

Université Bordeaux 1

THESE

Présentée par

Mohamed Soufiane Jouini

pour obtenir le titre de

DOCTEUR

EN SCIENCES PHYSIQUES ET DE L'INGÉNIEUR

**CARACTÉRISATION DES RÉSERVOIRS BASÉE SUR
L'UTILISATION DES TEXTURES DES IMAGES
SCANNERS DE CAROTTES**

Directeur de thèse : Professeur **Mohamed Najim**

Soutenue le 4 février 2009, devant la commission d'examen composée de :

Monsieur Georges OPPENHEIM Professeur à l'université d'Orsay	Président
Monsieur Jean-Marc CHASSERY Directeur de recherches CNRS à Grenoble	Rapporteur
Monsieur Remy PROST Professeur à l'INSA Lyon	Rapporteur
Monsieur Mohamed NAJIM Professeur à l'ENSEIRB	Examineur
Monsieur Yannick BERTHOUMIEU Professeur à l'ENSEIRB	Examineur
Monsieur Noomane KESKES Expert scientifique à TOTAL E&P	Examineur
Monsieur Sebastien GUILLON Ingénieur chercheur à TOTAL E&P	Examineur

Table des matières

1	Introduction	13
1.1	Contexte général de l'étude	13
1.2	Études des carottes	15
1.2.1	Extraction des échantillons "plugs"	15
1.2.2	Description des faciès texturaux	17
1.3	Imagerie scanner de carottes	17
1.3.1	Acquisition par rayons X	17
1.3.2	Éléments géologiques et pétrophysiques	20
1.3.2.1	Analyse géologique	20
1.3.2.2	Analyse structurale	21
1.3.2.3	Analyse pétrophysique :	22
1.3.3	Travaux antérieurs et limites	24
1.4	Méthodologie et organisation de la thèse	25
2	Caractérisation des textures	27
2.1	Généralités sur les textures	27
2.2	Les principales approches d'étude des textures	28
2.2.1	Approches non-paramétriques	28
2.2.2	Approches paramétriques	29
2.2.2.1	Approches statistiques	30
2.2.2.2	Approches stochastiques	31
2.2.2.3	Les modèles basés sur les champs de Markov	31
2.2.2.4	Modèle de Ma et Gagalowicz	32
2.3	Contraintes de l'application et adéquation du modèle	33
2.4	La modélisation multirésolution	34
2.4.1	Introduction aux ondelettes 1-D	34
2.4.2	Les Ondelettes 2-D	35
2.4.2.1	Transformée en ondelettes 2-D "directionnelle"	36
2.4.2.2	Transformée en ondelettes 2-D discrète	37
2.4.2.3	Les filtres de Gabor	40
2.4.2.4	Les pyramides orientées "Steerable Pyramids"	41
2.5	Choix du modèle de texture	45
2.5.1	La densité gaussienne généralisée	46
2.5.2	Estimation des paramètres des GGD	47
2.5.2.1	Méthode des moments	47
2.5.2.2	Méthode du maximum de vraisemblance	48

2.5.3	Gaussianisation des coefficients de la pyramide orientée	50
2.5.3.1	Objectifs et avantages	51
2.5.3.2	La procédure de gaussianisation	53
2.5.4	Choix des descripteurs	55
2.5.4.1	Moyenne, variance et dynamique (minimum et maximum)	56
2.5.4.2	Autocorrélations	56
2.5.4.3	Bilan des descripteurs	57
2.6	Validation du modèle	57
2.6.1	Validation subjective par synthèse de texture	58
2.6.1.1	Imposer une moyenne ou une variance	59
2.6.1.2	Imposer une autocorrélation	59
2.6.1.3	Résultats	60
2.6.2	Validation objective	62
2.6.2.1	Évaluation de la performance du modèle	63
2.6.2.2	Précision-Rappel	64
2.6.2.3	Le taux de bonne classification	65
2.6.2.4	La convergence	66
2.6.2.5	Procédure d'évaluation du modèle	66
3	Analyse des faciès texturaux	71
3.1	Introduction	71
3.1.1	Description manuelle	72
3.1.2	Analyse par tomographie	73
3.2	Classification non-supervisée	75
3.2.1	Classification par partitionnement	75
3.2.1.1	Partitionnement "dur"	75
3.2.1.2	Partitionnement "doux"	78
3.2.2	Classification hiérarchique	79
3.3	Application à la description de faciès texturaux	80
3.3.1	Le choix de Kohonen	80
3.3.2	Log textural	83
3.4	Log textural simplifié	84
3.5	Lien entre la description texturale et les faciès	90
3.6	Conclusion	92
4	Estimation des paramètres pétrophysiques	95
4.1	Introduction	95
4.2	Choix d'un outil d'apprentissage et de prédiction	96
4.3	Les réseaux de neurones	96
4.3.1	Généralités	96
4.3.2	Le neurone formel	97
4.3.3	Modèle du perceptron multicouches	99
4.3.4	La rétropropagation	99
4.3.5	Dimensionnement du réseau	100
4.4	Application : Prédiction des paramètres pétrophysiques	101
4.4.1	Les paramètres pétrophysiques	102
4.4.1.1	La porosité	102

4.4.1.2	La perméabilité	103
4.4.1.3	La saturation, Le facteur de formation et la cimentation	103
4.4.2	Mesures expérimentales	104
4.4.3	Logs pétrophysiques	104
4.5	Estimation par l'analyse texturale	105
4.5.1	Méthodologie	105
4.5.2	Étape d'apprentissage	105
4.5.3	Étape de prédiction et de validation	105
4.5.3.1	Validation par comparaison aux logs krigés et logs de représentativités	106
4.5.3.2	Exemple avec validation par Blind Test	108
4.6	Limites et perspectives	111
5	Conclusion générale et annexes	114
5.1	Conclusion générale	114
5.2	Annexes	116
5.2.1	Le Krigeage	116
5.2.2	Le krigeage avec dérive externe	117
	Bibliographie	118

Table des figures

1.1	Étapes de la caractérisation des réservoirs	14
1.2	Étape 1 : prélèvement des plugs et création du log pétrophysique	15
1.3	Étape 2 : Sciage des carottes et descriptions des faciès texturaux	16
1.4	Le scanner médical à rayons X	18
1.5	Principe de fonctionnement du scanner à rayons X	18
1.6	Exemples d'images issues de l'acquisition en mode scanner 3D	19
1.7	Description de faciès géologiques	21
1.8	Analyse structurale d'une carotte	22
1.9	Analyse du réseau poreux d'une carotte	23
1.10	3 exemples de sections verticales représentant 1 mètre de carotte chacune	24
1.11	Illustration des imageries de parois de puits	25
2.1	Exemples de textures	28
2.2	Texture mur de brique Brodatz	29
2.3	Existence d'orientations reliées au pendage	33
2.4	Variations tailles des vacuoles	34
2.5	Exemples d'ondelettes 1D	36
2.6	La fonction d'échelle et les fonctions d'ondelettes de Daubechies	37
2.7	Exemple de décomposition en ondelettes 2D	38
2.8	Décomposition en ondelettes 2D discrète	39
2.9	Schéma de reconstruction de l'image d'origine	40
2.10	Filtres de Gabor	40
2.11	Décomposition en pyramide orientée	42
2.12	Filtre passe haut	43
2.13	Filtre passe bas	43
2.14	Filtres directionnels	44
2.15	Comportement des sous-bandes orientées	46
2.16	Forme générale de la densité gaussienne généralisée	47
2.17	Ajustements des histogrammes des coefficients d'ondelettes	50
2.18	Gaussianisation des sous bandes orientées	52
2.19	Estimateur de la variance pour les signaux gaussiens et GGD	53
2.20	Exemple d'une <i>ggd</i> et sa fonction de répartition	55
2.21	Gaussianisation d'un signal GGD	56
2.22	Procédure de synthèse	58
2.23	Exemple de synthèse d'une texture de carbonates vacuolaires	61
2.24	Exemple de synthèse de textures de carbonates	61
2.25	Exemple de synthèse de textures hétérogènes	61
2.26	Exemple de synthèse de textures carbonates	62
2.27	Exemple de synthèse de textures homogènes	62
2.28	Schéma de principe d'un système CBIR	63

2.29	Exemples de courbes de précision-rappel.	65
2.30	Échantillons représentatifs de chaque classe de la base VisTex	66
2.31	Schéma d'analyse des textures et Indexation.	67
2.32	Résultats Précision-Rappel : apport de la gaussianisation	68
2.33	Comparaison de la convergence des 2 modèles	68
3.1	Description de faciès globale basée sur une section verticale	72
3.2	Cas synthétique : représentativité verticale et horizontale	73
3.3	Représentativité verticale et horizontale	74
3.4	Carte de Kohonen 1D	76
3.5	Carte de Kohonen 2D	77
3.6	Fonction χ pour l'actualisation des poids	78
3.7	Exemple de dendrogramme	79
3.8	Étapes de la classification hiérarchique	80
3.9	Carte Synthétique de Kohonen à partir de 400 classes	81
3.10	Carte de Kohonen à partir de 225 classes	82
3.11	Carte de Kohonen à partir de 324 classes	83
3.12	Classification sur la carte de kohonen	84
3.13	Carte de kohonen et cercle chromatique	85
3.14	Log textural	85
3.15	Carte Synthétique de Kohonen : Regroupement des classes	87
3.16	Regroupement des classes	88
3.17	Regroupement des classes	89
3.18	Distribution du faciès A sur la carte de Kohonen	90
3.19	Description de faciès par "Log textural" et par technique classique	91
3.20	Distribution des faciès : B, C, D et E sur la carte de Kohonen	92
4.1	Extraction de plugs et mesures pétrophysiques	96
4.2	Schéma général d'un neurone	97
4.3	Modèle d'un neurone formel	98
4.4	Réseaux de neurones à couches	99
4.5	Histogramme des différences entre le log krigé et prédit : en ordonnée le nombre d'erreurs en abscisse leurs valeurs	106
4.6	Porosité : Logs prédits et logs obtenus par Krigeage	107
4.7	Perméabilité : Log prédit et log par représentativités	109
4.8	Logs prédits pour M , Rho et FF	110
4.9	Prédiction de V_{clay} et comparaison avec le rayon gamma	112
5.1	Mise en oeuvre des traitements	115

Résumé

Les carottes, extraites lors des forages de puits de pétrole, font partie des éléments les plus importants dans la chaîne de caractérisation de réservoir. L'acquisition de celles-ci à travers un scanner médical permet d'étudier de façon plus fine les variations des types de dépôts. Le but de cette thèse est d'établir les liens entre les imageries scanners 3D de carottes, et les différentes propriétés pétrophysiques et géologiques. Pour cela la phase de modélisation des images, et plus particulièrement des textures, est très importante et doit fournir des descripteurs extraits qui présentent un assez haut degrés de confiance.

Une des solutions envisagée pour la recherche de descripteurs a été l'étude des méthodes paramétriques permettant de valider l'analyse faite sur les textures par un processus de synthèse. Bien que ceci ne représente pas une preuve pour un lien bijectif entre textures et paramètres, cela garantit cependant au moins une confiance en ces éléments.

Dans cette thèse nous présentons des méthodes et algorithmes développés pour atteindre les objectifs suivants :

1. Mettre en évidence les zones d'homogénéité sur les zones carottées. Cela se fait de façon automatique à travers de la classification et de l'apprentissage basés sur les paramètres texturaux extraits.
2. Établir les liens existants entre images scanners et les propriétés pétrophysiques de la roche. Ceci se fait par prédiction de propriétés pétrophysiques basées sur l'apprentissage des textures et des calibrations grâce aux données réelles.

Le travail présenté dans cette dans cette thèse a été effectué en collaboration avec la société Total qui a recommandé cette étude.

Abstract

Cores extracted, during wells drilling, are essential data for reservoirs characterization. A medical scanner is used for their acquisition. This feature provide high resolution images improving the capacity of interpretation. The main goal of the thesis is to establish links between these images and petrophysical data. Then parametric texture modelling can be used to achieve this goal and should provide reliable set of descriptors. A possible solution is to focus on parametric methods allowing synthesis. Even though, this method is not a proven mathematically, it provides high confidence on set of descriptors and allows interpretation into synthetic textures.

In this thesis methods and algorithms were developed to achieve the following goals :

1. Segment main representative texture zones on cores. This is achieved automatically through learning and classifying textures based on parametric model.
2. Find links between scanner images and petrophysical parameters. This is achieved though calibrating and predicting petrophysical data with images (Supervised Learning Process).

Remerciements

Ce travail a été effectué au Centre Scientifique et Technique Jean Feger de la société Total Exploration Production à Pau.

