

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Hassiba Benbouali de Chlef

Faculté Génie civil et d'architecture

Département Génie civil



THÈSE

Présentée pour l'obtention du diplôme de

DOCTORAT 3^{ème} CYCLE (LMD)

Filière: **Génie Civil**

Spécialité: **Structures**

Par

BENZAAMIA ALI

Thème :

Prédiction de la résistance au cisaillement des poutres en béton armé renforcées avec des matériaux composites à l'aide des techniques de l'intelligence artificielle

Soutenue le 28 Septembre 2024, devant le jury composé de :

LAMRI Belkacem	Professeur	Université de Chlef	Président
KENAI Said	Professeur	Université de Blida	Examineur
MENADI Belkacem	Professeur	Université de Blida	Examineur
KADA Abdelhak	MCA	Université de Chlef	Examineur
GHRICI Mohamed	Professeur	Université de Chlef	Rapporteur
REBOUH Redouane	MCB	Université de Chlef	Co-rapporteur

Dédicaces

En premier lieu, à mes parents bien-aimés, phares de ma vie. Vous m'avez insufflé le courage, la volonté et la confiance nécessaires pour persévérer. Votre amour inconditionnel et votre soutien constant resteront à jamais gravés dans mon cœur.

À mes frères et sœurs chéris, compagnons de route et confidents de toujours. Votre présence illumine mon chemin.

À ma tendre grand-mère, trésor de sagesse et gardienne de nos traditions.

À l'ensemble des familles BENZAAMIA et ELHAOUARI, dont les racines nourrissent mon identité et dont la bienveillance m'a porté jusqu'ici.

À mes amis fidèles, compagnons de route dans cette aventure scientifique, avec qui j'ai partagé les joies et les difficultés de nos études.

À mes professeurs et mentors en génie civil et en apprentissage automatique, qui m'ont guidé à travers les complexités de ces disciplines en constante évolution.

À tous ceux qui œuvrent pour l'innovation dans le génie civil par l'application de l'intelligence artificielle, source d'inspiration pour ce travail.

Que cette contribution soit le témoignage de ma reconnaissance envers vous tous et de mon engagement envers l'avancement de nos domaines.

Remerciements

Je remercie Allah le tout puissant de m'avoir accordé patience, courage et santé pour l'élaboration et la finalisation de cette thèse de doctorat.

Mes remerciements les plus sincères vont à mon directeur de thèse, Pr. GHRICI Mohamed, de l'Université de Chlef et Directeur du Laboratoire de Géomatériaux. Sa confiance, son expertise et sa disponibilité m'ont permis d'élargir mes connaissances et d'affiner ma réflexion. Son enthousiasme communicatif m'a révélé la passion du monde de la recherche. Ses relectures attentives et ses corrections judicieuses ont grandement contribué à la qualité de ce travail. Cette thèse lui doit beaucoup.

J'exprime ma profonde gratitude à mon co-directeur, Dr. REBOUH Redouane, Maître de conférences à l'Université de Chlef. Ses conseils avisés, son regard critique et son soutien constant ont été des atouts précieux tout au long de ce parcours doctoral.

Je tiens à remercier chaleureusement Pr. LAMRI Belkacem de l'Université de Chlef, pour avoir accepté de présider le jury de cette thèse. Son dévouement et ses précieux conseils ont été d'une grande valeur.

Je tiens à exprimer ma profonde reconnaissance aux membres éminents du jury : Pr. KENAI Said et Pr. MENADI Belkacem de l'Université Saad Dahlab Blida 1, ainsi que Dr. KADA Abdelhak, Maître de conférences à l'Université de Chlef. Leur acceptation d'examiner ce travail, leur expertise pointue et leur regard critique ont considérablement enrichi cette thèse et m'ont permis d'affiner ma réflexion.

Ma gratitude s'étend également au Pr. HARICHANE Zamila de l'Université de Chlef, dont le soutien indéfectible, les conseils éclairés et les encouragements constants ont été des piliers essentiels tout au long de ce parcours. Je souhaite par ailleurs exprimer ma sincère reconnaissance au Pr. ASTERIS Panagiotis, directeur du laboratoire "Computational Mechanics Laboratory" à l'Université d'Athènes, en Grèce, dont la collaboration précieuse et les perspectives novatrices ont significativement enrichi la portée et la qualité de ce travail de recherche.

Ma reconnaissance va au Pr. EZZIANE, vice-doyen des études post graduées, pour son soutien administratif et ses encouragements tout au long de ce parcours doctoral.

Je tiens à saluer l'ensemble des enseignants du département de Génie Civil, dont les enseignements et le soutien ont été essentiels à ma formation et à l'aboutissement de cette thèse.

Un grand merci à mes collègues du Laboratoire de Géomatériaux, en particulier Dr. SARI-AHMED Bilal, TOUALBIA Youssouf, HAMDAOUI Khaled et tous les autres, pour leur esprit de collaboration, leur soutien moral et les moments partagés qui ont rendu cette expérience enrichissante tant sur le plan professionnel que personnel.

Enfin, j'exprime ma profonde gratitude à ma famille et mes amis pour leur soutien inconditionnel, leur patience et leurs encouragements constants. Votre présence à mes côtés a été une source inestimable de motivation et de réconfort.

À tous ceux qui, de près ou de loin, ont contribué à la réalisation de ce travail, je vous adresse mes sincères remerciements.

Résumé

La prédiction précise de la contribution à la résistance au cisaillement des composites en polymères renforcés de fibres (PRF) collés extérieurement sur les poutres en béton armé (BA) est une tâche cruciale et difficile. Les modèles analytiques traditionnels et les dispositions des codes de conception peinent souvent à saisir l'interaction complexe entre le béton, l'acier et les PRF, conduisant à des prédictions imprécises ou trop conservatrices. Cette étude explore l'application de techniques avancées d'apprentissage automatique pour remédier à cette limitation. Six modèles d'intelligence artificielle diversifiés sont développés et évalués de manière exhaustive, notamment le Gradient Boosting eXtrême (XGB), les Réseaux de Neurones Profonds (DNN), le XGBoost Monotonique (MXGB), les Réseaux Neuronaux Monotoniques avec Contraintes (CMNN), et leurs homologues ensemblistes. Un ensemble complet de 394 spécimens de poutres BA renforcées avec diverses configurations de PRF est utilisé pour l'entraînement et la validation des modèles. L'intégration de contraintes de monotonie basées sur des comportements physiques connus améliore considérablement les performances prédictives, comme en témoignent la précision et les capacités de généralisation supérieures du MXGB par rapport au XGB, du CMNN par rapport au DNN, et du Modèle Ensembliste Monotonique (MENSM) par rapport au Modèle Ensembliste (ENSM). Les investigations par scénarios mettent en évidence la capacité exceptionnelle du CMNN à saisir avec précision les relations monotones, présentant des tendances lisses et logiques en accord avec les principes de la mécanique du cisaillement des PRF. La comparaison avec les directives de conception largement adoptées démontre la supériorité incontestable du CMNN, atteignant des performances statistiques optimales pour toutes les configurations de renforcement par PRF. Le CMNN émerge comme le modèle le plus adapté aux applications d'ingénierie, affichant une précision prédictive remarquable, une adhérence aux principes théoriques et des capacités d'extrapolation fiables au-delà des données d'entraînement. Cette étude souligne le potentiel des techniques d'apprentissage automatique intégrant des connaissances du domaine pour optimiser la conception du renforcement au cisaillement par PRF, contribuant ainsi à l'amélioration de la sécurité, de la fiabilité et de la rentabilité des infrastructures en BA.

Mots clés : résistance au cisaillement, poutres en béton armé, FRP collé extérieurement, apprentissage automatique, contraintes monotones, modélisation en ensemble.

Abstract

Accurately predicting the shear strength contribution of externally bonded fiber-reinforced polymer (EB-FRP) composites in reinforced concrete (RC) beams is a crucial yet challenging task in structural engineering. Traditional analytical models and design code provisions often struggle to capture the complex interplay between concrete, steel, and FRP, leading to inaccurate or overly conservative predictions. This study explores the application of advanced machine learning (ML) techniques to address this limitation. Six diverse soft computing models are developed and comprehensively evaluated, including eXtreme Gradient Boosting (XGB), Deep Neural Networks (DNN), Monotonic XGBoost (MXGB), Constrained Monotonic Neural Networks (CMNN), and their ensemble counterparts. A comprehensive experimental dataset comprising 394 RC beam specimens strengthened with various FRP configurations is employed for model training and validation. The incorporation of monotonicity constraints based on known physical behaviors significantly enhances predictive performance, as evidenced by the superior accuracy and generalization capabilities of MXGB over XGB, CMNN over DNN, and the Monotonic Ensemble Model (MENSM) over the Ensemble Model (ENSM). Scenario-based investigations highlight the CMNN's exceptional ability to accurately capture monotonic relationships, exhibiting smooth, logical trends aligning with FRP shear mechanics principles. Benchmarking against widely adopted design guidelines demonstrates the CMNN's unequivocal superiority, achieving optimal statistical performance across all FRP strengthening configurations. The CMNN emerges as the most suitable model for engineering applications, exhibiting remarkable predictive accuracy, adherence to theoretical principles, and reliable extrapolation capabilities beyond training data. This study underscores the potential of ML techniques integrating domain knowledge for optimizing FRP shear strengthening design, contributing to enhanced safety, reliability, and cost-effectiveness of RC infrastructure.

Keywords: shear strength, reinforced concrete beams, externally-bonded FRP, machine learning, monotonic constraints, ensemble modeling.

الملخص

التنبؤ بدقة بمساهمة قوة القص لمركبات البوليمر المقوى بالألياف الملتصقة خارجياً (EB-FRP) في العوارض الخرسانية المسلحة (RC) هو مهمة حاسمة لكنها تحدي كبير في هندسة الهياكل. غالباً ما تكافح النماذج التحليلية التقليدية وأحكام الأكواد التصميمية لالتقاط التفاعل المعقد بين الخرسانة والفولاذ والبوليمر المقوى بالألياف، مما يؤدي إلى توقعات غير دقيقة أو متحفظة للغاية. تستكشف هذه الدراسة تطبيق تقنيات التعلم الآلي المتقدمة لمعالجة هذا القيد. تم تطوير ستة نماذج متنوعة للحوسبة الذكية وتقييمها بشكل شامل، بما في ذلك تعزيز التدرج الفائق (XGB)، والشبكات العصبية العميقة (DNN)، وتعزيز التدرج الفائق الرتيب (MXGB)، والشبكات العصبية الرتيبة المقيدة (CMNN)، ونماذجها الجماعية. تم استخدام مجموعة بيانات تجريبية شاملة تضم 394 عينة من العوارض الخرسانية المسلحة المقواة بتكوينات البوليمر المقوى بالألياف المختلفة لتدريب النماذج والتحقق من صحتها. أدى تضمين قيود الرتبة بناءً على السلوكيات الفيزيائية المعروفة إلى تحسين الأداء التنبؤي بشكل كبير، كما يتضح من الدقة الفائقة وقدرات التعميم لنموذج MXGB مقارنة بـ XGB، و CMNN مقارنة بـ DNN، ونموذج التجميع الرتيب (MENSIM) مقارنة بنموذج التجميع (ENSM). تسلط التحقيقات المستندة إلى السيناريو الضوء على قدرة CMNN الاستثنائية على التقاط العلاقات الرتيبة بدقة، مع إبراز اتجاهات سلسلة ومنطقية تتماشى مع مبادئ ميكانيكا القص للبوليمر المقوى بالألياف. تُظهر المقارنات مع إرشادات التصميم المعتمدة على نطاق واسع تفوق CMNN بشكل لا لبس فيه، حيث يحقق الأداء الإحصائي الأمثل عبر جميع تكوينات تقوية البوليمر المقوى بالألياف. يظهر CMNN كالنموذج الأنسب لتطبيقات الهندسة، حيث يتميز بدقة تنبؤية رائعة، والتزام بالمبادئ النظرية، وقدرات استقرار موثوقة تتجاوز بيانات التدريب. تؤكد هذه الدراسة على إمكانات تقنيات التعلم الآلي التي تدمج المعرفة المتخصصة لتحسين تصميم تقوية القص باستخدام البوليمر المقوى بالألياف، مما يسهم في تحسين السلامة والموثوقية والفعالية من حيث التكلفة للبنية التحتية الخرسانية المسلحة.

كلمات مفتاحية: قوة القص، العوارض الخرسانية المسلحة، البوليمر المقوى بالألياف المثبت خارجياً، التعلم الآلي، القيود الرتيبة، النمذجة التجميعية.

TABLE DES MATIERES

Notations	V
Liste des Figures	VII
Liste des Tableaux	X

Introduction Générale

Généralités	2
But de travail.....	5
Plan des chapitres.....	6

Chapitre 1

Propriétés et applications des PRF dans le renforcement des structures en BA : État de l'Art

1.1 Introduction.....	9
1.2 Historique et évolution de l'utilisation des PRF pour le renforcement structural.....	9
1.3 Matériaux typiques des PRF	11
1.3.1 PRFC.....	13
1.3.2 PRFV	14
1.3.3 PRFA	14
1.3.4 PRFB.....	15
1.4 Matrice de PRF	15
1.4.1 Résine époxy.....	16
1.4.2 Ester vinylique	17
1.4.3 Polyester.....	17
1.5 Propriétés mécaniques	17
1.5.1 Résistance à la compression	18
1.5.2 Résistance au cisaillement	18
1.5.3 Résistance à la flexion	19
1.5.4 Résistance à la traction	20
1.6 Techniques de renforcement	21
1.7 Les caractéristiques d'adhérence des PRF	22

1.8 Applications des PRF	24
1.8.1 Confinement des colonnes et amélioration de la ductilité	26
1.8.2 Renforcement à la flexion.....	27
1.8.3 Renforcement au cisaillement.....	28
1.9 Conclusion	30

Chapitre 2

Cisaillement des poutres en BA : concepts de base et renforcement par PRF

2.1 Introduction.....	32
2.2 Comportement au cisaillement des poutres en BA sans armatures transversales.....	32
2.2.1 Mécanismes de résistance au cisaillement	35
2.2.1.1 Action de poutre	35
2.2.1.2 Action d'arche.....	37
2.2.2 Facteurs influençant le comportement au cisaillement.....	38
2.3 Effet des armatures de cisaillement	39
2.4 Modes de rupture au cisaillement dans les poutres en BA	40
2.5 Approches pour la modélisation du cisaillement dans les poutres en BA.....	42
2.5.1 Analogies de treillis	43
2.5.2 Modèles de bielle et tirant.....	44
2.5.3 La théorie modifiée du champ de compression	45
2.6 Renforcement au cisaillement des poutres par PRF collés extérieurement	45
2.7 Modes de rupture des poutres en BA renforcées au cisaillement par PRF collés extérieurement.....	49
2.8 Revue des formulations réglementaires pour la quantification de la résistance au cisaillement apportée par les PRF.....	50
2.9 Conclusion	54

Chapitre 3

Approches d'apprentissage automatique pour prédire la résistance au cisaillement des poutres en BA renforcées par PRF

3.1 Introduction.....	56
3.2 Apprentissage automatique : Concepts et méthodologies	57
3.2.1 Apprentissage automatique, intelligence artificielle et apprentissage profond	57
3.2.2 Principales catégories d'algorithmes d'apprentissage automatique.....	57
3.2.3 Étapes clés pour la construction de modèles d'apprentissage automatique efficaces	59
3.3 Aperçu des algorithmes d'apprentissage automatique	60
3.3.1 Techniques de régression.....	61
3.3.2 Réseaux de neurones artificiels (ANNs).....	62
3.3.3 Programmation génétique (GP) et programmation d'expression génique (GEP).....	63
3.3.4 Système d'inférence neuro-flou adaptatif (ANFIS)	64
3.3.5 Machines à vecteurs de support (SVM).....	64
3.3.6 Arbres de décision (DT)	65
3.3.7 Forêt aléatoire (RF).....	66
3.3.8 Algorithme de boosting	67
3.4 Application de l'apprentissage automatique pour prédire la résistance au cisaillement des poutres en BA renforcées par PRF	69
3.5 Discussion et recommandations.....	74
3.6 Conclusion	77

Chapitre 4

Approches et méthodologies

4.1 Introduction.....	80
4.2 Algorithmes d'apprentissage automatique avancés.....	81
4.2.1 eXtreme Gradient Boosting (XGBoost)	81
4.2.2 Réseaux de neurones profonds (DNN)	82
4.2.3 Renforcer les contraintes de monotonie dans les modèles d'apprentissage automatique.....	83
4.2.4 Modèles d'ensemble.....	85
4.3 Description de la base de données	87

4.3.1	Importance de la qualité et de l'exhaustivité des données d'entraînement.....	87
4.3.2	Présentation de l'ensemble de données original.....	89
4.3.3	Raffinement et sélection des données.....	91
4.4	Pré-traitement des données.....	95
4.5	Effet des paramètres d'entrée sur la contribution du renforcement au cisaillement par PRF..	98
4.5.1	Effet du rapport portée de cisaillement/profondeur (a/d).....	99
4.5.2	Effet du taux d'armature transversale en acier (ρ_{sw}).....	99
4.5.3	Effet de la résistance à la compression du béton (f_{ck}).....	100
4.5.4	Effet de la taille de la poutre (profondeur effective d).....	101
4.5.5	Effet de la conception des PRF et des caractéristiques des matériaux.....	101
4.6	Métriques d'évaluation de la performance.....	103
4.7	Réglage des hyperparamètres avec l'optimisation bayésienne..	106
4.8	Conclusion.....	108

Chapitre 5

Résultats et discussions

5.1	Introduction.....	111
5.2	Performance des modèles d'apprentissage automatique avancés.....	111
5.3	Interprétation visuelle des résultats.....	114
5.4	Application des modèles d'apprentissage automatique avancés.....	119
5.5	Évaluation comparative avec les codes de conception établis.....	128
5.6	Conclusion.....	132

Conclusions Générales et Recommandations

Conclusions générales.....	136
Recommandations.....	137

Références Bibliographiques.....	140
---	------------

Notations

a/d_e	Rapport portée de cisaillement sur hauteur utile
A_{90}	Surface de section transversale de l'acier de cisaillement par unité de longueur
A_{sv}	Ratio de renforcement transversal interne
A_v/S_v	Ratio surface des étriers sur espacement
B_f	Largeur du PRF
b_w	Largeur de la poutre
d_e	Hauteur utile de la poutre
d_f	Profondeur effective du PRF
E_f	Module d'élasticité du PRF
f_{ck}	Résistance à la compression du béton
f_f	Résistance à la traction du PRF
f_{yl}	Contrainte de plastification de calcul de l'acier longitudinal
f_{ys}	Contrainte de plastification de calcul de l'acier de cisaillement
h_b	Hauteur de la poutre
h_f	Hauteur de la bande de PRF
s_f	Espacement centre à centre des bandes de PRF
s_v	Espacement des étriers
t_f	Épaisseur du PRF
w_f	Largeur des bandes de PRF
w_f/s_f	Ratio largeur-espacement du PRF
a	Portée de cisaillement
ANFIS	Système d'inférence neuro-flou adaptatif
ANNs	Réseaux de neurones artificiels
BA	Béton armé

CI/PI	Indice de confiance
CMNN	Réseau de neurones monotone contraint
COV	Coefficient de variation
CS	Section transversale de la poutre en béton armé
DNN	Réseaux de neurones profonds
DT	Arbres de décision
EBR	Collage externe
ENSM	Modèle d'ensemble
<i>FM</i>	Mode de rupture
GA	Algorithme génétique
GEP	Programmation d'expression génique
GP	Programmation génétique
IA	Intelligence artificielle
KGE	Efficacité de Kling-Gupta
KNN	K plus proches voisins
Lasso	Régression Lasso
LR	Régression linéaire
MAE	Erreur absolue moyenne
MCFT	Théorie modifiée du champ de compression
MENSM	Modèle d'ensemble monotone
MGP	Programmation génétique multigène
MV	Valeur moyenne
MXGB	XGBoost monotone
<i>n</i>	Nombre de couches de PRF
NID	Diagramme d'interprétation neuronale
NSM	Montage près de la surface

OI	Indice global
PRF	Polymères renforcés de fibres
PRFA	Polymère renforcé de fibres d'aramide
PRFC	Polymère renforcé de fibres de carbone
PRFV	Polymère renforcé de fibres de verre
R^2	Coefficient de détermination
ReLU	Unité linéaire rectifiée
RF	Forêt aléatoire
RFE	Élimination récursive des caractéristiques
<i>RM</i>	Méthode de renforcement
RMSE	Racine carrée de l'erreur quadratique moyenne
RR	Régression Ridge
SELU	Unité linéaire exponentielle échelonnée
SVM	Machines à vecteurs de support
tanh	Tangente hyperbolique
TPE	Parzen à structure d'arbre
XGBoost	eXtreme Gradient Boosting
α_f	Angle d'inclinaison du PRF
ρ_f	Ratio du renforcement transversal PRF
ϵ_{fu}	Déformation ultime du PRF
ρ_s	Ratio de l'acier de cisaillement
ρ_{sl}	Ratio du renforcement longitudinal en acier

Liste des Figures

Fig. 1.1	Développement continu des composites à matrice FRP depuis le début des années 1970 jusqu'à présent.....	10
Fig. 1.2	Quatre types de barres en FRP	12
Fig. 1.3	Comparaison des matériaux FRP avec l'acier	13
Fig. 1.4	Composants d'un matériau composite en PRF	16
Fig. 1.5	Renforcement par composites PRF collés extérieurement (EBR)	21
Fig. 1.6	Renforcement par PRF monté près de la surface (NSM).....	22
Fig. 1.7	Description des principales applications du renforcement par composites PRF collés sur ouvrages de génie civil – (a) Renforcement à la flexion des poutres ; (b) Renforcement à l'effort tranchant des poutres ; (c) Confinement des colonnes	23
Fig. 1.8	Marchés actuels et applications des matériaux PRF.....	25
Fig. 1.9	Techniques de renforcement en flexion (par exemple, composites en PRFC).....	27
Fig. 1.10	Renforcement au cisaillement	29
Fig. 2.1	Dents en béton dans le système structural en forme de peigne	33
Fig. 2.2	Graphique de la vallée de Kani	34
Fig. 2.3	Résistance au cisaillement dans le mécanisme d'action de poutre	35
Fig. 2.4	Engrènement des granulats dans (a) le béton de gravillon (résistance intermédiaire et faible) et (b) le béton léger	37
Fig. 2.5	Résistance au cisaillement dans le mécanisme d'action de l'arc.....	37
Fig. 2.6	Modes de rupture par cisaillement	42
Fig. 2.7	Analogies de treillis.....	43
Fig. 2.8	Modèles de bielle et tirant pour une poutre en BA.....	44
Fig. 2.9	Configurations de renforcement au cisaillement par collage latéral (S)	47
Fig. 2.10	Configurations de renforcement au cisaillement par chemisage en U	47
Fig. 2.11	Configurations de renforcement au cisaillement par enveloppement (W).....	48
Fig. 2.12	Mécanismes de rupture des poutres en BA renforcées au cisaillement par PRF collés extérieurement	50

Fig. 3.1	Intelligence artificielle, apprentissage automatique et apprentissage profond.....	57
Fig. 3.2	Catégories d'algorithmes d'apprentissage automatique	59
Fig. 3.3	Flux de travail global des modèles d'apprentissage automatique.....	60
Fig. 3.4	Architecture d'un simple modèle ANN et son composant principal, le neurone.....	62
Fig. 3.5	Exemple d'un arbre de décision.....	65
Fig. 3.6	Entraînement parallèle de la forêt aléatoire (RF)	66
Fig. 3.7	Algorithme AdaBoost : une représentation visuelle avec deux apprenants faibles.....	67
Fig. 3.8	Une représentation visuelle du modèle GBM	68
Fig. 4.1	Architecture d'un dense CMNN modèle.....	85
Fig. 4.2	Organigramme du processus de mise en œuvre des modèles d'apprentissage automatique	87
Fig. 4.3	Représentation de la signification physique des variables	91
Fig. 4.4	Aperçu de la base de données expérimentale raffinée : (a) géométrie des poutres, (b) schémas de distribution des PRF, (c) armatures internes en acier, et (d) types de matériaux PRF	93
Fig. 4.5	Distributions d'histogrammes des attributs numériques et de la sortie	95
Fig. 5.1	Représentation visuelle de la performance prédictive des modèles d'apprentissage automatique : (Colonne 1) Contribution au cisaillement prédite par rapport à la contribution expérimentale du PRF, (Colonne 2) Distribution du rapport $V_{f,exp}/V_{f,préd}$, et (Colonne 3) Diagramme en boîte du rapport $V_{f,exp}/V_{f,préd}$	116
Fig. 5.2	Contribution au cisaillement des PRF vs. Résistance à la compression du béton (f_{ck}) pour différentes épaisseurs de PRF (t_f).	121
Fig. 5.3	Contribution au cisaillement des PRF vs. Profondeur effective de la poutre (d) pour différentes hauteurs de feuille de PRF (h_f)......	122
Fig. 5.4	Contribution au cisaillement des PRF vs. Taux d'armature transversale en acier (ρ_{sw}) pour différentes épaisseurs de PRF (t_f)......	123
Fig. 5.5	Comparaison des résultats prédits de différents modèles basés sur l'ensemble des données expérimentales.....	131

Liste des Tableaux

Tableau 1.1	Propriétés typiques du PRFC	13
Tableau 1.2	Propriétés typiques du PRFV	14
Tableau 1.3	Propriétés typiques du PRFA	15
Tableau 1.4	Propriétés typiques du PRFB	15
Tableau 1.5	Propriétés des résines thermodurcissables de la matrice de PRF	16
Tableau 2.1	Résumé des formulations de conception pour le renforcement au cisaillement avec PRF collés extérieurement.....	53
Tableau 3.1	Résumé des techniques d'apprentissage automatique pour prédire la résistance au cisaillement des poutres en BA renforcées par FRP collé extérieurement	71
Tableau 4.1	Répartition des spécimens dans la base de données raffinée.....	93
Tableau 4.2	Statistiques descriptives des paramètres d'entrée et de sortie utilisés pour prédire V_f	94
Tableau 4.3	Valeurs optimales des hyperparamètres utilisés dans la modélisation XGB et MXGB.	108
Tableau 4.4	Valeurs optimales des hyperparamètres utilisés dans la modélisation DNN et CMNN	108
Tableau.5.1	Détails exhaustifs des mesures de performance pour chaque modèle dans les phases d'entraînement et de test.....	112
Tableau.5.2	Résumé des variations des paramètres d'entrée pour l'investigation basée sur des scénarios de la contribution au cisaillement des PRF.....	120
Tableau.5.3	Évaluation comparative : modèle CMNN vs. Dispositions des codes de conception.....	130

Introduction Générale

Généralités

Les structures en béton armé (BA) constituent une partie substantielle des infrastructures mondiales, comprenant de nombreux bâtiments et installations. Cependant, un nombre important de ces structures dans le monde connaissent une détérioration, principalement due au vieillissement, au manque d'entretien adéquat et à l'exposition continue à des conditions environnementales rudes. Cette dégradation présente non seulement de graves dangers pour la sécurité publique, mais impose également des charges financières importantes en raison des coûts élevés associés à leur réparation ou leur remplacement. Ces dépenses mettent souvent à rude épreuve les budgets alloués à l'entretien et au développement des infrastructures (Stewart and Val 2003). En conséquence, il est devenu une priorité cruciale pour les communautés du monde entier de développer des techniques de réhabilitation rentables et efficaces afin de prolonger la durée de vie des structures en BA existantes et déficientes.

Le collage externe de composites en polymères renforcés de fibres (PRF) sur la surface des éléments en BA est apparu comme une technique prometteuse pour le renforcement et la réfection des structures déficientes au cours des dernières décennies. Les avantages des matériaux PRF sont multiples, notamment leurs rapports résistance/poids exceptionnellement élevés et leur impressionnante résistance à la corrosion, ce qui en fait une alternative favorable aux méthodes de renforcement traditionnelles (Sen and Mullins 2007 ; Zhou et al. 2019). En particulier, le procédé d'enroulement manuel permet le collage de fines feuilles de PRF flexibles sur les structures existantes, facilitant ainsi des modifications minimales de la géométrie structurelle et architecturale. De plus, les matériaux PRF présentent des rapports rigidité/poids élevés, une durabilité supérieure et une excellente résistance à la fatigue, améliorant considérablement la longévité et la résilience des structures (Van et al. 2003). Par conséquent, les composites PRF collés extérieurement sont de plus en plus reconnus comme une solution rapide, non invasive et rentable pour améliorer la capacité portante des ponts, bâtiments et autres infrastructures critiques en BA détériorés. Leur utilisation a été largement adoptée pour le renforcement en flexion, en cisaillement et en confinement des poutres, colonnes, dalles et autres éléments en béton (Chen et al. 2018 ; Lin and Teng 2020 ; Michel et al. 2009 ; Oller et al. 2019).

Bien qu'une recherche considérable ait été menée sur les applications de renforcement en flexion et en confinement, l'application des composites PRF pour améliorer la résistance au cisaillement des éléments en BA reste plus complexe et difficile (Chen et al. 2010 ; Jumaa and Yousif 2019). La rupture au cisaillement dans les éléments en BA est soudaine et

catastrophique, ce qui en fait un mode de rupture critique à prévenir (Khalifa and Nanni 2000). Cependant, il n'y a toujours pas de consensus au sein de la communauté de recherche et des dispositions relatives aux codes concernant l'évaluation de la contribution à la résistance au cisaillement des renforts en PRF collés extérieurement. Cela est attribuable à plusieurs facteurs, notamment (a) la complexité des mécanismes de rupture au cisaillement, (b) les ruptures potentielles du décollement spécifiques aux configurations de PRF, (c) le comportement linéaire élastique des PRF par rapport à la plastification de l'acier et (d) les interactions complexes entre le béton, les étriers en acier internes, les armatures longitudinales et les PRF externes (Oller et al. 2021). Trois principaux schémas de renforcement au cisaillement par PRF sont appliqués dans la pratique : (i) l'enveloppement complet des sections transversales à l'aide de feuilles de PRF continues, (ii) les chemises en PRF en forme de U collées sur le dessous et les côtés des éléments, et (iii) les feuilles ou bandes de PRF collées uniquement sur les surfaces latérales. Des feuilles continues sur toute la portée et des bandes de PRF discontinues avec un espacement régulier peuvent être mises en œuvre. Le système d'enveloppement complet offre l'amélioration la plus significative de la résistance au cisaillement en fournissant la surface maximale de collage PRF-béton pour prévenir les fissures de cisaillement (Kotynia et al. 2021). Cependant, la complexité de construction associée au passage des feuilles de PRF autour des coins dans le cas des poutres en T dissuade souvent l'adoption de l'enveloppement complet. Le collage latéral est le plus facile à installer mais offre la plus faible amélioration de la résistance au cisaillement. Les chemises en U présentent un compromis entre la facilité de construction et l'efficacité du renforcement. Pour les chemises en U et le collage latéral, le décollement avant d'atteindre la capacité ultime du PRF est une préoccupation majeure et un mode de rupture potentiel. Le décollement peut être retardé en incorporant des systèmes d'ancrage mécanique (Kalfat et al. 2013 ; Kalfat and Al-Mahaidi 2016).

Au cours des deux dernières décennies, de nombreuses études expérimentales ont exploré le comportement au cisaillement des poutres en BA renforcées avec des composites PRF collés extérieurement. Les chercheurs ont étudié systématiquement les effets de plusieurs paramètres, notamment la quantité et la configuration de PRF, la résistance à la compression du béton, les étriers en acier internes et le rapport portée de cisaillement sur profondeur, sur la réponse au cisaillement et la capacité résultantes des poutres renforcées en PRF (Gonzalez-Liberos et al. 2017 ; Li and Leung 2015; Mofidi and Chaallal 2014a; Sengun and Arslan 2022). Différents schémas de renforcement tels que l'enveloppement complet, le chemisage

en U et le collage latéral ont été testés (Samb et al. 2022 ; Shahriari and Naderpour 2020). L'influence de facteurs tels que la largeur, l'espacement, l'épaisseur et l'orientation des fibres des bandes de PRF a été étudiée (Al-Rousan and Haddad 2013 ; Alsayed and Siddiqui 2013 ; Hawileh et al. 2015). Des essais ont également évalué les performances des feuilles de PRF continues par rapport aux bandes discrètes (Jin et al. 2022). De plus, divers modèles analytiques, directives de conception et codes ont été proposés dans le monde entier pour prédire la contribution du PRF à la résistance totale au cisaillement des poutres en BA renforcées en PRF. Cependant, la précision et la fiabilité de ces modèles restent limitées. La plupart des spécifications de conception, ainsi que des études dans la littérature, simplifient le problème en négligeant l'interaction complexe entre la contribution du PRF et les autres contributions à la résistance au cisaillement des poutres en BA, à savoir le béton et les armatures de cisaillement internes, et en considérant la contribution à la résistance au cisaillement du PRF comme une contribution additive à la résistance au cisaillement de la poutre non renforcée. Ces hypothèses simplificatrices et l'incapacité à saisir les interactions complexes entre les variables, ainsi que les ensembles de données de calibration limités disponibles lors du développement des modèles, ont conduit à des écarts entre les prédictions des modèles et les résultats expérimentaux qui continuent d'entraver la codification et la confiance généralisée dans la conception du renforcement au cisaillement par PRF (Huang et al. 2023 ; Mhanna et al. 2021 ; Oller et al. 2021).

Récemment, les techniques d'apprentissage automatique basées sur les données ont démontré un immense potentiel pour relever les défis complexes de l'ingénierie. L'apprentissage automatique fait référence aux algorithmes de calcul qui peuvent automatiquement apprendre et s'améliorer sur des tâches spécifiques grâce à l'exposition aux données, plutôt qu'à une programmation explicite. Le concept fondamental est que l'ordinateur découvre les modèles et relations latents au sein des données par un processus d'optimisation itératif, identifiant les facteurs clés influençant le mappage entrée-sortie. Correctement conçus, les modèles d'apprentissage automatique présentent une capacité supérieure à représenter des comportements hautement non linéaires par rapport aux modèles traditionnels. Avec suffisamment de données de haute qualité pour l'entraînement, les algorithmes d'apprentissage automatique ont démontré leur capacité à représenter des phénomènes d'ingénierie complexes et à fournir une précision prédictive nettement améliorée. Plusieurs études ont déjà appliqué des algorithmes d'apprentissage automatique, notamment les réseaux de neurones artificiels (ANN), les algorithmes génétiques (GA), les systèmes d'inférence neuro-flous adaptatifs

(ANFIS), la régression par vecteurs de support (SVR), les arbres de décision (DT) et l'apprentissage ensemble (forêt aléatoire (RF), AdaBoost, XGBoost, etc.) pour estimer la résistance au cisaillement des éléments en BA renforcés avec des composites PRF collés extérieurement (Abuodeh et al. 2020 ; Kamgar et al. 2020 ; Kar et al. 2020 ; Kar and Biswal 2020 ; Naderpour and Alavi 2017 ; Nehdi and Nikopour 2011 ; Perera et al. 2010a ; Perera et al. 2010b ; Rahman et al. 2023 ; Anvari et al. 2023 ; Tanarslan et al. 2012 ; Wang et al. 2023).

Malgré les capacités prédictives démontrées de ces modèles d'apprentissage automatique, il existe encore un manque de transparence et d'interprétabilité des relations apprises, freinant leur adoption généralisée dans les applications d'ingénierie structurelle critiques pour la sécurité. Une limite fondamentale est leur incapacité à maintenir des relations monotones par rapport à certaines caractéristiques d'entrée. La monotonie fait référence à la propriété selon laquelle un changement dans une caractéristique d'entrée entraîne systématiquement un changement de la sortie dans une direction spécifique (croissante ou décroissante). Cependant, les modèles d'apprentissage automatique purement basés sur les données peuvent ne pas parvenir à saisir et à imposer de telles relations monotones, conduisant à des prédictions violant les principes physiques fondamentaux et les connaissances du domaine. Ce manque de respect des principes physiques établis régissant le comportement des composites PRF collés extérieurement dans les applications de renforcement au cisaillement peut compromettre la fiabilité et la crédibilité de ces modèles. Les développements récents dans les méthodes d'apprentissage automatique sous contraintes (Daniels and Velikova 2010 ; Gupta et al. 2019 ; You et al. 2017) ont introduit la possibilité d'incorporer les connaissances du domaine et les contraintes physiques, telles que la monotonie, dans les modèles d'apprentissage automatique. Cette capacité est particulièrement précieuse dans les applications d'ingénierie structurelle, où le respect des principes physiques établis et des considérations théoriques est crucial pour assurer des conceptions fiables et sûres. L'imposition de la monotonie peut également améliorer la capacité de généralisation et la précision prédictive des modèles, à condition que la monotonie imposée soit alignée sur le motif sous-jacent (Liu et al. 2020 ; Sivaraman et al. 2020).

But de travail

Dans cette étude, six modèles d'apprentissage automatique avancés sont développés pour prédire avec précision la contribution à la résistance au cisaillement des systèmes PRF collés extérieurement sur les poutres en BA. L'approche proposée exploite des algorithmes de pointe, notamment l'eXtreme Gradient Boosting (XGBoost) (Chen and Guestrin 2016) et les

réseaux de neurones profonds (DNNs). L'analyse emploie un vaste ensemble de données expérimentales comprenant 394 spécimens de poutres en BA renforcées avec diverses configurations de PRF, englobant une large gamme de paramètres pour assurer une représentation réaliste des scénarios pratiques. Les modèles proposés sont développés selon deux approches distinctes : non monotone et monotone. Les modèles non monotones, XGBoost (XGB) et DNN, sont entraînés uniquement sur les données expérimentales sans imposer de contraintes explicites sur les relations entre les caractéristiques d'entrée et la variable cible. En revanche, les modèles monotones, XGBoost Monotone (MXGB) et Réseau de Neurones Monotone Contraint (CMNN) (Runje and Shankaranarayana 2022), intègrent une connaissance a priori des relations monotones attendues entre les paramètres d'entrée et la contribution à la résistance au cisaillement du PRF. De plus, deux modèles ensembles sont construits pour tirer parti des bénéfices potentiels de l'apprentissage ensemble : le Modèle Ensemble (ENSM) et le Modèle Ensemble Monotone (MENSM). L'ENSM combine les prédictions de XGB et DNN par une simple approche de moyenne, tandis que le MENSM intègre les prédictions de MXGB et CMNN en utilisant une stratégie de moyenne simple similaire. L'approche d'ensemble vise à capitaliser sur les forces diverses des modèles de base individuels tout en compensant leurs faiblesses respectives, réduisant ainsi l'impact des biais et des variances des modèles individuels, conduisant à des prédictions plus robustes et précises.

Plan des chapitres

Dans cette section, nous proposons de décrire les différentes étapes qui ont jalonné la réalisation de ce travail de recherche.

Le chapitre 1 présente un état de l'art détaillé sur les matériaux composites en polymères renforcés de fibres (PRF) utilisés pour le renforcement des structures en génie civil. Leurs composants, propriétés mécaniques, modes d'application et considérations d'adhérence sont abordés. Les principales applications dans le renforcement des colonnes, poutres et dalles sont illustrées.

Le chapitre 2 aborde les concepts fondamentaux liés à la résistance au cisaillement des poutres en BA, y compris les mécanismes de transfert des efforts, les modes de rupture et les approches analytiques de modélisation. Le renforcement au cisaillement par collage extérieur de PRF est examiné en détail, incluant les différentes configurations, les formulations réglementaires et les lacunes actuelles.

Le chapitre 3 fournit une revue approfondie de l'application des techniques d'apprentissage automatique pour prédire la résistance au cisaillement des poutres en BA renforcées par PRF collés extérieurement. Différentes méthodes telles que les réseaux de neurones artificiels, la programmation génétique et les modèles d'ensemble sont passées en revue. Les défis et les perspectives d'amélioration de ces approches sont également discutés.

Le chapitre 4 décrit en détail la méthodologie mise en œuvre dans cette étude. Il présente le processus de constitution et de raffinement de la base de données expérimentale exhaustive, ainsi que les différents algorithmes d'apprentissage automatique développés, notamment le l'eXtreme Gradient Boosting, les réseaux de neurones profonds et leurs variantes intégrant des contraintes de monotonie. Les stratégies d'optimisation des modèles et d'évaluation de leurs performances sont également exposées.

Le chapitre 5 présente une analyse approfondie des performances des modèles d'apprentissage automatique développés pour prédire la contribution à la résistance au cisaillement des PRF. Les résultats sont évalués à l'aide de multiples métriques statistiques et de représentations visuelles. Des investigations basées sur des scénarios sont menées pour examiner la capacité des modèles à capturer fidèlement les relations physiques connues. Enfin, une comparaison détaillée est effectuée entre le meilleur modèle d'apprentissage automatique et les directives de conception existantes.

Pour clore cette thèse, les principales conclusions tirées de cette étude sont présentées, accompagnées de perspectives et de recommandations pour de futures investigations dans ce domaine.

CHAPITRE 01

Propriétés et applications des PRF dans le renforcement des structures en BA : État de l'Art

1.1 Introduction

Le renforcement et la réhabilitation des infrastructures existantes en génie civil représentent un défi majeur auquel doivent faire face les ingénieurs et les gestionnaires d'actifs. De nombreux ouvrages d'art tels que les ponts, les bâtiments ou les structures hydrauliques souffrent de dégradations prématurées liées au vieillissement, aux conditions environnementales sévères, aux charges excessives ou encore à une conception et une construction inadaptée.

Face à ce constat, l'utilisation de matériaux composites à matrice polymère renforcée de fibres (PRF) offre des solutions innovantes et performantes. Ces matériaux, combinant des fibres de haute résistance noyées dans une matrice polymère, présentent d'excellentes caractéristiques mécaniques, une grande légèreté ainsi qu'une résistance élevée à la corrosion et aux agressions environnementales.

Les PRF trouvent ainsi de nombreuses applications dans le domaine de la construction, que ce soit comme armatures de renfort interne au sein d'éléments en BA, ou sous forme de renforts extérieurs collés ou insérés dans des surfaces en béton, bois ou maçonnerie. Ils permettent d'augmenter significativement les performances structurelles en termes de résistance à la flexion, au cisaillement, à la compression et à la traction.

Ce premier chapitre a pour objectif de présenter un état de l'art détaillé sur les matériaux composites PRF utilisés dans le renforcement des structures en génie civil. Leurs composants, propriétés mécaniques et modes d'application seront abordés, en s'appuyant sur la littérature scientifique récente. Les aspects liés à l'adhérence à l'interface PRF/substrat, cruciaux pour l'efficacité du renforcement, seront également discutés. Enfin, les principales applications dans le renforcement des colonnes, poutres et dalles seront illustrées à travers de nombreux exemples et études de cas.

1.2 Historique et évolution de l'utilisation des PRF pour le renforcement structural

L'utilisation initiale des PRF était connue sous le nom de barres d'armature en 1975, notamment en Russie (Fig. 1.1) (Garden and Hollaway, 1998; Hollaway, 2010). Le PRF est également reconnu sous le nom de plastique renforcé de fibres, comprenant des matériaux qui utilisent des fibres synthétiques ou naturelles pour améliorer automatiquement la rigidité et la résistance d'un modèle polymère (Hollaway, 2010). Les PRF utilisés pour renforcer les

structures sont extrêmement résistants, évalués à 8 fois plus robustes que les barres d'armature en acier classiques (Gdoutos et al., 2000). Le polymère renforcé de fibres de verre (PRFV) est utilisé comme tendons de précontrainte pour renforcer un pont en bois de 9 m de long (Taerwe, 1995). Des recherches pertinentes sur l'utilisation des PRF comme barres d'armature pour remplacer l'utilisation de plaques d'acier collées pour la restauration et le renforcement des ponts ont été lancées en Europe dans les années 1980. Mais aux États-Unis, les composites PRF ont été engagés pour le renforcement structurel pendant environ 25 ans (ACI 440 1R-15). Au cours de cette période, le composite PRF a été accepté comme un matériau de construction principal parallèlement à la somme des projets de renforcement par PRF réalisés. L'utilisation du PRF pour le renforcement, la réhabilitation et le réaménagement a acquis plus de réputation auprès des consultants en conception que les méthodes de renforcement traditionnelles, telles que la mise en place des composants supplémentaires en acier de construction (ACI 440 Part 6–8).

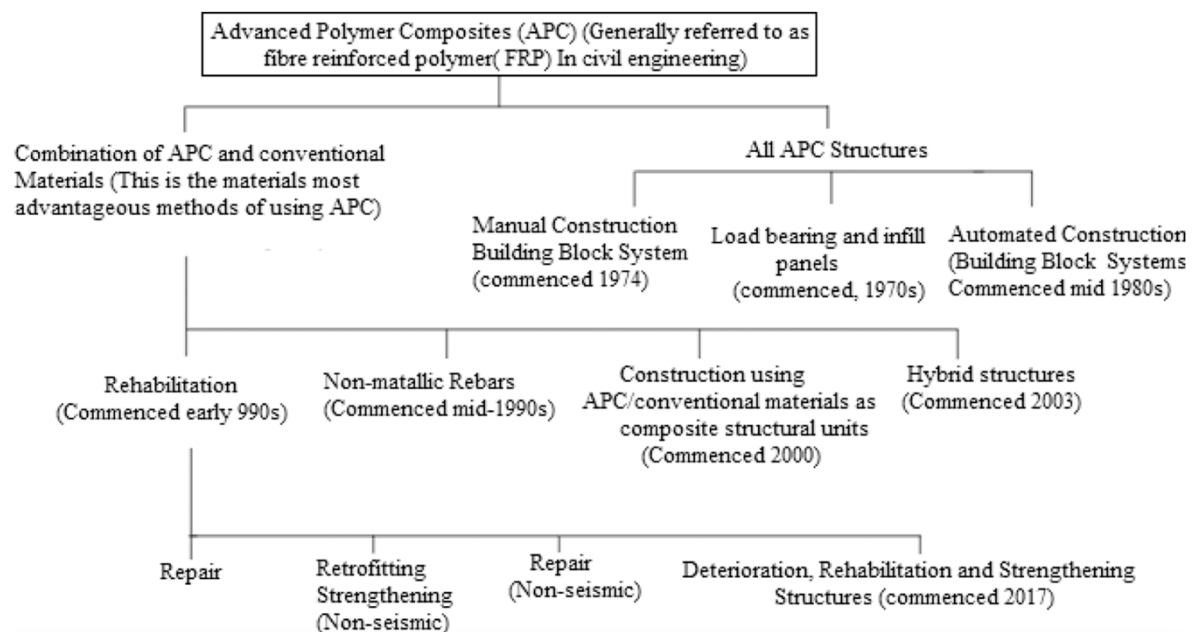


Fig. 1.1 — Développement continu des composites à matrice FRP depuis le début des années 1970 jusqu'à présent (Hollaway, 2010).

Le PRF est principalement utilisé comme renforcement intérieur, par exemple comme armature, ou comme renforcement externe collé pour renforcer les structures en béton, en bois, en acier et en maçonnerie (Al-Sunna et al., 2012). Au Japon, les barres de PRF ont connu un important soutien au cours des années 1990 grâce à l'étude sur des structures de support de train fascinantes (Teng et al., 2002). Le PRF possède également une caractéristique

de résistance à la traction unique supérieure à celle de l'acier mais ne pèse qu'un quart de celui-ci (Garden and Hollaway, 1998; Teng et al., 2002; Hollaway, 2010). En 1996, les Japonais ont été les premiers à annoncer les directives de conception pour le PRF dans le renforcement des structures en BA (Teng et al., 2002; Burgoyne, 2007). Par la suite, l'utilisation du PRF comme renforcement structurel s'est développée de manière exponentielle, et les codes et directives de conception ont été rédigés par les autorités du monde entier (CSA S807-10; Bakis et al., 2002). Le renforcement structurel avec un renfort PRF attaché extérieurement, en particulier avec un polymère renforcé de fibres de carbone à très haute résistance (PRFC), a été prouvé par les codes de conception pour les améliorations sismiques des structures pendant plusieurs années. Par exemple, le développement d'approches économiques et efficaces pour réparer, moderniser, renforcer ou rénover les ponts en BA existants a suscité un intérêt considérable récemment (Aashto, 2009; Calvi et al., 2005). La motivation pour renforcer un pont en BA existant provient généralement de deux sources : la nécessité de mettre à niveau la résistance du pont pour suivre l'augmentation du poids des véhicules de conception et le désir de rénover la détérioration qui s'est produite au fil des années de service (Cheng et al., 2005; Dong et al., 2014). La charge structurelle imposée aux éléments peut être augmentée en les enveloppant avec les renforts de PRF (Breña et al., 2001; Ning et al., 2015). Cependant, le PRF a vu sa croissance sur le marché augmenter ces dernières années, et ce marché devrait connaître une croissance rapide au cours de la période à venir.

1.3 Matériaux typiques des PRF

Les matériaux composites sont fabriqués en combinant deux ou plusieurs matériaux dans lesquels chaque matériau possède des caractéristiques uniques complètement différentes des matériaux individuels ajoutés (Weli et al., 2020). Le composite PRF est conçu à partir de fibres, de résines, d'une interface, de charges et d'additifs. Les fibres ont un module d'élasticité élevé contribuant aux propriétés mécaniques du PRF. Tandis que les résines aident à transférer ou à répartir les contraintes d'une fibre à l'autre afin de les protéger des dommages mécaniques et environnementaux. L'interface entre les fibres et la matrice est reconnue pour influencer de manière sûre le comportement des composites PRF. Outre ces trois constituants principaux, les charges permettent de réduire le retrait et le coût. Les additifs servent à améliorer les propriétés physiques et mécaniques ainsi que l'ouvrabilité pour les composites (Gudonis et al., 2013).

Les renforts composites PRF mutuellement utilisés dans le génie civil sont fabriqués par un procédé de pultrusion à partir de fibres de carbone (pour produire le PRFC), de fibres de verre (pour produire le PRFV), de fibres de basalte (pour produire le PRFB) et de fibres d'aramide (pour produire le PRFA) (Fig. 1.2) (Ammar, 2014; Banibayat and Patnaik, 2013). Le PRFV-E est le matériau le moins cher de tous les PRF structurels et est donc le plus consommé (Brothers, 2001). Contrairement au PRFV-E, le PRFB coûte plus cher en raison du manque de capacité de production des fabricants; cependant, son coût est raisonnable compte tenu de sa résistance supérieure au PRFV, de sa résistance aux alcalis et de sa ressource quasi infinie (Taerwe, 1995). La Fig. 1.3 illustre la comparaison globale entre les matériaux PRF et les armatures en acier sur la base du comportement contrainte-déformation. Le PRFA n'est pas une barre structurelle populaire en raison de sa faible résistance à la compression quelle que soit la direction de l'alignement des fibres et de son coût élevé (Davies et al., 2011; Sahu et al., 2014). La fibre d'aramide est le meilleur choix pour les tissus résistants aux balles puisque la fibre absorbe efficacement l'impact (Palmieri et al., 2012). Le PRFC a la plus haute résistance parmi les matériaux PRF et la plus grande variété de résistances (Zhou et al., 2016). Cette variété est due à la source de carbone et aux techniques de production. Cependant, le PRFC a montré la plus haute résistance à la fatigue et à la rupture par fluage que les autres matériaux PRF (Liu et al., 2010). Le coût élevé du PRFC est compensé par sa grande résistance et sa résistance à la fatigue et aux défaillances cycliques (Abdelrahman and El-Hacha, 2014; Das, 2001; Delgado et al., 2012). Les matériaux PRF sont examinés en détail dans les sous-sections suivantes.



Fig. 1.2 — Quatre types de barres en FRP (Abbood et al., 2021).




Fig. 1.3 — Comparaison des matériaux FRP avec l'acier (Abbood et al. 2021).

1.3.1 Polymère Renforcée de fibres de Carbone PRFC

La fibre de carbone est un matériau anisotrope par nature, fabriqué à 1300°C. Les principaux avantages de cette fibre comprennent une faible densité, une faible conductivité, une haute résistance à la fatigue, un module d'élasticité élevé, un bon niveau de fluage, une résistance aux effets chimiques et elle n'absorbe pas d'eau non plus (Tableau 1.1). Cependant, la faible résistance à la compression et le caractère anisotrope (résistance radiale diminuée) sont les faiblesses de la fibre de carbone. De plus, les besoins énergétiques relativement élevés pour produire la fibre de carbone entraînent une augmentation des coûts, ce qui est considéré comme une autre faiblesse (Gudonis et al., 2013; Günaslan et al., 2014).

Tableau 1.1 — Propriétés typiques du PRFC (Uomoto et al. 2002).

Propriété	Fibre de carbone			
	Polyacrylonitrile Carbone		Carbone de Brai	
	Haute résistance	Haut module	Ordinaire	Haut module
Densité (gm/cm ³)	1,7–1,8	1,8–2,0	1,6–1,7	1,9–2,1
Résistance à la traction (MPa)	3430	2450–3920	764–980	2940–3430
Module de Young (GPa)	196–235	343–637	37–39	392–784
Allongement (%)	1,3–1,8	0,4–0,8	2,1–2,5	0,4–1,5
Coefficient de dilatation thermique (10 ⁻⁶ /°C)	-0,6 up to -0,2	-1,2 up to -0,1	-0,6 up to -0,2	-1,2 up to -0,1

1.3.2 Polymère Renforcée de fibres de Verre PRFV

La fibre de verre est de nature isotrope et le filament le plus couramment utilisé. Le verre E, le verre S, le verre C et le verre AR sont les types de fibres de verre les plus populaires (Tableau 1.2). Une grande résistance, une bonne résistance à l'eau et aux produits chimiques avec un faible coût sont les principales caractéristiques de la fibre de verre. Des coûts relativement faibles par rapport aux autres types de PRF font de la fibre de verre le matériau le plus généralement utilisé dans l'industrie de la construction. Néanmoins, un module d'élasticité relativement faible, une faible résistance aux alcalins avec une faible résistance à long terme due à la rupture sous contrainte sont les principaux inconvénients de la fibre de verre. Dans les cas où une meilleure résistance aux alcalins est requise, le verre AR supposé pourrait être utilisé (Gudonis et al. 2013; Günaslan et al. 2014; Sonnenschein et al. 2016).

