



HAL
open science

**Élaboration d'un outil d'aide à la décision pour
l'estimation de l'uni longitudinal final des chaussées
intégrant les phasages de leur mise en œuvre : Une
approche combinant les réseaux de neurones artificiels et
l'analyse de données fonctionnelles issues d'auscultation**

Ayman Gourimate

► **To cite this version:**

Ayman Gourimate. Élaboration d'un outil d'aide à la décision pour l'estimation de l'uni longitudinal final des chaussées intégrant les phasages de leur mise en œuvre : Une approche combinant les réseaux de neurones artificiels et l'analyse de données fonctionnelles issues d'auscultation. Génie civil. INSA de Rennes, 2023. Français. NNT : 2023ISAR0008 . tel-04566497

HAL Id: tel-04566497

<https://theses.hal.science/tel-04566497v1>

Submitted on 2 May 2024

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

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

THESE DE DOCTORAT DE

L'INSTITUT NATIONAL DES SCIENCES
APPLIQUEES DE RENNES

ECOLE DOCTORALE N° 647
Sciences pour l'Ingénieur
Spécialité : *Génie civil*

Par

Aymane GOURIMATE

Elaboration d'un outil d'aide à la décision pour l'estimation de l'uni longitudinal final des chaussées intégrant les phasages de leur mise en œuvre.

Approche combinant Réseaux de neurones artificiels et analyse de données fonctionnelles issues d'auscultation

Thèse présentée et soutenue à Rennes, le 21/06/2023

Unité de recherche : Laboratoire de Génie Civil et Génie Mécanique

Thèse N° : 23ISAR 14 / D23 - 14

Rapporteurs avant soutenance :

Amine IHAMOUTEN Directeur de recherche - Université Gustave Eiffel
Jean-Michel LOUBES Professeur des Universités - Université Toulouse Paul Sabatier

Composition du Jury :

Présidente : Armelle CHABOT	Directrice de recherche - Université Gustave Eiffel
Examineurs : Amine IHAMOUTEN	Directeur de recherche - Université Gustave Eiffel
Jean-Michel LOUBES	Professeur des Universités - Université Toulouse Paul Sabatier
Dir. de thèse : Fekri MEFTAH	Professeur des Universités – INSA Rennes
Co-dir. de thèse : Jean-François DUPUY	Professeur des Universités – INSA Rennes
Encad. de thèse : Valerie GARES	Maitre de conférences – INSA Rennes

ÉCOLE DOCTORALE SCIENCES POUR L'INGÉNIEUR RENNES

THÈSE

Présentée devant

**L'INSTITUT NATIONAL DES SCIENCES
APPLIQUÉES DE RENNES**

Pour obtenir le grade de

DOCTEUR en GÉNIE CIVIL

par

Aymane GOURIMATE

Sujet de la thèse:

**ELABORATION D'UN OUTIL D'AIDE À LA DÉCISION POUR L'ESTIMATION
DE L'UNI LONGITUDINAL FINAL DES CHAUSSÉES INTÉGRANT
LES PHASAGES DE LEUR MISE EN ŒUVRE.
UNE APPROCHE COMBINANT LES RÉSEAUX DE NEURONES ARTIFICIELS
ET L'ANALYSE DE DONNÉES FONCTIONNELLES ISSUES
D'AUSCULTATION.**

soutenue publiquement le 21/06 Juin 2023 devant le jury composé de

Mr. Amine IHAMOUTEN	Université Gustave Eiffel	Rapporteur
Mr. Jean-Michel LOUBES	Université Toulouse Paul Sabatier	Rapporteur
Mme. Armelle CHABOT	Université Gustave Eiffel	Examinatrice
Mr. Fekri MEFTAH	Institut national des sciences appliquées de Rennes	Professeur des Universités
Mr. Jean-François DUPUY	Institut national des sciences appliquées de Rennes	Professeur des Universités
Mme. Valerie GARES	Institut national des sciences appliquées de Rennes	Maître de conférences

Table des matières

Table des matières	i
Liste des tableaux	iv
Table des figures	vi
Liste des acronymes	ix
Remerciements	xi
Résumé	1
Introduction générale	3
Problématique	5
1 État de l'art	9
1.1 Chaussée : caractérisation et indicateurs de qualité	9
1.1.1 La chaussée : une structure mécanique avec un rôle économique et social	10
La chaussée comme structure	10
La chaussée comme vecteur économique et social	11
La qualité d'usage de la chaussée	12
1.1.2 L'uni : l'indicateur de confort et de sécurité	17
Définition de l'uni	17
L'importance de l'uni et son influence sur plusieurs domaines	19
1.1.3 Mesure et caractérisation de l'uni	22
La mesure de l'uni : de la roue au laser	23
Les indicateurs de qualité de l'uni	29
1.1.4 Conclusion de la première partie :	37
1.2 Bibliographie Machine Learning :	38
1.2.1 L'apprentissage automatique :	38
L'apprentissage non-supervisé :	38

	L'apprentissage supervisé :	39
1.2.2	Modèles et algorithmes d'apprentissage supervisé pour les séries temporelles	41
	Les K-plus proches voisins (KNN) :	42
	La régression linéaire :	43
	Les machines à vecteurs de support pour régression :	45
	Les arbres binaires et leurs agrégations	47
	Les Réseaux de Neurones Artificiels (RNA) :	52
	Conclusion de la deuxième partie :	57
2	Description et exploitation des données	59
2.1	Présentation des données mesurées	59
2.2	L'impact de la réhabilitation sur l'évolution des défauts de l'uni	60
2.2.1	L'alignement des profils pré- et post-réhabilitation	60
2.2.2	L'identification et l'extraction des signatures des défauts pré- et post-réhabilitation	61
2.2.3	Étude comparative des défauts pré- et post-réhabilitation	62
2.3	L'impact de la réhabilitation en termes des énergies par bandes d'ondes (EBO) :	67
2.3.1	Description des signaux filtrés	67
2.3.2	Étude comparative des traces résiduelles pré- et post-réhabilitation par bandes d'ondes	70
	Les traces résiduelles des GO :	71
	Les traces résiduelles des MO :	72
	Les traces résiduelles des PO :	73
2.4	L'impact de la réhabilitation en termes des notes par bandes d'ondes (NBO) :	78
2.5	Conclusion :	82
3	Implémentation et benchmark de méthodes d'apprentissage supervisé de l'uni	87
3.1	Préparation des données	87
3.1.1	La superposition des profils pré- et post-réhabilitation :	88
3.1.2	Nettoyage des profils pré- et post-réhabilitation :	90
3.2	Filtrage en trois bandes d'ondes	91
3.3	Organisation des données	94
3.4	Analyse comparative des approches de prédiction	95
3.4.1	L'approche point par point :	97
	L'implémentation des modèles :	97
	L'entraînement et le test des modèles :	100
	Analyse des résultats :	101
3.4.2	L'approche séquence par séquence :	104

	L'implémentation des modèles LSTM :	106
	L'entraînement et le test des LSTM :	106
	Analyse des résultats :	108
3.5	Conclusion	110
4	Développement et implémentation d'un modèle U-RC-NET pour la prédiction de l'uni	113
4.1	U-RC-NET : l'architecture hybride	114
4.1.1	L'encodeur	116
	Les couches de convolution	116
	Les couches de maxpooling :	118
4.1.2	Le pont LSTM	119
4.1.3	Le décodeur	119
4.2	Métriques d'apprentissage et d'évaluation :	121
4.2.1	Métriques d'apprentissage :	122
4.2.2	Métriques d'évaluation	124
4.3	Entraînement de l'U-RC-NET développé :	125
4.3.1	Métriques d'apprentissage - Soft DTW vs MSE/MAE	126
4.3.2	Passage des traces résiduelles aux empreintes énergétiques	130
4.4	Test de l'U-RC-NET développé et analyse des résultats	135
4.5	Conclusion	145
	Conclusion générale et perspectives	147
A	Filtrage par bandes d'ondes	151
B	Étude paramétrique	155
	Bibliographie	157

Liste des tableaux

1.1	Bandes de longueurs d'onde de résonance en fonction de la vitesse [1]	32
1.2	Correspondance entre les EBO et les NBO [2].	34
2.1	Évolution du profil pré-réhabilitation suite au filtrage par bandes d'ondes. . . .	68
2.2	Évolution du profil post-réhabilitation suite au filtrage par bandes d'ondes. . . .	68
3.1	Résultat des tests des modèles point par point sur les trois bandes d'ondes. . . .	101
3.2	L'écart entre les notes prédites par les modèles point par point et celles réelles sur les données de test dans la bande GO.	104
3.3	L'écart entre les notes prédites par les modèles point par point et celles réelles sur les données de test dans la bande MO.	105
3.4	L'écart entre les notes prédites par les modèles point par point et celles réelles sur les données de test dans la bande PO.	105
3.5	Résultats de test du modèle LSTM sur les GO	107
3.6	Résultats de test du modèle LSTM sur les MO	107
3.7	Résultats de test du modèle LSTM sur les PO	107
3.8	L'écart entre les notes prédites par $LSTM_{GO}$ et celles réelles sur les données de test.	110
3.9	L'écart entre les notes prédites par $LSTM_{MO}$ et celles réelles sur les données de test.	110
3.10	L'écart entre les notes prédites par $LSTM_{PO}$ et celles réelles sur les données de test.	110
4.1	Les définitions des métriques d'évaluation post-apprentissage considérées	125
4.2	Résultats de test de $LSTM_{DTW_{GO}}$	126
4.3	Résultats de test de $LSTM_{DTW_{MO}}$	127
4.4	Résultats de test de $LSTM_{DTW_{PO}}$	127
4.5	L'écart entre les notes prédites par le $LSTM_{DTW_{GO}}$ et celles réelles sur les données de test.	127
4.6	L'écart entre les notes prédites par Le $LSTM_{DTW_{MO}}$ et celles réelles sur les données de test.	127
4.7	L'écart entre les notes prédites par le $LSTM_{DTW_{PO}}$ et celles réelles sur les données de test.	128
4.8	L'écart entre les notes prédites par le $LSTM_{DTW_{GO}}$ (entraîné sur les empreintes énergétiques) et celles réelles sur les données de test.	131

4.9	L'écart entre les notes prédites par Le $LSTM_{DTW_{MO}}$ (entraîné sur les empreintes énergétiques) et celles réelles sur les données de test.	132
4.10	L'écart entre les notes prédites par le $LSTM_{DTW_{PO}}$ (entraîné sur les empreintes énergétiques) et celles réelles sur les données de test.	132
4.11	Évaluation des résultats de test de l'U-RC-NET $_{GO}$ sur les GO	136
4.12	Évaluation des résultats de test de l'U-RC-NET $_{MO}$ sur les MO	136
4.13	Évaluation des résultats de test de l'U-RC-NET $_{PO}$ sur les PO	137
A.1	Les coefficients du filtre passe-bas limité à $\lambda_1 = 0.707$ m (Butterworth d'ordre 8)	153
A.2	Les coefficients du filtre passe-bas limité à $\lambda_2 = 2.828$ m (Butterworth d'ordre 8)	153
A.3	Les coefficients du filtre passe-bas limité à $\lambda_1 = 2.828$ m (Butterworth d'ordre 7)	153
A.4	Les coefficients du filtre passe-bas limité à $\lambda_2 = 11.312$ m (Butterworth d'ordre 7)	154
A.5	Les coefficients du filtre passe-bas limité à $\lambda_1 = 11.312$ m (Butterworth d'ordre 6)	154
A.6	Les coefficients du filtre passe-bas limité à $\lambda_2 = 45.248$ m (Butterworth d'ordre 6)	154

Table des figures

1.1	Terminologie des différentes couches de chaussée [3]	10
1.2	Phénomènes de résonance et d'amplification [4]	16
1.3	Les catégories des irrégularités géométriques à la surface d'une chaussée	18
1.4	Comparaison de l'évolution des fissures par fatigue : Sans surcharges dynamiques (Bleu) et avec surcharges dynamiques (Noir) [5]	20
1.5	Émissions de GES (gaz à effet de serre) sur le cycle de vie d'une chaussée urbaine dans le Missouri [6]	22
1.6	Estimation de la consommation supplémentaire de carburant due à l'interaction pneu / chaussée dans les sections d'essai des chaussées américaines [6]	23
1.7	Les dissipations énergétiques causées par l'uni et la déflexion de la chaussée [6] .	24
1.8	Principe de la remorque APL [2]	26
1.9	Fonction de transfert de l'APL [2]	27
1.10	Principe du MLPL tri-trace [2]	28
1.11	Exemple d'un profil mesuré par Unibox sur un tronçon de 2000 m et exploité par le logiciel APL2015 [7].	29
1.12	Unibox version bi-trace [8]	30
1.13	Schéma des bandes de longueurs d'ondes de résonance pour une vitesse de 90 km/h [9].	32
1.14	Exemple de profil mesuré et de son filtrage PO à un joint de reprise [7]	35
1.15	Exemple de signaux mettant en évidence une succession de défauts ponctuels dus à un arrêt prolongé du finisseur [2].	35
1.16	Détection d'un défaut périodique par l'analyse de la DSP (la courbe bleue correspond au relevé effectué dans la bande de roulement gauche et la courbe rouge à celui effectué dans la bande de roulement droite) [10].	36
1.17	Processus de l'application d'apprentissage supervisé	40
1.18	La régression par KNN :la prédiction (étoile bleue) est associée (reliée par un trait) au plus proche voisin identifié dans les données d'apprentissage. [11].	42
1.19	La structure SVR [12]	47
1.20	L'effet des deux hyperparamètres sur la régression SVR [13]	48
1.21	La construction d'un arbre binaire [14] où la variable explicative x_{ij} est notée X^j	49
1.22	Perceptron multicouche - PMC [15]	54

2.1	Aperçu des profils pré- et post- réhabilitation mesurés sur le tronçon du rechargement de l'A63.	60
2.2	L'évolution énergétique des défauts pré-réhabilitation	64
2.3	L'évolution énergétique des défauts pré-réhabilitation en fonction de leurs étendues	64
2.4	La répartition des défauts sur ces classes selon leurs étendues	65
2.5	La distribution des amplitudes post-réhabilitation mesurées et filtrées	69
2.6	La distribution des amplitudes pré-réhabilitation mesurées et filtrées	70
2.7	Les autocorrélations des profils pré- et post-réhabilitation	71
2.8	Les autocorrélations au niveau des GO	72
2.9	Les autocorrélations au niveau des MO	73
2.10	Les autocorrélations au niveau des PO	74
2.11	L'évolution énergétique des traces résiduelles GO des défauts pré-réhabilitation .	74
2.12	L'évolution énergétique des traces résiduelles GO pré-réhabilitation en fonction de leurs étendues.	75
2.13	L'évolution énergétique des traces résiduelles MO des défauts pré-réhabilitation.	75
2.14	L'évolution énergétique des traces résiduelles MO pré-réhabilitation en fonction de leurs étendues.	76
2.15	L'évolution énergétique des traces résiduelles PO des défauts pré-réhabilitation.	76
2.16	L'évolution énergétique des traces résiduelles PO pré-réhabilitation en fonction de leurs étendues.	77
2.17	L'évolution globale des NGO suite à la réhabilitation	79
2.18	le compartimentage des NGO avant travaux en fonction de leurs évolutions . . .	79
2.19	l'évolution globale des NMO suite à la réhabilitation	80
2.20	le compartimentage des NMO avant travaux en fonction de leurs évolutions . . .	81
2.21	L'évolution globale des NPO avant travaux suite à la réhabilitation	81
2.22	le compartimentage des NPO avant travaux en fonction de leurs évolutions . . .	85
2.23	L'évolution des NBO en fonction de l'amplitude des profils sinusoïdaux.	86
3.1	Exemple du décalage entre les signatures des défauts dans les profils mesurés . .	88
3.2	Aperçu des profils pré- et post- réhabilitation pré-traités superposés.	89
3.3	L'impact de la réhabilitation sur le décalage entre les signatures pré- et post-réhabilitation du défaut.	90
3.4	Exemple de nettoyage de données : identification d'un défaut amplifié.	92
3.5	Exemple des tests des modèles point par point sur les GO.	102
3.6	Exemple des tests des modèles point par point sur les MO.	102
3.7	Exemple des tests des modèles point par point sur les PO.	103
3.8	Le test du modèle LSTM _{GO} sur une séquence GO.	108
3.9	Le test du modèle LSTM _{MO} sur une séquence MO.	108
3.10	Le test du modèle LSTM _{PO} sur une séquence PO.	109
4.1	Illustration de l'architecture d'U-RC-NET développée.	117

4.2	Illustration d'une convolution transposée [16].	120
4.3	Limite de la MSE dans le cas d'une problématique de prédiction basée sur la forme [17].	122
4.4	Un exemple de DTW montre la similarité entre les séquences X et Y, toutes deux de longueur 10. L'alignement optimal est indiqué par la flèche le long des cases colorées. [18].	124
4.5	Le test du modèle $LSTM_{DTW_{GO}}$ sur une séquence GO.	129
4.6	Le test du modèle $LSTM_{DTW_{MO}}$ sur une séquence MO.	129
4.7	Le test du modèle $LSTM_{DTW_{PO}}$ sur une séquence PO.	130
4.8	Exemple des signaux GO pré- et post-réhabilitation après avoir élevé leurs amplitudes au carré.	131
4.9	Exemple des signaux MO pré- et post-réhabilitation après avoir élevé leurs amplitudes au carré.	132
4.10	Exemple des signaux PO pré- et post-réhabilitation après avoir élevé leurs amplitudes au carré.	133
4.11	Illustrations des séquences de test GO prédites par $LSTM_{DTW_{GO}}$ entraîné sur les traces résiduelles et sur les empreintes énergétiques.	133
4.12	Illustrations des séquences de test MO prédites par $LSTM_{DTW_{MO}}$ entraîné sur les traces résiduelles et sur les empreintes énergétiques.	134
4.13	Illustrations des séquences de test PO prédites par $LSTM_{DTW_{PO}}$ entraîné sur les traces résiduelles et sur les empreintes énergétiques.	134
4.14	Reconstitution des traces résiduelles à partir des empreintes énergétiques.	135
4.15	Test d'U-RC-NET $_{GO}$ sur la première séquence GO.	137
4.16	Test d'U-RC-NET $_{GO}$ sur la deuxième séquence GO.	138
4.17	Test d'U-RC-NET $_{GO}$ sur la troisième séquence GO.	138
4.18	Test d'U-RC-NET $_{GO}$ sur la quatrième séquence GO.	139
4.19	Test d'U-RC-NET $_{GO}$ sur la cinquième séquence GO.	139
4.20	Test d'U-RC-NET $_{MO}$ sur la première séquence MO.	140
4.21	Test d'U-RC-NET $_{MO}$ sur la deuxième séquence MO.	140
4.22	Test d'U-RC-NET $_{MO}$ sur la troisième séquence MO.	141
4.23	Test d'U-RC-NET $_{MO}$ sur la quatrième séquence MO.	141
4.24	Test d'U-RC-NET $_{PO}$ sur la première séquence PO.	142
4.25	Test d'U-RC-NET $_{PO}$ sur la deuxième séquence PO.	142
4.26	Test d'U-RC-NET $_{PO}$ sur la troisième séquence PO.	143
4.27	Test d'U-RC-NET $_{PO}$ sur la quatrième séquence PO.	143

Liste des acronymes

AEE	Absolute Energy Error
APL	Analyseur de Profil en Long
CNN	Convolutional Neural Network
DTW	Dynamic Time Warping
DSP	Densité Spectrale de Puissance
EBO	Energie par Bande d'Ondes
EGO	Energie des Grandes Ondes
EMO	Energie des Moyennes Ondes
EPO	Energie des Petites Ondes
G-TB	Gradient TreeBoost
GO	Grandes Ondes
IRI	International Roughness Index
KNN	K-Nearest Neighbours
LTU	Linear Threshold Unit
LSTM	Long Short-Term Memory
MDE	MeDian absolute Error
MAE	MaXimal residual Error
MLPL	MuLtiProfilomètre Longitudinal
MO	Moyennes Ondes
MSE	Mean Square Error
MXE	MaXimal residual Error
NBO	Notes par Bandes d'Ondes
NMO	Notes de Moyennes Ondes
NPO	Notes de Petites Ondes
NGO	Notes de Grandes Ondes
PO	Petites Ondes
REE	Relative Energy Error
RNA	Réseaux de Neurones Artificiels
SVR	Support vector machines for Regression
U-RC-NET	U-shaped Recurrent Convolution neural Network

Remerciements

Cette thèse s'est déroulée dans le cadre d'un partenariat tripartite sous le dispositif des conventions industrielles de formation par la recherche (CIFRE). L'encadrement académique précieux de l'Institut National des Sciences Appliquées de Rennes et la collaboration avec deux partenaires industriels de renom, Vinci Construction et Volvo, ont formé un écosystème d'une rare distinction. La synergie entre ces institutions a permis de concilier les connaissances scientifiques avancées avec les impératifs concrets du monde professionnel. Les résultats obtenus sont témoins de l'importance capitale de ces collaborations tripartites dans l'avancement de la recherche et l'innovation. Mes remerciements les plus sincères sont adressés à toutes les parties impliquées, qui ont placé leur confiance, apporté un soutien infaillible et contribué de manière inestimable à cette entreprise scientifique.

Il est de mon devoir de rendre un hommage appuyé à mes encadrants de thèse exceptionnels, Messieurs Fekri MEFTAH et Jean-François DUPUY, ainsi qu'à Madame Valerie GARES, qui ont joué un rôle primordial dans la réalisation de cette recherche. Leur expertise érudite, leur dévouement sans faille et leur encadrement éclairé ont été des éléments clés qui ont guidé et façonné ce travail académique. Leur mentorat bienveillant, empreint d'exigence intellectuelle, m'a permis de développer mes compétences et de progresser sur le chemin de la recherche scientifique. Je suis profondément reconnaissant pour leur investissement indéfectible, leur patience inébranlable et leur accompagnement bienveillant tout au long de ce parcours doctoral exigeant.

Il me tient à cœur de remercier les membres éminents du jury qui ont honoré cette soutenance de leur présence éclairée. Je souhaite tout d'abord rendre hommage à Madame Armelle CHABOT, qui a accepté avec générosité et bienveillance de jouer le rôle exigeant d'examinatrice. Je ne saurais oublier de remercier Monsieur Amine IHAMOUTEN et Monsieur Jean-François LOUBES, qui ont exercé avec maestria les fonctions de rapporteurs. A l'ensemble des membres distingués du jury, Je tiens à exprimer ma gratitude. Vos questions incisives et Vos commentaires constructifs ont stimulé un dialogue fécond.

Je suis empli d'une profonde gratitude envers Kamal BERRADA, mon encadrant au centre de recherche de Vinci construction, qui a été un pilier inestimable tout au long de cette thèse, m'accompagnant de A jusqu'à Z. Sa maîtrise incontestée du sujet, alliée à sa générosité intellectuelle, m'a permis de bénéficier de conseils avisés, de perspectives nouvelles et d'une approche novatrice dans ma recherche. Tout au long de ce parcours, Kamal a été

un vrai mentor bienveillant, attentif à mon épanouissement académique et professionnel. Il m'a guidé avec patience, m'a encouragé à persévérer face aux difficultés et m'a inspiré par son dévouement à l'excellence. Chaque étape, chaque défi rencontré a été l'occasion d'une discussion riche, nourrie par sa vision et son expérience solides dans le domaine de l'IA.

Ce travail n'aurait pas été possible sans le support de la direction technique et recherche de Vinci construction. Un grand merci à Ivan DROUADAINÉ, Frédéric DELFOSSE, Nathalie PAQUET et Bertrand POUTEAU qui ont été à l'origine du lancement de cette thèse et ont joué un rôle déterminant dans sa concrétisation jusqu'à ce jour. Leur confiance en ma capacité à mener à bien cette thèse a été le moteur de ma détermination et de mon engagement. Je tiens à souligner leur rôle prépondérant dans la réalisation de cette thèse. Leur appui financier, matériel et organisationnel a été d'une importance cruciale, en créant un environnement propice à la recherche, en facilitant l'accès aux ressources nécessaires et en favorisant les collaborations fructueuses avec les différentes parties prenantes.

Je souhaite également exprimer ma profonde gratitude envers mes collègues qui ont été présents à mes côtés, non seulement sur le plan professionnel, mais aussi sur le plan personnel, tout au long de cette aventure : Jonathan TOURAILLE (Mon Uber préféré), Thomas Giannetti, Fayçal LAHJIRI, Mustapha MASDAN, Juliette PARISOT, Valentina MUSUMECI, Louis MATHONNET et Micaelle LABICHE. Leurs encouragements constants, leurs conseils avisés et leur empathie ont été d'une aide précieuse dans les moments de fatigue, de stress ou d'incertitude.

À mes parents, gardiens bienveillants de mes rêves, à ma sœur, complice des aventures enfantines et confidente de mes aspirations, à mes cousines, compagnes de jeux inséparables et sources inépuisables de sourires, et à toute ma famille élargie, qui a tissé les fils de notre histoire commune, je dédie cette thèse...

Résumé

L'uni longitudinal caractérise l'écart entre le profil longitudinal théorique de la chaussée et celui de sa surface réelle. Ainsi, l'uni de la chaussée qualifie les dégradations de sa surface qui interfèrent avec la sécurité et le confort de ses passagers. Toutefois, cette notion reste difficilement maîtrisable surtout dans le cadre d'une réhabilitation, où le résultat obtenu dépend du niveau préexistant d'uni. En effet, la profession fait face aujourd'hui à un manque de connaissance sur l'impact de l'uni préexistant (l'état de support) sur la qualité de l'uni obtenu post-réhabilitation. Par conséquent, l'élaboration d'un modèle permettant de prédire l'impact de la réhabilitation sur l'amélioration de la chaussée reste une problématique posée à laquelle cette thèse répond avec un élément majeur d'originalité dans l'approche : développer un système apprenant pour prédire le profil post-réhabilitation à partir de celui préexistant. Ce positionnement amont (prédiction du profil post-réhabilitation) assure une estimation détaillée qui permet de cibler les zones potentiellement problématiques, en plus d'une polyvalence de l'outil quant à l'intégration a posteriori des différents indicateurs contractuels.

Après avoir élaboré un ensemble de procédures correctives suivi pour réduire les incohérences et les impertinences entre les mesures pré- et post-réhabilitation, nous proposons l'U-RC-NET : un réseau de neurones artificiels récurrents de convolution qui, grâce à son architecture innovante, est capable de traduire les mécanismes physiques d'évolution de l'uni de la chaussée. En effet, ce modèle reconnaît dans un premier temps la segmentation des séquences pré-réhabilitation par blocs monolithiques (défauts), et prédit ensuite leurs améliorations suite à la réhabilitation en estimant leurs atténuations en fonction de leurs formes. Pour ce faire, trois blocs principaux organisent l'architecture du modèle développé : le premier bloc est un encodeur qui extrait les caractéristiques des séquences d'entrée tout en réduisant leurs résolutions spatiales. Le deuxième bloc est une cellule LSTM qui génère un noyau de la séquence prédite. Enfin, le troisième bloc est le décodeur où le même niveau de résolution de la séquence d'entrée est retrouvé. Pour forcer le modèle à constituer les séquences prédites en estimant l'amélioration de chacune des formes (traces résiduelles) pré-réhabilitation présentes dans les séquences d'entrée, la fonction perte choisie pour l'apprentissage du modèle U-RC-NET est la Soft-DTW normalisée. Ce choix permet au modèle de se focaliser sur des prédictions basées sur la forme dès son entraînement.

Confronté aux données mesurées selon la méthodologie détaillée, l'U-RC-Net prédit l'évolution de l'uni par bandes d'ondes en identifiant les empreintes énergétiques des traces résiduelles préexistantes sous leurs différentes formes dans les séquences pré-réhabilitation d'entrée, et en extrayant leurs caractéristiques sous différents niveaux de résolutions pour estimer, ensuite, leurs évolutions. D'après les résultats concluants des tests, le modèle affiche des performances satisfaisantes.

Mots clés — *Réhabilitation de la chaussée, Amélioration de l'uni, Profil mesuré, Intelligence artificielle, Prédiction des séries temporelles, Apprentissage supervisé, Réseau de neurones récurrents de convolution*

Introduction générale

La chaussée est une structure qui se dégrade sous l'effet de plusieurs facteurs intrinsèques et extrinsèques variant dans l'espace et dans le temps. Ces dégradations sont d'ordres divers et peuvent se propager dans la structure pour se manifester à la surface comme défauts sous différentes formes. L'ensemble de ces irrégularités constitue l'uni de la chaussée.

Chaque défaut d'uni peut perturber, selon les fréquences d'excitation ou l'amplitude, la sécurité et le confort des passagers, voire l'usure et la consommation en carburant des véhicules. Ces défauts sont aussi la cause des phénomènes de surcharge dynamique qui accélèrent la fatigue des chaussées. La notion d'uni touche donc au cœur du métier à la fois des concepteurs de route, des fabricants de matériels et des gestionnaires des réseaux routiers.

Différents appareils ont été développés au fil des ans pour mesurer l'uni, variant selon la nature de leurs mesures et leurs techniques d'auscultation. Aujourd'hui, les dispositifs les plus répandus sont les profilomètres. Ces appareils relèvent le profil longitudinal de la chaussée en mesurant l'élévation de sa surface en fonction de la distance parcourue. Le traitement de ces mesures permet de calculer les quantificateurs d'uni des chaussées comme les Notes par Bandes d'Ondes (NBO), la Densité Spectrale de Puissance (DSP) et l'Indice de Rugosité International (IRI).

Plusieurs études ont été menées afin d'améliorer la mesure d'uni et les indices de qualité qui en découlent. Ces recherches aboutissent à des profilomètres à haut rendement ainsi qu'à des indicateurs d'uni plus sophistiqués. Par conséquent, les prescriptions d'uni, dans les cahiers de charges pour la construction ou la réhabilitation des routes, deviennent de plus en plus détaillées et précises. En effet, cette prescription d'uni peut être faite à la fois au travers d'une obligation de moyen, où le cahier des charges décrit l'organisation de l'atelier de mise en œuvre, et d'une obligation de résultat. En France, cette dernière s'exprime en termes de notes d'uni ou de niveaux de DSP à atteindre à la fin du chantier. Or, même en appliquant ces prescriptions, la qualité d'uni souhaitée après les travaux sur chantier n'est pas toujours atteinte. En fait, la notion d'uni reste difficilement maîtrisable surtout dans le cadre d'une réhabilitation, où le résultat obtenu dépend du niveau préexistant d'uni. Ceci est d'autant plus problématique étant donné qu'au cours de ces dernières années, les travaux de réhabilitation ont pris pas sur les travaux neufs. Pour relier les deux phases de travaux (pré- et post-réhabilitation) entre elles, il est nécessaire de se doter d'un outil de prédiction de

l'uni résultant (pré-réhabilitation) à partir de l'état initial de la chaussée (pré-réhabilitation). Le développement d'un modèle prédictif d'uni est donc au cœur de cet outil.

Le travail de cette thèse a pour objectif de développer un modèle apprenant qui est en mesure de prédire (estimer) le profil post-réhabilitation sur la base d'un profil pré-réhabilitation. Plus particulièrement, le modèle recherché doit être capable de retraduire les mécanismes physiques d'évolution de l'uni en établissant une association "cognitive" entre les défauts pré-existants et leurs correspondants post-réhabilitation.

Ce manuscrit de thèse s'articule autour de quatre chapitres principaux. Le premier chapitre dresse un état de l'art qui couvre deux domaines de compétences distincts, et qui se compose de facto de deux sections : d'une part, la première partie décrit les règles de l'art liés à l'uni longitudinal du point de vue du génie civil. D'autre part, la deuxième partie détaille l'état des connaissances concernant la prédiction du profil post-réhabilitation comme une série temporelle, relevant donc du domaine de l'intelligence artificielle. Le deuxième chapitre présente une analyse exploratoire des caractéristiques des mesures profilométriques pré- et post-réhabilitation de l'uni pour mettre en évidence les mécanismes de son évolution. Ce travail préparatoire a permis d'élaborer un processus de pré-traitement des profils mesurés et de se doter d'une méthodologie de prédiction en vue de l'apprentissage supervisé. Le troisième chapitre est consacré à l'implémentation des méthodes d'apprentissage supervisé qui ressortent de l'étude bibliographique présentée au premier chapitre. Il s'agit d'analyser leurs capacités à comprendre et à assimiler les spécificités de l'uni pour conserver notamment les corrélations spatiales dans les mesures profilométriques ainsi que leurs segmentations en bloc monolithique. Les limites des méthodes d'apprentissage considérées sont exposées et analysées. Le dernier chapitre est celui où le modèle développé est présenté : l'U-RC-NET. Ce réseau de neurones artificiels récurrents de convolution se compose de trois blocs principaux : le premier bloc est un encodeur qui extrait les caractéristiques des séquences d'entrée tout en réduisant leurs résolutions spatiales, à travers une succession de couches de convolution et de maxpooling. Le deuxième bloc est une cellule LSTM qui génère un noyau de la séquence prédite. Enfin, le troisième bloc est le décodeur où le même niveau de résolution de la séquence d'entrée est retrouvé. Évalué sur les données mesurées, l'U-RC-NET démontre sa capacité à restituer une séquence de sortie qui respecte les spécificités d'une mesure profilométrique, affiche des performances remarquables lors de la prédiction de l'amélioration des défauts pré-réhabilitation tout en traduisant les mécanismes physiques de l'évolution de l'uni.

Problématique

La problématique métier

Aujourd'hui, la profession fait face à un manque de connaissance sur l'impact de l'uni préexistant (l'état de support) sur la qualité de l'uni obtenu après réhabilitation. Certes, il existe des guides qui estiment le gain en matière d'uni en proposant des recommandations à suivre lors de la réalisation des travaux. Toutefois, ces estimations sont calculées à partir de la moyenne des gains en termes de notes par bandes d'ondes. Par conséquent, elles s'avèrent généralistes et incomplètes, puisque d'une part elles ne prennent pas en considération le niveau initial d'uni, et ne peuvent donc pas s'adapter au cas par cas, et d'autre part, elles ne fournissent aucune information sur l'évolution des autres indicateurs d'uni, comme la DSP. Ainsi, à l'absence d'un outil qui permet d'établir une liaison réelle entre la qualité de l'uni obtenu à l'état de support initial, l'évaluation des défauts post-réhabilitation ne se fait qu'à travers leurs impacts sur la mesure profilométrique qui n'intervient qu'après la réalisation des travaux, et ne permet donc pas d'anticiper des actions correctives.

Anticiper l'impact de la réhabilitation sur l'amélioration des défauts d'uni est un sujet qui a été abordé empiriquement. En effet, les origines multiples et non-déterministes des défauts d'uni ne permettent pas d'élaborer des approches mécanistiques fiables pour les prédire. Ceci laisse plusieurs questions posées par l'homme de l'art sans réponses claires telles que : les défauts d'uni s'amélioreront-ils en appliquant la technique de réhabilitation choisie ? sur la base de la connaissance du profil pré-réhabilitation, quel profil post-réhabilitation un environnement de réalisation permet d'atteindre ?

La réponse à cette problématique nécessite en premier lieu de disposer d'un outil d'aide à la décision qui soit en mesure d'estimer (prédire) l'uni final (post-réhabilitation) sur la base de la connaissance de l'état initial. Le développement d'un modèle de prédiction d'uni est donc au cœur de cet outil d'aide à la décision. Ce modèle se basera sur les données disponibles (de chantiers achevés) pour évaluer l'amélioration de l'uni sur la base d'un retour d'expérience.

L'objectif de la thèse

Si la mesure de l'uni a été l'objet d'attention de plusieurs textes normatifs [19, 20, 2], sa prévision a reçu moins de considération. Pourtant la prédiction précise d'uni de la chaussée

est importante pour une gestion efficace des infrastructures d'un réseau, pour la priorisation des projets et aussi pour l'établissement des actions correctives telles que la maintenance et la rénovation.

Différentes études ont été menées pour développer des modèles de prédiction d'uni longitudinal, suivant des approches empiriques ou mécanistes, qui varient en fonction des phénomènes mis en évidence et de facto des variables explicatives retenues. Par exemple, Ciavola et Mukherjee [21] ont étudié l'effet du trafic sur la dégradation de l'IRI. Lu et Tolliver [22] ont aussi analysé les effets des cycles de gel-dégel et des journées humides sur la dégradation de l'uni de la chaussée au cours de sa vie théorique. Ils ont utilisé une fonction exponentielle de l'âge de la chaussée pour représenter l'augmentation de l'IRI aux sections d'essai. Nous pouvons citer aussi l'étude de Saleh Mofreh [23] où un modèle entièrement mécaniste a été développé, qui repose sur l'analyse structurale par éléments finis pour estimer le changement de l'uni de la surface de la chaussée, en termes d'IRI, en fonction de la charge supportée. Un autre modèle mécaniste-empirique a été développé par l'association américaine des autoroutes et de transport (American Association of State Highway and Transportation Officials - AASHTO) pour prédire l'évolution de l'IRI des chaussées souples en fonction du temps, du trafic, des propriétés de ses couches ainsi que le climat [24]. Les modèles déterministes précédemment cités se basent sur les données historiques pour prédire l'évolution de l'uni. L'insuffisance de ces données est l'un des problèmes majeurs de ces modèles. Elle impacte également de manière significative la précision de leurs prédictions.

Flintsch et Chen [25] se sont penchés sur le problème de l'insuffisance des données et ont proposé l'utilisation des techniques d'apprentissage automatique (Machine learning) telles que les réseaux de neurones, les algorithmes génétiques, et les logiques floues (fuzzy control systems) pour la prédiction des performances de la chaussée. La non-linéarité intégrée dans les algorithmes d'apprentissage automatique réduit les problèmes de modèles déterministes. Dès 1994, Nii O. Attoh-Okine a montré que des réseaux neuronaux artificiels suffisamment entraînés peuvent servir de base au développement d'une prévision intelligente de l'IRI [26]. Plus tard, Kargah-Ostadi et al. ont mis au point une méthode de prédiction d'IRI pour les chaussées flexibles dans un climat humide, sur la base de la reconnaissance des formes (Pattern recognition) par les réseaux de neurones artificiels [27]. Une autre approche a été proposée par Mazari et Rodriguez en développant un modèle hybride, combinant les réseaux de neurones artificiels et des algorithmes génétiques. Cette approche hybride apporte davantage de précision dans la prédiction de l'IRI [28]. Ainsi, l'utilisation de modèles d'intelligence artificielle dans le domaine routier recèle un potentiel en matière de qualité de prédiction. Néanmoins, les modèles préexistants ne traitent que de l'évolution d'un seul indicateur global (IRI), qui plus est dans le cadre de problématiques relevant de l'estimation de la dégradation de la chaussée au cours de sa durée de vie théorique. Ces modèles sont plus employés dans le cadre de la gestion des réseaux routiers pour identifier les besoins d'entretien en déterminant la rentabilité générale de chacune des alternatives possibles. Ils ne peuvent donc pas constituer un outil de prise de décision pour prédire l'impact de la réhabilitation sur l'amélioration de la chaussée.

L'élaboration d'un modèle permettant de prédire l'impact de la réhabilitation sur l'amélioration de l'uni de la chaussée reste une problématique posée à laquelle cette thèse répond avec un élément majeur d'originalité dans l'approche : développer un système apprenant pour prédire le profil post-réhabilitation à partir de celui préexistant. Ce positionnement amont (prédiction du pseudo-profil) permet une polyvalence de l'outil quant à l'intégration a posteriori de différents indicateurs contractuels : IRI, NBO, DSP. En détail, le modèle proposé prédit le profil post-réhabilitation en estimant l'amélioration des défauts préexistants dans le profil initial, fournissant ainsi des prédictions détaillées avec une haute résolution spatiale pour cibler les sections de chaussée potentiellement problématiques. Ainsi, ce modèle évaluera le risque d'un défaut préexistant en prédisant son évolution dans la mesure profilométrique et non pas à partir de son impact sur un indicateur de qualité en particulier.

Afin d'aboutir à un tel modèle, plusieurs verrous restent à lever avant de pouvoir fournir une réponse pertinente à la problématique précédemment détaillée. Le premier verrou concerne la nature du signal issu de la mesure profilométrique : en effet, le profil d'une chaussée est un signal aléatoire pouvant présenter des corrélations spatiales liées à la présence de défauts ayant des amplitudes et des longueurs caractéristiques variables et contrastées. Il convient donc d'analyser en détails la composition du signal profilométrique afin de développer un modèle capable de les conserver dans ses prédictions. Ensuite, il convient d'élaborer un processus de traitement préparatoire du signal issu de la mesure profilométrique pour caractériser de façon objective les défauts pré-réhabilitation et ce qu'ils deviennent après la réalisation des travaux de réhabilitation. Ceci requière dans un premier temps d'établir une association entre les défauts présents dans les deux mesures (pré et post-réhabilitation), pour ensuite pouvoir les traiter dans leurs signaux de façon monolithique. Une fois cette association est établie, il est nécessaire de dévoiler l'impact de la réhabilitation sur les défauts d'uni, sur leurs différents niveaux de corrélation spatiale, afin d'adopter l'approche de modélisation capable de traduire les modalités de leurs évolution.

Chapitre 1

État de l'art

Dans ce travail de thèse, nous retrouverons à de nombreuses reprises, des notions relevant du génie civil, comme l'uni de la chaussée et la mesure de son profil, ainsi que d'autres relatives au domaine d'intelligence artificielle, comme l'apprentissage supervisé et les réseaux de neurones. Ces notions s'interfèrent mutuellement tout au long de cette étude. Il convient alors de définir un état de l'art transversal, pour couvrir les deux domaines de compétences, qui se constitue de deux parties principales : la première partie servira à présenter généralement la chaussée et sa structure, ainsi qu'à définir l'uni, la mesure profilométrique et les indices qui en découlent. La deuxième partie sera consacrée à la présentation des notions d'intelligence artificielle nécessaires pour comprendre le traitement de la mesure profilométrique comme une série temporelle, ainsi qu'à sa prédiction à l'aide des techniques d'apprentissage supervisé.

1.1 Chaussée : caractérisation et indicateurs de qualité

Cette première partie a pour objectif de définir le cadre général de cette thèse, d'un point de vue génie civil, en présentant les aspects bibliographiques liés à l'uni longitudinal de la chaussée.

Nous commençons par exposer des généralités sur la chaussée, à savoir sa structure mécanique, son rôle de catalyseur du développement socio-économique et les indicateurs pour quantifier sa qualité. Parmi ceux-ci, nous mettrons particulièrement l'accent sur l'uni de la chaussée, d'abord en le définissant, puis en exposant son impact sur la sécurité et le confort du passager, les méthodes de sa mesure et, enfin, le calcul de ses différents indices contractuels.

1.1.1 La chaussée : une structure mécanique avec un rôle économique et social

La chaussée comme structure

Des simples sentiers à la chaussée, la fonction principale d'une route est d'assurer une circulation sécurisée des passagers. Grâce à l'évolution des techniques de dimensionnement et d'exécution des travaux, les chaussées actuelles doivent également permettre une circulation confortable de leurs usagers.

D'un point de vue structurel, la chaussée est un empilement de couches constituées de différents matériaux d'épaisseur variable, chacune ayant un rôle prédéfini. Comme illustré dans la figure 1.1, la construction de la chaussée commence sur un sol terrassé, surmonté généralement par : une couche de forme, une couche d'assise et une couche de surface. Une succincte description fonctionnelle de chacune de ces couches est présentée ci-dessous [29] :

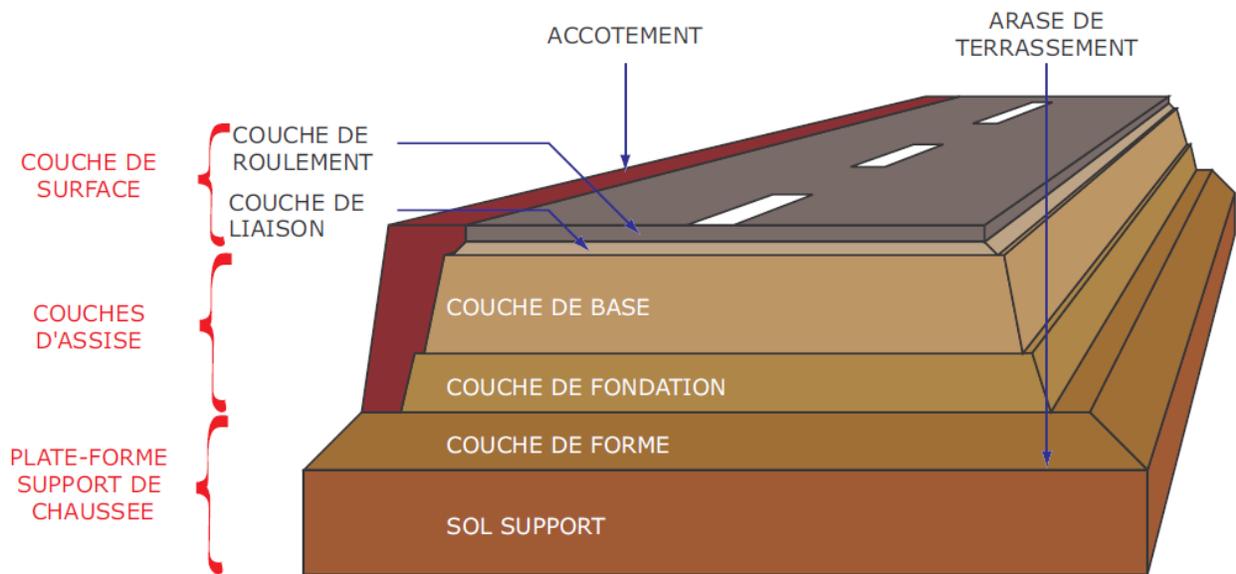


FIGURE 1.1 – Terminologie des différentes couches de chaussée [3]

La couche de forme : considérée comme une transition entre le sol support et le corps de la chaussée, cette couche a deux fonctions principales :

1. Pendant la phase des travaux : elle facilite la circulation des engins sur le chantier, en établissant un bon niveau de nivellement, tout en protégeant le sol support.

2. Au niveau de la structure : elle améliore les caractéristiques dispersées des matériaux du terrain en place, tout en le protégeant du gel.

La couche d'assise : généralement constituée d'une couche de fondation surmontée d'une autre couche de base, la couche d'assise répartit les pressions verticales sur le sol support pour maintenir les déformations dans leurs limites admissibles. La couche d'assise apporte donc la résistance nécessaire aux charges verticales induites par le trafic.

La couche de surface : Elle se compose d'une couche supérieure, appelée couche de roulement, sollicitée par les charges verticales et les actions du climat. Elle peut inclure aussi une deuxième couche appelée couche de liaison. Le rôle principal de la couche de surface est d'assurer la sécurité des usagers et le maintien de l'intégrité de la structure.

Selon le guide technique de la conception et de dimensionnement des structures de chaussée [29], plusieurs types de structure de chaussée existent sous la forme de combinaisons de différents matériaux avec leurs épaisseurs correspondantes. Ainsi, différentes familles de chaussées peuvent être distinguées : souples, bitumineuses épaisses, à assise traitée aux liants hydrauliques, à structure mixte, à structure inverse et en béton de ciments.

Plus amples détails concernant les structures de la chaussée se retrouvent dans le guide technique de la conception et de dimensionnement des structures des chaussées [29].

La chaussée comme vecteur économique et social

Selon le rapport intitulé "infrastructure pour le développement" [30], publié par la banque mondiale en 1994, il existe une forte corrélation positive entre le développement de l'infrastructure et la croissance économique des pays. En effet, plusieurs études axées sur les investissements de transports et de communications mettent en évidence l'impact de tels investissements sur l'expansion économique des régions concernées, notamment celles résumées dans la publication d'Aschauer [31]. Ces études indiquent que le développement de l'infrastructure a fait baisser les coûts de production dans les industries manufacturières en Allemagne, au Japon, au Mexique, au Royaume-Uni, en Suède et aux États-Unis. Certes, cette baisse a compensé les trois quarts des investissements consacrés aux réseaux d'autoroutes, entre les années 50 et 60, dans l'ensemble des pays précédemment cités. Or, l'efficacité de ces investissements varient en fonction du climat de l'activité économique de la région concernée, comme l'a souligné l'étude des taux de rentabilité économique de différents projets financés par la banque mondiale [30]. Cette étude indique aussi que dans les pays qui pratiquent une mauvaise politique économique ou une politique restrictive, le taux de rentabilité de leurs investissements dans l'infrastructure routière est inférieur de 50% ou plus à ce qu'il est dans un pays où les conditions économiques sont plus favorables.

L'infrastructure n'est pas qu'un paramètre essentiel dans l'équation du développement économique, mais aussi une mesure de la contribution de cette croissance au recul de la pauvreté. La banque mondiale affirme que l'amélioration des réseaux routiers contribue à augmenter les revenus et à les rendre moins précaires. En effet, l'expansion de ces réseaux permet souvent

de créer indirectement des emplois non agricoles dans les régions rurales. Elle facilite aussi l'accès à différents biens et services dans les régions urbaines. Cet accès est primordial pour les habitants des périphéries des agglomérations urbaines, qui voient leurs chances de trouver un emploi fortement dépendre du service des transports et de sa qualité. Ainsi, la banque mondiale affirme que la construction et l'entretien de certains réseaux d'infrastructure, en particulier les réseaux routiers, contribue au recul de la pauvreté en créant directement et indirectement des emplois [32].

Pour conclure, certes, il n'y a pas de consensus sur la quantification de l'impact des infrastructures sur le développement socio-économique d'un pays, ni sur le sens de la corrélation qui les relie. Or, la banque mondiale affirme que si l'infrastructure n'est le moteur de l'activité économique, elle est en du moins le véhicule.

La qualité d'usage de la chaussée

Comme précédemment établi, un réseau routier de qualité fait partie des infrastructures primordiales à la création d'un climat propice pour les investissements économiques et la croissance sociale.

En plus des qualités mécaniques que sa structure doit assurer, la chaussée doit permettre une circulation confortable à ses usagers. La qualité d'usage d'une chaussée dépend pour une large part de sa couche de surface, et se concrétise par quatre paramètres mesurables [29] : l'uni, l'adhérence, la drainabilité et la performance acoustique de la chaussée.

Dans ce qui suit, des généralités sur les trois derniers paramètres seront exposées, à savoir leurs définitions, leurs impacts sur la qualité d'usage de la chaussée et leurs principales méthodes de mesure. Quant à l'uni, la deuxième moitié de cette section lui sera consacrée.

L'adhérence :

L'adhérence d'une chaussée est définie par sa capacité à mobiliser des forces de frictions entre sa surface (revêtement) et les pneus du véhicule. Ce frottement est primordial pour la sécurité des usagers puisqu'il maintient le véhicule sur sa trajectoire quelles que soient les contraintes appliquées (accélération ou freinage). La texture du revêtement est conditionnée par la granularité de ses matériaux et son mode de mise en oeuvre. Les caractéristiques géométriques des aspérités de la texture sont variables, mais elles peuvent être découpées en deux échelles couramment utilisées [33, 34, 35] :

- La macrotexture : regroupe les aspérités visibles à l'oeil nu dont les dimensions sont comprises entre 0,1 mm et 20 mm d'amplitude verticale, et 0,5 mm et 50 mm d'étendu horizontal.
- La microtexture : définie comme les aspérités ressenties au toucher qui ont une amplitude verticale comprise entre 0,001 mm et 0,5 mm, et un étendu horizontal inférieur à 0,5 mm.[36]

Chacune de ces deux textures contribue différemment au contact pneu/chaussée.

D'une part, la microtexture intervient principalement en basses vitesses. Ses aspérités angulaires appliquent une pression pour expulser les films d'eau minces en rentrant en contact avec les pneus du véhicule. D'autre part, la macrotexture fournit un réseau de drainage, avec les sculptures du pneu, pour évacuer le bourrelet d'eau grâce à ses réservoirs communicants réduisant ainsi le risque d'aquaplanage [37, 36].

L'adhérence d'une chaussée peut être quantifiée directement par une mesure des coefficients de frottement, ou indirectement par la mesure du revêtement.

Dans le premier cas, deux coefficients doivent être distingués :

- Le coefficient de frottement longitudinal (CFL) : caractérise la friction dans la direction du mouvement du véhicule. Il influence directement la distance de freinage et impacte donc la sécurité des usagers. Plusieurs appareils proposent des mesures de ce coefficient, dont les plus courants sont le pendule SRT (Skid Resistance Tester)[38], l'ADHERA [39], Dynamic Friction Tester (DFT) [40].
- Le coefficient de frottement transversal (CFT) : mesure la friction dans la direction perpendiculaire à celle du mouvement du véhicule. Il traduit les performances d'un véhicule à négocier les virages. Le Sideway-force Coefficient Routine Investigation Machine (SCRIIM) est souvent utilisé pour la mesure de CFT [41].

Pour qualifier le revêtement, la majorité des méthodes développées mesurent la macrotexture dont les plus communes sont :

- La mesure à la tache : estime une Profondeur Moyenne de Texture (PMT), en remplissant les vides inter-granulaires du revêtement par un volume contrôlé de micro-billes étalé sous forme d'une surface circulaire [42].
- Flow Meter : qui est une méthode volumétrique pour mesurer le drainage d'eau par le réseau des réservoirs communicants de la macrotexture. Elle quantifie le risque d'aquaplanage en mesurant le temps nécessaire pour que la surface évacue un volume contrôlé d'eau[43].
- Circular Texture Meter (CTM) : qui est un dispositif de mesure sans contact, basé sur le laser, pour relever le profil d'une surface suivant un tracé circulaire de diamètre de 286 mm, avec un pas de 0.868 mm. Deux indices peuvent être calculés à partir de cette mesure : la profondeur moyenne de profil (MPD - Mean Profile Depth) et la moyenne quadratique (RMS : Root Mean Square)[44].

Le développement des techniques de laser a donné lieu à l'émergence de plusieurs dispositifs dont les niveaux de résolution et de précision sont suffisants pour atteindre la micro-texture, comme par exemple le modèle portable 9300 Laser Texture Scanner (LTS) qui est capable d'estimer les aspérités de la microtexture ayant une longueur d'onde comprise entre 0.03mm et 0.5mm. D'autres études ont évalué le déploiement des scanners laser pour une modélisation 3D de la texture. Néanmoins, cette approche reste plus coûteuse par rapport à ses précédentes [45]. Des alternatives moins onéreuses ont été développées en se basant sur la microscopie et la photogrammétrie stéréoscopique, créant ainsi une visualisation 3D de la texture, comme la technique de la photogrammétrie rapprochée (Close-range photogrammetry- CRP) [46, 47]. La méthode d'essai qui régit l'exploitation des ces mesures profilométriques de texture est

décrite par la norme EN ISO 13473. [42].

La drainabilité :

L'accumulation d'eau dans la chaussée accélère sa défaillance et altère sa qualité d'usage. En réalité, et selon une étude menée par NCHRP (National Cooperative Highway Research Program), la saturation des couches par l'eau réduit la durée de service de la chaussée de plus de la moitié. Une telle dégradation est atteinte dès lors que la couche de base sature à 10% [48]. L'évacuation d'eau est donc essentielle pour assurer l'intégrité de la structure de la chaussée et pour maintenir un niveau acceptable de ses conditions de service.

Pour ce faire, les approches proposées ne font pas consensus. Celles-ci varient d'une structure étanche, avec une couche de base de faible perméabilité, à une autre drainante ayant une couche de base perméable avec un système de drainage adapté.[49]. Ainsi, l'approche d'évacuation d'eau d'une chaussée est choisie en fonction de son environnement, ses couches structurantes et surtout des sources potentielles d'eau qui l'entourent.

La source la plus importante d'eau est constituée par les précipitations atmosphériques sous forme de pluie, de neige, de condensation ou de brouillard. Cette eau libre peut ruisseler ou stagner sur la couche de surface, s'infiltrer par la couche de la surface dans la structure ou s'infiltrer par le sol vers la structure [48].

La drainabilité de la chaussée traduit sa capacité à évacuer l'eau loin de sa structure, que ce soit par une couche de roulement qui empêche la stagnation d'eau, soit par ruissellement à travers les réseaux de la macrotecture, ou même par un drainage sous-jacent. Cette drainabilité réduit donc les projections d'eau lors du mouvement des véhicules et diminue la rétention d'eau au niveau des défauts géométriques.

Le drainage superficiel d'une chaussée est conditionné par la macrotecture du revêtement. Cependant, pour une même valeur de macrotecture, le drainage varie également en fonction du nombre d'aspérités et de leurs formes. La norme NF P 98 - 217- 1 [50] propose une méthode de mesure en continu d'un coefficient de drainabilité superficielle. Ce facteur traduit la capacité d'une surface de chaussée à évacuer l'eau sous les pneumatiques des véhicules. Il est mesuré à partir d'un patin porté par un véhicule en mouvement. En effet, ce patin est percé d'un orifice calibré par lequel s'écoule l'eau à pression constante. Ainsi le débit, mesuré entre le patin et la chaussée, caractérisera la section d'écoulement qui varie en fonction de la texture de la section auscultée. Si le revêtement est poreux, le drainage interne peut influencer le résultat de cette méthode.

Pour les couches de surface drainante, La norme NF P98-818-40 [51] décrit une méthode pour mesurer la capacité d'un revêtement à drainer l'eau : à l'aide d'un drainomètre, et dans des conditions de charge contrôlées, la conductivité hydraulique de ce revêtement est calculée à partir du temps nécessaire pour que 4 L d'eau percolent une section circulaire de revêtement. Les résultats sont relatifs puisqu'ils dépendent des dimensions du drainomètre utilisé. Cet essai peut être utilisé comme un contrôle de conformité, ou peut servir comme suivi des variations de la capacité drainante dans le temps.

L'acoustique :

La gêne la plus souvent citée par les personnes résidant à proximité des routes est le bruit causé par la circulation routière. Ce problème est de plus en plus présent étant donné l'accroissement du transport routier [52, 53]. La nuisance sonore de la circulation est donc une atteinte importante à l'environnement. En effet, l'exposition à ce bruit peut engendrer plusieurs types de problèmes sur la santé, comme les problèmes cardio-vasculaires, les troubles de sommeil, les retards de langage et de lecture chez les enfants, le stress et des effets physiologiques et comportementaux [54].

Comme illustrées dans la figure 1.2, deux sources principales sont à l'origine du bruit routier : le groupe motopropulseur (moteur, échappement) et le contact pneu / chaussée. Toutefois, le bruit de contact prédomine dès lors que la vitesse de la voiture dépasse les 40 km/h (70 km/h pour les camions). Ainsi, dans le cas d'une circulation fluide dans le milieu urbain, le contact pneu / chaussée reste la principale source du bruit routier [55]. Le bruit résultant de ce contact est la conséquence de plusieurs phénomènes physiques [4] :

- Les phénomènes vibratoires : les aspérités du revêtement en plus de la déformation de la zone contact, entre le pneu et la chaussée, génèrent des vibrations de fréquences inférieures à 1000 Hz.
- Les phénomènes de résonance : la succession de compression / détente de l'air emprisonné dans les cavités formées entre le pneumatique et la chaussée génère un bruit de fréquences voisines de 1000 Hz.
- Les phénomènes d'amplification ou l'effet de pavillon (horn effect) : à l'avant et à l'arrière du pneumatique, un dièdre est formé à cause de la réflexion du bruit entre la surface d'un pneu et la chaussée. Ce phénomène amplifie le bruit avant qu'il se propage de façon directive.
- Les phénomènes de crissement : à la zone de contact, la gomme du pneumatique adhère aux granulats du revêtement et subit une rupture d'adhérence à la sortie de cette zone. Cette succession d'adhérence/rupture d'adhérence intervient dans le domaine des fréquences supérieures à 1000 Hz.

L'évaluation du bruit routier peut suivre deux approches différentes : la mesure et la prévision. La première méthode se base sur des appareils sonores pour mesurer le bruit, tandis que la deuxième s'appuie sur les théories d'émission et de propagation du son pour simuler des situations réelles grâce aux modèles mathématiques et physiques. Dans la pratique, opter pour l'une ou l'autre de ces deux méthodes est un choix basé sur le niveau de précision des résultats requis, et aussi sur l'optimisation des coûts et de temps.

Pour la prévision du bruit, les méthodes varient selon le niveau des variables introduites, et de facto de la précision et de la fiabilité de leurs résultats. Ces méthodes peuvent être classées en trois grands groupes [52] :

- Des méthodes manuelles : qui se basent sur les modèles mathématiques du bruit de circulation. une formule générale est utilisée pour calculer le niveau de bruit de la

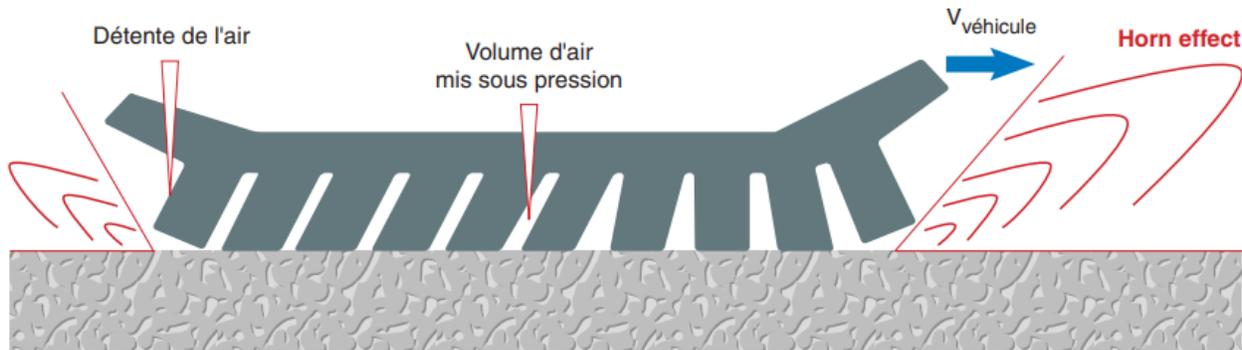


FIGURE 1.2 – Phénomènes de résonance et d'amplification [4]

circulation. Le résultat de ce calcul est généralement corrigé par des abaques et des tableaux en fonction des conditions topographiques. Différentes formules de calcul peuvent être utilisées comme "Calculation of Road Traffic Noise" (CoRTN) développée au Royaume-Uni [56], "Traffic Noise Model version 2.5" (TNM) développée aux États-Unis [57], "Acoustical Society of Japan-Road Traffic Noise" (ASJ RTN) développée au Japon [58] ou "Noise Propagation Computation Method Including Meteorological Effects" (NMPB) développée en France [59]. Dans son étude comparative [60], Simon de Lisle montre que la méthode de prédiction de CoRTN surestime le bruit (par plus de 10 dB) sur plusieurs tronçons, la méthode TNM surestime en moyenne le bruit produit par environ 2 dB, la méthode NMPB sous-estime le bruit de circulation (1 dB dans les régions rurales et 0.3 dB dans les régions urbaines) et l'ASJ RTN sous-estime considérablement le bruit de circulation. Ainsi, la méthode TNM est celle qui fournit les prédictions les plus précises.

- Les simulations par maquette : ce type de simulation permet d'obtenir des estimations détaillées à l'image des maquettes utilisées pour reproduire des situations spatiales. Cette approche nécessite une construction d'un modèle physique ad-hoc avec l'équipement expérimental sophistiqué, et reste donc une approche coûteuse qui nécessite une mobilisation de ressources considérables.
- Les simulations numériques : grâce aux programmes informatiques, les phénomènes acoustiques de propagation, de réflexion et d'absorption sont évalués pour différents scénarios topographiques. Le détail des résultats dépend de la complexité du modèle utilisé ainsi que la qualité des données d'entrée.

D'un point de vue technique, les méthodes de calcul sont préférées à celles de mesure grâce à leur faible coût et leur meilleure fiabilité. Certes, la prédiction du bruit permet de générer un grand nombre de scénarios en introduisant différents paramètres. Ceci permet éventuellement d'optimiser la conception des mesures éventuelles de réduction de bruit. Par contre, quand il s'agit d'une situation existante, comme dans le cas d'un contrôle ou d'un suivi, les méthodes

de mesure du bruit restent celles à privilégier. Ces méthodes sont régies par les organismes nationaux et internationaux de normalisation. Deux types de mesures existent : la mesure au passage et la mesure de proximité en continu [61].

La méthode au passage ou la méthode VI (véhicules isolés) mesure le niveau sonore maximal généré par le passage d'un grand nombre de véhicules, à l'aide d'un microphone situé en bord de la route à 7.5m de l'axe de la voie et à 1.2m de hauteur. Cette méthode est régie par la norme NF EN ISO 11819 [62]. Celle-ci fixe des conditions de prédominance du bruit de roulement en imposant une vitesse stable, supérieure à 45 Km/h, et en fixant un nombre minimal de mesure pour deux catégories de véhicules : 100 véhicules légers et 80 poids-lourds. Ces nombreuses restrictions rendent cette méthode lourde à mettre en oeuvre.

La mesure de proximité en continu, souvent désignée par son acronyme international CPX (Close ProXimity), consiste à mesurer le bruit émis par un pneumatique d'essais en roulement. En effet, deux microphones sont placés à proximité du contact entre le pneumatique et la chaussée, à 20 cm du flanc latéral du pneumatique, à 20 cm de l'axe de la roue et à 10 cm au dessus de la chaussée. Cette méthode est régie par la norme NF EN ISO 11819-2 [62]. Si cette méthode permet d'ausculter rapidement un grand linéaire de manière répétable, ce qui lui a valu une généralisation en Europe, sa mesure reste peu corrélée à l'exposition du riverain et peu représentative du trafic réel [61].

1.1.2 L'uni : l'indicateur de confort et de sécurité

Les indicateurs de qualité précédemment présentés caractérisent l'état de la surface dans la gamme de la texture du revêtement : microtexture, macrotecture et mégatexture (longueurs d'ondes inférieures à 0.5m). Or, d'autres irrégularités de surface peuvent exister (cf. figure 1.3) , et dont les dimensions caractéristiques sont comprises entre 0.5 m et 50 m : le domaine d'uni.

La deuxième partie de cette section présente l'uni en commençant par sa définition, pour ensuite expliciter son influence sur la chaussée et ses usagers, et finalement exposer les méthodes de sa mesure et du calcul de ses différents indices.

Définition de l'uni

En théorie, la chaussée est supposée suivre une surface courbe sans défauts de planéité. Or, dans la réalité, cette surface présente des irrégularités géométriques qui remontent à sa construction ou apparaissent ultérieurement au cours de sa vie. En effet, dès la phase des travaux, des irrégularités de surface peuvent être créées à cause de l'imperfection des méthodes et des équipements de mise en oeuvre ou de compactage. Nous distinguons deux types de ces irrégularités [2] :

- Des irrégularités ponctuelles qui impactent quelques centimètres de la chaussée, et qui se sous forme d'une concavité ou/et d'une convexité locale de la surface. Par exemple,

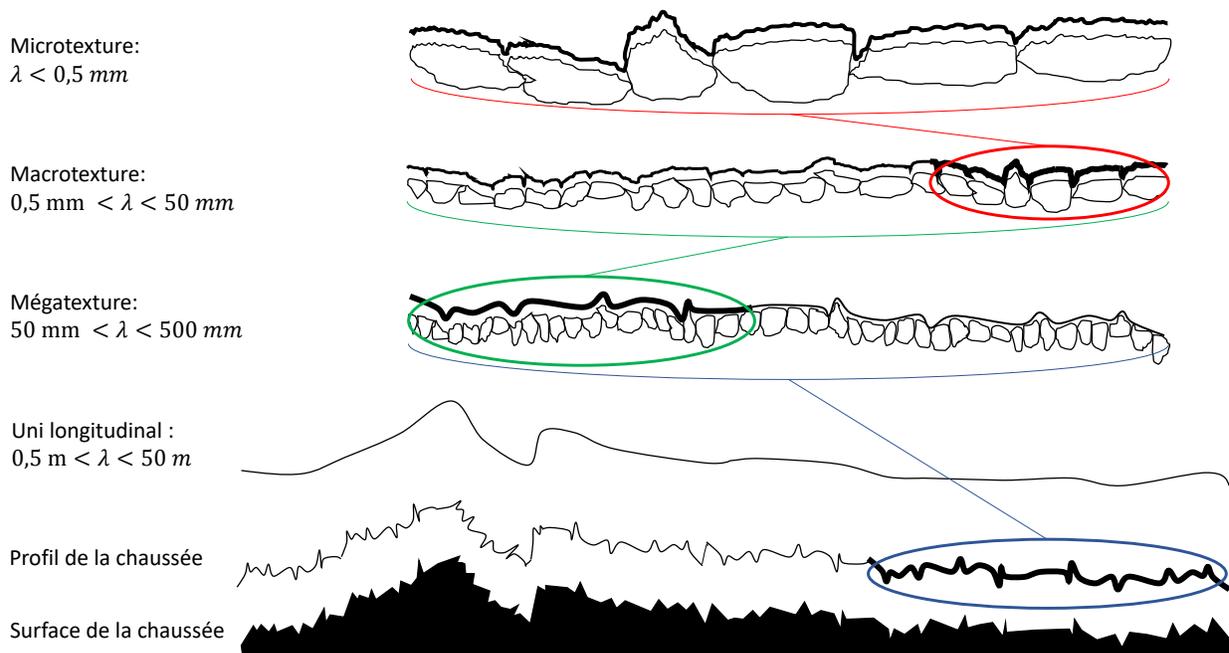


FIGURE 1.3 – Les catégories des irrégularités géométriques à la surface d'une chaussée

les défauts de joints de reprise, les arrêts prolongés du finisseur ou même des défauts copiés à cause d'un palpage sur la voie adjacente.

- Des irrégularités périodiques qui s'étalent sur plusieurs mètres, voire plusieurs kilomètres, sous forme d'ondulations de longueurs d'ondes variables :
 1. Lors de la mise en oeuvre, des dysfonctionnements matériels du finisseur (l'encrassement de sa chenille ou le pompage du vérin de sa table) ou au niveau de son guidage (notamment le guidage au fil) génèrent des défauts périodiques. Ceux-ci nuisent au confort des usagers, en particulier ceux des véhicules à empattement long.
 2. Lors du compactage, les risques de créer des défauts sont nombreux. Par exemple, un sur-compactage génère des défauts périodiques caractérisés par des faibles longueurs d'ondes.

Au cours de la vie de la chaussée, la détérioration se poursuit à cause de plusieurs facteurs extrinsèques que nous pouvons regrouper en trois catégories [63, 64, 65] :

- Les charges de trafic : qui varient en fonction de la pression, de l'essieu et de la configuration des pneus. Les effets dynamiques du véhicule, générés par sa vitesse, ainsi que le flux de trafic sont aussi des paramètres qui amplifient les charges appliquées sur la chaussée.

