



République Algérienne Démocratique et Populaire

Ministère de l'enseignement supérieur et de la recherche scientifique



Ecole Nationale Polytechnique

Département de Génie Civil

Laboratoire de Génie Sismique & Dynamique des Structures

Mémoire de fin d'études

En vue de l'obtention du diplôme d'Ingénieur d'Etat en Génie Civil

Thème

***Application des réseaux de neurones artificiels à
l'analyse des chaussées souples***

Réalisé par :

M. Housseem GHIAT

M. Mohamed El-Mehdi BOUKESSESSA

Proposé et dirigé par :

Pr. B. TILIOUINE

Promotion juin 2013

Ecole Nationale Polytechnique 10, Avenue Pasteur Hassen Badi BP182 El-Harrach

16200 Alger (Algérie)

Tel : 213 21 52 53 01/03 – Fax :213 21 52 29 73

www.enp.edu.dz

ملخص:

الهدف من هذا العمل هو إقتراح مقارنة بالشبكات العصبونية الإصطناعية بإستعمال برنامج Matlab من أجل تقييم الثوابت القابلة للإرتداد للمواد الحصوية الغير المعالجة والتي تعتبر بسيط مهم في تحليل الأرصفة المرنة وذلك إنطلاقاً من معطيات تجربة ثلاثية المحاور بتحميل مكرر.

النتائج توضح أنّ قيم الوحدات المحسوبة من طرف الشبكات دقيقة وأنّ للشبكات العصبونية الإصطناعية القدرة على إعطاء مفعول مختلف العوامل على الثابت، والنتائج توضح أنّ تحليل هيكل رصيف مسند على نموذج الشبكات عن طريق KENLAYER أكثر ثقة من نظيره المسند على نموذج $K.\theta$.

تقدم الشبكات أيضاً بديلاً عن التجربة الثلاثية المحاور حيث أنّها تجنب اللجوء إلى هذه الأخيرة بغية وصف المواد الحصوية تحت شروط غير محققة تجريبياً.

الكلمات المفتاحية: الشبكات العصبونية الإصطناعية, للمواد الحصوية الغير المعالجة, الأرصفة المرنة, تجربة ثلاثية المحاور بتحميل مكرر, $K.\theta$.

Résumé :

Le but de ce travail est de proposer une approche réseaux de neurones artificiels (RNA) par l'utilisation du logiciel MATLAB pour estimer le module réversible des graves non traitées (GNT), qui est un paramètre clé dans l'analyse des chaussées souples, à partir de résultats d'essais triaxiaux (TCR). Les résultats obtenus montrent que les valeurs des modules prédits par les RNA sont très précises et que les réseaux de neurones artificiels peuvent reproduire l'effet des différents facteurs sur le module. Les résultats montrent aussi qu'une analyse d'une structure de chaussée basée sur le modèle RNA faite moyennement le logiciel KENLAYER est plus fiable que son homologue en $K-\theta$. Les RNA offrent aussi une alternative aux TCR dans la mesure où ils épargnent le recours à ses derniers afin de caractériser les GNT sous des conditions non réalisés en essais.

Mots clés : Chaussées souples, Réseaux de neurones artificiels, MATLAB, $K-\theta$, critères de dimensionnement, modèle de Burmister, essai triaxial.

Abstract :

The aim of the present work is to provide an Artificial neural network (ANN) based approach by using MATLAB for estimating UGM resilient modulus, which is a key input parameter in the analysis of flexible pavement structures, based on results of triaxial test. Results obtained from the present study show that the resilient modulus values predicted by ANN are highly accurate and ANN's can reproduce the effects of different parameters on the modulus. Results show also that the analysis of pavement structure based on ANN model performed using KENLAYER is more reliable than the one based on $K-\theta$. ANN's offer also an alternative to the RLT. In fact, they avoid the recourse to the RLT in order to characterize UGM's under non realised laboratory tests.

Key words : flexible pavement, artificial neural network, MATLAB, $K-\theta$, design criteria, Burmister model, triaxial test.

Remerciement

Nous remercions notre Dieu le Tout Puissant et Miséricordieux de nous avoir accordé force, courage, persévérance et détermination afin de mener à son terme ce modeste travail.

Nos vifs remerciements s'adressent à notre promoteur et directeur de thèse le Professeur Tiliouine qui nous a été d'une aide essentiel et pour sa présence permanente afin de nous diriger, conseiller et apporter l'appui scientifique nécessaire afin de mener à bien notre travail.

Que les membres du jury en particulier le Pr.Hamouténe et M. Demidem trouvent ici l'expression de toute notre gratitude pour nous avoir fait l'honneur d'accepter l'examen de notre projet.

Nous tenons à remercier Mr. Sandjak de l'université de Boumerdes et chercheur au laboratoire LGSDS qui n'a pas ménager les efforts afin de nous apporter son aide.

Nos sincères remerciements s'adressent à Ali Haimoud Chouaib ingénieur ENP promo 2012 qui nous a été d'une aide très précieuse.

Nous tenons à remercier M. Hiloul du département d'automatique qui n'a montré aucune hésitation à répondre à l'appel afin de nous apporter ses éclaircissements.

Nous souhaiterions exprimer notre profond respect à tous les enseignants qui ont contribué à notre formation du deuxième cycle universitaire à l'Ecole Nationale Polytechnique.

Que tous ceux qui ont contribué de près ou de loin à la réalisation de ce modeste travail, que tous ceux qui ont su nous soutenir durant sa préparation, que toutes ces personnes trouvent ici l'expression de nos plus chaleureux remerciements.

Dédicaces

Je dédie cet accomplissement à mes chers et adorés parents. A ma mère mon exemple de courage et de persévérance, et ma source de quiétude. A mon père mon éternel source d'inspiration et de motivation.

A ma sœur Sarah ainsi qu'à sa petite famille.

A ma petite sœur adorée Meriem et à mon frère Abderrahmane.

Au petit ange de la famille ma petite nièce Lilia.

A mes grands parents Bba et Hbiba.

A ma tante Zoulikha ainsi qu'à toute sa famille.

A mes cousins avec qui j'ai grandi Sidi Mohamed et Aboubaker.

A mon oncle Noredine. Je tiens à te remercier pour toute l'aide que tu m'as apporté.

A toute la famille BOUKESSESSA et à toute la famille BENHALIMA.

Je le dédie aussi :

A mes amis Mohamed ams, Mehdi 29, Moustapha 13, Ayoub watanabé et son frère Mohamed, à Mohamed jap's, à Yacine et à Ahmed la SM et à la promo 3SE 2007. A Abdelillah et Karim: les souvenirs de la Z16 resteront gravés à jamais dans la mémoire. A Fares, Juba, Sidou, Islam, Nassim, Adel et Saïd tizi, à islam jari aux AbdenourS power et à A toute la promo Génie civil 2013.

A mon binôme et notre hacker Houssem.

A ceux que j'ai laissé de l'autre coté de la méditerranée : à Alaaeddine, Anis, Hichem, Jibril et à Souhaib.

W fi khater gaz hababna lli yabghouna.

Mehdi

Dédicace

Je dédie ce travail en premier lieu à mes parents. À ma mère que jamais je trouverai une personne pareille et à mon père l'homme qui a tout fait pour que je réussisse dans ma vie. Je tiens à m'excuser au préalable de vous chère mère et chère mère, je sais que j'étais pas toujours à la hauteur de vos attentes et j'espère que je le serais avec ce travail.

À mes deux magnifiques frères Aymen et Akrem. Vous avez grandi sans que je me rende compte, je vous aime ^^.

À ma petite adorable sœur ma joie de vivre Racha.

À mon oncle Mohammed 'baba'

À ma tante Tata

À ma tante Hassiba

À ma tante Dalila

À ma tante Sakina

À ma tante Zbida

À mes cousins et cousine.

À toute la famille GHIAI et à toute la famille BOUADAM.

Je le dédie aussi à une personne qui a été toujours là pour moi, une personne à qui je tiens énormément, mon ange Kenza, je serais toujours là pour toi quoi que arrive.

Table des matières

Introduction générale	7
1 Généralités sur la mécanique des chaussées	9
1.1 Structures des chaussées souples	10
1.1.1 Définitions	10
1.1.2 Fonctionnement	10
1.2 Les méthodes de dimensionnement des chaussées	11
1.2.1 L'approche empirique	11
1.2.2 L'approche théorique	12
Le modèle de BOUSSINESQ (modèle monocouche)	13
Les modèles bicouches	14
Le modèle multicouches de Burmister	17
Modèles éléments finis	18
1.3 Caractéristiques des matériaux routiers	19
1.3.1 Les matériaux bitumineux	19
Le module complexe	19
Phénomène de fatigue	20
Définition	20
La courbe de Wöhler	20
Conclusion sur les matériaux bitumineux	20
1.3.2 Les matériaux granulaires non traités	21
Module linéaire	21
Module réversible	21
Définitions	21
Évaluation par essai tri-axial à charges répétées (TCR)	22
Relation module réversible-contrainte	26
1.3.3 Sol support	27
Loi de comportement du sol	27

	Modélisation du sol support	27
1.4	Conclusion	29
2	Généralités sur les réseaux de neurones artificiels	30
2.1	Définitions	31
2.1.1	Qu'est-ce qu'un réseaux ?	31
2.1.2	Neurone	31
	Neurone biologique	31
	Neurone formel	32
2.1.3	Réseaux de neurones artificiels (RNA)	33
2.2	Types de RNA	33
2.2.1	Les réseaux de neurones non bouclés	34
	Le perceptron	35
	Le perceptron multicouches (PMC)	36
2.2.2	Les réseaux de neurones bouclés	36
2.3	Apprentissage des réseaux de neurones	37
2.3.1	Types d'apprentissage	39
	Apprentissage supervisé	39
	Apprentissage renforcé	39
	Apprentissage non supervisé	39
2.3.2	Règles d'apprentissage	39
	La règle delta (apprentissage par correction d'erreur)	39
	La règle de Hebb	40
2.3.3	Algorithme d'apprentissage	40
	Rétro-propagation	40
3	Simulation de la loi de comportement des GNT par RNA	43
3.1	Modélisation de l'architecture du réseau de neurones	44
3.1.1	Choix du type du réseau	44
3.1.2	Choix de la structure du réseau	44
3.1.3	Choix des fonctions d'activation	44
3.1.4	Choix de l'algorithme d'apprentissage	44
	critères de sélection	45
3.1.5	Machine d'apprentissage	45
3.2	Entraînement du réseau et résultats de la simulation	47
4	Application de l'approximation de Mr par RNA à l'analyse des chaussées souples	50
4.1	Description du logiciel KENLAYER	51
4.1.1	Présentation du logiciel	51

4.2	L'analyse non linéaire dans KENLAYER	51
4.3	Présentation de la structure d'étude	53
4.4	Démarche entreprise dans l'analyse non-linéaire basée sur le modèle RNA .	53
4.4.1	Principe de la démarche	53
4.4.2	Description du programme développé	54
4.5	Résultats et discussion	55
5	Prédiction du module réversible et enrichissement de bases de données	57
5.1	Littérature	58
5.2	Conception du réseau de neurones	58
5.2.1	Choix des paramètres d'entrées (facteurs d'influence	58
5.2.2	Architecture du réseaux de neurones	59
5.3	Résultats du test du réseau retenu	59
5.4	Application : Enrichissement de la base de données	61
	Conclusion générale	63

Table des figures

1.1	Structure de chaussées souples	10
1.2	Fonctionnement d'une chaussée souple	11
1.3	Réponse d'une structure de chaussée à une charge roulante	12
1.4	Principe de l'approche mécanistique du dimensionnement des chaussées	14
1.5	Diffusion de pression dans un massif de boussinesq	15
1.6	Travail en flexion d'une couche liée	15
1.7	Diffusion de la contrainte selon Westergaard	17
1.8	Modèle de Burmister	18
1.9	Définition du module réversible	22
1.10	Appareillage du tri-axial à charges répétées	23
1.11	Principe du tri-axial à charges répétées	24
1.12	Comportement du sol et définition des différents modules	28
2.1	Structure simplifié du neurone biologique	32
2.2	Évaluation de la sortie en présence et absence du biais b	33
2.3	Rôle de la fonction de sommation	33
2.4	Différentes fonction d'activation	34
2.5	Représentation d'un neurone formel	34
2.6	Représentation simplifié d'un RNA	35
2.7	RNA de type feed-forward	35
2.8	Le Perceptron : structure et comportement.	35
2.9	RNA de type feed-back	36
2.10	Évolution de l'erreur moyenne sur la base d'apprentissage et celle du test.	38
2.11	Phénomène du sur-apprentissage	38
2.12	Les différentes implémentation de la rétro-propagation des erreurs	41
3.1	Organigramme représentant le fonctionnement de la machine d'apprentissage	46
3.2	Droite de corrélation entre M_r expérimental et M_r RNA	47
3.3	Droite de corrélation entre M_r expérimental et $M_r K - \theta$	48

3.4	résultats du test de performance de l'architecture choisie	48
3.5	résultats du test de performance du modèle $K - \theta$	48
3.6	Exemple d'un RNA qui a subis un sur-apprentissage	49
4.1	Les étapes de l'approximation itérative incluse dans KENLAYER	52
4.2	Principe de l'approche itérative simplifiée utilisée dans KENLAYER	52
4.3	Structure de chaussé choisie	53
4.4	Organigramme de l'analyse non-linéaire basée sur l'approximation RNA	54
4.5	Variation de Mr dans la structure selon le $K - \theta$ et le RNA	55
5.1	Architecture du réseau de neurones.	59
5.2	Effet de la teneur en eau sur le module réversible	59
5.3	L'effet de la densité sur le module réversible comme prédit par RNA	60
5.4	L'effet de σ_3 sur le module réversible comme prédit par RNA	60
5.5	RNA toolbox sur MATLAB	66
5.6	Interface graphique pour la création d'un réseau de neurones	67
5.7	Interface graphique pour l'approximation de fonctions	67

Liste des tableaux

1.1	Valeurs retenus par le catalogue algerien pour le module E	20
4.1	Déformations aux interfaces BB/GNT et GNT/S.Support selon les deux approches	55
4.2	Nombre de répétition de charges pour les deux analyses	56
5.1	Base de données enrichie	61

Introduction générale

Le développement de l'infrastructure routière occupe une importance économique et stratégique particulière. Le réseau routier algérien est constitué principalement de structures de chaussées souples dont une grande partie se trouve dans un état peu satisfaisant. Dans ce type de structures les matériaux granulaires non-traités(MNT) sont utilisés comme couches de bases et couches de fondations. Ils jouent de ce fait un rôle essentiel dans la performance structurelle globale de la chaussée. La bonne connaissance du comportement de ce type de matériaux ainsi qu'une caractérisation rationnelle de leurs principales propriétés mécaniques est donc d'une importance capitale.