Tableau 1.2 — Propriétés typiques du PRFV (Uomoto et al. 2002).

Nom commercial	Densité (gm/cm ³)	Résistance à la traction (MPa)	Module de Young (GPa)	Allongement à la rupture (%)	Coefficient de dilatation thermique (10 ⁻⁶ /°C)
Verre E	2,5	3450	72,4	2,4	5,0
Verre S	2,5	4580	85,5	3,3	2,9
Verre C	2,5	3300	69	2,3	n/a
Verre AR	2,27	1800–3500	70–76	2,0–3,0	n/a

1.3.3 Polymère Renforcée de fibres d'Aramide PRFA

La fibre d'aramide est de nature anisotrope et généralement de couleur jaune. La fibre d'aramide est populairement appelée fibre Kevlar sur le marché, comme expliqué dans le Tableau 1.3. Les fibres d'aramide coûtent beaucoup plus cher que les fibres de verre, suffisantes pour les applications de traction comme les tendons et les câbles, cependant, elles ont une faible résistance à la compression. Elles ont une faible densité, une haute résistance à la traction, un module d'élasticité élevé et une rigidité suffisante. Cette fibre peut être utilisée pour les structures résistantes aux chocs statiques et dynamiques. Néanmoins, son application est restreinte en raison de sa faible résistance à long terme (rupture sous contrainte) et de sa faible résistance radiale. De plus, la difficulté de coupe et de mise en œuvre est une autre faiblesse de la fibre d'aramide. Il existe plusieurs types de Kevlar ayant diverses caractéristiques typiques telles que Kevlar-29, Kevlar-49, Kevlar-149, Technora H, Twaron et Twaron HM (Gudonis et al., 2013; Günaslan et al., 2014; Tuakta, 2005).

Tableau 1.3 — Propriétés typiques du PRFA (Uomoto et al. 2002).

Propriété	Fibre d'aramide					
	Kevlar-29	Kevlar-49	Kevlar-149	Technora H	Twaron	Twaron HM
Densité (gm/cm ³)	1,44	1,44	1,44	1,39	1,44	1,45
Résistance à la traction (MPa)	2760	3620	3450	3000	3000	3000
Module de Young (GPa)	62	124	175	70	80	124
Allongement à la rupture (%)	4,4	2,2	1,4	4,4	3,3	2,0
Coefficient de dilatation thermique (10 ⁻⁶ /°C)	-2,0 longitudinal, 59 radial					

1.3.4 Polymère Renforcée de fibres de Basalte PRFB

La fibre de basalte est un type de roche ignée qui se forme par le refroidissement rapide de la lave à la surface de la planète. La production de la fibre de basalte est similaire à celle des fibres de verre. Les roches de basalte concassées sont la seule matière première nécessaire pour fabriquer la fibre. Les fibres de basalte sont relativement nouvelles dans les composites PRF et les matériaux de structure. De telles fibres ont une haute résistance à la traction, une résistance parfaite aux hautes températures et une bonne durabilité (Tableau 1.4). D'autres avantages sont d'avoir d'excellentes caractéristiques électromagnétiques et d'être résistantes à la corrosion, aux acides, aux radiations et aux vibrations. Par rapport aux composites PRF fabriqués à partir de fibres de verre, de carbone et d'aramide, l'application du PRFB dans le domaine de la construction civile est assez limitée (Banibayat 2011; Brainard Abraham et al. 2020; Sonnenschein et al. 2016).

Tableau 1.4 — Propriétés typiques du PRFB (Landesmann et al. 2015).

Nom commercial	Résistance à la traction (MPa)	Module de Young (GPa)	Allongement (%)	Coefficient de dilatation thermique (10 ⁻⁶ /°C)
Rockbar	1000	50	2.24	2,0
BCR	1100	70	2.20	0,35–0,592

1.4 Matrice de PRF

La résine est l'agent de liaison de plusieurs composites de PRF et est également connue sous le nom de matrice. Les résines les plus typiques sont les polymères thermodurcissables et thermoplastiques (Gay, 1991). Le choix des résines lors du processus de production est crucial car ce choix a un impact sur les caractéristiques mécaniques des composites. Le polymère thermoplastique ne peut pas être utilisé pour les solutions de génie civil en raison de ses faibles résistances au fluage et à la chaleur. Cependant, les résines thermodurcissables, telles que les polyesters, les époxyes et les esters vinyliques (Tableau 1.5), qui sont les résines

les plus utilisées, présentent une stabilité thermique appropriée et une résistance aux agents chimiques et subissent un faible fluage et une faible réduction des contraintes, comme prescrit par le manuel de conception ISIS 2007 (Gay, 1991; Banibayat and Patnaik, 2013) et illustré dans le Tableau 1.5. De plus, les PRF sont des composites constitués de fibres et d'une matrice (Fig. 1.4). Les fibres sont les éléments qui supportent les charges appliquées, et la matrice assure la cohésion des fibres, la re-transition des charges appliquées aux fibres, et la protection des fibres contre l'environnement extérieur (Shokrieh and Omid, 2009).

Tableau 1.5 — Propriétés des résines thermodurcissables de la matrice de PRF (Gay, 1991).

Résine	Densité (ou gravité spécifique)	Résistance à la traction (MPa)	Module de traction (GPa)	Retrait de durcissement (%)
Époxy	1,2–1,3	55–130	2,75–4,1	1–5
Ester vinylique	73–81	1,12–1,32	3–3,35	5,4–10,3
Polyester	1,1–1,4	34,5–103,5	2,1–3,45	5–12




Fig. 1.4 — Composants d'un matériau composite en PRF.

1.4.1 Résine époxy

C'est un type de résines synthétiques comprenant une grande diversité, et avec un développement continu, elle peut être utilisée comme adhésif, revêtement, fondant, plastique de moulage et résine matricielle pour les PRF, qui sont appliqués dans les applications de construction (Wang et al., 2011). Le faible retrait et la simplicité de fabrication rendent la résine époxy remarquablement adaptée à de nombreuses applications. Par rapport au polyester thermodurcissable, la résine époxy a généralement de meilleures propriétés et une excellente résistance à la chaleur et aux produits chimiques, en particulier aux alcalins (Gibson, 2017).

Les résines époxy sont les substrats les plus couramment utilisés par de nombreux chercheurs en raison de leurs bonnes caractéristiques mécaniques, de leur résistance à la corrosion, de leur polyvalence et de leur durabilité (Nagaraja et al., 2021).

1.4.2 Ester vinylique

Cette résine thermodurcissable peut être utilisée comme substitut aux résines époxy et polyester en tant que matrice polymère thermodurcissable dans les composites PRF, car sa résistance, ses propriétés et ses coûts totaux sont intermédiaires entre l'époxy et le polyester. La résine ester vinylique a une viscosité minimale (environ 200 cps) inférieure à celle de l'époxy (environ 900 cps) et du polyester (environ 500 cps). C'est une résine populaire considérée pour les industries marines en raison de sa caractéristique anti-corrosion et de sa capacité à résister à l'absorption d'eau. L'ester vinylique est une résine largement appliquée pour la production de navires et de réservoirs en PRF conformément à la norme BS4994. Elle améliore les résistances et les caractéristiques mécaniques de manière moindre que l'époxy et supérieure aux résines polyester. La résine vinylique est souvent appliquée dans les matériaux de stratification et de réparation en raison de son étanchéité et de sa fiabilité (Yadav et al., 2018).

1.4.3 Polyester

La résine polyester est très largement utilisée dans les composites PRF en raison de son faible coût, de sa résistance à la corrosion, de sa cure rapide, de sa commodité et de sa tolérance aux températures. Néanmoins, elle présente quelques inconvénients, notamment un faible module d'élasticité et une amélioration jusqu'à (5-15) % seulement. Le polyester peut également produire un fluage. Le polyester produit un allongement à la rupture en traction d'environ (1-2) % par rapport à la résine époxy typique qui a (3,5-4,5) %. La résine polyester est désirée en raison de son coût minimum, tandis que la résine ester vinylique est préférée en raison des environnements saturés (Mugahed Amran et al., 2018; Idicula et al., 2006).

1.5 Propriétés mécaniques

Les propriétés mécaniques des composites PRF dépendent de la proportion de fibres et de matériaux matriciels, des méthodes de fabrication, des caractéristiques mécaniques des matériaux constitutifs et de l'orientation des fibres à travers la matrice. Les fibres peuvent être conçues sous "Forme Continue" (les fibres alignées et continues sont généralement droites et longues ainsi que parallèles entre elles) ou sous "Forme Tissée" (les fibres produites sous

forme de tissu et fournissant une résistance multidirectionnelle) ou sous "Forme Coupée" (les fibres sont généralement disposées de manière irrégulière et discontinue et courtes) (Abbood et al., 2021).

1.5.1 Résistance à la compression

Le PRFC et le PRFA ont respectivement la plus haute et la plus basse résistance à la compression, comparés aux autres composites PRF typiques (Sahu et al., 2014). Cependant, la résistance est élevée si les fibres de basalte sont soit placées sur la face, soit fournies en remplaçant les couches à travers le composite formant une forme de sandwich (Saradini et al., 2014). La résistance à la compression pour les fibres à base d'époxy est supérieure à celle des fibres à base de polyester, indiquant que la résistance du composite à base de polyester en tant que matrice avec ou sans charges est inférieure à celle des stratifiés à base d'époxy (Dhawan et al., 2013). Il a été révélé que la résistance des colonnes creuses enveloppées par (1 couche) et (3 couches) de PRFC est améliorée de 66% et 123% respectivement, tandis que l'enveloppement avec du PRFV n'a amélioré que de 36% et 105% (Zarringol and Zarringol, 2016). Néanmoins, pour une colonne creuse remplie de béton et enveloppée de (3 couches) de PRFC, la résistance a augmenté de 154% tandis que pour celle enveloppée de PRFV avec les mêmes couches, elle a augmenté de 144%. La réduction de la capacité de résistance à la compression de la colonne est causée par l'augmentation du moment intérieur (Han et al., 2014). Le béton à ultra-haute performance (BUHP) renforcé par des PRF a produit des résistances à la compression d'au moins 115% supérieures à celles du BUHP normal (Hung et al., 2017). De plus, en ce qui concerne les structures sandwich renforcées avec du PRFC, il a été constaté que la résistance à la compression est supérieure d'environ 24,68% à celle des structures non renforcées (Wu et al., 2016). L'épaisseur de la couche de PRF améliore efficacement la résistance à la compression des zones d'éléments en béton renforcés (Zhou et al., 2016).

1.5.2 Résistance au cisaillement

Le renforcement au cisaillement pour les éléments en BA peut être produit par collage époxydique avec des fibres aussi parallèles que pratiquement possible aux contraintes principales de traction. Le renforcement peut être mis en œuvre par enveloppement des éléments soit partiellement, soit complètement selon l'accessibilité (Bakis et al., 2002). L'augmentation de la quantité d'humidité absorbée par l'époxy entraîne une perte de la

résistance au cisaillement requise pour les éléments en BA (Selzer and Friedrich, 1995; Selzer and Friedrich, 1997). Cependant, afin de résister aux contraintes de cisaillement, des étriers ou des liens doivent être mis en place sur les éléments renforcés de PRF ou se fier uniquement à la résistance du béton aux charges de cisaillement si ce n'est pas fonctionnel comme dans le cas des réservoirs en BA (ACI 440 2R-17). La majorité des barres d'armature en PRF ont une rigidité ou un module d'élasticité remarquablement faible. Une faible rigidité indique la nécessité d'éléments profonds ou d'un renfort supplémentaire pour soulager la déflexion à long terme et réduire les ouvertures de fissures (Arya et al., 2002). Le calcul de la résistance au cisaillement pour les PRF utilise les procédures ACI 318-19, tandis que l'ACI 440 6-08(17) ne permet pas l'action de goujon pour les barres d'armature en PRF pour résister au cisaillement, contrairement à l'ACI 318-19 qui améliore la résistance au cisaillement pour les barres d'armature en acier. En outre, les textiles sont généralement développés pour présenter un profil charge-déformation spécifique dans les directions à 45 degrés, permettant l'effet idéal de la résistance au cisaillement de la poutre (Nabil et al., 2003). Néanmoins, les jauges de déformation en rosette ont révélé que les feuilles produisaient une résistance au cisaillement au-delà des fissures de cisaillement.

1.5.3 Résistance à la flexion

Les éléments renforcés de PRF sont normalement sur-renforcés, ce qui signifie que le pourcentage de barre de PRF par rapport au béton est supérieur au rapport équilibré. Par conséquent, le mode de rupture est contrôlé par l'écrasement du béton pour l'élément (ACI 440 6-08(17)). Néanmoins, lorsque le rapport de renforcement du béton est inférieur au rapport équilibré, le mode de rupture ductile est rencontré par le mode de rupture par rupture du PRF, ce qui n'est pas souhaitable (ACI 440 6-08(17); Sarasini et al., 2014). Le facteur de réduction de la résistance à la flexion varie de 0,55 à 0,65 en fonction du rapport de renforcement proposé par rapport au rapport de renforcement neutre en raison du manque de ductilité dans les modes de rupture du PRF (AASHTO 2009). Le facteur de réduction de résistance pour la rupture du PRF est égal à 0,55 à la rupture. Cependant, lorsque la rupture est destructrice dans le béton, le facteur de réduction de la résistance à la flexion a augmenté à 0,65, car le rapport de renforcement neutre du PRF est 1,4 fois inférieur au rapport de renforcement potentiel (AASHTO 2009). La résistance à la flexion pour la section enveloppée de PRFC a nettement diminué à mesure que le facteur de délaminage augmente (Haeger et al., 2016). Néanmoins, la résistance à la flexion pour les matériaux PRF est spécifiée en utilisant

l'ACI 440 identique à l'ACI 318 en raison du fait que les barres de PRF ne cèdent pas de la même manière que les barres d'armature en acier (ACI 318-19 ; ACI 440 6-08(17) ; ACI 440 1R-15). Pratiquement, il est supposé que l'aptitude à la flexion des parties renforcées a été limitée par la déformation de rupture pour les structures composites (Brena et al., 2001). Diverses recherches ont examiné les paramètres et les variables affectant la résistance à la flexion des composites PRF, tels que la longueur des fibres, la teneur en liant, les traitements thermiques et la pré-activation des fibres avant la création (Lim et al., 2014 ; Mastali and Dalvand, 2016). Pour le renforcement à la flexion, les barres d'armature, les feuilles et les plaques sont quelques-unes des formes de renforcement en PRF utilisées pour lier les côtés en traction du bois, du béton et de la maçonnerie. La résistance à la charge a été améliorée jusqu'à 40% par le renforcement des éléments fléchis (Mugahed Amran et al., 2018).

1.5.4 Résistance à la traction

Les PRF sont appliqués comme renfort intérieur et comme renforcement extérieur pour les structures en BA qui utilisent des fibres synthétiques dans des matrices polymères pour fournir une résistance à la traction massive parallèle à la direction des fibres (Jiao and Zhao, 2004). Les fibres sont disposées de manière droite, parallèle et continue à travers une matrice. Cependant, si les contraintes radiales d'éclatement commencent à devenir supérieures à la résistance à la traction dans l'élément en béton, des fissures se développeront et la liaison entre le béton et l'armature sera gravement affectée (Mugahed Amran et al., 2018). La valeur de la résistance à la traction des PRF est généralement spécifiée en fonction des types de fibres, de l'orientation des fibres, de la matrice, de l'interface de la section et de l'absorption d'humidité (Selzer and Friedrich, 1997). Par exemple, la résistance à la traction augmente à mesure que le rapport pondéral de fibre augmente d'une quantité spécifique (Fawzia et al., 2007). Néanmoins, il a été révélé que le PRFC a un faible poids et une haute résistance à la traction par rapport aux autres PRF courants (Mastali and Dalvand, 2016; Yu et al., 2012). Cette circonstance entraîne une réduction de poids considérable et un allongement de la portée pour les éléments précontraints (Han et al., 2015), considérant le PRFC comme un composite élastique-fragile économique. Pourtant, le PRFB présente une résistance à la traction et un allongement à la rupture de premier ordre (Hung et al., 2017). Wu et al. (2010) ont révélé que le PRFV a augmenté la résistance à la traction de 36% pour un PRF hybride par rapport à l'utilisation du PRFB, ce qui est supérieur de 2,56% au PBO (polyparaphénylène benzoisoxazole). Les recherches sur les PRFV ont montré que la résistance à la traction et la

résistance au cisaillement à courte portée pour la matrice ester vinylique sont légèrement influencées, tandis que la résistance à la traction pour la matrice polyester a nettement diminué de 80% (Cabral-Fonseca et al., 2012). De plus, les résistances à la traction pour le PRFV à base d'époxy et le PRFV à base de polyester diminuent d'environ 22,8% et 19,71% avec des charges de balle de riz et de balle de blé, respectivement (Zhao et al., 2016). Ce résultat conclut que la résistance à la traction du PRFV hybride est plus dispersive que celle obtenue uniquement par le PRFC ou le PRFV (Li et al., 2005).

1.6 Techniques de renforcement

Les approches de renforcement par collage externe (EBR) (Fig. 1.5) et par montage près de la surface (NSM) (Fig. 1.6) sont les approches de renforcement les plus courantes et les plus récemment utilisées pour les structures en BA (Maurizio et al., 2009; Deuring, 1993; Barnes and Mays, 1999). L'approche NSM est réalisée selon les étapes suivantes : (1) des fentes de 4 à 5 mm de largeur et de 12 à 15 mm de profondeur sont découpées à l'aide d'une tronçonneuse diamantée sur les surfaces en béton des éléments à renforcer, (2) les fentes sont nettoyées à l'air comprimé, (3) les couches de PRFC sont nettoyées à l'acétone, (4) la résine époxy est préparée conformément aux recommandations du fournisseur, (5) les fentes sont remplies avec la résine époxy, (6) la résine époxy est appliquée sur la surface des stratifiés, et (7) les stratifiés sont insérés dans les fentes et l'excédent de résine époxy est enlevé. Pour utiliser des tranches de stratifié PRFC découpées par l'approche EBR, les recherches ont réalisé les processus suivants (Shahawy and Beitelman, 1996; Das and Nizam, 2014) : (1) Sur les zones des surfaces de la poutre où les tranches du stratifié doivent être collées, de l'émeri a été utilisé pour éliminer le laitier superficiel ; (2) les résidus ont été écartés à l'air comprimé, (3) une couche d'apprêt a été appliquée pour uniformiser la surface du béton et améliorer la capacité de résistance du substrat en béton. Enfin, (4) les tranches du stratifié ont été collées sur les surfaces de la poutre à l'aide de résine époxy (Giamundo et al., 2014; Lima and Barros, 2011; Pellegrino and Vasic, 2014).



Fig. 1.5 — Renforcement par composites PRF collés extérieurement (EBR).



Fig. 1.6 — Renforcement par PRF monté près de la surface (NSM).

1.7 Les caractéristiques d'adhérence des PRF

Le collage des plaques ou des feuilles de PRF pour le renforcement et la réhabilitation des éléments en béton est devenu plus populaire dans les domaines du génie civil et de la construction en raison des caractéristiques remarquables, telles que la résistance à la corrosion et la légèreté, par rapport aux techniques de renforcement traditionnelles (Ammar, 2014 ; Ho et al., 2010). Cependant, l'adhérence au béton est essentielle pour la technique de renforcement extérieur, que ce soit pour la réparation ou le renforcement des éléments en BA. Dans la plupart des cas de renforcement, l'adhérence de l'interface est cruciale pour transférer les contraintes des structures en BA existantes aux composites PRF collés extérieurement (Maurizio et al., 2009; Deuring, 1993). Dans le système structurel en BA, le collage de feuilles présente un potentiel supérieur pour les défauts de construction, en raison du mélange

des résines et de la cure des composites PRF. L'Institut Japonais du Béton (JCI), Canada et la Grande-Bretagne ont reconnu un comité technique sur la technologie de rénovation qui s'est penché sur les propriétés d'adhérence entre les structures en BA existantes et les matériaux de rénovation pour les technologies de collage et de rénovation par chevauchement (Kumosa et al., 2004). Les applications actuelles du système de collage de feuilles comprennent le renforcement au cisaillement, le renforcement à la flexion et l'enveloppement de colonnes (Fig. 1.7) (Belarbi and Acun, 2013; Grace et al., 2003; Ho et al., 2013).

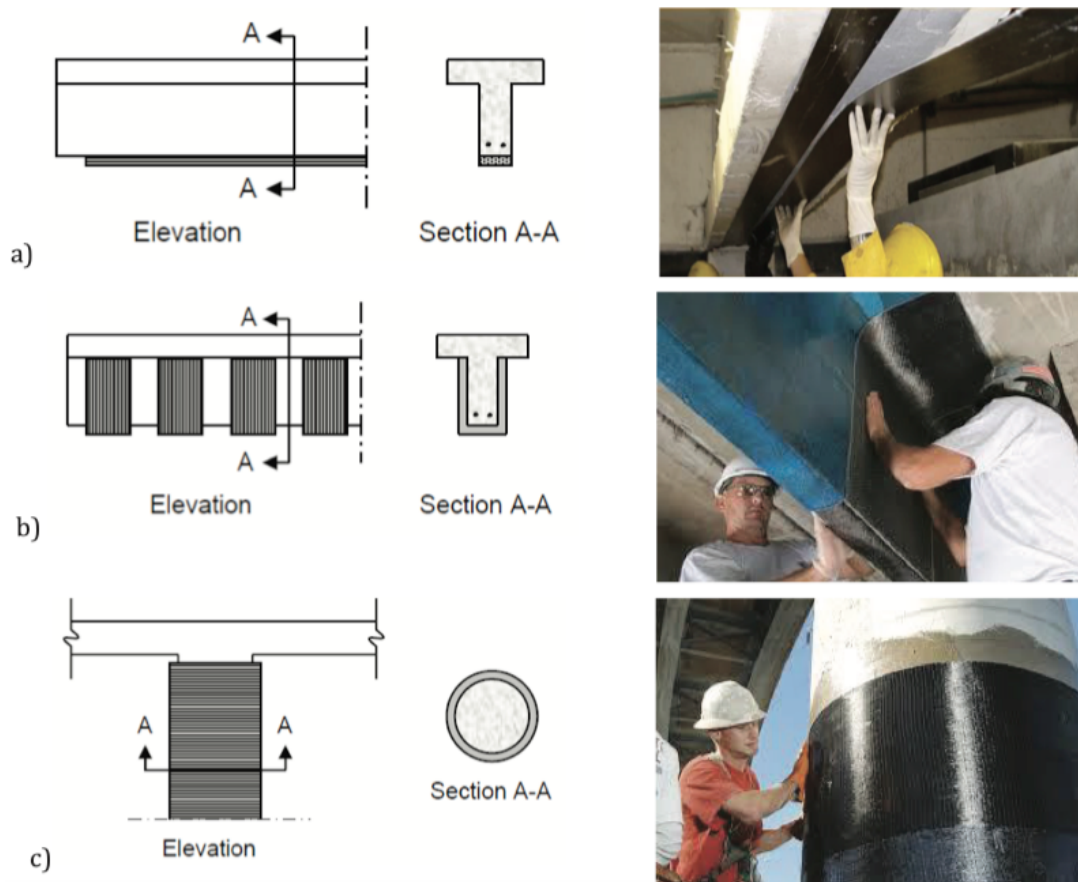


Fig. 1.7 — Description des principales applications du renforcement par composites PRF collés sur ouvrages de génie civil – (a) Renforcement à la flexion des poutres ; (b) Renforcement à l'effort tranchant des poutres ; (c) Confinement des colonnes.

Dans le cas de l'enveloppement de colonnes, la défaillance de l'interface d'adhérence n'est pas une préoccupation majeure par rapport à la rupture des feuilles de PRF qui est le mode de défaillance majeur (Tetta et al., 2016; Sheikh, 1978). Ainsi, il a été récemment recommandé que les matériaux PRF doivent être utilisés avec une capacité élevée de déformation à la rupture (Gdoutos et al., 2000; Taerwe, 1995). Cependant, pour les éléments en BA renforcés avec des feuilles de PRF pour le cisaillement et la flexion, le décollement du PRF du béton

régit les défaillances structurelles globales (Grace et al., 2003; Larbi et al., 2010). Dans les cas de renforcement à la flexion, le décollement des feuilles de PRF des substrats en béton est plus complexe, correspondant à plusieurs mécanismes de défaillance, contrairement aux cas de renforcement au cisaillement qui sont conformes aux résultats obtenus dans les essais d'adhérence au cisaillement par arrachement ; respectivement (Sas et al., 2009 ; Barros et al., 2007). Pour éviter la défaillance par décollement à mi-portée, la plupart des directives de conception recommandent des limites sur les déformations dans les feuilles de PRF car le décollement à mi-portée se produit toujours en raison de l'interaction entre l'enrobage de béton, les feuilles de PRF et l'armature en acier. À travers les résultats des essais d'arrachement, il est rapporté que la résistance du béton, la qualité de la surface du béton, l'épaisseur de la ligne de colle, la rigidité, la longueur d'adhérence et la largeur des feuilles de PRF ont un impact majeur sur la résistance d'adhérence du système composite PRF malgré la diversité des matériaux de renforcement utilisés (c'est-à-dire les composites de fibres de carbone, d'acier et de verre) (Kumosa et al., 2004). Plusieurs études ont rapporté que la rigidité des feuilles de PRF (module d'élasticité \times épaisseur) peut influencer la résistance d'adhérence (Attari et al., 2012; Nguyen et al., 2012). Par exemple, il a été obtenu que les couches d'adhérence avec des modules d'élasticité plus faibles, mais une bonne rigidité, pourraient contribuer à de plus grandes résistances d'adhérence à l'interface (Selzer and Friedrich, 1995; Selzer and Friedrich, 1997). Il a également été constaté que la largeur de la feuille n'affecte pas la résistance d'adhérence modérée des interfaces lorsque la largeur des feuilles est limitée entre 50 mm et 200 mm. Il est rapporté que la résistance d'adhérence augmente à mesure que la longueur d'adhérence de la feuille augmente. Néanmoins, les longueurs d'adhérence efficaces varient considérablement entre 45 mm et 275 mm (Kumosa et al., 2004). De plus, les directives de conception des PRF pour le renforcement des éléments en BA en ce qui concerne les caractéristiques d'adhérence locales et le rôle des caractéristiques d'adhérence à l'interface sur le comportement des éléments en BA seront informatives pour les ingénieurs, les chercheurs et les producteurs de matériaux, et les encourageront à approfondir leur compréhension de la technologie de rénovation et de renforcement par PRF.

1.8 Applications des PRF

Des projets de recherche à grande échelle entrepris en 1993 aux États-Unis et au Canada impliquant des composites PRFC/PRFV ont confirmé la décision d'utiliser de tels matériaux

dans la construction (Maurizio et al., 2009; Deuring, 1993; Barnes and Mays, 1999; Das and Nizam, 2014). Les États-Unis ne sont pas seulement le plus grand producteur et utilisateur de composites PRF, mais ils sont également à la tête du développement et de la mise en œuvre de la technologie des composites dans le monde. Selon les rapports, environ la moitié de la demande mondiale de PRF réside aux États-Unis, représentant environ 1,9 million de tonnes en 2002, mais la principale part de marché comprend près de 21% dans la construction, 32% dans les transports, 12% dans les applications résistantes à la corrosion, 10% dans les entreprises maritimes, 10% dans les industries électroniques, et les 0,6% restants sont utilisés dans les industries aérospatiale et aéronautique, comme l'indique l'association des composites SPI (Fig. 1.8) (Jameel et al., 2017).




Fig. 1.8 — Marchés actuels et applications des matériaux PRF (Mugahed Amran et al., 2018).

Dans le secteur du génie civil, l'application avancée des matériaux composites s'est développée progressivement en raison des contraintes économiques et de la technique complexe impliquée dans la substitution des systèmes composites avancés aux systèmes structurels conventionnels (Das, 2001; Delgado et al., 2012). Le domaine en développement du génie des structures avec les PRF se divise en 1) la réhabilitation, comprenant les applications pour la réparation des structures en BA existantes et 2) la nouvelle construction avec des solutions entières en PRF ou de nouveaux composites PRF/béton (Hosny and Abdelrahman, 2010).

Les composites PRF ont été efficacement utilisés pour la mise à niveau sismique des structures en BA, y compris les éléments intérieurs et extérieurs en raison de leur haute

résistance à la corrosion (Calvi et al., 2005; Dong et al., 2014). Ils améliorent les modes de rupture fragile comme la rupture par cisaillement des colonnes/poutres, le flambage des barres d'acier, la rupture par cisaillement des joints et la rupture des joints d'about (Arduini et al., 1997). Les systèmes PRF augmentent la dissipation d'énergie, le déplacement global et les performances globales (ASTM Committee). Les PRF sont généralement utilisés extérieurement pour le renforcement (collés ou montés en surface rapprochée) (Arduini et Nanni, 1997; Maurizio et al., 2009) et comme armatures intérieures dans les routes, les ponts, les pentes, les tunnels et les environnements marins (Fiore et al., 2011; Matta, 2003). Les études de cas pratique incluent l'utilisation de stratifiés PRFC comme barres de traction pour renforcer d'anciennes linteaux en pierre à la clôture Kaitbay au Caire (Hassan et al., 2017) et un système de dalle intelligente en mortier renforcé de textile en carbone (CTRM) pour renforcer une dalle de pont (Herbrand et al., 2017).

1.8.1 Confinement des colonnes et amélioration de la ductilité

Les composites PRF sont une solution de substitution de plus en plus adaptée au renforcement en acier pour les structures en BA, comprenant les ponts coulés en place et précontraints et post-tendus, les colonnes, les poutres, les tuyaux en béton préfabriqué et d'autres éléments (Han et al., 2014). L'utilisation de structures comme renforcement d'origine pour renforcer d'autres structures est de plus en plus spécifiée par les ingénieurs concepteurs de structures dans les industries de la construction privée et publique (Cheng et al., 2005; Wu et al., 2016). Actuellement, l'enveloppement des colonnes par des PRF est une solution courante dans le renforcement parasismique. Cette méthode, liée à d'autres choix de chemisage conventionnels, présente plusieurs avantages, comme la réversibilité, la facilité d'application et une excellente résistance à la corrosion. De plus, cette technique est approuvée pour la rénovation des éléments en BA à de multiples fins, par exemple fournir de la ductilité, prévenir le flambage des barres, augmenter la capacité au cisaillement et renforcer les éléments creux (Deuring, 1993; Jameel et al., 2017).

L'efficacité de l'enveloppement par PRF dans les zones d'about pour les sections transversales rectangulaires et circulaires a été vérifiée dans de nombreuses études (Gangarao and Vijay, 1998; Deuring, 1993; Hosny and Abdelrahman, 2010). De plus, de nombreux auteurs ont fourni des explications analytiques concernant les mécanismes impliqués dans l'amélioration de l'adhérence entre le béton et les barres aboutées attribuable à l'enveloppement, principalement à l'enveloppement par PRF (Maurizio et al., 2009; Hosny and Abdelrahman,

2010) et ont assuré un confinement supplémentaire du béton en utilisant des PRF (Garden and Hollaway, 1998; Hollaway, 2010). Le principal avantage du PRF est sa performance orthotrope qui contraint l'adhérence entre le béton et le chemisage dans la direction axiale; cette performance contribue à l'activation initiale de son confinement (Ho et al., 2010; Matta, 2003). Les recherches ont révélé que la ductilité et la résistance des colonnes sont améliorées en répartissant les barres longitudinales autour du périmètre du noyau et en réservant ces barres avec des éléments latéraux, comme des étriers, et que le plus petit rapport volumique d'étriers diminue le confinement du noyau en béton (Sheikh, 1978; Mourad and Shannag, 2012). Le plus grand rapport volumique de défauts d'étriers dans la stabilité du béton génère une zone faible entre l'enrobage en béton et le noyau (Kumar et al., 2004).

1.8.2 Renforcement à la flexion

Pour le renforcement à la flexion, des produits en barres de PRF tels que des plaques, des nappes et des barres d'armature sont fixés sur le côté tendu des substrats en maçonnerie, béton et bois à l'aide d'une résine époxy/fibres alignées parallèlement à la contrainte principale (Bakis et al., 2002; Attari et al., 2012). Par conséquent, de nombreux chercheurs ont étudié l'utilisation de diverses méthodes pour éliminer le décollement comme mode de défaillance en raison des méthodes expliquées dans la Fig. 1.9. Les composites PRFC sous forme de bandes offrent une solution rentable pour le renforcement des dalles en BA déficientes, augmentant la résistance à la charge jusqu'à 40% avec des fibres PRF à 0° (Van Den Einde et al., 2003; Grace et al., 2003). Les poutres renforcées présentent une résistance à la flexion accrue (36-57%), une rigidité accrue (45-53%), mais une ductilité et une rigidité réduites en raison du comportement élastique du PRF et du degré d'endommagement (Attari et al., 2012; Lu et al., 2009). Cependant, les poutres renforcées par des feuilles de PRFC sont sujettes à des défaillances prématurées et fragiles (Barros et al., 2007; Ferrari and De Hanai, 2012).




Fig. 1.9 — Techniques de renforcement en flexion (par exemple, composites en PRFC) (Mugahed Amran et al., 2018).

L'intérêt récent pour les composites PRF collés extérieurement s'est accru, améliorant les capacités au cisaillement des poutres en BA (Lu et al., 2009; Taljsten and Elfgren, 2000). Les défaillances au cisaillement ont été liées à des facteurs tels que le rapport du renforcement longitudinal à la traction (ACI 440 Part 6–8), le rapport portée efficace/profondeur (Taljsten and Elfgren, 2000) et le volume, l'orientation et l'espacement des bandes de PRFC (Bousselham and Chaallal, 2006). Bien que de nombreuses recherches aient été menées sur le renforcement à la flexion des poutres en BA à l'aide de matériaux PRF, les études se sont principalement concentrées sur les effets de la taille, de la profondeur, de l'épaisseur de l'enrobage de béton, de l'épaisseur, de la largeur et du type du PRF sur les modes de rupture (Wang and Li, 2006; Campione and Mangiavillano, 2008). La taille de la poutre n'affecte pas de manière significative la ductilité et la rigidité des poutres en BA renforcées au PRFC, mais la combinaison de PRFV et de PRFC améliore ces propriétés par ajustement du rapport des modules (Banibayat, 2011; Maalej and Leong, 2005). Attari et al., (2012) ont rapporté que l'utilisation de composites PRFC-PRFV à double couche a augmenté la capacité de résistance de 114% par rapport à la poutre témoin, et de 84% et 72% par rapport aux poutres de référence. La résistance à la flexion des poutres en BA a augmenté de 38,86% avec trois couches de PRFC, de 46,6% avec deux couches et de 15,5% avec une couche par rapport à la poutre témoin (Zarringol and Zarringol, 2016). La résistance des poutres en BA renforcées avec des feuilles de PRFV a augmenté de 45%, et avec des feuilles de PRFB de 27%, selon le nombre de couches, avec une réduction de déplacement de 53,6% (Breña et al., 2001).

1.8.3 Renforcement au cisaillement

Pour le renforcement au cisaillement, les procédures de conception des structures en BA avec des PRF liés extérieurement se trouvent dans de nombreux documents (ACI 440 1R-15 ; AASHTO 2009; ISIS 2007). Pour le renforcement au cisaillement, les barres de PRF sont fixées à l'extérieur des poutres en tant qu'étrier extérieur (Belarbi and Acun, 2013). Le renforcement au cisaillement des murs, par exemple les murs en BA sous-dimensionnés et les murs en maçonnerie non armée, peut être réalisé en enveloppant les PRF sur un ou deux côtés du mur selon un motif vertical, horizontal ou en X (45°) (Ferrari and De Hanai, 2012 ; Tetta et al., 2016). Le renforcement au cisaillement est réalisé avec des bords très minces avec seulement deux ou une feuille d'une épaisseur de 0,5 à 1,0 mm et permet d'obtenir des améliorations sismiques substantielles, en particulier pour une réponse de cisaillement dans le plan du mur (Yeh and Mo, 2005). Les résines époxy existantes sont robustes; par conséquent, les défaillances de surface se produisent généralement dans le béton, en particulier au niveau

d'un joint faible dans un élément en BA nécessitant un renforcement au cisaillement (Hosny and Abdelrahman, 2010). La méthode EBR est appliquée sous forme de chemisage continu ou de bandes. Trois formations principales de renforcement par PRF, à savoir l'enveloppement en U, l'enveloppement complet et le collage latéral (Fig. 1.10). L'enveloppement complet des éléments structurels en BA est reconnu comme la méthode la plus efficace pour le renforcement au cisaillement par PRF en raison de sa faisabilité en présence de certaines restrictions géométriques (Belarbi and Acun, 2013). Certaines études ont utilisé différentes méthodes pour le renforcement au cisaillement des poutres en BA, par exemple la précontrainte extérieure, les plaques d'acier collées et les matériaux fibreux (Bousselham and Chaallal, 2006; Khalifa and Nanni, 2002; Barros and Dias, 2006).




Fig. 1.10 — Renforcement au cisaillement (Bakis et al. 2002).

Les PRF appliqués extérieurement, comprenant des fibres d'aramide, de carbone et de verre, ont été largement utilisés pour le renforcement au cisaillement et à la flexion des poutres/colonnes en BA (Maalej and Leong, 2005; Wang and Li, 2006). Selon les rapports, l'utilisation de PRFC pour le renforcement au cisaillement des poutres en BA a montré une augmentation de la résistance au cisaillement de 19 à 122% attribuée à l'orientation du PRF à 45° et à la feuille de PRFC, par rapport aux poutres témoins (Bukhari et al., 2010). La résistance au cisaillement des poutres renforcées au PRF est généralement calculée par l'addition d'éléments individuels de résistance au cisaillement provenant du béton, du PRF et des étriers en acier. Il est rapporté que l'utilisation d'un système de renforcement au cisaillement en enveloppement en U de PRFC dans une poutre en BA augmente la capacité au cisaillement de 50% pour une couche de PRFC (Kim et al., 2012) et de 92% pour deux couches de PRFC (Jameel et al., 2017), en raison du rapport portée de cisaillement/profondeur limité à 3 ou > 2 . Par exemple, pour des poutres en BA avec un rapport de 1,5, le renforcement au cisaillement par PRFC n'a pas montré une telle augmentation de la résistance

au cisaillement. Une autre étude a examiné des dalles de pont renforcées avec des barres de PRFC avec des rapports supérieurs au rapport de renforcement équilibré, la capacité de résistance au cisaillement a été augmentée de 81% à 111% par rapport aux dalles témoins (El-Salakawy and Benmokrane, 2004).

1.9 Conclusion

L'utilisation des PRF pour le renforcement et la réhabilitation des structures en génie civil a considérablement augmenté ces dernières décennies, en raison des nombreux avantages que présentent ces matériaux composites par rapport aux techniques traditionnelles. Leur haute résistance, leur légèreté, leur résistance à la corrosion et leur facilité de mise en œuvre en font une solution privilégiée pour le renforcement des ouvrages existants ou la construction de nouvelles structures.

Parmi les différents types de PRF disponibles, les composites à fibres de carbone (PRFC) et à fibres de verre (PRFV) sont les plus couramment employés. Le PRFC offre une résistance mécanique et un module d'élasticité parmi les plus élevés, tandis que le PRFV constitue une alternative économique malgré des performances légèrement inférieures. Les fibres de basalte (PRFB) et d'aramide (PRFA) trouvent également certaines applications spécifiques.

Les principales techniques de renforcement par PRF étudiées sont le collage extérieur (EBR) et le montage près de la surface (NSM). Le choix entre ces méthodes dépend de la nature de l'élément à renforcer et des sollicitations à reprendre (flexion, effort tranchant, confinement, etc.). L'adhérence à l'interface entre le PRF et le substrat en béton, bois ou maçonnerie est un facteur clé conditionnant la performance du renforcement.

De nombreuses études ont ainsi démontré l'efficacité des PRF pour augmenter significativement la capacité portante des poutres, dalle et colonnes, tout en améliorant leur ductilité et leur résistance aux charges latérales. Le renforcement par PRF apparaît donc comme une solution durable et économique pour la réhabilitation du parc bâti existant et la conception de nouvelles structures sécuritaires résistant aux sollicitations sismiques.

CHAPITRE 02

*Cisaillement des poutres en BA :
concepts de base et renforcement par
PRF.*

2.1 Introduction

La rupture par cisaillement des poutres en BA est un mode de défaillance critique qui doit être évité en raison de son caractère fragile et soudain. Contrairement à la rupture en flexion qui est plutôt ductile, la rupture par cisaillement est connue pour être catastrophique et peut entraîner un effondrement partiel ou complet de la structure. Une compréhension approfondie du comportement au cisaillement ainsi que des techniques de renforcement appropriées est donc essentielle pour assurer la sécurité structurale.

Dans ce chapitre, les principaux concepts liés à la résistance au cisaillement des poutres en BA sont d'abord abordés. Les différents mécanismes de transfert des efforts de cisaillement, soit l'action de poutre et l'action d'arc, sont décrits en détail. Les paramètres influençant le comportement au cisaillement comme la géométrie, les propriétés des matériaux et les charges sont également exposés. Les différents modes de rupture fragiles pouvant survenir sont ensuite présentés et expliqués.

Les approches analytiques couramment utilisées pour modéliser la résistance au cisaillement sont par la suite passées en revue, en mettant l'accent sur les analogies de treillis, les modèles de bielle et tirant ainsi que la théorie modifiée du champ de compression.

Finalement, la technique de renforcement au cisaillement par collage extérieur de matériaux composites en PRF est abordée en détail. Les différentes configurations de renforcement possibles ainsi que leurs modes de rupture associés sont présentées. Une revue critique des principales formulations réglementaires existantes pour quantifier la contribution du renfort en PRF est également réalisée.

2.2 Comportement au cisaillement des poutres en BA sans armatures transversales

La compréhension du comportement au cisaillement des poutres est essentielle car, contrairement à la rupture par flexion qui est conçue pour être ductile, la rupture par cisaillement est connue pour être plus complexe, fragile et catastrophique par nature ([Taylor, 1974](#)). Par conséquent, les poutres en béton sont conçues pour avoir une résistance au cisaillement supérieure à la résistance à la flexion en tout point le long de la portée de la poutre.

Les travaux menés par [Kani \(1964, 1966\)](#) ont révélé que sous un chargement supplémentaire après l'amorce des fissures, une poutre en BA se transforme en une structure semblable à un

peigne. Cette structure est représentée par des dents verticales en béton qui se développent dans la zone de traction en raison des fissures de flexion, tandis que la soi-disant colonne vertébrale du peigne, à laquelle les dents en béton sont ancrées, est représentée par la zone de compression comme le montre la Fig. 2.1. On peut voir sur cette figure que les dents en béton travaillent comme de petites consoles chargées horizontalement par des forces de traction réparties le long des barres d'armature en acier liées, ΔT .




Fig. 2.1 — Dents en béton dans le système structural en forme de peigne (Kani, 1964).

Selon les travaux de Kani (1964, 1966), le système structural en forme de peigne a deux mécanismes différents, à savoir le mécanisme de type poutre (ou action de poutre) et le mécanisme d'arc lié (action d'arc), selon que la capacité des dents en béton est dépassée ou non. Le premier mécanisme (c'est-à-dire l'action de poutre) régit si la capacité des dents en béton n'est pas dépassée, tandis que le mécanisme d'action d'arc régit lorsque la capacité des dents en béton est dépassée.

La Fig. 2.2 illustre la variation de la ligne de capacité des dents en béton (c'est-à-dire la capacité fournie par le mécanisme d'action de poutre) et la courbe de capacité de l'arc restant (c'est-à-dire la capacité fournie par le mécanisme d'action d'arc). Le graphique a été extrait des travaux réalisés par Kani (1964) et relie le rapport entre M_{CR} et M_{FL} , respectivement le moment de flexion critique à la rupture par cisaillement et la pleine capacité de flexion de la section transversale, au rapport, portée de cisaillement sur profondeur effective (a/d) de la poutre. La portée de cisaillement (a) peut être définie par le rapport M/V où M est le moment maximum et V est l'effort tranchant maximum agissant sur la poutre. Par conséquent, la portée de cisaillement d'une poutre avec une charge uniformément répartie peut être calculée comme $a = L/4$ où L est la portée de la poutre (Kani, 1966).




Fig. 2.2 — Graphique de la vallée de Kani (Kani, 1964).

Comme on peut le voir dans le graphique de la vallée de Kani, les capacités des dents en béton et de l'arche restante forment trois zones distinctes du rapport a/d . Les caractéristiques de chaque zone sont :

- i. ($1 < a/d < 2,5$) : La capacité de l'arche est considérablement plus élevée que la capacité fournie par les dents en béton pour cette plage de rapport a/d ; par conséquent, la transformation de l'action de poutre à l'action d'arche se produit sous un chargement supplémentaire. Par conséquent, la rupture se produit lorsque la capacité de l'arche restante est dépassée.
- ii. ($2,5 < a/d < 5,6$) : Dans cette plage de rapport a/d , la capacité des dents en béton est supérieure à la capacité de l'arche et la rupture se produit lorsque la capacité des dents en béton est dépassée. Un effondrement soudain est attendu dans cette région en raison de la rupture fragile en traction des dents en béton lorsque la capacité de l'arche est inférieure à la charge appliquée.
- iii. ($5,6 < a/d$) : Pour les poutres ayant un rapport a/d de 5,6 et au-delà, seule une rupture par flexion est prépondérante car la pleine capacité de flexion de la section transversale est atteinte en premier. Par conséquent, une rupture due au dépassement de la capacité des dents en béton n'est pas possible.

2.2.1 Mécanismes de résistance au cisaillement

Comme mentionné dans les premières investigations (par ex. [Kani, 1964](#) ; [Taylor, 1974](#)), les poutres en BA peuvent résister explicitement au cisaillement après la fissuration par deux mécanismes fondamentalement différents, l'action de poutre et l'action d'arche. La contribution globale à la résistance au cisaillement régie par chaque mécanisme dépend de la compatibilité associée des déformations ([Jeong and Kim, 2014](#)). Dans les sous-sections suivantes, les composantes individuelles du transfert de cisaillement associées à l'action de poutre et à l'action d'arche sont présentées et discutées.

2.2.1.1 Action de poutre

Ce mécanisme de résistance au cisaillement est prédominant dans les poutres en BA ayant des rapports a/d entre 2,5 et 5,6. Selon le Comité [ASCE-ACI 426 \(1973\)](#) et le Comité [ASCE-ACI 445 \(1998\)](#), les composantes du transfert de cisaillement sont diverses dans le cas du mécanisme d'action de poutre. Elles peuvent être clarifiées à l'aide du diagramme de corps libre idéalisé donné à la [Fig. 2.3](#) d'une poutre avec une fissure de cisaillement diagonale critique. D'après la [Fig. 2.3](#), les composantes de transfert de cisaillement dues au mécanisme d'action de poutre sont les suivantes ([ASCE-ACI 426, 1973; Taylor, 1974](#)) :




Fig. 2.3 — Résistance au cisaillement dans le mécanisme d'action de poutre ([Abad et al., 2019](#)).

- i. **Contrainte de cisaillement dans le béton non fissuré, V_c** : Cela représente les contraintes de cisaillement qui peuvent être transférées par les poutres en béton non fissuré ou les parties en béton non fissuré des poutres en béton fissuré (c'est-à-dire le

béton dans la zone de compression). La résistance au cisaillement fournie par ce mécanisme dépend de la profondeur du béton non fissuré. Sa contribution au cisaillement a été mesurée par Taylor (1974) à l'aide de déformations en surface et s'est avérée être de 20% à 40%. Dans le cas de poutres élancées après fissuration, la contribution de la zone de compression au cisaillement est négligeable car la profondeur est relativement faible.

- ii. **Contraintes résiduelles de traction dans le béton après fissuration, σ_{ai}** : Il est bien connu que la perte de résistance à la traction du béton après fissuration (c'est-à-dire l'adoucissement du béton) ne se produit pas soudainement car même après fissuration, les forces de traction peuvent être transmises via de petits ponts de morceaux de béton à travers la fissure. Ces ponts de béton transmettent les forces de traction lorsque la largeur de la fissure n'est pas supérieure à 0,15 mm (Comité ASCE-ACI 445, 1998). Ce mécanisme de résistance au cisaillement est normal au plan de fissure.
- iii. **Engrènement des granulats (ou transfert de cisaillement d'interface), τ_{ai}** : Bien que la fissuration se produise normale à la direction des contraintes principales de traction où aucune contrainte de cisaillement n'est attendue, la redistribution des forces internes après fissuration entraîne une tendance au glissement le long de l'interface de la fissure. La résistance au glissement tangentiel fournie par les interfaces rugueuses formées sur les deux faces des fissures donne au béton la capacité de transférer les efforts de cisaillement à travers le plan de fissure. Ce phénomène a été particulièrement remarqué dans les éléments en béton de résistance normale, où les granulats dépassent du plan de fissure (Fig. 2.4). La résistance au cisaillement fournie par ce phénomène dépend de la taille des granulats utilisés dans le mélange de béton ainsi que de la largeur de la fissure. L'ampleur de cette résistance au cisaillement s'est avérée être comprise entre 33% et 50% et elle augmente avec l'augmentation de la taille des granulats, tandis qu'elle diminue avec l'augmentation de la largeur de la fissure (Taylor, 1974).
- iv. **Action de goujon des barres d'armature longitudinales, V_d** : L'intersection d'une fissure de cisaillement diagonale avec une barre d'armature longitudinale entraîne une résistance aux déplacements de cisaillement qui, à son tour, produit des forces de traction pour fendre le béton directement sous la barre. Par conséquent, le mécanisme de résistance au cisaillement susmentionné est fonction de la quantité d'armature longitudinale (c'est-à-dire de la rigidité de l'armature longitudinale), de la distribution de l'armature longitudinale le long de la profondeur de la poutre et de la résistance à la

traction de l'enrobage de béton entourant l'armature longitudinale. Environ 15% à 25% de l'effort tranchant appliqué peut être résisté par ce mécanisme (Taylor, 1974).




Fig. 2.4 — Engrènement des granulats dans (a) le béton de gravillon (résistance intermédiaire et faible) et (b) le béton léger (Walraven, 1980).

2.2.1.2 Action d'arche

Pour les poutres en BA ayant de petits rapports a/d (c'est-à-dire inférieurs à 2,5), les forces de cisaillement peuvent être directement transférées du point de charge appliquée jusqu'à la réaction la plus proche par le mécanisme d'action d'arche, où la bielle de compression inclinée, qui est responsable du transfert de cisaillement, est couplé avec le tirant (c'est-à-dire l'armature de traction longitudinale) qui fournit une résistance à la composante horizontale de la force de cisaillement inclinée comme illustré sur la Fig. 2.5.

Ce mécanisme de résistance au cisaillement dépend largement de la profondeur de la zone de compression de la poutre; ainsi, le mécanisme devient plus dominant à mesure que le rapport a/d diminue. De plus, il nécessite un support horizontal essentiel qui peut être fourni par l'armature de traction longitudinale ancrée (Park and Paulay, 1975).




Fig. 2.5 — Résistance au cisaillement dans le mécanisme d'action de l'arc (Park and Paulay, 1975).

2.2.2 Facteurs influençant le comportement au cisaillement

En plus du rapport a/d , qui joue un rôle principal dans le changement du mécanisme de résistance au cisaillement des poutres, le comportement au cisaillement des poutres en BA est considérablement influencé par les facteurs suivants (Taylor, 1974; Kesse, 2003; Punmia et al., 2007) :

- i. **Résistance du béton** : L'augmentation de la classe de résistance du béton jusqu'à une certaine limite entraîne une augmentation correspondante de la résistance au cisaillement des poutres. Bien que l'importance de la classe de résistance du béton devienne très prononcée dans la zone de compression après la rupture de l'engrènement des granulats, elle a également une influence significative sur la résistance à la traction, qui augmente à son tour la charge de fissuration et la résistance de l'action de goujon. De plus, elle améliore la résistance de l'engrènement des granulats nécessitant l'utilisation de granulats résistants dans le mélange de béton pour empêcher le développement de fissures à faces lisses, comme c'est le cas dans le béton à haute résistance.
- ii. **Pourcentage et grade de l'armature longitudinale de traction** : Les poutres pourvues de faibles rapports d'armature de traction longitudinale cèdent à des contraintes de cisaillement plus basses que les autres poutres avec des rapports adéquats. Cela peut être attribué au développement de fissures de flexion plus larges et plus longues à des charges plus faibles, ce qui réduit à son tour la zone de compression et le transfert de cisaillement d'interface. De plus, la réduction du rapport d'armature de traction longitudinale entraîne une réduction correspondante de l'action de goujon, en raison de la diminution de la rigidité de l'armature longitudinale. Pour l'effet du grade d'armature longitudinale, il est bien connu que l'utilisation d'un grade d'acier plus élevé conduit à une réduction du rapport d'armature en acier requis. Par conséquent, elle réduit la résistance au cisaillement de la poutre (Punmia et al. 2007).
- iii. **Pourcentage d'armature longitudinale de compression** : Les résultats liés à ce paramètre sont contradictoires. Selon Kesse (2003), l'effet du rapport d'armature de compression n'est pas clair, alors que Punmia et al. (2007) ont suggéré que la résistance au cisaillement augmente avec l'augmentation du pourcentage d'armature de compression, ce qui pourrait être attribué à l'amélioration de la zone de compression en béton (Gale and Ibell 2000).