Je remercie vivement M. Noomane Keskes expert scientifique chez TOTAL, M. Yannick Berthoumieu et M. Mohamed Najim Professeurs à l'université de Bordeaux¹, d'avoir dirigé et corrigé cette thèse.

Je tiens en particulier à remercier M. Jean-Pierre Leduc, François Umbhauer et Sébastien Guillon qui m'ont supervisé tout au long de cette thèse et m'ont énormément appris sur les applications liées à la pétrophysique.

Je voudrais aussi remercier tous les ingénieurs et docteurs de TOTAL EP au Centre Scientifique et Technique Jean Feger, qui ont participé, directement ou indirectement à ces travaux. Je tiens aussi à remercier Youssef Stitou et Noureddine Lasmar qui m'ont aidé dans ce travail et ont contribué de façon significative à sa réalisation.

Je remercie vivement mon père Salah, ma mère Hayet ainsi que ma soeur Sarah pour leur soutien constant pendant la durée de cette thèse.

Je voudrais remercier Monsieur Jean-Marc Chassery et Monsieur Remy Prost d'avoir accepté de rapporter cette thèse et Monsieur Georges Oppenheim pour avoir consenti à juger ce travail.

Introduction


1.1 Contexte général de l'étude

Les sociétés pétrolières sont en recherche permanente de nouveaux sites d'exploitation. Pour cela, de nombreux géologues et géophysiciens mettent leurs connaissances et leurs outils en commun afin de pouvoir déterminer si une zone est susceptible de contenir des poches de pétroles exploitables. Pour y parvenir plusieurs phases d'études sont nécessaires (figure 1.1) :

1. La première phase concerne l'étude menée sur les images sismiques. Celles-ci sont obtenues à partir de campagnes d'acquisitions fournissant une échographie du sous-sol. La résolution des images est de l'ordre de la dizaine de mètres par pixel. Ces images nous renseignent sur la manière selon laquelle se sont déposées les diverses couches sédimentaires. Les interprétations effectuées par les géophysiciens et les géologues sur ces données permettent de repérer potentiellement les zones réservoirs.
2. La deuxième phase concerne le forage au niveau de la zone repérée. Durant ces opérations, des séries de mesures relatives à la résistivité et la radioactivité des roches [1] par exemple sont effectuées. Ces données récupérées permettent de fournir des informations sur la nature des roches et des différents fluides qu'elles contiennent et ont une résolution de l'ordre de la dizaine de centimètres.
3. La troisième phase, quant à elle n'est pas systématique et concerne l'extraction des carottes. En effet, il est possible de réaliser un prélèvement au niveau du réservoir afin de confirmer ou d'infirmer les suppositions des géoscientifiques, mais aussi afin d'obtenir des informations supplémentaires sur la zone observée. On extrait alors, lors de l'opération de forage, une roche de forme cylindrique appelée "carotte". Les carottes présentent des diamètres d'une dizaine de centimètres et des hauteurs variables pouvant aller jusqu'à plusieurs centaines de mètres. Pour des raisons économiques, l'opération d'extraction des

carottes est effectuée sur des portions restreintes du puits. Elles permettent d'estimer la capacité de la roche à contenir des hydrocarbures "la porosité" et sa capacité à laisser passer ces derniers "la perméabilité". Les carottes permettent d'améliorer la résolution de caractérisation au niveau du centimètre.

4. D'autres phases peuvent suivre comme l'étude au microscope des échantillons pris sur les carottes. Ces derniers fournissent des descriptions de données à des résolutions de l'ordre du micromètre.



1.1 – Étapes de la caractérisation des réservoirs

- profondeur
- (1) Images sismiques acquises sur 10 km horizontalement et 4 km de
 - (2) Mesures récupérées lors du forage du puits
 - (3) Extraction des carottes dans la zone réservoir
 - (4) Extraction d'échantillons sur les carottes et analyse au microscope

La caractérisation et la modélisation d'une zone réservoir sont alors réalisées par analyse

conjointe de toutes ces informations c'est à dire à grande échelle nous disposons de données à faible résolution et plus localement à des données à forte résolution.

Le travail de cette thèse concerne l'analyse des images de carotte et l'extraction de paramètres permettant d'enrichir la compréhension du modèle réservoir.

1.2 Études des carottes



1.2 – Étape 1 : prélèvement des plugs et création du log pétrophysique

- (a) Extraction des plugs (forme cylindrique) sur les carottes
- (b) Évaluation expérimentale des paramètres pétrophysiques
- (c) Création du log pétrophysique par krigeage ou interpolation visuelle

1.4 – Le scanner médical à rayons X

Une acquisition scanner est avant tout une mesure de densité à chaque voxel du volume étudié. Pour mesurer la densité d'un corps, on utilise le principe d'absorption qui stipule que l'intensité des rayons X absorbés par le corps étudié dépend de la densité de celui-ci par l'intermédiaire de la constante d'atténuation μ . Le scanner est une chaîne de radiologie avec un tube à rayons X et un ensemble de détecteurs disposés en couronne. Le tube émet un faisceau de rayons X qui traverse un segment de carotte, tandis que les détecteurs mesurent les atténuations de ce faisceau. Le mouvement de rotation autour de la carotte permet d'enregistrer une série de profils d'atténuations résultant de la traversée de la même coupe selon différents angles de rotation (de l'ordre de 1000 mesures par rotation).

1.5 – Principe de fonctionnement du scanner à rayons X

La figure 1.5 montre ce principe d'acquisition. L'ensemble des profils d'atténuation sont

1.6 – Exemples d’images issues de l’acquisition en mode scanner 3D

numérisés, afin de générer une image 2D. La génération de la coupe, valeur d’atténuation en tout point est alors un problème d’inversion : l’image est reconstruite à partir des profils d’atténuation. A chaque pixel de cette image correspond une valeur d’atténuation ou de densité représentée sur l’image finale par une certaine valeur dans l’échelle des gris. Ces valeurs de densité sont exprimées en unité Hounsfield UH, elles s’échelonnent de -1000 à +4000, l’eau possédant une valeur nulle, l’air -1000 et le calcium +1000.

L’utilisation du terme "scanner 3D" est un peu abusive car, en réalité, l’acquisition n’est pas réellement 3D. En effet, le rôle du scanner est limité à l’acquisition des coupes transversales appelées “tomographies” illustrées dans la figure 1.6. L’objet 3D est alors obtenu par juxtaposition des différentes coupes.

Plusieurs avantages peuvent être cités concernant l’utilisation de cette technique. D’abord, l’acquisition peut être vue comme un moyen non destructif pour acquérir des informations sur les carottes. En effet, dans le laboratoire celles-ci sont manipulées par les pétrophysiciens et sédimentologues pour faire divers prélèvements d’échantillons, ce qui introduit des changements


irréversibles sur les carottes. Ensuite cette imagerie permet de mieux explorer la lithologie et la formation rocheuse car elle fournit un niveau de détail qui pourrait être invisible à l'oeil nu. Néanmoins la résolution de ce scanner atteint ses limites quand il s'agit d'étudier la roche au niveau des pores. Les phénomènes microscopiques ne sont pas perçus à cette échelle.

Les champs d'applications des images scanner de carottes sont relativement vastes. Ces applications ont pour but d'affiner l'interprétation des types de roches et de leurs propriétés et sont basées essentiellement sur l'observation à l'oeil nu. Pour résumer, on peut dissocier ces champs d'applications en trois grandes familles :

1. L'analyse géologique,
2. L'analyse structurale,
3. L'analyse pétrophysique.

1.3.2.1 Analyse géologique

La mesure des densités observées dans la carotte permet de mettre en relief les différentes roches présentes dans celle-ci en se basant sur les variations de contraste. La résolution du scanner est largement suffisante pour distinguer les différents types de dépôt (sables, argiles, etc...). Elle est telle que même une faible variation de densité entraîne un contraste visible à l'oeil nu. Cependant, l'image n'est plus significative pour des échelles inférieures au millimètre car, à cette échelle, le signal obtenu peut-être confondu avec le bruit de mesure. La figure 1.7 illustre le résultat d'une analyse des faciès texturaux observés par un sédimentologue, un faciès étant l'ensemble des caractéristiques générales d'une unité de roche qui reflètent son origine et qui permet de la différencier des autres. Ces caractéristiques peuvent être la minéralogie ou la texture par exemple. Cette description traduit une classification visuelle de la lithologie basée sur une liste pré-établie des classes de faciès connus. Chaque couleur représente une classe ou faciès ayant des propriétés granulométriques, minéralogiques et sédimentaires particulières. Dans cette figure nous observons que les faciès interprétés sont grossiers. La description que nous cherchons à construire doit tenir compte de toutes ces variations pour fournir une description plus fine de ces faciès.



1.7 – Description de faciès géologiques

- (a) Échelle des profondeurs
- (b) Coupe verticale scanner de carotte
- (c) Description des faciès texturaux fournie par les sédimentologues une

couleur par faciès

1.3.2.2 Analyse structurale

Dans ce cas c'est l'analyse de structure de la carotte qui est visée. Les éléments intéressants à déterminer sont les fractures et les fissures, qui peuvent être mis en évidence grâce aux algorithmes de traitement d'images. Un exemple illustrant cette caractérisation est fourni dans la figure 1.8. La première partie de la planche illustre une coupe verticale d'une carotte d'un mètre de long ainsi que l'enveloppe cylindrique de celle-ci. La deuxième partie est une vue en 3D où l'on peut voir une coupe verticale ainsi que 3 tomographies. Enfin, la troisième partie illustre, en 3D, les zones de fracturation détectés automatiquement qui se distinguent

par différentes couleurs.




1.8 – Analyse structurale d’une carotte

- (a) Photo réelle de carotte
- (b) Enveloppe cylindrique de l’image scanner de carotte
- (c) Coupe verticale scanner et une tomographie
- (c) Fractures détectées

1.3.2.3 Analyse pétrophysique :


les images scanners des carottes reflètent la densité des roches. Cette propriété peut être reliée naturellement à la faculté de ces dernières à contenir et diffuser les hydrocarbures. L’analyse pétrophysique vise à analyser et prédire, à partir de l’image, ces propriétés réservoir. L’extraction des zones à faible densités (figure 1.9), correspondent aux zones peu poreuse de la carotte, est un exemple de traitement qui permet d’affiner les propriétés réservoir. Nous avons décrit plus haut le processus d’analyse pétrophysique par extraction de plugs. Sans imagerie cette extraction de plugs faites à l’aveugle avec un pas régulier n’est pas toujours optimum. La figure 1.10 illustre trois exemples d’imageries scanner de carotte sur lesquels on peut observer les variations rapides des faciès. En effet, par exemple sur la première section, on peut observer une variation d’une zone lisse suivit d’une zone vacuolaire puis d’une zone lisse de nouveau.



1.9 – Analyse du réseau poreux d’une carotte


L’observation des images scanner issues de l’acquisition des carottes permet aux pétrophysiciens et géologues de mieux cibler les zones d’extraction des plugs. Cette visualisation permet donc d’optimiser le nombre de plugs extraits par rapport à l’extraction “aveugle” faite classiquement. Nous pouvons constater, dans les applications que nous venons de citer, que c’est le grain de l’image qui permet aux interpréteurs d’analyser ces images. En mathématiques appliquées cela revient à faire de l’analyse et de la modélisation de texture.

Le but de cette thèse concerne cette analyse de texture et d’établir les liens qui peuvent exister entre cette notion et les paramètres physiques de la roche.



1.10 – 3 exemples de sections verticales représentant 1 mètre de carotte chacune

L'analyse des textures est une méthode qui a déjà été utilisée dans le domaine de caractérisation des imageries de parois puits [2]. Cette technique permet de donner une description quantitative et objective des caractéristiques texturales des roches réservoir. La méthode utilisée [3] est basée sur une modélisation paramétrique de textures. Elle consiste à extraire des paramètres tels que les histogrammes et les autocorrélations. Ces descripteurs permettent de distinguer les zones homogènes des zones hétérogènes sur les imageries de parois de puits (figure 1.11). Cependant, la résolution plus fine des images de carotte implique une plus grande richesse de textures et les techniques appliquées aux images de parois de puits ne sont plus adaptées.



1.11 – Illustration des imageries de parois de puits

1.4 Méthodologie et organisation de la thèse

La démarche présentée dans ces travaux se fonde sur la modélisation de la texture, à la fois pour aider à l’analyse des faciès géologiques et pour établir l’existence de lien avec les données pétrophysiques. Il existe plusieurs types de modèles permettant de décrire les textures. Afin de pouvoir justifier la validité d’un modèle nous ne nous intéresserons qu’à ceux permettant de faire de la synthèse : étant donné un ensemble de paramètres extraits peut-on générer une texture similaire à l’originale.