- Les conditions d’environnement : L’intensité des précipitations, les variations de température ou les conditions de drainage conditionnent la création et la propagation des défauts de la structure de la chaussée à sa surface, notamment dans les régions où le risque du gel / dégel est présent.

Ces facteurs extrinsèques divers se conjuguent pour donner lieu à des mécanismes de dégradation complexes qui se manifestent assez tôt durant la vie de la chaussée, ou peuvent apparaître plus tard (15 ans à 35 ans) [66, 64].

Un premier exemple des dégradations prématurées est l’ornièrre. Ces défauts apparaissent à la surface de la chaussée à cause des charges de trafic lourd, d’une faible portance du sol d’infrastructure, d’un mauvais drainage ou d’un compactage insuffisant. Le soulèvement différentiel est un autre exemple des dégradations prématurées : le gel dans un sol d’infrastructure gélif, combiné avec un mauvais drainage, cause l’apparition d’une ondulation à la surface d’une longueur d’ondes variant entre 13m à 40m [67]. Par ailleurs, des fissures transversales peuvent apparaître dans le revêtement bitumineux assez tôt aussi durant la vie de la chaussée. Elles sont dues à la contrainte appliquée par les véhicules au sens perpendiculaire du roulement. Ces fissures génèrent des distorsions de longueurs d’ondes entre 1m et 3.3m [67].

Quant aux dégradations de la fin de vie de la chaussée, deux catégories sont à distinguer selon leurs causes [66] :

- Celles causées par un vieillissement de bitume comme le faïençage, le désenrobage ou l’arrachement.
- Celles dues aux effets du gel, du dégel et du trafic lourd comme un nid-de-poule ou une pelade.

Pour résumer, la chaussée est une structure qui se dégrade sous l’effet de plusieurs facteurs intrinsèques et extrinsèques variant dans l’espace et dans le temps. Ces dégradations sont d’ordres divers et peuvent se propager dans la structure pour se manifester à sa surface comme irrégularités géométriques sous différentes formes. L’ensemble de ces irrégularités, dont les dimensions caractéristiques sont comprises entre 0.5 m et 50 m, constitue l’uni de la chaussée [2].

L’importance de l’uni et son influence sur plusieurs domaines

Au niveau mondial, une grande importance est accordée à l’uni en tant que paramètre clé dans l’équation de la qualité de service de la chaussée. Cette importance provient de ses différents impacts sur la structure de la chaussée et sur la qualité de son usage :

Les surcharges dynamiques :

La majorité des méthodes de dimensionnement considèrent que la force appliquée par les pneus sur la surface de la chaussée reste constante lors de la circulation des véhicules. Or, des études [68, 69, 70] montrent que la charge d’essieu d’un véhicule, notamment celui d’un poids lourd, est amplifiée par les défauts d’uni. Ceci provoque des surcharges dynamiques

importantes qui accélèrent la dégradation de structure, réduisant ainsi la durée de vie utile de la chaussée à la moitié (de 1,31 million passages de véhicules à 0,63 million passages de véhicules) [5], comme l'indique la figure 1.4.

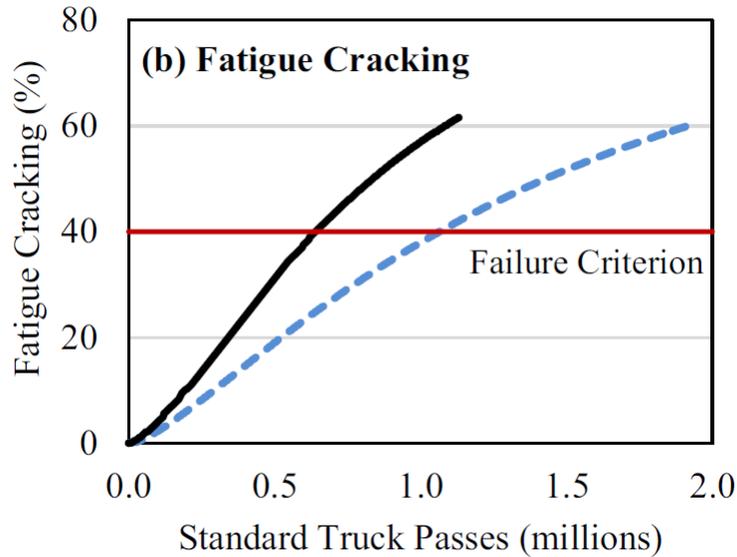


FIGURE 1.4 – Comparaison de l'évolution des fissures par fatigue : Sans surcharges dynamiques (Bleu) et avec surcharges dynamiques (Noir) [5]

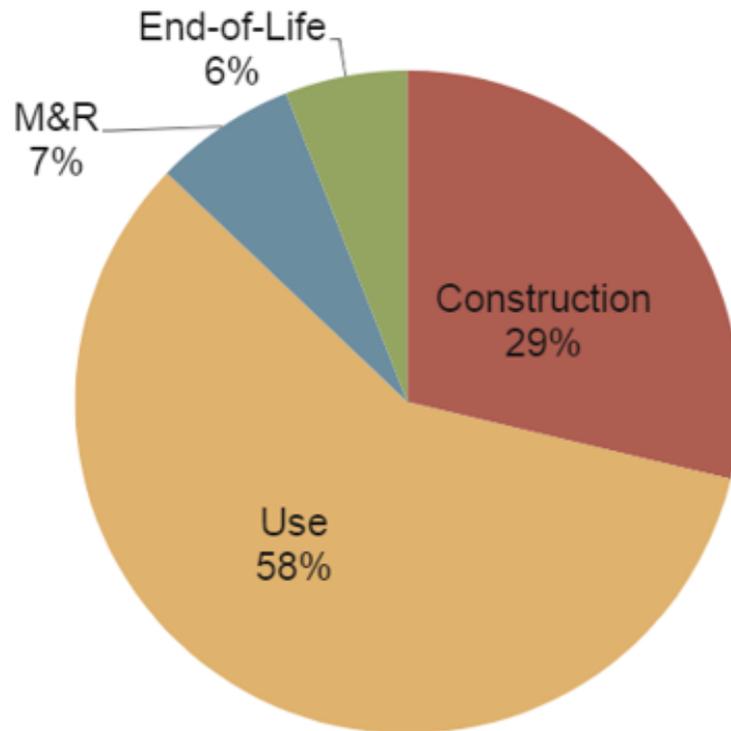
L'impact sur la sécurité et le confort de ses passagers :

En 1960, l'American Association of State Highway Office (AASHO) a montré qu'environ 95% des performances de service d'un réseau routier provenait de l'uni de sa surface, et depuis, plusieurs études ont été menées pour évaluer l'influence de l'uni sur la réponse d'un passager en quantifiant objectivement son impact via des indicateurs physiologiques : Baba Isao [71] a utilisé L'EEG (électroencéphalogramme) pour analyser les ondes cérébrales des passagers et les résultats ont montré que la fluctuation de l'EEG suit l'irrégularité de la surface, et que plus l'amplitude de l'irrégularité est importante, plus l'effet sur l'EEG est important. Fukuyama [72] a évalué le confort de conduite en utilisant la moyenne quadratique de l'accélération pondérée en fonction de la fréquence et a prouvé qu'il existe une relation entre l'uni de roulement et l'accélération des vibrations. G. Farah [73] a utilisé l'EMG (électromyogramme) pour évaluer les réactions des passagers. Il a confirmé que les accélérations latérales de la voiture engendrent un inconfort chez les passagers.

L'impact économique et écologique de l'uni

Bien que les coûts pour la construction ou la réhabilitation d'une chaussée soient importants, les coûts de son usage sont souvent plus élevés. En effet, ces derniers comprennent les multiples coûts générés lors de l'utilisation de la chaussée comme le carburant, la maintenance des véhicules ou le remplacement des pneus. Ainsi, compte tenu la diversité de leurs sources, le total de ces coûts d'usage s'accroît rapidement, surtout lorsque l'on considère l'ensemble de la flotte utilisant une chaussée sur toute sa durée de vie réelle [74]. En analysant les coûts d'usage totaux, il s'avère que le carburant en représente de 50 à 75 % [75]. En d'autres termes, toute optimisation des coûts d'usage doit passer essentiellement par une minimisation de la consommation de carburant. Au-delà de l'argument économique, cette dernière réduira aussi l'impact écologique de la chaussée. En effet, sur le cycle de vie d'une chaussée, 58% d'émissions de gaz à effet de serre (GES) proviennent de l'usage de la chaussée comme l'indique la figure 1.5, dont environ 93% sous forme de consommation de carburant [6].

Divers facteurs entraînent une augmentation de la consommation de carburant comme la chaleur des gaz d'échappement, la friction du moteur, la traînée aérodynamique ou notamment la résistance au roulement induite par l'interaction pneu / chaussée. Cette dernière engendre à elle seule un excès de consommation de carburant estimé à environ 2.6 milliards de litres aux Etats-Unis par an [6]. Cette interaction dissipe l'énergie sous trois formes : une première dissipation dans le système de suspension due au mouvement vertical du véhicule causé par les irrégularités d'uni de la chaussée, puis une deuxième au niveau des pneus due à la texture de la chaussée, et finalement une troisième dissipation d'énergie due à la déflexion de la chaussée sous la charge du véhicule. Certes les mécanismes de cette interaction interagissent régulièrement pour former une résistance au roulement. Or, leurs contributions à la dissipation énergétique totale ne sont pas égales. En réalité, les deux mécanismes prédominants sont le mouvement vertical dans le système de suspension, causé par les irrégularités d'uni, et la déflexion de la chaussée sous la charge des véhicules (cf. figure 1.5). Ainsi, en réduisant les irrégularités géométriques, une amélioration de la qualité d'uni induira moins de mouvement vertical dans le système de suspension et, de facto, réduira la consommation de carburant. Plusieurs études se sont penchées sur la quantification de l'impact d'uni sur la dissipation d'énergie en termes de consommation de carburant et d'émissions de CO₂, comme celle qui indique qu'une amélioration d'uni de 0.204 cm/m en termes d'IRI (International Roughness Index - cet indice de mesure d'uni sera expliqué dans la section suivante) entraînera une baisse de 10% de la résistance de roulement[76]. Une telle baisse de résistance réduira la consommation de carburant d'environ 1% à 2% [77], ce qui permettrait par exemple d'économiser environ 700 millions de gallons [6] de carburant par an sur l'ensemble des gallons consommés aux Etats-Unis (cf. figure 1.6).



Flexible pavement design developed by Applied Research Associates (ARA), Inc.; AADTT 8k/day; 6 lanes; Wet-freeze-MO; MEPDG-based rehabilitation schedule.

FIGURE 1.5 – Émissions de GES (gaz à effet de serre) sur le cycle de vie d'une chaussée urbaine dans le Missouri [6]

1.1.3 Mesure et caractérisation de l'uni

Au fil des ans, de nombreuses méthodes ont été mises au point pour mesurer l'uni des chaussées à l'aide de dispositifs tirant parti des progrès technologiques successifs, notamment dans les domaines de l'informatique et de l'électronique. Malgré cette diversité, aucun appareil ne peut reproduire les informations contrastées (les amplitudes et les ententes des irrégularités) du profil réel de la route. Par ailleurs, la précision de toute mesure d'uni peut être altérée par plusieurs facteurs comme la précision des capteurs, les filtres numériques sur les mesures de distance, les mesures d'accélération ou la vitesse d'auscultation de la chaussée. Ainsi, le terme pseudo-profil est souvent employé pour désigner le signal produit par les dispositifs de mesure d'uni. Cependant, pour des raisons de commodité d'écriture, le terme "profil" fera référence, comme dans la plupart des cas, à l'expression pseudo-profil. L'objectif ici n'est pas de détailler les nombreux appareils de mesure d'uni mais plutôt de présenter succinctement les principales catégories de dispositifs existants puis d'introduire la

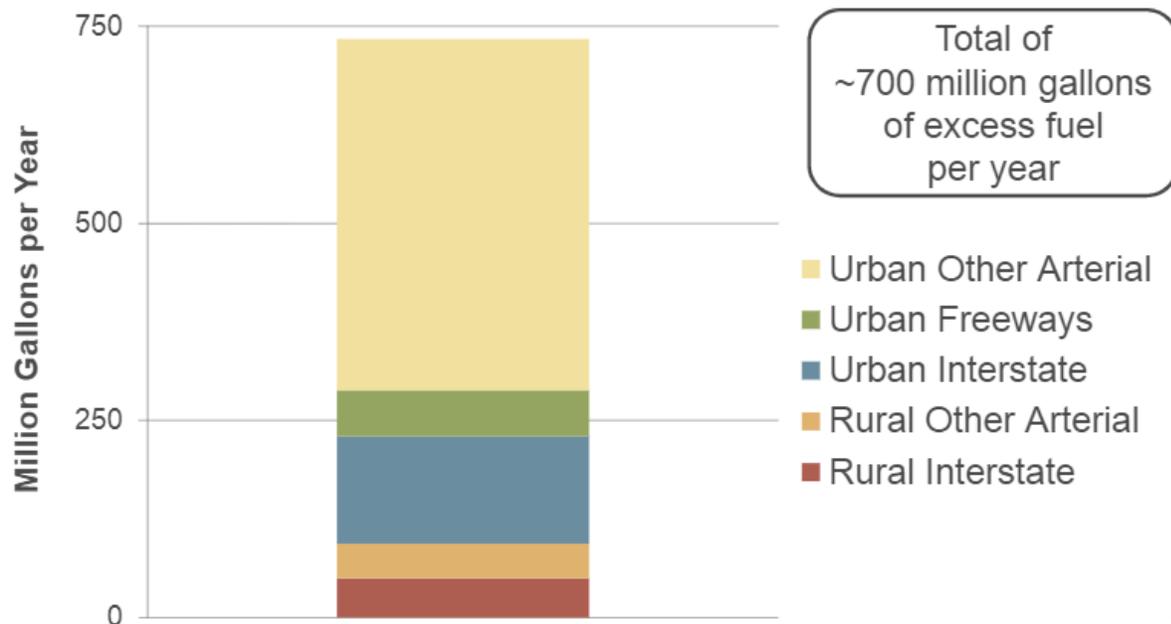


FIGURE 1.6 – Estimation de la consommation supplémentaire de carburant due à l'interaction pneu / chaussée dans les sections d'essai des chaussées américaines [6]

notion d'une mesure profilométrique, qui est la donnée clé dans ce travail de thèse, ses limites tributaires des dispositifs de mesure et le traitement pour en tirer des indicateurs de qualité d'uni.

La mesure de l'uni : de la roue au laser

Les appareils de mesure d'uni sont habituellement classés selon deux grandes catégories en fonction de leur rendement (le rapport entre la richesse de l'information et la praticité de la mesure). Ainsi, la première catégorie à distinguer comprend les systèmes de relevé statique ou quasi-statique qui déterminent les irrégularités de la surface mesurée par rapport à une géométrie ou à une position connue, comme le viagraphe, le poligraph ou les relevés topographiques. Ils peuvent garantir une précision allant jusqu'à 0.005 mm [10]. Par contre, l'inconvénient majeur de ces systèmes est qu'ils dépendent de la vitesse de déplacement de l'opérateur. Ceci implique que ces dispositifs ne peuvent être utilisés que pour l'auscultation des voies fermées afin de garantir la sécurité de leurs opérateurs. Par conséquent, les appareils à faible rendement sont rarement utilisés de nos jours pour la mesure profilométrique d'uni. Contrairement aux dispositifs précédents, les appareils à grand rendement permettent d'effectuer des auscultations à des vitesses plus élevées couvrant sur de grandes distances linéaires. Ces systèmes sont remorqués ou embarqués dans des véhicules. Ils se répartissent en deux

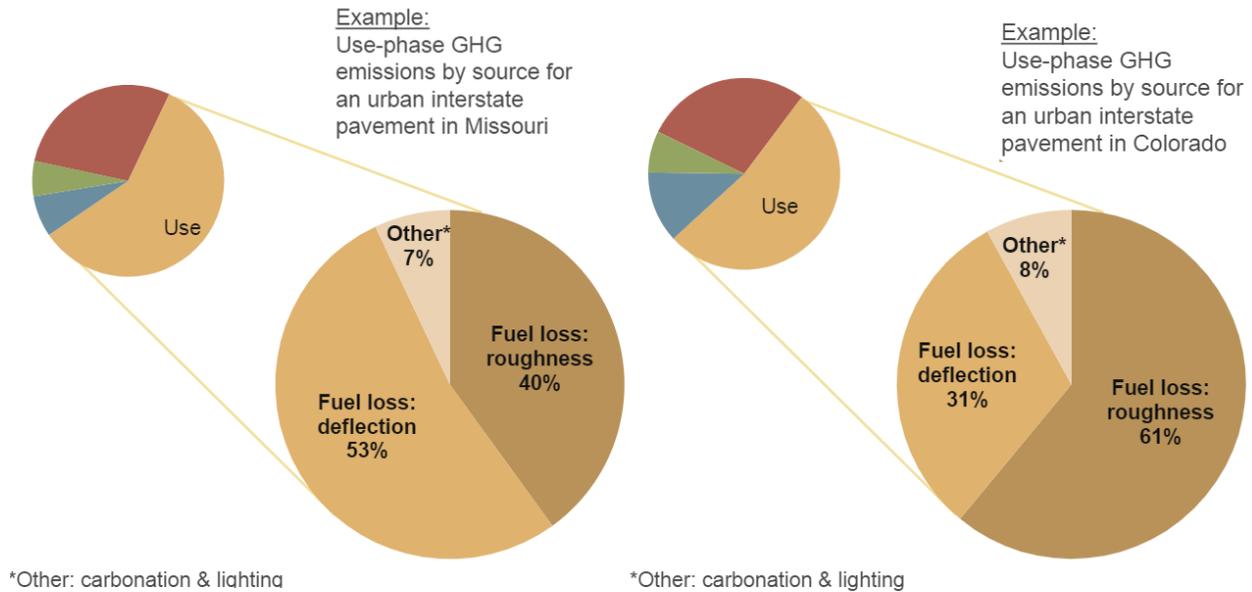


FIGURE 1.7 – Les dissipations énergétiques causées par l’uni et la déflexion de la chaussée [6]

larges catégories selon leur nature : les appareils de type réponse et les profilomètres. Les appareils de type réponse estiment la qualité d’uni à travers les interactions de leurs systèmes mécaniques avec les irrégularités de la surface auscultée. En effet, un système de type réponse se compose de trois éléments : un véhicule qui ausculte la chaussée à une certaine vitesse, un transducteur qui détecte le mouvement relatif de la suspension du véhicule et un afficheur relié au transducteur. Ces deux derniers forment le ”roadmeter”. Le résultat final est la conversion des mouvements enregistrés en indicateur d’uni. En d’autres termes, la mesure finale est le résultat de la réponse du roadmeter, de la procédure opérationnelle et du véhicule avec toutes les variables qui affectent sa réponse. Ainsi, ce type de mesure fournit une évaluation relative de la qualité de la route, qui dépend du système mécanique utilisé et de ses limites. Comme leurs dynamiques changent facilement, les véhicules doivent être régulièrement et rigoureusement entretenus, et les tests de contrôle doivent faire partie intégrante des procédures opérationnelles normales. Lorsque des changements se produisent, la mesure finale est difficilement interprétable, puisqu’il n’y a pas de correction simple qui peut être appliquée. Au lieu de cela, l’ensemble du système roadmeter-véhicule doit être recalibré [78, 79, 80].

Contrairement aux dispositifs de type réponse, les profilomètres relèvent une image du profil longitudinal de la route. Le profil est décrit par l’ensemble des valeurs d’élévation espacées à

intervalles rapprochés.

Le premier profilomètre moderne a été développé dans les années 1960 par les laboratoires General Motors Research (GMR). Le profilomètre GMR utilise deux roues à ressort qui suivent la route, et sont équipées d'un potentiomètre linéaire pour mesurer les déplacements relatifs entre le châssis du véhicule et la surface de la route. Les accéléromètres montés sur le châssis, au-dessus de chacune des roues, sont utilisés pour mesurer le mouvement du châssis du véhicule par double intégration du signal. Le mouvement du châssis est ensuite ajouté au mouvement des déplacements relatifs pour produire un signal de deux tensions qui, en théorie, représente le profil de la route sur la trajectoire des roues [81]. Ce système de profilomètre GMR a été commercialisé sous différents noms : le profilomètre General Motor, le profilomètre à déplacement rapide (Rapid Travel Profilometer - RTP) et le profilomètre de la dynamique de la surface (Surface Dynamics Profilometer - SDP).

Différents profilomètres sont utilisés au niveau international. Ils peuvent être regroupés en plusieurs catégories en fonction de la nature de leurs systèmes, de la résolution de leurs mesures ou de leurs souplesses d'utilisation. Par exemple, la Banque Mondiale a adopté une classification en fonction de leurs intervalles de mesures et de leurs marges d'erreur, pour obtenir 3 classes principales [80] :

- Classe I : Cette classe représente les normes de précision les plus élevées pour la mesure du profil de la route. Pour les profilomètres statiques, la distance entre les échantillons ne doit pas être supérieure à 250mm (au moins 4 mesures / mètre), avec une précision d'amplitude d'élévation mesurée de 0.5 mm. Les profilomètres de classe I ne donnent pas d'informations sur la façon dont les véhicules et leurs passagers vont réagir ou percevoir la qualité de roulement de la surface auscultée.
- Classe II : Cette classe comprend toutes les autres méthodes dans lesquelles le profil est mesuré comme base pour le calcul des indices d'uni, mais qui ne sont pas capables d'atteindre la précision requise pour une mesure de classe I. Bien que le matériel et les méthodes utilisés pour la mesure du profil soient vérifiés par un processus d'étalonnage indépendant, ils sont limités à une précision ou à une largeur de bande inférieure à celle nécessaire pour être qualifiés de méthode de classe I. Parmi les exemples de ces instruments, citons l'analyseur de profil longitudinal (APL), le profilomètre GM, le profilomètre K. J. Law et le profilomètre South Dakota. Les systèmes de classe II utilisent généralement un filtrage (matériel ou logiciel) pour limiter l'influence des grandes longueurs d'onde. Ils utilisent également des techniques de filtrage pour lisser les données des petites longueurs d'onde.
- Classe III : Inclut les appareils de type réponse. L'erreur maximale associée au fonctionnement de ces instruments est de 10 %. Des exemples de cette classe sont le Mays Ride Meter, le Cox Roadmeter, Roughometer du Bureau of Public Roads (BPR), et l'analyseur automatique de routes (ARAN).

En France, il convient de mentionner le profilomètre dynamique développé par l'université Gustave-Eiffel (Ex laboratoire central français des ponts et chaussées - LCPC) : l'analyseur de profil en long (APL). Ce dernier reste toujours le profilomètre de référence pour les mesures

contractuelles. Il prévoit la mesure de deux voies de profil longitudinal. Comme l'illustre la figure 1.8, chacune des remorques à roue unique qui constitue le dispositif de mesure est composée de :

1. Une roue d'auscultation mécaniquement conditionnée pour rester en contact avec la surface de la route, même à une vitesse relativement élevée jusqu'à 144 km/h, ou 72 km/h pour les auscultations ordinaires.
2. Un pendule inertiel utilisé comme référence de mesure.
3. Un bras porte-roue de mesure qui tourne autour du même axe que celui du pendule.

La liaison du châssis et le bras porte-roue est assurée par un système mécanique de ressort et d'amortisseur, ce qui permet de maintenir un contact permanent de la roue sur la chaussée. Les caractéristiques de ce système permettent de supporter des accélérations verticales transitoires de l'ordre de 100 m/s^2 .

Le centre de masse du pendule inertiel est situé au centre de percussion de la remorque par rapport au point de remorquage, ce qui permet de calculer l'amplitude des défauts auscultés en mesurant l'angle entre l'axe du bras porte-roue et celui du pendule inertiel. Ceci est réalisé avec un découplage mécanique adéquat du véhicule tracteur [2]. La fonction de transfert est

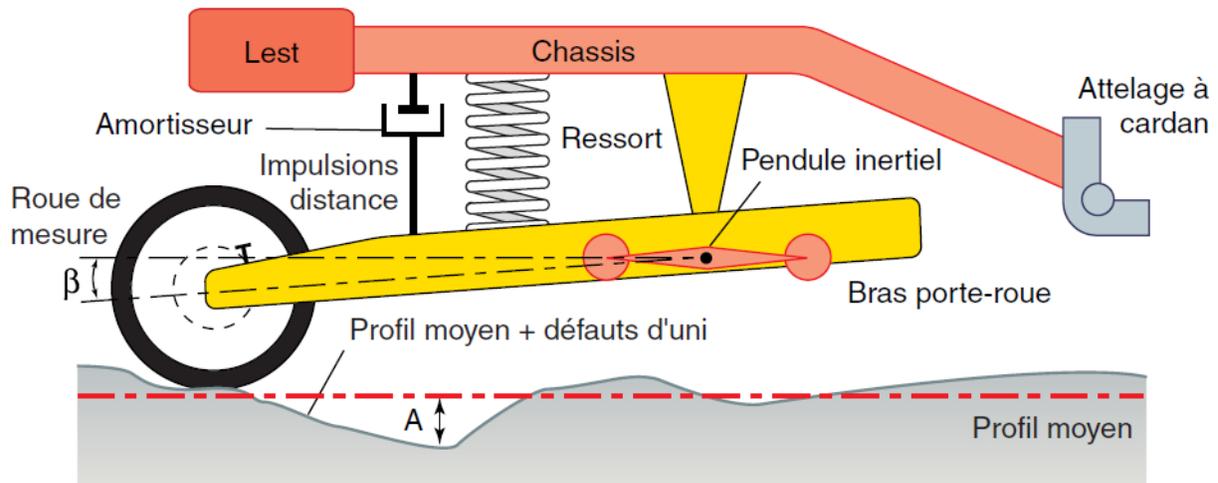


FIGURE 1.8 – Principe de la remorque APL [2]

quasi-unitaire dans le domaine de fréquence $[0.4 \text{ Hz} - 30 \text{ Hz}]$, comme indiquée dans la figure 1.9. Puisque les mesures d'APL sont sensibles à la vitesse d'auscultation, le constructeur préconise une vitesse constante autour de 72 km/h, avec une tolérance acceptée de $\pm 5 \text{ km/h}$, pour couvrir la gamme de longueurs d'ondes d'uni [2].

Les profilomètres mécaniques présentent donc des limites en termes de vitesse d'auscultation

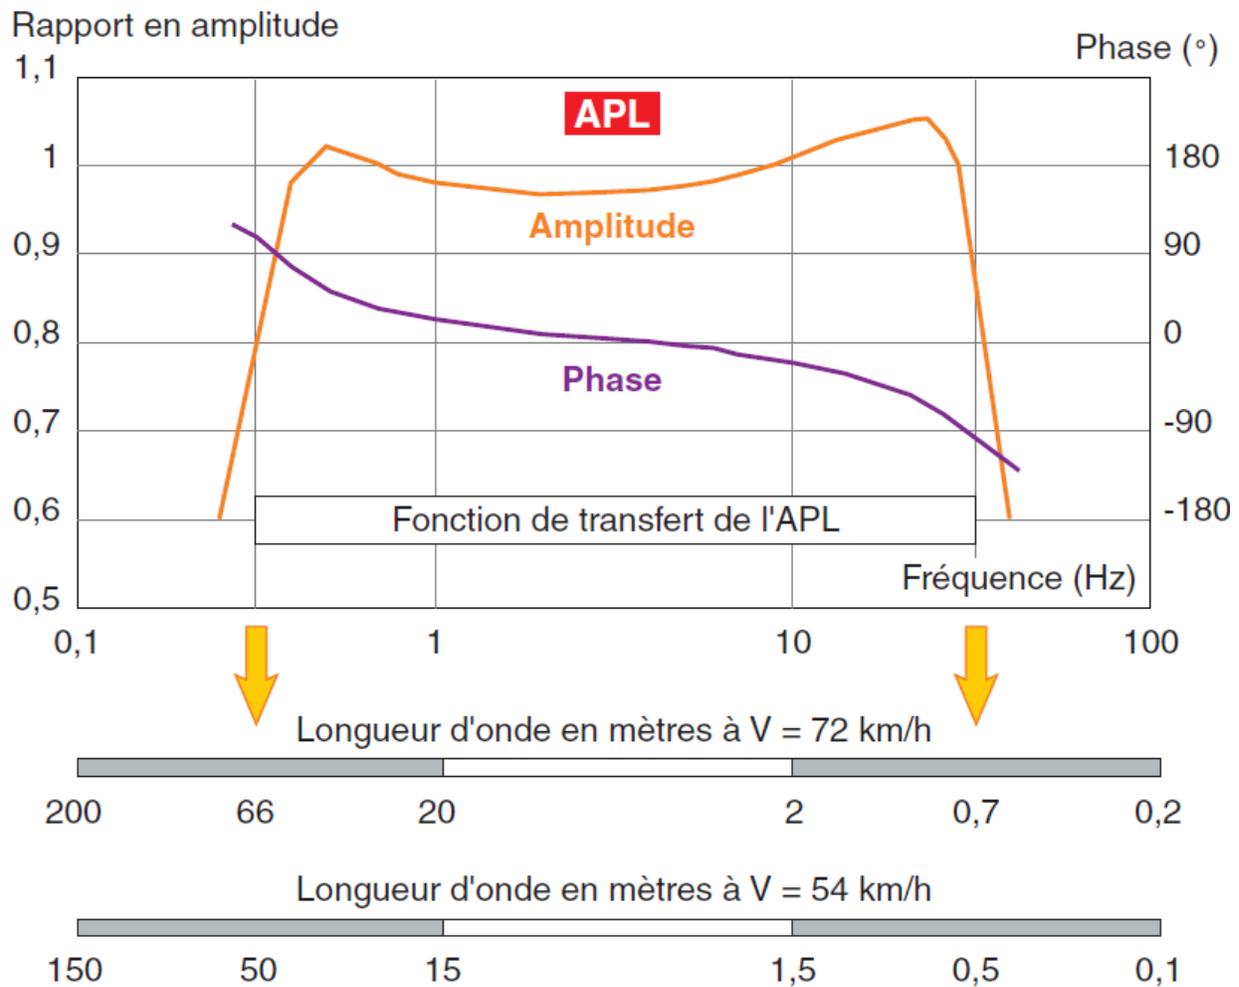


FIGURE 1.9 – Fonction de transfert de l'APL [2]

en raison de la réponse de leurs composants qui varient en fonction des fréquences des défauts auscultés, ainsi que du contact direct des roues sur la chaussée. Pour surmonter ces limites, d'autres types de profilomètres sans contact ont été développés en utilisant différentes techniques : acoustique, infrarouge, lumière blanche, laser et micro-ondes [81].

Le multiprofilomètre longitudinal (MLPL) est parmi les profilomètres sans contact qui ont été développés par l'université Gustave-Eiffel (adaptation d'un appareil développé par la société danoise Greenwood Engineering). Il comporte 2 ou 3 lasers, un accéléromètre et un gyroscope (cf. figure 1.10). L'ensemble forme une poutre solidaire à la caisse du véhicule d'auscultation. Ce profilomètre dynamique se base sur la méthode de Spangler [82] pour reconstruire le profil de la chaussée en combinant les accélérations du véhicules (mesurées par l'accéléromètre)

avec les déplacements entre la caisse et la chaussée (traduit par les lasers). En effet, Les accélérations sont intégrées deux fois de suite puis filtrées pour calculer le déplacement de la caisse. Celui-ci est ensuite retranché aux déplacements entre la caisse et la chaussée pour formuler un signal représentant le profil de la chaussée [10]. De plus amples détails peuvent être trouvés dans la thèse de Fabien Menant [10] intitulée : "Estimation de l'uni longitudinal des infrastructures routières au moyen de véhicules traceurs : développements méthodologiques et expérimentations". Comme l'APL, Le MLPL est un profilomètre qualifié pour exécuter les mesures contractuelles sur le réseau routier français.

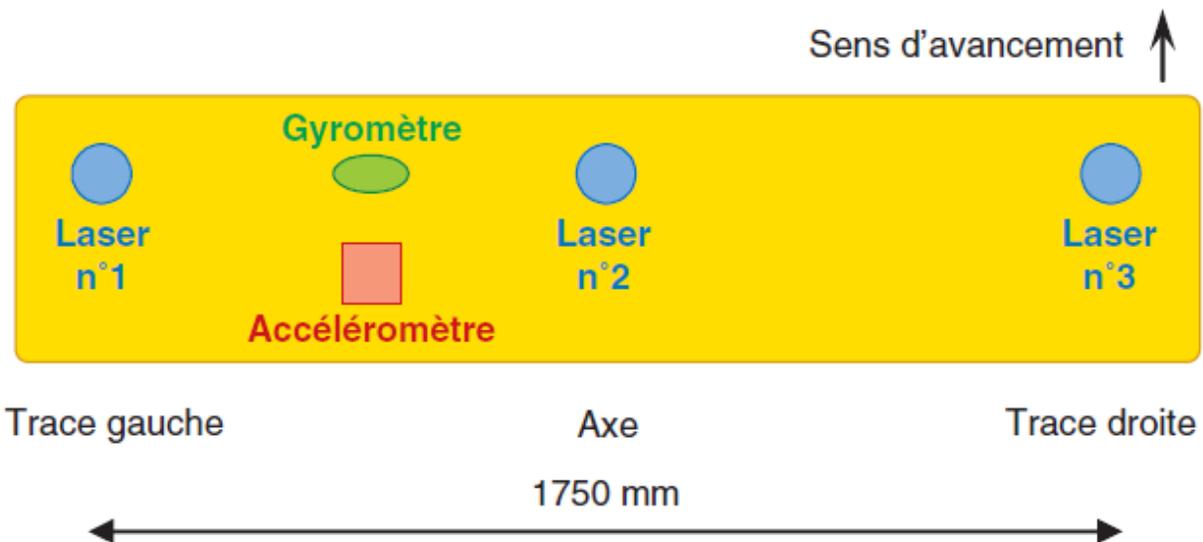


FIGURE 1.10 – Principe du MLPL tri-trace [2]

Il est important de signaler ici que le MLPL, comme l'APL, a été développé dans un contexte économique favorable où l'objectif ultime était de délivrer des profilomètres de plus en plus précis au détriment du coût de l'appareil. Cependant, dans le contexte économique actuel, les acteurs de la profession routière recherchent une optimisation des coûts d'auscultation. En effet, il existe une forte attente en matière d'auscultation économique et simplifiée de premier niveau, que ce soit dans le cadre du suivi de réseau non ausculté habituellement, ou en complément voire en remplacement des appareils traditionnels qui présentent aujourd'hui différents inconvénients comme la difficulté de leurs maintenances et leurs renouvellements onéreux [83].

Ainsi, différentes recherches ont été menées pour développer des outils dotés de technologies à bas coût et suffisamment précis pour la mesure d'uni longitudinal [10]. Un exemple de ces développements récents est le profilomètre Unibox. Issu des travaux de recherche de L'université Gustave-Eiffel, l'Unibox est un profilomètre munis de capteurs à faible coût se

voulant complémentaire aux profilomètres de référence. Il a été qualifié en 2015 et diffusé sous deux versions : un monotrace en 2016 et un bitrace depuis 2018 [84]. Son système se base sur le principe du MLPL en combinant la mesure d'un accéléromètre à celle d'un capteur optique de distance (laser de classe 2). Le logiciel d'acquisition permet de synchroniser les données de l'UniBox avec des informations de distance (codeurs incrémentaux ou GPS) et, optionnellement, des images d'environnement. La figure 1.11 illustre un exemple d'une mesure profilométrique par Unibox.

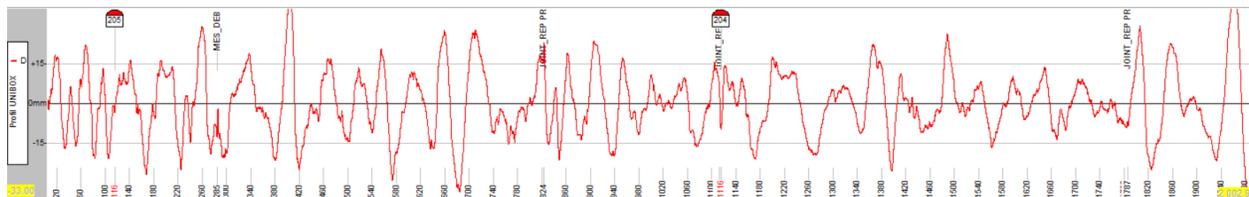


FIGURE 1.11 – Exemple d'un profil mesuré par Unibox sur un tronçon de 2000 m et exploité par le logiciel APL2015 [7].

L'Unibox est un appareil compact et intégrable sur n'importe quel véhicule-support (cf.figure 1.12). Ce profilomètre est utilisé de plus en plus en France grâce à son faible coût et sa souplesse d'utilisation. En effet, les entreprises de travaux publics l'utilisent pour l'autocontrôle d'uni dans leurs chantiers quelle que soit la couche mise en oeuvre. Cependant, l'Unibox présente des limites qu'il convient de préciser, notamment celles au niveau du capteur laser [84] :

- En termes de brillance : la mesure devient bruitée ou même invalide si la brillance de la chaussée dépasse 100000 lux. Ce seuil est atteint en plein été à cause du soleil éclairant la surface auscultée. Le bruit généré altère les petites fréquences du profil mesurée, mais il peut être éliminé en partie par un filtrage adéquat,
- Nature du revêtement de surface : la mesure laser présente aussi un bruit impactant la bande des petites ondes sur des revêtements très ouverts, comme le BBTM 0/10 ou enduits superficiels très grenus.

L'accéléromètre impose aussi une limite en termes de vitesse d'auscultation par Unibox, puisqu'il perd son efficacité en dessous de 36 km/h en altérant le domaine des grandes ondes ($\lambda \geq 12\text{m}$). Ainsi, pour délivrer des résultats pertinents corrects dans le spectre de l'uni ($0,5\text{m} \leq \lambda \leq 50\text{m}$), il est conseillé de maintenir une vitesse d'auscultation supérieure à 36 km/h. De plus amples détails peuvent être trouvés dans l'article de Menant et al.[85].

Les indicateurs de qualité de l'uni

Le véritable objectif du profilage de la route est d'obtenir une quantification de l'uni de la chaussée auscultée. Par conséquent, la mesure profilométrique ne présente que la moitié du travail. L'autre moitié consiste à traiter le profil mesuré pour en déduire un indice de qualité



FIGURE 1.12 – Unibox version bi-trace [8]

de l'uni sur le tronçon ausculté.

Dès le développement des appareils de type réponse, des indicateurs spécifiques à chacune de leurs mesures ont été utilisés pour évaluer l'uni de la chaussée auscultée. Ces indicateurs sont pour la plupart des indicateurs heuristiques à valeur unique. L'apparition des profilomètres, fournissant en sortie un signal numérique, a permis de définir des indicateurs théoriques mesurables avec n'importe quel profilomètre.

En revanche, la plupart des méthodes de traitement des signaux numériques utilisées pour analyser le profil ont été mises au point par des ingénieurs en électronique. Par conséquent, ces méthodes peuvent ne pas faire partie du répertoire standard du génie civil.

Dans ce qui suit, trois indicateurs d'uni seront définis ainsi que leurs méthodes de calcul : l'International Roughness Index (IRI), les Notes par Bandes d'Ondes (NBO) et la Densité Spectrale de Puissance (DSP).

International Roughness Index (IRI) :

L'IRI a été développé pour promouvoir l'utilisation d'un indice universel d'uni longitudinal. Il est ainsi nommé parce qu'il est le résultat d'une étude nommée International Road Roughness Experiment (IRRE), menée par un consortium de chercheurs du Brésil, d'Angleterre, de France, des États-Unis et de Belgique. Cette expérience s'est déroulée à Brasilia, en 1982, pour mesurer de manière contrôlée l'uni des chaussées dans diverses conditions et à l'aide de différents instruments et méthodes. L'indice d'uni retenu, l'IRI, était celui qui répondait le mieux aux critères de pertinence, de stabilité, de répétabilité, de reproductibilité sur les appareils d'auscultation, et de praticité pour les opérateurs [80].

Comme les appareils de type réponse étaient les plus répandus, l'IRI a été conçu pour être en bonne corrélation avec les résultats de ces systèmes. Le filtre de son calcul est basé sur un modèle mathématique appelé 'quart de voiture' (Quarter car model). Ce dernier calcule le

débattement de la suspension d'un système mécanique simulé, dont la réponse est similaire à celle d'un véhicule. Le mouvement de la suspension simulée est accumulé et divisé par la distance parcourue pour donner un indice avec des unités de pente (m/km, in/mi). La forme de réduction des données simule le fonctionnement d'un roadmeter parfait. En quelques mots, l'IRI est une pente exprimant une élévation moyenne par unité de longueur parcourue, qui se calcule à partir de la réponse d'un véhicule virtuel parcourant le profil mesuré, où la réponse du véhicule étant une transformé du profil mesuré par la fonction de transfert.

Ainsi, l'algorithme de calcul d'IRI se résume comme suit [86] :

1. La mesure des élévations le long de la surface auscultée à des points équidistants, pour construire le profil longitudinal.
2. Pour chaque point de ce profil, les pentes locales sont évaluées à partir des données d'élévation.
3. Les pentes locales servent comme donnée d'entrée dans un modèle à deux masses (suspendue et non suspendue) simulant le véhicule de référence standard (appelé "quarter car model"), dont la réponse à la vitesse de 80 km/h est calculée à chaque point.
4. A partir de cette réponse, les différences de pente des masses (suspendue et non suspendue) sont calculées et les valeurs absolues (pentes rectifiées) sont évaluées .
5. La valeur moyenne de toutes les pentes rectifiées donne l'IRI.

L'IRI est défini comme une propriété du profil réel de la chaussée, et par conséquent, il peut être mesuré avec n'importe quel profilomètre valide. Ainsi, L'IRI a été le premier indice d'uni largement utilisé.

Les Notes par bandes d'ondes (NBO) :

En France, une nouvelle méthode d'évaluation d'uni longitudinal a été introduite, dans les années 1970, qui se base sur l'analyse statistique de trois bandes de longueurs d'ondes adjacentes du profil mesuré. Par la suite, cette approche a été adoptée par d'autres pays d'Europe occidentale [1]. La segmentation de la bande d'ondes effective du profil en seulement trois niveaux de longueurs d'ondes est liée à l'interaction véhicule - chaussée. En effet, si nous considérons le couple chaussée - véhicule comme un seul système dynamique, le plus simple modèle de cette interaction est celui composé de deux masses reliées par des ressorts linéaires et des amortisseurs. Lorsqu'on adapte Un tel modèle aux paramètres des véhicules modernes, il affiche deux bandes de résonances : la première est dans la gamme de fréquences de 0.5 Hz à 2 Hz qui se manifeste sous forme d'un mouvement d'oscillation de la voiture dans son ensemble, tandis que la deuxième est approximativement dans la gamme de fréquences de 8 à 35 Hz qui se manifeste par un claquement des roues [9]. Puisque la fréquence de résonance est inversement liée à la longueur d'onde des défauts qui la provoque, la vibration dans la première bande de résonance est causée par les grandes longueurs d'ondes, tandis que celle de la deuxième bande est causée par les petites longueurs d'ondes. Pour combler l'écart manifeste entre ces deux bandes d'ondes de résonance, une bande de moyennes longueurs d'ondes

a été insérée obtenant ainsi une segmentation du spectre total en 3 bandes d'ondes (cf. Figure 1.13). Néanmoins, la définition de ces bandes d'ondes varie en fonction de la vitesse

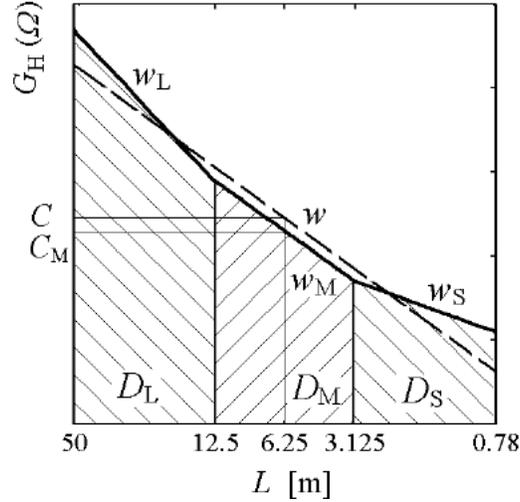


FIGURE 1.13 – Schéma des bandes de longueurs d'ondes de résonance pour une vitesse de 90 km/h [9].

d'auscultation, comme le montre le tableau 1.1. La norme française NF P98-218-3 prend

Vitesse (km/h)	Les bandes en longueurs d'ondes (m)
60	0.5 - 2 - 8 - 32
90	0.75 - 3 - 12 - 48
120	1 - 4 - 16 - 64
240	2 - 8 - 32 - 128

TABLE 1.1 – Bandes de longueurs d'onde de résonance en fonction de la vitesse [1]

en considération ces bandes de résonance et propose un découpage spectral en affinant la définition de leurs bornes comme suit :

— Bande de petites ondes PO :

$$0.707 < \lambda(m) < 2.828 \quad (1.1)$$

— Bande de moyennes ondes MO :

$$2.828 < \lambda(m) < 11.312 \quad (1.2)$$

— Bande de grandes ondes GO :

$$11.312 < \lambda(m) < 45.248 \quad (1.3)$$

Après avoir filtré la mesure profilométrique selon trois bandes d'ondes, l'énergie est calculée dans chaque bande d'onde et selon sa longueur de segmentation relative pour obtenir les indices suivants :

- EPO_{20} : les énergies de petites ondes calculées sur des segments successifs de 20 m.
- EMO_{100} : les énergies de moyennes ondes calculées sur des segments successifs de 100 m.
- EGO_{200} : les énergies de grandes ondes calculées sur des segments successifs de 200 m.

L'énergie d'un segment s'exprime comme la somme des carrés d'amplitudes de ses points :

$$E = \Delta x \sum_{i=1}^N A_i^2 \quad (1.4)$$

où Δx est le pas d'échantillonnage, $N = B/\Delta x$ est le nombre de points de mesure correspondant à la longueur B de la séquence étudiée et A_i l'amplitude en cm du signal au point i de la séquence.

Les valeurs des énergies EBO sont ensuite converties en notes par bandes d'ondes (NBO) sur une échelle de 0 (qualité médiocre d'uni) à 10 (excellente qualité d'uni). La correspondance entre les étendues d'énergies et les notes NBO est établie suivant le tableau 1.2

Or, la résolution du tableau 1.2 s'avère des fois insuffisante pour comparer deux mesures profilométriques ayant deux niveaux d'énergie similaires. Ainsi, une décimalisation de ce tableau a été proposée pour aboutir à des conversions plus précises :

- Note de petites ondes (NPO) :

$$NPO = -2.2373 \ln(EPO_{20}) + 9.975 \quad (1.5)$$

- Notes de moyennes ondes (NMO)

$$NMO = -2.2317 \ln(EMO_{100}) + 17.947 \quad (1.6)$$

- Notes de grandes ondes (NGO)

$$NGO = -2.2326 \ln(EGO_{200}) + 25.70 \quad (1.7)$$

Les notes par bandes d'ondes sont donc des indicateurs énergétiques de l'uni. En d'autres termes, plus l'énergie du tronçon de calcul est grande, plus il contient de défauts et plus sa note sera faible. Ainsi, les notes par bandes d'ondes mettent en évidence les défauts locaux contenus dans leurs tronçons de calcul. Par exemple, Les joints de reprise sont des défauts typiques de la bande de petites ondes (cf. Figure 1.14), qui peuvent atteindre des amplitudes importantes au point de dégrader d'une note NPO le tronçon impacté [7]. Les arrêts prolongés des finisseurs sont un autre défaut qui altère les NBO et qui n'est pas nécessairement visible sur la chaussée. Ces défauts peuvent être distingués dans la bande PO de la mesure profilométrique par deux pics caractéristiques [2] : le premier au stationnement et le deuxième

Notes NBO	Petites ondes EPO_{20} (en cm^3)	Moyennes ondes EMO_{100} (en cm^3)	Grandes ondes EGO_{200} (en cm^3)
10	0 à 1.1	0 à 39	0 à 1267
9.5	1.1 à 1.4	39 à 49	1267 à 1585
9	1.4 à 1.7	49 à 62	1585 à 1983
8.5	1.7 à 2.2	62 à 77	1983 à 2481
8	2.2 à 2.7	77 à 97	2481 à 3103
7.5	2.7 à 3.4	97 à 121	3103 à 3882
7	3.4 à 4.2	121 à 151	3882 à 4857
6.5	4.2 à 5.3	151 à 189	4857 à 6076
6	5.3 à 6.6	189 à 236	6076 à 7601
5.5	6.6 à 8.2	236 à 296	7601 à 9509
5	8.2 à 10.3	296 à 370	9509 à 11896
4.5	10.3 à 12.9	370 à 463	11896 à 14882
4	12.9 à 16.1	463 à 579	14882 à 18618
3.5	16.1 à 20.2	579 à 725	18618 à 23292
3	20.2 à 25.3	725 à 906	23292 à 29139
2.5	25.3 à 31.6	906 à 1134	29139 à 36453
2	31.6 à 39.5	1134 à 1419	36453 à 45604
1.5	39.5 à 49.5	1419 à 1775	45604 à 57051
1	49.5 à 61.9	1775 à 2220	57051 à 71372
0.5	61.9 à 77.4	2220 à 2778	71372 à 89288
0	supérieure à 77.4	supérieure à 2778	supérieure à 89288

TABLE 1.2 – Correspondance entre les EBO et les NBO [2].

lors du redémarrage (cf. Figure 1.15).

La densité Spectrale de Puissance (DSP) :

Outre les signatures des défauts locaux, la mesure profilométrique comporte aussi des défauts périodiques qui se manifestent par leurs formes quasi-sinusoidales, et qui s'étalent sur plusieurs centaines de mètres, voire plusieurs kilomètres. Les longueurs d'ondes caractéristiques de ces défauts varient en fonction de leurs natures. En effet, ceux qui dégradent le spectre de moyennes ondes apparaissent dès la mise en oeuvre des enrobés à cause de problèmes d'ordre matériel, comme le pompage du vérin de la table de finisseur, ou de guidage, notamment au

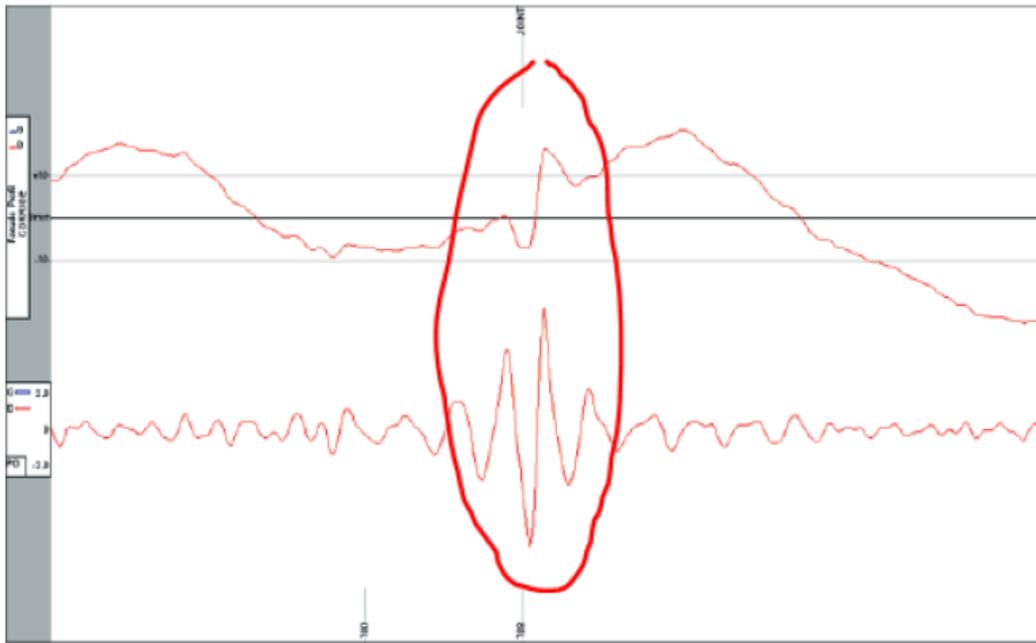


FIGURE 1.14 – Exemple de profil mesuré et de son filtrage PO à un joint de reprise [7]

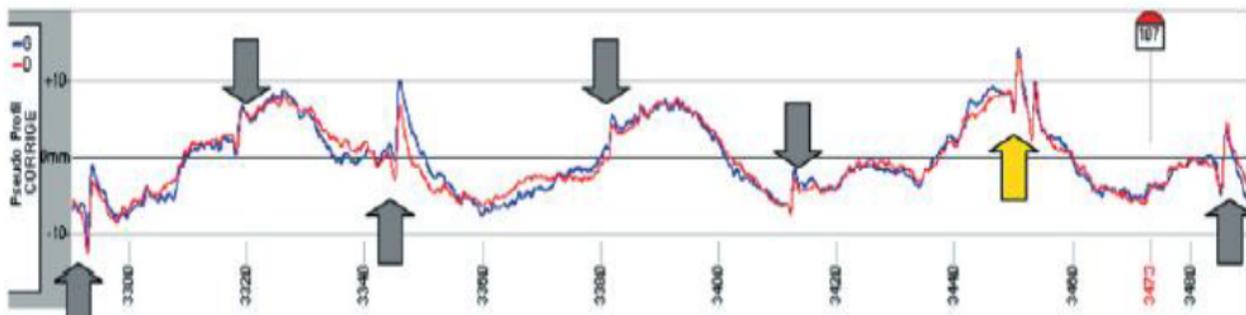


FIGURE 1.15 – Exemple de signaux mettant en évidence une succession de défauts ponctuels dus à un arrêt prolongé du finisseur [2].

fil. Par contre, les défauts périodiques de petites ondes ne sont générés qu'ultérieurement lors du compactage des enrobés [2].

Indépendamment de son amplitude, un défaut périodique dégrade la qualité d'usage de la chaussée à cause de sa forme périodique et de son étendue. En réalité, la forme périodique de la surface de la chaussée provoque des débattements dans les suspensions du véhicule. La grande étendue de ce type de défaut amplifie ces mouvements, et par conséquent, entraînent un inconfort pour les usagers, notamment chez les conducteurs de poids-lourds à cause de

leurs grands empattements.

Afin de détecter ses composantes périodiques, les analyses spectrales du profil mesuré s'imposent. Ces types d'analyses nécessitent une connaissance plus approfondie de la distribution des fréquences avec les amplitudes qui les accompagnent. Une de ces méthodes, très utilisée pour les profils routiers, est la densité spectrale de puissance (DSP) illustrée dans la figure 1.16.

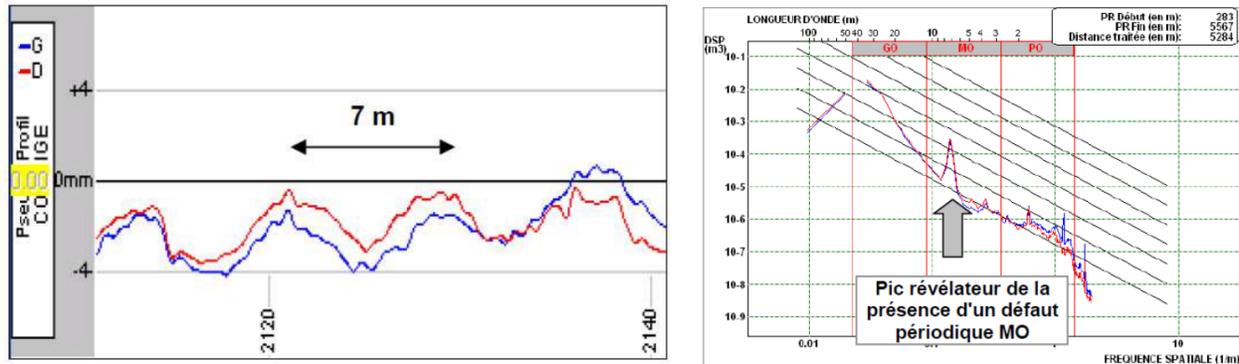


FIGURE 1.16 – Détection d'un défaut périodique par l'analyse de la DSP (la courbe bleue correspond au relevé effectué dans la bande de roulement gauche et la courbe rouge à celui effectué dans la bande de roulement droite) [10].

L'une des premières utilisations dans le domaine du génie civil a été présentée aux Etats-Unis dans la note technique 3484 [87] du National Advisory Committee for Aeronautics (NACA), puis étendue par Houbolt [88]. Dès 1955, ces études concluent que la DSP est une méthode plutôt concise pour identifier les caractéristiques périodiques de l'uni de la chaussée. Plusieurs recherches ultérieures ont été menées pour adapter la DSP aux mesures profilométriques et pour optimiser ses méthodes de calcul comme celle de La barre [89], ou celle de la British Standards Institution (BSI) [90]. L'évolution détaillée de la DSP dans le monde de la mesure routière, et ses conditions de validité, ont été présentées dans l'étude bibliographique de Peter Andrén [91].

En France, les logiciels de traitement des mesures profilométriques (APL2000 ou UniView) calculent la densité spectrale de puissance selon la méthode non-paramétrique de Welch qui se base sur la Transformation de Fourier Discrète (TFD) [92]. Cette méthode estime les périodogrammes, qui sont le résultat de la conversion d'un signal du domaine temporel au domaine fréquentiel. La DSP est privilégiée puisqu'elle réduit le bruit dans le spectre estimé en échange d'une réduction de la résolution en fréquence, ainsi que le nombre de calculs et la mémoire nécessaire pour l'estimation des périodogrammes. Son algorithme est le suivant [93, 92] :

1. Découpage de la mesure profilométrique en segments, qui se chevauchent partiellement jusqu'à 50 %, ayant une longueur égale à une puissance de 2 (4098 par défaut). Ce

- chevauchement permet de réduire la perte d'information due à l'atténuation du signal (causée par le fenêtrage qui va suivre) et de fournir des périodogrammes plus fiables.
2. Ce découpage engendre des transitions brusques aux extrémités des segments, ce qui peut perturber la composition spectrale des tronçons en créant des pseudo-fréquences. Ainsi, un fenêtrage est appliqué pour mettre en évidence les centres de segments tout en lisant leurs extrémités [94].
 3. La TFD de chaque segment est calculée. Les valeurs sont ensuite élevées au carré pour constituer les périodogrammes.
 4. Enfin, la moyenne de tous les périodogrammes est calculée pour estimer la DSP. Ce calcul de moyenne permet de lisser le résultat en réduisant le bruit.

1.1.4 Conclusion de la première partie :

L'uni longitudinal de la chaussée impacte la structure de la route, la sécurité de ses usagers et leurs confort. Sa dégradation engendre des conséquences économiques et écologiques alarmantes. Compte tenu sa forte influence sur la structure de la chaussée et sa qualité d'usage, l'uni a été le sujet de nombreuses recherches qui ont traité particulièrement sa mesure et les indicateurs qui en découlent. Ainsi, La mesure d'uni a évolué au fil du temps pour s'adapter aux différentes techniques disponibles et accessibles. Aujourd'hui, l'uni est mesuré à l'aide des profilomètres qui relèvent le profil de la chaussée auscultée. Cette mesure profilométrique reste la donnée la plus riche en termes d'informations, et celle qui représente en détails les défauts de la surface auscultée. C'est la raison pour laquelle, le travail de cette thèse se positionne à l'échelle du profil mesuré. En effet, la prédiction de l'évolution du profil de la route, suite à sa réhabilitation, fournira une estimation assez détaillée de l'amélioration de l'uni préexistant défaut par défaut. Cette approche choisie renvoie donc à une autre problématique qui est celle de la prédiction d'une série temporelle (le profil post-réhabilitation) à partir d'une autre (le profil préexistant). Cependant, le profil de la chaussée présente une corrélation spatiale qui peut concerner différentes échelles (longueurs d'ondes), ce qui le rend une entité monolithique sur les longueurs de corrélations identifiées. Cette corrélation introduit de facto une convolution entre les nuages de points échantillonnés pour décrire les profils d'entrée et de sortie. Une telle corrélation doit donc être transmise par le modèle de prédiction recherché. Compte tenu la nature de la problématique, l'approche adoptée dans ce travail de thèse est celle de prédire le profil post-réhabilitation par un modèle d'apprentissage automatique (Machine Learning), pour tirer parti de leur modélisation basée sur des architectures profondes et hiérarchisées. Il convient donc de consacrer la deuxième partie de ce chapitre pour présenter les notions essentielles de l'apprentissage supervisé.

1.2 Bibliographie Machine Learning :

Cette deuxième partie est consacrée à la présentation des aspects de l'apprentissage automatique nécessaires à la compréhension de ce travail de thèse.

Nous commencerons par présenter quelques généralités sur l'apprentissage automatique, puis nous nous concentrerons sur le type qui correspond à la problématique de cette thèse : l'apprentissage supervisé. Ainsi, nous définirons d'abord le processus d'apprentissage supervisé d'un modèle, puis nous présenterons les algorithmes les plus utilisés, tels que les machines à vecteurs de support, les forêts aléatoires et les réseaux de neurones.

1.2.1 L'apprentissage automatique :

L'apprentissage automatique, ou Machine Learning (ML) en anglais, est la discipline qui consiste à programmer des modèles de sorte à apprendre à résoudre un problème à partir des données qui l'illustrent. Tom Mitchell [95] définit l'apprentissage automatique comme : "Étant donné une tâche T et une mesure de performance P , on dit qu'un programme informatique apprend à partir d'une expérience E si les résultats obtenus sur T , mesurés par P , s'améliorent avec l'expérience E ". Les systèmes d'apprentissage automatique peuvent être classés en fonction de la quantité et du type de supervision requis pour leurs entraînements. Ainsi, deux catégories peuvent être distinguées : l'apprentissage non supervisé et l'apprentissage supervisé.

L'apprentissage non-supervisé :

L'apprentissage non supervisé est une technique de traitement de données non étiquetées. Les algorithmes de cet apprentissage analysent un ensemble de données pour découvrir les structures de groupe latentes et proposent donc des regroupements de données sans nécessiter d'intervention humaine [96]. Grâce à leur capacité à découvrir les similitudes et les différences entre les données, les modèles d'apprentissage non supervisé sont utilisés pour trois tâches principales :

- Le partitionnement ou le clustering : une technique d'exploration de données dont les algorithmes sont employés pour regrouper des données brutes et non classifiées selon des structures ou des formes hiérarchisées. La majorité des systèmes de détection de défaut ou d'anomalie se base sur la technique de clustering [97].
- Les règles d'association : est une méthode pour trouver des relations entre les variables dans un ensemble de données. Par exemple, ces méthodes sont utilisées pour comprendre les habitudes de consommation des clients, ce qui permet aux entreprises de développer de meilleures stratégies de vente ou des moteurs de recommandation. On peut en voir des exemples dans la suggestion d'Amazon "Les clients qui ont acheté cet article ont également acheté" [98] ou dans la liste de lecture "Découvrir chaque semaine" de Spotify.

- La réduction de dimensions : si les algorithmes d'apprentissage automatique nécessitent un grand nombre de données pour fournir des résultats précis, cette grande taille de données peut être problématique lors de la visualisation des données. La réduction de la dimensionnalité s'avère nécessaire lorsque le nombre de caractéristiques, ou de dimensions, dans un ensemble de données est trop élevé. Elle réduit le nombre d'entrées à une taille gérable tout en préservant, autant que possible, l'intégrité de l'ensemble des informations contenues dans le jeu de données. Ainsi, ces algorithmes tentent de préserver autant de structure que possible (par exemple, en essayant d'éviter que des clusters distincts dans l'espace d'entrée ne se chevauchent dans la visualisation), afin d'offrir une présentation plus claire des données [99].

L'apprentissage supervisé :

L'apprentissage supervisé requiert un jeu de données étiqueté, c'est à dire pour lequel chaque instance est accompagnée de la réponse souhaitée. L'ensemble de ces étiquettes servira comme cibles à atteindre lors de l'apprentissage du modèle. En d'autres termes, pour reprendre la définition de Tom Mitchell précédemment citée, l'apprentissage supervisé consiste à créer un modèle capable de prédire les cibles (la tâche T) à partir d'un entraînement sur l'ensemble des données (l'expérience E). La qualité de prédiction sera mesurée à partir d'une mesure de performance P qui s'adapte selon la nature du problème traité. Selon la nature de la cible, deux cadres fondamentaux sont distingués : la régression et la classification.

Lorsque la variable cible y ne prend qu'un nombre fini de valeurs, il s'agit alors d'un problème de classification supervisée. Par contre, lorsque la variable cible est continue et univariée ($y \in \mathbf{R}$ ou un intervalle de \mathbf{R}), nous parlons de régression. Si $y \in \mathbf{R}^{\mathbf{d}}$ avec $\mathbf{d} > 1$, où \mathbf{d} est la dimension de l'ensemble d'arrivée, il s'agit d'une régression multivariée. Cette dernière s'aborde comme la résolution de problèmes de régression univariée [100].

Puisque le profil mesuré de la chaussée se compose de plusieurs valeurs numériques, qui représentent les dénivellations de la surface, sa prédiction relève d'un problème de régression. L'application d'apprentissage supervisé aux problèmes du monde réel suit généralement le processus décrit dans la figure 1.17 : dans la plupart des cas, les données mesurées ne peuvent pas être exploitées directement puisqu'elles contiennent souvent des données bruitées ou tronquées ou corrompues. Le pré-traitement des données est donc une étape fondamentale avant de commencer l'analyse [101]. La corruption des données peut être due à de multiples raisons comme la défaillance du capteur, une erreur dans la transmission des données ou une saisie incorrecte des données. La corruption et le bruit dans les données doivent être correctement identifiés et des solutions appropriées doivent être trouvées pour les traiter [102]. A la fin du pré-traitement, le système d'apprentissage passe en général par deux phases : une première phase d'apprentissage où le modèle règle ses paramètres pour fonctionner au mieux sur une première partie des données, appelée jeu de données d'entraînement. Ainsi, le but de cette phase est de trouver les valeurs paramétriques qui minimisent l'erreur de la prédiction du modèle sur cet ensemble d'observations. Pour cela, une mesure de performance doit être

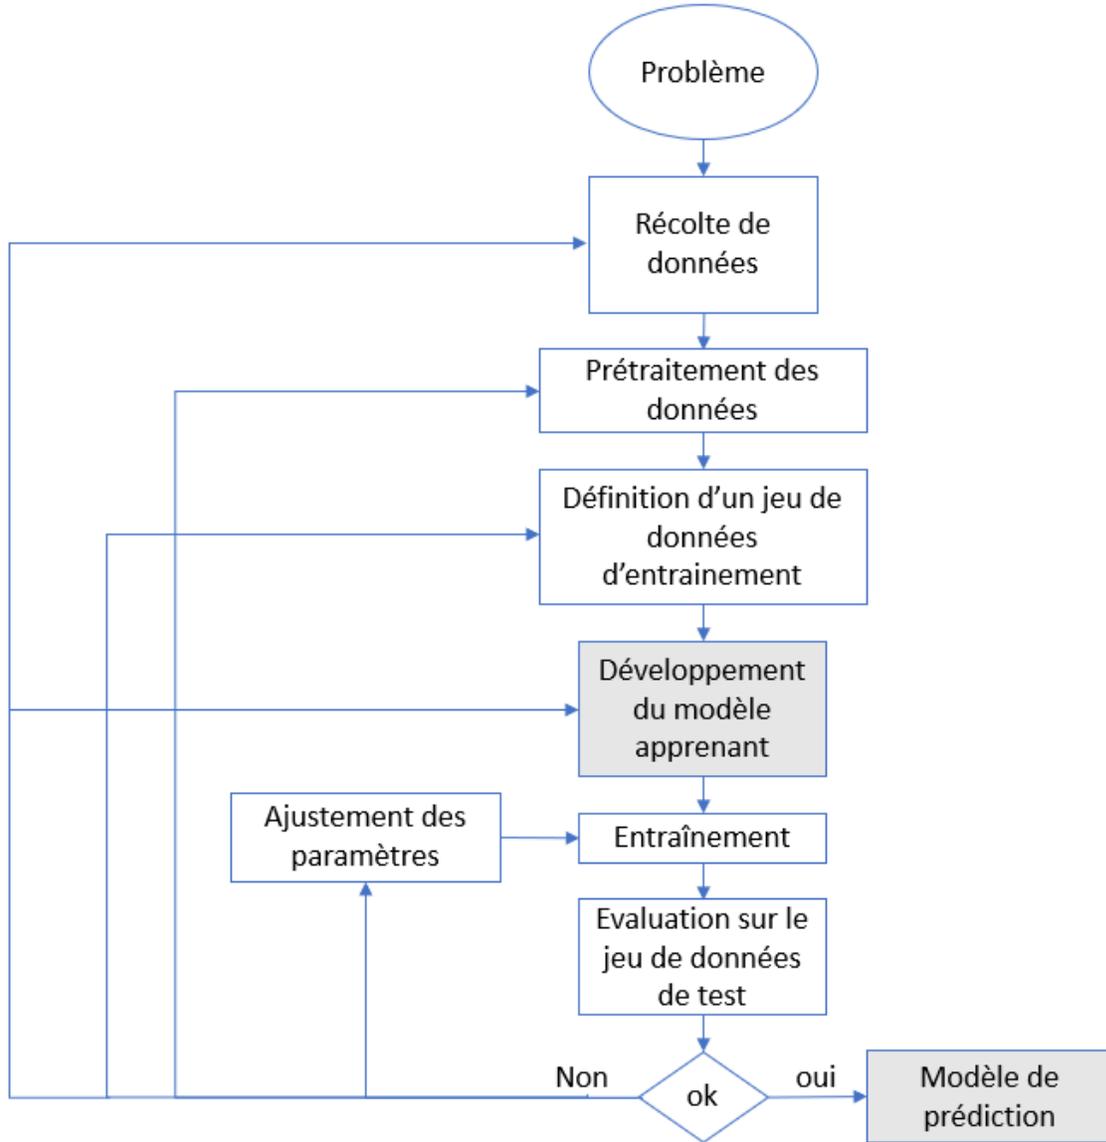


FIGURE 1.17 – Processus de l'application d'apprentissage supervisé

définie pour évaluer les prédictions du modèle. Dans la pratique, une mesure de l'erreur entre les prédictions et les observations correspondantes est généralement utilisée comme une fonction coût à minimiser. A la fin du processus, si le modèle n'arrive pas à estimer les données cibles du jeu d'entraînement, il s'agit alors de revoir le choix du modèle et son adéquation avec le type de problème traité. Dans le cas contraire, la deuxième phase de test commence pour évaluer le modèle (avec le jeu de paramètres construits) sur les observations d'une

deuxième partie de l'échantillon, appelée le jeu de données de test. Le but de cette dernière est de mesurer la capacité de la généralisation du modèle : si la performance du modèle sur le jeu de données de test est moindre, le modèle est alors surentraîné ou sur-ajusté. Ceci indique que les valeurs paramétriques construites lors de cette itération ont été sur-adaptées aux données d'entraînement, ce qui empêche le modèle de généraliser ses performances à de nouvelles observations. Ce problème peut survenir dans le cas où les données d'entraînement sont assez similaires donnant lieu à une erreur de prédiction minimale lors de l'entraînement, mais ces données n'étant pas représentatives de situations plus diverses, les paramètres du modèle ne permettent pas de prédire ces nouvelles situations lors du test. Il convient alors de relancer une nouvelle itération d'entraînement afin de réajuster les paramètres du modèle pour atteindre des performances similaires sur l'ensemble de données d'entraînement et de test. Ce schéma d'apprentissage est répété jusqu'à ce que le nombre d'itérations parcourues atteigne une limite prédéfinie. A la fin de cet apprentissage, si la performance du modèle sur le jeu de données de test n'a pas été améliorée, cela indique que le modèle possède plus de paramètres que nécessaire par rapport à la complexité du problème et à la quantité de données d'entraînement disponible. Dans ce cas, trois solutions sont envisageables : le ré-entraînement du modèle sur un jeu de données plus grand, le changement du modèle par un autre plus simple en termes de paramètres, ou la régularisation du modèle pour le contraindre et le forcer à un apprentissage plus efficace [13].