- iv. **Force axiale** : L'influence de la force axiale correspond au changement de l'angle de fissuration diagonale. La présence d'une force axiale de compression aux extrémités de la poutre, due aux charges appliquées, augmente la résistance au cisaillement et la charge de fissuration de la poutre, tandis que la résistance au cisaillement et la charge de fissuration sont diminuées lorsqu'une force axiale de traction est appliquée.
- v. **Section transversale** : Par rapport aux poutres rectangulaires ayant la même profondeur efficace et la même largeur d'âme, les poutres en T fournissent une meilleure résistance au cisaillement. Cela peut être attribué à la zone de compression supplémentaire due à l'aile de la poutre, et son ampleur dépend des dimensions de l'aile.

2.3 Effet des armatures de cisaillement

Il ne serait ni sûr ni économique de concevoir des poutres en BA au cisaillement en dépendant uniquement de la résistance au cisaillement fournie par le béton; par conséquent, une quantité minimale d'armature de cisaillement est recommandée dans les codes de pratique (Nilson, 1987).

Les étriers transversaux de cisaillement résistent aux forces de cisaillement en pontant les fissures de cisaillement. La contribution a lieu lorsqu'une fissure diagonale dans le béton croise un étrier de cisaillement en redistribuant les forces internes qui se forment après la fissuration. Cette contribution peut être observée via un développement soudain de déformations de traction dans les étriers. La présence d'étriers de cisaillement peut soit retarder, soit empêcher la rupture au cisaillement. L'ampleur de la résistance au cisaillement fournie par l'armature transversale dépend de la limite d'élasticité, de la section et de l'espacement entre les étriers en acier.

En plus de sa contribution directe au cisaillement mentionnée ci-dessus, les étriers de cisaillement fournissent un confinement au béton se trouvant entre les étriers. Ils peuvent également maintenir la contribution au cisaillement de l'engrènement des granulats en limitant la croissance de la largeur des fissures inclinées (ce qui entraîne une répartition des fissures le long de la portée de cisaillement) et en empêchant la pénétration de ces fissures dans la zone de compression de la poutre. De plus, ils peuvent considérablement améliorer le rôle de l'action de goujon dans la résistance au cisaillement, car les étriers peuvent fonctionner comme des points de retenue pour maintenir l'armature longitudinale en place et empêcher les forces de traction de fendre l'enrobage de béton. D'autre part, la capacité au cisaillement et la flèche correspondante des poutres avec des étriers de cisaillement internes sont beaucoup plus

élevées que celles des poutres sans étriers de cisaillement internes, et la majeure partie de la résistance au cisaillement est reprise par les étriers de cisaillement en raison des plus grandes ouvertures de fissures dans ces poutres correspondant à des flèches plus importantes près de la charge de rupture. Par conséquent, la contribution au cisaillement due à l'engrènement des granulats et à l'action de goujon ensemble, en pourcentage de la capacité au cisaillement, a été considérablement réduite comme l'ont rapporté [Swamy and Andriopoulos \(1974\)](#), où la contribution est passée d'environ 50 à 90% dans les poutres sans étriers de cisaillement à environ 30% dans des poutres similaires avec une armature d'âme.

Malgré le fait que la disposition d'étriers de cisaillement améliore la ductilité de la poutre, elle ne conduit pas nécessairement à un changement du mode de rupture d'un type fragile à un type ductile; et l'effondrement peut se produire sans avertissement adéquat à moins que la capacité de flexion de la poutre ne soit d'abord dépassée ([Kotsovos, 1987](#)).

2.4 Modes de rupture au cisaillement dans les poutres en BA

Dans cette section, les modes de rupture par cisaillement des poutres en BA simplement appuyées et soumises à des charges ponctuelles (voir [Fig. 2.6](#)), qui ont été observés lors d'essais expérimentaux, sont présentés et décrits. Outre le schéma de chargement, le mode de rupture par cisaillement dépend des aspects géométriques des poutres, notamment le rapport a/d , la profondeur de la poutre, l'épaisseur de l'âme et la rigidité de la membrure tendue (c'est-à-dire le rapport entre l'armature longitudinale et son adhérence avec le béton environnant) ([Rajagopalan, 2002](#)). Par conséquent, les modes de rupture par cisaillement peuvent être classés comme suit :

- i. ***Écrasement de la bielle et rupture par fendage*** : Ces deux modes de rupture, indiqués dans la [Fig. 2.6a](#), sont courants dans les poutres profondes avec $a/d < 1,0$. L'écrasement de la bielle ou la rupture par compression se produit en raison de l'écrasement du cordon de béton, qui est responsable de la transition directe de la charge appliquée vers l'appui le plus proche, située entre les fissures diagonales se développant le long de la ligne reliant les points de chargement et de réaction. Cependant, la rupture par fendage se produit en raison de la plastification/rupture de l'armature longitudinale (c'est-à-dire le tirant de traction) aux emplacements des fissures inclinées qui se développent sous le cordon de béton ou en raison d'un défaut d'ancrage/de butée aux extrémités de la poutre.
- ii. ***Rupture par cisaillement-compression/cisaillement-traction*** : Dans les poutres profondes ayant des rapports a/d supérieurs à 1,0 et inférieurs à 2,5, une rupture par

cisaillement-compression peut être observée lorsque le béton s'écrase à l'extrémité des fissures de cisaillement diagonales, car le tirant en béton causé par l'action d'arche empêche la pénétration des fissures de cisaillement diagonales vers la zone de compression sous un chargement supplémentaire, comme illustré sur la [Fig. 2.6b](#). La rupture par cisaillement-traction se produit lorsque la fissure s'étend vers l'armature tendue plutôt que vers la zone de compression, jusqu'à ce que le béton entourant l'armature tendue cède en raison de la fissuration par traction, comme le montre la [Fig. 2.6c](#).

- iii. **Rupture par traction diagonale** : Ce type de rupture au cisaillement est couramment observé dans les poutres avec des rapports a/d dans la plage de 2,5 à 5,6. La rupture commence par une fissure de flexion, qui, sous un chargement supplémentaire, se transforme en une fissure inclinée. Peu avant d'atteindre la rupture finale, la fissure s'ouvre largement au bas et se propage rapidement vers le point de chargement, provoquant un effondrement en divisant la poutre en deux parties (voir [Fig. 2.6d](#)).
- iv. **Rupture par cisaillement d'âme** : Pour les poutres conçues pour avoir des âmes minces, la rupture au cisaillement peut se produire, même avant l'initiation des fissures de flexion, en raison de l'écrasement du béton dans l'âme à l'emplacement de la contrainte maximale lorsque la limite de compression du béton est dépassée en raison d'une épaisseur d'âme inadéquate. Ce type de rupture est connu pour être soudain et violent, sans aucun ou très peu d'avertissement. Peu avant la rupture, la zone de rupture (c'est-à-dire l'âme de la poutre) est complètement non fissurée et la rupture se produit sous la forme d'une petite explosion de l'âme immédiatement après l'apparition de la première fissure. La rupture par cisaillement de l'âme est illustrée à la [Fig. 2.6e](#).




Fig. 2.6 — Modes de rupture par cisaillement (Keuork Qapo, 2016).

2.5 Approches pour la modélisation du cisaillement dans les poutres en BA

Les problèmes de cisaillement dans les poutres en BA ont été un domaine d'intérêt pour de nombreuses recherches et leurs contributions ont permis le développement d'un certain nombre de modèles pour expliquer la complexité du mécanisme de transfert des efforts tranchants. Les approches les plus appliquées pour le dimensionnement au cisaillement sont décrites dans les sous-sections suivantes.

2.5.1 Analogies de treillis

Le concept d'analogie de treillis a été initialement proposé par Ritter (1899) et développé plus avant par Morsch (1909). Ce concept est largement utilisé dans les modèles de dimensionnement au cisaillement (Stratford and Burgoyne, 2003) dans lesquels la poutre en béton avec étriers internes est représentée par un treillis, comme on peut le voir sur la Fig. 2.7. Le béton dans la direction des fissures inclinées et les étriers d'armature à l'effort tranchant représentent respectivement les bielles de compression et les tirants tendus du treillis, tandis que les semelles supérieure et inférieure sont représentées respectivement par le béton dans la zone de compression et l'armature tendue.




Fig. 2.7 — Analogies de treillis (Keuork Qapo, 2016).

La base de ce concept est que l'effort tranchant dans les poutres fissurées est repris par les contraintes qui se développent dans les bielles de compression, qui écartent les semelles supérieure et inférieure, provoquant ainsi une force de traction dans les tirants tendus (étriers) qui maintiennent les composants de la poutre ensemble.

Afin de déterminer la capacité au cisaillement de la poutre, Morsch (1909) a supposé que l'angle d'inclinaison des bielles de béton soit égal à 45° , car les trois équations statiques d'équilibre ne suffisent pas à déterminer mathématiquement les variables de cette approche. Ces variables sont la contrainte dans les bielles de béton, la contrainte dans les étriers, la contrainte dans l'armature longitudinale tendue et l'angle d'inclinaison des bielles de béton inclinées. Cependant, une telle hypothèse conduit à des résultats très conservatives ou non sécuritaires respectivement pour les poutres en béton avec un faible et un fort taux d'armature de cisaillement (Collins and Mitchell, 1980). De plus, elle peut ne pas refléter l'état réel des contraintes dans la poutre car, en général, la rigidité de l'armature longitudinale est supérieure à celle des étriers. Par conséquent, l'angle d'inclinaison des bielles de béton doit être plus plat que 45° .

Nielsen et al. (1978) ont ensuite modifié l'analogie du treillis basée sur la théorie de la plasticité en permettant à l'angle de la bielle de compression de varier. Le modèle modifié, dans lequel des limites supérieures et inférieures ont été suggérées pour la rupture par écrasement de l'âme, s'est avéré cohérent avec les résultats expérimentaux. Cependant, il convient de noter que les approches basées sur la théorie de la plasticité ne peuvent pas être appliquées aux matériaux fragiles comme dans le cas des armatures de cisaillement en PRF (Stratford et Burgoyne, 2003).

2.5.2 Modèles de bielle et tirant

Le modèle de bielle et tirant est une approche rationnelle qui a été initialement introduite par Schlaich et al. (1987) pour simuler l'écoulement complexe des forces dans les régions perturbées ou de discontinuité (c'est-à-dire les régions proches des charges concentrées, des appuis et des changements de section transversale) des structures en béton, où l'hypothèse de Bernoulli n'est pas valide car les sections planes ne sont plus planes au-delà de la flexion (Kuchma and Collins, 1998), en utilisant un modèle de treillis simplifié.

Dans la méthode de la bielle et du tirant, il n'y a pas de modèle unique ou unifié pour les situations de conception rencontrées, comme on peut le voir dans l'exemple illustré à la Fig. 2.8. Par conséquent, la complexité de l'analyse est contrôlée par la distribution adoptée de l'écoulement des forces. Néanmoins, la distribution des contraintes au sein de la structure est simulée à l'aide d'un système comprenant des éléments de compression en béton (bielles), des éléments de traction en armature (tirants) et des zones nodales dans lesquelles le béton est soumis à des contraintes élevées. Une quantité et un ancrage suffisants de l'armature sont requis pour permettre à la structure fissurée de supporter la charge anticipée.




Fig. 2.8 — Modèles de bielle et tirant pour une poutre en BA (Ibell et al., 1996).

Malgré le fait que la théorie de la plasticité sous-jacente à la méthode de la bielle et du tirant soit complexe, la méthode elle-même est directe et les forces dans chacun de ses composants (c'est-à-dire bielles, tirants et nœuds) peuvent être facilement déterminées.

2.5.3 La théorie modifiée du champ de compression

La théorie modifiée du champ de compression (MCFT) a été développée pour prédire la réponse charge-déformation des panneaux (ou éléments) en BA soumis à des contraintes de cisaillement dans le plan uniformément réparti et des contraintes normales biaxiales (Vecchio and Collins, 1986). Le modèle analytique utilise la compatibilité des déformations de l'armature (longitudinale et transversale) ainsi que du béton sollicité en compression diagonale pour déterminer les contraintes moyennes, les déformations moyennes et l'angle d'inclinaison du béton sollicité en compression diagonale qui résiste au cisaillement.

La MCFT permet au béton entre les fissures de transférer des contraintes de traction même après une fissuration extensive qui se produit à des valeurs de déformation de traction moyenne élevées, tandis que le comportement en compression du béton fissuré devient plus souple lorsqu'il est soumis à des déformations de traction latérale élevées (Vecchio and Collins, 1986). En raison des interactions susmentionnées de contraintes complexes, les lois constitutives (c'est-à-dire les relations contrainte-déformation du béton) dérivées des résultats des panneaux testés sont différentes des résultats qui seraient obtenus en utilisant des essais de matériaux standard.


Puisque la prédiction de la résistance au cisaillement des poutres est plus nécessaire dans la pratique que la réponse complète cisaillement-déformation, Bentz et al. (2006) ont proposé une version simplifiée de la MCFT pour les éléments en BA adaptée aux calculs manuels avec presque la même précision ou une réduction très limitée de la précision. Les rapports des résistances au cisaillement expérimentales sur prédites, de plus de 100 panneaux en BA testés en cisaillement pur, sont de 1,01 (avec un coefficient de variation de 12,2 %) et 1,11 (avec un coefficient de variation de 13,0 %) pour la MCFT et la MCFT simplifiée respectivement.

2.6 Renforcement au cisaillement des poutres par PRF collés extérieurement


Une résistance au cisaillement insuffisante peut être un problème critique pour les structures en BA, car elle peut entraîner une rupture catastrophique. Le collage extérieur de composites en PRF sur les structures en BA a été une pratique populaire dans l'industrie et la communauté de recherche au cours des dernières décennies (Pham and Hadi, 2014; Jalal and

Ramezaniapour, 2012; Hawileh et al., 2014). Cette approche s'est révélée être un moyen efficace d'augmenter la résistance au cisaillement et la ductilité des structures en BA. Le renfort PRF collé extérieurement appliqué sur la surface du béton vise à couvrir les fissures de cisaillement avec les fibres. Le renforcement au cisaillement des poutres en BA peut être réalisé de deux manières courantes : des bandes de PRF distribuées (D), espacées d'une distance s_f , ou des feuilles de PRF continues (C) appliquées sur toute la surface de l'élément en BA. La configuration de renforcement peut être montée sous forme de lamelles de PRF droites collées sur les côtés latéraux des poutres (collage latéral [Side bonding] – S, Fig. 2.9a, b), de feuilles de PRF ou de lamelles en forme de L collées sur les côtés latéraux et les surfaces inférieures des poutres en BA (chemisage en U [U-jacketing] – U, Fig. 2.10a, b), de feuilles enveloppant complètement la section transversale des poutres appliquées sous forme d'étriers fermés (enveloppement [Wrapping] – W, Fig. 2.11a, b) ou des lamelles/feuilles de chemisage en U ancrées à leurs extrémités. Bien que l'enveloppement complet (W) soit la méthode de renforcement la plus efficace dans la pratique, il n'est pas toujours possible de l'appliquer aux poutres en BA coulées de manière monolithique avec une dalle.

Le décollement de renforcement de cisaillement en PRF est généralement un phénomène fragile et commence après la formation d'une fissure de cisaillement critique. La principale cause du décollement des extrémités des bandes/feuilles de PRF est la longueur d'ancrage insuffisante du renfort en PRF au-delà de la fissure de cisaillement pour transférer les contraintes de traction dans les feuilles de PRF au substrat en béton. Pour prévenir ce décollement, plusieurs techniques d'ancrage ont été publiées dans la littérature au cours des deux dernières décennies : ancrages métalliques (Belarbi et al., 2012; Sato et al., 1996) ; ancrages en PRF (par exemple, PRF noyé, extension en PRF, pointes en PRF, patches en PRF, câbles en PRF) (Pellegrino and Modena, 2002; Mofidi et al., 2014) ; ancrages combinés acier et PRF (El-Maaddawy and Chekfeh, 2013) (Fig. 2.11c, d). Dans ces cas, le comportement de la configuration de chemisage en U doit être considéré comme équivalent à un enveloppement complet. L'utilisation d'ancrages métalliques pour l'ancrage des PRF présente des inconvénients tels que la rupture des fibres lors du perçage des trous pour les boulons d'ancrage et l'apparition d'une concentration de contraintes locales à l'emplacement des fixations. Dans le cas des matériaux en PRFC, il existe un danger de corrosion galvanique à l'interface entre les profilés en acier et l'armature d'ancrage en PRFC.




(a) Configuration DS




(b) Configuration CS

Fig. 2.9 — Configurations de renforcement au cisaillement par collage latéral (S) (Kotynia et al., 2021).




(a) Configuration DU




(b) Configuration CU


Fig. 2.10 — Configurations de renforcement au cisaillement par chemisage en U (Kotynia et al., 2021).




(a) Configuration CW



(b) Configuration DW



(c) Configuration CW



(d) Configuration DW

Fig. 2.11 — Configurations de renforcement au cisaillement par enveloppement (W) (Kotyna et al., 2021).

2.7 Modes de rupture des poutres en BA renforcées au cisaillement par PRF collés extérieurement

Les résultats d'essais sur des poutres en BA renforcées au cisaillement avec des composites PRF collés extérieurement ont indiqué plusieurs mécanismes de rupture. Certains sont liés aux modes de rupture par cisaillement typiques des poutres en BA d'origine et les autres correspondent à la configuration de renforcement au cisaillement en PRF. Parmi ces derniers, les modes de rupture les plus courants sont basés sur la perte d'adhérence PRF-béton et la rupture du PRF. Le décollement du PRF peut se produire dans une mince couche de béton d'enrobage en commençant au début de la fissure diagonale croisant la bande de PRF et en se développant jusqu'à l'extrémité du PRF (Chen and Teng, 2008). La rupture du composite peut se produire dans les éléments en BA complètement enveloppés, dans les poutres renforcées par un chemisage en U en PRF avec les deux extrémités ancrées dans l'aile de la section en T ou dans le cas d'une poutre très haute, pour laquelle la longueur d'ancrage du PRF hors du point d'intersection avec la fissure de cisaillement diagonale est supérieure à la longueur d'ancrage efficace requise pour transférer la force de traction totale du PRF collé extérieurement au substrat en béton. Le deuxième type de rupture du PRF peut se produire à l'angle de la poutre, où la feuille de PRF est pliée (Kotynia et al., 2021). La Fig. 2.12 montre les mécanismes de rupture de base et secondaires des poutres en BA renforcées au cisaillement.

Dans les poutres avec un faible taux d'armature longitudinale, les fissures de flexion s'initient, puis progressent vers un mode de rupture par cisaillement-traction, qui se produit après le décollement du PRF dû à l'ouverture et à la propagation de la fissure de cisaillement critique.

Cependant, dans les poutres avec une forte armature longitudinale en acier, le décollement du PRF dans la fissure de cisaillement critique a entraîné une rotation des deux parties de la poutre séparées par la fissure de cisaillement critique par rapport au joint formé dans la zone de compression de la section transversale (mode de rupture par cisaillement-compression).

Dans les poutres à section en T avec une âme étroite renforcées par un chemisage en U ou une configuration d'enveloppement en PRF, un écrasement du béton de la bielle de compression en béton séparée par deux fissures de cisaillement diagonales peut se produire. Ce mode de rupture est très dangereux, donc, pour l'éviter, une augmentation de la section transversale de la poutre est recommandée.

Généralement, la configuration de renforcement en PRF la plus efficace est l'enveloppement complet. La plupart des poutres subissent une rupture par flexion par écrasement du béton, ce qui confirme la protection complète contre la rupture par cisaillement et prouve l'augmentation maximale de la capacité au cisaillement. Cependant, le chemisage en U en PRF sans ancrage d'extrémité est susceptible d'un décollement d'extrémité au-dessus de la fissure de cisaillement. Les lamelles/feuilles collées sur les côtés ne constituent pas un moyen efficace de renforcement au cisaillement, en raison du manque d'ancrage d'extrémité dans les zones de compression et de traction. Par conséquent, pour améliorer la capacité au cisaillement, la technique la plus recommandée est l'enveloppement en PRF ou le chemisage en U avec des extrémités ancrées (Kotynia et al., 2021).




Fig. 2.12 — Mécanismes de rupture des poutres en BA renforcées au cisaillement par PRF collés extérieurement (Kotynia et al., 2021).

2.8 Revue des formulations réglementaires pour la quantification de la résistance au cisaillement apportée par les PRF

De nos jours, il n'existe toujours pas de consensus mondial sur l'évaluation de la contribution à la résistance au cisaillement des PRF collés extérieurement, dans les éléments renforcés au cisaillement par cette technique. Cela est dû à la confluence de nombreuses raisons différentes : a) la complexité du phénomène de cisaillement ; b) le décollement du renfort extérieur pour certaines configurations et sa prédiction, c) le comportement linéaire élastique du matériau PRF (les étriers PRF collés extérieurement ne se plastifient pas) ; et d) l'interaction entre le béton, l'armature transversale en acier interne si elle existe, l'armature longitudinale et le renfort en PRF collé extérieurement.

La résistance au cisaillement ultime des poutres renforcées extérieurement au cisaillement par des lamelles en PRF peut être calculée comme la somme des contributions des différents composants : béton (V_c), acier transversal interne (V_s) et PRF collé extérieurement (V_f). La

plupart des guides existants (ACI 440.2R-17; CSA-S806.12; fib Bulletin 90; fib Bulletin 14 et JSCE) ajoutent la contribution du renfort en PRF collé extérieurement à la résistance au cisaillement de l'élément non renforcé. Cependant, certaines dispositions européennes comme le CNR-DT 200.R1 2013 et le TR-55 négligent la contribution du béton V_f pour les poutres renforcées par des PRF. Cette approche a été précédemment discutée par Bouselham and Chaallal (2006), Chen et al. (2010) et Pellegrino and Vasic (2012), observant que la présence du PRF pourrait influencer la contrainte effective dans l'acier interne, conduisant parfois à des résultats non conservateurs. Cela pourrait être dû à des changements possibles dans l'orientation des bielles ou à des fissurations supplémentaires qui pourraient modifier la contribution du béton ou de l'armature transversale existante à la résistance au cisaillement. L'interaction du renfort au cisaillement en PRF avec l'acier transversal ou le béton n'est pris en compte que dans un petit nombre des formulations existantes (Mofidi and Chaallal, 2011; Ali et al., 2016; Monti and Liotta, 2007). Bouselham and Chaallal (2008) ont conclu que la contribution du béton reste plus ou moins inchangée après la formation de la fissuration diagonale pour les poutres de petite et moyenne taille. De plus, selon Bouselham and Chaallal (2008), le PRF a une influence significative sur le comportement de l'acier transversal. Dans le cas des poutres avec étriers transversaux, la contribution de l'acier transversal est supérieure à celle du PRF, en raison d'une meilleure adhérence à l'interface étrier-béton.

Selon Pellegrino and Modena (2008), Deniaud and Cheng (2001), Monti and Liotta (2007) et Ali et al. (2016), l'interaction entre l'acier transversal et le PRF est importante car il n'y a pas toujours une interaction complète entre la capacité au cisaillement des étriers en acier et le PRF, c'est-à-dire que le système n'est pas suffisamment ductile pour permettre que la contribution maximale de chaque matériau se produise au même instant. Mofidi and Chaallal (2011) ont réalisé une étude des principaux facteurs affectant la contribution au cisaillement du PRF, concluant que même si aucune des recommandations existantes ne considère explicitement la contribution de l'acier transversal interne lors du calcul de la résistance au cisaillement du PRF, elle a une influence significative. De plus, Mofidi and Chaallal (2014) ont conclu qu'une contribution inférieure des étriers en acier existants (en raison de la non-plastification) au lieu de la contribution complète considérée dans les recommandations existantes dépend de l'espacement des étriers. Pour cette raison, certaines des recommandations existantes sont très strictes dans les détails pour prendre en compte ce fait. Colotti and Swamy (2011) ont développé une solution analytique sous forme fermée pour

quantifier la contribution des étriers en acier et des bandes en PRF en intégrant les distributions de contraintes le long de la hauteur de la poutre à mesure que la fissure critique s'ouvre. Cette formulation fournit une valeur de pointe de la contribution combinée des deux matériaux, acier et PRF. La contribution du PRF suit le même traitement que celui utilisé par [Chen and Teng \(2003\)](#), mais avec un autre modèle de résistance d'adhérence.

Les guides existantes fournissent des formulations pour évaluer la contribution à la résistance au cisaillement des lamelles de PRF (V_f) qui sont similaires à la contribution de l'armature transversale en acier interne à la résistance au cisaillement ([Eq. 2.1](#)), puisque la plupart d'entre eux sont basés sur l'analogie du treillis.

$$V_f = \frac{A_f}{s_f} z_f f_{fd} (\cot \theta + \cot \alpha) \sin \alpha \quad (2.1)$$

Où A_f/s_f est l'aire par unité de longueur du renfort en PRF, z_f est le bras de levier intérieur du renfort en PRF, f_{fd} est la résistance à la traction de calcul du PRF lorsque la rupture se produit, θ est l'angle entre la bielle de compression en béton et l'axe longitudinal de l'élément, α est l'angle entre l'orientation principale des fibres du PRF et l'axe longitudinal de l'élément.

Les principales formulations fournis dans différentes guides pour évaluer la contribution au cisaillement du PRF V_f considérés dans cette étude sont résumés dans le [Tableau 2.1](#). La définition du niveau de contrainte dans le PRF et de l'angle θ constitue la principale différence entre les formulations et guides existantes. La contrainte ou la déformation effective du PRF est sensiblement inférieure à la résistance ou la déformation ultime du PRF, en raison de la contrainte de traction variable développée le long du profil de la fissure ([Monti and Liotta 2007](#)). Certaines des formulations adoptent 45° pour l'angle θ ([ACI 440.2R-17](#); [TR-55](#); [JSCE](#)) ou alternativement une approche d'angle variable ([CSA-S806.12](#); [fib Bulletin 14](#); [fib Bulletin 90](#); [CNR-DT200 R1.2013](#)).

La principale différence avec les formulations pour l'acier transversal interne est que le renfort en PRF ne se plastifie pas à la rupture. Les différents modèles existants définissent les contraintes dans le renfort collé extérieurement en fonction de sa configuration, en tenant compte du décollement pour les configurations en forme de U et collées sur les côtés (S), et en supposant une rupture de la lamelle dans l'angle arrondi des sections pour la configuration enveloppée (W). En d'autres termes, ils considèrent différents scénarios liés à la rupture. Pour tenir compte du décollement, l'ancrage de la lamelle de PRF par rapport à la fissure de cisaillement critique doit être défini. Par conséquent, certaines formulations considèrent une

valeur moyenne pour la longueur ancrée qui croise la fissure de cisaillement critique. Pour la configuration enveloppée (W), afin de considérer la rupture à l'angle arrondi, la plupart des formulations sont semi-empiriques et proviennent d'un ajustement d'une formule obtenue à partir d'essais de confinement réalisés sur des poteaux renforcés avec des feuilles de PRF.

Tableau 2.1 — Résumé des formulations de conception pour le renforcement au cisaillement avec PRF collés extérieurement.

	Guides de conception	Équations
1	ACI 440.2R-17	$V_f = \frac{A_f f_{fe} (\sin \alpha_f + \cos \alpha_f) d_f}{s_f}$ $A_{fv} = 2nt_f w_f; f_{fe} = E_f \varepsilon_{fe}; \text{ full wrapped : } \varepsilon_{fe} = 0.004 \leq 0.75 \varepsilon_{fu}; \text{ U-wrapped or side-bonded : } \varepsilon_{fe} = \kappa_v \varepsilon_{fu} \leq 0.004;$ $\kappa_v = \frac{k_1 k_2 L_e}{11900 \varepsilon_{fu}} \leq 0.75; L_e = \frac{23300}{(nt_f E_f)^{0.58}}; k_1 = \left(\frac{f'_c}{27}\right)^{\frac{2}{3}}; k_2 = \frac{d_f - L_e}{d_f} \text{ for U-wrapped; or } k_2 = \frac{d_f - 2L_e}{d_f} \text{ for side-bonded}$
2	CSA-S806.12	$V_f = \frac{A_f E_f \varepsilon_{fe} d_f (\cot \theta + \cot \alpha_f) \sin \alpha_f}{s_f}$ $A_f = 2nt_f w_f; \text{ full wrapped : } \varepsilon_{fe} = 0.006 \leq 0.75 \varepsilon_{fu}; \text{ U-wrapped or side-bonded : } \varepsilon_{fe} = \kappa_v \varepsilon_{fu} \leq 0.004;$ $\kappa_v = \frac{k_1 k_2 L_e}{11900 \varepsilon_{fu}} \leq 0.75; L_e = \frac{23300}{(nt_f E_f)^{0.58}}; k_1 = \left(\frac{f'_c}{27}\right)^{\frac{2}{3}}; k_2 = \frac{d_f - L_e}{d_f} \text{ for U-wrapped; or } k_2 = \frac{d_f - 2L_e}{d_f} \text{ for side-bonded}$
3	fib Bulletin 14	$V_f = 0.9 \varepsilon_{fe} E_f \rho_f b_w d (\cot \theta + \cot \alpha_f) \sin \alpha_f$ $\rho_f = \frac{2nt_f w_f}{b_w s_f}; \text{ U-wrapped or side-bonded : } \varepsilon_{fe} = \min \left\{ 0.65 \left(\frac{f'_c}{E_f \rho_f}\right)^{0.56} \times 10^{-3}; 0.17 \left(\frac{f'_c}{E_f \rho_f}\right)^{0.3} \varepsilon_{fu} \right\};$ $\text{ full wrapped : } \varepsilon_{fe} = 0.17 \left(\frac{f'_c}{E_f \rho_f}\right)^{0.3} \varepsilon_{fu}; \text{ or } \varepsilon_{fe} = 0.048 \left(\frac{f'_c}{E_f \rho_f}\right)^{0.47} \varepsilon_{fu} \text{ (AFRP)}$
4	fib Bulletin 90	$V_f = A_{fwc} h_{fe} f_{fe} (\cot \theta + \cot \alpha_f) \sin \alpha_f$ $A_{fwc} = 2t_{fe} w_f / s_f \text{ for strips; and } 2t_{fe} \sin \alpha_f \text{ for continuous FRP; } t_{fe} = nt_f \text{ for } n < 4 \text{ and } (nt_f)^{0.85} \text{ for } n \geq 4;$ $h_{fe} = \min \{h_f; h - 0.1d\};$ $\text{ full wrapped : } f_{fe} = f_{fwc} = \alpha_t k_r f_{fu}; \alpha_t = 0.8; k_r = 0.5 \frac{r_c}{50} \left(2 - \frac{r_c}{50}\right) \text{ for } r_c < 50 \text{ mm and } k_r = 0.5 \text{ for } r_c \geq 50 \text{ mm}$ $\text{ U-wrapped : } f_{fe} = \min \{f_{fwc}; f_{fbw}\}$ $\text{ For continuous FRP sheets : } f_{fbw} = \left[1 - \frac{1}{3} \frac{l_e}{h_{fe} / \sin \alpha_f}\right] f_{bk} \text{ for } x \geq l_e; \text{ or } f_{fbw} = \frac{2}{3} \frac{h_{fe} / \sin \alpha_f}{l_e} f_{bk} \text{ for } x \leq l_e$ $\text{ For discrete FRP strips : } f_{fbw} = f_{bk} \text{ for } x \geq l_e \text{ and } l_e \leq y \leq x; \text{ or } f_{fbw} = \left[1 - \left(1 - \frac{2ms_f}{3l_e}\right) \frac{m}{n}\right] f_{bk} \text{ for } x \geq l_e \text{ and } y \leq l_e;$ $\text{ or } f_{fbw} = \frac{2}{3} \frac{ns_f / (\cot \theta + \cot \alpha_f) \sin \alpha_f}{l_e} f_{bk} \text{ for } x \leq l_e \text{ and } y \leq x$ $x = \frac{h_{fe}}{\sin \alpha_f}; y = \frac{s_f}{(\cot \theta + \cot \alpha_f) \sin \alpha_f}; n = \text{int} \left(\frac{h_{fe} (\cot \theta + \cot \alpha_f)}{s_f}\right); m = \text{int} \left(\frac{l_e (\cot \theta + \cot \alpha_f) \sin \alpha_f}{s_f}\right); f_{bk} = \sqrt{\frac{E_f s_{0k} \tau_{b1k}}{t_{fe}}}; l_e = \frac{\pi}{2} \sqrt{\frac{E_f t_{fe} s_{0k}}{\tau_{b1k}}};$ $s_{0k} = 0.37; \tau_{b1k} = 0.37 \sqrt{f_{cm} f_{ctm}}; f_{ctm} = 0.62 \sqrt{f_{cm}}$
5	CNR-DT200 R1.2013	$V_f = 0.9 d f_{fe} 2nt_f (\cot \theta + \cot \alpha_f) \frac{w_f}{s_f}$ $\text{ U-wrapped or side-bonded : } f_{fe} = f_{dad} \left[1 - \frac{1}{3} \frac{L_e \sin \alpha_f}{\min(0.9d; h_w)}\right]; f_{dad} = \frac{1}{1.2} \sqrt{\frac{2E_f \Gamma_{fd}}{nt_f}}; L_e = \max \left\{ \frac{1}{1.25 f_{bd}} \sqrt{\frac{\pi^2 E_f nt_f \Gamma_{fd}}{2}}; 200 \right\};$ $f_{bd} = \frac{2\Gamma_{fd}}{S_u}; S_u = 0.25; \Gamma_{fd} = k_b k_G \sqrt{f_{cm} f_{ctm}}; \text{ for } \frac{w_f}{b_w} \geq 0.25 : k_b = \sqrt{\frac{2 - (w_f/b_w)}{1 + (w_f/b_w)}} \geq 1; \text{ for } \frac{w_f}{b_w} < 0.25 : k_b = 1.18; k_G = 0.037;$ $\text{ full wrapped : } f_{fe} = f_{dad} \left[1 - \frac{1}{3} \frac{L_e \sin \alpha_f}{\min(0.9d; h_w)}\right] + \frac{1}{2} (\emptyset_R f_{fu} - f_{dad}) \left[1 - \frac{L_e \sin \alpha_f}{\min(0.9d; h_w)}\right]; \emptyset_R = 0.2 + 1.6 \frac{r_c}{b_w} \text{ with } 0 \leq \frac{r_c}{b_w} \leq 0.5$
6	TR-55	$V_f = \frac{A_f}{s_f} \left(d_f - \frac{n_s}{3} l_{t,max} \cos \alpha_f\right) E_f \varepsilon_{fe} (\sin \alpha_f + \cos \alpha_f)$ $A_f = 2nt_f w_f; l_{t,max} = 0.7 \sqrt{\frac{E_f nt_f}{f_{ctk}}}; f_{ctk} = 0.18 (f_{cu})^{\frac{2}{3}}; \varepsilon_{fe} = \min \left(\frac{\varepsilon_{fu}}{2}; 0.5 \sqrt{\frac{f_{ctk}}{E_f nt_f}}; 0.004\right);$ $\text{ full wrapped : } n_s = 0; \text{ U-wrapped : } n_s = 1; \text{ side-bonded : } n_s = 2$
7	JSCE	$V_f = K A_f f_{fud} Z \frac{(\sin \alpha_f + \cos \alpha_f)}{s_f}$ $K = 1.68 - 0.67R \text{ with } 0.4 \leq K \leq 0.8; R = (\rho_f E_f)^{0.25} \left(\frac{f_{rud}}{E_f}\right)^{\frac{2}{3}} \left(\frac{1}{f'_c}\right)^{\frac{1}{3}} \text{ with } 0.5 \leq R \leq 2;$ $A_f = 2nt_f w_f; \rho_f = \frac{A_f}{b_w s_f}; f_{rud} = \frac{f_{fu}}{1.2}; Z = \frac{d}{1.5}$

2.9 Conclusion

Ce chapitre a présenté une revue approfondie du comportement au cisaillement des poutres en BA, y compris les mécanismes de transfert des efforts de cisaillement, les effets des armatures transversales en acier et les différents modes de rupture possibles. Les principales approches de modélisation pour l'analyse du cisaillement ont également été discutées, notamment l'analogie du treillis, les modèles de bielle et tirant et la théorie modifiée du champ de compression.

Une attention particulière a été portée au renforcement au cisaillement des poutres en BA par des PRF collés extérieurement. Les différentes configurations possibles de renforcement par PRF (collage latéral, chemisage en U, enveloppement) ainsi que les modes de rupture associés ont été examinés. Un état de l'art détaillé des formulations proposées dans les guides de conception existants pour la quantification de la contribution du PRF à la résistance au cisaillement a été présenté et discuté. Les principales différences entre ces formulations résident dans la définition du niveau de contrainte ou de déformation effective du PRF ainsi que l'angle d'inclinaison des bielles de compression en béton.

Malgré les nombreux travaux déjà réalisés, il n'existe toujours pas de consensus international sur l'évaluation précise de la contribution au cisaillement apportée par les renforts en PRF collés extérieurement. Cela est dû à la complexité des phénomènes de cisaillement, du décollement prématuré des renforts pour certaines configurations, du comportement linéaire élastique des PRF jusqu'à la rupture et de l'interaction entre le béton, l'armature transversale interne et le PRF. Des efforts de recherche supplémentaires sont donc encore nécessaires pour élaborer un modèle de dimensionnement au cisaillement unifié et largement accepté pour les poutres renforcées par PRF.

CHAPITRE 03

*Approches d'apprentissage automatique
pour prédire la résistance au cisaillement
des poutres en BA renforcées par PRF.*

3.1 Introduction

Les techniques d'apprentissage automatique ont connu un essor remarquable ces dernières années, offrant des approches novatrices pour relever les défis complexes rencontrés dans divers domaines, y compris le génie civil. Dans le contexte des structures en BA renforcées par PRF, la prédiction précise de la résistance au cisaillement revêt une importance cruciale pour assurer une conception et une évaluation adéquates.

Les méthodes empiriques conventionnelles et les équations de conception présentent des limites inhérentes pour capturer les interactions complexes entre les multiples paramètres influant sur la résistance, tels que les propriétés des matériaux et les configurations géométriques. En revanche, les techniques d'apprentissage automatique, grâce à leur capacité à détecter et modéliser les relations non linéaires à partir de données, offrent un potentiel prometteur pour améliorer la précision et la fiabilité des prédictions de la résistance au cisaillement.

Ce chapitre présente une revue approfondie de l'état de l'art de l'application des approches d'apprentissage automatique pour prédire la résistance au cisaillement des poutres en BA renforcées par PRF collés extérieurement. Il explore un large éventail de techniques, allant des réseaux de neurones artificiels aux modèles d'ensemble en passant par la programmation génétique et les systèmes d'inférence neuro-flous adaptatifs. Une analyse comparative des forces et des limites de ces différentes approches est proposée, mettant en évidence leurs performances par rapport aux modèles empiriques traditionnels.

L'influence des divers paramètres d'entrée, tels que les propriétés du béton, les caractéristiques des armatures PRF et les configurations géométriques, sur la précision et la robustesse des modèles d'apprentissage automatique est examinée. Les défis liés à la disponibilité des données, à l'optimisation des modèles et à l'évaluation de la fiabilité sont également abordés, ouvrant la voie à de nouvelles pistes de recherche.

En synthétisant les dernières avancées et en identifiant les lacunes actuelles, ce chapitre vise à fournir une compréhension globale du potentiel et des limites des techniques d'apprentissage automatique dans la prédiction de la résistance au cisaillement des structures en BA renforcées par PRF collés extérieurement. Il contribue ainsi au développement de modèles plus précis et fiables, favorisant une conception et une évaluation optimales de ces systèmes structurels innovants.

3.2 Apprentissage automatique : Concepts et méthodologies

3.2.1 Apprentissage automatique, intelligence artificielle et apprentissage profond

Les concepts d'intelligence artificielle (IA), d'apprentissage automatique et d'apprentissage profond sont souvent mal compris au sein de la communauté du génie civil. L'IA est un vaste domaine englobant des algorithmes et des techniques visant à imiter l'intelligence humaine pour des tâches telles que le raisonnement, la prise de décision et la résolution de problèmes (Alkayem et al., 2018; Stefano and Bini, 2018; Dimiduk et al., 2018). L'apprentissage automatique est un sous-domaine de l'IA impliquant des algorithmes qui permettent aux machines d'apprendre à partir de données pour faire des prédictions et des classifications. L'apprentissage profond est une branche spécialisée de l'apprentissage automatique qui utilise des architectures de réseaux de neurones sophistiquées capables d'apprendre à partir de grands ensembles de données et de s'attaquer à des problèmes complexes. La Fig. 3.1 illustre clairement les distinctions entre l'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond.

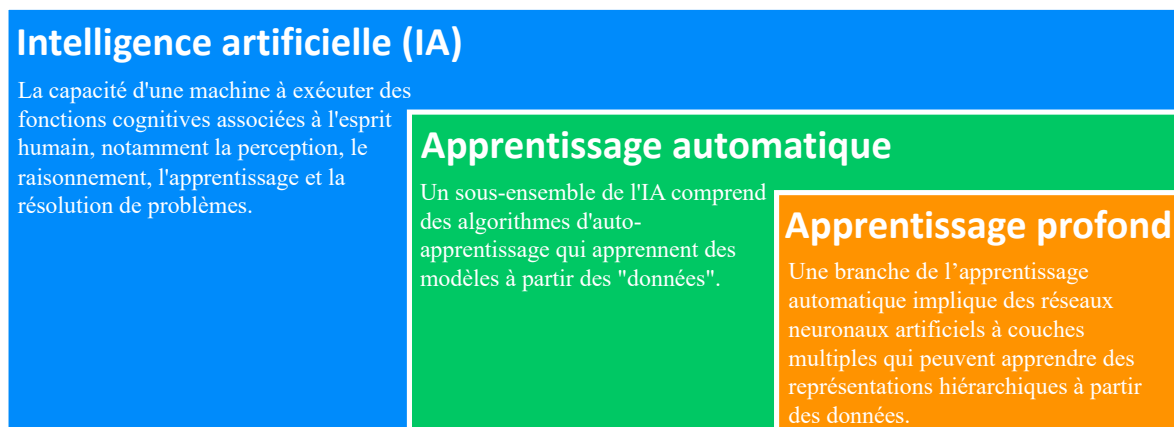


Fig. 3.1 — Intelligence artificielle, apprentissage automatique et apprentissage profond.

3.2.2 Principales catégories d'algorithmes d'apprentissage automatique

L'apprentissage automatique est un sous-domaine de l'intelligence artificielle qui développe des modèles capables d'apprendre à partir de données pour faire des prévisions ou des classifications sans programmation explicite (Ongsulee, 2017). L'objectif principal de l'apprentissage automatique est d'établir des modèles mathématiques, également connus sous le nom de "boîtes noires", entraînés sur des ensembles de données pour faire des prédictions ou des décisions sur de nouvelles données (Gianey and Choudhary, 2017). Les modèles d'apprentissage automatique ont été largement appliqués dans divers domaines, notamment

l'analyse d'images, la régression de données, la modélisation expérimentale, le traitement du langage naturel et le diagnostic médical (Singh et al., 2016). L'apprentissage automatique peut être classé en quatre types principaux, comme l'illustre la Fig. 3.2:

- i. ***Apprentissage supervisé*** : Cette catégorie repose sur des instances d'entraînement étiquetées dérivées de données numériques ou expérimentales (Shang et al., 2022 ; Ahmad et al., 2022). Le but est de déterminer les corrélations entre les variables indépendantes et dépendantes, permettant ainsi des prédictions ou des classifications de la variable dépendante. Les paradigmes d'apprentissage supervisé incluent la régression linéaire, les réseaux de neurones artificiels, les machines à vecteurs de support et les arbres de décision.
- ii. ***Apprentissage non supervisé*** : Ces algorithmes utilisent des instances de données non étiquetées et sont principalement employés pour le clustering de données, la détection d'anomalies et la réduction de dimension. Le clustering divise les données en groupes en fonction de leur similarité, tandis que la détection d'anomalies identifie les points de données anormaux. La réduction de dimension élimine les caractéristiques inutiles sans affecter les corrélations entrée-sortie (Alloghani et al., 2019).
- iii. ***Apprentissage semi-supervisé*** : Cette approche combine des instances d'entraînement étiquetées et non étiquetées. Elle vise à tirer parti des données étiquetées pour améliorer les performances du modèle dans l'apprentissage des modèles à partir d'instances non étiquetées. L'apprentissage semi-supervisé aborde les limites de l'apprentissage supervisé et non supervisé en utilisant une petite partie de données étiquetées et une grande partie de données non étiquetées, réduisant ainsi le temps nécessaire au prétraitement des données (Cao et al., 2016).
- iv. ***Apprentissage par renforcement*** : Cette catégorie repose sur des agents opérant dans un environnement, apprenant par un processus d'essai et d'erreur à l'aide de retours d'expérience (Roh et al., 2021). Contrairement à l'apprentissage supervisé, l'apprentissage par renforcement utilise un système de récompense et de punition pour les actions souhaitables et indésirables. Bien que largement utilisé dans les applications d'IA, l'apprentissage par renforcement a une application limitée en génie des structures ou en science du béton (Tapeh and Naser, 2023; Nithurshan and Elakneswaran, 2023).

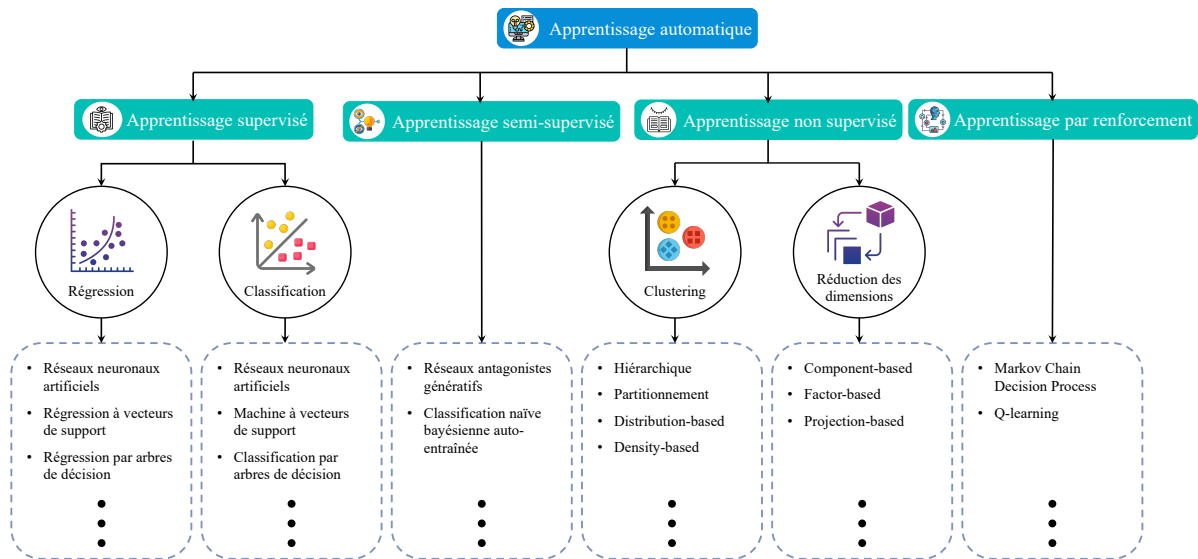


Fig. 3.2 — Catégories d'algorithmes d'apprentissage automatique.

3.2.3 Étapes clés pour la construction de modèles d'apprentissage automatique efficaces

La mise en œuvre des modèles d'apprentissage automatique implique généralement quatre étapes clés : la collecte de données, le prétraitement des données, l'entraînement du modèle et le test et l'évaluation du modèle (Alkayem et al., 2024), comme l'illustre la Fig. 3.3 :

- i. **Collecte de données** : La collecte d'un ensemble de données approprié est cruciale pour développer des modèles d'apprentissage automatique efficaces. L'ensemble de données doit fournir les modèles d'apprentissage nécessaires tout en tenant compte des paramètres pertinents et en tirant parti du plus grand nombre possible d'instances de données disponibles.
- ii. **Prétraitement des données** : Cette étape cruciale améliore la qualité et la fiabilité des données pour l'entraînement du modèle. Elle implique le nettoyage des données (gestion des données manquantes et bruitées), la transformation (normalisation, sélection des caractéristiques, discrétisation) et les techniques de réduction (réduction de la dimension, échantillonnage) (Alexandropoulos et al., 2019; Ayesha et al., 2020).
- iii. **Développement du modèle** : Après le prétraitement, les données sont prêtes pour l'entraînement du modèle. L'algorithme approprié (par exemple, réseaux de neurones, machines à vecteurs de support, arbres de décision) est sélectionné en fonction des caractéristiques des données. L'entraînement implique de partitionner les données en ensembles d'entraînement et de validation, en utilisant des techniques comme le holdout

ou la validation croisée K-fold (Chaabene et al., 2020). Les métriques de performance guident le réglage et l'affinement du modèle.

- iv. **Évaluation et test du modèle** : Les performances du modèle entraîné sont évaluées de manière approfondie à l'aide de métriques statistiques telles que l'erreur absolue moyenne (MAE), la racine carrée de l'erreur quadratique moyenne (RMSE), le R-carré (R^2) et l'erreur de pourcentage absolue moyenne (MAPE). Si les performances ne répondent pas au seuil de précision souhaité, le modèle est ajusté en étendant l'ensemble des données, en améliorant l'architecture ou en ajustant les hyperparamètres (Naser and Alavi, 2021; Bardhan and Asteris, 2023).

Le développement des modèles d'apprentissage automatique à haute performance nécessite une sélection minutieuse des données, un prétraitement robuste, une sélection appropriée de l'algorithme, une évaluation complète des performances et un affinement itératif du modèle pour obtenir des prédictions précises et des applications pratiques dans le monde réel.

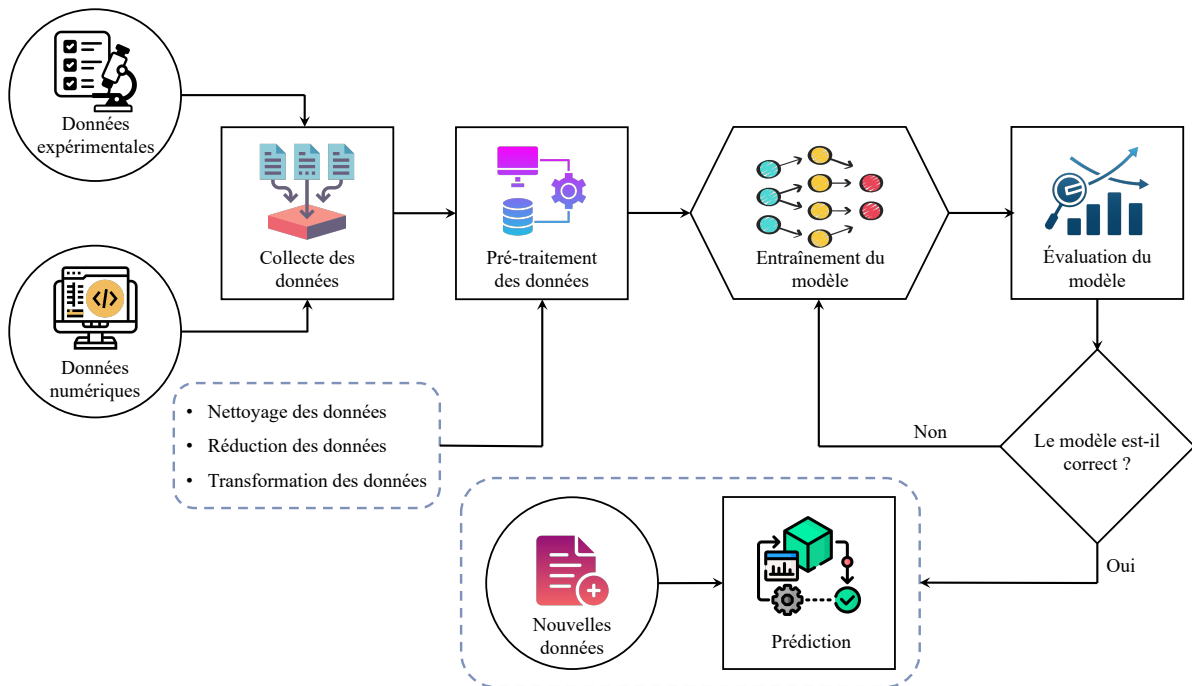


Fig. 3.3 — Flux de travail global des modèles d'apprentissage automatique.

3.3 Aperçu des algorithmes d'apprentissage automatique

Cette section donne un aperçu des différents algorithmes d'apprentissage automatique qui ont été employés pour prédire la résistance au cisaillement des poutres en BA renforcées par PRF collés extérieurement. Ceux-ci comprennent les techniques de régression, les réseaux de

neurones artificiels, la programmation génétique, les systèmes d'inférence neuro-flous adaptatifs, les machines à vecteurs de support, les arbres de décision, les méthodes d'ensemble comme les forêts aléatoires et les algorithmes de boosting. Les principes de fonctionnement, les forces et les limites de ces algorithmes sont discutés en détail.

3.3.1 Techniques de régression

L'analyse de régression modélise la relation entre une ou plusieurs variables indépendantes (prédicteurs) et une variable dépendante (cible). Pour prédire la résistance au cisaillement des poutres en BA renforcées par PRF, les techniques de régression mettent en relation les paramètres d'entrée tels que les propriétés du béton, les détails d'armature en PRF et les configurations géométriques avec la caractéristique de résistance cible.

