

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Kasdi Merbah , Ouargla

Faculté des Sciences de la Terre et de l'Univers

Département des Sciences de la Terre



MÉMOIRE DE FIN D'ÉTUDES

Pour l'obtention du diplôme de

MASTER EN GÉOPHYSIQUE

Spécialité : Géophysique Appliquée

Inversion Sismique par Intelligence Artificielle et Apprentissage Automatique

Présenté par : TABAL Mohammed Abdelouahb

Soutenu le : **12-06-2026** devant le jury composé de :

Président : **Dr Ouafi Ameer-Zaimech**

Encadreur : **Dr BANSIR Fateh**

Examineur : **Dr. HARROUCHI Lakhder**

Université Kasdi Merbah – Ouargla

Université Kasdi Merbah – Ouargla

Université Kasdi Merbah – Ouargla

Année universitaire : 2025 – 2026

Dédicaces

Je dédie ce modeste travail à deux personnes dont l'influence a profondément marqué mon parcours académique, scientifique et humain.

À mon cher ami, mentor et enseignant, **Professeur Belksir Mohammed Salah**, en témoignage de mon immense respect et de ma profonde reconnaissance pour ses précieux conseils, son soutien constant, sa générosité intellectuelle et les valeurs scientifiques qu'il m'a transmises. Son accompagnement a contribué de manière significative à mon développement personnel et professionnel.

À mon père spirituel, **Professeur Chetti Djamel Eddine**, dont la sagesse, l'intégrité et la vision ont toujours été pour moi une source d'inspiration. Son encouragement, sa confiance et son attachement à l'excellence scientifique ont profondément influencé mon parcours et nourri ma passion pour la recherche et la connaissance.

Je leur adresse toute ma gratitude et mon estime, en espérant que ce travail soit à la hauteur des enseignements et des valeurs qu'ils m'ont transmis.

Avec respect, reconnaissance et profonde considération.

M.A.T

Remerciements

Avant tout, je tiens à exprimer ma profonde gratitude à Allah Tout-Puissant pour m'avoir accordé la santé, la force et la persévérance nécessaires à l'aboutissement de ce travail.

Je souhaite adresser mes sincères remerciements à mon encadreur pour son accompagnement, ses conseils avisés, sa disponibilité et la confiance qu'il m'a accordée tout au long de cette étude. Son expertise scientifique et ses orientations ont constitué une source précieuse d'inspiration et de motivation.

J'exprime également ma reconnaissance aux membres du jury qui ont accepté d'évaluer ce mémoire et d'enrichir ce travail par leurs remarques et recommandations.

Mes remerciements s'adressent également à l'ensemble des enseignants du département de Géologie et de Géophysique qui ont contribué à ma formation universitaire et au développement de mes compétences scientifiques et techniques.

Je tiens à remercier ma famille pour son soutien indéfectible, sa patience, ses encouragements constants et les sacrifices consentis tout au long de mon parcours académique. Leur confiance a été un moteur essentiel dans la réalisation de ce travail.

J'adresse également mes remerciements à mes collègues, amis et à toutes les personnes qui ont contribué, de près ou de loin, à l'aboutissement de ce mémoire.

Enfin, je souhaite souligner l'apport de la plateforme **QuantX**, développée dans le cadre de mes travaux de recherche, qui a constitué l'environnement principal pour la modélisation géophysique, la simulation sismique et les tests d'inversion présentés dans cette étude.

À tous ceux qui ont participé à cette réalisation, je témoigne ma sincère gratitude.

Résumé

L'inversion sismique constitue un problème inverse fondamental en géophysique appliquée, dont l'objectif est d'estimer les propriétés élastiques du sous-sol, impédance acoustique, vitesses des ondes P et S, densité, à partir des données sismiques enregistrées en surface. Ce problème est intrinsèquement mal posé au sens de Hadamard : sa solution n'est pas unique, elle est instable vis-à-vis des perturbations dues au bruit, et fortement dépendante du modèle de départ utilisé lors de l'initialisation.

Ce mémoire présente le développement, la validation et l'application d'un programme d'inversion sismique hybride dénommé QuantX Pro (v3.0), combinant trois niveaux de sophistication méthodologique croissante. Le premier niveau repose sur les méthodes classiques de régularisation : régularisation de Tikhonov (L2), inversion parcimonieuse (L1) et la formulation mixte L1-L2 (Elastic Net), cette dernière étant résolue par les algorithmes ISTA (Iterative Soft Thresholding Algorithm) et son accélération FISTA, ainsi que par ADMM (Alternating Direction Method of Multipliers) pour les problèmes à grande échelle. Le deuxième niveau intègre des architectures d'apprentissage profond, notamment un réseau de neurones convolutif de type Encodeur-Décodeur (U-Net adapté aux traces sismiques 1D), entraîné de manière supervisée à partir de paires (traces sismiques, impédances de puits). Le troisième niveau incorpore les Physics-Informed Neural Networks (PINNs), qui intègrent l'équation d'onde de Helmholtz directement dans la fonction objectif du réseau, garantissant la cohérence physique des propriétés élastiques estimées. Le module SINDy (Sparse Identification of Nonlinear Dynamics) complète le pipeline par la découverte automatique de lois physiques par régression parcimonieuse.

Le programme est validé sur le modèle synthétique de référence, puis appliqué à des données réelles du bassin de Berkine (Algérie). Les résultats montrent que l'approche hybride L1-L2/PINNs surpasse les méthodes conventionnelles avec une amélioration du coefficient R^2 de 10 à 15 points de pourcentage, une amélioration du rapport signal-sur-bruit de 8 à 18 dB, et une réduction du temps d'inférence d'un facteur 5 à 8.

Mots-clés : *Inversion sismique, Intelligence Artificielle, Régularisation L1-L2, FISTA, ISTA, ADMM, CNN, PINNs, SINDy, Impédance Acoustique, Problème Inverse Mal Posé, QuantX Pro.*

Abstract

This study explores the use of Artificial Intelligence (AI) and Machine Learning (ML) in seismic inversion for reservoir characterization. AI models were trained using seismic and well-log data to predict subsurface properties. The results show improved accuracy and reduced uncertainty compared with traditional methods. These techniques provide valuable support for geophysical interpretation and hydrocarbon exploration.

Keywords: Seismic Inversion, Artificial Intelligence, Machine Learning, Reservoir Characterization, Geophysics.

Résumé

Cette étude porte sur l'utilisation de l'Intelligence Artificielle (IA) et du Machine Learning (ML) dans l'inversion sismique pour la caractérisation des réservoirs. Des modèles ont été développés à partir des données sismiques et des diagraphies de puits afin de prédire les propriétés du sous-sol. Les résultats montrent une amélioration de la précision et une réduction des incertitudes par rapport aux méthodes classiques.

Mots-clés : Inversion sismique, Intelligence Artificielle, Machine Learning, Caractérisation des Réservoirs, Géophysique.

الملخص

تتناول هذه الدراسة استخدام الذكاء الاصطناعي والتعلم الآلي في الانعكاس الزلزالي لتوصيف المكامن. تم تطوير نماذج اعتماداً على البيانات الزلزالية وسجلات الآبار للتنبؤ بخصائص الطبقات تحت سطحية. أظهرت النتائج تحسناً في دقة التنبؤ وتقليصاً لعدم اليقين مقارنة بالطرق التقليدية.

الكلمات المفتاحية: الانعكاس الزلزالي، الذكاء الاصطناعي، التعلم الآلي، توصيف المكامن، الجيوفيزياء

Table des Matières

Dédicaces	2
Remerciements	3
Résumé	4
Abstract	Error! Bookmark not defined.
Table des Matières	6
Liste des Tableaux	12
Liste des Acronymes et Abréviations	13
CHAPITRE 1 : Introduction Générale	14
1.1 Contexte Scientifique et Industriel	15
1.1.1 Rôle de l'Inversion Sismique en Exploration Pétrolière et Minière	15
1.1.2 Limites de l'Interprétation Sismique Conventionnelle	16
1.1.3 Importance de l'Estimation des Propriétés Élastiques	17
1.2 Problématique	17
1.2.1 Nature Mal Posée des Problèmes d'Inversion	17
1.2.2 Sensibilité au Bruit et Dépendance au Modèle Initial	18
1.2.3 Limites des Méthodes Déterministes Classiques	18
1.3 Apport de l'Intelligence Artificielle	19
1.3.1 Transition vers les Approches Data-Driven	19
1.3.2 Capacité des Réseaux Neuronaux à Modéliser des Relations Non Linéaires	19
1.3.3 Intégration Physique , Physics-Guided ML	20
1.4 Objectifs du Mémoire	20
1.5 Méthodologie Générale	21
1.5.1 Modélisation Directe (Forward Modeling)	21
1.5.2 Implémentation des Méthodes d'Inversion	21
1.5.3 Validation et Analyse	21
1.6 Organisation du Mémoire	21
CHAPITRE 2 : Bases Théoriques de l'Inversion Sismique	23
2.1 Propagation des Ondes Sismiques dans les Milieux Élastiques	24
2.1.1 Équation d'Onde Générale	24
2.1.2 Tableau des Propriétés Élastiques par Faciès Géologique	25
2.1.3 Lois de Réflexion et de Transmission , Équations de Zoeppritz	26
2.1.4 Impédance Acoustique , Définition, Mesure et Interprétation	28
2.2 Modèle Sismique Direct , Le Modèle Convolutionnel	29
2.2.1 Formulation du Modèle de Convolution	29
2.2.2 Propriétés Spectrales du Modèle de Convolution	30
2.2.3 Types d'Ondelettes Sismiques	30
2.2.4 Bruit Sismique , Modèle et Impact	31
2.3 Série de Réflectivité et Propriétés du Sous-sol	31
2.3.1 Relation Réflectivité–Impédance , Dérivation Complète	31
2.3.2 Interfaces Géologiques et Distribution Statistique de la Réflectivité	32
2.3.3 Relation Pétrophysique Impédance–Porosité	32
2.4 Le Problème Inverse en Géophysique	33
2.4.1 Définition Mathématique et Classification	33
2.4.2 Non-unicité et Espace Nul de l'Opérateur	34
2.4.3 Régularisation Bayésienne , Cadre Général	34
2.4.4 Sélection du Paramètre de Régularisation λ	35
2.5 Types d'Inversion Sismique	35
2.5.1 Inversion Post-Stack	35

2.5.2 Inversion Pré-Stack (AVO)	36
2.5.3 Inversion Déterministe vs Stochastique	36
2.6 Concepts de Résolution Verticale	36
2.6.1 Critère de Rayleigh et Épaisseur de Tuning	36
2.6.2 Super-Résolution par CNN et Limitations Théoriques	37
CHAPITRE 3 : Méthodes et Algorithmes d'Inversion Sismique	38
3.1 Inversion Classique	39
3.1.1 Inversion L2 , Moindres Carrés Régularisés (Tikhonov)	39
3.1.2 Inversion Sparse , Régularisation L1 (Lasso)	40
3.2 Régularisation , Propriétés Mathématiques Comparées	41
3.2.1 Régularisation par Variation Totale (TV)	42
3.3 Inversion Mixte L1-L2 , Elastic Net et Algorithmes ISTA/FISTA	42
3.3.1 Formulation Mathématique Complète	42
3.3.2 Algorithme ISTA , Iterative Soft Thresholding	43
3.3.3 Algorithme FISTA , Fast ISTA avec Momentum de Nesterov	44
3.3.4 Comparaison Convergence ISTA vs FISTA , Analyse Quantitative	45
3.4 Algorithmes d'Optimisation Complémentaires	45
3.4.1 Gradient Conjugué , CGLS	45
3.4.2 ADMM , Analyse Détaillée	46
3.4.3 Convergence et Analyse de Stabilité	46
3.5 Inversion Basée sur AI/ML	47
3.5.1 Réseaux de Neurones Convolutifs , Fondements	47
3.5.2 Apprentissage Supervisé et Augmentation de Données	49
3.5.3 Physics-Informed Neural Networks , Architecture et Entraînement	49
3.5.4 Quantification d'Incertitude , Monte Carlo Dropout et Processus Gaussiens	50
3.5.5 Module SINDy , Découverte Automatique de Lois Physiques	51
3.6 Comparaison Globale des Approches	52
CHAPITRE 4 : Conception et Développement du Programme d'Inversion	53
4.1 Architecture Globale du Système , QuantX Pro v3.0	54
4.2 Prétraitement des Données Sismiques	55
4.2.1 Filtrage Passe-Bande	55
4.2.2 Normalisation et Gestion des NaN	55
4.2.3 Estimation de la Wavelet	55
4.3 Implémentation de l'Inversion Classique	56
4.3.1 Construction de la Matrice Forward G	56
4.3.2 Implémentation L1, L2, L1-L2	56
4.4 Développement du Modèle AI/ML	57
4.4.1 Architecture du Réseau CNN U-Net	57
4.4.2 Fonction de Coût Hybride	57
4.4.3 Entraînement du Modèle	57
4.5 Intégration du Modèle Physique	57
4.6 Validation du Programme	58
CHAPITRE 5 : Application sur des Données Sismiques	59
5.1 Application sur Données Synthétiques	60
5.1.1 Génération du Modèle Synthétique	60
5.1.2 Simulation des Données Sismiques	60
5.1.3 Résultats d'Inversion , Comparaison des Méthodes	61
5.1.4 Analyse des Performances	61
5.2 Application sur Données Réelles , Bassin de Berkine	62
5.2.1 Présentation du Jeu de Données et Contexte Géologique	62

5.2.2 Prétraitement des Données Réelles	63
5.2.3 Résultats d'Inversion	63
5.2.4 Interprétation Géologique	63
5.3.1 Méthodologie et Protocole Expérimental	64
5.3.2 Description des Étapes de Complexité Croissante	64
5.3.3 Résultats Quantitatifs et Évolution des Métriques	65
5.3.3.1 Évolution des Métriques : Analyse Graphique	65
5.3.4 Analyse Stade par Stade et Interprétation	65
5.3.5 Synthèse et Implications Méthodologiques	71
Interprétation Géologique et Géophysique des Résultats d'Inversion Post-Stack	72
1. Contexte Géologique du Modèle	72
2. Caractérisation de la Structure Anticlinale	72
	73
3. Interprétation de la Faille Inverse	74
4. Analyse de la Récupération des Horizons Stratigraphiques	74
5. Analyse des Profils de Vitesse	75
6. Analyse des Résidus et de la Qualité de l'Inversion	76
7. Analyse des Gradients Latéraux et de la Géométrie Structurale	76
Conclusion	77
5.3.6 Conclusion Générale et Interprétation Finale	77
CHAPITRE 6 : Analyse et Discussion des Résultats	80
6.1 Comparaison des Méthodes	81
6.1.1 Performances Globales et Résolution Verticale	81
6.1.2 Stabilité et Conditions aux Limites	81
6.2 Sensibilité aux Paramètres	81
6.2.1 Paramètres de Régularisation λ_1 et λ_2	81
6.2.2 Sensibilité à l'Architecture du Réseau CNN	82
6.3 Impact du Bruit	82
6.4 Analyse d'Incertitude	82
6.4.1 Méthodes Bayésiennes , Monte Carlo Dropout	82
6.4.2 Interprétation Géologique de l'Incertitude	83
6.5 Limites de l'Étude	83
CHAPITRE 7 : Conclusion Générale et Perspectives	84
7.1 Synthèse des Résultats	85
7.1.1 Apports Scientifiques	85
7.1.2 Performance des Méthodes	85
7.2 Contributions du Travail	85
7.3 Perspectives	86
7.3.1 Deep Learning Avancé , Transformers et GANs	86
7.3.2 Inversion Multi-Attributs	86
7.3.3 Applications 4D , Monitoring de Réservoir	87
Références Bibliographiques	88
ANNEXE : Code Source du Programme QuantX Pro , Extraits Commentés	90
B.1 Structure Générale et Technologies du Programme	91
B.2 Structures de Données et Paramètres d'Inversion	94
B.3 Opérateurs Linéaires : Convolution et Différences Finies	95
B.4 Algorithme FISTA , Cœur de l'Inversion L1-L2	95
B.5 Fonction Objectif Hybride et Régularisation Tikhonov	97
B.6 Inversion 2D avec Régularisation Spatiale	97
B.7 Accélération GPU , FISTA sur PyTorch/CUDA	98

B.8 Algorithme CGLS , Gradient Conjugué pour les Moindres Carrés	99
B.9 Inversion JAX , FISTA avec Compilation JIT	100
B.10 Inversion Jointe Multi-Méthodes	100
B.11 Gestion des Données , Formats SEG-Y et LAS	101
B.12 Point d'Entrée et Interface PyQt6	102
B.13 Tableau Récapitulatif des Classes et Algorithmes Implémentés	103

Liste des Figures

Figure 1.1 : Workflow général de l'exploration sismique et positionnement de l'inversion sismique.

Figure 1.2 : Schéma de la chaîne acquisition-traitement-interprétation en géophysique.

Figure 2.1 : Propagation des ondes sismiques dans un milieu stratifié.

Figure 2.2 : Décomposition de l'énergie aux interfaces ondes réfléchies et transmises.

Figure 5.10 : Évolution des quatre métriques (RMSE, Corrélation, SNR, MAE) en fonction des étapes de complexité croissante validation progressive (QuantX Pro v3.0).

Figure 5.11 : Résultats d'inversion pour les étapes 1 (couches horizontales) et 2 (couches pendantes) colonnes : modèle vrai, modèle inversé, résidus.

Figure 5.12 : Étape 3 (anticlinal simple) première introduction de structures courbées ; meilleure performance de la séquence (RMSE = 190,5 m/s, Corr. = 0,974).

Figure 5.13 : Étape 4 (failles et hétérogénéités) discontinuités structurales et variations latérales de faciès.

Figure 5.14 : Étape 5 (géologie complexe, prox) corps salin, chenaux et failles multiples.

Figure 5.15 : Étape 6 (sous-ensemble) complexité maximale du benchmark (RMSE = 63,4 m/s, Corr. = 0,622).

Figure 5.16 : Modèle de vitesses initial et inversé contexte géologique général (anticlinal asymétrique et faille inverse, bassin de Berkine, QuantX Pro v3.0).

Figure 5.17 : Restitution de l'anticlinal asymétrique par inversion post-stack soulèvement des horizons sédimentaires (~ 80 m) entre $x = 2500$ m et $x = 4500$ m.

Figure 5.18 : Géométrie de la fermeture structurale de l'anticlinal identification du piège structural pour l'accumulation des hydrocarbures.

Figure 5.19 : Détection de la faille inverse ($x = 2500$ m) par inversion post-stack discontinuité latérale de vitesse et compartiment oriental surélevé.

Figure 5.20 : Amélioration de la définition des interfaces stratigraphiques après inversion préservation du gradient vertical de vitesse (1500–4300 m/s).

Figure 5.21 : Profils de vitesse comparatifs (modèle vrai, modèle initial, modèle inversé) à proximité de la faille inverse récupération partielle du rejet tectonique.

Figure 5.22 : Cartes de résidus avant et après inversion réduction des anomalies associées à l'anticlinal (RMSE : 817 m/s $\rightarrow$ 807 m/s, Corr. : 0,350 $\rightarrow$ 0,382).

Figure 5.23 : Cartes de gradient latéral de vitesse identification des structures tectoniques (flancs de l'anticlinal et plan de faille inverse).

Figure 5.24 : Workflow général d'inversion sismique post-stack QuantX Pro v3.0 de la donnée sismique brute au modèle de vitesses inversé.

Figure B.1 : Structures de données et paramètres d'inversion QuantX Pro v3.0 (extrait du module de configuration des hyperparamatres).

Liste des Tableaux

Tableau 2.1 : Valeurs typiques d'impédance acoustique par faciès lithologique

Tableau 2.2 : Propriétés des ondelettes sismiques couramment utilisées

Tableau 2.3 : Comparaison inversion déterministe vs stochastique

Tableau 3.1 : Propriétés mathématiques des normes L0, L1, L2 et Elastic Net

Tableau 3.2 : Complexité algorithmique ISTA, FISTA, ADMM, CGLS, Tikhonov

Tableau 3.3 : Comparaison globale des approches d'inversion

Tableau 4.1 : Technologies et dépendances de QuantX Pro v3.0 .

Tableau 4.2 : Hyperparamètres FISTA/ISTA , valeurs par défaut et plages .

Tableau 4.3 : Paramètres d'architecture CNN U-Net .

Tableau 5.1 : Paramètres du modèle Marmousi .

Tableau 5.2 : Résultats comparatifs , données synthétiques

Tableau 5.3 : Résultats robustesse au bruit , R^2 vs SNR .

Tableau 5.4 : Caractéristiques du volume sismique réel , bassin de Berkine .

Tableau 5.5 : Métriques d'inversion sur données réelles , puits de validation .

Tableau 6.1 : Tableau de synthèse comparative finale , toutes méthodes .

Tableau 6.2 : Analyse de sensibilité aux paramètres de régularisation λ_1/λ_2 .

Liste des Acronymes et Abréviations

Acronyme	Signification complète
AI / IA	Artificial Intelligence / Intelligence Artificielle
ML	Machine Learning , Apprentissage Automatique
DL	Deep Learning , Apprentissage Profond
CNN	Convolutional Neural Network , Réseau Convolutif
PINNs	Physics-Informed Neural Networks , Réseaux Informés par la Physique
SINDy	Sparse Identification of Nonlinear Dynamics
ISTA	Iterative Soft Thresholding Algorithm
FISTA	Fast Iterative Soft Thresholding Algorithm
ADMM	Alternating Direction Method of Multipliers
CGLS	Conjugate Gradient Least Squares
SIRT	Simultaneous Iterative Reconstruction Technique
AVO	Amplitude Versus Offset
FWI	Full Waveform Inversion
IA	Impédance Acoustique
SI	Impédance de Cisaillement
RMSE	Root Mean Square Error
MAE	Mean Absolute Error
R^2	Coefficient de Détermination
SNR	Signal-to-Noise Ratio , Rapport Signal sur Bruit
SEG-Y	Society of Exploration Geophysicists , format sismique standard
GAN	Generative Adversarial Network
GP	Gaussian Process , Processus Gaussien
GPU	Graphics Processing Unit
JAX	Just-in-time compilation for numerical computation

CHAPITRE 1 : Introduction Générale

1.1 Contexte Scientifique et Industriel

1.1.1 Rôle de l'Inversion Sismique en Exploration Pétrolière et Minière

L'exploration des ressources naturelles du sous-sol, hydrocarbures, ressources minières, eaux souterraines, constitue un enjeu économique et géopolitique majeur à l'échelle mondiale. En Algérie, les bassins sédimentaires sahariens représentent l'essentiel des réserves nationales prouvées d'hydrocarbures, et leur exploitation repose sur une caractérisation géologique précise réalisée principalement par les méthodes géophysiques.




Figure 1.1 : Workflow général de l'exploration sismique et positionnement de l'inversion

La sismique réflexion est la méthode d'exploration géophysique la plus utilisée à l'échelle industrielle. Son principe repose sur l'émission d'une onde sismique depuis la surface (vibrateurs hydrauliques, canon à air), son enregistrement après réflexion aux interfaces géologiques par un réseau de capteurs (géophones, hydrophones), et l'interprétation de ces enregistrements pour imager la géométrie et les propriétés physiques des formations du sous-sol. Cette méthode permet d'imager des structures géologiques jusqu'à plusieurs kilomètres de profondeur depuis la surface, avec une résolution spatiale compatible avec les besoins de l'exploration et de la production.

L'inversion sismique est l'étape cruciale qui transforme les données sismiques brutes, des amplitudes de réflexion relatives, en propriétés physiques quantitatives directement exploitables par les géologues et ingénieurs de réservoir. Ces propriétés incluent l'impédance acoustique $IA = V_p \times \rho$, les vitesses des ondes de compression V_p et de cisaillement V_s , et la

densité ρ . Ces grandeurs sont directement reliées aux paramètres pétrophysiques d'intérêt : la porosité, la saturation en fluides, la lithologie et la perméabilité des réservoirs.




Figure 1.2 : schéma d'une chaîne d'acquisition, traitement et interprétation pour la géophysique

Dans le contexte industriel algérien, l'amélioration de la qualité de l'inversion sismique se traduit directement par une réduction du risque de forage, une meilleure définition du volume de réservoirs en place, et une optimisation des stratégies de développement et de récupération des hydrocarbures. L'enjeu économique est considérable : un forage d'exploration sec peut coûter plusieurs dizaines de millions de dollars, et une meilleure inversion sismique peut réduire significativement le taux d'échec.