Le chapitre 2 de la thèse est consacré à l’étude du modèle de texture choisi. Dans le chapitre 3, nous présentons les techniques de classification non-supervisée et une application basée sur l’utilisation du modèle de texture pour segmenter les blocs d’images de carottes et fournir les classes de textures les plus représentatives dans le domaine carotté. Enfin, le chapitre 4 est dédié à l’estimation des paramètres pétrophysiques à partir d’une calibration des images par rapport aux données pétrophysiques estimées en laboratoire sur les échantillons “plugs”.

Caractérisation des textures

Dans ce chapitre nous présentons d'abord quelques généralités sur la notion de texture et les différentes approches existantes dans la littérature pour la caractériser. Nous introduisons ensuite l'approche que nous avons retenue et présentons les avantages qu'elle apporte pour l'étude des textures. Enfin, nous proposons une modélisation stochastique de type leptokurtique à queue lourde¹, car comme nous le verrons dans la suite certaines variables étudiées présentent des distributions qui peuvent être approximées par ce type modèle.

2.1 Généralités sur les textures

La texture est l'une des principales caractéristiques visuelles utilisées par notre système nerveux central pour interpréter le contenu d'une image (figure 2.1). En vision artificielle à l'instar du système visuel, la texture joue un rôle prépondérant dans de nombreuses applications : en analyse, en classification et en compression des images. Le thème de la modélisation et de l'analyse des textures est aujourd'hui central à de nombreux domaines comme les géosciences [4], l'océanographie et les sciences du vivant [5]. Cette notion met en relief l'organisation spatiale des niveaux de gris de l'image. Elle donne une impression visuelle exprimée souvent par une description des attributs et motifs de base comme la forme, la taille, la densité, la répartition, la connectivité et l'orientation.

Bien qu'il n'existe pas une définition de texture unanimement acceptée, la définition littéraire la considère comme une "répétition spatiale d'un même motif dans différentes directions de l'espace". Cette définition est limitative car elle caractérise l'objet indépendamment d'un observateur humain. La définition donnée par Unser [6] repose sur l'aspect perceptuel : "la texture représente une région d'une image pour laquelle il est possible de définir une fenêtre de dimensions minimales, telle qu'une observation au travers de celle-ci se traduit par une impression visuelle souvent exprimée par une description des attributs identique pour toutes

1. Modèle de distribution qui est plutôt pointu en sa moyenne et ayant des queues de distribution épaisses

les translations possibles de cette fenêtre à l'intérieur de la région considérée. Une autre approche serait encore de définir la texture à partir de deux types d'informations essentielles que comporte l'image :

- Les contours, de type mono dimensionnel, qui marquent les frontières entre régions homogènes,
- La surface, de type bidimensionnel, qui définit les régions homogènes.

2.1 – Exemples de textures

2.2 Les principales approches d'étude des textures

Nous présentons dans un premier temps les principaux modèles d'étude des textures. Ces modèles sont généralement classés en deux grandes familles : les approches paramétriques et non-paramétriques.

Ces approches sont déterministes et supposent qu'une texture est un agencement de primitives ou de textons [7], qui se répètent. Elles sont orientées vers la synthèse de texture à partir des primitives caractérisées, par exemple la brique élémentaire de la figure 2.2, et des

relations de voisinages [8]. C'est le cas par exemple, de la texture d'un mur [9] de briques où la brique serait la primitive. Ces approches que l'on peut qualifier de structurale aussi sont adaptées aux textures de type macroscopique ou présentant en général des motifs de grandes tailles. Une fois les primitives de la texture retrouvées, l'idée est d'essayer de déterminer la règle de placement de ces dernières dans la texture [10, 11].

2.2 – Texture mur de brique Brodatz

Une première méthode, utilisant les propriétés du pavage de Voronoï, a été proposée par Tuceryan et Jain [12]. Cette méthode consiste à extraire les primitives de la texture par détection de contours en utilisant un filtre Laplacien de Gaussienne (LoG) défini par :

$$LoG \triangleq \Delta G_{\sigma}(x, y) = \frac{\partial^2 G_{\sigma}(x, y)}{\partial x^2} + \frac{\partial^2 G_{\sigma}(x, y)}{\partial y^2} \quad (2.1)$$

où

$$G_{\sigma}(x, y) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp\left\{-\frac{1}{2} \frac{x^2 + y^2}{\sigma^2}\right\}.$$

Ensuite, on crée le pavage de Voronoï de chacune des primitives obtenues. Enfin, on extrait les propriétés statistiques de chaque cellule du pavage et on regroupe les primitives ayant des statistiques similaires afin de construire des régions uniformément texturées. Cette méthode est utile si l'on veut réaliser la segmentation d'images texturées.

Un deuxième type de méthode structurale s'attache à déterminer les règles de placement des différentes primitives. En général, ce type de problème est assez complexe. Une méthode de ce type consiste à analyser les réponses de la texture à l'application d'un LoG à différentes échelles et d'en déduire la règle d'agencement des textons [8]. Des méthodes utilisant des structures en arbre sont aussi disponibles dans la littérature.

Les applications de ces méthodes structurales sont essentiellement orientées vers la synthèse de texture. L'idée étant de reproduire au mieux la primitive extraite.

Ces approches considèrent qu'une texture peut être modélisée par un ensemble de para-

mètres mathématiques (approches statistiques) ou qu'elle peut s'apparenter à une variable aléatoire (approches stochastiques).

2.2.2.1 Approches statistiques

L'ensemble de ces paramètres extraits sont en général reliés aux contrastes, corrélations, directivités, uniformités, entropies, etc... Ces éléments sont généralement obtenus à partir des matrices de co-occurrences [13]. Ces dernières contiennent les moyennes d'espace du second ordre pour une image codée sur L niveaux de gris, la matrice de cooccurrence sera de taille $L \times L$. Pour une translation t du plan, ses éléments sont définis par :

$$M_{\mathcal{C}}(i, j) = \text{card}(a, b), (a + t_x, b + t_y) / I(a, b) = i \text{ et } I(a + t_x, b + t_y) = j$$

où I est la matrice des niveaux de gris de la texture et (a, b) un couple de coordonnées de cette matrice, t_x et t_y sont les coordonnées de la translation t . Les matrices de co-occurrences contiennent une quantité d'information trop importante, $t \times L \times L$, qui est difficilement manipulable dans son intégralité. Quatorze indices ont été définis [14] afin de modéliser les principaux caractères descriptifs d'une texture. Les indices les plus fréquemment utilisés sont rappelées ci-dessous sous forme normalisée. Dans ces formules N_c est le nombre de couples de la région étudiée, m_x est la moyenne pondérée des lignes de $M_{\mathcal{C}t}$, m_y est la moyenne pondérée des colonnes de $M_{\mathcal{C}t}$, σ_x est la variance des lignes de $M_{\mathcal{C}}$ et σ_y est la variance des colonnes de $M_{\mathcal{C}t}$.

$$\begin{aligned} & \frac{1}{N} \sum_i \sum_j M_{\mathcal{C}}(i, j)^2 \\ & \frac{1}{N(L-1)^2} \sum_k k^2 \sum_{|i-j|=k} M_{\mathcal{C}}(i, j)^2 \\ & 1 - \frac{1}{N(N)} \sum_i \sum_j M_{\mathcal{C}}(i, j) \cdot \ln(M_{\mathcal{C}}(i, j)) \cdot I_{\mathcal{M}}(i, j) \\ & \frac{1}{N \sigma_x \sigma_y} \left| \sum_i \sum_j (i - m_x)(j - m_y) M_{\mathcal{C}}(i, j) \right| \\ & \frac{1}{N} \sum_i \sum_j \frac{1}{(i-j)^2} M_{\mathcal{C}}(i, j) \\ & \frac{1}{N} \sum_i \sum_j M_{\mathcal{C}}(i, i) \\ & \frac{1}{N^2} \sum_i \sum_j M_{\mathcal{C}}(i, i)^2 \end{aligned}$$

Les approches statistiques sont orientées vers l'analyse des textures. Les paramètres extraits permettent de discriminer, segmenter et classier les textures. Plusieurs travaux se sont intéressés à ces descripteurs pour faire de la synthèse [15]. Ces derniers ont montré que ces paramètres statistiques donnent de bons résultats pour un nombre réduit de variétés de textures. Seules les textures homogènes peuvent être régénérées avec une bonne qualité. Les carottes, quant à elles, montrent une grande richesse de textures hétérogènes, pour cette raison les

approches statistiques ne satisfont pas nos contraintes applicatives.

2.2.2.2 Approches stochastiques

Ces approches supposent qu'une texture est la réalisation d'un processus stochastique qui est régi par un ensemble de paramètres. Les méthodes basées sur des modèles stochastiques consistent à construire un modèle de l'image qui sera utilisé non seulement pour analyser la texture mais aussi pour la synthétiser. Les paramètres de ces modèles contiennent alors les informations relatives à la périodicité, l'orientation et l'agencement des pixels entre eux. Il existe dans la littérature plusieurs travaux traitant ces types de modèles comme par exemple :

- Les modèles du type champs de Markov : Manjunath et Chellapa [16] et Zhu [17].
- Les modèles paramétriques basés sur des descripteurs spatiaux : Ma et Gagalowicz [3], Portilla et Simoncelli [18].

Par définition ces modèles correspondent parfaitement aux critères que nous avons énoncé à savoir : la possibilité d'obtenir un ensemble de descripteurs à partir de l'analyse qui permettent de régénérer des textures de bonne qualité. L'approche que nous allons proposer repose donc sur ces modèles que nous détaillons dans la suite de ce chapitre.

2.2.2.3 Les modèles basés sur les champs de Markov

Les champs de Markov reposent sur le principe que l'intensité d'un pixel dépend seulement des intensités des pixels voisins. Dans ce type d'approches, les intensités et les labels des pixels sont considérés comme des champs de variables aléatoires. La caractérisation des textures est basée sur la probabilité d'observation d'un champ de labels L sachant que l'on dispose du champ des intensités I , c'est-à-dire $P(L = l/I = i)$, où l et i sont des réalisations de ces deux champs. En utilisant le théorème de Bayes, ce problème se ramène à la maximisation de $P(I = i/L = l)P(L = l)$.

Le théorème de Hammersley-Clifford permet de dire que L est un champ markovien associé au voisinage V si $P(L = l)$ est une mesure de Gibbs définie par :

$$P(L = l) = ce^{-U_2(l)}$$

où $U_2(l)$ appelée énergie, est une somme de fonctions définies sur les voisinages (cliques) et c est une constante de normalisation. En posant, $U_1(i, l) = -\ln(P(I = i/L = l))$ on ramène le problème à la minimisation de $U_1(i, l) + U_2(l)$.

2.2.2.4 Modèle de Ma et Gagalowicz

Un autre exemple de modèle probabiliste a été proposé par Ma et Gagalowicz en 1983. Ce modèle est défini par les moyennes d'espace du premier ordre (histogramme) et les moments d'espace du deuxième ordre (auto-covariance). En utilisant un nombre de paramètres relativement faible par rapport aux autres modèles statistiques (matrices de co-occurrence, etc), Ma et Gagalowicz ont montré que ce modèle permet de représenter une vaste classe de textures. En effet, l'histogramme permet de conserver le contraste de la texture et l'auto-covariance fournit les informations sur l'orientation et la taille des grains. Cependant, ce modèle n'est valable que pour les textures microscopiques. L'histogramme H et l'auto-covariance M_2 sont donnés par les deux équations suivantes :

$$H(l) = \frac{1}{N} \sum_{i=1}^N \delta(X_i - l)$$

$$M_2(\Delta) = \frac{1}{N} \sum_{i=1}^N \frac{(X_i - \eta)(X_{i+\Delta} - \eta)}{\sigma^2}$$

$$\text{avec } \eta = \frac{1}{N} \sum_{i=1}^N X_i$$

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (X_i - \eta)^2$$

$\Delta = (x, \Delta_y)$ est une translation du plan,

N est le nombre de points de l'échantillon de texture,

X_i est la valeur de l'intensité lumineuse à la position i ,

$l \in L$, où L est l'ensemble de toutes les luminances possibles,

δ est l'indice de Kronecker.

Étant donné que $M_2(-\Delta) = M_2(\Delta)$, l'ensemble des translations T_Δ se réduit à une demi-fenêtre asymétrique.