- **Régression linéaire:** Suppose une relation linéaire entre les entrées et la cible, en ajustant une ligne droite/un hyperplan pour minimiser les métriques d'erreur comme MAE ou RMSE. Inclut la régression linéaire simple (une entrée) et la régression linéaire multiple.
- **Régression multivariée:** Extension de la régression linéaire multiple, avec plusieurs variables dépendantes au lieu d'une seule variable cible, utile pour modéliser simultanément plusieurs caractéristiques de résistance.
- **Régression polynomiale:** Étend la régression linéaire en ajustant des polynômes courbes pour capturer les relations non linéaires, mais risque un sur-apprentissage avec des polynômes de degré élevé.
- **Régression régularisée:** Des techniques comme la régression Ridge et Lasso introduisent des pénalités pour réduire les coefficients des prédicteurs moins importants vers zéro, améliorant la généralisation et réduisant le sur-apprentissage (Géron, 2019). Ridge utilise la régularisation L2, tandis que Lasso utilise la régularisation L1 pour une sélection automatique des variables.

Bien qu'appliquées en génie des structures, ces techniques peuvent avoir des performances limitées pour les relations hautement complexes et non linéaires dans la prédiction de la résistance du BA renforcé par PRF. Des algorithmes avancés comme les réseaux de neurones, les machines à vecteurs de support et les méthodes d'ensemble peuvent mieux capturer les modèles complexes et les non-linéarités.

3.3.2 Réseaux de neurones artificiels (ANNs)

Les réseaux de neurones artificiels (ANNs) sont des algorithmes d'apprentissage automatique puissants inspirés des réseaux neuronaux biologiques, capables d'apprendre des mappages non linéaires complexes entre les entrées et les sorties (Rosa and Rosa, 2016; Cao et al., 2016; Abunassar et al., 2023). Les ANNs comprennent des nœuds interconnectés (neurones) organisés en couches, avec des connexions pondérées ajustées de manière itérative lors de l'entraînement pour optimiser les performances. La structure de base d'un ANN se compose d'une couche d'entrée, d'une ou plusieurs couches cachées et d'une couche de sortie (Fig. 3.4). Les entrées se propagent à travers le réseau, chaque neurone caché calculant une somme pondérée transformée par une fonction d'activation non linéaire, permettant ainsi la modélisation de non-linéarités complexes. Des algorithmes d'optimisation, comme la rétropropagation (optimisation basée sur le gradient), ajustent les poids des connexions pour minimiser les erreurs de prédiction pendant l'entraînement.

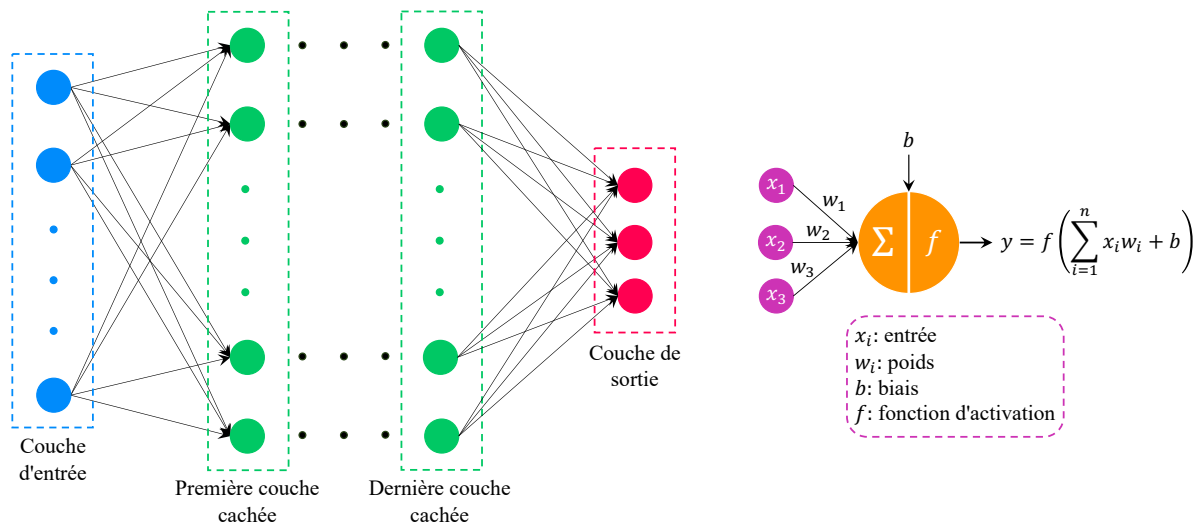


Fig. 3.4 — Architecture d'un simple modèle ANN et son composant principal, le neurone.

Bien que l'optimisation basée sur le gradient domine l'entraînement des ANNs, les algorithmes de calcul évolutionnaire (EC) inspirés des phénomènes naturels ont émergé, améliorant les capacités d'entraînement grâce à une recherche globale, à l'évasion des optima locaux et à l'amélioration de la généralisation (Alkayem et al., 2024). Les modèles hybrides EC-ANN combinent de manière synergique les capacités de recherche des algorithmes EC avec l'approximation de fonction des ANNs pour améliorer les prédictions en génie des structures.

Les ANNs offrent plusieurs avantages, notamment leur capacité à apprendre à partir de données sans s'appuyer sur des règles de programmation explicites, leur aptitude à modéliser des relations complexes et non linéaires, et leur potentiel de traitement parallèle, qui peut conduire à une efficacité computationnelle. Cependant, ils ont également des limites, comme le risque de sur-apprentissage lorsque le modèle devient trop complexe et mémorise les données d'entraînement, le besoin de grandes quantités de données d'entraînement représentatives, et des problèmes potentiels d'interprétabilité, car les ANNs peuvent parfois être perçus comme des modèles de type "boîte noire".

3.3.3 Programmation génétique (GP) et programmation d'expression génique (GEP)

La programmation génétique (GP) (Bi et al., 2021) et la programmation d'expression génique (GEP) (Zhong et al., 2017) sont deux techniques de calcul évolutionnaire (EC) qui ont gagné une attention significative dans le domaine du génie des structures. Ces méthodes s'inspirent des algorithmes génétiques et utilisent des principes évolutionnaires pour découvrir les relations mathématiques et les modèles sous-jacents dans les données.

La GP utilise des représentations arborescentes pour faire évoluer des programmes informatiques ou des expressions mathématiques qui modélisent le système cible. La population initiale est constituée d'individus représentés sous forme d'arbres, avec des nœuds internes comme fonctions et des nœuds feuilles comme terminaux. Par le biais de la sélection, des opérations génétiques (mutation, croisement) et de l'évaluation de l'aptitude, la GP fait évoluer ces arbres pour trouver les meilleures expressions décrivant les relations entrée-sortie. La GEP, en revanche, est une extension de la GP qui utilise un schéma de représentation linéaire traduisible en arbres d'expressions, combinant les avantages des structures linéaires et arborescentes. La GEP maintient des représentations cohérentes et compactes, quelle que soit la complexité de la solution, atténuant le problème de boursoufflement de la GP où les arbres deviennent excessivement grands. La GEP a démontré des performances supérieures dans les applications d'ingénierie comme la science du béton en faisant évoluer des modèles mathématiques concis et interprétables.

La GP et la GEP sont toutes deux des techniques puissantes pour modéliser des systèmes complexes et non linéaires, en découvrant automatiquement des expressions mathématiques à partir de données, sans programmation explicite ou connaissance préalable. Cependant, les performances dépendent de facteurs tels que le choix des opérateurs génétiques, la taille de la population et la représentation du problème.

3.3.4 Système d'inférence neuro-flou adaptatif (ANFIS)

Le système d'inférence neuro-flou adaptatif (ANFIS) (Salleh et al., 2017) est une technique d'apprentissage automatique hybride combinant les réseaux de neurones artificiels et les systèmes d'inférence floue. Il exploite les capacités d'apprentissage des réseaux de neurones et l'interprétabilité de la logique floue pour modéliser des relations non linéaires complexes. ANFIS convient bien aux données imprécises ou incertaines, en intégrant le raisonnement flou. Il utilise généralement le modèle flou Takagi-Sugeno-Kang (TSK), où les parties conséquentes des règles floues sont des combinaisons linéaires des variables d'entrée, fournissant une approche systématique pour générer des règles à partir de données.

L'architecture ANFIS se compose de cinq couches : la couche d'appartenance (calculant les valeurs d'appartenance des entrées), la couche de fuzzification (combinant les entrées fuzzifiées), la couche de règles floues (calculant les forces de déclenchement des règles), la couche de normalisation (normalisant les forces de déclenchement) et la couche de défuzzification (calculant la sortie pondérée finale). L'entraînement consiste à ajuster les paramètres des fonctions d'appartenance et les parties conséquentes pour minimiser les erreurs de prédiction grâce à un algorithme d'apprentissage hybride combinant les méthodes des moindres carrés et de la rétropropagation. Les avantages d'ANFIS incluent la capture des non-linéarités tout en fournissant des règles floues interprétables, aidant à la compréhension des modèles. Il est efficace sur le plan calculatoire et atteint une grande précision dans les tâches de prédiction et de classification.

3.3.5 Machines à vecteurs de support (SVM)

Les machines à vecteurs de support (SVM) sont des algorithmes d'apprentissage automatique puissants pour les tâches de classification binaire, de régression et de clustering (Boser et al., 1992; Vapnik, 1995; Ben-Hur et al., 2001). Les SVM trouvent un hyperplan optimal qui maximise la marge entre les classes dans un espace de caractéristiques de grande dimension, en utilisant les vecteurs de support pour définir la frontière de décision. Pour les données non linéairement séparables, les SVM emploient des fonctions noyaux pour mapper les entrées dans des dimensions supérieures où la séparation linéaire est possible. Des noyaux comme linéaire, polynômial, fonction de base radiale (RBF) et sigmoïde permettent de modéliser différentes non-linéarités (Tharwat, 2019).

La régression à vecteurs de support (SVR) étend les SVM aux problèmes de régression, en trouvant une fonction approchant les cibles dans une tolérance d'erreur prédéfinie tout en minimisant la complexité du modèle et le risque empirique.

Les SVM gèrent efficacement les données de grande dimension et éparées, les rendant polyvalentes pour des applications comme la reconnaissance de formes et le traitement du signal. Cependant, les performances dépendent du choix du noyau et du réglage des hyperparamètres comme la pénalité (C) et les paramètres du noyau (par exemple, gamma pour RBF) à l'aide des techniques comme la recherche par grille et la validation croisée. La capacité des SVM à capturer les non-linéarités, à gérer les grandes dimensions et à fournir des solutions parcimonieuses en fait des outils puissants, mais un réglage approprié des paramètres est crucial pour des performances optimales.

3.3.6 Arbres de décision (DT)

Les arbres de décision (DT) sont des modèles d'apprentissage automatique interprétables représentant une série de décisions basées sur les caractéristiques d'entrée pour prédire les résultats aux nœuds feuilles. Ils gèrent les données numériques et catégorielles et offrent une interprétabilité et une efficacité computationnelle. La structure d'un DT (Fig. 3.5) comprend un nœud racine (l'ensemble complet des données), des nœuds de décision internes (divisant les données en fonction des caractéristiques/règles), des branches (issues des divisions) et des nœuds feuilles (prévisions finales). La construction de l'arbre divise récursivement les données en sous-ensembles à chaque nœud en utilisant la caractéristique la plus discriminante en fonction de mesures d'impureté comme l'indice de Gini, le gain d'information (classification) ou l'erreur quadratique moyenne (régression) (Géron, 2019).

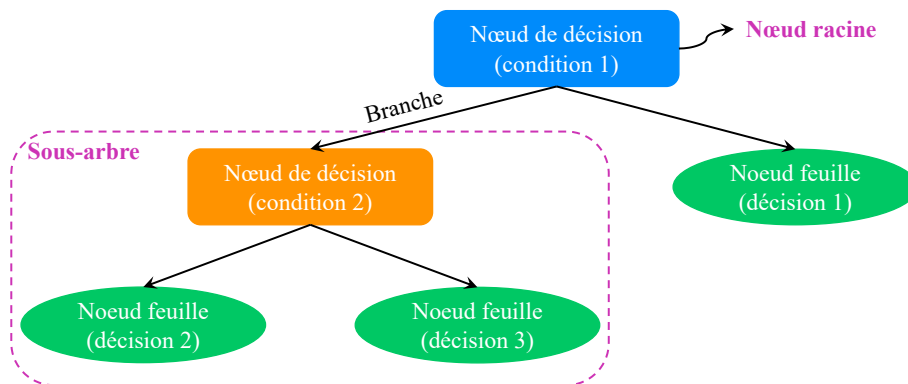


Fig. 3.5 — Exemple d'un arbre de décision (DT).

L'avantage clé des DT est leur interprétabilité, qui visualise le processus de décision. Cependant, ils sont enclins au sur-apprentissage, atténué par des techniques de régularisation comme la limitation de la profondeur, le nombre minimal d'échantillons pour la division/les feuilles ou l'élagage. Les DT individuels peuvent avoir une précision inférieure aux méthodes d'ensemble comme les forêts aléatoires ou le boosting de gradients, servant souvent d'apprenants de base. Les performances dépendent des mesures d'impureté, des critères d'arrêt et des paramètres de régularisation, nécessitant un réglage approprié via des techniques comme la validation croisée ou la recherche par grille. Malgré leur simplicité, les DT offrent une interprétabilité précieuse, tandis que les méthodes d'ensemble améliorent leur précision prédictive.

3.3.7 Forêt aléatoire (RF)

La forêt aléatoire (RF) est une puissante technique d'apprentissage ensemble combinant plusieurs arbres de décision pour améliorer les performances prédictives et la robustesse (Breiman, 2001). RF construit un ensemble d'arbres entraînés sur différents sous-ensembles de données grâce au bootstrap agrégé (bagging) et à la sélection aléatoire de caractéristiques à chaque nœud. La nature d'ensemble offre des avantages par rapport aux arbres individuels en réduisant la variance et le sur-apprentissage par la moyenne des prédictions. La sélection aléatoire des caractéristiques décorrèle les arbres, améliorant la diversité et la robustesse. Pour la prédiction, les sorties des arbres individuels sont combinées par vote majoritaire (classification) ou moyennées (régression) (Fig. 3.6).

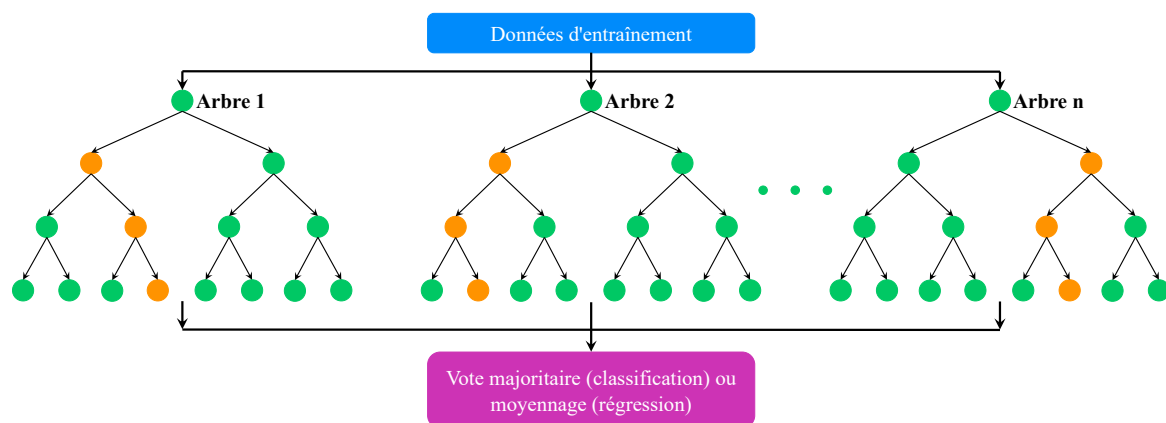


Fig. 3.6 — Entraînement parallèle de la forêt aléatoire (RF).

Les principaux points forts comprennent la gestion des données de grande dimension par la sélection implicite des caractéristiques pendant la croissance des arbres et une relative

insensibilité au réglage des hyperparamètres. Cependant, le réglage du nombre d'arbres, de la profondeur et des caractéristiques par division peut encore améliorer la précision. Bien qu'efficace, RF peut être coûteux en calcul pendant l'entraînement et son interprétabilité est réduite en raison de la nature d'ensemble. Globalement, RF exploite la diversité d'ensemble et la sélection implicite de caractéristiques pour atteindre des performances prédictives robustes et de grande dimension, en faisant un outil puissant pour diverses applications.

3.3.8 Algorithme de boosting

Les algorithmes de boosting sont des ensembles d'apprentissage automatique qui combinent plusieurs apprenants faibles (par exemple, arbres de décision) pour créer un modèle prédictif puissant (Schapire, 1999). Ils entraînent de manière itérative une séquence de modèles faibles, en se concentrant sur les instances mal classées ou mal prédites par les modèles précédents. Cette combinaison additive capture les modèles complexes et les non-linéarités pour améliorer les performances prédictives.

Les principaux algorithmes de boosting comprennent :

- a) **AdaBoost (AdaB)** (Freund and Schapire, 1996; Freund and Schapire, 1997) : Entraîne itérativement des apprenants faibles (arbres de décision à une seule division) sur des données pondérées, en augmentant les poids des instances mal classées. Le modèle final combine des apprenants faibles pondérés en fonction de leurs performances (Fig. 3.7).




Fig. 3.7 — Algorithme AdaBoost : une représentation visuelle avec deux apprenants faibles.

- b) **Machine à gradient boosting (GBM) (Friedman, 2001)** : Emploie la descente de gradient avec des apprenants faibles de type arbres de décision. À chaque itération, un nouvel arbre s'ajuste aux erreurs résiduelles de l'ensemble précédent (Fig. 3.8). Offre un réglage des arbres, du taux d'apprentissage, etc.

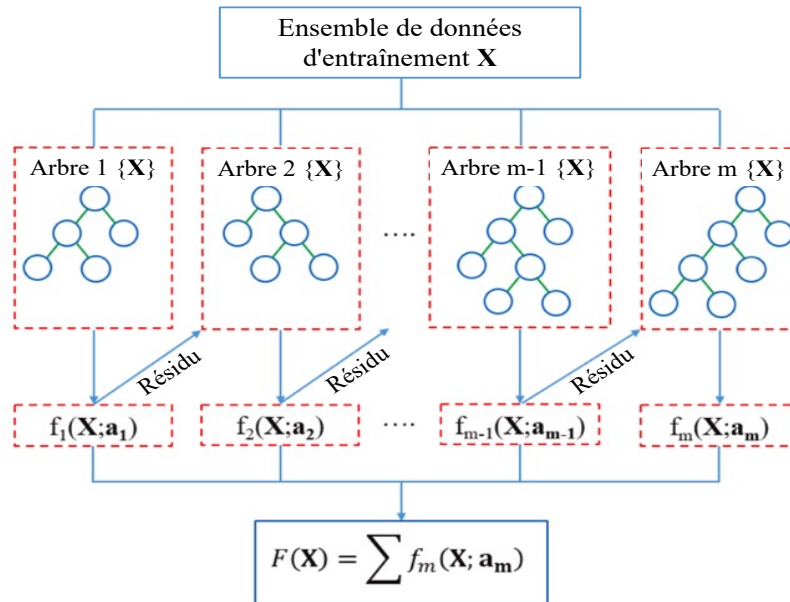


Fig. 3.8 — Une représentation visuelle du modèle GBM.

- c) **eXtreme Gradient Boosting (XGBoost) (Chen and Guestrin, 2016)** : Implémentation efficace et évolutive de GBM avec parallélisation, élagage et structure de données compressée. Utilise une randomisation et un sous-échantillonnage de colonnes pour réduire le sur-apprentissage.
- d) **LightGBM (LGBM) (Ke et al., 2017)** : GBM efficace axé sur la rapidité de calcul et l'évolutivité. Utilise une croissance d'arbre feuille par feuille, un échantillonnage basé sur le gradient et un regroupement de caractéristiques.
- e) **CatBoost (CatB) (Prokhorenkova et al., 2018)** : Conçu pour une gestion efficace des données catégorielles grâce à un échantillonnage à variance minimale au niveau de l'arbre.

Les algorithmes de boosting ont démontré un succès remarquable dans diverses applications d'apprentissage automatique, dépassant souvent d'autres techniques en termes de précision prédictive. Cependant, leurs performances peuvent être influencées par des facteurs tels que le choix des apprenants faibles, le nombre d'itérations et les réglages des hyperparamètres (par exemple, taux d'apprentissage, profondeur de l'arbre, paramètres de régularisation). Un

réglage et une sélection appropriés de l'algorithme de boosting et de ses hyperparamètres sont cruciaux pour obtenir des performances optimales sur des tâches et des ensembles de données spécifiques.

3.4 Application de l'apprentissage automatique pour prédire la résistance au cisaillement des poutres en BA renforcées par PRF

Prédire avec précision les paramètres de résistance, tels que la résistance au cisaillement, est crucial pour la conception et l'évaluation des structures en BA renforcées par PRF collés extérieurement. Cependant, la complexité des mécanismes de rupture au cisaillement sous-jacents, les interactions complexes entre les divers facteurs d'influence, notamment la conception du mélange de béton, les propriétés des composites PRF, le comportement d'adhérence à l'interface et les conditions de chargement, posent des défis importants pour les modèles empiriques conventionnels afin de capturer les non-linéarités complexes inhérentes à ces systèmes structurels.

Ces dernières années, les techniques d'apprentissage automatique sont apparues comme des alternatives prometteuses basées sur les données, offrant la possibilité de modéliser le comportement en résistance des éléments en BA renforcés par PRF avec une meilleure précision et fiabilité. En exploitant la capacité des algorithmes d'apprentissage automatique à apprendre à partir de grands ensembles de données et à identifier des modèles complexes, ces techniques peuvent efficacement capturer les relations complexes entre les paramètres d'entrée et les propriétés de résistance cibles.

Cette section fournit une revue complète de l'état de l'art de l'application des approches d'apprentissage automatique pour prédire la résistance au cisaillement dans les poutres en BA renforcées avec des PRF collés extérieurement. Elle couvre un large éventail de techniques d'apprentissage automatique, notamment les réseaux de neurones artificiels (ANN), les machines à vecteurs de support (SVM), la programmation génétique (GP), les modèles d'apprentissage ensemble (par exemple, forêts aléatoires, gradient boosting) et les techniques émergentes telles que la programmation d'expression génique (GEP). La revue analyse les forces, les limites et les capacités prédictives de ces modèles d'apprentissage automatique, mettant en évidence leurs performances par rapport aux modèles empiriques conventionnels et aux directives de conception.

En outre, la revue examine l'influence de divers paramètres d'entrée, notamment les propriétés du béton, les caractéristiques des armatures PRF et les configurations géométriques, sur la précision et la robustesse des modèles d'apprentissage automatique. Elle aborde également les défis liés à la disponibilité des données, à l'optimisation des modèles et à l'évaluation de la fiabilité des techniques d'apprentissage automatique dans le contexte de la prédiction de la résistance au cisaillement pour les poutres en BA renforcées par PRF collés extérieurement.

En synthétisant les dernières avancées de la recherche et en identifiant les lacunes et les orientations futures de la recherche, cette section vise à fournir une compréhension globale du potentiel et des limites des techniques d'apprentissage automatique dans ce domaine, contribuant ainsi au développement de modèles de prédiction de résistance plus précis et plus fiables.

Le [Tableau 3.1](#) résume les caractéristiques clés des différentes approches d'apprentissage automatique employées dans ce domaine, y compris la référence, la technique, la taille de l'ensemble de données, la configuration PRF, le nombre de paramètres d'entrée et les variables d'entrée spécifiques considérées. Cette vue d'ensemble facilite une analyse comparative des différents modèles d'apprentissage automatique, de leurs portées et des facteurs pris en compte dans chaque étude.

Parmi les études pionnières explorant l'application des techniques d'apprentissage automatique pour prédire la résistance au cisaillement des poutres en BA renforcées par PRF collé extérieurement, [Perera et al. \(2010a, 2010b\)](#) ont employé des ANNs et des GAs. Leurs recherches se sont concentrées sur l'estimation de la capacité au cisaillement des poutres en BA renforcées avec des configurations de PRF en forme de U et enveloppées (W). Les résultats ont démontré le potentiel de ces techniques d'apprentissage automatique pour saisir les interrelations complexes entre les différents paramètres d'entrée régissant le comportement au cisaillement, dépassant les modèles empiriques conventionnels. Parallèlement, [Nehdi and Nikopour \(2010\)](#) ont utilisé des GA pour optimiser les équations de conception au cisaillement pour les poutres en BA renforcées de feuilles de PRF collées extérieurement, tenant compte des mécanismes d'interaction entre le béton, l'armature en acier et les stratifiés de PRF. [Tanarlan et al. \(2012\)](#) ont développé un modèle d'ANN qui incorporait l'influence du rapport portée de cisaillement sur profondeur, un paramètre crucial souvent négligé dans les directives de conception, améliorant ainsi les capacités prédictives du modèle.

Tableau 3.1 — Résumé des techniques d'apprentissage automatique pour prédire la résistance au cisaillement des poutres en BA renforcées par FRP collé extérieurement.

N°	Réf.	Type d'apprentissage automatique	N° de données	Configuration du PRF	N° d'entrée	Variables d'entrée
1	Perera et al. (2010a)	ANN, GA	46	U	9	$b_w, h_b, \rho_f, \alpha_f, E_f, \rho_{sl}, A_{90}, f_{ys}, f_{ck}$
2	Perera et al. (2010b)	ANN	98	U, W	11	$b_w, h_b, \rho_f, \alpha_f, E_f, \rho_{sl}, A_{90}, f_{ys}, f_{ck}, a/d_e, \text{type of configuration}$
3	Nehdi and Nikopour (2010)	GA	212	S, U, W	6	$a/d_e, f_{ck}, b_w, d_e, \varepsilon_{fu}, I_f$
4	Tanarslan et al. (2012)	ANN	84	U, W	9	$b_w, d_e, f_{ck}, w_f/s_f, \alpha_f, E_f, \varepsilon_{fu}, t_f, a/d_e$
5	Naderpour and Alavi (2017)	ANFIS	89	U, W	6	$\varepsilon_{fu}, d_f, f_{ck}, a/d_e, B, R$
6	Kamgar et al. (2020a)	MGP	89	U, W	6	$\varepsilon_{fu}, d_f, f_{ck}, a/d_e, B, R$
7	Abuodeh et al. (2020)	ANN avec RFE et NID	120	S, U	12	$b_w, d_e, a/d_e, f_{ck}, f_{ys}, A_v/S_v, t_f, h_f, w_f/s_f, B_f, E_f, f_f$
8	Kar et al. (2020)	ANFIS	119	W	11	$d_e, a, f_{ck}, A_{sv}, w_f, s_f, \alpha_f, n, t_f, E_f, \varepsilon_{fu}$
9	Kar and Biswal (2020)	ANFIS	148	U	12	$b_w, a/d_e, f_{ck}, A_{sv}, d_f, w_f, s_f, \alpha_f, n, t_f, E_f, \varepsilon_{fu}$
10	Karzad et al. (2022)	ANN	191	S, U	16	$f_{ck}, a/d_e, \rho_{sl}, f_{yb}, S_v, \rho_s, f_{ys}, E_f, \varepsilon_{fu}, h_f, w_f, s_f, t_f, \text{type of stirrups, FRP type, FRP distribution}$
11	Taghipour Anvari et al. (2023)	GEP	785	S, U, W	9	$d_e, a/d_e, f_{ck}, b_w, f_{ys}, E_f, \rho_f, \rho_s, \varepsilon_{fu}$
12	Ezami et al. (2023)	XGB, RF, AdaB, ElasticNet, KNN, GBM	196	S, U, W	15	$b_w, d_e, f_{ck}, f_{ys}, A_{sv}, S_v, a/d_e, E_f, \varepsilon_{fu}, f_f, t_f, w_f, s_f, h_f, \alpha_f$
13	Gasser et al. (2023)	ANN	200	S, U, W	13	$b_w, h_b, d_e, h_f, w_f, t_f, s_f, \rho_f, \alpha_f, E_f, f_f, \varepsilon_{fu}, \text{wrapping scheme}$
14	Wang et al. (2023)	ANN, XGB, RF, CatB, LGBM, AdaB	315	S, U, W	8	$a/d_e, \rho_s, h_f, \rho_f, RM, FM, CS, \alpha_f$
15	Rahman et al. (2023)	LR, RR, LASSO, KNN, SVR, DT, RF, XGB, AdaB, CatB	584	S, U, W	12	$b_w, d_e, a/d_e, h_f, E_f, \varepsilon_{fu}, A_{sv}, f_{ck}, t_f, f_f, \text{type of wrapping scheme, type of fiber}$
16	Rahman and Muntasir Billah (2024)	RF, XGB, AdaB, CatB	302	S, U, W	12	$b_w, d_e, a/d_e, h_f, E_f, \varepsilon_{fu}, A_{sv}, f_{ck}, t_f, f_f, \text{type of wrapping scheme, type of fiber}$

Désignations : GA = Algorithme génétique; MGP = Programmation génétique multigène ; RFE = Élimination récursive des caractéristiques ; NID = Diagramme d'interprétation neuronale ; LR = Régression linéaire, RR = Régression Ridge, Lasso = Régression Lasso ; KNN = K plus proches voisins ; b_w = largeur de la poutre ; h_b = hauteur de la poutre ; ρ_f = ratio du renforcement transversal PRF ; α_f = angle d'inclinaison du PRF ; E_f = module d'élasticité du PRF ; ρ_{sl} = ratio du renforcement longitudinal en acier ; A_{90} = surface de section transversale de l'acier de cisaillement par unité de longueur ; f_{ys} = contrainte de plastification de calcul de l'acier de cisaillement ; f_{ck} = résistance à la compression du béton ; a/d_e = rapport portée de cisaillement sur hauteur utile ; d_e = hauteur utile de la poutre ; ε_{fu} = déformation ultime du PRF ; w_f/s_f = ratio largeur-espacement du PRF ; t_f = épaisseur du PRF ; d_f = profondeur effective du PRF ; A_v/S_v = ratio surface des étriers sur espacement ; h_f = hauteur de la bande de PRF ; B_f = largeur du PRF ; f_f = résistance à la traction du PRF ; a = portée de cisaillement ; A_{sv} = ratio de renforcement transversal interne ; w_f = largeur des bandes de PRF ; s_f = espacement centre à centre des bandes de PRF ; n = nombre de couches de PRF ; f_{yt} = contrainte de plastification de calcul de l'acier longitudinal ; S_v = espacement des étriers ; ρ_s = ratio de l'acier de cisaillement ; RM = méthode de renforcement ; FM = mode de rupture ; CS = section transversale de la poutre en béton armé.

Les recherches ultérieures ont exploré l'application de divers algorithmes d'apprentissage automatique à ce défi. [Naderpour and Alavi \(2017\)](#) ont introduit un système d'ANFIS pour estimer la contribution au cisaillement du PRF collé extérieurement dans les poutres en BA, démontrant une performance supérieure par rapport aux équations directrices existantes. [Kar et al. \(2020\)](#) et [Kar and Biswal \(2020\)](#) ont employé des modèles ANFIS pour prédire respectivement la contribution au cisaillement du PRF collé extérieurement dans des poutres en BA enveloppées (W) et forme de U, mettant en évidence la capacité de l'ANFIS à considérer l'effet combiné de multiples paramètres d'entrée. [Kamgar et al. \(2020a\)](#) ont utilisé la programmation génétique multigène (MGP) pour formuler une nouvelle équation de prédiction de la capacité au cisaillement des poutres en BA renforcées de PRF collé extérieurement, surpassant les méthodes conventionnelles en termes de précision. [Abuodeh et al. \(2020\)](#) ont appliqué des réseaux neuronaux à rétropropagation résilients (RBPNN) conjointement avec l'élimination récursive des caractéristiques (RFE) et les diagrammes d'interprétation neuronale (NID) pour identifier les paramètres critiques influençant la capacité au cisaillement des poutres en BA renforcées de PRF collé extérieurement sur les côtés (S) et en forme de U. [Karzad et al. \(2022\)](#) ont développé un modèle d'ANN pour tenir compte de l'interaction défavorable potentielle entre le PRF collé extérieurement et les étriers en acier, une considération importante dans la conception et l'évaluation de ces systèmes structurels. [Gasser et al. \(2023\)](#) ont proposé un modèle de RNA pour estimer la résistance au cisaillement des poutres en BA renforcées de PRF collé extérieurement, considérant divers paramètres tels que la géométrie des éléments, les détails et configurations de renforcement, démontrant une meilleure concordance avec les données expérimentales par rapport aux modèles précédents. [Anvari et al. \(2023\)](#) ont utilisé la programmation d'expression génique

(GEP) pour développer des modèles basés sur les données prédisant la résistance totale au cisaillement des poutres en BA renforcées de feuilles de PRF collées extérieurement, révélant l'influence significative de la profondeur de la poutre en BA et de la profondeur efficace des feuilles de PRF collées extérieurement sur la résistance totale au cisaillement.

Les contributions plus récentes se sont concentrées sur l'évaluation et la comparaison des performances de divers algorithmes d'apprentissage automatique pour cette tâche. [Ezami et al. \(2023\)](#) ont mené une évaluation complète d'algorithmes tels que XGB, RF, AdaB, ElasticNet, KNN et GBM, identifiant XGB comme le meilleur performant en termes de précision et de fiabilité. [Wang et al. \(2023\)](#) ont employé des techniques d'apprentissage automatique interprétables, notamment les ANNs, XGB, RF, CatB, LGBM et AdaB, pour prédire la contribution du PRF collé extérieurement à la résistance au cisaillement des poutres en BA avec armature de cisaillement interne. Leur recherche a dérivé une équation explicite basée sur le modèle XGB, combinant la précision de l'apprentissage automatique avec une signification physique. [Rahman et al. \(2023\)](#) et [Rahman and Muntasir Billah \(2024\)](#) ont développé de multiples modèles d'apprentissage automatique, englobant LR, RR, LASSO, KNN, SVR, DT, RF, XGB, AdaB et CatB, pour prédire la résistance au cisaillement des poutres en BA renforcées par PRF collé extérieurement. Leurs études ont démontré la performance supérieure des modèles d'apprentissage ensemblistes, en particulier RF, CatB et XGB, dans l'estimation de la capacité au cisaillement des poutres rectangulaires et en T, dépassant les modèles existants basés sur la mécanique. De plus, ils ont utilisé les explications additives de Shapley (SHAP) pour interpréter l'importance des caractéristiques d'entrée, révélant l'influence significative de paramètres tels que la profondeur efficace et la hauteur des couches de PRF collées extérieurement.

Les études examinées illustrent collectivement le potentiel des techniques d'apprentissage automatique pour améliorer la précision et la fiabilité des prédictions de la résistance au cisaillement des éléments en béton renforcés par PRF collé extérieurement. Un large éventail d'approches d'apprentissage automatique, notamment les ANNs, les GA, l'ANFIS, la MGP, la SVR, les DTs et les modèles d'apprentissage ensemblistes, ont été employés avec succès, dépassant systématiquement les équations empiriques traditionnelles et les directives de conception. Cela reflète l'évolution continue et l'exploration de différentes approches d'apprentissage automatique pour mieux saisir le comportement complexe au cisaillement des poutres en béton renforcées par PRF collé extérieurement.

Alors que les premières études se concentraient principalement sur les configurations de PRF en forme de U et enveloppées (W), les recherches récentes se sont étendues pour incorporer les schémas de collage latéral (S), fournissant une représentation plus complète des stratégies de renforcement pratiques. La diversité des tailles des ensembles de données, allant de relativement petites (par exemple, 46 points de données dans [Perera et al. \(2010a\)](#)) à des ensembles de données plus importants dépassant 500 points de données (par exemple, [Anvari et al., 2023](#); [Rahman et al., 2023](#)), souligne les efforts continus pour améliorer la généralisabilité et la robustesse des modèles, malgré les défis inhérents à l'acquisition des données et aux exigences de calcul. Le nombre de paramètres d'entrée pris en compte dans ces modèles d'apprentissage automatique varie considérablement, de six à seize, reflétant la complexité du comportement au cisaillement et les compromis entre la capture d'interactions complexes et le risque de sur-apprentissage, en particulier pour les ensembles de données plus petits. Bien que les facteurs fondamentaux tels que la géométrie des poutres, la résistance du béton, l'armature de cisaillement en acier et les détails du renforcement en PRF soient systématiquement inclus, les chercheurs ont également exploré l'incorporation des paramètres supplémentaires, tels que les détails de l'armature longitudinale en acier, les types d'étriers, les types de fibres et les motifs de distribution du PRF, pouvant potentiellement améliorer les capacités prédictives des modèles d'apprentissage automatique.

3.5 Discussion et recommandations

La revue exhaustive des techniques d'apprentissage automatique pour prédire la résistance au cisaillement des poutres en BA renforcés de PRF collés extérieurement a mis en évidence les progrès significatifs réalisés dans ce domaine, ainsi que les défis et les opportunités pour de nouvelles recherches et développements.

Premièrement, les études ont systématiquement démontré les capacités prédictives supérieures des modèles d'apprentissage machine par rapport aux équations empiriques conventionnelles et aux directives de conception. En exploitant des algorithmes avancés et la puissance de calcul, les techniques d'apprentissage automatique peuvent efficacement capturer les non-linéarités complexes et les interactions entre les multiples paramètres influents, résultant en une précision et une fiabilité accrue dans les prédictions de résistance, où les modèles d'apprentissage automatique ont constamment dépassé les modèles traditionnels orientés conception.

Deuxièmement, la diversité des techniques d'apprentissage automatique explorées dans ce domaine est remarquable, reflétant l'évolution continue et l'exploration de différentes approches pour mieux saisir le comportement complexe des poutres en BA renforcés par PRF collés extérieurement. Des premières applications des ANNs et des GA aux avancées récentes des modèles d'apprentissage ensemblistes (par exemple, les forêts aléatoires, le boosting de gradient), la programmation génétique multigène (MGP) et les modèles hybrides, le domaine a été témoin d'une expansion et d'un raffinement continus des méthodologies d'apprentissage automatique adaptées aux tâches de prédiction de résistance.

Cependant, plusieurs défis restent à relever pour faciliter l'adoption pratique et la mise en œuvre généralisée des techniques d'apprentissage automatique dans la conception et l'évaluation des structures en BA renforcées par PRF.

- ***Disponibilité et qualité des données*** : Le développement des modèles d'apprentissage automatique précis et fiables dépend de la disponibilité de bases de données expérimentales complètes et diversifiées, englobant un large éventail de propriétés des matériaux, de configurations géométriques, de conditions de chargement et de modes de rupture. Des ensembles de données plus importants et plus représentatifs sont essentiels pour l'entraînement et la validation des modèles d'apprentissage automatique, assurant leur généralisabilité et leur robustesse. Des efforts devraient être déployés pour standardiser les pratiques de collecte et de documentation des données, permettant le partage collaboratif des données et le développement des modèles entre groupes et institutions de recherche.
- ***Interprétabilité et cohérence physique des modèles*** : Bien que les approches d'apprentissage automatique basées sur les données aient démontré des performances prédictives supérieures, les professionnels cherchent souvent à combler le fossé entre ces solutions et les approches mécanistes traditionnelles. Améliorer l'interprétabilité et la cohérence physique des modèles d'apprentissage automatique est crucial pour leur acceptation et leur intégration dans les cadres de conception existants. Des efforts devraient être déployés pour développer des modèles d'apprentissage automatique interprétables capables de fournir des informations sur les mécanismes physiques sous-jacents, potentiellement grâce à des approches hybrides combinant des techniques basées sur les données et des modèles mécanistes ou en incorporant des contraintes

physiques et des connaissances du domaine dans les algorithmes d'apprentissage automatique.

- ***Quantification de l'incertitude et évaluation de la fiabilité*** : L'évaluation de la fiabilité et la quantification de l'incertitude des modèles d'apprentissage automatique dans le contexte des prédictions de résistance pour les structures en BA renforcées par PRF nécessitent de nouvelles recherches. Les méthodologies de quantification des incertitudes des modèles, de prise en compte des valeurs aberrantes ou anomalies dans les données, et d'établissement d'intervalles de confiance sont cruciales pour une mise en œuvre pratique et l'acceptation par la communauté de l'ingénierie. Des techniques telles que les réseaux de neurones bayésiens, la prédiction conforme et les méthodes ensemblistes peuvent être explorées pour améliorer la fiabilité et la confiance dans les prédictions de résistance basées sur l'apprentissage automatique.
- ***Transfert d'apprentissage et adaptation de domaine*** : Dans les scénarios où la disponibilité des données est limitée ou restreinte à des domaines spécifiques, les techniques de transfert d'apprentissage et d'adaptation de domaine peuvent être exploitées pour transférer les connaissances de domaines ou d'ensembles de données connexes, réduisant potentiellement les besoins en données pour développer des modèles d'apprentissage automatique précis. Ces techniques peuvent faciliter le développement efficace des modèles d'apprentissage automatique pour de nouveaux systèmes de matériaux, configurations géométriques ou conditions de chargement, en tirant parti des connaissances des modèles précédemment entraînés ou des domaines connexes.
- ***Intégration avec les cadres d'analyse structurelle et de conception*** : En fin de compte, le véritable potentiel des modèles de prédiction de résistance basés sur l'apprentissage automatique peut se concrétiser grâce à leur intégration transparente dans les cadres d'analyse structurelle et de conception. En couplant ces modèles basés sur les données avec l'analyse par éléments finis, les méthodologies de conception basées sur la performance, et les systèmes d'aide à la décision, les ingénieurs pourront exploiter les forces des techniques d'apprentissage machine pour optimiser la conception et l'évaluation des structures en BA renforcées par PRF, en considérant de multiples critères de performance et contraintes de conception.

En relevant ces défis et en exploitant les synergies entre les techniques d'apprentissage automatique basées sur les données et les principes traditionnels de l'ingénierie, le domaine du

génie structural peut libérer le plein potentiel de ces approches de modélisation avancées. Des efforts collaboratifs entre les chercheurs, les praticiens et les parties prenantes de l'industrie sont essentiels pour surmonter les obstacles restants et ouvrir la voie à des solutions plus efficaces, fiables et économiques pour concevoir et évaluer les structures en BA renforcées par PRF.

3.6 Conclusion

L'application des techniques d'apprentissage automatique a révolutionné l'approche de la prédiction de la résistance au cisaillement des poutres en BA renforcées par PRF collés à l'extérieur. Cette revue exhaustive a mis en lumière le potentiel considérable des algorithmes d'apprentissage automatique pour capturer les relations non linéaires complexes et les interactions entre les multiples paramètres influents, dépassant systématiquement les modèles empiriques conventionnels et les directives de conception en termes de précision.

Diverses techniques telles que les réseaux de neurones artificiels, les machines à vecteurs de support, la programmation génétique et génétique multigène, les systèmes d'inférence neuro-flous adaptatifs et les modèles d'apprentissage ensemble ont tous démontré leur capacité à offrir des prédictions supérieures de la résistance au cisaillement. Cette diversité reflète l'évolution dynamique du domaine, explorant constamment de nouvelles approches afin d'améliorer la compréhension du comportement complexe de ces systèmes structurels.

Malgré les progrès significatifs réalisés dans ce domaine, plusieurs défis restent à relever pour faciliter l'adoption pratique et la mise en œuvre généralisée des techniques d'apprentissage automatique dans la conception et l'évaluation des éléments en BA renforcées par PRF. Ces défis comprennent l'assurance de la disponibilité et de la qualité des données, l'amélioration de l'interprétabilité et de la cohérence physique des modèles, la quantification des incertitudes et l'évaluation de la fiabilité, l'exploitation des techniques d'apprentissage par transfert et d'adaptation de domaine, et l'intégration harmonieuse des modèles de prédiction de résistance basés sur l'apprentissage automatique avec les cadres d'analyse et de conception structurelle.

Des efforts de collaboration entre les chercheurs, les praticiens et les parties prenantes de l'industrie sont cruciaux pour surmonter ces obstacles restants. En combinant les forces des techniques d'apprentissage automatique basées sur les données et des principes d'ingénierie traditionnels ainsi que des connaissances de domaine, le domaine de l'ingénierie des structures peut libérer tout le potentiel de ces approches de modélisation avancées, ouvrant la voie à des

solutions plus efficaces, fiables et économiques dans la conception et l'évaluation des structures en BA renforcées par PRF.

Alors que l'adoption des composites FRP continue de se développer dans l'industrie de la construction, le développement des modèles de prédiction de résistance précis et fiables jouera un rôle essentiel dans la mise en œuvre sûre et rentable de ces matériaux innovants. La fusion des méthodologies d'apprentissage automatique et de l'expertise en génie civil recèle un immense potentiel pour faire progresser l'état de l'art dans ce domaine, contribuant ainsi à la réalisation des structures en béton plus durables, résistantes et performantes.

CHAPITRE 04

Approches et méthodologies.

4.1 Introduction

Le renforcement des structures en BA par collage extérieur de matériaux composites en PRF est devenu de plus en plus populaire ces dernières années, s'imposant comme une technique prometteuse pour améliorer la durabilité, la résistance et la performance des infrastructures vieillissantes. Cependant, malgré les avantages reconnus de cette approche, la prédiction précise de la contribution des PRF à la résistance au cisaillement des poutres renforcées reste un défi majeur. Les modèles empiriques et semi-empiriques actuels, bien que fournissant des estimations initiales, font face à des limitations inhérentes en termes de précision et de capacité de généralisation à différentes configurations structurelles complexes.

Face à ces défis, l'application des techniques d'apprentissage automatique émerge comme une alternative prometteuse, offrant le potentiel de capturer et de modéliser efficacement les relations complexes entre les paramètres d'entrée et la réponse structurelle désirée. Les algorithmes d'apprentissage automatique avancés, tels que les réseaux de neurones profonds et les ensembles d'arbres décisionnels, possèdent une puissante capacité à apprendre directement à partir des données, sans nécessiter d'hypothèses restrictives ou de simplifications inhérentes aux approches conventionnelles.

Ce chapitre présente une méthodologie rigoureuse combinant des techniques d'apprentissage automatique de pointe et des stratégies robustes pour développer des modèles prédictifs précis de la contribution des PRF à la résistance au cisaillement des poutres en BA. Une base de données expérimentale exhaustive, soigneusement raffinée et validée, constitue le fondement de cette étude, assurant une représentation adéquate de la gamme complète de configurations structurelles rencontrées dans les applications d'ingénierie réelles.

Ce chapitre explore en détail les différentes étapes méthodologiques cruciales, allant du pré-traitement rigoureux des données à l'implémentation et à l'optimisation des modèles d'apprentissage automatique. Des algorithmes puissants tels que l'eXtreme Gradient Boosting, les réseaux de neurones profonds et leurs variantes intégrant des contraintes de monotonie sont présentés et discutés. L'adoption d'une stratégie d'ensemble judicieuse vise à capitaliser sur les forces complémentaires de ces modèles individuels, conduisant à des prédictions plus robustes et précises.

Des analyses approfondies mettent en lumière les relations complexes entre les paramètres d'entrée clés et la contribution au cisaillement des PRF, fournissant des informations précieuses pour guider le développement des modèles. L'intégration de ces connaissances

physiques, combinée à des techniques avancées telles que l'optimisation bayésienne des hyperparamètres et la validation croisée, vise à améliorer la fiabilité et la généralisation des modèles proposés.

Enfin, une suite complète de métriques de performance statistique est employée pour évaluer et comparer de manière approfondie les capacités prédictives des différents modèles développés. Cette évaluation multidimensionnelle fournit des informations précieuses sur les forces et les faiblesses relatives des modèles, permettant d'identifier les approches les plus prometteuses pour des applications pratiques.

4.2 Algorithmes d'apprentissage automatique avancés

4.2.1 eXtreme Gradient Boosting (XGBoost)

eXtreme Gradient Boosting (XGBoost) (Chen and Guestrin, 2016) est une implémentation hautement efficace et évolutive du cadre de gradient boosting, qui a gagné une grande popularité dans diverses applications d'apprentissage automatique en raison de ses performances prédictives supérieures et de son efficacité computationnelle. Le gradient boosting est une technique d'apprentissage ensemble qui combine des modèles de prédiction faibles (généralement des arbres de décision) de manière additive pour créer un modèle prédictif puissant et robuste (Friedman, 2001).

L'algorithme XGBoost opère en entraînant de manière itérative un ensemble d'arbres de décision, où chaque nouvel arbre vise à corriger les erreurs commises par l'ensemble précédent. Ce processus itératif est guidé par une fonction de perte qui mesure l'écart entre les valeurs prédites et réelles. L'algorithme optimise cette fonction de perte en calculant les gradients et en les utilisant pour déterminer la direction et l'ampleur des mises à jour pour chaque arbre successif. L'un des principaux avantages de XGBoost est sa capacité à traiter divers types de données, y compris numériques, catégorielles et avec des valeurs manquantes, sans nécessiter un prétraitement approfondi des données. Ceci est réalisé en mettant en œuvre des techniques avancées telles que la recherche de divisions prenant en compte les données éparées, qui gère efficacement les données éparées, et le calcul parallèle structuré par blocs, qui permet une parallélisation et une évolutivité efficaces. Une autre caractéristique importante de XGBoost est sa capacité à incorporer automatiquement des techniques de régularisation, telles que la régularisation L1 et L2, qui pénalisent la complexité du modèle pour éviter le sur-apprentissage et améliorer les capacités de généralisation du modèle (Chen and Guestrin, 2016).

XGBoost a démontré un succès remarquable dans de nombreuses compétitions d'apprentissage automatique et a été largement adopté dans divers domaines, notamment la finance, l'énergie, la modélisation environnementale et les applications en génie des structures (Bakouregui et al., 2021; Feng et al., 2021; Yan et al., 2023).

4.2.2 Réseaux de neurones profonds (DNN)

Les réseaux de neurones profonds (DNN) sont une classe puissante de modèles d'apprentissage automatique inspirés de la structure et du fonctionnement des réseaux neuronaux biologiques dans le cerveau humain (Cao et al., 2016; Rosa, 2016). Les DNN sont un type de réseau de neurones artificiels (ANN) caractérisés par leur profondeur, composés de multiples couches cachées entre les couches d'entrée et de sortie. Cette architecture profonde permet aux DNN d'apprendre des représentations hiérarchiques des données d'entrée, capturant des motifs complexes et des interactions de caractéristiques qui peuvent être difficiles pour les algorithmes d'apprentissage automatique traditionnels (LeCun et al., 2015; Chollet, 2021).

Les blocs de construction fondamentaux des DNN comprennent des nœuds interconnectés, appelés neurones ou unités, organisés en couches. Ces connexions entre les neurones dans les couches adjacentes ont des poids numériques associés, qui sont ajustés de manière itérative pendant le processus d'entraînement pour optimiser les performances du réseau. La structure de base d'un DNN consiste en une couche d'entrée, de multiples couches cachées et une couche de sortie. La couche d'entrée reçoit les données d'entrée, qui sont ensuite propagées à travers le réseau. À chaque neurone dans les couches cachées, une somme pondérée des entrées de la couche précédente est calculée, et une fonction d'activation non linéaire, telle que l'unité linéaire rectifiée (ReLU), la sigmoïde ou la tangente hyperbolique (tanh), est appliquée pour introduire la non-linéarité. Ces transformations non linéaires par les fonctions d'activation permettent au réseau de modéliser des mappages complexes et non linéaires entre les variables d'entrée et de sortie (Goodfellow et al., 2016).

Le processus d'entraînement d'un DNN implique l'ajustement des poids de connexion et des biais pour minimiser l'écart entre les sorties prédites et réelles. Ceci est généralement réalisé à l'aide d'un algorithme d'optimisation, tel que la rétropropagation, qui calcule les gradients de la fonction d'erreur par rapport aux poids et propage ces gradients en arrière à travers le réseau, mettant à jour itérativement les poids pour minimiser l'erreur (Haykin, 2009). Des techniques de régularisation, telles que le dropout (Srivastava et al., 2014), l'arrêt précoce et la

décroissance des poids, sont souvent employées pour prévenir le sur-apprentissage et améliorer la capacité de généralisation des DNN.

Malgré leurs puissantes capacités de modélisation, les DNN peuvent être computationnellement intensifs à entraîner, en particulier pour les grands ensembles de données ou les architectures complexes. De plus, l'interprétabilité des DNN peut être difficile, car ils opèrent souvent comme des modèles "boîtes noires", rendant difficile la compréhension des relations spécifiques apprises par le réseau et des contributions des caractéristiques d'entrée individuelles aux prédictions finales.

4.2.3 Renforcer les contraintes de monotonie dans les modèles d'apprentissage automatique

Dans de nombreuses applications du monde réel, en particulier dans le domaine de l'ingénierie, les relations entre les variables d'entrée et la variable cible sont souvent régies par des principes physiques inhérents ou des contraintes spécifiques au domaine. Une telle contrainte est la monotonie, qui fait référence à la propriété d'une fonction où une augmentation (ou une diminution) de la variable d'entrée entraîne un changement correspondant non décroissant (ou non croissant) de la variable de sortie. Mathématiquement, une fonction $f(x)$ est dite croissante monotone si pour deux valeurs d'entrée x_1 et x_2 telles que $x_1 < x_2$, les valeurs de sortie correspondantes satisfont $f(x_1) \leq f(x_2)$. À l'inverse, la fonction est décroissante monotone si $f(x_1) \geq f(x_2)$ pour tout $x_1 < x_2$. Par exemple, dans un scénario où l'objectif est de prédire la valeur d'une voiture d'occasion, le nombre de kilomètres parcourus est une caractéristique importante. Intuitivement, nous nous attendons à ce que la valeur de la voiture d'occasion n'augmente jamais lorsque les kilomètres augmentent, en supposant que toutes les autres valeurs de caractéristiques restent constantes. Cependant, un modèle entraîné sur un nombre limité d'échantillons bruités peut ne pas adhérer à ces connaissances préalables (Gupta et al., 2015; Gupta et al., 2019).