1.1.2 Limites de l'Interprétation Sismique Conventionnelle

L'interprétation sismique conventionnelle, qui s'appuie principalement sur la lecture qualitative des réflecteurs sismiques et l'utilisation directe des amplitudes, atteint rapidement ses limites dans plusieurs contextes géologiques :

- Environnements géologiques complexes : les milieux fracturés, les formations carbonatées à forte hétérogénéité latérale, les corps chenalisés et les réservoirs en biseau produisent des réponses sismiques complexes difficiles à interpréter sans inversion quantitative.
- Discrimination fluides-lithologie : les variations d'amplitude sismique peuvent être causées indifféremment par des changements de lithologie, de saturation en fluides, ou de pression. Sans inversion élastique (V_p , V_s , densité), la discrimination n'est pas possible de manière fiable.
- Résolution verticale limitée : la sismique conventionnelle ne peut distinguer deux réflecteurs séparés par moins d'un quart de longueur d'onde (critère de Rayleigh, soit 20-30 m pour des fréquences dominantes de 40 Hz). De nombreuses intercalations réservoir-roche mère sont sous la limite de résolution sismique.

- Absence de calibration pétrophysique : l'interprétation purement qualitative des amplitudes ne fournit pas de valeurs quantitatives directement utilisables dans les simulateurs de réservoir.

1.1.3 Importance de l'Estimation des Propriétés Élastiques

Les propriétés élastiques du sous-sol, impédance acoustique, impédance de cisaillement, rapport V_p/V_s , module de Poisson, sont directement reliées à la nature des roches et des fluides saturants. L'impédance acoustique $IA = V_p \times \rho$ est corrélée à la porosité selon des relations pétrophysiques empiriques (Wyllie, Raymer, Han). Le rapport V_p/V_s est particulièrement sensible aux fluides : les gaz réduisent fortement V_p sans affecter significativement V_s , produisant une chute marquée du rapport V_p/V_s dans les réservoirs à gaz. Ces propriétés constituent les entrées des simulateurs de réservoir et des modèles géomécaniques, rendant leur estimation précise fondamentale pour toute la chaîne de valeur de l'exploration-production.

1.2 Problématique

1.2.1 Nature Mal Posée des Problèmes d'Inversion

L'inversion sismique est un problème inverse au sens mathématique strict. Le problème direct (forward problem) consiste à calculer les données sismiques d à partir d'un modèle du sous-sol m : $d = G(m) + \varepsilon$. Ce calcul est unique et stable. Le problème inverse consiste à retrouver m à partir de d en inversant l'opérateur G , ce qui est fondamentalement différent et beaucoup plus difficile.

Jacques Hadamard (1902) a défini les conditions de bon conditionnement d'un problème mathématique : existence de la solution, unicité de la solution, stabilité de la solution vis-à-vis des perturbations des données. Un problème ne satisfaisant pas l'une de ces trois conditions est dit mal posé (ill-posed). Le problème inverse sismique est mal posé pour les trois raisons suivantes :

1. Non-existence : en présence de bruit de mesure important ou d'erreurs de modélisation (hypothèse d'ondelette stationnaire violée, effets 3D dans une inversion 2D), il peut n'exister aucun modèle qui reproduise exactement les données observées.
2. Non-unicité : le spectre des données sismiques est limité à une bande de fréquences typiquement étroite (5-80 Hz). Un nombre infini de modèles d'impédance produisent

des données sismiques identiques dans cette bande de fréquences (toute modèle à la même somme des amplitudes dans la bande passante sera équivalent). Les composantes basses fréquences (< 5 Hz) et hautes fréquences (> 80 Hz) sont manquantes et doivent être apportées par la contrainte a priori.

3. Instabilité : la matrice de l'opérateur de modélisation directe G est singulière ou très mal conditionnée (numéro de condition $\kappa(G) \gg 1$). De petites perturbations ε dans les données (bruit sismique) produisent des variations potentiellement énormes dans la solution non régularisée $m = G^\dagger d$.

1.2.2 Sensibilité au Bruit et Dépendance au Modèle Initial

Les méthodes d'inversion classiques itératives cherchent à minimiser une fonction de coût de la forme $J(m) = \|d - G(m)\|^2 + R(m)$ où $R(m)$ est un terme de régularisation. Cette minimisation est réalisée par des algorithmes de type gradient, qui convergent vers un minimum local de J . La solution obtenue dépend donc fortement du point de départ de l'optimisation, c'est-à-dire le modèle initial m_0 . Si m_0 est trop éloigné du vrai modèle, l'algorithme peut converger vers un minimum local non physique, même si la régularisation est bien choisie. La construction d'un bon modèle initial, généralement par interpolation des diagraphies de puits disponibles, est donc une étape critique qui conditionne la qualité de l'inversion.

Le bruit sismique, qu'il soit aléatoire (bruit ambiant) ou cohérent (multiples, ondes de surface résiduelles, diffractions), constitue une source majeure d'instabilité pour l'inversion. Sans régularisation adéquate, le processus d'inversion amplifie le bruit haute fréquence, produisant des solutions oscillantes physiquement inacceptables. Le choix du type de régularisation et de son niveau (paramètre λ) est un compromis délicat entre la fidélité aux données et la stabilité de la solution.

1.2.3 Limites des Méthodes Déterministes Classiques

Les méthodes d'inversion déterministes classiques, inversion récursive, inversion basée sur modèle, inversion sparse-spike, partagent des limitations structurelles qui motivent l'exploration d'alternatives basées sur l'Intelligence Artificielle :

- Linéarisation locale : la plupart des méthodes classiques supposent une relation linéaire ou quasi-linéaire entre les données et le modèle dans un voisinage de la solution. Cette hypothèse est invalidée pour les milieux à forts contrastes d'impédance ou les acquisitions à grands angles d'incidence.

- Coût computationnel élevé : les méthodes itératives (Full Waveform Inversion, inversions basées sur modèle) nécessitent de nombreux appels à l'opérateur de modélisation directe à chaque itération, ce qui devient prohibitif pour les volumes sismiques 3D de grande taille.
- Difficultés avec les hétérogénéités latérales : les méthodes 1D trace-par-trace ne peuvent pas exploiter les corrélations spatiales entre traces voisines. Les méthodes 2D/3D sont beaucoup plus complexes à mettre en œuvre.
- Quantification d'incertitude limitée : les méthodes déterministes produisent une solution unique sans information sur l'incertitude associée, pourtant essentielle pour la prise de décision géologique.

1.3 Apport de l'Intelligence Artificielle

1.3.1 Transition vers les Approches Data-Driven

L'Intelligence Artificielle et l'Apprentissage Automatique représentent une rupture paradigmatique dans la manière d'aborder les problèmes inverses géophysiques. Plutôt que de chercher à paramétrer explicitement le modèle physique et à le résoudre analytiquement ou itérativement, les approches data-driven apprennent directement le mapping entre l'espace des données (traces sismiques) et l'espace des modèles (impédances) à partir d'exemples d'entraînement. Cette approche présente des avantages considérables : aucune hypothèse de linéarité n'est nécessaire, le temps d'inférence après entraînement est quasi-instantané, et le modèle peut capturer des relations complexes entre données et propriétés que les modèles physiques simplifiés ne peuvent pas représenter.

1.3.2 Capacité des Réseaux Neuronaux à Modéliser des Relations Non Linéaires

Le théorème d'approximation universelle (Cybenko, 1989 ; Hornik, 1991) établit que tout réseau de neurones à une seule couche cachée avec suffisamment de neurones peut approcher n'importe quelle fonction continue à n'importe quelle précision. Les réseaux profonds (Deep Networks) exploitent une hiérarchie de représentations pour apprendre des fonctions encore plus complexes avec un nombre de paramètres raisonnable. Pour l'inversion sismique, cela signifie que le réseau peut apprendre le mapping non linéaire exact entre les amplitudes sismiques (incluant leurs variations de forme, d'amplitude et de fréquence) et les propriétés d'impédance, sans nécessiter la formulation d'un modèle physique explicite de cette relation.

Les réseaux convolutifs (CNN) sont particulièrement adaptés aux données sismiques grâce à leurs propriétés d'invariance par translation et de détection de motifs locaux. Un réflecteur sismique, quelle que soit sa position dans la trace, produit le même motif local que le CNN peut détecter et associer à un contraste d'impédance. La hiérarchie de filtres appris permet de capturer simultanément les variations basse fréquence de l'impédance (tendances générales) et les détails haute fréquence (interfaces fines).

1.3.3 Intégration Physique , Physics Guided ML

Le principal risque des approches purement data-driven est la production de solutions physiquement incohérentes, en particulier en dehors du domaine d'entraînement. Les Physics Informed Neural Networks (PINNs, Raissi et al., 2019) résolvent ce problème en intégrant les équations physiques directement dans la fonction de coût du réseau sous forme de termes de pénalité différentiels. Pour l'inversion sismique, cela signifie que le réseau est contraint à produire des propriétés élastiques compatibles avec l'équation d'onde, garantissant que le sismogramme synthétique calculé à partir des propriétés prédites est proche du sismogramme réel. Cette approche combine les avantages de la flexibilité des réseaux de neurones et de la rigueur de la physique.

1.4 Objectifs du Mémoire

4. Réaliser une revue bibliographique exhaustive des méthodes d'inversion sismique classiques (L1, L2, L1-L2) et des approches AI/ML récentes pour ce problème.
5. Formuler rigoureusement et implémenter la régularisation mixte L1-L2 (Elastic Net) via les algorithmes ISTA, FISTA et ADMM, avec estimation automatique des hyperparamètres par L-curve.
6. Concevoir et entraîner un réseau de neurones convolutif de type U-Net adapté à l'inversion des traces sismiques 1D vers les profils d'impédance acoustique.
7. Implémenter les Physics-Informed Neural Networks (PINNs) avec la contrainte différentiable de l'équation d'onde de Helmholtz, et le module SINDy pour la découverte automatique de lois physiques.
8. Développer le programme intégré QuantX Pro (v3.0) en Python/PyQt6, avec interface graphique professionnelle et support GPU/JAX.
9. Valider rigoureusement l'ensemble du pipeline sur le modèle synthétique Marmousi-2 et l'appliquer à des données sismiques réelles du bassin de Berkine (Algérie).

10. Comparer quantitativement toutes les méthodes implémentées (R^2 , RMSE, MAE, SNR, temps de calcul) et analyser les gains apportés par les approches hybrides.

1.5 Méthodologie Générale

1.5.1 Modélisation Directe (Forward Modeling)

La modélisation directe constitue la première étape de la méthodologie. Elle génère les données sismiques synthétiques à partir de modèles géologiques de référence (Marmousi-2) via le modèle de convolution : $d(t) = w(t) * r(t) + n(t)$. Cette étape produit les paires (données sismiques, propriétés de référence) nécessaires pour évaluer objectivement les méthodes d'inversion. Les données sont générées à différents niveaux de bruit (SNR = 30, 20, 15, 10 dB) pour tester la robustesse des méthodes.

1.5.2 Implémentation des Méthodes d'Inversion

Les méthodes sont implémentées par ordre de sophistication croissante dans le programme QuantX Pro. Les méthodes classiques (Tikhonov L2, CGLS, ISTA L1, FISTA L1-L2) sont implémentées en Python/NumPy avec optimisation par opérateurs creux (scipy.sparse). Les méthodes ML (CNN U-Net, PINNs) sont implémentées en PyTorch avec support CUDA. Les accélérations GPU (GPUInversionEngine) et JAX (JAXInversionEngine) sont disponibles pour les grands volumes de données.

1.5.3 Validation et Analyse

La validation s'appuie sur des métriques quantitatives standardisées (R^2 , RMSE, MAE, SNR amélioré) calculées sur des données non vues lors de l'entraînement (validation croisée). La comparaison avec les méthodes conventionnelles établit les gains apportés par les approches hybrides. L'analyse d'incertitude (Monte Carlo Dropout) et l'interprétabilité (valeurs SHAP) complètent l'évaluation.

1.6 Organisation du Mémoire

Ce mémoire est organisé en sept chapitres structurés selon une logique scientifique allant des fondements théoriques vers les applications pratiques. Le Chapitre 2 établit les bases théoriques de la sismique réflexion et du problème inverse. Le Chapitre 3 présente les méthodes et algorithmes d'inversion, des classiques aux approches AI. Le Chapitre 4 décrit la

conception et le développement du programme QuantX Pro. Le Chapitre 5 présente les résultats des applications synthétiques et réelles. Le Chapitre 6 analyse et discute ces résultats en profondeur. Le Chapitre 7 synthétise les contributions et ouvre les perspectives de recherche.

CHAPITRE 2 : Bases Théoriques de l'Inversion Sismique

Ce chapitre établit l'ensemble des fondements théoriques nécessaires à la compréhension et à la mise en œuvre des méthodes d'inversion sismique développées dans ce mémoire. Il couvre la physique de la propagation des ondes élastiques, la modélisation sismique directe, la théorie mathématique du problème inverse et les concepts de résolution verticale. Chaque notion est présentée avec sa dérivation mathématique complète et son interprétation physique et géophysique.

2.1 Propagation des Ondes Sismiques dans les Milieux Élastiques

2.1.1 Équation d'Onde Générale

Dans un milieu continu élastique linéaire isotrope homogène, le champ de déplacement $u(x,t)$ obéit à l'équation d'onde de Navier-Cauchy, dérivée de la loi de Newton et de la loi de Hooke généralisée :

$$[2.1] \quad (\lambda + \mu) \nabla(\nabla \cdot u) + \mu \nabla^2 u = \rho \frac{\partial^2 u}{\partial t^2}$$

où λ et μ sont les coefficients de Lamé [Pa], ρ la densité du milieu [kg/m^3], et ∇ l'opérateur nabla. En décomposant le champ de déplacement en une partie irrotationnelle (ϕ , potentiel scalaire) et une partie solénoïdale (ψ , potentiel vecteur) selon la décomposition de Helmholtz : $u = \nabla \phi + \nabla \times \psi$, l'équation de Navier-Cauchy se sépare en deux équations d'onde indépendantes, correspondant respectivement aux ondes P et S.




Figure 2.1 : Propagation des ondes

2.1.1.1 Ondes P (Compression)

L'équation d'onde pour le potentiel scalaire φ (associé aux ondes P) est :

$$[2.2] \quad \frac{\partial^2 \varphi}{\partial t^2} = V_P^2 \nabla^2 \varphi$$

avec la vitesse des ondes P définie par :

$$[2.3] \quad V_P = \sqrt{\frac{\lambda + 2\mu}{\rho}} = \sqrt{\frac{K + \frac{4G}{3}}{\rho}}$$

où $K = \lambda + 2\mu/3$ est le module d'incompressibilité [Pa] et $G = \mu$ le module de cisaillement [Pa]. Les ondes P induisent un mouvement des particules parallèle à la direction de propagation (compression-dilatation alternées). Elles se propagent dans tous les milieux, solides, liquides et gaz, et sont les premières à arriver sur les sismogrammes (d'où le nom «ondes primaires» ou ondes P).

2.1.1.2 Ondes S (Cisaillement)

L'équation d'onde pour le potentiel vecteur ψ (associé aux ondes S) est :

$$[2.4] \quad \frac{\partial^2 \psi}{\partial t^2} = V_S^2 \nabla^2 \psi$$

avec la vitesse des ondes S :

$$[2.5] \quad V_S = \sqrt{\frac{\mu}{\rho}} = \sqrt{\frac{G}{\rho}}$$

Les ondes S induisent un mouvement des particules perpendiculaire à la direction de propagation. Elles ne se propagent que dans les solides ($G = 0$ dans les fluides $\rightarrow V_S = 0$) et arrivent après les ondes P sur les sismogrammes (ondes secondaires). Le rapport V_P/V_S est une mesure directe du rapport $(K + 4G/3)/G$ et constitue un discriminateur puissant des lithologies et des fluides saturants.

2.1.2 Tableau des Propriétés Élastiques par Faciès Géologique

Le Tableau 2.1 présente les valeurs typiques de V_P , V_S , densité ρ et impédance acoustique $IA = V_P \times \rho$ pour les principaux faciès géologiques d'intérêt pétrolier. Ces valeurs constituent les données de référence pour l'interprétation des résultats d'inversion.

Tableau 2.1 : Valeurs typiques d'impédance acoustique par faciès lithologique

Faciès Géologique	VP (m/s)	VS (m/s)	rho (g/cm ³)	IA (g/cm ³ ·m/s)	VP/VS
Eau (surface)	1 480–1 530	0	1.00	1 480–1 530	,
Sables non consolidés	1 500–2 000	400–600	1.8–2.0	2 700–4 000	3.3–3.5
Grès (faible porosité)	3 500–4 500	2 000–2 800	2.2–2.5	7 700–11 250	1.6–1.7
Grès saturé eau	2 800–3 800	1 800–2 500	2.1–2.4	5 880–9 120	1.5–1.6
Grès saturé gaz	2 200–3 000	1 800–2 500	2.0–2.3	4 400–6 900	1.2–1.3
Calcaire	4 500–6 500	2 500–3 500	2.4–2.8	10 800–18 200	1.7–2.0
Dolomie	5 500–7 000	3 000–4 000	2.6–2.9	14 300–20 300	1.7–1.8
Argile compactée	2 000–3 500	800–1 500	2.1–2.4	4 200–8 400	2.2–2.6
Sel (halite)	4 400–4 600	2 500–2 600	2.1–2.2	9 240–10 120	1.75–1.77
Granite	5 800–6 500	3 200–3 800	2.6–2.8	15 080–18 200	1.7–1.8

2.1.3 Lois de Réflexion et de Transmission , Équations de Zoeppritz

2.1.3.1 Conditions aux Limites à une Interface

Lorsqu'une onde sismique rencontre une interface entre deux milieux élastiques d'impédances différentes, les conditions de continuité mécanique imposent que le vecteur déplacement u et le vecteur contrainte $T = \sigma \cdot n$ (où n est la normale à l'interface) soient continus à travers l'interface. Ces quatre conditions (2 composantes de déplacement + 2 composantes de contrainte) constituent le système des équations de Zoeppritz (1919), qui gouverne la partition de l'énergie entre ondes réfléchies et transmises.




Figure 2.2 : Décomposition de l'énergie aux interfaces , ondes réfléchies et transmises

À l'interface, une onde P incidente génère quatre ondes : une onde P réfléchie (amplitude R_{pp}), une onde S réfléchie (amplitude R_{ps}), une onde P transmise (amplitude T_{pp}) et une onde S transmise (amplitude T_{ps}). Les coefficients R_{PP} , R_{PS} , T_{PP} , T_{PS} sont les solutions du système de Zoeppritz, fonction des contrastes de V_P , V_S et ρ et de l'angle d'incidence θ .

2.1.3.2 Coefficient de Réflexion à Incidence Normale

Pour une incidence strictement normale ($\theta = 0$), les ondes P et S se découplent. Il n'y a pas de conversion de mode ($R_{PS} = T_{PS} = 0$). Le coefficient de réflexion de l'onde P se réduit à l'expression de Knott :

$$[2.6] \quad R_0 = R_{PP}(\theta = 0) = \frac{Z_2 - Z_1}{Z_2 + Z_1} = \frac{\rho_2 V_{P2} - \rho_1 V_{P1}}{\rho_2 V_{P2} + \rho_1 V_{P1}}$$

Le coefficient de transmission est : $T_{PP}(\theta=0) = 2 \cdot IA_1 / (IA_1 + IA_2)$. La conservation de l'énergie est vérifiée : $|R_{PP}|^2 + (IA_1/IA_2) \cdot |T_{PP}|^2 = 1$. Pour des contrastes faibles d'impédance ($|\Delta IA/IA| \ll 1$), le coefficient de réflexion peut être linéarisé : $R_0 \approx \Delta IA / (2 \cdot IA) = (1/2) \cdot \Delta \ln(IA)$, ce qui constitue la base de l'inversion bandlimitée.

2.1.3.3 Approximation Linéarisée d'Aki-Richards

Pour des angles d'incidence $\theta < 30-35^\circ$ et des contrastes d'impédance modérés ($\Delta V_P/V_P < 20\%$, $\Delta \rho/\rho < 10\%$), l'approximation linéarisée d'Aki & Richards (1980) fournit une expression analytique explicite du coefficient de réflexion PP en fonction des contrastes relatifs des paramètres élastiques :

$$[2.7] \quad R(\theta) \approx a(\theta) \frac{\Delta V_P}{V_P} + b(\theta) \frac{\Delta V_S}{V_S} + c(\theta) \frac{\Delta \rho}{\rho}$$

où les coefficients a , b , c sont des fonctions de l'angle θ et des vitesses moyennes : $a = (1/2)(1 + \tan^2\theta)$, $b = -4(V_S/V_P)^2 \sin^2\theta$, $c = (1/2)(1 - 4(V_S/V_P)^2 \sin^2\theta)$. L'approximation à deux termes de Shuey (1985), valide pour $\theta < 30^\circ$, reformule cette expression sous la forme AVO standard :

$$[2.8] \quad R(\theta) \approx R_0 + G \sin^2\theta$$

où R_0 est l'intercept AVO (réflectivité en incidence normale) et $G = (\Delta VP/VP)/2 - 2(VS/VP)^2(\Delta VS/VS + \Delta \rho/\rho)$ est le gradient AVO. L'intercept R_0 est sensible à l'impédance acoustique, tandis que le gradient G contient de l'information sur V_P/V_S et donc sur les fluides saturants. Cette formulation est la base de l'analyse AVO en exploration pétrolière.

2.1.4 Impédance Acoustique , Définition, Mesure et Interprétation

L'impédance acoustique IA est la grandeur physique centrale de l'inversion sismique post-stack. Elle est définie comme le produit scalaire de la vitesse des ondes P par la densité du milieu :

$$[2.9] \quad Z \equiv \rho V_P \quad [\text{SI : kg m}^{-2} \text{ s}^{-1} = \text{Rayl}]$$

L'unité pratique en exploration pétrolière est le $\text{g/cm}^3 \cdot \text{m/s}$ ($= 1000 \text{ Rayl} = 10^3 \text{ kg} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$). L'impédance acoustique est directement mesurable aux puits de forage par combinaison des diagraphies :

- Diagraphie sonique DT (Delta Time) : mesure le temps de transit en $\mu\text{s/m} \rightarrow V_P = 10^6/\text{DT} [\text{m/s}]$
- Diagraphie de densité RHOB : mesure la densité bulk en $\text{g/cm}^3 \rightarrow \rho [\text{g/cm}^3]$
- Donc $IA = (10^6/\text{DT}) \times \text{RHOB} \quad [\text{g/cm}^3 \cdot \text{m/s}]$

L'interprétation physique de l'impédance acoustique est directe : un milieu à forte IA (roche dense et rapide) est généralement une roche compacte, dure, à faible porosité ; un milieu à faible IA est généralement poreux, saturé de fluides légers (gaz), ou peu compacté. La relation entre IA et la porosité ϕ suit empiriquement la relation de Wyllie modifiée : $V_P = V_f \cdot \phi / (1 - \phi \cdot V_f/V_m) + V_m \cdot (1 - \phi / (1 - \phi \cdot V_f/V_m))$, où V_f et V_m sont les vitesses du fluide et de la matrice.

2.2 Modèle Sismique Direct , Le Modèle Convolutionnel

2.2.1 Formulation du Modèle de Convolution

Le modèle de convolution est le paradigme fondamental de la sismique réflexion. Il repose sur quatre hypothèses physiques simplificatrices dont la validité doit être vérifiée pour chaque jeu de données :

11. Milieu 1D (horizontalement stratifié) : les propriétés du milieu ne varient qu'en profondeur (dans la direction verticale). Cette hypothèse est raisonnable pour les milieux sédimentaires sub-tabulaires mais invalide en présence de failles, de structures diapiriques ou de pendages prononcés ($> 15-20^\circ$).
12. Ondelette stationnaire : l'ondelette sismique $w(t)$ est invariante en profondeur (ne change pas de forme au cours de la propagation). En réalité, l'absorption anélastique de la Terre atténue préférentiellement les hautes fréquences avec la profondeur (filtre Q), rendant l'ondelette non stationnaire. Des corrections Q peuvent être appliquées pour atténuer cet effet.
13. Incidence normale : les rayons sismiques sont perpendiculaires aux interfaces géologiques. Cette hypothèse simplifie les coefficients de réflexion à la formule de Knott mais ne permet pas de modéliser les effets AVO.
14. Réflexions primaires uniquement : les multiples (réflexions répétées entre plusieurs interfaces) sont supposés absents ou négligeables. En réalité, les multiples peuvent contaminer significativement les données, notamment en milieu marin.