1.2.2 Modèles et algorithmes d'apprentissage supervisé pour les séries temporelles

Une série temporelle est une suite d'observations faites séquentiellement dans le temps. Nous en trouvons des exemples dans de nombreux domaines, allant de l'économie à l'ingénierie. Dans le domaine de l'économie, les cours des actions, les exportations mensuelles, l'évolution des revenus et les bénéfices annuels sont tous des exemples de séries temporelles. De nombreuses séries temporelles sont couramment enregistrées en économie et en finance. Par exemple, les cours des actions sur des jours successifs, les totaux des exportations sur des mois successifs, les revenus moyens au cours de mois successifs ou les bénéfices des entreprises au cours d'années successives. De nombreux types de séries temporelles sont utilisés dans les sciences physiques notamment en météorologie, en sciences marines et en géophysique. Par exemple, les précipitations sur des jours successifs, et la température de l'air mesurée sur des heures, des jours ou des mois successifs sont des séries temporelles aussi [103]. Chaque série temporelle contient des caractéristiques relatives au phénomène qu'elle représente. Ainsi, pour la régression des séries temporelles, plusieurs algorithmes peuvent être utilisés pour prendre en compte chacune de leurs caractéristiques.

Dans le cas du profil longitudinal, la mesure profilométrique est un signal composé par l'ensemble des points d'élévation de la surface espacées à intervalles rapprochés. En d'autres termes, le profil longitudinal est donc une série de points qui représente des observations relevées séquentiellement dans l'espace et de facto dans le temps. Ainsi, la prédiction du profil

post-réhabilitation est une problématique d'apprentissage supervisé d'une série temporelles où deux évolutions sont à estimer : (i) une première pseudo-temporelle liant les profils pré- et post-réhabilitation, (ii) ainsi qu'une deuxième évolution des voisinages caractérisant les défauts monolithiques de l'uni.

Il existe plusieurs algorithmes d'apprentissage supervisé pour la régression des séries temporelles, dont les principaux sont : les K-plus proches voisins, les modèles linéaires, les machines à vecteurs de support, les forêts aléatoires, les arbres à gradient adaptatif et les réseaux de neurones [13]. Puisque nous utiliserons chacune de ces techniques dans la suite de ce travail de cette thèse, nous présentons dans ce qui suit leurs notions fondamentales.

Les K-plus proches voisins (KNN) :

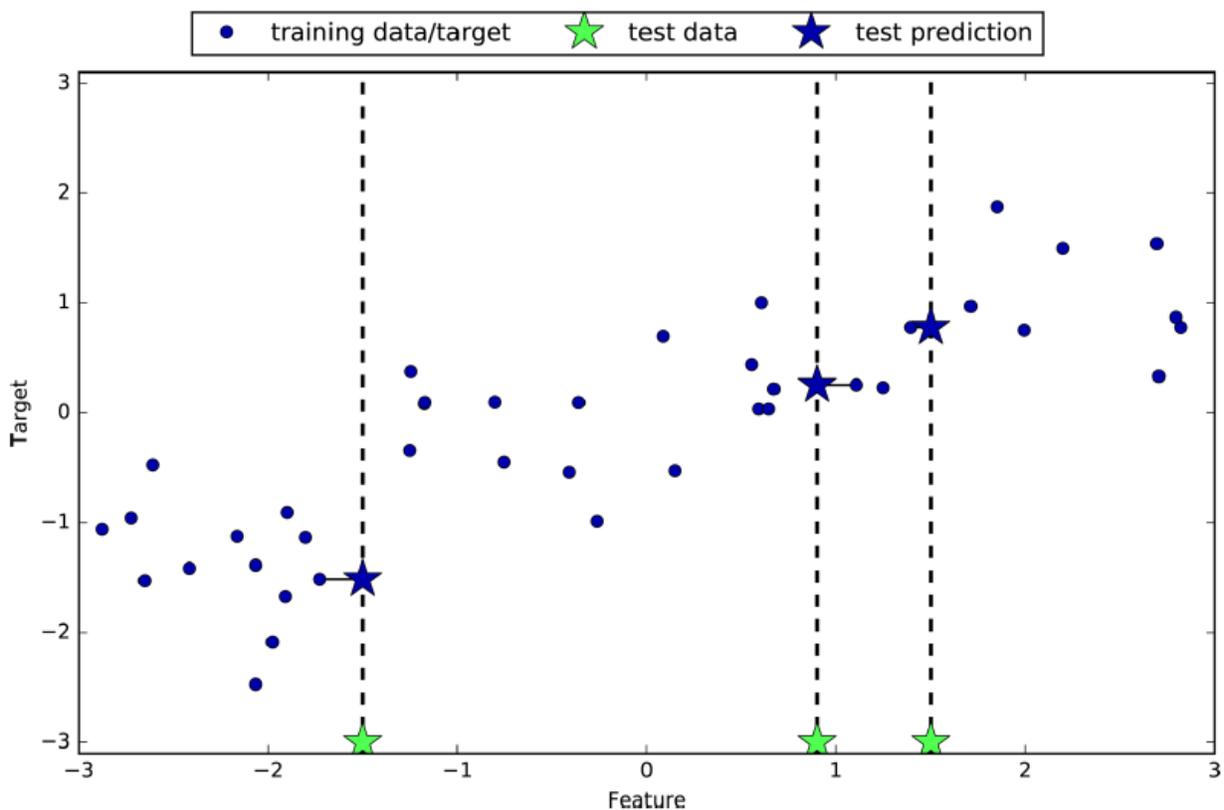


FIGURE 1.18 – La régression par KNN : la prédiction (étoile bleue) est associée (reliée par un trait) au plus proche voisin identifié dans les données d'apprentissage. [11].

La méthode des k plus proches voisins (K-Nearest Neighbors - KNN) est un algorithme d'apprentissage largement appliqué en classification ainsi qu'en régression, puisqu'il présente

plusieurs avantages comme sa simplicité, son efficacité et sa robustesse aux données bruitées. Ainsi, nous trouvons différentes applications de régression par KNN dans plusieurs domaines comme celui de la météorologie, pour simuler les précipitations quotidiennes, celui de la finance pour découvrir les tendances du marché, ou celui de la médecine pour identifier les facteurs de risque du cancer de la prostate [104].

L'algorithme KNN s'appuie sur l'ensemble des données d'apprentissage pour fournir ses prédictions. Pour la prédiction d'un nouveau point, l'algorithme cherche dans l'ensemble des données d'apprentissage les K observations les plus similaires (voisines), pour en calculer la moyenne comme indiqué dans la figure 1.18. L'algorithme KNN n'a pas donc de modèle autre que le stockage de l'ensemble des données. Cette méthode KNN fait partie de la famille des algorithmes d'apprentissage "paresseux". Le terme "paresseux" vient du fait que la phase d'apprentissage se limite à construire des structures sophistiquées de stockage de données d'apprentissage, pour faciliter la recherche de la correspondance et de la similarité entre les données [105, 106, 11].

Une mesure de distance est utilisée pour déterminer lesquelles des K observations de l'ensemble des données d'apprentissage sont les plus similaires à une nouvelle entrée. La mesure la plus populaire est la distance euclidienne, mais d'autres peuvent être utilisées comme celle de cosinus, de Manhattan et de Minkowski selon le contexte, la nature des données et leurs caractéristiques [107].

La régression linéaire :

Les modèles linéaires sont largement utilisés dans la pratique. Ils ont des racines qui remontent à plus de cent ans, et ont été étudiés et améliorés au cours de ces dernières décennies. Le modèle se représente sous forme d'une relation linéaire qui lie un ensemble de valeurs d'entrée \mathbf{x} (où $\mathbf{x} \in \mathbf{R}^p$), appelées variables explicatives, à un ensemble de valeurs observées y (où $y_i \in \mathbf{R}$), par un jeu de coefficients (w) comme indiqué dans l'équation suivante [11] :

$$y_i = \sum_{j=1}^p x_{ij} w_j + w_0 + \epsilon \quad (1.8)$$

où ϵ est un bruit aléatoire et $i \in \{1, \dots, N\}$ avec N : le nombre des observations.

L'apprentissage d'un modèle de régression linéaire consiste à chercher le jeu de coefficients (\hat{w}) qui optimise la prédiction de y sur les données d'entraînement. Selon le paradigme d'apprentissage supervisé, un modèle de régression linéaire optimise la recherche de ses coefficients en suivant l'algorithme du gradient [108], qui est très générique et capable de trouver des solutions optimales à un large éventail de problèmes. L'idée générale de cette descente est de modifier itérativement les coefficients du modèle afin de minimiser l'erreur sur l'ensemble des données d'entraînement. Concrètement, l'algorithme commence par une initialisation aléatoire des coefficients pour comparer la prédiction avec la valeur réelle à l'aide d'une fonction d'erreur. Ensuite, le gradient local de cette fonction est calculé par rapport au vecteur des coefficients. L'algorithme améliore la performance du modèle en modifiant ses coefficients par

un pas, appelé pas d'apprentissage, vers la direction descendante du gradient. Ainsi, chaque pas améliore la performance du modèle jusqu'à ce que l'algorithme converge vers un minimum [13].

Il existe des variantes de ce modèle d'apprentissage supervisé linéaire. Celles-ci ne cherchent pas qu'à minimiser l'erreur de la prédiction sur les données d'apprentissage, mais aussi à réduire la complexité du modèle : la régularisation de ces modèles. Pour un modèle linéaire, la régularisation est généralement obtenue en contraignant la norme du vecteur des poids. Les deux régularisations les plus couramment utilisées à la régression linéaire sont celle de Ridge et celle de Lasso.

La régression Ridge :

La régression Ridge, également appelée régularisation Tikhonov, est une version régularisée de la régression linéaire : l'introduction d'un terme de régularisation, égal à $\alpha \sum_{j=1}^p \hat{w}_j^2$, dans la fonction coût, force le modèle à la fois à s'adapter aux données d'apprentissage et à garder les poids du modèle aussi petits que possible [11, 109]. Ainsi, l'entraînement du modèle linéaire de la régression Ridge se résume à la minimisation de la fonction coût f_c suivante [11] :

$$f_c = \sum_{i=1}^N (y_i - \hat{y}_i)^2 + \frac{\alpha}{2} \sum_{j=1}^p \hat{w}_j^2 \quad (1.9)$$

avec \hat{y}_i est la valeur prédite où $\hat{y}_i = \sum_{j=1}^p x_{ij} \hat{w}_j + \hat{w}_0$.

Si $\alpha = 0$, la régression Ridge est simplement une régression linéaire. Si α est très grand, alors tous les poids finissent par être très proches de zéro et le résultat est une ligne plate passant par la moyenne des données.

La régression Lasso :

La régression Lasso, l'abréviation de "Least Absolute Shrinkage and Selection Operator Regression", est une autre régularisation de la régression linéaire qui ajoute le terme $\alpha \sum_{i=1}^p |\hat{w}_i|$. La fonction coût devient donc [109, 11] :

$$f_c = \sum_{i=1}^N (y_i - \hat{y}_i)^2 + \frac{\alpha}{2} \sum_{i=1}^p |\hat{w}_i| \quad (1.10)$$

Une caractéristique importante de la régression Lasso est qu'elle a tendance à éliminer complètement les poids des variables explicatives les moins importantes. En d'autres termes, la régression Lasso effectue automatiquement la sélection des variables explicatives pertinentes [68].

Les machines à vecteurs de support pour régression :

Afin d'optimiser leurs performances, une base théorique a été développée pour combiner les modèles d'apprentissage supervisé avec des fonctions noyaux [110]. Cette combinaison conduit à de nouveaux algorithmes qui se formulent en tant que problèmes d'optimisation convexe exempts de minima locaux. Les fonctions noyau offrent la possibilité de modéliser les structures non-linéaires à l'aide des représentations linéaires [111].

Les machines à vecteurs support (Support Vector Machines - SVM), sont l'exemple le plus connu des modèles d'apprentissage supervisé à noyau. Les SVM ont été introduites en 1992 [112], et ont été depuis généralisées et appliquées à différents problèmes, où elles ont tenu des records de performance [113], comme la reconnaissance de chiffres manuscrits [114], la catégorisation des textes [115], le traitement d'images [116] et le traitement des séries temporelles [117].

Les machines à vecteurs support de régression, couramment appelé SVR, reposent sur deux idées principales : la première est d'estimer l'hyperplan qui ajuste les données d'entraînement, tandis que la deuxième est de transformer l'espace de représentation de données initial en un espace dans lequel il est probable que l'ajustement de données soit linéaire à l'aide d'une fonction noyau (Kernel trick) [13]. La formulation mathématique du problème de régression est la suivante [118, 112] : considérons les données d'entraînement sous la forme suivante :

$$\{(\mathbf{x}_i, y_i) ; i = 1 \dots N\} \subset \mathbf{R}^p \times \mathbf{R} \quad (1.11)$$

où \mathbf{R}^p est l'espace de données d'entrée, $\mathbf{x}_i \in \mathbf{R}^p$ est la série des variables explicatives et $y_i \in \mathbf{R}$ est la série de la variable cible. L'idée majeure de SVR est de faire revenir un problème de régression non linéaire par à autre linéaire grâce à une fonction φ qui permet de définir la fonction f comme :

$$f(\mathbf{x}_i) = \langle w, \varphi(\mathbf{x}_i) \rangle + b \quad (1.12)$$

où \langle, \rangle est le produit scalaire dans \mathbf{R}^p , $w \in \mathbf{R}^k$ est le vecteur qui regroupe le jeu de coefficients de la régression, $\varphi(.) : \mathbf{R}^p \rightarrow \mathbf{R}^k$ est la fonction non linéaire qui fait correspondre l'espace d'entrée à un espace dit de haute dimension où la régression linéaire est effectuée. La dimension k de cet espace est implicitement définie, ce qui signifie qu'il peut être de dimension infinie. b est le terme de biais.

L'estimation de ces deux paramètres de SVR est un problème d'optimisation qui se formule comme suit :

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (1.13)$$

Avec les trois contraintes suivantes :

- $y_i - f(\mathbf{x}_i) \leq \epsilon + \xi_i$
- $f(\mathbf{x}_i) - y_i \leq \epsilon + \xi_i^*$
- $\xi_i, \xi_i^* \geq 0$

et la fonction d'erreur suivante :

$$|y - f(\mathbf{x}, w)|_\epsilon = \begin{cases} 0 & \text{si } |y - f(\mathbf{x}, w)| \leq \epsilon \\ |y - f(\mathbf{x})| - \epsilon & \text{sinon.} \end{cases} \quad (1.14)$$

où : la constante C est le coefficient de régularisation et ϵ représente la précision de la fonction estimée. Ces derniers sont deux hyperparamètres : des constantes définies par l'utilisateur qui sont généralement calculées de manière empirique (cf. Figure 1.20). L'algorithme précédemment détaillé est réalisable dans l'hypothèse où la fonction f existe. Cependant, cela n'est pas toujours le cas. Ainsi, deux variables sont introduites (ξ_i^* , ξ_i) pour ajouter des seuils d'erreur acceptables [117].

La solution de ce problème est obtenue en suivant la méthode de Lagrange avec les conditions de KKT (Karush- Kuhn-Tucker). Plus de détails sur ces deux techniques se trouvent dans [119, 120, 118]. Au final, le SVR résultant pour l'estimation de fonctions non linéaires prend la forme de :

$$f(\mathbf{x}) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \langle \varphi(\mathbf{x}), \varphi(\mathbf{x}_i) \rangle + b \quad (1.15)$$

où α_i et α_i^* sont les multiplicateurs de Lagrange. Ces derniers ne peuvent être non-nuls que dans le cas où $|y - f(\mathbf{x})| \geq \epsilon$. En d'autres termes, pour tous les points qui sont à l'intérieur du tube de diamètre ϵ , les multiplicateurs sont nuls [118]. Ainsi, les échantillons qui ont des multiplicateurs Lagrange non-nuls sont appelés vecteurs de support (SV), d'où le nom les machines à vecteurs de support (cf. Figure 1.19).

En injectant une fonction noyau $K(\mathbf{x}, \mathbf{x}_i) = \langle \varphi(\mathbf{x}), \varphi(\mathbf{x}_i) \rangle$ dans l'équation 1.15, la fonction non-linéaire recherchée prend la forme :

$$f(\mathbf{x}) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(\mathbf{x}, \mathbf{x}_i) + b \quad (1.16)$$

Plusieurs fonctions noyau peuvent être choisies selon la nature des données comme [118] :

— La fonction linéaire :

$$K(\mathbf{x}, \mathbf{x}_i) = \langle \mathbf{x}, \mathbf{x}_i \rangle \quad (1.17)$$

— La fonction polynomiale :

$$K(\mathbf{x}, \mathbf{x}_i) = (\langle \mathbf{x}, \mathbf{x}_i \rangle + p)^d, d \in \mathbf{N}, p > d \quad (1.18)$$

— La fonction perceptron multi-couches :

$$K(\mathbf{x}, \mathbf{x}_i) = \tanh(\phi \langle \mathbf{x}, \mathbf{x}_i \rangle + \theta), \phi > 0, \theta > 0 \quad (1.19)$$

— Les fonctions radiales de base gaussienne :

$$K(\mathbf{x}, \mathbf{x}_i) = \exp\left(\frac{-\|\mathbf{x} - \mathbf{x}_i\|^2}{2\sigma^2}\right) \quad (1.20)$$

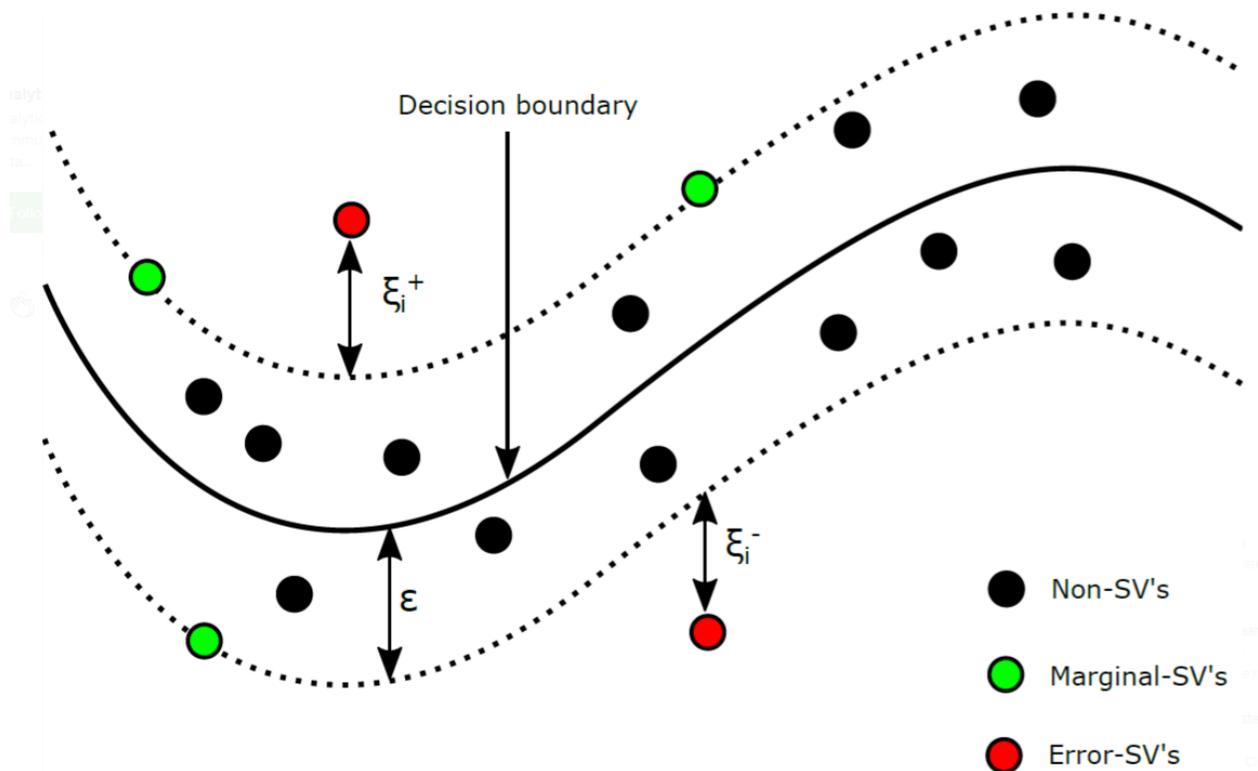


FIGURE 1.19 – La structure SVR [12]

Les arbres binaires et leurs agrégations

En 1984, Breiman et al. présentent un cadre général des méthodes de partitionnement récursif ou de segmentation [121], sous l'acronyme CART : Classification and Regression Tree. Ces méthodes présentent leurs résultats sous une forme graphique simple à interpréter : l'ensemble des observations est regroupé à la racine d'un arbre qui se décline en plusieurs noeuds, où chaque noeud père se divise en deux noeuds fils qui contiennent des données plus homogènes en termes d'un critère de division. Le même processus se répète pour diviser les données d'apprentissage en populations plus fines jusqu'à un critère d'arrêt, pour arriver finalement aux noeuds terminaux auxquels sont attribuées des valeurs de la variable quantitative [122]. Ainsi, la forme finale des résultats est un arbre binaire commençant par une racine jusqu'à plusieurs noeuds terminaux, appelés aussi feuilles.

L'arbre binaire, ainsi décrit, nécessite de définir un critère de division selon lequel la population d'un noeud (t) est découpée. Ce découpage est de forme :

$$\{x_{ij} \leq d\} \cup \{x_{ij} \geq d\} \quad (1.21)$$

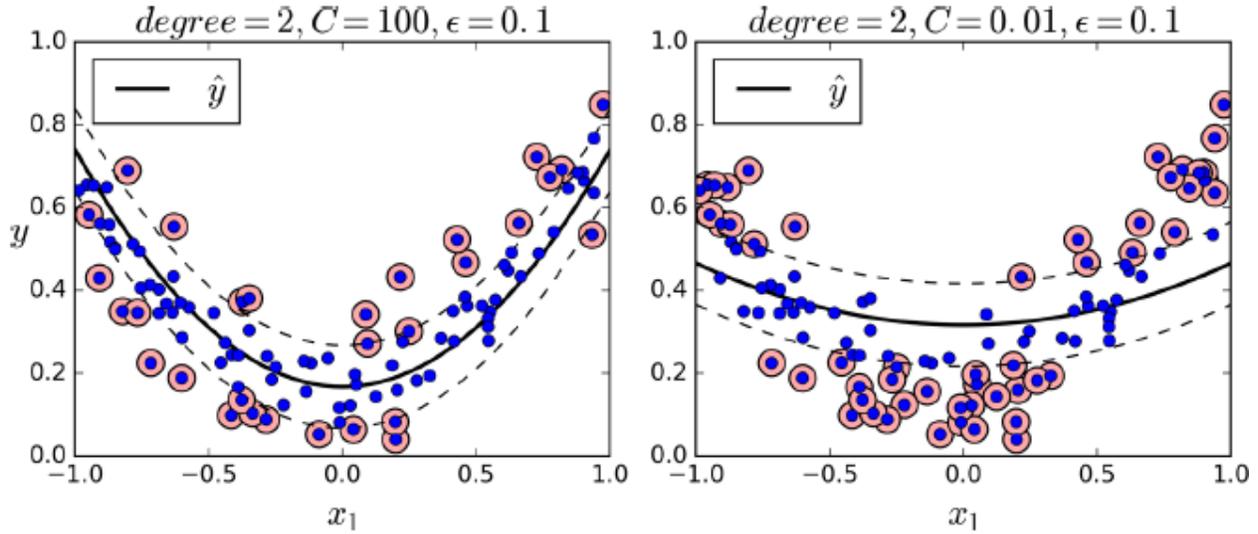


FIGURE 1.20 – L'effet des deux hyperparamètres sur la régression SVR [13]

où $i \in \{1, \dots, N\}$, $j \in \{1, \dots, p\}$ et $d \in \mathbf{R}$. Ainsi, et selon ce découpage, toutes les observations ayant une valeur de la variable explicative $x_{i,j}$ inférieure à d passeront au noeud fils gauche t_l , tandis que le reste des observations du noeud père ira dans le noeud fils droite (t_r). L'objectif de cet algorithme est de définir le critère de division qui fournit le meilleur découpage. En d'autres termes, il faut définir le couple (j,d) qui minimise une certaine fonction coût. Pour le cas de la régression, le couple (j,d) est celui qui minimise la variance intra-groupes résultant du découpage du noeud t en 2 noeuds fils (cf. Figure 1.21) [14].

Puisque la variance d'un noeud (t) se définit comme [123] :

$$V(t) = \frac{1}{\#t} \sum_{i:x_i \in t} (y_i - \bar{y}_t)^2 \quad (1.22)$$

où \bar{y}_t est la moyenne des observations y_i présentes dans le noeud t . Donc, le critère de division est la solution optimale de l'équation suivante :

$$\frac{1}{N} \sum_{(x_i, y_i) \in t_l} (y_i - \bar{y}_{t_l})^2 + \frac{1}{N} \sum_{(x_i, y_i) \in t_r} (y_i - \bar{y}_{t_r})^2 = \frac{\#t_l}{N} V(t_l) + \frac{\#t_r}{N} V(t_r) \quad (1.23)$$

Le découpage selon le critère de division commence par la racine, qui regroupe toutes les données d'entraînement, pour définir les deux noeuds fils, qui subiront eux aussi un découpage, et ainsi de suite. Le procédé est répété jusqu'à atteindre un critère d'arrêt, qui se formule souvent en termes d'un nombre minimal d'observations contenues dans les noeuds terminaux. La valeur de sortie de chaque noeud terminal est la moyenne de ses observations. Ainsi, l'arbre

maximal pleinement développé (T_{max}) est obtenu, qui se compose du nombre maximal de feuilles possibles ce qui le rend excessivement développé. Il n'est pas stable puisqu'il sur-ajuste les données d'entraînement et ne peut pas généraliser ses estimations sur les données de test. Il convient donc de chercher un sous-arbre binaire de (T_{max}) plus parcimonieux et donc plus robuste au moment du test. Cette procédure de sélection de modèles s'appelle l'élagage de l'arbre maximal (pruning) [123, 14].

L'arbre optimal admissible varie de celui trivial, qui est réduit à une seule feuille, à celui maximal (T_{max}). Ainsi, le nombre des modèles admissibles s'accroît exponentiellement, et il n'est donc pas envisageable de tous les considérer. Leo Breiman et al. [121] proposent de construire une suite de sous-arbres emboîtés, c'est à dire élagués les uns des autres, qui minimise une erreur de généralisation. Cette suite est obtenue itérativement en coupant des branches à chaque étape pour minimiser l'erreur d'ajustement du sous-arbre T élagué [123] :

$$\overline{err}(T) = \frac{1}{N} \sum_{t \text{ feuille de } T} \sum_{(x_i, y_i) \in t} (y_i - \bar{y}_t)^2 \quad (1.24)$$

en la régularisant par une fonction linéaire du nombre de feuilles $|T|$, ce qui conduit au critère des moindres carrés pénalisés :

$$crit_\alpha(T) = \overline{err}(T) + \alpha|T| \quad (1.25)$$

La solution ainsi obtenue est un optimum local mais l'efficacité et la fiabilité sont préférées à l'optimalité.

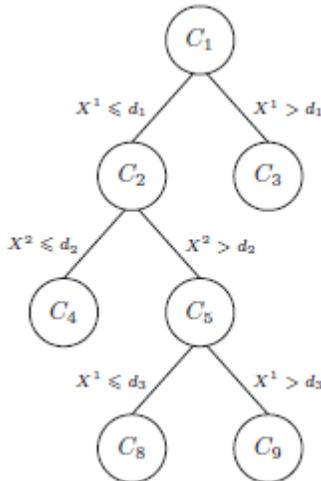


FIGURE 1.21 – La construction d'un arbre binaire [14] où la variable explicative $x_{i,j}$ est notée X^j .

Pour améliorer les prédictions issues des arbres binaires de décision, des algorithmes ont été développés combinant un grand nombre d'arbres binaires, pour améliorer l'ajustement de

données, selon deux stratégies : une première agrégation aléatoire qui se base sur le bagging comme dans le cas des forêts aléatoires, et une deuxième qui repose sur une construction adaptative (Boosting) comme dans le cas des arbres à gradient adaptatif. Dans ce qui suit, les fondamentaux de chacune de ces deux stratégies seront présentés respectivement.

Les forêts aléatoires - ‘Random Inputs’ : Avant de présenter les forêts aléatoires, il convient de présenter la méthode aléatoire sur laquelle elles se basent : le Bagging - **Bootstrap** et **Aggregating**. Cette méthode a été introduite par Breiman [124]. Elle consiste à tirer indépendamment plusieurs échantillons Bootstrap des données disponibles, à appliquer une méthode de prédiction (appelée aussi règle de base) sur chacun d’eux pour obtenir une collection de prédicteurs, et enfin d’agréger ces prédicteurs de base. Ainsi, l’idée est donc construire une collection variée de prédicteurs qui, lorsqu’ils seront combinés, permettent d’obtenir un modèle de prédiction performant.

Un échantillon Bootstrap peut être obtenu en tirant aléatoirement n observations avec remise dans l’échantillon d’apprentissage, où la probabilité du tirage de chaque observation est de $\frac{1}{N}$. Une deuxième façon serait de tirer aléatoirement k observations sans remise avec $k < N$ [125].

Les modèles de forêts aléatoires suivent la même logique de Bagging. Leur construction commence par générer plusieurs échantillons Bootstrap. Chacun de ces échantillons servira comme données d’entraînement pour un arbre binaire : le critère de division de chaque noeud est défini sur un tirage aléatoire de m variables explicatives. Chacun de ces arbres est développé jusqu’à sa forme maximale sans élagage. L’ensemble des arbres binaires agrégés constitue le prédicteur forêts aléatoires dont la sortie est la moyenne des estimations de chacune de ses arbres binaires maximales [126, 127].

Les forêts aléatoires est donc une variante du Bagging avec une variable aléatoire supplémentaire : le découpage des noeuds selon m variables tirées aléatoirement, uniformément et sans remise [123]. Le nombre m est un hyperparamètre fixé par l’utilisateur. Ainsi, les forêts aléatoires possèdent deux sources d’aléas pour l’agrégation de ses prédicteurs individuels : le Bootstrap, qui perturbe les échantillons d’entraînement, et le tirage de m variables aléatoires à chaque noeud, pour introduire un aspect aléatoire lors du développement de la règle de base (l’arbre binaire) [128].

Grâce à ces deux aléas, les perturbations induites dans les forêts aléatoires impliquent une indépendance et une différence entre les arbres binaires construits, sans pour autant dégrader leurs performances individuelles. Or, cette perturbation reste à calibrer pour trouver un compromis : d’une part, une grande perturbation dégrade les estimations des arbres et de facto celle du prédicteur agrégé. D’autre part, une faible perturbation fournit des prédicteurs individuels similaires et n’améliore donc pas celui agrégé [129, 130, 131].

Les arbres à gradient adaptatif : Les arbres à gradient adaptatif se basent sur la méthode de boosting pour construire leurs modèles. Cette méthode d’ensemble est l’une

des plus performantes à ce jour [123] et a été introduite par Freund en 1996 [132] pour des problèmes de classification sous le nom d'Adaboost (**Ad**aptive **bo**osting). Comme le Bagging, l'Adaboost est une méthode d'agrégation de modèles par une moyenne pondérée des estimations. Or, et contrairement à celle du Bagging, la construction des modèles agrégés dans le cas d'Adaboost est adaptative [133] : chaque modèle est une amélioration de son précédent en affectant, lors de son estimation, des poids plus importants aux observations mal-ajustées par son précédent. En effet, toutes les observations commencent par un poids initial uniforme ($\frac{1}{N}$). Ces poids évolueront à chaque itération en fonction de la qualité de leurs estimations : le poids d'une observation reste constant si elle est bien estimée, sinon il accroît proportionnellement à l'erreur d'ajustement du modèle. A la fin de l'algorithme Adaboost, les modèles issus de chaque itérations sont agrégés sous forme d'une combinaison pondérée par leurs qualités d'ajustement.

Une autre forme aléatoire de Boosting a été proposée par Breiman sous le nom d'Arcing [134] (**Ad**aptively **res**ample and **comb**ine), qui remplace la mise à jour des poids à chaque itération par un tirage avec remise, comme dans le Bootstrap, d'un nouvel échantillon d'apprentissage selon des probabilités proportionnelles à l'erreur d'ajustement de l'étape précédente [128]. L'algorithme d'Arcing adapté à la régression commence par le tirage uniforme d'un premier échantillon bootstrap, sur lequel est entraînée une règle de base pour obtenir un premier prédicteur. Ensuite, l'erreur de prédiction sur ce premier échantillon est mesurée pour déterminer la loi de tirage d'un deuxième échantillon. En effet, l'idée est d'accorder plus d'importance aux observations mal prédites en augmentant leurs probabilités lors du tirage du deuxième échantillon bootstrap. La règle de base sera entraînée sur ce nouvel échantillon pour obtenir un deuxième prédicteur, dont l'erreur conditionnera le tirage d'un troisième échantillon et ainsi de suite. L'ensemble de prédicteurs est agrégé pour fournir une seule sortie calculée par une moyenne pondérée.

Ainsi, le boosting est une méthode qui se concentre de plus en plus sur les observations difficiles à estimer par la règle de base choisie, pour améliorer la performance globale d'un ensemble agrégé, en construisant d'une manière séquentielle des prédicteurs qui se complètent l'un l'autre. Elle a été adaptée aussi pour les problèmes de régression.

Dans la même approche adaptative, Friedman a introduit un modèle G-TB (Gradient-TreeBoost)[135] d'agrégation d'arbres binaires pour minimiser une fonction d'erreur pas à pas. En effet, et à chaque itération, un arbre binaire est ajouté à l'ensemble pour améliorer sa performance. Le modèle G-TB est donc une descente de gradient approché par un arbre de régression. Ainsi, et à chaque itération m , le modèle f du G-TB s'exprime comme suit [128] :

$$f_m = f_{m-1} - \gamma_m \sum_{i=1}^N \nabla_{f_{m-1}} l(y_i, f_{m-1}(\mathbf{x}_i)) \quad (1.26)$$

où γ est le pas de la descente de gradient et $l()$ est la fonction d'erreur de l'agrégation du modèle.

La construction d'un modèle G-TM se résume alors en un problème d'optimisation du pas

d'apprentissage γ pour minimiser la fonction suivante :

$$\min_{\gamma} \sum_{i=1}^N [l(y_i, f_{m-1}(\mathbf{x}_i) - \gamma \frac{\delta l(y_i, f_{m-1}(\mathbf{x}_i)}{\delta f_{m-1}(\mathbf{x}_i)})] \quad (1.27)$$

Le déroulement de l'algorithme G-TB [135] commence par l'initialisation d'une racine. Pour une itération m , l'estimation du gradient consiste à calculer les termes $(\frac{\delta l(y_i, f_{m-1}(\mathbf{x}_i)}{\delta f_{m-1}(\mathbf{x}_i)})$ à chaque noeud du modèle de l'itération $m-1$ et pour chaque échantillon des données d'apprentissage. Ainsi, un arbre de régression δ_m est entraîné sur l'ensemble des couples $(\mathbf{x}_i, \frac{\delta l(y_i, f_{m-1}(\mathbf{x}_i)}{\delta f_{m-1}(\mathbf{x}_i)})$. Ensuite, le pas de descente du gradient γ_m est calculé en minimisant l'équation 1.27. À la fin de chaque itération, l'arbre δ_m est combiné avec le modèle de l'étape précédente selon l'équation suivante :

$$f_m(\mathbf{x}) = f_{m-1}(\mathbf{x}) + \gamma_m \delta_m(\mathbf{x}) \quad (1.28)$$

Dans la même étude [135], Friedman introduit une variante du modèle G-TB, pour incorporer le caractère aléatoire comme partie intégrante de la procédure, sous le nom de Stochastic Gradient-TreeBoost (SG-BT). À chaque itération, un sous-échantillon est tiré aléatoirement à partir de l'ensemble de données d'apprentissage. Ce sous-échantillon est utilisé pour ajuster le prédicteur de base et mettre à jour l'ensemble agrégé pour l'itération en cours. Ce tirage aléatoire permet de construire, comme dans le cas du bagging, une agrégation de prédicteurs plus indépendants.

Les Réseaux de Neurons Artificiels (RNA) :

Les techniques d'apprentissage supervisé s'inspirent de plusieurs domaines de recherche comme les statistiques, l'algèbre linéaire, la robotique, et notamment les neurosciences. Ces dernières ont inspiré le développement des réseaux de neurones artificiels : en 1947, Warren McCulloch et Walter Pitts introduisent le premier neurone artificiel [136] qui active sa sortie binaire lorsque le nombre de ses entrées binaires actives dépasse un seuil. Plusieurs neurones artificiels peuvent être combinés sous forme d'un réseau pour couvrir les différentes propositions logiques. En 1958, Frank Rosenblatt invente une architecture de RNA [137] qui se base sur une version modifiée du neurone artificiel nommé LTU (Linear Threshold Unit) [138], qui ne traite pas que les entrées binaires mais aussi celles réelles pour calculer leur somme pondérée :

$$S = \sum_{i=1}^N w_i \cdot x_i \quad (1.29)$$

Une fonction échelon est ensuite appliquée à la somme S pour produire la sortie du LTU :

$$H_w(x) = Step(S) = Step \left(\sum_{i=1}^N w_i \cdot x_i \right) \quad (1.30)$$

Un simple perceptron est un réseau composé d'une couche principale de LTU où chaque neurone est connecté à toutes les entrées. Ces connexions sont souvent établies à travers des neurones intermédiaires qui constituent la couche d'entrée [138].

L'entraînement du perceptron se base sur l'apprentissage hebbien : Donald Hebb [139] suggère que lorsqu'un neurone biologique déclenche un autre, leur liaison se renforce. Ainsi, Franck Rosenblatt propose un entraînement du perceptron basé sur une variante de la règle de Hebb [138]. En effet, et à chaque itération d'entraînement, le perceptron renforce le poids des connexions liés aux entrées qui contribuent à la prédiction correcte, et affaiblit ceux liés à chaque sortie qui produit une prédiction erronée. La mise à jour des poids s'exprime donc comme suit :

$$w_{ij} \leftarrow w_{ij} + \eta(y_i - \hat{y}_j).x_i \quad (1.31)$$

où :

- w_{ij} : le poids de la connexion entre le $i^{\text{ème}}$ neurone d'entrée et le $j^{\text{ème}}$ neurone de sortie.
- x_i : la $i^{\text{ème}}$ entrée du perceptron.
- \hat{y}_j : la prédiction du $j^{\text{ème}}$ neurone de sortie
- y_j : la valeur observée et souhaitée pour le $j^{\text{ème}}$ neurone de sortie.
- η : le taux d'apprentissage.

Cependant, Marvin Minsky et Seymour Papert [140] ont exposé les limitations des perceptrons, notamment dans les problèmes de classification XOR (OU exclusif). Certaines limites sont levées en agrégeant plusieurs perceptrons. L'ensemble forme un Perceptron MultiCouche (PMC), illustré dans la figure 1.22, qui est constitué d'une couche d'entrée, d'une ou plusieurs couches de LTU appelées couches cachées et d'une dernière couche de LTU appelée couche de sortie [141]. Les PMC sont donc des réseaux de neurones profonds (RNP).

Pour entraîner les RNP, Rumelhart et McClelland [142] introduisent l'algorithme rétropropagation pour effectuer une descente de gradient en utilisant la différentiation automatique en mode inverse : à chaque itération d'entraînement, l'algorithme commence par effectuer une prédiction en calculant la sortie de chacun des neurones de sortie ainsi que son erreur ; cette étape est appelée communément la passe en avant (Forward pass). Ensuite, l'algorithme détermine la contribution de chaque neurone de la couche cachée précédente à l'erreur de chaque neurone de la couche de sortie. Le processus se poursuit jusqu'à ce que l'algorithme atteigne la couche d'entrée. Ainsi cette passe en arrière rétropropage le gradient d'erreur sur tous les poids des connexions du réseau. A la fin, l'algorithme se termine par une étape de descente de gradient pour mettre à jour les poids des connexions du réseau pour améliorer l'ajustement des données d'apprentissage. Il est important de mentionner que cet algorithme n'est effectif que si la fonction échelon des LTU est remplacée par la fonction logistique :

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (1.32)$$

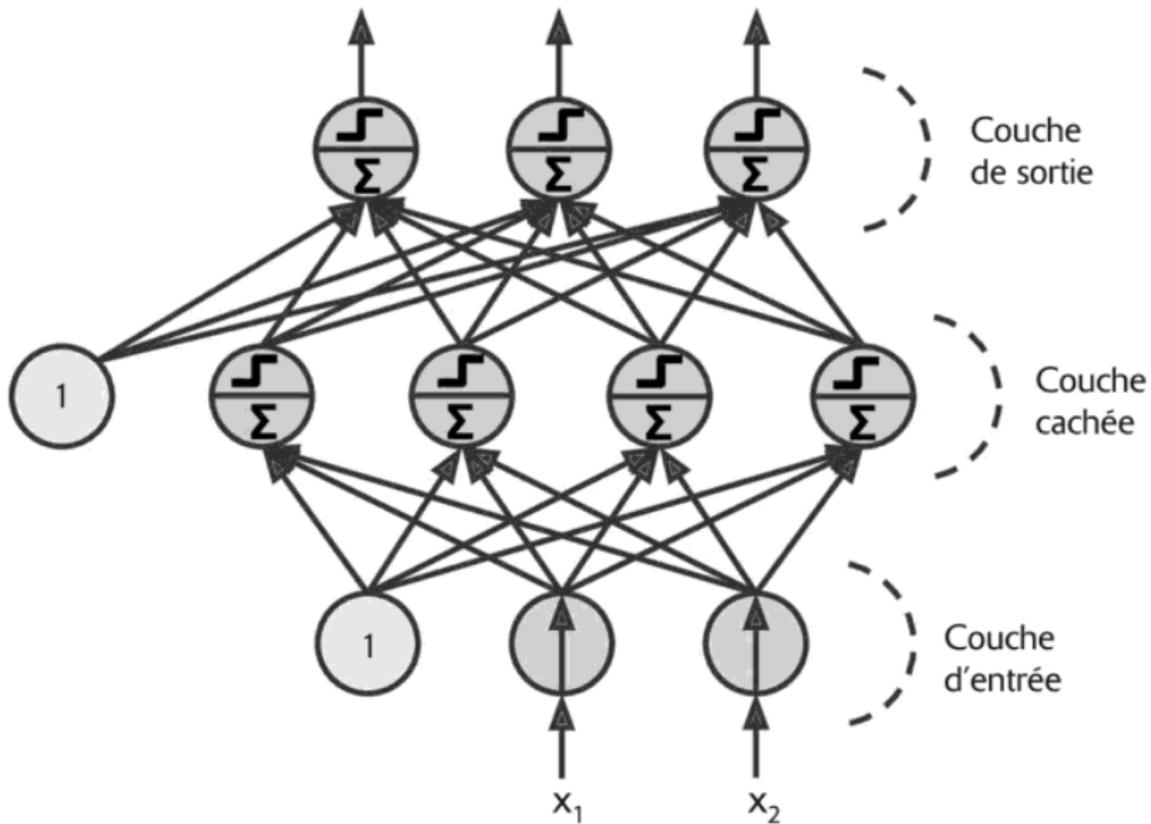


FIGURE 1.22 – Perceptron multicouche - PMC [15]

Les réseaux de neurones récurrents (RNR) : D'innombrables tâches d'apprentissage nécessitent un traitement séquentiel des données, comme le traitement d'images et la reconnaissance vocale. Dans d'autres domaines, tels que la prédiction de séries temporelles et l'analyse vidéo, un modèle doit apprendre à traiter les données séquentielles. Les tâches interactives, telles que la traduction du langage naturel et le contrôle robotique exigent les deux capacités. Les réseaux de neurones récurrents (RNR) se proposent comme une solution pour capturer la dynamique des séquences. Les modèles RNR ont la capacité de transmettre sélectivement des informations entre les étapes d'une séquence, tout en traitant ses données un élément à la fois. Ils peuvent donc modéliser des dépendances séquentielles et temporelles sur plusieurs échelles [143].

Dans sa forme la plus simple [144], un RNR est composé d'un seul neurone qui, à chaque étape temporelle t , reçoit à la fois le vecteur d'entrée x_t et le vecteur de sortie de l'étape

précédente y_t . Il possède donc deux jeux de poids : un premier pour les entrées W_x et un deuxième pour les sorties précédentes W_y . Ainsi, la sortie d'une couche de neurones récurrents s'exprime selon l'équation 1.33 [143].

$$\underline{y}_t = \phi(W_x^T \cdot \underline{x}_t + W_y^T \cdot \underline{y}_{t-1} + \underline{b}) \quad (1.33)$$

avec :

- \underline{y}_t : les sorties de la couche à l'étape temporelle t.
- \underline{x}_t : les entrées de la couche à l'étape temporelle t.
- W_x : les poids des connexions des entrées pour l'étape t.
- W_y : les poids des connexions des sorties pour l'étape t-1
- \underline{b} : les termes constants des neurones de la couche.

A une étape temporelle t, la sortie du neurone récurrent dépend de l'historique de ses entrées. Ce neurone peut être considéré comme une cellule de mémoire qui conserve un état entre plusieurs étapes temporelles. L'état \underline{h}_t est une fonction de l'entrée \underline{x}_t et de son état à l'étape précédente \underline{h}_{t-1} : $\underline{h}_t = f(\underline{h}_{t-1}, \underline{x}_t)$. En dépliant le réseau dans le temps, ce dernier peut être interprété non pas comme cyclique mais plutôt comme un RNP avec une couche dont les poids sont partagés entre les pas de temps. Les RNC peuvent être entraînés en suivant une rétropropagation à travers le temps [145].

L'entraînement des réseaux de neurones profonds a longtemps été considéré comme difficile, mais celui des réseaux récurrents peut être particulièrement problématique à cause des difficultés de capturer les dépendances à longue portée [146]. En effet, et sur les longues séquences, l'entraînement des RNR s'exécute sur de nombreuses étapes temporelles. Ainsi, le RNR résultant est extrêmement profond et peut donc être confronté à des problèmes de disparition ou d'explosion de gradient lors de la rétropropagation des erreurs sur de nombreux pas temporels. Razvan et al. [147] traitent ces deux problèmes d'un point de vue analytique et déterminent les conditions dans lesquelles ils se produisent. Ils proposent aussi une approche d'entraînement par le biais d'une régularisation qui force les poids de connexions à rester dans des intervalles où le gradient ne disparaît ni explose.

Pour résoudre ces problèmes, Hochreiter et Schmidhuber [148] ont introduit une variation de la cellule mémoire : La cellule de longue mémoire à court terme (Long short-term memory - LSTM). Grâce à son architecture qui permet un flux d'informations constant à travers des unités auto-connectées, LSTM apprend à franchir des intervalles de temps de plus de 1000 pas. Ainsi, ce réseau de neurones récurrents peut être décrit comme une cellule mémoire dont l'état est divisé en deux vecteurs : h_t l'état à court terme et c_t l'état à long terme. En détail, son architecture est composée de 4 couches :

- La couche principale : traite les entrées \underline{x}_t et l'état à court terme précédent \underline{h}_{t-1} pour fournir \underline{g}_t , qui sera partiellement stocké dans l'état à long terme (expliqué ci-après).
- Les trois contrôleurs de porte : par le biais de leur fonction d'activation logistique, leurs sorties varient entre 0 à 1 pour contrôler les portes de multiplication par éléments suivantes :

- La porte d'entrée : identifie les parties pertinentes de \underline{g}_t pour les ajouter à l'état long terme (voilà pourquoi nous avons qualifié \underline{g}_t comme partiellement stocké). Cette porte est contrôlée par \underline{i}_t .
- La porte d'oubli : identifie les parties pertinentes de l'état à long terme à abandonner (oublier) et donc les parties complémentaires à maintenir de manière pertinente en mémoire à long terme. Cette porte est contrôlée par \underline{f}_t .
- La porte de sortie : identifie les parties de l'état long terme à lire et à produire lors de l'étape courante. Cette porte est contrôlée par \underline{o}_t .

Le processus du traitement LSTM est résumé par les équations suivantes ;

- La couche principale :

$$\underline{g}_t = \tanh(W_{xg}^T \cdot \underline{x}_t + W_{hg}^T \cdot \underline{h}_{t-1} + \underline{b}_g) \quad (1.34)$$

- Le contrôleur de la porte d'entrée :

$$\underline{i}_t = \sigma(W_{xi}^T \cdot \underline{x}_t + W_{hi}^T \cdot \underline{h}_{t-1} + \underline{b}_i) \quad (1.35)$$

- Le contrôleur de la porte d'oubli :

$$\underline{f}_t = \sigma(W_{xf}^T \cdot \underline{x}_t + W_{hf}^T \cdot \underline{h}_{t-1} + \underline{b}_f) \quad (1.36)$$

- Le contrôleur de la porte de sortie :

$$\underline{o}_t = \sigma(W_{xo}^T \cdot \underline{x}_t + W_{ho}^T \cdot \underline{h}_{t-1} + \underline{b}_o) \quad (1.37)$$

- L'état à long terme :

$$\underline{c}_t = \underline{f}_t \otimes \underline{c}_{t-1} + \underline{i}_t \otimes \underline{g}_t \quad (1.38)$$

- La sortie et l'état à court terme :

$$\underline{y}_t = \underline{h}_t = \underline{o}_t \otimes \tanh(\underline{c}_t) \quad (1.39)$$

où :

- \otimes est la multiplication élément par élément entre les séquences (produit matriciel de Hadamard).
- W_{xi}, W_{xf}, W_{xo} et W_{xg} : les poids de connexions des 4 couches à l'entrée x_t .
- W_{hi}, W_{hf}, W_{ho} et W_{hg} : les poids de connexions des 4 couches au l'état court terme.
- $\underline{b}_i, \underline{b}_f, \underline{b}_o$ et \underline{b}_g : les termes constants des 4 couches.

En résumé, une cellule LSTM dispose de quatre fonctionnalités : identifier la partie pertinente de l'entrée grâce à la porte d'entrée, la sauvegarder dans l'état à long terme, apprendre à la maintenir aussi longtemps que nécessaire grâce à la porte d'oubli et apprendre à l-extraire lorsqu'elle est requise. Ceci explique la haute performance de la cellule LSTM, son entraînement rapide et sa détection des dépendances à long-terme.

Conclusion de la deuxième partie :

Comme précédemment présenté, la problématique à laquelle cette thèse se propose de répondre est l'estimation de l'amélioration de l'uni de la chaussée suite à sa réhabilitation. Pour ce faire, l'approche adoptée est de prédire le profil post-réhabilitation à partir de celui préexistant. Ce positionnement à l'échelle des profils permet de fournir une estimation assez détaillée de l'amélioration de l'uni préexistant défaut par défaut. Cette approche adoptée renvoie donc à une autre problématique qui est celle de la prédiction d'une série temporelle (le profil post-réhabilitation) à partir d'une autre (le profil préexistant). Cependant, le profil de la chaussée présente une corrélation spatiale qui peut concerner différentes échelles (longueurs d'ondes) dans la série temporelle. Compte tenu la nature de la problématique, l'approche adoptée dans ce travail de thèse est celle de prédire le profil post-réhabilitation par un modèle d'apprentissage automatique.

La deuxième partie de ce chapitre a été consacrée pour présenter les notions fondamentales de l'apprentissage automatique. Cet état de l'art indique que les algorithmes d'apprentissage supervisé sont particulièrement adaptés pour la prédiction des séries temporelles, comme celui de K-plus-proches voisins (KNN), les machines à vecteurs de support (SVR), les forêts aléatoires, les arbres à gradient adaptatif et les cellules mémoires de réseaux de neurones récurrents (LSTM). Ces méthodes présentent potentiellement les prédispositions à traiter de l'évolution d'un signal. Cependant, la corrélation spatiale dans le cas de l'uni et son caractère d'hérédité, en passant de la phase avant à celle après travaux, nécessite de faire un benchmark de ces méthodes quant à rendre compte de cette propriété particulière. Ce benchmark devant permettre d'aboutir au modèle le plus à même de prédire l'évolution de l'uni.

Toutefois, avant d'aborder la modélisation du profil post-réhabilitation, il convient de mettre en évidence ses caractéristiques statistiques comme une série temporelle ainsi que ses modalités d'évolution suite à la réhabilitation. Le chapitre suivant propose donc une analyse exploratoire de la notion du profil de la route et l'effet de la réhabilitation sur son évolution. En se basant sur les résultats de cette analyse, une stratégie de développement du modèle d'apprentissage supervisé pour la prédiction du profil post-réhabilitation sera mise en place.

Chapitre 2

Description et exploitation des données

2.1 Présentation des données mesurées

Les données utilisées dans cette étude sont issues du chantier d'entretien de l'autoroute A63. Plus précisément, les données caractérisent le rechargement de la voie lente par 4 cm de béton bitumineux drainant (BBD_r). Ce rechargement a été appliqué par le biais d'un finisseur guidé par vis calée. Les mesures des profils pré- et post-réhabilitation ont été réalisées par l'Unibox et s'étalent sur une distance de 9495 m avec un pas d'échantillonnage de 0.05m. Ainsi, l'ensemble de données se compose de deux profils (préexistant et post-réhabilitation) dont chacun contient 191940 points. La figure 2.1 présente un exemple d'un tronçon de ces deux mesures.

Le choix de la mesure de la totalité des données sur ce tronçon se justifie par deux raisons : d'une part, pour préserver l'homogénéité de l'ensemble de données. En effet, les procédés d'application des matériaux, comme le mode de guidage du finisseur ou le type de compactage, conditionnent les modes d'amélioration des défauts d'uni. Puisque ces procédés changent généralement d'un tronçon à l'autre sur le même chantier, les modes d'amélioration de l'uni changent aussi. Ceci induit des tendances divergentes dans l'ensemble des données mesurées sur le même chantier. Pour éviter cette hétérogénéité, le tronçon de la voie lente de l'A63 a été choisi puisque les procédés de sa réhabilitation restent inchangés le long de ses 9495 m. D'autre part, ce chantier est suffisamment long pour permettre un apprentissage efficace et un test significatif du modèle développé. Plus précisément, les données mesurées sur ce tronçon couvrent différents types d'irrégularités géométriques préexistantes, en termes d'amplitudes et d'étendues, avec leurs irrégularités géométriques post-réhabilitation correspondantes. Cette variété de données augmente la complexité du processus d'apprentissage, et par conséquent permet un entraînement représentatif du modèle, pour augmenter la précision de ses prédictions, tout en préservant sa capacité de généralisation lors de son test.

Ce volume restreint dépend de l'ensemble des données disponibles au moment de la réalisation

de cette thèse ainsi que celles que nous avons été en mesure d'analyser et d'épurer.

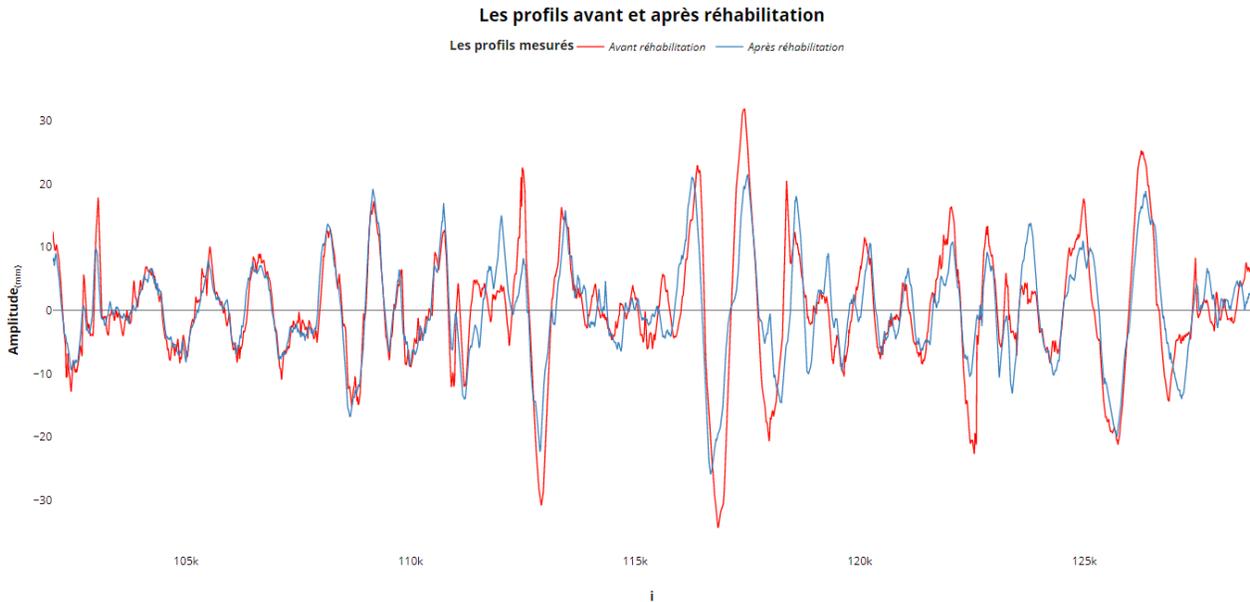


FIGURE 2.1 – Aperçu des profils pré- et post- réhabilitation mesurés sur le tronçon du rechargement de l'A63.

Dans ce qui suit, l'analyse exploratoire commence par l'identification de l'impact de la réhabilitation sur les défauts en comparant leurs empreintes pré- et post-réhabilitation.

2.2 L'impact de la réhabilitation sur l'évolution des défauts de l'uni

L'idée de cette étude est d'identifier l'impact de la réhabilitation sur les défauts en comparant l'empreinte énergétique initiale du défaut, dans le profil pré-réhabilitation, à celle du défaut qui lui correspond dans le profil post-réhabilitation. Cela nécessite dans un premier temps de pouvoir aligner convenablement les deux profils mesurés, ce qui permettra d'identifier la signature d'un défaut dans le profil pré-réhabilitation et celle de son correspondant dans le profil post-réhabilitation, pour ensuite les isoler et comparer leurs évolutions énergétiques. Ces deux étapes seront détaillées dans ce qui suit.

2.2.1 L'alignement des profils pré- et post-réhabilitation

Cette première étape vise à déterminer l'alignement convenable des profils mesurés, pré- et post-réhabilitation, qui facilitera l'identification de la signature initiale d'un défaut

préexistant et de sa correspondante dans le profil post-réhabilitation.

Pour ce faire, une correspondance est établie entre les abscisses GPS des origines et des fins pré- et post-réhabilitation relevés lors des mesures profilométriques en calculant les distances qui les séparent, pour ensuite ajuster leurs décalages.

Ce calcul de distance se base sur la formule d'Haversine qui s'exprime comme suit pour les deux points X_A et X_B :

$$d = 12742 \times \arcsin \left(\sqrt{\sin^2 \left(\frac{\varphi_B - \varphi_A}{2} \right) + \cos(\varphi_A) \cos(\varphi_B) \sin^2 \left(\frac{\lambda_B - \lambda_A}{2} \right)} \right) \quad (2.1)$$

où φ et λ sont respectivement la latitude et la longitude en radians.

Le résultat de cette première partie est deux signaux de même longueur mesurés entre deux points d'origine et de fin fixes avec une incertitude relative due à la résolution spatiale du capteur GPS. Ce niveau de précision est suffisant pour l'identification et l'extraction des signatures des défauts pré- et post-réhabilitation. Cependant, cet alignement des signaux sera affiné (cf. section 3.1.1) car il modifie l'association du modèle entre les défauts pré- et post-réhabilitation, nécessaire pour prédire l'évolution de l'uni.

2.2.2 L'identification et l'extraction des signatures des défauts pré- et post-réhabilitation

Après avoir amélioré la superposition des signatures des profils mesurés, la deuxième étape consiste à extraire la signature d'un défaut dans le profil pré-réhabilitation et celle de son correspondant dans le profil post-réhabilitation.

Avant de chercher à identifier un défaut, il convient de le définir à partir de sa mesure profilométrique. Puisque l'uni est défini comme l'ensemble des irrégularités géométriques de la surface de la chaussée, une première approche serait de considérer toute fluctuation du profil comme un défaut d'uni. Cette approche s'avère problématique : une fluctuation dans le signal mesuré ne représente pas nécessairement une irrégularité géométrique puisque la mesure comporte des données bruitées, notamment à l'échelle des petites ondes. Ceci est d'autant plus problématique quand le profilomètre repose sur des mesures lasers, comme dans le cas d'Unibox, qui sont plus susceptibles de subir des perturbations par la brillance de la chaussée. Par conséquent, il est nécessaire de définir un défaut comme étant une irrégularité géométrique monolithique, caractérisée par son amplitude et son étendue spatiale (c'est-à-dire son énergie), indépendamment de la fluctuation locale du signal erratique. Donc, la définition d'un défaut se basera sur son empreinte énergétique dans le signal profil mesuré.

L'algorithme 1 commence par le calcul de l'accumulation des énergies sur les profils mesurés. Ceci permettra de mettre en évidence les défauts qui seront repérés grâce à leurs sauts énergétiques brusques qu'ils engendrent sur les courbes d'accumulation. L'idée est donc d'identifier ces sauts énergétiques en calculant les dérivées des énergies accumulées pré- et post-réhabilitation. La dérivée d est estimée en suivant une approximation centrée du 4ème

ordre de la méthode des différences finies, comme indiqué par l'équation 2.2 :

$$d(i) = \frac{-1}{12\Delta x}(-y(i+2) + 8y(i+1) - 8y(i-1) + y(i-2)) \quad (2.2)$$

L'ensemble des données des dérivées est transmis à la fonction '*Peak detector*' qui a pour but de détecter les pics et les vallées dans les dérivées calculées. Ainsi, un défaut se définira comme une succession de deux vallées intercalées par un pic. Cette fonction *Peak detector* est basé sur un algorithme qui ajuste un polynôme quadratique à des groupes séquentiels de points de données. Le nombre de points de données utilisés dans l'ajustement est spécifié par le paramètre *Largeur*. Pour chaque pic ou vallée, l'ajustement quadratique est testé par rapport à un paramètre *Seuil*. Les pics dont la hauteur est inférieure au seuil ou les vallées dont le creux est supérieur au seuil sont ignorés. La définition d'un défaut se fait donc à travers le paramétrage de *Seuil* et *Largeur*. Dans cette étude, nous considérons une irrégularité géométrique comme un défaut d'uni que si son étendu dépasse 3 échantillons avec un gradient énergétique plus grand que $0.02 \text{ cm}^3/\text{cm}$. En dessous de ces seuils, la fonction *Peak detector* relève toutes les fluctuations erratiques dans la mesure profilométrique. Ainsi, toutes les fluctuations qui sont au dessous de ces deux seuils ne seront pas considérées comme un défaut d'uni.

2.2.3 Étude comparative des défauts pré- et post-réhabilitation

L'application de l'algorithme 1 sur les profils préalablement alignés mène à identifier 473 défauts dans le profil pré-réhabilitation contre 507 défauts dans le profil post-réhabilitation. Ce résultat indique que, lors de la réhabilitation de la chaussée, 34 défauts ont été créés à cause de divers problèmes de mise en oeuvre ou de compactage liés à différents aléas de chantier. Puisque la causalité entre ces aléas de chantier et la création de l'uni n'est pas encore complètement comprise, et que le but de cette étude est de prédire l'amélioration de l'uni de la chaussée, les données correspondant à cette détérioration sont considérées comme non pertinentes dans le cas de l'étude comparative qui suit. Cette dernière ne concernera donc que les 473 défauts appariés pré- et post-réhabilitation. Cet ensemble présente des énergies variables entre 0.5 cm^3 et 30000 cm^3 . Parmi les 473 identifiés, 74 défauts pré-réhabilitation (15.64 %) ont une énergie inférieure ou égale à 10 cm^3 . Les autres classes énergétiques ont des occurrences variables entre 1 à 16 défauts dans le profil pré-réhabilitation.

D'un point de vue général, la réhabilitation a amélioré 256 défauts préexistants (dont l'énergie post-réhabilitation est inférieure à celle pré-réhabilitation), atteignant ainsi un taux d'amélioration total de 54.1 %. Cependant, la comparaison des défauts pré- et post-réhabilitation par classes énergétiques retraduit des modes d'évolution amorphes : les taux d'amélioration et de dégradation sont dissemblables même entre deux classes énergétiques adjacentes, comme l'indique la figure 2.2. Ainsi, afin de comprendre davantage les modes d'évolution énergétique des défauts, il convient d'analyser ces taux d'amélioration et de dégradation selon un autre

Algorithme 1 Identification des signatures des irrégularités géométriques dans le profil pré-réhabilitation et celles de leurs correspondantes dans le profil post-réhabilitation

Entrées : y_{1_n} et y_{2_n} : les amplitudes des profils pré- et post-réhabilitation mesurés respectivement,

Sortie : S_{1_k} et S_{2_k} : les séquences des défauts pré- et post-réhabilitation dans les profils mesurés.

Tant que $i \leq n$ **Faire**

Tant que $j \leq i$ **Faire**

 ▷ Calculer les énergies accumulées sur les profils mesurés

$$C_1(j) = y_1^2(j) + C_1(j-1)$$

$$C_2(j) = y_2^2(j) + C_2(j-1)$$

Fin Tant que

Fin Tant que

▷ Estimer les dérivées des énergies accumulées

Tant que $2 \leq i \leq n-1$ **Faire**

$$d_1(i) = \frac{-1}{12\Delta x} (-y_1(i+2) + 8y_1(i+1) - 8y_1(i-1) + y_1(i-2))$$

$$d_2(i) = \frac{-1}{12\Delta x} (-y_2(i+2) + 8y_2(i+1) - 8y_2(i-1) + y_2(i-2))$$

Fin Tant que

▷ Détecter les pics et les vallées

$Seuil \leftarrow 0.02$

$Largeur \leftarrow 3$

$(X_{pic1_k}, A_{pic1_k}, X_{val1_k}, A_{val1_k}) = Peak\ detector(d_1, Seuil, Largeur)$

$(X_{pic2_k}, A_{pic2_k}, X_{val2_k}, A_{val2_k}) = Peak\ detector(d_2, Seuil, Largeur)$

▷ Extraction des séquences des défauts pré- et post-réhabilitation

Tant que $i \leq k-1$ **Faire**

Si $X_{val1}(i) \leq X_{pic1}(i) \leq X_{val1}(i+1)$ **Alors**

$$S_1(i) = [y_1(X_{val1}(i)), y_1(X_{val1}(i+1))]$$

Si non $S_1(i) = [y_1(X_{val1}(i)), y_1(X_{val1}(i+2))], i \leftarrow i+2$

Fin Si

Fin Tant que

Tant que $i \leq k-1$ **Faire**

Si $X_{val2}(i) \leq X_{pic2}(i) \leq X_{val2}(i+1)$ **Alors**

$$S_2(i) = [y_2(X_{val2}(i)), y_2(X_{val2}(i+1))]$$

Si non

$$S_2(i) = [y_2(X_{val2}(i)), y_2(X_{val2}(i+2))], i \leftarrow i+2$$

Fin Si

Fin Tant que

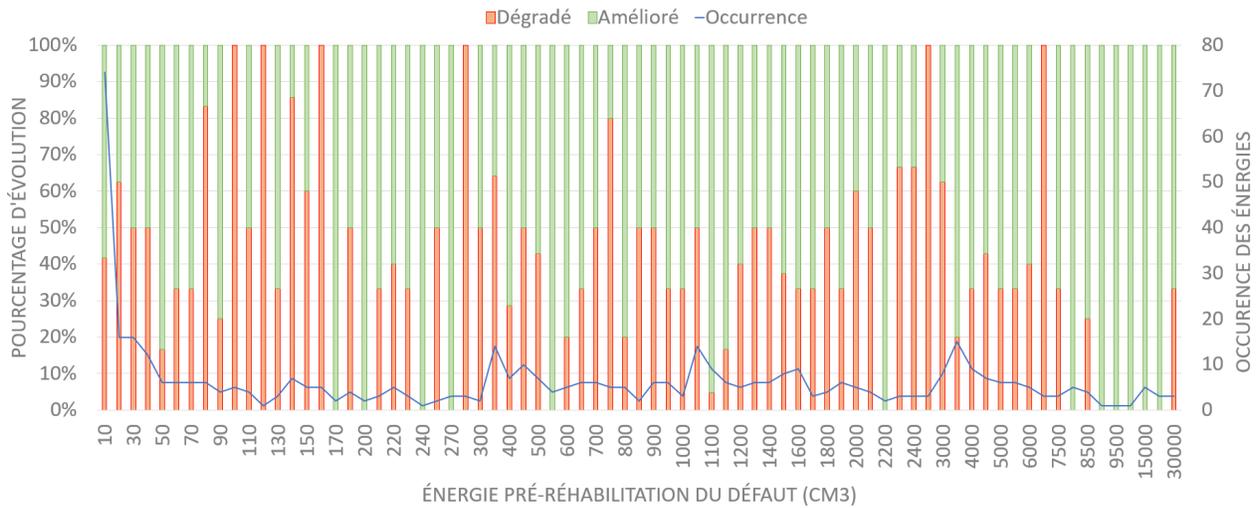


FIGURE 2.2 – L'évolution énergétique des défauts pré-réhabilitation

angle.

