseaux de neurones pour réaliser la phase de classification proprement dite.

1.3 Cartographie des fonds marins

L'identification de la nature de la couche superficielle du fond de la mer joue un grand rôle dans la connaissance et la compréhension de l'environnement sous-marin. De nombreuses applications civiles sont concernées : la géologie marine, la prospection minière, la pêche, ... Pour la communauté militaire, la connaissance de la nature de la surface des fonds marins d'une zone donnée peut se révéler précieuse pour lutter efficacement contre la menace représentée par les mines ou plus généralement par la présence d'objets manufacturés sur le fond. Elle définit en effet les zones où la chasse aux mines pourra s'effectuer. La cartographie des fonds marins en imagerie sonar est donc le domaine privilégié de l'étude. Elle consiste à établir une carte des fonds marins d'une zone donnée à partir d'un sonar, où chaque parcelle de terrain est identifiée. Dans le cadre de l'étude, on cherchera à identifier quatre *types de fonds marins* (ou *classes*) : les cailloux, les dunes, les rides et le sable. La cartographie fait appel au domaine de la classification d'images, problème courant qui peut se résoudre en deux temps. La première étape consiste à caractériser une image, c'est à dire à déterminer un ensemble de paramètres caractéristiques (également désignés sous le terme d'*attributs caractéristiques*) d'une image donnée, afin de réduire le volume de données contenu dans l'image à une quantité plus facilement exploitable, tout en préservant la majeure partie de l'information discriminante. La classification proprement dite consiste ensuite à exploiter ces informations comme entrées d'un classifieur de manière à identifier les différentes classes recherchées. Les performances du classifieur sont fortement conditionnées par le pouvoir discriminant des informations d'entrée c'est-à-dire par l'étape de caractérisation. C'est pourquoi nous avons porté nos efforts sur cette étape. Nous précisons enfin que l'invariance en échelle n'est pas recherchée dans le cadre de cette étude (bien que réalisée par la transformation Log-Polaire), le sonar remorqué étant asservi pour demeurer à hauteur constante.

Cet article est articulé en quatre parties. La première partie est consacrée à l'imagerie acoustique des fonds marins et à ses caractéristiques. Les types de fonds traités ainsi que le bruit de *speckle* inhérent aux images sonar y sont présentés. La seconde partie présente la modélisation AR2D intrinsèquement invariante aux rotations (les attributs doivent caractériser de la même façon une image de texture "ride" orientée à 45 degrés et une image de texture "ride" orientée à 83 degrés par exemple) pour laquelle nous avons proposé une extension [40] de la méthode initialement proposée dans [19]. La troisième partie s'articule autour de trois paragraphes. Le premier paragraphe décrit des paramètres fortement discriminants mais non robustes vis-à-vis des rotations d'images : les paramètres AR et les paramètres COR. Le deuxième paragraphe est consacré à la transformation log-Polaire et le troisième décrit la méthode des moments de Zernike, méthodes qui permettent de rendre invariants en rotation les paramètres AR et les paramètres COR. Une étude comparative des performances des

cinq méthodes pour la caractérisation d'images sonar invariante en rotation est présentée en dernière partie.

2 Contexte de l'étude

Les images sonar à très haute définition sont formées par un sonar² actif latéral fonctionnant à fréquences élevées (de l'ordre de quelques centaines de kHz). Le sonar imageur est généralement un sonar actif latéral remorqué à l'arrière du bâtiment par l'intermédiaire d'un câble. Il possède un module d'émission d'ondes sonores contrairement au sonar dit passif qui en est dépourvu³. Le terme latéral signifie que le sonar émet des signaux acoustiques dans une direction perpendiculaire au déplacement du navire qui le tracte.

Les types de fonds marins La nature des fonds marins présents sur des zones d'intérêt est assez variée : sable, vase, roche, gravier, dune, ride... Alors que le géologue peut connaître la nature précise de ceux-ci en analysant la granulométrie, les couches de sédiments, la porosité et les proportions de minéraux qu'ils contiennent, le "traiteur" d'images ne dispose que des informations fournies par l'image (*i.e.*, l'amplitude du signal acoustique rétrodiffusé par le fond), liées au pouvoir réfléchissant des composants de chaque type de fond (*sable, caillou, dune* et *ride* : cf. *Fig. 1*) ainsi qu'à leur disposition spatiale.

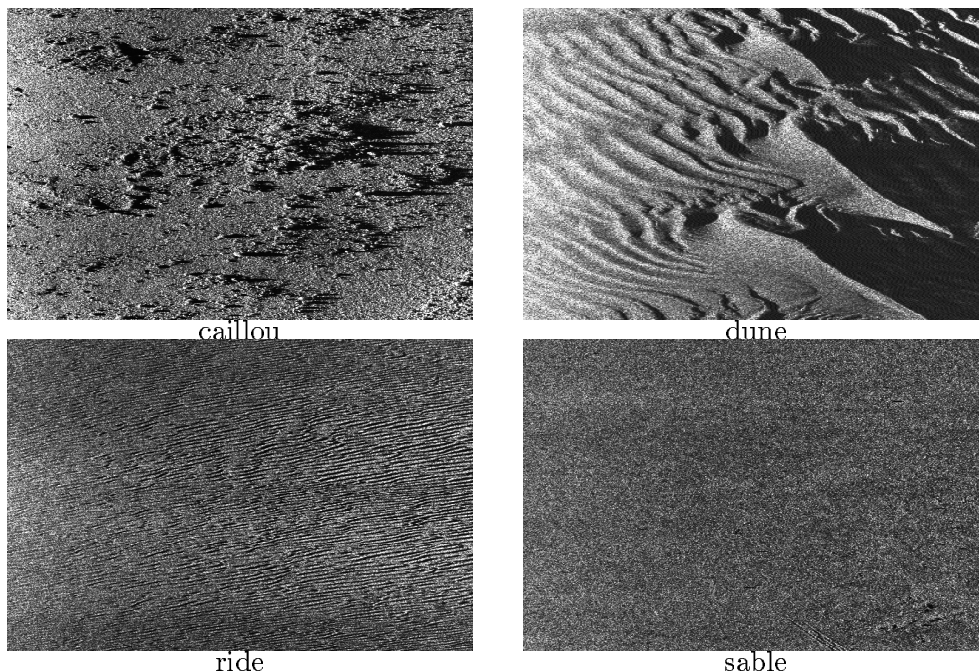


Figure 1: *Quatre types de fonds marins illustrés par quatre images sonar de taille 512×768 pixels, codées sur 256 niveaux de gris. Un pixel représente spatialement une zone du fond de l'ordre de 100 cm^2 .*

²acronyme de SOund NAvigation and Ranging.

³La vocation des sonars passifs, dits de veille, est l'écoute passive en vue d'identifier d'éventuelles cibles moins discrètes.



Figure 2: Textures de Brodatz : grass (D9), sand (D29), straw (D15), wood (D19) et weave (D16)

L'aspect granulaire est dû au *speckle* qui se traduit par une multitude de points en niveaux de gris sur l'image. L'origine de cette granularité provient de la rugosité des surfaces insonifiées et de la cohérence de l'onde acoustique émise [12].

Les textures issues de l'album de Brodatz[3] Nous avons également utilisé différents types de textures naturelles (*cf.* Fig. 2), issues de l'album de P. Brodatz, provenant de milieux naturels, pour lesquelles différents angles d'observation sont disponibles [3], nous permettant ainsi de valider nos approches.

3 Modélisation AR intrinsèquement invariante aux rotations

Nous présentons brièvement dans ce paragraphe les extensions que nous avons apportées [40] à la méthode AR circulaire proposée par Kashyap et Khotanzad dans [19]. Cette méthode consiste à définir un modèle paramétrique AR bidimensionnel utilisant 8 luminances voisines du pixel courant, équiréparties sur un cercle passant par les quatre pixels voisins au sens du voisinage de 4-connexité. Les 4 luminances manquantes sont obtenues par simple interpolation. Le voisinage circulaire ainsi défini permet d'obtenir un modèle AR circulaire avec seulement 3 paramètres, notés α_{11} , β_{11} et ζ_{11} [19]. Cette méthode a retenu toute notre attention pour les raisons suivantes : 1) les paramètres extraits de ce modèle sont robustes vis-à-vis des rotations d'images ; 2) les interactions spatiales entre pixels sont prises en compte de façon efficace ; 3) des bons taux de reconnaissance ont été obtenus avec cette méthode sur des images de l'album de Brodatz [19] et 4) cette méthode permet d'obtenir un nombre restreint de paramètres fortement significatifs (paramètres α_{11} , β_{11} et ζ_{11}). Toutefois, cette méthode ne prend en compte que des voisinages de faible taille (3×3 pixels).

Nous proposons trois paramètres supplémentaires - α_{22} (paramètre circulaire), β_{22} (paramètre d'erreur) et ζ_{22} (paramètre directionnel) - qui décrivent un voisinage plus étendu, de taille 5×5 pixels et dont l'extraction est similaire à celle de α_{11} , β_{11} et ζ_{11} . D'autres travaux concernant les champs de Markov [31] et les modèles AR [27, 17] ont montré l'intérêt d'étendre la taille du voisinage. Notons qu'en principe une généralisation à des voisinages plus grands est possible. Toutefois, cela conduit à une formulation lourde et complexe pour un bénéfice incertain dans le cadre de notre application.

3.1 Paramètres du modèle circulaire AR2D (α_{22} et β_{22})

Soit $\{y(s)\}$ l'ensemble des luminances d'une image, observées aux sites $s \in S$ où S désigne une grille régulière de dimension $K \times K$. Les paramètres α_{22} et β_{22} sont les paramètres du modèle autorégressif symétrique circulaire défini par l'équation :

$$y(s) = \alpha_{22} \sum_{p \in N_c} y(s+p) + \sqrt{\beta_{22}} v(s) \quad (1)$$

où $v(s)$ représente une séquence aléatoire de moyenne nulle et de variance unité et N_c le voisinage circulaire d'un pixel de luminance $y(s)$, centré sur ce pixel, de rayon 2 :

$$N_c = \{(\sqrt{2}, \sqrt{2}), (-\sqrt{2}, -\sqrt{2}), (\sqrt{2}, -\sqrt{2}), (-\sqrt{2}, \sqrt{2}), (0, 2), (0, -2), (2, 0), (-2, 0)\}$$

Ce modèle est une extension du modèle de Kashyap permettant l'estimation de α_{11} et de β_{11} (modèle régi également par l'équation (1) où α_{11} joue le rôle de α_{22} , β_{11} joue le rôle de β_{22} et N_c est un voisinage circulaire de rayon 1). Les luminances des pixels ne se situant pas sur la grille des points sont interpolées en utilisant les quatre plus proches voisins. Les paramètres α_{22} et β_{22} sont ensuite directement estimés par une méthode des moindres carrés [40].