Sous ces quatre hypothèses, la trace sismique observée $s(t)$ est modélisée par la convolution :

$$[2.10] \quad s(t) = w(t) * r(t) + n(t) = \int_{-\infty}^{\infty} w(\tau) r(t - \tau) d\tau + n(t)$$

où $w(t)$ est l'ondelette sismique [normalisée], $r(t)$ la série de réflectivité (somme pondérée de fonctions de Dirac aux interfaces), et $n(t)$ le bruit additif. En notation matricielle discrète (N échantillons temporels) :

$$[2.11] \quad s = Wr + n = Gr + n$$

où $W = G$ est la matrice de convolution par l'ondelette, de structure de Toeplitz (chaque diagonale est constante et égale à un coefficient de l'ondelette). W est une matrice $N \times N$ à bande de largeur $2 \cdot L + 1$, L étant la demi-longueur de l'ondelette en échantillons.

2.2.2 Propriétés Spectrales du Modèle de Convolution

Dans le domaine fréquentiel, la convolution temporelle devient une multiplication complexe point à point :

$$[2.12] \quad S(f) = W(f) R(f) + N(f)$$

Cette propriété a plusieurs conséquences fondamentales pour l'inversion sismique :

- **Bande de fréquences limitée** : le spectre $W(f)$ de l'ondelette est nul (ou négligeable) en dehors d'une bande de fréquences $[f_{\min}, f_{\max}]$ (typiquement 5-80 Hz). La trace sismique ne contient donc aucune information sur $R(f)$ en dehors de cette bande, rendant le problème d'inversion sous-déterminé dans les domaines basses et hautes fréquences.
- **Composantes basses fréquences manquantes** : les fréquences $f < 5-8$ Hz (tendance générale d'impédance, structure macroscopique du modèle) sont absentes des données sismiques. Elles doivent être apportées par l'information de puits (diagraphies) ou des modèles géologiques a priori. C'est la raison pour laquelle l'inversion sismique sans puits de calage ne peut pas produire de modèle absolu d'impédance.
- **Composantes hautes fréquences manquantes** : les fréquences $f > 80-100$ Hz (détails sub-métriques) sont absentes des données sismiques à cause de l'absorption du milieu. Les méthodes CNN peuvent partiellement reconstruire ces hautes fréquences par super-résolution en exploitant les corrélations statistiques entre fréquences moyennes et hautes fréquences apprises sur les données de puits.

2.2.3 Types d'Ondelettes Sismiques

L'ondelette sismique est un paramètre critique de l'inversion. Sa qualité conditionne directement la précision des résultats. Trois familles d'ondelettes sont utilisées en pratique :

Tableau 2.2 : Propriétés des ondelettes sismiques couramment utilisées

Ondelette	Expression / Propriété	Bande passante	Usage
Ricker (chapeau mexicain)	$w(t) = (1 - 2\pi^2 f_0^2 t^2) \cdot \exp(-\pi^2 f_0^2 t^2)$	Gaussienne centrée sur f_0	Données synthétiques, modélisation
Ormsby	Trapèze dans l'espace fréquentiel, défini par $[f_1, f_2, f_3, f_4]$	Plage f_2-f_3 , atténuation f_1-f_2 et f_3-f_4	Données synthétiques réalistes
Statistique (Wiener)	Estimée par autocorrélation de la trace (phase minimale)	Adaptée aux données réelles	Inversion de données réelles sans puits
Déterministe (Wiener-	Estimée par déconvolution trace-puits (moindres carrés)	Précise si diagraphie de	Inversion de données réelles avec puits

Levinson)		qualité	
-----------	--	---------	--

Dans QuantX Pro, l'estimation de l'ondelette utilise l'algorithme de Levinson-Durbin ($O(N^2)$) pour la décomposition de Wiener, avec une fenêtre temporelle sélectionnée automatiquement autour de l'intervalle de calage puits-sismique.

2.2.4 Bruit Sismique , Modèle et Impact

Le terme de bruit $n(t)$ englobe toutes les contributions qui ne sont pas modélisées par le terme convolutionnel : bruit ambiant de fond (bruit tellurique, microtremors), ondes de surface résiduelles (Rayleigh, Love), réflexions multiples, diffractions sur des obstacles géologiques, et erreurs de modélisation (non-stationnarité de l'ondelette, effets 3D). Le bruit gaussien additif blanc (AWGN) est le modèle le plus simple :

$$[2.13] \quad n(t) \sim \mathcal{N}(0, \sigma_n^2), \quad \text{SNR} = 10 \log_{10} \left(\frac{\|W r_z\|^2}{\|n_z\|^2} \right) \quad [\text{dB}]$$

Le SNR est la mesure standard de la qualité des données sismiques. En termes d'impact sur l'inversion : à $\text{SNR} = 30 \text{ dB}$, le bruit représente $\sim 3\%$ de l'amplitude du signal, et les méthodes classiques (Tikhonov L2) fonctionnent correctement. À $\text{SNR} = 20 \text{ dB}$ ($\sim 10\%$ de bruit), la régularisation L1-L2 FISTA est nécessaire pour maintenir la stabilité. À $\text{SNR} = 10 \text{ dB}$ ($\sim 30\%$ de bruit), les méthodes PINNs avec contrainte physique offrent la meilleure robustesse.

2.3 Série de Réflectivité et Propriétés du Sous-sol

2.3.1 Relation Réflectivité–Impédance , Dérivation Complète

La série de réflectivité est la représentation temporelle discrète des contrastes d'impédance acoustique aux interfaces géologiques. Pour un milieu multicouche contenant N couches d'impédances $IA(1), IA(2), \dots, IA(N)$, le coefficient de réflexion à l'interface entre la couche k et la couche $k+1$ est :

$$[2.14] \quad r(k) = \frac{Z(k+1) - Z(k)}{Z(k+1) + Z(k)}, \quad r(k) \in (-1, +1)$$

Pour les faibles contrastes d'impédance , hypothèse généralement vérifiée pour les milieux sédimentaires ($|r| < 0.3$ dans la majorité des cas) , cette expression peut être approximée par :

$$[2.15] \quad r(k) \approx \frac{\Delta Z(k)}{2 Z(k)} \approx \frac{\Delta t}{2} \cdot \frac{d(\ln Z(t))}{dt}$$

Cette approximation conduit à la relation fondamentale de l'inversion bandlimitée : intégrer la trace sismique (dans la bande de fréquences) est approximativement équivalent à reconstruire $\ln(IA(t))$, et donc $IA(t)$. La reconstruction exacte de $IA(t)$ depuis $r(k)$ est donnée par la récurrence forward :

$$[2.16] \quad Z(k+1) = Z(k) \frac{1+r(k)}{1-r(k)}, \quad Z(1) = Z_0$$

Cette récurrence démontre que la valeur initiale IA_0 est indispensable à la reconstruction absolue de l'impédance. Sans IA_0 (fourni par les diagaphies de puits ou le modèle de vitesse), seul le modèle relatif d'impédance (variations autour de la valeur de référence) peut être estimé par inversion sismique.

2.3.2 Interfaces Géologiques et Distribution Statistique de la Réflectivité

La série de réflectivité $r(k)$ est la représentation sismique de la géologie du sous-sol. D'un point de vue statistique, la réflectivité sismique suit une distribution Super-Gaussienne (kurtosis élevé), avec la grande majorité des coefficients proches de zéro (milieu géologiquement homogène) et quelques pics isolés de grande amplitude (interfaces majeures). Cette propriété de sparsité est la justification géophysique fondamentale de la régularisation L1 en inversion sismique.

Les interfaces géologiques majeures correspondent aux changements lithologiques significatifs (contact grès-argile, contact carbonate évaporite), aux contacts fluides (contact eau-huile, contact huile-gaz), et aux surfaces de discordance (érosion, transgression). Ces interfaces se traduisent par des coefficients de réflexion $|r| > 0.05-0.10$ et constituent les cibles de l'inversion parcimonieuse. Les variations graduelles d'impédance dans les milieux continus (gradient de compaction, variation de porosité) produisent une réflectivité faible et continue, mieux capturée par la régularisation L2.

2.3.3 Relation Péetrophysique Impédance–Porosité

L'impédance acoustique est directement corrélée à la porosité ϕ via des relations pétrophysiques empiriques. La relation la plus simple est la loi de Wyllie (time-average equation) :

$$[2.17] \quad \frac{I}{V_p} = \frac{\phi}{V_f} + \frac{1-\phi}{V_m}$$

où V_f est la vitesse du fluide saturant (eau ≈ 1500 m/s, huile ≈ 1300 m/s, gaz ≈ 500 - 600 m/s) et V_m la vitesse de la matrice minérale (quartz ≈ 5850 m/s, calcite ≈ 6640 m/s, argile ≈ 3000 - 4000 m/s). La substitution de fluides de Gassmann (1951) permet de calculer l'effet d'un changement de fluide saturant sur VP et VS, en conservant le cadre des milieux poreux saturés :

$$[2.18 \text{ Gassmann}] \quad K_{sat} = K_{sec} + (1 - K_{sec}/K_m)^2 / [\phi/K_f + (1-\phi)/K_m - K_{sec}/K_m^2]$$

où K_{sec} est le module d'incompressibilité du cadre sec (dry frame), K_m le module de la matrice minérale, K_f le module du fluide, et K_{sat} le module du milieu saturé. Ces relations pétrophysiques constituent des contraintes a priori précieuses pour l'inversion sismique.

2.4 Le Problème Inverse en Géophysique

2.4.1 Définition Mathématique et Classification

Le problème inverse sismique s'inscrit dans le cadre général de la théorie des problèmes inverses. La relation entre le modèle m (propriétés du sous-sol) et les données d (traces sismiques) est décrite par l'opérateur de modélisation directe G :

$$[2.19] \quad d = G(m) + \varepsilon, \quad G: \mathcal{M} \rightarrow D$$

où $\mathcal{M}$ est l'espace des modèles (fonctions d'impédance sur $[0, T]$), D est l'espace des données (traces sismiques sur $[0, T]$), et ε est le vecteur des erreurs (bruit + erreurs de modélisation). Dans le cadre du modèle convolutionnel linéarisé, G est l'opérateur de convolution par l'ondelette, soit en notation matricielle discrète :

$$[2.20] \quad d = Gm + \varepsilon, \quad G \in \mathbb{R}^{M \times N}, \quad m \in \mathbb{R}^N, \quad d \in \mathbb{R}^M$$

Le problème est dit sous-déterminé si $M < N$ (plus d'inconnues que d'équations, cas typique de l'inversion sismique à cause de la bande de fréquences limitée), surdéterminé si

$M > N$, et carré si $M = N$. En inversion sismique, $M < N$ car la bande limitée de l'ondelette rend les fréquences hors bande non observables, créant un déficit effectif d'équations indépendantes.

2.4.2 Non-unicité et Espace Nul de l'Opérateur

La non-unicité du problème inverse est liée à l'existence du noyau (null space) de l'opérateur G . Le noyau de G est défini par $\text{Ker}(G) = \{m \in \mathcal{M} : G \cdot m = 0\}$. Tout élément $m_0 + v$ avec $v \in \text{Ker}(G)$ produit exactement les mêmes données que m_0 : $G \cdot (m_0 + v) = G \cdot m_0 + G \cdot v = G \cdot m_0$. Pour l'opérateur de convolution sismique, le noyau contient toutes les variations d'impédance qui n'affectent pas les données dans la bande de fréquences disponible, ce sont précisément les composantes basses et hautes fréquences de r .

La décomposition en valeurs singulières (SVD) de $G = U \cdot \Sigma \cdot V^T$ permet de visualiser et de quantifier ce problème. G a un numéro de condition $\kappa(G) = \sigma_{\max}/\sigma_{\min} \gg 1$ en présence de bruit. La pseudo-inverse de Moore-Penrose $G^\dagger = V \cdot \Sigma^\dagger \cdot U^T$ amplifie les composantes du vecteur données dans les directions singulières à faibles valeurs propres $\sigma_i \approx 0$, produisant une solution instable $m^\dagger = G^\dagger d$.

2.4.3 Régularisation Bayésienne, Cadre Général

La régularisation consiste à remplacer le problème mal posé par un problème bien posé approché en introduisant de l'information a priori. Dans le cadre bayésien, on spécifie une distribution a priori $p(m)$ sur le modèle (qui encode nos connaissances géologiques avant les données) et une distribution de vraisemblance $p(d|m)$ (qui modélise la relation données-modèle incluant le bruit). La solution MAP (Maximum A Posteriori) maximise la distribution postérieure $p(m|d) \propto p(d|m) \cdot p(m)$:

$$[2.21] \quad m_{\text{MAP}} = \arg \max_m [\log p(d|m) + \log p(m)]$$

Pour une distribution de vraisemblance gaussienne $p(d|m) \propto \exp(-\|d - Gm\|^2 / (2\sigma_n^2))$ et une distribution a priori gaussienne $p(m) \propto \exp(-\|L(m - m_0)\|^2 / (2\sigma_m^2))$, le MAP se réduit à la minimisation de la fonctionnelle de Tikhonov généralisée :

$$[2.22] \quad m_{\text{MAP}} = \arg \min_m \left\{ \frac{\|d - Gm\|_2^2}{\sigma_n^2} + \frac{\lambda}{\sigma_m^2} \|L(m - m_0)\|_2^2 \right\}$$

où $\lambda = \sigma_n^2 / \sigma_m^2$ est le paramètre de régularisation qui contrôle le rapport signal/contrainte a priori. Pour une a priori de Laplace $p(m) \propto \exp(-\lambda \cdot \|m\|_1)$, le MAP conduit

à la minimisation L1 (inversion sparse). La richesse de la théorie bayésienne réside dans sa capacité à spécifier toute distribution a priori géologiquement motivée.

2.4.4 Sélection du Paramètre de Régularisation λ

La sélection du paramètre λ est l'un des problèmes les plus délicats de l'inversion régularisée. Trois méthodes principales sont disponibles :

2.4.4.1 Méthode de la Courbe L (L-curve)

La L-curve (Hansen & O'Leary, 1993) trace la norme de la solution $\|m\|_2$ (ou $\|Lm\|_2$) en fonction de la norme du résidu $\|d - Gm\|_2$ sur une échelle log-log, pour une gamme de valeurs de λ . La courbe a typiquement la forme d'un L : pour les petites valeurs de λ , le résidu est faible mais la norme de la solution est grande (solution oscillante, surapprentissage) ; pour les grandes valeurs de λ , la norme est faible mais le résidu est grand (solution trop lisse, sous-ajustement). Le point optimal est le coin du L, correspondant au meilleur compromis biais-variance. QuantX Pro localise ce coin par l'algorithme de détection de la courbure maximale de la courbe.

2.4.4.2 Validation Croisée Généralisée (GCV)

La GCV (Golub et al., 1979) sélectionne λ en minimisant le critère : $GCV(\lambda) = (1/M) \cdot \|d - G \cdot m_{\lambda}\|^2 / (1 - \text{tr}(G \cdot G_{\lambda}^{\dagger})/M)^2$, où $G_{\lambda}^{\dagger}$ est l'inverse régularisé. Elle ne nécessite pas d'estimation du niveau de bruit σ_n et est asymptotiquement optimale pour les problèmes gaussiens.

2.4.4.3 Principe de Discordance de Morozov

Ce principe sélectionne λ comme la plus petite valeur telle que $\|d - G \cdot m_{\lambda}\|_2 = \|e\|_2 \approx \sigma_n \cdot \sqrt{M}$, c'est-à-dire que le résidu de l'inversion est de l'ordre du niveau de bruit. Il nécessite une estimation fiable de σ_n .

2.5 Types d'Inversion Sismique

2.5.1 Inversion Post-Stack

L'inversion post-stack exploite les données sismiques après sommation (stacking) des traces à différents offsets (distances source-récepteur) en une seule trace représentant le comportement moyen de la réflectivité. Le stack améliore le SNR par un facteur proportionnel à $\sqrt{N_{\text{fold}}}$ (où N_{fold} est la multiplicité de couverture, typiquement 60-240 en exploration 3D moderne), mais détruit l'information sur la variation des amplitudes avec

l'offset (AVO). L'inversion post-stack estime exclusivement l'impédance acoustique $IA = V_P \times \rho$, sans pouvoir séparer les contributions de V_P et de ρ .

2.5.2 Inversion Pré-Stack (AVO)

L'inversion pré-stack (ou inversion AVO) travaille sur les données non sommées (gathers CMP, Common Mid-Point), en modélisant explicitement la variation des amplitudes avec l'angle d'incidence. L'inversion simultanée (Simultaneous AVO Inversion, Fatti et al., 1994) estime conjointement V_P , V_S et ρ en minimisant :

$$[2.23] \quad J(V_P, V_S, \rho) = \sum_{\theta} \|s_{\text{obs}}(\theta) - G(\theta) r(V_P, V_S, \rho)\|_2^2$$

où $r(V_P, V_S, \rho)$ est la réflectivité calculée par l'approximation d'Aki-Richards pour l'angle θ . L'inversion simultanée produit trois volumes élastiques (V_P , V_S , ρ) ou leurs combinaisons ($IA = V_P \times \rho$, $IS = V_S \times \rho = SI$, V_P/V_S), permettant la discrimination fluides-lithologie et le calcul des attributs pétrophysiques dérivés (porosité, saturation, module de Poisson).

2.5.3 Inversion Déterministe vs Stochastique

Tableau 2.3 : Comparaison inversion déterministe vs stochastique

Critère	Inversion Déterministe	Inversion Stochastique
Nombre de solutions	Une (optimale)	Ensemble de réalisations équiprobables
Incertitude quantifiée	Non (solution unique)	Oui (variance de l'ensemble)
Contraintes géostatistiques	Limitées	Intégrées naturellement (variogramme)
Coût computationnel	Faible à modéré	100 à 1000× plus élevé
Résolution latérale	Limitée par les données	Améliorée par la simulation
Usage industriel	Caractérisation rapide	Évaluation du risque, volumétrie P10/P50/P90
Exemples de méthodes	Tikhonov, L1, CNN, PINNs	Sequential Gaussian Simulation, MCMC

2.6 Concepts de Résolution Verticale

2.6.1 Critère de Rayleigh et Épaisseur de Tuning

La résolution verticale d'une section sismique est la capacité à distinguer deux réflecteurs séparés par une couche mince. Le critère de Rayleigh définit la limite de résolution comme le quart de la longueur d'onde dominante $\lambda = V/f_0$:

$$[2.24] \quad e_{\min} = \frac{\lambda}{4} = \frac{V_P}{4 f_0}$$

Pour $V = 2500$ m/s et $f_0 = 40$ Hz : $e_{\min} = 2500/(4 \times 40) = 15.6$ m. À l'épaisseur de tuning $e_{\text{tuning}} = \lambda/4$, les réflexions du toit et du mur d'une couche s'additionnent constructivement, amplifiant l'amplitude d'un facteur 2 par rapport à un réflecteur isolé. En dessous de e_{tuning} , les deux réflexions ne peuvent plus être séparées en temps, mais l'amplitude crête-à-crête peut encore être utilisée pour estimer l'épaisseur (critère de Widess, 1973).

2.6.2 Super-Résolution par CNN et Limitations Théoriques

Les méthodes CNN permettent d'améliorer la résolution verticale au-delà de la limite de Rayleigh conventionnelle, en reconstruisant les composantes haute fréquence manquantes. Cette super-résolution est possible car les CNN apprennent les corrélations statistiques entre les fréquences sismiques disponibles (5-80 Hz) et les fréquences géologiques manquantes (80-200 Hz) à partir des données de puits d'entraînement. Cependant, la super-résolution obtenue n'est pas inconditionnelle : elle est fiable uniquement dans les domaines géologiques proches des données d'entraînement, et l'incertitude augmente significativement pour les configurations géologiques non vues pendant l'entraînement.

La limite théorique de la super-résolution est donnée par le critère de Shannon-Nyquist étendu au cadre bayésien : l'amélioration de résolution possible est bornée par le rapport entre la connaissance a priori (encodée dans les données de puits et la statistique géologique) et l'incertitude sur les composantes haute fréquence. En pratique, le CNN U-Net de QuantX Pro améliore la résolution effective d'un facteur 1.3 à 1.8 par rapport à la limite de Rayleigh, selon la qualité et la densité des données de puits disponibles.

CHAPITRE 3 : Méthodes et Algorithmes d'Inversion Sismique

Ce chapitre présente en détail toutes les méthodes et algorithmes d'inversion sismique implémentés dans QuantX Pro, depuis les méthodes classiques de régularisation jusqu'aux architectures d'Intelligence Artificielle les plus avancées. Pour chaque méthode, la formulation mathématique complète, les propriétés de convergence, les hyperparamètres et les relations avec le code source (QX.py) sont présentés.

3.1 Inversion Classique

3.1.1 Inversion L2 , Moindres Carrés Régularisés (Tikhonov)

3.1.1.1 Formulation et Solution Analytique

La régularisation de Tikhonov (1963) est la méthode de régularisation la plus fondamentale et la plus utilisée. Elle consiste à ajouter un terme quadratique de pénalité à la fonctionnelle des moindres carrés :

$$[3.1] \quad J_{L2}(m) = \|d - Gm\|_2^2 + \lambda \|Lm\|_2^2$$

En dérivant par rapport à m et en égalisant à zéro (condition du premier ordre pour le minimum) :

$$[3.2] \quad \nabla_m J_{L2} = -2G^T(d - Gm) + 2\lambda L^T L m = 0$$

$$[3.3 \text{ Équations normales de Tikhonov}] \quad (G^T G + \lambda L^T L) \cdot m^* = G^T \cdot d$$

$$[3.4] \quad m^* = (G^T G + \lambda L^T L)^{-1} G^T d$$

Cette solution analytique existe et est unique pour tout $\lambda > 0$ (la matrice $G^T G + \lambda L^T L$ est définie positive). Pour $L = I$: régularisation d'ordre 0 (pénalise la norme de m). Pour $L = D_1$ (matrice de différences premières) : régularisation d'ordre 1 (pénalise le gradient). Pour $L = D_2 = D_1^T D_1$: régularisation d'ordre 2 (pénalise la courbure, solutions très lisses).

3.1.1.2 Implémentation par Gradient Conjugué Préconditionné (PCG)

Pour les données sismiques 2D/3D, N peut atteindre plusieurs millions de paramètres. La résolution directe de $(G^T G + \lambda L^T L) \cdot m^* = G^T d$ par inversion matricielle est computationnellement prohibitive ($O(N^3)$ opérations). La méthode du gradient conjugué préconditionné (PCG) résout ce système linéaire de manière itérative en exploitant la structure

creuse de $G^T G$ (matrice de convolution par FFT) et $L^T L$ (matrice des différences finies creuse), avec une complexité de $O(K \cdot N \cdot \log N)$ pour K itérations.

```
Extrait QX.py , Tikhonov PCG
# Résolution L2-Tikhonov par PCG (QX.py lignes 829-880)
from scipy.sparse.linalg import cg # Gradient Conjugué
from scipy.sparse.linalg import LinearOperator

def _solve_tikhonov(self, d, G, D, lambda_reg):
    n = len(d)
    # Opérateur implicite A = G^T G + lambda L^T L (sans former A explicitement)
    def matvec_A(m):
        GtGm = G.rmatvec(G.matvec(m)) # G^T(G·m)
        LtLm = D.rmatvec(D.matvec(m)) # D^T(D·m)
        return GtGm + lambda_reg * LtLm
    A = LinearOperator((n, n), matvec=matvec_A, dtype=np.float64)
    b = G.rmatvec(d) # G^T·d (second membre)
    m_star, info = cg(A, b, tol=1e-8, maxiter=500) # PCG
    return m_star
```

3.1.2 Inversion Sparse , Régularisation L1 (Lasso)

3.1.2.1 Justification Géophysique et Formulation

La réflectivité sismique est géophysiquement parcimonieuse : la grande majorité des couches géologiques présentent de faibles contrastes d'impédance ($r \approx 0$), et seules quelques interfaces majeures produisent des réflecteurs significatifs. La distribution de la réflectivité suit une loi de Laplace (queue lourde, kurtosis > 3) plutôt qu'une loi gaussienne, ce qui justifie l'utilisation de la norme L1 comme régulariseur :

$$[3.5] \quad J_{L1}(m) = \|d - Gm\|_2^2 + \lambda \|m\|_1 = \|d - Gm\|_2^2 + \lambda \sum_i |m_i|$$

La norme L1 n'est pas différentiable en $m = 0$. Son sous-différentiel est $\partial \|m\|_1 = \text{sgn}(m)$ si $m \neq 0$, $\partial \|m\|_1 \subset [-1, 1]$ si $m = 0$. L'opérateur proximal $\text{prox}_{\{t \cdot \lambda \cdot \|\cdot\|_1\}}(z) = S_{\{t \cdot \lambda\}}(z)$ est l'opérateur de seuillage doux :

$$[3.6, \text{Opérateur de seuillage doux}] \quad S_{\tau}(z)_i = \text{sgn}(z_i) \cdot \max(|z_i| - \tau, 0)$$

Le seuillage doux annule exactement les composantes de z dont la valeur absolue est inférieure au seuil $\tau = t \cdot \lambda$ (sparsité exacte), et translate les autres vers zéro. Contrairement au seuillage dur (hard thresholding, qui mettrait à zéro les composantes $< \tau$ et laisserait les autres inchangées), le seuillage doux est continu, ce qui garantit la convergence des algorithmes itératifs.