L'incorporation de contraintes de monotonie dans les modèles d'apprentissage automatique offre plusieurs avantages. Premièrement, elle permet d'intégrer les connaissances et l'expertise du domaine dans le modèle, réduisant le risque d'apprendre des relations incohérentes ou contre-intuitives à partir des données. Ceci est particulièrement important dans les applications critiques pour la sécurité, comme le génie des structures, où les modèles doivent adhérer à des principes physiques et des considérations théoriques bien établis. Deuxièmement, les contraintes de monotonie peuvent améliorer les performances du

modèle et ses capacités de généralisation en fournissant un biais inductif utile, en améliorant l'efficacité des données et en permettant des prédictions plus puissantes avec des ensembles d'entraînement plus petits (Dugas et al., 2000; Mitchell, 1980; Veličković, 2019). De plus, la monotonie favorise la transparence et l'interprétabilité, qui sont cruciales pour établir la confiance et assurer des décisions de conception fiables dans les domaines de l'ingénierie (Gupta et al., 2015).

Plusieurs algorithmes d'apprentissage automatique, comme XGBoost, prennent en charge les contraintes de monotonie de manière inhérente grâce à leur paramètre `monotone_constraints`. Cette fonctionnalité permet à l'utilisateur de spécifier les relations monotones entre les attributs d'entrée et la variable cible pendant le processus d'entraînement du modèle, assurant ainsi que les arbres de décision appris présentent les relations monotones souhaitées. Pour les réseaux de neurones, connus pour leur flexibilité dans l'approximation de fonctions non linéaires complexes, l'application de la monotonie peut être plus difficile. Bien que les premières approches, comme la contrainte des signes des poids et l'utilisation de fonctions d'activation monotones (Archer and Wang, 1993), étaient limitées aux fonctions convexes, des techniques plus avancées comme les réseaux min-max (Daniels and Velikova, 2010), les réseaux de treillis profonds (You et al., 2017) et les approches basées sur la régularisation (Gupta et al., 2019; Sivaraman et al., 2020; Liu et al., 2020) ont été développées. Cependant, celles-ci nécessitent souvent des modifications architecturales, des paramètres supplémentaires ou des fonctions de perte personnalisées, compliquant le développement et l'entraînement des modèles. Pour surmonter ces défis, une nouvelle approche appelée Réseau de Neurones Monotone Contraint (CMNN) a été proposée par Runje and Shankaranarayana (2022). CMNN offre une solution simple et élégante pour combler ce fossé en employant des contraintes de poids similaires aux approches antérieures. L'idée clé est de construire deux fonctions d'activation supplémentaires à partir d'une fonction d'activation monotone typique comme ReLU ou SELU et de les utiliser sur des groupes de neurones séparés dans une couche. Une fonction est concave et bornée supérieurement, tandis que l'autre est saturée. Cela permet d'approximer à la fois les fonctions convexes et non convexes tout en préservant les contraintes de monotonie. Les neurones concaves approximent les relations non monotones et les neurones saturés assurent l'approximation théorique d'universalité - la propriété mathématique qu'un modèle est capable d'approximer n'importe quelle fonction continue sur un domaine borné jusqu'à un niveau de précision arbitrairement élevé, avec suffisamment de paramètres et de données d'entraînement.

CMNN introduit un vecteur indicateur de monotonicité t pour encoder les contraintes entrée-sortie attendues en fonction de l'expertise du domaine. Les éléments de t sont définis à 1 pour les variables qui doivent être croissantes monotones par rapport à la sortie, -1 pour les variables décroissantes monotones et 0 pour les variables non monotones. Les couches denses monotones résultantes peuvent directement remplacer les couches denses standard dans les réseaux de neurones tout en garantissant la monotonicité par construction. De plus, aucun paramètre supplémentaire n'est nécessaire par rapport à un réseau non contraint pour la même tâche, et la procédure d'entraînement reste inchangée - aucune fonction de perte ou contrainte spéciale n'est requise. Par exemple, l'architecture du perceptron multicouche largement utilisée peut-être facilement adaptée en employant une couche dense monotone pour le vecteur d'entrée configuré sur la base de t (Fig. 4.1). Les couches cachées suivantes appliqueraient des blocs denses monotones qui propagent les contraintes des entrées vers les sorties éventuelles en fixant $t=1$. Enfin, la fonction d'activation de la couche de sortie (linéaire, sigmoïde, softmax, etc.) peut être choisie de manière appropriée pour le type de tâche - régression, classification ou problème multi-tâche. Cette construction modulaire simplifie considérablement l'application des connaissances monotones du domaine des entrées vers les sorties.

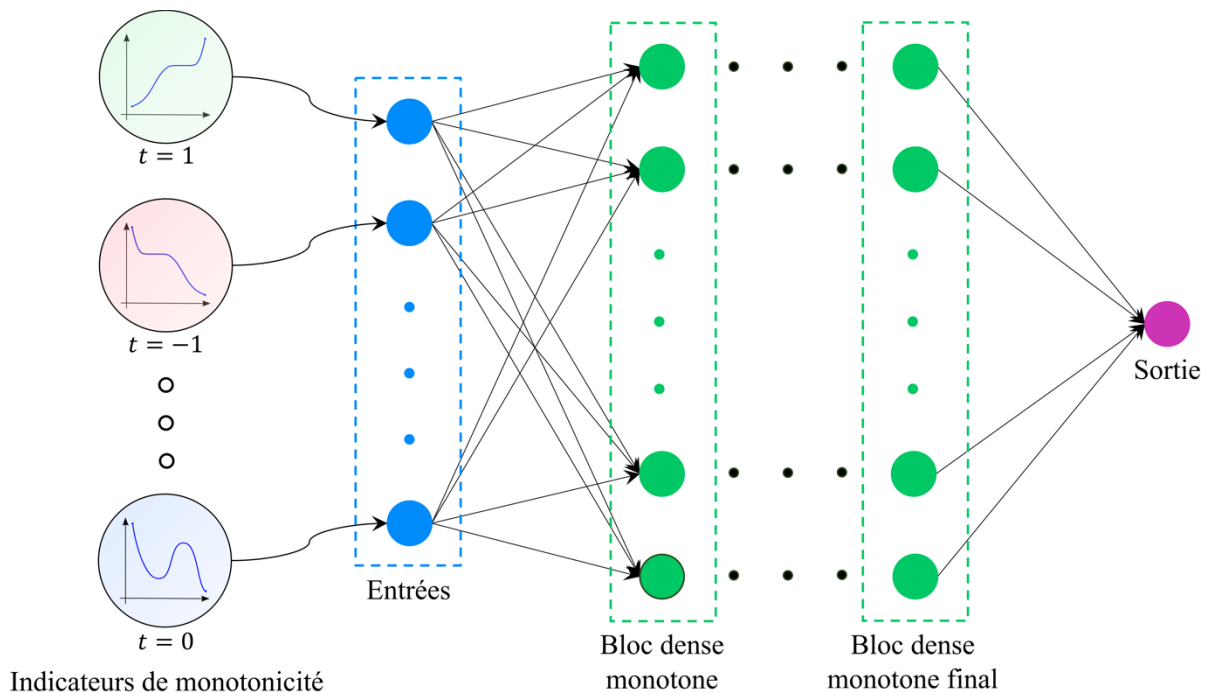


Fig. 4.1 — Architecture d'un dense CMNN modèle.

4.2.4 Modèles d'ensemble

L'apprentissage par ensemble est un paradigme puissant d'apprentissage automatique qui combine les prédictions de plusieurs modèles individuels pour améliorer les performances prédictives globales et réduire la variance (Caruana et al., 2004). Cette approche exploite les forces de divers algorithmes d'apprentissage tout en atténuant leurs faiblesses, résultant en un modèle prédictif plus robuste et précis. Les méthodes d'ensemble offrent plusieurs avantages, notamment la réduction du risque de sélectionner un modèle sous-optimal, une meilleure efficacité computationnelle dans le traitement des solutions localement optimales, et des capacités de représentation améliorées, car la fonction sous-jacente réelle peut ne pas être adéquatement représentée par un seul modèle ou hypothèse (Dietterich, 2000; Asteris et al., 2021).

Dans cette étude, nous avons employé une stratégie d'ensemble pour tirer parti des forces complémentaires des modèles de base discutés précédemment : XGBoost (XGB), réseau de neurones profond (DNN), XGBoost monotone (MXGB) et réseau de neurones monotone contraint (CMNN). Deux modèles d'ensemble ont été construits : le modèle d'ensemble (ENSM) et le modèle d'ensemble monotone (MENSM).

Le modèle ENSM combine les prédictions de XGB et DNN à travers une simple approche de moyenne : $ENSM = 0,5 \times XGB + 0,5 \times DNN$. De même, le modèle MENSM intègre les prédictions de MXGB et CMNN en utilisant une simple moyenne : $MENSM = 0,5 \times MXGB + 0,5 \times CMNN$.

L'approche d'ensemble vise à capitaliser sur les forces diverses des modèles de base individuels tout en compensant leurs faiblesses respectives, réduisant ainsi l'impact des biais et des variances des modèles individuels, conduisant à des prédictions plus robustes et précises. La prémisse sous-jacente est que différentes méthodes d'apprentissage automatique peuvent exceller dans différents scénarios, et une méthode combinant plusieurs modèles diversifiés devrait produire de meilleurs résultats. Bien que les modèles d'ensemble offrent une approche pratique pour combiner plusieurs apprenants de base, leur efficacité dépend de la diversité et de la qualité des modèles constituants, ainsi que de l'adéquation de la stratégie d'ensemble pour le domaine de problème spécifique (Opitz and Maclin, 1999).

La Fig. 4.2 présente un organigramme exhaustif qui illustre visuellement le flux de travail d'implémentation pour les six modèles développés dans cette étude. Cette représentation schématique fournit un aperçu clair des étapes séquentielles impliquées dans l'exécution et le

fonctionnement de ces modèles, facilitant une compréhension simple des processus sous-jacents.

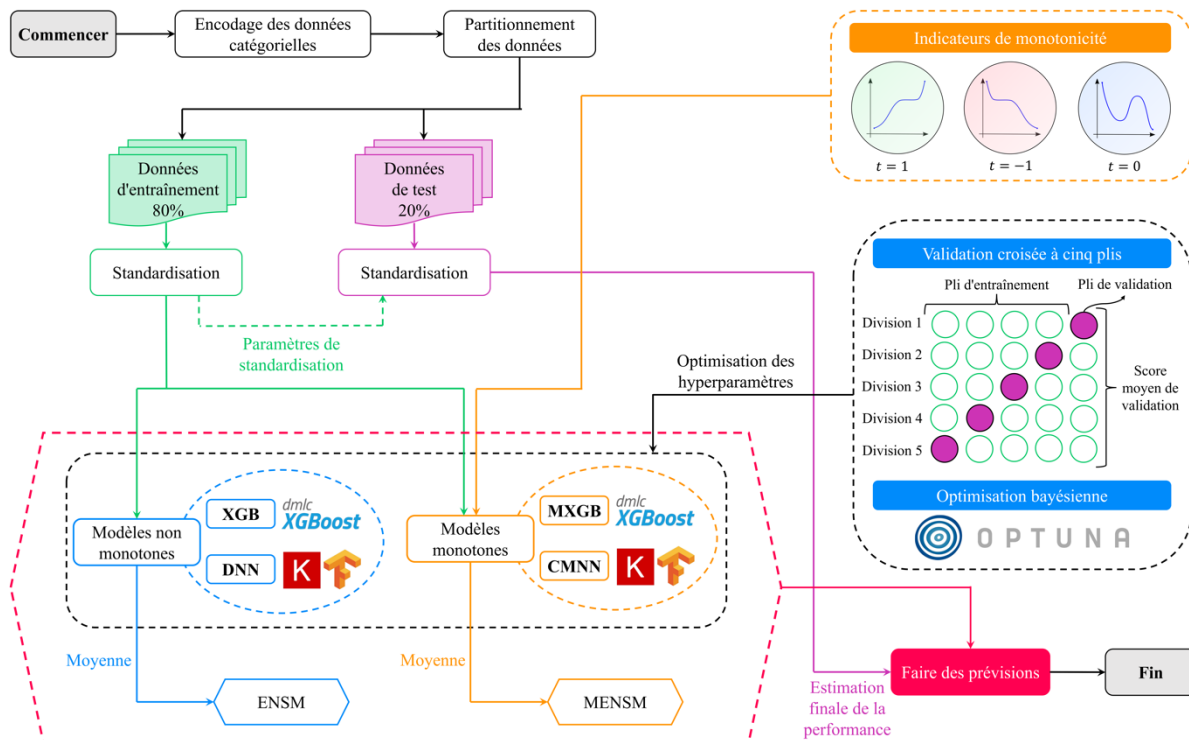


Fig. 4.2 — Organigramme du processus de mise en œuvre des modèles d'apprentissage automatique.

4.3 Description de la base de données

4.3.1 Importance de la qualité et de l'exhaustivité des données d'entraînement

La qualité et l'exhaustivité de l'ensemble de données d'entraînement sont des facteurs cruciaux mais parfois négligés dans le développement de modèles d'apprentissage automatique précis. Bien que les méthodes computationnelles et les algorithmes soient indubitablement des composantes essentielles, l'ensemble de données lui-même doit représenter adéquatement le domaine complet du problème pour permettre des simulations réalistes et des prédictions précises. Pour qu'un ensemble de données soit considéré comme suffisant, il doit non seulement posséder une quantité substantielle de données, mais aussi une grande variété de combinaisons entre toutes les variables d'entrée pertinentes.

Cette couverture exhaustive est particulièrement importante pour les ensembles de données expérimentales, car les valeurs mesurées dans de telles collections peuvent présenter une grande variabilité due à la fois à la variabilité inhérente entre les expériences et aux incertitudes épistémiques intrinsèques aux tests physiques. Les données expérimentales sont

souvent sujettes à diverses sources d'erreur, telles que les imprécisions de mesure, les facteurs environnementaux et les erreurs humaines, qui peuvent introduire des incohérences et des valeurs aberrantes. En conséquence, un ensemble de données fiable avec un minimum d'incohérences et d'erreurs est essentiel pour dériver des modèles d'apprentissage automatique applicables à des scénarios d'ingénierie réels avec un haut niveau de confiance dans leurs capacités prédictives.

Un ensemble de données diversifié et de haute qualité, couvrant l'intégralité du domaine d'intérêt, est crucial pour améliorer la capacité du modèle à généraliser au-delà de la distribution des données d'entraînement. Lorsqu'un modèle est entraîné sur un ensemble de données complet couvrant un large éventail de scénarios, il est mieux équipé pour gérer de nouvelles conditions inédites et améliorer ses performances dans des applications pratiques. Ceci est particulièrement important dans les applications scientifiques et d'ingénierie, où les modèles doivent souvent faire des prédictions précises dans des environnements divers et complexes.

De plus, un ensemble de données exhaustif permet une exploration plus approfondie des relations sous-jacentes entre les variables d'entrée et la sortie cible. En capturant un large éventail de combinaisons de variables, l'ensemble de données permet au modèle d'apprentissage automatique de mieux comprendre les motifs complexes et les interactions présents dans les données. Cela peut à son tour conduire à des modèles plus robustes et interprétables, essentiels pour la compréhension scientifique et les processus décisionnels.

En outre, un ensemble de données bien organisé et diversifié peut aider à atténuer le risque de sur-apprentissage, un écueil courant dans la modélisation d'apprentissage automatique. Le sur-apprentissage se produit lorsqu'un modèle mémorise trop étroitement les données d'entraînement, ce qui se traduit par de mauvaises performances de généralisation sur de nouvelles données inédites. En s'entraînant sur un ensemble de données complet couvrant un large éventail de scénarios, le modèle est moins susceptible de se fixer sur des motifs ou du bruit spécifiques présents dans les données d'entraînement, réduisant ainsi le risque de sur-apprentissage et améliorant sa capacité à généraliser à de nouvelles instances.

En résumé, la qualité et l'exhaustivité de l'ensemble de données d'entraînement sont des facteurs cruciaux qui ne doivent pas être négligés dans le développement des modèles d'apprentissage automatique précis. Un ensemble de données fiable, diversifié et bien organisé est essentiel pour permettre des simulations réalistes, améliorer la généralisation des

modèles, atténuer le sur-apprentissage et, en fin de compte, atteindre des capacités prédictives élevées dans des scénarios d'ingénierie réels. Investir des efforts dans l'organisation et l'expansion de l'ensemble de données d'entraînement peut rapporter des dividendes importants en termes de performances, d'interprétabilité et d'applicabilité pratique des modèles.

4.3.2 Présentation de l'ensemble de données original

Cette étude utilise la base de données des poutres en BA renforcées par collage extérieur des matériaux composite en PRF, une ressource méticuleusement compilée et exhaustive développée par [Kotynia et al. \(2021\)](#) et [Oller et al. \(2021\)](#). La base de données d'origine représente un effort considérable dans la collecte et la consolidation des données expérimentales provenant de 81 programmes de recherche distincts, comprenant un total de 555 spécimens de poutres en BA renforcées avec des composites en PRF collés extérieurement et soumises à une rupture par cisaillement. Cette base de données comprend les données d'essai préparées par l'Université de Minho dans leur base de données Dabasum disponible et d'autres bases de données publiées dans la littérature scientifique ([Sas et al., 2009](#); [Perera et al., 2009](#); [Bousselham and Chaallal, 2009](#); [Bukhari et al., 2010](#); [Colotti and Swamy, 2011](#); [Pellegrino and Vasic, 2013](#); [Rousakis et al., 2016](#)). Bien que certaines des données appartiennent à des bases de données existantes, toutes les données incluses dans cette base de données ont été préalablement vérifiées par les auteurs par rapport à la source d'origine. Cette vaste collection constitue une base précieuse pour étudier le comportement et les performances des poutres en BA renforcées par PRF sous des conditions de chargement de cisaillement.

Plus de poutres (354, 64% de toutes les poutres) avaient une section transversale rectangulaire (R), tandis que 201 poutres (36%) avaient une section en T (T). Le paramètre le plus important affectant la résistance au cisaillement est l'élancement au cisaillement, connu sous le nom de rapport portée de cisaillement sur la profondeur (a/d). Dans la base de données, a/d variait entre 1,3 et 5,2. Il est bien connu que $a/d < 2,5$ régit l'effet d'arche dans les poutres en BA. Un certain nombre de poutres avec un rapport portée de cisaillement sur la profondeur ($a/d < 2,5$) était de 99 poutres (18%), tandis que 456 poutres (82%) avaient ($a/d \geq 2,5$), ce qui n'indique pas l'effet d'arche sur la résistance au cisaillement des poutres en BA. Les fibres PRF les plus fréquemment utilisées pour le renforcement au cisaillement étaient les fibres de carbone (PRFC). En termes de schéma statique, presque toutes les poutres étaient simplement appuyées avec une portée simple, tandis que seulement 3 poutres ont été testées comme poutres à double portée.

En ce qui concerne la configuration de renforcement nommée : S, U et W, une division supplémentaire des poutres a été introduite selon les configurations de feuille continue (C) et de feuille / ou de bande distribuée (D). Le plus grand nombre de poutres ont été renforcées avec une configuration en U continue (134 poutres R – 24% et 119 poutres T – 20%) et moins de poutres ont été renforcées par enveloppement (96 poutres R – 17% et 68 poutres T – 12%). La plupart des poutres (89%) ont été renforcées avec des fibres orientées verticalement (90°), 10% des poutres ont été renforcées avec une inclinaison PRF de 45° et seulement 1% ont été renforcées avec une inclinaison de fibres de 60° , 73° et 20° . Les poutres sans armature de cisaillement interne (sans A_{st}) représentaient 249 (45% de toutes les poutres renforcées), le reste 306 poutres (55%) avaient l'armature de cisaillement interne (avec A_{st}).

Pour chaque spécimen de la base de données, un ensemble complet d'informations est fourni, capturant les détails essentiels pertinents pour la configuration expérimentale, les propriétés des matériaux et les résultats observés. Ces informations comprennent :

- Les dimensions géométriques de l'élément poutre (b_t , b_w , h , d , L et a/d) (Fig. 4.1), permettant une caractérisation précise des propriétés transversales et longitudinales.
- La résistance à la compression du béton (f_{ck}), un paramètre essentiel influençant le comportement global et la capacité de la poutre en BA.
- Les détails de l'armature en acier (ρ_{sL} , ϕ_w , s_w , ρ_{sw} et E_s), englobant les taux d'armature longitudinale et transversale, les diamètres des barres, l'espacement et les propriétés des matériaux.
- La configuration et le type de renforcement par PRF, spécifiant l'arrangement et la composition du renforcement PRF collé extérieurement.
- Les caractéristiques de l'armature en PRF (h_f , b_f , t_f , s_f , ρ_f , α_f , f_{fu} , E_f et ε_{fu}) (Fig. 4.3), incluant les dimensions, l'espacement, le taux d'armature, l'angle d'inclinaison, la résistance ultime à la traction, le module d'élasticité et la déformation ultime.
- Les modes de rupture observés, fournissant des informations sur les mécanismes de rupture gouvernants et le comportement sous chargement de cisaillement.
- Les forces de cisaillement ultimes des poutres renforcées et de référence ($V_{u, str}$, $V_{u, unstr}$), quantifiant respectivement la capacité au cisaillement des spécimens renforcés et non renforcés.
- La contribution au cisaillement du PRF (V_f), représentant la capacité de cisaillement supplémentaire apportée par le renforcement externe en PRF.

- L'efficacité du renforcement (η), une mesure de l'efficacité du renforcement en PRF dans l'amélioration de la capacité au cisaillement.




Fig. 4.3 — Représentation de la signification physique des variables.

Cette compilation exhaustive de données expérimentales provenant de divers programmes de recherche dans le monde entier assure un ensemble de données diversifié et représentatif, capturant une large gamme de géométries de poutres, de propriétés des matériaux, de configurations de renforcement et de conditions de chargement. Un tel ensemble de données diversifié est essentiel pour développer des modèles d'apprentissage automatique fiables et généralisables capables de prédire avec précision le comportement au cisaillement des poutres en BA renforcées par PRF dans des applications d'ingénierie réelles.

4.3.3 Raffinement et sélection des données

Malgré la richesse des informations contenues dans la base de données originale, il est primordial d'assurer la plus haute qualité et fiabilité des données pour développer des modèles d'apprentissage automatique précis et robustes. À cette fin, un rigoureux processus de raffinement a été entrepris, aboutissant à un sous-ensemble plus ciblé et cohérent de 394 spécimens. Ce processus de raffinement a impliqué les étapes cruciales suivantes :

- **Suppression des doublons** : Les entrées de données en double ont été identifiées et éliminées pour éviter la surreprésentation de certains cas et assurer l'unicité de chaque spécimen au sein de l'ensemble de données. Les entrées en double peuvent introduire un biais et fausser le processus d'entraînement du modèle, pouvant conduire à des prédictions inexactes.
- **Traitement des essais répétés** : Dans les cas où plusieurs essais ont été réalisés sur des spécimens aux caractéristiques identiques, les données ont été soigneusement évaluées pour leur cohérence. Si la contribution au cisaillement du PRF présentait des niveaux

de variance acceptables, ce qui peut être attendu en raison de la variabilité inhérente aux conditions expérimentales, la valeur moyenne a été calculée et utilisée comme mesure représentative. Cette approche atténue l'impact des valeurs aberrantes et fournit une représentation plus précise de la contribution au cisaillement du PRF. Cependant, si un écart significatif dans la contribution au cisaillement du PRF a été observé, indiquant des erreurs ou des anomalies potentielles dans le processus de collecte des données, toutes les entrées répliquées ont été supprimées de l'ensemble de données. Cette étape assure l'intégrité et la fiabilité de la base de données raffinée en éliminant les points de données potentiellement erronés ou incohérents.

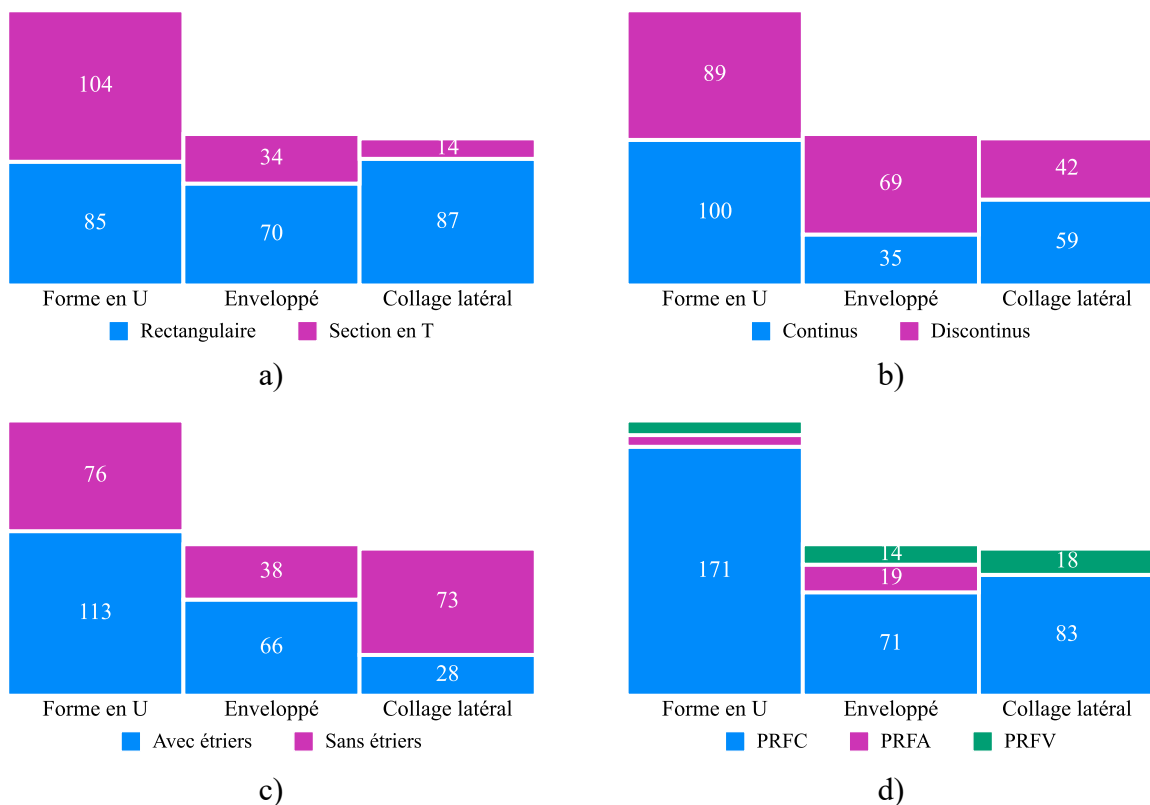
- **Concentration sur les angles de PRF standard** : Afin s'aligner sur les pratiques courantes de l'industrie et améliorer la pertinence pratique des modèles développés, les poutres utilisant des PRF avec des angles d'inclinaison autres que les configurations largement étudiées de 45 et 90 degrés ont été exclues de l'ensemble de données raffiné. Cette priorisation des angles de renforcement les plus courants augmente l'applicabilité et la pertinence des modèles développés dans les contextes d'ingénierie pratiques où ces configurations sont principalement rencontrées.

En mettant en œuvre ces étapes rigoureuses de raffinement, la base de données résultante de 394 spécimens représente une ressource de haute qualité, cohérente et fiable pour développer et valider des modèles d'apprentissage automatique adaptés à la prédiction de la résistance au cisaillement des poutres en BA renforcées par PRF collés extérieurement.

Le [Tableau 4.1](#) et la [Fig. 4.4](#) fournissent un aperçu détaillé de la composition de cette base de données raffinée. Ils présentent la répartition de ces 394 spécimens en différents sous-groupes, en fonction de caractéristiques clés telles que la géométrie de la section transversale (rectangulaire ou en T), la configuration du renforcement PRF (enveloppée (W), en U ou collée latéralement (S)), le type de fibres PRF utilisées (PRFC, PRFV ou PRFA), les schémas de disposition du PRF (continus ou discontinus), ainsi que la présence ou l'absence d'armatures transversales internes en acier. Cette ventilation exhaustive met en évidence la diversité et la représentativité de l'ensemble de données, capturant une vaste gamme de configurations expérimentales pertinentes pour le renforcement au cisaillement des poutres en BA par PRF collés extérieurement.

Tableau 4.1 — Répartition des spécimens dans la base de données raffinée.

		Enveloppement (W)		Chemisage en U		Collage latéral (S)		Total
		D	C	D	C	D	C	
Rectangulaire (242 poutres, 61%)	Avec A_{st}	25	12	26	23	7	12	105
	Sans A_{st}	17	16	18	18	33	35	137
Section en T (152 poutres, 39%)	Avec A_{st}	24	5	34	30	1	8	102
	Sans A_{st}	3	2	11	29	1	4	50
Nombre total	R	42	28	44	41	40	47	394
	T	27	7	45	59	2	12	

**Fig. 4.4** — Aperçu de la base de données expérimentale raffinée : (a) géométrie des poutres, (b) schémas de distribution des PRF, (c) armatures internes en acier, et (d) types de matériaux PRF.

La sélection minutieuse des attributs d'entrée est cruciale pour atteindre des performances de modèle fiables et précises. Dans cette étude, les paramètres d'entrée choisis pour prédire la

capacité au cisaillement des PRF sont basés sur les études de recherche antérieures (Abuodeh et al., 2020; Rahman et al., 2023; Wang et al., 2023) et les équations existantes des directrices de conception. Un total de 11 variables d'entrée clés ont été prises en compte pour développer les modèles d'apprentissage automatique présentés dans ce travail. Ces paramètres incluent la profondeur effective de la poutre d , le rapport de la portée de cisaillement sur la profondeur a/d , la résistance à la compression du béton f_{ck} , le taux d'armature transversale ρ_{sw} , les configurations de renforcement au cisaillement par PRF (type de schéma d'enveloppement), la hauteur de la feuille de PRF h_f , le rapport largeur-espacement du PRF b_f/s_f , l'épaisseur du PRF t_f , le module d'élasticité du PRF E_f , la déformation effective du PRF ε_{fu} et l'angle d'inclinaison du PRF α_f . La plage (Min et Max), la moyenne, l'écart-type (STDEV) et les valeurs des 25e, 50e et 75e percentiles des principales paramètres numériques sélectionnées et de la sortie incluse dans la base de données sont répertoriés dans le [Tableau 4.2](#).

Tableau 4.2 — Statistiques descriptives des paramètres d'entrée et de sortie utilisés pour prédire V_f .

Variable	Symbole	Unité	Catégorie	Statistiques						
				Moyenne	STDEV	Min	25%	50%	75%	Max
Profondeur effective de la poutre	d	mm	Entrée	318.42	136.86	85	223	305.5	362	831
Portée de cisaillement sur profondeur	a/d	–	Entrée	2.83	0.74	1.3	2,5	3	3.3	6.9
Résistance à la compression du béton	f_{ck}	MPa	Entrée	29.04	10.87	4	22	28	35	63.4
Taux d'armature transversale	ρ_{sw}	%	Entrée	0.12	0.16	0	0	0.1	0.19	0.84
Hauteur de la feuille de PRF	h_f	mm	Entrée	320.29	136.14	64	229	300	400	762
Rapport largeur-espacement du PRF	b_f/s_f	–	Entrée	0.7	0.32	0.11	0.4	0.7	1	1
Épaisseur du PRF	t_f	mm	Entrée	0.46	0.57	0.04	0.12	0.21	0.44	4
Module d'élasticité du PRF	E_f	GPa	Entrée	181.76	92.95	5	102	230	234	640
Déformation effective du PRF	ε_{fu}	‰	Entrée	16.1	6.05	4	13.3	15.2	16.7	47.4
Angle d'inclinaison du PRF	α_f	°	Entrée	82.69	16.62	45	90	90	90	90
Contribution au cisaillement du PRF	V_f	kN	Sortie	70.86	79.38	2.79	24.36	45.55	80	551

En outre, la [Fig. 4.5](#) présente l'histogramme de fréquence de ces attributs numériques essentiels et de la sortie correspondante. Ces illustrations sont remarquablement bénéfiques, identifiant le spectre des valeurs de paramètres où la disponibilité des données est insuffisante, indiquant ainsi les domaines où l'acquisition de données supplémentaires est nécessaire.

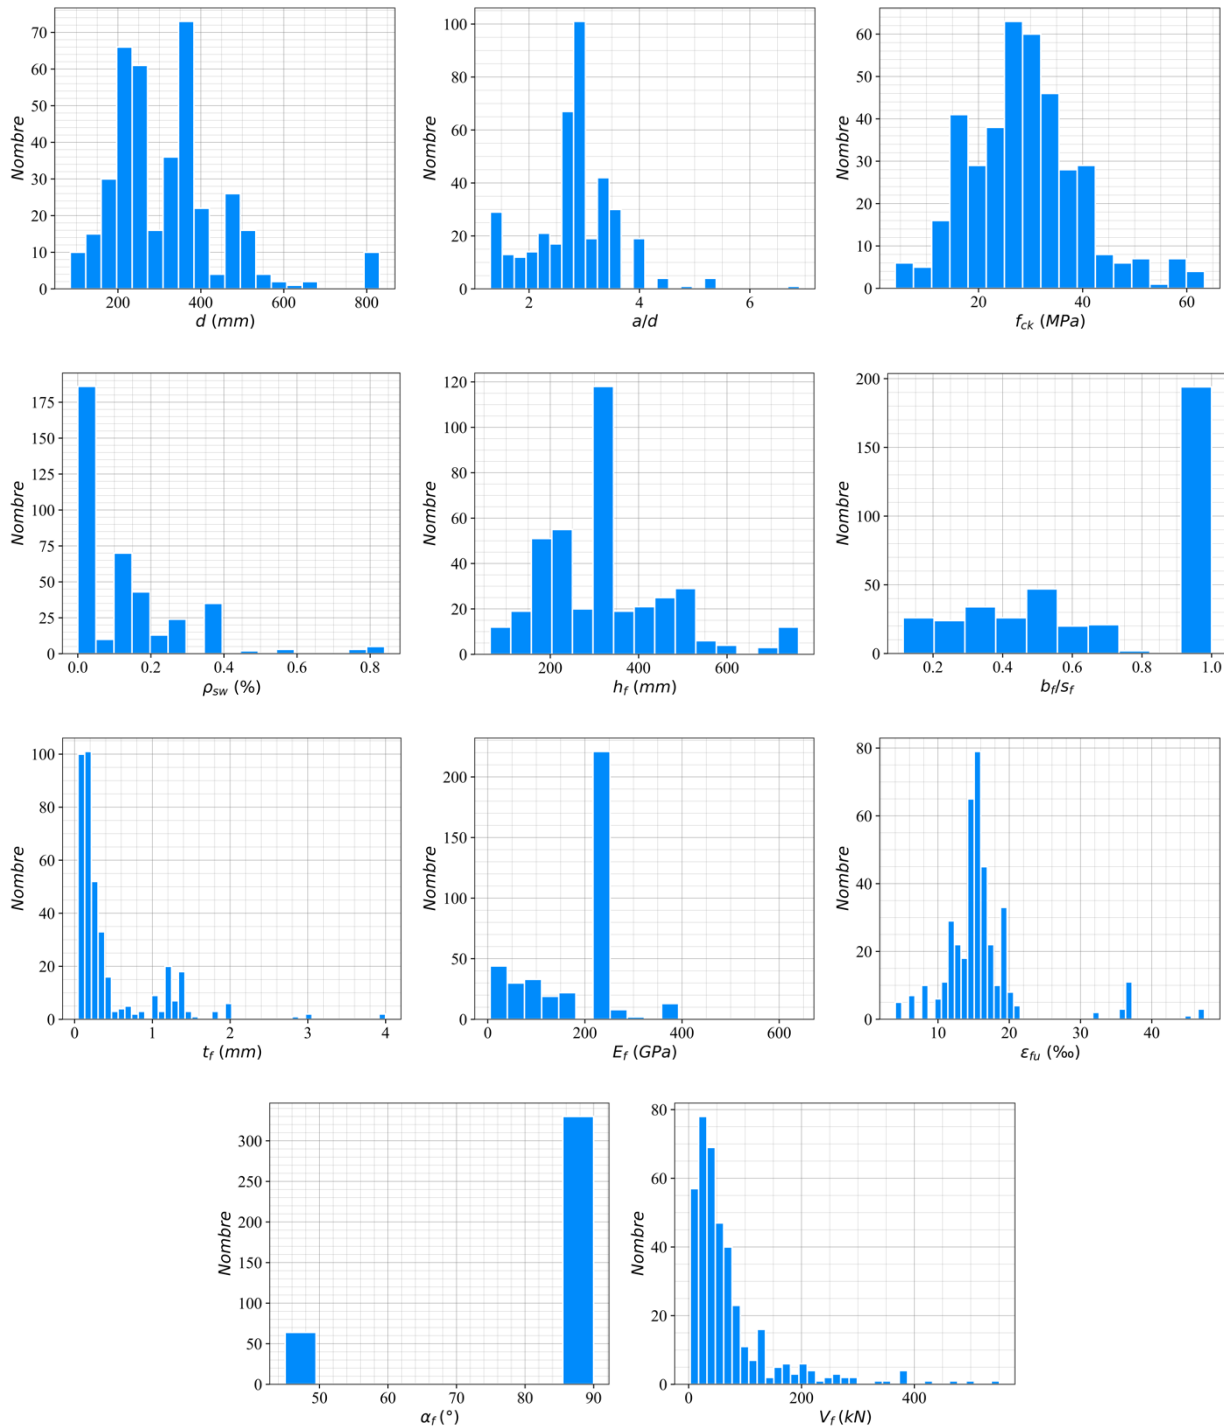


Fig. 4.5 — Distributions d'histogrammes des attributs numériques et de la sortie.

4.4 Pré-traitement des données

Avant d'entraîner les modèles d'apprentissage automatique, l'ensemble de données expérimentales a été soumis à une phase de pré-traitement afin d'en garantir la pertinence et l'adéquation pour une analyse approfondie. L'étape de pré-traitement est d'une importance capitale car elle permet d'organiser et d'affiner les données brutes, facilitant ainsi une

modélisation efficace et précise. Cette section fournit un aperçu complet des techniques employées pour le pré-traitement des données, englobant la division de l'ensemble de données en sous-ensembles d'entraînement et de test, le codage des variables catégorielles et la mise à l'échelle des attributs.

- **Division des données en ensembles d'entraînement et de test :** Une étape cruciale pour prévenir le sur-apprentissage et permettre une évaluation impartiale de la généralisabilité du modèle réside dans la division minutieuse de l'ensemble de données expérimentales compilées en ensembles d'entraînement et de test. Ce processus sépare les données utilisées pour l'entraînement des paramètres du modèle (ensemble d'entraînement) des données réservées à l'évaluation de sa performance sur des données inédites (ensemble de test). Une approche courante consiste à effectuer une répartition 80/20, où 80 % des données sont attribuées à l'ensemble d'entraînement et les 20 % restants constituent l'ensemble de test. Dans cette étude, nous avons suivi cette approche, ce qui a donné lieu à un ensemble d'entraînement de 314 points de données et un ensemble de test de 80 points de données. Cependant, une simple répartition aléatoire ne garantit pas que l'ensemble de test reflète avec précision la distribution des caractéristiques présentes dans l'ensemble de données d'origine. Pour remédier à cela, nous avons employé une technique d'échantillonnage aléatoire stratifié lors de la sélection de l'ensemble de test. Cette méthode assure une représentation proportionnelle de chaque configuration de renforcement par PRF (PRF collés sur les côtés (S), PRF en forme de U (U) et PRF enveloppés (W)) dans l'ensemble de test. Le processus de sélection a consisté à choisir aléatoirement un pourcentage prédéfini (par exemple, 20 %) de points de données de chaque catégorie, reflétant ainsi leurs proportions relatives au sein de l'ensemble de données d'origine. Ce processus de sélection minutieux garantit que l'ensemble de test englobe le spectre complet des schémas de renforcement, permettant ainsi une évaluation complète de la capacité du modèle à se généraliser à des données inédites à travers les différentes configurations.
- **Encodage des données catégorielles :** L'encodage one-hot a été utilisé pour transformer la variable catégorielle de configuration de renforcement par PRF en une représentation numérique adaptée aux algorithmes d'apprentissage automatique. Cette technique permet de relever efficacement le défi de la représentation de catégories non numériques au sein du modèle. Elle y parvient en convertissant chaque catégorie distincte (par exemple, PRF collés sur les côtés (S), PRF en forme de U (U), PRF enveloppés (W)) en

un vecteur binaire séparé. Au sein de ce vecteur, une valeur de "1" dénote la présence de cette catégorie spécifique, tandis que "0" signifie son absence. Par exemple, la catégorie "PRF collés sur les côtés (S)" serait codée comme [1, 0, 0]. Bien que l'encodage one-hot offre l'avantage d'éviter toute hypothèse implicite sur une relation ordinaire entre les catégories, il présente un inconvénient potentiel. Cet inconvénient réside dans l'augmentation de la dimensionnalité des données due à la création de K attributs binaires pour une variable catégorielle avec K niveaux distincts. Cette inflation de l'espace des attributs peut mener au problème de la multi colinéarité, où les attributs codés deviennent fortement corrélés les uns aux autres. Pour atténuer ce problème et promouvoir l'efficacité du modèle, une pratique courante consiste à supprimer la première colonne des variables encodées en one-hot. Cela peut être fait sans perte d'information car les K-1 vecteurs binaires restants contiennent toutes les informations nécessaires pour reconstruire les données catégorielles d'origine. Cette approche permet d'éliminer efficacement la multi colinéarité tout en préservant les avantages l'encodage one-hot pour la représentation des variables catégorielles dans les modèles d'apprentissage automatique.

- **Mise à l'échelle des attributs** : Pour assurer des performances optimales et faciliter la convergence de l'entraînement des modèles de réseaux de neurones artificiels employés dans cette étude, les caractéristiques d'entrée ont subi une normalisation par Z-score, une technique de pré-traitement largement utilisée. Cette technique remise à l'échelle les données de telle sorte que les attributs normalisés aient une moyenne de 0 et un écart-type de 1 (Éq. 4.1).

$$z = \frac{x - \mu}{\sigma} \quad (4.1)$$

Où z est la valeur normalisée, x est la valeur originale, μ est la moyenne et σ est l'écart-type.

La normalisation par Z-score offre plusieurs avantages convaincants pour l'entraînement des réseaux de neurones profonds (DNN). Premièrement, elle établit un terrain d'entente commun pour tous les attributs en les mettant à l'échelle sur une plage normalisée. Cela atténue le problème des attributs ayant de grandes amplitudes qui domineraient le processus d'entraînement. Dans les réseaux de neurones, les fonctions d'activation fonctionnent souvent plus efficacement dans une plage d'entrée spécifique. La normalisation garantit que tous les attributs contribuent de manière proportionnelle à

l'optimisation du modèle, conduisant potentiellement à une convergence plus rapide et à un apprentissage amélioré. Deuxièmement, la normalisation peut grandement améliorer la stabilité du processus d'entraînement, en particulier pour les modèles qui utilisent des algorithmes d'optimisation basés sur les gradients. Ces algorithmes reposent sur le calcul des gradients, qui peuvent devenir numériquement instables avec des caractéristiques ayant des échelles très différentes. La normalisation résout cette préoccupation, favorisant une convergence plus lisse et réduisant potentiellement le risque de rester bloqué dans des minima locaux.

Maintenir une séparation stricte entre les données d'entraînement et de test est crucial durant le flux de travail d'apprentissage automatique. Par conséquent, la moyenne (μ) et l'écart-type (σ) utilisés pour la normalisation ont été calculés uniquement à partir des données d'entraînement. Cela prévient les fuites de données, un phénomène où des informations provenant de l'ensemble de test influencent involontairement le processus d'entraînement du modèle. Bien que la normalisation par Z-score offre des avantages significatifs pour les réseaux de neurones, il est important de reconnaître que certains algorithmes d'apprentissage automatique, comme XGBoost, sont moins sensibles à la mise à l'échelle des attributs. La normalisation pourrait ne pas être nécessaire dans de tels cas, et le choix des techniques de pré-traitement peut être adapté à l'algorithme spécifique employé.

4.5 Effet des paramètres d'entrée sur la contribution du renforcement au cisaillement par PRF

Optimiser la conception et la performance du renforcement au cisaillement par PRF dans les poutres en BA nécessite une compréhension approfondie de l'interaction entre divers paramètres d'entrée et leur influence sur l'efficacité des PRF. Bien que les codes de conception existants intègrent certains de ces paramètres, une connaissance plus approfondie de leurs effets individuels reste cruciale pour obtenir une conception optimale. Cette section comble cette lacune en connaissances en étudiant systématiquement l'influence des principaux paramètres d'entrée sur la contribution à la résistance au cisaillement des PRF. Nous analysons les mécanismes sous-jacents qui régissent ces influences, mettant en évidence les tendances prévues et les complexités potentielles entre certains paramètres et l'efficacité des PRF. Cette compréhension globale permet de développer des approches de conception plus affinées et des prévisions plus précises.

4.5.1 Effet du rapport portée de cisaillement/profondeur (a/d) :

L'influence du rapport portée de cisaillement/profondeur (a/d) sur l'efficacité du renforcement au cisaillement par PRF reste un sujet de recherche en cours, avec des études limitées examinant explicitement cette relation. Bien que les codes de conception existants puissent ne pas tenir pleinement compte de cet effet, [Li and Leung \(2015\)](#) ont observé une tendance intéressante où la contribution des PRF à la résistance au cisaillement augmentait initialement avec l'augmentation du rapport a/d . Cependant, cette augmentation a cessé et a même démontré une légère diminution lorsque le rapport dépassait 2,5. Des résultats similaires ont été rapportés par [Li and Leung \(2017\)](#), avec une augmentation initiale de la contribution au cisaillement des PRF avec l'augmentation de a/d , suivie d'une diminution une fois le rapport dépassé 2,0. Cette tendance observée peut s'expliquer par plusieurs facteurs influençant l'interaction entre la section en béton et le mécanisme de renforcement par PRF. Dans les poutres plus profondes (a/d faible), la section en béton elle-même peut résister à une partie importante des efforts de cisaillement par effet d'arche, les PRF jouant un rôle complémentaire dans le contrôle de l'initiation des fissures. Lorsque a/d augmente (poutres plus minces), l'effet d'arche s'affaiblit et les PRF deviennent plus critiques pour la résistance au cisaillement. De plus, l'angle de fissure critique joue un rôle. Dans les poutres plus profondes, l'angle des fissures est moins favorable pour que les PRF résistent aux efforts de cisaillement. À l'inverse, les poutres plus minces subissent des fissures mieux alignées avec la direction des fibres de PRF, permettant une résistance au cisaillement plus efficace. Cependant, il existe une limite à cet avantage. Au-delà d'un certain rapport a/d (environ 2,0), une portion plus importante des PRF peut se retrouver en dehors de la "zone de travail effective" (la zone la plus cruciale pour le contrôle des fissures), entraînant une diminution de la contribution globale des PRF. Enfin, pour des rapports a/d très élevés, le mode de rupture au cisaillement peut passer d'un cisaillement-compression à un cisaillement-traction, provoquant potentiellement une propagation plus rapide des fissures et un décollement des bandes de PRF dans la zone effective, réduisant davantage l'efficacité des PRF ([Li and Leung, 2017](#)).

4.5.2 Effet du taux d'armature transversale en acier (ρ_{sw}) :

L'influence du taux d'armature transversale en acier sur l'efficacité du renforcement au cisaillement par PRF a été largement étudiée dans la littérature ([Bousselham and Chaallal, 2008](#); [Gonzalez-Libreros et al., 2017](#); [Grande et al., 2009](#); [Mofidi and Chaallal, 2014b](#); [Pellegrino and Modena, 2002](#)). Ces études rapportent de manière constante une réduction

notable de la contribution des PRF à la résistance au cisaillement avec l'inclusion d'armatures transversales en acier internes. Cet effet peut être attribué aux rôles qui se chevauchent de l'acier transversal et des PRF dans la résistance aux efforts de cisaillement dépassant la capacité du béton. Cependant, en raison de son ancrage interne dans le béton, l'acier transversal fournit généralement une liaison plus forte à l'interface acier-béton que les PRF collées extérieurement. Cette liaison plus forte se traduit par une résistance au cisaillement accrue par rapport aux PRF, qui reposent sur une liaison adhésive à la surface du béton. De plus, les détails d'ancrage des armatures transversales en acier offrent souvent un mécanisme plus efficace pour résister aux efforts de cisaillement. À l'inverse, en l'absence d'étriers internes, les PRF deviennent le seul pourvoyeur d'armature de cisaillement. Ils y parviennent en empêchant l'ouverture et la propagation des fissures diagonales, conduisant finalement à une contribution plus importante à la résistance au cisaillement (Bousselham and Chaallal, 2008). Cependant, l'augmentation de la quantité totale d'armatures transversales (acier et PRF combinés) peut conduire à un motif de fissuration plus réparti. Cela réduit à son tour la longueur d'ancrage disponible pour les PRF, diminuant par conséquent la force d'adhérence et la contribution des PRF à la résistance au cisaillement. Ceci souligne le rôle crucial de la qualité de la liaison entre les PRF et le béton dans la détermination de l'efficacité des PRF à résister aux efforts de cisaillement (Mofidi and Chaallal, 2014b).

4.5.3 Effet de la résistance à la compression du béton (f_{ck}) :

Plusieurs études ont rapporté une corrélation positive entre la résistance à la compression du béton (f_{ck}) et l'efficacité du renforcement au cisaillement par PRF (Hilal et al., 2021; Jumaa and Yousif, 2019; Mofidi and Chaallal, 2014a). Cette observation est conforme aux codes de conception en vigueur et aux équations de capacité au cisaillement proposées, qui définissent souvent la résistance au cisaillement comme proportionnelle à f_{ck} . Mofidi and Chaallal (2014a) ont spécifiquement démontré une relation directe entre f_{ck} et la contribution des PRF à la résistance au cisaillement dans les poutres en BA. Leurs données expérimentales ont révélé qu'une augmentation de f_{ck} entraînait une augmentation correspondante de la contribution au cisaillement des PRF. Ce phénomène peut être attribué à la capacité d'adhérence améliorée entre le substrat en béton et la feuille de PRF à des résistances à la compression plus élevées (Hilal et al., 2021). Un béton plus résistant fournit une plateforme plus robuste pour que les PRF transfèrent les contraintes de cisaillement, entraînant une adhérence plus efficace et, par conséquent, une contribution globale plus importante des PRF à la résistance au cisaillement.

4.5.4 Effet de la taille de la poutre (profondeur effective d) :

L'influence de la taille de la poutre, en particulier de la profondeur de la poutre (d), sur la contribution des PRF à la résistance au cisaillement a été bien documentée dans la littérature. Les études expérimentales rapportent de manière constante un effet d'échelle, où l'efficacité des PRF pour augmenter la capacité au cisaillement diminue généralement lorsque la profondeur de la poutre augmente (Alam and Hussein, 2012; Benzeguir et al., 2019; Benzeguir and Chaallal, 2021; Jiang et al., 2023; Yu et al., 2016). Cela peut être dû à une longueur d'ancrage insuffisante par rapport à la hauteur de la poutre. Lorsque la taille de la poutre augmente, cette longueur d'ancrage limitée devient insuffisante pour transférer efficacement les contraintes de cisaillement.

4.5.5 Effet de la conception des PRF et des caractéristiques des matériaux :

L'efficacité des systèmes de renforcement externe en PRF pour améliorer la capacité de cisaillement des poutres en BA est considérablement influencée par la conception et les caractéristiques des matériaux du renfort PRF. Cette sous-section examine les effets individuels de diverses variables de conception du PRF, notamment le rapport largeur-espacement, l'épaisseur, la hauteur, l'angle d'inclinaison, le module élastique et la déformation ultime, sur la contribution à la résistance au cisaillement du PRF :

- *Rapport largeur-espacement des PRF (b_f/s_f)* : Bien qu'on puisse intuitivement supposer qu'augmenter la quantité de matériau de renforcement par PRF améliorerait la résistance au cisaillement, les recherches suggèrent une relation plus nuancée. Khalifa and Nanni (2000) ont observé que dépasser un certain seuil de quantité de PRF entraînait des rendements décroissants en termes d'efficacité de renforcement au cisaillement. Leurs conclusions, corroborées par des études ultérieures (Khalifa and Nanni, 2002; Zhang and Hsu, 2005), soulignent l'importance d'optimiser l'utilisation des PRF. Mofidi and Chaallal (2011) ont analysé une exhaustive base de données de résultats d'essais sur des poutres en BA renforcées avec des bandes de PRF. Leurs résultats contredisent l'hypothèse courante d'une relation linéaire entre la rigidité des PRF et la résistance au cisaillement. Au contraire, les résultats démontrent qu'augmenter la rigidité des PRF (c'est-à-dire le rapport b_f/s_f) ne garantit pas nécessairement un gain de capacité au cisaillement. Cette observation est en accord avec les recherches antérieures de Triantafillou (1998) et Khalifa and Nanni (2000). Ces résultats suggèrent des limites dans les modèles de conception actuels qui supposent souvent une relation linéaire entre la rigidité des PRF et leur contribution au cisaillement. Intégrer les

conclusions concernant l'effet non linéaire de b_f/s_f sur la résistance au cisaillement est prometteur pour affiner et améliorer les directives de conception existantes pour les éléments en béton renforcés avec des PRF.