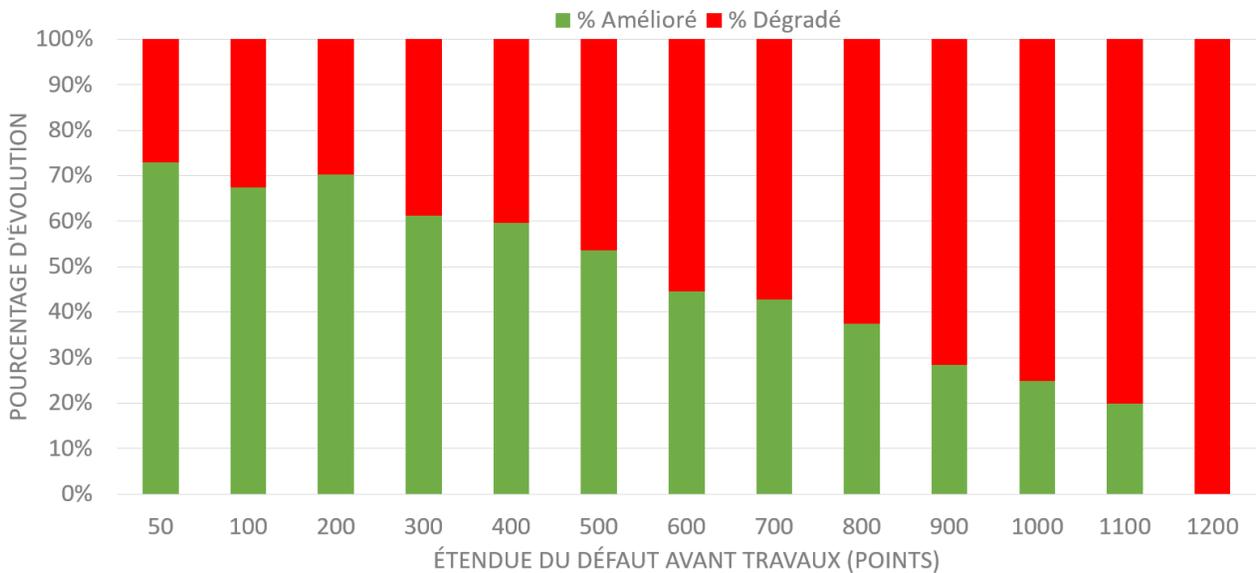


FIGURE 2.3 – L'évolution énergétique des défauts pré-réhabilitation en fonction de leurs étendues

La figure 2.3 présente l'évolution des taux d'amélioration et de dégradation des défauts pré-existants en fonction de leurs étendues. Elle indique l'existence d'une corrélation négative

entre le taux d'amélioration d'un défaut et son étendue : 73 % des défauts d'étendue inférieure à 2.5 m (50 points) ont été améliorés. Ce taux d'amélioration des défauts diminue progressivement en allant vers des étendues plus grandes, jusqu'à ce qu'il s'annule en atteignant une étendue de 60 m (1200 points). Cette corrélation rend la prise en compte des étendues déterminante pour la prédiction de l'évolution de défauts préexistants. Afin de comprendre l'impact de cette corrélation sur l'évolution des classes énergétiques, il convient d'analyser la composition de ces classes en termes d'étendues de défauts.

La figure 2.4 présente les taux de composition des classes énergétiques en termes des étendues de leurs défauts : contre-intuitivement, la répartition des étendues de défauts est assez dispersées sur les classes énergétiques. Par exemple, les défauts ayant une étendue inférieure ou égale à 2.5 m sont présents non seulement dans les classes de faibles énergies (inférieure à 40 cm^3), mais aussi dans celle d'énergie aussi élevée que 1900 cm^3 (où ils présentent environ 50 % de l'ensemble des défauts de la classe). Ainsi, la dispersion des étendues de défauts induit une différence de composition des classes énergétiques et engendre de facto des évolutions dissemblables, suite à la réhabilitation, même entre deux adjacentes.

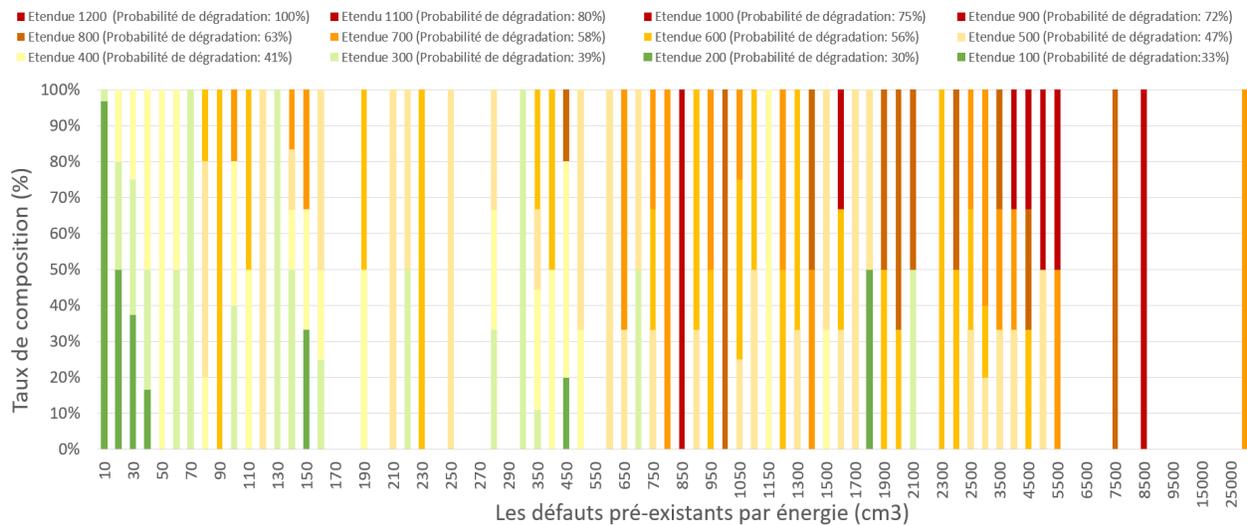


FIGURE 2.4 – La répartition des défauts sur ces classes selon leurs étendues

Pour résumer, l'identification de l'impact de la réhabilitation sur les défauts préexistants nécessite dans un premier temps d'identifier l'hérédité qui relie les profils pré- et post-réhabilitation. A cette fin, l'alignement des profils mesurés est amélioré. Dans un deuxième temps, les défauts appariés seront extraits, selon l'algorithme 1 précédemment développé (cf. section 2.2.2), pour analyser leurs évolutions énergétiques. En effet, la comparaison des énergies pré- et post-réhabilitation des défauts appariés indique l'existence d'une corrélation négative entre le taux d'amélioration d'un défaut et son étendue initiale. Or, la répartition des étendues de défauts sur l'espace énergétique est dispersée. Ceci induit une différence de

composition des classes énergétiques de défaut et engendre de facto des évolutions dissemblables, suite à la réhabilitation, même entre deux adjacentes.

Cette première étude traite l'évolution des défauts préexistants, en comparant leurs signatures énergétiques pré- et post-réhabilitation extraites directement des pseudo-profils mesurés. Ainsi, elle quantifie les améliorations et les dégradations réelles de l'uni perceptibles sur le terrain sans avoir recours à des indicateurs d'uni, qui traitent les signaux mesurés pour fournir une quantification de la qualité de l'uni conditionnée par la nature de ce traitement. Les défauts relevés des mesures profilométriques sont caractérisés par différents ordres d'énergie, variant de 10 cm^3 à 30000 cm^3 , et d'étendues pouvant atteindre 60 m. Cette disparité des ordres de grandeur (amplitude et étendue) des défauts se reflète par des fluctuations de fréquences variables, formant ainsi une série temporelle erratique.

Cependant, ce fort contraste de fréquence et d'amplitude est problématique pour la prédiction du profil post-réhabilitation. En effet, les méthodes d'apprentissage supervisé, notamment les réseaux de neurones, ont un biais vers les basses fréquences : indépendamment de leurs amplitudes, les plus basses fréquences de la série temporelle sont inhéremment régressées en premier. De plus, elles sont plus robustes que les fréquences plus élevées aux perturbations des paramètres qui peuvent survenir lors de l'entraînement du modèle. Ainsi, l'ajustement des fréquences plus élevées nécessite un réglage fin et stable des paramètres puisque ceux qui sont impliqués dans l'expression des composantes à hautes fréquences occupent un petit volume dans l'espace global des paramètres [149]. Par conséquent, ce biais spectral doit être évité pour permettre un apprentissage qui couvre tous les défauts préexistants, quelles que soient leurs étendues, leurs amplitudes ou leurs fréquences. A cette fin, les profils mesurés doivent être divisés en différentes catégories de bandes d'ondes, afin de dédier un modèle à chaque bande d'ondes dans lequel le contraste de fréquence est réduit. Chaque modèle spécifique est ensuite entraîné à estimer les défauts contenus dans la catégorie de bande d'onde. Une prédiction globale de la post-réhabilitation peut alors être construite en additionnant les prédictions de chaque bande d'ondes.

Dans le cadre de l'uni longitudinal, trois catégories de longueurs d'onde de défauts sont généralement considérées : petites ondes - PO ($0.707 < \lambda(m) < 2.828$), moyennes ondes - MO ($2.828 < \lambda(m) < 11.312$), et grandes ondes - GO ($11.312 < \lambda(m) < 45.248$). Le même découpage est adopté lors du calcul des indicateurs NBO.

Afin d'élaborer le modèle de prédiction adéquat pour chacune des trois bandes d'ondes, la section suivante présente une analyse de la compositions des signaux filtrés par bandes d'ondes et des transitions énergétiques pré- et post-réhabilitation qui les relient.

Pour dissocier les irrégularités géométriques présentes dans les profils de leurs images dans les signaux filtrés, dans ce qui suit, le terme 'défauts' sera consacré aux irrégularités géométriques identifiées dans la mesure profilométrique, tandis que leurs images dans les signaux filtrés seront désignées par 'traces résiduelles'

2.3 L'impact de la réhabilitation en termes des énergies par bandes d'ondes (EBO) :

L'idée de cette étude est d'analyser le changement qu'implique le filtrage en bandes d'ondes sur la composition des signaux filtrés ainsi que sur les transitions énergétiques qui relient les traces résiduelles pré- et post-réhabilitation. Cette analyse comporte donc deux parties : une première qui décrit les caractéristiques des signaux filtrés, et une deuxième qui se focalise sur les transitions énergétiques pré- et post-réhabilitation des traces résiduelles dans chaque bande d'ondes.

2.3.1 Description des signaux filtrés

La norme NF EN-13036-5 [150] préconise une décomposition en bandes d'ondes en se basant sur les filtres Butterworth : un filtre linéaire conçu pour maintenir un gain stable le long de sa bande passante. Les caractéristiques des filtres butterworth sont détaillées dans l'annexe A.

Dans cette étude, le filtrage des profils mesurés pré- et post-réhabilitation suit les recommandations de la norme NF EN-13036-5. En comparant les signaux filtrés aux profils mesurés, nous remarquons une atténuation progressive amplitudes d'une bande d'ondes à sa suivante. En effet, comme indiqué par les tableaux 2.1 et 2.2, les amplitudes des profils mesurés sont atténuées progressivement par le filtrage, jusqu'à atteindre 1.49 cm sur les PO post-réhabilitation par exemple : l'effet atténuant du filtrage numérique. Cette atténuation des amplitudes de défauts mesurés se traduit par un resserrement progressif des distributions des signaux filtrés, comme l'illustre les figures 2.5 et 2.6. En effet, et dans le cas post réhabilitation par exemple, 92 % des valeurs PO sont comprises entre ± 0.5 cm, 94% des valeurs MO sont comprises entre ± 2 cm, tandis que 95% des valeurs GO varient entre ± 10 cm. Cette différence d'ordre de grandeurs entre les bandes d'ondes impose des niveaux différents de précision requise pour leurs prédictions.

Le filtrage en bandes d'ondes engendre 3 signaux ayant des compositions différentes : afin de caractériser les liaisons entre les points des profils (mesurés et filtrés), l'auto-corrélation $R(k)$ des signaux est calculée selon l'équation 2.3 [151] :

$$R(k) = \frac{1}{(n-k)\sigma^2} \sum_{t=1}^{n-k} (X_t - \mu)(X_{t+k} - \mu) \quad (2.3)$$

où n est le nombre d'observations $\{X_1, X_2, \dots, X_n\}$, μ est la moyenne arithmétique et σ^2 est la variance.

L'autocorrélation représente donc les corrélations croisées entre les séquences d'un même signal, décalées les unes par rapport aux autres par k points. Le coefficient de corrélation calculé à chaque décalage varie entre 1 (corrélation maximale) et -1 (corrélation inversée). Elle permet d'identifier les liaisons entre les points d'un signal en relevant les régularités

Indicateurs statistiques	Profil pré-réhabilitation	GO pré-réhabilitation	MO pré-réhabilitation	PO pré-réhabilitation
Moyenne arithmétique	0.03	0	0.02	0
Écart-type	9.41	4.8	1.19	0.32
Valeur minimale	-43.88	-27.39	-7.07	-5.16
Percentile 25%	-5.19	-2.68	-0.57	-0.16
Médiane	-0.14	0	0	0
Percentile 75%	5.13	2.48	0.56	0.16
Valeur maximale	41.85	23.53	14.25	5.47

TABLE 2.1 – Évolution du profil pré-réhabilitation suite au filtrage par bandes d’ondes.

Indicateurs statistiques	Profil post-réhabilitation	GO post-réhabilitation	MO post-réhabilitation	PO post-réhabilitation
Moyenne arithmétique	0.01	0	0.01	0
Écart-type	8.94	3.49	0.73	0.18
Valeur minimale	-41.66	-19.56	-5.34	-1.91
Percentile 25%	-5.13	-2.06	-0.36	-0.11
Médiane	-0.32	-0.02	0	0
Percentile 75%	5.34	1.99	0.38	0.11
Valeur maximale	43.25	15.62	8.58	1.49

TABLE 2.2 – Évolution du profil post-réhabilitation suite au filtrage par bandes d’ondes.

courtes ainsi que les fréquences longues d’un signal.

La figure 2.7 illustre les autocorrélations des profils pré- et post-réhabilitation : les deux profils comportent des valeurs positives et négatives, ce qui se traduit par des pics (positifs) et des vallées (négatives) d’autocorrélation entre les points. Au niveau du profil pré-réhabilitation, l’autocorrélation commence naturellement par une valeur $R(1) = 1$ pour diminuer vers sa valeur minimale $R(550) = 0.6$. Ensuite, l’autocorrélation présente un dernier pic $R(1100) = 0.2$ pour finir en oscillant dans le domaine statistiquement non significatif entre ± 0.1 (indiqué en gris dans la figure 2.7). Quant au profil post-réhabilitation mesuré, son autocorrélation

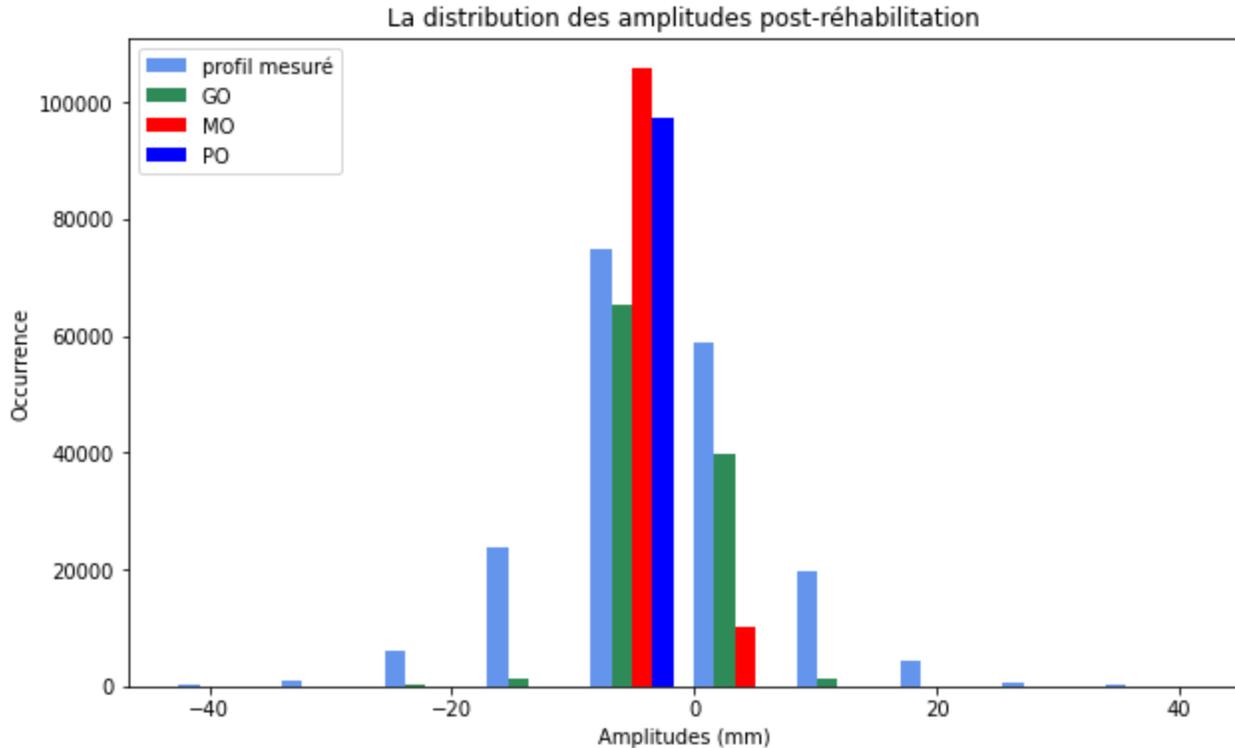


FIGURE 2.5 – La distribution des amplitudes post-réhabilitation mesurées et filtrées

est quasiment identique à celle du pré-réhabilitation, avec quelques différences au niveau des amplitudes statistiquement non-significatives. La réhabilitation de la chaussée, par la mise en oeuvre d'une nouvelle couche, préserve donc la corrélation spatiale pré-existante et la reproduit au profil post-réhabilitation.

Les figures 2.8, 2.9 et 2.9 présentent les autocorrélations des signaux pré- et post-réhabilitations filtrés par bande d'ondes : au niveau des GO (cf. 2.8), les autocorrélations présentent des pics, ou des vallées, successifs espacés de 600 points ce qui indique l'existence d'une ondulation fondamentale (défaut périodique) d'environ 30 m. La réhabilitation de la chaussée par la mise en oeuvre d'une nouvelle couche ne permet pas de corriger ce défaut périodique, puisque sa signature persiste dans l'autocorrélation post-réhabilitation. Au niveau des MO (cf. 2.9), La comparaison des autocorrélations pré- et post-réhabilitation indique la préexistence d'une ondulation dominante de 7 m (un pic tous les 140 points environ). Ce défaut périodique a été amplifié après la réhabilitation. Quant aux PO (cf. 2.10), la longueur d'onde principale est celle de 2.5m, marqué par un pic de coefficient de corrélation tous les 50 points. Ce défaut périodique est moins apparent sur l'autocorrélation pré-réhabilitation, ce qui indique son atténuation suite à la mise en oeuvre et le compactage de la nouvelle couche de la chaussée. Pour résumer, les résultats de cette section indique une atténuation des amplitudes filtrés

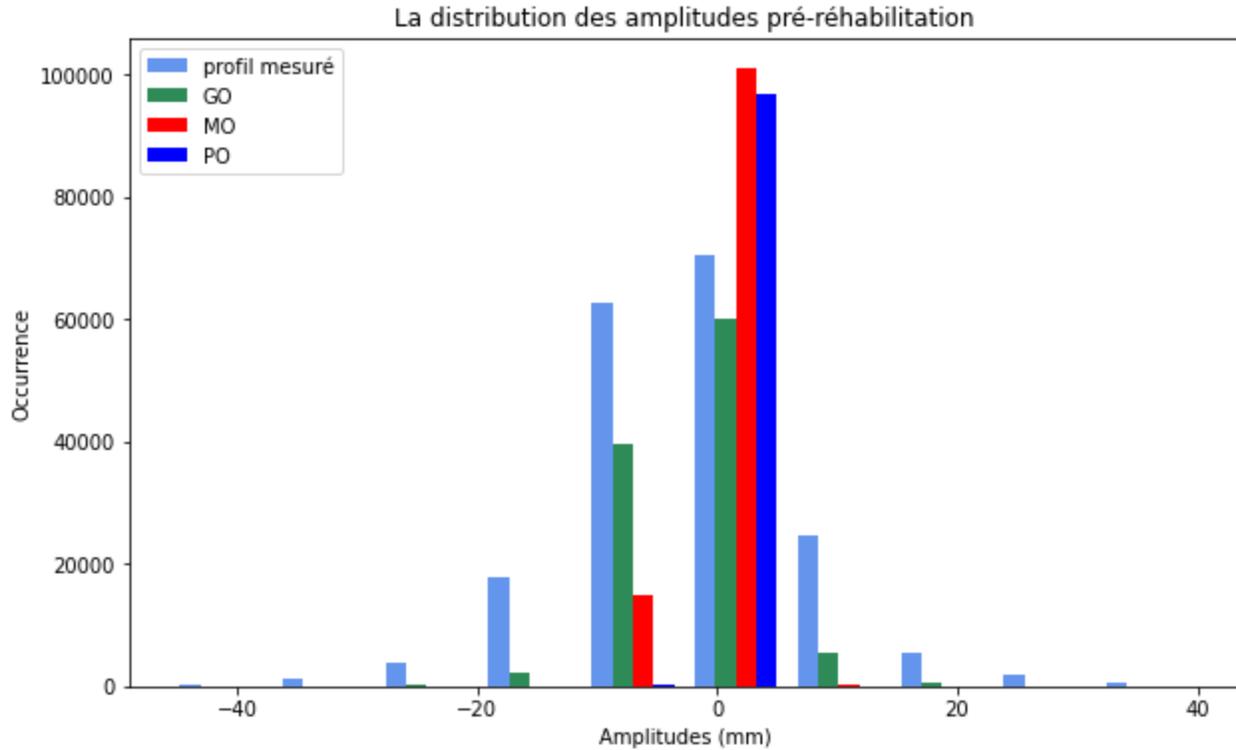


FIGURE 2.6 – La distribution des amplitudes pré-réhabilitation mesurées et filtrées

par bande d’ondes, en comparaison à celles des profils mesurés, selon les fonctions de transfert des filtres caractéristiques. Cette analyse a aussi relevé l’existence des autocorrélations d’ordres de grandeur différents dans les signaux filtrés selon leurs bandes d’ondes. Ceci implique que l’approche de leur prédiction à élaborer doit prendre en compte cette diversité de caractéristiques.

2.3.2 Étude comparative des traces résiduelles pré- et post-réhabilitation par bandes d’ondes

Comme précédemment indiqué, les trois bandes d’ondes affichent des amplitudes et des autocorrélations d’ordres de grandeurs différents. Ainsi, chaque défaut réel (détecté sur les profils pré- ou post-réhabilitation mesurés) se caractérisera par des traces résiduelles, sur les signaux filtrés, dont les caractéristiques dépendent de son amplitude ainsi que de son étendue (son énergie). A cause de cet effet de filtrage, les traces résiduelles suivent des schémas d’évolution différents de ceux observés au niveau des défauts. Dans ce qui suit, une étude comparative des traces résiduelles pré- et post-réhabilitation est présentée.

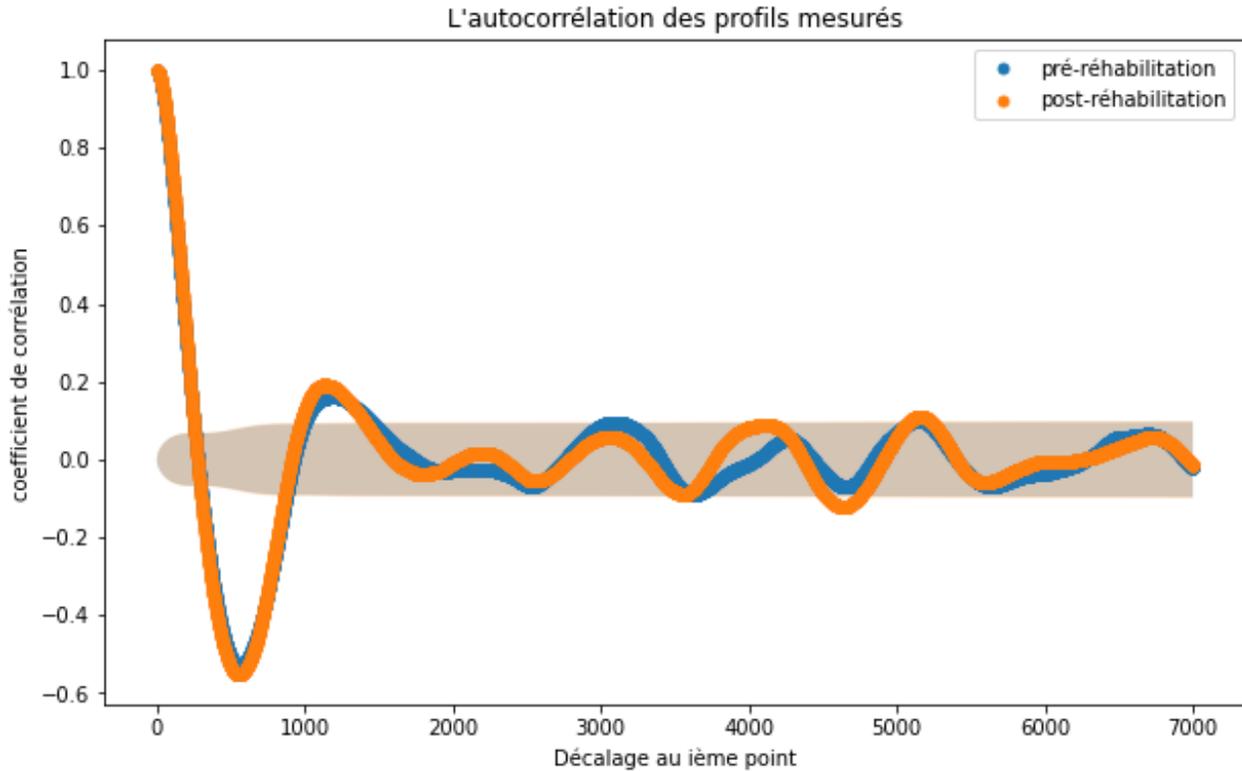


FIGURE 2.7 – Les autocorrélations des profils pré- et post-réhabilitation

Les traces résiduelles des GO :

Sur la bandes des GO, le filtrage des 473 paires de défauts donne lieu à 619 traces résiduelles pariées pré- et post-réhabilitation. Cette différence entre le nombre de défauts réelles et celui de leurs traces résiduelles s'explique par l'effet décomposant du filtrage numérique : en effet, un défaut réel peut se traduire par une trace résiduelle ou plus, suite à son filtrage, selon son étendue ou sa forme géométrique.

La figure 2.11 présente les taux d'évolution des traces résiduelles GO pré-réhabilitation en fonction de leurs énergies : sur les 619 traces résiduelles pré-réhabilitation, 279 traces (45.07 %) se caractérisent par des énergies inférieures ou égales à 100cm^3 . Cette occurrence diminue graduellement dans les classes énergétiques plus grandes. Les énergies des traces résiduelles ne dépassent pas 600cm^3 , alors qu'elles atteignent 30000cm^3 sur les défauts réels. Cette diminution des énergies s'explique par les effets atténuant et décomposant du filtrage numérique. En comparant les énergies des traces résiduelles appariées, la réhabilitation a amplifié 225 traces pré-réhabilitation pour atteindre ainsi un taux de dégradation global de 36.34 %. En particulier, cette dégradation est observée principalement dans la classe énergétique de 100

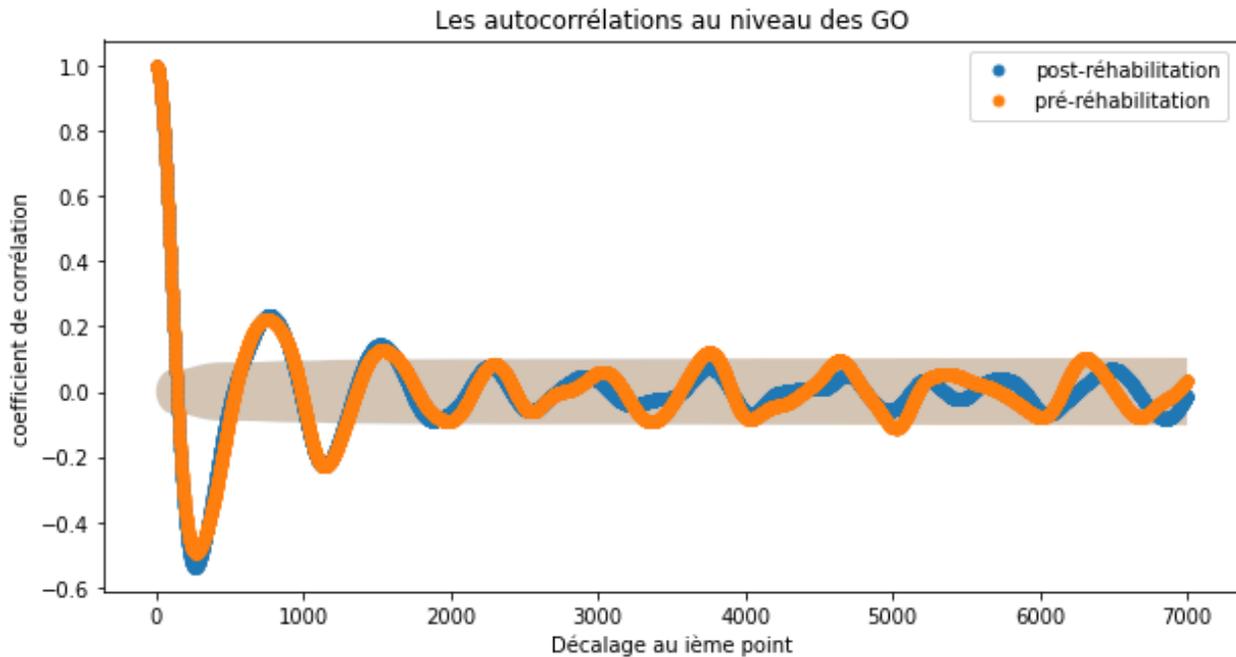


FIGURE 2.8 – Les autocorrélations au niveau des GO

cm^3 , où le taux de dégradation est de 51%. Ce taux suit une tendance descendante pour s'annuler à la classe énergétique de $1400 cm^3$, comme l'indique la figure 2.11. Ainsi, les traces résiduelles GO présentent donc des modalités d'évolution plus structurées que celles des défauts présentées dans la figure 2.2.

La figure 2.12 décrit les taux d'évolution des traces résiduelles GO pré-réhabilitation en fonction de leurs étendues : sur l'ensemble des traces GO détectées, l'étendue maximale est de 600 points (30 m), alors que les défauts détectés peuvent atteindre une étendue de 1000 points. Sur l'ensemble des traces résiduelles détectées, la classe d'étendue la plus présente est celle de 300 points (235 traces), qui présente aussi le taux de dégradation le plus élevé (40%). Ce taux diminue graduellement pour atteindre 15% aux limites des étendues observées (étendue 50 et 600).

Les traces résiduelles des MO :

Les 473 paires de défauts sont décomposées en 2417 traces résiduelles pré- et post-réhabilitation sur la bande des MO (effet décomposant du filtrage).

La figure 2.13 présente les taux d'évolution des traces résiduelles MO pré-réhabilitation en fonction de leurs énergies : sur les 2417 des traces pré-réhabilitation de cette bande, 1142, 1142 se caractérisent par des énergies inférieures ou égales à $1 cm^3$. L'occurrence des classes

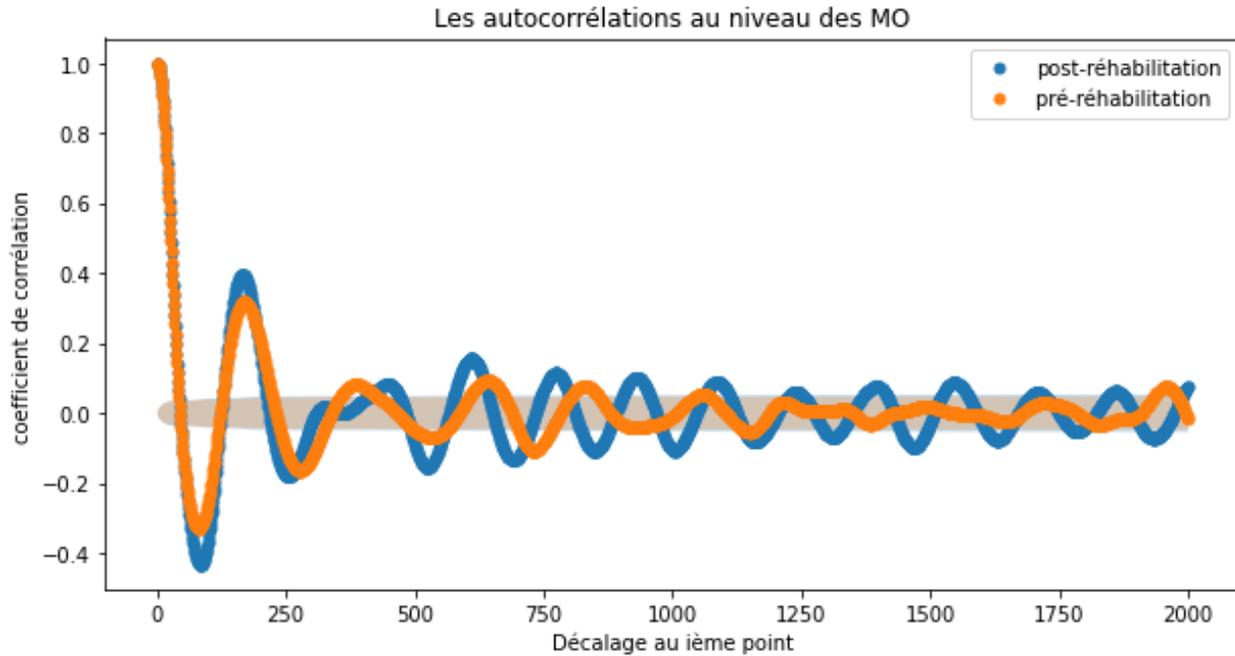


FIGURE 2.9 – Les autocorrélations au niveau des MO

énergétiques diminue proportionnellement à leurs valeurs. En comparant les énergies des traces résiduelles appariées, 1016 traces pré-réhabilitation ont été amplifiées pour que le taux de dégradation globale atteigne 40.51 %. En particulier, les traces résiduelles PO les plus amplifiées sont celles ayant une énergie inférieure ou égale à 1 cm^3 , où le taux de dégradation spécifique à cette classe s'élève à 61.82 %. Ce taux diminue ensuite dans les classes énergétiques plus grandes, jusqu'à ce qu'il s'annule à la classe de 60 cm^3 .

La figure 2.14 décrit le taux d'évolution des traces résiduelles MO pré-réhabilitation en fonction de leur étendues : les étendues des traces relevées varient de 10 à 140 points (7m), où 420 traces pré-réhabilitation se caractérisent par une étendue de 80 points (4m).

La description taux d'évolution - étendue indique que les traces les plus amplifiées sont celles caractérisées par des étendues entre 70 à 110 points (3.5 à 5.5 m). Le taux de dégradation diminue progressivement en allant vers les limites des étendues détectées (Étendues 10 et 140).

Les traces résiduelles des PO :

Sur la bande des PO, l'effet décomposant du filtrage est le plus conséquent (en comparaison aux deux bandes précédentes) puisque les 473 paires de défauts sont décomposées en 10496 traces résiduelles pariées pré- et post-réhabilitation.

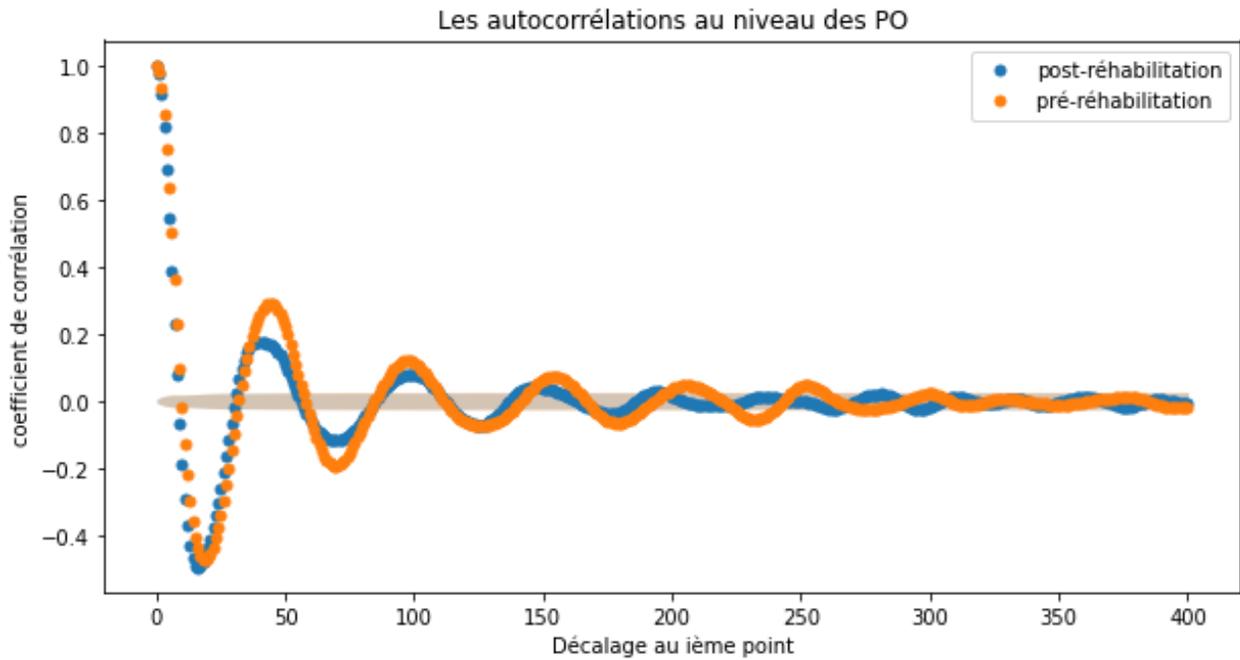


FIGURE 2.10 – Les autocorrélations au niveau des PO

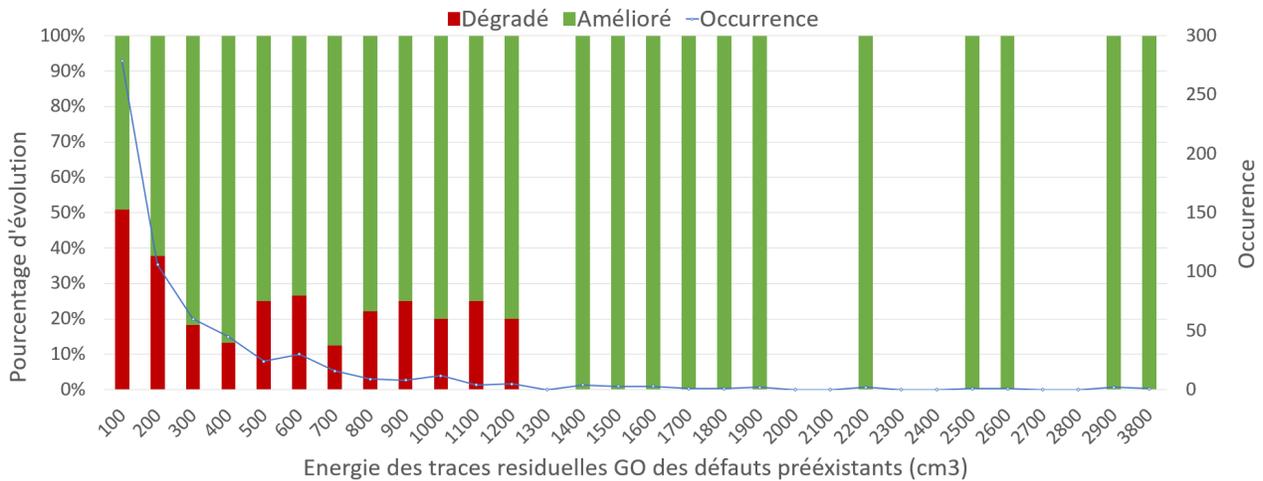


FIGURE 2.11 – L'évolution énergétique des traces résiduelles GO des défauts pré-réhabilitation

La figure 2.15 présente les taux d'évolution des traces résiduelles PO pré-réhabilitation en fonction de leurs énergies : sur les 10496 traces pré-réhabilitation de cette bande, 3192 se caractérisent par des énergies inférieures ou égales à 0.01 cm^3 . Cette occurrence diminue gra-

2.3. L'IMPACT DE LA RÉHABILITATION EN TERMES DES ÉNERGIES PAR BANDES D'ONDES (EBO) :

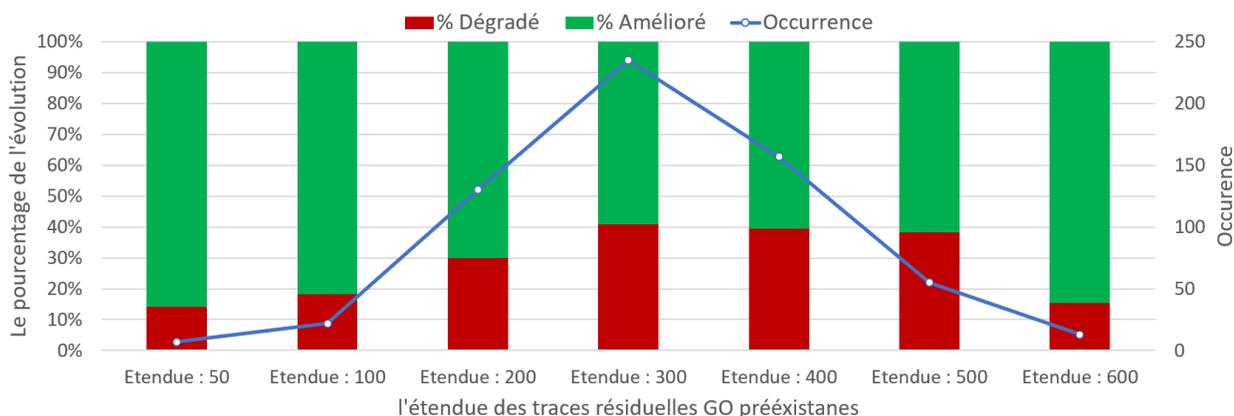


FIGURE 2.12 – L'évolution énergétique des traces résiduelles GO pré-réhabilitation en fonction de leurs étendues.

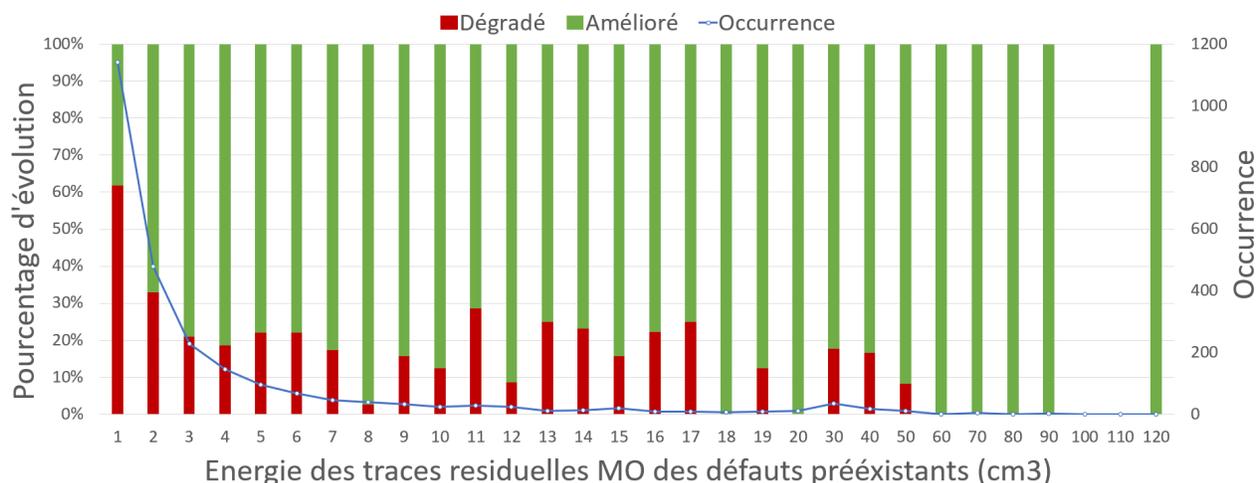


FIGURE 2.13 – L'évolution énergétique des traces résiduelles MO des défauts pré-réhabilitation.

duellement dans les classes énergétique plus grandes, pour atteindre qu'une seule trace sur la classe énergétique maximale de 8 cm^3 comme l'indique la figure 2.15. En comparant les énergies des traces résiduelles appariées, 4778 traces pré-réhabilitation ont été amplifiées pour que le taux de dégradation global atteigne 45.52 %. Plus spécifiquement, la classe énergétique la plus dégradée est celle de 0.01 cm^3 , où le taux de dégradation s'élève à 74.62 %. Ce taux diminue ensuite dans les classes énergétiques plus grande, jusqu'à ce qu'il s'annule à la classe de 0.5 cm^3 .

La figure 2.16 décrit le taux d'évolution des traces résiduelles PO pré-réhabilitation en fonc-

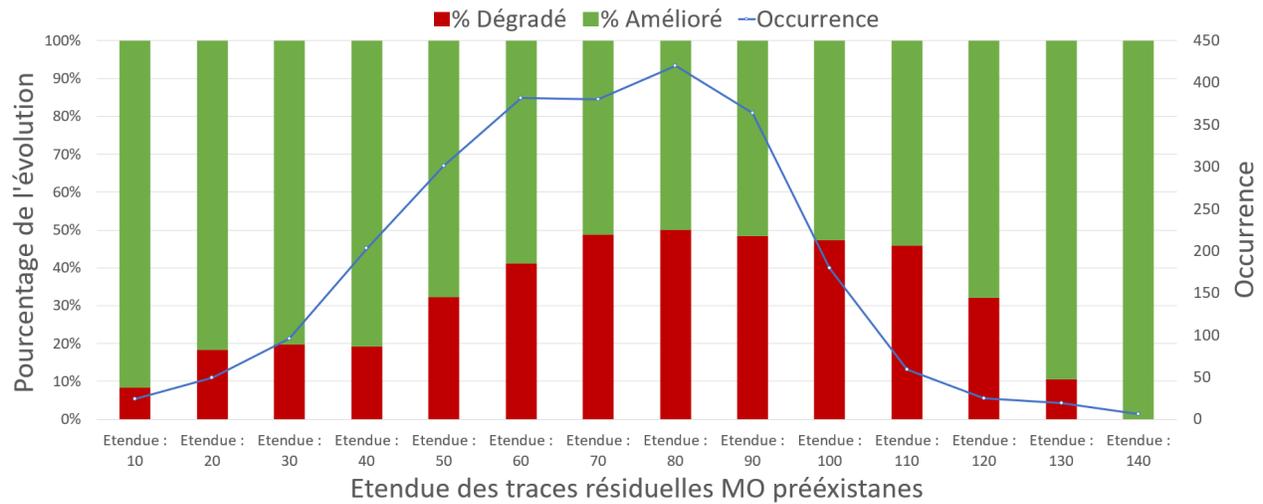


FIGURE 2.14 – L'évolution énergétique des traces résiduelles MO pré-réhabilitation en fonction de leurs étendues.

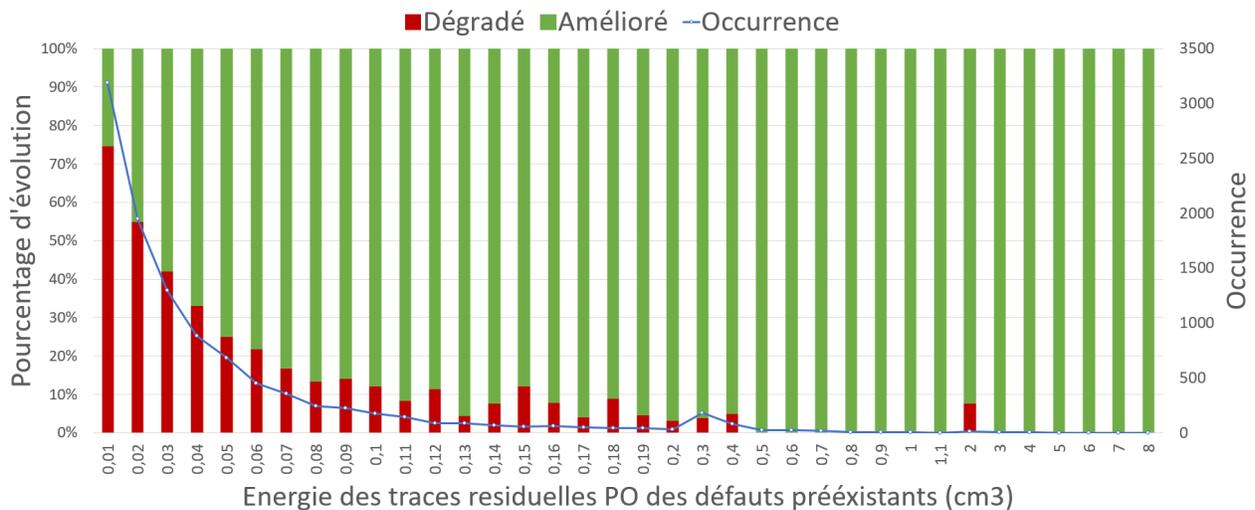


FIGURE 2.15 – L'évolution énergétique des traces résiduelles PO des défauts pré-réhabilitation.

tion de leurs étendues : les étendues des traces relevées varient de 4 à 30 points, où 17 % des traces (1790) se caractérisent par des étendues de 12 points. La description taux d'évolution - étendue indique que les classes d'étendues les plus dégradées sont celles entre 14 et 18 points (de 0.7 à 0.9 m). La description taux d'évolution - étendue montre que les traces les plus dégradées sont celles ayant des étendues entre 12 et 22 points (de 0.6 à 1.1 m). Au-delà de ces classes, le taux de dégradation diminue progressivement en allant vers les limites des

2.3. L'IMPACT DE LA RÉHABILITATION EN TERMES DES ÉNERGIES PAR BANDES D'ONDES (EBO) :

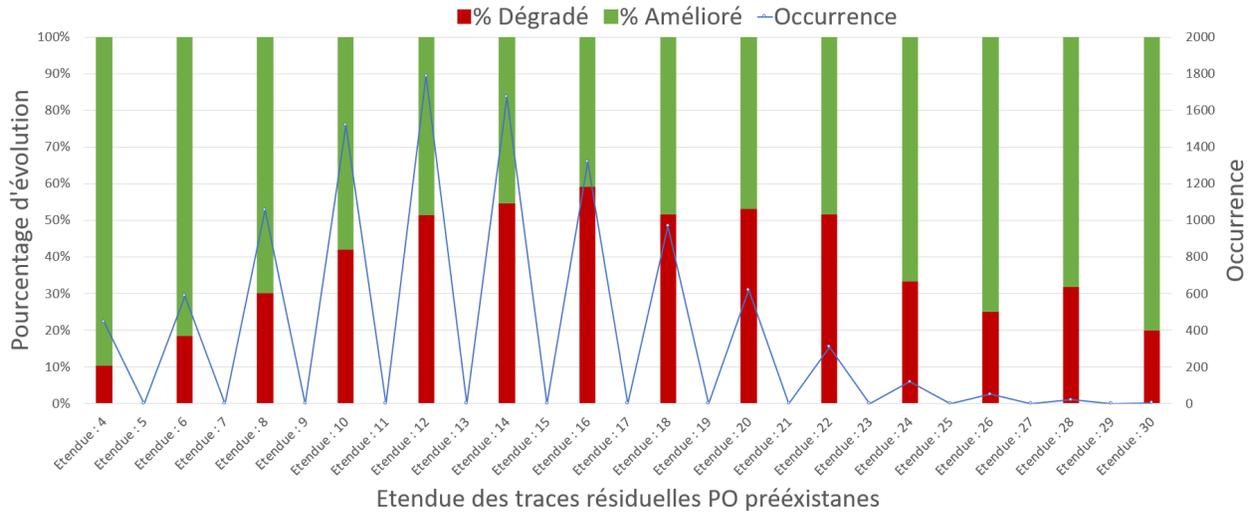


FIGURE 2.16 – L'évolution énergétique des traces résiduelles PO pré-réhabilitation en fonction de leurs étendues.

étendues détectées (les étendues de 4 et 30 points).

Pour résumer, le filtrage des 473 paires de défauts pré- et post-réhabilitation permet de relever des schémas plus structurés d'évolution de l'uni : si la description des taux d'amélioration / de dégradation des défauts pré-réhabilitation en fonction de leurs énergies ne permet pas de souligner des tendances d'évolution claires (cf. 2.2.3), la même description concernant les traces résiduelles indique des schémas d'évolutions structurés et similaires entre les trois bandes d'ondes. En effet, et comme illustré dans les figures 2.11, 2.13 et 2.15, les taux de dégradation sont inversement proportionnels aux énergies des traces résiduelles dans chaque bande d'ondes.

D'autre part, le filtrage numérique d'un défaut le décompose en une ou plusieurs traces résiduelles selon les fonctions de transfert des filtre utilisés : l'effet décomposant. Cet effet réduit les étendues des traces résiduelles relevées dans chaque bande d'onde. Il impacte ainsi la description de l'évolution énergétique des classes d'étendue : au niveau des profils mesurés, les taux d'amélioration des défauts diminuent en augmentant leurs étendues. Or, au niveau des signaux filtrés, ce sont les traces résiduelles ayant des étendues médianes qui sont les plus dégradées dans chaque bande d'ondes.

La différence d'ordre de grandeur entre les bandes d'ondes implique une différence de facto dans la précision requise lors de la prédiction de leurs signaux post-réhabilitation filtrés par bande d'ondes. En effet, la précision de la prédiction doit être adaptée à la sensibilité énergétique de chacune des trois bandes. Une analyse de sensibilité des trois bandes est donc présentée dans la section suivante.

2.4 L'impact de la réhabilitation en termes des notes par bandes d'ondes (NBO) :

La construction d'indicateur(s) d'évaluation de l'évolution des défauts d'uni, suite à la réhabilitation, a vocation ici de se doter d'outils d'analyse de l'évolution du signal afin de déterminer s'il est nécessaire de filtrer davantage le signal pour mieux le prédisposer à un processus d'apprentissage supervisé.

Rappelons que la première étape du calcul des NBO, comme détaillé dans la section 1.1.3, commence par un filtrage du profil mesuré selon trois bandes d'ondes prédéfinies : PO ($0.707 < \lambda(m) < 2.828$), MO ($2.828 < \lambda(m) < 11.312$), et GO ($11.312 < \lambda(m) < 45.248$). L'énergie de chaque bande d'ondes est calculée selon des segments de calcul. La deuxième étape consiste à convertir les énergies des segments filtrés par bandes d'ondes en notes sur une échelle de 0 (qualité médiocre) à 10 (excellente qualité).

La sensibilité des bandes d'ondes en termes de NBO est au coeur de cette section. Ainsi, une analyse de l'évolution apparente de l'uni, en termes de NBO, est présentée dans ce qui suit. Le calcul des NBO a suivi l'algorithme détaillé dans la section 1.1.3, pour obtenir un ensemble de notes qui se compose de 49 NGO, 92 NMO et 479 NPO appariées (pré- et post-réhabilitation). Ainsi, les modes apparents d'évolution de l'uni sont détaillées dans ce qui suit en comparant les notes pré- et post-réhabilitation par bande d'ondes.

Au niveau des GO, la figure 2.17 décrit l'impact global de la réhabilitation sur les NGO : la réhabilitation a amélioré 28 notes et a dégradé les 21 notes restantes (un taux d'amélioration de 57.14% contre un taux de dégradation de 42.85%). Au-delà des notes entre 5.5 et 6.5, dont l'occurrence est faible pour pouvoir en tirer des indicateurs significatifs, les notes les plus dégradées sont celles de 7.5 et de 10.

La figure 2.18 propose une présentation hiérarchique de l'ensemble des notes avant travaux ainsi qu'une description plus affinée de leurs évolutions suite à la réhabilitation. Cette figure décrit chaque note avant travaux par un compartiment dont la surface est proportionnelle à son occurrence. Chaque compartiment est divisé en sous-compartiments qui correspondent aux notes post-réhabilitation (notées 'Ap' sur la figure) vers lesquelles la note avant travaux a évolué. Le sens de l'évolution est indiqué par un code couleur : vert pour l'amélioration et rouge pour la dégradation.

La figure 2.18 permet de souligner la disparité de l'évolution des notes NGO suite à la réhabilitation : par exemple, la réhabilitation d'un tronçon ayant une note avant travaux de 9 peut améliorer sa qualité d'uni jusqu'à atteindre une note post-réhabilitation de 10. La même note avant travaux peut subir aussi une forte dégradation suite à la réhabilitation de la chaussée jusqu'au point d'évoluer vers une note post-réhabilitation de 6.5. Cette disparité d'évolution se confirme aussi pour le cas des notes avant travaux de 8, dont leurs correspondantes notes post-réhabilitation varient entre 10 et 6.5 aussi.

Au niveau des MO, la réhabilitation a amélioré 74 NMO avant travaux et a dégradé les 18 notes restantes. Ainsi, et avec un taux d'amélioration de NMO qui s'élève à 80.4%, la

2.4. L'IMPACT DE LA RÉHABILITATION EN TERMES DES NOTES PAR BANDES D'ONDES (NBO) :

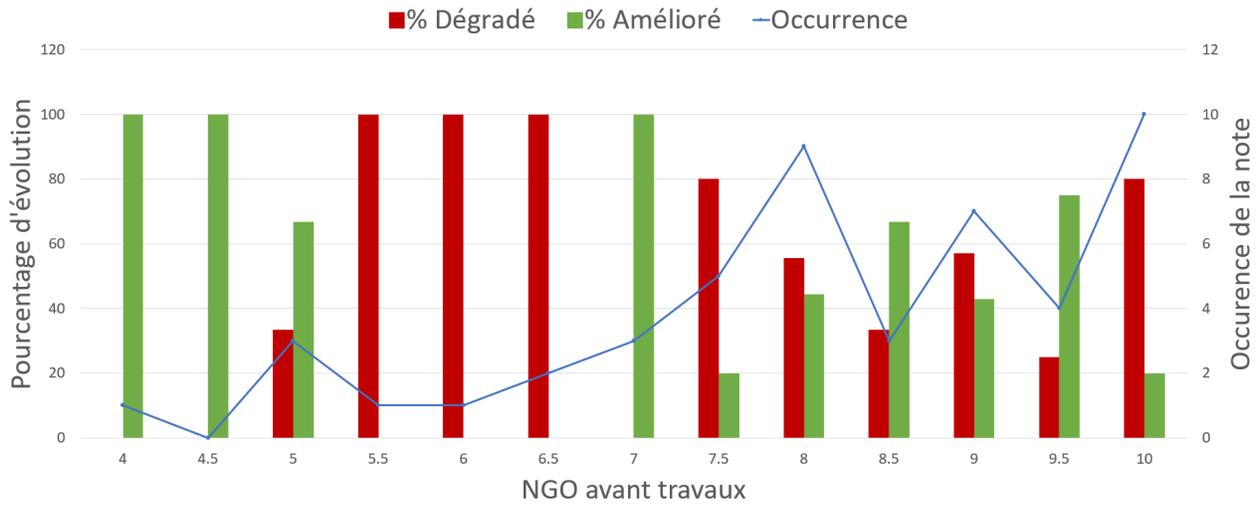


FIGURE 2.17 – L'évolution globale des NGO suite à la réhabilitation

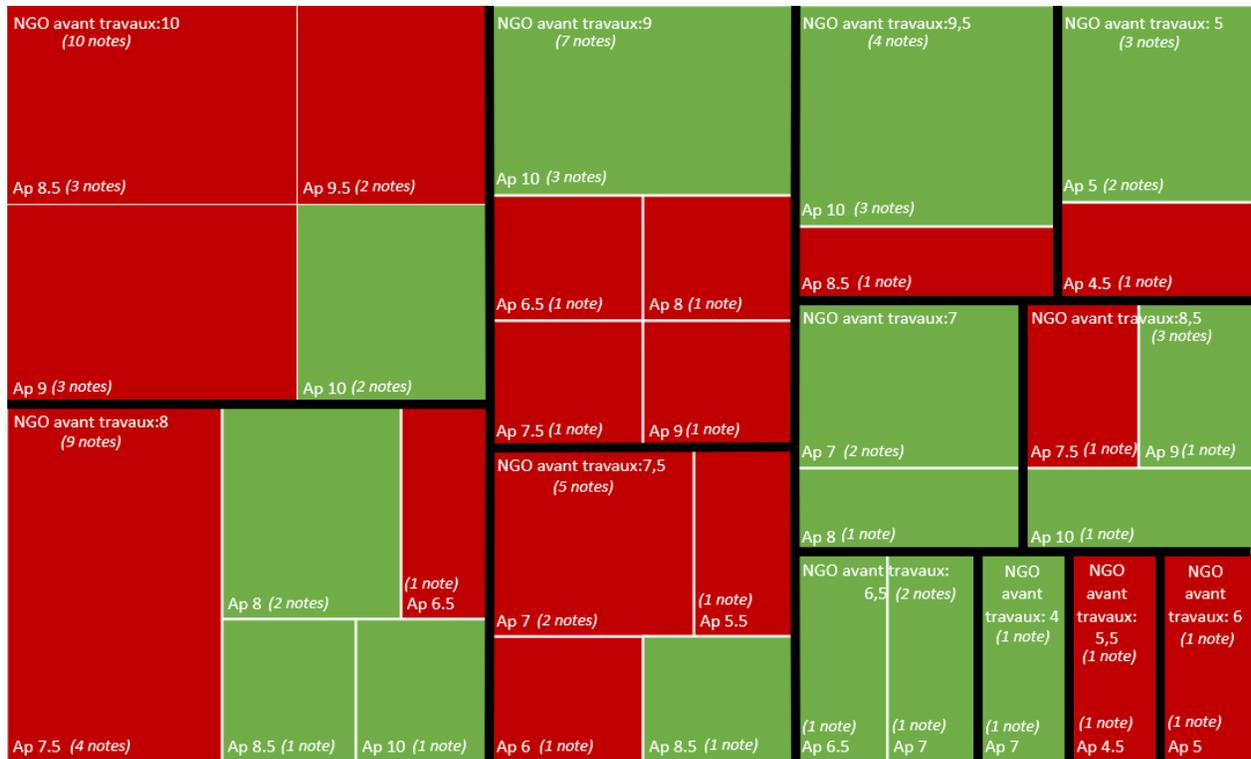


FIGURE 2.18 – le compartimentage des NGO avant travaux en fonction de leurs évolutions

réhabilitation est significativement plus amélioratrice sur la bande des moyennes ondes que sur celle des grandes ondes. Comme le détaille la figure 2.19, et à l'exception de la classe des NMO de 5 qui n'est représentée que par une seule note avant travaux, toutes les classes des NMO avant travaux connaissent un taux d'amélioration supérieur à 50%.

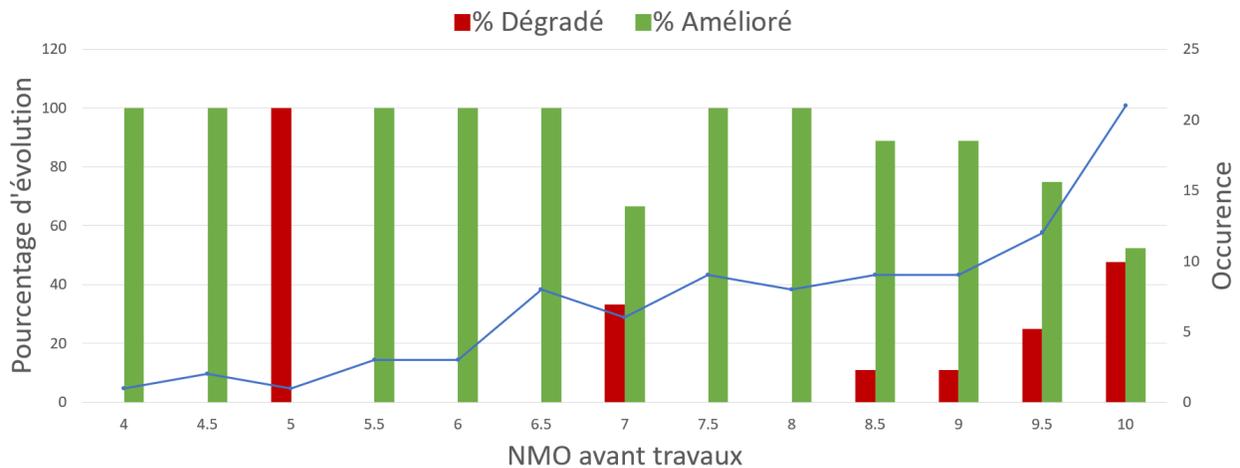


FIGURE 2.19 – l'évolution globale des NMO suite à la réhabilitation

Cependant, et comme l'indique la figure 2.20, l'évolution des notes NMO reste assez dispersée : par exemple, les NMO avant travaux de 5.5 évolueront vers des notes post-réhabilitation entre 4.5 et 10. Cette disparité d'évolution est confirmée sur toutes les classes des NMO ayant des échantillons représentatifs. Au niveau des PO, la figure 2.21 décrit l'impact global de la réhabilitation sur les NBO : sur les 479 NPO avant travaux, 198 sont des notes de 10 (41.33% de l'ensemble des NPO). Sur cette classe de note, la réhabilitation a dégradé 134 notes contre seulement 64 notes améliorées. La dégradation de cette classe fait monter le taux global de dégradation sur toute la bande des petites ondes à 36.11%. Sur les autres classes de NPO avant travaux, le taux d'amélioration des notes dépasse 75%.

La figure 2.22 met en évidence les modes d'évolution des NPO avant travaux : 42.38% des NPO avant travaux améliorées évoluent vers une note post-réhabilitation de 10. Ce pourcentage atteint 75% même sur une classe de notes avant travaux aussi faible que 5. Cependant, la classe de NPO avant travaux de 10 suit une évolution dispersée : seuls 32% maintiennent leur note de 10, tandis que le reste se dégrade vers des notes post-réhabilitation entre 9.5 et 7. Ainsi, la comparaison des notes pré- et post-réhabilitation permet de formuler une appréciation globale de l'évolution de l'uni par bande d'ondes.

Les transitions de notes apparentes sont liées aux évolutions énergétiques du segment suite

2.4. L'IMPACT DE LA RÉHABILITATION EN TERMES DES NOTES PAR BANDES D'ONDES (NBO) :



FIGURE 2.20 – le compartimentage des NMO avant travaux en fonction de leurs évolutions

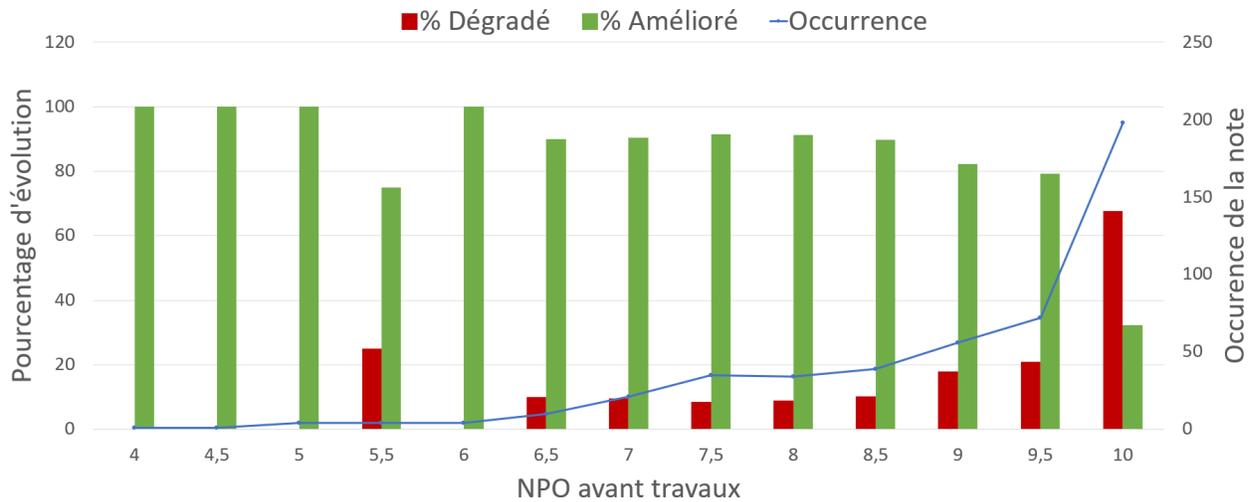


FIGURE 2.21 – L'évolution globale des NPO avant travaux suite à la réhabilitation

à sa réhabilitation par l'équation f ci-dessous :

$$f(E_1, E_2) = \Delta N = -A \log \left(\frac{E_2}{E_1} \right) = -A \log \left(1 + \frac{\Delta E}{E_1} \right) \quad (2.4)$$

où $A > 0$ est le coefficient qui diffère d'une bande d'ondes à une autre selon les équations 1.5 1.6 et 1.7, et $\Delta E = E_2 - E_1$ est le gradient énergétique.

Selon l'équation 2.4, l'évolution de la note d'un segment est liée au rapport $(\frac{\Delta E}{E_1})$. L'énergie E_1 amortit donc l'effet du gradient énergétique sur l'évolution de la note. Ceci induit une disparité entre les bandes d'ondes : en effet, plus l'ordre de grandeur de la bande d'ondes est important, plus l'impact du gradient énergétique sur ses notes est faible. Par exemple, un gradient énergétique de 50 cm^3 peut améliorer ou dégrader la note d'une séquence de petites ondes par 9 points. Le même gradient énergétique ne produit aucune évolution significative des notes de grandes ondes. Les trois bandes d'ondes présentent donc des sensibilités différentes à l'évolution de leurs défauts suite à la réhabilitation.

Pour mettre en évidence ce dernier point, une étude est menée pour analyser l'impact de l'évolution du profil de la chaussée sur l'évolution des NBO : l'idée est de simuler le profil de la chaussée par une sinusoïdale de longueur d'onde $\lambda(m)$ et d'amplitude $A(mm)$. Ces deux paramètres seront ensuite incrémentés pour couvrir tout le domaine de l'uni. A chaque incrément la note correspondante sera calculée.