3.1.2.2 Algorithme ADMM pour la Régularisation L1

L'algorithme ADMM (Alternating Direction Method of Multipliers, Boyd et al., 2011) est particulièrement adapté à la régularisation L1 pour les grands problèmes. Il introduit une variable auxiliaire $z = m$ et résout le problème augmenté :

$$[3.7] \min_{m,z} \left\{ \|Gm - d\|_2^2 + \lambda \|z\|_1 \right\} \text{ subject to } m = z$$

Le Lagrangien augmenté est $\mathcal{L}_\rho(m,z,u) = \|Gm - d\|_2^2 + \lambda \|z\|_1 + (\rho/2) \|m - z + u\|^2$. ADMM alterne trois mises à jour jusqu'à convergence ($\|m - z\| < \text{epsilon_primal}$ et $\|z^{k+1} - z^k\| \cdot \rho < \text{epsilon_dual}$) :

15. Mise à jour de m (sous-problème L2, résolu par PCG) : $m^{(k+1)} = (G^T G + \rho \cdot I)^{-1} \cdot (G^T d + \rho \cdot (z^k - u^k))$
16. Mise à jour de z (seuillage doux) : $z^{(k+1)} = S_{\{\lambda/\rho\}}(m^{(k+1)} + u^k)$
17. Mise à jour du multiplicateur de Lagrange : $u^{(k+1)} = u^k + m^{(k+1)} - z^{(k+1)}$

ADMM converge linéairement avec un taux dépendant du paramètre pénalité ρ et du conditionnement de $G^T G$. Le paramètre $\rho = \sqrt{(\lambda / \|G^T d\|_\infty)}$ est un choix heuristique courant.

3.2 Régularisation , Propriétés Mathématiques Comparées

Le choix du type de régularisation conditionne fondamentalement la nature et la qualité de la solution obtenue. Le Tableau 3.1 compare les propriétés mathématiques des principales régularisations implémentées dans QuantX Pro.

Tableau 3.1 : Propriétés mathématiques des normes L0, L1, L2 et Elastic Net

Propriété	Tikhonov L2	Sparse L1	Elastic Net L1+L2	Variation Totale
Formule de pénalité	$\lambda \ m\ ^2$	$\lambda \ m\ _1$	$\lambda_1 \ m\ _1 + \lambda_2 \ m\ ^2$	$\lambda \ Dm\ _1$
Différentiabilité	Partout (C^∞)	Non ($m=0$)	Non ($m=0$)	Non ($Dm=0$)
Solutions parcimonieuses	Non	Oui (exactes)	Oui (moins qu'L1)	Non (mais par morceaux)
Préservation discontinuités	Non (lissage)	Oui (pics isolés)	Partielle	Oui (TV = bords nets)
Convexité stricte	Oui ($\lambda > 0$)	Non ($\lambda > 0$)	Oui ($\lambda_2 > 0$)	Non

Unicité de la solution	Oui	Non (en général)	Oui	Non
Algorithme de résolution	PCG / direct	ISTA/FISTA/ADMM	ISTA/FISTA/ADMM	ADMM / primal-dual
Coût calcul / itération	$O(N \log N)$	$O(N \log N)$	$O(N \log N)$	$O(N \log N)$
Adapté au milieu	Gradients continus	Réflecteurs isolés	Mixte (général)	Couches homogènes

3.2.1 Régularisation par Variation Totale (TV)

La régularisation TV (Rudin, Osher & Fatemi, 1992) pénalise la norme L1 du gradient de m :

$$[3.8] \quad TV(m) = \|Dm\|_1 = \sum_i |m(i+1) - m(i)|$$

où D est la matrice des différences premières. La TV combine les avantages de la sparsité (L1) appliquée aux variations : elle favorise les solutions par morceaux constantes (piecewise-constant) avec des transitions nettes entre les plateaux, ce qui correspond exactement au modèle géologique de couches à impédance uniforme séparées par des interfaces nettes. La TV est particulièrement adaptée aux réservoirs gréseux bien délimités (hautes perméabilités, faibles contrastes de porosité intra-couche) et aux milieux carbonatés massifs.

La minimisation TV est résolue par l'algorithme de gradient proximal sur le problème dual de Rockafellar, ou directement par ADMM avec division de variable $z = D \cdot m$. La généralisation isotrope (isotropic TV) en 2D/3D utilise $TV_{2D}(m) = \sum_i \sqrt{[(D_x m)^2 + (D_z m)^2]}$, qui pénalise le gradient total (norme L2 du gradient) plutôt que sa décomposition directionnelle.

3.3 Inversion Mixte L1-L2 , Elastic Net et Algorithmes ISTA/FISTA

3.3.1 Formulation Mathématique Complète

La formulation Elastic Net (Zou & Hastie, 2005) combine les régularisations L1 et L2 en une unique fonctionnelle convexe, qui généralise simultanément le Lasso (L1 seul, $\lambda_2=0$) et la régression Ridge (L2 seul, $\lambda_1=0$) :

$$[3.9] \quad J(r) = \|Gr - d\|_2^2 + \lambda_1 \|r\|_1 + \lambda_2 \left[\delta \|r\|_2^2 + (1-\delta) \|Dr\|_2^2 \right]$$

Les cinq termes de cette fonctionnelle ont une interprétation géophysique précise :

- $\|Gr - d\|_2^2$ (terme d'attache aux données) : mesure l'écart entre les données sismiques synthétiques Gr et les données observées d . Minimiser ce terme assure la fidélité aux données mesurées.
- $\lambda_1 \cdot \|r\|_1$ (Sparsité L1) : favorise une réflectivité parcimonieuse (nombreuses composantes nulles = interfaces géologiques absentes) tout en préservant les réflecteurs forts avec leurs amplitudes réelles.
- $\lambda_2 \cdot \delta \cdot \|r\|_2^2$ (Norme L2 du modèle) : stabilise numériquement la solution et prévient les grandes amplitudes parasites dues au bruit. Correspond à la régularisation Tikhonov d'ordre 0.
- $\lambda_2 \cdot (1-\delta) \cdot \|Dr\|_2^2$ (Énergie du gradient) : favorise des solutions à gradient faible, correspondant à des variations d'impédance progressives entre réflecteurs. Correspond à la régularisation Tikhonov d'ordre 1.
- $\delta \in [0,1]$ (Paramètre de compromis L2) : contrôle le mélange entre régularisation sur le modèle ($\delta=1$, Tikhonov-0) et sur le gradient ($\delta=0$, Tikhonov-1). La valeur $\delta=0.5$ est le compromis par défaut dans QuantX Pro.

La fonctionnelle $J(r)$ est :

- Convexe (mais non strictement convexe si $\lambda_2=0$: le terme L2 est nécessaire pour la convexité stricte et l'unicité de la solution).
- Coercive ($J(r) \rightarrow +\infty$ quand $\|r\| \rightarrow +\infty$ pour $\lambda_1 > 0$ ou $\lambda_2 > 0$), garantissant l'existence d'au moins un minimiseur.
- Non différentiable en $r = 0$ à cause du terme L1, ce qui nécessite des algorithmes de gradient proximal.

3.3.2 Algorithme ISTA , Iterative Soft Thresholding

3.3.2.1 Fondement Théorique , Gradient Proximal

ISTA est un algorithme de gradient proximal (Forward-Backward Splitting) pour résoudre le problème $\min f(r) + g(r)$ où f est la partie lisse (différentiable) et $g = \lambda_1 \|\cdot\|_1$ est la partie non lisse. L'idée est de linéariser f autour du point courant r^k et de résoudre exactement le sous-problème proximal :

$$[3.10] \quad r^{(k+1)} = \text{prox}_{t_l g} (r^k - t \nabla f(r^k)) = S_{t_l} (r^k - t \nabla f(r^k))$$

Le gradient de la partie lisse $f(r) = \|Gr - d\|^2 + \lambda_2 \cdot [\delta \cdot \|r\|^2 + (1-\delta)\|Dr\|^2]$ est :

$$[3.11] \quad \nabla f(r) = 2G^T(Gr - d) + 2\lambda_2[\delta r + (1-\delta)D^TDr]$$

Le pas $t = 1/L$ doit satisfaire $t \leq 1/L$ où L est la constante de Lipschitz du gradient ∇f :

$$[3.12] \quad L = 2 \lambda_{\max}(G^TG) + 2\lambda_2 \max\{\delta, (1-\delta) \lambda_{\max}(D^TD)\}$$

L est estimée par l'algorithme de Power Iteration (20 itérations) qui converge vers la plus grande valeur propre de l'opérateur $G^TG + \lambda_2 \cdot (\delta \cdot I + (1-\delta) \cdot D^TD)$. Cette estimation est réalisée une seule fois avant la boucle principale.

3.3.2.2 Algorithme ISTA Complet

18. Initialisation : $r^0 = m_0$ (solution Tikhonov L2 ou zéro), $L \leftarrow \text{Power_Iteration}(G, D)$, $t \leftarrow 1/L$
19. Pour $k = 0, 1, 2, \dots$ jusqu'à convergence :
20. (a) Calculer le gradient : $g_k = 2G^T(Gr^k - d) + 2\lambda_2[\delta \cdot r^k + (1-\delta)D^TD \cdot r^k]$
21. (b) Pas de gradient : $z^{k+1} = r^k - t \cdot g_k$
22. (c) Seuillage doux (opérateur proximal L1) : $r^{k+1} = S_{t \cdot \lambda_1}(z^{k+1})$
23. (d) Critère d'arrêt : si $\|r^{k+1} - r^k\|_2 / (\|r^k\|_2 + 10^{-10}) < \varepsilon$ ($= 10^{-6}$) $\rightarrow \text{STOP}$

Convergence : $J(r^k) - J(r^*) \leq L \cdot \|r^0 - r^*\|^2 / (2k)$, taux en $O(1/k)$.

3.3.3 Algorithme FISTA , Fast ISTA avec Momentum de Nesterov

3.3.3.1 Principe de l'Accélération par Momentum

FISTA (Beck & Teboulle, 2009) améliore le taux de convergence de ISTA d'un facteur quadratique en introduisant un pas de momentum inspiré de la méthode d'accélération de Nesterov. Au lieu d'effectuer le gradient proximal depuis le point courant r^k , FISTA le calcule depuis un point auxiliaire y^k qui est une extrapolation des deux dernières itérées :

$$[3.13] \quad y^k = r^{(k-1)} + \frac{t_{k-1} - 1}{t_k} (r^{(k-1)} - r^{(k-2)})$$

$$[3.14, \text{ Mise à jour momentum Nesterov}] \quad t_k = (1 + \sqrt{1 + 4 \cdot t_{k-1}^2}) / 2, \quad t_1 = 1$$

La séquence t_k croît comme $k/2$ pour les grands k , et le terme de momentum $[(t_{k-1} - 1)/t_k] \rightarrow 1 - 3/k \rightarrow 1$, permettant une inertie croissante vers la solution.

3.3.3.2 Algorithme FISTA Complet , 5 Étapes

24. Initialisation : $r^0 = 0$ (ou solution L2), $y^1 = r^0$, $t_1 = 1$, $L \leftarrow \text{Power_Iteration}(G, D, 20 \text{ iter})$, $\text{step} = 1/L$
25. Pour $k = 1, 2, \dots, \text{max_iter}$:
26. Étape 1 , Gradient depuis y^k : $g_k = 2G^T(G \cdot y^k - d) + 2\lambda_2[\delta \cdot y^k + (1-\delta)D^T D \cdot y^k]$
27. Étape 2 , Pas gradient : $z^{k+1} = y^k - \text{step} \cdot g_k$
28. Étape 3 , Seuillage doux : $r^{k+1} = S_{\{\text{step} \cdot \lambda_1\}}(z^{k+1})$
29. Étape 4 , Momentum Nesterov : $t_{k+1} = (1 + \sqrt{1 + 4t_k^2})/2$
30. Étape 5 , Point auxiliaire : $y^{k+1} = r^{k+1} + ((t_k - 1)/t_{k+1}) \cdot (r^{k+1} - r^k)$
31. Critère d'arrêt : si $\|r^{k+1} - r^k\| / (\|r^k\| + 10^{-10}) < \varepsilon \rightarrow \text{STOP}$ (convergence atteinte)

Convergence : $J(r^k) - J(r^*) \leq 2L \cdot \|r^0 - r^*\|^2 / k^2$, taux en $O(1/k^2)$, amélioration d'un facteur k par rapport à ISTA.

3.3.4 Comparaison Convergence ISTA vs FISTA , Analyse Quantitative

Tableau 3.2 : Complexité algorithmique ISTA, FISTA, ADMM, CGLS, Tikhonov

Paramètre	ISTA	FISTA	ADMM
Taux de convergence	$O(1/k)$	$O(1/k^2)$	$O(1/k)$ (linéaire)
Nombre d'itérations typ.	200–500	50–100	100–200
Opérations par itération	$1 \cdot G \cdot r + 1 \cdot G^T \cdot d$	$1 \cdot G \cdot y + 1 \cdot G^T \cdot e$	1 solve L2 + 1 seuillage
Mémoire requise	r^k, z^{k+1}	$r^k, r^{k-1}, y^k, z^{k+1}$	m, z, u (3 vecteurs)
Parallélisme GPU	Excellent (FFT batché)	Excellent (FFT batché)	Bon (PCG parallélisable)
Sensibilité au pas t	Modérée ($t = 1/L$ garanti)	Modérée ($t = 1/L$ garanti)	Sensible à ρ
Mise en œuvre	Très simple	Simple (+2 lignes vs ISTA)	Modérément complexe
Recommandé pour	Problèmes $< 10\,000$ param.	Problèmes $< 10M$ param.	Très grands problèmes 3D

3.4 Algorithmes d'Optimisation Complémentaires

3.4.1 Gradient Conjugué , CGLS

La méthode CGLS (Conjugate Gradient Least Squares) résout $\min \|Gm - d\|^2$ en générant une suite de directions conjuguées qui minimisent progressivement le résidu dans des sous-espaces de Krylov de dimension croissante. La convergence est garantie en au plus N itérations (N = dimension du problème) pour les problèmes quadratiques. L'algorithme CGLS est numériquement stable même pour les opérateurs G mal conditionnés (contrairement à CG appliqué directement aux équations normales $G^T Gm = G^T d$, qui amplifie les erreurs d'arrondi pour les petites valeurs singulières).

$$[3.15] \quad m^{(k+1)} = m^k + \alpha_k p^k, \quad \alpha_k = \frac{\|s^k\|_2^2}{\|Gp^k\|_2^2}$$

$$[3.16] \quad p^{(k+1)} = s^{(k+1)} + \beta_k p^k, \quad \beta_k = \frac{\|s^{(k+1)}\|_2^2}{\|s^k\|_2^2}$$

où $s^k = G^T(d - Gm^k)$ est le gradient du résidu et p^k la direction conjuguée courante.

3.4.2 ADMM , Analyse Détaillée

L'algorithme ADMM (Alternating Direction Method of Multipliers) est basé sur la décomposition du problème d'optimisation en sous-problèmes plus simples. Son fondement mathématique est le Lagrangien augmenté d'Hestenes-Powell-Rockafellar. Pour le problème L1-L2 : $\min_r f(r) + g(r)$ avec $f(r) = \|Gr - d\|^2 + \lambda_2 \|Lr\|^2$ et $g(r) = \lambda_1 \|r\|_1$, ADMM reformule :

$$[3.17] \quad \min_{r,z} \{f(r) + g(z)\} \quad \text{subject to} \quad r - z = 0$$

$$[3.18, \text{Lagrangien augmenté}] \quad \mathcal{L}_\rho(r, z, u) = f(r) + g(z) + (\rho/2) \|r - z + u\|^2$$

Les trois mises à jour ADMM à l'itération k sont :

$$[3.19a, \text{Sous-problème L2}] \quad r^{(k+1)} = \arg \min_r f(r) + (\rho/2) \|r - z^k + u^k\|^2$$

$$[3.19b, \text{Seuillage doux}] \quad z^{(k+1)} = S_{\{\lambda_1/\rho\}}(r^{(k+1)} + u^k)$$

$$[3.19c, \text{Mise à jour duale}] \quad u^{(k+1)} = u^k + r^{(k+1)} - z^{(k+1)}$$

Le sous-problème (3.19a) est un problème L2 standard résolu par PCG : $(G^T G + \lambda_2 L^T L + \rho \cdot I) \cdot r = G^T d + \rho \cdot (z^k - u^k)$. ADMM est particulièrement avantageux pour les très grands problèmes 3D car il décompose le problème en sous-problèmes indépendants facilement parallélisables sur GPU multi-cartes.

3.4.3 Convergence et Analyse de Stabilité

La convergence des algorithmes proximaux implémentés dans QuantX Pro est garantie sous les conditions suivantes :

Tableau 3.2b : Conditions de convergence et taux de convergence des algorithmes proximaux

Algorithme	Condition de convergence	Taux	Critère d'arrêt dans QX.py
ISTA	$t \leq 1/L$ ($L = \text{const. Lipschitz}$)	$O(1/k)$	$\ r^{(k+1)} - r^k\ / \ r^k\ < 10^{-6}$
FISTA	$t \leq 1/L$ (même condition)	$O(1/k^2)$	$\ r^{(k+1)} - r^k\ / \ r^k\ < 10^{-6}$
ADMM	$\rho > 0$, f et g convexes	Linéaire	$\ r - z\ < 10^{-4}$ et $\ \Delta z\ \cdot \rho < 10^{-4}$
CGLS	G pas singulière nulle	Exacte en $\leq N$ iter	$\ r_{\text{résidu}}\ / \ d\ < 10^{-8}$
PCG	Préconditionneur défini positif	Linéaire améliorée	$\ r^{(k+1)}\ / \ b\ < 10^{-8}$

3.5 Inversion Basée sur AI/ML

3.5.1 Réseaux de Neurones Convolutifs , Fondements

3.5.1.1 Théorème d'Approximation Universelle

Le théorème d'approximation universelle (Cybenko, 1989 ; Hornik, 1991) établit que tout réseau de neurones à une seule couche cachée avec une fonction d'activation sigma non polynomiale (sigmoïde, ReLU, tanh) et suffisamment de neurones peut approcher n'importe quelle fonction continue $f: \mathbb{R}^n \rightarrow \mathbb{R}^m$ sur tout compact de $\mathbb{R}^n$ avec une précision epsilon > 0 arbitraire. Pour l'inversion sismique, cela signifie qu'il existe théoriquement un réseau de neurones capable d'approcher le mapping non linéaire exact entre les traces sismiques et les profils d'impédance, quel que soit la complexité de ce mapping.

3.5.1.2 Convolution 1D et Avantages pour les Données Sismiques

L'opération de convolution discrète 1D entre la trace $x \in \mathbb{R}^N$ et un filtre appris $f \in \mathbb{R}^K$ est définie par :

$$[3.20] \quad (x * f)_t = \sum_{k=0}^{K-1} f(k) x(t - k), \quad t = 0, 1, \dots, N-1$$

Les CNN 1D présentent trois avantages fondamentaux pour les données sismiques :

32. Invariance par translation : un motif sismique (réflecteur, multiplet) est reconnu par le même filtre quelle que soit sa position dans la trace, grâce au partage des poids du filtre.

33. Localité : chaque couche de convolution traite uniquement un voisinage local de chaque échantillon (champ réceptif de taille K). Les couches successives élargissent progressivement le champ réceptif effectif.
34. Hiérarchie de représentations : les couches basses détectent des motifs locaux simples (flancs de réflecteurs, pics d'ondelette) ; les couches hautes combinent ces motifs pour reconnaître des structures géologiques complexes (cycles transgression-régression, séquences de dépôt).

3.5.1.3 Architecture U-Net Détaillée pour l'Inversion Sismique

L'architecture U-Net implémentée dans QuantX Pro comprend les composants suivants, détaillés couche par couche :

Tableau 4.3 : Paramètres d'architecture CNN U-Net implémenté dans QuantX Pro v3.0

Couche	Type	Paramètres	Sortie (taille)	Rôle
Entrée	,	,	$N \times 1$	Trace sismique normalisée
Enc-1	$2 \times \text{Conv1D-BN-ReLU}$	32 filtres, $k=3$	$N \times 32$	Détection motifs locaux
Pool-1	$\text{MaxPool1D}(2)$	,	$N/2 \times 32$	Réduction résolution $\times 2$
Enc-2	$2 \times \text{Conv1D-BN-ReLU}$	64 filtres, $k=3$	$N/2 \times 64$	Caractéristiques intermédiaires
Pool-2	$\text{MaxPool1D}(2)$	,	$N/4 \times 64$	Réduction résolution $\times 2$
Enc-3	$2 \times \text{Conv1D-BN-ReLU}$	128 filtres, $k=3$	$N/4 \times 128$	Représentations abstraites
Pool-3	$\text{MaxPool1D}(2)$	,	$N/8 \times 128$	Réduction résolution $\times 2$
Enc-4	$2 \times \text{Conv1D-BN-ReLU}$	256 filtres, $k=3$	$N/8 \times 256$	Représentations profondes
Pool-4	$\text{MaxPool1D}(2)$	,	$N/16 \times 256$	Réduction résolution $\times 2$
Bottleneck	$2 \times \text{Conv1D-BN-ReLU}$	512 filtres, $k=3$	$N/16 \times 512$	Représentation latente
Up-4	ConvTranspose1D	256 filtres, $k=4$, $s=2$	$N/8 \times 256$	Upsampling $\times 2$
Concat-4	$\text{Cat}([\text{Up-4}, \text{Enc-4}])$	,	$N/8 \times 512$	Skip connection
Dec-4	$2 \times \text{Conv1D-BN-ReLU}$	256 filtres, $k=3$	$N/8 \times 256$	Reconstruction haut niveau
Up-1	ConvTranspose1D	32 filtres, $k=4$, $s=2$	$N \times 32$	Upsampling final
Sortie	Conv1D-Linear	1 filtre, $k=1$	$N \times 1$	Profil d'impédance prédit

Le nombre total de paramètres entraînaables est approximativement 7.8 millions pour $N=512$. Le temps d'entraînement sur GPU RTX 3060 (CUDA) est de 35-90 minutes pour 300 epochs avec un batch de 64 traces.

3.5.2 Apprentissage Supervisé et Augmentation de Données

L'entraînement supervisé du CNN U-Net nécessite un ensemble de paires (trace sismique x_i , profil d'impédance y_i) pour $i = 1, \dots, N_{\text{train}}$. Ces paires proviennent des puits de calage (diagraphies DT, RHOB calées sur le sismique). La rareté des puits impose d'augmenter artificiellement le jeu d'entraînement par des transformations préservant la relation physique trace-impédance :

- Augmentation par modélisation directe : à partir des profils d'impédance des puits existants, on génère des milliers de traces synthétiques avec différentes ondelettes (Ricker de fréquences variées 20-60 Hz), différents niveaux de bruit (SNR = 10-40 dB) et différentes distorsions de phase (ondelettes de phase nulle à minimale). Cela augmente le jeu d'entraînement d'un facteur 50 à 200.
- Perturbation temporelle (Time Jittering) : les profils d'impédance sont étirés/comprimés aléatoirement de $\pm 5\%$ à 10% pour simuler des variations de vitesse. La trace correspondante est recalculée par modélisation directe, préservant la cohérence physique.
- Inversion de polarité : multiplier simultanément trace et réflectivité par -1 , ce qui correspond à une inversion des contrastes d'impédance (cas physiquement possible et fréquent dans la pratique).
- Mixage géologique (Geological Mixing) : interpolation linéaire des profils d'impédance de deux puits voisins $\alpha \cdot IA_1 + (1-\alpha) \cdot IA_2$ avec $\alpha \in [0,1]$, produisant des profils synthétiques géologiquement plausibles.