Durant les dernières décennies d'importants travaux de recherches ont été entrepris afin de cerner le comportement des matériaux granulaires non-traités. Ces travaux ont révélé que les matériaux granulaires non traités ont un comportement réversible non-linéaire dépendant de l'état de contrainte au moment de la réponse. Une non-linéarité qui est plus manifeste pour les structures de chaussées souples faisant appel aux MNT comme principaux éléments de diffusion des charges, c'est à dire des structure à couche bitumineuse mince.

Le module réversible est un paramètre clé qui caractérise le comportement réversible non-linéaire des matériaux non-traités. Plusieurs modèles liant le module réversible à l'état de contrainte à des degrés de sophistication variés ont été développés, le plus connu étant le $k - \theta$. De nombreux travaux de recherche ont aussi confirmé que le module réversible est fortement influencé par la teneur en eau, la densité sèche, la granulométrie des matériaux ainsi que la pourcentage des fines.

L'essai de laboratoire qui simule adéquatement le comportement des matériaux sous des conditions in-situ des charges de trafic et sous différents conditions est l'essai tri-axial à charges répétées. Le test peut être réalisé avec différentes contraintes, densités et teneurs en eau...etc pour ainsi apprécier l'influence des différents paramètres sur le module réversible.

Les réseaux de neurones artificiels (RNA) est un puissant outil basé sur des méthodes mathématiques et doté d'une intelligence artificiel qui a connu un essor particulier

ces derniers temps et qui fait l'unanimité quant à sa capacité à résoudre avec efficacité, fiabilité et robustesse des problèmes complexes non descriptibles sous forme analytique. Les réseaux de neurones ont de plus prouvé leur supériorité par rapport aux techniques de régressions classiques conduisant aux équations de prédiction d'un phénomène donné. Les principaux avantages de l'approche RNA sont d'une part l'absence d'a priori des formes fonctionnelles régissant la dépendance aux différents paramètres, celle-ci devant "automatiquement" émerger des données, ainsi qu'une quantification simple de l'importance relative des variables indépendantes qui affectent un phénomène donné.

Objectif du mémoire : Le présent mémoire a pour objectif de proposer un champ d'application des réseaux de neurones artificiels à la caractérisation du module réversible des graves non traitées et à l'analyse des chaussées souples. Deux principales applications ont été abordées : l'approximation de la loi de comportement des GNT par RNA et son incidence sur l'analyse d'une structure de chaussée souple ; et la prédiction du module réversible pour des conditions non réalisées en essai et l'enrichissement de bases de données, chose qui présenterait un intérêt économique considérable notamment pour les petites juridictions n'ayant pas les ressources nécessaires à la réalisation des essais tri-axiaux.

Organisation du mémoire : Notre mémoire se compose de cinq chapitres. Dans le premier chapitre nous allons passer en revue les principes de base de la mécanique des chaussées. Le deuxième chapitre est une introduction aux réseaux de neurones artificiels où nous allons présenter les définitions de bases ainsi que les principes de fonctionnement des RNA. Au troisième chapitre nous abordons le problème de l'approximation de la loi de comportement de la GNT par RNA et sa comparaison avec le modèle $K - \theta$. La comparaison entre l'analyse d'une structure de chaussée souple basée sur le modèle RNA et une autre basée sur le modèle classique $K - \theta$ est faite au quatrième chapitre. Le cinquième chapitre traite de la prédiction du module réversible pour des conditions non réalisées en essai et l'enrichissement de bases de données. Enfin, une conclusion générale synthétisera les principaux résultats auxquels nous sommes parvenus.

CHAPITRE 1

Généralités sur la mécanique des chaussées

En premier lieu, une brève définition des structures de chaussées sera faite. Par la suite les différentes théories de dimensionnement des chaussées seront passées en revue. Enfin Les caractéristiques des différents matériaux rentrant dans la composition de chaussés souples seront abordées.

Le sol naturel étant généralement incapable de supporter les pressions exercées par les pneumatiques (de l'ordre de 0,2 à 0,7MPa), la chaussée a pour rôle de diffuser cette pression afin de l'amener à un niveau pouvant être supporté par le sol support. Ceci se fait par la superposition de couches (structure) de matériaux à caractéristiques décroissantes (en termes de rigidité) jusqu'au sol support. Le trafic routier sans cesse croissant a fait apparaître le besoin de développer des matériaux plus performant. Plusieurs types de structures de chaussées ont ainsi vu leurs apparitions avec le développement de ces matériaux. On peut citer à titre d'exemple les structures de chaussées souples, les structures de chaussées rigides, semi rigide et mixtes dans ce chapitre nous allons nous intéressés au type de structures faisant l'objet de notre mémoire, c'est-à-dire les chaussées souples.

1.1 Structures des chaussées souples

1.1.1 Définitions

C'est la présence des graves non traitées (GNT) qui donne le caractère souple à ce type de chaussées. Notons qu'il existe ce qu'on appelle les chaussées extra souples : c'est un empierrement non revêtu de matériaux granulaires, généralement répandus dans les pays peu développés. Une chaussée souple se compose :

- D'une couche de roulement mince en matériaux bitumineux parfois réduite à un enduit superficielle sur chaussées à très faible trafic.
- D'une assise en une ou plusieurs couches de matériaux granulaires non traités (GNT). L'assise est composée d'une couche de base et d'une couche de fondation dans le cas du RP2 (réseau principal 2) tandis que pour le cas du RP1 (réseau principal 1) elle n'est composée que d'une couche de fondation.

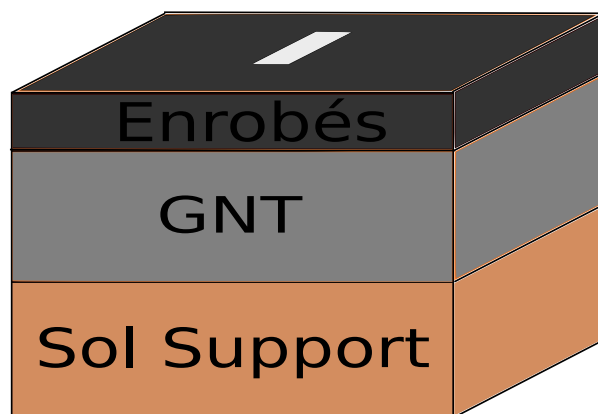


FIGURE 1.1 – Structure de chaussées souples

1.1.2 Fonctionnement

Leur fonctionnement peut être schématisé comme l'indique la figure (1.2) Comme la couverture bitumineuse est mince, les efforts verticaux sont transmis au support avec

une faible diffusion. Les contraintes verticales élevées engendrent par leur répétition des déformations plastiques qui se répercutent en déformation permanentes à la surface de la chaussée. La couverture bitumineuse subit à la base des efforts répétés de traction-flexion.

L'évolution la plus fréquente des chaussées souples se manifeste d'abord par l'apparition de déformations de type ornièrage et affaissement qui détériorent les qualités des profils en travers et en long.

Les sollicitations répétées de flexion alternée dans la couverture bitumineuse entraînent une détérioration par fatigue sous forme de fissures.




FIGURE 1.2 – Fonctionnement d'une chaussée souple

1.2 Les méthodes de dimensionnement des chaussées

Le dimensionnement d'une chaussée consiste à déterminer la nature et l'épaisseur des différentes couches qui la constituent afin qu'elle puisse résister aux charges routières. Ce dimensionnement obéit au principe de dimensionnement de tout ouvrage en génie civil à savoir l'analyse des contraintes et des déformations dans les différentes couches et la comparaison de celles-ci aux valeurs limites trouvées expérimentalement. De ce fait, les méthodes de dimensionnement des chaussées ne sont en fait que des méthodes de vérification de chaussées préalablement établies.

Deux approches de dimensionnement subsistent : l'approche empirique et l'approche rationnelle.

1.2.1 L'approche empirique

Cette approche est basée sur l'observation du comportement de chaussées réelles ou expérimentales sous trafic et la déduction de règles de dimensionnement à l'aide de méthodes statistiques. La démarche est la suivante : un critère de fin de durée de vie est d'abord fixé. La durée de vie de chacune des sections observées est ensuite déterminée selon ce critère et on établit par des méthodes statistiques de régression multiple, des relations entre la durée de vie et les épaisseurs des couches ainsi que leurs propriétés mécaniques.

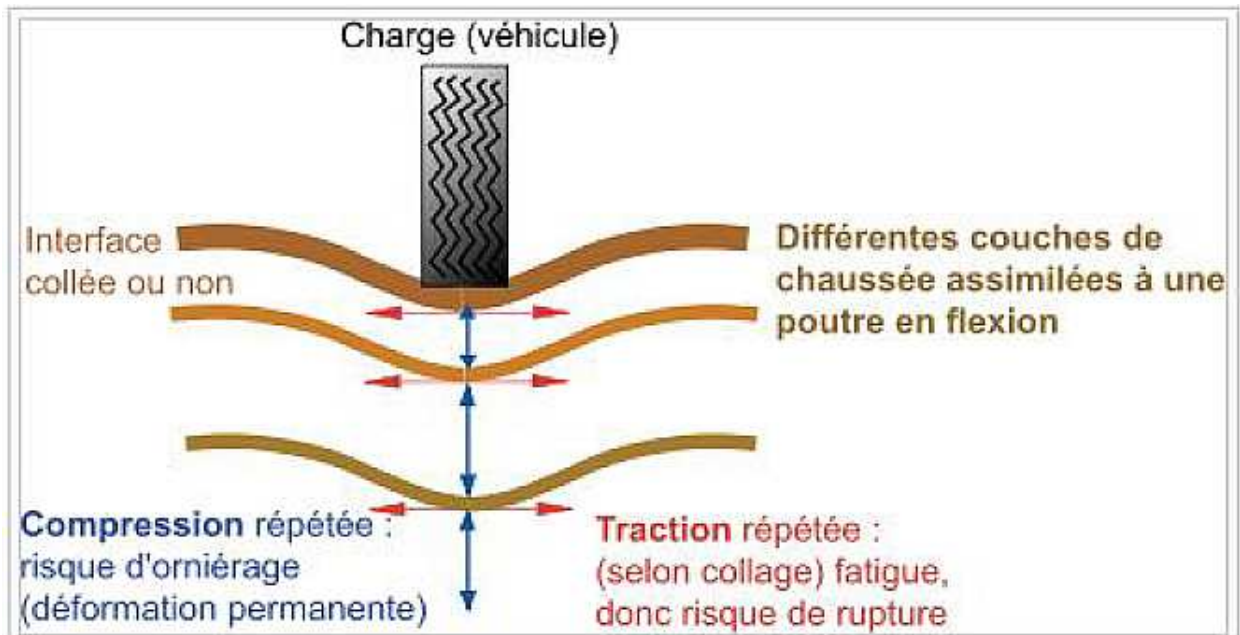


FIGURE 1.3 – Réponse d'une structure de chaussée à une charge roulante

Les premiers essais qui ont débouché vers les premières règles empiriques ont été réalisés par l'AASHO (American Association of State Highway Officials). En effet, 240 sections de chaussées souples, 271 sections de chaussées rigides et une cinquantaine de sections de chaussées souples avec couche de base stabilisée ont été soumises à environ 1 million de charges roulantes ce qui a permis :

- de fixer des lois d'équivalence entre les charges de poids différents,
- de relier statistiquement les déflexions à la structure de la chaussée,
- de définir un indice de qualité de service des chaussées et d'étudier ses variations avec le trafic, en relation avec la structure de la chaussée.

Cependant cette approche a ses limites :

- le coût exorbitant du grand nombre d'essai qu'il faudra afin de connaître l'influence de paramètres telles que les épaisseurs des différentes couches et les propriétés mécaniques des matériaux.
- le temps de réponse est très long car il n'y a pas d'effet d'accélération du trafic, et les extrapolations sont hasardeuses.
- L'impossibilité de généraliser due au fait que l'analyse statistique par régression ne s'applique qu'aux matériaux étudiés, qu'aux conditions d'environnement de l'expérimentation, et qu'aux sols supports rencontrés.