Les résultats indiquent que le changement de la fréquence n'a aucun impact sur la note de la même bande d'ondes. L'amplitude du signal est donc le paramètre ayant l'effet prépondérant sur la note : comme indiqué dans la figure 2.23, et au niveau des petites ondes, il suffit d'une augmentation de 4 mm pour dégrader la note de 10 à 9. La décroissance de la note continue jusqu'à ce qu'elle atteigne 0 pour amplitude de 2,6 cm. Pour les moyennes ondes, la première dégradation de la note apparaît à l'amplitude de 1 cm. cette note s'annule à l'amplitude de 7.1 cm. Quant aux grandes ondes, cette bande est moins sensible à l'augmentation de l'amplitude, puisque la première dégradation de la note n'apparaît qu'avec une amplitude de 3.8 cm.

L'équation 2.5 indique la différentielle de la fonction d'amélioration par rapport aux deux variables énergétiques E_1 et E_2 :

$$df = \frac{A}{E_1} dE_1 - \frac{A}{E_2} dE_2 \quad (2.5)$$

La composante logarithmique induit une proportionnalité inverse entre le taux d'évolution de la note et les variables énergétiques (E_1, E_2) , indépendamment du sens des corrélations qui les relient. Ceci signifie qu'au niveau de la même bande d'ondes, les PO par exemple, une diminution d'énergie de 2 cm^3 améliorerait une note avant travaux de 7 par 3 points, tandis qu'elle n'améliorerait une note avant travaux de 6 que par 1 point.

2.5 Conclusion :

Pour résumer, ce chapitre présente les caractéristiques du profil de la route mesuré pour mettre en évidence les mécanismes de son évolution suite à la réhabilitation, pour les prendre

en compte et les retraduire lors de la prédiction du profil post-réhabilitation.

Après avoir présenté les profils pré- et post réhabilitation mesurés, ce chapitre commence par une première étude (cf. section 2.2) qui vise à analyser l'évolution de l'uni perceptibles sur le terrain, sans avoir recours à des indicateurs d'uni, en comparant les empreintes énergétiques appariés pré- et post-réhabilitation des défauts identifiés dans les profils mesurés. Les défauts relevés sont caractérisés par différents ordres d'énergie, variant de 10 cm^3 à 30000 cm^3 , et d'étendues pouvant atteindre 60 m. Ce contraste d'amplitude et d'étendue est problématique pour la prédiction du profil post-réhabilitation, puisque les méthodes d'apprentissage supervisé ont un biais vers les basses fréquences. Afin d'éviter ce biais, et pour assurer un apprentissage qui couvre tous les types de défauts préexistants, il convient de décomposer les profils mesurés en différentes bandes d'ondes, dans lesquelles le contraste de fréquence est réduit, et de dédier un modèle à chaque bande d'ondes. La décomposition adoptée dans cette thèse est la suivante : petites ondes - PO ($0.707 < \lambda(m) < 2.828$), moyennes ondes - MO ($2.828 < \lambda(m) < 11.312$), et grandes ondes - GO ($11.312 < \lambda(m) < 45.248$).

La section 2.3 commence par une analyse des caractéristiques des signaux filtrés comme séries temporelles. Les résultats de cette première partie (cf. 2.3.1) montre une atténuation des amplitudes, en comparaison à celles des profils mesures, selon les fonctions de transfert des filtres caractéristiques. Cette analyse a aussi relevé l'existence des autocorrélations relatives à chacune des trois bandes d'ondes. Ceci implique que chaque bande d'onde doit bien être traitée séparément et le signal filtré en conséquence . Ensuite, la deuxième partie (cf. section 2.3.2) présente une analyse des transitions énergétiques qui relient les traces résiduelles pré- et post-réhabilitation. Les résultats de cette deuxième partie indique que le filtrage des 473 paires de défauts pré- et post-réhabilitation permet de relever des schémas plus structurés d'évolution de l'uni : si la description des taux d'amélioration / de dégradation des défauts pré-réhabilitation en fonction de leurs énergies ne permet pas de souligner des tendances d'évolution claires, la même description concernant les traces résiduelles indique des schémas d'évolutions structurés et similaires entre les trois bandes d'ondes. En effet, les taux de dégradation sont inversement proportionnels aux énergies des traces résiduelles dans chaque bande d'ondes.

Cependant, la différence des ordres de grandeur entre les bandes d'ondes implique de facto une différence des précisions requises lors de la prédiction des signaux post-réhabilitation filtrés par bandes d'ondes. En effet, la précision recherchée de la prédiction devrait convenir à la sensibilité des indicateurs post-évaluation choisis. Ainsi, une analyse de sensibilité des trois bandes est présentée dans la section 2.4. Les résultats de cette partie montrent que les trois bandes d'ondes présentent des sensibilités différentes à l'évolution de leurs traces résiduelles suite à la réhabilitation. Par exemple, pour dégrader une note de 10 par un point il suffit d'une augmentation d'amplitude de 4 mm sur l'ensemble du segment de calcul des PO. Au niveau des MO, la même dégradation n'est atteinte qu'avec une augmentation d'amplitude d'1 cm. Quant aux GO, cette bande est moins sensible à l'augmentation de l'amplitude, puisque la première dégradation de la note n'apparaît qu'avec une augmentation d'amplitude de 3.8 cm.

Plus globalement, cette analyse technique de l'évolution des défauts d'uni a permis de se doter d'une méthodologie d'un premier niveau de prétraitement du signal en vue de l'apprentissage supervisé. L'objectif de ce chapitre était donc de présenter les travaux préparatoires sur les mesures profilométriques brutes, dont les principales conclusions peuvent être résumées comme suit :

- L'amélioration de l'alignement des mesures profilométriques est nécessaire afin d'éviter d'introduire de biais lors de l'apprentissage. Ceci permettra au modèle de baser son analyse sur une correspondance maîtrisée entre les irrégularités pré- et post-réhabilitation (modification d'amplitude, de longueur d'onde, ou shift de la localisation).
- Il est nécessaire de définir la corrélation spatiale (dans le signal pré-réhabilitation) qui donne lieu à un défaut monolithique et ce que ce dernier devient après la réalisation de la réhabilitation. A contrario, il est faut capturer la corrélation spatiale (dans le signal post-réhabilitation) qui donne lieu à un défaut monolithique qui n'existait pas nécessairement avant travaux.
- Sur la base de la comparaison statistique des notes par bandes d'ondes pré- et post-réhabilitation, il est faut structurer l'apprentissage par famille de bande d'ondes. Ainsi, il est nécessaire de filtrer davantage les profils mesurés pour mieux les prédisposer au processus d'apprentissage.

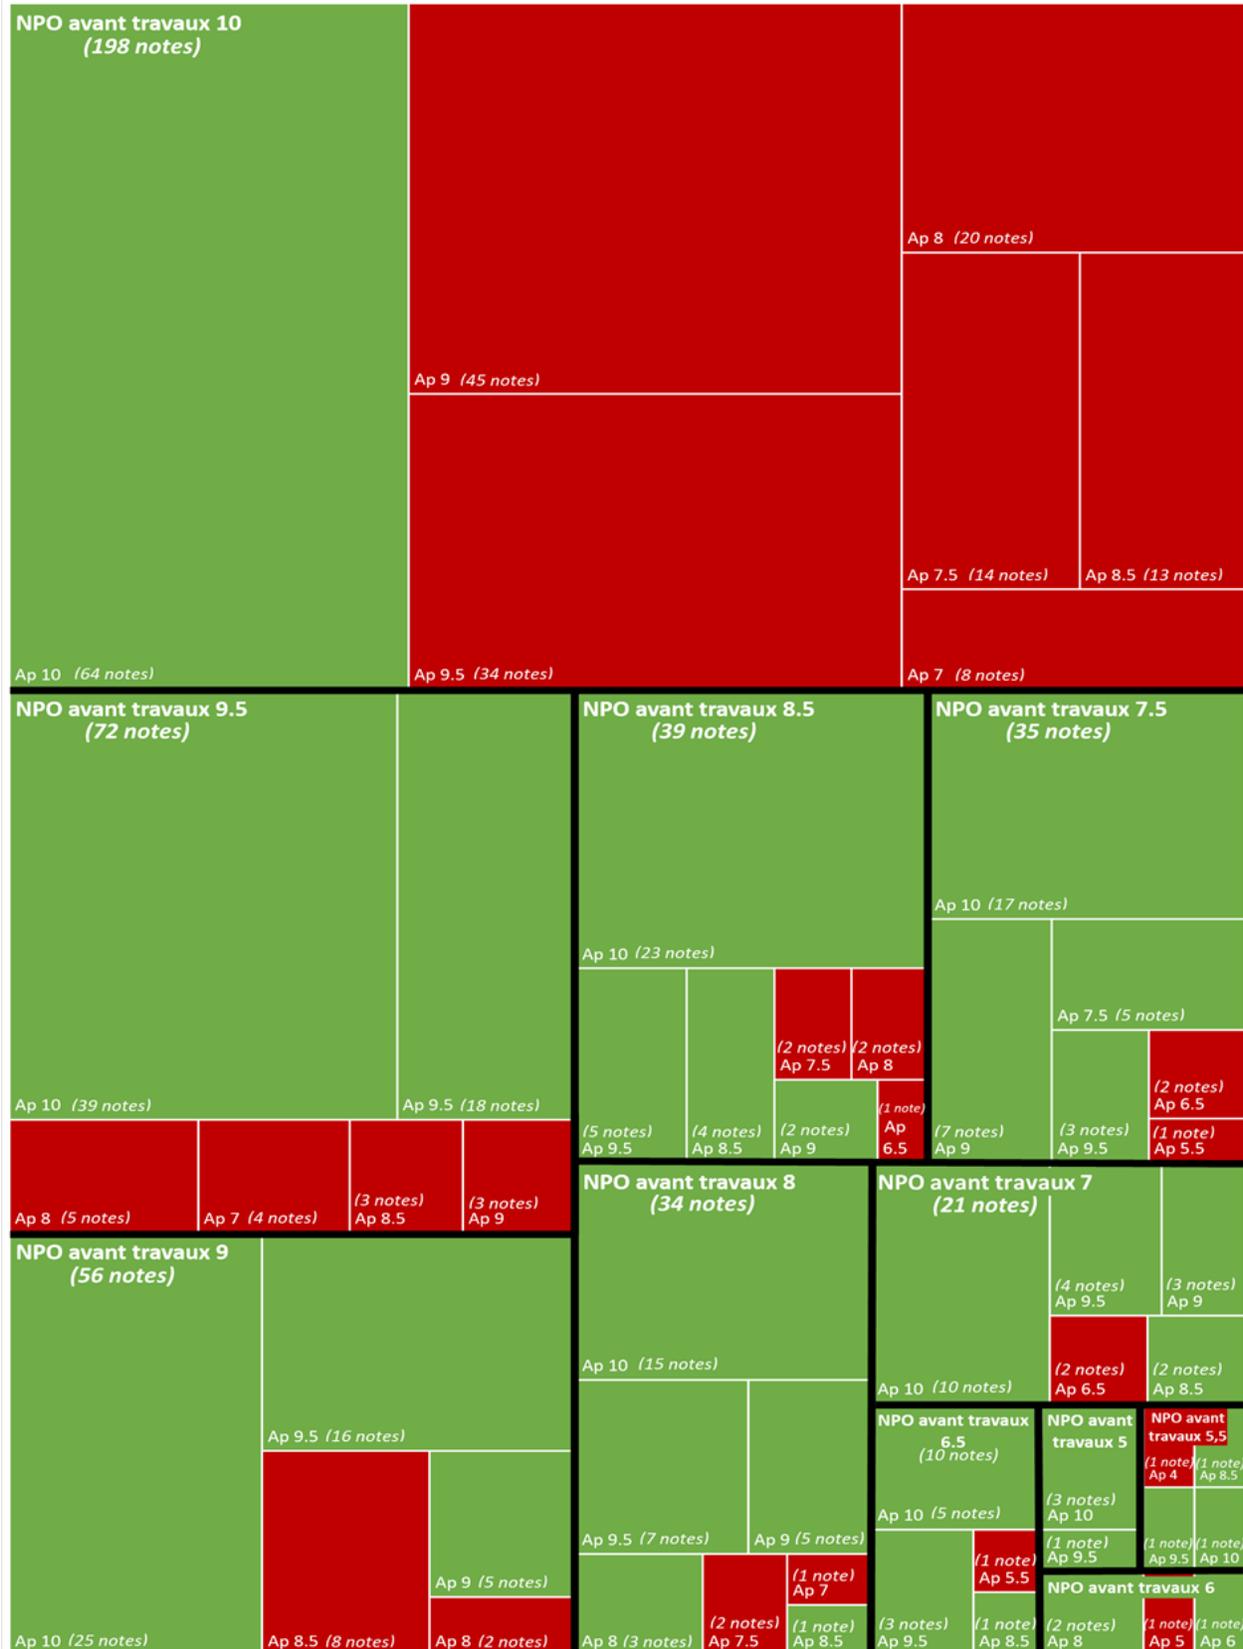


FIGURE 2.22 – le compartimentage des NPO avant travaux en fonction de leurs évolutions

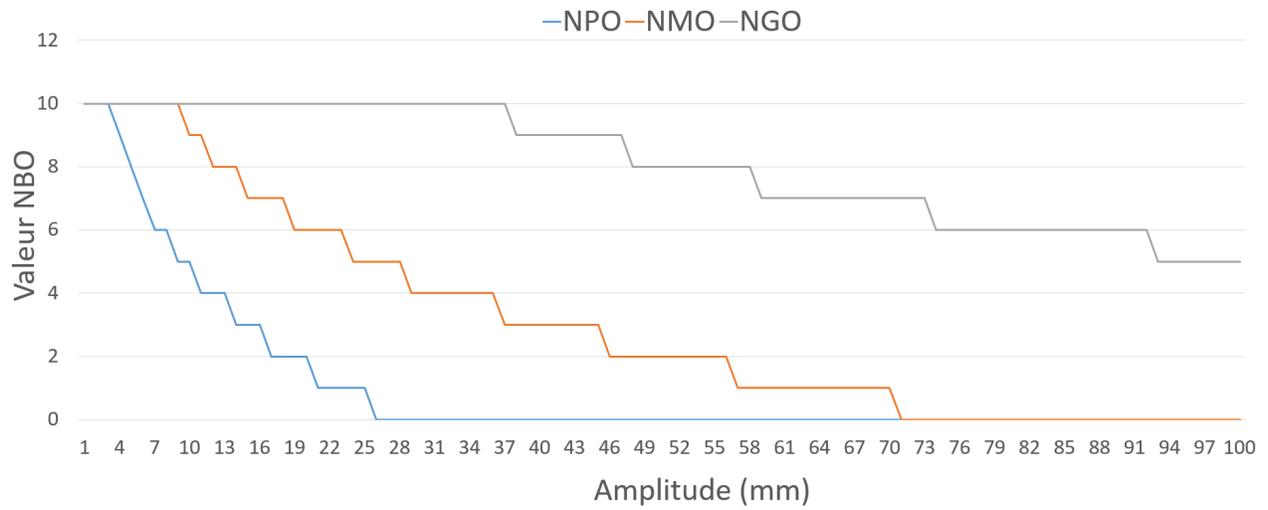


FIGURE 2.23 – L'évolution des NBO en fonction de l'amplitude des profils sinusoidaux.

Chapitre 3

Implémentation et benchmark de méthodes d'apprentissage supervisé de l'uni

L'objectif central de ce chapitre est d'implémenter les méthodes d'apprentissage supervisé qui ressortent de l'étude bibliographique de la section 1.2 et d'analyser leurs capacités à capturer les corrélations spatiales des traces résiduelles dans les signaux filtrés et à les restituer dans l'estimation des évolutions des défauts monolithiques d'uni. Avant de procéder à ce benchmark, ce chapitre commence par présenter l'application du pré traitement des données découlant de l'analyse du chapitre 2. Ensuite, les modèles retenus sont évalués en analysant leurs performances prédictives ainsi que leurs limites à préserver les spécificités de l'uni lors de l'estimation de son évolution.

3.1 Préparation des données

La fiabilité des prédictions des modèles d'apprentissage automatique dépend de la qualité des données disponibles. Sous leur forme brute, les données du monde réel sont souvent partiellement corrompues, bruitées ou proviennent de plusieurs niveaux de granularité. La raison de ces problèmes échappe parfois au contrôle des opérateurs. Dans le cas des données d'uni, des facteurs non contrôlés sur le terrain peuvent conduire à des données partiellement incohérentes ou non pertinentes. En effet, la mesure longitudinale de l'uni entraîne des incohérences de superposition entre les profils pré- et post-réhabilitation : (i) les origines et les fins des deux signaux peuvent ne pas se superposer, (ii) la variation de la vitesse du véhicule pendant la mesure peut introduire une distorsion pathologique des signaux. En outre, divers imprévus peuvent survenir au cours du processus de réhabilitation, entraînant une détérioration imprévisible de l'uni. Les procédures correctives de ces problèmes sont détaillées dans les sections suivantes.

3.1.1 La superposition des profils pré- et post-réhabilitation :

L'objectif ici est de préserver la correspondance spatiale entre les profils pré- et post-réhabilitation, c'est-à-dire d'identifier le segment réhabilité sur les deux profils mesurés. Cela nécessite de déterminer les points d'origines et de fins des deux profils et de corriger leurs distorsions spatiales induites par la variation de la vitesse du véhicule entre ces deux points. La première étape consiste à identifier les points de départ et d'arrivée d'une section donnée en faisant correspondre leurs coordonnées sur la base des données de relevé GPS. Cela permet d'obtenir un premier alignement des signaux mesurés avec une incertitude variable, en raison de la résolution spatiale du capteur GPS, et qui engendre un décalage local et variable qui peut atteindre jusqu'à 15 m (cf. figure 3.1). Chaque point de données du signal mesuré se verra donc attribuer une coordonnée spatiale relative.

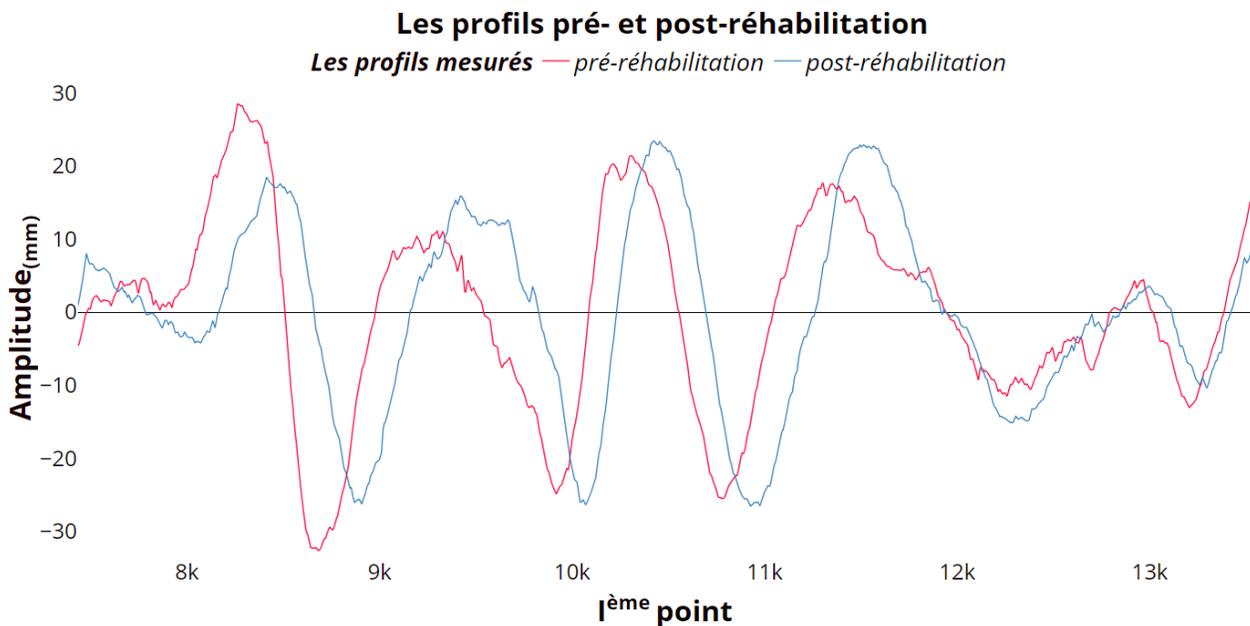


FIGURE 3.1 – Exemple du décalage entre les signatures des défauts dans les profils mesurés

Ce décalage est problématique pour l'identification des signatures pré- et post-réhabilitation des défauts, et de facto pour l'apprentissage supervisé d'un modèle à estimer l'amélioration de l'uni, puisqu'il altère la corrélation entre les deux profils mesurés. Ce décalage doit donc être pré-traité pour minimiser son impact sur la qualité de la prédiction du profil post-réhabilitation.

La deuxième étape vise à rééchantillonner par sections les profils pré- et post-réhabilitation alignés ci-dessus, afin de corriger les décalages locaux : (i) le pas d'échantillonnage uniforme entre deux points concomitants est modifié (augmenté ou réduit) en fonction de la variation de la vitesse d'auscultation. Ce signal intermédiaire est comme si la mesure avait été

faite avec une vitesse d'auscultation constante. (ii) le signal final rééchantillonné est ensuite construit par interpolation, sur la base d'un pas d'échantillonnage constant, afin de préserver la cohérence spatiale des signaux.

La dernière étape est consacrée à l'affinement de l'alignement initial approximatif obtenu lors de la première étape. Les signatures locales des signaux pré- et post-réhabilitation, qui sont rendues homogènes à une vitesse de mesure uniforme dans la deuxième étape, sont utilisées pour affiner la correspondance spatiale entre les deux signaux. A cette fin, les deux signaux sont considérés comme étant alignés de manière optimale lorsqu'une valeur minimale d'écart-type est atteinte par un processus de moyenne mobile concernant les localisation des signatures locales.

L'application de cet algorithme sur les données mesurées améliore la superposition entre les profils pré- et post-réhabilitation comme le montre la figure 3.2.

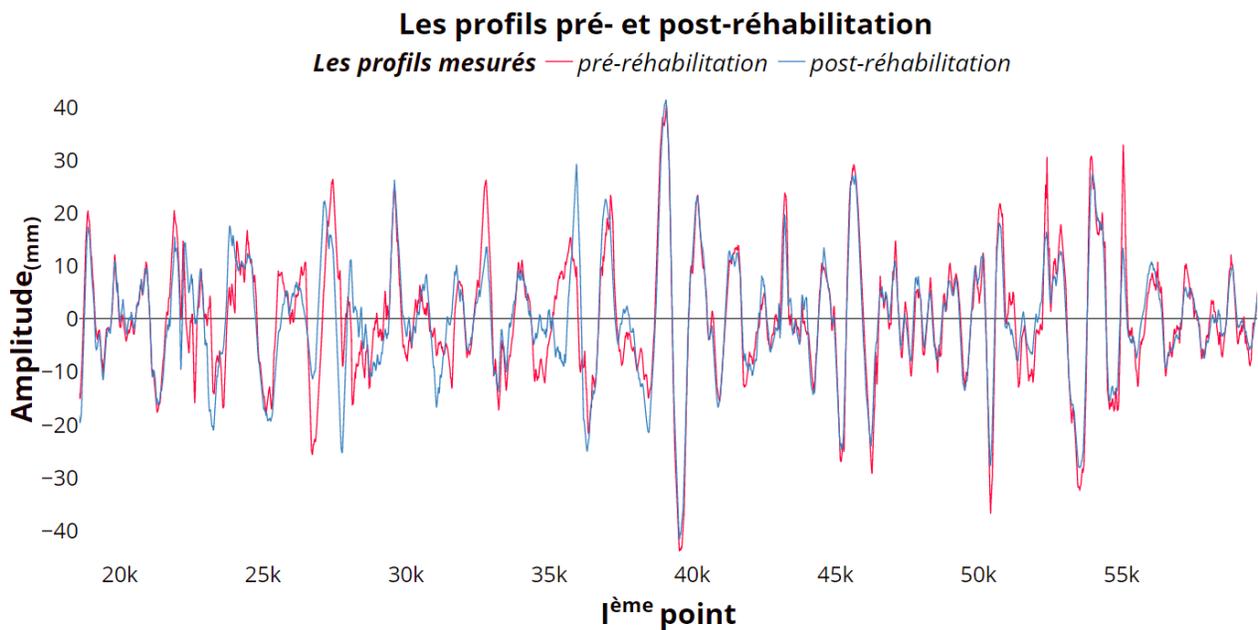


FIGURE 3.2 – Aperçu des profils pré- et post- réhabilitation pré-traités superposés.

Il convient de noter que certains décalages locaux résiduels peuvent persister de manière inhérente même si les procédures correctives sont envisagées, en raison de :

- la répétabilité difficile de la trajectoire longitudinale : un profil longitudinal de la chaussée est la mesure de ses irrégularités le long d'une ligne imaginaire (trajectoire du véhicule). Par conséquent, si la mesure de la même section de la chaussée est répétée, le même profil longitudinal ne peut être obtenu que si la même ligne imaginaire est suivie. Ceci est pratiquement difficile pour les mesures sur de longues distances. En

outre, dans la cas des profilomètres modernes utilisant des lasers (le cas de l'Unibox utilisé dans cette thèse), les mesures ne couvrent qu'une trace de quelques millimètres de la route. Ceci rend la trajectoire suivie plus fine et de facto la répétabilité du même profil routier avec les signatures exactes plus difficile. Ce dernier point explique l'utilisation du terme 'pseudo'-profil pour désigner les mesures longitudinales du profil de la route dans quelques ouvrages de référence.

- L'impact de la réhabilitation : lors de l'entretien de la chaussée par mise en oeuvre d'une nouvelle couche, les défauts préexistants évoluent selon différents mécanismes. Un schéma de cette évolution est celui qui dilate l'étendue de l'irrégularité géométrique tout en atténuant son amplitude, comme le cas du premier défaut de la figure 3.3. Cette dilatation engendre un décalage entre les signatures pré- et post-réhabilitation du défaut qui s'avère irréductible puisqu'il ne provient pas d'un artefact du filtrage ou de mesure, mais plutôt d'un mécanisme intrinsèque de l'évolution de l'uni suite à la réhabilitation.

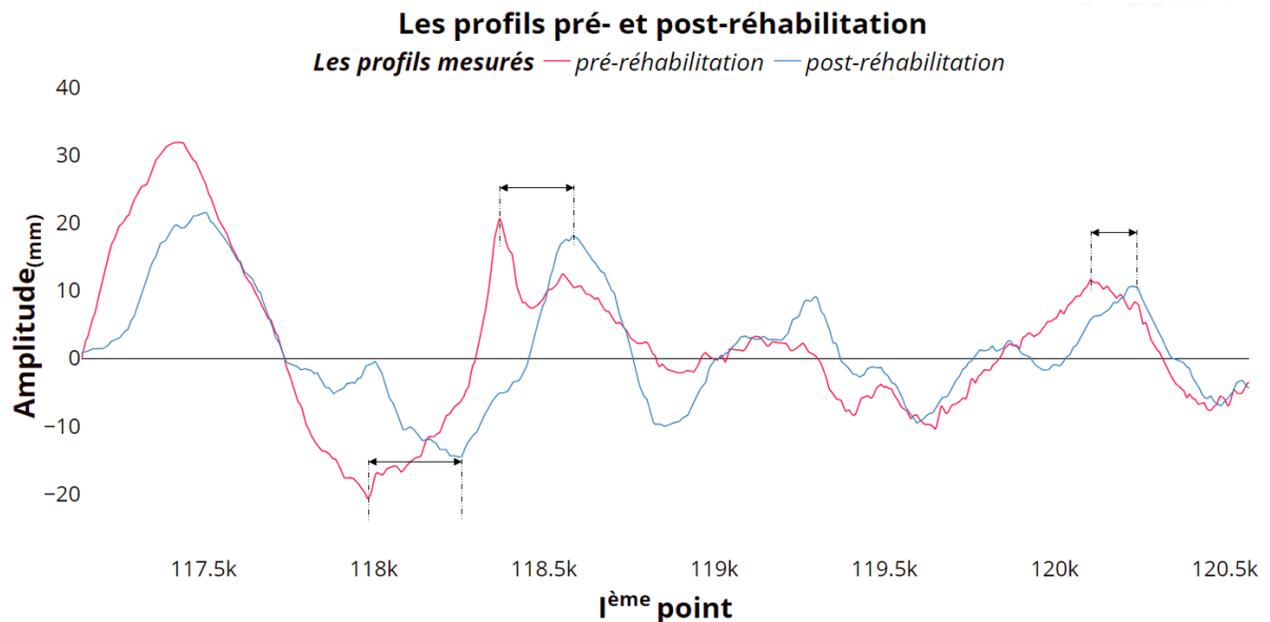


FIGURE 3.3 – L'impact de la réhabilitation sur le décalage entre les signatures pré- et post-réhabilitation du défaut.

3.1.2 Nettoyage des profils pré- et post-réhabilitation :

La détérioration de l'uni peut apparaître soit en créant de nouveaux défauts sur le profil post-réhabilitation, n'ayant aucune hérédité qui les lie au profil pré-réhabilitation, soit en

amplifiant des défauts préexistants. En effet, ce type de défauts est le résultat de divers aléas de chantier (tels que les arrêts prolongé du finisseur, les joints de reprise ou les défaut de compactage) qui peuvent globalement être anticipés et corrigés lors de la mise en oeuvre ou du compactage de la nouvelle couche d'enrobé. L'étude de ces défauts dépasse le cadre de cette thèse, qui vise à prédire l'amélioration des défauts d'uni préexistants. Par conséquent, les signaux des profils pré- et post-réhabilitation doivent être prétraités afin de faire abstraction de ce type de défauts.

A cette fin, il est nécessaire de détecter tout défaut significatif dans le signal, le défaut étant défini comme une irrégularité géométrique monolithique caractérisée par son amplitude et son étendue spatiale (i.e. son énergie), indépendamment de la fluctuation locale du signal erratique. Un critère basé sur l'énergie est adopté pour détecter un défaut comme une séquence monolithique du signal caractérisée morphologiquement par deux vallées entrecoupées d'au moins un pic dominant.

L'identification des défauts se fait en délimitant les écarts d'énergie significatifs dus à ces défauts sur les signaux superposés selon l'algorithme 1(cf. section 2.2.2). Une concordance est ensuite établie entre les séquences de défauts délimités, où pour chaque défaut pré-réhabilitation est identifié le défaut post-réhabilitation correspondant : appariement des défauts. Ainsi, l'évolution d'un défaut pré-réhabilitation est déterminée en comparant son énergie à celle de son défaut post-réhabilitation correspondant. Un défaut pré-réhabilitation est donc considéré comme amplifié si son énergie est supérieure à l'énergie post-réhabilitation correspondante (centrée sur sa signature délimitée dans le signal de pré-réhabilitation). Dans ce cas, les signatures du défaut amplifié sont supprimées des profils pré- et post-réhabilitation : nettoyage des données.

La figure 3.4 illustre la procédure de nettoyage des données : des séquences de défauts monolithiques sont identifiées et appariées sur le pseudo-profil de pré-réhabilitation (rouge) et le profil correspondant de post-réhabilitation (bleu). Sur cette figure, le premier défaut a une énergie post-réhabilitation plus élevée et est donc exclu de l'ensemble de données.

3.2 Filtrage en trois bandes d'ondes

Rappelons que l'exploration des mesures profilométriques (cf.section 2.2.3) indique que les défauts d'uni ont des ordres de grandeur et des fréquences variable. Cependant, ce fort contraste observé est problématique pour la prédiction du profil post-réhabilitation puisque les méthodes d'apprentissage supervisé, notamment les réseaux de neurones, ont un biais vers les basses fréquences. En effet, l'ajustement des hautes fréquences nécessite un réglage fin des paramètres puisque ceux impliqués dans l'expression des composantes de haute fréquence occupent un petit volume dans l'espace des paramètres. Par conséquent, ce biais spectral doit être évité pour permettre un apprentissage qui couvre tous les défauts préexistants, quelles que soient leurs étendues. A cette fin, les profils mesurés sont décomposés en trois bandes d'ondes, dans lesquelles le contraste des traces résiduelles est réduit, qui sont : petites

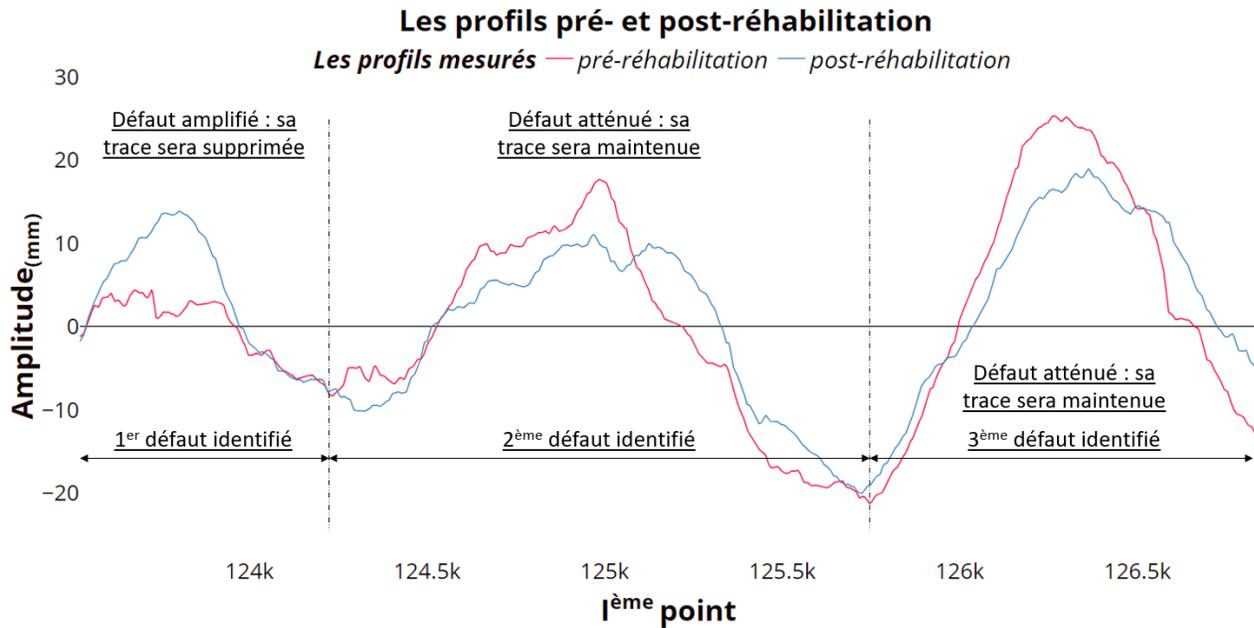


FIGURE 3.4 – Exemple de nettoyage de données : identification d'un défaut amplifié.

ondes - PO ($0.707 < \lambda(m) < 2.828$), moyennes ondes - MO ($2.828 < \lambda(m) < 11.312$), et grandes ondes - GO ($11.312 < \lambda(m) < 45.248$). Ensuite, un modèle dédié à chaque bande d'ondes sera spécifiquement développé pour estimer l'atténuation ses traces résiduelles pré-réhabilitation suite à la réhabilitation. Une prédiction globale de la post-réhabilitation peut alors être construite en additionnant les estimations de chaque bande d'ondes.

La décomposition de la mesure en trois bandes d'ondes peut être réalisée grâce des filtres passe-bande, où chaque filtre ne laisse passer que la bande comprise entre ces deux fréquences de coupure. Or, cette méthode de filtrage reste instable, peu précise et risque d'engendrer des distorsions dans les signaux filtrés, altérant ainsi la superpositions des traces résiduelles pré- et post-réhabilitation . Par conséquent, la décomposition en bande d'ondes suivie dans cette thèse se base sur un filtrage successif par filtres passe-bas plus stables [150]. En effet, pour extraire la bande d'ondes définie entre les deux longueurs d'ondes λ_1 et λ_2 , la décomposition ci-dessous a été suivi :

1. Filtrer le profil mesuré par un premier filtre de Butterworth passe-bas dont la longueur de coupure est λ_1
2. Filtrer le profil mesuré par un deuxième filtre de Butterworth passe-bas dont la longueur de coupure est λ_2
3. Calculer la différence entre le résultat du premier filtrage et celui du deuxième filtrage, pour extraire la bande définie entre λ_1 et λ_2 .

La décomposition des profils en trois bandes d'ondes suit ce même enchaînement en adaptant à chaque fois λ_1 et λ_2 aux longueurs d'ondes qui définissent les GO, MO et PO. Plus de détails sur les filtres employés se trouvent dans l'annexe A.

Certes, le choix de décomposer les mesures profilométriques en trois bandes d'onde, afin de dédier ensuite un modèle à chaque bande, a été motivé par le souci d'éviter le biais spectral des modèles d'apprentissage supervisé et d'attribuer des prédictions significatives des défauts d'uni préexistants indépendamment de leurs ordres de grandeur. Or, il convient de noter que ce choix impose une limite qu'il faut souligner : la prédiction des atténuations des traces résiduelles post-réhabilitation d'une bande d'ondes à partir de celles pré-réhabilitation correspondant suppose d'une part une indépendance entre les trois bandes d'ondes, et d'autre part une concordance entre l'évolution du défaut et celles des traces résiduelles des trois bandes d'ondes. En d'autres termes, l'évolution d'un défaut se traduira par des évolutions concordantes des traces résiduelles post-réhabilitation par bandes d'ondes indépendantes les unes des autres. Ainsi, l'amélioration d'un défaut retenu dans le profil pré-existant nettoyé peut être prédite en estimant séparément les atténuations de ses traces résiduelles sur les trois bandes d'ondes. Néanmoins, ces deux hypothèses (indépendance et concordance) ne sont pas vérifiées dans quelques cas (9 défauts sur 473 relevés) : comme précédemment indiqué dans la section 3.1.1, un des schémas d'évolution des défauts pré-existants suite à la réhabilitation est celui où l'amplitude du bloc monolithique (défaut) est atténuée en dilatant son étendue. Cette dilatation instaure une interdépendance entre les traces résiduelles à la limite de trois bandes d'ondes : considérons l'exemple simple d'un défaut pré-existant ayant une composante principale caractérisée par une longueur d'onde de 2.7 m. La décomposition d'un tel défaut donne lieu à une trace résiduelle pré-réhabilitation PO majeure ainsi que deux traces résiduelles pré-réhabilitation MO et GO insignifiantes (leurs énergies sont faibles). Si l'amélioration de ce défaut passe par une dilatation de son étendue, sa longueur d'onde augmentera ce qui se traduira par une trace résiduelle post-réhabilitation MO majeure avec deux traces PO et GO insignifiantes. Ainsi, cette interdépendance entre les bandes d'ondes engendre une discordance entre l'évolution d'un défaut et celles de ses traces résiduelles par bandes d'ondes : l'amélioration du défaut de cet exemple se traduit en termes de comparaison par bande d'ondes par un effacement de la trace résiduelle PO pré-réhabilitation (amélioration) et son apparition comme une trace résiduelle MO post-réhabilitation (dégradation). Dans une approche de prédiction bande par bande, la trace résiduelle MO post-réhabilitation ne peut être prédite puisqu'elle n'a aucune hérédité qui la relie à celle MO pré-réhabilitation, mais elle est plutôt le résultat de l'évolution de la trace résiduelle d'une autre bande. Ce type de défauts échappe donc à cette approche et il convient de l'écarter de l'ensemble des données. A l'issue de pré-traitement des profils, trois paires de signaux filtrés sont obtenus : les signaux GO qui comportent 88000 points chacun, les signaux MO où chacun contient 28000 points et les signaux PO qui se composent de 6800 points.

3.3 Organisation des données

A l'issue des deux étapes du pré-traitement détaillées précédemment, la troisième étape de ce processus consiste à organiser les données filtrées pour les adapter aux schémas d'apprentissage supervisé choisi. Ainsi, le terme organisation désigne ici la mise en forme des données pour convenir à la stratégie adoptée pour prédire les signaux post-réhabilitation filtrés des trois bandes d'ondes.

Pour ce faire, et se basant sur les méthodes d'apprentissage supervisé pour le traitement des séries temporelles détaillées dans la bibliographie (cf. section 1.2), deux approches se distinguent : une première qui consiste à construire les signaux par bandes d'ondes post-réhabilitation point par point et une deuxième qui le fait séquence par séquence.

Pour l'approche "point par point", elle comprend toutes les méthodes d'apprentissage qui construisent itérativement la série temporelle prédite (le signal filtré post-réhabilitation par bande d'ondes dans ce cas) un point à la fois. Cependant, puisque la corrélation entre les signaux filtrés pré- et post-réhabilitation s'établit au niveau des traces résiduelles, un point d'une trace résiduelle post-réhabilitation n'existe que comme résultat de l'évolution de l'ensemble de points qui forme la trace résiduelle pré-réhabilitation. Par conséquent, la prédiction d'un point du signal post-réhabilitation filtré y_i en l'associant qu'à un point du signal pré-réhabilitation x_i ($y_i = f(x_i)$) n'est pas suffisante pour produire une estimation significative de l'évolution de l'uni suite à la réhabilitation de la chaussée. En outre, cette méthode reste d'autant plus problématique dans ce cas puisque la superposition entre les signaux pré- et post-réhabilitation n'atteint pas le niveau du point par point, à cause du décalage résiduel et variable, ce qui altère la précision de la prédiction. Il convient donc de prendre en compte le contexte spatial lors de la prédiction de l'évolution d'une trace résiduelle pré-réhabilitation. Ainsi, et dans le cadre d'une approche point par point, les signaux post-réhabilitation relatifs à chacune des trois bandes d'ondes sont prédits en estimant la fonction f définie par l'équation 3.1. Cette fonction associe un point du signal filtré post-réhabilitation y_i à une fenêtre du signal pré-réhabilitation filtré de longueur $2lag + 1$ centrée autour du point x_i .

$$\hat{y}_i = f(x_{i-lag} \dots x_{i+lag}) \quad (3.1)$$

Quant à l'approche "séquence par séquence", elle regroupe les méthodes d'apprentissage qui prennent en entrée une séquence d'une série temporelle pour en générer une autre comme sortie. Employés pour la prédiction de l'uni, les modèles séquence par séquence traitent comme entrée une séquence du signal pré-réhabilitation pour prédire en sortie la séquence du signal post-réhabilitation qui lui correspond. Ainsi, et contrairement à celle point par point, l'approche séquence par séquence construit itérativement le signal post-réhabilitation une séquence à la fois. Dans le cadre d'une approche séquence par séquence, les signaux post-réhabilitation relatifs à chacune des trois bandes d'ondes sont prédits en estimant la fonction f définie par l'équation 3.2. Cette approche préserverait les dépendances à plusieurs niveaux nécessaires pour prédire l'évolution de l'uni : d'une part, et au niveau des signaux filtré pré-réhabilitation, le traitement par séquence permettrait de prendre en compte l'ensemble de

traces résiduelles pour préserver les corrélations spatiales qui relient leurs points. D'autre part, l'approche séquence par séquence introduit davantage de contexte spatial lors de la prédiction des points de la séquence post-réhabilitation, ce qui préserverait les corrélations entre les traces pré- et post-réhabilitation.

$$(\widehat{y}_i)_{k.N \leq i \leq (k+1).N} = f((x_i)_{k.N \leq i \leq (k+1).N}) \quad (3.2)$$

Pour pouvoir être traitées par les méthodes d'apprentissage supervisé qui analysent les séries temporelles selon cette deuxième approche, les données des trois bandes d'ondes doivent être segmentées pour obtenir des séquences unitaires dont les longueurs diffèrent d'une bande d'onde à l'autre à l'image des autocorrélations de leurs signaux. Cependant, cette segmentation risque de créer un effet de bord susceptible d'altérer la qualité de prédiction au début et à la fin de chaque séquence. Cet effet devient particulièrement problématique dans le cas d'une évaluation qualitative des résultats qui suit aussi une approche de segmentation comme celle des NBO : si la longueur des segments de prédiction est plus petite que celle du calcul des NBO, les effets de bord se répéteront plusieurs fois dans un seul segment de calcul ce qui altérera la note prédite. Donc, la longueur des séquences doit être au moins égale à celle des segments de calcul des NBO. Ainsi, les longueurs des séquences unitaires sont : 20 m (400 points) pour les PO, 100 m (2000 points) pour les MO et 200 m (4000 points) pour les GO.

Le choix d'une des deux approches conditionne la mise en forme des données. Toutefois, ce choix doit se faire sur la base d'une analyse comparative des performances des modèles de référence de chacune des deux approches. Ainsi, dans ce qui suit nous présentons un benchmark de ces deux stratégies de prédiction (point par point et séquence par séquence) selon le même processus d'évaluation pour évaluer leurs pertinences.

3.4 Analyse comparative des approches de prédiction

Nous rappelons ici que l'objectif de ce travail est de proposer un modèle de prédiction qui préserve les dépendances à plusieurs niveaux : les corrélations spatiales des traces résiduelles au sein d'un même signal d'une bande d'ondes et les corrélations entre les traces résiduelles pré- et post-réhabilitation.

Pour ce faire, et en se basant sur les modèles détaillés dans la bibliographie (cf. section 1.2), deux approches de prédiction se distinguent : une première qui consiste à construire les signaux par bandes d'ondes post-réhabilitation point par point et une deuxième qui le fait séquence par séquence. Dans ce qui suit, ces deux approches seront testées pour évaluer leurs pertinences.

Chacun des modèles d'apprentissage supervisé sera évalué sur les trois bandes d'ondes suivant le même processus : la première étape est celle d'entraînement où le modèle affine ses paramètres pour s'ajuster au mieux au jeu de données d'entraînement de chaque bande d'ondes.

Pour cela, la qualité d'ajustement du modèle sera évaluée à travers une mesure de performance appelée la fonction coût.

La deuxième étape est celle de test qui consiste à évaluer la capacité du modèle, avec les paramètres ajustés lors de son entraînement, à généraliser ses prédictions sur un nouveau jeu de données de test. Nous choisissons dans notre cas les fonctions d'erreur les plus courantes pour la régression des séries, qui sont l'erreur quadratique moyenne (mean square error - MSE) et l'erreur moyenne absolue (mean absolute error - MAE) définies respectivement aux équations 3.3 et 3.4

$$MSE = \frac{1}{N_{test}} \sum_{i=1}^{N_{test}} (y_i - \hat{y}_i)^2 \quad (3.3)$$

$$MAE = \frac{1}{N_{test}} \sum_{i=1}^{N_{test}} |y_i - \hat{y}_i| \quad (3.4)$$

où \hat{y} est la valeur prédite, y est la valeur réelle (cible) et N_{test} est le nombre de points de test. Ainsi, la performance du modèle sur ce jeu de test est celle qui quantifie la qualité d'apprentissage et permet d'évaluer la pertinence des prédictions du modèle entraîné.

Ces deux étapes assurent un apprentissage qui permet de prédire les traces résiduelles par bandes d'ondes post-réhabilitation et d'évaluer la pertinence de cette prédiction en se basant sur une approche quantitative. En d'autres termes, la performance du modèle produit est liée à une fonction d'erreur où la meilleure prédiction est celle qui la minimise, indépendamment du sens physique que la série temporelle représente. Il convient donc de compléter cette approche quantitative par une autre qualitative qui évalue la pertinence de la prédiction, comme série temporelle qui représente des traces résiduelles post-réhabilitation par bandes d'ondes, et qui préserve le sens de son post-traitement : la prédiction du profil post-réhabilitation n'est pas l'aboutissement final du processus d'estimation de l'impact de la réhabilitation sur l'amélioration de la chaussée, mais plutôt une étape à adapter en fonction du couplage "profil prédit / indicateur contractuel" prévu. Dans cette thèse, les NBO sont choisies comme la métrique d'évaluation qualitative de la prédiction, puisqu'elles suivent la même décomposition en bandes d'ondes PO, MO et GO. Ainsi, la troisième étape du processus d'évaluation des modèles consiste à calculer les NBO de leurs prédictions sur le jeu de données de test pour les comparer aux NBO réelles.

L'application de ce processus d'évaluation des modèles passe d'abord par une division des jeu de données de chaque bande d'ondes en deux sous-ensemble : 75 % comme un jeu de données d'entraînement (N_{train}) et les 25 % restants comme un jeu de données de test (N_{test}). Par conséquent, la forme finale des données est la suivante :

- Sur les GO : 68000 points dans le jeu d'entraînement et 20000 points dans le jeu de test.
- Sur les MO : 20000 points dans le jeu d'entraînement et 8000 points dans le jeu de test.
- Sur les PO : 5200 points dans le jeu d'entraînement et 1600 points dans le jeu de test.

Dans le reste de ce document, les signaux pré- et post-réhabilitation pré-traités et filtrés par bandes d'ondes seront notés respectivement (X_{GO}, X_{MO}, X_{PO}) et (Y_{GO}, Y_{MO}, Y_{PO}) .

3.4.1 L'approche point par point :

Les modèles qui suivent cette approche parmi ceux détaillés dans la section 1.2.1 sont les régressions Ridge et Lasso, les K-plus proches voisins (KNN), les machines à vecteurs de support pour régression (SVR), les forêts aléatoires et les arbres à gradient adaptatif (G-TB). Dans notre cas, ces modèles apprennent à estimer la fonction d'association f qui associe un point du signal filtré post-réhabilitation y_i à une fenêtre du signal pré-réhabilitation filtré de longueur $2lag + 1$ centrée autour du point x_i , comme l'indique l'équation 3.5.

$$\hat{y}_i = f(x_{i-lag} \dots x_{i+lag}) \quad (3.5)$$

Après avoir détaillé leurs implémentations dans ce qui suit, ces modèles seront entraînés et testés sur les données des trois bandes d'ondes pour ensuite analyser ses résultats.

L'implémentation des modèles :

Le terme "implémentation" désigne ici la procédure de développement du modèle, et plus particulièrement sa description en termes d'hyperparamètres, avant de lancer son entraînement. Ainsi, dans ce qui suit l'implémentation des modèles à tester sera détaillée en suivant les valeurs par défaut proposés habituellement utilisés. Ces dernières feront l'objet d'une étude paramétrique pour évaluer leurs impacts sur les performances des modèles.

Les régressions linéaires :

Les modèles de régression linéaire estiment la fonction f en ajustant les poids \hat{w}_j et b de l'équation linéaire 3.6 :

$$\hat{y}_i = \sum_{p=i-lag}^{p=i+lag} \hat{w}_p x_p + b \quad (3.6)$$

Ainsi, l'entraînement du modèle consiste à trouver la combinaison des w et b qui estime au mieux les valeurs observées (y_i) d'entraînement.

Pour un modèle linéaire, deux versions de régularisations sont obtenues en contraignant la norme du vecteur des poids : celle de Ridge et celle de Lasso.

Pour la régression de Ridge (RR), le terme de régularisation $\alpha \sum_{p=i-lag}^{p=i+lag} \hat{w}_p^2$ est introduit dans la fonction coût. Dans notre cas, α est fixée à 1. Ainsi, l'entraînement du modèle linéaire de la régression Ridge consiste à minimiser la fonction coût suivante :

$$\frac{1}{N_{train}} \sum_{i=1}^{N_{train}} \left(y_i - \sum_{p=i-lag}^{p=i+lag} \hat{w}_p x_p - b \right)^2 + \sum_{p=i-lag}^{p=i+lag} (\hat{w}_p)^2 \quad (3.7)$$

Pour la régression de Lasso (RL), le terme de régularisation est $\alpha \sum_{p=i-lag}^{p=i+lag} |\hat{w}_p|$. Dans notre cas, α est fixée à 1. La fonction à minimiser lors de l'entraînement devient donc :

$$\frac{1}{N_{train}} \sum_{i=1}^{N_{train}} \left(y_i - \sum_{p=i-lag}^{p=i+lag} \hat{w}_p x_p + b \right)^2 + \sum_{p=i-lag}^{p=i+lag} |\hat{w}_p| \quad (3.8)$$

Les K-plus proches voisins (KNN) :

Dans le cas de la régression, un modèle KNN associe à une nouvelle entrée $(x_p)_{i-lag \leq p \leq i+lag}$ la moyenne des K observations les plus proches (similaires), selon une distance à définir, parmi celles sauvegardées lors de son entraînement.

L'implémentation de ce modèle nécessite ainsi de spécifier :

- La distance selon laquelle la similarité entre les observations est quantifiée : dans ce cas, la distance choisie est celle Euclidienne.
- Le nombre d'observations les plus proches à prendre en considération lors du calcul de la moyenne : ce nombre est fixé à 5 observations.
- La pondération de la moyenne : la sortie est la moyenne des 5 plus proches voisins.

Les machines à vecteurs de support pour régression (SVR) :

Comme détaillé dans la section 1.2.2, la fonction non-linéaire estimée par un modèle SVR, lors de son entraînement sur un jeu de donnée de forme $\{(\mathbf{x}_i, y_i) ; i = 1 \dots N_{train}\} \subset \mathbf{R}^{2lag+1} \times \mathbf{R}$, est décrite par l'équation 1.12. L'objectif d'entraînement d'un modèle SVR est de trouver le jeu de poids w et b optimal selon deux critères : le premier est la minimisation de l'erreur d'estimation des valeurs cibles (y_i) sur le jeu d'entraînement, également connue sous le nom de risque empirique \mathbf{R}_{emp} détaillée par l'équation 3.9, définie par rapport à un seuil de précision ϵ . D'autre part, le deuxième critère est la régularisation des poids qui peut être mesurée par la norme euclidienne (i.e minimiser $\|w\|^2$).

$$\mathbf{R}_{emp}(y, \mathbf{x}, \epsilon) = |y - f(\mathbf{x}, w)|_\epsilon = \begin{cases} 0 & \text{si } |y - f(\mathbf{x}, w)| \leq \epsilon \\ |y - f(\mathbf{x}, w)| - \epsilon & \text{sinon.} \end{cases} \quad (3.9)$$

Ainsi, l'objectif global de l'entraînement consiste à minimiser la fonction décrite par l'équation 3.10.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^{N_{train}} \mathbf{R}_{emp}(y_i, \mathbf{x}_i, \epsilon) \quad (3.10)$$

L'implémentation d'un modèle SVR nécessite donc la définition de trois hyperparamètres :

- Le coefficient de régularisation C : détermine le compromis entre la régularisation w et le seuil jusqu'au-quel les écarts supérieurs à ϵ sont tolérés. Une plus petite valeur de C tolère ainsi un plus grand écart. Dans cette étude, C est fixé à 1.

- Le seuil de précision ϵ : spécifie le tube epsilon à l'intérieur duquel aucune pénalité n'est associée dans la fonction dans le risque empirique d'apprentissage aux points prédits à une distance epsilon de la valeur réelle. Ce seuil de précision est fixé à 0.1.
- La fonction noyau K : la fonction "Kernel" choisie est celle radiale de base gaussienne - RBF (cf. équation 3.11). Le comportement du modèle est très sensible au paramètre gamma γ . Si γ est trop grand, le rayon de la zone d'influence des vecteurs de support ne comprend que le vecteur de support lui-même et aucune régularisation avec C ne sera en mesure d'empêcher le surajustement. Lorsque γ est très petit, le modèle est trop contraint et ne peut pas capturer la complexité ou la "forme" des données. Il convient donc de choisir une valeur intermédiaire de gamma qui prend en compte les caractéristiques et la complexité des données. Ainsi, la valeur choisie est $\gamma = \frac{1}{((2.lag+1) Var(x))}$ où $Var(x) = \frac{1}{N_{train}} \sum_{i=1}^{N_{train}} (x_i - \frac{1}{N_{train}} \sum_{i=1}^{N_{train}} x_i)^2$.

$$K(\mathbf{x}_1, \mathbf{x}_2) = \exp(-\gamma \|\mathbf{x}_1 - \mathbf{x}_2\|^2) \quad (3.11)$$

Les forêts aléatoires :

L'implémentation des forêts aléatoires suit une logique de bagging (cf. section 1.2.2) : elle commence par le tirage de plusieurs échantillons Bootstrap à partir du jeu d'entraînement (tirage aléatoire de n observations avec remise dans les données d'entraînement). Chacun de ces échantillons servira comme données d'entraînement pour un arbre binaire en injectant une autre variable aléatoire : le critère de division de chaque noeud est défini sur un tirage aléatoire de m variables explicatives. Chacun de ces arbres est développé jusqu'à sa forme maximale sans élagage. A la fin, les arbres binaires sont agrégés pour constituer une forêt aléatoire dont la sortie est la moyenne des estimations de chacune de ses arbres binaires maximales.

L'implémentation des forêts aléatoires passe donc par la définition des hyperparamètres suivants :

- Le nombre d'arbres binaires : la forêt aléatoire se compose de 100 arbres binaires.
- Le nombre minimum d'échantillons requis pour être à un noeud feuille : un point de découpage à n'importe quelle profondeur ne sera considéré que s'il laisse au moins 2 échantillons d'entraînement dans chacune des branches gauche et droite. Cela peut avoir pour effet de lisser le modèle, en particulier dans la régression.
- Le nombre de variables explicatives m à prendre en compte lors de la recherche de la meilleure division : $m = \sqrt{2lag + 1}$.

Les arbres à gradient adaptatif G-TB :

Un modèle G-TB se base sur la méthode de boosting (cf. section 1.2.2) pour construire séquentiellement des arbres binaires qui se complètent l'un l'autre. En effet, les arbres bi-

naires sont agrégés pour minimiser une fonction d'erreur pas à pas, où à chaque itération un arbre binaire est ajouté à l'ensemble pour améliorer sa performance. Ainsi, et à une itération m , le modèle f du G-TB s'exprime comme indiqué par l'équation 3.12 :

$$f_m = f_{m-1} - \gamma_m \sum_{i=1}^N \nabla_{f_{m-1}} l(y_i, f_{m-1}(\mathbf{x}_i)) \quad (3.12)$$

où γ_m est le pas de la descente de gradient (le taux d'apprentissage) et $l()$ est la fonction d'erreur de l'agrégation du modèle.

A la fin de chaque itération, l'arbre δ_m est combiné avec le modèle de l'étape précédente selon l'équation 3.13 :

$$f_m(\mathbf{x}) = f_{m-1}(\mathbf{x}) + \gamma_m \delta_m(\mathbf{x}) \quad (3.13)$$

Certes, la dépendance entre les arbres assure un apprentissage suivant une approche adaptative où un arbre binaire corrige son précédent. Or, cette dépendance risque d'être contraignante dans le cas où un arbre de l'ensemble produit une grande erreur qui ne peut être rattrapée par les prédicteurs suivants. Il convient donc d'introduire une indépendance entre les arbres. Pour ce faire, l'arbre binaire ajouté à chaque itération sera entraîné sur un sous-échantillon tiré aléatoirement à partir de l'ensemble des données d'entraînement disponible. Ce tirage aléatoire permet d'incorporer le caractère aléatoire comme partie intégrante de l'agrégation des arbres binaires, comme dans le cas du bagging : l'optimisation stochastique. L'implémentation d'un modèle G-BT nécessite donc la définition des hyperparamètres suivants :

- La fonction $l()$ selon laquelle l'erreur de la prédiction sera mesurée : la fonction qui sera optimisée lors de l'entraînement du modèle est la MSE.
- Le taux d'apprentissage γ_m réduit la contribution de chaque arbre. Il existe un compromis entre le taux d'apprentissage et le nombre d'estimateurs agrégés. Cet hyperparamètre est fixé à 0.1 .
- Le nombre d'estimateurs : où le nombre d'itérations à exécuter. Les G-BT sont assez robustes à l'ajustement excessif, donc un grand nombre donne généralement de meilleures performances. Ce nombre d'estimateurs est fixé à 100.
- La fraction des échantillons à utiliser à chaque itération d'entraînement : pour créer des arbres binaires sensiblement indépendants, l'arbre binaire ajouté à chaque itération pourra être entraîné que sur une partie des données d'entraînement tiré aléatoirement. La valeur par défaut est choisie pour ce premier test (100%).

L'entraînement et le test des modèles :

Lors de l'entraînement des modèles par bandes d'ondes, le lag change d'un modèle à un autre pour convenir aux autocorrélations observées sur chacune des bandes : au niveau des GO, lag égale à 300 points pour inclure l'autocorrélation de 600 points observée sur cette

bande d'ondes. Suivant le même principe, lag égale à 70 points sur les MO et à 25 points sur les PO.

Ainsi, chacun des 6 modèles point par point implémentés est entraîné à estimer trois fonctions par bandes d'ondes :

$$\hat{y}_{GO(i)} = f_{GO}(x_{GO(i-300)} \dots x_{GO(i+300)}) \quad (3.14)$$

$$\hat{y}_{MO(i)} = f_{MO}(x_{MO(i-70)} \dots x_{MO(i+70)}) \quad (3.15)$$

$$\hat{y}_{PO(i)} = f_{PO}(x_{PO(i-25)} \dots x_{PO(i+25)}) \quad (3.16)$$

Il est important de noter que l'ensemble des données de chaque bande d'ondes est divisé en deux sous-ensembles selon le découpage suivant : les premiers 75 % des points de chaque bande d'ondes constituent le jeu d'entraînement et les 25% derniers points composent le jeu de test.

À la fin de l'entraînement, sur chacune des trois bandes d'ondes, les modèles calibrés présentent des performances similaires, avec des MSE et MAE de l'ordre de 0.4 et 0.2 mm pour les GO, 0.2 et 0.1 mm pour les MO, et 0.004 et 0.04 mm pour les PO respectivement.

Après avoir entraîné les six modèles sur les données de chacune des trois bandes d'ondes, la capacité de ces modèles à généraliser leurs prédictions sur les trois bandes d'ondes est évaluée en mesurant la MSE et la MAE sur le jeu de test. Les résultats qui en découlent sont présentés dans le tableau 3.1 et les figures 3.5, 3.6 et 3.7.

	GO		MO		PO	
	MAE (mm)	MSE	MAE (mm)	MSE	MAE (mm)	MSE
RR	2.08	7.97	0.53	0.76	0.14	0.03
RL	2.08	7.97	0.53	0.76	0.14	0.03
KNN	2.24	9.11	0.66	0.89	0.18	0.05
SVR	1.94	7.58	0.53	0.76	0.14	0.03
Forêt aléatoire	2.11	8.08	0.55	0.66	0.14	0.03
G-TB	2.08	7.97	0.54	0.67	0.14	0.03

TABLE 3.1 – Résultat des tests des modèles point par point sur les trois bandes d'ondes.

Analyse des résultats :

Si l'entraînement des modèles point par point permet d'ajuster leurs hyperparamètres de manière à estimer les traces résiduelles post-réhabilitation par bande d'ondes du jeu de

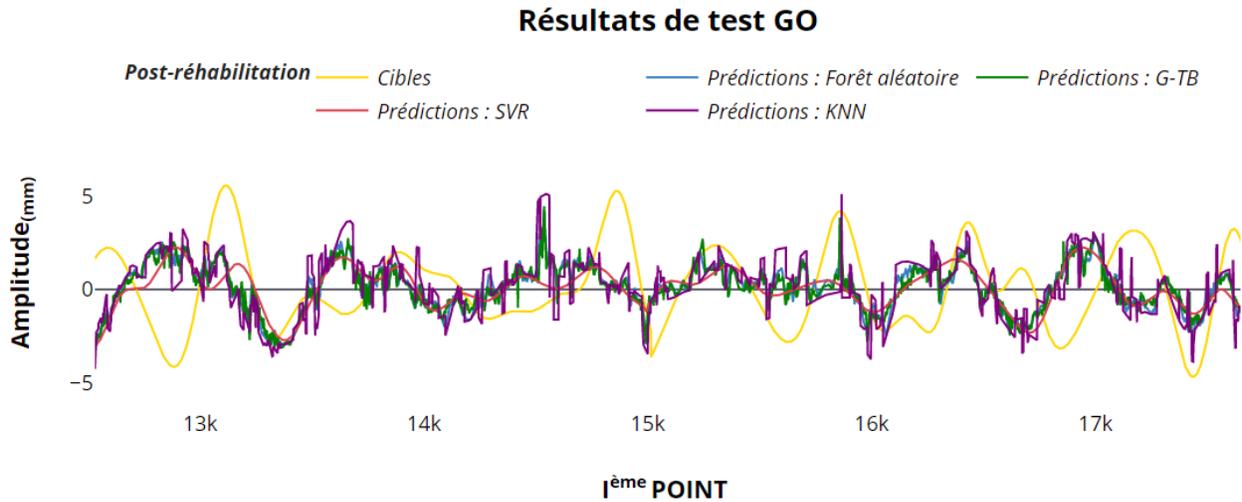


FIGURE 3.5 – Exemple des tests des modèles point par point sur les GO.

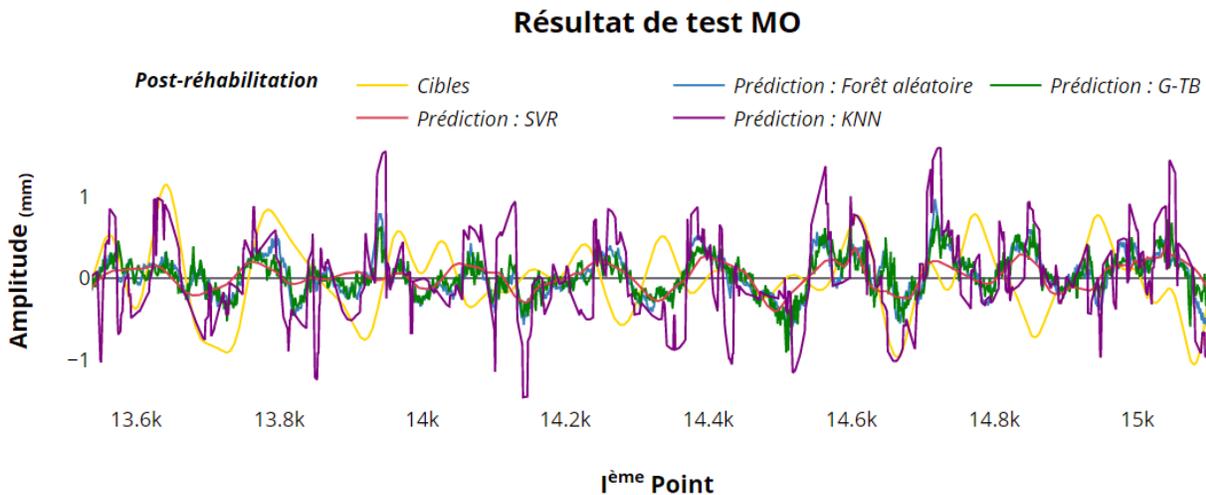


FIGURE 3.6 – Exemple des tests des modèles point par point sur les MO.

données d'entraînement avec des MAE et MSE réduites à zéro, cet entraînement ne donne pas lieu à des modèles capables de généraliser leurs performances sur des nouvelles observations puisque leurs MAE et MSE augmentent considérablement sur le jeu de données de test. Cette dégradation de performance lors des tests peut indiquer un surapprentissage qui provient d'un manque d'adéquation entre la complexité du modèle et le dimensionnement du jeu

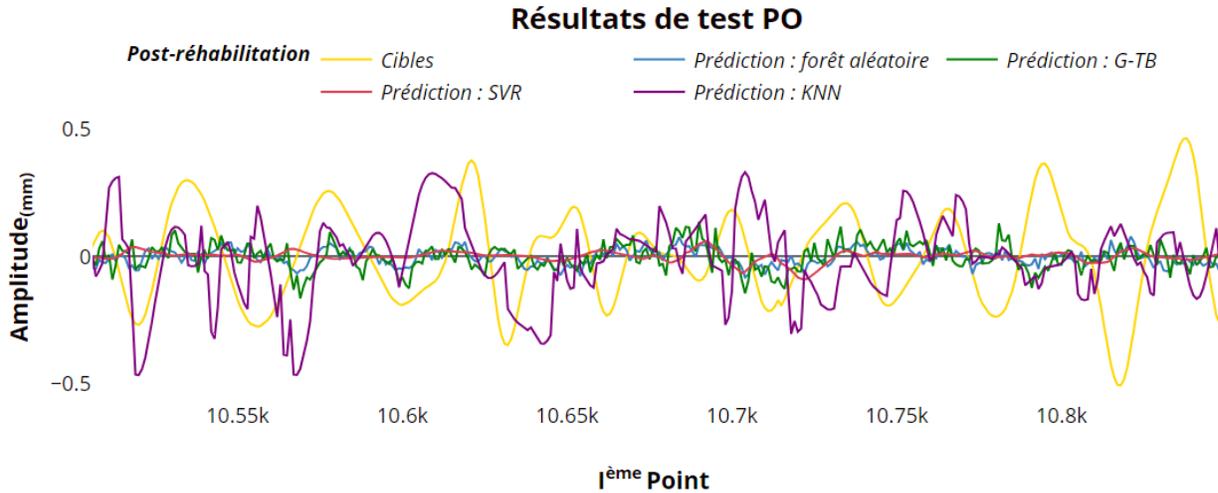


FIGURE 3.7 – Exemple des tests des modèles point par point sur les PO.

de données. La solution algorithmique consiste à réajuster les hyperparamètres afin de simplifier les modèles pour les contraindre à ne pas surajuster les données cibles d’entraînement, et assurer ainsi des performances généralisables : à l’aide de la fonction "GridSearchCV", disponible sur Python, les hyperparamètres nécessaires à l’implémentation des modèles point par point sont optimisés par une recherche validée par croisement sur les grilles d’intervalles possibles. A l’issue de cette recherche, la combinaison des valeurs d’hyperparamètres permettant une optimisation des performances des modèles est déterminée, i.e., celle qui assure les valeurs minimales de MAE et MSE sur les données de test. Or, même en affinant les hyperparamètres des modèles, cette optimisation ne mène à aucune amélioration significative des performances des modèles point par point sur les données de test (au delà d’une différence au niveau du 3^{ème} chiffre après la virgule de la MAE et la MSE). L’incapacité des modèles point par point à généraliser leurs performances ne provient donc pas d’un problème de sur-apprentissage.

Cette dégradation des performances des modèles sur les données de test, par rapport à celles observées sur le jeu d’entraînement, reste similaire par bandes d’ondes indépendamment de la méthode d’apprentissage choisie : sur les GO, la MSE et la MAE sont respectivement de l’ordre de 8 et 2 mm. Sur les MO, les valeurs de MSE et MAE diminuent respectivement à 0.76 et 0.53 mm. Finalement pour les PO, les valeurs de MSE et MAE sont respectivement de l’ordre de 0.3 et 0.14 mm. La similitude des erreurs par bandes d’ondes indépendamment des modèles indique une limite de l’approche point par point pour prédire significativement l’évolution des traces résiduelles par bande d’ondes. En d’autres termes, quelque soit l’affinement de ses hyperparamètres, un modèle qui vise à construire le signal post-réhabilitation point par point ne convergera vers un apprentissage pertinent stable et généralisable sur des

nouvelles données.