3.5.3 Physics-Informed Neural Networks , Architecture et Entraînement

3.5.3.1 Structure de la Fonction de Coût PINNs

Les PINNs (Raissi et al., 2019) distinguent deux types de données d'entraînement : les données de supervision (labeled data, issues des puits de calage) et les points de collocation (unlabeled data, positions où la contrainte physique est évaluée , ici toutes les traces du volume sismique). La fonction de coût totale est :

$$[3.21] \quad \ell_{\text{total}}(\theta) = w_1 \ell_{\text{sup}}(\theta) + w_2 \ell_{\text{phys}}(\theta) + w_3 \ell_{\text{reg}}(\theta)$$

où θ désigne l'ensemble des paramètres du réseau de neurones, et :

$$[3.22a] \quad \ell_{\text{sup}}(\theta) = \frac{1}{N_w} \sum_i \|Z(x_i; \theta) - Z_{\text{ref}}(x_i)\|_2^2$$

$$[3.22b] \quad \ell_{\text{phys}}(\theta) = \frac{1}{N_t} \sum_j \|W \hat{r}(x_j; \theta) - s_{\text{obs}}(x_j)\|_2^2$$

$$[3.22c] \quad \ell_{\text{reg}}(\theta) = \lambda_1 \|\hat{r}(\theta)\|_1 + \lambda_2 \|D \hat{r}(\theta)\|_2^2$$

Le terme L_{physique} est calculé pour chaque trace sismique en synthétisant $s_{\text{synth}} = w * r_{\text{pred}}(\text{IA}_{\text{pred}})$ par convolution différentiable, puis en comparant à s_{obs} . La différentiabilité de toute la chaîne $\text{IA}_{\text{pred}} \rightarrow r_{\text{pred}} \rightarrow s_{\text{synth}} \rightarrow L_{\text{physique}}$ permet le calcul de $\partial L_{\text{physique}} / \partial \theta$ par rétropropagation automatique.

3.5.3.2 Boucle d'Apprentissage Inverse Différentiable

```
Extrait QX.py , Boucle d'entraînement PINNs
# Boucle PINNs dans QuantX Pro (QX.py)
for epoch in range(max_epochs):
    for batch_traces, batch_impedances in dataloader:
        optimizer.zero_grad()
        # Forward pass CNN → impédances prédites
        IA_pred = cnn_model(batch_traces) # [B, N]
        # Calcul réflectivité depuis impédances (différentiable)
        log_IA = torch.log(IA_pred + 1e-6)
        r_pred = torch.diff(log_IA, dim=-1) / 2.0 # r ≈ Δln(IA)/2
        # Synthèse sismique différentiable (FFT sur GPU)
        wavelet_fft = torch.fft.rfft(wavelet_tensor, n=N)
        r_fft = torch.fft.rfft(r_pred, n=N)
        s_synth = torch.fft.irfft(wavelet_fft * r_fft, n=N)
        # Pertes (supervision + physique + régularisation)
        L_sup = F.mse_loss(IA_pred, batch_impedances) # Supervision puits
        L_phys = F.mse_loss(s_synth, batch_traces) # Misfit sismique
        L_l1 = lambda1 * torch.mean(torch.abs(r_pred)) # Sparsité L1
        L_total = w1*L_sup + w2*L_phys + w3*L_l1
        L_total.backward() # Rétropropagation automatique
        optimizer.step() # Mise à jour Adam
```

3.5.4 Quantification d'Incertaineté , Monte Carlo Dropout et Processus Gaussiens

3.5.4.1 Monte Carlo Dropout

Le Monte Carlo Dropout (MC-Dropout, Gal & Ghahramani, 2016) repose sur l'observation que l'entraînement d'un réseau avec Dropout est approximativement équivalent à l'apprentissage variationnel dans un espace de processus gaussiens profonds. En maintenant le Dropout actif en inférence et en réalisant T passes stochastiques, on obtient un ensemble de T prédictions $\{\text{IA}_{\text{pred}}^{(t)}\}_{t=1}^T$ dont les statistiques estiment la distribution postérieure :

$$[3.23a] \quad \mu(x) = \frac{1}{T} \sum_{t=1}^T Z^{(t)}(x)$$

$$[3.23b] \quad \sigma^2(x) = \frac{1}{T} \sum_{t=1}^T [Z^{(t)}(x) - \mu(x)]^2$$

Avec $T = 300$ passes stochastiques, les cartes d'incertitude $\sigma(x)$ convergent en pratique (variance de $\sigma < 2\%$). Le taux de dropout optimal est de 0.25-0.35 (compromise entre diversité des prédictions et qualité individuelle).

3.5.4.2 Processus Gaussiens (GPyTorch)

Les processus gaussiens (GP, Williams & Rasmussen, 2006) offrent un cadre bayésien rigoureux pour la régression avec incertitude. Un GP définit une distribution sur les fonctions $f(x) \sim GP(\mu(x), k(x, x'))$, entièrement caractérisée par la fonction moyenne $\mu(x) = 0$ et la fonction de covariance (noyau) $k(x, x') = \sigma^2 \cdot \exp(-\|x - x'\|^2 / (2l^2))$ (noyau RBF). La prédiction GP à un nouveau point x^* donne une distribution gaussienne $p(f^* | X, y, x^*) = N(\mu^*, \sigma^{*2})$ avec expression analytique exacte. Dans QuantX Pro, GPyTorch implémente les GP par approximation inducing points pour les grandes dimensions ($N > 10\,000$ traces).

3.5.5 Module SINDy, Découverte Automatique de Lois Physiques

SINDy (Brunton, Proctor & Kutz, 2016) découvre les équations différentielles qui gouvernent les données sismiques par régression parcimonieuse dans un dictionnaire de fonctions candidates. L'hypothèse fondamentale est que les données sont gouvernées par une EDP de la forme :

$$[3.24] \quad \frac{\partial m}{\partial t} = \Theta(m) \xi$$

où $\Theta(m)$ est la matrice du dictionnaire (colonnes = fonctions candidates évaluées aux données : polynômes $m, m^2, m^3, \sin(m)$, dérivées $\partial m / \partial x, \partial^2 m / \partial x^2, \dots$) et ξ est le vecteur sparse des coefficients actifs. La régression parcimonieuse LASSO identifie les termes actifs :

$$[3.25] \quad \xi^* = \arg \min_{\xi} \left\{ \left\| \frac{\partial m}{\partial t} - \Theta(m) \xi \right\|_2^2 + \gamma \|\xi\|_1 \right\}$$

Pour les données sismiques, le dictionnaire inclut les termes : $m, m^2, \partial m / \partial x, \partial^2 m / \partial x^2, \partial m / \partial t, \partial^2 m / \partial t^2, m \cdot \partial m / \partial x$, et les termes trigonométriques $\sin(m), \cos(m)$. L'EDP identifiée peut valider le modèle physique (équation d'onde attendue) ou révéler des effets non modélisés (dispersion, absorption, non-linéarités).

3.6 Comparaison Globale des Approches

Le Tableau 3.2 présente une comparaison quantitative et qualitative exhaustive de toutes les méthodes implémentées dans QuantX Pro, permettant de guider le choix de la méthode la plus adaptée selon les caractéristiques des données et les objectifs de l'étude.

Tableau 3.3 : Comparaison globale des approches d'inversion sismique

Méthode	R ² Marmousi (SNR=30)	R ² SNR=10	Résolution vert.	Cohér. phys.	Temps/trace	Données puits
Tikhonov L2	0.851	0.697	Faible (lisse)	Partielle	0.01 s	Non nécessaire
CGLS	0.863	0.718	Intermédiaire	Partielle	0.03 s	Non nécessaire
L1 Sparse (ISTA)	0.887	0.771	Haute (sparse)	Partielle	0.08 s	Non nécessaire
L1-L2 ISTA	0.899	0.795	Haute + stable	Partielle	0.10 s	Non nécessaire
L1-L2 FISTA	0.914	0.808	Haute + stable	Partielle	0.09 s	Non nécessaire
TV (ADMM)	0.902	0.801	Interfaces nettes	Partielle	0.15 s	Non nécessaire
CNN U-Net	0.937	0.861	Très haute (SR)	Non garantie	0.003 s	Oui (obligatoire)
PINNs (CNN+Phys.)	0.953	0.895	Haute + physique	Garantie	0.005 s	Oui (conseillé)
Ensemble Final	0.962	0.921	Maximale	Garantie	0.015 s	Oui (conseillé)

La sélection de la méthode doit prendre en compte cinq critères pratiques : (1) la disponibilité et la qualité des puits de calage, (2) le niveau de bruit des données, (3) la complexité géologique du milieu (milieu à couches ou à gradients), (4) les ressources computationnelles disponibles (CPU ou GPU), et (5) les exigences de l'étude en termes de quantification d'incertitude et d'interprétabilité des résultats.

CHAPITRE 4 : Conception et Développement du Programme d'Inversion

4.1 Architecture Globale du Système , QuantX Pro v3.0

QuantX Pro (Quantitative seismic inversion eXpert) est un programme Python de 11 327 lignes développé selon une architecture orientée objet stricte et modulaire. Il intègre une interface graphique professionnelle PyQt6, un moteur d'inversion hybride (classique + ML), et des modules d'accélération GPU (PyTorch/CUDA) et JAX. L'architecture est organisée en quatre modules fonctionnels principaux, interconnectés par un orchestrateur de pipeline central :

Tableau 4.1 : Architecture globale des modules de QuantX Pro v3.0

Module	Sous-modules	Technologies
Prétraitement	Lecture SEG-Y/LAS/NPY, filtrage, normalisation, extraction d'attributs	segio, obspy, lasio, scipy.signal
Modélisation	Opérateurs linéaires G et D, forward modeling différentiable, estimation ondelette	NumPy, scipy.sparse, FFT
Inversion	Tikhonov/CGLS/ISTA/FISTA/ADMM, GPU-FISTA, JAX-FISTA, CNN U-Net, PINNs, SINDy, Bayesian GP	PyTorch, JAX, PySINDy, GPyTorch, XGBoost
Visualisation & Export	Sections sismiques 2D/3D, cartes d'incertitude, rapports PDF	matplotlib, plotly, reportlab, PyQt6

Les technologies implémentées sont illustrées dans le tableau suivant :

Tableau 4.2 : Technologies et dépendances de QuantX Pro v3.0

Bibliothèque	Version min.	Rôle dans QuantX Pro
Python	3.8+	Langage principal , 11 327 lignes
PyQt6	6.0+	Interface graphique professionnelle , fenêtre principale, panneaux, toolbar
PyTorch	1.13+	CNN U-Net, PINNs, GPU-FISTA, GNN, Diffusion Models
JAX	0.4+	FISTA accéléré JIT/XLA , compilation automatique GPU/TPU
NumPy / SciPy	1.22+ / 1.9+	Calcul matriciel, FFT, filtres, opérateurs creux
XGBoost / LightGBM	1.7+ / 4.0+	Prédiction de vitesse par gradient boosting
GPyTorch	1.10+	Processus gaussiens bayésiens , quantification incertitude
PySINDy	1.7+	Découverte automatique de PDE par régression

		parcimonieuse
Segyio / Lasio	1.9+ / 0.31+	Lecture/écriture SEG-Y et diagraphies LAS
Matplotlib / Plotly	3.7+ / 5.11+	Visualisation 2D/3D sections et cartes
Optuna	3.2+	Optimisation bayésienne des hyperparamètres (TPE)
CUDA	11.8+	Accélération GPU , facteur x10 à x50 vs CPU

4.2 Prétraitement des Données Sismiques

4.2.1 Filtrage Passe-Bande

Un filtre passe-bande de Butterworth d'ordre 4 est appliqué dans la bande 5-80 Hz (paramétrable). Le filtre de Butterworth présente un gain maxalement plat dans la bande passante et une atténuation progressive de -80 dB/décade (ordre 4) hors de la bande. La conception du filtre utilise `scipy.signal.butter()` et son application se fait par filtrage directionnel (`filtfilt`) pour éliminer les déphasages.

```
Extrait QX.py , Filtrage passe-bande
# Filtrage passe-bande Butterworth ordre 4 (QX.py)
from scipy import signal
def bandpass_filter(trace, dt, f_low=5, f_high=80):
    nyq = 0.5 / dt # Fréquence de Nyquist
    low = f_low / nyq # Fréquence normalisée basse
    high = f_high / nyq # Fréquence normalisée haute
    b, a = signal.butter(4, [low, high], btype='bandpass')
    return signal.filtfilt(b, a, trace) # Zero-phase filtering
```

4.2.2 Normalisation et Gestion des NaN

La normalisation par z-score global est appliquée à l'ensemble du volume sismique pour garantir l'homogénéité des amplitudes entre traces. Les valeurs manquantes (NaN) et les traces mortes (amplitude max < seuil) sont détectées et remplacées par des traces nulles avec un flag d'exclusion. L'option de normalisation AGC (Automatic Gain Control) par trace individuelle est disponible pour les données à fort contraste d'amplitude latéral.

4.2.3 Estimation de la Wavelet

QuantX Pro implémente trois méthodes d'estimation de l'ondelette :

35. Ondelette analytique : Ricker (chapeau mexicain), Ormsby (trapèze dans l'espace fréquentiel), ou ondelette personnalisée fournie par l'utilisateur.

36. Estimation statistique : déconvolution de Wiener basée sur l'autocorrélation de la trace sismique, sous l'hypothèse de phase minimale et de réflectivité blanche.
37. Estimation déterministe : Estimateur de Wiener multi-traces minimisant $\|\text{sismogramme synthétique} - \text{trace réelle}\|^2$ par rapport aux coefficients de l'ondelette, nécessitant une diagraphie de puits calée.

4.3 Implémentation de l'Inversion Classique

4.3.1 Construction de la Matrice Forward G

La matrice de modélisation directe G est implémentée comme un opérateur linéaire `scipy.sparse.linalg.LinearOperator`, permettant de calculer $G \cdot r$ et $G^T \cdot d$ par convolution/corrélation FFT en $O(N \log N)$ sans former explicitement la matrice G (évitant le stockage de N^2 flottants). L'opérateur `ConvolutionOperator` est défini par :

```
Extrait QX.py lignes 471-484 , ConvolutionOperator
class ConvolutionOperator(LinearOperator):
    """Opérateur G : r -> d = G·r par convolution FFT"""
    def __init__(self, wavelet, n_samples):
        self.wavelet = wavelet
        self.shape = (n_samples, n_samples)
        self.dtype = np.float64
    def _matvec(self, r): # Produit G·r
        return signal.convolve(r, self.wavelet, mode='same', method='fft')
    def _rmatvec(self, d): # Produit G^T·d (corrélation)
        return signal.correlate(d, self.wavelet, mode='same', method='fft')
```

4.3.2 Implémentation $L1$, $L2$, $L1-L2$

Chaque méthode est encapsulée dans la classe `SeismicInversionEngine` et sélectionnée via l'énumération `SolverType`. L'implémentation FISTA (cœur du programme) est détaillée ci-dessous avec les 4 étapes de l'algorithme :

```
Extrait QX.py lignes 584-668 , FISTA complet
def _solve_ld(self, seismic_data, progress_callback, initial_guess):
    G = ConvolutionOperator(self.wavelet, n_samples) # Opérateur G
    D = DifferenceOperator(n_samples, order=2) # Opérateur L
    L_lip = self._estimate_lipschitz(G, D, n_samples) # Constante Lipschitz
    step_size = 1.0 / L_lip # t = 1/L (garanti convergence)
    r, y, t = np.zeros(n_samples), np.zeros(n_samples), 1.0
    for k in range(self.params.max_iter):
        r_old = r.copy()
        # Étape 1 : gradient sur y (point auxiliaire FISTA)
        residual = G.matvec(y) - seismic_data
        grad_data = 2 * G.rmatvec(residual) # 2·G^T·(Gy-d)
        grad_reg = 2*self.params.lambda2*(self.params.delta*y +
            (1-self.params.delta)*D.rmatvec(D.matvec(y)))
        gradient = grad_data + grad_reg
        # Étape 2 : pas de gradient (gradient step)
        z = y - step_size * gradient
        # Étape 3 : seuillage doux (proximal L1)
        r_new = self._soft_threshold(z, self.params.lambda1*step_size)
```

```
# Étape 4 : momentum Nesterov (FISTA uniquement)
t_new = (1 + np.sqrt(1 + 4*t**2)) / 2
y = r_new + ((t-1)/t_new) * (r_new - r)
t, r = t_new, r_new
if np.linalg.norm(r-r_old)/(np.linalg.norm(r_old)+1e-10) < self.params.tol:
    break
```

4.4 Développement du Modèle AI/ML

4.4.1 Architecture du Réseau CNN U-Net

Le CNN U-Net est implémenté en PyTorch. L'architecture comprend un encodeur à 4 niveaux (Conv1D-BatchNorm-ReLU-MaxPool, filtres 32-64-128-256), un bottleneck (2× Conv1D 512 filtres), et un décodeur à 4 niveaux (ConvTranspose1D + cat(skip) + 2× Conv1D-BN-ReLU). La couche de sortie est Conv1D(1, k=1, activation=linear). Le nombre total de paramètres est approximativement 7.8 millions.

4.4.2 Fonction de Coût Hybride

La fonction de coût pour l'entraînement du CNN combine : le terme de supervision (MSE entre impédances prédites et de référence aux puits), la régularisation L2 sur les poids (weight decay, $\alpha = 1e-4$), et optionnellement le terme de contrainte physique PINNs ($\mathcal{L}_{phys} = \|s_{pred} - s_{obs}\|^2$) :

$$\mathcal{L}_{total} = MSE(IA_{pred}, IA_{ref}) + \alpha \cdot \|W\|_2^2 + \lambda_3 \cdot \mathcal{L}_{phys}$$

4.4.3 Entraînement du Modèle

L'entraînement est réalisé sur des paires (traces sismiques synthétiques, profils d'impédance Marmousi-2), augmentées par bruit gaussien de SNR variable. L'optimiseur Adam ($\text{lr}_0 = 1e-3$, $\text{betas} = (0.9, 0.999)$, $\text{eps} = 1e-8$) est utilisé avec un scheduler ReduceLROnPlateau (facteur 0.5, patience 30 epochs). L'arrêt anticipé (Early Stopping, patience 50 epochs sur le R^2 de validation) prévient le surapprentissage. La taille des lots est 64 traces. L'entraînement typique dure 200-500 epochs (30-90 minutes sur GPU RTX 3060).

4.5 Intégration du Modèle Physique

L'intégration des PINNs dans la boucle d'entraînement exploite la différentiation automatique de PyTorch. Après chaque passe forward du CNN (prédiction des impédances IA_{pred}), le module de modélisation directe différentiable calcule la réflectivité $r_{pred} =$

$\Delta[\log(\text{IA_pred})]$ par différences finies différentiables, puis le sismogramme synthétique $s_pred = w * r_pred$ par FFT différentiable. Le terme $\mathcal{L}_{phys} = \|s_pred - s_obs\|^2$ est calculé et son gradient par rapport aux paramètres du réseau est obtenu automatiquement par la chaîne de rétropropagation de PyTorch, permettant l'optimisation conjointe de l'ajustement aux données de puits et de la cohérence avec les données sismiques.

4.6 Validation du Programme

La validation est conduite à trois niveaux : (1) Tests unitaires (pytest) : chaque classe et fonction est testée individuellement avec des cas analytiques dont la solution exacte est connue (trace de Dirac, réflectivité monorélecteur). (2) Tests d'intégration : le pipeline complet est testé de bout en bout sur le modèle Marmousi-2 et comparé aux résultats publiés dans la littérature. (3) Comparaison avec des logiciels de référence : les résultats FISTA et Tikhonov sont comparés aux implémentations de référence disponibles dans pyDLT (Ravasi & Vasconcelos, 2021) et OpendTect (open source).

CHAPITRE 5 : Application sur des Données Sismiques

5.1 Application sur Données Synthétiques

5.1.1 Génération du Modèle Synthétique

le standard de référence international pour l'évaluation des méthodes d'inversion élastique. Il représente une section géologique réaliste de $17 \text{ km} \times 3.5 \text{ km}$, incluant des structures anticlinales complexes, des failles normales et inverses, une intrusion saline halocinétique, et un réservoir de gaz en profondeur. Les 199 couches géologiques avec des propriétés élastiques (V_p , V_s , ρ) variant de manière complexe en 2D constituent un test sévère pour toute méthode d'inversion.

Tableau 5.1 : Paramètres du modèle Marmousi-2 utilisés pour la validation synthétique

Paramètre	Valeur	Unité
Dimensions du modèle ($x \times z$)	$17\,000 \times 3\,500$	m
Pas spatial ($dx = dz$)	1.25×1.25	m
Nombre de couches géologiques	199	,
Plage de vitesse V_P	1 500 – 4 700	m/s
Plage de vitesse V_S	0 – 2 750	m/s
Plage de densité ρ	1.0 – 2.7	g/cm^3
Plage d'impédance IA	1 500 – 12 690	$\text{g/cm}^3 \cdot \text{m/s}$
Fréquence centrale ondelette Ricker	25	Hz
Intervalle d'échantillonnage temporel	2	ms
Niveaux de bruit (SNR)	30, 20, 15, 10	dB
Nombre de traces synthétiques générées	13 600	,

5.1.2 Simulation des Données Sismiques

Les traces sismiques synthétiques sont générées par convolution de la réflectivité calculée depuis les profils d'impédance acoustique du modèle Marmousi-2 avec une ondelette de Ricker ($f_0 = 25 \text{ Hz}$) :

$$s(k, t) = w(t) * r(k, t) + n(k, t), \quad k = 1, \dots, 13\,600 \text{ traces}$$

Le bruit gaussien blanc $n(k, t)$ est ajouté à quatre niveaux de SNR (30, 20, 15, 10 dB) pour tester la robustesse des méthodes face à des conditions de bruit croissant. Les données synthétiques sont utilisées comme jeu d'entraînement (70%, traces 1-9520), validation (15%,

traces 9521-11560) et test final (15%, traces 11561-13600), sans chevauchement géographique.

5.1.3 Résultats d'Inversion , Comparaison des Méthodes

Tableau 5.2 : Résultats comparatifs des méthodes d'inversion sur données synthétiques (Marmousi-2)

Méthode	RMSE	MAE	R ²	SNR amélioré	Convergence	Temps/trace
Tikhonov L2	512 ± 48	398 ± 36	0.851 ± 0.012	6.2 dB	1 iter (direct)	0.01 s
CGLS	487 ± 44	375 ± 32	0.863 ± 0.011	7.1 dB	50 iter	0.03 s
L1 Sparse (ISTA)	423 ± 39	325 ± 27	0.887 ± 0.009	9.8 dB	350 iter	0.08 s
L1-L2 ISTA	402 ± 36	308 ± 24	0.899 ± 0.008	10.7 dB	280 iter	0.10 s
L1-L2 FISTA	367 ± 30	281 ± 21	0.914 ± 0.006	12.1 dB	85 iter	0.09 s
CNN U-Net	302 ± 24	231 ± 17	0.937 ± 0.005	14.7 dB	N/A	0.003 s
PINNs (CNN+contrainte)	261 ± 20	198 ± 14	0.953 ± 0.004	17.2 dB	N/A	0.005 s
Ensemble Final	238 ± 18	181 ± 13	0.962 ± 0.003	18.8 dB	N/A	0.015 s

5.1.4 Analyse des Performances

Les résultats montrent une progression monotone des performances avec la sophistication de la méthode. La régularisation mixte L1-L2 FISTA améliore le R² de 6.3 points par rapport à Tikhonov L2, grâce à la combinaison de la sparsité (préservation des interfaces nettes) et du lissage (stabilité numérique). Le passage à FISTA réduit le nombre d'itérations de 280 (ISTA) à 85 (FISTA), confirmant le gain en $O(1/k^2)$ vs $O(1/k)$ attendu théoriquement.

Le CNN U-Net (R² = 0.937) apporte un gain de 2.3 points supplémentaires par rapport à FISTA grâce à sa capacité à modéliser les non-linéarités et à exploiter les corrélations entre traces. Les PINNs (R² = 0.953) apportent encore 1.6 points en imposant la cohérence physique, ce qui est particulièrement bénéfique dans les zones à faible couverture de puits. L'Ensemble final (R² = 0.962) est le meilleur résultat global.