1.2.2 L'approche théorique

L'approche théorique fait appel à la mécanique des chaussées qui a pour objet de modéliser le comportement d'une chaussée afin de se rapprocher de son comportement réel. Différents modèles ont été proposés à travers le temps dont la plupart sont fondés sur la

mécanique des milieux continus (le modèle de **BOUSSINESQ** étant basé sur la mécanique des sols). A l'aide de ces modèles on détermine les sollicitations et les déformations qui sont comparées aux sollicitations et aux déformations admissibles.

La vérification mécanique porte en fait sur deux points :

- Une vérification vis-à-vis de la rupture par fatigue : on vérifie que la rupture par fatigue ne se produit pas avant la fin de la durée de vie souhaitée pour la chaussée, ou encore que, si la rupture par fatigue dans une couche donnée se produit, elle ne se manifestera pas en surface avant la fin de cette durée de vie.
- Une vérification vis-à-vis des déformations permanentes à la surface de la chaussée, on vérifie que les déformations permanentes dans les matériaux de chaussées qui peuvent en présenter (matériaux non liés ou à liants hydrocarbonés) et dans le sol-support, ne conduisent pas à l'apparition en surface de déformations excessives, produisant des ornières.

Il est à préciser que ces modèles n'ont connu un réel essor qu'avec le développement de l'outil informatique qui a permis un l'emploi aisé des méthodes numériques (éléments finis, différences finis) et qui a dispensé des calculs manuels très fastidieux pour la résolution des équations différentielles.

Il est aussi important de préciser que la proposition d'un modèle mécanique de la chaussée n'est qu'une partie de son analyse. La seconde partie et la plus importante est la modélisation du comportement des matériaux qui vont servir à la réalisation de la structure de la chaussée et du sol-support, c'est-à-dire la définition des paramètres dont le modèle dépend.

Le modèle de BOUSSINESQ (modèle monocouche)

Ce modèle suppose que la pression exercée par les pneumatiques est amenée à un niveau supportable par le sol-support par un matériau dont le comportement est semblable à celui du sol (un matériau granulaire par exemple) et donc auquel on peut appliquer la loi de répartition des pressions dans le sol de BOUSSINESQ :

$$\sigma_z = q_0 \frac{1 - z^3}{(a^2 + z^2)^3}$$

Ceci conduit à définir une méthode simpliste de dimensionnement :

- La pression appliquée à la chaussée est schématisée par une pression q_0 sur un cercle de rayon a .
- Le sol-support est supposé élastique (module de Young E_2 , coefficient de Poisson ν_2). Il ne peut supporter sans se déformer exagérément qu'une contrainte admissible inférieure à la pression q_0 .
- On cherche à quelle profondeur h du sol la pression verticale a été suffisamment diffusée pour ne pas dépasser la contrainte admissible.

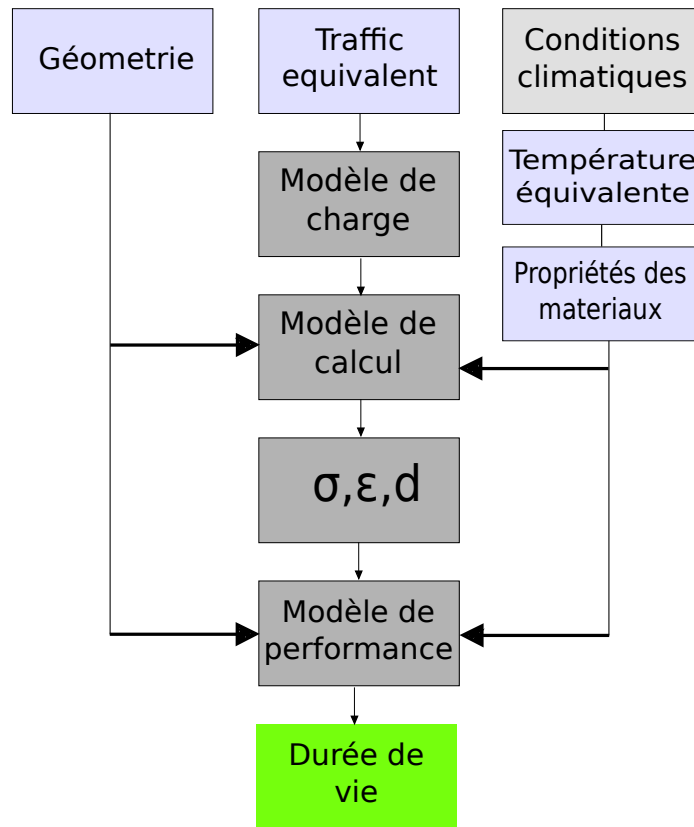


FIGURE 1.4 – Principe de l'approche mécanistique du dimensionnement des chaussées

- On peut assimiler l'épaisseur H à l'épaisseur de chaussée ou bien lui faire correspondre une épaisseur de chaussée $H' < H$ par une règle simple tenant compte du module E_1 du corps granulaire et du module E_2 du sol-support.

Pour une contrainte admissible égale à $\frac{q_0}{10}$ l'épaisseur H est de $3,7a$. En sachant que a est de l'ordre de 15cm , on peut déduire que H est de l'ordre de 55cm . Si la contrainte admissible du sol est très petite devant la pression appliquée q_0 , on peut être amené à adopter de très fortes épaisseurs de chaussées. (Une contrainte admissible de $\frac{q_0}{20}$ donnerait H égale à 85cm) Le module E_1 du corps du corps granulaire étant supérieur au module E_2 du sol-support, l'épaisseur H' qu'il conviendrait de donner à la chaussée est :

$$H' = H f\left(\frac{E_1}{E_2}\right), f\left(\frac{E_1}{E_2}\right) \leq 1$$

Les modèles bicouches

Comme l'indique le modèle de BOUSSINESQ, on peut être amenée à adopter des épaisseurs très importantes de matériaux granulaires dans le cas de contraintes admissibles très faibles du sol, chose qui ne peut être envisageable vu le cout élevée que cela représenterait. L'épaisseur peut être diminuée en adoptant des matériaux ayant un module E_1 nettement supérieur à celui du sol-support (en augmentant le rapport $\frac{E_1}{E_2}$). Ce résultat est atteint en employant des liants hydrauliques ou hydrocarbonés.

Cependant, en employant des matériaux lié on modifie complètement le fonctionnement mécanique de la chaussée. En effet, la couche de chaussée fléchit sous la charge




FIGURE 1.5 – Diffusion de pression dans un massif de boussinesq

appliquée ; ce fléchissement est accompagné de traction par flexion à la base de la chaussée qu'on ne peut admettre. Le dimensionnement de la chaussée consiste alors à vérifier deux critères qui conditionnent son comportement dans le temps :

- la contrainte verticale sur le sol-support doit être inférieure à une valeur limite fonction de la nature du sol-support et du nombre de chargements (cycles) envisagés.
- la contrainte de traction par flexion à la base de la couche de chaussée doit également être inférieure à une valeur limite fonction de la nature du matériau de chaussée et du nombre de cycles. L'étude d'un tel problème ne peut se faire à l'aide du simple modèle de Boussinesq. L'utilisation d'un modèle bicouche est nécessaire.




FIGURE 1.6 – Travail en flexion d'une couche liée

Le modèle de Hogg (1938) La chaussée représentée par une plaque au sens de Navier (Sous hypothèses de Navier pour les plaques minces) repose sur un massif infini de type Boussinesq (E_2, γ_2). Le comportement de la plaque est régi par l'équation de Lagrange des plaques minces :

$$D\Delta^2 w = p$$

avec

$$D = \frac{E_1 H^3}{12(1 - \gamma_1^2)}$$

Où w sont les déplacements verticaux de la fibre neutre de la plaque, D représente la rigidité de la plaque et p désigne la somme des pressions verticales, soit $p = \sigma_z - q_0$ à l'aplomb du cercle de charge et σ_z à l'extérieur de ce cercle.

L'opérateur différentiel Δ^2 désigne le double Laplacien en coordonnées polaires.

$$\frac{d^2}{dr^2} + \frac{1}{r} \frac{d}{dr}$$

Le problème comporte deux inconnues que sont : le déplacement vertical et la contrainte verticale sur le massif. L'équation de Lagrange fournit une relation entre ces deux inconnues. La contrainte sur le massif et les déplacements verticaux qui sont assimilés au déplacement verticaux du massif sont reliés grâce aux formules de Boussinesq.

Ainsi la contrainte de traction au bas de la couche liée est donnée par la relation de la forme :

$$\sigma_T = \frac{1}{H^2} \frac{1 + \gamma}{2} q_0 a^2 F\left(\frac{E_1 H^3}{E_2 a^3}\right)$$

Le modèle de Westergaard (1926) Westergaard a adopté pour le sol support une autre hypothèse simplificatrice de son comportement que celle du massif de Boussinesq. Cette approche facilite nettement les calculs en assimilant le sol-support à un assemblage de ressorts dont le déplacement vertical en un point (w) est proportionnel à la pression verticale (v), soit $v = kw$.

Le couplage de cette relation à l'équation de Lagrange donne une équation différentiel de 4^{eme} ordre pour laquelle l'utilisation des transformées de Henkel, assez analogues aux transformées de Fourier, aide beaucoup à la résolution. En effet, cette transformation possède la propriété de correspondre à l'opérateur Laplacien une multiplication par m^2 , où m est la variable transformée de x .

Il est à noter que la transformée inverse qui permet de remonter aux valeurs des fonctions recherchées n'est pas toujours facile. Néanmoins, on peut obtenir le résultat sous la forme de développement en séries se prêtant bien au calcul numérique (même manuel).




FIGURE 1.7 – Diffusion de la contrainte selon Westergaard

Le modèle multicouches de Burmister

En dépit des avantages qu'offrent les modèles bicouches décrits précédemment à savoir déterminer les grandes tendances de variations (rôle de l'épaisseur, rôle du rapport de module entre couches, influence du rayon de chargement) ces modèles possèdent deux limitations principales :

- Les chaussées souples traditionnelles sont en effet des structures tri-couches (sol, corps granulaire et enrobé). Aussi, dans les études de renforcement des schémas de structures ayant un nombre de couches plus important s'avèrent nécessaires
- Les modèles bicouches de Hogg et de Westergaard ainsi que le modèle monocouche de Boussinesq ne prennent pas en compte l'effet de la non-linéarité des matériaux granulaires.

Burmister a développé en premier en 1943 des solutions pour un système bicouches lesquels il a étendu par la suite pour un système tri-couches (Burmister, 1945)

Les hypothèses de base à vérifier pour l'utilisation du modèle de Burmister sont :

- Chaque couche est homogène, isotropique et linéaire élastique avec un module élastique E et un coefficient de poisson ν .
- Chaque couche a une épaisseur finie h à l'exception du sol support qui est considéré comme infini.
- Une pression uniforme q est appliquée à la surface sur une surface d'impact circulaire.
- Les conditions de continuité sont satisfaites aux interfaces entre les différentes couches : continuité des contraintes verticales et tangentielles et des déplacements verticaux ainsi que radiaux. Pour les interfaces décollées les contraintes tangentielles ainsi que des déplacements radiaux sont considérés comme nuls à chaque côté de l'interface.

Pour évaluer les contraintes et les déplacements dans les couches, Burmister a utilisé la théorie de l'élasticité et l'hypothèse de la symétrie de révolution du chargement qui a beaucoup facilité les calculs. Les transformations de Hankel ont facilité la résolution des équations du problème d'élasticité, en coordonnées cylindriques. Les formules sont




FIGURE 1.8 – Modèle de Burmister

généralisées pour n couches.

Modèles éléments finis

Le développement des méthodes numériques et en particulier la méthode des éléments finis, a permis d'envisager l'utilisation de modèles encore plus réalistes. On peut ainsi prendre en compte la non-linéarité des matériaux, les conditions complexes de contact entre les différentes couches, conditions complexes de chargement (forme de charge, les efforts horizontaux), viscoélasticité de la couche bitumineuse, les charges dynamiques, modélisation élasto-plastique. Les modèles éléments finis ont donné la possibilité de la modélisation tridimensionnelle des structures de chaussées, ce qui a permis d'utiliser des modèles de non linéarité tridimensionnelle (Classical- Universel, Modified-Universel, Couplé hyperélastique de Tacirouglu) même de faire des jumelages en cas de non linéarité de certaines couches. De nos jours plusieurs codes de calcul sont utilisés dans le dimensionnement et l'analyse des structures de chaussées, on peut citer à titre d'exemple :

- Le programme PANCH développé au laboratoire de génie sismique et dynamique des structures LGSDS à l'école nationale polytechnique d'Alger.
- Les programmes ALIZE 3 et CESAR du LCPC (Laboratoire Centrale des Ponts et chaussées - France).
- Le programme NOEL 8 de l'université de Nantes – France
- Le code de calcul FENLAP de l'université de Nottingham – Angleterre

– Le programme DIANA de l’université de Delft – Hollande

1.3 Caractéristiques des matériaux routiers

Les différents matériaux constitutifs des diverses couches d’une chaussée doivent présenter des caractéristiques mécaniques leur permettant de résister aux différentes sollicitations que subit la chaussée durant sa vie de service. Le dimensionnement des chaussées nécessite la connaissance des propriétés mécaniques des matériaux utilisés et leur comportement rhéologique. Ces matériaux peuvent être classés en général en deux types :

- matériaux traités (cas des matériaux bitumineux, grave-ciment, etc...)
- matériaux non-traités (graves non-traitées et sols)

Ces deux types de matériaux sont complexes : leur comportement est en général hétérogène, anisotrope, non-linéaire, et leurs propriétés dépendent parfois du temps, de la température, de leurs états hydriques, etc... Ceci montre la difficulté de l’étude rhéologique de ces matériaux, plus particulièrement pour la loi de comportement reliant les déformations aux contraintes.