Cette limite se manifeste plus clairement sur les figures 3.5, 3.6 et 3.7, où les modèles point par point ne constituent pas le signal post-réhabilitation sur une bande d'ondes en traduisant le mécanisme physique de l'évolution de l'uni, c'est-à-dire en estimant les évolutions individuelles des traces résiduelles pré-réhabilitation, mais se contentent plutôt de générer un signal erratique qui ne respecte pas l'hérédité qui lie les signaux pré- et post-réhabilitation. En continuant l'évaluation de l'apprentissage point par point d'une perspective qualitative, les NBO des signaux post-réhabilitation prédits sur les données de test (notes prédites) seront comparées à celles des signaux post-réhabilitation réels correspondants (notes réelles) : dans un premier temps, et suivant l'algorithme détaillé dans la section 1.1.3, les notes réelles de chaque bande d'ondes sont calculées à partir des valeurs cibles (y_i) de son jeu de données de test. A l'issue de cette première étape, l'ensemble des notes réelles se compose de 5 NGO, 4 NMO et 4 NPO. Ensuite, le même algorithme est appliqué sur les prédictions de chaque modèle (y_{itest}), générées lors de son test sur chacune des trois bandes d'ondes, pour calculer les notes prédites. Les résultats de la comparaison entre les notes prédites et celles réelles ($\Delta N = |N_{prédite} - N_{réelle}|$) sont résumés dans les tableaux 3.2, 3.3 et 3.4 : les erreurs de prédiction des modèles point par point ne peuvent être négligeables puisqu'elles se traduisent par des écarts significatifs entre les notes prédites et celles réelles pouvant atteindre même 3 points. Compte tenu des limites de cette approche à la fois sur le plan quantitatif et sur le plan qualitatif, cette approche ne peut constituer la base d'un modèle de prédiction de l'uni post-réhabilitation.

	ΔN_1 ($0 \leq i \leq 4000$)	ΔN_2 ($4000 \leq i \leq 8000$)	ΔN_3 ($8000 \leq i \leq 12000$)	ΔN_4 ($12000 \leq i \leq 16000$)	ΔN_5 ($16000 \leq i \leq 20000$)
RR	1.25	2.73	3.02	1.35	1.50
RL	1.25	2.73	3.02	1.35	1.50
KNN	1.37	2.51	3.74	1.68	2.08
SVR	0.94	2.64	2.81	1.08	1.25
Forêt aléatoire	1.29	2.64	3.27	1.48	1.72
G-TB	1.26	2.72	3.07	1.37	1.50

TABLE 3.2 – L'écart entre les notes prédites par les modèles point par point et celles réelles sur les données de test dans la bande GO.

3.4.2 L'approche séquence par séquence :

Les modèles qui représentent cette approche parmi ceux détaillés dans la section 1.2.1 sont les réseaux de neurones récurrents, et plus précisément la cellule LSTM (cf. section 1.2.2).

	ΔN_1 ($0 \leq i \leq 2000$)	ΔN_2 ($2000 \leq$ $i \leq 4000$)	ΔN_3 ($4000 \leq$ $i \leq 6000$)	ΔN_4 ($6000 \leq$ $i \leq 8000$)
RR	1.47	3.01	1.50	1.20
RL	1.47	3.01	1.50	1.20
KNN	1.78	3.28	1.94	1.21
SVR	1.42	2.97	1.53	1.20
Forêt aléatoire	1.47	3.2	1.7	1.20
G-TB	1.49	2.93	1.68	1.13

TABLE 3.3 – L'écart entre les notes prédites par les modèles point par point et celles réelles sur les données de test dans la bande MO.

	ΔN_1 ($0 \leq i \leq 400$)	ΔN_2 ($400 \leq i \leq 800$)	ΔN_3 ($800 \leq$ $i \leq 1200$)	ΔN_4 ($1200 \leq i \leq$ 1600)
RR	1.56	3.09	2.52	2.18
RL	1.56	3.09	2.52	2.18
KNN	1.72	3.28	2.64	2.21
SVR	1.51	-3.09	2.53	2.19
Forêt aléatoire	1.53	3.11	2.58	2.20
G-TB	1.53	3.02	2.61	2.25

TABLE 3.4 – L'écart entre les notes prédites par les modèles point par point et celles réelles sur les données de test dans la bande PO.

Dans notre cas, cette cellule apprendra à estimer la fonction f qui associe une séquence du signal filtré post-réhabilitation à celle qui lui correspond du signal pré-réhabilitation filtré, comme l'indique l'équation .

$$(\hat{y}_i)_{k.N \leq i \leq (k+1).N} = f((x_i)_{k.N \leq i \leq (k+1).N}) \quad (3.17)$$

Comme précédemment indiqué les longueurs des séquences unitaires sont : 20 m (400 points) pour les PO, 100 m (2000 points) pour les MO et 200 m (4000 points) pour les GO. Par conséquent, la forme segmentée des données est la suivante :

- Pour les GO : 17 séquences d'entraînement et 5 séquences de test
- Pour les MO : 10 séquences d'entraînement et 4 séquences de test
- Pour les PO : 13 séquences d'entraînement et 4 séquence de test

Ce nombre de séquences peut s'avérer limitatif. En effet, il reste tributaire des données disponibles qui ont pu être épurées au cours de ce travail.

Après avoir détaillé son implémentation dans ce qui suit, La cellule LSTM sera entraînée et testée sur les données des trois bandes d'ondes pour ensuite analyser ses résultats.

L'implémentation des modèles LSTM :

Rappelons que l'idée centrale derrière le développement d'LSTM est de créer une cellule mémoire capable d'identifier la partie pertinente de l'entrée grâce à la porte d'entrée, de la sauvegarder dans l'état à long terme, d'apprendre à la maintenir aussi longtemps que nécessaire grâce à la porte d'oubli et d'apprendre à l'extraire lorsqu'elle est requise. Ceci explique la haute performance de la cellule LSTM dans le traitement des séries temporelles pour détecter les motifs à long-terme. Plus de détails mathématiques sont présentés dans la section 1.2.2.

L'implémentation d'LSTM à l'aide de Tensorflow (une plateforme open source pour l'apprentissage automatique développée par Google et disponible sur Python) nécessite la définition des hyperparamètres suivants :

- La fonction d'erreur à minimiser : l'entraînement des LSTM optimisera la fonction MSE.
- Le nombre d'époques : cet hyperparamètre définit le nombre d'itérations à exécuter lors de l'apprentissage sur l'ensemble des données d'entraînement. Théoriquement, ce nombre varie entre 1 et l'infini. La valeur optimale de cet hyperparamètre est donc affinée en augmentant sa valeur jusqu'à ce que l'erreur de prédiction atteigne sa valeur minimale. Dans notre cas, cet hyperparamètre est défini implicitement suivant la méthode d'arrêt précoce : l'entraînement du modèle entame une nouvelle époque tant que les performances du modèle ne cessent de s'améliorer. Cet apprentissage ne s'arrêtera que si aucune amélioration n'est observée durant les 50 dernières époques .
- Le nombre de neurones : c'est ce concept fondamental qui fait que les réseaux de neurones profond sont qualifiés de "boîte noire", souvent critiqués pour leur manque de transparence et le fait que leurs prédictions ne sont pas traçables. Il n'y a pas de chiffre définitif sur le nombre de neurones ou de couches cachées à utiliser, donc cet hyperparamètre est affiné en fonction de la complexité de chaque problème. Ainsi, le nombre de neurones a été affiné en suivant une approche empirique qui cherche sa valeur optimale en minimisant l'erreur MSE de prédiction des LSTM sur chacune des trois bandes. Cette recherche a été menée à l'aide du programme d'optimisation d'hyperparamètres 'Keras Tuner'. Les résultats de cette recherche montrent que la valeur optimale de cet hyperparamètre est de 1000 neurones pour les GO, 300 neurones pour les MO et 100 neurones pour les PO.

L'entraînement et le test des LSTM :

A l'issu de l'implémentation, trois modèles sont à distinguer : un premier LSTM_{GO} développé pour traiter des séquences de longueur de 4000 points. Il sera entraîné à estimer 17 séquences de traces résiduelles GO post-réhabilitation , pour ensuite évaluer son apprentissage sur 5 autres séquences. Un deuxième LSTM_{MO} e été adapté au traitement des séquences de longueur de 2000 points. Il sera entraîné à prédire 10 séquences de traces résiduelles MO post-réhabilitation, pour ensuite tester son apprentissage sur 4 autres séquences. Finalement

un troisième LSTM_{PO} a été développé pour traiter les séquences de longueur de 400 points. Il sera entraîné à estimer 13 séquences de traces résiduelles PO post-réhabilitation, pour ensuite tester la pertinence de son apprentissage sur 4 autres séquences.

Lors de leurs entraînements, les vitesses de convergence des trois modèles sont différentes : l'entraînement d'LSTM_{GO} s'arrête à la 164^{ème} époque où les valeurs minimales de MSE et de MAE sont respectivement 0.12 et 0.26 mm. Au niveau des MO, la performance de LSTM_{MO} cesse de s'améliorer après la 73^{ème} époque à une MSE minimale de 0.18 et une MAE minimale de 0.35 mm. Quant aux PO, LSTM_{PO} atteint sa performance maximale dès la 30^{ème} époque où les valeurs minimales de MSE et MAE sont respectivement 1.01 et 0.67 mm.

Pour la phase de test, les résultats sont résumés dans les tableaux 3.5, 3.6, 3.7 et illustrés dans les figures 3.8, 3.9 et 3.10.

Séquence N°1		Séquence N°2		Séquence N°3		Séquence N°4		Séquence N°5	
MSE	MAE (mm)								
2.09	0.70	1.94	0.69	1.82	0.70	1.81	0.67	2.10	0.70

TABLE 3.5 – Résultats de test du modèle LSTM sur les GO

Séquence N°1		Séquence N°2		Séquence N°3		Séquence N°4	
MSE	MAE (mm)	MSE	MAE (mm)	MSE	MAE (mm)	MSE	MAE (mm)
0.48	0.59	0.35	0.27	0.5	0.57	0.98	1.7

TABLE 3.6 – Résultats de test du modèle LSTM sur les MO

Séquence N°1		Séquence N°2		Séquence N°3		Séquence N°4	
MSE	MAE (mm)	MSE	MAE (mm)	MSE	MAE (mm)	MSE	MAE (mm)
0.48	0.4	0.62	0.73	0.48	0.35	0.54	0.5

TABLE 3.7 – Résultats de test du modèle LSTM sur les PO

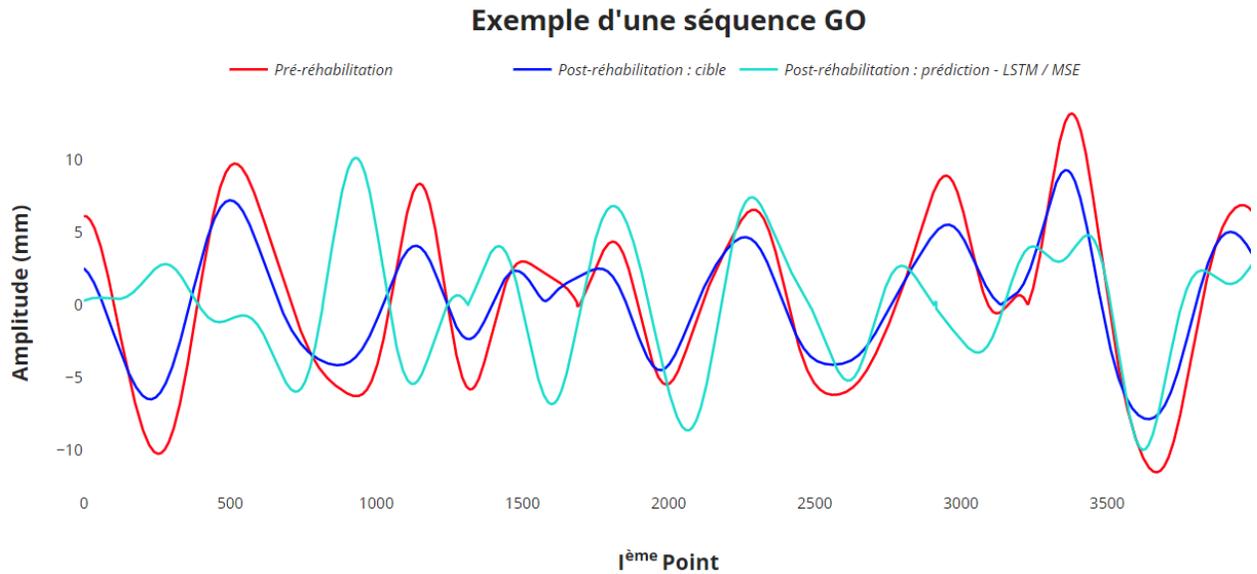


FIGURE 3.8 – Le test du modèle LSTM_{GO} sur une séquence GO.

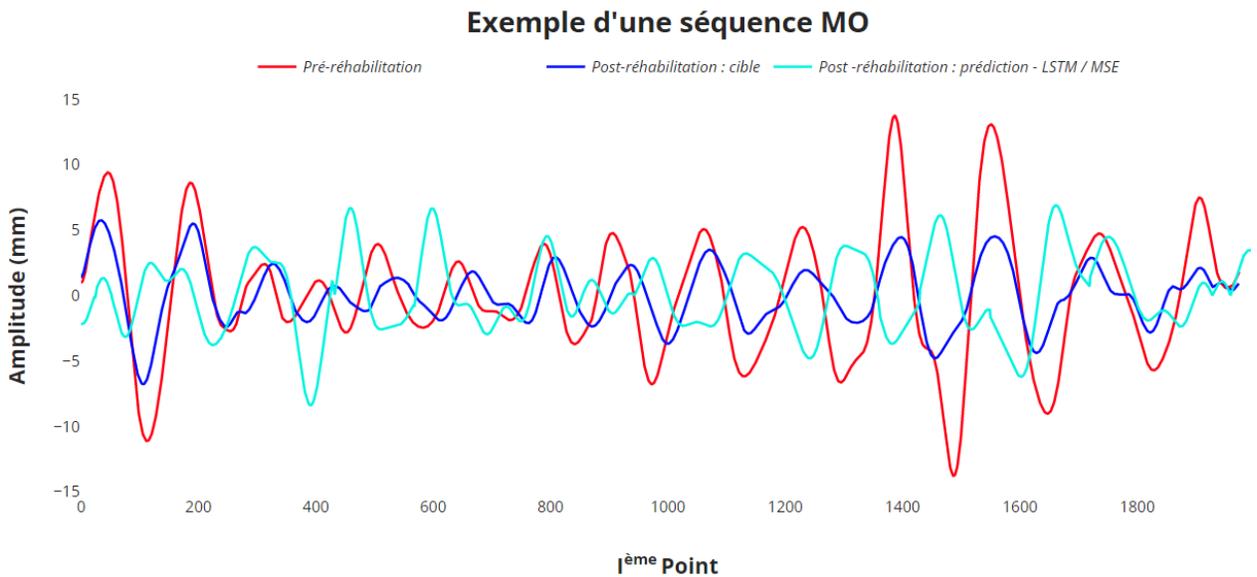
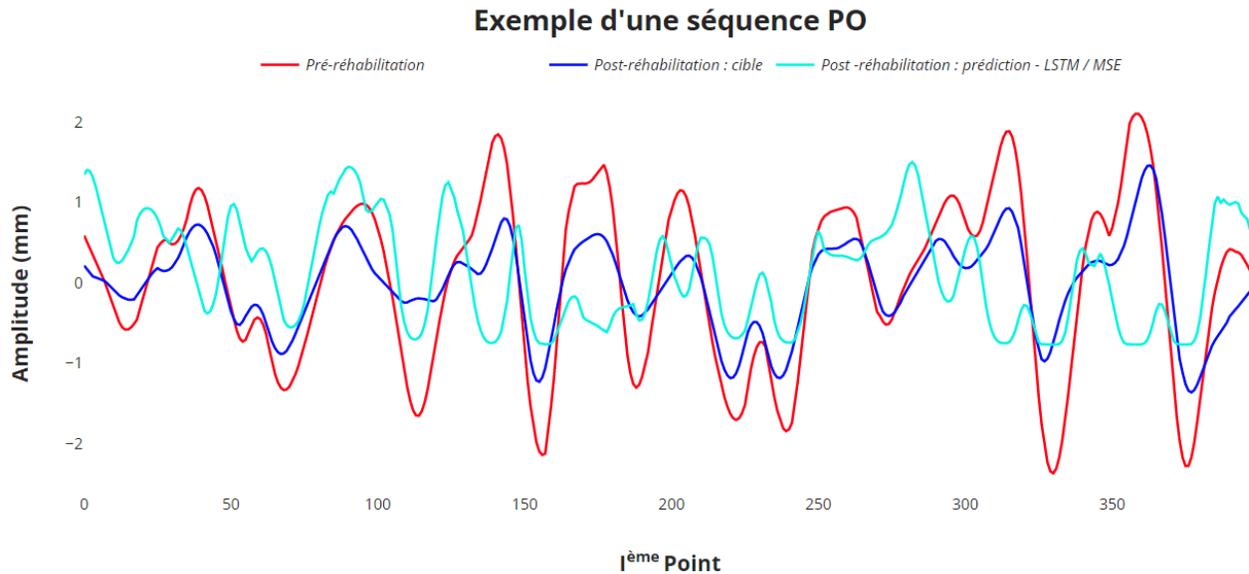


FIGURE 3.9 – Le test du modèle LSTM_{MO} sur une séquence MO.

Analyse des résultats :

Les performances des LSTM sur les données de test des trois bandes d'ondes sont similaires à celles sur les données d'entraînement. Ceci indique que cet entraînement a donné lieu à

FIGURE 3.10 – Le test du modèle $LSTM_{PO}$ sur une séquence PO.

des LSTM capables de généraliser leurs performances sur des nouvelles observations tout en gardant des erreurs de prédictions stables. Toutefois, les valeurs de ces imprécisions ne peuvent être interprétées indépendamment de leurs répercussions sur le post-traitement des séquences prédites, à savoir le calcul des NBO. Il convient donc d'évaluer qualitativement les valeurs MSE et MAE, présentés dans les tableaux 3.5, 3.6 et 3.7 en fonction des erreurs NBO qu'elles traduisent.

Après avoir calculé les NBO des séquences cibles des données de test et celles des séquences prédites, les résultats de leurs comparaisons ($\Delta N = |N_{prédite} - N_{réelle}|$) sont présentés dans les tableaux 3.8 - 3.10 : sur les GO, le modèle $LSTM_{GO}$ entraîné estime les traces résiduelles post-réhabilitation avec une erreur moyenne NGO de 1.01 point. Au niveau des MO, les séquences prédites par le modèle $LSTM_{MO}$ affichent une erreur moyenne NMO de 2.96 points. Quant aux PO, les traces résiduelles post-réhabilitation sont estimées par le modèle $LSTM_{PO}$ avec une erreur moyenne NPO de 2.87 points. Ainsi, l'évaluation qualitative des valeurs MSE et MAE mesurées sur l'ensemble des données de test des trois bandes d'ondes indique qu'elles se traduisent par des écarts NBO importants, pouvant atteindre jusqu'à 3 points sur les bandes MO et PO.

Pour comprendre davantage les performances des modèles LSTM sur les trois bandes, les figures 3.8, 3.9 et 3.10 illustrent des exemples des séquences prédites sur les données test : les modèles LSTM commencent à générer des séquences prédites constituées de blocs (traces résiduelles) similaires à ceux dans les séquences cibles. Cependant, la pertinence de

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4	Séquence N°5
ΔN_{GO}	0.62	1.24	1.4	0.7	1.1

TABLE 3.8 – L'écart entre les notes prédites par LSTM_{GO} et celles réelles sur les données de test.

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4
ΔN_{MO}	2.9	2.3	3.2	3.5

TABLE 3.9 – L'écart entre les notes prédites par LSTM_{MO} et celles réelles sur les données de test.

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4
ΔN_{PO}	2.5	3.2	2.7	3.1

TABLE 3.10 – L'écart entre les notes prédites par LSTM_{PO} et celles réelles sur les données de test.

l'estimation des traces résiduelles change d'une bande d'ondes à l'autre. En effet, les traces résiduelles des séquences GO prédites sont similaires à celles des séquences cibles. Donc, Les erreurs de prédiction du modèle LSTM_{GO} proviennent essentiellement de l'estimation des amplitudes des traces résiduelles prédites. Au niveau des MO et PO, les séquences prédites n'affichent pas les mêmes traces résiduelles présentes dans les séquences cibles, notamment celles de basses amplitudes que les modèles LSTM_{MO} et LSTM_{PO} n'estiment pas mais se contentent plutôt de les remplacer par des oscillations de faibles amplitudes centrées autour de zéro. Cette approche est suffisante pour minimiser la MSE lors de l'entraînement dans le cas où les signaux cibles à estimer sont de faibles amplitudes, comme dans le cas des MO et PO.

3.5 Conclusion

Ce chapitre présente les traitements préparatoires des données avant de procéder à un benchmark des méthodes de modélisation, qui ressortent de l'étude bibliographique de la section 1.2, afin d'analyser leurs capacités à capturer les corrélations spatiales des traces résiduelles dans les signaux filtrés et à les restituer dans l'estimation des évolutions des défauts monolithiques d'uni.

Le processus de pré-traitement se compose de trois étapes où les deux premières sont génériques, tandis que la dernière est spécifique à la stratégie de prédiction adoptée. En effet, la première étape préparatoire améliore la correspondance spatiale entre les mesures pré- et post-réhabilitation

en proposant un ensemble de procédures correctives qui visent, dans un premier temps, à réduire les incohérences de superposition entre les profils mesurés, pour ensuite les nettoyer des données de détérioration qui sont considérées dans notre cas comme non-pertinentes. La deuxième étape du pré-traitement des données est celle du filtrage en bandes d'ondes, où les signaux préparés sont décomposés en trois bandes d'ondes : petites ondes - PO ($0.707 < \lambda(m) < 2.828$), moyennes ondes - MO ($2.828 < \lambda(m) < 11.312$) et grandes ondes - GO ($11.312 < \lambda(m) < 45.248$). Finalement, la troisième étape du pré-traitement est celle de l'organisation des signaux filtrés, où les données sont mises en forme pour convenir à la stratégie adoptée de prédiction des signaux post-réhabilitation filtrés des trois bandes d'ondes. A ce niveau, deux stratégies de prédiction peuvent être distinguées selon l'approche d'apprentissage supervisé choisie : une première qui consiste à construire les signaux post-réhabilitation des trois bandes d'ondes point par point et une deuxième qui le fait séquence par séquence. Ainsi, le choix d'une des deux approches conditionne la mise en forme des données. Toutefois, ce choix doit se faire sur la base d'une analyse comparative des performances des modèles de référence de chacune des deux approches. Par conséquent, il convient d'évaluer la capacité des deux approches (point par point et séquence par séquence) à élaborer un modèle capable de prédire les signaux post-réhabilitation selon les trois bandes, à partir de ceux pré-réhabilitation qui leur correspondent, au sein desquels les corrélations entre les traces résiduelles sont préservées. Pour ce faire, les modèles d'apprentissage supervisé de référence qui suivent ces deux approches ont été évalués selon le même schéma : la première étape est celle d'entraînement où les modèles apprennent à estimer une première partie des données (jeu d'entraînement) en ajustant leurs paramètres internes. La deuxième étape consiste à évaluer la capacité de ces modèles entraînés à généraliser ses prédictions (la stabilité de l'apprentissage) sur la deuxième partie des données (jeu de test). La troisième et dernière étape est celle de l'évaluation qualitative qui consiste à calculer les NBO des séquences prédites et les comparer à celles réelles. Pour ce faire, les modèles d'apprentissage supervisé de référence qui suivent ces deux approches ont été évalués selon le même schéma : la première étape est celle d'entraînement où les modèles apprennent à estimer une première partie des données (jeu d'entraînement) en ajustant leurs paramètres internes. La deuxième étape consiste à évaluer la capacité de ces modèles entraînés à généraliser ses prédictions (la stabilité de l'apprentissage) sur la deuxième partie des données (jeu de test). La troisième et dernière étape est celle de l'évaluation qualitative qui consiste à calculer les NBO des séquences prédites et les comparer à celles réelles.

L'application de ce processus d'évaluation sur les modèles point par point prouve que cette approche ne peut assurer apprentissage stable ou significatif de l'évolution d'uni : même si ces modèles arrivent à afficher des erreurs nulles à l'issue de leurs entraînements, leurs performances se dégradent sur les données test en générant des signaux erratiques qui ne respectent pas l'hérédité liant les signaux pré- et post-réhabilitation. Ceci se traduit en termes de NBO par des écart significatifs entre les notes prédites et celles réelles qui atteignent un écart de 3 points sur les trois bandes d'ondes. Quant à l'approche de prédiction séquence par séquence, l'évaluation des modèles LSTM entraînés indique que leurs performances sont plus stables

(par rapport aux modèles point par point) sur les données test, avec des erreurs de prédictions en termes de MAE qui sont de l'ordre de 0.7 mm sur les GO, de 0.78 mm sur les MO et de 0.5 mm sur les PO. Certes, ces erreurs se traduisent par des écarts entre les notes des séquences prédites et celles des séquences réelles pouvant atteindre 3 points sur les MO et les PO. Or, l'analyse graphique des séquences prédites indique que les modèles LSTM commencent à générer des séquences prédites constituées d'une succession de traces résiduelles similaires à celles dans les séquences réelles, notamment sur les GO. Par conséquent, les modèles LSTM sont ceux qui démontrent un potentiel à reconstituer les signaux post-réhabilitation en suivant le mécanisme d'évolution physique d'évolution de l'uni, à savoir former les séquences prédites en estimant successivement l'évolution des traces résiduelles pré-réhabilitation. Ainsi, la prédiction des traces résiduelles post-réhabilitation séquence par séquence est l'approche retenue dans le reste de ce document. Toutefois, les performances doivent être améliorées au niveau des MO et PO, où l'apprentissage en minimisant la MSE ne donne pas lieu à des modèles LSTM capables d'identifier le découpage des traces résiduelles pré-réhabilitation, dans les signaux d'entrée d'aussi faibles amplitudes, pour ensuite estimer leurs évolutions et les retraduire dans les séquences prédites.

Le confrontation de ces schémas prouve donc que l'approche séquence par séquence est celle qui démontre un potentiel à reconstituer les signaux post-réhabilitation en suivant le mécanisme d'évolution physique d'évolution de l'uni, à savoir former les séquences prédites en estimant successivement l'évolution des traces résiduelles pré-réhabilitation. Ainsi, cette approche est celle choisie pour le développement du modèle de prédiction dans le reste de ce document.

Chapitre 4

Développement et implémentation d'un modèle U-RC-NET pour la prédiction de l'uni

Si les modèles LSTM présentent des performances qui restent perfectibles, notamment sur les MO et PO, cette cellule de réseaux récurrents recèle un potentiel à retraduire le mode d'évolution de l'uni, car elle génère des séquences prédites avec le même découpage en traces résiduelles que leurs séquences cibles.

Ainsi, nous proposons dans ce chapitre une nouvelle modélisation qui combine la cellule LSTM avec un encodeur et un décodeur pour former l'U-RC-NET. En effet, trois étapes principales organisent le modèle développé : tout d'abord, un processus de contraction est appliqué aux séquences d'entrée dans un encodeur, qui vise à réduire leurs informations spatiales tout en augmentant leurs caractéristiques extraites. Ensuite, la cellule LSTM opère sur le signal contracté et produit le noyau de la prédiction. Enfin, le signal prédit complet est généré en augmentant successivement la résolution de la prédiction LSTM dans un décodeur. L'évaluation des performances d'U-RC-Net sur les trois bandes d'ondes suivra le même processus décrit dans le chapitre précédant : la première étape consiste à affiner les paramètres du modèle U-RC-Net afin d'ajuster ses prédictions aux séquences post-réhabilitation cibles d'entraînement de chaque bandes d'ondes. Contrairement aux modèles précédents, la qualité d'ajustement d'U-RC-Net sera évaluée selon la fonction Soft-DTW qui mesure la distance (ressemblance) entre deux séries temporelles. Ainsi, l'entraînement d'U-RC-NET consiste à minimiser la distance Soft-DTW entre les séquences prédites et celles cibles de l'ensemble des données d'entraînement. La deuxième étape consiste à évaluer la capacité du modèle U-RC-NET à généraliser sa performance sur les données de l'ensemble de test, toujours selon la même fonction Soft-DTW. La troisième et dernière étape est celle où les performances d'U-RC-Net sur les données sont évaluées qualitativement en comparant les NBO des séquences prédites avec celles des séquences cibles.

Dans ce qui suit, après avoir détaillé l'architecture d'U-RC-Net, l'implémentation de ce

modèle avec la fonction d'erreur Soft-DTW sera décrite, pour finalement analyser les résultats de son test sur l'estimation des traces résiduelles post-réhabilitation des trois bandes d'ondes.

4.1 U-RC-NET : l'architecture hybride

L'une des conditions cruciales à remplir pour prédire pertinemment le profil post-réhabilitation est la segmentation de sa structure : le profil mesuré d'une chaussée est une succession d'irrégularités géométriques qui agissent comme des blocs monolithiques. A l'échelle des bandes d'ondes, ceci se traduit par une corrélation entre les signaux filtrés qui s'établit au niveau des traces résiduelles pré- et post-réhabilitation. Par conséquent, prédire l'amélioration de l'uni de la chaussée équivaut à estimer l'atténuation des traces résiduelles préexistantes en fonction de leurs formes (leurs étendues et leurs amplitudes) sur chacune de ses trois bandes d'ondes. Ainsi, le modèle recherché doit être capable de transmettre cette corrélation qui rend les signaux filtrés des entités monolithiques sur les longueurs des traces résiduelles identifiées. Cette corrélation introduit de facto une convolution entre les nuages de points, partageant les mêmes caractéristiques, pour décrire les traces résiduelles dans les séquences traitées. Le repérage des traces résiduelles revient donc à identifier l'ensemble des caractéristiques communes dans les nuages de points qui définissent ces blocs monolithiques.

Pour ce faire, une couche de convolution propose une solution à ce problème de segmentation. En effet, cette couche sert à repérer la présence d'un ensemble de caractéristiques (*features*) dans les signaux d'entrée en réalisant un filtrage glissé par convolution : le principe est de faire glisser une fenêtre de filtrage sur le signal, et de calculer le produit de convolution entre les poids du filtrage et chaque portion du signal traitée. Donc, cette couche calcule la convolution de chacune de ses entrées avec une multitude de filtres qui sont censés correspondre aux caractéristiques à identifier.

Pour cela, les caractéristiques utiles à la segmentation des séquences ne sont pas explicitement pré-définies, mais apprises par le réseau lors de la phase d'entraînement : les noyaux des filtres désignent les poids de la couche de convolution. Ils sont initialisés puis mis à jour par rétropropagation du gradient lors de l'entraînement du réseau. Ainsi, l'avantage majeur des couches de convolution est leur capacité à déterminer toute seules les caractéristiques discriminantes dans une séquence. A la sortie de cette couche, et pour chacun de ses filtres, une carte d'activation est obtenue indiquant les localisations d'une caractéristique dans la séquence : plus la valeur est élevée, plus le point correspondant dans la séquence comporte la caractéristique recherchée.

Compte tenu de ce qui précède, le modèle proposé dans ce chapitre combine des couches de convolution avec la cellule LSTM pour former un réseau de neurones récurrent de convolution (Recurrent Convolutional Neural Network - RCNN) : d'une part, la partie convolutive sert à extraire les caractéristiques des séquences d'entrée pour identifier leurs segmentations adéquates en traces résiduelles. D'autre part, La cellule LSTM traite les traces résiduelles pré-réhabilitation identifiées et leurs caractéristiques extraites pour estimer leur évolution

suite à la réhabilitation.

Les RCNNs sont généralement utilisés dans le traitement des séries temporelles pour apprendre le mappage des caractéristiques d'une suite récurrente de séquences de séries temporelles. Ce fonctionnement est particulièrement performant dans les problèmes de classification où la sortie se base sur les vecteurs des caractéristiques extraites pour produire des étiquettes de classification. Cependant, et dans notre cas de régression de séries temporelles, le modèle doit non seulement convertir les séquences d'entrée en vecteurs de caractéristiques, mais aussi reconstruire une séquence à partir de ce vecteur. En d'autres termes, l'architecture du modèle RCNN recherchée doit non seulement extraire les caractéristiques des traces résiduelles pré-réhabilitation dans la séquence d'entrée pour estimer leurs évolutions, mais aussi garder leurs localisations pour les transmettre à la reconstruction des séquences de sortie. Cette problématique est en effet similaire à celle de la segmentation sémantique dans le domaine de vision par ordinateur : aussi appelée classification basée sur les pixels ou bien prédiction dense, la segmentation sémantique consiste à classer chacun des pixels de l'image d'entrée selon une classe précise. Ainsi, les résultats attendus ne sont pas des étiquettes de classification, mais plutôt une image à haute résolution où chaque pixel appartient à une des classes prédéfinies. Ainsi, la segmentation sémantique est appliquée dans plusieurs cas d'usage comme dans les voitures autonomes, pour détecter les bords de la route ainsi que les panneaux de signalisation routière, dans la cartographie par satellites, pour détecter les bâtiments et les routes à partir des images, où même la segmentation des images médicales pour détecter des anomalies ou des tumeurs. Plusieurs architectures ont contribué significativement au domaine de la vision par ordinateur, et qui ont donc constitué la base pour le développement de la segmentation sémantique, comme AlexNet, ResNet, VGG-16, GoogLeNet et notamment le U-Net qui est particulièrement intéressant dans notre cas : en 2015, Ronneberger et al. ont introduit un réseau de convolution en forme de U pour la segmentation sémantique des images biomédicales [152]. Des performances élevées peuvent être atteintes même si ce modèle est entraîné sur très peu de données grâce à son architecture simple qui se résume en trois blocs : un premier chemin de contraction qui se base sur deux couches de convolution et de sous-échantillonnage (Maxpooling) pour capturer les caractéristiques de l'image d'entrée. Le deuxième bloc, appelé le pont, assure la liaison entre le chemin de contraction et celui d'expansion et se compose de deux couches de convolution. Le troisième et dernier bloc est le chemin d'expansion qui sur-échantillonne les cartes de caractéristiques extraites pour augmenter successivement la résolution de l'image de la sortie, où chaque pixel est représenté par une couleur qui indique sa classe. L'architecture d'U-Net a été particulièrement inspirante et peut être considérée comme la base du développement de l'architecture du modèle U-RC-NET détaillée dans ce qui suit.

Dans cette thèse, nous proposons une forme modifiée de l'architecture U-Net (cf. Figure 4.1) en adaptant son chemin de contraction et d'expansion pour traiter les séries temporelles tout en remplaçant le pont convolutif par une cellule LSTM. Les idées principales derrière ces 3 blocs sont :

- L'encodeur ou le bloc de contraction : simplifie la séquence d'entrée par un sous-

échantillonnage successif précédé d'une augmentation des caractéristiques extraites à chaque couche de convolution. Ces dernières seront partiellement stockées. Ainsi, cet encodeur simplifie graduellement la séquence d'entrée et extrait les caractéristiques de ses traces résiduelles pré-réhabilitation sous différentes résolutions spatiales.

- Le pont sous forme d'une cellule LSTM : alimentée par la sortie de la dernière couche de l'encodeur, la cellule LSTM se focalise particulièrement sur les traces résiduelles prédominantes (qui persistent même après la série de sous-échantillonnages) pour estimer leurs évolutions en se basant sur leurs cartes de caractéristiques. Cette cellule génère ainsi le noyau de la séquence prédite post-réhabilitation.
- Le décodeur ou le bloc d'expansion : la cellule LSTM est complétée par un bloc d'expansion qui augmente graduellement la résolution spatiale de la prédiction. En effet, et à chaque couche du décodeur, un niveau de détails supplémentaire est ajouté en combinant un sur-échantillonnage de la sortie de sa précédente avec une concaténation des caractéristiques à haute résolution provenant de l'encodeur. (c'est pourquoi elles ont été décrites précédemment comme étant "partiellement" stockées).

Les compositions des trois blocs de cette architecture sont détaillées dans les sections suivantes.

4.1.1 L'encodeur

L'objectif de ce premier bloc est d'extraire les caractéristiques des traces résiduelles pré-réhabilitation présentes dans la séquence d'entrée sous différents niveaux de résolution. Pour ce faire, l'encodeur se base sur deux types de couches : une première couche de convolution pour extraire les cartes de caractéristiques et une deuxième couche de maxpooling qui sous-échantillonne son entrée pour diminuer sa résolution spatiale. Ces deux types de couches sont arrangés selon une architecture typique d'un CNN : l'empilement répété d'une couche de convolution suivie par une autre de maxpooling. Dans une telle configuration, les cartes de caractéristiques rétrécissent au fur et à mesure à cause des pas de convolution de maxpooling. Par conséquent, les couches de convolution sont configurées de façon à augmenter progressivement le nombre de leurs cartes de caractéristiques pour compenser leur rétrécissement [15]. Ainsi, L'encodeur proposé se compose de 3 niveaux où chacun représente un empilement d'une couche de convolution suivie par une couche de maxpooling. Dans ce qui suit, le fonctionnement de ces deux types de couches est détaillé.

Les couches de convolution

Dans une couche de convolution, une fenêtre de filtrage (appelée aussi le noyau de convolution) parcourt la séquence d'entrée pour calculer le produit de convolution entre ses poids et chaque segment de la séquence traitée [153, 154]. Dans une succession de couches de convolution, comme dans le cas de l'encodeur, un neurone d'une couche n'est connecté qu'à ceux situés à l'intérieur du segment convolué de sa précédente [15]. Cette architecture permet donc

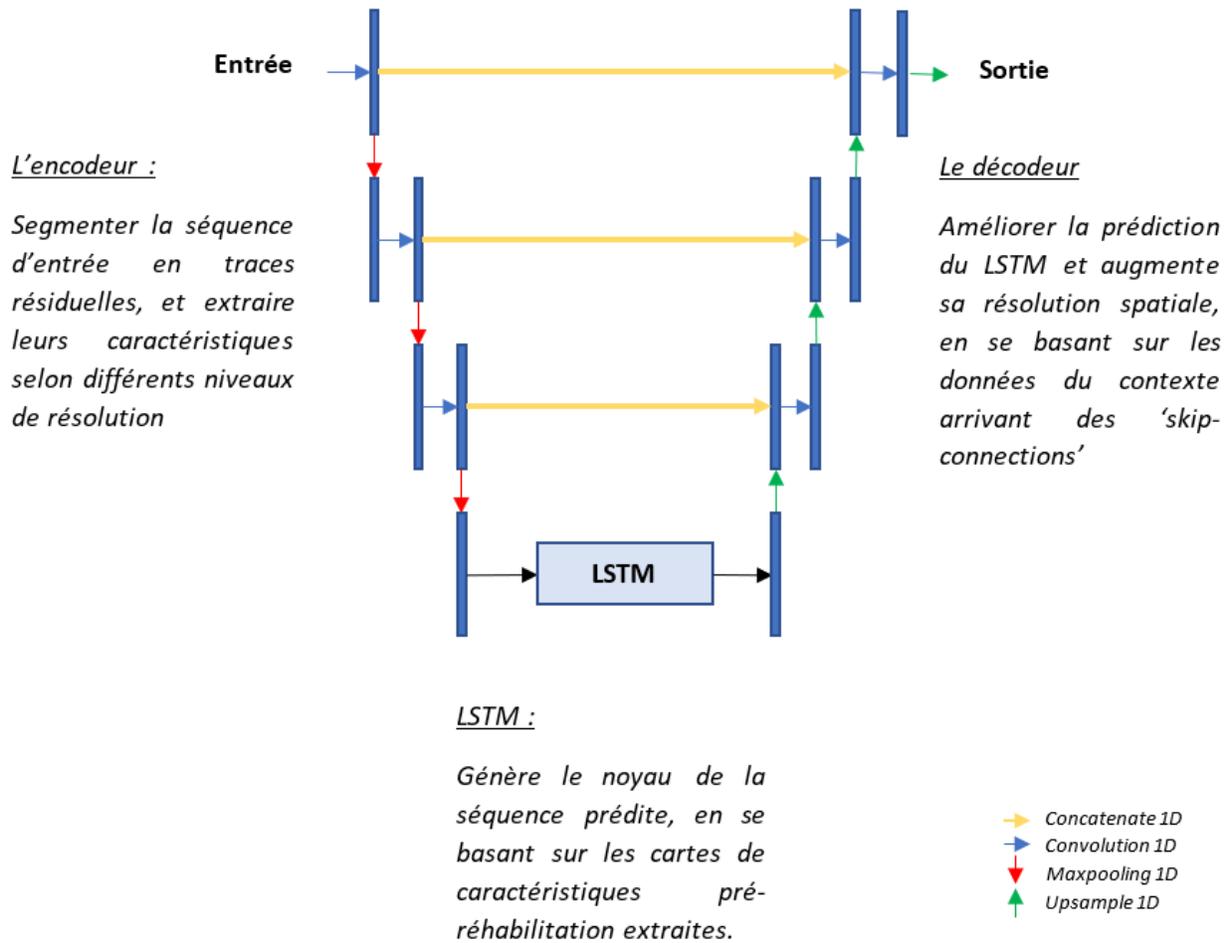


FIGURE 4.1 – Illustration de l'architecture d'U-RC-NET développée.

au réseau de mettre en évidence les caractéristiques de bas niveau dans la première couche, pour les assembler en caractéristiques de haut niveau dans la couche suivante. Par conséquent, l'encodeur peut extraire les caractéristiques significatives des traces résiduelles présentes dans les séquences d'entrée sous différentes résolutions grâce à cette structure hiérarchique. Ainsi, l'entraînement de l'encodeur consiste à trouver les poids des filtres qui seront les plus utiles à la segmentation des séquences en traces résiduelles et à l'extraction de leurs caractéristiques déterminantes sur chaque niveau de résolution.

Il convient de noter que lors du passage d'un niveau à l'autre de l'encodeur, le nombre de canaux de caractéristiques est doublé afin de produire une carte de caractéristiques dont la profondeur est deux fois plus grande que celle de son prédécesseur, qui sera partiellement stockée (voir ci-après).

Le dimensionnement d'une couche de convolution passe par la définition de quatre hyperparamètres [155]. Leurs définitions sont présentées ci-dessous, ainsi que leurs valeurs optimales obtenues après une analyse paramétrique que nous avons menée :

- La profondeur de la couche : désigne le nombre de filtres appliqués pour construire les cartes de caractéristiques extraites. Cet hyperparamètre commence à 16 pour la première couche pour se multiplier par deux d'un niveau à son suivant.
- La taille du noyau de convolution : spécifie la longueur de la fenêtre de convolution qui parcourt les données d'entrée. Cet hyperparamètre est fixé à 2 points pour toutes les couches de convolution du réseau.
- Le pas du noyau de la convolution : détermine le pas de chevauchement de la fenêtre de convolution pour parcourir les données d'entrée. Ainsi, plus le pas est petit, plus les fenêtres se chevauchent et plus la taille des cartes de caractéristiques extraites sera grande. Cet hyperparamètre est fixé à 2 points pour toutes les couches de convolution du réseau.
- Le type de remplissage (*Padding*) : l'application répéter des couches de convolution mène à un rétrécissement des cartes de caractéristiques extraites le long du réseau. Cependant, il est souhaitable parfois de conserver la même taille des cartes. Pour cela, une marge de zéros peut être ajoutée à la frontière des entrées : zero-padding. La taille de cette marge est le quatrième hyperparamètre à spécifier.

Dans la couche de convolution, lors de l'extraction de la carte des caractéristiques, un ensemble restreint de points est considéré pour réduire la séquence d'entrée originale (grâce à l'hyperparamètre *stride*). Cependant, ces cartes extraites enregistrent la position exacte des caractéristiques dans la séquence d'entrée, ce qui les rend très sensibles à la position spatiale des caractéristiques dans la séquence d'entrée. En d'autres termes, tout déplacement relativement faible de la position de l'élément dans la séquence d'entrée peut conduire à une carte de caractéristiques extraite différente. Pour y remédier, une couche de maxpooling suivra celle de convolution pour réduire davantage l'échantillonnage des cartes caractéristiques extraites.

Les couches de maxpooling :

Les couches de maxpooling sont celles qui réduisent la résolution de leurs entrées (cartes de caractéristiques) en les sous-échantillonnant à travers une fenêtre glissante. En outre, ce sous-échantillonnage réduit la charge de calcul, l'utilisation de la mémoire et le nombre de paramètre, limitant ainsi le risque de sur-ajustement.

A l'image des couches de convolution, chaque neurone de la couche de maxpooling n'est connecté qu'aux sorties des neurones de la couche précédente situés à l'intérieur de la fenêtre glissante. Par contre, les neurones de cette couche ne possèdent aucun poids mais se contentent d'agréger les entrées en fonction de leurs valeurs maximales.

L'implémentation de cette couche nécessite la définition de trois hyperparamètres similaires à ceux des couches de convolution, à savoir la taille du noyau de maxpooling (fixée à 2 points), son pas (égale à 2 points), et le type de remplissage.

4.1.2 Le pont LSTM

A la fin de l'encodeur, les séquences d'entrée sont simplifiées pour atteindre leurs résolutions spatiales les plus réduites avec un nombre maximal de caractéristiques extraites. Sur ces séquences rétrécies, seules les formes prédominantes des traces résiduelles persistent après les séries de convolution et maxpooling. Alimentées par ces séquences réduites, LSTM se focalise donc sur les formes prédominantes des traces résiduelles pré-existantes et estime leurs évolutions en se basant sur leurs caractéristiques extraites dans les différentes cartes. En d'autres termes, la cellule LSTM opère sur la forme abrégée de la carte des caractéristiques de pré-réhabilitation en exploitant ses dépendances longues et courtes pour prédire son évolution après la réhabilitation, produisant ainsi une carte abrégée des caractéristiques de post-réhabilitation. Cette cellule LSTM génère ainsi le noyau de la séquence prédite post-réhabilitation qui sera ensuite améliorée par le décodeur.

L'implémentation de la cellule LSTM et son fonctionnement ont été déjà détaillés dans les sections 1.2.2 et 3.4.2.

4.1.3 Le décodeur

Pour assurer la transition d'une carte de caractéristiques à une séquence, similaire à l'entrée, un chemin expansif est mis en œuvre. Son rôle principal est de réorganiser les caractéristiques principales de la carte produite par la LSTM en une séquence en augmentant progressivement sa résolution spatiale. Pour ce faire, le chemin expansif suit une architecture symétrique à trois niveaux par rapport au chemin contractant, mais avec des fonctions opposées : application répétée d'un sur-échantillonnage (couche de convolution transposée 1D) suivie d'une convolution (couche de convolution 1D sans réduction de la résolution spatiale). En fait, à chaque niveau, la résolution spatiale de la carte de caractéristiques d'entrée est quadruplée dans la couche de sur-échantillonnage (sauf la première et la dernière couche, où la résolution est doublée), afin de fournir une carte de caractéristiques de sortie dont la taille spatiale est quatre fois plus grande que celle de sa prédécesseur. En détail, la méthode de suréchantillonnage utilisée ici est la convolution transposée (ConvTranspose 1D), mise en œuvre avec Pytorch, où l'association entre l'entrée et la sortie est traitée dans le sens inverse par rapport à une convolution standard (association un-à-plusieurs plutôt que plusieurs-à-un). En tant que telle, la convolution peut être émulée en utilisant la convolution transposée. En d'autres termes, l'entrée est complétée (ajout de nouveaux éléments) de sorte que la convolution directe produise le même effet que la convolution transposée. Cette couche peut donc être considérée comme le gradient de la couche de convolution 1D par rapport à son entrée. Dans cette étude, la couche de convolution transposée est utilisée comme un outil de sur-échantillonnage "intelligent", où les poids de l'opérateur peuvent être appris, sans qu'il soit nécessaire de prédéfinir une méthode d'interpolation. Les détails techniques de cette couche peuvent être trouvés dans la documentation de Pytorch [156] .

L'utilisation de convolutions transposées dans ce décodeur provient du besoin d'utiliser une

transformation allant dans la direction opposée d'une convolution normale, c'est-à-dire, de quelque chose qui a la forme de la sortie d'une certaine convolution à quelque chose qui a la forme de son entrée tout en maintenant un modèle de connectivité compatible avec celui de la convolution [157]. L'opération de base d'une convolution transposée est illustrée par l'exemple dans la figure 4.2 [16] : la convolution transposée d'une séquence d'entrée de 2 points par un noyau de filtre de 3 points avec un pas de 2 points génère une séquence de sortie de 5 valeurs. Cette séquence est obtenue en copiant chaque valeur d'entrée pondérée par le filtre pour ensuite additionner les chevauchements. L'entraînement de cette couche de convolution transposée consiste à mettre à jour les poids des filtres adéquats pour le sur-échantillonnage.

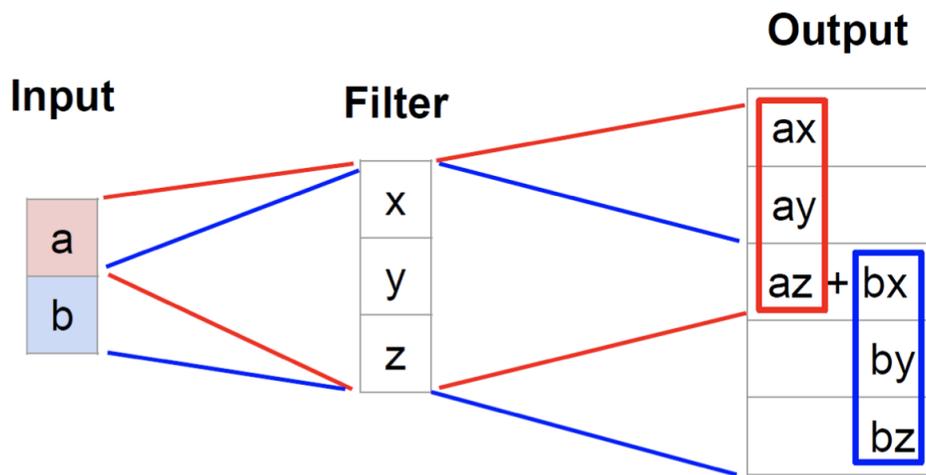


FIGURE 4.2 – Illustration d'une convolution transposée [16].

À la sortie de la couche de convolution transposée, la carte des caractéristiques gagne en résolution spatiale grâce à son sur-échantillonnage qui ajoute plus de granularité (détails / fluctuations) aux tendances post-réhabilitation significatives à chaque niveau du chemin expansif. Ces détails à plus haute résolution sont considérés comme une évolution des caractéristiques de pré-réhabilitation des fluctuations qui ont été rejetées pendant le maxpooling dans la trajectoire de contraction. Ils doivent donc être insérés dans la carte des caractéristiques à leur position spatiale appropriée. À cette fin, à chaque niveau de l'expansion, la carte de caractéristiques à échantillonnage croissant (sortie de la couche de convolution transposée) est concaténée avec la carte de caractéristiques de pré-réhabilitation correspondante provenant du même niveau de résolution de l'encodeur (c'est pourquoi elle a été décrite plus tôt comme étant "partiellement" stockée). Cette concaténation est rendue possible par des "skip-connections" qui permettent au réseau de propager plus de contexte spatial (les caractéristiques d'encodeur au décodeur). Afin de faire correspondre la position spatiale des caractéristiques sur-échantillonnées avec les caractéristiques correspondantes avant

la réhabilitation, la carte concaténée est ensuite convoluée dans la couche de convolution suivante pour fusionner ses caractéristiques, tout en réduisant de moitié ses canaux de caractéristiques (profondeur). À la fin du chemin expansif, le même niveau de résolution de l'entrée est retrouvé. Par conséquent, la séquence de sortie du modèle est calculée en estimant l'évolution des défauts monolithiques de l'entrée de pré-réhabilitation sous les différentes résolutions nécessaires à la prédiction de l'uni.

L'implémentation de la couche de convolution transposée nécessite la définition de trois hyperparamètres :

- La profondeur de la couche : détermine le nombre des cartes de caractéristiques à la sortie de la couche.
- Le noyau de la convolution transposée : identifier les caractéristiques du filtre selon lequel la séquence d'entrée sera sur-échantillonnée. Les études paramétriques que nous avons mené ont montré que la taille optimale est de 8 points, avec un chevauchement de 2 points des valeurs pondérées lors du sur-échantillonnage. Comme dans toutes les couches de convolution et de maxpooling dans le réseau, cet hyperparamètre est fixé à 2 points.
- Le type de remplissage : cet hyperparamètre permet de contrôler la taille des données de sorties en rajoutant des marges de zéros à la frontière des données d'entrée.

4.2 Métriques d'apprentissage et d'évaluation :

Rappelons que le processus suivi pour l'évaluation des performances des modèles sur les trois bandes d'ondes se compose de trois étapes : on entraîne le modèle sur un premier jeu de données pour qu'il affine ses paramètres, ensuite on le teste sur un deuxième jeu de données pour évaluer ses capacités de généralisation sur des nouvelles observations. Ce schéma classique assure un apprentissage basé sur une approche purement quantitative : indépendamment du sens physique que la série temporelle à prédire, l'entraînement et le test du modèle sont liés à une fonction d'erreur (MSE dans le cas des sections 3.4.1 et 3.4.2) de manière que la meilleure prédiction est celle qui minimise cette fonction. L'approche qualitative (évaluation) n'intervient qu'à la troisième étape où la pertinence des prédictions, comme des séquences représentant les traces résiduelles post-réhabilitation, est évaluée en calculant leurs NBO. L'implémentation de l'U-RC-NET suivra le même schéma, mais avec un éventail plus large de métriques pour permettre une prise en compte de l'approche quantitative à un stade plus précoce, ainsi qu'une évaluation plus détaillée de son apprentissage et de ses tests. Nous présentons donc dans ce qui suit les métriques d'apprentissage du modèle (fonctions coût à minimiser lors de son entraînement) ainsi que celles exploitées lors de la phase de son évaluation après apprentissage.

4.2.1 Métriques d'apprentissage :

Pour entraîner et évaluer les performances des RNA dans le domaine d'analyse des séries temporelles, les fonctions d'erreur classiques sont les MSE, MAE et leurs variantes [17]. Cependant, le recours à ces fonctions conventionnelles peut s'avérer inadéquat dans notre contexte : le modèle recherché est celui qui construit la séquence prédite en suivant le mode d'évolution physique de l'uni, à savoir constituer la prédiction en estimant les évolutions de chacune des traces résiduelles pré-réhabilitation. Ainsi, l'estimation des séquences du profil post-réhabilitation est un problème de prédiction basé sur la forme. Or, malgré leurs convergences lors de l'entraînement, l'évaluation des performances des modèles précédents démontrent que ces derniers n'arrivent pas à retraduire les modes d'évolution physiques de l'uni mais se contentent de générer un signal suffisamment erratique pour minimiser les MSE et MAE, notamment au niveau des MO et GO. Cette limite des fonction classique a été démontrée aussi par Guen et Thome [17] dans leur article publié en 2019, où ils présentent trois prédictions significativement différentes d'une fonction échelon comme cible, mais avec la même erreur MSE comme illustré dans la figure 4.3 : la prédiction (a) n'est pas significative puisqu'elle n'a pas capté la forte chute à venir. Les prédictions (b) et (c) reflètent beaucoup mieux le changement de régime puisque la chute brutale est effectivement anticipée, bien qu'avec un léger retard (b) ou avec une légère imprécision de l'amplitude (c). Malgré les grandes différences entre ces trois prédictions, leurs comparaisons avec la fonction échelon cible affichent la même valeur MSE de 8.

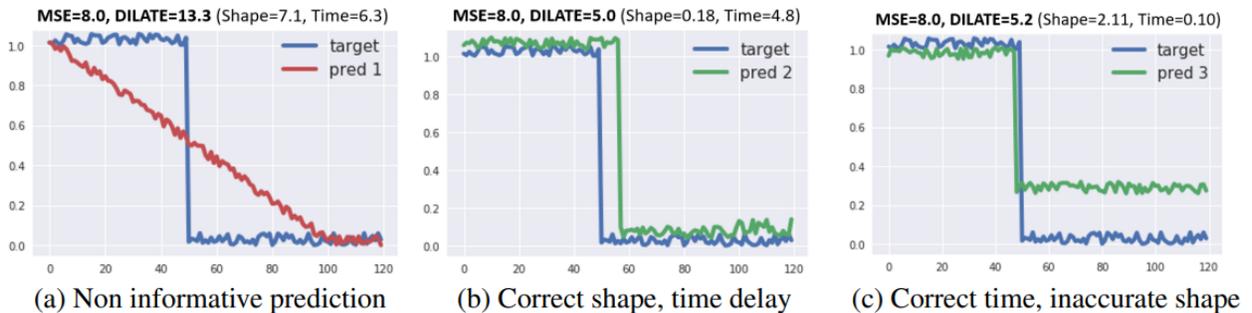


FIGURE 4.3 – Limite de la MSE dans le cas d'une problématique de prédiction basée sur la forme [17].

Il existe d'autres métriques prenant en compte la forme et la localisation temporelle (ou spatiale) des séries temporelles lors de leurs prédictions, comme la Dynamic Time Warping (DTW). Le paradigme DTW est basé sur une géométrie simple où le meilleur alignement possible entre deux séries temporelles de longueurs respectives n et m , est défini en calculant d'abord la matrice de distance entre ces $n \times m$ paires de points pour résoudre ensuite un programme dynamique utilisant la récursion de Bellman avec un coût quadratique de l'ordre de $n \times m$. La fonction coût de cet alignement optimal peut être

formulée mathématiquement comme suit [158] : Soit $X = \langle x_1 \dots x_n \rangle$ et $Y = \langle y_1 \dots y_m \rangle$ deux séquences et soit δ une mesure de distance entre les séquences. Le coût $D(X_i, Y_j)$ de l'alignement optimal des deux sous-séquences $X_i = \langle x_1 \dots x_i \rangle$ et $Y_j = \langle y_1 \dots y_j \rangle$ est présenté dans l'équation 4.1.

$$D(X_i, Y_j) = \delta(x_i, y_j) + \min \left\{ \begin{array}{l} D(X_{i-1}, Y_{j-1}) \\ D(X_i, Y_{j-1}) \\ D(X_{i-1}, Y_j) \end{array} \right\}. \quad (4.1)$$

La similarité globale entre les séquences X et Y est donnée par l'équation 4.2.

$$D(X_{|X|}, Y_{|Y|}) = D(X_n, Y_m) \quad (4.2)$$

En introduisant la matrice des coûts $\Delta(X, Y) = [\delta(x_i, y_j)]_{i,j} \in R^{n \times m}$ et l'ensemble des matrices d'alignement binaires $\mathcal{A}_{n,m} \subset \{0,1\}^{n \times m}$, le produit interne $\langle A, \Delta(X, Y) \rangle$ donne le score de l'alignement A (indiqué en rouge dans la figure 4.4). Par conséquent, la DTW des deux séries temporelles est défini par l'équation 4.3.

$$DTW(X, Y) = \min_{A \in \mathcal{A}_{n,m}} \langle A, \Delta(X, Y) \rangle \quad (4.3)$$

La DTW a été utilisée pour des problèmes de classification, généralement avec des classificateurs K-NN ou SVM [159], tandis que d'autres études ont tenté de l'adapter au calcul de la moyenne des séries temporelles [158, 160, 161]. Ces approches peuvent être considérées comme un premier essai d'utilisation de la DTW comme une fonction d'erreur à minimiser pour la prédiction de séries temporelles. Cependant, le fait que la DTW ne soit pas différentiable a entravé ces études d'un point de vue informatique. Pour surmonter ce problème, Cuturi et Blondel [162] ont présenté une approximation lisse de la DTW, la rendant différentiable dans tous ses arguments, en introduisant l'opérateur *min* avec un paramètre de lissage γ , comme le montre l'équation 4.4.

$$\min^\gamma \{a_1 \dots a_n\} = \begin{cases} \min_{i \leq n} a_i & \text{si } \gamma = 0 \\ -\gamma \log \sum_{i=1}^n e^{-\frac{a_i}{\gamma}} & \text{si } \gamma > 0 \end{cases} \quad (4.4)$$

Ainsi, la Soft-DTW est définie dans l'équation 4.5.

$$\text{Soft-DTW}_\gamma(X, Y) = \min^\gamma \{ \langle A, \Delta(X, Y) \rangle, A \in \mathcal{A}_{n,m} \} \quad (4.5)$$

Pour forcer les modèles à constituer les séquences prédites en estimant l'amélioration de chacune des formes (traces résiduelles) pré-réhabilitation présentes dans les séquences d'entrée, la fonction perte choisie pour l'apprentissage du modèle U-RC-NET pourrait être la Soft-DTW normalisée indiquée par l'équation 4.6. Ce choix permettrait au modèle de traduire les mécanismes physiques d'évolution de l'uni en se focalisant sur des prédictions basées sur la forme dès son entraînement. La pertinence de ce choix sera évaluée à la section 4.3.1.

$$\text{Soft-DTW}_{norm}(X, Y) = \frac{\text{Soft-DTW}(X, Y)}{|X|} \quad (4.6)$$

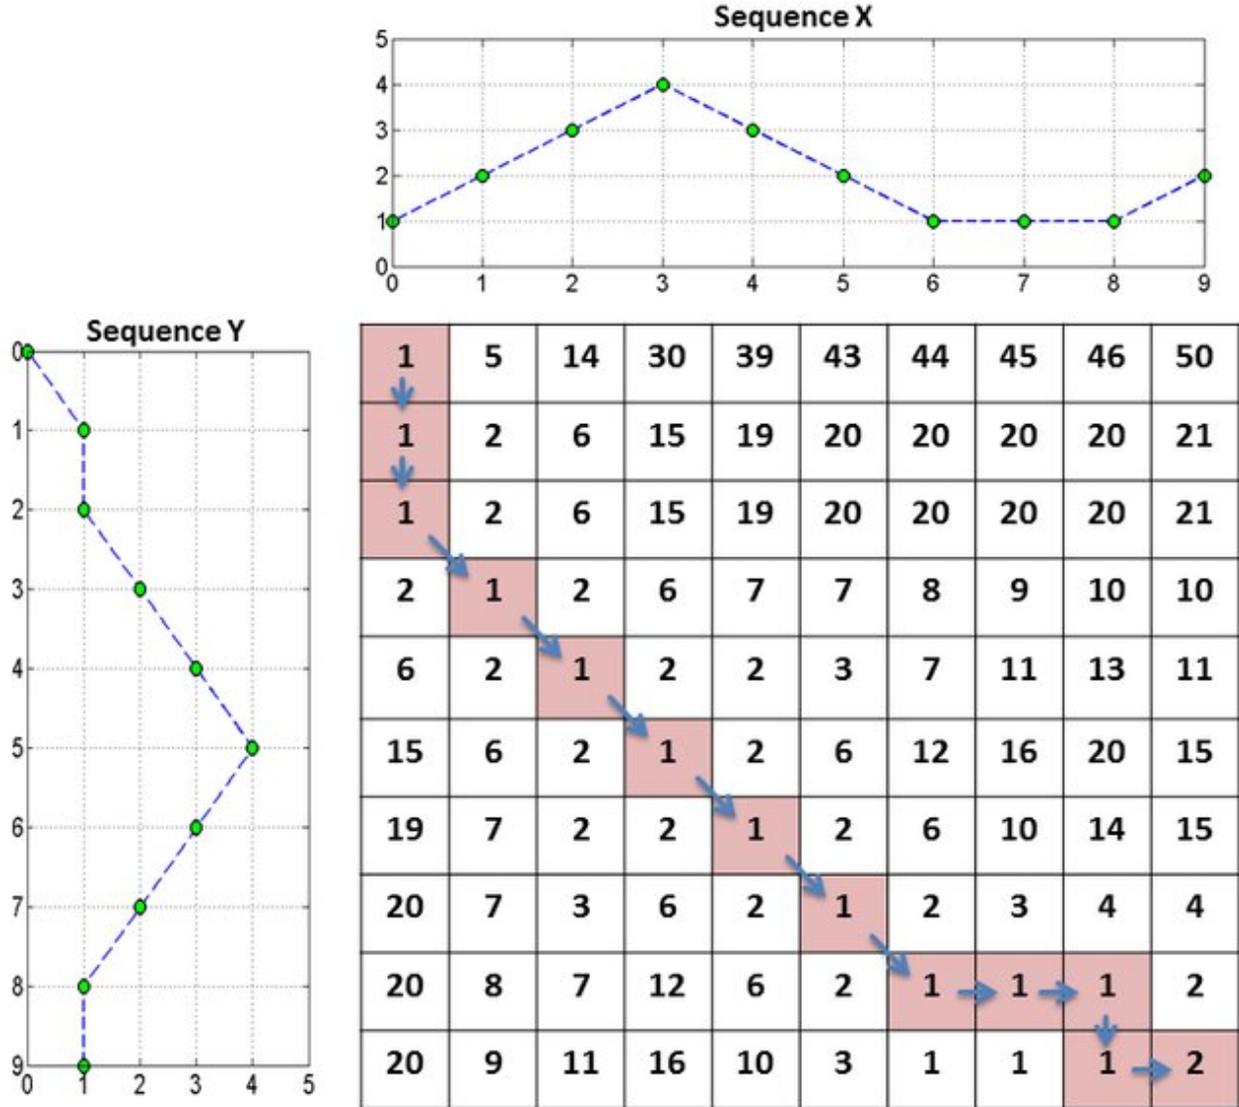


FIGURE 4.4 – Un exemple de DTW montre la similarité entre les séquences X et Y, toutes deux de longueur 10. L'alignement optimal est indiqué par la flèche le long des cases colorées. [18].

4.2.2 Métriques d'évaluation

Quant à la phase d'évaluation post-apprentissage, différentes métriques sont considérées et présentées dans le tableau 4.1, où y_i et \hat{y}_i sont respectivement les amplitudes au point i des séquences cibles et prédites et N est le nombre de leurs points. Les métriques sélectionnées peuvent être regroupées en trois catégories différentes : la première est constituée des métriques classiques qui qualifient la performance du modèle en comparant les points des séquences

prédites avec leurs cibles, comme l'erreur résiduelle maximale (MaXimal residual Error - MXE), l'erreur absolue médiane (MeDian absolute error - MDE) et le coefficient de détermination R^2 . La deuxième classe comprend des métriques qui qualifient la pertinence des prédictions en termes d'énergie E, (cf. équation 1.4), telles que l'erreur énergétique absolue (Absolute Energy Error - AEE), l'erreur énergétique relative (Relative Energy Error - REE). Le choix de cette deuxième classe de métriques s'inscrit dans la continuité de l'approche énergétique déjà considérée dans la section 2.2.2 relative lors de l'identification des défauts sur les profils. Rappelons que dans cette dernière un défaut est défini en fonction de son empreinte énergétique dans le profil. La dernière classe présente des métriques qui délèguent le calcul de l'énergie à des indicateurs d'uni communément utilisés pour l'évaluation contractuelle de la qualité des chaussées. Ainsi, on considère l'erreur de notes par bandes d'onde (Waveband Notations Error - WNE) qui implique le calcul des trois notes par bandes d'ondes (NBO) définies par les équations 1.5 - 1.7. Le choix des NBO est motivé par des raisons pratiques, puisque leur calcul est déployé selon un filtrage à trois bandes d'ondes et une segmentation des signaux filtrés pour obtenir des séquences unitaires similaires à celles générées par le modèle.

Métrique d'évaluation post-apprentissage	Définition
Erreur résiduelle maximale	$MXE = \max_N y_i - \hat{y}_i $
Erreur absolue médiane	$MDE = median_N y_i - \hat{y}_i $
Coefficient de détermination	$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - (\frac{1}{n} \sum_{i=1}^N y_i))^2}$
Erreur absolue d'énergie	$AEE = \hat{E}_{seq\ prédite} - E_{seq\ cible}$
Erreur d'énergie relative	$REE = \frac{\hat{E}_{seq\ prédite} - E_{seq\ cible}}{\hat{E}_{seq\ prédite}}$
Erreur NBO	$\Delta N = \widehat{NBO}_{seq\ prédite} - NBO_{seq\ cible} $

TABLE 4.1 – Les définitions des métriques d'évaluation post-apprentissage considérées

4.3 Entraînement de l'U-RC-NET développé :

A l'issue de l'implémentation de l'U-RC-NET selon l'architecture détaillée dans la figure 4.1, trois modèles sont à distinguer : un premier U-RC-NET_{GO} adapté pour le traitement des séquences GO comptant 4000 points par séquence. Il mobilise 121153 paramètres à calibrer lors de son entraînement. Le deuxième modèle U-RC-NET_{MO} est développé pour traiter des séquences MO comptant 2000 points par séquence. Ce modèle ajuste 71489 paramètres lors de son apprentissage sur le jeu de données d'entraînement MO. Le troisième et dernier modèle est l'U-RC-NET_{PO} qui est adapté pour traiter des séquences PO comptant 400 points par

séquence. Ce modèle affine 35844 paramètres à chaque itération de son apprentissage pour ajuster les données d'entraînement PO.

4.3.1 Métriques d'apprentissage - Soft DTW vs MSE/MAE

L'objectif de cette section est d'évaluer la pertinence du choix de la $Soft - DTW_{norm}$ comme une métrique d'apprentissage. Il est à noter que les métriques d'apprentissage portent sur la cellule LSTM, étant la couche du modèle développé qui traite les séries temporelles. Ainsi, l'apport de la $Soft - DTW_{norm}$ sur la cellule LSTM sera confronté aux résultats du modèle LSTM seul (cf. 3.4.2) entraîné en utilisant la MSE comme métrique d'apprentissage. On référera à ce cas par $LSTM_{MSE}$ alors que celui basé sur la $Soft - DTW_{norm}$ sera noté $LSTM_{DTW}$.

L'apprentissage des modèles $LSTM_{MSE}$ et $LSTM_{DTW}$ dans cette analyse comparative suivront le même schéma décrit dans la section 3.4.2. Ainsi, six modèles sont à distinguer : les modèles $LSTM_{MSE_{GO}}$, $LSTM_{MSE_{MO}}$ et $LSTM_{MSE_{PO}}$ qui ont été implémentés précédemment, ainsi que les modèles $LSTM_{DTW_{GO}}$, $LSTM_{DTW_{MO}}$ et $LSTM_{DTW_{PO}}$ qui sont entraînés à estimer les traces résiduelles post-réhabilitation des trois bandes d'ondes en utilisant la $Soft - DTW_{norm}$.