Le nombre de translations de cet ensemble est alors donné par :

$$\text{card}(T_\Delta) = \frac{N_x + N_y - 1}{2}$$


N_x et N_y sont les tailles de la taille de la fenêtre pour le calcul de M_2 . Plus la texture considérée est grossière, plus grande doit être la taille de la fenêtre de contrôle utilisée.

A chaque paramètre du second ordre sera associée une des translations Δ de l'ensemble T_Δ . La taille du vecteur attribut contenant l'histogramme H et les auto-covariances $M_2(\Delta)_{\Delta \in T_\Delta}$, c'est-à-dire le nombre de paramètres du modèle, est donc :

$$N_{\mathbf{p}} = \text{card}(L) + \frac{Nx + Ny - 1}{2}.$$

Dans notre application, nous voulons prouver l'existence de liens entre la nature des textures observées et les paramètres pétrophysiques d'autre part et les formations et dépôts sédimentaires d'une autre part. La modélisation paramétrique se trouve être la plus adaptée pour répondre au problème posé : il suffira alors de montrer l'existence du lien entre paramètres de texture et paramètres pétrophysiques. De plus, les sédimentologues et pétrophysiciens nous imposent une autre contrainte qui consiste à ce le modèle proposé doit permettre d'analyser les textures et de les resynthétiser. La synthèse est utilisée comme outil de validation du modèle de texture d'une part et pourra servir à faire des interprétations d'une autre part. Pour résumer nous sommes à la recherche d'un modèle de texture paramétriques permettant d'analyser et resynthétiser les textures.

2.3 Contraintes de l'application et adéquation du modèle



2.3 – Existence d'orientations reliées au pendage


- (a1), (b1), (c1) textures avec une orientation horizontale
 (a2), (b2), (c2) textures avec une orientation inclinée

Afin de proposer un modèle de texture qui permet de représenter au mieux les textures visibles dans les imageries de carottes, il est important de tenir compte de la nature et des propriétés de celles-ci. Dans ce cadre, nous pouvons noter les constatations suivantes :

1. La première concerne l'existence de la notion d'orientation dans ces textures. Ceci est la conséquence de l'existence de pendage dans les carottes extraites (figure 2.3). Dans cette

—

—



2.11 – Décomposition en pyramide orientée

- (1) Sortie du passe haut
- (2) , (3), (4) Échelle 1 : Sous-bandes orientées
- (5) Sortie du dernier passe après sous échantillonnage
- (6) Échelle 2 : Bloc récursif

Les composantes radiale $H(r)$ et angulaire $G_k(\theta)$ sont décrites ci-dessous.

La composante passe-haut du filtre radial s'écrit :

$$H(r) = \begin{cases} \cos(\frac{\Pi}{2} \log_2(\frac{r}{\Pi})) , & \text{si } \frac{1}{2} < \frac{r}{\Pi} < 2 \\ 0 , & \text{sinon} \end{cases}$$


La composante passe-bas du filtre à l'échelle n s'écrit :

$$L_n(r) = \begin{cases} \cos(\frac{\Pi}{2} \log_2(\frac{2^n r}{\Pi})) , & \text{si } \frac{1}{2^{n+1}} < \frac{r}{\Pi} < \frac{1}{2^n} \\ 1 , & \text{si } \frac{r}{\Pi} < \frac{1}{2^{n+1}} \\ 0 , & \text{si } \frac{r}{\Pi} > \frac{1}{2^n} \end{cases}$$

Les figures 2.12 et 2.13 illustrent la décomposition du filtre radial en deux composantes passe-haut et passe bas.

-

-



2.15 – Comportement des sous-bandes orientées

(a1), (a2), (a3) Histogrammes des coefficients des sous-bandes orientées pour une décomposition 1 échelle et 3 orientations

Dans le cas où X suit une loi GGD, la densité de probabilité f est définie par deux paramètres α et β :

$$f_{\mathbf{a}}(x) = \frac{\beta}{2\alpha\Gamma(\frac{1}{\beta})} e^{-(\frac{|x|}{\alpha})^\beta}$$

où Γ est la fonction Gamma définie pour $z > 0$ par la formule suivante :

$$\Gamma(z) = \int_0^{+\infty} e^{-t} t^{z-1} dt \quad (2.3)$$

Le paramètre α est appelé paramètre d'échelle (). Il modélise la largeur du pic. Le paramètre β est appelé paramètre de forme ().

—
—
—
—

de probabilités ou de densités, qui peut être compliqué à dériver. Il est préférable de dériver une somme. C'est pour cette raison que nous commençons par remplacer la vraisemblance par son logarithme. La fonction logarithme étant croissante, il est équivalent de maximiser $Vr(x, \alpha, \beta)$ ou $\log(Vr(x, \alpha, \beta))$ sous l'hypothèse de l'indépendance des coefficients, la fonction de maximum de vraisemblance s'écrit :

$$\log(Vr(x, \alpha, \beta)) = \log\left(\prod_{i=1}^L f_{\alpha, \beta}(x_i)\right) \quad (2.6)$$

L'estimateur de maximum de vraisemblance permet l'estimation de (α, β) en annulant les dérivées de l'équation 2.6 par rapport à α et β :

$$\frac{\partial \log(Vr(x, \alpha, \beta))}{\partial \alpha} = -\frac{L}{\alpha} + \sum_{i=1}^L \frac{\beta |x_i|^{\beta} \alpha^{-\beta}}{\alpha} = 0 \quad (2.7)$$

$$\frac{\partial \log(Vr(x, \alpha, \beta))}{\partial \beta} = \frac{L}{\beta} + \frac{L\Psi\left(\frac{1}{\beta}\right)}{\beta^2} - \sum_{i=1}^L \left(\frac{|x_i|}{\alpha}\right)^{\beta} \log\left(\frac{|x_i|}{\alpha}\right) = 0 \quad (2.8)$$

avec Ψ est la fonction digamma définie par

$$\Psi(t) = \frac{\Gamma'(t)}{\Gamma(t)}.$$

L'équation 2.7 possède une unique solution :

$$\hat{\alpha} = \frac{\beta}{L} \sum_{i=1}^L |x_i|^{\beta} \frac{1}{\beta}$$

En remplaçant α par $\hat{\alpha}$ dans l'équation 2.8, on vérifie que le paramètre de forme estimé $\hat{\beta}$ vérifie :

$$g(\hat{\beta}) = \frac{\Psi\left(\frac{1}{\hat{\beta}}\right)}{\hat{\beta}} - \frac{\sum_{i=1}^L |x_i|^{\hat{\beta}} \log|x_i|}{\sum_{i=1}^L |x_i|^{\hat{\beta}}} + \frac{\log\left(\frac{\hat{\beta}}{L} \sum_{i=1}^L |x_i|^{\hat{\beta}}\right)}{\hat{\beta}} = 0 \quad (2.9)$$

L'équation 2.9 se résout efficacement à l'aide de la procédure itérative de Newton-Raphson. Le principe de cette procédure se base sur le théorème du point fixe, on part donc d'une racine β_k à l'itération k , et on l'améliore en calculant

$$\beta_{k+1} = \beta_k + \frac{g(\beta_k)}{g'(\beta_k)}$$

qui représente la nouvelle racine qui sera utilisée pour l'itération $k+1$. La procédure s'arrête quand $|\beta_{k+1} - \beta_k| < \varepsilon$ où ε est une erreur fixée à priori (par exemple $\varepsilon = 10^{-6}$).

Un calcul simple donne :

$$g'(\beta) = \frac{\Psi(\frac{1}{\beta})}{\beta^2} - \frac{\Psi'(\frac{1}{\beta})}{\beta^3} + \frac{1}{\beta^2} - \frac{\sum_{i \neq}^L |x_i|^\beta (\log|x_i|)^2}{\sum_{i \neq}^L |x_i|^\beta} + \frac{(\sum_{i \neq}^L |x_i|^\beta \log|x_i|)^2}{(\sum_{i \neq}^L |x_i|^\beta)^2} \\ + \frac{(\sum_{i \neq}^L |x_i|^\beta \log|x_i|)^2}{(\sum_{i \neq}^L |x_i|^\beta)^2} + \frac{\sum_{i \neq}^L |x_i|^\beta \log|x_i|}{\beta \sum_{i \neq}^L |x_i|^\beta} - \frac{\log(\frac{\beta}{L} \sum_{i \neq}^L |x_i|^\beta)}{\beta^2}$$

La racine de départ β_0 peut être quelconque, mais pour une bonne estimation nous prendrons $\beta_0 = F_M^{-1}(\frac{1}{\beta})$, β_0 est en fait une estimation de la solution de l'équation 2.9 par la méthode des moments, et la procédure de Newton-Raphson dans ce cas n'est autre qu'un raffinement de cette solution, la convergence est alors obtenue en trois ou quatre itérations.

La figure 2.17 illustre, les histogrammes des coefficients d'ondelettes ainsi que l'estimation des GGD associées, basée sur la méthode maximum de vraisemblance. Elle montre que l'on réussit bien à ajuster les lois marginales des histogrammes des sous bandes orientées en vert, suivant une forme leptokurtique à queue lourde, par les lois de type ggd (en rouge).



2.17 – Ajustements des histogrammes des coefficients d'ondelettes
(a1), (a2), (a3) couples (α, β) estimés pour chaque histogramme ainsi que
les courbes ajustées en rouge

2.5.3.1 Objectifs et avantages

La gaussianisation proposée permet de transformer un signal suivant une loi marginale de type GGD en un signal suivant une loi gaussienne. Elle représente une étape intermédiaire dans notre processus de modélisation des textures.

L'introduction de la procédure de Gaussianisation permet :

- de garantir qu'il n'y a pas de perte d'information lors de la transformation car la gaussianisation est inversible et ne modifie pas les structures. La figure 2.18 illustre ce fait, nous pouvons constater que la transformation préserve les formes et structures ce qui nous conforte dans le fait de pouvoir extraire les autocorrélations sur le signal transformé. Ceci nous permettra de fournir une meilleure estimation des paramètres texturaux [34]. Ces derniers sont estimés de façon beaucoup plus précise sur des signaux de type gaussien que sur des signaux suivant des lois GGD.
- de limiter le nombre de statistiques utilisées pour décrire le modèle de texture. En effet, les signaux gaussiens sont caractérisés parfaitement par les statistiques d'ordre un et deux [35]. De plus, le modèle paramétrique sur lequel on se base est celui proposé par Portilla et Simoncelli [36]. Ce dernier met en jeu un grand nombre de paramètres dont plusieurs statistiques d'ordre supérieur ou égale à 3. Cette technique de gaussianisation doit donc nous permettre de limiter le nombre de statistiques à utiliser pour notre modèle.

Pour illustrer ce dernier point, nous nous sommes intéressés à l'étude de l'estimateur de la variance σ^2 . Pour un échantillon de taille n , si μ_4 représente le moment d'ordre 4 et S^2 représente l'estimateur de la variance alors la variance de l'estimateur de variance a pour expression théorique l'équation 2.10.

$$var(S^2) = \frac{(\mu_4 - \sigma^4)}{n} - 2\frac{(\mu_4 - 2\sigma^4)}{n^2} + \frac{(\mu_4 - 3\sigma^4)}{n^3} \quad (2.10)$$

Pour un échantillon respectivement gaussien et gaussien généralisé, cette variance s'écrit sous les deux formes suivantes :

$$var(S^2) = \frac{(n-1)\sigma^4}{n^2} \quad (2.11)$$

— —

—

—

la synthèse [38, 39].

2.5.4.3 Bilan des descripteurs

Nous passons en revue les paramètres texturaux choisis pour le modèle et issus de la décomposition pyramidale en N échelles et K orientations :

- Les statistiques marginales :
 1. La texture initiale : moyenne, variance, minimum et maximum.
 2. Les sous bandes orientées : moyennes.
- Les statistiques d'ordre 2 ou statistiques spatiales : Autocorrélations des coefficients d'ondelettes issus de chaque sous-bande orientée. $s \times t$, $(s, t) \in \mathbb{N} \times \mathbb{N}$ représente la taille de la matrice d'autocorrélation. Cette dernière étant symétrique nous allons alors extraire seulement $\frac{(s \times t) + 1}{2}$ paramètres.

	Statistiques marginales	Autocorrélations des sous-bandes
Nombre des paramètres	$4 + N \times K$	$(N \times K + 1) \times \frac{(s \times t) + 1}{2}$

2.2 – Nombre des paramètres extraits

Par exemple, pour une décomposition en 2 échelles, 3 orientations et une fenêtre d'analyse d'autocorrélation de taille 7×7 nous obtenons 8 descripteurs. Le nombre de descripteurs proposé par Portilla et Simoncelli est de 21 [36] pour les mêmes conditions. Le tableau 2.2 résume le nombre de paramètres utilisés.