Dans le but d’analyser ces structures de chaussées, on utilise des modèles avec des degrés de sophistication variés. L’approche simple, la plus souvent utilisée est l’analyse élastique de systèmes multicouches nécessitant la connaissance des paramètres de rigidité, tels que le module de *Young* et le coefficient de Poisson. Par ailleurs avec l’introduction de plus en plus de la méthode des éléments finis pour le traitement de la non-linéarité, on est amené à caractériser avec plus de précision cette rigidité, en tenant compte de l’effet des nombreux paramètres qui peuvent l’affecter ; comme l’état de contrainte, la température, ou les conditions hydriques pour les sols.

1.3.1 Les matériaux bitumineux

Le module complexe

Le comportement des matériaux bitumineux est caractérisé par ce qu’on appelle le module de déformation complexe E . Ces matériaux possèdent en effet un caractère viscoélastique qui se manifeste par un retard de la déformation sur la contrainte appliquée, un retard qui se traduit par un angle de déphasage Φ . Ceci s’écrit sous forme d’équations comme suit : pour une contrainte sinusoïdale imposée de la forme $\sigma(t) = \sigma_0 \sin \omega t$ la réponse en déformation est de la forme $\epsilon = \epsilon_0 (\sin \omega t - \Phi)$. Le module complexe s’écrit alors en notation imaginaire $E^*(i\omega) = |E^*| e^{i\Phi} = E_1 + iE_2$, $|E^*| = \sqrt{E_1^2 + E_2^2}$ appelé module de rigidité.

Le module est élevé lorsque le matériau est soumis à une sollicitation rapide est la rigidité est quasi élastique. Le contraire se produit lorsque la sollicitation est lente et le comportement est viscoplastique.

La deuxième variable influençant le module d’un enrobé est la température ; celle-

TABLE 1.1 – Valeurs retenus par le catalogue algerien pour le module E

Matériau	E(30 · C, 10Hz) (MPa)	E(25 · C, 10Hz) (MPa)	E(20 · C, 10Hz) (MPa)	E(10 · C, 10Hz) (MPa)
BB	2500	3500	4000	-
GB	3500	5500	7000	12500

ci un rôle symétrique de celui de la fréquence : aux fortes températures correspond un faible module qui augmente rapidement quand la température diminue. L'influence de la température sur le module est très importante puisque le module est divisé par 10 lorsque la température varie de 10°C à 40°C. On peut citer parmi les essais permettant caractériser le module complexe des matériaux bitumineux : l'essai de compression simple, traction indirecte, traction par flexion.

Phénomène de fatigue

Définition

Depuis très longtemps il a été observé que des pièces ou de matériaux peuvent se rompre si on leur applique de façon répétée un grand nombre de sollicitations dont l'amplitude est inférieure à la résistance à la rupture instantanée. C'est *le phénomène de fatigue*.

La courbe de Wöhler

L'expérience de base qui a pour objet de mettre en exergue le comportement à la fatigue d'un matériau consiste à soumettre une éprouvette de ce dernier à des sollicitations répétées identiques et à déterminer le nombre de répétitions provoquant la rupture.

La courbe qui représente le nombre de répétitions de sollicitations provoquant la rupture en fonction de l'amplitude de cette de la contrainte (ou déformation) appliquée s'appelle *la courbe de Wöhler*.

Plusieurs formes de relations ont été proposées afin de relier analytiquement l'amplitude de la sollicitation et la durée de vie. Toutes faisant intervenir le logarithme.

On rencontre le plus souvent les deux formes suivantes :

$\sigma = AN^{-Y}$ (La courbe de Wöhler est une droite en échelle logarithmique).

$\sigma = a - b \log N$ (la courbe de Wöhler est une droite en échelle semi-logarithmique).

Conclusion sur les matériaux bitumineux

Le catalogue de dimensionnement algérien des chaussées neuves retient les valeurs du module suivantes pour les matériaux bitumineux :

Le catalogue adopte aussi la formule suivante pour le calcul des déformations admissible :

$$\epsilon_{t,ad} = \epsilon_6(10^\circ C, 25Hz) \left(\frac{TCE_i}{10^6} \right)^{b_k \theta k r k c}$$

Où

$\epsilon_6(10^\circ C, 25Hz)$: est la déformation limite détenue au bout de 10^6 cycle avec une

probabilité de rupture de à $10^{\circ}C$ et $25Hz$ (essai de fatigue)

TCE_i : est le trafic cumulé en poids lourds

k_{θ} : Facteur lié à la température.

k_r : Facteur lié à au risque et aux dispersions

k_c : Facteur lié au calage des résultats du modèle avec le comportement observé sur les chaussées.

Il existe une autre expression du modèle de performance de la couche bitumineuse adoptée par entres autres ; Asphalt Institut et par Shell :

$$N_f = f_1(\epsilon_t)^{-f_2} E_1^{-f_3}$$

Où f_1, f_2, f_3 sont des constantes déterminées expérimentalement par test de fatigue avec f_3 tenant compte des observations faites sur le terrain. Asphalt institue utilise 0.0769, 3.291, 0.854 pour f_1, f_2, f_3 respectivement tandis que Shell adopte les valeurs suivantes : 0.0658, 5.671, 2.363.

1.3.2 Les matériaux granulaires non traités

Malgré la large utilisation de la théorie de l'élasticité linéaire dans l'analyse des structures de chaussées, il est reconnu que les matériaux granulaires non liés ont un comportement élastique non-linéaire ; leur rigidité étant fonction de l'état de contrainte. Dans la dernière décennie, la plupart des recherches de caractérisation des couches de base granulaires, ont demandé le développement d'essais tri-axiaux à chargements répétés et l'application de modèles non-linéaires.

Module linéaire

Le catalogue algérien de dimensionnement adopte comme module de rigidité une valeur moyenne égale à $500MPa$ appelée module caractéristique pour la GNT - qui peut varier en fonction de la classification cette dernière - employée en couche de base. Pour la couche de fondation un coefficient ($k = 2.5$) pondère le module du sol support afin d'obtenir celui de la GNT. Dans le cas où la couche de fondation est réalisée en plusieurs sous couches ce même coefficient pondère le module de la $(i-1)^{me}$ sous couche afin d'obtenir celui de la i^{me} . Ceci est en effet une approximation grossière car plusieurs études ont montré que considérer la GNT comme un matériau linéaire donne des résultats loin de la réalité ; constatation qui prend toute son ampleur dans le cas des chaussées souples.

Module réversible

Définitions

Le module réversible est le module élastique utilisé dans la théorie élastique. Il est bien connu que la plupart des matériaux routiers ont un comportement non-élastique. Cependant, si la charge est petite comparée à la résistance du matériau

et si elle est répétée un certain nombre de fois, la déformation due à chaque répétition de la charge est pratiquement totalement récupérée (réversible) et est proportionnelle à la charge ce qui permet de considérer le comportement du matériau comme élastique.

En effet, un échantillon soumis à un chargement répété se comporte comme suit (voir figure 1.9) : aux premiers cycles de l'application de la charge la partie non réversible (plastique) de la déformation est considérable. Au fur et à mesure que le nombre de répétitions augmente la déformation plastique due à chaque répétition de la charge décroît jusqu'à ce que la déformation devienne entièrement réversible (ϵ_r sur la figure).




FIGURE 1.9 – Définition du module réversible

Le module élastique basé sur les déformations réversibles sous chargement répétées est appelé module réversible et est défini comme suit :

$$M_r = \frac{\sigma_d}{\epsilon_r}$$

Où

σ_d : est la contrainte déviatorique qui représente la différence entre les deux contraintes principale dans un essai tri-axial.

ϵ_r : est la déformation réversible.

Le module réversible est généralement évalué en laboratoire à l'aide d'un essai tri-axial à chargement répété (TCR).

Évaluation par essai tri-axial à charges répétées (TCR)

L'équipement tri-axial (T.C.R) a été développé en premier lieu en 1974 à l'Université de Nottingham par Brown et son équipe, et à partir de 1980 en France par le L.C.P.C. Cet essai est apparu comme l'outil adéquat pour l'étude du comportement des graves non-traitées de par la similitude qu'il présente par rapport aux contraintes induites par le trafic, surtout en simulant la répartition des charges.

Les résultats expérimentaux issus des essais tri-axiaux ont beaucoup aidé au développement des modèles de comportement théoriques dans le cas réversible non-linéaire et pour les déformations permanentes des matériaux granulaires. Ces modèles ont été utilisés dans des calculs par éléments finis pour prédire la réponse des structures de chaussée.



FIGURE 1.10 – Appareillage du tri-axial à charges répétées

Principe de l'essai : Cet essai consiste à appliquer à une éprouvette une pression de confinement (obtenue par l'air comprimé) et un déviateur (délivré par un vérin pneumatique) durant un grand nombre de cycles de chargement. La contrainte latérale σ_3 (contrainte principale minimale) est obtenue par la pression du fluide de la cellule. La contrainte principale maximale σ_1 est la somme de la pression du fluide et de la contrainte de chargement axiale.

$$\sigma_1 = q + \sigma_3$$

La procédure de l'essai du module réversible suit les étapes suivantes :




FIGURE 1.11 – Principe du tri-axial à charges répétées

- L'échantillon est placé dans une membrane à l'intérieur d'un moule de façon à obtenir la densité voulue ;
- Le chargement consiste en une impulsion de charge de 0,1 sec et une période de repos de 0,9 sec ;
- Des séquences de 200 chargements sont appliquées à différents niveaux de contrainte pour conditionner l'échantillon ;
- Une séquence de 200 chargements est ensuite appliquée à l'échantillon pour chacune des conditions suivantes ;

On distingue deux méthodes dans la pratique de l'essai triaxial à chargement répétés l'essai CLC et l'essai CLV.

Pression de confinement (kPa)	Déviateur σ_d (kPa)
138	69, 138, 207, 276
103	69, 138, 207, 276
69	34, 69, 138, 207
34	34, 69, 103

Essai CLC : Pour l'essai effectué à contrainte latérale constante (CLC), on applique une pression de confinement σ_3 constante (vecteur OA), et par suite le déviateur des contraintes $q = \sigma_1 - \sigma_3$ variant cycliquement entre 0 et une valeur maximale (vecteur AB). L'essai CLC est un cas particulier de chargement réel à condition que σ_3 reste au plus égale à 15 kPa à la base de la couche de fondation, ce qui correspond à la contrainte due au poids propre de la chaussée.

On note que :


$$p = \frac{\sigma_1 + 2\sigma_3}{3} = \frac{q}{3} + \sigma_3$$

Ce qui donne :

$$p_{max} = \frac{q_{max}}{3} + \sigma_{3max}$$

D'où une pente égale à 1/3 pour le vecteur AB.

Essai CLV : Pour l'essai effectué à contrainte latérale variable (CLV), la pression de confinement varie cycliquement de 0 à σ_{3max} en phase avec le deviateur des contraintes q , qui lui varie toujours entre 0 et q_{max} . (Vecteur OB). L'essai CLV correspond le mieux au chargement appliqué sur une chaussée réelle.



Relation module réversible-contrainte

L'essai triaxial permet de déterminer une relation entre le module réversible et la contrainte appliquée pour donner des modèles. Il permet aussi de reproduire les cheminements de contraintes les plus complexes susceptibles de se retrouver sur le terrain. Plusieurs modèles sont développés pour le calcul du module réversible des sols de plates formes et des matériaux granulaires utilisés pour couches d'assises. Ainsi nous avons :

Le modèle $K - \theta$ (matériaux à gros grains) Ce modèle est le plus fréquemment utilisé, et surtout pour les matériaux à gros grains

$$Mr = k_1 \theta^{k_2}$$

Où θ est la trace du tenseur état de contraintes donnée par : $\theta = \sigma_1 + 2\sigma_3$ en kPa.

σ_1 est la contrainte majeur verticale

σ_3 est la contraintes horizontale (sous hypothèse du modèle axisymétrique)

K_1, k_2 coefficients élastiques non linéaires déterminés expérimentalement.

Le modèle $k - \sigma_d$ (matériaux à grains fins)

$$Mr = k_1 \sigma_d^{k_2}$$

Mr est le module réversible en kPa.

$\sigma_d = \sigma_1 - \sigma_3$ Contrainte déviatorique en kPa.

K_1, k_2 coefficients élastiques non linéaires déterminés expérimentalement.