3.2 Paramètre directionnel (ζ_{22})

Le paramètre directionnel ζ_{22} est obtenu en appliquant quatre fois le modèle AR 2D non-causal décrit par l'équation ci-dessous:

$$y(s) = \sum_{p \in N} \theta_p y(s+p) + \sqrt{\rho} w(s) \quad (2)$$

où l'ensemble $\{\theta_p\}$ désigne les paramètres AR estimés pour un voisinage N et $w(s)$ une séquence aléatoire de moyenne nulle et de variance unité. ρ joue le même rôle que β_{22} de l'équation (1). Le voisinage non-causal N prend les quatre définitions successives :

$$\left\{ \begin{array}{l} N_1 = \{(0, 2), (0, -2), (2, 0), (-2, 0)\} \\ N_2 = \{(2, 2), (2, -2), (-2, 2), (-2, -2)\} \\ N_3 = \{(-1, 2), (1, -2), (-2, -1), (2, 1)\} \\ N_4 = \{(-2, 1), (2, -1), (-1, -2), (1, 2)\} \end{array} \right. \quad (3)$$

Ce modèle prend en compte différents voisinages et permet de détecter des orientations privilégiées dans des textures : les directions privilégiées se traduisent par des valeurs importantes des paramètres AR correspondants. C'est l'équation d'un modèle autorégressif bidimensionnel, dans lequel un point dépend linéairement de ses voisins situés dans un voisinage N autour de ce point.

Pour chacun des cas de l'équation 3, nous estimons la moitié des paramètres AR lui correspondant, en raison de la propriété de symétrie de ces paramètres [39]. Par exemple, pour le voisinage N_1 , on ne conserve que $\theta_{(0,2)}$ et $\theta_{(2,0)}$. Nous définissons enfin ζ_{22} par :

$$\zeta_{22} = \max\{|\theta_{(2,0)} - \theta_{(0,2)}|, |\theta_{(2,2)} - \theta_{(2,-2)}|, |\theta_{(-1,2)} - \theta_{(2,1)}|, |\theta_{(-2,1)} - \theta_{(1,2)}|\} \quad (4)$$

Cette définition permet de prendre en compte un grand nombre de directions privilégiées de certaines textures (et notamment situées entre 0 et 45 degrés) et non pas de détecter uniquement des orientations verticales/horizontales ou bien diagonales-gauches/diagonales-droites, comme c'est le cas lorsque l'on calcule de manière similaire ζ_{11} ($\zeta_{11} = \max\{|\theta_{(1,0)} - \theta_{(0,1)}|, |\theta_{(1,1)} - \theta_{(1,-1)}|\}$). Il s'agit en ce sens d'une extension intéressante de la méthode. La figure 3-a (*resp.* 3-b) illustre la robustesse de l'ensemble des paramètres circulaires $\{\alpha_{11}, \beta_{11}, \zeta_{11}\}$ (*resp.* l'ensemble $\{\alpha_{22}, \beta_{22}, \zeta_{22}\}$) vis-à-vis des rotations : dans l'espace de ces paramètres, quatre groupes de points, représentant individuellement un type de fond (d'orientation quelconque), sont séparables.

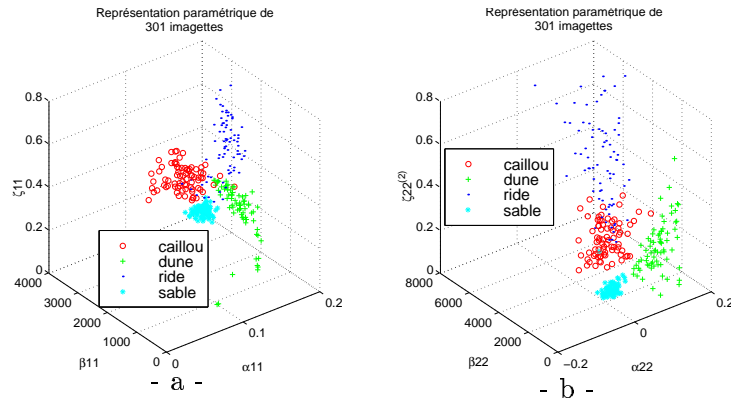


Figure 3: Nuages de points représentant 301 imagerie sonar réparties en quatre classes, dans un espace à trois dimensions formées par : (a) $\alpha_{11}, \beta_{11}, \zeta_{11}$; (b) $\alpha_{22}, \beta_{22}, \zeta_{22}$.

4 Transformations assurant l'invariance en rotation

Cette partie propose d'utiliser des descripteurs sensibles aux rotations (paramètres autorégressifs (*cf.* § 4.1.1) et de corrélation (*cf.* § 4.1.2)), que l'on transforme en paramètres invariants en rotation grâce à la transformation log-polaire (*cf.* § 4.2) et aux moments de Zernike (*cf.* § 4.3).

4.1 Paramètres non-invariants en rotation

4.1.1 Paramètres AR

Dans le cas bidimensionnel, le modèle AR décrit linéairement les dépendances spatiales statistiques d'un pixel d'une image donnée avec un ensemble de pixels situés dans son entourage : la luminance de chaque pixel d'une image donnée est considérée comme étant une combinaison linéaire des luminances des pixels contenus dans un voisinage fixé.

Soit $\{y(k, l)\}$ l'ensemble des pixels d'une image de taille $K \times K$ donnée. Le modèle AR 2D stationnaire non-causal est alors défini par l'équation suivante [6] :

$$y(k, l) = - \underbrace{\sum_{(m,n) \in V} a(m, n)}_{(m,n) \in V} \cdot y(k - m, l - n) + e(k, l) \quad (5)$$

où l'ensemble $\{a(m, n)\}$ représente les paramètres AR et $e(k, l)$ une erreur de prédiction de variance σ_e^2 . V désigne le support non-causal du modèle. Il est défini par :

$$V = \{(m, n), m \in [-M \cdots + M], n \in [-N \cdots + N] \text{ et } (m, n) \neq (0, 0)\} \quad (6)$$

On parlera indifféremment de voisinage d'ordre (M, N) ou de voisinage (M, N) . Les méthodes d'estimation des paramètres d'un modèle AR 2D sont nombreuses (méthodes au sens des moindres carrés [29, 18, 46, 24], méthodes au sens du maximum de vraisemblance [20, 13, 6], méthodes utilisant les réseaux neuronaux [34, 26, 2], ...). La méthode Pseudo-Inverse, utilisant le critère des moindres carrés, présente l'avantage de ne nécessiter aucune hypothèse sur les caractéristiques du bruit, d'être aisée à implanter et de toujours fournir des résultats significatifs dans le cadre de l'application visée [39].

4.1.2 Paramètres COR

Les relations entre les coefficients d'un modèle autorégressif (paramètres AR) et les échantillons de la fonction d'autocorrélation (paramètres COR) ont souvent été mentionnées dans la littérature [44]. On peut montrer que la méthode Pseudo-Inverse revient à trouver les coefficients $a(m, n)$ qui vérifient :

$$\hat{y}(k, l) = - \sum_{(m,n) \in V} a(m, n) y(k - m, l - n) \quad \forall (k, l) \in V \quad (7)$$

où $\hat{y}(k, l)$ représente l'échantillon estimé par le modèle au pixel (k, l) . Ainsi, en notant σ_e^2 la variance de l'erreur $e(k, l) = y(k, l) - \hat{y}(k, l)$ sur l'ensemble de l'image, on écrit

$$\begin{aligned}
 \sigma_e^2 &= E \left[e(k, l)^2 \right] \\
 &= E \left[\left(y(k, l) + \sum_{(m,n) \in V} a(m, n) y(k - m, l - n) \right) \left(y(k, l) + \sum_{(p,q) \in V} a(p, q) y(k - p, l - q) \right) \right] \\
 &= E \left[\left(\sum_{(m,n) \in V \cup \{0,0\}} a(m, n) y(k - m, l - n) \right) \left(\sum_{(p,q) \in V \cup \{0,0\}} a(p, q) y(k - p, l - q) \right) \right] \\
 &= \sum_{(m,n) \in V \cup \{0,0\}} \sum_{(p,q) \in V \cup \{0,0\}} a(m, n) a(p, q) E [y(k - m, l - n) y(k - p, l - q)] \\
 &= \sum_{(m,n) \in V \cup \{0,0\}} \sum_{(p,q) \in V \cup \{0,0\}} a(m, n) a(p, q) r(m - p, n - q) \tag{8}
 \end{aligned}$$

où r désigne la fonction d'autocorrélation 2D et $a(0, 0) = 1$. On obtient donc

$$\sigma_e^2 = r(0, 0) + 2 \sum_{(m,n) \in V} a(m, n) r(m, n) + \sum_{(m,n) \in V} \sum_{(p,q) \in V} a(m, n) a(p, q) r(m - p, n - q) \tag{9}$$

L'équation (9) indique que des liens existent entre les paramètres AR et les paramètres COR $r(k, l)$: σ_e^2 s'obtient à partir des seules données $a(m, n)$ et $r(k, l)$. On en déduit alors aisément que l'estimation $\hat{r}(k, l)$ de $r(k, l)$ grâce aux paramètres AR s'écrit

$$\begin{aligned}
 \hat{r}(k, l) &= E [\hat{y}(m, n) \hat{y}(m - k, n - l)] \\
 &= E \left[\sum_{(i,j) \in V} a(i, j) y(m - i, n - j) \sum_{(p,q) \in V} a(p, q) y(m - k - p, n - l - q) \right] \\
 &= \sum_{(i,j) \in V} \sum_{(p,q) \in V} a(i, j) a(p, q) E [y(m - i, n - j) y(m - k - p, n - l - q)] \\
 &= \sum_{(i,j) \in V} \sum_{(p,q) \in V} a(i, j) a(p, q) r(k + p - i, l + q - j) \tag{10}
 \end{aligned}$$

Pour un voisinage d'ordre (M, N) donné, le nombre des paramètres COR équivalents est égal au nombre de combinaisons possibles entre tous les pixels de ce voisinage, car les échantillons de la fonction d'autocorrélation doivent être calculés pour tous les couples $(k + p - i, l + q - j)$, d'après l'équation (10).