2.6 Validation du modèle

Afin de valider le modèle de la partie précédente, nous proposons deux façons :

1. Une validation subjective grâce à la synthèse de texture à partir des descripteurs choisis,
2. Une validation objective à travers un système d'évaluation inspiré des techniques d'indexation.

$$\frac{\partial A(s, t)}{\partial X(i, j)} = \frac{1}{N \times M} (X(|i + s|_S, |j + t|_T) + X(|i - s|_S, |j - t|_T))$$

L'image transformée sera alors :

$$X^{\mathbf{w}}(i, j) = X(i, j) + \sum_{(\mathbf{s}) \in V} \lambda_{\mathbf{s}} \frac{\partial A(s, t)}{\partial X(i, j)}$$


Où V est le voisinage sur lequel est restreint la matrice d'autocorrélation. L'équation précédente peut aussi s'écrire sous la forme $X^{\mathbf{w}} = X \otimes h_y$ où $\otimes$ est la convolution circulaire. La solution de ce problème dont les inconnues sont les composantes du filtre de convolution, est obtenue en imposant l'autocorrélation de la texture à la nouvelle itération à celle souhaitée notée $A_{\mathbf{D}}$. On a alors $A_{\mathbf{D}} = A \otimes A'_h$ où A et $A_{\mathbf{D}}$ sont respectivement les matrices d'autocorrélations de l'image courante et celle souhaitée. En écrivant les éléments de $A_{\mathbf{D}}$ et les inconnues A_h sous forme de vecteurs et ceux de A sous la forme d'une matrice circulante ceci se ramène alors à un système à N équations et N inconnues. Ce système apparaît alors comme une forme carrée en h_y . Dans le cas général on peut l'approximer par : $h_y \simeq \sqrt{h'_y}$ où $h'_y = TF^{-1} \sqrt{|TF(A_h(i, j))|}$, lorsque A_h est définie positive.

2.6.1.3 Résultats

Afin de valider la pertinence du modèle de texture choisi, dans une première phase, nous nous sommes basés sur la synthèse d'un grand nombre de textures représentatives, échantillonnées sur les carottes. Cette validation est subjective, néanmoins elle a permis de donner une assez grande confiance aux pétrophysiciens et sédimentologues concernant le modèle. Le modèle choisi fait intervenir une plus grande souplesse sur le nombre d'orientations et d'échelles. Le choix des échelles et du nombre d'orientation est basé sur un compromis entre la qualité de la synthèse des textures et le nombre de paramètres à extraire. En effet, le nombre de paramètres extraits est proportionnel au nombre d'échelles et d'orientations mis en jeu. Plus ce nombre est grand plus la qualité de la synthèse a tendance à s'améliorer. Néanmoins, nous devons utiliser les descripteurs à des fins de classification et d'apprentissage basés sur les réseaux de neurones entre autre. Ceci implique des restrictions quant au nombre de ses descripteurs pour des raisons de stabilités essentiellement. Nous avons choisi alors un compromis à travers plusieurs tests de synthèse de textures et notre choix s'est fixé sur $K = 3$ orientations et $N = 2$ échelles ce qui génère 6 paramètres texturaux. Nous pouvons aussi justifier le nombre d'échelles par la nature même des images. En effet, les tailles des grains et des vacuoles représentatifs sont largement captés sur 2 échelles.

Nous présentons dans ce qui suit quelques exemples de textures obtenues grâce à ces descripteurs. Les figures 2.23, 2.24, 2.25, 2.26, 2.27, illustrent chacune :

1. Une texture originale $\emptyset$,
2. Trois réalisations de textures synthétiques $\{1, 2, 3\}$ obtenues à partir des mêmes descripteurs texturaux extraits et des bruits blancs différents.




2.23 – Exemple de synthèse d’une texture de carbonates vacuolaires



2.24 – Exemple de synthèse de textures de carbonates



2.25 – Exemple de synthèse de textures hétérogènes



(0)

(1)

(2)

(3)

2.26 – Exemple de synthèse de textures carbonates

(0)

(1)

(2)

(3)

2.27 – Exemple de synthèse de textures homogènes

Nous constatons que pour une grande variété de type de textures de carottes, nous obtenons visuellement des textures synthétiques d’une très bonne qualité. Ceci a conforté la démarche suivie pour pouvoir établir des liens physiques basés sur ces descripteurs.

La synthèse de texture permet de valider de façon qualitative la pertinence du modèle paramétrique de texture proposé. Afin de valider, de façon quantitative et objective ce dernier, nous nous sommes intéressé à étudier ses performances grâce à l’indexation. L’opération d’indexation automatique est au coeur des activités documentaires, du traitement des documents et du fondement de la recherche de l’information. “L’indexation a pour but de faciliter l’accès au contenu d’un document ou d’un ensemble de documents à partir d’un sujet ou d’une combinaison de sujets” [42]. Elle consiste à faire reconnaître de façon automatique des documents en se basant sur une description de ces derniers. La première génération des systèmes d’indexation automatique ont concerné les documents textuels permettant de localiser un terme ou un ensemble de termes au sein d’une collection de documents. L’indexation d’un document consiste en la caractérisation de son contenu à l’aide de descripteurs afin de pouvoir retrouver aussi facilement que possible dans l’ensemble de la masse documentaire les informations pertinentes qu’il contient. Le descripteur est l’unité de représentation d’un contenu qui est de

meilleur qu'un autre si, en l'utilisant dans un schéma CBIR, sa courbe de Rappel-Précision est au dessus. La comparaison des courbes de précision-rappel pour deux modèles M1 et M2 est présenté dans la figure 2.29. Cette dernière illustre que le système M2 est plus performant que le système M1 puisqu'il présente précision en fonction du rappel supérieure en tout point. Un système parfait aura une courbe constante de valeur 1. Plus les courbes tendent vers cet extrême plus les méthodes sont performantes.



2.29 – Exemples de courbes de précision-rappel.

2.6.2.3 Le taux de bonne classification


Ce critère permet de donner un taux global de bonne classification du système. En effet, il suffit d'analyser toute la base de données de textures et d'utiliser une distance associée pour classer toutes les données de cette base. Connaissant l'appartenance réelle de chaque texture, il est alors facile de quantifier ce taux, en calculant la moyenne des bonnes classifications sur toutes la base. Si K est le nombre de classes, N_k , $k \in K$ le nombre de textures présentes dans chaque classe et n_{b_k} , $k \in K$ le nombre de bonne classifications pour la classe k alors le taux de bonne classification s'écrit :

$$\Theta = \frac{1}{K} \sum_{k=1}^{K} \frac{n_{b_k}}{N_k}$$

2.6.2.4 La convergence

La convergence consiste à représenter le rappel en fonction des tailles de requêtes considérées. Les courbes résultantes permettent d’avoir une idée sur la taille de requête nécessaire pour récupérer le maximum des images pertinentes. Un bon modèle permet de récupérer la majorité des images pertinentes en utilisant une requête de taille raisonnable. Par exemple, une récupération supérieure à 80% des images pertinentes en parcourant seulement 10 % de la base est une bonne performance. Il est évident qu’on atteindra 100% de récupération si toute la base est parcourue.

2.6.2.5 Procédure d’évaluation du modèle



2.30 – Échantillons représentatifs de chaque classe de la base VisTex

Nous allons utiliser la base du MIT Vision Texture (VisTex) qui est constituée de 10 classes de 6 éléments chacune soit une taille de 60 images, représentant des textures naturelles diverses de taille 256×256 . La figure 2.30 illustre un échantillon représentatif de chacune des classes.

Les paramètres extraits pour le modèle sont ceux explicités dans le paragraphe 2.4.4.3. La figure 2.31 rappelle le schéma général pour l’évaluation de l’apport du modèle choisi :

1. La première phase consiste à décomposer la texture en entrée sur la pyramide orientée,
2. Dans la deuxième phase, les sorties des différentes bandes sont gaussianisées dans un cas et pas dans l’autre,


3

Analyse des faciès texturaux

3.1 Introduction

Sur la base du modèle de texture développé au chapitre 2, nous exposons dans ce qui suit l'analyse de faciès texturaux par classification automatique. L'étape de description des faciès géologiques et pétrophysiques, au niveau des carottes, est primordiale pour connaître les zones dites de représentativité. Ces dernières ont des propriétés pétrophysiques et lithologiques proches. Les sédimentologues les établissent manuellement en visualisant les carottes sciées. Plus particulièrement, c'est l'aspect textural des roches qui permet, en grande partie, de les délimiter.

L'amélioration attendue consiste à raffiner cette description pour tenir compte de toutes les variations de lithologie et de textures par le biais de l'analyse texturale. Nous allons montrer que la finesse de la résolution des images scanner de carotte et le traitement proposé sur tomographies répondent à cette exigence. Pour cela nous utiliserons la redondance et la représentativité des données, comme expliqué dans l'introduction, pour établir les classes de textures les plus représentatives vues sur les carottes. La solution choisie est basée sur les cartes topologiques de Kohonen. Ces dernières permettent de fournir les classes de textures recherchées à travers la carte synthétique d'une part et permettent de les représenter de façon organisée, c'est à dire deux classes voisines ont des textures voisines, d'autre part.



3.1 – Description de faciès globale basée sur une section verticale

(a) Sections verticales d'images scanner de carottes

(b) Description grossière des faciès texturaux fournie par les

sédimentologues

La description manuelle est basée sur les observations réelles faites sur les carottes, la figure 3.1 illustre un exemple de ce type de description. La première partie de cette figure correspond à l'image scanner carotte (a) et la seconde illustre un ensemble de couleurs chacun des faciès texturaux retrouvés par le sédimentologue (b).

Le protocole actuel de reconnaissance manuelle des faciès sur les carottes sciées est sous optimum pour les raisons suivantes :

- Le choix de la coupe verticale est arbitraire et fournit donc une représentation ou description qui dépend de la façon dont la donnée est visualisée. Deux coupes verticales prises à des angles de 45° par exemple peuvent fournir des descriptions différentes.
- La précision de la description est limitée dans la mesure où le géologue n'a accès qu'à une sous partie de l'information totale, cela peut altérer la qualité et la précision de la description. Par exemple, si nous considérons le cas synthétique de la figure 3.2, la section verticale nous montre un gradient de texture : passage de zones fortement à faiblement vacuolaires. Cette visualisation verticale nous pousse à associer une seule

texture représentant cet effet visuel du gradient alors que dans la réalité il existe trois textures bien distinctes correspondant aux tailles des vacuoles.




- 3.2 – Cas synthétique : représentativité verticale et horizontale
- (a) Sur la section verticale : perception d'un gradient de texture
 - (b) Sur les tomographies : perception de différentes tailles de vacuoles

Afin d'améliorer la précision de l'analyse de faciès, nous proposons une analyse par tomographie (section horizontale) et d'associer un faciès géologique par coupe. La résolution de l'analyse sera alors celle de l'acquisition c'est à dire 0.625 mm.

$$\varepsilon(t) = \frac{1}{1+t} \quad (3.1)$$

La fonction $\chi(t, j)$ donnée dans l'équation 3.2 et représentée dans la figure 3.6, permet de propager l'apprentissage aux classes voisines du vainqueur. Le nombre de voisins touchés doit lui décroître au cours du temps afin de permettre à l'apprentissage de converger. La fonction la plus utilisée est la gaussienne avec une variance $\sigma(t)$ diminuant au cours du temps. Les classes voisines voient donc leurs poids augmenter proportionnellement à la distance par rapport à la classe gagnante.

$$\chi(t, j) = \exp\left(\frac{-d_j^2}{2\sigma(t)^2}\right) \quad (3.2)$$




3.6 – Fonction χ pour l'actualisation des poids

où d_j est la distance topologique dans la carte entre la cellule gagnante et la classe c_j .

3.2.1.2 Partitionnement "doux"

Une autre alternative consiste à dire qu'une séparation parfaite entre régions n'est pas réaliste. En particulier, l'analyse discriminante nous a habitué à penser en termes de classes ayant des distributions multinormales, et donc se chevauchant nécessairement. Ceci nous incite à considérer la possibilité que les classes puissent empiéter les unes sur les autres. Le mélange de modèles et la classification font partie de ces techniques :

1. Mélanges de modèles : Cette technique part du principe, que pour un nombre supposé de classes C donné, on considérera que l'ensemble des données est en fait un échantillon tiré de C distributions multinormales, chacune affectée d'une probabilité a priori [45]. Il faut alors chercher les centres et matrices de covariances de ces distributions, ainsi que les probabilités a priori. Ce qui permet de maximiser la vraisemblance des données. Ceci est rendu possible par l'utilisation de l'algorithme dit "EM" (Expectation Maximization) [46].