Le modèle d'Uzan et Witczac

$$Mr = k_1 \theta^{k_2} \sigma_d^{k_3}$$

C'est le modèle le plus représentatif des matériaux granulaires car il tient compte des effets de la résistance au cisaillement des matériaux. Mr est le module réversible en kPa

θ en kPa : somme de contraintes. σ_d Contrainte déviatorique en kPa. k_1, k_2, k_3 coefficients élastiques non linéaires déterminés expérimentalement

Le modèle Modified Universel Le modèle Modified Universel ou modified ASSHTO est considéré comme le modèle donnant la meilleur approximation de Mr en terme d'exactitude d'implémentation et d'exactitude. Ce modèle est donné par la formule :

$$Mr = k_1 Pa \frac{\theta^{k_2}}{Pa} \left(\frac{\tau_{oct}}{Pa} + 1 \right)^{k_3}$$

Pa est la pression atmosphérique. Dans un cas axisymétrique : $\tau_{oct} = \frac{\sqrt{2}}{3} \sigma_d$ Et k_1, k_2, k_3 coefficients élastiques non linéaires déterminés expérimentalement.

La détermination des paramètres des modèles se fait par différentes techniques de régressions linéaires, multi-linéaire, non-linéaire, non-linéaire multiple et des techniques de minimisation avec poids. Cette opération est appelée calage de modèle.

1.3.3 Sol support

Le sol support peut être considéré comme un matériau granulaire particulier avec une granulométrie plus étendue. Sa réponse aux chargements peut être très dépendante d'une certaine manière des conditions hydriques, de son histoire, etc... Le matériau sol a un comportement non-linéaire, qui se complique lors du dimensionnement par ses variations dans le profit en long de la chaussée et dans son état hydrique suivant les saisons.

L'utilisation d'une théorie élastique linéaire requière la connaissance de la valeur du module réversible, valeur qui affecte clairement le dimensionnement. Pour cela il existe, comme pour les graves non-traitées, deux approches : rapproche empirique utilisant la notion d'indice de portance CBR et l'approche rationnelle qui caractérise cette rigidité l'aide des essais à chargement répété ou bien à l'aide de l'essai de plaque.

Loi de comportement du sol

À partir d'un essai triaxial on peut apprécier le comportement d'un sol et ainsi définir quatre modules distincts :

- Le module tangent à l'origine E_0
- Le module tangent pour une valeur intermédiaire de la déformation ϵ_t
- Le module sécant $E_1 = \frac{\sigma_1 - \sigma_2}{\epsilon}$
- Le module réversible $E_2 = \frac{\sigma_1 - \sigma_3}{\epsilon_r}$

Modélisation du sol support

L'approche empirique (l'approche CBR) Le sol support est le seul matériau dans la structure de chaussée qui est imposé, et de ce fait, il est le point de départ dans le processus de dimensionnement. L'approche la plus largement utilisée dans ce cas pour évaluer la rigidité E_r du sol est de la relier à l'indice de portance C.B.R. sous la forme générale suivante :

$$E_r = K.CBR \quad (MPa)$$

La relation la plus utilisée est celle proposée par Heukelom et Klomp basée sur la corrélation des essais CBR avec des essais dynamiques in situ ;

$$E_r = 10.CBR \quad (MPa)$$

Il y a plusieurs objections à cette simple procédure. D'abord, l'essai CBR est un essai de pénétration sur une petite surface de sol chargée jusqu'à la rupture et




FIGURE 1.12 – Comportement du sol et définition des différents modules

ne présente pas les conditions de chargement dues au trafic où le niveau de contraintes répétées est bien inférieur à la contrainte de rupture. D'autre part, cet essai ne mesure pas la courbe caractéristique contraintes-déformations et les résultats sont beaucoup influencés par les conditions hydriques. Ainsi, la relation précédente est loin d'être satisfaisante, mais son grand avantage est sa simplicité.

L'approche rationnelle

Approche par essai tri-axial De façon similaire aux graves non-traitées, la caractérisation de la rigidité du sol requière des essais tri-axiaux à chargement répété sous des conditions appropriées. Comme pour les graves non-traitées, une approche utilisant un module du type K-G semble être la plus prometteuse pour caractériser avec précision les propriétés réversibles du sol support. Le module réversible non-linéaire M_r , d'un sol cohérent est relié aux contraintes par la relation :

Où K et n sont les constantes du sol, q le déviateur répété des contraintes dues au trafic et p_0 la contrainte effective moyenne dans le sol due au poids propre.

L'approche par essai de plaque Il permet d'apprécier directement le module d'un sol par un essai sur le terrain. Cet essai consiste à charger une plaque circulaire et à mesurer le déplacement vertical sous charge. On déduit ensuite un module de sol à l'aide de la formule de Boussinesq, qui relie le déplacement vertical

e, la pression q_0 , le rayon de charge a et les caractéristiques du massif E, ν .

$$E_\nu = \frac{\pi}{2}(1 - \nu^2) \frac{\sigma r}{e}$$

Dans la pratique le module de la couche de grave devrait être proportionnel à celui du sol avec un coefficient pouvant varier de 2 à 4. Ceci dans le but de modérer les contraintes transmises.

- 0 « 5 MPa sol très déformable (portance 0)
- 5 « 20 MPa sol déformable (portance 1)
- 20 « 35 MPa sol déformable (portance 2)
- 35 « 50 MPa sol peu déformable (portance 3)
- > 50 MPa sol très peu déformable (portance 4)

Orniérage du sol support On rappelle que l'endommagement d'une chaussée est peut être provoqué par les deux mécanismes que sont : la fatigue des matériaux liés ou l'accumulation des déformations permanentes sur le sol support appelé aussi orniérage.

Plusieurs chercheurs ont tenté de lier empiriquement par des modèles mathématiques la déformation permanente de compression pour le sol support sous une chaussée souple au nombre de répétition de la charge. Différents modèles ont ainsi été proposés par les différents auteurs :

Université de Nottingham $\epsilon_z = 21600 \cdot 10^{-6} N^{-0.28}$

Formule de Shell $\epsilon_z = 28000 \cdot 10^{-6} N^{-0.25}$

Formule CBR $\epsilon_z = 11000 \cdot 10^{-6} N^{-0.23}$

On note que la formule adoptée par le catalogue algérien de dimensionnement est la suivante :

$$\epsilon_{z,adm} = 2210^{-3} N^{-0.235}$$

1.4 Conclusion

Dans ce chapitre nous avons relaté l'essentiel de ce qui constitue la mécanique des chaussées. Dans ce qui suit, notre travail sera basé sur la théorie multicouche de Burmister décrite dans le premier paragraphe du chapitre. Parmi les modèles de non-linéarité des graves non-traitées nous retenons le modèle $K - \theta$ car étant le plus fréquemment utilisé et adopté par le programme KENLAYER qui sera décrit par la suite. Enfin, les modèles de performance adoptés afin d'apprécier la durée de vie de la chaussée sont ceux de Shell.

CHAPITRE 2

Généralités sur les réseaux de neurones artificiels

Les réseaux neuronaux sont construits sur un paradigme biologique, celui du neurone formel (comme les algorithmes génétiques le sont sur la sélection naturelle). Ces types de métaphores biologiques sont devenues courantes avec les idées de la cybernétique et bio-cybernétique. Celui-ci ne prétend pas davantage décrire le cerveau qu'une aile d'avion, par exemple, copier celle d'un oiseau. Ce chapitre portera sur les réseaux de neurones, leurs définition, l'analogie avec le system nerveux biologique, les différents types de réseaux existants, leurs apprentissages et les applications de ces nouveaux modèles de calculs.

2.1 Définitions

2.1.1 Qu'est-ce qu'un réseaux ?

Le terme générique " réseau " définit un ensemble d'entités (objets, personnes, etc.) interconnectées les unes avec les autres. Un réseau permet ainsi de faire circuler des éléments matériels ou immatériels entre chacune de ces entités selon des règles bien définies.

Selon le type d'entité concernée, le terme utilisé sera ainsi différent :

- réseau de transport : ensemble d'infrastructures et de disposition permettant de transporter des personnes et des biens entre plusieurs zones géographiques
- réseau téléphonique : infrastructure permettant de faire circuler la voix entre plusieurs postes téléphoniques
- réseau de neurones : ensemble de cellules inter-connectées entre-elles
- réseau de malfaiteurs : ensemble d'escrocs qui sont en contact les uns avec les autres (un escroc en cache généralement un autre !)
- réseau informatique : ensemble d'ordinateurs reliés entre eux grâce à des lignes physiques et échangeant des informations sous forme de données numériques (valeurs binaires, c'est-à-dire codées sous forme de signaux pouvant prendre deux valeurs : 0 et 1)

2.1.2 Neurone

Neurone biologique

Un neurone, ou cellule nerveuse, est une cellule excitable constituant l'unité fonctionnelle de base du système nerveux. Le terme de " neurone " fut introduit dans le vocabulaire médical en 1881 par l'anatomiste allemand Heinrich Wilhelm Waldeyer. Les neurones assurent la transmission d'un signal bioélectrique appelé influx nerveux. Ils sont 10 à 50 fois moins nombreux que les cellules gliales, seconds composants du tissu nerveux assurant plusieurs fonctions dont le soutien et la nutrition des neurones.

Les neurones ont deux propriétés physiologiques : l'excitabilité, c'est-à-dire la capacité de répondre aux stimulations et de convertir celles-ci en impulsions nerveuses, et la conductivité, c'est-à-dire la capacité de transmettre les impulsions.

Le neurone est composé d'un corps appelé péricaryon ou corps cellulaire ou encore soma, et de deux types de prolongements : l'axone, unique, qui conduit le potentiel d'action de manière centrifuge, et les dendrites, qui sont en moyennes 7 000 par neurone. La morphologie, la localisation et le nombre de ces prolongements, ainsi que la forme du soma, varient et contribuent à définir différentes familles

morphologiques de neurones. Par exemple, il existe des neurones uni-polaires ou multi-polaires.




FIGURE 2.1 – Structure simplifié du neurone biologique

Neurone formel

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

Poids (w) et biais (b) d'un neurone : Le poids est un facteurs multiplicateurs qui affectent l'influence de chaque entrée sur la sortie du neurone.

Le biais est une entrée toujours égale à 1, elle permet d'ajouter de la flexibilité au réseau en permettant de varier le seuil de déclenchement du neurone par l'ajustement du poids du biais lors de l'apprentissage.

La fonction de sommation ou de combinaison \sum : Le rôle de cette fonction consiste à sommer les différents valeurs d'entrées pondérés. ($n = \sum w_i x_i$)

Fonctions d'activations : La fonction d'activation (ou fonction de seuillage, ou encore fonction de transfert) sert à introduire une non-linéarité dans le fonctionnement du neurone.

Les fonctions de seuillage présentent généralement trois intervalles :



FIGURE 2.2 – Évaluation de la sortie en présence et absence du biais b 

FIGURE 2.3 – Rôle de la fonction de sommation

- en dessous du seuil, le neurone est non-actif (souvent dans ce cas, sa sortie vaut 0 ou -1) ;
- aux alentours du seuil, une phase de transition ;
- au-dessus du seuil, le neurone est actif (souvent dans ce cas, sa sortie vaut 1).

Fonctionnement du neurone formel : En recevant un vecteur d'entrées (x_1, x_2, \dots, x_n) , le neurone formel évaluera la sortie o_j comme suit : Tout d'abord chaque valeur x_i du vecteur d'entrée, sera multipliée par la valeur du poids w_i qui lui correspond, en suite les valeurs du vecteur obtenu seront sommées à l'aide de la fonction de combinaison ($\sum x_i w_i = net_j$), la somme net_j est comparée à un seuil θ_j , si $net_j > \theta_j$ le neurone est actif et la sortie $o_j = \phi(net_j)$, sinon le neurone est passif et la sortie vaut 0.

2.1.3 Réseaux de neurones artificiels (RNA)

Les réseaux de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires (ou neurone formel) fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit. Toute structure hiérarchique de réseaux est évidemment un réseau.

2.2 Types de RNA

On distingue deux types de réseaux, en fonction du graphe de leurs connexions, c'est-à-dire du graphe dont les nœuds sont les neurones et les arrêtes sont les

Nom de la fonction	Relation d'entrée/sortie	Icône	Nom Matlab
seuil	$a = 0$ si $n < 0$ $a = 1$ si $n \geq 0$		hardlim
seuil symétrique	$a = -1$ si $n < 0$ $a = 1$ si $n \geq 0$		hardlims
linéaire	$a = n$		purelin
linéaire saturée	$a = 0$ si $n < 0$ $a = n$ si $0 \leq n \leq 1$ $a = 1$ si $n > 1$		satlin
linéaire saturée symétrique	$a = -1$ si $n < -1$ $a = n$ si $-1 \leq n \leq 1$ $a = 1$ si $n > 1$		satlins
linéaire positive	$a = 0$ si $n < 0$ $a = n$ si $n \geq 0$		poslin
sigmoïde	$a = \frac{1}{1+\exp^{-n}}$		logsig
tangente hyperbolique	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		tansig
compétitive	$a = 1$ si n maximum $a = 0$ autrement		compet

FIGURE 2.4 – Différentes fonction d'activation

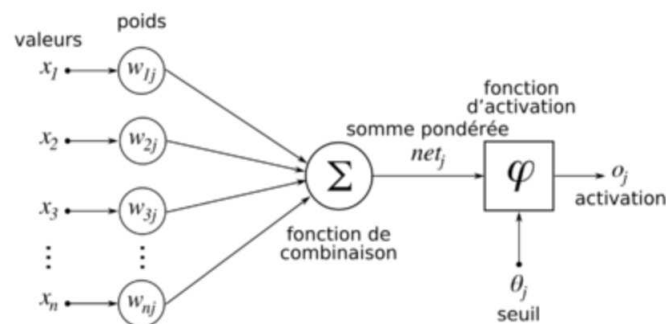


FIGURE 2.5 – Représentation d'un neurone formel

connexions entre ceux-ci. En d'autres termes selon la circulation de l'information :

- Les réseaux de neurones statiques (acycliques, ou non bouclés).
- Les réseaux de neurones dynamiques (récurrents, ou bouclés).