On constate finalement que les échantillons de la fonction d'autocorrélation, correspondant à un voisinage d'ordre (M, N) , peuvent être estimés en considérant le voisinage d'ordre $(2M, 2N)$ réduit de moitié (figure 4). La figure 5 illustre, sur quelques images sonar de taille 64×64 pixels (ou imageries), la pertinence des paramètres COR, évalués sur un voisinage d'ordre $(M, N) = (5, 5)$.

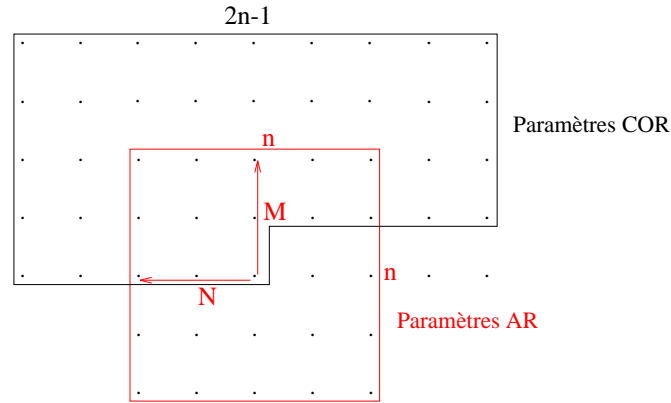


Figure 4: *Voisinages équivalents.* Par exemple, pour un voisinage d'ordre $(M = 2, N = 2)$, le nombre de paramètres AR est égal à $(2M + 1)(2N + 1) - 1 = 24$ et le nombre de paramètres COR équivalents est égal à $\frac{(4M+1)(4N+1)-1}{2} + 1 = 41$.

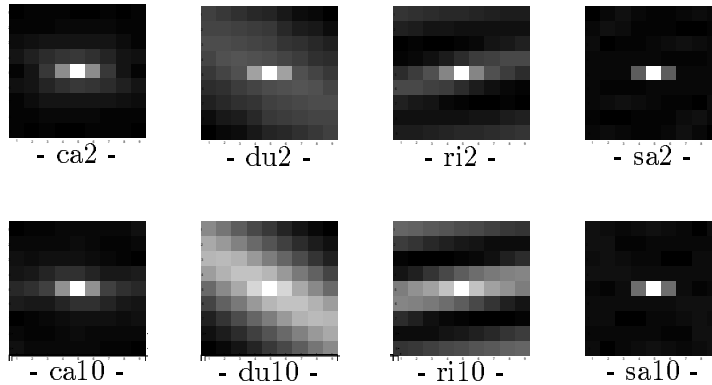


Figure 5: *Echantillons de la fonction d'autocorrélation r pour huit imagerie, représentés sous la forme d'une image en niveaux de gris.* Le pixel central correspond à l'échantillon $r(0,0)$ et les pixels aux positions (i, j) correspondent aux échantillons $r(i, j)$. La fonction d'autocorrélation étant symétrique ($r(i, j) = r(-i, -j)$), les pixels de coordonnées (i, j) et $(-i, -j)$ sont identiques. Le niveau de gris 0 (resp. 255) est affecté à la plus faible (resp. plus forte) valeur des échantillons. On observe une orientation privilégiée de la fonction d'autocorrélation pour les imagerie de type "dune" (du2 et du10) ou "ride" (ri2 et ri10). Celle-ci est directement liée à la position des dunes ou rides de sable présentes dans l'imagerie. Enfin, on constate un rayon de corrélation plus faible dans le cas d'imagerie de sable (sa2, sa10) que dans le cas d'imagerie de cailloux (ca2, ca10).

4.2 Transformation Log-Polaire

La transformation logarithmique complexe (ou *transformation log-polaire*) fut introduite dans le domaine de la vision par ordinateur il y a une vingtaine d'années [22]. Notre intérêt pour cette transformation réside

dans ses propriétés d'invariance induite. Parce qu'elle transforme les rotations et les changements d'échelle en translations, elle rend possible l'invariance en rotation des paramètres AR et des paramètres COR tout en prenant en compte la décroissance des valeurs des paramètres AR (représentés sous forme d'images) au fur et à mesure que l'on s'éloigne du centre. La méthode log-polaire transforme une rotation en une translation le long de l'axe angulaire et c'est la Densité Spectrale de Puissance (DSP) de l'image log-polaire qui vérifie l'invariance en rotation en s'affranchissant du décalage le long de cet axe. En effet, au niveau de la transformée de Fourier, la translation devient un déphasage qui n'intervient plus lorsque l'on considère le module au carré de la transformée de Fourier (DSP).

4.2.1 Formulation mathématique et discrétisation du plan log-polaire

Soient (x, y) les coordonnées cartésiennes d'un point de l'image et (ρ, η) ses coordonnées polaires. Un point (x, y) peut être représenté par un complexe z , dans une base logarithmique a quelconque ($a > 0$) [22] tel que :

$$z = x + jy = \rho a^{j\eta} \quad \text{où } \rho \in [\rho_0 \dots \rho_{\max}], \text{ et } \eta \in [0 \dots 2\pi[$$

avec $\rho = \sqrt{x^2 + y^2}$, $\eta = \text{Arg}(z) = \arctan(y/x)$, ρ_0 et ρ_{\max} désignent respectivement le rayon de la fovea⁴ et la moitié de la taille de l'image tandis que le paramètre a rappelle le facteur d'amplification cortical [22]. Usuellement la transformation log-polaire ne s'applique qu'à la partie non-fovéale de l'image pour éviter la singularité à l'origine et garder une région échantillonnée de manière homogène au centre. La transformation log-polaire générale w d'un point complexe z est définie comme :

$$w = \log_a(z) = \log_a(\rho) + j\eta \quad (11)$$

Un capteur CCD "hard" (matériel) à géométrie logarithmique ou une mise en oeuvre "soft" (logicielle) de la transformation log-polaire nécessite une discrétisation du plan log-polaire en $N_r \times N_a$ points où N_r désigne le nombre de cellules dans la direction radiale et N_a le nombre de cellules dans la direction angulaire (figure 6). La transformation des coordonnées polaires (ρ, η) en coordonnées log-polaires (ξ, γ) s'écrit [41] :

$$\xi = \log_a(\rho/\rho_0) = \log_a(\rho) - \log_a(\rho_0) \quad (12)$$

$$\gamma = \frac{N_a}{2\pi} \eta \quad (13)$$

avec $\xi \in \mathbb{N}$ et $\gamma \in \mathbb{N}$ qui satisfont respectivement $0 \leq \xi < N_r$ et $0 \leq \gamma < N_a$ et le facteur d'amplification a tel que :

$$a = \exp\left(\frac{1}{N_r - 1} \ln\left(\frac{\rho_{\max}}{\rho_0}\right)\right) \quad (14)$$

⁴La fovea désigne la partie centrale de l'image, par analogie avec la composition de la rétine, dont le fonctionnement est à l'origine de la transformation log-polaire.

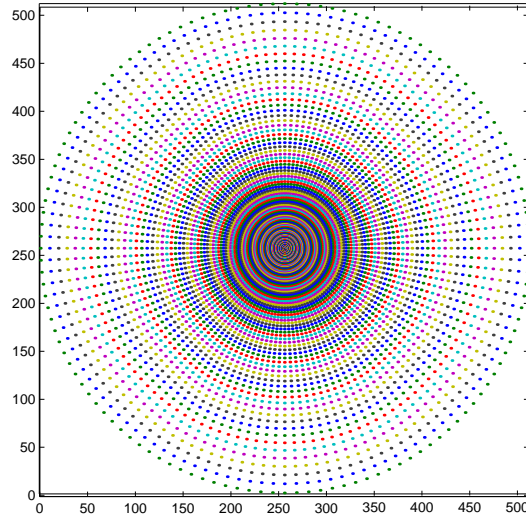


Figure 6: Exemple de discrétisation du plan image ($N_a = N_r = 128$).

4.2.2 Invariance en rotation

Supposons qu'une image I_r ait subi une rotation d'angle α par rapport à une image originale I alors un point $z_r = (x_r, y_r)$ de l'image I_r s'écrit (avec les notations précédentes) $z_r = \rho \exp(j(\eta + \alpha))$ où (ρ, η) sont les coordonnées polaires du point z dans l'image I . Dans le domaine log-polaire, z_r devient w_r tel que (équation (11)) :

$$w_r = \log_a(\rho) + j(\eta + \alpha) \quad (15)$$

L'équation (15) montre qu'une rotation d'angle α dans le domaine cartésien se transforme en une translation le long de l'axe γ dans le domaine log-polaire.

4.2.3 Densité Spectrale de Puissance (DSP) de l'image log-polaire

Les nouveaux attributs de texture associés à la méthode log-polaire sont les échantillons de la Densité Spectrale de Puissance (DSP) de l'image log-polaire des paramètres AR (ou paramètres COR) obtenus comme suit :

- estimation des paramètres AR (ou des paramètres COR) pour un voisinage d'ordre (M, N) donné ;
- détermination de l'image log-polaire des paramètres AR (ou paramètres COR) pour N_a, N_r et ρ_0 donnés, notée symboliquement I_{lp} . Les paramètres N_a, N_r et ρ_0 sont choisis heuristiquement en fonction du nombre des paramètres AR ou COR ;

- calcul de la DSP de l'image log-polaire I_{lp} . Les échantillons de la DSP sont représentés sous la forme d'un vecteur (qui résulte du parcours de "l'image" de haut en bas et de gauche à droite).

Les figures 7 et 8 montrent que les échantillons de la DSP calculés à partir des paramètres COR sont plus robustes vis-à-vis des rotations d'images que ceux calculés à partir des paramètres AR.