- *Épaisseur des PRF (t_f)* : Augmenter l'épaisseur des PRF, généralement réalisée en appliquant des couches supplémentaires de feuilles de PRF, conduit généralement à une contribution accrue à la résistance au cisaillement (Banjara and Ramanjaneyulu, 2017). Cependant, le taux d'augmentation de la résistance au cisaillement diminue avec chaque couche supplémentaire (Hawileh et al., 2015; Sengun and Arslan, 2022).
- *Hauteur des PRF (h_f)* : Une corrélation positive a été établie entre la hauteur des PRF et leur capacité à améliorer la résistance au cisaillement, comme rapporté par Wang et al. (2023) et corroboré par d'autres investigations expérimentales (Li et al., 2015). Cette corrélation peut être attribuée à la surface de matériau et de surface d'adhérence accrue fournie par une feuille de PRF plus haute, ce qui facilite un transfert plus efficace des efforts de cisaillement du béton vers les PRF.
- *Angle d'inclinaison des PRF (α_f)* : L'angle auquel les PRF sont positionnés par rapport à l'axe de la poutre peut également influencer leur efficacité. Plusieurs études ont rapporté que les feuilles de PRF orientées à un angle de 45° sont légèrement plus efficaces pour augmenter la résistance au cisaillement que celles appliquées perpendiculairement (90°) (Al-Rousan, 2020; Al-Rousan and Haddad, 2013; Sim et al., 2005).
- *Module d'élasticité des PRF (E_f)* : Le module d'élasticité du matériau PRF est un autre facteur crucial influençant son efficacité pour le renforcement au cisaillement. Les études ont montré une corrélation positive entre le module d'élasticité des PRF et leur contribution à la résistance au cisaillement (Nguyen-Minh et al., 2018; Nguyen-Minh and Rovňák, 2015; Vo-Le et al., 2022). La performance améliorée avec un module d'élasticité plus élevé peut être attribuée à la rigidité axiale accrue des PRF. Une feuille de PRF plus rigide présente une plus grande résistance à la déformation sous charge. Cette rigidité accrue permet aux PRF de restreindre plus efficacement l'ouverture et la propagation des fissures diagonales dans l'élément en béton, retardant et atténuant ainsi la rupture au cisaillement.
- *Déformation ultime des PRF (ε_{fu})* : La relation entre la déformation ultime des PRF et leur contribution à la résistance globale au cisaillement d'une poutre est complexe. Bien qu'une déformation ultime plus élevée indique un matériau avec une plus grande

capacité d'allongement, une corrélation directe avec la résistance au cisaillement n'est pas toujours observée. Théoriquement, la poutre se déforme sous la charge, induisant une déformation (allongement) dans les PRF collés. Ce développement de la déformation dans les PRF leur permet de s'engager et de restreindre les fissures diagonales dans le béton, résistant ainsi aux forces de cisaillement internes. Par conséquent, une augmentation de la déformation des PRF peut améliorer la capacité au cisaillement de la poutre. Cependant, les directives de conception reconnaissent ce bénéfice théorique, mais adoptent une approche conservatrice en utilisant une déformation de calcul (déformation effective), généralement une fraction de la déformation ultime, pour tenir compte de plusieurs limitations pratiques (rupture de l'adhérence entre les PRF et le béton, rupture des PRF et incertitudes inhérentes à la prédiction de la distribution réelle des déformations). Cette approche assure une performance fiable sans compter sur le plein potentiel des PRF.

L'analyse a révélé une interaction complexe entre les paramètres d'entrée et la contribution des PRF à la résistance au cisaillement. Cela comprenait des relations monotones (augmentant ou diminuant de manière continue) et non monotones (ayant un pic ou un point d'inflexion). Pour tirer parti de ces connaissances dans les modèles d'apprentissage automatique monotones employés, nous avons encodé le comportement physique anticipé de chaque variable d'entrée. Cet encodage a permis aux modèles de capturer le sens (positif ou négatif) de l'influence du paramètre sur la contribution des PRF à la résistance au cisaillement. Spécifiquement, les paramètres connus pour avoir une influence positive, tels que la résistance à la compression du béton (f_{ck}), la hauteur de la feuille de PRF (h_f), l'épaisseur des PRF (t_f), le module d'élasticité des PRF (E_f) et la déformation ultime des PRF (ε_{fu}), ont été désignés comme des variables monotones croissantes. À l'inverse, les paramètres présentant une influence négative, notamment la profondeur effective de la poutre (d), le taux d'armature transversale interne en acier (ρ_{sw}) et l'angle d'inclinaison des PRF (α_f), ont été désignés comme des variables monotones décroissantes. Enfin, les paramètres restants, notamment le rapport portée de cisaillement/profondeur (a/d), le rapport largeur/espacement des PRF (b_f/s_f) et les configurations catégoriques de renforcement au cisaillement par PRF, ont été identifiés comme non monotones ; ces variables présentent des relations complexes avec la contribution des PRF à la résistance au cisaillement, et les modèles ont été conçus pour apprendre directement ces relations à partir des données d'entraînement. Cette approche d'encodage permet aux modèles monotones d'appliquer ces relations monotones connues pendant

l'entraînement, conduisant potentiellement à des prédictions de contribution des PRF à la résistance au cisaillement plus fiables et précises.

4.6 Métriques d'évaluation de la performance

Les performances des modèles développés ont été évaluées à l'aide d'une suite complète de six métriques de performance statistique (Éqs. 4.2-4.7) : Coefficient de détermination (R^2), Efficacité de Kling-Gupta (KGE), Erreur absolue moyenne (MAE), Racine carrée de l'erreur quadratique moyenne (RMSE), Indice de confiance (CI/PI) et Indice global (OI). Ces métriques offrent une perspective multidimensionnelle sur les performances des modèles, englobant l'explication de la variance, l'ampleur des erreurs et la précision globale.

- **Explication de la variance :**

Coefficient de détermination ou R^2 : (Éq. 4.2) Cette métrique reflète la proportion de variance de la variable dépendante expliquée par les variables indépendantes du modèle. Les valeurs de R^2 vont de $-\infty$ à 1, les valeurs plus élevées indiquant un pouvoir explicatif plus fort. Un score parfait de 1 signifie que le modèle capture parfaitement la variance des données, tandis qu'une valeur de 0 suggère aucune amélioration par rapport à la simple prédiction de la moyenne de la variable dépendante. Une valeur négative de R^2 implique que le modèle performe moins bien que l'utilisation de la moyenne de la variable dépendante comme prédicteur, signalant un très mauvais ajustement du modèle.

Efficacité de Kling-Gupta (KGE) : (Éq. 4.3) Cette métrique va au-delà de R^2 en incorporant des mesures de corrélation, de variabilité et de biais en un seul score allant de moins l'infini à 1. Un score parfait de 1 indique un accord idéal entre les prédictions du modèle et les données observées.

- **Ampleur des erreurs :**

Erreur absolue moyenne (MAE) : (Éq. 4.4) Cette métrique quantifie l'ampleur moyenne de la différence entre les valeurs prédites et réelles, indépendamment de leur direction (erreurs positives ou négatives). Elle est interprétable dans les unités de la variable de réponse, ce qui facilite la compréhension de la taille typique des erreurs. Des valeurs MAE plus basses indiquent de meilleures performances du modèle, ce qui signifie des écarts moyens plus faibles entre les prédictions et les observations.

Racine carrée de l'erreur quadratique moyenne (RMSE) : (Éq. 4.5) Cette métrique mesure la taille typique de l'erreur de prédiction en élevant au carré les écarts entre les valeurs prédites

et réelles, puis en prenant la racine carrée. Bien que les résultats RMSE soient également affichés dans les unités de la variable de réponse, elle est plus sensible aux valeurs aberrantes que la MAE. Cela est dû au fait que l'élevation au carré des erreurs plus importantes amplifie leur contribution au score final. Des valeurs RMSE plus basses indiquent des écarts moyens plus faibles entre les prédictions et les cibles.

- **Performance globale du modèle :**

Indice de confiance (CI/PI) : (Éq. 4.6) Cette métrique offre une évaluation robuste des performances du modèle avec un score compris entre 0 et 1. Un score de 1 indique une performance idéale, avec des catégories de scores prédéfinies : 'Excellent' (>0,85), 'Très bon' (0,76–0,85), 'Bon' (0,66–0,75), 'Satisfaisant' (0,61–0,65), 'Faible' (0,51–0,60), 'Mauvais' (0,41–0,50) et 'Très mauvais' (<0,40), reflétant la précision et la fiabilité du modèle. Le CI/PI fournit une indication rapide et claire des performances globales d'un modèle à partir d'un score unique.

Indice global (OI) : (Éq. 4.7) Cette métrique composite combine RMSE avec une mesure d'erreur relative et un terme de correction pour évaluer la précision des modèles de prévision. Les valeurs vont de -1 à +1, les valeurs plus élevées indiquant des performances supérieures du modèle. L'OI fournit un score unique qui intègre à la fois la racine carrée de l'erreur quadratique moyenne (RMSE) et l'erreur relative du modèle, offrant une évaluation plus complète de la précision des prévisions.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.2)$$

$$KGE = \sqrt{(R - 1)^2 + (\beta - 1)^2 + (\gamma - 1)^2} \quad (4.3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.5)$$

$$CI = R * WI \quad (4.6)$$

$$OI = \frac{1}{2} \left[1 - \frac{RMSE}{y_{max} - y_{min}} + EC \right] \quad (4.7)$$

Où : n est le nombre d'échantillons, y_i et \hat{y}_i représentent les valeurs expérimentales et prédites de l'échantillon i respectivement, \bar{y} représente la valeur moyenne expérimentale, R est le coefficient de corrélation de Pearson, β est le ratio de biais, γ est le ratio de variabilité, WI est l'indice de Willmott et EC est le coefficient d'efficacité.

Pour mieux comprendre les performances prédictives du modèle, la valeur moyenne (MV) et le coefficient de variation (COV) des ratios entre les valeurs expérimentales et prédites sont analysés. La MV donne un aperçu du biais systématique du modèle. Une MV supérieure à 1,0 signifie une sous-estimation systématique par le modèle, suggérant un biais conservateur. Cela peut être interprété comme une tendance à prédire des capacités de cisaillement plus faibles pour les sections renforcées par PRF par rapport aux résultats expérimentaux. D'un point de vue pratique, un biais conservateur pourrait être considéré comme plus sûr d'un point de vue ingénierie, mais il pourrait également conduire à sous-estimer le potentiel réel de la technique de renforcement au cisaillement par PRF. Le COV, une mesure statistique sans dimension, capture à la fois la précision et la variabilité des prédictions du modèle. Il est calculé en divisant l'écart-type des ratios par le ratio moyen (MV). Des valeurs de COV plus basses indiquent une plus grande cohérence et précision dans les prédictions du modèle. À l'inverse, un COV élevé signifie une dispersion importante des ratios, suggérant que les performances du modèle peuvent varier considérablement selon les différents points de données expérimentaux. Un faible COV est crucial pour une application fiable du modèle, garantissant des prédictions cohérentes dans divers scénarios.

4.7 Réglage des hyperparamètres avec l'optimisation bayésienne

La sélection des hyperparamètres optimaux pour des modèles complexes comme XGBoost et les réseaux de neurones profonds (DNNs) est cruciale pour obtenir des performances optimales. En raison du grand nombre de configurations d'hyperparamètres potentiels (espace de recherche), une approche de recherche exhaustive par grille devient rapidement non pratique d'un point de vue computationnel. Pour relever ce défi, nous avons employé l'optimisation bayésienne, une technique d'optimisation séquentielle basée sur un modèle qui navigue efficacement dans l'espace de recherche tout en minimisant le nombre d'évaluations requises. Nous avons utilisé la bibliothèque Optuna ([Akiba et al., 2019](#)) pour l'optimisation bayésienne. Optuna offre plusieurs avantages, notamment la mise en œuvre efficace des estimateurs de Parzen à structure d'arbre (TPE) comme algorithme d'échantillonnage bayésien par défaut. TPE suggère itérativement des configurations d'hyperparamètres prometteuses à

évaluer sur la base des performances des essais précédents. Cette approche permet à Optuna d'"apprendre" des évaluations passées et de prioriser les configurations les plus susceptibles d'améliorer les performances.

Chaque classe de modèle (XGBoost et réseau de neurones profond) avait neuf hyperparamètres clés ciblés pour l'optimisation, les autres étant réglés sur leurs valeurs par défaut. Ces hyperparamètres régissent divers aspects du processus d'apprentissage, tels que la complexité du modèle (par exemple, la profondeur des arbres dans XGBoost, le nombre de couches cachées dans les réseaux de neurones profonds), le taux d'apprentissage et les paramètres de régularisation. En optimisant ces hyperparamètres, nous visons à régler avec précision la capacité des modèles à apprendre des schémas complexes à partir des données d'entraînement tout en évitant le sur-apprentissage.

Pour assurer la généralisabilité du processus de réglage des hyperparamètres et obtenir une estimation plus robuste des performances du modèle, nous avons employé une validation croisée à cinq plis. Au sein de chaque pli, les données d'entraînement étaient divisées en 80% pour l'entraînement du modèle et 20% pour la validation. Optuna a exécuté l'optimisation bayésienne pour un total de 2 000 essais pour les modèles XGBoost (XGB et MXGB) et 1 000 essais pour les modèles de réseaux de neurones profonds (DNN et CMNN). Cette répartition reflète les temps d'entraînement différents entre les modèles. Les modèles XGBoost sont généralement plus rapides à entraîner que les réseaux de neurones profonds. Par conséquent, un nombre plus élevé d'essais (2 000) a été alloué à XGBoost pour permettre une exploration plus approfondie de l'espace de recherche. Chaque essai impliquait l'entraînement d'un modèle avec une configuration d'hyperparamètres spécifique sur l'ensemble d'entraînement d'un pli et l'évaluation de ses performances sur l'ensemble de validation correspondant. L'échantillonneur TPE au sein d'Optuna a utilisé la performance moyenne de validation sur tous les plis comme fonction objectif. Cette stratégie a facilité le réglage automatisé des hyperparamètres tout en tenant compte de la variabilité potentielle entre les différentes répartitions de données. En considérant la performance moyenne sur les plis, nous avons obtenu une estimation plus fiable de la capacité du modèle à se généraliser à des données non vues, conduisant à une meilleure évaluation de son potentiel de performance réel. Enfin, le modèle avec la meilleure performance moyenne de validation sur les cinq plis a été sélectionné comme modèle optimal pour une analyse et une évaluation plus approfondie.

Les configurations d'hyperparamètres spécifiques pour les meilleurs modèles XGBoost et de réseaux de neurones profonds sont présentées respectivement dans les [Tableaux 4.3](#) et [4.4](#).

Ces tableaux fournissent une ventilation détaillée des hyperparamètres optimisés et de leurs valeurs correspondantes, permettant la reproduction et la comparaison avec les études futures.

Tableau 4.3 — Valeurs optimales des hyperparamètres utilisés dans la modélisation XGB et MXGB.

Hyperparamètre	XGB	MXGB
Objectif	reg:tweedie	reg:tweedie
Puissance de la variance de Tweedie	1.7	1.7
Taux d'apprentissage	0.9990786347962595	0.30646742493968876
Profondeur maximale	13	9
Poids minimal de l'enfant	88.97504170107001	1.641899190664528
Sous-échantillonnage	0.5836498014862241	0.5811112903648679
Colsample bytree	0.7975429198420823	0.8080123271003194
Reg alpha	2.3563070478068124	0.5648495746729459
Reg lambda	7.6607698887251585	2.2468752655596385
Gamma	0.13118609180641577	2.344234071855143e-08

Tableau 4.4 — Valeurs optimales des hyperparamètres utilisés dans la modélisation DNN et CMNN.

Hyperparamètre	DNN	CMNN
Nombre de couches	3	3
Neurones par couche	[29, 19, 32]	[23, 30, 23]
Fonctions d'activation	SELU	SELU
Taux d'apprentissage initial de l'optimiseur Adam	0.012280265238397451	0.01041600662466786
Décroissance du poids de l'optimiseur Adam	5.4556831135751466e-06	7.018350371747546e-06
Taux de dropout	[0.0, 0.16, 0.42]	[0.0, 0.27, 0.44]
Taille du lot	16	64

4.7 Conclusion

Cette étude a mis en œuvre une approche rigoureuse combinant des techniques d'apprentissage automatique avancées et des stratégies méthodologiques robustes pour développer des modèles précis capables de prédire la contribution des PRF à la résistance au cisaillement des poutres en BA. Un vaste ensemble de données expérimentales, soigneusement raffiné et exhaustif, a constitué la base de cette enquête, assurant une représentation adéquate des divers scénarios rencontrés dans les applications d'ingénierie réelles.

Des algorithmes d'apprentissage automatique puissants tels que XGBoost, les réseaux de neurones profonds, ainsi que des variantes intégrant des contraintes de monotonie, ont été mis en œuvre et optimisés de manière approfondie. L'adoption d'une stratégie d'ensemble judicieuse a permis de tirer parti des forces complémentaires de ces modèles individuels, conduisant à des prédictions plus robustes et précises.

Des efforts considérables ont été déployés pour garantir l'intégrité et la qualité des données d'entrée. Un processus rigoureux de raffinage a permis d'éliminer les valeurs aberrantes, les doublons et les incohérences potentielles, aboutissant à un ensemble de données fiable de 394 spécimens. Le pré-traitement méticuleux, l'encodage des variables et la mise à l'échelle ont davantage amélioré la pertinence de l'ensemble de données pour l'entraînement des modèles.

Des analyses approfondies ont révélé des relations complexes entre les paramètres d'entrée clés et la contribution au cisaillement des PRF. Cette compréhension approfondie des mécanismes physiques régissant l'efficacité des PRF a été encodée dans les modèles monotones, permettant des prédictions plus précises et fiables.

L'implémentation des modèles a tiré parti de techniques avancées telles que les contraintes de monotonie, l'optimisation bayésienne des hyperparamètres et la validation croisée. Cela a permis de capturer les relations physiques sous-jacentes entre les paramètres d'entrée et la contribution au cisaillement, tout en ajustant avec précision la complexité du modèle pour prévenir le sur-apprentissage.

Une suite complète de métriques de performance statistique a été utilisée pour évaluer et comparer de manière approfondie les capacités prédictives des différents modèles développés. Cette évaluation multidimensionnelle, englobant des mesures d'explication de la variance, d'ampleur des erreurs et de performance globale, a fourni des informations précieuses sur les forces et les faiblesses relatives des modèles.

Grâce à cette méthodologie complète et rigoureuse, les modèles résultants sont bien positionnés pour fournir des prédictions fiables de la contribution des PRF à la résistance au cisaillement dans des applications pratiques d'ingénierie. Ces prédictions précises peuvent éclairer les décisions de conception, optimiser l'utilisation des ressources et assurer la sécurité et la durabilité des structures renforcées par PRF.

Cette étude jette les bases d'une adoption plus large des techniques d'apprentissage automatique dans le domaine du renforcement des structures par PRF. Les résultats et les analyses présentés dans le chapitre suivant mettront en lumière les avancées significatives

réalisées grâce à cette approche novatrice, ouvrant la voie à de nouvelles perspectives pour l'ingénierie des structures durables et résilientes.

CHAPITRE 05

Résultats et discussions.

5.1 Introduction

Ce chapitre présente une étude approfondie de l'application des techniques d'apprentissage automatique avancées pour prédire la contribution à la résistance au cisaillement des composites PRF collés extérieurement sur des poutres en BA. Après un processus rigoureux d'optimisation des hyperparamètres, divers modèles d'apprentissage automatique ont été développés, entraînés et évalués à l'aide de tous l'ensemble de données expérimentales englobant 394 spécimens de poutres en BA renforcées avec diverses configurations de PRF.

Les capacités prédictives des différents modèles sont évaluées de manière approfondie à l'aide d'une suite complète de métriques de performance statistiques et de représentations visuelles. L'étude explore l'impact de l'incorporation des contraintes de monotonie basées sur les comportements physiques connus des paramètres d'entrée, un aspect crucial pour garantir le respect des principes théoriques et la cohérence des prédictions. Des investigations basées sur des scénarios sont menées pour évaluer de manière approfondie la capacité des modèles à saisir et à représenter avec précision les relations physiques connues régissant la contribution au cisaillement des PRF, telles que les effets de la résistance à la compression du béton, de la profondeur effective des poutres, de l'épaisseur des PRF et du taux d'armature transversale en acier.

Enfin, une évaluation comparative rigoureuse est réalisée entre le modèle d'apprentissage automatique le plus performant et les directives et codes de conception largement adoptés pour le renforcement au cisaillement par PRF. Cette comparaison exhaustive vise à démontrer la supériorité potentielle des modèles d'apprentissage automatique en termes de précision prédictive, de cohérence et de respect des principes théoriques sous-jacents.

Cette étude approfondie vise à mettre en évidence le potentiel des techniques d'apprentissage automatique, en particulier celles intégrant des connaissances du domaine et des contraintes physiques, pour prédire avec précision et fiabilité la contribution à la résistance au cisaillement des PRF dans les poutres en BA. Les résultats obtenus contribueront à optimiser la conception et les performances des systèmes de renforcement au cisaillement par PRF, améliorant ainsi la sécurité structurelle, la fiabilité et la rentabilité des infrastructures en BA renforcées par PRF.

5.2 Performance des modèles d'apprentissage automatique avancés

Après le processus rigoureux d'optimisation bayésienne des hyperparamètres détaillé dans le chapitre précédent, les modèles finaux d'apprentissage automatique ont été entraînés sur

l'ensemble des 314 échantillons de données d'entraînement, en utilisant leurs configurations d'hyperparamètres optimisées respectives. Cette approche d'entraînement exhaustive a permis de s'assurer que les modèles exploitaient efficacement la totalité des données disponibles afin d'établir des relations prédictives robustes entre les caractéristiques d'entrée et la variable cible, à savoir la contribution à la résistance au cisaillement des PRF collés extérieurement. Par la suite, les capacités prédictives des six modèles d'apprentissage automatique développés ont été minutieusement évaluées à l'aide de l'ensemble complet de métriques de performance décrites dans le précédent chapitre.

Le [Tableau 5.1](#) présente une ventilation détaillée des métriques de performance obtenues par les six modèles lors des phases d'entraînement et de test. Les métriques de la phase d'entraînement donnent un aperçu de la capacité des modèles à apprendre et à capturer les tendances présentes dans les données d'entraînement, tandis que les résultats de la phase de test servent de référence ultime pour une évaluation impartiale de la capacité de généralisation de chaque modèle sur des données inédites, un aspect crucial pour les applications pratiques.

Tableau 5.1 — Détails exhaustifs des mesures de performance pour chaque modèle dans les phases d'entraînement et de test.

Modèle	Phase	Prédiction de V_f						$V_{f,exp}/V_{f,préd}$	
		R ²	KGE	MAE	RMSE	CI	OI	MV	CV (%)
XGB	Entraînement	0.91	0.94	15.28	25.21	0.93	0.93	1,01	33.05
	Test	0.86	0.89	15.77	22.08	0.90	0.90	1.21	43.24
DNN	Entraînement	0.94	0.94	11.84	20.20	0.96	0.95	0.95	34.72
	Test	0.86	0.89	15.06	22.00	0.89	0.90	1.02	41.04
ENSM	Entraînement	0.94	0.94	12.09	20.46	0.95	0.95	0.96	30.80
	Test	0.89	0.91	14.52	20.04	0.91	0.92	1.07	39.72
MXGB	Entraînement	0.95	0.96	09.32	18.31	0.97	0.96	1.01	20.94
	Test	0.89	0.93	15.23	20.00	0.91	0.92	1.14	47.24
CMNN	Entraînement	0.91	0.89	16.44	25.20	0.93	0.93	0.97	41.30
	Test	0.90	0.92	14.12	19.11	0.92	0.92	1.01	44.94
MENSM	Entraînement	0.95	0.95	11.84	19.07	0.96	0.96	0.96	27.39
	Test	0.91	0.93	13.88	18.13	0.93	0.93	1.03	36.89

Globalement, les résultats soulignent le potentiel des techniques d'apprentissage automatique pour prédire avec précision la contribution à la résistance au cisaillement des PRF, comme en témoignent les métriques de performance favorables obtenues par tous les modèles lors des phases d'entraînement et de test. Cependant, des différences notables sont apparues entre les

modèles, mettant en évidence l'impact des choix architecturaux, des stratégies d'ensemble et de l'incorporation de contraintes monotones basées sur les comportements physiques connus.

Parmi les modèles de base, XGB et DNN ont montré des caractéristiques de performance distinctes. Pendant la phase d'entraînement, DNN a surpassé XGB, obtenant des mesures d'erreur plus faibles (MAE = 11,84 kN vs 15,28 kN pour XGB, RMSE = 20,20 kN vs 25,21 kN pour XGB), une meilleure explication de la variance ($R^2 = 0,94$ vs 0,91) et des indices de performance globale supérieurs (CI = 0,96, OI = 0,95 vs CI = 0,93, OI = 0,93). Cela suggère que l'architecture de réseau de neurones profond de DNN était mieux à même de capturer les relations complexes et non linéaires présentes dans les données d'entraînement par rapport au modèle XGB basé sur les arbres. Cependant, sur l'ensemble de test, qui évalue la généralisation aux scénarios inédits, l'écart de performance entre XGB et DNN s'est réduit. Les deux modèles ont atteint des capacités d'explication de la variance similaires ($R^2 = 0,86$ et KGE = 0,89), indiquant un accord comparable avec les données observées. DNN a montré des mesures d'erreur légèrement inférieures (MAE = 15,06 kN vs 15,77 kN pour XGB, RMSE = 22,00 kN vs 22,08 kN pour XGB). Bien que les deux modèles aient présenté un biais conservateur, avec des ratios moyens des valeurs expérimentales sur les valeurs prédites supérieurs à 1,0, DNN a montré un ratio moyen inférieur (1,02 vs 1,21 pour XGB) et une variabilité de prédiction plus faible, avec un coefficient de variation (CV) de 41,04 % contre 43,24 % pour XGB. Ces résultats suggèrent que, bien que DNN ait excellé dans l'apprentissage des données d'entraînement, sa capacité de généralisation aux scénarios inédits était comparable à celle de XGB, avec un léger avantage en termes de précision et de cohérence des prédictions.

L'incorporation de contraintes monotones basées sur les comportements physiques connus des paramètres d'entrée, telle qu'elle a été mise en œuvre dans les modèles MXGB et CMNN, a permis d'obtenir des améliorations notables des performances par rapport à leurs homologues non monotones. Pendant l'entraînement, MXGB a atteint les meilleures métriques parmi tous les modèles ($R^2 = 0,95$, KGE = 0,96, MAE = 9,32 kN, RMSE = 18,31 kN, CI = 0,97, OI = 0,96), avec un faible CV de 20,94 %, indiquant une excellente explication de la variance, de faibles erreurs de prédiction et une grande cohérence. CMNN a également montré de solides performances d'entraînement, bien qu'inférieures à celles de MXGB. Sur l'ensemble de test, CMNN a légèrement surpassé MXGB, émergeant comme le meilleur modèle de base. CMNN a atteint un R^2 de 0,90, le plus élevé parmi les modèles de base, et a présenté les mesures d'erreur les plus faibles (MAE = 14,12 kN, RMSE = 19,11 kN) ainsi que l'indice de

performance globale le plus élevé (CI = 0,92) parmi les modèles de base. De plus, les deux modèles ont présenté un biais conservateur (ratios moyens > 1,0), mais CMNN a montré un ratio moyen inférieur (1,01 vs 1,14 pour MXGB) et un CV inférieur (44,94 % vs 47,24 % pour MXGB), indiquant un biais conservateur plus faible et des prédictions plus cohérentes par rapport à MXGB. Ces améliorations peuvent être attribuées aux contraintes monotones, qui ont obligé les modèles à apprendre des relations entre les caractéristiques d'entrée et la variable cible conformes au comportement physique connu. En limitant l'espace de recherche du modèle aux fonctions monotones, le risque de sur-apprentissage des tendances fortuites a été réduit, conduisant à une meilleure performance de généralisation.

Les modèles d'ensemble, ENSM et MENSM, ont constamment surpassé leurs modèles de base constitutifs sur diverses métriques de performance. Pendant l'entraînement, ENSM a obtenu des scores plus élevés que XGB et DNN, avec un R^2 de 0,94, un KGE de 0,94 et de faibles mesures d'erreur (MAE = 12,09 kN, RMSE = 20,46 kN), ainsi que des valeurs de CI et OI de 0,95. De même, MENSM a montré une précision d'entraînement exceptionnelle, dépassant légèrement MXGB, avec un R^2 de 0,95, un KGE de 0,95, une MAE de 11,84 kN, une RMSE de 19,07 kN et des CI/OI de 0,96. Sur l'ensemble de test, MENSM s'est révélé le modèle le plus performant dans l'ensemble, atteignant un R^2 de 0,91, un KGE de 0,93, une MAE de 13,88 kN, une RMSE de 18,13 kN et des CI/OI de 0,93. Fait notable, MENSM a présenté la plus faible variabilité de prédiction, avec un CV de 36,89 % sur l'ensemble de test, le plus bas parmi tous les modèles. Cela a renforcé les avantages potentiels de l'incorporation de contraintes de monotonie dans les cadres d'ensemble. ENSM a également bien performé sur l'ensemble de test, mais s'est classé légèrement derrière MENSM, atteignant un R^2 de 0,89, un KGE de 0,91, une MAE de 14,52 kN, une RMSE de 20,04 kN et des CI/OI de 0,91-0,92. La réussite des modèles d'ensemble peut être attribuée à leur capacité à tirer parti des forces diverses des modèles de base individuels tout en atténuant leurs faiblesses, réduisant efficacement l'impact des biais et des variances individuels des modèles, conduisant à des prédictions plus robustes et précises.

5.3 Interprétation visuelle des résultats

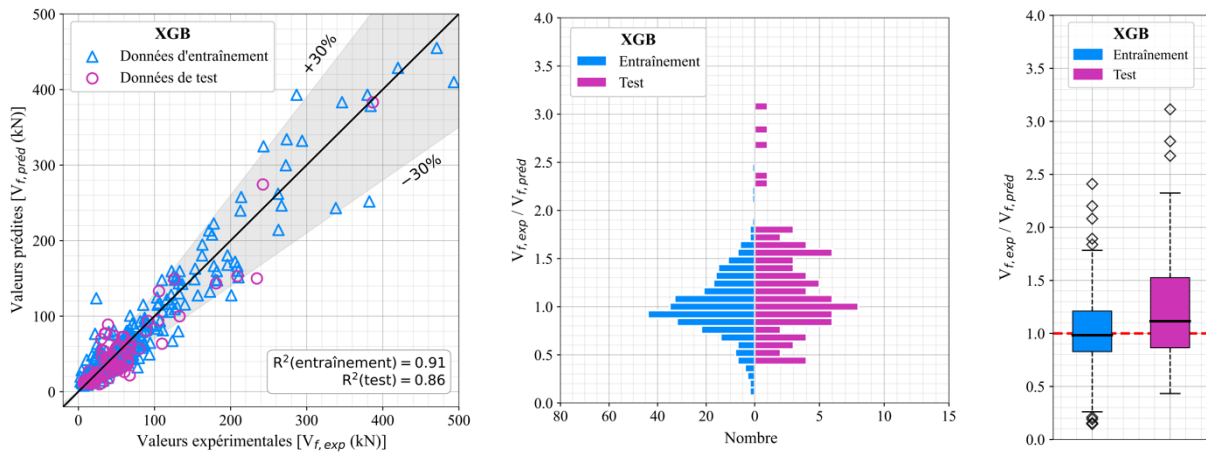
Pour compléter l'ensemble complet de métriques de performance numériques présentées dans le [Tableau 5.1](#), des représentations visuelles ont été générées afin de faciliter une interprétation plus intuitive des capacités prédictives des modèles. La [Fig. 5.1](#) offre une perspective multidimensionnelle sur les performances de chaque modèle à travers trois éléments de visualisation distincts, fournissant collectivement une compréhension globale des

performances prédictives du modèle, permettant une évaluation holistique de ses forces, faiblesses et domaines d'amélioration potentiels.

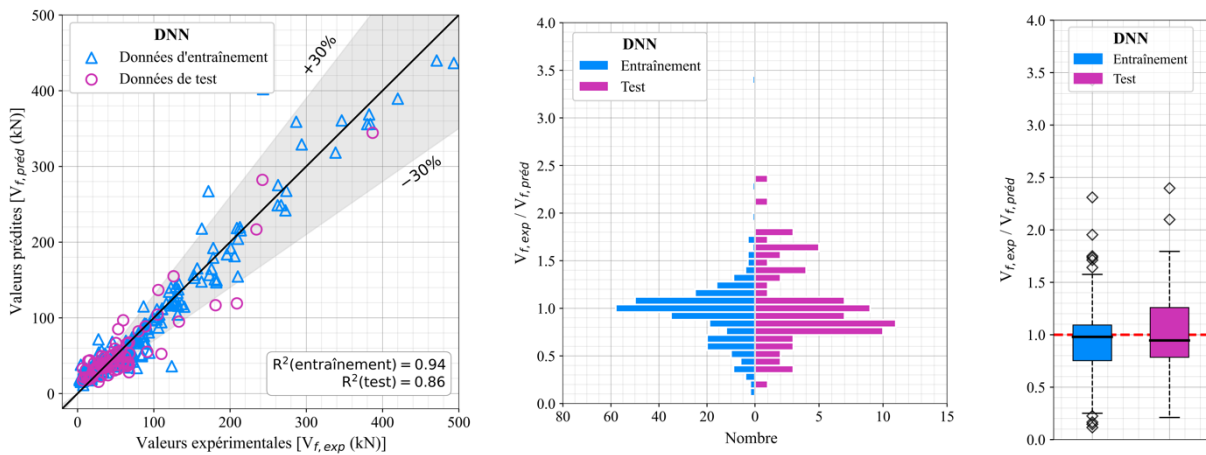
La première colonne représente des nuages de points comparant les valeurs prédites de V_f à leurs homologues expérimentaux correspondants. Un modèle idéal présenterait des points de données regroupés étroitement le long de la ligne diagonale ($y = x$), indiquant une forte concordance entre les prédictions et les observations. Les écarts par rapport à cette ligne, en particulier une plus grande dispersion des points, suggèrent des incohérences potentielles et des faiblesses dans la capacité à capturer précisément les relations sous-jacentes.

La deuxième colonne visualise la distribution du ratio $V_{f,exp}/V_{f,préd}$, qui sert de mesure directe du biais et de la variabilité du modèle. Une distribution normale centrée autour de 1,0 signifie un biais systématique minimal, le modèle ne surestimant ni ne sous-estimant systématiquement la contribution des PRF. L'étendue de la distribution reflète la cohérence du modèle, une distribution plus resserrée indiquant une variabilité de prédiction plus faible et une fiabilité plus élevée dans divers scénarios.


La troisième colonne présente des diagrammes en boîte ou Boîte à moustaches (boxplots), offrant une représentation concise mais informative de la distribution du ratio $V_{f,exp}/V_{f,préd}$. L'étendue interquartile (IQR), représentée par l'étendue de la boîte, capture les 50 % centraux des données, donnant un aperçu de la cohérence globale du modèle. Une boîte plus étroite indique une variabilité de prédiction plus faible, tandis qu'une boîte plus large suggère une incohérence plus élevée. La ligne médiane à l'intérieur de la boîte devrait idéalement s'aligner sur 1,0, signifiant aucune sur- ou sous-estimation systématique. Les écarts par rapport à 1,0 indiquent des biais potentiels, les valeurs supérieures à 1,0 suggérant une sous-estimation et les valeurs inférieures à 1,0 indiquant des tendances à la surestimation. Les moustaches s'étendent de la boîte, englobant généralement les données dans 1,5 fois l'IQR, fournissant un aperçu de la répartition des 25 % restants des points de données. Les valeurs aberrantes, représentées par des points individuels au-delà des moustaches, peuvent signaler des problèmes potentiels de qualité des données, une variabilité inhérente ou des limites dans la généralisation du modèle. Bien que la présence de quelques valeurs aberrantes soit attendue, un nombre important peut justifier une investigation plus approfondie.



a) XGBoost (XGB)



b) Réseaux de neurones profonds (DNN)



c) Modèle d'ensemble (ENSM)

Fig. 5.1 — Représentation visuelle de la performance prédictive des modèles d'apprentissage automatique : (Colonne 1) Contribution au cisaillement prédite par rapport à la contribution expérimentale du PRF, (Colonne 2) Distribution du rapport $V_{f,exp}/V_{f,préd}$, et (Colonne 3) Diagramme en boîte du rapport $V_{f,exp}/V_{f,préd}$.

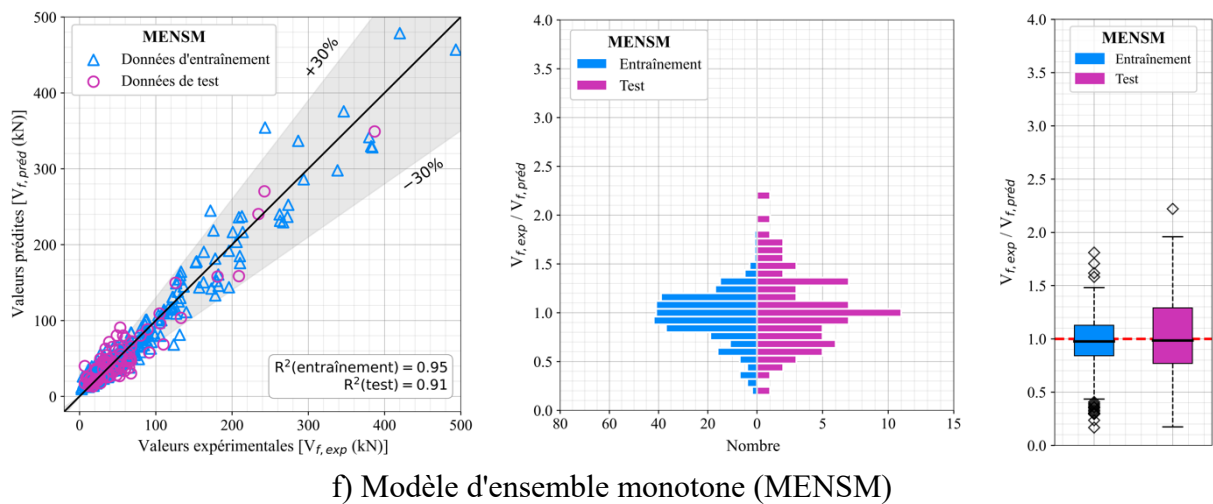
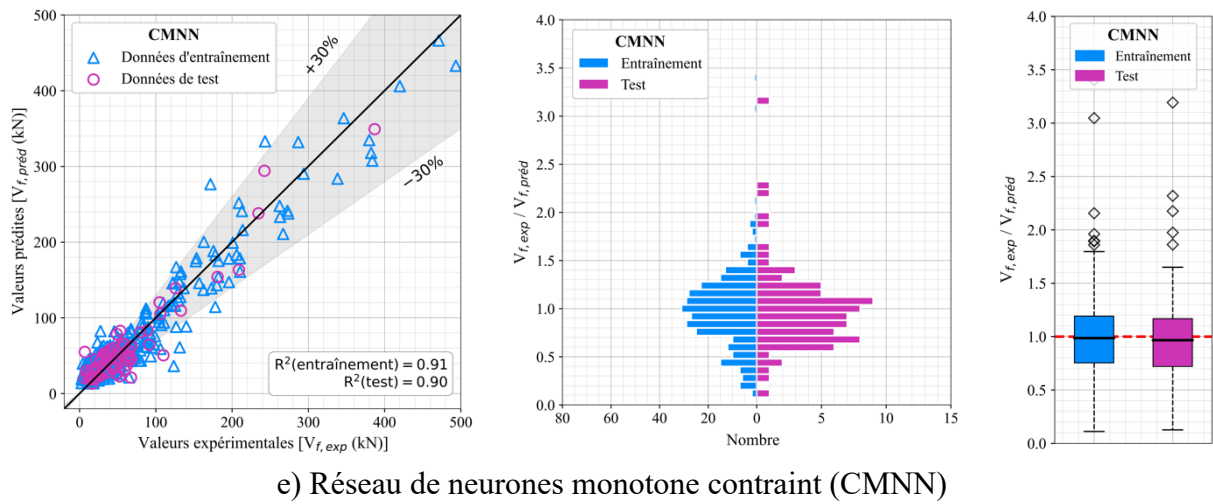
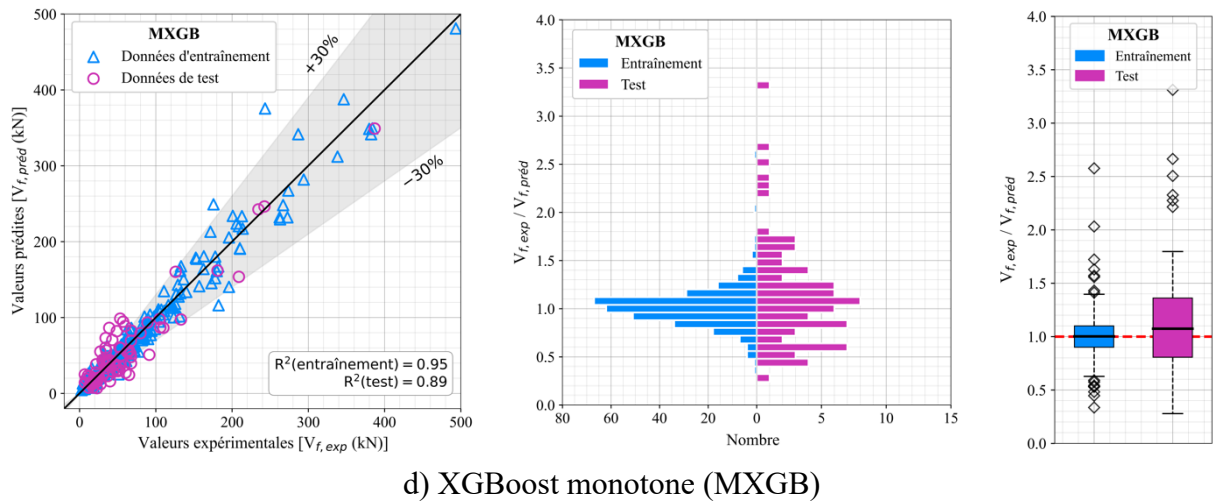


Fig. 5.1 — (Suite)

En examinant les nuages de points, il devient évident que le modèle MENSM présente le regroupement le plus serré des points de données le long de la ligne diagonale, indiquant la meilleure concordance entre les contributions au cisaillement des PRF prédites et expérimentales. Les modèles ENSM, CMNN et MXGB affichent également un regroupement relativement serré, suggérant leur capacité à capturer efficacement les relations sous-jacentes. En revanche, les modèles XGB et DNN présentent des schémas légèrement plus dispersés dans leurs nuages de points, particulièrement perceptibles dans les données de test, indiquant une marge d'amélioration potentielle de leurs capacités prédictives.

Les distributions des ratios et les boîtes à moustaches corroborent les observations des nuages de points et mettent en évidence les performances relatives des modèles dans la phase de test. Les distributions et boîtes à moustaches montrent que CMNN surpasse MXGB, avec une distribution plus resserrée centrée plus près de 1,0 et une étendue interquartile plus étroite avec moins de valeurs aberrantes, indiquant un biais systématique plus faible, une cohérence plus élevée et une meilleure précision dans les prédictions de CMNN par rapport à MXGB. De même, les distributions des ratios et les boîtes à moustaches démontrent la performance légèrement supérieure de DNN sur XGB, DNN présentant une distribution plus favorable et une étendue interquartile plus resserrée avec moins de valeurs aberrantes, suggérant une variabilité d'erreur plus faible, des biais potentiels moindres et une précision supérieure à XGB.

Ces représentations visuelles renforcent les métriques de performance numériques présentées dans le [Tableau 5.1](#), mettant en évidence les avantages de la modélisation par ensemble et les bénéfices potentiels de l'incorporation de contraintes de monotonie basées sur les comportements physiques connus. Bien que tous les modèles aient démontré des capacités prédictives raisonnables, le modèle d'ensemble monotone MENSM, qui combine les forces des modèles de base monotones MXGB et CMNN, démontre de manière constante les meilleures capacités prédictives à travers toutes les visualisations, émergeant comme le modèle le plus performant dans l'ensemble. Cependant, le choix du modèle le plus approprié dépend en fin de compte des exigences et des priorités spécifiques de l'application pratique. Le processus de prise de décision doit évaluer et équilibrer attentivement les compromis entre la précision prédictive, l'interprétabilité du comportement du modèle et les contraintes ou exigences spécifiques au domaine. Par conséquent, une validation et des tests supplémentaires sur divers scénarios du monde réel sont recommandés pour garantir l'adéquation et la fiabilité du modèle choisi dans les applications pratiques, car les performances des modèles

d'apprentissage automatique peuvent être influencées par des facteurs tels que la qualité des données, les changements de distribution et les cas limites imprévus rencontrés dans les déploiements en conditions réelles.

5.4 Application des modèles d'apprentissage automatique avancés

Tirant parti de l'évaluation complète des performances et de l'interprétation visuelle présentées dans les sections 5.2 et 5.3, cette section explore plus en détail l'applicabilité pratique et le comportement des modèles d'apprentissage automatique développés à travers des investigations systématiques basées sur des scénarios. Ces scénarios examinent les relations complexes entre la contribution à la résistance au cisaillement des PRF prédite et les paramètres d'entrée cruciaux, éclairant le comportement des modèles et servant de lien essentiel entre le processus rigoureux de développement et d'évaluation des modèles et leur déploiement potentiel dans des applications d'ingénierie du monde réel.

L'analyse comprend trois scénarios distincts, chacun conçu stratégiquement pour isoler et examiner la relation entre la contribution à la résistance au cisaillement des PRF prédite par les modèles et deux paramètres d'entrée simultanément. Dans chaque scénario, deux paramètres d'entrée sélectionnés ont été systématiquement variés tout en maintenant les autres variables constantes en utilisant différentes géométries de poutres, configurations et schémas de distribution du renforcement par PRF, ainsi que la présence ou l'absence d'armatures en acier internes (comme décrit dans le [Tableau 5.2](#)). Cette approche a permis une évaluation ciblée des effets individuels et combinés des paramètres d'entrée sélectionnés sur les prédictions des modèles. Par conséquent, des connaissances précieuses ont été acquises sur la capacité des modèles à capturer et représenter avec précision les comportements physiques et les relations connus régissant la contribution à la résistance au cisaillement des PRF discutés dans le chapitre précédent. Le premier scénario, illustré à la [Fig. 5.2](#), a exploré la relation entre la contribution à la résistance au cisaillement des PRF et la résistance à la compression du béton (f_{ck}) pour différentes épaisseurs de PRF (t_f). Le deuxième scénario, représenté sur la [Fig. 5.3](#), s'est concentré sur la relation entre la contribution à la résistance au cisaillement des PRF et la profondeur effective des poutres (d) pour différentes hauteurs de feuille de PRF (h_f). Enfin, le troisième scénario, présenté à la [Fig. 5.4](#), a évalué l'effet du taux d'armature transversale en acier (ρ_{sw}) sur la contribution à la résistance au cisaillement des PRF pour différentes épaisseurs de PRF (t_f).

Tableau 5.2 — Résumé des variations des paramètres d'entrée pour l'investigation basée sur des scénarios de la contribution au cisaillement des PRF.

Paramètre	Scénario 1	Scénario 2	Scénario 3
Géométrie de la poutre	Rectangulaire	Rectangulaire	Section T
Configuration de renforcement	Collage latéral (S)	Chemisage en U	Enveloppement (W)
d (mm)	260	De 300 à 550 avec un pas de 10	350
a/d	3	3	3
f_{ck} (MPa)	De 20 à 60 avec un pas de 1	20	20
ρ_{sw}	0.3	0	De 0 à 0,8 avec un pas de 0,01
h_f (mm)	300	250–275–300–325–350	300
b_f / s_f	0.5	0.75	1
t_f (mm)	0.1–0.2–0.3–0.4	0.2	0.1–0.2–0.3–0.4
E_f (GPa)	231	231	231
ε_{fu}	15.8	15.8	15.8
α_f (°)	90	45	90

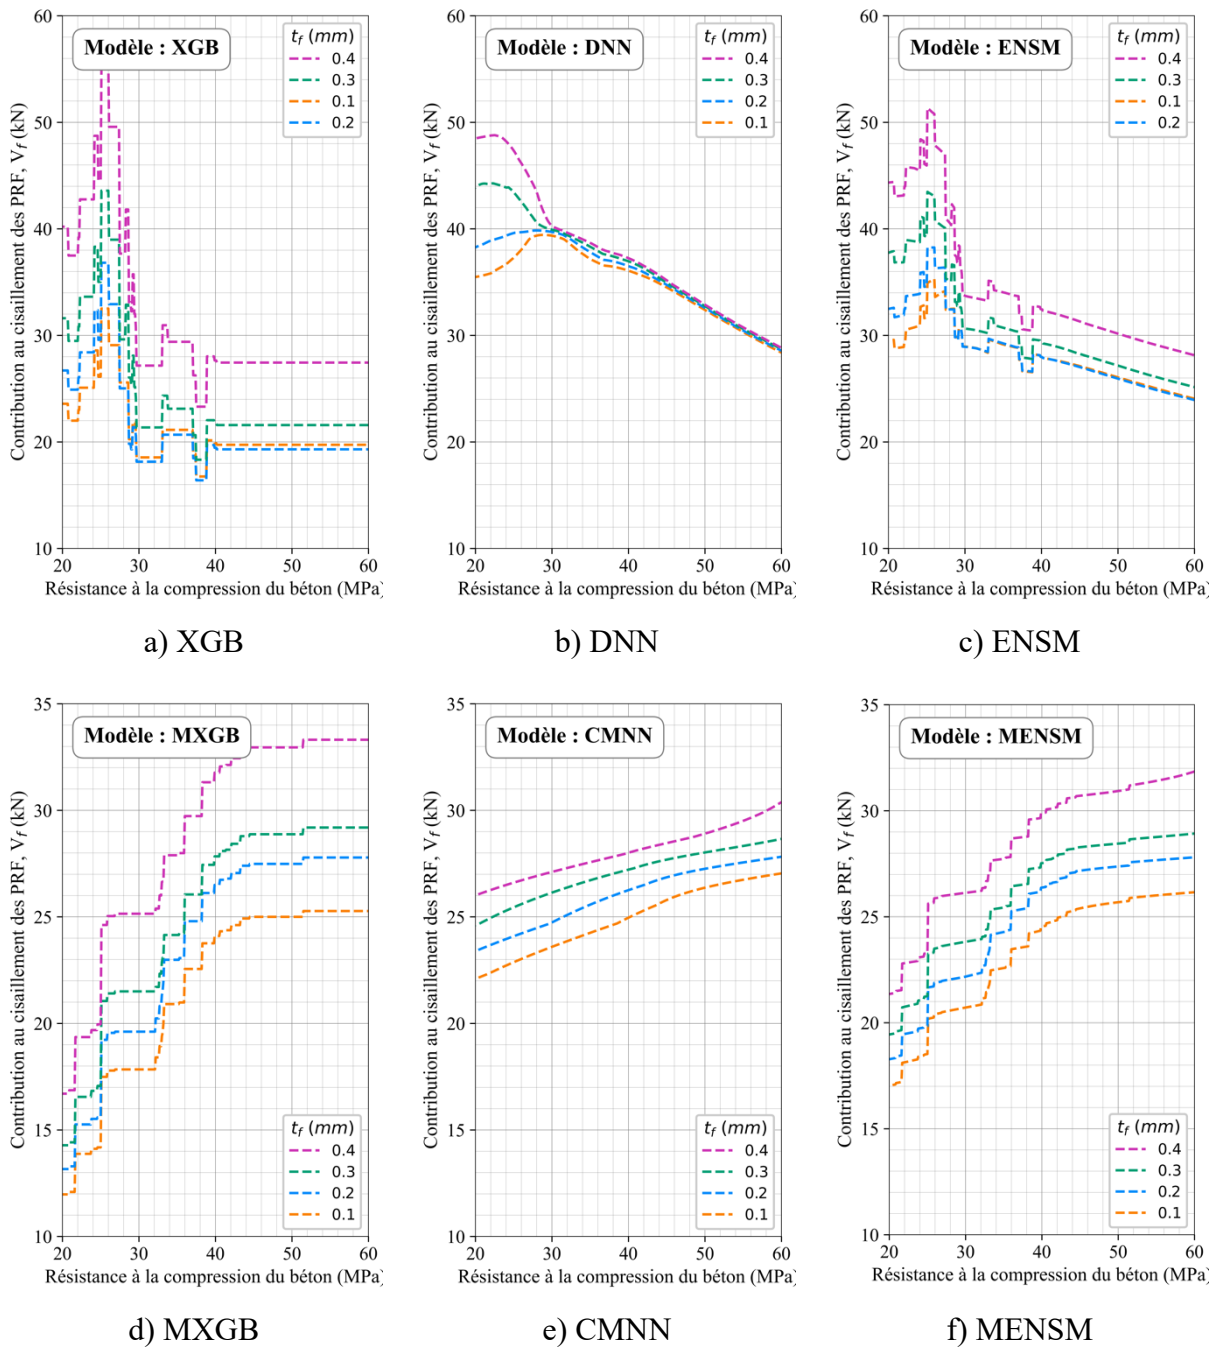


Fig. 5.2 — Contribution au cisaillement des PRF vs. Résistance à la compression du béton (f_{ck}) pour différentes épaisseurs de PRF (t_f).