2.2.1 Les réseaux de neurones non bouclés

Un réseau de neurones non bouclé réalise une (ou plusieurs) fonction algébrique de ses entrées par composition des fonctions réalisées par chacun de ses neurones. Ces réseaux dits "feedforward" sont représentés graphiquement par un ensemble de neurones "connectés" entre eux, l'information circulant des entrées vers les sorties sans "retour en arrière". Si l'on représente le réseau comme un graphe dont les nœuds sont les neurones et les arêtes sont les "connexions" entre ceux-ci, le graphe d'un réseau non bouclé est acyclique. Le terme de "connexions" est une métaphore : dans la très grande majorité des applications, les réseaux de neurones




FIGURE 2.6 – Représentation simplifiée d'un RNA

sont des formules algébriques dont les valeurs numériques sont calculées par des programmes d'ordinateurs, non des objets physiques (circuits électroniques spécialisés); néanmoins, le terme de connexion, issu des origines biologiques des réseaux de neurones, est passé dans l'usage, car il est commode quoique trompeur.




FIGURE 2.7 – RNA de type feed-forward

Le perceptron

Avant d'aborder le comportement collectif d'un ensemble de neurones, nous allons présenter le Perceptron (un seul neurone) en phase d'utilisation. L'apprentissage ayant été réalisé, les poids sont fixes. Le neurone de la Fig. (2.8) réalise une simple somme pondérée de ses entrées, compare une valeur de seuil, et fournit une réponse binaire en sortie. Par exemple, on peut interpréter sa décision comme classe 1 si la valeur de x est $+1$ et classe 2 si la valeur de x est -1 .




FIGURE 2.8 – Le Perceptron : structure et comportement.

Le perceptron multicouches (PMC)

Dans un tel type de réseau les neurones cachés sont organisés en couches, les neurones d'une même couche n'étant pas connectés entre eux. De plus les connexions entre deux couches de neurones non consécutives sont éliminées. Une telle architecture est historiquement très utilisée, surtout en raison de sa pertinence en classification (Fig. (2.7)).

2.2.2 Les réseaux de neurones bouclés

L'architecture la plus générale pour un réseau de neurones est le "réseau bouclé", dont le graphe des connexions est cyclique : lorsqu'on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ (un tel chemin est désigné sous le terme de cycle). La sortie d'un neurone du réseau peut donc être fonction d'elle-même ; cela n'est évidemment concevable que si la notion de temps est explicitement prise en considération.

Ainsi, à chaque connexion d'un réseau de neurones bouclé (ou à chaque arête de son graphe) est attaché, outre un poids comme pour les réseaux non bouclés, un retard, multiple entier (éventuellement nul) de l'unité de temps choisie. Une grandeur, à un instant donné, ne pouvant pas être fonction de sa propre valeur au même instant, tout cycle du graphe du réseau doit avoir un retard non nul. Les connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation défini dans un réseau multicouche. Ces connexions sont le plus souvent locales.

Pour éliminer le problème de la détermination de l'état du réseau par bouclage, on introduit sur chaque connexion "en retour" un retard qui permet de conserver le mode de fonctionnement séquentiel du réseau (Fig. (2.9)). Le graphe des connexions de réseaux récurrents est cyclique. Ces réseaux sont décrits par un système d'équations aux différences.




FIGURE 2.9 – RNA de type feed-back

2.3 Apprentissage des réseaux de neurones

Le point crucial du développement d'un réseau de neurones est son apprentissage. Il s'agit d'une procédure adaptative par laquelle les connexions des neurones sont ajustées face à une source d'information. Dans le cas des réseaux de neurones artificiels, on ajoute souvent à la description du modèle l'algorithme d'apprentissage. Le modèle sans apprentissage présente en effet peu d'intérêt.

Dans la majorité des algorithmes actuels, les variables modifiées pendant l'apprentissage sont les poids des connexions. L'apprentissage est la modification des poids du réseau dans l'optique d'accorder la réponse du réseau aux exemples et à l'expérience. Les poids sont initialisés avec des valeurs aléatoires. Puis des exemples expérimentaux représentatifs du fonctionnement du procédé dans un domaine donné, sont présentés au réseau de neurones. Ces exemples sont constitués de couples expérimentaux de vecteurs d'entrée et de sortie. Une méthode d'optimisation modifie les poids au fur et à mesure des itérations pendant lesquelles on présente la totalité des exemples, afin de minimiser l'écart entre les sorties calculées et les sorties expérimentales. Afin d'éviter les problèmes de sur-apprentissage, la base d'exemples est divisée en deux parties : la base d'apprentissage et la base de test. L'optimisation des poids se fait sur la base d'apprentissage, mais les poids retenus sont ceux pour lesquels l'erreur obtenue sur la base de test est la plus faible. En effet, si les poids sont optimisés sur tous les exemples de l'apprentissage, on obtient une précision très satisfaisante sur ces exemples mais on risque de ne pas pouvoir généraliser le modèle à des données nouvelles. A partir d'un certain nombre d'itérations, le réseau ne cherche plus l'allure générale de la relation entre les entrées et les sorties du système, mais s'approche trop près des points et " apprend " le bruit. Sur la Fig. (2.10) ci-dessous, on peut observer qu'au début de l'apprentissage, pour les premières itérations, l'erreur sur la base d'apprentissage est grande et peut légèrement augmenter étant donné que les poids initiaux sont choisis aléatoirement. Ensuite, cette erreur diminue avec le nombre d'itérations. L'erreur sur la base de test diminue puis augmente à partir d'un certain nombre d'itérations. Les poids retenus sont ceux qui minimisent l'erreur sur la base de test.

Sur-apprentissage

Il arrive qu'à faire apprendre un réseau de neurones toujours sur le même échantillon, celui-ci devient inapte à reconnaître autre chose que les éléments présents dans l'échantillon. Le réseau ne cherche plus l'allure générale de la relation entre les entrées et les sorties du système, mais cherche à reproduire les allures de l'échantillon. On parle alors de sur apprentissage : le réseau est devenu trop spécialisé et ne généralise plus correctement.

Ce phénomène apparaît aussi lorsqu'on utilise trop d'unités cachées (de con-

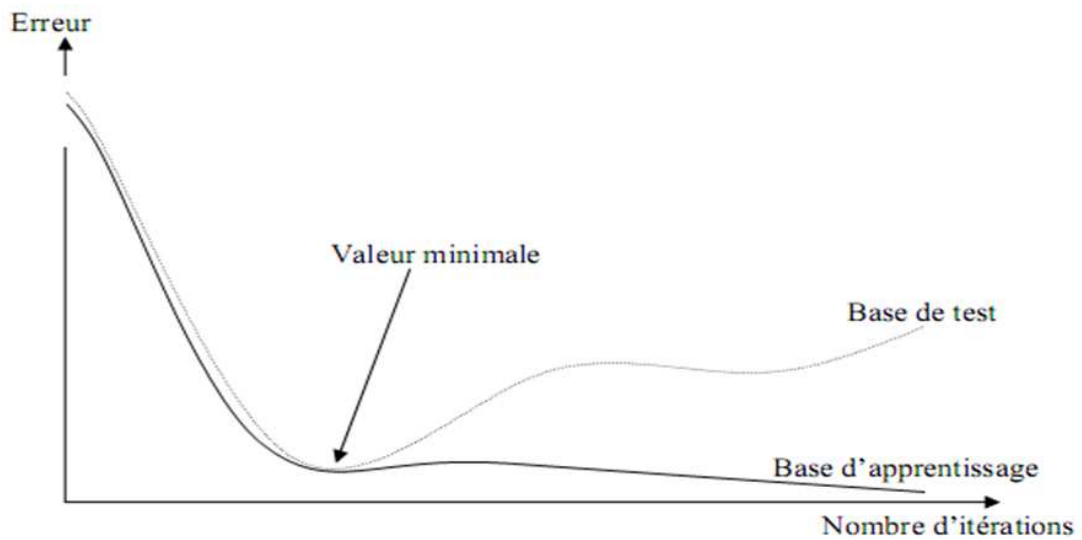


FIGURE 2.10 – Évolution de l'erreur moyenne sur la base d'apprentissage et celle du test.

nexions), la phase d'apprentissage devient alors trop longue (trop de paramètres réglables dans le système) et les performances du réseau en généralisation deviennent médiocres.

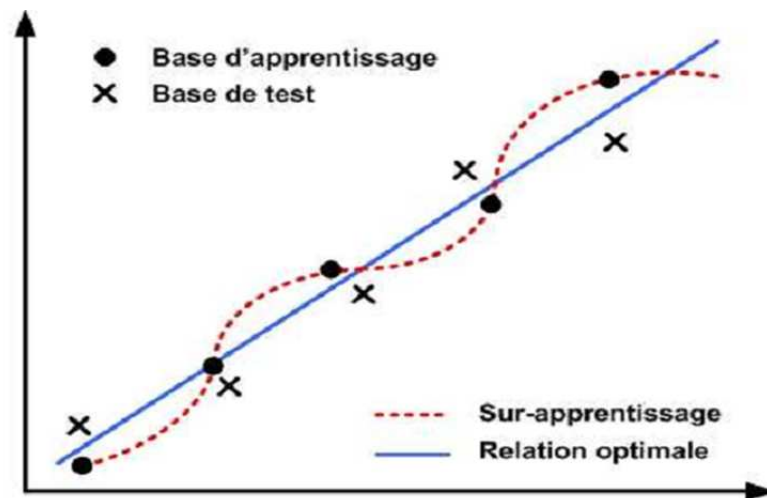


FIGURE 2.11 – Phénomène du sur-apprentissage

2.3.1 Types d'apprentissage

Il existe de nombreux types d'apprentissage qui peuvent être regroupées en trois catégories : les l'apprentissage supervisé, non supervisé, et renforcé.

Apprentissage supervisé

Un apprentissage est dit supervisé lorsque l'on force le réseau à converger vers un état final précis, en même temps qu'on lui présente un motif. Ce genre d'apprentissage est réalisé à l'aide d'une base d'apprentissage, constituée de plusieurs exemples de type entrées-sorties (les entrées du réseau et les sorties désirées ou encore les solutions souhaitées pour l'ensemble des sorties du réseau).

La modification des poids s'effectue progressivement jusqu'à ce que l'erreur (ou l'écart) entre les sorties du réseau (ou résultats calculés) et les résultats désirés soient minimisés. Cet apprentissage n'est possible que si un large jeu de données est disponible et si les solutions sont connues pour les exemples de la base d'apprentissage.

Apprentissage renforcé

L'apprentissage renforcé est une technique similaire à l'apprentissage supervisé à la différence qu'au lieu de fournir des résultats désirés au réseau, on lui accorde plutôt un grade (ou score) qui est une mesure du degré de performance du réseau après quelques itérations. Les algorithmes utilisant la procédure d'apprentissage renforcé sont surtout utilisés dans le domaine des systèmes de contrôle.

Apprentissage non supervisé

L'apprentissage non supervisé consiste à ajuster les poids à partir d'un seul ensemble d'apprentissage formé uniquement de données. Aucun résultat désiré n'est fourni au réseau. Qu'est-ce que le réseau apprend exactement dans ce cas ? L'apprentissage consiste à détecter les similarités et les différences dans l'ensemble d'apprentissage. Les poids et les sorties du réseau convergent, en théorie, vers les représentations qui capturent les régularités statistiques des données. Ce type d'apprentissage est également dit compétitif et (ou) coopératif. L'avantage de ce type d'apprentissage réside dans sa grande capacité d'adaptation reconnue comme une auto organisation. L'apprentissage non supervisé est surtout utilisé pour le traitement du signal et l'analyse factorielle.

2.3.2 Règles d'apprentissage

La règle delta (apprentissage par correction d'erreur)

La correction d'erreur désigne la correction de l'erreur observée en sortie. L'apprentissage par correction des erreurs consiste à minimiser un indice de perfor-

mance E basé sur les signaux d'erreur $e(\tau_i)$ qui est l'erreur entre ce qu'on obtient $y_k(x)$ et ce qu'on voudrait obtenir t_k , dans le but de faire converger les sorties du réseau avec ce qu'on voudrait qu'elles soient. Un critère très usuel est la somme des erreurs quadratiques E . Il faut changer les poids de réseau dans une direction qui diminue E , c'est-à-dire dans le sens opposé au gradient. On parle alors d'une direction de " descente " donnée par :

$$\Delta w^\tau = -\eta \nabla E^\tau$$

Où η est appelée le taux d'apprentissage.

La règle de Hebb

On peut formuler l'énoncé de Hebb sous la forme d'une règle d'apprentissage donnée par :

$$\Delta w_j^{\tau-1} = \eta p_j^\tau a^\tau$$

Où η est une constante positive qui détermine la vitesse de l'apprentissage, p_j^τ correspond à l'activité pré-synaptique (l'entrée j du neurone) au temps τ , et a_j^τ à l'activité post-synaptique (sortie du neurone) à ce même temps τ .