L'analyse de robustesse au bruit montre que la méthode Tikhonov L2 est la plus sensible : son R^2 chute de 18% entre SNR=30 dB et SNR=10 dB (de 0.851 à 0.697). FISTA L1-L2 est nettement plus robuste (-11%, $R^2 = 0.808$ à SNR=10 dB). Les PINNs montrent la meilleure robustesse (-6%, $R^2 = 0.895$ à SNR=10 dB), la contrainte physique jouant le rôle de régularisation implicite supplémentaire.

5.2 Application sur Données Réelles , Bassin de Berkine

5.2.1 Présentation du Jeu de Données et Contexte Géologique

Le bassin de Berkine est situé dans le nord-est du Sahara algérien (wilaya d'Ilizi). C'est l'un des bassins sédimentaires les plus actifs en matière d'exploration et de production d'hydrocarbures en Algérie, avec d'importants gisements pétroliers découverts à partir des années 1990. La stratigraphie est dominée par des séquences paléozoïques (Cambrien à Dévonien) et mésozoïques (Trias-Crétacé), avec plusieurs niveaux réservoirs d'intérêt pétrolier.

Le réservoir cible de cette étude est constitué par les grès du Dévonien Inférieur (Formation TKAZ, Tadrart-Khatata), situés entre 3 100 et 3 400 m de profondeur TVD. Ces grès présentent une bonne porosité primaire intergranulaire (18-22%) et une bonne perméabilité (50-500 mD), les classant parmi les meilleurs réservoirs de la région. La roche couverture est constituée par les argiles du Dévonien Moyen (Formation ASER), de bonne qualité et d'extension régionale.

Tableau 5.4 : Caractéristiques du volume sismique réel — bassin de Berkine (Algérie)

Caractéristique	Description
Type de données	Volume sismique 3D post-stack prétraité et migré en temps
Superficie du volume	450 km ²
Nombre d'inlines	450 (espacement 25 m)
Nombre de crosslines	650 (espacement 25 m)
Intervalle d'échantillonnage	2 ms
Fenêtre temporelle	1 800 – 3 500 ms TWT
Puits disponibles	3 puits (P1, P2 calage + P3 validation)
Diagraphies disponibles	GR, DT, RHOB, NPHI, CALI, PE
Réservoir cible	Grès Dévonien Formation TKAZ
Profondeur cible	3 100 – 3 400 m TVD

Source sismique	Vibrateurs hydrauliques , bande 8-80 Hz
-----------------	---

5.2.2 Prétraitement des Données Réelles

Le prétraitement des données réelles comprend plusieurs étapes spécifiques. Le filtrage passe-bande (8-70 Hz) est adapté au spectre réel de la source vibreur. La correction des amplitudes par sphéricité géométrique et absorption anélastique (correction Q, facteur Q = 80 estimé par analyse spectrale) est appliquée pour retrouver les amplitudes relatives en profondeur. Le calage puits-sismique (well-to-seismic tie) est réalisé pour les trois puits par corrélation croisée des sismogrammes synthétiques (calculés depuis les diagraphies DT et RHOB) avec les traces sismiques réelles au droit des puits. Les coefficients de corrélation obtenus sont : P1 = 0.87, P2 = 0.83, P3 = 0.89, confirmant la bonne qualité du calage.

5.2.3 Résultats d'Inversion

Les méthodes L1-L2/FISTA et l'Ensemble PINNs+CNN ont été appliquées au volume sismique 3D complet en mode trace-par-trace parallélisé. L'inversion a produit des volumes d'impédance acoustique et de réflectivité à la même résolution que le volume sismique d'entrée. Les performances évaluées au puits de validation P3 (non utilisé lors de l'entraînement) sont :

Tableau 5.5 : Métriques d'inversion sur données réelles aux puits de validation

Métrique	L2 Tikhonov	L1-L2 FISTA	CNN U-Net	PINNs Ensemble
RMSE (g/cm ³ ·m/s)	521	381	389	342
MAE (g/cm ³ ·m/s)	418	291	298	261
R ²	0.861	0.914	0.912	0.941
Corrélation de Pearson	0.929	0.957	0.955	0.971
Erreur relative (%)	6.7	4.4	4.6	3.9
Temps inversion 3D	2 h 15	48 min	12 min (GPU)	35 min (GPU)

5.2.4 Interprétation Géologique

Le volume d'impédance acoustique inversé révèle des structures géologiques cohérentes avec la connaissance géologique disponible de la région. Les corps gréseux du

Dévonien (faibles impédances : $6\,500\text{--}8\,200\text{ g/cm}^3\cdot\text{m/s}$) contrastent nettement avec les argiles encaissantes ($9\,500\text{--}11\,000\text{ g/cm}^3\cdot\text{m/s}$), permettant une cartographie précise de la géométrie du réservoir.

La carte d'impédance extraite à l'horizon TKAZ révèle des failles normales conjuguées d'orientation NE-SW, cohérentes avec la tectonique de rifting régionale. Les corps gréseux en biseau contre ces failles constituent des pièges stratigraphico-structuraux potentiels pour les hydrocarbures. Les zones de plus faible impédance (porosité maximale) corréleront avec les meilleures productivités mesurées aux puits existants, validant la pertinence de l'inversion pour la caractérisation de réservoir.

5.3 Validation Progressive de l'Inversion Sismique : De la Géométrie Simple au Modèle Marmousi

5.3.1 Méthodologie et Protocole Expérimental

Afin de valider de manière systématique et rigoureuse les performances du moteur d'inversion sismique QuantX SeismicInversionEngine, une stratégie de validation progressive a été adoptée. Cette approche consiste à faire croître graduellement la complexité du modèle de vitesses utilisé, depuis des géométries élémentaires horizontalement stratifiées jusqu'au modèle de référence international Marmousi, reconnu pour sa complexité structurale représentative des milieux géologiques réels.

Le protocole expérimental repose sur la génération de données sismiques synthétiques par convolution ondelette-réflexivité (ondelette de Ricker à 25 Hz), suivie d'une inversion post-stack via l'algorithme L1-L2 avec régularisation mixte (60 itérations), sur une grille de 200×300 noeuds couvrant un domaine de $800\text{ m} \times 1200\text{ m}$. Quatre métriques de performance sont évaluées systématiquement à chaque étape : l'erreur quadratique moyenne (RMSE), le coefficient de corrélation de Pearson (Corr.), le rapport signal-sur-bruit (SNR en dB) et l'erreur absolue moyenne (MAE), comparant systématiquement les modèles vrai et inversé.

5.3.2 Description des Étapes de Complexité Croissante

Six étapes de complexité croissante ont été définies, chacune introduisant une difficulté structurale supplémentaire par rapport à la précédente :

Étape 1 (Couches Horizontales) : modèle tabulaire à trois couches horizontales à vitesse constante par couche, constituant le cas le plus simple de la stratigraphie classique.

Étape 2 (Couches Pendantes) : introduction d'un pendage structural de 17° , simulant une séquence monoclinale simple avec décalage latéral des interfaces.

Étape 3 (Gradient de Vitesse) : ajout d'un gradient vertical de vitesse (± 200 m/s par couche), représentant la compaction progressives des sédiments avec la profondeur.

Étape 4 (Failles et Hétérogénéités) : introduction de deux discontinuités de faille et d'hétérogénéités aléatoires (filtrées par filtre de Wiener), simant les variations latérales de faciès lithologique.

Étape 5 (Géologie Complexe) : modèle proxy lissé incorporant un corps salin, des chenaux sédimentaires et un réseau de failles ; cette étape constitue un test de pré-qualification pour le modèle réel.

5.3.3 Résultats Quantitatifs et Évolution des Métriques

Le tableau 5.6 présente les métriques de performance obtenues pour chacune des six étapes de validation progressive. Ces résultats constituent la base quantitative de l'analyse comparative développée dans les sections suivantes.

Tableau 5.6 Métriques de performance de l'inversion progressive (QuantX Pro v3.0, Ricker 25 Hz, grille 200×300)

Étape	ModèleModèle géologique	RMSE	Corrélation	SNR (dB)	MAE (m/s)	Ratio Variance
1	Couches Horizontales	289.9	0.9295	8.6	158.9	0.907
2	Couches Pendantes	328.1	0.9201	8.0	215.8	0.973
3	Gradient de Vitesse	190.5	0.9741	12.9	135.7	0.948
4	Failles et Hétérogénéités	281.6	0.9395	9.2	163.8	0.998
5	Géologie Complexe	367.7	0.9022	7.3	215.2	0.900
6	Sous-ensemble	63.4	0.6219	1.9	48.8	0.621

Meilleure performance étape 3 (vert) ; dégradation maximale étape 6 (rouge) voir discussion section 5.3.4

5.3.3.1 Évolution des Métriques : Analyse Graphique

La Figure 5.10 présente les courbes d'évolution des quatre métriques (RMSE, Corrélation, SNR, MAE) en fonction des étapes de complexité croissante. Ces trajectoires révèlent des comportements distincts selon la métrique considérée, permettant une analyse multi-dimensionnelle des performances de l'inversion post-stack.

5.3.4 Analyse Stade par Stade et Interprétation

■ Étapes 1 et 2 Couches Horizontales et Pendantes




Figure 5.10 Évolution des métriques d'inversion (RMSE, Corrélation, SNR, MAE) sur les six étapes de complexité croissante. La RMSE et la MAE présentent des trajectoires non monotones, avec un optimum à l'étape 3 (gradient de vitesse). La corrélation et le SNR décroissent progressivement




Figure 5.11 Résultats d'inversion pour les étapes 1 (couches horizontales) et 2 (couches pendantes). Colonnes de gauche à droite : modèle vrai, modèle inversé, résidu, profils de traces et crossplot de corrélation.

L'étape 1 (couches horizontales, RMSE = 289.9 m/s, Corr. = 0.930, SNR = 8.65 dB) constitue le référentiel de performance pour le cas le plus favorable. L'inversion post-stack récupère correctement les trois interfaces principales, comme l'atteste le crossplot de corrélation ($r = 0.930$). Cependant, les profils de traces révèlent une incapacité à reproduire les valeurs absolues de vitesse : la pseudo-inverse en bande limitée ne peut restituer les composantes basse fréquence du modèle (< 10 Hz), qui ne sont pas contenues dans le signal

sismique. Ce déficit de basse fréquence, caractéristique de l'inversion post-stack conventionnelle (Tarantola, 1987 ; Oldenburg et al., 1983), est intrinsèquement lié à la nature band-limitée de l'ondelette sismique et ne peut être résolu qu'en intégrant un modèle de vitesses basse fréquence issu des puits ou d'une analyse de vitesse tomographique.

L'étape 2 (couches pendantes, 17° , RMSE = 328.1 m/s, Corr. = 0.920) enregistre une dégradation mesurée (+38.2 m/s RMSE, -1.0 point de corrélation) par rapport à l'étape 1. Ce comportement est théoriquement attendu : le modèle convolutionnel post-stack assume implicitement une incidence normale et des réflecteurs horizontaux (Sheriff et Geldart, 1995). Le pendage de 17° introduit des effets de migration non corrigés (erreurs de positionnement latéral des réflecteurs) et des variations d'amplitude liées à l'obliquité du rayon incident. Le ratio de variance élevé (0.973) indique toutefois que l'inversion restitue correctement la dispersion globale du modèle, confirmant sa robustesse pour des pendages modérés.

■ Étape 3 Gradient de Vitesse : Performance Optimale




Figure 5.12 Étape 3 (gradient de vitesse) : meilleure performance de la séquence progressive. Le modèle inversé reproduit fidèlement les gradients intra-couche (RMSE = 190.5 m/s, Corr. = 0.974, SNR = 12.91 dB, MAE = 135.7 m/s).

L'étape 3 constitue la meilleure performance de la séquence progressive (RMSE = 190.5 m/s, Corr. = 0.974, SNR = 12.91 dB), un résultat apparemment paradoxal qui mérite une explication rigoureuse. Le gradient vertical de vitesse (± 200 m/s/couche) génère une réflectivité distribuée de manière plus régulière et de plus faible amplitude que les cas à couches discrètes, créant une fonction de Green plus favorable à l'inversion par régularisation mixte L1-L2. La continuité des gradients intra-couches réduit le conditionnement de la

matrice de convolution de Toeplitz, améliorant la stabilité numérique de l'inversion (Tikhonov et Arsenin, 1977). Ce résultat illustre la dépendance de la performance d'inversion vis-à-vis de la structure spectrale du modèle de vitesses sous-jacent.

■ Étapes 4 et 5 Failles, Hétérogénéités et Géologie Complexe




Figure 5.13 *Étape 4 (failles et hétérogénéités) : introduction de discontinuités structurales et de variations latérales de faciès. Les failles génèrent des déphasages locaux dans l'image inversée. RMSE = 281.6 m/s, Corr. = 0.939, SNR = 9.17 dB.*




Figure 5.14 Étape 5 (géologie complexe, proxy Marmousi lissé) : corps salin, chenaux et failles multiples. La dégradation des métriques (RMSE = 367.7 m/s, Corr. = 0.902) reflète les limites du modèle convolutionnel 1D face à une géologie 2D fortement hétérogène.

L'étape 4 (failles et hétérogénéités, RMSE = 281.6 m/s, Corr. = 0.939) enregistre une récupération partielle des performances par rapport à l'étape 2, suggérant que le filtre de Wiener appliqué aux hétérogénéités aléatoires a pour effet positif de lisser les variations haute fréquence, créant un modèle plus adapté à l'inversion band-limitée. Néanmoins, les discontinuités de faille génèrent des artefacts d'inversion locaux (déphasages, faux réflecteurs diffractés) non représentables dans un modèle convolutionnel monodimensionnel. L'étape 5 (géologie complexe, RMSE = 367.7 m/s, Corr. = 0.902, SNR = 7.26 dB) marque une dégradation significative liée à la présence d'un corps salin à fort contraste d'impédance (hétérogénéités latérales majeures non modélisables 1D) et de multiples failles subparallèles générant des effets d'ombre (shadow zones) dans les traces de profondeur.

■ Étape 6 Sous-ensemble : Test de Complexité Maximale




Figure 5.15 Étape 6 (sous-ensemble) : complexité maximale du benchmark. Malgré la forte diminution de la corrélation ($r = 0.622$), la RMSE reste faible (63.4 m/s) en raison de la plage de vitesse restreinte du sous-ensemble sélectionné (1 400–1 900 m/s).

L'étape 6 (RMSE = 63.4 m/s, Corr. = 0.622, SNR = 1.93 dB) présente un comportement dual en apparence contradictoire : la RMSE absolue est paradoxalement très faible (63.4 m/s), la plus basse de toute la séquence, tandis que la corrélation s'effondre à 0.622, son niveau le plus bas. Ce paradoxe s'explique par la plage de vitesse extrêmement restreinte du sous-ensemble utilisé (coin supérieur gauche, vitesses 1 400–1 900 m/s uniquement), qui réduit mécaniquement la RMSE, tandis que la forte complexité structurale interne (failles conjuguées, lentilles sédimentaires, gradients latéraux) dégrade la corrélation structurale. Avec un SNR de seulement 1.93 dB, le bruit d'inversion domine le signal utile : l'inversion post-stack est proche de sa limite fonctionnelle pour ce type de complexité. Ce résultat est parfaitement cohérent avec les conclusions de Martin et al. (2006) sur les limites de l'inversion linéaire pour le modèle Marmousi complet.

5.3.5 Synthèse et Implications Méthodologiques

La validation progressive démontre que l'algorithme d'inversion QuantX SeismicInversionEngine présente une dégradation graduellement contrôlée des performances avec la complexité géologique, sans effondrement catastrophique. La corrélation reste supérieure à 0.90 jusqu'à l'étape 5 (géologie complexe) et le RMSE ne dépasse pas 370 m/s sur les modèles synthétiques à large gamme de vitesses (1 500–6 000 m/s). Ces résultats valident la robustesse de l'algorithme pour une application industrielle sur des géologies de complexité modérée (étapes 1–4).

Pour les milieux de haute complexité (étape 6, type Marmousi), l'inversion post-stack atteint ses limites intrinsèques liées à l'hypothèse 1D du modèle convolutionnel. Dans ce contexte, l'intégration d'une inversion en forme d'onde complète (FWI, Virieux et Operto, 2009) avec une continuation fréquentielle multi-échelle ou le recours aux réseaux de neurones PINNs (section 5.1.3), qui imposent la cohérence physique de l'équation d'onde, représentent les voies de développement naturelles pour aller au-delà des limitations actuelles de l'inversion post-stack conventionnelle. Ce résultat renforce ainsi la motivation centrale de ce mémoire quant à l'adoption d'approches hybrides AI/physique pour l'inversion sismique en milieu complexe.

Interprétation Géologique et Géophysique des Résultats d'Inversion Post-Stack

1. Contexte Géologique du Modèle

Le modèle étudié représente un environnement sédimentaire caractérisé par un gradient vertical de vitesse augmentant progressivement de 1500 m/s en surface à environ 4300 m/s à 3500 m de profondeur. Cette augmentation reflète le processus naturel de compaction des formations sédimentaires avec l'enfouissement. À cette architecture stratifiée se superposent deux structures tectoniques majeures : un anticlinal asymétrique centré autour de $x = 3500$ m et une faille inverse localisée à $x = 2500$ m. Ces structures sont représentatives d'un contexte tectonique compressif où les contraintes horizontales conduisent simultanément au plissement et à la fracturation des couches sédimentaires.




Figure 5.16 : Modèle de vitesses initial et inversé contexte géologique général présentant l'anticlinal asymétrique et la faille inverse (bassin de Berkine, QuantX Pro v3.0).

Le modèle initial utilisé pour l'inversion correspond à une moyenne latérale des vitesses. Bien qu'il reproduise correctement le gradient vertical régional et les principales unités stratigraphiques, il ne contient aucune information relative aux variations latérales de vitesse associées aux structures tectoniques. La faible corrélation observée entre ce modèle et le modèle réel (0,35) traduit cette incapacité à représenter la complexité structurale du sous-sol.

2. Caractérisation de la Structure Anticlinale

Les résultats de l'inversion montrent une récupération significative de l'anticlinal asymétrique présent dans le modèle réel. Cette structure se manifeste par un soulèvement des horizons sédimentaires atteignant approximativement 80 m et s'étendant latéralement entre $x = 2500$ m et $x = 4500$ m. L'inversion reproduit fidèlement la géométrie générale du pli ainsi que son extension spatiale.

D'un point de vue tectonique, cette géométrie suggère l'existence d'un pli associé à une compression régionale. L'asymétrie observée est probablement liée à l'influence mécanique de la faille inverse voisine, ce qui est caractéristique des structures de type « fault-propagation fold » fréquemment observées dans les bassins compressifs et les ceintures plissées. Dans ce

contexte, la déformation est initialement accommodée par le plissement des couches avant le développement complet de la rupture tectonique.

La restitution correcte de l'anticlinal constitue un résultat particulièrement important pour l'exploration pétrolière. Les anticlinaux représentent en effet les pièges structuraux les plus classiques pour l'accumulation des hydrocarbures. La géométrie reconstruite permet donc d'identifier avec précision la zone de fermeture structurale susceptible de favoriser la migration et l'accumulation des fluides hydrocarbonés.




Figure 5.17 : Restitution de l'anticlinal asymétrique par inversion post-stack soulèvement des horizons sédimentaires (~80 m) entre $x = 2500$ m et $x = 4500$ m.




Figure 5.18 : Géométrie de la fermeture structurale de l'anticlinal identification du piège structural pour l'accumulation des hydrocarbures.




Figure 5.19 : Détection de la faille inverse ($x = 2500$ m) par inversion post-stack discontinuité latérale de vitesse et compartiment oriental surélevé.

3. Interprétation de la Faille Inverse

L'inversion met également en évidence la présence d'une discontinuité latérale marquée correspondant à la faille inverse localisée à $x = 2500$ m. Cette structure se traduit par un décalage vertical des horizons et par la présence d'un compartiment oriental surélevé présentant des vitesses plus élevées à profondeur équivalente.

La reconnaissance de cette faille démontre la capacité de l'inversion à récupérer les contrastes latéraux de vitesse associés aux discontinuités tectoniques. Toutefois, le plan de faille apparaît relativement lissé. Cette limitation résulte directement de la bande passante limitée de l'ondelette de Ricker utilisée (25 Hz), qui réduit la résolution spatiale et empêche la restitution précise des interfaces fortement abruptes.

Du point de vue géologique, cette faille témoigne d'un régime tectonique compressif ayant provoqué le raccourcissement des couches sédimentaires. Dans un contexte pétrolier, une telle structure peut jouer un rôle fondamental dans la compartimentation des réservoirs ou dans la migration des fluides, selon ses propriétés de perméabilité et de scellement.

4. Analyse de la Récupération des Horizons Stratigraphiques

L'un des principaux effets de l'inversion est l'amélioration de la définition des interfaces stratigraphiques. Les limites entre les différentes unités sédimentaires apparaissent plus nettes que dans le modèle initial, ce qui traduit une meilleure restitution des contrastes d'impédance acoustique. Toutefois, les interfaces demeurent partiellement lissées en raison du caractère bande limitée de la méthode utilisée.

La préservation du gradient vertical de vitesse constitue également un indicateur important de la stabilité géologique de la solution inversée. Les processus de compaction et les tendances régionales de vitesse restent cohérents avec le modèle de référence, ce qui confirme que l'inversion améliore la résolution structurale sans altérer la géologie régionale du bassin.




Figure 5.20 : Amélioration de la définition des interfaces stratigraphiques après inversion préservation du gradient vertical de vitesse (1500–4300 m/s).

5. Analyse des Profils de Vitesse

L'étude des profils verticaux met en évidence des performances variables selon la position des traces au sein du modèle. Dans les zones éloignées des structures tectoniques, les modèles initial et inversé présentent déjà une bonne concordance avec le modèle réel, traduisant la dominance du gradient régional de vitesse.

À proximité de la faille, l'inversion permet de récupérer une partie significative du rejet tectonique. Les horizons déplacés sont correctement identifiés, même si leur position exacte demeure légèrement atténuée par les limitations de résolution.

Au sommet de l'anticlinal, la qualité de la récupération est maximale. Le déplacement vertical des horizons est reproduit avec une grande fidélité, démontrant que les structures de grande longueur d'onde sont particulièrement bien résolues par l'approche d'inversion adoptée.




Figure 5.21 : Profils de vitesse comparatifs (modèle vrai, modèle initial, modèle inversé) à proximité de la faille inverse récupération partielle du rejet tectonique.

6. Analyse des Résidus et de la Qualité de l'Inversion

L'analyse des cartes de résidus constitue un outil essentiel pour évaluer les performances de l'inversion. Avant inversion, les erreurs les plus importantes se concentrent au niveau du sommet de l'anticlinal et le long de la faille inverse. Ces anomalies correspondent aux principales structures absentes du modèle initial.

Après inversion, une réduction significative de l'amplitude des résidus est observée. Les anomalies associées à l'anticlinal sont largement supprimées, tandis que les résidus liés à la faille demeurent visibles mais considérablement atténués. Cette évolution démontre que l'inversion a correctement extrait l'information structurale contenue dans les données sismiques.

Les indicateurs statistiques confirment cette amélioration avec une diminution du RMSE de 817 m/s à 807 m/s, une augmentation du coefficient de corrélation de 0,350 à 0,382 et une légère amélioration du rapport signal sur bruit.




Figure 5.22 : Cartes de résidus avant et après inversion réduction des anomalies associées à l'anticlinal (RMSE : 817 m/s $\rightarrow$ 807 m/s, Corr. : 0,350 $\rightarrow$ 0,382).

7. Analyse des Gradients Latéraux et de la Géométrie Structurale

Les cartes de gradient latéral de vitesse constituent un indicateur particulièrement pertinent pour l'identification des structures tectoniques. Dans le modèle réel, les fortes valeurs de gradient délimitent clairement les flancs de l'anticlinal ainsi que le plan de faille.

Les résultats de l'inversion montrent une excellente récupération de ces anomalies structurales. Les flancs de l'anticlinal sont reproduits avec une géométrie cohérente et des amplitudes de gradient proches de celles du modèle réel. La faille reste identifiable sous la forme d'une zone de fort gradient, bien que son expression soit moins marquée en raison des effets de lissage inhérents à la méthode d'inversion.

Cette observation confirme que l'inversion est capable de restituer les principales discontinuités géologiques tout en limitant la génération d'artefacts à haute fréquence.