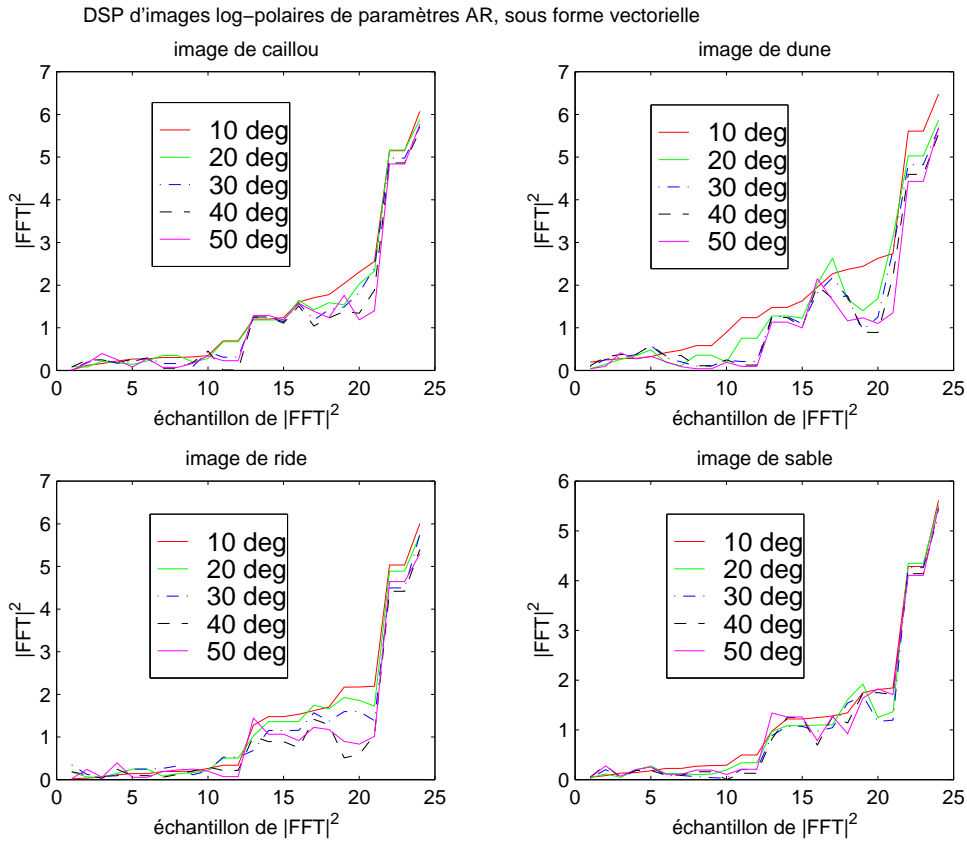


Figure 7: Illustration de la robustesse des échantillons de la DSP de I_{lp} calculée à partir des paramètres AR vis-à-vis de rotations. Chaque sous-figure est associée à un type de fond et représente cinq courbes illustrant le comportement des échantillons de la DSP pour des rotations géométriques d'angles respectifs 10, 20, 30, 40 et 50 degrés (la même image a servi à la création de ces cinq imagettes). On a choisi $\rho_0 = 0.86$, $N_a = 12$ et $N_r = 6$ pour un voisinage AR de taille $M = N = 3$ ($(2M + 1)(2N + 1) = 49$ paramètres). La DSP de l'image log-polaire des paramètres AR présente des valeurs très faibles pour les fréquences angulaires impaires (ceci est dû au caractère quasi-périodique selon γ (de période $N_a/2$) du fait de la symétrie des paramètres AR). Aussi ne représente-t-on ici que les $24 \left(\frac{N_a}{2} \left(\frac{N_r}{2} + 1 \right) = 24 \right)$ paramètres correspondant à la moitié du spectre restreint aux fréquences paires.

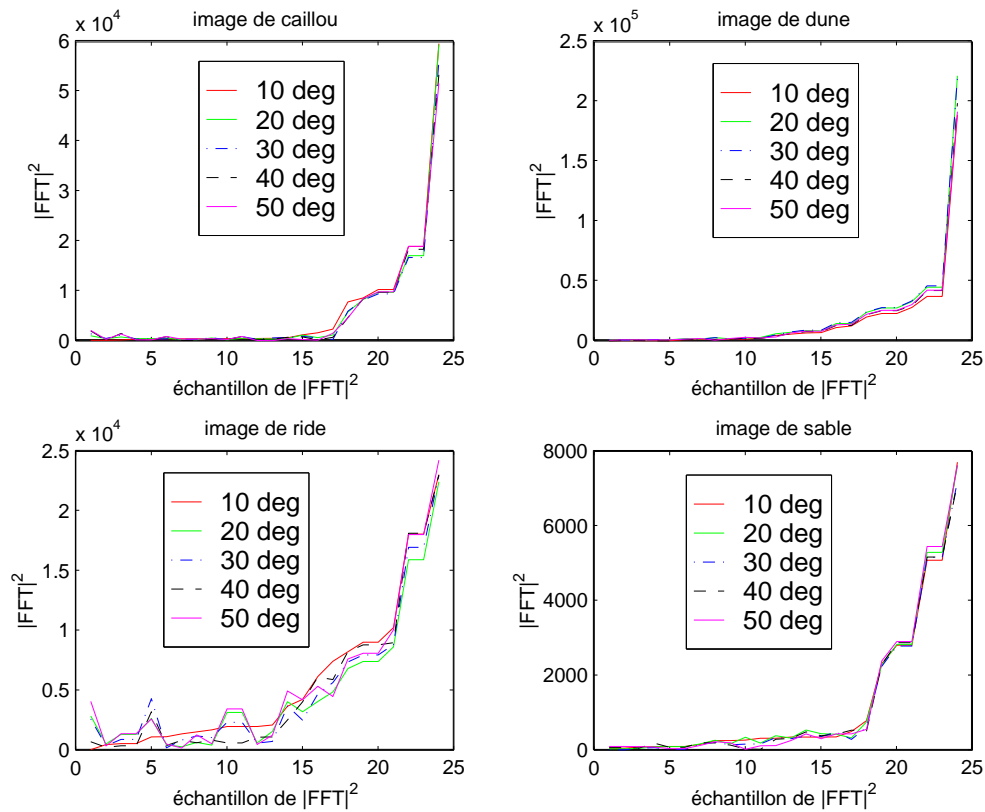


Figure 8: De même que pour la figure 7, on illustre ici la robustesse vis-à-vis de rotations des échantillons de la DSP de I_{lp} calculés cette fois à partir de paramètres COR. Chaque sous-figure est associée à un type de fond et les cinq courbes illustrent le comportement des échantillons de la DSP pour cinq imagerie sonar ayant subi des rotations géométriques d'angles respectifs 10, 20, 30, 40 et 50 degrés (la même image a servi à la création de ces cinq imagerie).

4.3 Moments de Zernike

Contrairement à beaucoup d'applications (reconnaissance de caractères [36, 21], reconnaissance d'objets 2D [1]...), nous proposons d'utiliser les moments de Zernike, non pas pour obtenir des descripteurs invariants en rotation directement à partir d'une image, mais plutôt pour rendre des descripteurs donnés invariants en rotation (paramètres AR et paramètres COR). La méthode des moments de Zernike possède en effet un atout incontestable : les paramètres qu'elle fournit sont intrinsèquement invariants en rotation.

Les moments de Zernike font partie de la famille des moments orthogonaux. La propriété d'orthogonalité, essentielle pour obtenir une reconstruction simple d'une image, permet en outre de séparer la contribution individuelle de chacun des moments lors du processus de reconstruction. Teh et Chin [36] ont notamment montré qu'en terme de performance globale (dans le cas précis d'un système de classification de caractères manuscrits), les moments de Zernike et les Pseudo-Zernike sont plus efficaces que d'autres moments (moments réguliers, rotationnels, complexes). Khotanzad et Hong l'ont également constaté dans une étude similaire [21].

4.3.1 Polynômes orthogonaux et moments de Zernike

Les moments de Zernike d'ordre n et de répétition m , notés A_{nm} , sont issus de la projection d'une fonction $f(x, y)$ sur des fonctions de base V_{nm} à valeurs complexes définissant une base orthogonale⁵ au sens du produit scalaire Euclidien. Les polynômes V_{nm} sont définis à l'intérieur du cercle unité, *i.e.* $x^2 + y^2 \leq 1$ par [21] :

$$V_{nm}(x, y) = V_{nm}(\rho, \theta) = R_{nm}(\rho) \exp(jm\theta) \quad (16)$$

où n est un entier positif ou nul et m représente des entiers relatifs ($\in \mathbb{Z}$) tels que $n - |m|$ pair et $|m| \leq n$. ρ définit la norme du vecteur de l'origine aux coordonnées (x, y) : $\rho = \sqrt{x^2 + y^2}$ et θ désigne l'angle que fait le vecteur de norme ρ et l'axe x (défini dans le sens horaire) : $\theta = \arctan(y/x)$. Les polynômes radiaux $R_{nm}(\rho)$ sont définis par :

$$R_{nm}(\rho) = \sum_{s=0}^{n-|m|/2} (-1)^s \cdot \frac{(n-s)!}{s! \binom{n+|m|}{2} - s! \binom{n-|m|}{2} - s!} \rho^{n-2s} = R_{n,-m}(\rho) \quad (17)$$

Les polynômes V_{nm} sont orthogonaux mais non orthonormés :

$$\iint_{x^2+y^2 \leq 1} V_{nm}^*(x, y) V_{pq}(x, y) dx dy = \frac{\pi}{n+1} \delta_{np} \delta_{mq} \text{ avec } \delta_{a,b} = \begin{cases} 1 & \text{si } a = b \\ 0 & \text{sinon} \end{cases} \quad (18)$$

⁵ Une famille d'éléments d'un espace vectoriel forme une base orthogonale de cet espace si leur produit scalaire deux à deux est nul [10].

Par définition [16], les polynômes radiaux sont bornés : $R_{nm}(\rho) \in [-1...1] \forall |\rho| \leq 1$ et la condition de normalisation des fonctions de base de Zernike requiert $R_{nm}(1) = 1$. La fonction angulaire $\exp(jm\theta)$ peut être vue comme l'enveloppe modulant le polynôme radial $R_{nm}(\rho)$. Comme $R_{nm}(\rho)$ est à valeurs réelles, elle constitue le seul contrôle sur la phase de $V_{nm}(\rho, \theta)$. La partie imaginaire de la fonction angulaire se déduit de la partie réelle par un déphasage d'angle⁶ $\frac{\pi}{2m}$. Pour une fonction $f(x, y)$ discrète, le moment de Zernike A_{nm} est défini par [21] :

$$A_{nm} = \frac{n+1}{\pi} \sum_x \sum_y f(x, y) V_{nm}^*(x, y) \text{ avec } x^2 + y^2 \leq 1 \quad (19)$$

Seul le cas discret nous intéresse puisque la fonction $f(x, y)$ représentera successivement l'ensemble des paramètres AR et l'ensemble des paramètres COR, ensembles discrets (matrices 2D).