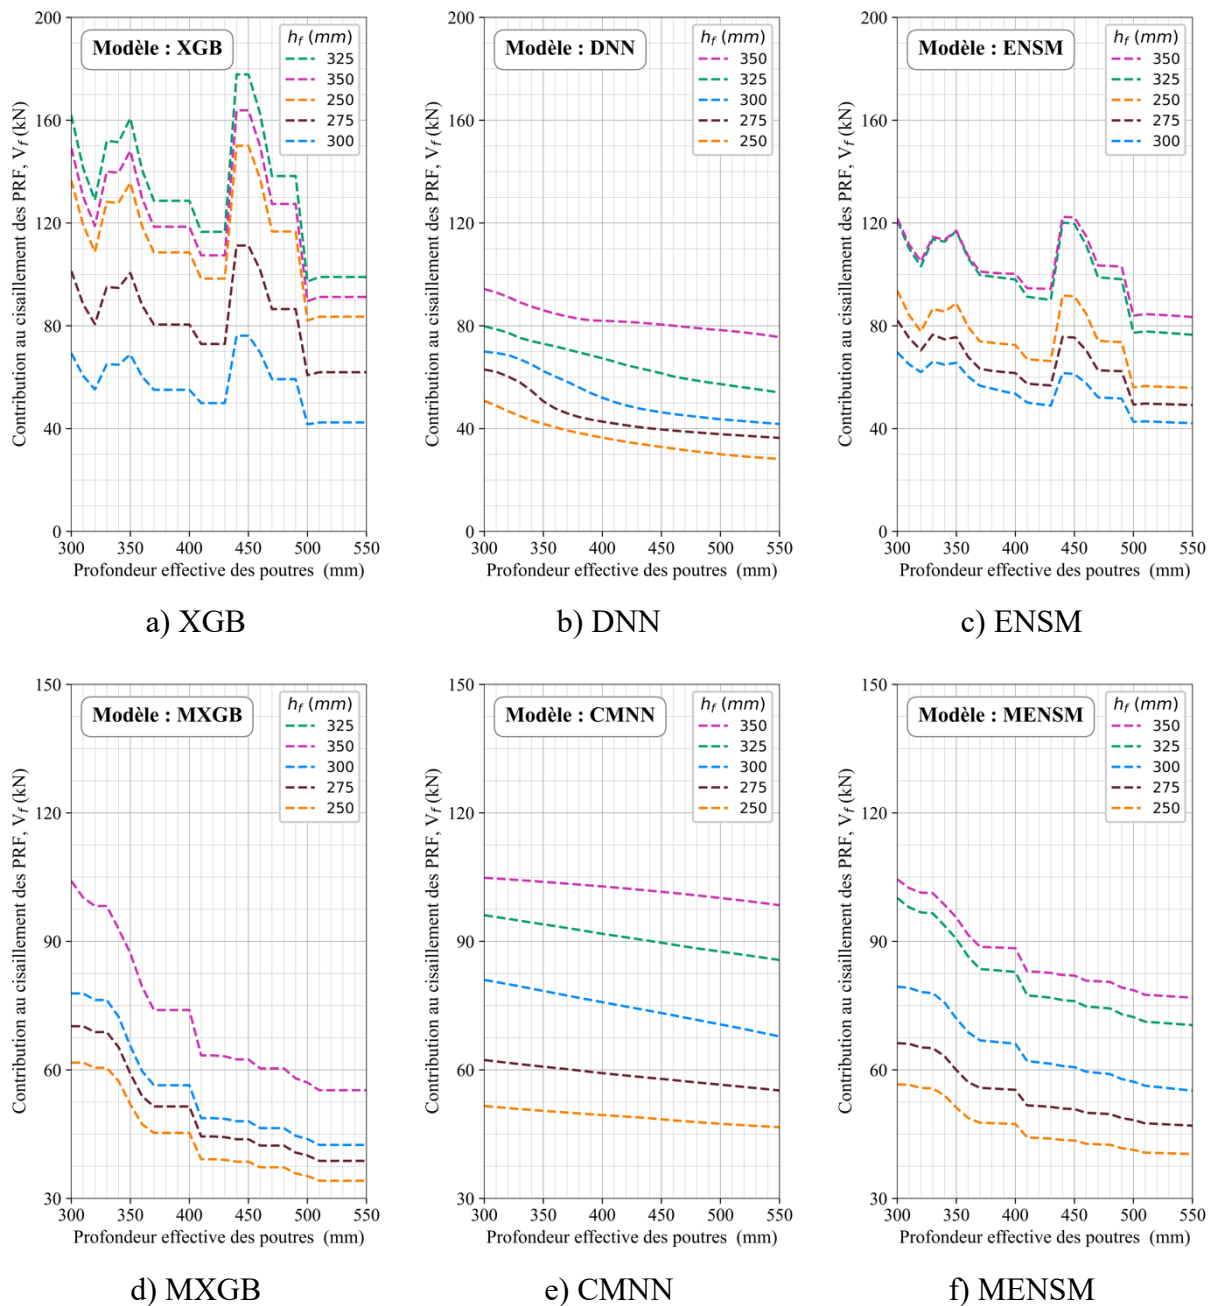


Fig. 5.3 — Contribution au cisaillement des PRF vs. Profondeur effective de la poutre (d) pour différentes hauteurs de feuille de PRF (h_f).

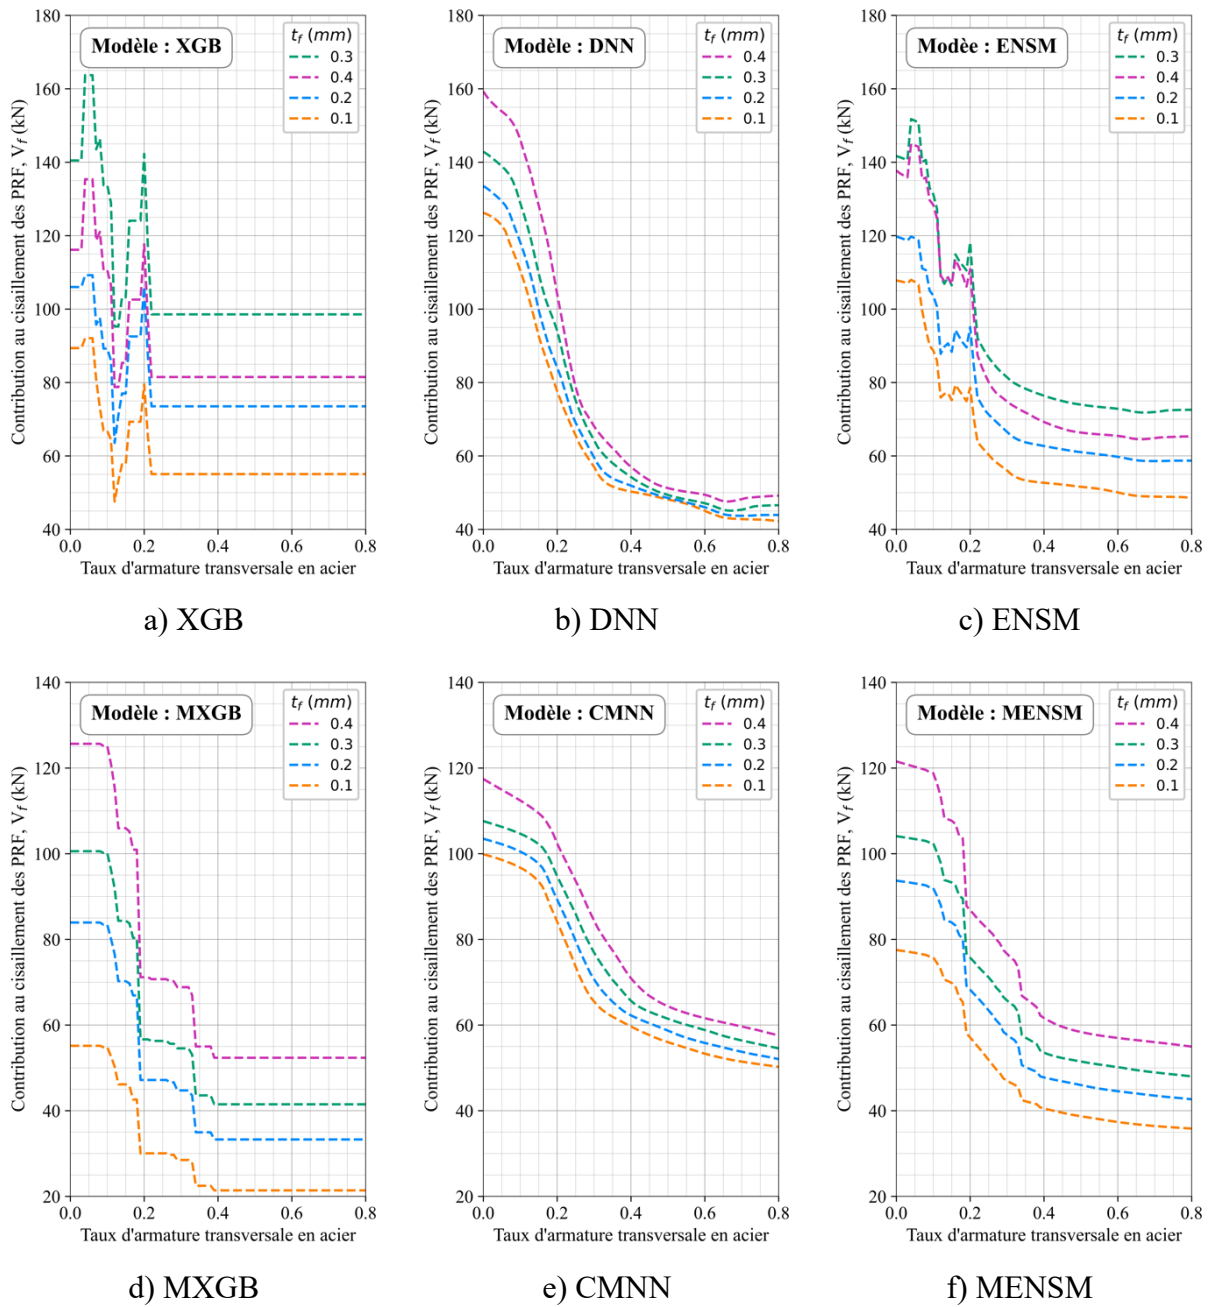


Fig. 5.4 — Contribution au cisaillement des PRF vs. Taux d'armature transversale en acier (ρ_{sw}) pour différentes épaisseurs de PRF (t_f).

Les investigations basées sur des scénarios ont révélé des aperçus critiques sur les capacités et les limites des modèles à représenter avec précision les comportements physiques connus et les relations régissant la contribution à la résistance au cisaillement des PRF. Tout d'abord, les modèles de base non monotones, XGB et DNN, ont montré des comportements distincts. Le modèle XGB n'a pas réussi à saisir et à représenter avec précision les comportements physiques et les relations connus à travers les trois scénarios, présentant des tendances erratiques où la contribution à la résistance au cisaillement des PRF prédite augmentait parfois et diminuait autrefois en réponse aux changements dans les paramètres d'entrée, résultant en des courbes irrégulières et non lisses, s'écartant des tendances anticipées. Cette incohérence peut être attribuée à plusieurs facteurs, notamment la taille limitée et la variabilité des données d'entraînement (314 points de données) combinées à la dimensionnalité élevée de l'espace d'entrée (11 paramètres d'entrée) ; les données disponibles peuvent avoir été insuffisantes pour saisir de manière fiable les relations complexes et non linéaires régissant la contribution à la résistance au cisaillement des PRF. De plus, la variabilité intrinsèque et les incertitudes épistémiques inhérentes aux données expérimentales, dues à des facteurs tels que les différences dans les configurations expérimentales, les propriétés des matériaux et les incertitudes de mesure, peuvent introduire du bruit et des incohérences susceptibles d'entraver la capacité du modèle à discerner et à généraliser les véritables relations sous-jacentes. En outre, en tant que modèle purement basé sur les données, XGB n'incorpore pas de contraintes explicites ou de connaissances préalables sur les comportements physiques et les relations monotones attendus, et cette absence d'orientation spécifique au domaine peut conduire à des prédictions erronées ou incohérentes, en particulier dans les régions de l'espace d'entrée où les données sont clairsemées ou bruitées.

En revanche, le modèle DNN a démontré une performance plus nuancée, saisissant et représentant avec précision les comportements physiques et les relations connus dans le deuxième et le troisième scénario. Cette observation renforce les conclusions des Sections 5.2 et 5.3, qui suggéraient que l'architecture de réseau de neurones profond DNN était mieux équipée pour capturer les relations complexes et non linéaires présentes dans les données par rapport au modèle XGB basé sur les arbres, et présentait en conséquence de meilleures capacités de généralisation sur des scénarios inédits. Cependant, le modèle DNN a rencontré des difficultés dans le premier scénario impliquant la relation entre la contribution à la résistance au cisaillement des PRF et la résistance à la compression du béton (f_{ck}), mettant en

évidence les limites potentielles d'une dépendance exclusive aux architectures d'apprentissage profond pour généraliser avec précision sur divers scénarios.

En conséquence des limites des modèles de base individuels, le modèle d'ensemble, ENSM, qui combinait les prédictions de XGB et DNN, n'a pas réussi à saisir et à représenter de manière cohérente les comportements physiques et les relations attendus dans les trois scénarios. Malgré les avantages potentiels de la modélisation par ensemble pour atténuer les biais et les variances individuels des modèles, les faiblesses sous-jacentes des modèles constituants se sont propagées, résultant en une incapacité globale à représenter avec précision les relations attendues. Ce résultat souligne l'importance de s'assurer que les modèles de base dans un cadre d'ensemble peuvent représenter avec précision les principes physiques sous-jacents avant de les combiner, car les performances de l'ensemble restent tributaires de la qualité et de la cohérence des modèles de base constituants sous-jacents.

Contrairement aux modèles non monotones, les trois modèles monotones (MXGB, CMNN et MENSM) ont démontré une capacité remarquable à maintenir et représenter avec précision les comportements physiques et relations connus à travers les trois scénarios. Cette capacité provient de l'encodage a priori des relations monotones anticipées entre les caractéristiques d'entrée et la variable cible, contraignant efficacement l'espace de recherche des modèles aux fonctions monotones. En limitant les modèles à apprendre dans les limites de ces contraintes monotones, le risque de sur-apprentissage des tendances fortuites ou des comportements incohérents a été atténué, conduisant à de meilleures performances de généralisation et à un meilleur alignement avec les connaissances du domaine.

Cependant, malgré la réussite globale des modèles monotones, des différences notables sont apparues dans leurs comportements spécifiques. Un examen plus approfondi des prédictions du modèle MXGB a révélé des courbes de prédiction très irrégulières et non lisses, présentant des changements brusques (sauts) qui ne pouvaient pas être considérés comme appropriés pour les applications de conception en ingénierie (par exemple, dans le premier scénario, les modèles MXGB et MENSM présentent une augmentation soudaine et élevée de la contribution à la résistance au cisaillement des PRF pour différentes épaisseurs de PRF lorsque la résistance à la compression augmente de 24 à 25 MPa). Ce comportement est inhérent aux modèles basés sur les arbres, tels que XGBoost, qui fonctionnent en divisant récursivement l'espace des caractéristiques en régions distinctes, pouvant entraîner des discontinuités et des changements soudains dans les valeurs prédites aux frontières de ces régions - car l'induction d'arbres fonctionne en divisant sur les caractéristiques, puis en traitant

les enfants séparément, les résultats peuvent être très discontinus car les feuilles des "enfants gauche" et "droite" à chaque division peuvent produire des sorties très différentes, conduisant à des changements brusques dans la réponse du modèle. Bien que cette caractéristique puisse être acceptable dans certaines applications, elle est généralement indésirable en conception de structures, où des représentations lisses, continues et différentiables des processus physiques sous-jacents sont préférées.

À l'inverse, le modèle CMNN a montré des tendances de sensibilité lisses et logiques qui s'alignaient sur les principes de la mécanique du cisaillement des PRF et les observations expérimentales. En tirant parti de la capacité inhérente des réseaux de neurones à apprendre des fonctions continues et différentiables, le modèle CMNN a pu saisir efficacement les relations sous-jacentes tout en adhérant aux contraintes monotones imposées, à condition que les données d'entraînement et l'architecture du modèle soient conçues et configurées de manière appropriée.

Le modèle MENSM, construit comme une simple combinaison de MXGB et CMNN, a hérité de certaines des irrégularités et discontinuités observées dans le modèle MXGB, bien que dans une moindre mesure. Bien que l'approche d'ensemble ait atténué les faiblesses individuelles de ses modèles constitutifs, le comportement non lisse a persisté, limitant potentiellement l'adéquation du modèle pour les applications nécessitant des prédictions continues et différentiables.

Les investigations basées sur des scénarios ont souligné l'importance d'incorporer des connaissances spécifiques au domaine et des contraintes physiques dans les modèles d'apprentissage automatique développés pour des applications d'ingénierie. Bien qu'ils soient capables de saisir des relations complexes, les modèles non monotones ont eu du mal à représenter avec précision les comportements physiques connus, en particulier dans les régions où les données étaient clairsemées ou bruitées. Cette limitation met en évidence la nécessité d'un comportement monotone dans les modèles de conception, car cela garantit que les prédictions s'alignent sur les principes fondamentaux et les tendances attendues dérivées de considérations théoriques et d'observations expérimentales.

Les contraintes de monotonie améliorent les capacités de généralisation des modèles et renforcent leur interprétabilité et leur fiabilité, qui sont des facteurs cruciaux dans les applications d'ingénierie où la sécurité et la fiabilité sont d'une importance primordiale. En outre, le respect de critères spécifiques, notamment la représentation de relations continues et

différentiables qui saisissent avec précision les principes physiques sous-jacents, est impératif lors du développement de modèles de conception pour les applications d'ingénierie des structures. Dans ce contexte, le modèle CMNN est apparu comme le choix le plus préférable. En présentant des tendances lisses et attendues dans les scénarios examinés, le modèle CMNN a maintenu les relations monotones configurées et s'est aligné sur les principes de comportement au cisaillement sous-jacents pour les poutres renforcées par des PRF. Cette vérification confirme la capacité du modèle CMNN à apprendre des mécanismes de cisaillement globalement cohérents plutôt que d'interpoler simplement entre les points de données. Cette capacité souligne l'adéquation du modèle CMNN pour un déploiement pratique, car ses capacités d'extrapolation logiques et son respect des principes physiques connus augmentent la confiance dans ses prédictions, même pour des scénarios dépassant le cadre des données d'entraînement initiales.

En revanche, les courbes irrégulières et non lisses présentées par les modèles MXGB et MENSIM, caractérisées par des changements soudains ou des discontinuités, soulèvent des préoccupations quant à leur pertinence pour les applications de conception en ingénierie. Les changements brusques ou les discontinuités dans la résistance au cisaillement prédite pourraient potentiellement conduire à des conceptions non sécurisées ou trop conservatives, compromettant l'intégrité et l'efficacité des structures renforcées, à moins que de tels comportements ne puissent être étayés par des preuves empiriques rigoureuses ou des fondements théoriques bien établis.

Bien que les modèles non monotones aient montré des limites dans la capacité à saisir et à représenter avec précision les comportements physiques connus, leurs performances ne doivent pas être totalement écartées. Ces modèles pourraient encore trouver des applications dans des scénarios où le strict respect des relations monotones n'est pas une exigence critique ou lorsque l'accent est mis principalement sur l'obtention d'une précision prédictive élevée dans les limites de la distribution des données d'entraînement. Cependant, pour les applications de conception en ingénierie des structures qui privilégient la sécurité, la fiabilité et le respect des principes théoriques, le modèle CMNN émerge comme le choix le plus approprié parmi les modèles développés dans cette étude. Cette conclusion servira de base pour la section suivante, où les performances du modèle CMNN seront comparées aux directives de conception pour vérifier davantage sa supériorité pour les applications d'ingénierie des structures.

5.5 Évaluation comparative avec les codes de conception établis

Pour évaluer rigoureusement l'efficacité des modèles d'apprentissage automatique développés, en particulier le modèle CMNN le plus approprié, une évaluation comparative approfondie a été réalisée par rapport aux directives et codes de conception largement adoptés pour le renforcement au cisaillement par PRF décrits dans la Section 2.8 (chapitre 2). Pour cette évaluation comparative, θ est conservativement pris comme 45° pour permettre une comparaison directe entre les modèles avec des angles de treillis fixes et variables. De plus, certaines directives comme le [fib Bulletin 90](#) et le [CNR-DT200 R1.2013](#) prennent en compte l'effet du rayon de courbure (r_c) des poutres renforcées lors de la prédiction de V_f . Cependant, les données d'essai originales sur r_c ne sont souvent pas disponibles. Par conséquent, r_c est supposé égal à 10 mm indépendamment de la taille de la poutre, puisque 10 mm est la valeur minimale rapportée et donnera des résultats conservateurs, suivant la procédure de [D'Antino and Triantafillou \(2016\)](#). De plus, tous les facteurs de réduction de résistance sont fixés à l'unité pour permettre une comparaison directe entre les résultats expérimentaux et les valeurs prédites sans biais dû aux facteurs spécifiés par les codes.

L'exercice d'évaluation comparative a utilisé l'ensemble complet des données de 394 poutres en BA, englobant toutes les configurations de renforcement par PRF (enveloppées (W), en forme de U et collées sur les côtés (S)). Cet ensemble de données étendu a permis une évaluation approfondie, capturant les performances des modèles sur un large éventail de scénarios pratiques. L'évaluation a employé la suite de métriques de performance statistiques décrites dans le chapitre précédent. Les résultats, résumés dans le [Tableau 5.3](#), démontrent sans équivoque la supériorité du modèle CMNN sur les directives de conception existantes. Pour toutes les métriques statistiques et cas de test, englobant les configurations en forme de U, collées sur les côtés (S), totalement enveloppées (W) et toutes les configurations, le CMNN a systématiquement obtenu les meilleurs scores, mettant en évidence sa précision et sa robustesse remarquables.

De plus, la confirmation visuelle de la précision supérieure des prédictions du CMNN est fournie dans la [Fig. 5.5](#), qui présente les nuages de points comparant les valeurs de contribution au cisaillement des PRF (V_f) prédites à leurs mesures expérimentales correspondantes. Un examen attentif de ces nuages de points révèle que le modèle CMNN présente le regroupement le plus compact des points de données le long de la ligne diagonale, indiquant une concordance remarquablement forte entre ses prédictions et les contributions au

cisaillement des PRF empiriques pour toutes les configurations de renforcement. À l'inverse, les nuages de points pour les modèles des directives de conception existantes présentent une distribution plus dispersée des points, s'écartant de la ligne diagonale. Cette dispersion plus large suggère des incohérences et des limites potentielles pour saisir avec précision les relations complexes régissant la contribution au cisaillement des PRF dans divers scénarios.

Les résultats numériques et graphiques valident collectivement le modèle CMNN comme un outil hautement fiable et robuste pour prédire les contributions au cisaillement des PRF dans les poutres en BA, surpassant les directives de conception en termes de précision et de cohérence sur un large éventail de configurations de PRF.

Tableau 5.3 — Évaluation comparative : modèle CMNN vs. Dispositions des codes de conception.

Modèle	Config	#	Prédiction de V_f						$V_{f,exp}/V_{f,préd}$	
			R ²	KGE	MAE	RMSE	CI	OI	MV	CV (%)
ACI 440.2R-17	U	181	0,17	0,35	30,94	54,9	0,27	0,52	1,6	158,69
	S	80	0,04	0,63	31,84	46,23	0,57	0,41	1,22	86,25
	W	104	0,13	0,29	69,98	102,8	0,48	0,47	3,17	76,64
	All	365	0,24	0,48	42,26	70,53	0,39	0,55	1,96	121,72
CSA-S806.12	U	181	0,17	0,35	30,94	54,9	0,27	0,52	1,6	158,69
	S	94	-0,04	0,57	31,37	47,03	0,57	0,37	0,95	69,67
	W	104	0,31	0,45	58,21	91,41	0,55	0,57	2,11	76,49
	All	379	0,33	0,61	38,53	65,43	0,49	0,61	1,58	127,83
fib Bulletin 14	U	189	0,41	0,47	31,7	45,65	0,56	0,65	0,85	64,17
	S	101	-0,06	0,38	33,05	47,01	0,59	0,35	0,72	52,62
	W	104	0,61	0,81	45,52	68,78	0,78	0,74	1,11	53,41
	All	394	0,55	0,68	35,69	53,06	0,72	0,73	0,88	61,21
fib Bulletin 90	U	189	0,06	0,36	35,42	57,68	0,27	0,46	1,3	112,71
	S	—	—	—	—	—	—	—	—	—
	W	104	-0,13	0,27	83,17	117,04	0,21	0,33	2,32	75,36
	All	293	0,07	0,37	52,37	83,72	0,25	0,46	1,66	98,99
CNR-DT200 R1.2013	U	189	0,17	0,4	30,15	54,06	0,29	0,52	1,51	84,51
	S	101	0,15	0,65	25,74	42,02	0,63	0,47	1,22	76,79
	W	104	-0,04	0,32	79,41	112,44	0,47	0,38	3,39	61,99
	All	394	0,17	0,4	42,02	72,06	0,32	0,52	1,93	88,87
TR-55	U	189	0,19	0,33	29,18	53,44	0,28	0,53	1,62	147,92
	S	101	0,39	0,71	24,46	35,67	0,63	0,61	1,08	62,24
	W	104	-0,02	0,32	78,34	111,2	0,48	0,39	3,6	65,07
	All	394	0,21	0,39	40,95	70,43	0,34	0,54	2	114,68
JSCE	U	189	-4,45	-0,72	97,79	138,84	0,16	-1,89	0,53	95,03
	S	101	-25,47	-2,1	153,44	234,9	0,11	-12,81	0,42	88,4
	W	104	0,37	0,7	53,94	87,17	0,66	0,61	1,29	69
	All	394	-3,04	-0,32	100,48	159,36	0,19	-1,17	0,7	99,88
CMNN	U	189	0,88	0,87	15,66	21,02	0,9	0,91	0,98	50,82
	S	101	0,9	0,89	11,03	14,74	0,92	0,91	0,97	35,37
	W	104	0,9	0,9	21,34	34,42	0,93	0,92	1	29,13
	All	394	0,91	0,9	15,97	24,09	0,93	0,93	0,98	42,15

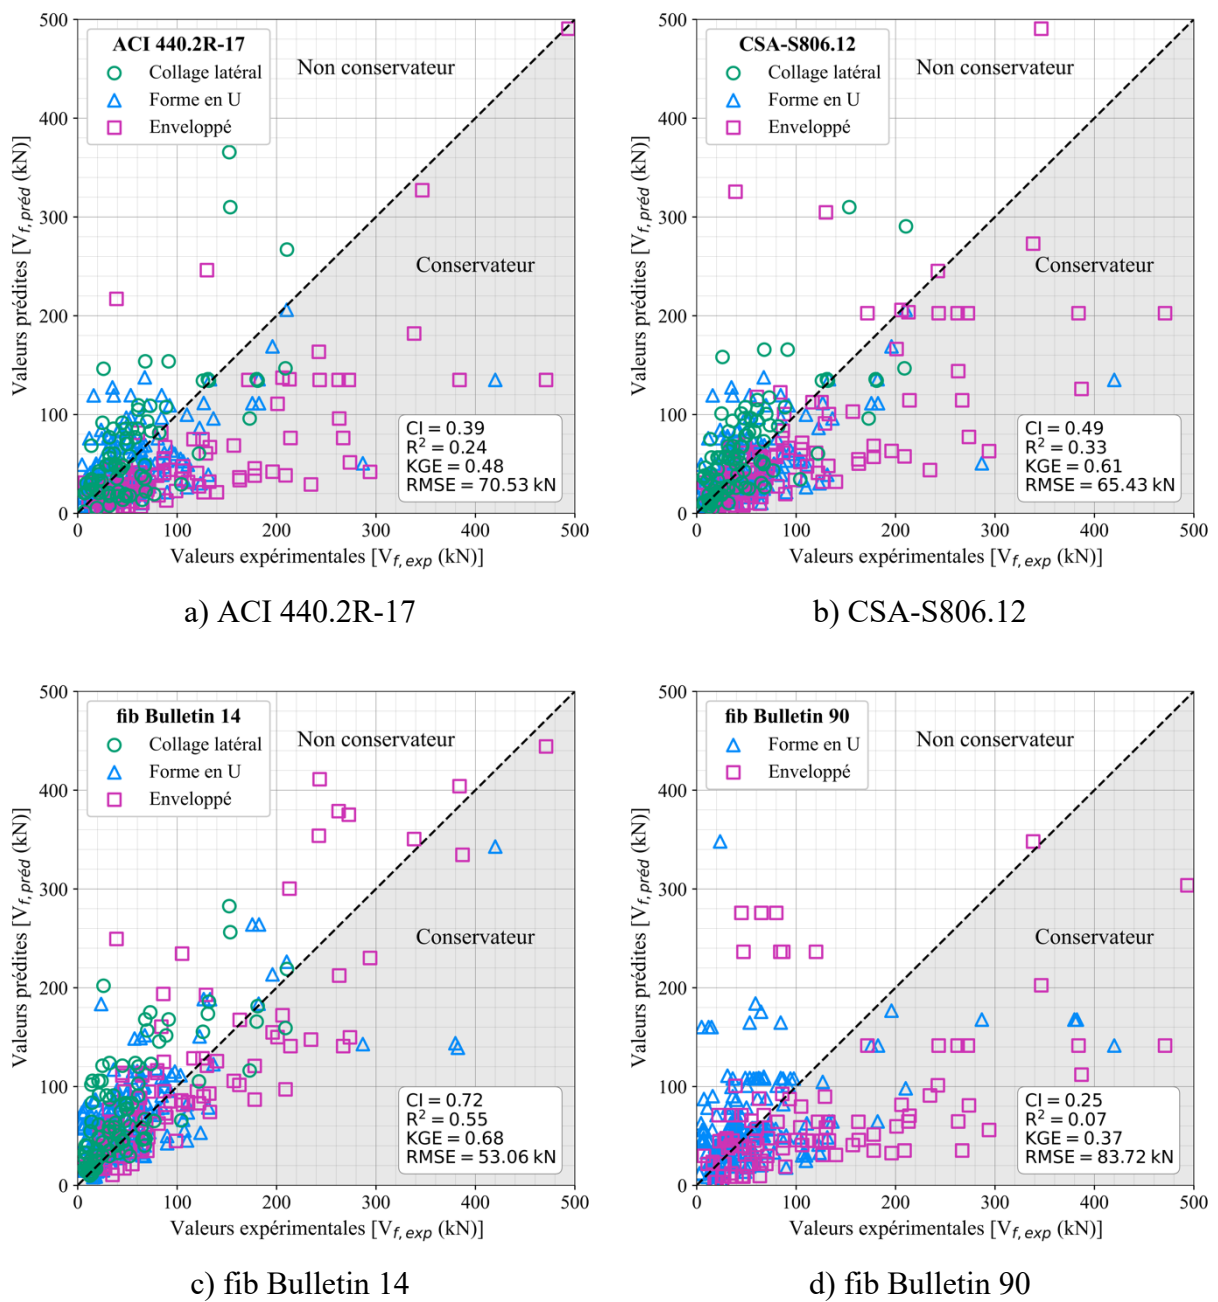


Fig. 5.5 — Comparaison des résultats prédits de différents modèles basés sur l'ensemble des données expérimentales.

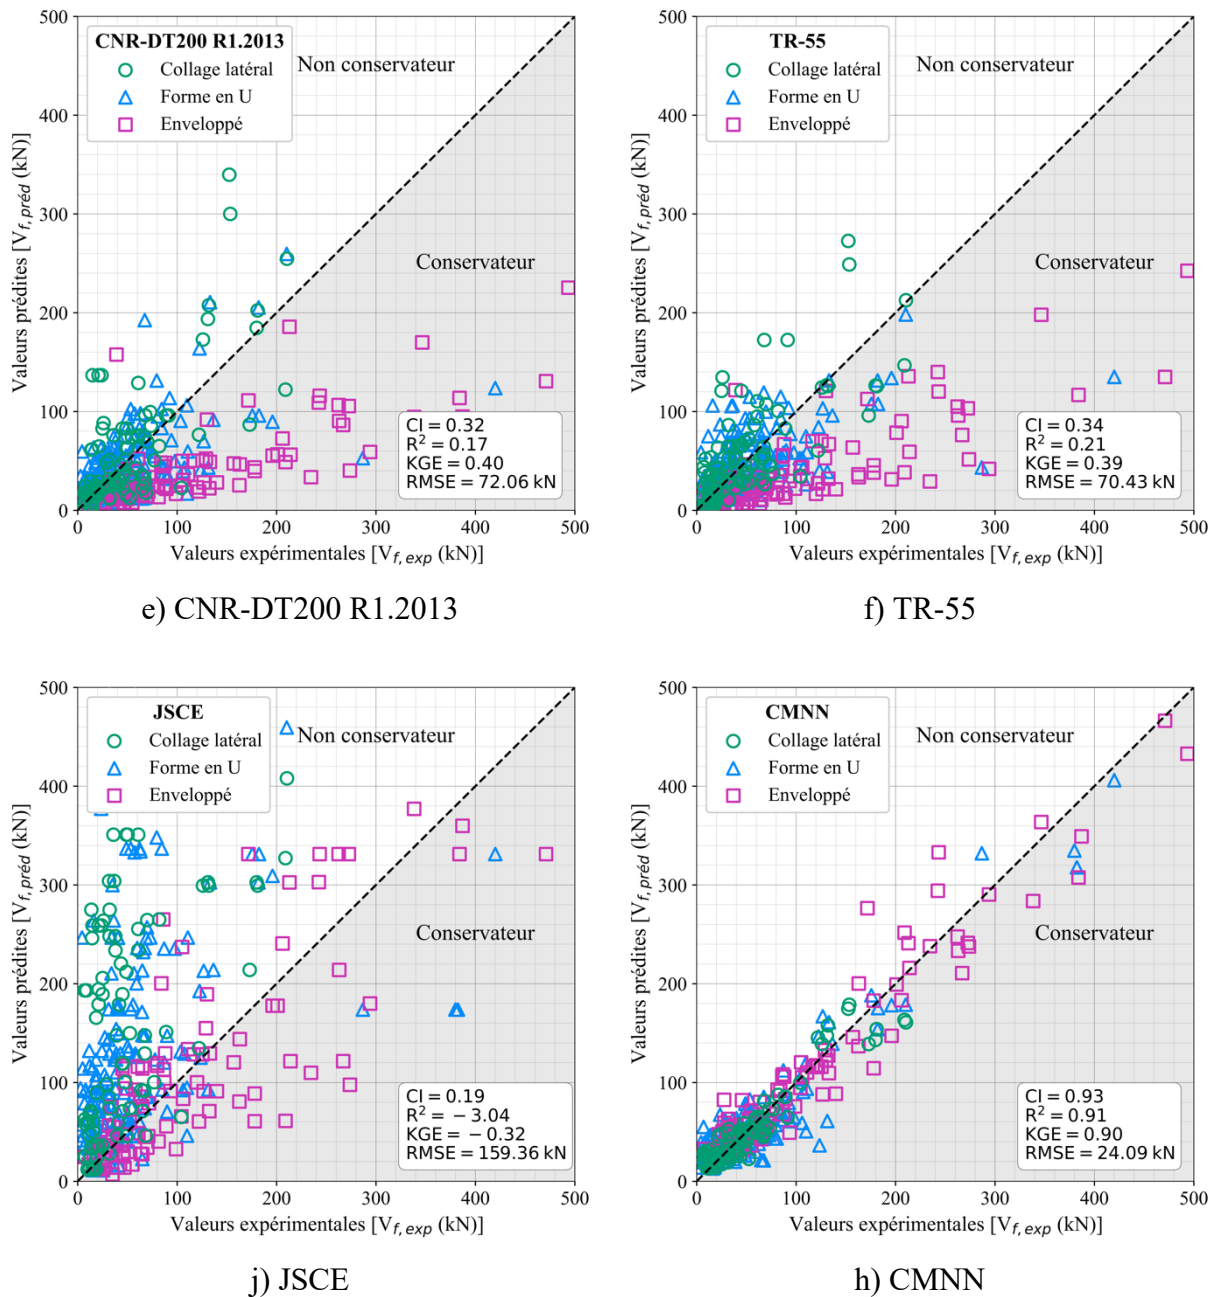


Fig. 5.5 — (Suite)

5.6 Conclusion

Ce chapitre a présenté une investigation approfondie sur l'application de techniques avancées d'apprentissage automatique pour prédire la contribution à la résistance au cisaillement des composites PRF collés extérieurement sur des poutres en BA. Six modèles distincts ont été développés, comprenant le Gradient Boosting extrême (XGB), les réseaux de neurones profonds (DNN), le XGBoost monotone (MXGB), les réseaux de neurones monotones contraints (CMNN), ainsi que leurs homologues ensemblistes (ENSM et MENSM). Les

modèles ont été entraînés et évalués à l'aide d'un ensemble de données expérimentales comprenant 394 spécimens de poutres en BA renforcées avec diverses configurations de PRF, englobant une large gamme de paramètres pour assurer une pertinence pratique.

Les capacités prédictives ont été minutieusement évaluées à l'aide d'une suite complète de métriques de performance statistiques et de représentations visuelles. Les résultats ont mis en évidence les avantages potentiels de l'apprentissage par ensemble, ENSM surpassant ses modèles de base constitutifs XGB et DNN, et MENSMS surpassant MXGB et CMNN. Fait notable, l'incorporation de contraintes de monotonie, basées sur les comportements physiques connus des paramètres d'entrée, a considérablement amélioré la précision et les capacités de généralisation des modèles, comme en témoigne la performance supérieure de MXGB sur XGB, de CMNN sur DNN et de MENSMS sur ENSM.

Des investigations basées sur des scénarios ont été menées pour évaluer la capacité des modèles à saisir et représenter avec précision les relations physiques connues régissant la contribution à la résistance au cisaillement des PRF. Les modèles non monotones, XGB et DNN, ont montré des limites dans la représentation de ces relations, en particulier dans les régions où les données étaient clairsemées ou bruitées, conduisant à des prédictions erratiques et incohérentes. En revanche, les modèles monotones (MXGB, CMNN et MENSMS) ont démontré un succès remarquable dans le maintien précis des relations monotones anticipées à travers divers scénarios.

Cependant, les modèles MXGB et MENSMS ont présenté des courbes de prédiction irrégulières et non lisses, caractérisées par des changements brusques ou des discontinuités, soulevant des préoccupations quant à leur adéquation pour les applications de conception en ingénierie. En revanche, le modèle CMNN a montré des tendances de sensibilité lisses, logiques et continues qui s'alignaient sur les principes de la mécanique du cisaillement des PRF et les observations expérimentales, soulignant son adéquation pour un déploiement pratique.

Un exercice d'évaluation comparative complet a été mené, comparant les performances du modèle CMNN aux directives et codes de conception largement adoptés pour le renforcement au cisaillement par PRF. Les résultats ont démontré sans équivoque la supériorité du modèle CMNN, avec des scores optimaux constants sur toutes les métriques statistiques et tous les cas de test, englobant diverses configurations de renforcement par PRF. Des représentations visuelles ont en outre corroboré la remarquable précision du modèle CMNN, présentant le

regroupement le plus compact des points de données le long de la ligne diagonale, indiquant une forte concordance entre les prédictions et les mesures expérimentales.

Les résultats de cette étude mettent en évidence le potentiel des techniques d'apprentissage automatique, en particulier celles incorporant des connaissances spécifiques au domaine et des contraintes physiques, pour une prédiction précise et fiable de la contribution à la résistance au cisaillement des PRF dans les poutres en BA. Le modèle CMNN développé est apparu comme le choix le plus approprié pour les applications d'ingénierie pratiques, présentant une précision prédictive supérieure, le respect des principes théoriques et des capacités d'extrapolation logiques au-delà de la distribution des données d'entraînement. En dépassant les limites des directives de conception existantes, le modèle CMNN offre une voie prometteuse pour optimiser la conception et les performances des systèmes de renforcement au cisaillement par PRF, contribuant en fin de compte à la sécurité, la fiabilité et la rentabilité des infrastructures en BA.

*Conclusions Générales
et Recommandations*

Conclusions générales

La présente thèse a exploré l'application novatrice des techniques d'apprentissage automatique pour la prédiction précise de la contribution à la résistance au cisaillement des composites en PRF collés extérieurement sur les poutres en BA. Cette approche a été motivée par les limitations inhérentes des directives de conception et des modèles empiriques existants, qui peinent à saisir les interactions complexes entre les multiples paramètres influençant le comportement au cisaillement des éléments renforcés par PRF.

Un état de l'art exhaustif a d'abord été présenté, soulignant les avantages des PRF pour le renforcement structurel, notamment leur haute résistance, leur légèreté et leur durabilité. Les concepts fondamentaux du cisaillement dans les poutres en BA ainsi que les différentes configurations de renforcement par PRF ont été abordés en détail. Une revue critique des formulations réglementaires actuelles pour l'évaluation de la contribution des PRF à la résistance au cisaillement a mis en évidence les lacunes et les divergences persistantes au sein de la communauté scientifique et technique.

Les capacités uniques des algorithmes d'apprentissage automatique pour modéliser les relations non linéaires complexes à partir des données ont été soulignées, ouvrant de nouvelles perspectives pour surmonter les défis rencontrés avec les approches conventionnelles. Une analyse approfondie de l'état de l'art de l'application de ces techniques dans le contexte du renforcement au cisaillement par PRF a révélé leur potentiel prometteur pour des prédictions améliorées.

Une méthodologie rigoureuse a ensuite été présentée, combinant des algorithmes d'apprentissage automatique de pointe tels que l'eXtreme Gradient Boosting, les réseaux de neurones profonds et leurs variantes intégrant des contraintes de monotonie basées sur les connaissances physiques. Un ensemble de données expérimentales exhaustif de 394 spécimens de poutres renforcées par PRF a été soigneusement constitué, prétraité et exploité pour l'entraînement et l'évaluation des modèles proposés.

Les résultats obtenus ont démontré de manière concluante la supériorité des techniques d'apprentissage automatique, en particulier celles intégrant des contraintes de monotonie, pour capturer avec précision les relations complexes régissant la contribution au cisaillement des PRF. Des investigations détaillées basées sur des scénarios ont mis en évidence la capacité des modèles monotones à représenter fidèlement les comportements physiques

anticipés, tout en évitant les prédictions erratiques et incohérentes des modèles non contraints dans les régions de données clairsemées ou bruitées.

Parmi les différents modèles évalués, le réseau de neurones monotone contraint (CMNN) s'est démarqué comme le choix optimal pour les applications pratiques d'ingénierie. Ce modèle a non seulement démontré une précision prédictive remarquable, mais a également exhibé des tendances de sensibilité lisses, logiques et continues, en parfait accord avec les principes théoriques sous-jacents de la mécanique du cisaillement des PRF.

Une évaluation comparative approfondie a clairement établi la supériorité du modèle CMNN par rapport aux directives et codes de conception largement adoptés pour le renforcement au cisaillement par PRF. Les prédictions du CMNN ont montré une concordance exceptionnelle avec les mesures expérimentales, englobant diverses configurations de renforcement par PRF et couvrant une large gamme de paramètres d'entrée.

En transcendant les limites des approches conventionnelles, cette étude a ouvert la voie à l'adoption généralisée des techniques d'apprentissage automatique dans le domaine du renforcement des structures en BA par PRF. Les modèles développés, en particulier le CMNN, offrent des outils puissants pour optimiser la conception et les performances des systèmes de renforcement au cisaillement par PRF, contribuant ainsi à la sécurité, la fiabilité et la rentabilité des infrastructures en BA.

Recommandations

Bien que les résultats obtenus soient prometteurs, plusieurs recommandations peuvent être formulées pour poursuivre le développement et faciliter l'adoption généralisée des techniques d'apprentissage automatique dans le domaine du renforcement des structures en béton armé par PRF :

1. *Poursuite des efforts de collecte et de partage des données expérimentales* : L'accès à des ensembles de données expérimentales de haute qualité et exhaustifs est essentiel pour entraîner des modèles d'apprentissage automatique précis et robustes. Il est recommandé d'encourager la collaboration entre les chercheurs, les laboratoires et l'industrie afin de constituer des bases de données centralisées et standardisées sur les essais de renforcement par PRF. Ces efforts faciliteront le développement de modèles plus génériques et transférables.

2. *Intégration de contraintes physiques et de connaissances du domaine supplémentaires* : Les résultats de cette étude ont clairement démontré les avantages de l'incorporation de contraintes de monotonie basées sur les connaissances de la mécanique du cisaillement des PRF. Il est recommandé d'explorer l'intégration d'autres contraintes physiques pertinentes, telles que les interactions entre les différentes contributions à la résistance au cisaillement (béton, acier, PRF), afin d'améliorer davantage la précision et la cohérence des prédictions avec les principes théoriques établis.
3. *Exploration des techniques d'apprentissage par transfert et d'adaptation de domaine* : Pour tirer pleinement parti des ensembles de données disponibles, il est recommandé d'investiguer l'application des techniques d'apprentissage par transfert et d'adaptation de domaine. Ces approches permettraient d'exploiter des données provenant de sources hétérogènes et de transférer les connaissances acquises à de nouveaux contextes, améliorant ainsi la généralisation et la robustesse des modèles d'apprentissage automatique.
4. *Développement d'outils logiciels intégrés pour la conception et l'évaluation* : Afin de faciliter l'adoption pratique des modèles d'apprentissage automatique par les ingénieurs et les professionnels de la construction, il est recommandé de développer des outils logiciels conviviaux intégrant ces modèles dans les cadres d'analyse et de conception structurelle existants. Ces outils permettraient une évaluation et une conception optimisées des systèmes de renforcement par PRF, en tirant parti des capacités prédictives supérieures des techniques d'apprentissage automatique.
5. *Renforcement de la collaboration interdisciplinaire* : L'application réussie des techniques d'apprentissage automatique dans le domaine du renforcement des structures par PRF nécessite une collaboration étroite entre les experts en ingénierie des structures, les spécialistes de l'apprentissage automatique et les professionnels de l'industrie de la construction. Il est recommandé d'encourager les échanges interdisciplinaires et de favoriser un dialogue ouvert entre ces différents acteurs afin de surmonter les obstacles restants et d'accélérer l'adoption de ces approches innovantes.

En suivant ces recommandations, la communauté scientifique et l'industrie de la construction pourront tirer pleinement parti du potentiel transformateur des techniques d'apprentissage automatique pour la conception et l'évaluation des structures en béton armé renforcées par PRF. Cela contribuera à la réalisation d'infrastructures plus sûres, durables et résilientes, répondant aux défis croissants du vieillissement des infrastructures mondiales et assurant la protection de la vie humaine et des investissements.

*Références
Bibliographiques*

Références Bibliographiques

- AASHTO (2009). Bridge design guide specifications for GFRP—reinforced concrete bridge decks and traffic railings. Washington (DC): American Association of State Highway and Transportation Officials.
- Abbood, Imad. Shakir., Sief, Aldeen. Odaa., Kamalaldin, F. Hasan., & Mohammed, A. Jasim. (2021). Properties evaluation of fiber reinforced polymers and their constituent materials used in structures—A review. *Materials Today: Proceedings* 43, 1003-1008.
- Abdelrahman, K., & El-Hacha, R. (2014). Cost and ductility effectiveness of concrete columns strengthened with CFRP and SFRP sheets. *Polymer*, 6(5), 1381–402.
- Abraham, C. B., Nathan, V. B., Jaipaul, S. R., Nijesh, D., Manoj, M., & Navaneeth, S. (2020). Basalt fibre reinforced aluminium matrix composites—a review. *Materials Today: Proceedings*, 21, 380-383.
- Abad, B. F., Lantsoght, E., & Yang, Y. (2019). Shear capacity of steel fibre reinforced concrete beams. In W. Derkowski, P. Krajewski, P. Gwozdziwicz, M. Pantak, & L. Hojdys (Eds.), *Proceedings of the FIB Symposium 2019: Concrete - Innovations in Materials, Design and Structures*. International Federation for Structural Concrete (fib), 1710-1717.
- Abunassar, N., Alas, M., & Ali, S. I. A. (2023). Prediction of Compressive Strength in Self-compacting Concrete Containing Fly Ash and Silica Fume Using ANN and SVM. *Arabian Journal for Science and Engineering*, 48(4), 5171–5184.
- Abuodeh, O. R., Abdalla, J. A., & Hawileh, R. A. (2020). Prediction of shear strength and behavior of RC beams strengthened with externally bonded FRP sheets using machine learning techniques. *Composite Structures*, 234.
- ACI 318-19. (2019). Building Code Requirements for Structural Concrete and Commentary. American Concrete Institute (ACI), Farmington Hills, MI, USA, 624.
- ACI 440 1R-15. (2007). Guide for the design and construction of structural concrete reinforced with FRP bars. Farmington Hills, MI, American Concrete Institute (ACI).
- ACI 440 2R-17. (2017). Guide for the Design and Construction of Externally Bonded FRP Systems for Strengthening Concrete Structures. American Concrete Institute (ACI), Farmington Hills, MI, USA, 112.
- ACI 440 6-08. (2017). Specification for Carbon and Glass Fiber-Reinforced Polymer Bar Materials for Concrete Reinforcement American Concrete Institute (ACI), Farmington Hills, MI, USA, 6.
- ACI 440 Part 6–8. (2008). Specification for carbon and glass fiber-reinforced polymer bar materials for concrete reinforcement. Farmington Hills, MI, American Concrete Institute (ACI).

- ACI-ASCE Committee 426. (1973). The shear strength of reinforced concrete members. ASCE.
- Adeli, H., & Yeh, C. (1989). Perceptron Learning in Engineering Design. *Computer-Aided Civil and Infrastructure Engineering*, 4(4), 247–256.
- Ahmad, A., Ahmad, W., Aslam, F., & Joyklad, P. (2022). Compressive strength prediction of fly ash-based geopolymer concrete via advanced machine learning techniques. *Case Studies in Construction Materials*, 16, e00840.
- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A Next-generation Hyperparameter Optimization Framework. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2623–2631.
- Al-Rousan, R. (2020). The shear behavior of CFRP strengthened RC beams. *Magazine of Civil Engineering*, 98(6).
- Al-Rousan, R., & Haddad, R. (2013). NLFEA sulfate-damage reinforced concrete beams strengthened with FRP composites. *Composite Structures*, 96, 433–445.
- Al-Sunna, R., Pilakoutas, K., Hajirasouliha, I., & Guadagnini, M. (2012). Deflection behaviour of FRP reinforced concrete beams and slabs: An experimental investigation. *Compos Part B Eng*, 43(5), 2125–2134.
- Alam, M. S., & Hussein, A. (2012). Size Effect on Shear Strength of FRP Reinforced Concrete Beams without Stirrups. *Journal of Composites for Construction*, 17(4), 507–516.
- Alexandropoulos, E., Papoutsidakis, M., & Nikitakos, N. (2019). SCADA Backup System for the Control of Networked Valves in Modern Ships Facilities. *International Journal of Computer Applications*, 178(25), 975–8887.
- Ali, M. M., Oehlers, D. J., & Seracino, R. (2006). Vertical shear interaction model between external FRP transverse plates and internal steel stirrups. *Engineering Structures*, 28(3), 381-389.
- Alkayem, N. F., Cao, M., Zhang, Y., Bayat, M., & Su, Z. (2018). Structural damage detection using finite element model updating with evolutionary algorithms: a survey. *Neural Computing and Applications*, 30(2), 389–411.
- Alkayem, N. F., Shen, L., Mayya, A., Asteris, P. G., Fu, R., Di Luzio, G., Strauss, A., & Cao, M. (2024). Prediction of concrete and FRC properties at high temperature using machine and deep learning: A review of recent advances and future perspectives. *Journal of Building Engineering*, 83, 108369.
- Alloghani, M., Al-Jumeily, D., Mustafina, J., Hussain, A., & Aljaaf, A. J. (2020). A Systematic Review on Supervised and Unsupervised Machine Learning Algorithms for Data Science. 3–21.

- Altoubat, S., Karzad, A. S., Maalej, M., Barakat, S., & Junaid, T. (2020). Experimental study of the steel/CFRP interaction in shear-strengthened RC beams incorporating macro-synthetic fibers. *Structures*, 25, 88–98.
- Amanpreet Singh, Narina Thakur, & Aakanksha Sharma. (n.d.). A review of supervised machine learning algorithms | IEEE Conference Publication | IEEE Xplore.
- Ammar, M. A. (2014). Bond durability of basalt fibre-reinforced polymers (BFRP) bars under freeze-and-thaw conditions Ph.D thesis Dept. of Civil Engineering, Université Laval, 125.
- Archer, N. P., & Wang, S. (1993). Application of the Back Propagation Neural Network Algorithm with Monotonicity Constraints for Two-Group Classification Problems*. *Decision Sciences*, 24(1), 60–75.
- Arduini, M., & Nanni, A. (1997). Parametric study of beams with externally bonded FRP reinforcement. *ACI Struct J*, 94(5), 493–501.
- Arduini, M., Tommaso, A., & Nanni, A. (1997). Brittle failure in FRP plate and sheet bonded beams. *ACI Struct J*, 94(4), 363–70.
- Arya, C., Clarke, J. L., Kay, E. A., Regan, P. D. O., TR 55. (2002). Design guidance for strengthening concrete structures using fibre composite materials: a review, *Eng. Struct*, 24 (7), 889–900.
- ASCE-ACI Committee 445 on Shear and Torsion. (1998). Recent approaches to shear design of structural concrete. *Journal of structural engineering*, 124(12), 1375-1417.
- Asteris, P. G., Skentou, A. D., Bardhan, A., Samui, P., & Pilakoutas, K. (2021). Predicting concrete compressive strength using hybrid ensembling of surrogate machine learning models. *Cement and Concrete Research*, 145, 106449.
- ASTM Committee D-20 on Plastics. Section D20. 70.01. (1991). Standard test methods for density and specific gravity (relative density) of plastics by displacement. American Society for Testing and Materials.
- Attari, N., Amziane, S., & Chemrouk, M. (2012). Flexural strengthening of concrete beams using CFRP, GFRP and hybrid FRP sheets. *Constr Build Mater*, 37, 746–57.
- Ayesha, S., Hanif, M. K., & Talib, R. (2020). Overview and comparative study of dimensionality reduction techniques for high dimensional data. *Information Fusion*, 59, 44–58.
- Bakis, C. E, Bank, L. C, Brown, V., Cosenza, E., Davalos, J. F., & Lesko, J. J. (2002). Fiber-reinforced polymer composites for construction—state-of-the-art review. *J Compos Constr*, 6(2), 73–87.
- Bakouregui, A. S., Mohamed, H. M., Yahia, A., & Benmokrane, B. (2021). Explainable extreme gradient boosting tree-based prediction of load-carrying capacity of FRP-RC columns. *Engineering Structures*, 245, 112836.