3.11 – Carte de Kohonen à partir de 324 classes

Suite à cette étude, nous avons retenu la taille 10×10 comme référence. Comme nous le verrons plus loin, les caractéristiques topologiques de la carte de Kohonen nous permettront aisément de réduire le nombre final de classes.

Les classes ordonnées de la carte topologique nous permettent de générer une diagraphie de texture, appelée log textural. La diagraphie correspond à l'évolution des textures des carottes de la formation rocheuse en fonction de la profondeur. On définit ainsi le log textural en associant à chaque coupe horizontale une classe de la carte de Kohonen.

La figure 3.12 illustre cette opération de classification issue de la comparaison des distances entre le vecteur de descripteurs obtenue à l'aide des images issues de la tomographie et ceux de chaque classe. Une fois la classe d'appartenance trouvée, nous proposons le couple (d, α) comme représentation équivalente; où d est la distance au centre de la carte et α l'angle associé. Afin de proposer un log Textural, nous réduisons le couple (d, α) à une couleur en associant à la carte de Kohonen une palette de couleur issue du cercle chromatique 3.13 : α représente alors la teinte et d la saturation. Le nouveau mécanisme de création du log textural est alors le suivant : pour chaque tomographie, la classe issue de la carte de Kohonen est alors associée au couple (d, α) et à la couleur correspondante. Finalement le log textural est une

courbe verticale où l'on associe une classe à chaque tomographie (voir figure 3.14).

.....


3.12 – Classification sur la carte de kohonen

- (a) Textures des tomographies des carottes analysées
- (b) Une tomographie et son vecteur de descripteur correspondant
- (c) Calcul de la distance euclidienne avec les vecteurs de chaque classe
- (d) C : Classe d'appartenance trouvée en rouge ici.


Nous pouvons constater ensuite qu'au sein du même faciès textural détecté nous voyons des variations faibles comme le passage de l'orange foncé à l'orangé clair. Cette technique permet donc de décrire aussi bien la variation de texture de façon globale que locale. Enfin, ces variations peuvent être aussi fines que la résolution des données images.

3.4 Log textural simplifié

Les classes voisines qui présentent des textures ressemblantes peuvent être regroupées pour simplifier la carte topologique (diminuer le nombre de classes), en ce que l'on appelle faciès texturaux. Cette simplification se base sur les interprétations sur cette carte synthétique de Kohonen par une interaction manuelle. En d'autres termes, pour les besoins de cette application nous laissons le choix aux géologues et aux sédimentologues de regrouper les zones représentatives qui leurs semblent pertinentes.




3.15 – Carte Synthétique de Kohonen : Regroupement des classes



3.16 – Regroupement des classes

- (a) Échelle des profondeurs
- (b) Photo réelle de carottes
- (c) Sections verticales de carottes
- (d) Sections verticales perpendiculaire à (b) de carottes
- (e) Log textural automatique




3.17 – Regroupement des classes

- (a) Échelle des profondeurs
- (b) Photo réelle de carottes
- (c) Sections verticales de carottes
- (d) Sections verticales perpendiculaires à (b) de carottes
- (e) Log textural automatique
- (f) Log textural regroupé


3.5 Lien entre la description texturale et les faciès

Afin de valider de façon quantitative les liens entre les faciès texturaux établis par les sédimentologues et les logs texturaux fournis par notre technique, nous proposons de calculer sur la carte de Kohonen la distribution de chaque faciès. Cette représentation revient à comparer une description fournie par les sédimentologues et la classification automatique que nous fournissons. En d'autres termes, nous nous intéressons à un faciès donné, que l'on nommera faciès A couleur violette (figure 3.19), nous allons rechercher dans le log textural toutes les classes de Kohonen associées à ce même faciès. Nous cumulonons alors sur la carte de Kohonen la fréquence d'apparition de chaque classe pour ce faciès donné. La figure 3.18 montre la carte de fréquence associée au faciès A. L'échelle de couleur s'étend du bleu vers le rouge, représentant respectivement les faibles et hautes fréquences d'apparition du faciès sur la carte.

La figure 3.20 illustre l'étalement des distributions d'autres faciès (B, C, D, E) sur la carte de Kohonen.



3.18 – Distribution du faciès A sur la carte de Kohonen



3.19 – Description de faciès par “Log textural” et par technique classique

- (a) Sections verticales de carottes
- (b) Description de faciès par le sédimentologue
- (c) Log textural automatique

Nous constatons que pour chaque faciès textural, nous trouvons une correspondance sur la carte de Kohonen qui lui est propre. Dans certains cas, comme pour le faciès D, il existe deux régions de textures qui lui correspondent sur la carte de Kohonen. Ceci s’explique par le fait que pour certains faciès comme les laminées, qui sont une succession de couches de sables et argiles, nous pouvons trouver ces deux derniers types de textures différentes mais

lorsqu'ils sont assemblés, ils représentent finalement le même faciès pour le sédimentologue. Ces résultats confirment les liens pressentis intuitivement entre les textures et faciès.

3.20 – Distribution des faciès : B, C, D et E sur la carte de Kohonen

3.6 Conclusion

La technique de classification non-supervisée de Kohonen associée au modèle de texture proposé nous montrent qu'il est possible de fournir des représentations de classifications texturales de hautes résolutions, automatiques et fiables. Ce système peut aussi s'apparenter à un

outil d'aide à la décision capable de fournir aux pétrophysiciens et sédimentologues une aide pour réduire le temps de création des logs de faciès texturaux.

Une application supplémentaire, que permet cette technique, est de fournir une stratégie d'extraction des plugs plus objective que les méthodes existantes. En effet, les techniques traditionnelles consistent à extraire des échantillons "plugs" avec un pas régulier sans vraiment tenir compte des faciès texturaux car fait en aveugle. Ceci engendre :

1. Un sur-échantillonnage du nombre de plugs si le pas est serré et donc un temps plus long pour effectuer les mesures.
2. Une perte de représentativité des propriétés de certains faciès dans le cas où le pas est grand.

La technique proposée permet de résoudre ces problèmes puisque la représentation fournie tient compte d'une part de toutes les variations des textures et donne d'autre part, une représentativité globale des ressemblances entre régions. Nous pouvons utiliser alors ce résultat pour optimiser l'échantillonnage des plugs.

Dans le chapitre suivant, nous allons exposer la deuxième application basée sur les textures pour retrouver le liens avec les paramètres pétrophysiques.


Estimation des paramètres pétrophysiques

4.1 Introduction

La deuxième application que nous présentons consiste à montrer la possibilité d'estimer certains paramètres pétrophysiques à partir des textures des images scanner. En effet, nous disposons d'un nombre de paramètres pétrophysiques mesurés sur des échantillons "plugs" où nous connaissons aussi les textures des images scanner de carottes associées (figure 4.1). L'idée est de montrer d'abord qu'il existe une relation entre les descripteurs texturaux et les paramètres pétrophysiques. Ensuite il s'agit de prédire ces propriétés pétrophysiques de façon continue sur le reste des zones des carottes en se basant seulement sur les descripteurs texturaux. Le problème se résume alors à une étape d'apprentissage suivie d'une étape de prédiction.

Nous ne connaissons pas a priori de forme analytique pour écrire cette relation. Le seul élément dont nous disposons est l'ensemble de paires (entrées, sorties) qui est notre base d'apprentissage. En d'autres termes, il s'agit d'établir une fonction F , comme dans l'équation 4.1, reliant un vecteur de descripteurs de textures $x \in (x^0, \dots, x^{t-1})$ aux paramètres pétrophysiques $y \in (y^0, \dots, y^{p-1})$ où $t \in \mathbb{N}$ et $p \in \mathbb{N}$.

$$\begin{aligned} F : \mathbb{R}^t &\mapsto \mathbb{R}^p \\ x &\mapsto y \end{aligned} \tag{4.1}$$



4.1 – Extraction de plugs et mesures pétrophysiques

- (a) Zones d'extraction des plugs
- (b) Valeurs pétrophysiques associées

4.2 Choix d'un outil d'apprentissage et de prédiction


Les systèmes réels sont complexes et possèdent dans la plus part des cas des comportements non-linéaires [47]. Ceci rend difficile les étapes de modélisation de leur fonctionnement. Dans notre application, le nombre ainsi que la nature hétérogène des paramètres en entrée font que ce type de fonction est a priori non-linéaire. Les techniques d'intelligence artificielle semblent être les plus adaptées dans notre cas puisque leur force réside dans leur aptitude à apprendre et capturer les relations subtiles entre données même si ces relations sont inconnues ou difficiles à décrire. Plusieurs travaux ont été menés pour comparer les différentes approches possibles pour la résolution de ce type de problèmes de prédictions [48]. Il s'avère que les meilleures performances parmi les systèmes disponibles sont ceux à base de réseaux de neurones [49]. Nous nous sommes donc focalisé sur cette solution pour résoudre notre problème.

Dans ce qui suit nous décrivons le principe des réseaux de neurones ainsi que l'étape d'apprentissage. Ensuite nous illustrons et validons les résultats de prédiction.

4.3 Les réseaux de neurones

Les méthodes de réseaux de neurones, imitant certaines fonctions du cerveau humain, sont modélisées par un ensemble de neurones formels inter-connectés. Les premiers travaux ont été écrits dans les années 1950 par Mc Culloch, Pitts et Hebb, [50, 51], mais l'essor réel de cette technologie date des années 1980 [52, 53]. Un neurone biologique est constitué principalement

d'un corps cellulaire entouré de dendrites et d'un fin prolongement appelé axone qui se termine par de multiples ramifications.



4.2 – Schéma général d'un neurone

Un neurone reçoit des informations de plusieurs milliers d'autres neurones, par ses dendrites, au niveau des liaisons synaptiques. Lorsque la somme des impulsions électriques reçues dépasse un certain seuil, il se produit une brusque dépolarisation du corps cellulaire qui est transmise le long de l'axone jusqu'à d'autres neurones. Au niveau d'une synapse, le message électrique n'est pas directement transmis d'un neurone excitateur à un neurone cible, mais il est transmis par l'intermédiaire de substances chimiques appelées neurotransmetteurs. Une synapse peut être excitatrice ou inhibitrice, c'est-à-dire qu'elle peut engendrer une dépolarisation ou une hyperpolarisation du neurone cible. L'amplitude de la polarisation engendrée constitue aussi une caractéristique propre à chaque liaison synaptique. Les caractéristiques des synapses sont modifiées au cours du processus d'apprentissage.

Un neurone formel est une représentation mathématique et informatique d'un neurone biologique. Le neurone formel possède généralement plusieurs entrées et une sortie qui correspondent respectivement aux dendrites et au cône d'émergence du neurone biologique (point de départ de l'axone). Les actions excitatrices et inhibitrices des synapses sont représentées, la plupart du temps, par des coefficients numériques (les poids synaptiques) associés aux entrées. Les valeurs numériques de ces coefficients sont ajustées dans une phase d'apprentissage. Dans sa version la plus simple, un neurone formel calcule la somme pondérée des entrées reçues, puis applique à cette valeur une fonction d'activation, généralement non linéaire. La valeur finale obtenue est la sortie du neurone. Une représentation du neurone formel est donnée dans la figure 4.3.

a été proposé par Lippmann en 1987 [55]. Cette technique consiste à corriger les erreurs selon l'importance des éléments qui ont participé à la réalisation de ces erreurs. Dans le cas des réseaux de neurones, les poids synaptiques qui contribuent à engendrer une erreur importante se verront modifiés de manière plus significative que les poids qui ont engendré une erreur marginale. Les descentes de gradient ont pour but de converger de manière itérative vers une configuration optimisée des poids synaptiques. Cet état peut être un minimum local de la fonction à optimiser et idéalement, un minimum global de cette fonction (dite fonction de coût). Normalement, la fonction de coût est non-linéaire au regard des poids synaptiques. Elle dispose également d'une borne inférieure et moyennant quelques précautions lors de l'apprentissage, les procédures d'optimisation finissent par aboutir à une configuration stable au sein du réseau de neurones.

Les poids dans le réseau de neurones sont au préalable initialisés avec des valeurs aléatoires. On considère ensuite un ensemble de données qui vont servir à l'apprentissage. Chaque échantillon possède ses valeurs cibles qui sont celles que le réseau de neurones doit à terme prédire lorsque on lui présente le même échantillon. A partir des couples de données (entrée/sortie) d'apprentissage, les réseaux modifient les poids de connexion jusqu'à la stabilisation, en utilisant l'algorithme de rétropropagation d'erreur. Plus le nombre de couches est élevé, plus les réseaux sont capables d'explorer l'espace des solutions pour la classification, mais l'algorithme de rétropropagation en sera d'autant plus complexifié. Cette méthode de rétropropagation est présentée dans l'algorithme .