Grâce à l'orthogonalité des fonctions de base de Zernike, on peut reconstruire la fonction $f(x, y)$ à partir des moments A_{nm} calculés jusqu'à un ordre donné n_{max} [21]. Soit $\hat{f}(x, y)$ cette version reconstruite :

$$\hat{f}(x, y) = \sum_{n=0}^{n_{max}} \sum_m A_{nm} V_{nm}(x, y) \quad (20)$$

La fonction $\hat{f}(x, y)$ sera d'autant plus proche de $f(x, y)$ que l'ordre n_{max} sera grand.

4.3.2 Invariance en rotation

Supposons que l'image f subisse une rotation d'angle α . L'image résultat f^r vérifie la relation $f^r(\rho, \theta) = f(\rho, \theta - \alpha)$, (ρ, θ) étant les coordonnées polaires de $f(x, y)$ définies à l'équation (16). On montre alors [21] que les moments de Zernike calculés à partir de f^r vérifient :

$$A_{nm}^r = A_{nm} \exp(-jm\alpha) \quad (21)$$

Les moments de Zernike ont des propriétés de rotation simples : chaque moment est déphasé d'un angle connu mais son module reste inchangé lors de l'étape de rotation. Ainsi, le module des moments de Zernike $|A_{nm}|$ peut être utilisé comme caractéristique invariante en rotation. Puisque $A_{nm}^* = A_{n, -m}$, il est possible de se concentrer uniquement sur $|A_{nm}|$ avec $m \geq 0$. Nous avons établi les deux formules suivantes pour la détermination du nombre de ces caractéristiques, noté $nbpar$, en fonction de l'ordre maximal n_{max} retenu :

⁶ $\exp(jm\theta) = \cos(m\theta) + j \sin(m\theta)$ et $\sin(m\theta) = \cos(m\theta - \pi/2) = \cos[m(\theta - \pi/2m)] \forall \theta \in [0, 2\pi[$. La partie imaginaire est donc égale à la partie réelle déphasée de $\pi/2m$.

- n_{\max} pair : $nbpar = \sum_{i=1}^{n_{\max}/2} (2i) + (\frac{n_{\max}}{2} + 1) = (\frac{n_{\max}}{2} + 1)^2$ (en utilisant $\sum_{x=1}^q x = \frac{q(q+1)}{2}$)
- n_{\max} impair : $nbpar = \sum_{i=1}^{(n_{\max}+1)/2} (2i) = (\frac{n_{\max}}{2} + 1)^2 + (\frac{n_{\max}}{2} + 1)$

4.3.3 Estimation des moments de Zernike

Les nouveaux attributs de texture associés à la méthode des moments de Zernike sont les moments de Zernike $|A_{nm}|$ obtenus comme suit :

- estimation d'un modèle autorégressif d'ordre $(M, N) = (3, 3)$ sur une imagette sonar donnée (de taille 64×64 pixels) et sauvegarde des paramètres AR obtenus sous forme d'une image (démarche identique pour les échantillons de la fonction d'autocorrélation)
- interpolation de l'ensemble des paramètres AR (ou paramètres COR) par une fonction bilinéaire de manière à doubler le nombre des paramètres
- calcul des moments de Zernike jusqu'à l'ordre $n = 12$ par application de la formule donnée en (19). Le problème lié à la sélection de l'ordre n reste ouvert. Le choix de $n = 12$ est motivé par des considérations bibliographiques, empiriques et calculatoires.

Les figures 9 et 10 montrent que le module des moments de Zernike (représentés dans l'ordre donné au tableau des correspondances, tableau 1) calculés à partir des paramètres COR sont plus robustes vis-à-vis des rotations d'images que ceux calculés à partir des paramètres AR.

numéro du moment	1	2	3	4	5	6	7	8	9	...
(n, m)	(0, 0)	(1, 1)	(2, 0)	(2, 2)	(3, 1)	(3, 3)	(4, 0)	(4, 2)	(4, 4)	...

Tableau 1: *Tableau des correspondances entre le numéro donné à un moment sur les figures illustrant l'allure du module des moments et le couple (n, m) correspondant (n et m étant respectivement l'ordre et la répétition d'un moment). Le moment de numéro 1 est A_{00} . Ensuite, les numéros sont affectés aux moments A_{nm} dans l'ordre des n , et des m correspondants, croissants. Ainsi, le moment numéro 2 est A_{11} . L'ordre n suivant étant $n = 2$, A_{20} est le troisième moment ($m = 0$) et A_{22} est le quatrième.*

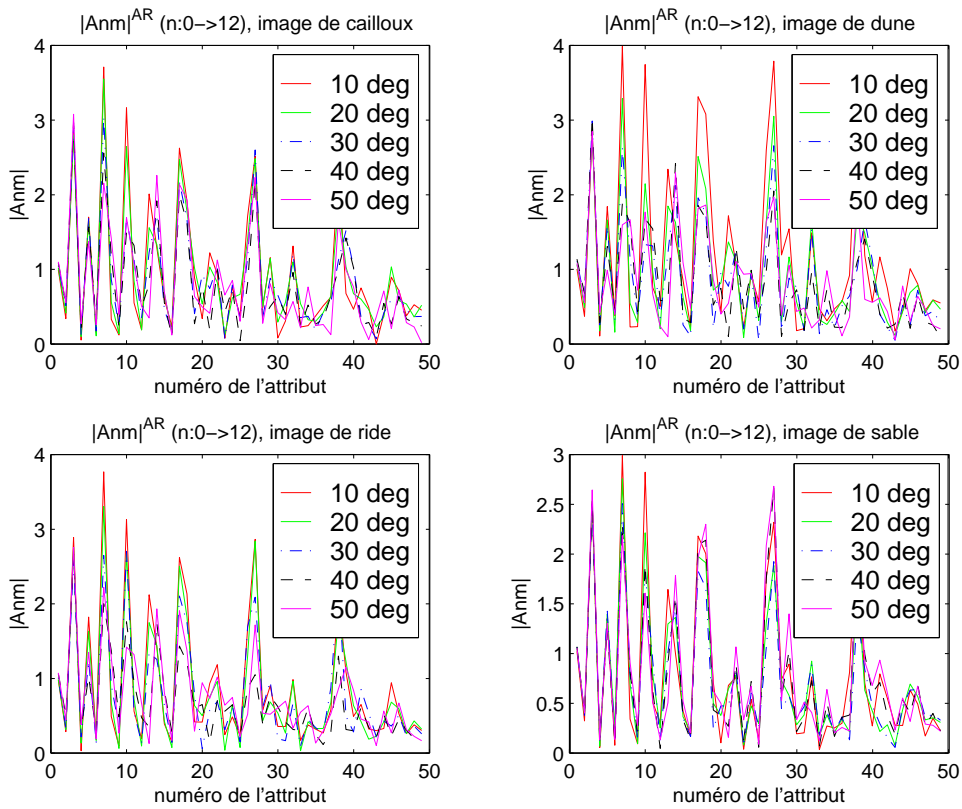


Figure 9: Illustration de la robustesse des 49 premiers moments de Zernike calculés sur l'ensemble des paramètres AR vis-à-vis de rotations. Chaque sous-figure est associée à un type de fond et représente cinq courbes illustrant le comportement du module des moments pour cinq imagerie sonar ayant subi des rotations géométriques d'angles respectifs 10, 20, 30, 40 et 50 degrés (une même image a été tournée de cinq angles différents et a donc produit cinq images). Le tableau des correspondances permet de trouver le couple (n, m) associé au numéro du moment (ou numéro de l'attribut).

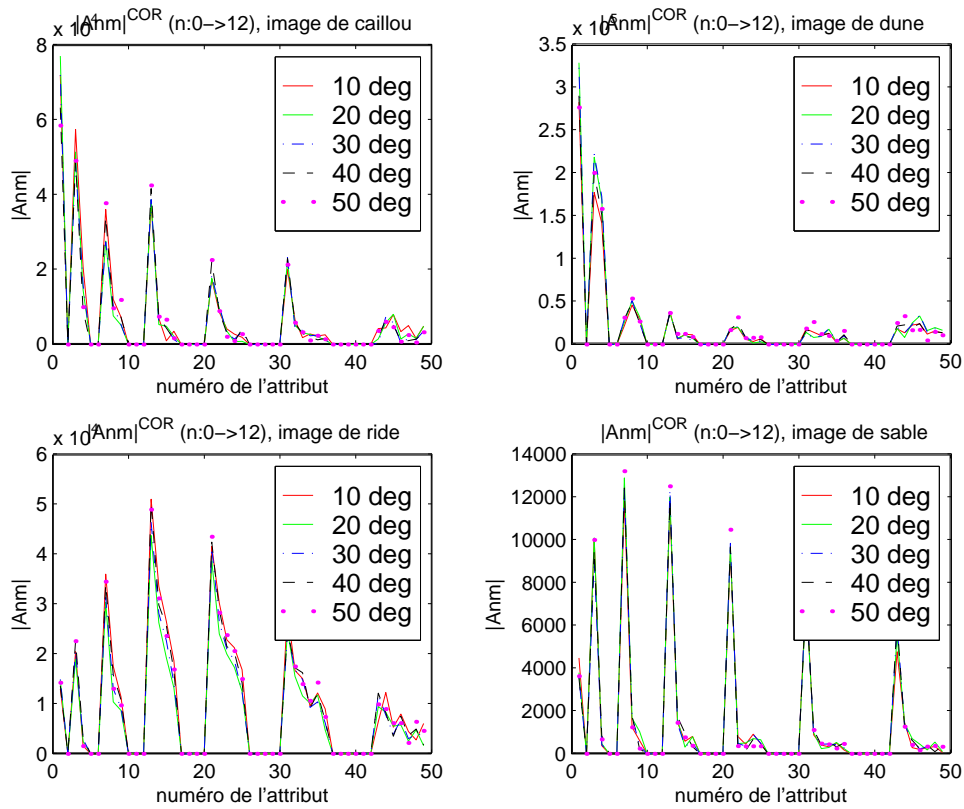


Figure 10: Evolution des 49 premiers moments de Zernike calculés sur l'ensemble des paramètres COR vis-à-vis de rotations. Chaque sous-figure est associée à un type de fond et représente cinq courbes illustrant le comportement du module des moments pour cinq images sonar ayant subi des rotations géométriques d'angles respectifs 10, 20, 30, 40 et 50 degrés (une même image a été tournée de cinq angles différents et a donc produit cinq images). Le tableau des correspondances permet de trouver le couple (n, m) associé au numéro du moment (ou numéro de l'attribut).