2.3.3 Algorithme d'apprentissage

L'algorithme d'apprentissage est la méthode mathématique qui va modifier les poids de connexions afin de converger vers une solution qui permettra au réseau d'accomplir la tâche désirée. L'apprentissage est une méthode d'identification paramétrique qui permet d'optimiser les valeurs des poids du réseau. Plusieurs algorithmes itératifs peuvent être mis en œuvre, parmi lesquels on note : l'algorithme de rétro-propagation, la Méthode Quasi-Newton, Algorithme de BFGS etc.

Rétro-propagation

l'algorithme de rétro propagation (ARP) ou de propagation arrière " backpropagation " est l'exemple d'apprentissage supervisé le plus utilisé à cause de l'écho médiatique de certaines applications spectaculaires telles que la démonstration de Sejnowski et Rosenberg dans laquelle l'ARP est utilisé dans un système qui apprend à lire un texte. Un autre succès fut la prédiction des cours du marché boursier et plus récemment la détection de la fraude dans les opérations par cartes de crédit.

La rétro-propagation consiste à rétro-propager l'erreur commise par un neurone à ses synapses et aux neurones qui y sont reliés. Pour les réseaux de neurones, on utilise habituellement la rétro-propagation du gradient de l'erreur, qui consiste à corriger les erreurs selon l'importance des éléments qui ont justement participé à la réalisation de ces erreurs : les poids synaptiques qui contribuent à engendrer

une erreur importante se verront modifiés de manière plus significative que les poids qui ont engendré une erreur marginale.

Il existe plusieurs variantes de l'algorithme de rétro-propagation de l'erreur. Elles sont résumées dans le tableau suivant.

Algorithme	Caractéristiques
Descente du gradient	
Descente du gradient simple (<i>traingd</i>)	Descente du gradient de base. Réponse lente; peut être utilisée pour apprentissage en mode séquentiel
Descente du gradient avec moment (<i>traindm</i>)	Descente du gradient avec moment. Le moment permet à un réseau de répondre non seulement au gradient local, mais aussi aux tendances récentes dans la surface d'erreur. Sans moment un réseau peut être coincé dans un minimum local peu profond. Plus rapide que <i>traingd</i> , ne peut être utilisée que pour apprentissage en mode séquentiel
Descente du gradient avec taux d'apprentissage variable (<i>trainda</i>)	Taux d'apprentissage variable. Plus rapide que <i>traindm</i> , mais ne peut être utilisée que pour apprentissage en mode batch. Utilise des règles heuristiques pour la variation du taux d'apprentissage
Descente du gradient avec moment et taux d'apprentissage variable (<i>traindx</i>)	Descente du gradient avec inertie (momentum) et taux d'apprentissage variable
Descente des gradients conjugués	
Descente des gradients conjugués avec la méthode de mise à jour de Fletcher-Reeves (<i>traincgf</i>)	Il possède la plus petite mémoire de stockage parmi les algorithmes de gradient conjugués.
Descente des gradients conjugués avec la méthode de mise à jour de Polak-Ribière (<i>traincgp</i>)	Nécessite une mémoire de stockage légèrement plus grande que <i>traincgf</i> . Convergence plus rapide sur quelques problèmes.
Descente des gradients conjugués avec la méthode de reprises Powell-Beale (<i>traincgb</i>)	Nécessite une mémoire de stockage légèrement plus grande que <i>traincgp</i> . Convergence Généralement plus rapide.
Scaled conjugate gradient (<i>traincsg</i>)	Le seul algorithme de gradients conjugués qui n'exige aucune recherche de ligne. Très bon algorithme d'apprentissage en général.
Quasi-Newton	
BFGS quasi-Newton (<i>trainbfg</i>)	Il exige le stockage d'une approximation de la matrice Hessienne et nécessite plus de calcul à chaque itération que les algorithmes de gradients conjugués, mais possède habituellement une convergence plus rapide.
Sécante à un pas (<i>trainoss</i>)	Cet algorithme exige moins de stockage et calcul par époque que l'algorithme BFGS. On peut considérer cela un compromis entre des algorithmes de quasi-Newton complets et des algorithmes de gradients conjugués.
Levenberg-Marquardt	
Levenberg-Marquardt (<i>trainlm</i>)	C'est l'algorithme d'apprentissage le plus rapide pour les réseaux de taille modérée. Il a la caractéristique de réduction de mémoire pour l'utilisation quand l'échantillon d'apprentissage est grand.

FIGURE 2.12 – Les différentes implémentations de la rétro-propagation des erreurs

Conclusion

Par leur puissance et leur principe de boîte noire les réseaux de neurones s'impose dans le domaine de l'ingénierie. A l'aide d'un tel outil on peut réaliser des approximations à une précision accrue, pour peu que l'on ait à notre disposition une base d'apprentissage de taille et de pertinence adéquates.

Ce chapitre nous a aidé à nous initier à l'utilisation des réseaux de neurones et à nous familiariser avec. Les notions théoriques acquises au cours de ce chapitre nous ont donné les outils suffisants pour choisir l'architecture à utiliser lors de la modélisation.

CHAPITRE 3

Simulation de la loi de comportement des GNT par RNA

Dans ce chapitre consacré à l'approximation de la relation module réversible-contrainte des GNT nous allons exposer la méthodologie entreprise afin de modéliser l'architecture du réseau et de régler les paramètres la régissant dans le but d'obtenir la meilleure approximation de Mr.

3.1 Modélisation de l'architecture du réseau de neurones

Il est avant tout important de noter qu'il n'existe pas de méthodes ou de règles prédéfinies permettant de concevoir à priori l'architecture du réseau. Il est toutefois possible de cerner plus ou moins le problème en définissant les principaux paramètres la régissant :

- Le type de réseau.
- La structure du réseau (nombre de couches cachées et de neurones par couche).
- Les fonctions d'activation.
- L'algorithme d'apprentissage

3.1.1 Choix du type de réseau

Nous avons constaté dans l'étude bibliographique que nous avons effectuée que le réseau du type feed-forward à perceptron multicouche est le plus préconisé pour l'approximation de fonction. Notre choix s'est donc porté sur ce type de réseau.

3.1.2 Choix de la structure du réseau

Le choix de la structure du réseau revient à fixer les deux paramètres suivant : le nombre de couches cachées et le nombre de neurones dans chaque couche.

3.1.3 Choix des fonctions d'activation

La fonction de transfert généralement adoptée pour les couches cachées dans le cadre de l'approximation de fonctions et de l'algorithme d'apprentissage de rétro propagation des erreurs est du type sigmoïde. Ce qui restreint notre recherche à deux fonctions : logarithme sigmoïde (logsig) et tangente sigmoïde (tansig).

Notre choix s'est porté sur la fonction tansig car elle produit des valeurs positives et négatives contrairement au logsig, ce qui permet d'avoir un apprentissage plus rapide. Quant à la couche de sortie la fonction d'activation utilisée est l'identité (purelin).

3.1.4 Choix de l'algorithme d'apprentissage

Les algorithmes d'apprentissage utilisés pour la résolution de problèmes d'approximation ne sont en fait que des algorithmes d'optimisation, le but étant de trouver les valeurs optimales des poids synaptiques.

L'algorithme de retro propagation de l'erreur pour lequel nous avons opté dans le cadre de notre étude est le plus utilisé et le plus préconisé pour ce type de problème. Cet algorithme comprend deux étapes :

- Etape 1 : Les poids dans chaque neurone sont d'abord aléatoirement initial-

isés. Les entrées sont ensuite propagées dans le réseau pour donner en sortie des résultats qui sont forcément erronés. L'erreur entre chaque entrée et la sortie correspondante est calculée.

- Etape 2 : Les poids dans les neurones sont ajustés selon la règle Delta afin de réduire l'erreur.

Ces deux étapes sont répétées par l'algorithme jusqu'à ce que l'erreur cesse de diminuer. A ce moment là l'algorithme stoppe le processus et garde les poids donnant l'erreur la plus petite.

Il existe plusieurs classes d'algorithmes de retro propagation, selon la méthode d'optimisation. Pour les réseaux de taille modérée comme le notre, l'utilisation de l'algorithme de Levenberg-Marquardt est préconisé, c'est donc sur celui-ci que notre choix s'est porté.

critères de sélection

Deux critères de sélection ont été adoptés afin de juger de la capacité d'une structure donnée à approcher le module réversible :

- *Critère 1* : L'erreur quadratique moyenne (MSE : mean squared error) :

$$e = \frac{\sqrt{\sum (Mr_{exp} - Mr_{est})^2}}{n}$$

Où :

Mr_{est} : Valeur estimée du module réversible estimé.

Mr_{exp} : Valeur du module expérimental.

Plus l'erreur quadratique moyenne est petite et plus le réseau effectue une meilleure approximation des valeurs expérimentales.

- *Critère 2* : La capacité de prédiction (ou capacité à généraliser)

Afin de juger de la capacité de prédiction d'une structure de RNA donnée, on la soumet à un test de performance. ce test consiste à injecter un important ensemble d'invariants θ dans la structure à la suite de son entraînement et à dresser la courbe donnant le module réversible en fonction de ces invariants. L'allure de cette courbe permet d'apprécier la capacité à généraliser de la structure : Si l'allure suit la tendance de l'évolution du module réversible en fonction de l'invariant θ alors on peut juger que le réseau possède une capacité de généralisation.

3.1.5 Machine d'apprentissage

Comme susmentionné, il n'existe aucune règle qui permet au préalable de fixer le nombre de couche ainsi que le nombre de neurones dans chaque couche. Il faut donc procéder par tâtonnement afin de trouver la structure optimale. Afin de contrôler ce comportement "aléatoire" des réseaux de neurones nous avons développé

un programme sous MATLAB qui permet d'exécuter un balayage de toutes les structures de réseaux en allant de un neurone jusqu'à un seuil supérieur fixé par l'utilisateur. Nous avons remarqué que les structures à 2 et à 3 trois couches cachées ne donnent pas de résultats satisfaisants chose qui nous a amené à exclure ces 2 possibilités.

Le programme exécute donc le balayage d'une seule couche cachée. Ce programme est appelé machine d'apprentissage. L'organigramme dressé sur la figure (5.7) en donne de plus ample détails.

nota : I_{max} et J_{max} sont respectivement le seuil du nombre maximum de neurones dans la couche cachée et le nombre maximum d'entraînement par structure.

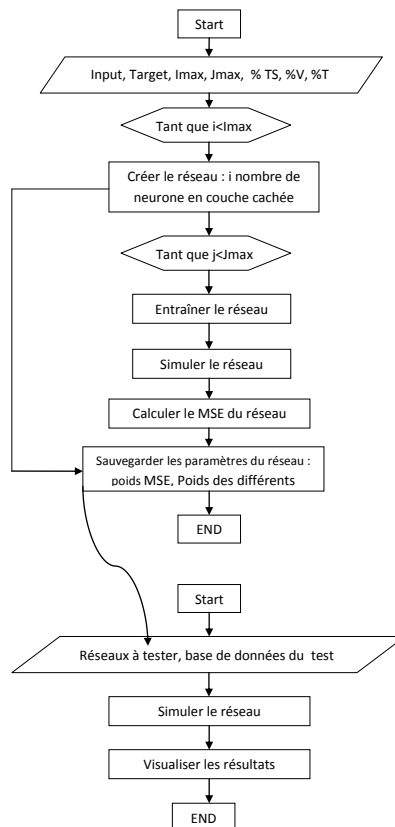


FIGURE 3.1 – Organigramme représentant le fonctionnement de la machine d'apprentissage

3.2 Entraînement du réseau et résultats de la simulation

Après exécution de la machine d'apprentissage et après avoir visualisé et examiné l'ensemble des courbes de prédictions et des MSE, nous avons remarqué que globalement les MSE donnés par l'ensemble des architectures sont acceptables. En revanche, nous avons remarqué que les courbes de prédiction commencent à dégénérer à partir de 8 neurones en couche cachée. Le meilleur compromis entre les deux critères (MSE et courbe de prédiction) est obtenu pour une architecture ayant 6 neurones en couche cachée.

Résultats de simulation du réseau choisi :




FIGURE 3.2 – Droite de corrélation entre Mr expérimental et Mr RNA

D'après la droite et l'indice de corrélation R^2 montrés sur la Figure (3.2) qui est de 0.9971, on constate que le réseau de neurone approche Mr d'une manière précise. Le MSE de cette architecture est de $1545.65kPa$, ce qui est considéré comme une bonne valeur comparée à celle donné par le modèle $K - \theta$ qui est de $5738.05kPa$ cf. Fig. (3.5) et Fig. (3.3)

la Figure (3.4) nous permet d'apprécier la capacité de prédiction du réseau de neurone. On remarque que la courbe de prédiction reproduit judicieusement l'évolution du module réversible en fonction de l'invariant θ et ne fluctue pas entre les points expérimentaux ce qui est un indicateur d'une excellente capacité de généralisation.