- Balsamo, A., Nardone, F., Iovinella, I., Ceroni, F., & Pecce, M. (2013). Flexural strengthening of concrete beams with EB-FRP, SRP and SRCM: Experimental investigation. *Composites Part B: Engineering*, 46, 91–101.
- Banibayat, P. (2011). Experimental investigation of the mechanical and creep rupture properties of basalt fiber reinforced polymer (BFRP) bars. The University of Akron.
- Banibayat, P., & Patnaik, A. (2013). Creep rupture performance of basalt fiber-reinforced polymer bars. *J Aersp Eng*, 28(3), 04014074.
- Banjara, N. K., & Ramanjaneyulu, K. (2017). Experimental and numerical investigations on the performance evaluation of shear deficient and GFRP strengthened reinforced concrete beams. *Construction and Building Materials*, 137, 520–534.
- Bardhan, A., & Asteris, P. G. (2023). Application of hybrid ANN paradigms built with nature inspired meta-heuristics for modelling soil compaction parameters. *Transportation Geotechnics*, 41, 100995.
- Barnes, R. A., & Mays G. C. (1999). Fatigue performance of concrete beams strengthened with CFRP plates. *J Compos Constr*, 3(2), 63–72.
- Barone, G., & Frangopol, D. M. (2014). Reliability, risk and lifetime distributions as performance indicators for life-cycle maintenance of deteriorating structures. *Reliability Engineering & System Safety*, 123, 21–37.
- Barros, J. A. O., & Dias, S. J. E. (2006). Near surface mounted CFRP laminates for shear strengthening of concrete beams. *Cement and Concrete Composites*, 28(3), 276-292.
- Barros, J. A. O., Dias, S. J. E., & Lima, J. L. T. (2007). Efficacy of CFRP-based techniques for the flexural and shear strengthening of concrete beams. *Cem Concr Compos*, 29(3), 203–17.
- Bastidas-Arteaga, E., & Schoefs, F. (2012). Stochastic improvement of inspection and maintenance of corroding reinforced concrete structures placed in unsaturated environments. *Engineering Structures*, 41, 50–62.
- Belarbi, A., & Acun, B. (2013). FRP systems in shear strengthening of reinforced concrete structures. *Procedia Engineering*, 57, 2–8.
- Belarbi, A., Bae, S. W., & Brancaccio, A. (2012). Behavior of full-scale RC T-beams strengthened in shear with externally bonded FRP sheets. *Construction and Building Materials*, 32, 27-40.
- Ben Chaabene, W., Flah, M., & Nehdi, M. L. (2020). Machine learning prediction of mechanical properties of concrete: Critical review. *Construction and Building Materials*, 260, 119889.
- Ben-Hur, A., Horn, D., Siegelmann, H. T., Vapnik, V., Critianini, N., Shawe-Taylor, J., & Williamson, B. (2001). Support Vector Clustering. *Journal of Machine Learning Research*, 2, 125–137.

- Bentz, E. C., Vecchio, F. J., & Collins, M. P. (2006). Simplified Modified Compression Field Theory for Calculating Shear Strength of Reinforced Concrete Elements. *ACI Structural Journal*, 103 (4), 614-624.
- Benzeguir, Z. E. A., & Chaallal, O. (2021). Size Effect in FRP Shear-Strengthened RC Beams: Design Models versus Experimental Data. *CivilEng 2021*, Vol. 2, Pages 874-894, 2(4), 874–894.
- Benzeguir, Z. E. A., El-Saikaly, G., & Chaallal, O. (2019). Size Effect in RC T-Beams Strengthened in Shear with Externally Bonded CFRP Sheets: Experimental Study. *Journal of Composites for Construction*, 23(6), 04019048.
- Berto, L., Vitaliani, R., Saetta, A., & Simioni, P. (2009). Seismic assessment of existing RC structures affected by degradation phenomena. *Structural Safety*, 31(4), 284–297.
- Bi, Y., Xue, B., & Zhang, M. (2021). Evolutionary Computation and Genetic Programming. *Adaptation, Learning, and Optimization*, 24, 49–74.
- Bini, S. A. (2018). Artificial Intelligence, Machine Learning, Deep Learning, and Cognitive Computing: What Do These Terms Mean and How Will They Impact Health Care? *The Journal of Arthroplasty*, 33(8), 2358–2361.
- Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). Training algorithm for optimal margin classifiers. *Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory*, 144–152.
- Bousselham, A., & Chaallal, O. (2006). Behavior of reinforced concrete T-beams strengthened in shear with carbon fiber-reinforced polymer-an experimental study. *ACI structural Journal*, 103(3), 339.
- Bousselham, A., & Chaallal, O. (2006). Effect of transverse steel and shear span on the performance of RC beams strengthened in shear with CFRP. *Compos Part B*, 37(1), 37–46.
- Bousselham, A., & Chaallal, O. (2008). Mechanisms of Shear Resistance of Concrete Beams Strengthened in Shear with Externally Bonded FRP. *Journal of Composites for Construction*, 12(5), 499–512.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Breña, S. F., Bramblett, R. M., Benouaich, M. A., Wood, S. L., & Kreger, M. E. (2001). Use of carbon fiber reinforced polymer composites to increase the flexural capacity of reinforced concrete beams (No. Research Report 1776-1). University of Texas at Austin.
- Brothers, H. (2001). Glass fiber reinforced polymer (GFRP) rebar Aslan 100. Seward, Neb.
- Bukhari, I. A., Vollum, R. L., Ahmad, S., & Sagaseta, J. (2010). Shear strengthening of reinforced concrete beams with CFRP. *Magazine of Concrete Research*, 62(1), 65-77.

- Burgoyne, C. (2007). FRP reinforcement in RC structures. Switzerland: International Federation for Structural Concrete (FIB).
- Cabral-Fonseca, S., Correia, J. R., Rodrigues, M. P., & Branco, F. A. (2012). Artificial Accelerated Ageing of GFRP Pultruded Profiles Made of Polyester and Vinylester Resins: Characterisation of Physical–Chemical and Mechanical Damage. *Strain*, 48(2), 162–173.
- Calvi, G. M., Pavese, A., Rasulo, A., & Bolognini, D. (2005). Experimental and numerical studies on the seismic response of RC hollow bridge piers. *Bull Earthq Eng*, 3(3), 267–97.
- Campione, G., & Mangiavillano, M. L. (2008). Fibrous reinforced concrete beams in flexure: Experimental investigation, analytical modelling and design considerations. *Engineering structures*, 30(11), 2970-2980.
- Canadian Standards Association. (2010). Specification for fibre-reinforced polymers,(CAN/CSA S807-10). Canadian Standards Association, Mississauga, Ont.
- Cao, M., Alkayem, N. F., Pan, L., Novák, D., Cao, M., Alkayem, N. F., Pan, L., & Novák, D. (2016). Advanced Methods in Neural Networks-Based Sensitivity Analysis with their Applications in Civil Engineering. *Artificial Neural Networks - Models and Applications*.
- Caruana, R., Niculescu-Mizil, A., Crew, G., & Ksikes, A. (2004). Ensemble selection from libraries of models. *International Conference on Machine Learning*, 137–144.
- Cha, Y. J., Choi, W., & Büyüköztürk, O. (2017). Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 32(5), 361–378.
- Chen, G. M., Teng, J. G., Chen, J. F., & Rosenboom, O. A. (2010). Interaction between Steel Stirrups and Shear-Strengthening FRP Strips in RC Beams. *Journal of Composites for Construction*, 14(5), 498–509.
- Chen, J. F., & Teng, J. G. (2003). Shear capacity of FRP-strengthened RC beams: FRP debonding. *Construction and Building Materials*, 17(1), 27-41.
- Chen, J. F., & Teng, J. G. (2008). Shear strengthening of reinforced concrete (RC) beams with fibre-reinforced polymer (FRP) composites. In *Strengthening and Rehabilitation of Civil Infrastructures Using Fibre-Reinforced Polymer (FRP) Composites* (pp. 141-157). Woodhead Publishing.
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 13-17-August-2016, 785–794.
- Chen, W., Pham, T. M., Sichembe, H., Chen, L., & Hao, H. (2018). Experimental study of flexural behaviour of RC beams strengthened by longitudinal and U-shaped basalt FRP sheet. *Composites Part B: Engineering*, 134, 114–126.

- Cheng, C. T., Mo, Y., & Yeh, Y. K. (2005). Evaluation of as-built, retrofitted, and repaired shear-critical hollow bridge columns under earthquake-type loading. *J Bridg Eng*, 10(5), 520–9.
- Choi, K. S., Lee, D., You, Y. C., & Whan Han, S. (2022). Long-term performance of 15-year-old full-scale RC beams strengthened with EB FRP composites. *Composite Structures*, 299, 116055.
- Chollet, F. (2021). *Deep Learning with Python, Second Edition*. Deep Learning with Python.
- CNR (National Research Council) Advisory Committee on technical recommendations for construction (2013). *Istruzioni per la Progettazione, l'Esecuzione ed il Controllo di Interventi di Consolidamento Statico mediante l'utilizzo di Compositi Fibrorinforzati*. CNR-DT200. Rome, Italy.
- Colalillo, M. A., & Sheikh, S. A. (2014). BEHAVIOR OF SHEAR-CRITICAL RC BEAMS STRENGTHENED WITH FRP - EXPERIMENTATION. *Structural Journal*, 111(6), 1373–1384.
- Collins, M. P. & Mitchell, D. (1980). Shear and Torsion Design of Prestressed and Non-Prestressed Concrete Beams. *PCI Journal*, 25 (5), 32-100.
- Colotti, V., & Swamy, R. N. (2011). Unified analytical approach for determining shear capacity of RC beams strengthened with FRP. *Engineering Structures*, 33(3), 827-842.
- Cortes, C., Vapnik, V., & Saitta, L. (1995). Support-vector networks. *Machine Learning* 1995 20:3, 20(3), 273–297.
- CSA-S806.12. (2017). *Design and construction of building structures with fiber reinforced polymers*. Canadian Standards Association, Mississauga, Ontario.
- CSTR (2012). *Design guidance for strengthening concrete structures using fibre composite materials*. London, Great Britain.
- Daniels, H., & Velikova, M. (2010). Monotone and partially monotone neural networks. *IEEE Transactions on Neural Networks*, 21(6), 906–917.
- Das, S. (2001). *The cost of automotive polymer composites: a review and assessment of DOE's lightweight materials composites research*. Springfield, VA: American Department of Energy, 1–47.
- Das, S. C., & Nizam, M. E. H. (2014). Applications of fiber reinforced polymer composites (FRP) in civil engineering. *International Journal of Advanced Structures and Geotechnical Engineering*, 3(3), 11.
- Davies, P., Reaud, Y., Dussud, L., & Woerther, P. (2011). Mechanical behaviour of HMPE and aramid fibre ropes for deep sea handling operations. *Ocean Engineering*, 38(17-18), 2208-2214.

- Delgado, P., Arêde, A., Pouca, N. V., Rocha, P., Costa, A., & Delgado, R. (2012). Retrofit of RC hollow piers with CFRP sheets. *Composite Structures*, 94(4), 1280-1287.
- Deniaud, C., & Cheng, J. R. (2001). Review of shear design methods for reinforced concrete beams strengthened with fibre reinforced polymer sheets. *Canadian Journal of Civil Engineering*, 28(2), 271-281.
- Deuring, M. (1993). Post-strengthening of concrete structures with pretensioned advanced composites. Swiss Federal Laboratories for Materials Testing and Research (EMPA), 224. Research Report.
- Dhawan, V., Singh, S., & Singh, I. (2013). Effect of natural fillers on mechanical properties of GFRP composites. *J. Compos*, 2013, 792620.
- Dietterich, T. G. (2000). Ensemble Methods in Machine Learning. Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 1857 LNCS, 1–15.
- Dimiduk, D. M., Holm, E. A., & Niezgoda, S. R. (2018). Perspectives on the Impact of Machine Learning, Deep Learning, and Artificial Intelligence on Materials, Processes, and Structures Engineering. *Integrating Materials and Manufacturing Innovation* 2018 7:3, 7(3), 157–172.
- Dong, Z. H., Han, Q., Du, X. L., & Zhang, D. J. (2014). Experimental study on seismic performance of CFRP confined RC rectangular hollow section bridge piers. *International efforts in lifeline earthquake engineering*, 457–64.
- Dugas, C., Bengio, Y., Bélisle, F., Nadeau, C., & Garcia, R. (2000). Incorporating Second-Order Functional Knowledge for Better Option Pricing. *Advances in Neural Information Processing Systems*, 13.
- El-Maaddawy, T., & Chekfeh, Y. (2013). Shear strengthening of T-beams with corroded stirrups using composites. *ACI Structural Journal*, 110(5), 779.
- El-Salakawy, E., & Benmokrane, B. (2004). Serviceability of concrete bridge deck slabs reinforced with fiber-reinforced polymer composite bars. *Structural Journal*, 101(5), 727-736.
- Ezami, N., Özyüksel Çiftçioğlu, A., Mirrashid, M., & Naderpour, H. (2023). Advancing Shear Capacity Estimation in Rectangular RC Beams: A Cutting-Edge Artificial Intelligence Approach for Assessing the Contribution of FRP. *Sustainability*, 15(22), 16126.
- Fang, H., Bai, Y., Liu, W., Qi, Y., & Wang, J. (2019). Connections and structural applications of fibre reinforced polymer composites for civil infrastructure in aggressive environments. *Composites Part B: Engineering*, 164, 129–143.
- Fawzia, S., Al-Mahaidi, R., Zhao, X. L., & Rizkalla, S. (2007). Strengthening of circular hollow steel tubular sections using high modulus CFRP sheets. *Constr. Build. Mater*, 21 (4), 839–845.

- Feng, D.-C., Wang, W.-J., Mangalathu, S., & Taciroglu, E. (2021). Interpretable XGBoost-SHAP Machine-Learning Model for Shear Strength Prediction of Squat RC Walls. *Journal of Structural Engineering*, 147(11), 04021173.
- Ferrari, V. J., & De Hanai, J. B. (2012). Flexural strengthening of reinforced concrete beams with carbon fibers reinforced polymer (CFRP) sheet bonded to a transition layer of high-performance cement-based composite. *IBRACON Structures and Materials Journal*, 5(5), 596–626.
- fib Task group 5.1. FIB Bulletin 90. (2019). Externally applied FRP reinforcement for concrete structures. Lausanne, Switzerland.
- fib Task Group 9.3 FRP Reinforcement for Concrete Structures. Externally bonded FRP reinforcement for RC structures (2001). Technical report on the design and use of externally bonded fibre reinforced polymer reinforcement (FRP EBR) for reinforced concrete structures, Fib Bulletin 14. 2001.
- Fiore, V., Di Bella, G., & Valenza, A. (2011). Glass–basalt/epoxy hybrid composites for marine applications. *Mater Des*, 32(4), 2091–9.
- Freund, Y., & Schapire, R. (1996). Experiments with a New Boosting Algorithm. *International Conference on Machine Learning*.
- Freund, Y., & Schapire, R. E. (1997). A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of Computer and System Sciences*, 55(1), 119–139.
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine, 29(5), 1189–1232.
- Gale, L., & Ibell, T. J. (2000). Effects of compression reinforcement on the shear strength of reinforced concrete bridge beams. *Magazine of Concrete Research*, 52(4), 275–285.
- Gangarao, H. V., & Vijay, P. (1998). Bending behavior of concrete beams wrapped with carbon fabric. *J Struct Eng*, 124(1), 3–10.
- Garden, H. N., & Hollaway, L. C. (1998). An experimental study of the influence of plate end anchorage of carbon fibre composite plates used to strengthen reinforced concrete beams. *Compos Struct*, 42(2), 175–88.
- Gasser, M., Mahmoud, O., Elsayed, T., & Deifalla, A. (2023). Reliable machine learning for the shear strength of beams strengthened using externally bonded FRP jackets. *Frontiers in Materials*, 10.
- Gay, Daniel. (1991). *Materiaux composites*. Paris. 3e edition Hermes, 564.
- Gdoutos, E. E., Pilakoutas, K., & Rodopoulos, C. A. (2000). *Failure analysis of industrial composite materials*. New York: McGraw-Hill Professional Engineering, 51–108.
- Géron, A. (2017). *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow* (2019, O’reilly). *Hands-On Machine Learning with R*, 510.

- Giamundo, V., Lignola, G P., Prota, A., & Manfredi, G. (2014). Analytical evaluation of FRP wrapping effectiveness in restraining reinforcement bar buckling. *J Struct Eng*, 140(7), 04014043.
- Gianey, H. K., & Choudhary, R. (2017). Comprehensive Review On Supervised Machine Learning Algorithms. *Proceedings - 2017 International Conference on Machine Learning and Data Science, MLDS 2017*, 2018-January, 38–43.
- Gibson, G. (2017). Epoxy Resins. *Brydson's Plastics Materials (Eighth Edition)*, M. Gilbert, (Ed.) Butterworth-Heinemann, Oxford, UK, 773–797.
- Gonzalez-Libreros, J. H., Sneed, L. H., D'Antino, T., & Pellegrino, C. (2017). Behavior of RC beams strengthened in shear with FRP and FRCM composites. *Engineering Structures*, 150, 830–842.
- Goodfellow, I., Bengio, Y., & Courville, A. (n.d.). *Deep Learning*.
- Grace, N. F., Ragheb, W. F., & Abdel-Sayed, G. (2003). Flexural and shear strengthening of concrete beams using new triaxially braided ductile fabric. *ACI Struct J*, 100(6), 804–14.
- Grande, E., Imbimbo, M., & Rasulo, A. (2009). Effect of Transverse Steel on the Response of RC Beams Strengthened in Shear by FRP: Experimental Study. *Journal of Composites for Construction*, 13(5), 405–414.
- Gudonis, E., Timinskas, E., Gribniak, V., Kaklauskas, G., Arnautov, A. K., & Tamulėnas, V. (2013). FRP reinforcement for concrete structures: state-of-the-art review of application and design. *Engineering Structures and Technologies*, 5(4), 147-158.
- Günaslan, S. E., Karasbin, A., & Öncü, M. E. (2014). Properties of FRP materials for strengthening, *Int. J. Innov. Sci. Eng. Technol*, 1 (9), 656–660.
- Gupta, A., Shukla, N., Marla, L., Kolbeinsson, A., & Yellepeddi, K. (2019). How to Incorporate Monotonicity in Deep Networks While Preserving Flexibility?
- Gupta, M., Cotter, A., Pfeifer, J., Voevodski, K., Canini, K., Mangylov, A., Moczydlowski, W., & van Esbroeck, A. (2015). Monotonic Calibrated Interpolated Look-Up Tables.
- Hackl, J., & Kohler, J. (2016). Reliability assessment of deteriorating reinforced concrete structures by representing the coupled effect of corrosion initiation and progression by Bayesian networks. *Structural Safety*, 62, 12–23.
- Haeger, A., Schoen, G., Lissek, F., Meinhard, D., Kaufeld, M., Schneider, G., Schuhmacher, S., & Knoblauch, V. (2016). Non-destructive detection of drilling-induced delamination in CFRP and its effect on mechanical properties. *Procedia Engineering*, 149, 130-142.
- Han, Q., Wang, L., & Xu, J. (2015). Experimental research on mechanical properties of transverse enhanced and high-temperature-resistant CFRP tendons for prestressed structure. *Construction and Building Materials*, 98, 864-874.

- Han, Q., Wen, J., Du, X., & Jia, J. (2014). Experimental and numerical studies on seismic behavior of hollow bridge columns retrofitted with carbon fiber reinforced polymer. *J. Reinf. Plast. Compos*, 33 (24), 2214–2227.
- Hassan, W. M., Hodhod O. A., Hilal, M. S., & Bahnasaway, H. H. (2017). Behavior of eccentrically loaded high strength concrete columns jacketed with FRP laminates. *Constr Build Mater*, 138, 508–27.
- Hawileh, R. A., Nawaz, W., Abdalla, J. A., & Saqan, E. I. (2015). Effect of flexural CFRP sheets on shear resistance of reinforced concrete beams. *Composite Structures*, 122, 468–476.
- Hawileh, R. A., Rasheed, H. A., Abdalla, J. A., & Al-Tamimi, A. K. (2014). Behavior of reinforced concrete beams strengthened with externally bonded hybrid fiber reinforced polymer systems. *Materials & Design*, 53, 972-982.
- Haykin, S. (2009). *Neural networks and learning machines*, 3/E. Pearson Education India.
- Hilal, A. O., Hamoody, A. Z., & Saadon, A. S. (2021). Behavior of FRP sheet-concrete bond in high strength concrete samples. *IOP Conference Series: Materials Science and Engineering*, 1090(1), 012105.
- Ho, I., Lam E., Wu B., Wang Y. (2013). Monotonic behavior of reinforce concrete columns confined with high-performance ferrocement. *J Struct Eng ASCE*, 139(4), 574–83.
- Ho, J. C. M., Lam, J. Y. K., & Kwan, A. K. H. (2010). Effectiveness of adding confinement for ductility improvement of high-strength concrete columns. *Eng Struct*, 32, 714–25.
- Hollaway, L. C. (2010). A review of the present and future utilisation of FRP composites in the civil infrastructure with reference to their important in-service properties. *Constr Build Mater*, 24(12), 2419–45.
- Hoskere, V., Narazaki, Y., Hoang, T. A., & Spencer, B. F. (2020). MaDnet: multi-task semantic segmentation of multiple types of structural materials and damage in images of civil infrastructure. *Journal of Civil Structural Health Monitoring*, 10(5), 757–773.
- Hosny, A. H., Abdelrahman, A. (2010). Applications of FRP projects in Egypt. *IABSE Symposium International Association for Bridge and Structural Engineering*, 97, 51–58.
- Huang, X., Zhou, Y., Li, W., Hu, B., & Zhang, J. (2023). Reliability-based design of FRP shear strengthened reinforced concrete Beams: Guidelines assessment and calibration. *Composite Structures*, 323, 117421.
- Hung, C. C., Li, H., Chen, H. C. (2017). High-strength steel reinforced squat UHPFRC shear walls: cyclic behavior and design implications. *Eng. Struct*, 141, 59–74.

- Ibell, T. J., Morley, C. T., & Middleton, C.R., (1996). Background to and Developments in Shear in Reinforced Concrete. Technical Report No. CUED/D-Struct/TR 151. Cambridge: University of Cambridge.
- Idicula, M., Boudenne, A., Umadevi, L., Ibos, L., Candau, Y., & Thomas, S. (2006). Thermophysical properties of natural fibre reinforced polyester composites. *Compos. Sci. Technol*, 66 (15), 2719–2725.
- Intelligent Sensing for Innovative Structures (ISIS). (2007). Reinforcing concrete structures with fibre reinforced polymers (FRPs) – ISIS design manual. Winnipeg, M., Canada: ISIS.
- Jalal, M., & Ramezani pour, A. A. (2012). Strength enhancement modeling of concrete cylinders confined with CFRP composites using artificial neural networks. *Composites Part B: Engineering*, 43(8), 2990-3000.
- Jameel, M., Sheikh, M. N., & Hadi, M. N. (2017). Behaviour of circularized and FRP wrapped hollow concrete specimens under axial compressive load. *Compos Struct*, 171, 538–48.
- Jeong, J. P., & Kim, W. (2014). Shear resistant mechanism into base components: Beam action and arch action in shear-critical RC members. *International Journal of Concrete Structures and Materials*, 8, 1-14.
- Jiang, X., Jin, L., Lu, K., & Du, X. (2023). Experimental and numerical tests on shear failure and size effect of CFRP-wrapped RC beams without stirrups: Influence of the shear-span ratio. *Engineering Structures*, 288.
- Jiao, H., & Zhao, X. L. (2004). CFRP strengthened butt-welded very high strength (VHS) circular steel tubes. *Thin-Wall. Struct*, 42 (7), 963–978.
- JSCE Japanese Society of Civil Engineers (2000). Recommendations for upgrading of concrete structures with use of continuous fiber sheets.
- Jumaa, G. B., & Yousif, A. R. (2019). Numerical modeling of size effect in shear strength of FRP-reinforced concrete beams. *Structures*, 20, 237–254.
- Kamgar, R., Bagherinejad, M. H., & Heidarzadeh, H. (2020). A new formulation for prediction of the shear capacity of FRP in strengthened reinforced concrete beams. *Soft Computing*, 24(9), 6871–6887.
- Kani, G. N. J. (1964, April). The riddle of shear failure and its solution. In *Journal Proceedings* (Vol. 61, No. 4, pp. 441-468).
- Kani, G. N. J. (1966, June). Basic facts concerning shear failure. In *Journal Proceedings* (Vol. 63, No. 6, pp. 675-692).
- Kar, S., & Biswal, K. C. (2020). FRP shear contribution prediction for U-wrapped RC T-beams using a soft computing tool. *Structures*, 27, 1093–1104.

- Kar, S., Pandit, A. R., & Biswal, K. C. (2020). Prediction of FRP shear contribution for wrapped shear deficient RC beams using adaptive neuro-fuzzy inference system (ANFIS). *Structures*, 23, 702–717.
- Karzad, A. S., Khalil, M. A., Mohamed, A. M., & Barakat, S. (2023). Modeling the shear capacity of externally bonded fiber reinforced polymer strengthened beams by artificial neural network. *International Journal of Applied Science and Engineering*, 20(1).
- Kaveh, A., Gholipour, Y., & Rahami, H. (2008). Optimal Design of Transmission Towers Using Genetic Algorithm and Neural Networks. [Http://Dx.Doi.Org/10.1260/026635108785342073](http://dx.doi.org/10.1260/026635108785342073), 23(1), 1–19.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). LightGBM: A Highly Efficient Gradient Boosting Decision Tree. In I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 30). Curran Associates, Inc.
- Kesse, G. (2004). Concrete beams with external prestressed carbon FRP shear reinforcement (Doctoral dissertation, University of Cambridge).
- Khalifa, A., & Nanni, A. (2000). Improving shear capacity of existing RC T-section beams using CFRP composites. *Cement and Concrete Composites*, 22(3), 165–174.
- Khalifa, A., & Nanni, A. (2002). Rehabilitation of rectangular simply supported RC beams with shear deficiencies using CFRP composites. *Construction and Building Materials*, 16(3), 135–146.
- Kim, Y., Quinn, K., Satrom, N., Garcia, J., Sun, W., Ghannoum, W. M., & Jirsa, J. O. (2012). Shear strengthening of reinforced and prestressed concrete beams using carbon fiber reinforced polymer (CFRP) sheets and anchors (No. FHWA/TX-12/0-6306-1).
- Kotsovos, M. D. (1987). Shear failure of reinforced concrete beams. *Engineering Structures*, 9(1), 32-38.
- Kotynia, R., Oller, E., Mari, A., & Kaszubska, M. (2021). Efficiency of shear strengthening of RC beams with externally bonded FRP materials – State-of-the-art in the experimental tests. *Composite Structures*, 267, 113891.
- Kuchma, D. A., & Collins, M. P. (1998). Advances in Understanding Shear Performance of Concrete Structures. *Progress in Structural Engineering and Materials*, 1 (4), 360-369.
- Kumar, P. R., Oshima, T., & Mikami, S. (2004). Ferrocement confinement of plain and reinforced concrete. *Prog Struct Eng Mater*, 6(4), 241–51.
- Kumosa, L., Benedikt, B., Armentrout, D., & Kumosa, M. (2004). Moisture absorption properties of unidirectional glass/polymer composites used in composite (non-ceramic) insulators. *Compos A: Appl Sci Manuf*, 35(9), 1049–63.

- Landesmann, A., Seruti, C. A., & Batista, E. d. M. (2015). Mechanical properties of glass fiber reinforced polymers members for structural applications. *Mater Res*, 18(6), 1372–1383.
- Larbi, A. Si., Contamine, R., Ferrier, E., Hamelin, P., (2010). Shear strengthening of RC beams with textile reinforced concrete (TRC) plate. *Constr Build Mater*, 24(10), 1928–36.
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature* 2015 521:7553, 521(7553), 436–444.
- Li, C. Q., & Melchers, R. E. (2005). Time-Dependent Risk Assessment of Structural Deterioration Caused by Reinforcement Corrosion. *Structural Journal*, 102(5), 754–762.
- Li, L., Guo, Y., Liu, F., & Bungey, J. (2005). Efficiency of hybrid FRP sheets in strengthening concrete beams. Presented at Repair and Renovation of Concrete Structures. University of Dundee. Scotland. UK.
- Li, W., & Leung, C. K. Y. (2015). Shear Span–Depth Ratio Effect on Behavior of RC Beam Shear Strengthened with Full-Wrapping FRP Strip. *Journal of Composites for Construction*, 20(3), 04015067.
- Li, W., & Leung, C. K. Y. (2017). Effect of shear span-depth ratio on mechanical performance of RC beams strengthened in shear with U-wrapping FRP strips. *Composite Structures*, 177, 141–157.
- Li, W., Li, J., Ren, X., Leung, C. K. Y., & Xing, F. (2015). Coupling effect of concrete strength and bonding length on bond behaviors of fiber reinforced polymer–concrete interface. [Http://Dx.Doi.Org/10.1177/0731684415573816](http://dx.doi.org/10.1177/0731684415573816), 34(5), 421–432.
- Lim, J. I., Rhee, K. Y., Kim, H. J., & Jung, D. H. (2014). Effect of stacking sequence on the flexural and fracture properties of carbon/basalt/epoxy hybrid composites. *Carbon letters*, 15(2), 125–128.
- Lima, J. L., & Barros, J. A. (2011). Reliability analysis of shear strengthening externally bonded FRP models. *Proceedings of the Institution of Civil Engineers-Structures and Buildings*, 164(1), 43–56.
- Lin, G., & Teng, J. G. (2020). Advanced stress-strain model for FRP-confined concrete in square columns. *Composites Part B: Engineering*, 197, 108149.
- Liu, H., Zhao, X., & Al-Mahaidi, R. (2010). Effect of fatigue loading on bond strength between CFRP sheets and steel plates. *Int J Struct Stab Dyn*, 10(01), 1–20.
- Liu, X., Han, X., Zhang, N., & Liu, Q. (2020). Certified Monotonic Neural Networks. *Advances in Neural Information Processing Systems*, 2020–December.
- Lu, X. Z., Chen, J. F., Ye, L. P., Teng, J. G., & Rotter, J. M. (2009). RC beams shear-strengthened with FRP: stress distributions in the FRP reinforcement. *Constr Build Mater*, 23, 1154–544.

- Maalej, M., & Leong, K. S. (2005). Effect of beam size and FRP thickness on interfacial shear stress concentration and failure mode of FRP-strengthened beams. *Composites Science and Technology*, 65(7-8), 1148-1158.
- Maclin, R., & Opitz, D. (2011). Popular Ensemble Methods: An Empirical Study. *Journal Of Artificial Intelligence Research*, 11, 169–198.
- Martin, H., Viviane, A., Martin, C., Dominik, K., & Josef, H. (2017). Strengthening of existing bridge structures for shear and bending with carbon textile-reinforced mortar. *Materials*, 10(9), 1099.
- Mastali, M., & Dalvand, A. (2016). The impact resistance and mechanical properties of self-compacting concrete reinforced with recycled CFRP pieces. *Compos. B Eng*, 92, 360–376.
- Matta, F. (2003). Bond between steel and CFRP laminates for rehabilitation of metallic bridges. Faculty of Engineering, University of Padua: Padua, Italy.
- Maurizio, G., Kypros, P., & Iman, H. (2009). Deflection prediction of FRP reinforced concrete beams. *Advanced composites in construction 2009. ACIC 2009 - Proceedings of the 4th International Conference*.
- Michel, L., Ferrier, E., Agbossou, A., & Hamelin, P. (2009). Flexural stiffness modelling of RC slab strengthened by externally bonded FRP. *Composites Part B: Engineering*, 40(8), 758–765.
- Mitchell, T. M. (1980). *The Need for Biases in Learning Generalizations by The Need for Biases in Learning Generalizations*.
- Mofidi, A., & Chaallal, O. (2011a). Shear Strengthening of RC Beams with Externally Bonded FRP Composites: Effect of Strip-Width-to-Strip-Spacing Ratio. *Journal of Composites for Construction*, 15(5), 732–742.
- Mofidi, A., & Chaallal, O. (2011b). Shear strengthening of RC beams with EB FRP: Influencing factors and conceptual debonding model. *Journal of Composites for Construction*, 15(1), 62-74.
- Mofidi, A., & Chaallal, O. (2014a). Reinforced-concrete beams retrofitted in shear with externally-bonded fibre-reinforced polymer: Development of a design model. *Australian Journal of Structural Engineering*, 15(4).
- Mofidi, A., & Chaallal, O. (2014b). Tests and Design Provisions for Reinforced-Concrete Beams Strengthened in Shear Using FRP Sheets and Strips. *International Journal of Concrete Structures and Materials*, 8(2), 117–128.
- Mofidi, A., Thivierge, S., Chaallal, O., & Shao, Y. (2014). Behavior of reinforced concrete beams strengthened in shear using L-shaped CFRP plates: Experimental investigation. *Journal of composites for construction*, 18(2), 04013033.
- Monti, G., & Liotta, M. A. (2007). Tests and design equations for FRP-strengthening in shear. *Construction and Building Materials*, 21(4), 799-809.

- Morsch, E. (1909) *Der Eisenbetonbau* (Published in English as *Concrete-Steel Construction*). 3rd ed. New York: Engineering News Publishing.
- Mourad, S. M., & Shannag, M. J. (2012). Repair and strengthening of reinforced concrete square columns using ferrocement jackets. *Can Cotter Compos*, 34(2), 288–94.
- Mugahed Amran, Y. H., Alyousef, R., Rashid, R. S. M., Alabduljabbar, H., & Hung, C. C. (2018). Properties and applications of FRP in strengthening RC structures: a review, *Structures* 16, 208–238.
- Nabil, W. F. R., Grace, F., George, A. S. (2003). Flexural and shear strengthening of concrete beams using new triaxially braided ductile fabric. *ACI Struct. J*, 100 (6), 804–814.
- Naderpour, H., & Alavi, S. A. (2017). A proposed model to estimate shear contribution of FRP in strengthened RC beams in terms of Adaptive Neuro-Fuzzy Inference System. *Composite Structures*, 170, 215–227.
- Nagaraja, K. C., Rajanna, S., Prakash, G. S., & Rajeshkumar, G. (2021). Mechanical properties of polymer matrix composites: Effect of hybridization. *Materials Today: Proceedings*, 34, 536-538.
- Naser, M. Z., & Alavi, A. H. (2021). Error Metrics and Performance Fitness Indicators for Artificial Intelligence and Machine Learning in Engineering and Sciences. *Architecture, Structures and Construction* 2021 3:4, 3(4), 499–517.
- Nehdi, M., & Nikopour, H. (2011). Genetic algorithm model for shear capacity of RC beams reinforced with externally bonded FRP. *Materials and Structures/Materiaux et Constructions*, 44(7), 1249–1258.
- Nguyen-Minh, L., & Rovňák, M. (2015). Size effect in uncracked and pre-cracked reinforced concrete beams shear-strengthened with composite jackets. *Composites Part B: Engineering*, 78, 361–376.
- Nguyen-Minh, L., Vo-Le, D., Tran-Thanh, D., Pham, T. M., Ho-Huu, C., & Rovňák, M. (2018). Shear capacity of unbonded post-tensioned concrete T-beams strengthened with CFRP and GFRP U-wraps. *Composite Structures*, 184, 1011–1029.
- Nguyen, T. C., Bai, Y., Zhao, X. L., & Al-Mahaidi, R. (2012). Effects of ultraviolet radiation and associated elevated temperature on mechanical performance of steel/CFRP double strap joints. *Compos Struct*, 94(12), 3563–73.
- Nielsen, M.P., Braestrup, M.W., & Bach, F. (1978). Rational Analysis of Shear in Reinforced Concrete Beams. In *IABSE Proceedings*, 15/78.
- Nilson, A.H. (1987). *Design of Prestressed Concrete*. 2nd ed. Canada: John Wiley & Sons Inc.
- Ning, H., Li, Y., Hu, N., Arai, M., Takizawa, N., Liu, Y., ... & Mo, F. (2015). Experimental and numerical study on the improvement of interlaminar mechanical properties of Al/CFRP laminates. *Journal of Materials Processing Technology*, 216, 79-88.

- Nithurshan, M., & Elakneswaran, Y. (2023). A systematic review and assessment of concrete strength prediction models. *Case Studies in Construction Materials*, 18, e01830.
- Oller, E., Kotynia, R., & Marí, A. (2021). Assessment of the existing models to evaluate the shear strength contribution of externally bonded frp shear reinforcements. *Composite Structures*, 266, 113641.
- Oller, E., Pujol, M., & Marí, A. (2019). Contribution of externally bonded FRP shear reinforcement to the shear strength of RC beams. *Composites Part B: Engineering*, 164, 235–248.
- Ongsulee, P. (2018). Artificial intelligence, machine learning and deep learning. *International Conference on ICT and Knowledge Engineering*, 1–6.
- Palmieri, A., Matthys, S., & Taerwe, L. (2012). Experimental investigation on fire endurance of insulated concrete beams strengthened with near surface mounted FRP bar reinforcement. *Compos Part B Eng*, 43(3), 885–95.
- Park, R., & Paulay, T. (1991). *Reinforced concrete structures*. John Wiley & Sons.
- Pellegrino, C., & Modena, C. (2002). Fiber Reinforced Polymer Shear Strengthening of Reinforced Concrete Beams with Transverse Steel Reinforcement. *Journal of Composites for Construction*, 6(2), 104–111.
- Pellegrino, C., & Modena, C. (2008). An experimentally based analytical model for the shear capacity of FRP-strengthened reinforced concrete beams. *Mechanics of composite materials*, 44, 231-244.
- Pellegrino, C., & Vasic, M. (2013). Assessment of design procedures for the use of externally bonded FRP composites in shear strengthening of reinforced concrete beams. *Composites Part B: Engineering*, 45(1), 727-741.
- Perera, R., Arteaga, A., & Diego, A. De. (2010). Artificial intelligence techniques for prediction of the capacity of RC beams strengthened in shear with external FRP reinforcement. *Composite Structures*, 92(5), 1169–1175.
- Perera, R., Barchín, M., Arteaga, A., & Diego, A. De. (2010). Prediction of the ultimate strength of reinforced concrete beams FRP-strengthened in shear using neural networks. *Composites Part B: Engineering*, 41(4), 287–298.
- Pham, T. M., & Hadi, M. N. (2014). Confinement model for FRP confined normal-and high-strength concrete circular columns. *Construction and Building Materials*, 69, 83-90.
- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A. (2018). CatBoost: unbiased boosting with categorical features. In S. Bengio, H. Wallach, H. Larochelle, K. Grauman, N. Cesa-Bianchi, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 31). Curran Associates, Inc.
- Punmia, B. C., Jain, A. K., Jain, A. K., Jain, A. K., & Jain, A. K. (2007). Limit state design of reinforced concrete. *Firewall Media*.

- Qapo, M. K. (2016). Nonlinear finite element modelling of FRP shear-strengthened prestressed and reinforced concrete beams (Doctoral dissertation, University of Birmingham).
- Rahman, J., & Muntasir Billah, A. H. M. (2024). Interpretable Ensemble Machine Learning Models for Shear Strength Prediction of Reinforced Concrete Beams Externally Bonded with FRP. *Lecture Notes in Civil Engineering*, 359, 1265–1278.
- Rahman, J., Arafin, P., & Muntasir Billah, A. H. M. (2023). Machine learning models for predicting concrete beams shear strength externally bonded with FRP. *Structures*, 53, 514–536.
- Rajagopalan, N. (2002) *Prestressed Concrete*. UK: Alpha Science International Ltd.
- Rashid, Y.R. (1968) Ultimate Strength Analysis of Prestressed Concrete Pressure Vessels. *Nuclear Engineering and Design*, 7 (4), 334-344
- Rasheed, H. A., Harrison, R. R., Peterman, R. J., & Alkhrdaji, T. (2010). Ductile strengthening using externally bonded and near surface mounted composite systems. *Composite Structures*, 92(10), 2379–2390.
- Ritter, K. W. (1899) Die Bauweise Hennebique (The Hennebique Construction Method). *Schweizerische Bauzeitung*, 33 (7), 59-61
- Roh, Y., Heo, G., & Whang, S. E. (2021). A Survey on Data Collection for Machine Learning: A Big Data-AI Integration Perspective. *IEEE Transactions on Knowledge and Data Engineering*, 33(4), 1328–1347.
- Rosa, J. L. G., & Rosa, J. L. G. (2016). *Artificial Neural Networks - Models and Applications*. Artificial Neural Networks - Models and Applications.
- Rousakis, T. C., & Karabinis, A. I. (2012). Adequately FRP confined reinforced concrete columns under axial compressive monotonic or cyclic loading. *Materials and Structures/Materiaux et Constructions*, 45(7), 957–975.
- Runje, D., & Shankaranarayana, S. M. (2022). *Constrained Monotonic Neural Networks*.
- Sahu, N. P., Khande, D. K., Patel, G. C., Bohidar, S. K., & Sen, P. K. (2014). Study on aramid fibre and comparison with other composite materials. *International Journal for Innovative Research in Science & Technology*, 1(7), 303-306.
- Sahu, N.P., Khande, D. K., Patel, G. C., Bohidar, S., & Sen, P. (2014). Study on aramid fibre and comparison with other composite materials. *Int. J. Innov. Res. Sci. Technol*, 1 (7), 303–306.
- Salleh, M. N. M., Talpur, N., & Hussain, K. (2017). Adaptive Neuro-Fuzzy Inference System: Overview, Strengths, Limitations, and Solutions. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10387 LNCS, 527–535.
- Sarasini, F., Tirillò, J., Ferrante, L., Valente, M., Valente, T., Lampani, L., Gaudenzi, P., Cioffi, S., Iannace, S., & Sorrentino, L. (2014). Drop-weight impact behaviour of woven hybrid basalt–carbon/epoxy composites. *Compos. Part B: Eng*, 59, 204–220.

- Sas, G., Täljsten, B., Barros, J., Lima, J., Carolin, A. (2009). Available models reliable for predicting the FRP contribution to the shear resistance of RC beams *J Compos Constr*, 13(6), 514–34.
- Sato, Y., Ueda, T., Kakuta, Y., & Tanaka, T. (1996). Shear reinforcing effect of carbon fiber sheet attached to side of reinforced concrete beams. In *Proceedings of the 2nd International Conference on Advanced Composite Materials in Bridges and Structures, ACMBS-II, Montreal 1996*.
- Schapiro, R. E. (1999). A Brief Introduction to Boosting. *Proceedings of the Sixteenth International Joint Conference on Artificial Intelligence*, 1401–1406.
- Schlaich, J., Schafer, K., & Jennewein, M. (1987). Toward a Consistent Design of Structural Concrete. *PCI Journal*, 32 (3), 74-15.
- Selzer, R., & Friedrich, K. (1995). Influence of water up-take on interlaminar fracture properties of carbon fibre-reinforced polymer composites. *J. Mater. Sci*, 30 (2), 334–338.
- Selzer, R., & Friedrich, K. (1997). Mechanical properties and failure behaviour of carbon fibre-reinforced polymer composites under the influence of moisture. *Compos. A Appl. Sci. Manuf*, 28 (6), 595–604.
- Sen, R., & Mullins, G. (2007). Application of FRP composites for underwater piles repair. *Composites Part B: Engineering*, 38(5–6), 751–758.
- Sengun, K., & Arslan, G. (2022). Parameters affecting the behaviour of RC beams strengthened in shear and flexure with various FRP systems. *Structures*, 40, 202–212.
- Sha, X., & Davidson, J. S. (2020). Analysis of interfacial stresses in concrete beams strengthened by externally bonded FRP laminates using composite beam theory. *Composite Structures*, 243, 112235.
- Shahawy, M., & Beitelman, T. (1996). Flexural behavior of reinforced concrete beams strengthened with advanced composite materials. *Society for the Advancement of Material and Process Engineering. Covina, CA (United States)*, 1, 1015–25.
- Shang, M., Li, H., Ahmad, A., Ahmad, W., Ostrowski, K. A., Aslam, F., Joyklad, P., & Majka, T. M. (2022). Predicting the Mechanical Properties of RCA-Based Concrete Using Supervised Machine Learning Algorithms. *Materials 2022*, Vol. 15, Page 647, 15(2), 647.
- Sheikh, S. A. (1978). Effectiveness of rectangular ties as confinement steel in reinforced concrete columns PhD dissertation Canada: Department of Civil Engineering. University of Toronto.
- Shokrieh, M. M, & Omid, M. J. (2009). Tension behavior of unidirectional glass/epoxy composites under different strain rates. *Compos Struct*, 88(4), 595–601.
- Sim, J., Kim, G., Park, C., & Ju, M. (2005). Shear Strengthening Effects with Varying Types of FRP Materials and Strengthening Methods. *Special Publication*, 230, 1665–1680.

- Sivaraman, A., Farnadi, G., Millstein, T., & Broeck, G. Van den. (2020). Counterexample-Guided Learning of Monotonic Neural Networks.
- Sonnenschein, R., Bilcik, J., & Gajdosova, K. (2016). Crack Width Control in Concrete Structures with FRP Reinforcement. Presented at Engineering Mechanics, Svratka, Czech Republic.
- Sonnenschein, R., Gajdosova, K., & Holly, I. (2016). FRP composites and their using in the construction of bridges. *Procedia Eng*, 161, 477–482.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15(56), 1929–1958.
- Stratford, T., & Burgoyne, C. (2003). Shear Analysis of Concrete with Brittle Reinforcement. *ASCE Journal of Composites for Construction*, 7 (4), 323330.
- Swamy, R. N., & Andriopoulos, A. D. (1974). Contribution of aggregate interlock and dowel forces to the shear resistance of reinforced beams with web reinforcement. *Special Publication*, 42, 129-168.
- Taerwe, Luc. (1995). Non-metallic (FRP) reinforcement for concrete structures. *Proceedings of the Second International RILEM Symposium*, 29.
- Taghipour Anvari, A., Babanajad, S., & Gandomi, A. H. (2023). Data-Driven Prediction Models For Total Shear Strength of Reinforced Concrete Beams With Fiber Reinforced Polymers Using An Evolutionary Machine Learning Approach. *Engineering Structures*, 276.
- Taljsten, B., & Elfgren, L. (2000). Strengthening concrete beams for shear using CFRP-materials: evaluation of different application methods. *Compos Part B*, 31(2), 87–96.
- Tanarlan, H. M., Secer, M., & Kumanlioglu, A. (2012). An approach for estimating the capacity of RC beams strengthened in shear with FRP reinforcements using artificial neural networks. *Construction and Building Materials*, 30, 556–568.
- Tapeh, A. T. G., & Naser, M. Z. (2022). Artificial Intelligence, Machine Learning, and Deep Learning in Structural Engineering: A Scientometrics Review of Trends and Best Practices. *Archives of Computational Methods in Engineering* 2022 30:1, 30(1), 115–159.
- Taylor, H. P. (1974). The fundamental behavior of reinforced concrete beams in bending and shear. *Special Publication*, 42, 43-78.
- Teng, J.G., Chen, Jian. Fei., Smith, Scott. T., & Lam, L. (2002). FRP: strengthened RC structures. *Front Phys*, 266.
- Tetta, Z. C, Koutas, L. N, Bournas D. A. (2016). Shear strengthening of full-scale RC T-beams using textile-reinforced mortar and textile-based anchors. *Compos Part B Eng*, 95, 225–39.

- Thai, H. T. (2022). Machine learning for structural engineering: A state-of-the-art review. *Structures*, 38, 448–491.
- Tharwat, A. (2019). Parameter investigation of support vector machine classifier with kernel functions. *Knowledge and Information Systems*, 61(3), 1269–1302.
- Triantafillou, T. C. (1998). Shear strengthening of reinforced concrete beams using epoxy-bonded FRP composites. *ACI Structural Journal*, 95, 107–115.
- Tuakta, C. (2005). Use of fiber reinforced polymer composite in bridge structures M. Eng. Thesis, Massachusetts Institute of Technology, Cambridge, MA USA.
- Uomoto, T., Mutsuyoshi, H., Katsuki, F., & Misra, S. (2002). Use of fiber reinforced polymer composites as reinforcing material for concrete, *J. Mater. Civ. Eng*, 14 (3), 191–209.
- Van Den Einde, L., Zhao, L., & Seible, F. (2003). Use of FRP composites in civil structural applications. *Construction and Building Materials*, 17(6–7), 389–403.
- Vecchio, F. J., & Collins, M. P. (1986). The Modified Compression-Field Theory for Reinforced Concrete Elements Subjected to Shear. *ACI Journal Proceedings*, 83 (2), 219-231.
- Veličkovi, P. (2019). The resurgence of structure in deep neural networks. PhD thesis, University of Cambridge.
- Vo-Le, D., Tran, D. T., Pham, T. M., Ho-Huu, C., & Nguyen-Minh, L. (2022). Re-evaluation of shear contribution of CFRP and GFRP sheets in concrete beams post-tensioned with unbonded tendons. *Engineering Structures*, 259.
- Walraven, J. C. (1980). Aggregate interlock: a theoretical and experimental analysis [PhD thesis]. Delft, Netherlands: Delft University of Technology, 208.
- Wang, C., Zou, X., Sneed, L. H., Zhang, F., Zheng, K., Xu, H., & Li, G. (2023). Shear strength prediction of FRP-strengthened concrete beams using interpretable machine learning. *Construction and Building Materials*, 407.
- Wang, R. M., Zheng, S. R., & Zheng, Y. P. (2011). *Matrix materials. Polymer Matrix Composites and Technology* Woodhead Publishing Cambridge UK, 101–548.
- Weli, S. S., Abbood, I. S., Hasan, K. F., & Jasim, M. A. (2020, July). Effect of steel fibers on the concrete strength grade: a review. In *IOP Conference Series: Materials Science and Engineering* (Vol. 888, No. 1, p. 012043). IOP Publishing.
- Wenwei, W., & Guo, L. (2006). Experimental study and analysis of RC beams strengthened with CFRP laminates under sustaining load. *International Journal of Solids and Structures*, 43(6), 1372-1387.
- Wu, Q., Ma, L. I., Wu, L., & Xiong, J. (2016). A novel strengthening method for carbon fiber composite lattice truss structures. *Compos. Struct*, 153, 585–592.
- Wu, Y. F., & Jiang, J. F. (2013). Effective strain of FRP for confined circular concrete columns. *Composite Structures*, 95, 479–491.

- Wu, Z., Wang, X., Iwashita, K., Sasaki, T., & Hamaguchi, Y. (2010). Tensile fatigue behaviour of FRP and hybrid FRP sheets. *Composites Part B: Engineering*, 41(5), 396-402.
- Yadav, S. K., Schmalbach, K.M., Kinaci, E., Stanzione, J. F., G.R. Palmese, G. R. (2018). Recent advances in plant-based vinyl ester resins and reactive diluents. *Eur. Polym. J*, 98, 199–215.
- Yan, B., Tong, M., Furtado, C., Danzi, F., Arteiro, A., & Camanho, P. P. (2023). A design methodology of composite scarf repairs using artificial intelligence. *Composites Part B: Engineering*, 266, 111020.
- Yeh, Y. K., & Mo, Y. L. (2005). Shear retrofit of hollow bridge piers with carbon fiber-reinforced polymer sheets. *Journal of Composites for Construction*, 9(4), 327-336.
- You, S., Ding, D., Canini, K., Pfeifer, J., & Gupta, M. R. (2017). Deep Lattice Networks and Partial Monotonic Functions. *Advances in Neural Information Processing Systems*, 2017-December, 2982–2990.
- Yu, Q., Le, J. L., Hubler, M. H., Wendner, R., Cusatis, G., & Bažant, Z. P. (2016). Comparison of main models for size effect on shear strength of reinforced and prestressed concrete beams. *Structural Concrete*, 17(5), 778–789.
- Yu, T., Fernando, D., Teng, J. G., & Zhao, X. L. (2012). Experimental study on CFRP-to-steel bonded interfaces. *Compos. B Eng*, 43 (5), 2279–2289.
- Zarringol, M., & Zarringol, M. (2016). A comparative study on the efficiency of CFRP and GFRP in the improvement of compressive strength, acoustic impedance and bracing of filled and hollow concrete columns in different layers and ages. *Journal of Sustainable Development*, 9(5), 110.
- Zhang, Z., & Hsu, C.-T. T. (2005). Shear Strengthening of Reinforced Concrete Beams Using Carbon-Fiber-Reinforced Polymer Laminates. *Journal of Composites for Construction*, 9(2), 158–169.
- Zhao, X. L., Bai, Y., Al-Mahaidi, R., & Rizkalla, S. (2014). Effect of dynamic loading and environmental conditions on the bond between CFRP and steel: state-of-the-art review. *J. Compos. Constr*, 18 (3).
- Zhong, J., Feng, L., & Ong, Y. S. (2017). Gene Expression Programming: A Survey [Review Article]. In *IEEE Computational Intelligence Magazine* (Vol. 12, Issue 3, pp. 54–72). Institute of Electrical and Electronics Engineers Inc.
- Zhou, J., Bi, F., Wang, Z., & Zhang, J. (2016). Experimental investigation of size effect on mechanical properties of carbon fiber reinforced polymer (CFRP) confined concrete circular specimens. *Construction and Building Materials*, 127, 643-652.
- Zhou, Y., Guo, M., Sui, L., Xing, F., Hu, B., Huang, Z., & Yun, Y. (2019). Shear strength components of adjustable hybrid bonded CFRP shear-strengthened RC beams. *Composites Part B: Engineering*, 163, 36–51.