5 Résultats obtenus sur images de l'album de Brodatz et sur images sonar

Cette partie illustre les résultats obtenus sur quelques images issues de l'album de Brodatz, avant de comparer nos approches sur images réelles.

5.1 Objectifs et méthodologie

Il s'agit de comparer expérimentalement les trois méthodes de caractérisation texturale : la modélisation AR 2D circulaire, la méthode des moments de Zernike et la méthode log-polaire. Pour cela, nous avons évalué les performances d'un système de reconnaissance d'images sonar supervisé basé sur un classifieur neuronal alimenté par des attributs caractéristiques provenant successivement de ces trois méthodes d'analyse de texture. Ce système est décrit à la figure 11.

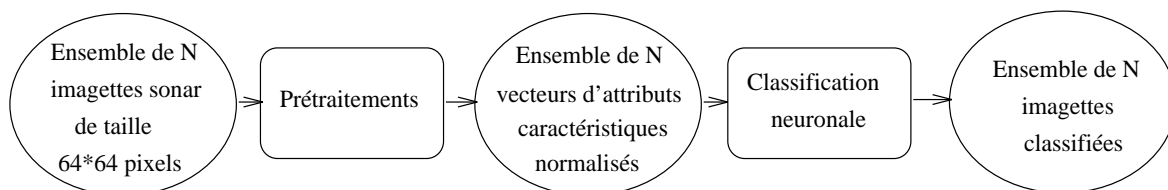


Figure 11: *Chaîne de traitement globale pour l'évaluation des performances du système de reconnaissance d'images sonar. Les N imagettes sonar peuvent constituer une image sonar entière de taille assez grande.*

L'étape de classification consiste à affecter une classe connue à chaque pixel ou sous-ensemble de pixels d'une image, caractérisé par un des trois jeux de paramètres précités. Le classifieur retenu est un réseau de neurones de type Perceptron MultiCouche (PMC), largement utilisé en traitement d'images et particulièrement en reconnaissance des formes. Le choix du classifieur neuronal pour assurer la classification proprement dite dans la chaîne de traitement résulte également d'une comparaison avec l'algorithme des K Plus Proches Voisins (un vecteur de paramètres est classifié en fonction de la classe affectée à ses K plus proches voisins, au sens d'une distance euclidienne par exemple, dans l'espace des paramètres), réalisée dans le cadre de l'évaluation de la robustesse des paramètres AR circulaires vis-à-vis des rotations d'images. Ces résultats [40] montrent des taux de classification très proches pour les deux classifieurs, alimentés par les mêmes descripteurs et testés dans les mêmes conditions expérimentales. Dans le cadre de la classification des mines à partir d'images sonar ainsi que dans le cadre de la classification d'images aériennes [4], les taux de classification obtenus par les deux classifieurs sont également très proches. Cependant, l'algorithme des KPPV est très gourmand en temps de calcul (car il faut calculer les distances par rapport à tous les prototypes), c'est le PMC qui sera retenu pour comparer les différentes méthodes de caractérisation. Il est donc nécessaire de constituer une base d'apprentissage et une

base de test.

Les performances de l'étape de classification sont établies à partir d'un nombre N d'imagettes (portions d'image) sonar et s'expriment sous la forme de Taux de Reconnaissance Individuel (TRI, pourcentages d'imagettes sonar bien classées par rapport au nombre total d'imagettes à classer) regroupés dans des matrices de confusion. Celles-ci donnent en outre pour chaque classe à reconnaître (représentée par un grand nombre d'imagettes sonar) le nombre des imagettes bien reconnues et pour celles qui auraient été mal classées, la ou les classe(s) avec lesquelles elles sont confondues. Le Taux de Reconnaissance Moyen (TRM) est également donné.

5.2 Conditions expérimentales

Des conditions de tests identiques ont été adoptées pour établir une comparaison efficace (mesure des performances en classification) entre les différentes méthodes. Le choix de ces trois méthodes de caractérisation textuelle étant basé sur la propriété d'invariance en rotation des attributs caractéristiques extraits, nous avons évalué les performances de ces trois méthodes dans le cadre d'un système de reconnaissance d'images sonar d'*orientations quelconques*.

La base d'apprentissage intègre des imagettes tout à fait distinctes (pas de chevauchements entre elles) et représentatives des cinq textures de Brodatz ou des quatre types de fonds à distinguer, de façon équiprobable (on n'émet aucune hypothèse *a priori* sur la répartition probabiliste des différentes textures de Brodatz ou des types de fonds sur lesquels peuvent reposer les mines).

Le PMC est constitué d'une seule couche cachée dont le nombre de neurones optimal⁷ varie en fonction du type du vecteur d'attributs caractéristiques. Les poids du réseau sont initialisés aléatoirement. La règle usuelle de la rétropropagation du gradient de l'erreur est utilisée pour l'apprentissage du réseau. Les résultats que nous présentons sont donnés pour un nombre optimal de neurones cachés et un nombre optimal de cycles⁸ (et qui dépendent de la méthode de caractérisation adoptée).

5.2.1 Textures de Brodatz

Les bases d'apprentissage et de test ont été constituées à partir de 7×5 images (5 textures et 7 orientations par texture) de Brodatz de taille 512×512 pixels. Chacune de ces 35 images a été découpée en imagettes de taille 64×64 pixels. La base d'apprentissage est constituée de $32 \times 4 \times 5$ imagettes : pour chaque texture considérée, on a conservé les 32 "premières" imagettes (partie supérieure) extraites des images de taille 512×512 orientées

⁷celui qui donne les meilleurs taux de classification.

⁸terme qui désigne le nombre de fois que l'ensemble des échantillons de la base d'apprentissage est présenté au réseau pour son apprentissage.

à 0, 60, 120 et 200 degrés. La base de test, constituée de façon similaire, contient $32 \times 3 \times 5$ imagettes : pour chaque texture considérée, on a conservé les 32 "dernières" imagettes (partie inférieure) extraites des images orientées à 0, 90 et 150 degrés.

5.2.2 Images sonar

Pour constituer la base d'apprentissage et la base de test, nous avons créé dix ensembles d'imagettes intitulés *Rot10*, *Rot20*, ..., *Rot80*, et *Rot120* et *Rot150*, respectivement obtenus pour des angles de rotations de 10 ... 80, 120 et 150 degrés. 360 imagettes puisées dans les ensembles *Rot10*, *Rot20* et *Rot30* et réparties en quatre classes constituent la base d'apprentissage alors que 420 imagettes puisées dans les autres ensembles, également réparties en quatre classes, constituent la base de test.

5.3 Résultats comparatifs

5.3.1 Résultats sur textures de Brodatz

Modélisation AR circulaire De façon attendue, les paramètres issus de la modélisation AR circulaire sont aptes à reconnaître des textures d'orientations diverses. Le système utilisant l'ensemble $E_{CIRC} = \{\alpha_{22}, \beta_{22}, \zeta_{22}\}$ reconnaît très bien les textures sand, wood et weave et, avec seulement quelques erreurs, les textures grass et straw.

E_{CIRC}	grass	sand	straw	wood	weave	TRI (%)
grass	92	2	2	0	0	95%
sand	0	96	0	0	0	100%
straw	2	1	89	4	0	92%
wood	0	0	0	96	0	100%
weave	0	0	0	0	96	100%
					TRM:	97%

Tableau 2: Performances de la modélisation AR circulaire sur textures de Brodatz: matrice de confusion associée à l'ensemble d'attributs caractéristiques E_{CIRC} .

Méthode logarithmique complexe Les résultats du tableau 3 montrent que la méthode log-polaire appliquée aux paramètres COR (ensemble E_{LP-COR}) présente des attributs caractéristiques invariants en rotation : les taux de reconnaissance obtenus pour les cinq textures sont excellents.

Les paramètres AR utilisés comme données de base pour la méthode log-polaire (ensemble E_{LP_AR}) induisent des taux de classification assez médiocres, excepté pour la texture sand. Ces mauvais résultats sont probablement provoqués par des interpolations induites lors de la formation des images constituant les bases d'apprentissage et de test. Plus précisément, il semble que l'interpolation d'une image a une influence néfaste sur l'estimation des paramètres AR, qu'elle n'a pas sur les paramètres COR [38].

E_{LP_AR}	grass	sand	straw	wood	weave	TRI (%)
grass	47	15	7	0	27	48%
sand	4	80	5	6	1	83%
straw	3	8	72	8	5	75%
wood	0	0	25	71	0	73%
weave	19	2	10	4	61	63%
					TRM:	68%

E_{LP_COR}	grass	sand	straw	wood	weave	TRI (%)
grass	95	1	0	0	0	98%
sand	1	93	0	0	2	96%
straw	1	2	90	3	0	93%
wood	0	0	0	96	0	100%
weave	0	1	0	0	95	98%
					TRM:	97%

Tableau 3: Performances de la méthode log-polaire sur textures de Brodatz: matrices de confusion associées respectivement de gauche à droite aux ensembles d'attributs caractéristiques E_{LP_AR} et de E_{LP_COR} .

Moments de Zernike L'intérêt d'utiliser les moments de Zernike pour rendre invariants en rotation les paramètres d'une modélisation AR 2D non-causale n'est pas vérifié : les taux de reconnaissance du tableau 4 (ensemble E_{ZER_AR}) sont plutôt médiocres : ils varient de 38% à 88% selon la classe. L'explication est la même que celle suggérée pour les résultats concernant la méthode log-polaire calculée sur les paramètres AR.