Afin de dimensionner le réseau, l'analyste doit décider du nombre de couches intermédiaires ou cachées ainsi que du nombre de neurones par couche. Sans couches cachées, le réseau n'offre que de faibles possibilités d'adaptation. Dès lors qu'on lui rajoute une couche cachée il est capable, avec un nombre suffisant de neurones, d'approximer toute fonction continue [56]. Une seconde couche permet de prendre en compte les discontinuités éventuelles. Chaque neurone supplémentaire permet de prendre en compte des profils spécifiques des neurones en entrée.

Un nombre plus important permet donc de mieux coller aux données présentées mais diminue la capacité de généralisation du réseau. Ici non plus il n'existe pas de règle générale mais des règles empiriques. Il existe plusieurs stratégies pour le choix du nombre de neurones de la couche cachée :

- soit égale à celle de la couche d'entrée [57],
- soit égale à la racine carrée du produit du nombre de neurones dans la couche d'entrée et de sortie [58],
- soit égale à 75% de celle-ci [59].

Algorithm 4 La Rétropropagation

Soit un échantillon $\vec{x}$ que l'on met à l'entrée du réseau de neurones et la sortie recherchée pour cet échantillon $\vec{t}$,

On propage le signal en avant dans les couches du réseau de neurones $x_k^{(n-1)} \rightarrow x_j^{(n)}$,

La propagation vers l'avant se calcule à l'aide la fonction d'activation φ , de la fonction d'agrégation h (souvent un produit scalaire entre les poids et les entrées du neurone 4.3) et des poids synaptiques $w_{jk}^{(n)}$ entre le neurone $x_k^{(n-1)}$ et le neurone $x_j^{(n)}$ où n est le numéro de la couche courante $n \in \mathbb{N}$:

$$x_j^{(n)} = \varphi^{(n)}(h_j^{(n)}) = \varphi^{(n)}\left(\sum_k w_{jk}^{(n)} x_k^{(n-1)}\right)$$

Lorsque la propagation vers l'avant est terminée, on obtient à la sortie le résultat $\vec{y}$,

On calcule alors l'erreur entre la sortie donnée par le réseau $\vec{y}$ et le vecteur désiré $\vec{t}$ à la sortie pour cet échantillon. Pour chaque neurone i dans la couche de sortie, on calcule :

$$err_i^{(n)} = \varphi'(h_i^{(n)}) [t_i - y_i]$$

On propage l'erreur vers l'arrière $err_i^{(n)} \rightarrow err_j^{(n-1)}$ grâce à la formule suivante :

$$err_j^{(n-1)} = \varphi'^{(n-1)}(h_j^{(n-1)}) \left(\sum_i w_{ji}^{(n)} err_i^{(n)} \right)$$

On met à jour les poids dans toutes les couches :

$$\Delta w_{ji}^{(n)} = \lambda err_i^{(n)} x_j^{(n-1)}$$

où λ représente le taux d'apprentissage (de faible magnitude et inférieur à 1.0).

Notre modèle de texture engendre un grand nombre de descripteurs, l'utilisation de la première stratégie fait apparaître alors dans plusieurs cas des instabilités dues au grand nombre de degrés de liberté du système. Notons aussi que le deuxième choix réduit le nombre de degrés de liberté au réseau et donc la capacité d'adaptation sur l'échantillon d'apprentissage, au profit d'une plus grande stabilité/capacité de généralisation. La troisième stratégie apparaît alors comme étant le bon compromis dans notre application.

4.4 Application : Prédiction des paramètres pétrophysiques

Dans cette partie nous allons d'abord introduire les divers paramètres pétrophysiques que l'on désire estimer grâce aux textures, ainsi que quelques notions sur les roches réservoirs.

Ensuite, nous citons les diverses techniques utilisées pour l'évaluation de celles-ci. Enfin, nous exposons la méthode basée sur les textures pour réaliser l'estimation de paramètres pétrophysiques.

Les roches réservoirs sont des roches suffisamment poreuses et perméables pour pouvoir contenir des fluides (eau, huile, gaz, etc...). Ces roches, que ce soit des calcaires, des dolomies ou encore des grès, ont un intérêt économique si leurs volumes sont suffisants et si elles sont recouvertes par des roches couvertures imperméables interdisant aux fluides de s'en échapper. Pour exploiter convenablement un gisement de pétrole, de gaz naturel ou encore une roche aquifère, il faut connaître aussi bien que possible les caractéristiques intrinsèques des roches qui renferment ces ressources. Leur capacité de stockage (c'est-à-dire la porosité), leur aptitude à laisser circuler les fluides (c'est-à-dire la perméabilité) ainsi que les méthodes utilisées pour mesurer l'une et l'autre sont des informations primordiales à réunir et à étudier pour décrire le réservoir. Lorsqu'un réservoir potentiel souterrain est repéré par des méthodes de surface, géologiques et géophysiques, il faut en étudier ses qualités. Celles qui conditionnent le rendement potentiel, qu'il soit aquifère ou pétrolier, sont principalement :

1. son volume,
2. sa porosité,
3. son taux de saturation,
4. sa perméabilité,
5. les différents fluides qu'il renferme (huile, gaz, eau).

La texture de la roche, décrite par la relation grain à grain, nous semble de façon intuitive avoir un lien avec ses paramètres.

4.4.1.1 La porosité

L'espace poreux est une continuité d'absence de matière solide imbriquée dans la continuité de matière solide ; il est par essence irrégulier dans ses formes et inconstant dans ses qualités ce qui lui confère une grande complexité . Il apparaît donc logique d'étudier sa variabilité spatiale. La porosité est liée à la dimension, la forme et la distribution des grains.

La porosité (ϕ) [60] correspond au volume total occupé par les vides de la roche (V_p) divisé par le volume total de la roche (V_t), elle s'exprime le plus souvent en pourcentage mais on peut la trouver sous forme de fraction.

$$\phi = \frac{Vp}{Vt}$$

- ϕ : porosité [%]
- Vt : volume total (ou apparent) de l'échantillon [m^3]
- Vp : volume des vides (ou volume des pores) entre les grains solides [m^3]

4.4.1.2 La perméabilité

La perméabilité notée K , caractérise l'aptitude des roches à laisser circuler les fluides contenus dans son volume poreux [61]. Les mesures de perméabilité sont réalisées avec la loi dite de Darcy, qui est d'ailleurs l'unité de mesure. Dans le cas d'une mesure de perméabilité au liquide, elle est définie par :

$$K_l = \frac{u Q_m}{S \rho}$$

où ρ est la masse volumique,

Q_m est le débit massique,

u est le paramètre de forme des pores,

S est la surface de l'échantillon.

Dans le cas de la perméabilité au gaz :

$$K_g = \frac{2 P_a Q \mu L}{S (P_e^2 - P_s^2)}$$

où Q est le débit (cm^3/sec),

μ est la viscosité,

L est la longueur de l'échantillon,

P_e est la pression d'entrée,

P_s est la pression de sortie,

P_a est la pression de mesure du débit du gaz.

4.4.1.3 La saturation, Le facteur de formation et la cimentation

Il existe, en plus des mesures effectuées sur plugs, d'autres mesures électriques relevées au niveaux de la carotte comme la résistivité. Ces mesures servent à l'interprétation en termes de saturation à l'eau et en hydrocarbures [62]. L'équation d'Archie est fréquemment utilisée pour relier la résistivité d'une roche à sa saturation en eau S_w .

$$S_w^n = \frac{a R_w}{\phi^m R_t}$$

où n est un exposant de saturation,

a est une constante,

ϕ est la porosité,

m est l'exposant de cimentation,

R_w est la résistivité de l'eau de formation,

R_t est la résistivité de l'échantillon.

Le facteur de formation est un paramètre relié directement à la résistivité de la roche et est défini par :

$$FF = \frac{a}{\phi^m}$$

L'exposant de cimentation utilisé dans les formules précédentes est défini par :

$$m = -\frac{\text{Log}(FF)}{\text{Log}(\phi)}$$

L'extraction des plugs permet de déterminer, expérimentalement et de façon précise, les valeurs des données pétrophysiques au niveau de la roche. Ces données mesurées au niveau des carottes sont les seules données qui représentent la réalité "terrain". Cependant cette opération coûte cher en temps et en finance : à titre d'exemple il faut environ 2 à 3 semaines pour obtenir une valeur pétrophysique précise entre le moment de l'extraction et la mesure. Pour cela on n'effectue cette opération que de façon ponctuelle sur les carottes. Les mesures des divers paramètres (porosité, perméabilité, saturation, etc) sont effectuées sur les échantillons dans les conditions de pressions et températures des puits.

L'étape qui suit les mesures expérimentales, est la création du "log pétrophysique" [63]. Cette technique consiste à créer une courbe continue, représentant la propriété pétrophysique le long des carottes, à partir des données ponctuelles extraites sur plugs. Cette opération est fondamentale pour la caractérisation du réservoir, aussi bien, au niveau des zones carottées que sur le reste du puits. Actuellement, deux techniques sont utilisées pour faire cette interpolation :

1. La première consiste à interpoler entre les points de mesures en se basant sur la représentativité des faciès fournie par la description du sédimentologue. En d'autres termes, pour chaque faciès on duplique la valeur mesurée de ce même faciès (figure 4.7).
2. La deuxième est le krigeage, qui met une méthode d'interpolation basée sur l'analyse statistique des données observées. Cette méthode est présentée en annexe.

Ces techniques sont peu précises car les résolutions des courbes produites dépendent beaucoup de l'espacement des données, de la finesse de la description fournie par le sédimentologue et

des résolutions des mesures externes utilisées pour le krigeage. En plus, les mesures utilisées comme dérive externe ne sont pas toujours disponibles, et ces mesures ne sont pas réalisables sur les carottes inconsolidées.

La technique présentée dans le paragraphe suivant est une alternative aux deux méthodes présentées ci-dessus.

4.5 Estimation par l'analyse texturale

Afin de créer le log pétrophysique, nous proposons de montrer l'existence d'un lien entre les paramètres texturaux et la mesure pétrophysique. Pour ce faire nous créons un ensemble d'apprentissage à partir des mesures réalisées sur les plugs ainsi que des paramètres texturaux. L'objectif étant d'apprendre la loi sur l'ensemble d'apprentissage puis de l'appliquer sur le reste des zones non-pluguées. Nous avons choisi les réseaux de neurones qui sont parfaitement adaptés à ce type de problème.

L'étape d'apprentissage sert à rechercher une fonction reliant les valeurs pétrophysiques aux descripteurs des textures, au niveau des plugs extraits. Pour ce faire, nous proposons d'utiliser la méthode basée sur les réseaux de neurones supervisés, plus particulièrement les perceptrons "MLP" détaillés au début de ce chapitre. Nous disposons pour l'apprentissage d'un ensemble d'exemples, c'est à dire un ensemble fini de couples de vecteurs (x_i, y_i) où $i \in N$, N étant le nombre d'exemples où x_i désigne le vecteur de paramètres texturaux à l'entrée du réseau et y_i le paramètre pétrophysique associée à cette entrée.


Les propriétés pétrophysiques estimées, à partir des images scanner de carottes, sont essentiellement la porosité, la densité, la cimentation, le facteur de formation ainsi que la perméabilité horizontale (publié dans [64]). Dans ce qui suit nous exposons les résultats de prédiction de ces paramètres et les validons de deux façons :

1. La première consiste à comparer les résultats prédits par la loi apprise aux divers logs pétrophysiques obtenus dans des études précédantes par krigeage ou représentativité.
2. La deuxième consiste à utiliser la technique du "Blind Test". Il s'agit d'utiliser une partie des mesures plugs (les deux tiers en général) qui sont à notre disposition pour apprendre la loi les reliant aux textures associées et garder le reste des mesures pour la validation.