On a constaté lors des entraînements que les modèles LSTM convergent plus lentement lorsqu'ils sont entraînés à minimiser la Soft-DTW par rapport à la MSE. En détail, l'entraînement du modèle $LSTM_{DTW_{GO}}$ s'arrête à la 232^{ème} itération où la valeur minimale de la $Soft - DTW_{norm}$ est 7.9. Au niveau des MO, la performance de $LSTM_{DTW_{MO}}$ cesse de s'améliorer après la 95^{ème} itération à une $Soft - DTW_{norm}$ minimale de 0.59. Quant aux PO, $LSTM_{DTW_{PO}}$ atteint sa performance optimale dès sa 47^{ème} itération, où la valeur minimale affichée est de 0.09. Pour rappel (cf. 3.4.2), les itérations limites avec la MSE sont respectivement 164, 73 et 30. Ces modèles affichent des performances assez similaires lors de leurs tests comme l'indiquent les tableaux 4.2 -4.4. Ceci indique que la généralisation des modèles $LSTM_{DTW}$ reste acceptable avec des niveaux d'erreur stables.

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4	Séquence N°5
$Soft - DTW_{norm}$	11.87	12.97	11.39	14.63	11.54

TABLE 4.2 – Résultats de test de $LSTM_{DTW_{GO}}$.

Pour comparer les $LSTM_{DTW}$ avec les $LSTM_{MSE}$, ni la MSE ni la $Soft - DTW_{norm}$ ne peuvent être utilisées pour croiser leurs performances, puisque chaque groupe de modèles aura naturellement des performances optimales en fonction de sa métrique d'apprentissage. Par conséquent, la comparaison des modèles se fera en termes de deux critères : d'une part, les

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4
$Soft - DTW_{norm}$	1.78	1.86	2.12	2.73

TABLE 4.3 – Résultats de test de $LSTM_{DTW_{MO}}$.

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4
$Soft - DTW_{norm}$	0.98	1.03	0.72	1.13

TABLE 4.4 – Résultats de test de $LSTM_{DTW_{PO}}$.

erreurs ΔN qui serviront pour comparer les performances énergétiques globales des modèles $LSTM_{DTW}$ avec celles des $LSTM_{MSE}$ sur chacune des trois bandes d'ondes. D'autre part, le deuxième critère sera la comparaison graphique des séquences prédites pour évaluer la logique de leurs compositions.

Les tableaux 4.5 - 4.7 présentent les écarts ΔN du modèle $LSTM_{DTW}$ sur les jeux de test des trois bandes d'ondes. En comparant ces écarts à ceux affichés par les modèles $LSTM_{MSE}$ (cf. tableaux 3.8 - 3.10), nous constatons que les $LSTM_{DTW}$ démontrent plus de précision énergétique (par rapport aux $LSTM_{MSE}$) puisqu'ils affichent des écarts de notes plus faibles sur les trois bandes d'ondes.

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4	Séquence N°5
ΔN_{GO}	0.34	1.12	1.39	0.37	0.75

TABLE 4.5 – L'écart entre les notes prédites par le $LSTM_{DTW_{GO}}$ et celles réelles sur les données de test.

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4
ΔN_{MO}	1.75	2.02	1.68	1.56

TABLE 4.6 – L'écart entre les notes prédites par Le $LSTM_{DTW_{MO}}$ et celles réelles sur les données de test.

Les figures 4.5 -4.7 illustrent des exemples de prédiction des modèles $LSTM_{DTW}$ et $LSTM_{MSE}$ sur les données de test des trois bandes d'ondes : en comparant la composition de leurs prédictions, il s'avère que les séquences des $LSTM_{DTW}$ sont plus marquées par une segmentation en blocs monolithiques (traces résiduelles). En effet, au niveau des GO, les prédictions

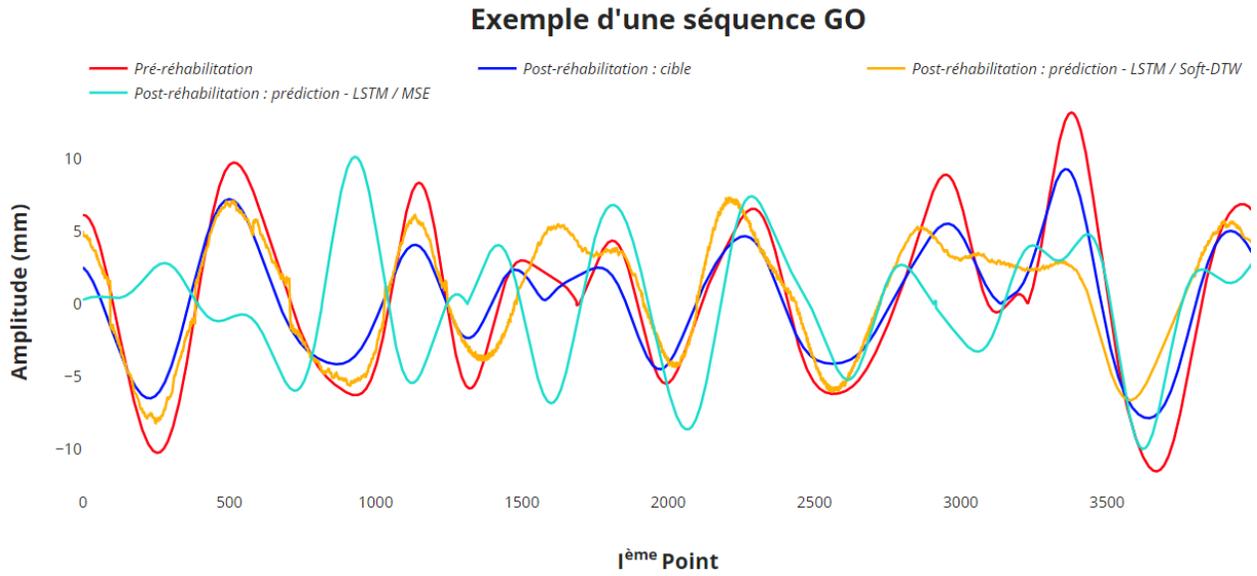
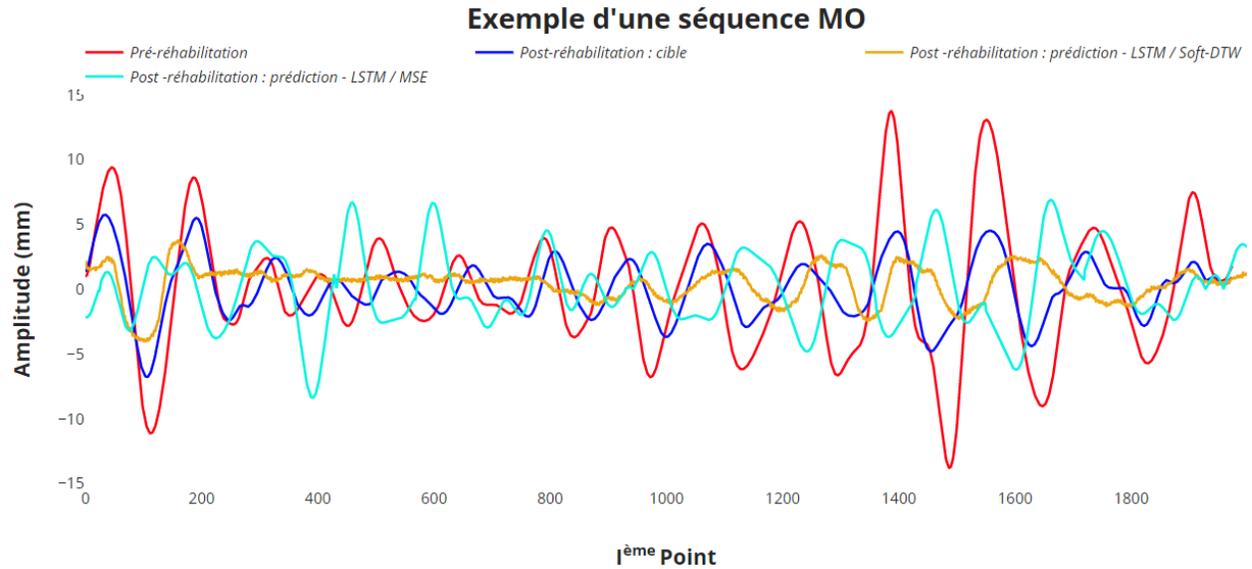
	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4
ΔN_{PO}	2.19	2.84	2.61	2.31

TABLE 4.7 – L'écart entre les notes prédites par le $LSTM_{DTW_{PO}}$ et celles réelles sur les données de test.

de $LSTM_{DTW_{GO}}$ présentent quasiment les mêmes traces résiduelles que les séquences cibles. La qualité de ce découpage se dégrade sur les séquences MO prédites par le $LSTM_{DTW_{MO}}$, mais reste toutefois plus pertinentes que celles prédites par le $LSTM_{MSE_{MO}}$, où on ne retrouve que des oscillations aléatoires mais suffisantes pour minimiser la MSE. Quant au PO, le $LSTM_{DTW_{PO}}$ n'arrive pas à suivre le découpage fin des blocs monolithiques de cette bande d'ondes et ne génère que des enveloppes générales des traces résiduelles post-réhabilitation, tandis que le $LSTM_{MSE_{PO}}$ se contente de générer un signal erratique n'ayant aucune hérédité le reliant au profil pré-réhabilitation.

En conclusion, la *Soft - DTW* aide certainement le modèle à construire ses prédictions en fonction de la forme de ses cibles. Ainsi, dans notre cas, l'apprentissage basé sur la minimisation de la *Soft - DTW* permet au modèle de respecter plus la segmentation du profil de la chaussée en blocs monolithiques, notamment au niveau des GO. Par conséquent, seule la *Soft - DTW* est retenue comme métrique d'apprentissage dans la suite du mémoire.

Cependant, même avec la *Soft - DTW* comme métrique d'apprentissage, les MO et PO restent difficiles à prédire puisqu'elles comportent des fluctuations erratiques qui empêchent les modèles de distinguer les tendances majeures des traces résiduelles. Les séquences doivent donc être lissées pour mettre en évidence les principales composantes de leurs traces résiduelles dans les bandes d'ondes tout en atténuant leurs bruits.

FIGURE 4.5 – Le test du modèle $LSTM_{DTW_{GO}}$ sur une séquence GO.FIGURE 4.6 – Le test du modèle $LSTM_{DTW_{MO}}$ sur une séquence MO.

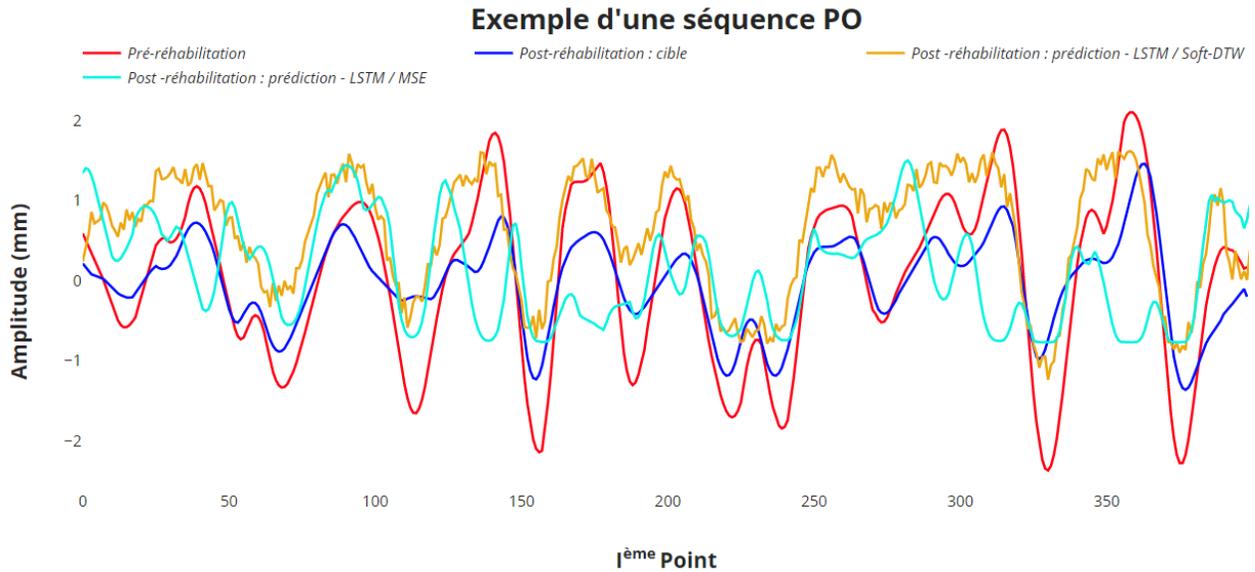


FIGURE 4.7 – Le test du modèle $LSTM_{DTW_{PO}}$ sur une séquence PO.

4.3.2 Passage des traces résiduelles aux empreintes énergétiques

Dans le cas d'un signal segmenté et erratique tel que le profil de la route (mesure profilométrique), toutes les fluctuations ne sont pas pertinentes à considérer, surtout celles fines (de haute résolution) qui font partie d'un même bloc monolithique (défaut). En effet, prédire l'amélioration du profil de la chaussée par bandes d'ondes revient à estimer l'atténuation des traces résiduelles préexistantes en fonction de leurs formes et de leurs amplitudes, indépendamment de leurs fluctuations locales. En d'autres termes, le modèle doit dissocier les tendances significatives d'un bloc monolithique de sa composante locale erratique (bruit), notamment au niveau des PO et MO. Ainsi, il convient d'appréhender le défaut comme un motif sur un voisinage indépendamment des fluctuations locales erratiques précédemment mentionnées. Cela revient à faire apprendre au modèle les tendances remarquables du profil sans le noyer d'informations issues des fluctuations locales. Pour ce faire, les amplitudes de chacune des bandes d'ondes filtrées sont élevées au carré, comme le montrent les figures 4.8 - 4.10. Ce passage des traces résiduelles à leurs empreintes énergétiques permet de lisser les fluctuations locales tout en augmentant les amplitudes des tendances remarquables de la séquence.

Les modèles $LSTM_{DTW}$ ont été entraînés et testés à prédire les empreintes énergétiques des traces résiduelles par bande d'ondes en minimisant la $Soft-DTW_{norm}$. Le lissage des courbes dû à l'élévation au carré de leurs amplitudes permet aux modèles d'améliorer la segmentation de leurs prédictions en blocs monolithiques (empreintes énergétiques), notamment sur les MO et les PO (cf. Figures 4.11 - 4.13). Cependant, cette amélioration est légèrement contreba-

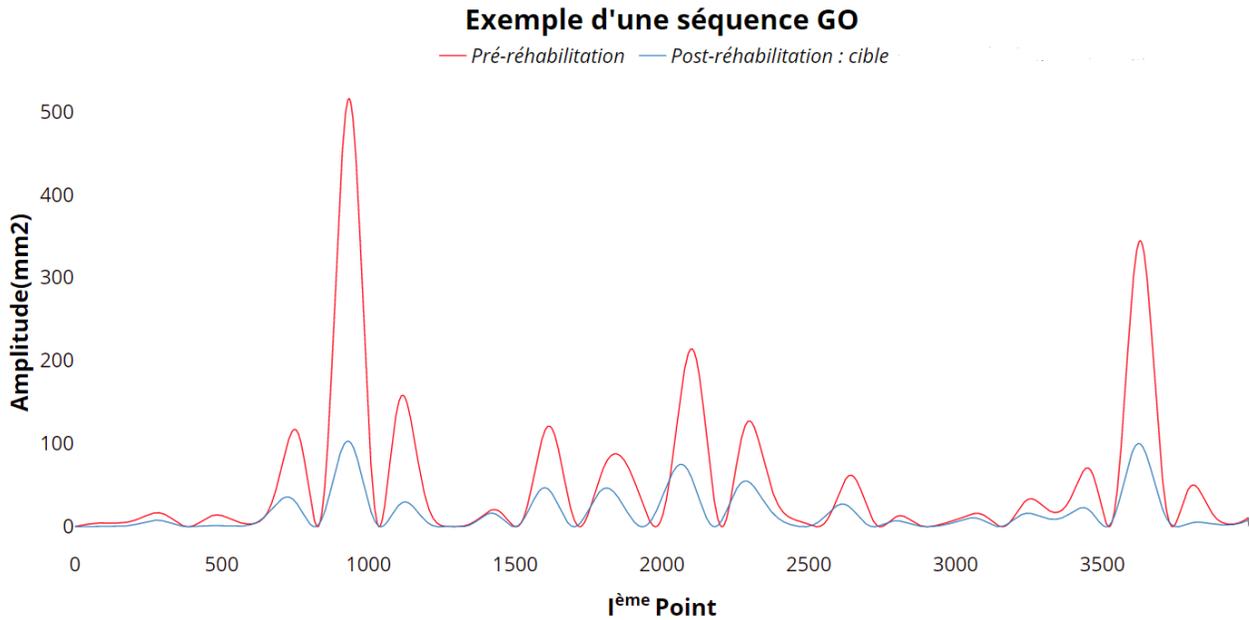


FIGURE 4.8 – Exemple des signaux GO pré- et post-réhabilitation après avoir élevé leurs amplitudes au carré.

lancée par une dégradation au niveau des amplitudes empreintes énergétiques prédites. Globalement, le passage des traces résiduelles aux empreintes énergétiques permet d'améliorer les notes par bandes d'ondes prédites, comme indiqué dans les tableaux 4.8 - 4.10.

De plus, le passage à l'espace énergétique permet d'augmenter la sensibilité aux valeurs extrêmes. En effet, dans le cas d'une séquence d'uni qui contient des pics et des creux très prononcés, l'élévation au carré de ces valeurs aide à mieux les détecter et à les inclure plus facilement dans les prédictions. En outre, puisque la mesure profilométrique se compose d'une suite de motifs récurrents (blocs monolithiques), l'élévation au carré aide à renforcer cette récurrence et à encourager une certaine régularité dans la série temporelle. Cela rend le modèle plus robuste et plus facile à interpréter.

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4	Séquence N°5
ΔN_{GO}	0.68	0.98	1.31	0.78	0.57

TABLE 4.8 – L'écart entre les notes prédites par le $LSTM_{DTW_{GO}}$ (entraîné sur les empreintes énergétiques) et celles réelles sur les données de test.

Ainsi, la méthodologie retenue pour la prédiction de l'uni consiste à générer des séquences

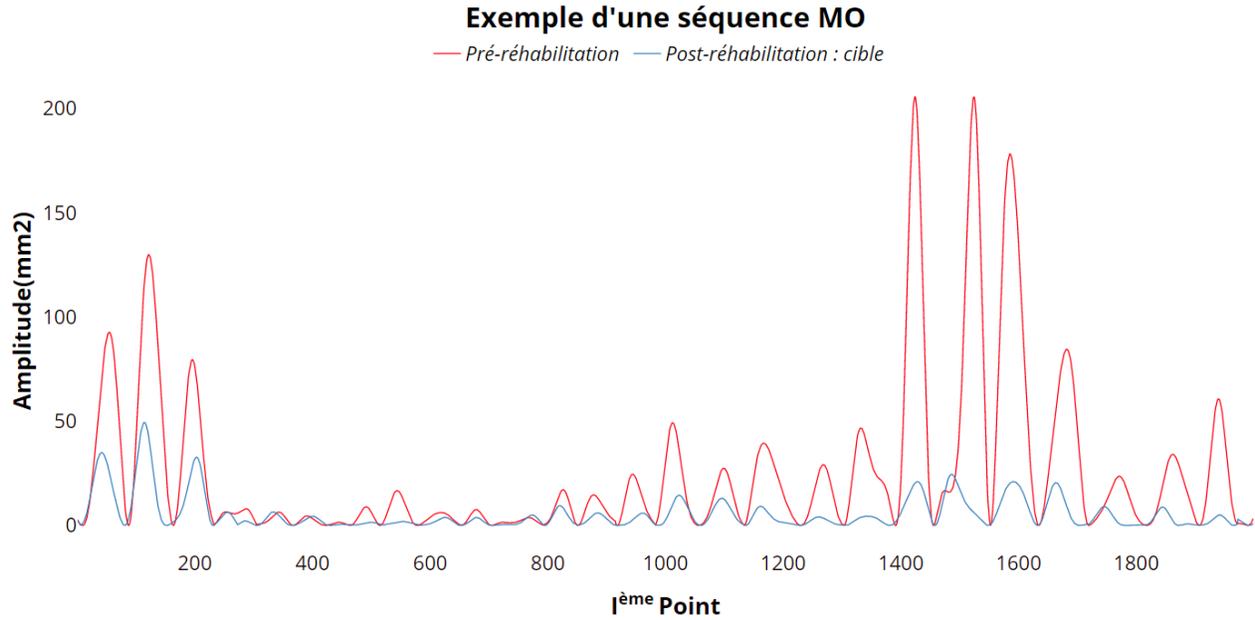


FIGURE 4.9 – Exemple des signaux MO pré- et post-réhabilitation après avoir élevé leurs amplitudes au carrée.

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4
ΔN_{MO}	1.38	1.72	1.82	1.49

TABLE 4.9 – L'écart entre les notes prédites par Le $LSTM_{DTW_{MO}}$ (entraîné sur les empreintes énergétiques) et celles réelles sur les données de test.

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4
ΔN_{PO}	1.73	2.57	1.93	1.84

TABLE 4.10 – L'écart entre les notes prédites par le $LSTM_{DTW_{PO}}$ (entraîné sur les empreintes énergétiques) et celles réelles sur les données de test.

d'empreintes énergétiques post-réhabilitation à partir de leurs correspondantes pré-réhabilitation. Ensuite, les séquences des traces résiduelles post-réhabilitation peuvent être restituées selon les mêmes tableaux de variation de leurs séquences pré-réhabilitation correspondantes (cf. Figure 4.14 : (1) avant d'élever au carré les amplitudes de ses traces résiduelles, il convient de localiser les indices i des points où la séquence pré-réhabilitation change de signe (d'une valeur négative à une valeur positive ou vice-versa). Ensuite, la séquence d'empreintes énergétiques pré-réhabilitation est traitée par le modèle de prédiction pour prédire sa correspondante post-

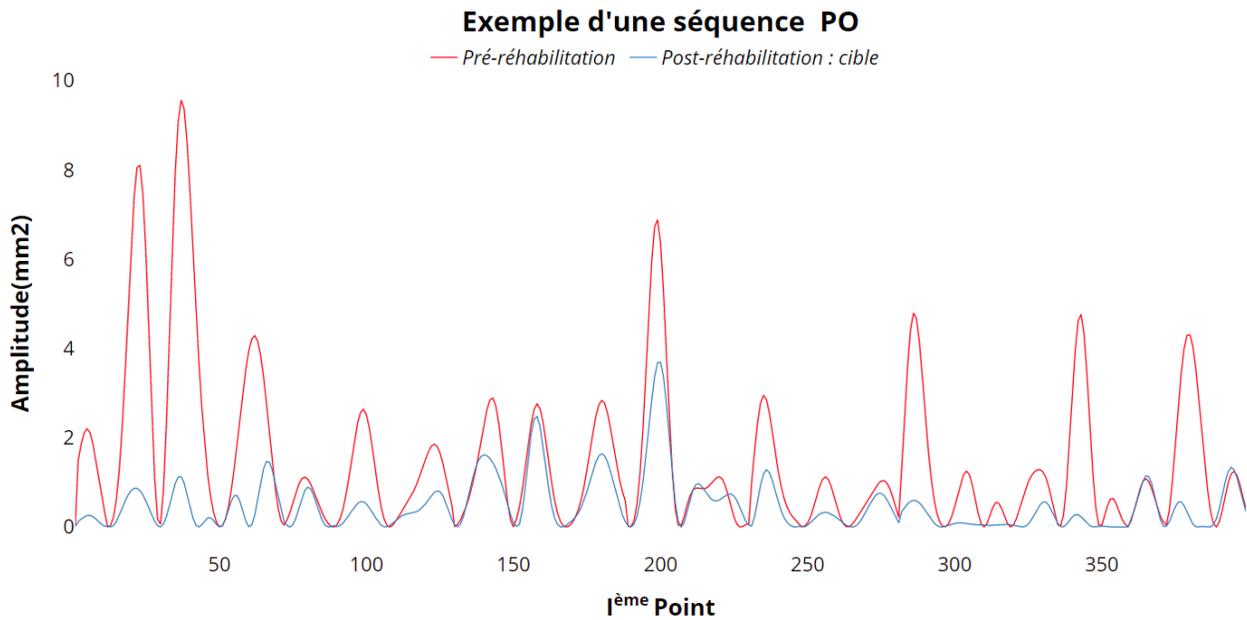


FIGURE 4.10 – Exemple des signaux PO pré- et post-réhabilitation après avoir élevé leurs amplitudes au carré.

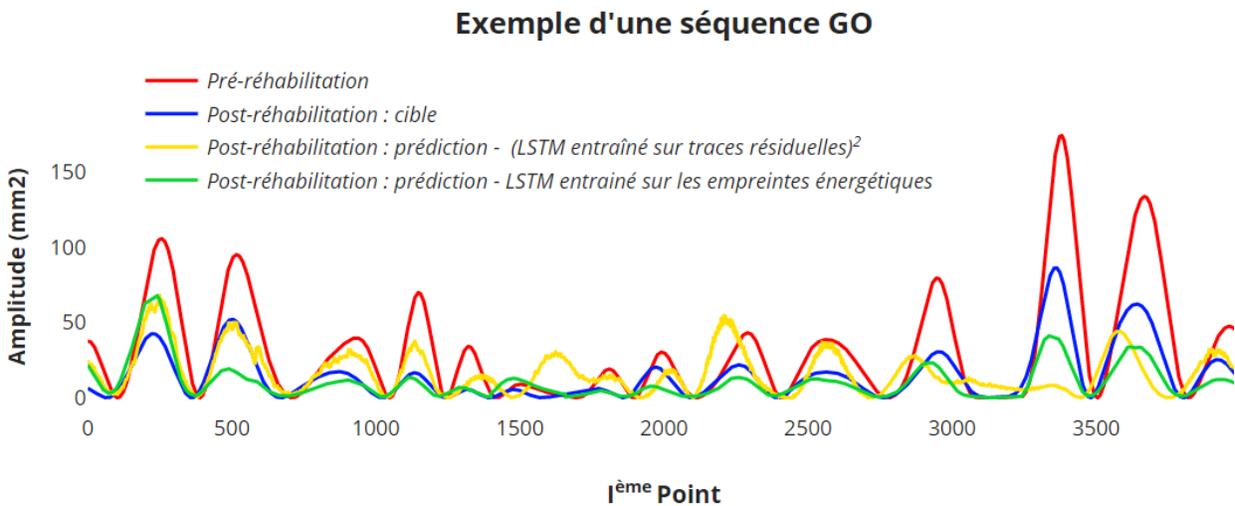


FIGURE 4.11 – Illustrations des séquences de test GO prédites par $LSTM_{DTW_{GO}}$ entraîné sur les traces résiduelles et sur les empreintes énergétiques.

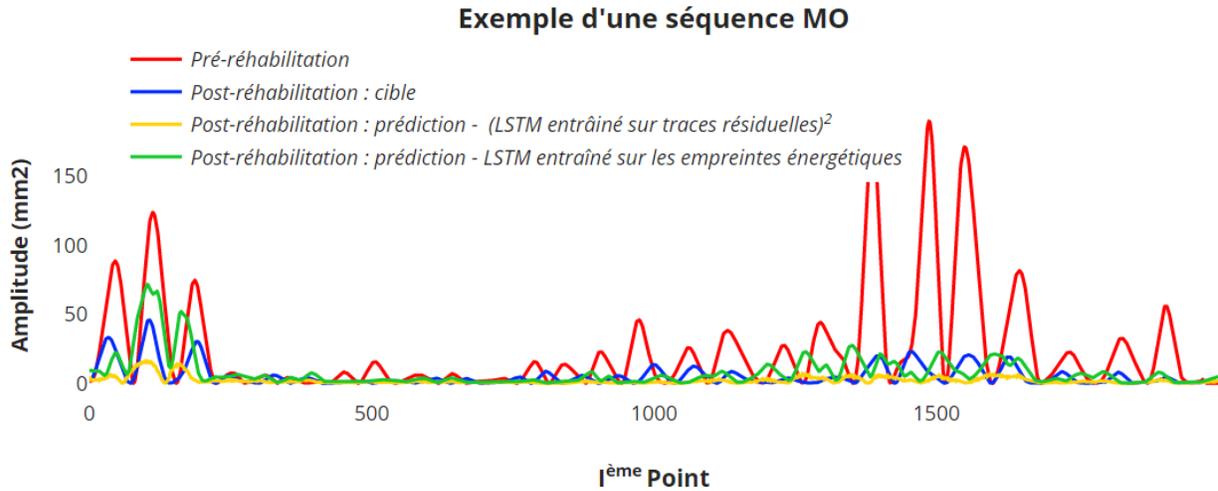


FIGURE 4.12 – Illustrations des séquences de test MO prédites par $LSTM_{DTW_{MO}}$ entraîné sur les traces résiduelles et sur les empreintes énergétiques.

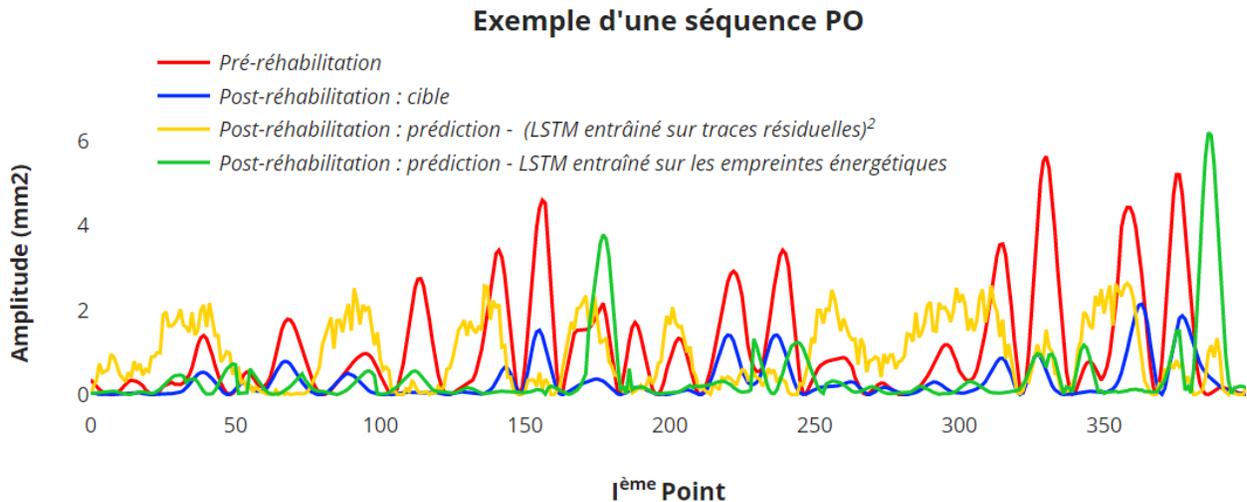


FIGURE 4.13 – Illustrations des séquences de test PO prédites par $LSTM_{DTW_{PO}}$ entraîné sur les traces résiduelles et sur les empreintes énergétiques.

réhabilitation (2). L'étape (3) consiste à calculer la racine carrée de la séquence prédite pour retrouver les indices i' où les traces résiduelles absolues post-réhabilitation s'annulent (ou atteignent des minima locaux proches de 0). Une correspondance entre les deux ensembles d'indices est établie où chaque i est associé à son plus proche i' (4). Finalement, la séquence

de traces résiduelles post-réhabilitation est construite suivant les mêmes variations de sa séquence pré-réhabilitation à chacun des points i' (5).

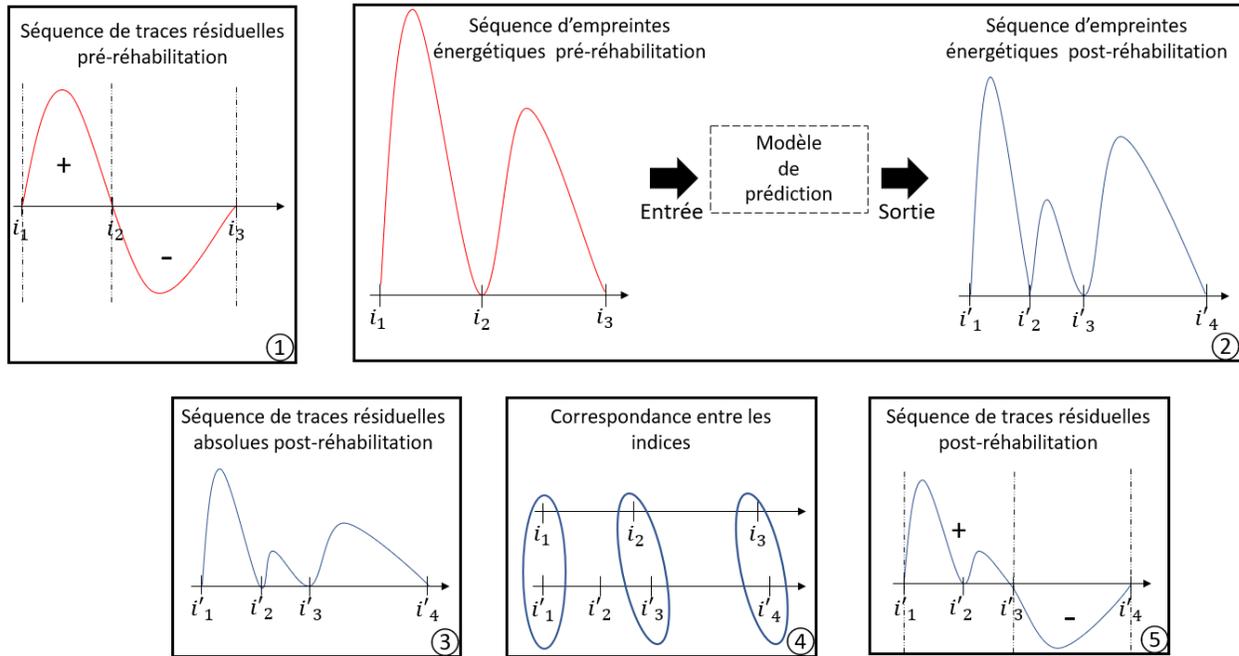


FIGURE 4.14 – Reconstitution des traces résiduelles à partir des empreintes énergétiques.

Suivant cette méthodologie, les U-RC-NETs sont ainsi entraînés à prédire les empreintes énergétiques des traces résiduelles post-réhabilitation par bande d'ondes. Lors de leurs entraînements, les trois modèles U-RC-NET affichent des vitesses de convergences différentes : l'entraînement d'U-RC-NET_{GO} s'arrête à la 354^{ème} époque où la valeur de la Soft-DTW_{norm} est de 5.3 . Au niveau des MO, la performance d'U-RC-NET_{MO} cesse de s'améliorer après la 281^{ème} époque à une Soft-DTW_{norm} minimale de 0.176. Quant aux PO, l'U-RC-NET_{PO} atteint sa performance maximale dès la 79^{ème} époque où la valeur minimale de la Soft-DTW_{norm} est de 0.01.

4.4 Test de l'U-RC-NET développé et analyse des résultats

Après avoir entraîné le modèle sur l'ensemble d'entraînement, sa capacité de généralisation sera mesurée sur l'ensemble de test à travers les différentes métriques présentées dans le tableau 4.1. Les résultats des trois bandes d'ondes sont rapportés dans les tableaux 4.11 - 4.13 et illustrés dans les figures 4.15 - 4.27.

Métriques	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4	Séquence N°5
MSE	21.62	27.29	26.90	60.35	435.11
MAE (mm^2)	3.45	3.91	3.82	5.17	9.23
R^2	0.93	0.73	0.78	0.95	0.13
MXE (mm^2)	13.79	13.68	15.14	28.49	135.59
MDE (mm^2)	2.37	2.72	2.78	3.12	3.27
Énergie prédite(cm^3)	2886.97	1704.91	1822.20	3346.79	4640.47
AEE (cm^3)	112.04	127.63	351.92	243.52	1225.31
REE (%)	3.8	7.48	19.31	7.27	26.40
NGO	7.17	8.39	8.24	6.82	6.06
ΔN_{GO}	0.09	0.17	0.41	0.16	0.71
Soft-DTW _{norm}	6.41	7.97	10.42	13.02	19.52

TABLE 4.11 – Évaluation des résultats de test de l'U-RC-NET_{GO} sur les GO

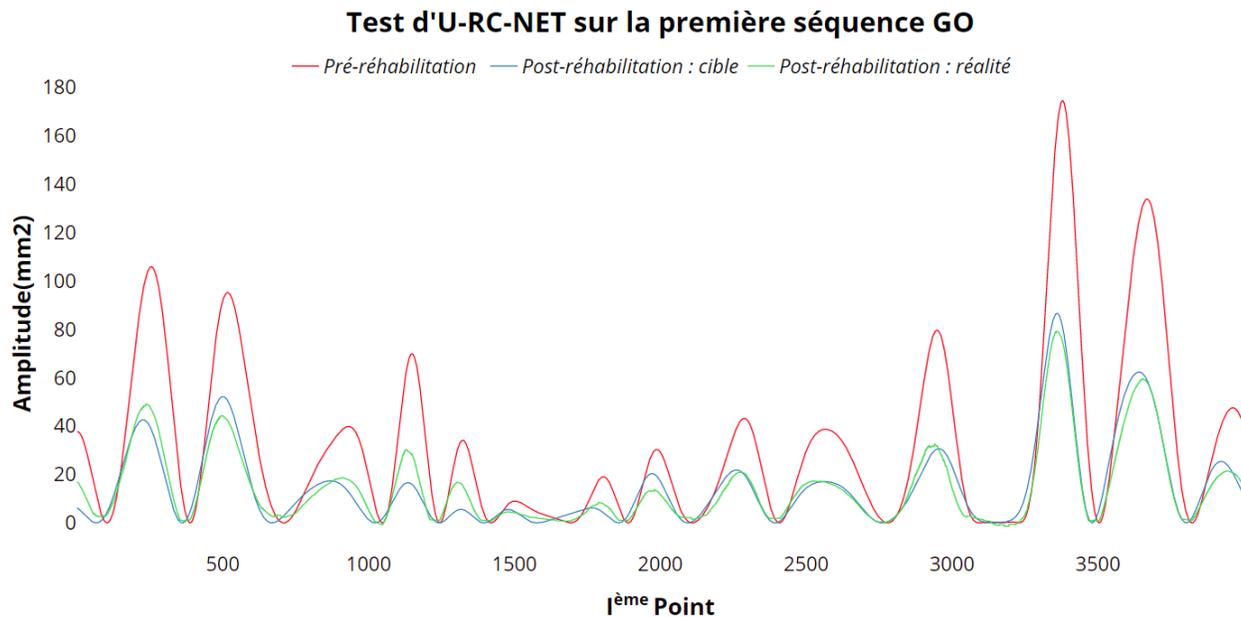
	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4
MSE	1.513	1.260	0.314	0.902
MAE (mm^2)	0.892	0.778	0.483	0.680
R^2	0.977	0.967	0.938	0.925
MXE (mm^2)	5.946	5.654	1.893	4.752
MDE (mm^2)	0.691	0.561	0.450	0.507
Énergie prédite(cm^3)	600.168	502.184	206.627	311.905
AEE (cm^3)	40.570	46.452	40.743	54.117
REE (%)	6.7	9.24	19.71	17.35
NMO	0.156	0.217	0.490	0.425
ΔN_{MO}	0.156	0.217	0.490	0.425
Soft-DTW _{norm}	0.54	0.62	0.26	0.45

TABLE 4.12 – Évaluation des résultats de test de l'U-RC-NET_{MO} sur les MO

Les performances des U-RC-Nets sur les données de test des trois bandes d'ondes sont similaires à celles sur les entraînements, notamment sur les MO et PO. La stabilité des erreurs sur les deux jeux de données indique que les U-RC-Nets entraînés ont atteint des performances généralisables.

Puisqu'il s'agit d'un problème de prédiction basé sur la forme, les deux perspectives à partir

	Séquence N°1	Séquence N°2	Séquence N°3	Séquence N°4
MSE	0.021	0.018	0.030	0.038
MAE (mm^2)	0.128	0.122	0.158	0.182
R^2	0.940	0.741	0.815	0.865
MXE (mm^2)	0.349	0.267	0.395	0.490
MDE (mm^2)	0.125	0.128	0.174	0.190
Énergie prédite(cm^3)	11.970	6.322	8.779	10.319
AEE (cm^3)	2.288	2.336	2.759	2.802
REE (%)	24.06	36.95	31.42	27.15
NPO	4.421	5.849	5.115	4.753
ΔN_{PO}	0.475	1.032	0.844	0.709
Soft-DTW _{norm}	0.02	0.02	0.04	0.05

TABLE 4.13 – Évaluation des résultats de test de l'U-RC-NET_{PO} sur les POFIGURE 4.15 – Test d'U-RC-NET_{GO} sur la première séquence GO.

desquelles les résultats des tests seront analysés sont : la forme des séquences prédites et leurs précisions énergétiques. En d'autres termes, les séquences prédites seront d'abord comparées visuellement avec leurs cibles pour analyser leurs corrélations spatiales (si elles contiennent

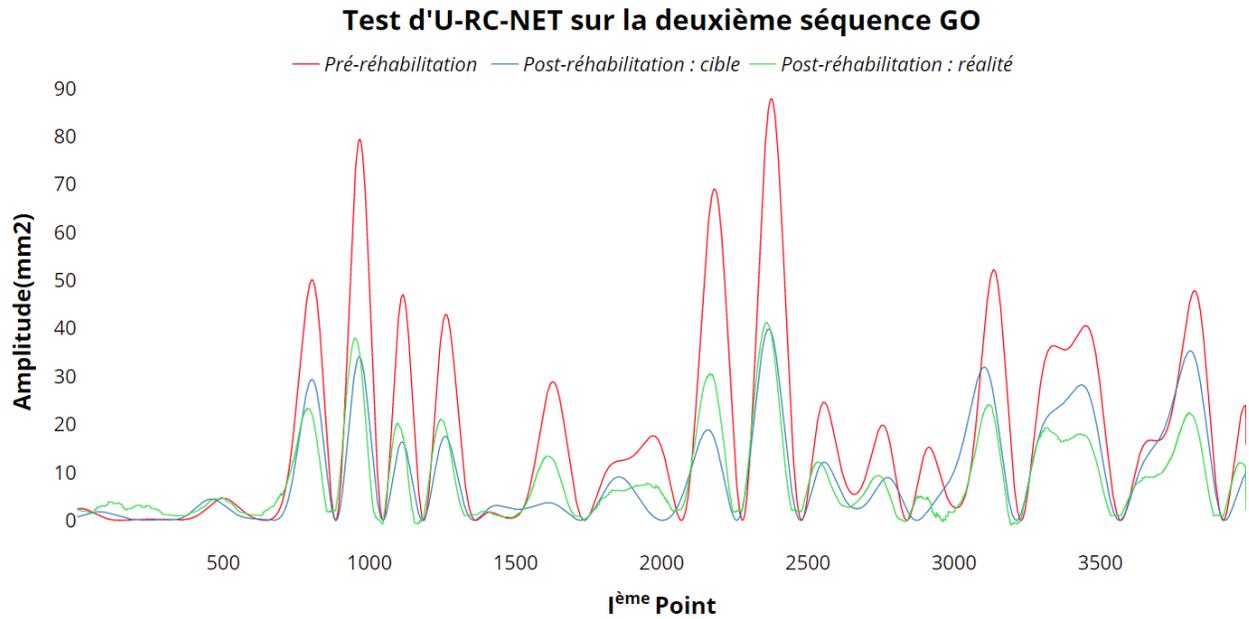


FIGURE 4.16 – Test d'U-RC-NET_{GO} sur la deuxième séquence GO.

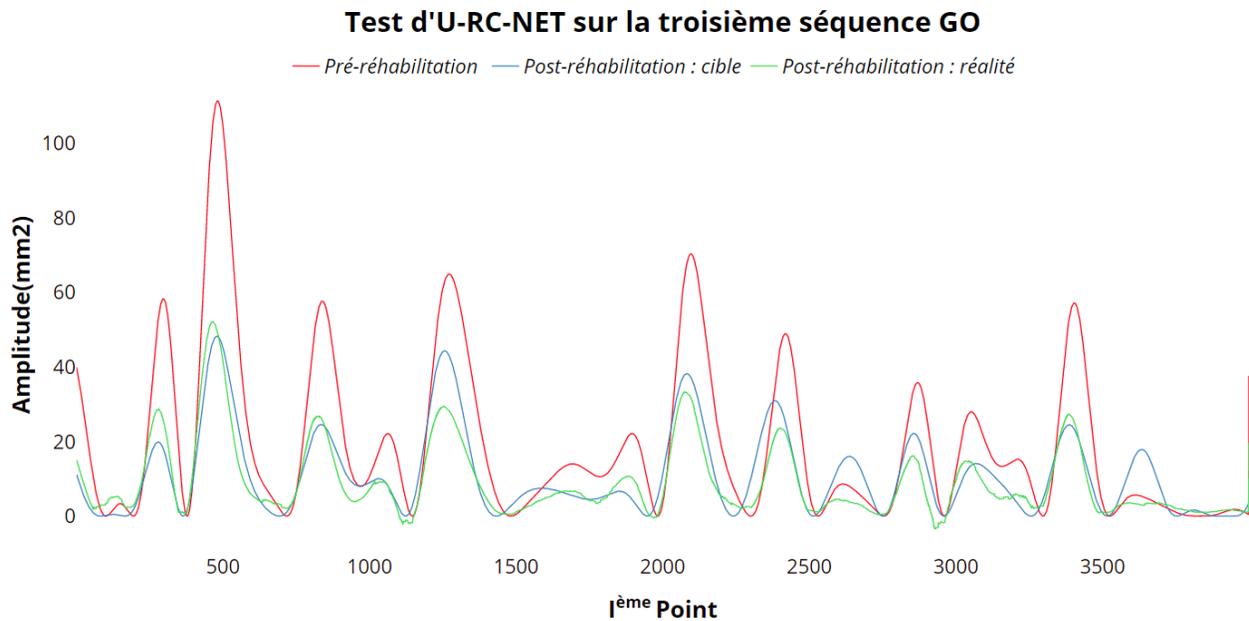
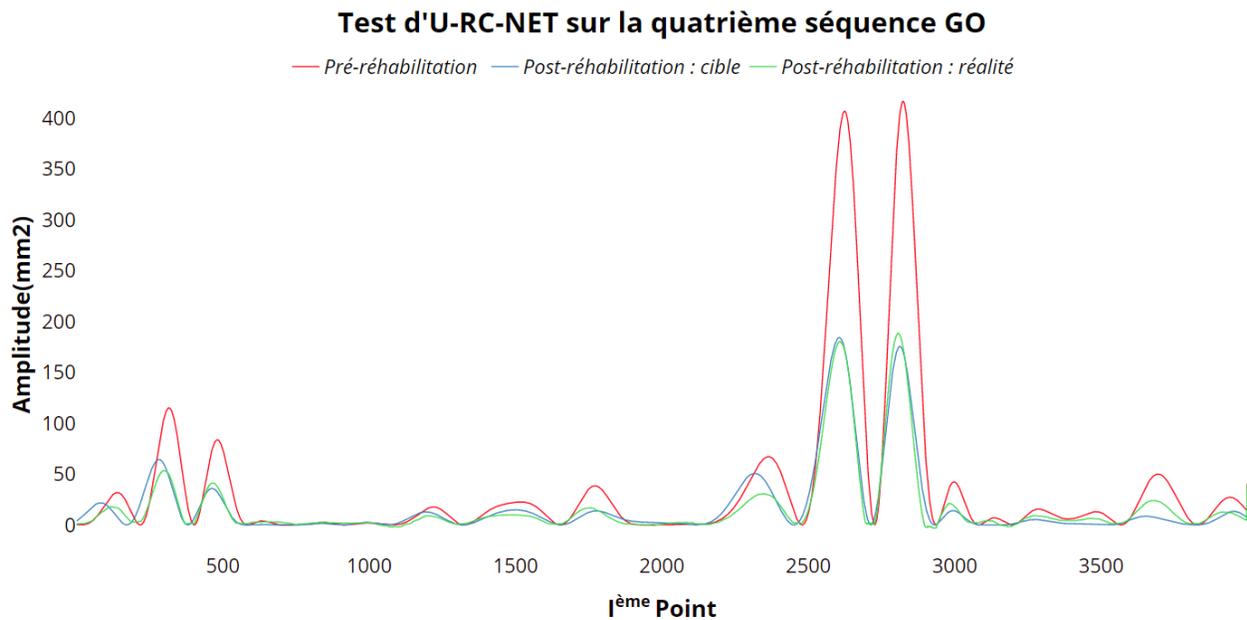
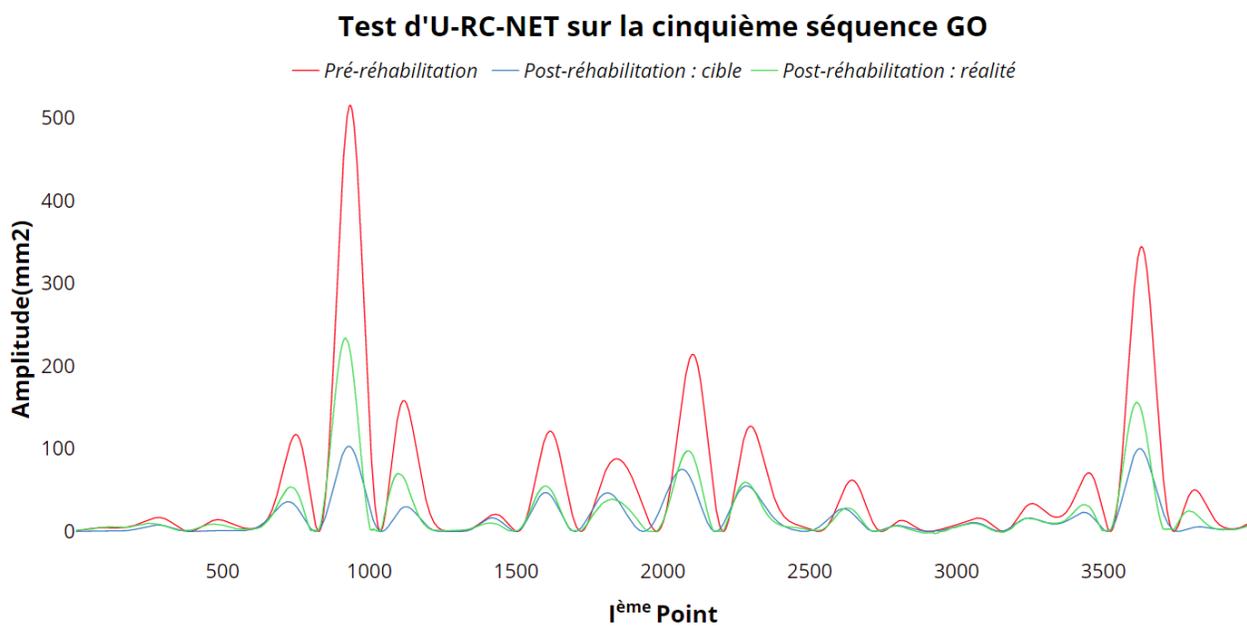


FIGURE 4.17 – Test d'U-RC-NET_{GO} sur la troisième séquence GO.

FIGURE 4.18 – Test d'U-RC-NET_{GO} sur la quatrième séquence GO.FIGURE 4.19 – Test d'U-RC-NET_{GO} sur la cinquième séquence GO.

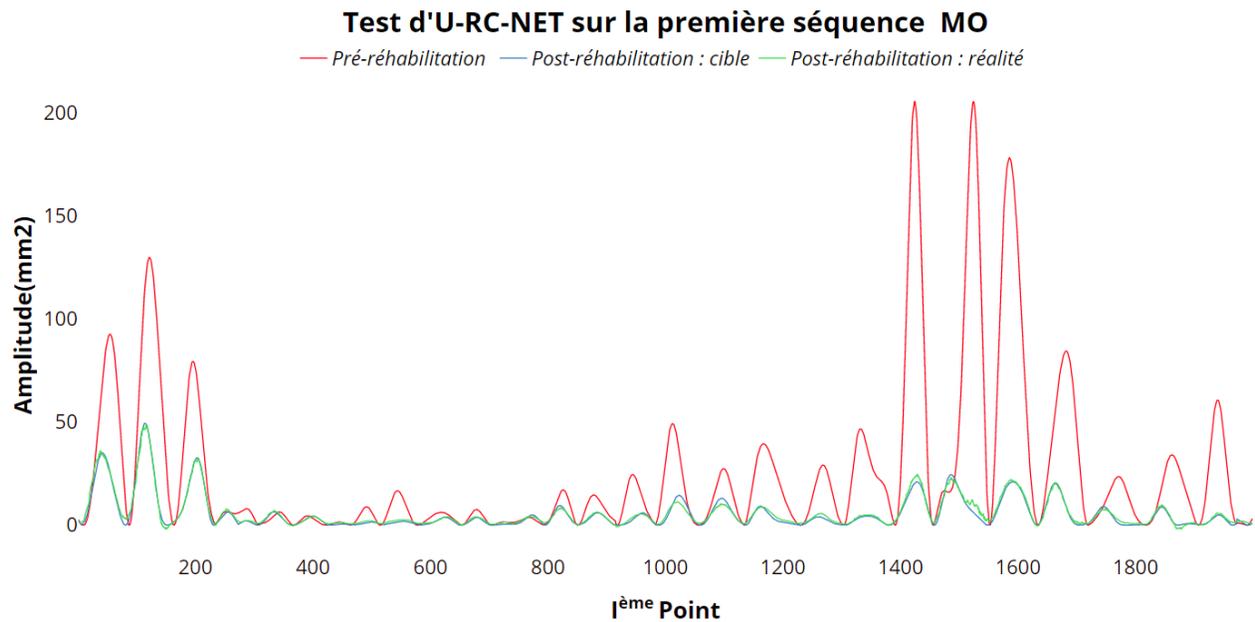


FIGURE 4.20 – Test d'U-RC-NET_{MO} sur la première séquence MO.

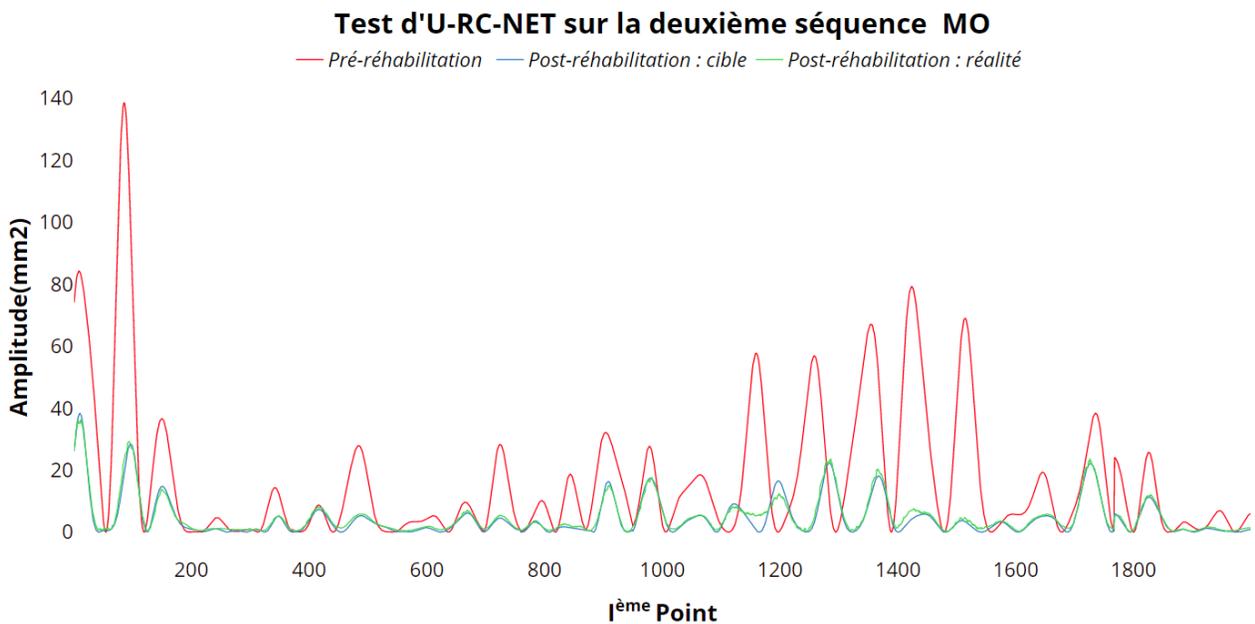
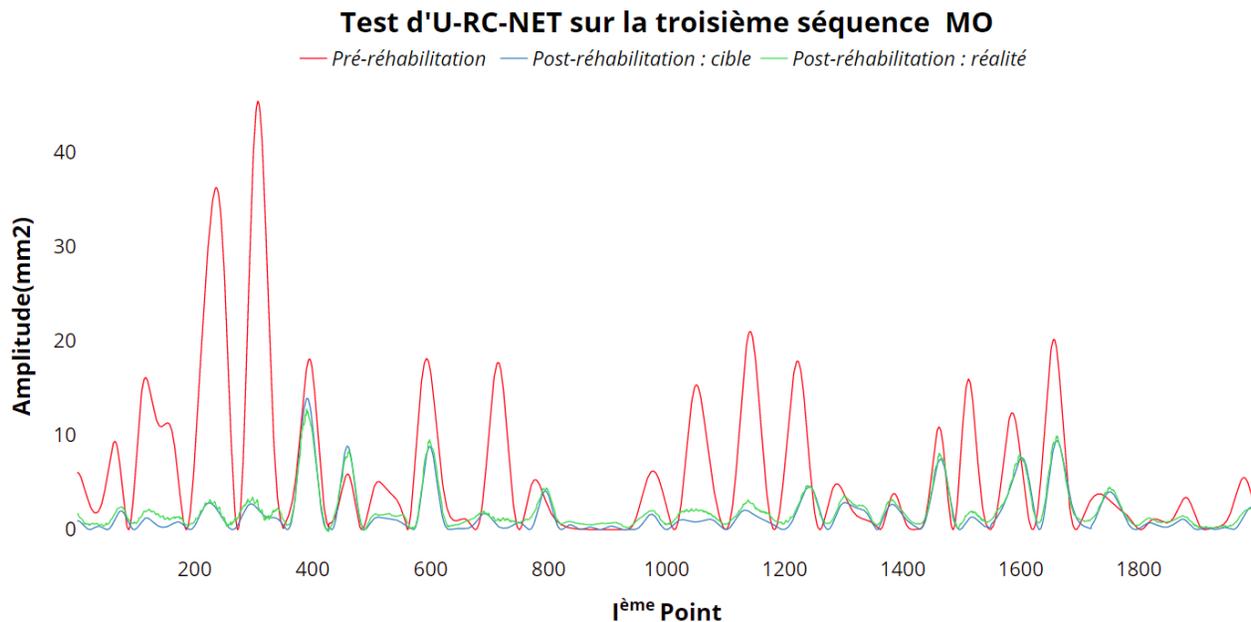
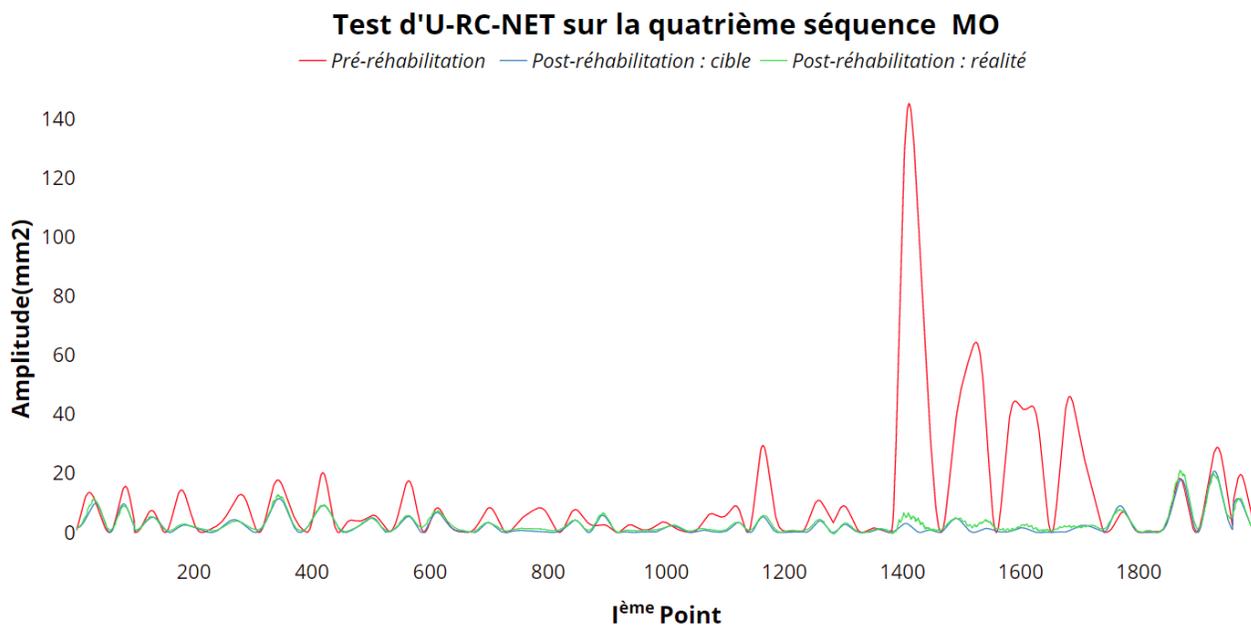


FIGURE 4.21 – Test d'U-RC-NET_{MO} sur la deuxième séquence MO.

FIGURE 4.22 – Test d'U-RC-NET_{MO} sur la troisième séquence MO.FIGURE 4.23 – Test d'U-RC-NET_{MO} sur la quatrième séquence MO.

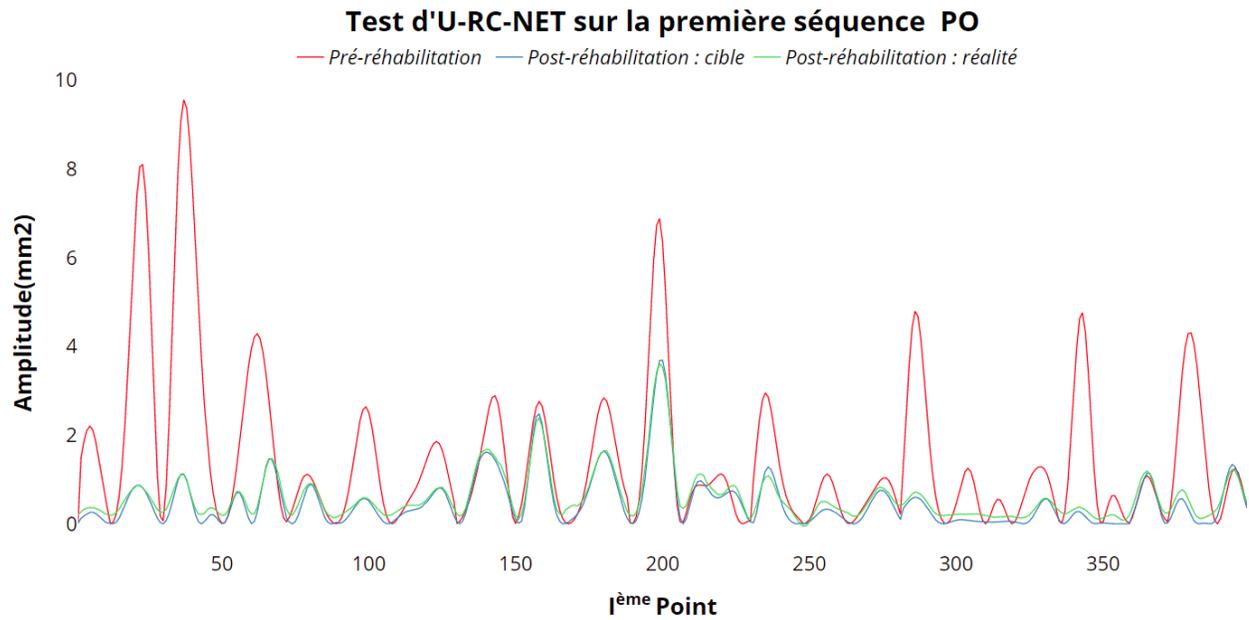


FIGURE 4.24 – Test d'U-RC-NET_{PO} sur la première séquence PO.

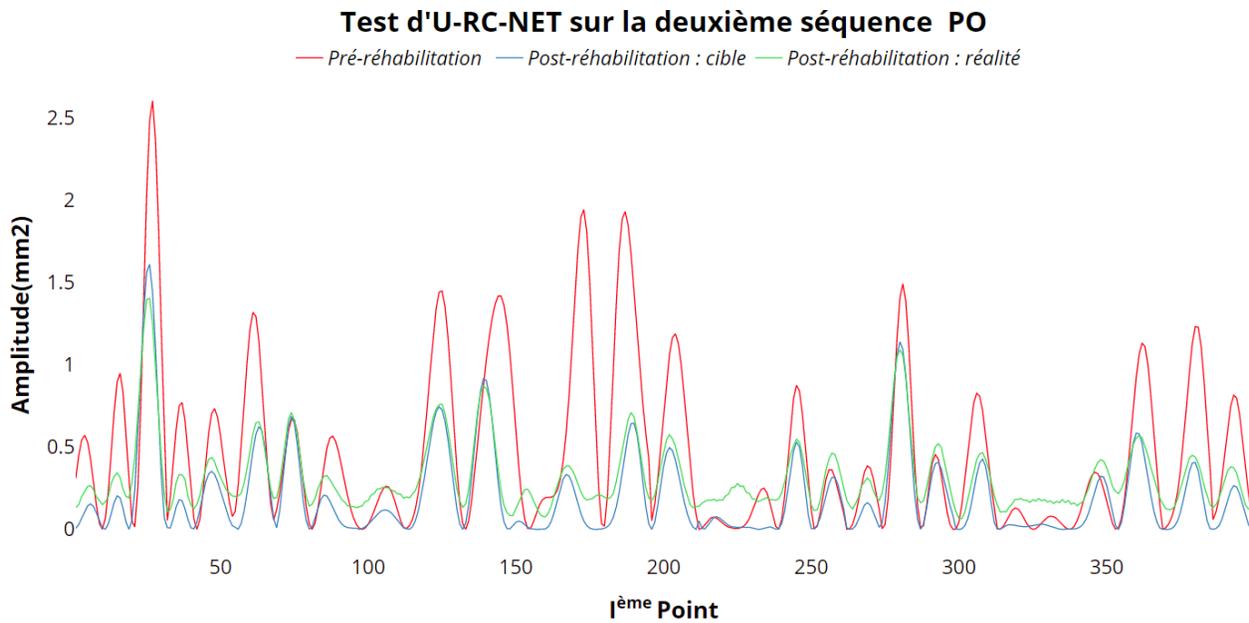
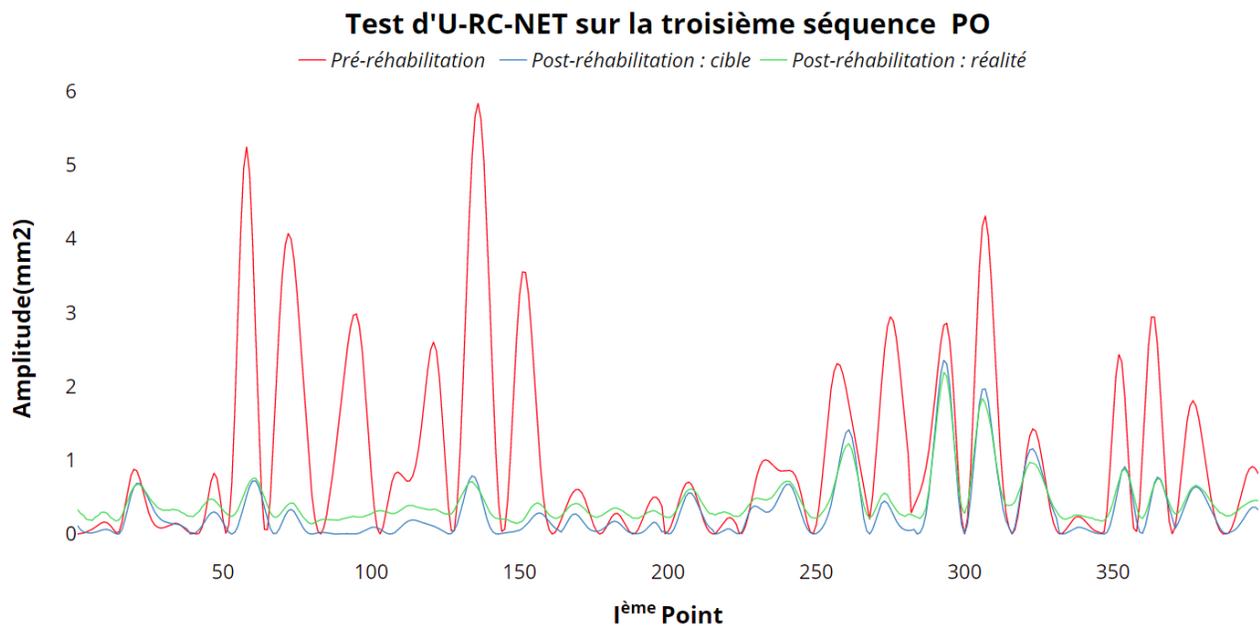
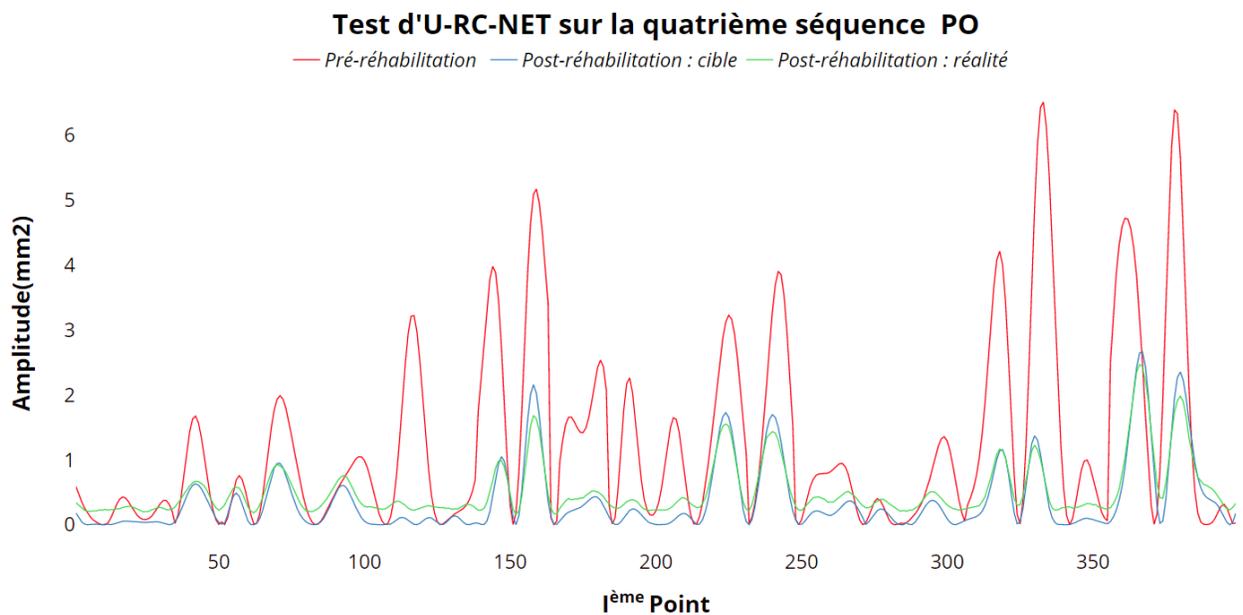


FIGURE 4.25 – Test d'U-RC-NET_{PO} sur la deuxième séquence PO.