L'ensemble E_{ZER_COR} (ensembles de moments de Zernike appliqués aux paramètres COR) permet par contre de très bien distinguer les 4 textures grass, sand, wood et weave, et assez bien la texture straw.

5.3.2 Résultats sur images sonar

Les résultats obtenus sur images sonar sont similaires à ceux obtenus sur les cinq textures de Brodatz considérées.

Modélisation AR circulaire Les paramètres issus de la modélisation AR circulaire sont aptes à reconnaître les quatre fonds marins. Le système utilisant l'ensemble $E_{CIRC} = \{\alpha_{22}, \beta_{22}, \zeta_{22}\}$ reconnaît très bien les fonds caillou, ride et sable (TRI=100%) et, dans une moindre mesure, la classe dune (TRI de l'ordre de 92%).

Méthode logarithmique complexe Similairement aux résultats obtenus sur textures de Brodatz, les résultats du tableau 6 montrent que la méthode log-polaire appliquée aux paramètres COR (ensemble E_{LP_COR})

E_{ZER_AR}	grass	sand	straw	wood	weave	TRI (%)
grass	37	24	0	1	34	38%
sand	6	85	2	3	0	88%
straw	4	9	68	5	10	70%
wood	0	11	25	60	0	62%
weave	30	7	3	5	51	53%
					TRM:	62%

E_{ZER_COR}	grass	sand	straw	wood	weave	TRI (%)
grass	94	2	0	0	0	97%
sand	0	96	0	0	0	100%
straw	2	1	90	2	1	93%
wood	0	0	0	96	0	100%
weave	0	0	0	0	96	100%
					TRM:	98%

Tableau 4: Performances de la méthode des moments de Zernike sur textures de Brodatz : matrices de confusion associées respectivement de gauche à droite aux ensembles d'attributs caractéristiques E_{ZER_AR} et de E_{ZER_COR} .

E_{CIRC}	caillou	dune	ride	sable	TRI (%)
caillou	105	0	0	0	100%
dune	2	97	0	6	92%
ride	0	0	105	0	100%
sable	0	0	0	105	100%
				TRM:	98%

Tableau 5: Performances de la modélisation AR circulaire sur images sonar : matrice de confusion associée à l'ensemble d'attributs caractéristiques E_{CIRC} .

présente des attributs caractéristiques invariants en rotation : les taux de reconnaissance obtenus pour les classes caillou, ride et sable sont excellents (respectivement 100%, 95% et 100%). La classe dune est moins bien reconnue et majoritairement confondue avec la classe sable.

Les paramètres AR utilisés comme données de base pour la méthode log-polaire (ensemble E_{LP_AR}) induisent des taux de classification très médiocres, excepté pour la classe sable. L'explication est la même que celle suggérée dans le cadre de l'application de cette méthode aux textures de Brodatz (une image ayant subi une rotation artificielle est une image interpolée).

Moments de Zernike L'intérêt d'utiliser les moments de Zernike pour rendre invariants en rotation les paramètres d'une modélisation AR 2D non-causale n'est pas vérifié : les taux de reconnaissance du tableau 7 (ensemble E_{ZER_AR}) sont très médiocres : ils varient de 30% à 80% selon la classe. L'explication est la même que celle suggérée pour les résultats concernant la méthode log-polaire calculée sur les paramètres AR.

E_{LP_AR}	caillou	dune	ride	sable	TRI (%)
caillou	40	4	0	61	38%
dune	21	60	0	24	57%
ride	2	0	15	88	14%
sable	0	0	0	105	100%
				TRM:	52%

E_{LP_COR}	caillou	dune	ride	sable	TRI (%)
caillou	105	0	0	0	100%
dune	7	77	3	18	73%
ride	0	2	100	3	95%
sable	0	0	0	105	100%
				TRM:	92%

Tableau 6: Performances de la méthode log-polaire sur images sonar : matrices de confusion associées respectivement de gauche à droite aux ensembles d'attributs caractéristiques E_{LP_AR} et de E_{LP_COR} .

L'ensemble E_{ZER_COR} (ensembles de moments de Zernike appliqués aux paramètres COR) permet par contre de distinguer très bien les classes caillou, ride et sable (TRI=100%), et assez bien la classe dune (75%).

E_{ZER_AR}	caillou	dune	ride	sable	TRI (%)
caillou	32	54	14	5	30%
dune	5	85	14	1	80%
ride	0	8	49	48	46%
sable	0	6	21	78	74%
				TRM:	58%

E_{ZER_COR}	caillou	dune	ride	sable	TRI (%)
caillou	105	0	0	0	100%
dune	8	79	0	18	75%
ride	0	0	105	0	100%
sable	0	0	0	105	100%
				TRM:	94%

Tableau 7: Performances de la méthode des moments de Zernike sur images sonar : matrices de confusion associées respectivement de gauche à droite aux ensembles d'attributs caractéristiques E_{ZER_AR} et de E_{ZER_COR} .

5.4 Résumé

Les résultats illustrés au paragraphe précédent nous ont conduit à ne pas retenir la méthode des moments de Zernike ni la méthode log-polaire appliquées aux paramètres AR comme méthode de caractérisation textuelle invariante en rotation. Celles-ci donnent des taux de classification médiocres. La raison majeure est très probablement la présence d'interpolations dans le processus de formation des bases d'images, qui dégrade l'ensemble des paramètres AR ainsi extraits.

La modélisation AR 2D circulaire ainsi que la méthode des moments de Zernike et la méthode log-polaire appliquées toutes deux aux paramètres COR donnent en revanche de très bons résultats. Ces résultats sont d'ailleurs comparables en ce qui concerne les textures de Brodatz.

La figure 12 met en évidence la supériorité de la modélisation AR 2D circulaire sur les deux autres méth-

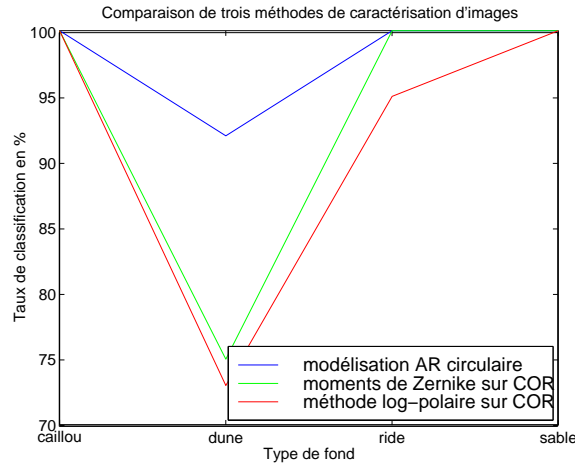


Figure 12: Résultats comparatifs entre la modélisation AR circulaire, les moments de Zernike appliqués aux paramètres COR et la méthode log-polaire appliquée aux paramètres COR.

odes, lorsqu'elles sont appliquées aux images sonar. Cette supériorité est due essentiellement à une meilleure reconnaissance de la classe dune.

6 Conclusion

Le travail présenté dans cet article s'inscrit dans le cadre de l'élaboration d'une chaîne complète de classification supervisée d'images sonar fortement bruitées. L'approche retenue consiste à combiner une méthode de caractérisation d'images texturées et un classifieur neuronal. L'invariance en rotation des attributs a été particulièrement recherchée pour faciliter et améliorer l'apprentissage du classifieur. La démarche adoptée pour caractériser ces images texturées associe une notion d'invariance en rotation à une modélisation AR 2D en vue d'une application au cas très spécifique des images sonar. Nous avons proposé parallèlement cinq méthodes de caractérisation des images texturées basées sur la modélisation AR : la modélisation AR circulaire enrichie, les moments de Zernike appliqués aux paramètres AR et aux paramètres COR et la transformation log-polaire (respectivement sur paramètres AR et paramètres COR). Celles-ci permettent d'obtenir un vecteur d'attributs caractéristiques théoriquement invariant en rotation, *i.e.*, très robuste vis-à-vis des rotations d'images sonar.

Les résultats expérimentaux ont montré que les attributs caractéristiques fournis par la modélisation AR circulaire enrichie sont très robustes vis-à-vis des rotations artificielles appliquées aux images sonar.

D'autre part, les résultats expérimentaux obtenus en classification par les deux méthodes Moments de Zernike et Transformation Log-Polaire justifient pleinement leur utilisation sur les paramètres COR. Par contre, leur utilisation n'est pas souhaitable sur les paramètres AR.

Parmi toutes les méthodes étudiées, c'est la modélisation paramétrique circulaire qui répond actuellement le plus efficacement aux objectifs visés (application aux images sonar) : fournir au classifieur des paramètres caractéristiques très pertinents, en nombre réduit et très robustes vis-à-vis des rotations d'images. Cependant, nous pensons qu'il est fort probable que dans l'avenir, lorsque des bases de données plus grandes et plus variées seront prises en compte, la méthode des moments de Zernike, calculés sur les paramètres COR, fournisse des résultats meilleurs puisque l'information de texture prise en compte par cette méthode est beaucoup plus riche que celle contenue dans les paramètres "circulaires". Enfin, une approche intégrant une analyse à deux résolutions constitue une piste à explorer afin de mieux détecter la classe dune.

Références

- [1] S.M. Abdallah, E.M. Nebot, and D.C. Rye. 2-D object recognition via Zernike moments. pages 100–105, Toowoomba, Australia, 1994. IEEE Computer Society Press.
- [2] B. Augereau, M. Khoudeir, and J. Bernard. Identification sans contrainte de stationnarité d'un modèle ar d'une texture. volume 1, pages 479–482, Grenoble, France, 15-19 septembre 1997.
- [3] P. Brodatz. *Textures : a photographic album for artists and designers*. Dover Publications, New York, 1966. <http://wwwradig.informatik.tu-muenchen.de/bilder/texture/>.
- [4] G. Burel. *Réseaux de neurones en traitement d'images: des modèles théoriques aux applications industrielles*. Phd thesis, Université de Bretagne Occidentale, décembre 1991.
- [5] T. Chang and C.-C. Jay Kuo. Texture classification with tree-structured wavelet transform. *IEEE Transactions on image processing*, 1(2):205–220, April 1992.
- [6] R. Chellappa and R.L. Kashyap. Synthetic generation and estimation in random field models of images. *IEEE Computer Society Conference on Pattern Recognition and Image Processing*, pages 577–582, 3-5 August 1981.
- [7] R.W. Conners and C.A. Harlow. A theoretical comparison of texture algorithms. *IEEE Trans. Pattern Anal. Machine Intell.*, 2(3):204–222, May 1980.
- [8] G.R Cross and A.K. Jain. Markov random field texture models. *IEEE Transactions on patten analysis and machine intelligence*, PAMI-5(1):25–39, January 1983.
- [9] B.V. Dasarathy and E.B. Holder. Image characterizations based on joint gray level-run length distributions. *Pattern Recognit. Lett.*, 12(8):497–502, august 1991.
- [10] R. Fortet. *Vecteurs, fonctions et distributions aléatoires dans les espaces de Hilbert. Analyse harmonique et prévision*. HERMES, Paris, 1995.
- [11] A. Gagalowicz. *Vers un modèle de textures*. Thèse d'état, Université Pierre et Marie Curie, 1983.
- [12] J.W. Goodman. Some fundamental properties of speckle. *Journal of Optical Society of America*, 6(11):1145–1150, November 1976.
- [13] R.R. Hansen and R. Chellappa. Empirical robust estimators for 2D noncausal autoregressive models. volume 4, pages 2005–8, 3-6 April 1990. Albuquerque.