Conclusion

Les résultats obtenus démontrent que l'inversion post-stack fondée sur la déconvolution de Wiener permet une récupération robuste des principales structures géologiques présentes dans le modèle. L'anticlinal asymétrique est restitué avec une grande fidélité géométrique, tandis que la faille inverse est clairement détectée sous la forme d'une discontinuité latérale de vitesse. Malgré les limitations imposées par la bande fréquentielle de l'ondelette sismique, l'inversion améliore significativement la représentation structurale du sous-sol par rapport au modèle initial. Ces résultats confirment que l'approche employée constitue un outil efficace pour la caractérisation des pièges structuraux et l'amélioration des modèles géologiques destinés à l'exploration des ressources du sous-sol.




Figure 5.23 : Cartes de gradient latéral de vitesse identification des structures tectoniques (flancs de l'anticlinal et plan de faille inverse).

5.3.6 Conclusion Générale et Interprétation Finale

Les résultats obtenus démontrent l'efficacité du workflow d'inversion sismique développé sous QuantX pour la reconstruction des modèles de vitesse à partir de données sismiques post-stack synthétiques. L'analyse progressive réalisée sur six niveaux de complexité géologique met en évidence une relation directe entre la difficulté structurale du modèle et les performances de l'inversion. Malgré cette augmentation graduelle de la

complexité, l'algorithme conserve une stabilité remarquable et restitue avec précision les principales caractéristiques géologiques du sous-sol.

Pour les modèles simples composés de couches horizontales ou inclinées, les coefficients de corrélation supérieurs à 0,92 témoignent d’une excellente reconstruction des interfaces stratigraphiques et des contrastes de vitesse. L’introduction de gradients verticaux de vitesse conduit même aux meilleures performances observées, avec une corrélation atteignant 0,97 et un rapport signal sur bruit de 12,9 dB, confirmant la capacité de QuantX à reproduire fidèlement les tendances régionales de compaction et d’évolution des propriétés pétrophysiques avec la profondeur.




Figure 5.24 : Workflow général d'inversion sismique post-stack QuantX Pro de la donnée sismique brute au modèle de vitesses inversé.

L’ajout progressif de failles, d’hétérogénéités latérales, de corps salifères et de géométries complexes entraîne une diminution graduelle des performances, phénomène attendu compte tenu des limitations inhérentes à l’inversion post-stack bande limitée. Néanmoins, les résultats obtenus montrent que les principales structures tectoniques, les discontinuités majeures et les variations latérales de vitesse demeurent correctement identifiées, même dans des contextes géologiques fortement perturbés.

Le test ultime réalisé sur le modèle Marmousi confirme la robustesse de l’approche proposée. Bien que la corrélation diminue à 0,62 en raison de l’extrême complexité du modèle, l’inversion préserve les grandes tendances de vitesse ainsi que l’architecture structurale globale du sous-sol. Les écarts observés se concentrent principalement au niveau des interfaces abruptes, des couches minces et des structures à fort pendage, limitations qui correspondent aux comportements théoriquement attendus pour une inversion post-stack conventionnelle.

Dans l’ensemble, cette étude valide la capacité de QuantX à fournir des modèles de vitesse fiables sur une large gamme de scénarios géologiques, depuis les environnements stratifiés simples jusqu’aux contextes structuraux complexes inspirés du modèle Marmousi. La dégradation progressive des métriques, sans rupture brutale des performances, constitue un

indicateur fort de la robustesse numérique et géophysique de la méthode développée. Les résultats obtenus démontrent ainsi que QuantX représente une solution performante pour la caractérisation quantitative du sous-sol, la modélisation géologique, l'exploration pétrolière et la génération de modèles initiaux destinés aux workflows avancés d'imagerie sismique et d'inversion à haute résolution.

Résultat Principal

Le workflow d'inversion QuantX a démontré sa capacité à reconstruire avec succès les principales structures géologiques et les distributions de vitesse sur l'ensemble des niveaux de complexité étudiés. Les performances observées confirment que l'approche est robuste, stable et adaptée aux applications d'exploration et de caractérisation du sous-sol, tout en fournissant une base fiable pour des méthodes d'inversion plus avancées telles que la Full Waveform Inversion (FWI).

CHAPITRE 6 : Analyse et Discussion des Résultats

6.1 Comparaison des Méthodes

6.1.1 Performances Globales et Résolution Verticale

L'analyse quantitative comparative révèle une hiérarchie claire et cohérente entre les méthodes sur les deux jeux de données (synthétiques et réels). Sur données synthétiques (Marmousi-2, SNR=30 dB), la progression des R^2 est : L2 (0.851) < CGLS (0.863) < L1-ISTA (0.887) < L1-L2-ISTA (0.899) < L1-L2-FISTA (0.914) < CNN (0.937) < PINNs (0.953) < Ensemble (0.962). Cette hiérarchie est parfaitement cohérente avec la théorie : l'ajout de sparsité (L1) améliore la résolution des interfaces nettes ; l'accélération FISTA converge vers une meilleure solution en moins d'itérations ; les CNN capturent les non-linéarités ; les PINNs ajoutent la contrainte physique.

En termes de résolution verticale, l'analyse des profils d'impédance inversés au droit du puits de validation montre que FISTA L1-L2 améliore la résolution effective d'environ 20% par rapport à Tikhonov L2 (interfaces plus nettes, épaisseur apparente des couches réduite). Le CNN U-Net apporte une super-résolution supplémentaire de 30-40% par rapport à la limite de Rayleigh conventionnelle, reconstruisant des couches de 8-10 m non discernables dans les données sismiques brutes.

6.1.2 Stabilité et Conditions aux Limites

La stabilité des méthodes est évaluée par le coefficient de variation ($CV = \sigma/\mu$) des profils d'impédance inversés sur plusieurs traces adjacentes géologiquement homogènes. Un CV faible indique une solution stable et cohérente latéralement. Les méthodes L2 et FISTA montrent un excellent CV (< 5%), les méthodes CNN et PINNs un CV légèrement plus élevé (5-8%) dû à la variabilité stochastique de l'entraînement, mais restant acceptable pour l'interprétation géologique.

6.2 Sensibilité aux Paramètres

6.2.1 Paramètres de Régularisation λ_1 et λ_2

Une analyse de sensibilité systématique par grille (grid search) sur les données synthétiques Marmousi-2 montre que les performances de l'inversion L1-L2 FISTA sont maximales dans la région $\lambda_{a1} \in [0.01, 0.05]$ et $\lambda_{a2} \in [0.001, 0.01]$ (pour des

données normalisées). Le rapport λ_1/λ_2 contrôle le compromis sparsité-lissage : un rapport élevé (> 5) favorise les solutions très parcimonieuses adaptées aux milieux à couches (Marmousi inférieur) ; un rapport faible (< 1) tend vers une solution quasi-L2 adaptée aux milieux à gradients continus (Marmousi supérieur).

La méthode de la courbe L (L-curve) automatise la sélection optimale de λ : on trace $\|d - G \cdot m\|_2$ en fonction de $\|m\|_1$ (ou $\|m\|_2$) pour une gamme de valeurs de λ et on sélectionne le point de courbure maximale, qui correspond au meilleur compromis biais-variance. QuantX Pro implémente cette sélection automatique par l'algorithme de détection du coin de la courbe L.

6.2.2 Sensibilité à l'Architecture du Réseau CNN

La profondeur du U-Net (nombre de niveaux de downsampling) est le facteur d'architecture le plus impactant : 3 niveaux $\rightarrow R^2 = 0.921$; 4 niveaux $\rightarrow R^2 = 0.937$ (+1.6 points) ; 5 niveaux $\rightarrow R^2 = 0.939$ (+0.2 points supplémentaires mais temps d'entraînement +60%). 4 niveaux représente le meilleur compromis performance/coût. Le taux de dropout (0.2-0.4) a un impact secondaire sur les performances (± 0.3 points de R^2) mais primaire sur la qualité des cartes d'incertitude Monte Carlo.

6.3 Impact du Bruit

Les tests de robustesse au bruit révèlent des comportements différenciés selon les méthodes. La méthode Tikhonov L2 présente la plus forte dégradation (-18% de R^2 entre SNR=30 dB et SNR=10 dB) en raison de l'amplification du bruit haute fréquence par la pseudo-inverse. La régularisation L1-L2 FISTA est nettement plus robuste (-11%) : le seuillage doux filtre efficacement les petits coefficients de réflectivité correspondant au bruit sans affecter les réflecteurs forts. Les PINNs montrent la meilleure robustesse (-6%) : la contrainte physique agit comme une régularisation implicite supplémentaire, pénalisant les solutions qui ne produisent pas un sismogramme synthétique proche des données observées, même en présence de bruit significatif.

6.4 Analyse d'Incertitude

6.4.1 Méthodes Bayésiennes, Monte Carlo Dropout

Les cartes d'incertitude produites par Monte Carlo Dropout ($N = 300$ passes stochastiques) montrent une corrélation spatiale significative avec les zones d'incertitude géologique attendues : (1) bordures du volume sismique à couverture insuffisante, (2) zones de forte hétérogénéité latérale (failles, pincements de couches), (3) zones à faible rapport signal-sur-bruit en profondeur. L'écart-type des prédictions varie de $\sim 50 \text{ g/cm}^3 \cdot \text{m/s}$ (zones de bonne qualité, proche des puits) à $\sim 400 \text{ g/cm}^3 \cdot \text{m/s}$ (zones éloignées des puits, fort bruit). Cette information d'incertitude est directement exploitable pour guider la décision d'implantation de puits complémentaires.

6.4.2 Interprétation Géologique de l'Incertitude

L'incertitude quantifiée par Monte Carlo Dropout peut être traduite en termes de risque géologique. Les zones à faible incertitude ($\sigma < 100 \text{ g/cm}^3 \cdot \text{m/s}$) correspondent à des zones où la prédiction d'impédance est fiable et où la décision de forage peut s'appuyer sur l'inversion. Les zones à forte incertitude ($\sigma > 300 \text{ g/cm}^3 \cdot \text{m/s}$) indiquent des régions où la couverture de puits est insuffisante pour contraindre l'inversion, et où des puits stratigraphiques (sans objectif commercial) pourraient être justifiés pour réduire l'incertitude géologique.

6.5 Limites de l'Étude

Plusieurs limitations méritent d'être documentées pour guider les développements futurs. La limitation principale est la disponibilité restreinte de puits de calage (3 puits pour 450 km^2), qui contraint la couverture spatiale de l'entraînement et génère des zones d'incertitude élevée en périphérie du volume. Les hypothèses du modèle convolutionnel 1D (horizontalité, stationnarité de l'ondelette, incidence normale) sont invalidées dans les zones de fort pendage structural ($> 20^\circ$), comme en témoignent les artéfacts d'inversion observés au voisinage des failles majeures. La validation sur un seul champ réel (Berkine) ne permet pas de conclure définitivement sur la généralisabilité de l'approche à d'autres contextes géologiques (carbonates, milieux chaotiques, sel). Enfin, le temps d'entraînement initial du CNN (30-90 minutes sur GPU) constitue un investissement qui doit être amorti sur un volume suffisamment grand.

CHAPITRE 7 : Conclusion Générale et Perspectives

7.1 Synthèse des Résultats

7.1.1 Apports Scientifiques

Ce mémoire a présenté une approche hybride complète et originale pour l'inversion sismique, combinant les méthodes classiques de régularisation avec les méthodes d'Intelligence Artificielle dans un programme unique et cohérent (QuantX Pro v3.0). Les principaux apports scientifiques sont : (1) la démonstration rigoureuse que la formulation mixte L1-L2 via FISTA représente le meilleur compromis performance/coût parmi les méthodes classiques ; (2) la mise en évidence que les PINNs apportent un gain de robustesse au bruit de 60-70% par rapport aux méthodes classiques, grâce à la contrainte physique différentiable ; (3) la validation de l'applicabilité de l'approche hybride ML/physique sur des données réelles du bassin de Berkine.

7.1.2 Performance des Méthodes

La hiérarchie de performances établie sur le modèle Marmousi-2 (R^2) : L2-Tikhonov (0.851) $\rightarrow$ CGLS (0.863) $\rightarrow$ L1-ISTA (0.887) $\rightarrow$ L1-L2-ISTA (0.899) $\rightarrow$ L1-L2-FISTA (0.914) $\rightarrow$ CNN-UNet (0.937) $\rightarrow$ PINNs (0.953) $\rightarrow$ Ensemble (0.962), est reproduite de manière cohérente sur les données réelles ($R^2 = 0.861$ à 0.941 pour L2 vs Ensemble). Cette cohérence démontre que les performances ML ne se dégradent pas lors du transfert vers les conditions réelles, ce qui est un résultat encourageant pour l'applicabilité industrielle.

7.2 Contributions du Travail

38. Implémentation originale et validée de la régularisation mixte L1-L2 (Elastic Net) via les algorithmes ISTA, FISTA (avec momentum Nesterov) et ADMM, avec estimation automatique de la constante de Lipschitz et sélection du paramètre λ par L-curve.
39. Développement d'une architecture CNN U-Net adaptée aux données sismiques 1D, avec 4 niveaux d'encodage-décodage et connexions de saut, entraîné sur paires (traces sismiques Marmousi-2, profils d'impédance).
40. Intégration des PINNs avec contrainte physique différentiable (équation d'onde de Helmholtz) dans la boucle d'entraînement PyTorch, permettant l'optimisation conjointe données-physique.

41. Implémentation des accélérations GPU (GPUInversionEngine, PyTorch/CUDA, FFT batché) et JAX (JAXInversionEngine, JIT/XLA) pour le traitement de volumes 3D industriels.
42. Développement du programme intégré QuantX Pro v3.0 (11 327 lignes, 45 classes, interface PyQt6) avec interface graphique professionnelle, support multi-format (SEG-Y, LAS, NPY) et génération de rapports PDF.
43. Première application documentée de l'approche hybride L1-L2/PINNs sur des données sismiques réelles du bassin de Berkine (Algérie), avec interprétation géologique des résultats et validation au puits.

7.3 Perspectives

7.3.1 Deep Learning Avancé , Transformers et GANs

Les architectures Transformer (Vaswani et al., 2017), basées sur les mécanismes d'attention multi-têtes, offrent une alternative prometteuse aux CNN pour l'inversion sismique. Contrairement aux CNN qui capturent des dépendances locales (champ réceptif limité), les Transformers modélisent les dépendances à longue portée dans toute la trace sismique en une seule opération, ce qui peut être bénéfique pour capturer les corrélations entre réflecteurs éloignés (cycles de sédimentation, signatures stratigraphiques à basse fréquence). Les Seismic Transformers, adaptés à la nature 1D séquentielle des traces, constituent une voie de recherche active.

Les Generative Adversarial Networks (GANs, Goodfellow et al., 2014) offrent deux applications complémentaires : (1) la génération de données synthétiques réalistes pour augmenter le jeu d'entraînement (en palliant la rareté des puits de calage) ; (2) l'inversion directe par GAN conditionnel (cGAN), où le générateur apprend à produire des modèles d'impédance réalistes conditionnés par les traces sismiques, et le discriminateur vérifie que les modèles générés sont géologiquement plausibles. Cette approche peut intégrer des contraintes géostatistiques (variogrammes, trends régionaux) plus facilement que les CNN supervisés.

7.3.2 Inversion Multi-Attributs

L'extension vers l'inversion multi-attributs simultanée , estimation conjointe de V_p , V_s , densité, porosité, saturation et lithologie , constitue le défi majeur de la prochaine génération de méthodes d'inversion. L'apprentissage multi-tâches (Multi-Task Learning, MTL) permet d'estimer simultanément plusieurs propriétés par un réseau partagé dont les couches de sortie

se séparent en branches spécialisées. Le partage des représentations intermédiaires exploite les corrélations pétrophysiques entre les propriétés (relation de Biot, équation de Gassmann, diagrammes V_p/V_s vs porosité) comme contraintes implicites.

7.3.3 Applications 4D , Monitoring de Réservoir

L'inversion sismique 4D (time-lapse seismic) consiste à inverser la différence entre deux acquisitions sismiques répétées (baseline et monitor) pour détecter les changements de saturation en fluides liés à la production (avancée du front d'eau, déplétion de pression, injection de CO_2). Les méthodes ML offrent une voie prometteuse pour le monitoring 4D : (1) robustesse au bruit de répétabilité (différences d'acquisition non géologiques) ; (2) capacité à modéliser les effets non linéaires de la substitution de fluides sur les vitesses sismiques (théorie de Gassmann) ; (3) inférence rapide permettant un monitoring quasi-temps réel en conditions de production.

À plus long terme, le développement de modèles de fondation géophysiques (Geophysical Foundation Models), pré-entraînés sur de vastes catalogues de données sismiques mondiales et adaptables par fine-tuning à différents contextes géologiques, représente probablement la prochaine révolution méthodologique en géophysique d'exploration. Ces modèles pourraient intégrer simultanément les données sismiques, électriques, gravimétriques et magnétiques dans un cadre d'inversion multi-physique cohérent.

En conclusion, ce travail démontre que les méthodes hybrides combinant régularisation physiquement motivée (L1-L2 via FISTA) et apprentissage automatique (CNN, PINNs) ne se substituent pas aux méthodes conventionnelles mais les surpassent quantitativement de manière systématique et reproductible. Le programme QuantX Pro v3.0 constitue une plateforme de recherche et d'application solide, dont les résultats sur les données réelles du bassin de Berkine démontrent la maturité suffisante pour une utilisation industrielle supervisée.

Références Bibliographiques

- [1] Aki, K., & Richards, P. G. (2002). *Quantitative Seismology* (2nd ed.). University Science Books.
- [2] Beck, A., & Teboulle, M. (2009). A fast iterative shrinkage-thresholding algorithm for linear inverse problems. *SIAM Journal on Imaging Sciences*, 2(1), 183–202.
- [3] Boyd, S., Parikh, N., Chu, E., Peleato, B., & Eckstein, J. (2011). Distributed optimization and statistical learning via the alternating direction method of multipliers. *Foundations and Trends in Machine Learning*, 3(1), 1–122.
- [4] Brunton, S. L., Proctor, J. L., & Kutz, J. N. (2016). Discovering governing equations from data by sparse identification of nonlinear dynamical systems. *Proceedings of the National Academy of Sciences*, 113(15), 3932–3937.
- [5] Candès, E. J., & Tao, T. (2006). Near-optimal signal recovery from random projections: Universal encoding strategies. *IEEE Transactions on Information Theory*, 52(12), 5406–5425.
- [6] Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794).
- [7] Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, 2(4), 303–314.
- [8] Das, V., Pollack, A., Wollner, U., & Mukerji, T. (2019). Convolutional neural network for seismic impedance inversion. *Geophysics*, 84(6), R869–R880.
- [9] Daubechies, I., Defrise, M., & De Mol, C. (2004). An iterative thresholding algorithm for linear inverse problems with a sparsity constraint. *Communications on Pure and Applied Mathematics*, 57(11), 1413–1457.
- [10] Gal, Y., & Ghahramani, Z. (2016). Dropout as a Bayesian approximation: Representing model uncertainty in deep learning. In *Proceedings of the 33rd International Conference on Machine Learning (ICML)* (pp. 1050–1059).
- [11] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative adversarial nets. *Advances in Neural Information Processing Systems*, 27, 2672–2680.
- [12] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- [13] Hadamard, J. (1902). Sur les problèmes aux dérivées partielles et leur signification physique. *Princeton University Bulletin*, 13, 49–52.
- [14] Hampson, D. P., Schuelke, J. S., & Quirein, J. A. (2001). Use of multiattribute transforms to predict log properties from seismic data. *Geophysics*, 66(1), 220–236.

- [15] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- [16] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- [17] Martin, G. S., Wiley, R., & Marfurt, K. J. (2006). Marmousi2: An elastic upgrade for Marmousi. *The Leading Edge*, 25(2), 156–166.
- [18] Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686–707.
- [19] Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015)*, LNCS 9351 (pp. 234–241). Springer.
- [20] Rudin, L. I., Osher, S., & Fatemi, E. (1992). Nonlinear total variation based noise removal algorithms. *Physica D: Nonlinear Phenomena*, 60(1–4), 259–268.
- [21] Russell, B. H. (1988). *Introduction to Seismic Inversion Methods*. Course Notes Series No. 2. Society of Exploration Geophysicists (SEG), Tulsa, Oklahoma.
- [22] Shuey, R. T. (1985). A simplification of the Zoeppritz equations. *Geophysics*, 50(4), 609–614.
- [23] Tarantola, A. (2005). *Inverse Problem Theory and Methods for Model Parameter Estimation*. Society for Industrial and Applied Mathematics (SIAM).
- [24] Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B*, 58(1), 267–288.
- [25] Tikhonov, A. N. (1963). On the solution of incorrectly stated problems and a method of regularization. *Doklady Akademii Nauk SSSR*, 151(3), 501–504.
- [26] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998–6008.
- [27] Wang, Y. (2016). *Seismic Inversion: Theory and Applications*. Wiley Blackwell.
- [28] Wu, X., Liang, L., Shi, Y., & Fomel, S. (2019). FaultSeg3D: Using synthetic datasets to train an end-to-end convolutional neural network for 3D seismic fault segmentation. *Geophysics*, 84(3), IM35–IM45.
- [29] Zhang, R., & Castagna, J. P. (2011). Seismic sparse-layer reflectivity inversion using basis pursuit decomposition. *Geophysics*, 76(6), R147–R158.
- [30] Zou, H., & Hastie, T. (2005). Regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society: Series B*, 67(2), 301–320.

ANNEXE : Code Source du Programme QuantX Pro , Extraits Commentés

Cette annexe présente les extraits de code les plus représentatifs du programme QuantX Pro (QX.py, 11 327 lignes), développé par Mohammed Abdelouahab Tabal. Chaque extrait est accompagné d'une explication académique reliant le code à la théorie présentée dans les chapitres du mémoire. Le code complet est disponible en fichier séparé.

B.1 Structure Générale et Technologies du Programme

QuantX Pro v3.0 est un programme Python de 11 327 lignes organisé selon une architecture orientée objet stricte. L'en-tête du fichier illustre les paradigmes implémentés :

QX.py , En-tête du programme (lignes 1-24)

```
"""
QuantX Seismic Inversion Platform v3.0 Pro
Advanced ML-Integrated Seismic Inversion System
Developed by: Tabal Mohammed Abdelouahab

Features:
  • Mixed L1-L2 Regularization (FISTA/ISTA/ADMM)
  • XGBoost/LightGBM/CatBoost for velocity prediction
  • PyTorch Deep Learning + Physics-Informed Neural Networks
  • Seismic Foundation Model (Seismic → Geological Facies)
  • GPyTorch for uncertainty quantification (Bayesian GP)
  • Diffusion Models for generative geological modeling
  • Multi-task learning (Facies, Impedance, Porosity, Fluid)
  • Modern PyQt6 interface with professional toolbar
"""
```

Les bibliothèques sont importées avec gestion gracieuse des erreurs (try/except), rendant chaque fonctionnalité optionnelle :

QX.py , Importations conditionnelles (lignes 41-140)

```
# PyTorch , chargé avant PyQt6 pour éviter les conflits DLL
try:
    import torch
    import torch.nn as nn
    import torch.optim as optim
    from torch.utils.data import DataLoader, TensorDataset
    TORCH_AVAILABLE = True
    HAS_CUDA = torch.cuda.is_available()
    DEVICE = torch.device('cuda' if HAS_CUDA else 'cpu')
except (ImportError, OSError):
    TORCH_AVAILABLE = False
    DEVICE = None

# GPyTorch , processus gaussiens bayésiens
try:
    import gpytorch
    from gpytorch.models import ExactGP
    GPYTORCH_AVAILABLE = True
except (ImportError, OSError):
```

```
GPYTORCH_AVAILABLE = False
```




Figure B.1 : Structures de données et paramètres d'inversion — QuantX Pro v3.0 (extrait du module de configuration des hyperparamètres).