4.7 – Perméabilité : Log prédit et log par représentativités

- (a) Echelles des profondeurs
- (b) Sections verticales
- (c) Log crénaux
- (d) Log crénaux lissé par une fenêtre de 50 cm
- (e) Log prédit



4.9 – Prédiction de Vclay et comparaison avec le rayon gamma

Conclusion générale et annexes

5.1 Conclusion générale

L'utilisation des diverses techniques présentées a été intégrée sous forme d'une chaîne de traitement comportant plusieurs phases décrites dans la figure 5.1 :

1. La première étape consiste à analyser les images scanner de carottes, en entrée du système. Ceci revient plus précisément, à la modélisation des textures des coupes transversales ou tomographies,
2. La deuxième étape concerne la création de la carte synthétique de Kohonen ainsi que la classification qui lui est associée,
3. La troisième étape permet de fournir une stratégie d'échantillonnage des plugs, à partir du résultat de la classification, c'est à dire le log textural,
4. La quatrième étape consiste à récupérer alors les propriétés pétrophysiques, calculées au laboratoire, pour calibrer le système et fournir les logs pétrophysiques.

Le système proposé est un outil de classification basé sur l'analyse des textures et peut donc s'apparenter à une technique d'aide à la décision. La contribution principale de ce travail a été de fournir, aux pétrophysiciens et sédimentologues, des outils d'aide à la décision permettant de générer des résultats fiables, de haute résolution tout en réduisant le temps de calcul pour les logs pétrophysiques. La technique proposée présente plusieurs avantages :

1. Le premier est de fournir une description fine et précise des différentes zones des carottes. Ceci permet d'avoir une idée a priori sur les zones de représentativité recherchées. Ce qui permet de faciliter le travail de délimitation et d'interprétation.

Lorsque on cherche à interpoler les données pétrophysiques ponctuelles, on peut s'aider, dans certains cas, par des variables auxiliaires continues. Ces dernières sont en général, les mesures effectuées directement au niveau de la carotte comme la mesure de radioactivité, rayon Gamma, ou la mesure de densité carotte. La technique du krigeage avec dérive externe permet de modéliser cette allure et de l'incorporer dans la donnée à interpoler afin de mieux reproduire la structure spatiale. Par exemple la mesure de densité au niveau de la carotte est une donnée continue qui est utilisée pour interpoler la donnée porosité. Cependant cette technique possède deux inconvénients majeurs :

1. La résolution des données mesurées au niveau de la carotte sont de l'ordre de la dizaine de centimètres, ce qui fourni une donnée interpolée au mieux à cette résolution.
2. Ces dérives externes ne sont pas toujours mesurables de façon fiable, ceci à cause de l'état des carottes quand elles sont friables par exemple.

Bibliographie

- [1] S. Yilmaz and C. Demircioglu, "Application of artificial neural networks to optimum bit selection," *Journal of Applied Geophysics*, vol. 28, pp. 261–269, 2002.
- [2] J. Shen, "Analyse d'imagerie de puits detection automatique des heterogeneites sedimentaires et tectoniques," *Geophysics*, 1997.
- [3] A. Gagalowicz, "Vers un modele de texture," *Journal of Applied Geophysics*, 1983.
- [4] B. Leiss, K. Ullemeyer, K. Weber, and H. Brokmeier, "Recent developments and goals in texture research of geological materials," *Journal of Applied Geophysics*, vol. 22, pp. 1531–1540, 2000.
- [5] C. Hafemeister and J. Cocquerez, "Detection estimation of wave phenomena in image processing : Application to oceanographic images," *Journal of Applied Geophysics*, 1994.
- [6] M. Unser, "Description statistique de textures : Application inspection automatique," *Journal of Applied Geophysics*, 1984.
- [7] B. Julesz, "Texton gradients : The texton theory revisited," *Journal of Applied Geophysics*, vol. 54, pp. 245–251, 1986.
- [8] M. Haindl, "Texture synthesis," *Journal of Applied Geophysics*, vol. 4, pp. 305–331, 1991.
- [9] Brodatz, "Textures : A photographic album for artists and designers," 1996.
- [10] U. Grenander and A. Srivastava, "Probability models for clutter in natural images," *Journal of Applied Geophysics*, vol. 23, pp. 424–429, 2001.
- [11] D. Mumford and B. Gidas, "Stochastic models for generic images," *Journal of Applied Geophysics*, vol. LIV, pp. 85–111, 2001.
- [12] M. Tuceryan and A. Jain, *Texture Analysis and Synthesis*. World Scientific Publishing Co., Inc., 1993.
- [13] R. Haralick, K. Shanmugam, and I. Dinstein, "Textural features for image classification," *Journal of Applied Geophysics*, vol. 6, pp. 610–621, 1973.
- [14] R. Haralick, "Statistical and structural approaches to texture," *Journal of Applied Geophysics*, vol. 67, pp. 786–804, 1979.

- [15] C. Copeland, "Texture synthesis using gray-level co-occurrence models : Algorithms, experimental analysis, and psychophysical support," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 40, p. 2655, 2001.
- [16] R. Chellappa and B. Manjunath, "Model-based texture segmentation and classification," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 277–310, 1993.
- [17] S. Zhu and D. Mumford, "Filters, random fields and maximum entropy (frame) : Towards a unified theory for texture modeling," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 27, pp. 107–126, 1998.
- [18] E. Simoncelli and T. Freeman, "The steerable pyramid : A flexible architecture for multi-scale derivative computation," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 444–447, 1995.
- [19] S. Mallat, "A theory for multiresolution signal decomposition : The wavelet representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, pp. 674–693, 1989.
- [20] T. Hsu and R. Wilson, "Texture analysis using the multiresolution fourier transform," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 823–830, 1993.
- [21] I. Daubechies, "Orthonormal bases of compactly supported wavelets," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, pp. 499–519, 1993.
- [22] J. Daugman, "Uncertainty relations for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 2, pp. 1160–1169, 1985.
- [23] C. Chui, *Wavelets: A Mathematical Tool for Signal Processing*. San Diego, CA, USA : Academic Press Professional, Inc., 1992.
- [24] S. Mallat, *Wavelet Theory and Applications*. Academic Press, 1999.
- [25] G. Strang and T. Nguyen, "A tutorial on filter banks and wavelets," 1995.
- [26] R. Navarro, A. Taberero, and G. Cristobal, "Image representations with gabor wavelets and its applications," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 97, 1996.
- [27] T. Freeman and H. Adelson, "The design and use of steerable filters," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 13, pp. 891–906, 1991.
- [28] H. Knutsson and G. H. Granlund, "Texture Analysis Using Two-Dimensional Quadrature Filters," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1983.
- [29] M. Porat and Y. Zeevi, "Localized texture processing in vision : Analysis and synthesis in gaborian space," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 36, pp. 115–129, 1989.
- [30] Q. Chen and J. Luo, "Fast and active texture segmentation based on orientation and local variance," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 18, pp. 119–129, 2007.

- [31] K. Sharifi and A. Garcia, "Estimation of shape parameter for generalized gaussian distributions in subband decompositions of video," *IEEE Transactions on Image Processing*, vol. 5, pp. 52–56, 1995.
- [32] G. Wouwer, P. Scheunders, and D. Dyck, "Statistical texture characterization from discrete wavelet representations," *IEEE Transactions on Image Processing*, vol. 8, pp. 592–598, 1999.
- [33] M. Do and M. Vetterli, "Wavelet-based texture retrieval using generalized Gaussian density and Kullback-Leibler distance," *IEEE Transactions on Image Processing*, vol. 11, no. 2, pp. 146–158, 2002.
- [34] S. Jouini, N. Lasmar, Y. Stitou, Y. Berthoumieu, and M. Najim, "Parametric Gaussianization procedure of wavelet coefficients for texture retrieval," in *Proceedings of the IEEE International Conference on Image Processing (ICIP)*, pp. 749–752, 2008.
- [35] G. Tzagkarakis, B. Beferull-Lozano, and P. Tsakalides, "Rotation-Invariant Texture Retrieval with Gaussianized Steerable Pyramids," *IEEE Transactions on Image Processing*, vol. 15, pp. 2702–2718, 2006.
- [36] P. Simoncelli and J. Portilla, "A parametric texture model based on joint statistics of complex wavelet coefficients," *IEEE Transactions on Image Processing*, vol. 40, pp. 49–71, 2000.
- [37] D. Heeger, J. Bergen, and R. James, "Pyramid-based texture analysis synthesis," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 229–238, ACM, 1995.
- [38] B. Julesz and J. Victor, "Visual discrimination of textures with identical third-order statistics," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 31, 1978.
- [39] O. Faugeras and W. Pratt, "Decorrelation methods of texture feature extraction," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 1, pp. 323–332, 1980.
- [40] J. Rosen, "The gradient projection method for nonlinear programming. part 1 : Linear constraints," *Mathematical Programming*, vol. 8, pp. 181–217, 1960.
- [41] H. Paul and J. Mori, "North-holland projected gradient methods for linearly constrained problems," 1986.
- [42] P. Pomart and E. Sutter, "indexation," *IEEE Transactions on Image Processing*, 1997.
- [43] J. McQueen, "Some methods for classification and analysis of multivariate observations," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 1, pp. 281–297, 1967.
- [44] T. Kohonen, "Self-organized formation of topologically correct feature maps," pp. 509–521, 1988.

- [45] G. Celeux and G. Govaert, "A mixture of Gaussians model for clustering," *Journal of the Royal Statistical Society B*, vol. 28, pp. 781–793, 1995.
- [46] A. Dempster, N. Laird, and D. Rubin, "Maximum likelihood from incomplete data via the em algorithm with discussion," *Journal of the Royal Statistical Society B*, vol. 1, pp. 1–38, 1977.
- [47] Q. Zhang, "Nonlinear filtering and control of a switching diffusion with small observation noise," *Journal of the Royal Statistical Society B*, vol. 36, pp. 1638–1668, 1998.
- [48] R. Yam, P. Tse, L. Li, and P. Tu, "Intelligent predictive decision support system for condition-based maintenance," *Journal of the Royal Statistical Society B*, vol. 17, pp. 383–391, 2001.
- [49] B. Samanta and C. Nataraj, "Prognostics of machine condition using soft computing," *Journal of the Royal Statistical Society B*, vol. 24, no. 6, pp. 816–823, 2008.
- [50] W. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *Journal of the Royal Statistical Society B*, pp. 15–27, 1988.
- [51] D. Hebb, *An Introduction to the Psychology of the Human Mind*. Wiley, 1949.
- [52] J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Journal of the Royal Statistical Society B*, vol. 79, no. 8, pp. 2554–2558, 1982.
- [53] J. McClelland and D. Rumelhart, *Explorations in Parallel Distributed Processing*. MIT Press, 1989.
- [54] D. Rumelhart and J. McClelland, *Explorations in Parallel Distributed Processing*. MIT Press, 1986.
- [55] R. Lipmann, "An introduction to computing with neural," *Journal of the Royal Statistical Society B*, vol. 4, pp. 4–22, 1987.
- [56] K. Hornik, "Approximation capabilities of multilayer feedforward networks," *Journal of the Royal Statistical Society B*, vol. 4, pp. 251–257, 1991.
- [57] J. Wierenga and J. Kluytmans, "Neural nets versus marketing models in time series analysis : a simulation studies," *Journal of the Royal Statistical Society B*, vol. 45, pp. 1139–1153, 1994.
- [58] W. Sheppard and R. Simpson, "Using a competitive learning neural network to evaluate software complexity," pp. 262–267, 1990.
- [59] V. Venugopal and W. Baets, "Neural networks and their applications in marketing management," *Journal of the Royal Statistical Society B*, vol. 45, pp. 16–21, 1994.
- [60] G. habezloo and J. SaintMarc, "Evaluation of a permeability-porosity relationship in a low permeability creeping material using a single transient test," *Journal of the Royal Statistical Society B*, pp. 761–768, 2008.

- [61] G. habezloo and J. SaintMarc, "Evaluation of a permeability-porosity relationship in a low permeability creeping material using a single transient test," *Journal of Applied Geophysics*, vol. 46, pp. 761–768, 2009.
- [62] A. Kovsky, W. Patzek, and C. Radke, "Mechanistic foam flow simulation in heterogeneous and multidimensional porous media," *Journal of Applied Geophysics*, vol. 2, pp. 511–526, 1997.
- [63] N. AlBulushi, M. Araujo, and M. Kraaijveld, "Predicting water saturation using artificial neural networks (anns)," in *Proceedings of the 10th International Conference on Artificial Neural Networks*, (Anaheim, CA, USA), pp. 57–62, ACTA Press, 2007.
- [64] S. Jouini and N. Keskes, "Petrophysical properties prediction using 3d core scanner imagery," *Journal of Applied Geophysics*, vol. 2, p. SPE116393, 2008.
- [65] T. Hengl, G. Heuvelink, and D. Rossiter, "About regression-kriging : From equations to case studies," *International Journal of Geographical Information Science*, vol. 33, pp. 1301–1315, 2007.