- [14] R.M. Haralick. Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5):787–804, May 1979.
- [15] R.M. Haralick, K. Shanmugam, and its'hak Dinstein. Textural features for image classification. *IEEE Trans. Syst., Man, Cybern.*, SMC-3:610–621, November 1973.
- [16] P.C. Hew. Zernike radial polynomial is bounded. Rapport interne : <http://maths.uwa.edu.au/phew/postgrad/diaries/zerradbounded.p> Department of Mathematics, The University of Western Australia, 7 October 1996.
- [17] R.L. Kashyap, R. Chellappa, and A. Khotanzad. Texture classification using features derived from random field models. *Pattern Recognition Letters*, 1(1):43–50, October 1982.
- [18] R.L. Kashyap, R. Chellappa, and A.K. Mahalanabis. Classification of images using features derived from random field models. pages 303–307, 5-7 January 1982. New Dehli, India.
- [19] R.L. Kashyap and A. Khotanzad. A model-based method for rotation invariant texture classification. *IEEE Trans. Pattern Anal. and Machine Intell.*, PAMI-8(4):472–481, July 1986.
- [20] R.L. Kashyap and J.-N. Liaw. Subset least squares method for robust speech and image processing. *Int. Journal of Patt. Rec. and Art. Intell.*, 10(5):447–471, 1996.
- [21] A. Khotanzad and Y.H. Hong. Invariant image recognition by zernike moments. *IEEE transactions on Pattern Analysis and Machine Intelligence*, 12(5):489–497, May 1990.
- [22] V. Krüger. Optical flow estimation in the complex logarithmic plane. Rapport technique, Institut d'informatique et de mathématiques appliquées, Université de Kiel (Allemagne), December 1995. <http://www.informatik.uni-kiel.de/vok/>.
- [23] H. Laur, T. Le Toan, and A. Lopes. Textural segmentation of SAR images using first order statistical parameters. pages 1463–1468, May 1987.
- [24] H. Lebet and L. El Ghaoui. Moindres carrés robustes. volume 1, pages 447–450, 15-19 septembre, Grenoble 1997.
- [25] J.H. Lee, N.I. Lee, and S.D. Kim. A fast and adaptive method to estimate texture statistics by the spatial gray level dependence matrix(SGLDM) for texture image segmentation. *Pattern Recognit. Lett.*, 13:291–303, April 1992.
- [26] S.W. Lu and H. Xu. Textured image segmentation using autoregressive model and artificial neural network. *Pattern Recognition*, 28(12):1807–1817, December 1995.
- [27] J. Mao and A.K. Jain. Texture classification and segmentation using multiresolution simultaneous autoregressive models. *Pattern Recognition*, 25(2):173–188, February 1992.
- [28] D.J. Marceau, P.J. Howarth, J.-M.M. Dubois, and D.J. Gratton. Evaluation of the grey-level cooccurrence matrix method for land-cover classification using spot imagery. *IEEE Trans. on Geoscience and Remote Sensing*, 28(4):513–519, July 1990.
- [29] J.P. Nougier. *Méthodes de calcul numérique*. MASSON, Paris, 1993.
- [30] S. Peleg, J. Naor, R. Hartley, and D. Avnir. Multiple resolution texture analysis and classification. *IEEE Trans. Pattern Anal. Machine Intell.*, PAMI-6(4):518–523, July 1984.
- [31] R. Porter and N. Canagarajah. Robust rotation invariant texture classification. volume IV, pages 3157–160, 21-24 april 1997. Munich, Germany.
- [32] J. Ronsin, D. Barba, and S. Raboisson. Comparison between cooccurrence matrices, local histograms and curvilinear integration for texture characterization. volume 596, pages 98–104, 1985.

- [33] D. Sersic and S. Loncaric. Enhancement of mammographic images for detection of microcalcifications. volume II, pages 693–696, September 1998. Rhodes Island, Greece.
- [34] L. Sukissian, S. Kollias, and Y. Boutalis. Adaptative classification of textured images using linear prediction and neural networks. *Signal Processing*, 36(2):209–232, 1994.
- [35] H. Tamura, S. Mori, and T. Yamawaki. Textural features corresponding to visual perception. *IEEE Trans. Syst. Man Cybern.*, SMC-8(6):460–473, june 1978.
- [36] C.-H. Teh and R.T. Chin. On image analysis by the methods of moments. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10(4):496–513, July 1988.
- [37] A. Teuner, O. Pichler, and B.J. Hosticka. Unsupervised texture segmentation of images using tuned matched gabor filters. *IEEE Trans. Image Process.*, 4(6):863–870, june 1995.
- [38] H. Thomas. *Contribution à la reconnaissance des fonds marins en imagerie sonar*. Thèse de doctorat (PhD thesis), Université de Bretagne Occidentale - Ecole Navale (Laboratoire GTS), décembre 1998.
- [39] H. Thomas, C. Collet, K. Yao, and G. Burel. Classification neuronale des fonds marins par modélisation autorégressive bidimensionnelle. volume 2, pages 925–928, Grenoble, France, septembre 1997.
- [40] H. Thomas, C. Collet, K. Yao, and G. Burel. Some improvements of a rotation invariant autoregressive method. Application to the neural classification of noisy sonar images. volume IV, pages 2001–2004, Rhodes island, Greece, September 1998.
- [41] M. Tistarelli and G. Sandini. Dynamic aspects in active vision. *CVGIP Image Understanding*, 56(1):108–129, July 1992.
- [42] M. Tuceryan. Moment based texture segmentation. volume III, pages 45–48, The Hague, Netherlands, August 1992.
- [43] M. Tuceryan and A.K. Jain. Texture segmentation using voronoi polygons. *IEEE Trans. Pattern Anal. Machine Intell.*, 12(2):211–216, February 1990.
- [44] M. Tuceryan and A.K. Jain. *Texture analysis*. in Handbook of Pattern Recognition and Computer Vision, 1993. Eds. C.H. CHEN, L.F. PAU and P.S.P. WANG, World Scientific Publishing Company.
- [45] H. Wechsler. Texture analysis - a survey. *Signal Processing*, 2:271–282, 1980.
- [46] H. Youlal, M. Janati Idrissi, and M. Najim. *Modélisation paramétrique en traitement d'images*. MASSON, Paris, 1994.
- [47] P.A. Zinzindohoue. *Applications de l'analyse de texture en microscopie électronique*. Thèse de doctorat, Université de Reims Champagne-Ardenne, 1988.

7 Auteurs



Hélène THOMAS est enseignant-chercheur à l'Ecole Nationale Supérieure des Etudes et des Techniques d'Armement (Brest) depuis janvier 1999. Elle enseigne le traitement du Signal et de l'Image. Elle est diplômée

de l'Institut de Recherche et d'Enseignement Supérieur aux Techniques de l'Electronique (1994) et docteur en Electronique de l'Université de Bretagne Occidentale (1998). Ses activités de recherche au sein de l'Equipe Signal concernent la théorie de la décision (estimation, réduction de bruit) appliquée aux signaux sous-marins (sédimentologie, sismique).



Christophe COLLET est né le 31 mars 1966. Il a obtenu son doctorat à l'Université de Toulon en 1992 et soutiendra son Habilitation à diriger des Recherches à l'Université de Bretagne Occidentale en mai 2000. Il est actuellement maître de conférences à l'Université de Bretagne Occidentale, détaché à l'Ecole navale, où il a dirigé le laboratoire GTS de 1994 à 2000. Ses centres d'intérêt en recherche concernent l'analyse statistique des images en océanographie, la segmentation markovienne hiérarchique non supervisée (imagerie SPOT, sonar, infrarouge), le traitement des formes, l'analyse de textures en imagerie sonar, les techniques d'optimisation en traitement d'images.



Koffi-Clément YAO est docteur de l'Université Louis Pasteur de Strasbourg (1990) en traitement optique du signal préparé au LSP de l'ENSP de Strasbourg. Après un post-doctorat au Groupe Optique et Systèmes de Communication de l'ENST de Bretagne, il est maître de conférences de l'Université de Bretagne Occidentale en poste à l'Ecole Navale depuis 1992. Ses travaux de recherche au sein du Groupe de Traitement du Signal de l'IRENav portent actuellement sur les réseaux de neurones et les statistiques d'ordre supérieur pour la localisation et la séparation de sources en Acoustique Sous-Marine.



Gilles BUREL est né le 2 mars 1964. Il a obtenu le diplôme d'ingénieur Supélec en 1988, le doctorat de

l'Université de Bretagne Occidentale en 1991 et l'Habilitation à Diriger des Recherches en avril 1996. Il est auteur de 19 brevets et de 50 articles. Après avoir débuté sa carrière à Thomson CSF en 1988, dans le domaine du traitement d'images, il a ensuite rejoint Thomson Multimédia. Depuis septembre 1997, il est Professeur à l'Université de Bretagne Occidentale, où il assure la responsabilité de l'un des quatre thèmes des recherche du Laboratoire d'Electronique et Systèmes de Télécommunications (UMR CNRS 6616), le thème " Traitement du Signal et Circuits ". Ses nouvelles activités de recherche se situent essentiellement dans le domaine des communications numériques.