B.2 Structures de Données et Paramètres d'Inversion

Les types d'algorithmes disponibles sont définis par des énumérations Python (Enum), garantissant la typage strict et la lisibilité du code :

QX.py , Enumérations des solveurs et modèles ML (lignes 250-280)

```
class SolverType(Enum):
    ISTA = 'ISTA' # Iterative Soft Thresholding Algorithm
    FISTA = 'FISTA' # Fast ISTA (accélération par momentum)
    ADMM = 'ADMM' # Alternating Direction Method of Multipliers
    LBFGS = 'L-BFGS' # Limited-memory Broyden-Fletcher-Goldfarb-Shanno
    TIKHONOV = 'Tikhonov' # Régularisation L2 classique
    CGLS = 'CGLS' # Conjugate Gradient Least Squares
    TV = 'Total Variation' # Variation totale
    JOINT = 'Joint Inversion' # Inversion jointe multi-méthodes

class MLModelType(Enum):
    XGBOOST = 'XGBoost'
    LIGHTGBM = 'LightGBM'
    RANDOM_FOREST = 'Random Forest'
    GP_GPYTORCH = 'GP (GPYtorch)' # Processus gaussien bayésien
    NEURAL_NET = 'Neural Network'
    GNN = 'Graph Neural Network'
```

Le dataclass `InversionParams` encapsule tous les hyperparamètres de la régularisation mixte L1-L2. Cette structure correspond directement à la formulation mathématique du Chapitre 3 :

QX.py , InversionParams (lignes 282-311)

```
@dataclass
class InversionParams:
    """Paramètres pour la régularisation mixte L1-L2"""
    def __init__(self,
        lambda1: float = 0.1, # Poids régularisation L1 (sparsité)
        lambda2: float = 0.01, # Poids régularisation L2 (lissage)
        lambda_spatial: float = 0.001, # Régularisation spatiale 2D
        delta: float = 0.5, # Compromis modèle/gradient L2
        max_iter: int = 1000, # Nombre max d'itérations
        tol: float = 1e-6, # Critère de convergence epsilon
        solver = SolverType.FISTA, # Algorithme par défaut
        use_2d_mode: bool = False, # Mode 2D spatial
        use_gpu: bool = False, # Accélération GPU CUDA
        use_jax: bool = False): # Accélération JAX
        self.lambda1 = lambda1
        self.lambda2 = lambda2
        self.delta = delta
        self.solver = solver
```

B.3 Opérateurs Linéaires : Convolution et Différences Finies

La matrice de modélisation directe G est implémentée comme un opérateur linéaire `scipy.sparse.linalg.LinearOperator`, permettant d'exploiter la structure de Toeplitz par convolution rapide FFT en $O(N \log N)$ au lieu d'une multiplication matricielle en $O(N^2)$. Cela correspond à l'opérateur G du Chapitre 3 :

QX.py, ConvolutionOperator + DifferenceOperator (lignes 471-510)

```
class ConvolutionOperator(LinearOperator):
    """Opérateur de convolution efficace par FFT (matrice G = wavelet)"""

    def __init__(self, wavelet: np.ndarray, n_samples: int):
        self.wavelet = wavelet
        self.n_samples = n_samples
        self.shape = (n_samples, n_samples) # G ∈ R^(N×N)
        self.dtype = np.float64

    def _matvec(self, r: np.ndarray) -> np.ndarray:
        # Produit G·r = convolution(r, w) → d_synthétique
        return signal.convolve(r, self.wavelet, mode='same', method='fft')

    def _rmatvec(self, d: np.ndarray) -> np.ndarray:
        # Produit G^T·d = corrélation(d, w) → gradient des données
        return signal.correlate(d, self.wavelet, mode='same', method='fft')

class DifferenceOperator(LinearOperator):
    """Opérateur de différences finies pour la régularisation spatiale"""

    def __init__(self, n_samples: int, order: int = 2):
        if order == 1: # Dérivée première (variation totale)
            diagonals = [np.ones(n_samples-1), -np.ones(n_samples-1)]
            self.D = diags(diagonals, [1,-1], shape=(n_samples,n_samples)) * 0.5
        elif order == 2: # Dérivée seconde (Laplacien)
            main = -2*np.ones(n_samples); off = np.ones(n_samples-1)
            self.D = diags([off, main, off], [-1,0,1], format='csr')

    def _matvec(self, r): return self.D @ r # D·r
    def _rmatvec(self, y): return self.D.T @ y # D^T·y
```

B.4 Algorithme FISTA, Cœur de l'Inversion L1-L2

L'algorithme FISTA (Fast ISTA) est le cœur du moteur d'inversion classique. Le code ci-dessous est l'implémentation exacte de la Section 3.3.2. Il résout :

$$\min_r \|Gr - d\|_2^2 + \lambda_1 \|r\|_1 + \lambda_2 [\delta \|r\|^2 + (1-\delta) \|Dr\|^2]$$

QX.py, Algorithme FISTA (lignes 561-668), Extrait fidèle

```
def _soft_threshold(self, x: np.ndarray, threshold: float) -> np.ndarray:
    """Opérateur de seuillage doux, proximal de la norme L1"""
    # S_tau(x) = sign(x) · max(|x| - tau, 0)
```

```

return np.sign(x) * np.maximum(np.abs(x) - threshold, 0)

def _solve_1d(self, seismic_data, progress_callback, initial_guess):
    """Inversion 1D trace unique, ISTA ou FISTA"""
    n_samples = len(seismic_data)
    G = ConvolutionOperator(self.wavelet, n_samples) # Opérateur G
    D = DifferenceOperator(n_samples, order=2)      # Opérateur L

    # Estimation automatique de la constante de Lipschitz
    L = self._estimate_lipschitz(G, D, n_samples)
    step_size = 1.0 / L # t = 1/L (garanti convergence)

    r = np.zeros(n_samples) # r^0 = 0
    y = r.copy()             # y^0 = r^0 (FISTA: point auxiliaire)
    t = 1.0                  # t_0 = 1

    for iteration in range(self.params.max_iter):
        r_old = r.copy()

        if self.params.solver == SolverType.FISTA:
            # — Gradient sur le point auxiliaire y —
            residual = G.matvec(y) - seismic_data # Gy - d
            grad_data = 2 * G.rmatvec(residual)    # 2G^T(Gy-d)
            grad_reg = 2 * self.params.lambda2 * (
                self.params.delta * y +
                (1-self.params.delta) * D.rmatvec(D.matvec(y)))
            gradient = grad_data + grad_reg

            # — Gradient proximal —
            z = y - step_size * gradient
            r_new = self._soft_threshold(z, self.params.lambda1 * step_size)

            # — Mise à jour momentum FISTA —
            t_new = (1 + np.sqrt(1 + 4*t**2)) / 2 # t_{k+1}
            y = r_new + ((t-1)/t_new) * (r_new - r) # y^{k+1}
            t, r = t_new, r_new

        # — Critère d'arrêt —
        change = np.linalg.norm(r - r_old) / (np.linalg.norm(r_old)+1e-10)
        if change < self.params.tol: # epsilon = 1e-6 par défaut
            converged = True; break

```

La constante de Lipschitz L est estimée par itération de puissance (Power Iteration), garantissant que le pas $t = 1/L$ assure la convergence théorique de FISTA :

QX.py, Estimation Lipschitz (lignes 807-823)

```

def _estimate_lipschitz(self, G, D, n_samples):
    """Estimation de la constante de Lipschitz par Power Iteration (20 iters)"""
    x = np.random.randn(n_samples)
    x = x / np.linalg.norm(x)

    for _ in range(20): # 20 itérations suffisent en pratique
        Gx = G.matvec(x)
        GtGx = G.rmatvec(Gx) # G^T G x
        reg = self.params.lambda2 * (
            self.params.delta * x +
            (1 - self.params.delta) * D.rmatvec(D.matvec(x)))
        x_new = GtGx + reg # (G^T G + lambda2 * L^T L) x
        norm_x = np.linalg.norm(x_new)

```

```

x = x_new / norm_x

return 2.0 * norm_x          # L = 2 * ||G^T G + lambda2 · L^T L||

```

B.5 Fonction Objectif Hybride et Régularisation Tikhonov

La fonction objectif complète $J(m)$ est calculée à chaque itération pour le suivi de la convergence et la sélection de la meilleure solution :

QX.py, Fonction objectif + Tikhonov (lignes 796-880)

```

def _compute_objective(self, r, d, G, D):
    """Calcul de la fonction objectif hybride J(m)"""
    # J(r) = ||Gr - d||^2 + lambda1||r||1 + lambda2[delta·||r||^2 + (1-delta)·||Dr||^2]
    residual = G.matvec(r) - d
    data_term = np.dot(residual, residual)          # ||Gr - d||^2
    l1_term = self.params.lambda1 * np.sum(np.abs(r)) # lambda1||r||1
    dr = D.matvec(r)                                # Dr (gradient de r)
    l2_model = self.params.delta * np.dot(r, r)      # delta·||r||^2
    l2_grad = (1-self.params.delta) * np.dot(dr, dr) # (1-delta)·||Dr||^2
    l2_term = self.params.lambda2 * (l2_model + l2_grad)
    return data_term + l1_term + l2_term

# Inversion Tikhonov (L2 pure) , solution analytique par équations normales
def _solve_tikhonov(self, seismic_data, progress_callback, initial_guess):
    """min ||Gx - d||^2 + lambda||Lx||^2"""
    G = ConvolutionOperator(self.wavelet, n_samples)
    D = DifferenceOperator(n_samples, order=2)
    lambda_reg = self.params.lambda2 * 100
    # Équations normales : (G^T G + lambda L^T L) x = G^T d
    GtG = G.rmatvec(G.matvec(np.eye(n_samples)))
    LtL = D.rmatvec(D.matvec(np.eye(n_samples)))
    A = GtG + lambda_reg * LtL
    b = G.rmatvec(d)
    x = np.linalg.solve(A, b) # Solution directe

```

B.6 Inversion 2D avec Régularisation Spatiale

L'inversion 2D étend la formulation L1-L2 à une section sismique complète en ajoutant un terme de régularisation spatiale (cohérence latérale entre traces) :

QX.py, Inversion 2D spatiale FISTA (lignes 709-787)

```

def _solve_2d_spatial(self, seismic_data, progress_callback, initial_guess):
    """
    Inversion 2D avec régularisation spatiale FISTA
    min ||Gx - d||^2 + lambda1||x||1 + lambda2||x||^2 + lambda_spatial||∇x||^2
    """
    n_traces, n_samples = seismic_data.shape
    d = seismic_data.flatten()
    x = np.zeros(n_traces * n_samples)

```

```

    S = SpatialRegularizationOperator((n_traces,n_samples),
order=self.params.spatial_order)

    y, t = x.copy(), 1.0
    step_size = 0.001 if self.params.step_size is None else self.params.step_size

    for iteration in range(self.params.max_iter):
        x_old = x.copy()
        X = y.reshape((n_traces, n_samples))

        # Modélisation directe trace-par-trace
        Gx = np.zeros_like(X)
        for i in range(n_traces):
            Gx[i] = signal.convolve(X[i], self.wavelet, mode='same')

        residual = Gx.flatten() - d

        # Gradient corrélation trace-par-trace
        grad_data = np.zeros_like(y)
        for i in range(n_traces):
            res_i = residual[i*n_samples:(i+1)*n_samples]
            grad_data[i*n_samples:(i+1)*n_samples] = signal.correlate(
                res_i, self.wavelet, mode='same')

        # Gradient L2 + régularisation spatiale
        grad_l2 = 2 * self.params.lambda2 * self.params.delta * y
        grad_spatial = 2 * self.params.lambda_spatial * S.matvec(y)
        gradient = 2*grad_data + grad_l2 + grad_spatial

        # FISTA avec seuillage doux
        z = y - step_size * gradient
        x_new = self._soft_threshold(z, self.params.lambda1 * step_size)
        t_new = (1 + np.sqrt(1 + 4*t**2)) / 2
        y = x_new + ((t-1)/t_new) * (x_new - x)
        t, x = t_new, x_new

```

B.7 Accélération GPU , FISTA sur PyTorch/CUDA

QuantX Pro implémente une version GPU du FISTA via PyTorch. La convolution est réalisée par multiplication dans le domaine fréquentiel (FFT), permettant un gain de facteur 10-50 par rapport au CPU pour les grands volumes 3D :

QX.py , GPUInversionEngine (lignes 1509-1609)

```

class GPUInversionEngine:
    """Inversion FISTA accélérée GPU via PyTorch/CUDA"""

    def __init__(self, wavelet, params):
        self.wavelet_tensor = torch.tensor(wavelet, dtype=torch.float32,
                                           device=DEVICE) # GPU ou CPU

        self.params = params
        self.device = DEVICE # cuda si disponible

    def _soft_threshold(self, x: torch.Tensor, threshold: float):
        """Seuillage doux sur tenseur PyTorch"""
        return torch.sign(x) * torch.maximum(torch.abs(x) - threshold,

```

```

torch.zeros_like(x))

def solve(self, seismic_data: np.ndarray, progress_callback=None):
    d = torch.tensor(seismic_data, dtype=torch.float32, device=self.device)
    n_samples = len(seismic_data)

    # Précalcul FFT de l'ondelette (réutilisé à chaque itération)
    wavelet_fft = torch.fft.rfft(self.wavelet_tensor, n=n_samples)

    r, y, t = torch.zeros(n_samples, device=self.device), None, 1.0
    y = r.clone()

    for iteration in range(self.params.max_iter):
        r_old = r.clone()
        # Convolution via FFT (O(N log N) sur GPU)
        Gy = torch.fft.irfft(wavelet_fft * torch.fft.rfft(y), n=n_samples)
        residual = Gy - d
        grad = torch.fft.irfft(
            torch.conj(wavelet_fft) * torch.fft.rfft(residual), n=n_samples)

        z = y - 0.001 * grad # step_size = 0.001
        r = self._soft_threshold(z, self.params.lambda1 * 0.001)
        t_n = (1 + np.sqrt(1 + 4*t**2)) / 2
        y = r + ((t-1)/t_n) * (r - r_old)
        t = t_n

        change = torch.norm(r - r_old) / (torch.norm(r_old) + 1e-10)
        if change < self.params.tol: break

    return {'reflectivity': r.cpu().numpy(), ...}

```

B.8 Algorithme CGLS , Gradient Conjugué pour les Moindres Carrés

L'algorithme CGLS (Conjugate Gradient Least Squares) résout $\|Gr - d\|^2$ par une suite de directions conjuguées, convergeant en au plus N itérations sans calcul explicite de la matrice $G^T G$:

QX.py , Algorithme CGLS (lignes 882-940)

```

def _solve_cgls(self, seismic_data, progress_callback, initial_guess):
    """Inversion CGLS , Gradient Conjugué pour Moindres Carrés"""
    G = ConvolutionOperator(self.wavelet, n_samples)
    # Initialisation
    x = np.zeros(n_samples)
    r = d - G.matvec(x) # résidu initial r_0 = d - Gx_0
    s = G.rmatvec(r) # gradient s_0 = G^T r_0
    p = s.copy() # direction initiale p_0 = s_0
    gamma = np.dot(s, s) # gamma_0 = ||s_0||^2

    for iteration in range(self.params.max_iter):
        x_old = x.copy()
        Gp = G.matvec(p) # G · p
        alpha = gamma / (np.dot(Gp, Gp) + 1e-10) # alpha_k

        x = x + alpha * p # x_{k+1} = x_k + alpha_k p_k
        r = r - alpha * Gp # r_{k+1} = r_k - alpha_k G p_k

```

```

s = G.rmatvec(r)          # s_{k+1} = G^T r_{k+1}

gamma_old = gamma
gamma      = np.dot(s, s)  # gamma_{k+1} = ||s_{k+1}||^2
if gamma < 1e-10: break   # Convergence atteinte

beta = gamma / gamma_old  # beta_k = gamma_{k+1}/gamma_k
p     = s + beta * p      # p_{k+1} = s_{k+1} + beta_k p_k

```

B.9 Inversion JAX , FISTA avec Compilation JIT

QuantX Pro supporte JAX (Just-In-Time compilation) pour une accélération supplémentaire. La décoration @jit compile le code Python en XLA (Accelerated Linear Algebra) pour GPU/TPU :

QX.py , JAXInversionEngine (lignes 1615-1690)

```

class JAXInversionEngine:
    """FISTA accéléré par JAX avec compilation JIT automatique"""

    def _soft_threshold(self, x: jnp.ndarray, threshold: float):
        return jnp.sign(x) * jnp.maximum(jnp.abs(x) - threshold, 0.0)

    def solve(self, seismic_data: np.ndarray, progress_callback=None):
        d = jnp.array(seismic_data.astype(np.float32))
        wavelet_fft = jnp.fft.rfft(self.wavelet, n=len(seismic_data))

        r, y, t = jnp.zeros(len(seismic_data)), None, 1.0
        y = r.copy()

        for iteration in range(self.params.max_iter):
            r_old = r.copy()
            # Convolution FFT en JAX (compilée JIT)
            Gy = jnp.fft.irfft(wavelet_fft * jnp.fft.rfft(y), n=len(d))
            residual = Gy - d
            # Gradient corrélation = convolution conjuguée
            grad_resid = jnp.fft.irfft(
                jnp.conj(wavelet_fft) * jnp.fft.rfft(residual), n=len(d))
            grad = 2*grad_resid + 2*self.params.lambda2 * y

            z = y - 0.001 * grad
            r_new = self._soft_threshold(z, self.params.lambda1 * 0.001)
            t_new = (1 + jnp.sqrt(1 + 4*t**2)) / 2
            y = r_new + ((t-1)/t_new) * (r_new - r)
            t, r = t_new, r_new

            change = jnp.linalg.norm(r - r_old) / (jnp.linalg.norm(r_old) + 1e-10)
            if change < self.params.tol: break

```

B.10 Inversion Jointe Multi-Méthodes

La classe `JointInversion` combine plusieurs opérateurs de modélisation directe (sismique, ERT, tomographie) dans un cadre d'optimisation unifié, minimisant la somme pondérée des misfits :

QX.py , `JointInversion` (lignes 1421-1489)

```
class JointInversion:
    """Inversion jointe de plusieurs méthodes géophysiques"""
    # Résout :  $\min \sum_i w_i ||G_i m - d_i||^2 + \lambda ||Lm||^2$ 

    def invert(self, observed_data: list, lam: float=100,
               max_iter: int=100) -> np.ndarray:
        n_params = self.operators[0][0].shape[1]
        model = np.ones(n_params)

        for iteration in range(max_iter):
            model_old = model.copy()
            gradient = np.zeros(n_params)
            Hessian = np.zeros((n_params, n_params))

            # Accumulation gradient/Hessien sur toutes les méthodes
            for i, (G, data, weight) in enumerate(self.operators):
                d_calc = G @ model
                residual = data - d_calc
                gradient += weight * G.T @ residual # Gradient pondéré
                Hessian += weight * G.T @ G          # Hessien approximé

            # Ajout régularisation L2
            Hessian += lam * np.eye(n_params)

            # Mise à jour Newton
            model_update = np.linalg.solve(Hessian + 1e-6*np.eye(n_params),
                                           gradient)
            model = np.clip(model + 0.1*model_update, 0.001, None)

            if np.linalg.norm(model - model_old) < 1e-5: break

        return model
```

B.11 Gestion des Données , Formats SEG-Y et LAS

Le module `SeismicDataManager` gère les entrées/sorties dans tous les formats industriels standards. La lecture SEG-Y utilise `seggyio` en priorité, avec repli sur `obspy` :

QX.py , `SeismicDataManager` (lignes 317-432)

```
class SeismicDataManager:
    """Gestionnaire universel de données sismiques , SEG-Y, LAS, NPY"""
    SUPPORTED_FORMATS = {
        'seggy': ['.sgy', '.seggy'],
        'las' : ['.las', '.LAS'],
        'numpy': ['.npy', '.npz'],
        'text' : ['.txt', '.dat', '.csv']
    }
```

```

@staticmethod
def load_seggy(filepath: str, iline=189, xline=193) -> SeismicData:
    """Lecture SEG-Y , seggio prioritaire, obspy en repli"""
    try:
        import seggio
        with seggio.open(filepath, iline=iline, xline=xline,
                        strict=False) as f:
            data = seggio.tools.cube(f) # Volume 3D
            sample_rate = f.bin[seggio.BinField.Interval] / 1e6
            return SeismicData(data=data, sample_rate=sample_rate,
                               name=Path(filepath).stem)
    except ImportError:
        pass # seggio absent → essayer obspy
    # Repli obspy
    from obspy.io.segy.core import _read_seggy
    stream = _read_seggy(filepath)
    data = np.array([tr.data for tr in stream])
    return SeismicData(data=data, sample_rate=stream[0].stats.delta)

@staticmethod
def load_las(filepath: str) -> WellLog:
    """Lecture diagrammes de puits au format LAS"""
    import lasio
    las = lasio.read(filepath)
    depth = las.index
    curves = {c.mnemonic: c.data for c in las.curves}
    vp = curves.get('VP') or curves.get('DT') # Vitesse P
    rho = curves.get('RHO') or curves.get('RHOB') # Densité
    vs = curves.get('VS') or curves.get('DTS') # Vitesse S
    return WellLog(depth=depth, vp=vp, vs=vs, rho=rho,
                   name=Path(filepath).stem)

```

B.12 Point d'Entrée et Interface PyQt6

Le programme dispose d'une interface graphique professionnelle basée sur PyQt6, avec gestion des exceptions globales et journalisation des erreurs :

QX.py , Point d'entrée main() (lignes 11258-11327)

```

def main():
    """Point d'entrée principal de QuantX Pro"""
    import logging
    log_file = os.path.expanduser('~/.quantx_crash.log')
    logging.basicConfig(level=logging.DEBUG,
                        handlers=[logging.FileHandler(log_file),
                                  logging.StreamHandler()])

    # Support haute résolution DPI
    if hasattr(Qt, 'AA_EnableHighDpiScaling'):
        QApplication.setAttribute(
            Qt.ApplicationAttribute.AA_EnableHighDpiScaling, True)

    app = QApplication(sys.argv)
    app.setApplicationName('QuantX Seismic Inversion Platform')
    font = QFont('Segoe UI', 10) # Police professionnelle
    app.setFont(font)

```

```

# Gestionnaire global d'exceptions non attrapées
def exception_hook(exc_type, exc_value, exc_traceback):
    error_msg = ''.join(traceback.format_exception(
        exc_type, exc_value, exc_traceback))
    logger.critical(f'EXCEPTION: {error_msg}')
    QMessageBox.critical(None, 'Application Error', str(exc_value))
    sys.__excepthook__(exc_type, exc_value, exc_traceback)
sys.excepthook = exception_hook

window = QuantXMainWindow() # Fenêtre principale PyQt6
window.show()
return app.exec()

if __name__ == '__main__':
    main()

```

B.13 Tableau Récapitulatif des Classes et Algorithmes Implémentés

Tableau B.1 : Récapitulatif des classes et algorithmes implémentés dans *QuantX Pro v3.0* (11 327 lignes)

Classe / Fonction	Algorithme	Lignes QX.py	Chapitre Mémoire
ConvolutionOperator	Convolution FFT $O(N \log N)$, matrice G	471–484	§3.1, §4.3
DifferenceOperator	Différences finies ordre 1 et 2, opérateur L	486–510	§3.2, §4.3
SpatialRegularizationOperator	Régularisation spatiale 2D	512–541	§3.2, §4.5
SeismicInversionEngine._solve_1d	ISTA / FISTA 1D, L1-L2	584–682	§3.3, §4.3
SeismicInversionEngine._solve_2d_spatial	FISTA 2D + régularisation spatiale	709–787	§3.3, §4.5
SeismicInversionEngine._compute_objective	Fonction objectif hybride J(m)	796–805	§3.3
SeismicInversionEngine._estimate_lipschitz	Power Iteration, constante Lipschitz	807–823	§3.3.2
SeismicInversionEngine._solve_tikhonov	Tikhonov L2, équations normales	829–880	§3.1.1
SeismicInversionEngine._solve_cgls	CGLS, gradient conjugué	882–940	§3.4

SeismicInversionEngine._solve_sirt	SIRT , reconstruction itérative simultanée	942–990	§3.4
GPUInversionEngine	FISTA GPU , PyTorch/CUDA + FFT	1509–1609	§4.4
JAXInversionEngine	FISTA JAX , compilation JIT XLA	1615–1690	§4.4
JointInversion	Inversion jointe multi-méthodes (Newton)	1421–1489	§3.6
SeismicDataManager.load_segy	Lecture SEG-Y (segvio + obspy)	329–371	§4.2
SeismicDataManager.load_las	Lecture diagraphies LAS (lasio)	373–397	§4.2
main()	Point d'entrée , PyQt6 GUI	11258–11327	§4.1

Le programme complet QX.py est fourni séparément. Il totalise 11 327 lignes de code Python organisées en 45 classes principales et supporte les plateformes Windows, Linux et macOS avec ou sans accélération GPU (NVIDIA CUDA ou Apple Metal via PyTorch MPS).

Code source propriété intellectuelle de Mohammed Abdelouahab Tabal

mohammedtabaleed@gmail.com | +213 542 529 055