FIGURE 4.26 – Test d'U-RC-NET_{PO} sur la troisième séquence PO.FIGURE 4.27 – Test d'U-RC-NET_{PO} sur la quatrième séquence PO.

les mêmes blocs monolithiques). Ensuite, les énergies des séquences prédites seront comparées avec leurs cibles correspondantes pour évaluer la pertinence et la précision de ces prédictions. En ce qui concerne la forme des prédictions, les séquences prédites ainsi que leurs cibles partagent la même segmentation en termes de blocs monolithiques, comme le montrent les figures 4.15 - 4.27. Cela indique que l'architecture développée de ce RCNN fournit des prédictions significatives des évolutions énergétiques. En fait, le modèle prédit les empreintes énergétiques des irrégularités géométriques post-réhabilitation en identifiant les voisinages monolithiques significatifs de la séquence d'entrée dans un premier temps, pour ensuite faire évoluer leurs amplitudes ainsi que leurs étendues. Ainsi, pour chacune des trois bandes d'ondes, les dépendances multi-niveaux entre les empreintes énergétiques préexistantes, et leurs équivalentes dans les séquences post-réhabilitation prédites, sont bien préservées indépendamment de leurs résolutions (étendue et amplitude). Il est à noter que les limites des métriques de régression habituelles (qui sont principalement basées sur le calcul point à point), telles que la MAE ou la MSE, sont confirmées dans le cas de problèmes de prédiction basés sur la forme. Par exemple, au niveau des GO, l'erreur Soft-DTW de la prédiction n°2 est inférieure à celle de la prédiction n°3. Ainsi, en termes d'appariement des formes à leurs cibles, cela indique que la deuxième séquence est plus précise que la troisième. Cependant, les MSE et MAE de la prédiction n°2 sont plus élevés que ceux de la prédiction n°3. La même discordance peut être confirmée en étendant cette évaluation aux bandes d'ondes moyennes et courtes.

Quant à l'évaluation de la précision énergétique des séquences prédites, les valeurs d'EEA affichées restent comparables au sein de chacune des trois bandes d'ondes, ce qui indique que la capacité de généralisation du modèle reste stable. La seule exception qui doit être mentionnée est la séquence prédite n°5 de la bande d'onde longue, où l'AEE atteint 1225.31 cm^3 . Cette valeur élevée s'explique par la sous-estimation de l'amplitude de l'une des principales empreintes énergétiques de la séquence, où l'erreur résiduelle maximale de 135.59 mm^2 se produit. Par conséquent, cette seule sous-estimation provoque l'augmentation de toutes les mesures d'erreur de la séquence. Cependant, au-delà de ce cas spécifique, les autres irrégularités géométriques de la séquence sont significativement précises où la MDE est aussi faible que 3.27 mm^2 . Globalement, les AEE moyennes sur les GO, MO et PO sont respectivement 241.02 cm^3 , 45.47 cm^3 et 2.54 cm^3 . Ces valeurs d'AEE se traduisent par des N comparables dans la même bande d'ondes où l'erreur de note moyenne est aussi faible que 0.308 sur la bande des GO, 0.32 sur la bande des MO et 0.76 sur la bande des PO.

Pour comparer les performances du modèle sur les trois bandes d'ondes, nous considérons le REE qui calcule l'erreur d'énergie de la séquence prédite par rapport à l'échelle d'énergie de chaque bande d'ondes. Les résultats des tests montrent que le REE maximale est de 26.4% dans la bande GO 19.71 % dans la bande MO et 36.95 dans la bande PO, atteignant une erreur moyenne de 12.85 % dans la bande GO, 13.25% dans la bande MO et 29.895 % dans la bande PO.

En détail, pour le test GO, en excluant le cas précédemment détaillé de la séquence n°5, les autres prédictions sont significativement précises lorsque le REE est aussi bas que 3.8 % donnant une moyenne de 9.465 %. La même précision est confirmée sur le test MO, où

la moyenne des REE est de 13.25 % avec un maximum de 19.71 %. Pour le test PO, les performances du modèle sont moins précises puisque le REE maximum atteint de 36.95 % avec une moyenne de 29.895 %. Grâce à la visualisation des données, cette baisse de performance est due à l'apparition d'une composante continue dans la sortie autour de 0.2 mm^2 . Ainsi, tous les détails en dessous de ce seuil ne sont pas prédits mais plutôt surévalués par cette composante continue. Cela provoque une augmentation systématique de l'énergie des séquences prédites. L'apparition de la composante continue traduit donc une incapacité du modèle à estimer les faibles amplitudes sur cette bande d'ondes : en effet, cette incapacité du modèle s'explique par la disparition des faibles amplitudes de l'entrée en raison des maxpoolings successifs dans chacune des couches du chemin de contraction. Par conséquent, et à la fin de l'encodeur composé de 3 couches, une séquence d'entrée composée de 400 points sera réduite à une forme excessivement simpliste ne fournissant aucune information sur ces basses amplitudes et donc, la cellule LSTM ne prédira que l'évolution des hautes amplitudes restantes. Certes, les basses amplitudes ne seront pas complètement perdues puisqu'elles seront transmises au chemin expansif par des connexions de saut. Cependant, la tâche principale de chaque couche de sur-échantillonnage de ce chemin expansif est d'augmenter la résolution de sa sortie précédente tout en tenant compte des informations des skip-connexions. En d'autres termes, ces faibles amplitudes ne seront prises en compte qu'à titre de référence et à un stade avancé du processus. Pour compenser cette incapacité, le modèle introduit cette composante continue pour minimiser l'impact des faibles amplitudes sur la mesure de l'erreur pendant l'apprentissage. Ceci explique donc la baisse de performance d'U-RC-NET sur les PO par rapport à celles sur les MO et les GO.

4.5 Conclusion

L'objectif de ce chapitre est de développer un modèle qui reconnaît la segmentation des séquences pré-réhabilitation par blocs monolithiques, pour ensuite prédire leurs évolutions suite à la réhabilitation en estimant leurs atténuations en fonction de leurs formes. Pour ce faire, nous proposons une architecture innovante d'un modèle RCNN implémentée avec la fonction Soft-DTW comme métrique d'apprentissage : l'U-RC-NET. Ce modèle se compose de trois blocs principaux : le premier bloc est un encodeur qui extrait les caractéristiques des séquences d'entrée tout en réduisant leurs résolutions spatiales, à travers une succession de couches de convolution et de maxpooling. Le deuxième bloc est une cellule LSTM qui génère un noyau de la séquence prédite. Enfin, le troisième bloc est le décodeur où le même niveau de résolution de la séquence d'entrée est retrouvé en appliquant de manière répétée un sur-échantillonnage par convolution transposée qui double la taille de leurs séquences d'entrée, et qui divise également par deux leurs nombres de cartes de caractéristiques, suivi d'une concaténation avec la carte de caractéristiques correspondante provenant du bloc contractant. Cette concaténation est rendue possible grâce à des "skip-connexions" permettant au réseau de propager des caractéristiques de plus haute résolution de la voie de contraction à

la voie d'expansion et donc d'augmenter significativement la résolution de la sortie.

Appliqué aux données mesurées selon la méthodologie précédemment détaillée, l'U-RC-Net prédit l'évolution de l'uni par bandes d'ondes en identifiant les empreintes énergétiques des traces résiduelles préexistantes sous leurs différentes formes possibles dans les séquences pré-réhabilitation d'entrée, et en extrayant leurs caractéristiques sous différents niveaux de résolutions pour estimer, ensuite, leurs évolutions. D'après les résultats des tests, le modèle affiche des performances remarquables sur les GO et MO. Cependant, pour les PO, les résultats du modèle sont moins précis mais restent acceptables en termes de notes. Cette baisse de performance s'explique par la disparition des défauts ayant des faibles amplitudes dans les séquences d'entrée, en raison du maxpooling successif dans chacune des couches de l'encodeur.

Une solution à ce problème pourrait être de réduire la profondeur du chemin de contraction pour éviter la sursimplification des faibles amplitudes dans les séquences d'entrée PO. Cette réduction de la profondeur doit être entreprise tout en respectant le compromis entre la capacité d'extraction de caractéristiques selon différents niveaux de résolution, qui nécessite un chemin de contraction à couches suffisantes, et celle de la sursimplification, puisqu'un grand nombre de couches de convolution et de maxpooling fait disparaître les faibles amplitudes dans les séquences PO.

De plus, une solution alternative pourrait être d'utiliser une concaténation déséquilibrée, en combinant les convolutions transposées des caractéristiques avec celles des skip-connexions, pour obliger le décodeur à allouer plus d'importance aux caractéristiques à haute résolution provenant du chemin contractant.

Conclusion générale et perspectives

Au terme de cette thèse, nous allons dresser un bilan général des travaux présentés dans ce mémoire, et nous efforcer de dégager des réflexions utiles aux orientations futures.

Ce travail de thèse s'ouvre sur une analyse exploratoire des caractéristiques du profil de la chaussée pour ensuite mettre en évidence les mécanismes de son évolution. Cette analyse démontre que les défauts relevés sont caractérisés par différents ordres d'énergie, variant de 10 cm^3 à 30000 cm^3 , et d'étendues pouvant atteindre 60 m . Ce contraste d'amplitude et d'étendue est problématique pour la prédiction du profil post-réhabilitation, puisque les méthodes d'apprentissage supervisé ont un biais vers les basses fréquences. Afin d'éviter ce biais, et pour assurer un apprentissage qui couvre tous les types de défauts préexistants, il convient de décomposer les profils mesurés en différentes bandes d'ondes, dans lesquelles le contraste de fréquence est réduit, et de dédier un modèle à chaque bande d'ondes. Dans l'ensemble, ce travail pourrait servir de point de départ à la compréhension de la composition des profils de chaussée et leurs modes d'évolution selon trois niveaux de granularité : les profils mesurés, les signaux filtrés par bandes d'ondes et les notes par bandes d'ondes pré- et post-réhabilitation.

Ensuite, la méthodologie de la prédiction des profils post-réhabilitation suivie dans cette thèse est présentée. Sa première étape consiste à préparer les profils pour réduire les incohérences entre les mesures pré- et post-réhabilitation. En effet, dans le cas des données d'uni, des facteurs incontrôlables sur le terrain peuvent mener à des données partiellement incohérentes ou non pertinentes. Par exemple, la mesure longitudinale de l'uni entraîne des incohérences de superposition entre les profils pré- et post-réhabilitation : (i) les origines et les fins des deux signaux peuvent ne pas se superposer, (ii) la variation de la vitesse du véhicule pendant la mesure peut introduire une distorsion pathologique des signaux. En outre, divers imprévus peuvent survenir au cours du processus de réhabilitation, entraînant une détérioration imprévisible de l'uni. Ainsi, dans cette première partie préparatoire, nous proposons l'ensemble de procédures correctives suivi pour résoudre ces problèmes. La deuxième étape du pré-traitement des données est celle du filtrage en bandes d'ondes, où les signaux mesurés sont décomposés en trois bandes d'ondes : petites ondes - PO ($0.707 < \lambda(m) < 2.828$), moyennes ondes - MO ($2.828 < \lambda(m) < 11.312$) et grandes ondes - GO ($11.312 < \lambda(m) < 45.248$). Finalement, la dernière étape du pré-traitement est celle de l'organisation de données.

A ce niveau, deux schémas peuvent être distingués selon l'approche d'apprentissage supervisé choisie : une première qui consiste à construire les signaux post-réhabilitation des trois bandes d'ondes point par point et une deuxième qui le fait séquence par séquence. Le confrontation de ces schémas prouve que l'approche séquence par séquence est celle qui démontre un potentiel à reconstituer les signaux post-réhabilitation en suivant le mécanisme d'évolution physique d'évolution de l'uni, à savoir former les séquences prédites en estimant successivement l'évolution des traces résiduelles pré-réhabilitation. Ainsi, les données des trois bandes d'ondes sont segmentées pour obtenir des séquences unitaires dont les longueurs sont : 20 *m* (400 points) pour les PO, 100 *m* (2000 points) pour les MO et 200 *m* (4000 points) pour les GO.

Finalement, nous proposons une nouvelle modélisation capable de reconnaître la segmentation des séquences pré-réhabilitation par blocs monolithiques (traces résiduelles), pour ensuite prédire leurs évolutions suite à la réhabilitation en estimant leurs atténuations en fonction de leurs formes. Pour ce faire, nous présentons une architecture innovante d'un modèle RCNN : l'U-RC-NET. En effet, trois blocs principaux organisent le modèle développé : le premier bloc est un encodeur qui extrait les caractéristiques des séquences d'entrée tout en réduisant leurs résolutions spatiales, à travers une succession de couches de convolution et de maxpooling. Le deuxième bloc est une cellule LSTM qui génère un noyau de la séquence prédite. Enfin, le troisième bloc est le décodeur où le même niveau de résolution de la séquence d'entrée est retrouvé en appliquant de manière répétée un sur-échantillonnage par convolution transposée qui double la taille de leurs séquences d'entrée, et qui divise également par deux leurs nombres de cartes de caractéristiques, suivi d'une concaténation avec la carte de caractéristiques correspondante provenant du bloc contractant. Cette concaténation est rendue possible grâce à des "skip-connexions" permettant au réseau de propager des caractéristiques de plus haute résolution de la voie de contraction à la voie d'expansion et donc d'augmenter significativement la résolution de la sortie. Pour forcer le modèle à constituer les séquences prédites en estimant l'amélioration de chacune des formes (traces résiduelles) pré-réhabilitation présentes dans les séquences d'entrée, la fonction perte choisie pour l'apprentissage du modèle U-RC-NET est la Soft-DTW normalisée. Ce choix permettra au modèle de traduire les mécanismes physiques d'évolution de l'uni en se focalisant sur des prédictions basées sur la forme dès son entraînement.

Appliqué aux données mesurées selon la méthodologie précédemment détaillée, l'U-RC-Net prédit l'évolution de l'uni par bandes d'ondes en identifiant les traces résiduelles préexistantes sous leurs différentes formes possibles dans les séquences pré-réhabilitation d'entrée, et en extrayant leurs caractéristiques sous différents niveaux de résolutions pour estimer, ensuite, leurs évolutions. D'après les résultats des tests, le modèle affiche des performances remarquables, notamment sur les GO et MO.

le fort intérêt présenté, dans notre travail, par les données mesurées pré- et post-réhabilitation nous amène maintenant à évoquer les perspectives à envisager.

En premier lieu, la recherche d'une validation complète du modèle doit être poursuivie. En particulier, les données traitées dans ces travaux découlent exclusivement d'un chantier de

réhabilitation par un rechargement de 4 cm de BBDr. Ce choix a été motivé par la nécessité d'assurer le plus grand jeu de données possible qui représente un procédé d'application homogène parmi les chantiers disponibles. Cependant, compte tenu de ses premières performances encourageantes, il convient de le consolider l'apprentissage de l'U-RC-Net sur un jeu de données plus conséquent pour inclure les multiples scénarios de réhabilitation possibles. Ainsi, il convient d'élaborer une base de données "Profils pré- et post-réhabilitation - Variables d'environnement", où ce travail tirera profit du savoir-faire et des outils d'organisation et d'analyse des données d'auscultation présenté dans ce mémoire : le but est d'associer dans un premier temps selon un protocole unifié les mesures standardisées des profils à celles de paramètres d'environnement qui caractérisent chaque projet de réhabilitation de la chaussée. La deuxième phase consistera à intégrer, à la base de données, les mesures issues au fil de l'eau (selon le protocole unifié) de chantiers de réhabilitation. Les outils présentés du pré-traitement de données seront alors utilisés pour fiabiliser la base de données et éventuellement identifier des améliorations à apporter au protocole du pré-traitement.

A l'issue de l'élaboration de cette base de données, la construction et validation des variables explicatives peuvent commencer. En effet, les nombreux paramètres d'environnement impactant les résultats des travaux en termes d'uni longitudinal sont hétérogènes (impliquant des physiques différentes, pouvant être pour partie couplées) et leurs incidences sur les résultats des travaux peuvent être fortement non linéaires. En outre, selon les circonstances, un paramètre important dans une situation peut devenir secondaire dans une autre. Ainsi, il est possible que quelques paramètres d'environnement puissent être fortement dépendants / corrélés pour permettre de construire / extraire un paramètre unifié représentatif d'une classe de paramètres et donc assurer une réduction de la dimensionnalité et une sélection de variables explicatives plus pertinente.

Pour ce faire, l'approche des "wrappers" peut être suivie : le principe est de générer des sous ensembles candidats et de les évaluer grâce à un modèle d'apprentissage choisi (l'U-RC-NET dans notre cas). En effet, cette évaluation se base sur un calcul d'un score, qui peut être par exemple sous forme d'un compromis entre le nombre de variables éliminées et la soft-DTW qui mesure la performance du modèle sur les données test. Ainsi, un mécanisme de validation croisée est utilisé où à chaque sélection d'une variable, le modèle est appelé pour évaluer sa performance et juger donc la pertinence d'une caractéristique. En d'autres termes, le principe de wrappers est de générer un sous ensemble de variables bien adaptés à un modèle d'apprentissage prédéfini. Cette méthode permet d'améliorer les performances du modèle choisi puisque les variables d'environnement sont affinées en prenant en compte son biais intrinsèque. Toutefois, cette méthode ne procure pas de justification théorique à la sélection des variables et ils ne nous permettent pas de comprendre les relations de dépendances conditionnelles qu'il peut y avoir entre les variables. D'autre part, la procédure de sélection est spécifique à un modèle de particulier et les sous ensembles trouvés ne sont pas forcément valides si la méthode d'apprentissage est changée.

Pour introduire plus de sens dans la sélection des variables, nous proposons une approche plus complète où les paramètres d'environnement jugés les plus significatifs par l'homme

de l'art seront considérés comme corpus initial. Dans un premier temps, des analyses de corrélations seront réalisées pour construire des méta-variables pouvant définir des classes de paramètres d'environnement et continuer à avoir un sens pour l'homme de l'art : par exemple, une seule variable de performance qui puisse concaténer l'expérience de l'opérateur et la performance du matériel. Dans un deuxième temps, des analyses de réduction de dimensions seront opérées pour éviter des distributions de données éparses pour les variables explicatives ainsi construites, pour former un premier . Ensuite, la phase de validation des choix de variables explicatives s'appuiera sur le recours à l'approche "wrappers", en générant des sous ensembles candidats du corpus construit et les évaluer grâce à l'U-RC-NET selon le mécanisme de validation croisée. Cette phase, peut donner lieu à des ajustements ou à choix alternatifs des variables explicatives qui seront à nouveau soumise à l'évaluation de l'homme de l'art puis évaluer selon l'approche ci-dessus.

Annexe A

Filtrage par bandes d'ondes

Contrairement aux filtres analogiques qui sont réalisés à l'aide d'un agencement de composants physiques (résistance, condensateur, inductance), les filtres numériques réalisent théoriquement la totalité des effets de filtrage par des fonctions mathématiques. En effet, tout filtre numérique d'ordre N peut être décrit dans le domaine discret (temporel) avec l'équation A.1.

$$y_i = \sum_{k=0}^M b_k x_{i-k} - \sum_{k=1}^N a_k y_{i-k} \quad (\text{A.1})$$

où x est le signal d'entrée, y est le signal de sortie (filtré) et les $[(a_k), (b_k)]$ sont les coefficients qui définissent le filtre.

Ainsi, le filtre s'applique à l'ensemble du signal et non seulement à l'échantillon en cours. En d'autres termes, pour obtenir une valeur du signal filtré, plusieurs points sont considérés en les pondérant par des coefficients de filtrage. La nature des points considérée permet de distinguer deux types de filtrage : les filtres à réponse impulsionnelle finie (RIF) et les filtres à réponse impulsionnelle (RII).

Pour les filtres RIF, la réponse se base uniquement sur un nombre fini de valeurs du signal d'entrée (appelé l'ordre du filtre). Par conséquent, un filtre RIF d'ordre M se définit comme une somme linéaire pondérée de M points du signal d'entrée comme l'indique l'équation A.2.

$$y_i = \sum_{k=0}^M b_k x_{i-k} \quad (\text{A.2})$$

Contrairement à celle du filtre RIF, la réponse du filtre RII ne dépend pas que des valeurs du signal d'entrée mais aussi des valeurs antérieures de sa réponse (cf. équation A.3), comme les filtres Butterworth qui seront utilisés dans cette thèse pour la décomposition des mesures profilométriques en trois bandes d'ondes GO, MO et PO.

$$y_i = \sum_{k=0}^M b_k x_{i-k} - \sum_{k=1}^M a_k y_{i-k} \quad (\text{A.3})$$

La décomposition de la mesure en trois bandes d'ondes peut être réalisée grâce des filtres passe-bande, où chaque filtre ne laisse passer que la bande comprise entre ces deux fréquences de coupure. Or, cette méthode de filtrage reste instable, peu précise et risque d'engendrer des distorsions dans les signaux filtrés, altérant ainsi la superpositions des traces résiduelles pré- et post-réhabilitation . Par conséquent, la décomposition en bande d'ondes suivie dans cette thèse se base sur un filtrage successif par filtres passe-bas plus stables [150]. En effet, pour extraire la bande d'ondes définie entre les deux longueurs d'ondes λ_1 et λ_2 , la décomposition ci-dessous a été suivie :

1. Filtrer le profil mesuré par un premier filtre de Butterworth passe-bas dont la longueur de coupure est λ_1
2. Filtrer le profil mesuré par un deuxième filtre de Butterworth passe-bas dont la longueur de coupure est λ_2
3. Calculer la différence entre le résultat du premier filtrage et celui du deuxième filtrage, pour extraire la bande définie entre λ_1 et λ_2 .

La décomposition des profils en trois bandes d'ondes suit ce même enchaînement en adaptant à chaque fois λ_1 et λ_2 aux longueurs d'ondes qui définissent les GO, MO et PO.

Dans ce qui suit, la description des filtres Butterworth utilisés suivra les conventions du traitement habituelles, à savoir la transformée de Laplace de sa fonction de transfert normalisée $H(z)$ comme l'indique l'équation A.4.

$$H(z) = \frac{Y(z)}{X(z)} = \frac{b_0 + b_1z^{-1} + \dots + b_mz^{-m}}{1 + a_1z^{-1} + \dots + a_nz^{-n}} \quad (\text{A.4})$$

où X est la transformée de Laplace du signal d'entrée, y est la transformée de Laplace du signal de sortie (filtré) et n est l'ordre du filtre.

Ainsi, les coefficients qui seront détaillés dans ce qui suit peuvent être retrouvés en utilisant la fonction "filtfilt" sur Matlab ou celle de la conception des filtres sur Labview, en supposant que la pas d'échantillonnage est de 5 cm :

Numérateur	Dénominateur
2, 14529801577021.10 ⁻⁶	1
17, 16238412616169.10 ⁻⁶	-5,7242226208025686
60, 06834444156591.10 ⁻⁶	14,58145031328104
120, 13668888313182.10 ⁻⁶	-21,537527317629245
150, 17086110391477.10 ⁻⁶	20,139632615427132
120, 13668888313182.10 ⁻⁶	-12,191803302114604
60, 06834444156591.10 ⁻⁶	4,6608025372476556
17, 16238412616169.10 ⁻⁶	-1,0278051611001193
2, 14529801577021.10 ⁻⁶	0,1000221319827452

TABLE A.1 – Les coefficients du filtre passe-bas limité à $\lambda_1 = 0.707$ m (Butterworth d'ordre 8)

Numérateur	Dénominateur
68, 70180553.10 ⁻¹²	1
549, 61444423.10 ⁻¹²	-7,4306085596572169
1923, 65055482.10 ⁻¹²	24,175130708312153
3847, 30110964.10 ⁻¹²	-44,978754448661576
4809, 12638705.10 ⁻¹²	52,3418378405241
3847, 30110964.10 ⁻¹²	-39,0107816193456
1923, 65055482.10 ⁻¹²	18,184703074245409
549, 61444423.10 ⁻¹²	-4,8471638604738629
68, 70180553.10 ⁻¹²	0,56563688264425616

TABLE A.2 – Les coefficients du filtre passe-bas limité à $\lambda_2 = 2.828$ m (Butterworth d'ordre 8)

Numérateur	Dénominateur
1, 2797761878.10 ⁻⁹	1
8, 95843331461.10 ⁻⁹	-6,5008074238777498
26, 87529994383.10 ⁻⁹	18,128343066119079
44, 79216657305.10 ⁻⁹	-28,11014538461913
44, 79216657305.10 ⁻⁹	26,175397507756664
26, 87529994383.10 ⁻⁹	-14,63648503523595
8, 95843331461.10 ⁻⁹	4,5504954916545053
1, 2797761878.10 ⁻⁹	-0,60679805798606612

TABLE A.3 – Les coefficients du filtre passe-bas limité à $\lambda_1 = 2.828$ m (Butterworth d'ordre 7)

Numérateur	Dénominateur
93, 55624.10 ⁻¹⁵	1
654, 89367.10 ⁻¹⁵	-6,8751933778374745
1964, 68102.10 ⁻¹⁵	20,258931436785097
3274, 46837.10 ⁻¹⁵	-33,166446092752317
3274, 46837.10 ⁻¹⁵	32,580346116749226
1964, 68102.10 ⁻¹⁵	-19,203775331356002
654, 89367.10 ⁻¹⁵	6,2887997685528836
93, 55624.10 ⁻¹⁵	-0,88266252012943813

TABLE A.4 – Les coefficients du filtre passe-bas limité à $\lambda_2 = 11.312$ m (Butterworth d'ordre 7)

Numérateur	Dénominateur
6, 79745149.10 ⁻¹²	1
40, 78470894.10 ⁻¹²	-5,8926970878872194
101, 96177236.10 ⁻¹²	14,469227251620786
135, 94902981.10 ⁻¹²	-18,949743931136801
101, 96177236.10 ⁻¹²	13,960843524977586
40, 78470894.10 ⁻¹²	-5,4858787617673777
6, 79745149.10 ⁻¹²	0,89824900462806312

TABLE A.5 – Les coefficients du filtre passe-bas limité à $\lambda_1 = 11.312$ m (Butterworth d'ordre 6)

Numérateur	Dénominateur
1, 71738.10 ⁻¹⁵	1
10, 30426.10 ⁻¹⁵	-5,9731741134704492
25, 76064.10 ⁻¹⁵	14,866230144781298
34, 34752.10 ⁻¹⁵	-19,733176391096528
25, 76064.10 ⁻¹⁵	14,733889456574856
10, 30426.10 ⁻¹⁵	-5,8672997515712346
1, 71738.10 ⁻¹⁵	0,97353065478216805

TABLE A.6 – Les coefficients du filtre passe-bas limité à $\lambda_2 = 45.248$ m (Butterworth d'ordre 6)

Annexe B

Étude paramétrique

Un hyperparamètre est un paramètre de l'algorithme d'apprentissage, et non pas un paramètre du modèle. En d'autres termes, il ne fait pas partie des paramètres à optimiser lors de l'apprentissage du modèle. Ainsi, l'ensemble des hyperparamètres est passé comme arguments (valeurs d'entrée) lors de l'implémentation des modèles avant de lancer leurs apprentissages. Les exemples typiques sont C, kernel et gamma pour les SVR ou alpha pour le Lasso. Toutefois, l'ensemble des hyperparamètres de chaque modèle reste à affiner afin d'améliorer ses performances sur l'ensemble des données d'apprentissage.

Dans cette étude, les hyperparamètres des modèles point par point (cf. Section 3.4.1) sont affinés à l'aide de la fonction "GridSearchCV" proposée par Scikit-learn sur Python. Cette fonction procède à une recherche exhaustive sur les valeurs des paramètres spécifiés pour un modèle donné. En effet, la recherche par grille fournie par GridSearchCV génère de manière exhaustive les combinaisons possibles à partir d'une grille de valeurs d'hyperparamètres spécifiées avec l'argument *param_grid*. Ainsi, la fonction GridSearchCV lance l'apprentissage du modèle : lors de son "ajustement" sur un ensemble de données, toutes les combinaisons possibles de valeurs de paramètres sont évaluées et la meilleure combinaison est retenue (celle qui minimise la fonction).

Ainsi, à l'aide de la fonction "GridSearchCV", les hyperparamètres nécessaires à l'implémentation des modèles point par point sont affinés de manière à minimiser la MSE sur leurs données d'entraînement et de test.

Les grilles des hyperparamètres parcourues se composent des intervalles suivants :

Pour les K-plus proches voisins (KNN) :

- La distance selon laquelle la similarité entre les observations est quantifiée = { 'minkowski (p=1)', 'minkowski(p=2)', 'minkowski(p=3)', 'minkowski(p=4)'}
— Le nombre d'observations les plus proches à prendre en considération lors du calcul de la moyenne = { 1, 5, 25, 125}
- La pondération de la moyenne = { 'uniform', 'distance'}

Pour les machines à vecteurs de support pour régression (SVR) :

- Le coefficient de régularisation $C = \{ 1, 10, 100, 1000 \}$.
- Le seuil de précision $\epsilon = \{ 1e-1, 1e-2, 1e-3, 1e-4, 1e-5 \}$.
- La fonction noyau $K = \{ \text{'linear'}, \text{'poly'}, \text{'rbf'}, \text{'sigmoid'} \}$.

Pour les forêts aléatoires :

- Le nombre d'arbres binaires = $\{ 10, 100, 1000, 10000 \}$
- Le nombre minimum d'échantillons requis pour arriver à un noeud feuille = $\{ 1, 2, 3, 4 \}$
- Le nombre de variables explicatives = $\{ \text{'sqrt'}, \text{'log2'}, \text{'auto'} \}$

Pour les arbres à gradient adaptatif (G-TB) :

- Le taux d'apprentissage $\gamma_m = \{ 0.0001, 0.001, 0.01, 0.1, 0.2, 0.3 \}$.
- Le nombre d'estimateurs = $\{ 10, 100, 1000, 10000 \}$
- Profondeur maximale des arbres de régression individuels = $\{ 2, 5, 10, 20 \}$
- La fraction des échantillons à utiliser à chaque itération d'entraînement = $\{ 0.5, 0.6, 0.7, 0.8, 0.9 \}$

Bibliographie

- [1] O. Kropáč and P. Múčka, “Indicators of Longitudinal Road Unevenness and their Mutual Relationships,” *Road Materials and Pavement Design*, vol. 8, pp. 523–549, Jan. 2007. Publisher : Taylor & Francis <https://doi.org/10.1080/14680629.2007.9690087>.
- [2] B. Robert, E. Delaval, J. M. Martin, and M. Boulet, *Mesure de l’uni longitudinal des chaussées routières et aéronautiques : Exécution et exploitation des relevés profilométriques : Méthode d’essai n°46, Version 2.0*. Laboratoire Central des Ponts et Chaussées (LCPC), 2009.
- [3] B. Pouteau, *Durabilité mécanique du collage blanc sur noir dans les chaussées*. These de doctorat, 2004.
- [4] P. Dunez, G. Priolet, F. Ledee, Y. Pichaud, L. Segaud, L. Toussaint, and R. Durang, *Méthode d’essai des lpc n°63 : Mesure en continu du bruit de contact pneumatique / chaussée*. Laboratoire Central Ponts Et Chaussees (LCPC), 2008.
- [5] S. Misaghi, C. Tirado, S. Nazarian, and C. Carrasco, “Impact of pavement roughness and suspension systems on vehicle dynamic loads on flexible pavements,” *Transportation Engineering*, vol. 3, Mar. 2021.
- [6] J. Gregory, “Pavement-related research at the MIT concrete sustainability hub,” *Iowa Concrete Paving Association 51 st Annual Concrete Paving Workshop*, Feb. 2015.
- [7] A. Gourimate, “Amélioration d’uni longitudinal.” Institut National des Sciences Appliquées de Rennes. Rapport de projet de fin d’études. Juin. 2018.
- [8] “Unibox : un dispositif économique pour le suivi de l’uni longitudinal des chaussées.” <https://lames.univ-gustave-eiffel.fr/materiels-et-logiciels/unibox>.
- [9] O. Kropáč and P. Múčka, “Relations between characteristics of longitudinal unevenness : a review,” *Strojnícky casopis – Journal of Mechanical Engineering*, vol. 54, pp. 49–64, Jan. 2003.
- [10] F. Menant, *Estimation de l’uni longitudinal des infrastructures routières au moyen de véhicules traceurs : développements méthodologiques et expérimentations*. These de doctorat, Ecole Centrale de Nantes, Jan. 2014.

- [11] A. C. Müller and S. Guido, *Introduction to Machine Learning with Python : A Guide for Data Scientists*. O'Reilly Media, 1er édition ed., Sept. 2016.
- [12] A. Singh, V. Kotiyal, S. Sharma, J. Nagar, and C.-C. Lee, “A Machine Learning Approach to Predict the Average Localization Error With Applications to Wireless Sensor Networks,” *IEEE Access*, vol. 8, pp. 208253–208263, Nov. 2020.
- [13] A. Géron, *Hands-On Machine Learning with Scikit-Learn and TensorFlow*. O'Reilly Media Inc, Mar. 2017.
- [14] Wikistat, “Arbres binaires de décision — wikistat.” <http://wikistat.fr/pdf/st-m-explo-classif.pdf>. Mise en ligne le 21-janvier-2016.
- [15] A. Géron, *Deep Learning avec TensorFlow*. Dunod, Nov. 2017.
- [16] A. Karpathy, G. Toderici, S. Shetty, T. Leung, R. Sukthankar, and L. Fei-Fei, “Large-scale video classification with convolutional neural networks,” in *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, pp. 1725–1732, 2014.
- [17] V. L. Guen and N. Thome, “Shape and Time Distortion Loss for Training Deep Time Series Forecasting Models,” Tech. Rep. arXiv :1909.09020, arXiv, Nov. 2019. arXiv :1909.09020 [cs, stat] type : article.
- [18] A. Al-Jawad, M. R. Adame, M. Romanovas, M. Hobert, W. Maetzler, M. Traechter, K. Moeller, and Y. Manoli, “Using multi-dimensional dynamic time warping for tug test instrumentation with inertial sensors,” in *IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI)*, pp. 212–218, 2012.
- [19] *Uni longitudinal - État de l'art et recommandations*. Cerema, Sept. 2014.
- [20] *Circulaire N°2000-36 relative au contrôle de l'uni longitudinal des couches de roulement neuves*. Ministère de l'équipement, des transports et du logement. 2000.
- [21] B. Ciavola and A. Mukherjee, “Empirical assessment of Pavement Roughness to Estimate pavement life cycle Use-Phase Emissions,” 2015.
- [22] P. Lu, “Pavement Pre- and Post- Treatment Performance Models using LTPP Data,” *Journal of the Transportation Research Forum*, vol. 51, pp. 67–81, Oct. 2012.
- [23] M. F. Saleh, M. S. Mamlouk, and E. B. Owusu-Antwi, “Mechanistic Roughness Model Based on Vehicle-Pavement Interaction,” *Transportation Research Record*, vol. 1699, pp. 114–120, Jan. 2000. Publisher : SAGE Publications Inc.
- [24] R. W. Perera and A. Al-Rawashdeh, “Investigation of Increase in Roughness Due to Environmental Factors in Flexible Pavements Using Profile Data from Long-Term Pavement Performance Specific Pavement Studies 1 Experiment,” Oct. 2017. Number : HRT-17-049.

- [25] G. W. Flintsch and C. Chen, “Soft Computing Applications in Infrastructure Management,” *Journal of Infrastructure Systems*, vol. 10, pp. 157–166, Dec. 2004.
- [26] N. O. Attoh-Okine, “Predicting roughness progression in flexible pavements using artificial neural networks,” in *Transportation Research Board Conference Proceedings*, vol. 1, 1994. ISSN : 1073-1652 Issue : 1.
- [27] N. Kargah-Ostadi, S. M. Stoffels, and N. Tabatabaee, “Network-level pavement roughness prediction model for rehabilitation recommendations,” *Transportation Research Record*, vol. 2155, pp. 124–133, Jan. 2010. Publisher : SAGE Publications Inc.
- [28] M. Mazari and D. D. Rodriguez, “Prediction of pavement roughness using a hybrid gene expression programming-neural network technique,” *Journal of Traffic and Transportation Engineering (English Edition)*, vol. 3, pp. 448–455, Oct. 2016.
- [29] *Conception et dimensionnement des structures de chaussée*. Service d’Etudes sur les Transports, les Routes et leurs Aménagements (SETRA) and Laboratoire Central Ponts Et Chaussées (LCPC). 1994.
- [30] *Rapport sur le développement dans le monde : Une infrastructure pour le développement*. International Bank for Reconstruction and Development. 1994.
- [31] D. A. Aschauer, “Genuine Economic Returns to Infrastructure Investment,” *Policy Studies Journal*, vol. 21, pp. 380–390, June 1993.
- [32] *Rapport sur le développement dans le monde : 1990*. Paris : Economica. OCLC : 22471034, International Bank for Reconstruction and Development. 1990.
- [33] I. M. Asi, “Evaluating skid resistance of different asphalt concrete mixes,” *Building and Environment*, vol. 42, pp. 325–329, Jan. 2007.
- [34] J. M. Pardillo Mayora and R. Jurado Piña, “An assessment of the skid resistance effect on traffic safety under wet-pavement conditions,” *Accident Analysis & Prevention*, vol. 41, pp. 881–886, July 2009.
- [35] A. Savkoor, “Paper viii (iii) tribology of tyre traction on dry and wet roads,” in *Vehicle Tribology* (D. Dowson, C. Taylor, and M. Godet, eds.), vol. 18 of *Tribology Series*, pp. 213–228, Elsevier, 1991.
- [36] M.-T. Do, “Adhérence des chaussées : de l’étude cognitive aux applications,” Université de Bordeaux I. <https://theses.hal.science/tel-008512202010>. 2010.
- [37] P. A. Serigos, A. De Fortier Smit, and J. A. Prozzi, “Incorporating surface microtexture in the prediction of skid resistance of flexible pavements,” *Transportation Research Record : Journal of the Transportation Research Board*, vol. 2457, pp. 105–113, Jan. 2014.

- [38] C. G. Giles, B. E. Sabey, and K. F. Cardew, "Development and performance of the portable skid-resistance tester," in *Symposium on Skid Resistance*, pp. 50–74, West Conshohocken, PA : ASTM International, Jan. 1962.
- [39] *Norme : XP CEN/TS 15901-3 - Caractéristiques de surface des routes et aéroports - Partie 3 : Mode opératoire de détermination de l'adhérence d'un revêtement de chaussée à l'aide d'un dispositif à frottement longitudinal contrôlé (CFLA) : l'ADHERA*. 2011.
- [40] V. Cerezo, M. T. Do, P. Maisonneuve, M. Liegeois, and P. Pellegrino, "L'appareil DFT (Dynamic Friction Tester) : première expérimentation française," *Revue générale des routes et des aérodromes*, 907, pp. 60-66, ill., tabl., ill. en coul., graphiques. <https://hal.science/hal-00851503>. 2013.
- [41] J. Hosking and G. Woodford, "Measurement of skidding resistance, part 1 : guide to the use of scrim," *Transport and Road Research Laboratory (TRRL)*. 1976.
- [42] *Characterization of pavement texture by use of surface profiles — Part 1 : Determination of mean profile depth*, vol. 2019. Norme : ISO 13473-1, International Organization for Standardization. Feb. 2019.
- [43] *Norme ASTM E2380 - Standard test method for measuring pavement texture drainage using an outflow meter*. 2019.
- [44] *Guide for Pavement Friction*. Transportation Research Board. National Cooperative Highway Research Program (NCHRP) and National Academies of Sciences, Engineering, and Medicine (NASEM). Transportation Research Board, 2009.
- [45] S. Li, S. Noureldin, K. Zhu, and Y. Jiang, "Pavement surface microtexture : Testing, characterization, and frictional interpretation," pp. 59–76, West Conshohocken, PA : ASTM International, Oct. 2012.
- [46] D. Woodward, P. Millar, and G. McQuaid, "Use of 3D modelling techniques to better understand road surface textures," *Safer Roads 2014 : 4th International Safer Roads Conference*, May 2014.
- [47] G. Mcquaid, D. Woodward, P. Millar, and S. Friel, "Use of close range photogrammetry to assess the microtexture of asphalt surfacing aggregates," Dec. 2013.
- [48] H. R. Cedergren, J. A. Arman, and K. H. O'Brien, *Development of Guidelines for the Design of Subsurface Drainage Systems for Highway Pavement Structural Sections*. No. FHWA-RD-73-14, Feb. 1973.
- [49] N. A. Caleb, J. C. Dario, and L. N. John, *Subsurface Drainage Manual for Pavements in Minnesota*. No. MN/RC 2009-17, June 2009.
- [50] *Norme : NF P 98-217-1 - Essais associés à la macrotexture - Partie 1 : Mesure de la drainabilité superficielle*. 1995.

- [51] *Norme : EN 12697-40 - Mélanges bitumineux - Méthodes d'essai - Partie 40 : Drainabilité in situ*. Comité Européen de Normalisation (CEN). Feb. 2020.
- [52] *Evaluation de l'impact des routes sur l'environnement : rapport / réalisé par un groupe d'experts scientifiques de l'OCDE*. Recherche en matière de routes et de transports routiers, Paris : OCDE, 1994.
- [53] E. Freitas, C. Mendonça, J. Santos, C. Murteira, and J. Ferreira, "Traffic noise abatement : How different pavements, vehicle speeds and traffic densities affect annoyance levels," *Transportation Research Part D : Transport and Environment*, vol. 17, pp. 321–326, June 2012.
- [54] F. B. Berry and I. H. Flindell, "Estimating dose-response relationships between noise exposure and human health impacts in the UK," on behalf of Interdepartmental Group on Costs and Benefits Noise Subject Group (IGCB(N)), Berry Environmental Ltd. July. 2009.
- [55] U. Sandberg and J. A. Ejsmont, *Tyre/road Noise : Reference Book*. Informex, Harg, SE-59040 Kisa, Sweden. 2002.
- [56] *Calculation of Road Traffic Noise*. Department of transport Welsh office. ISBN : 0 11 550847 3. HMSO Publications Centre. 1988.
- [57] J. L. Rochat and G. G. Fleming, *Validation of FHWA's traffic noise model (TNM) : phase 1*. Report Number : DOT-VNTSC-FHWA-02-01 ;FHWA-EP-02-031. Aug. 2002.
- [58] S. Sakamoto, "Road traffic noise prediction model asj rtn model 2013" : Report of the research committee on road traffic noise," *Acoustical Science and Technology*, vol. 36, no. 2, pp. 49–108, 2015.
- [59] G. Dutilleux, J. Defrance, D. Ecotière, B. Gauvreau, M. Bérengier, F. Besnard, and E. L. Duc, "NMPB-Routes-2008 : The Revision of the French Method for Road Traffic Noise Prediction," *Acta Acustica united with Acustica*, vol. 96, pp. 452–462, May 2010.
- [60] S. de Lisle, "Comparison of Road Traffic Noise Prediction Models : CoRTN, TNM, NMPB, ASJ RTN," *Acoustics Australia*, vol. 44, pp. 409–413, Dec. 2016.
- [61] *Bruit de roulement : Etat de l'art et recommandations*. Institut des routes, des rues et des infrastructures pour la mobilité (IDRRIM). Mai. 2009.
- [62] *Norme ISO : 11819 - Acoustique — Méthode de mesurage de l'influence des revêtements de chaussées sur le bruit émis par la circulation*. International Organization for Standardization (ISO). 2017.
- [63] P. Ullidtz, *Pavement analysis. Development in civil engineering, 19*. may 1987.
- [64] F. Bernard and M. Brodeur, *Manuel d'identification des dégradations des chaussées flexibles*. Transports Québec, Service de la qualité et des normes. OCLC : 77028671.

- Québec (Province), Ministère des transports et Service de la qualité et des normes. 2002.
- [65] R. Haas, W. R. Hudson, and J. P. Zaniewski, *Modern pavement management*. Krieger Publishing Company. 1994.
- [66] M. Vaillancourt, *Méthodologie de modélisation de l'uni des chaussées souples et impact des sols d'infrastructure*. These de doctorat. Ecole de technologie supérieure université du Québec. Nov. 2004.
- [67] *Caractéristiques de surface des revêtements routiers : leur interaction et leur optimisation*. Recherche en matière de routes et de transports routiers, OCDE, 1984.
- [68] D. Cebon, *Handbook of vehicle-road interaction : vehicle dynamics, suspension design, and road damage*. No. 2. Advances in engineering. Swets & Zeitlinger. 1999.
- [69] T. D. Gillespie, S. M. Karamihas, M. W. Sayers, M. A. Nasim, W. Hansen, N. Ehsan, and D. Cebon, *Effects of Heavy-vehicle characteristics on pavement response and performance*. Transportation Research Board, 1993.
- [70] D. J. Cole and D. Cebon, *Predicting vertical dynamic tire forces of heavy trucks*. Conference, Vehicle-Road Interaction II, ASTM International, 1994.
- [71] I. Baba, K. Endou, and K. Himeno, “Adaptability of evaluation method based on physiology in pms,” *The 57th Civil Society Annual Conference - JSCE 2002 Annual Meeting*, 2002.
- [72] F. T., Y. Fujino, and T. Matsumoto, “Measurement and evaluation index of driving comfort on road,” *JSCE 2002 Annual Meeting*, 2001.
- [73] G. Farah, C. Petit-Boulanger, D. Hewson, and J. Duchêne, “Surface electromyography as a tool to assess the responses of car passengers to lateral accelerations. Part II : Objective comparison of vehicles,” *Journal of Electromyography and Kinesiology*, vol. 16, pp. 677–684, Dec. 2006.
- [74] S. Islam and W. G. Buttlar, “Effect of Pavement Roughness on User Costs,” *Transportation Research Record : Journal of the Transportation Research Board*, vol. 2285, pp. 47–55, Jan. 2012.
- [75] K. C. Sinha and S. Labi, *Transportation Decision Making : Principles of Project Evaluation and Programming*. John Wiley & Sons, Sept. 2011. Google-Books-ID : 870LEFbxZTQC.
- [76] T. D. Gillespie and M. W. Sayers, *Measuring Road Roughness and Its Effects on User Cost and Comfort : A Symposium*. ASTM International, 1985. Google-Books-ID : o1LvFZLGwroC.

- [77] Transportation Research Board, *Tires and Passenger Vehicle Fuel Economy : Informing Consumers, Improving Performance – Special Report 286*. Washington, DC : The National Academies Press, 2006.
- [78] F. Hu, *Development of a direct type road roughness evaluation system*. PhD thesis. University of South Florida, 2004.
- [79] M. M. Rashid and K. Tsunokawa, “Potential Bias of Response Type Road Roughness Measuring Systems : Causes and Remedial Measures,” *The Open Transportation Journal*, vol. 2, Oct. 2008.
- [80] T. Gillespie, W. Paterson, and M. Sayers, “Guidelines for conducting and calibrating road roughness measurements,” World bank technical paper number 46. 1986.
- [81] J. C. Wambold, L. E. DeFrain, R. R. Hegmon, K. McGhee, J. Reichert, and E. B. Spangler, “State of the art of measurement and analysis of road roughness,” in *Transportation Research Record*, 1981. ISSN : 0361-1981.
- [82] E. B. Spangler, “Method and system for measurement of road profile.” Patent. May. 1988.
- [83] J.-M. Martin, “Auscultation et diagnostic sur infrastructures - auscultation des chaussées par système bas-coût,” *Congrès de l’IDRRIM*, June 2016.
- [84] *Note d’information n°38 : Positionnement de l’Unibox vis-à-vis de l’APL*. Institut des routes, des rues et des infrastructures pour la mobilité (IDRRIM) pour le groupe national - Groupe national caractéristiques de surface (GNCDS). 2019.
- [85] F. Menant, J. Jean Marc Martin, and D. Meignen, “L’unibox : un nouvel outil pour le contrôle de profil en long des infrastructures de transport,” *Revue Generale des Routes et de l’Aménagement (RGRA)*, 2016.
- [86] M. W. Sayers, T. D. Gillespie, and C. a. V. Queiroz, “the international road roughness experiment : a basis for establishing a standard scale for road roughness measurements,” in *Transportation Research Record*. ISSN : 0361-1981. 1986.
- [87] W. J. Houbolt, J.C. and R. Smiley, *On spectral analysis of runway roughness and loads developed during taxiing, Technical Note 3484*. Langley Aeronautical Laboratory, National Advisory Committee for Aeronautics, Langley Field, VA., 1955.
- [88] J. C. Houbolt, “Runway roughness studies in the aeronautical field,” *Transactions of the American Society of Civil Engineers*, vol. 127, pp. 427–447, Jan. 1962. Publisher : American Society of Civil Engineers.
- [89] R. P. L. Barre, S. Andrew, and R. T. Forbes, *The Measurement and Analysis of Road Surface Roughness*. Motor Industry Research Association, 1969.
- [90] *Proposals for generalised road inputs to vehicles, BSI (1972) MEE/158/3/1*. British Standard Institution (BSI 72/34562), 1972.

- [91] P. Andren, "Power spectral density approximations of longitudinal road profiles," *International Journal of Vehicle Design*, vol. 40, no. 1/2/3, 2006.
- [92] P. Welch, "The use of fast Fourier transform for the estimation of power spectra : A method based on time averaging over short, modified periodograms," 1967.
- [93] M. H. Same, G. Gandubert, G. Gleeton, P. Ivanov, and R. Landry, "Simplified Welch Algorithm for Spectrum Monitoring," *Applied Sciences*, vol. 11, p. 86, Dec. 2020.
- [94] L. Marple, "A new autoregressive spectrum analysis algorithm," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 28, pp. 441–454, Aug. 1980. Conference Name : IEEE Transactions on Acoustics, Speech, and Signal Processing.
- [95] T. M. Mitchell, *Machine Learning*. McGraw-Hill, 1997. Google-Books-ID : EoYBn-gEACAAJ.
- [96] "What is Unsupervised Learning?." <https://www.ibm.com/cloud/learn/unsupervised-learning>. IBM Cloud Education. June. 2021.
- [97] N. Li, M. Shepperd, and Y. Guo, "A Systematic Review of Unsupervised Learning Techniques for Software Defect Prediction," *arXiv :1907.12027 [cs]*, Feb. 2020. arXiv : 1907.12027.
- [98] G. S. Kumar, "Market-basket analysis and prediction." <https://towardsdatascience.com/market-basket-analysis-using-associative-data/mining-and-apriori-algorithm-bddd07c6a71a>. Towards data science Medium blog. Jun. 2020.
- [99] L. K. Saul and S. T. Roweis, "Think Globally, Fit Locally : Unsupervised Learning of Low Dimensional Manifolds," *Journal of Machine Learning Research*, vol. 4, no. Jun, pp. 119–155, 2003.
- [100] S. Arlot, *Fondamentaux de l'apprentissage statistique*. Editions Technip, 9782710811824. HAL-ID :01485506f. Mar. 2018.
- [101] S. Zhang, C. Zhang, and Q. Yang, "Data preparation for data mining," *Applied Artificial Intelligence*, vol. 17, pp. 375–381, May 2003. Publisher : Taylor & Francis _eprint : <https://doi.org/10.1080/713827180>.
- [102] A. Famili, W.-M. Shen, R. Weber, and E. Simoudis, "Data preprocessing and intelligent data analysis," *Intelligent Data Analysis*, vol. 1, pp. 3–23, Jan. 1997.
- [103] C. Chatfield and H. Xing, *The analysis of time series : an introduction with R*. Chapman & Hall/CRC texts in statistical science series, Boca Raton : CRC Press, Taylor and Francis Group, seventh edition ed., 2019.
- [104] S. Baf, E. Im, and M. Bol, "Application of K-Nearest Neighbor (KNN) approach for predicting economic events : theoretical background," *International Journal of Engineering Research and Applications*, 2013.

- [105] I.-J. Li, J.-C. Chen, and J.-L. Wu, "A fast prototype reduction method based on template reduction and visualization-induced self-organizing map for nearest neighbor algorithm," *Applied Intelligence*, vol. 39, pp. 564–582, Oct. 2013.
- [106] Y. Xu and L. Wang, "K-nearest neighbor-based weighted twin support vector regression," *Applied Intelligence*, vol. 41, pp. 299–309, July 2014.
- [107] L.-Y. Hu, M.-W. Huang, S.-W. Ke, and C.-F. Tsai, "The distance function effect on k-nearest neighbor classification for medical datasets," *SpringerPlus*, vol. 5, p. 1304, Aug. 2016.
- [108] S. Ruder, "An overview of gradient descent optimization algorithms," June 2017. arXiv :1609.04747 [cs].
- [109] J. Brownlee, "Master Machine Learning Algorithms," January 2016.
- [110] N. Cristianini and B. Scholkopf, "Support Vector Machines and Kernel Methods : The New Generation of Learning Machines," *AI Magazine*, vol. 23, pp. 31–31, Sept. 2002. Number : 3.
- [111] J. Shawe-Taylor and N. Cristianini, *Kernel methods for pattern analysis*. Cambridge : Cambridge University Press, 2004.
- [112] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers," in *Proceedings of the fifth annual workshop on Computational learning theory, COLT '92*, (New York, NY, USA), pp. 144–152, Association for Computing Machinery, July 1992.
- [113] P. Rivas-Perea, J. Cota-Ruiz, D. G. Chaparro, J. A. P. Venzor, A. Q. Carreón, and J. G. Rosiles, "Support Vector Machines for Regression : A Succinct Review of Large-Scale and Linear Programming Formulations," vol. 2013, Dec. 2012. Scientific Research Publishing.
- [114] K. Labusch, E. Barth, and T. Martinetz, "Simple method for high-performance digit recognition based on sparse coding," *IEEE transactions on neural networks*, vol. 19, pp. 1985–1989, Nov. 2008.
- [115] H. Al-Mubaid and S. Umair, "A New Text Categorization Technique Using Distributional Clustering and Learning Logic," *IEEE Transactions on Knowledge and Data Engineering*, vol. 18, pp. 1156–1165, Sept. 2006. Conference Name : IEEE Transactions on Knowledge and Data Engineering.
- [116] K. Wu and K.-H. Yap, "Fuzzy SVM for content-based image retrieval : a pseudo-label support vector machine framework," *IEEE Computational Intelligence Magazine*, vol. 1, pp. 10–16, May 2006. Conference Name : IEEE Computational Intelligence Magazine.

- [117] N. I. Sapankevych and R. Sankar, “Time Series Prediction Using Support Vector Machines : A Survey,” *IEEE Computational Intelligence Magazine*, vol. 4, pp. 24–38, May 2009. Conference Name : IEEE Computational Intelligence Magazine.
- [118] Haifeng Wang and Dejin Hu, “Comparison of SVM and LS-SVM for Regression,” in *2005 International Conference on Neural Networks and Brain*, vol. 1, (Beijing, China), pp. 279–283, IEEE, 2005.
- [119] T. Hastie, R. Tibshirani, and J. Friedman, “Kernel Smoothing Methods,” in *The Elements of Statistical Learning : Data Mining, Inference, and Prediction* (T. Hastie, R. Tibshirani, and J. Friedman, eds.), Springer Series in Statistics, pp. 191–218, New York, NY : Springer, 2009.
- [120] T. Hastie, R. Tibshirani, and J. Friedman, “Support Vector Machines and Flexible Discriminants,” in *The Elements of Statistical Learning : Data Mining, Inference, and Prediction* (T. Hastie, R. Tibshirani, and J. Friedman, eds.), Springer Series in Statistics, pp. 417–458, New York, NY : Springer, 2009.
- [121] L. Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone, *Classification And Regression Trees*. Boca Raton : Routledge, 1984.
- [122] J. R. Quinlan, *C4.5 : Programs for Machine Learning*. Morgan Kaufmann. Google-Books-ID : HExncpjbYroC. 1993.
- [123] R. Genuer and J.-M. Poggi, “Arbres CART et Forêts aléatoires, Importance et sélection de variables,” p. 46.
- [124] L. Breiman, “Bagging predictors,” *Machine Learning*, vol. 24, pp. 123–140, Aug. 1996.
- [125] B. Efron and R. J. Tibshirani, *An Introduction to the Bootstrap*. Boston, MA : Springer US, 1993.
- [126] L. Breiman, “Random Forests,” *Machine Learning*, vol. 45, pp. 5–32, Oct. 2001.
- [127] L. Breiman, “Statistical Modeling : The Two Cultures,” *Statistical Science*, vol. 16, pp. 199–231, Aug. 2001. Publisher : Institute of Mathematical Statistics.
- [128] Wikistat, “Agrégation de modèles — wikistat.” <http://wikistat.fr/pdf/st-m-explo-classif.pdf>. Mise en ligne le 21-janvier-2016.
- [129] U. Grömping, “Variable Importance Assessment in Regression : Linear Regression versus Random Forest,” *The American Statistician*, vol. 63, pp. 308–319, Nov. 2009.
- [130] P. Probst, M. N. Wright, and A. Boulesteix, “Hyperparameters and tuning strategies for random forest,” *WIREs Data Mining and Knowledge Discovery*, vol. 9, May 2019.
- [131] G. Louppe, L. Wehenkel, A. Suter, and P. Geurts, *Understanding variable importances in forests of randomized trees*, vol. 26. Curran Associates, Inc. 2013.

- [132] Y. Freund and R. E. Schapire, “Experiments with a New Boosting Algorithm,” *Machine Learning : Proceedings of the Thirteenth International Conference*, 1996.
- [133] S. Gey and J.-M. Poggi, “Boosting and instability for regression trees,” *Computational Statistics & Data Analysis*, vol. 50, pp. 533–550, Jan. 2006.
- [134] L. Breiman, “Arcing Classifiers,” *The Annals of Statistics*, vol. 26, no. 3, pp. 801–824. Institute of Mathematical Statistics. 1998.
- [135] J. H. Friedman, “Stochastic gradient boosting,” *Computational Statistics & Data Analysis*, vol. 38, pp. 367–378, Feb. 2002.
- [136] W. S. McCulloch and W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” *The bulletin of mathematical biophysics*, vol. 5, pp. 115–133, Dec. 1943.
- [137] F. Rosenblatt, “The perceptron : A probabilistic model for information storage and organization in the brain.,” *Psychological Review*, vol. 65, no. 6, pp. 386–408, 1958.
- [138] F. Rosenblatt, “Perceptron Simulation Experiments,” *Proceedings of the IRE*, vol. 48, pp. 301–309, Mar. 1960.
- [139] F. Attneave and M. B., “Review of The Organization of Behavior ; A Neuropsychological Theory,” *The American Journal of Psychology*, vol. 63, no. 4, pp. 633–642, 1950. Publisher : University of Illinois Press.
- [140] M. Minsky and S. Papert, *Perceptrons*. Perceptrons, Oxford, England : M.I.T. Press, 1969.
- [141] M. W. Gardner and S. R. Dorling, “Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences,” *Atmospheric Environment*, vol. 32, pp. 2627–2636, Aug. 1998.
- [142] D. E. Rumelhart and J. L. McClelland, “Learning Internal Representations by Error Propagation,” in *Parallel Distributed Processing : Explorations in the Microstructure of Cognition : Foundations*, pp. 318–362, MIT Press. Conference Name : Parallel Distributed Processing : Explorations in the Microstructure of Cognition : Foundations. 1987.
- [143] Z. C. Lipton, J. Berkowitz, and C. Elkan, “A Critical Review of Recurrent Neural Networks for Sequence Learning,” *arXiv :1506.00019*, Oct. 2015.
- [144] J. L. Elman, “Finding structure in time,” *Cognitive Science*, vol. 14, pp. 179–211, 1990.
- [145] P. Werbos, “Backpropagation through time : what it does and how to do it,” *Proceedings of the IEEE*, vol. 78, no. 10, pp. 1550–1560. Conference Name : Proceedings of the IEEE. Oct. 1990.

- [146] J. F. Kolen and S. C. Kremer, “Gradient Flow in Recurrent Nets : The Difficulty of Learning LongTerm Dependencies,” in *A Field Guide to Dynamical Recurrent Networks*, pp. 237–243, IEEE, 2001. Conference Name : A Field Guide to Dynamical Recurrent Networks.
- [147] R. Pascanu, T. Mikolov, and Y. Bengio, “On the difficulty of training Recurrent Neural Networks,” *arXiv :1211.5063 [cs]*, Feb. 2013.
- [148] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory,” *Neural Computation*, vol. 9, pp. 1735–1780, Nov. 1997.
- [149] N. Rahaman, A. Baratin, D. Arpit, F. Draxler, M. Lin, F. A. Hamprecht, Y. Bengio, and A. Courville, “On the Spectral Bias of Neural Networks,” *arXiv :1806.08734 [cs, stat]*, May 2019.
- [150] *Norme NF EN 13036-5 - Caractéristiques de surface des routes et aérodromes - Méthodes d’essais - Partie 5 : détermination des indices d’uni longitudinal*. Comité Technique CEN, 2020.
- [151] Z. A. Lomnicki and S. K. Zaremba, “On the Estimation of Autocorrelation in time Series,” *The Annals of Mathematical Statistics*, vol. 28, no. 1, pp. 140–158, 1957. Publisher : Institute of Mathematical Statistics.
- [152] O. Ronneberger, P. Fischer, and T. Brox, “U-Net : Convolutional Networks for Biomedical Image Segmentation,” *arXiv :1505.04597 [cs]*, May 2015. arXiv : 1505.04597.
- [153] S. Albawi, T. A. Mohammed, and S. Al-Zawi, “Understanding of a convolutional neural network,” in *2017 International Conference on Engineering and Technology (ICET)*, pp. 1–6, Aug. 2017.
- [154] K. Fukushima, “Neocognitron : A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position,” *Biological Cybernetics*, vol. 36, pp. 193–202, Apr. 1980.
- [155] L. Alzubaidi, J. Zhang, A. J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, J. Santamaría, M. A. Fadhel, M. Al-Amidie, and L. Farhan, “Review of deep learning : concepts, CNN architectures, challenges, applications, future directions,” *Journal of Big Data*, vol. 8, p. 53, Mar. 2021.
- [156] A. Paszke, S. Gross, F. Massa, A. Lerer, J. Bradbury, G. Chanan, T. Killeen, Z. Lin, N. Gimelshein, L. Antiga, A. Desmaison, A. Köpf, E. Yang, Z. DeVito, M. Raison, A. Tejani, S. Chilamkurthy, B. Steiner, L. Fang, J. Bai, and S. Chintala, “PyTorch : An Imperative Style, High-Performance Deep Learning Library,” Dec. 2019. arXiv :1912.01703.
- [157] V. Dumoulin and F. Visin, “A guide to convolution arithmetic for deep learning,” Tech. Rep. arXiv :1603.07285, arXiv, Jan. 2018.

- [158] F. Petitjean and P. Gañarski, “Summarizing a set of time series by averaging : From Steiner sequence to compact multiple alignment,” *Theoretical Computer Science*, vol. 414, pp. 76–91, Jan. 2012.
- [159] B.-K. Yi, H. Jagadish, and C. Faloutsos, “Efficient retrieval of similar time sequences under time warping,” in *Proceedings 14th International Conference on Data Engineering*, pp. 201–208, Feb. 1998.
- [160] F. Petitjean, A. Ketterlin, and P. Gañarski, “A global averaging method for dynamic time warping, with applications to clustering,” *Pattern Recognition*, vol. 44, pp. 678–693, Mar. 2011.
- [161] D. Schultz and B. Jain, “Nonsmooth Analysis and Subgradient Methods for Averaging in Dynamic Time Warping Spaces,” Tech. Rep. arXiv :1701.06393, arXiv, Jan. 2017.
- [162] M. Cuturi and M. Blondel, “Soft-DTW : a Differentiable Loss Function for Time-Series,” Tech. Rep. arXiv :1703.01541, arXiv, Feb. 2018.

Titre : Elaboration d'un outil d'aide à la décision pour l'estimation de l'uni longitudinal de la chaussée intégrant les phasages de leur mise en œuvre. Approche combinant Réseaux de neurones artificiels et analyse des données fonctionnelles issues d'auscultation.

Mots clés : *Réhabilitation de la chaussée - Amélioration de l'uni longitudinal - Intelligence artificielle - Réseau de neurones récurrents de convolution - Prédiction des séries temporelles - Apprentissage supervisé*

Résumé : L'uni longitudinal caractérise l'écart entre le profil longitudinal théorique de la chaussée et celui de sa surface réelle. Ainsi, l'uni de la chaussée qualifie les dégradations de sa surface qui interfèrent avec la sécurité et le confort de ses passagers. Toutefois, cette notion reste difficilement maîtrisable surtout dans le cadre d'une réhabilitation, où le résultat obtenu dépend du niveau préexistant d'uni. En effet, la profession fait face aujourd'hui à un manque de connaissance sur l'impact de l'uni préexistant (l'état de support) sur la qualité de l'uni obtenu post-réhabilitation. Par conséquent, l'élaboration d'un modèle permettant de prédire l'impact de la réhabilitation sur l'amélioration de la chaussée reste une problématique posée à laquelle cette thèse répond avec un élément majeur d'originalité dans l'approche : développer un système apprenant pour prédire le profil post-réhabilitation à partir de celui préexistant. Ce positionnement amont (prédiction du profil post-réhabilitation) assure une estimation détaillée qui permet de cibler les zones potentiellement problématiques, en plus d'une polyvalence de l'outil quant à l'intégration a posteriori des différents indicateurs contractuels.

Après avoir élaboré un ensemble de procédures correctives suivies pour réduire les incohérences et les impertinences entre les mesures pré- et post-réhabilitation, nous proposons l'U-RC-NET : un réseau de neurones artificiels récurrents de convolution qui, grâce à son architecture innovante, est capable de traduire les mécanismes physiques d'évolution de l'uni de la chaussée

En effet, ce modèle reconnaît dans un premier temps la segmentation des séquences pré-réhabilitation par blocs monolithiques (traces résiduelles des défauts), et prédit ensuite leurs améliorations à la suite de la réhabilitation en estimant leurs atténuations en fonction de leurs formes. Pour ce faire, trois blocs principaux organisent l'architecture du modèle développé : le premier bloc est un encodeur qui extrait les caractéristiques des séquences d'entrée tout en réduisant leurs résolutions spatiales. Le deuxième bloc est une cellule LSTM qui génère un noyau de la séquence prédite. Enfin, le troisième bloc est le décodeur où le même niveau de résolution de la séquence d'entrée est retrouvé. Pour forcer le modèle à constituer les séquences prédites en estimant l'amélioration de chacune des formes (traces résiduelles) pré-réhabilitation présentes dans les séquences d'entrée, la fonction perte choisie pour l'apprentissage du modèle U-RC-NET est la Soft-DTW normalisée. Ce choix permet au modèle de focaliser sur des prédictions basées sur la forme dès son entraînement.

Confronté aux données mesurées selon la méthodologie détaillée, l'U-RC-Net prédit l'évolution de l'uni par bandes d'ondes en identifiant les traces résiduelles préexistantes sous leurs différentes formes possibles dans les séquences pré-réhabilitation d'entrée, et en extrayant leurs caractéristiques sous différents niveaux de résolutions pour estimer, ensuite, leurs évolutions. D'après les résultats des tests, le modèle affiche des performances remarquables et encourageantes.

Title: Development of a decision-making tool to estimate the final longitudinal unevenness of pavements that integrates the phasing of their implementation. An Approach combining artificial neural networks and analysis of functional data from inspection.

Keywords: *Pavement rehabilitation - Improvement of the longitudinal evenness - Artificial intelligence - Recurrent convolutional neural networks - Time series prediction - Supervised learning*

Abstract: The longitudinal unevenness characterizes the difference between the theoretical longitudinal profile of the pavement and that of its actual surface. Thus, the evenness of the pavement qualifies the deterioration of its surface which interferes with the safety and comfort of its passengers. However, this notion remains difficult to control, especially in the context of rehabilitation, where the result obtained depends on the pre-existing level of evenness. Indeed, the profession is currently facing a lack of knowledge on the impact of the pre-existing evenness on the quality of the evenness obtained after rehabilitation. Consequently, the development of a model to predict the impact of rehabilitation on pavement improvement remains a problem that this thesis addresses with a major element of originality in the approach: developing a learning system to predict the post-rehabilitation profile from the pre-existing one. This upstream positioning ensures a detailed estimation that allows to target the potentially problematic areas, in addition to a versatility of the tool as for the a posteriori integration of the various contractual indicators. After having developed a set of corrective procedures followed to reduce inconsistencies and impertinences between pre- and post-rehabilitation measurements, we propose the U-RC-NET: an artificial recurrent convolution neural network which, thanks to its innovative architecture, is able to translate the physical mechanisms of pavement surface evolution

Indeed, this model first recognizes the segmentation of pre-rehabilitation sequences by monolithic blocks (residual traces of defects), and then predicts their improvements following rehabilitation by estimating their attenuation according to their shapes. To do so, three main blocks organize the architecture of the developed model: the first block is an encoder that extracts the features of the input sequences while reducing their spatial resolutions. The second block is an LSTM cell that generates a kernel of the predicted sequence. Finally, the third block is the decoder where the same level of resolution of the input sequence is recovered. To force the model to build up the predicted sequences by estimating the improvement of each of the pre-rehabilitation shapes (residual traces) present in the input sequences, the loss function chosen for training the U-RC-NET model is the normalized Soft-DTW. This choice allows the model to focus on shape-based predictions right from its training. Confronted with the data measured according to the detailed methodology, the U-RC-Net predicts the evolution of the unevenness per waveband by identifying the pre-existing residual traces in their different possible forms in the input pre-rehabilitation sequences, and by extracting their characteristics under different levels of resolution to then estimate their evolutions. According to the test results, the model shows notable and encouraging performances.