FIGURE 3.3 – Droite de corrélation entre Mr expérimental et Mr $K - \theta$

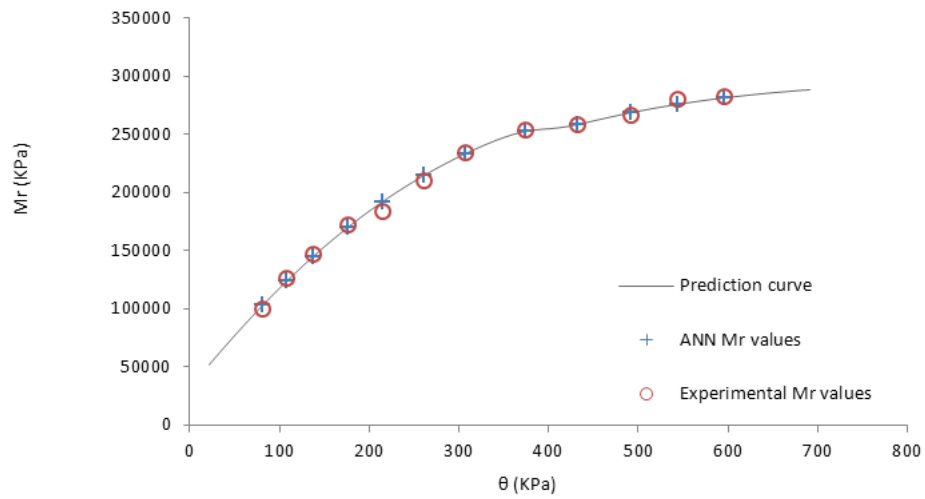


FIGURE 3.4 – résultats du test de performance de l'architecture choisie

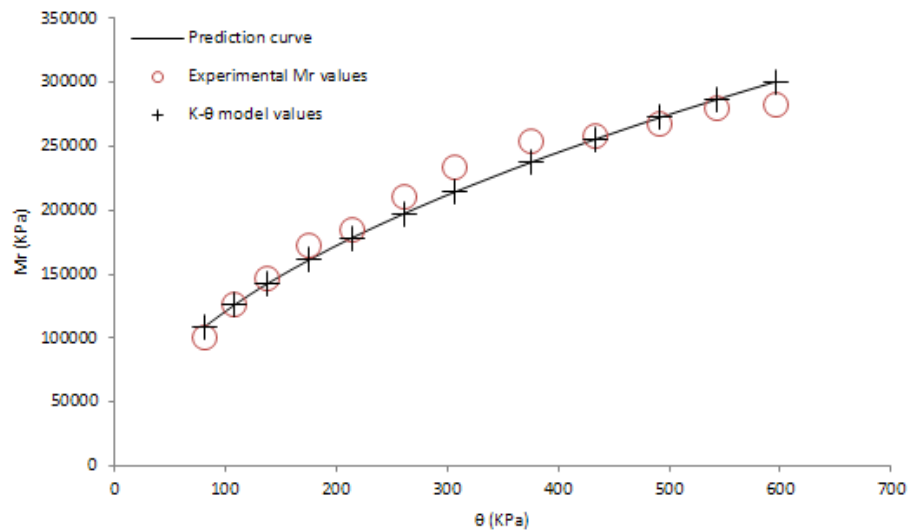


FIGURE 3.5 – résultats du test de performance du modèle $K - \theta$

La figure (3.6) montre l'exemple d'une architecture ayant une médiocre capacité à généraliser en dépit de son excellente capacité à retrouver les valeurs expérimentales (un MSE de 793.12 kPa). c'est ce qu'on appelle le sur apprentissage.




FIGURE 3.6 – Exemple d'un RNA qui a subi un sur-apprentissage

Conclusion

Les réseaux de neurones du type feed forward perceptron multi-couche à une seule couche cachée offrent une meilleure approximation du module réversible que le modèle analytique le plus utilisé $k - \theta$ en terme de précision vis à vis des valeurs expérimentales (base de données d'apprentissage) et en terme de généralisation. La plus grande difficulté dans les réseaux neurones en général de part leur caractère complexe est de trouver la structure optimale. Toutefois cette difficulté peut être plus ou moins cernée en automatisant l'entraînement de plusieurs architectures jusqu'à aboutir à l'optimale.

CHAPITRE 4

Application de l'approximation de Mr par RNA à l'analyse des chaussées souples

Le présent chapitre est consacré à l'application de l'approximation de Mr par RNA à l'analyse non linéaire des chaussées souples selon la théorie multicouche élastique de Burmister moyennant le logiciel KENLAYER et à sa comparaison avec une analyse basée sur le modèle $K - \theta$ du comportement non-linéaire. En premier lieu, une brève présentation du logiciel KENLAYER est faite ainsi que les avantages qu'il présente suivi par la présentation de la structure faisant l'objet de notre étude. Par la suite, la démarche entreprise ainsi que le programme développé afin d'effectuer l'analyse sont présentés. Enfin, les principaux résultats sont illustrés et commentés.

4.1 Description du logiciel KENLAYER

4.1.1 Présentation du logiciel

KENLAYER est un programme informatique développé à Université de Kentucky par Yang H.HUANG et utilisé pour la solution d'un système élastique multicouche sous une région circulaire chargée. Le principe du calcul de ce logiciel est basé sur la théorie de Brumister d'un system multicouches élastique comme d'autres programmes basés sur la méthode analytique. Les solutions sont superposées pour les chargements multiples comme double roues (essieu) ou double tandem. La supériorité de KENLAYER sur les autres programmes utilisant la théorie multi-couche élastique de Burmister est sa capacité de résoudre des systèmes linéaires élastiques, non-linéaires-élastiques ou viscoélastique. Le Programme exécute aussi l'analyse du dégât pour évaluer la durée de vie de conception étant donné le dégât causé par fatigue par fissuration ou les déformations permanentes en utilisant des expressions de base données par des modèles de performance tel que celle données par Asphalt Institute. Dans sa dimension présente, il peut être appliqué à un maximum de 19 couches avec sortie à 25 coordonnées radiales différentes et 19 coordonnées verticales différentes, ou un total de 475 points. Pour faciliter l'entrée et édition des données, un programme nommé LAYERINP (distribué dans le même package) est utilisé. Le programme utilise des menus et des formes pour l'entrée des données dans l'ordre pour créer et éditer le fichier des données (input file).

4.2 L'analyse non linéaire dans KENLAYER

Il est bien connu que les matériaux granulaires sont modélisés par un comportement non linéaire réversible qui varie avec l'état de contrainte. Le module réversible des matériaux granulaires augmente avec l'augmentation de l'intensité de contrainte. Si le rapport entre le module réversible et l'état de chargement est donné, une méthode d'approximations successives peut être utilisée. Un inconvénient majeur de la théorie élastique multi-couches est la supposition que chacune des couches est homogène avec les mêmes propriétés partout dans la couche. Pour considérer ce comportement des matériaux granulaires dans cette phase d'analyse, les développeurs de KENLAYER ont inclus le module de l'analyse non-linéaire pour les matériaux non linéaire. Cette approche peut être expliquée brièvement par cet organigramme simple 4.1

Le modèle de non linéarité mécanique employé dans KENLAYER est le modèle $K - \theta k_1$ et k_2 étant des paramètres de modèle sont définis dans l'étape de l'entrée pour chaque sous couche. Comme expliqué avant, le module élastique de chaque

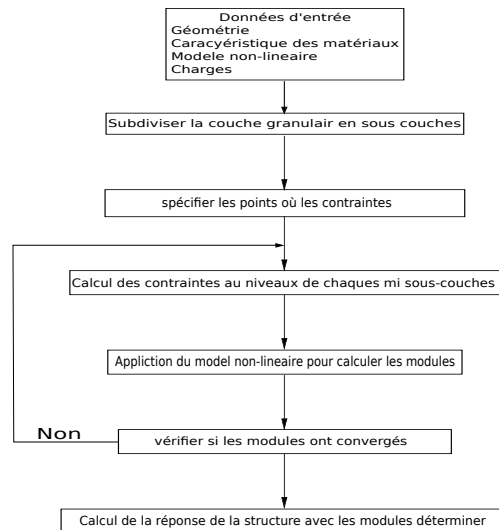


FIGURE 4.1 – Les étapes de l'approximation itérative incluse dans KENLAYER

couche non-linéaire est déterminé depuis un point désigné. Alors, la question qui survient : Quel point dans la couche non linéaire devrait être sélectionné pour représenter la couche entière ? Comme il l'est habituellement dans la conception de chaussées, un point près de l'axe de la charge appliquée peut être raisonnablement sélectionné. Dans ce qui suit, parce que les réponses sont calculées sous une seule charge de roue, les points juste à les mi- profondeurs de chaque sous couche le long du axe du chargement circulaire sont sélectionnés comme points du contrainte (calcul de module réversible). La figure 4.2 est une représentation graphique de ce type d'analyse.




FIGURE 4.2 – Principe de l'approche itérative simplifiée utilisée dans KENLAYER

Cette approche simplifiée pour la modélisation des caractéristiques dépendantes de la contrainte des matériaux granulaires ne représente pas réellement le comportement in-situ du matériau. Puisque KENLAYER est un programme basé sur la théorie élastique multi-couche, les valeurs des modules de chaque sous couche sont encore supposé être constant horizontalement, mais dans la réalité, le module réversible varie d'un point à un autre avec l'état de contrainte dans une même

couche granulaire. Il est important de noter que pour représenter le comportement réel des matériaux granulaires sous condition de la charge, la variation du module réversible le long de la direction radiale devraient aussi être prises en considération en plus de variation le long de la direction verticale. Comme expliqué plus tôt, ce type d'analyse peut être effectué en utilisant la technique des éléments finis où les paramètres du matériau peuvent être définis séparément pour chaque élément.

4.3 Présentation de la structure d'étude

Afin d'étudier l'incidence du modèle RNA du comportement non-linéaire des chaussées souples nous avons sélectionné une structure du catalogue algérien de dimensionnement des chaussées souples. La structure est résumée dans le figure suivante :




FIGURE 4.3 – Structure de chaussé choisie

Les paramètres K_1 et K_2 ont été déterminés en utilisant l'approximation par moindres carrées du modèle $K - \theta$. Cette structure est soumise à une charge réglementaire de 65KN distribuée sur un disque de diamètre de 35 Cm (pression de 675.6 kPa).

4.4 Démarche entreprise dans l'analyse non-linéaire basée sur le modèle RNA

4.4.1 Principe de la démarche

Le principe de la démarche entreprise est similaire à celui du module de KEN-LAYER traitant la non-linéarité à savoir le principe itératif d'approximation successive. Le demi-espace de la couche de GNT est subdivisé en plusieurs sous-couches en supposant un vecteur de modules réversibles de départ puis la théorie

de Burmister est appliquée à l'aide du KENLAYER afin de déterminer l'état de contrainte au milieu de chaque sous-couche. Une fois les contraintes obtenues un nouveau vecteur de modules réversibles est déterminé à l'aide du RNA trouvé dans le chapitre précédent. Ce processus est répété jusqu'à ce que le vecteur de modules entre deux itérations successives convergent à une tolérance spécifiée.

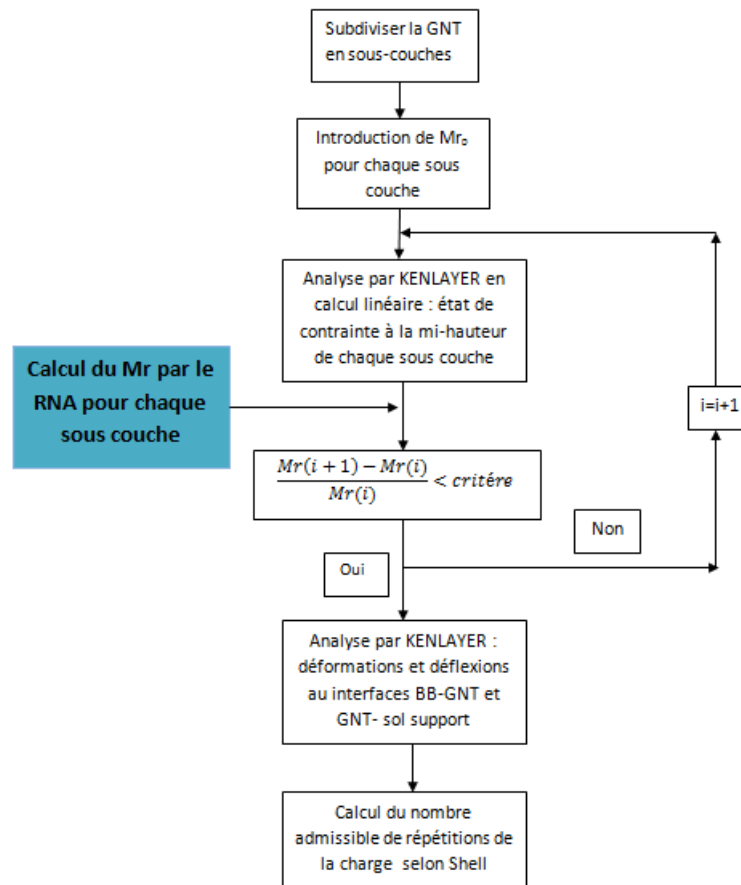


FIGURE 4.4 – Organigramme de l'analyse non-linéaire basée sur l'approximation RNA

4.4.2 Description du programme développé

Afin d'automatiser le processus un programme sous C++ à été développé afin de gérer l'interaction entre le KENLAYER et MATLAB.

Tout d'abord le programme C++ crée un fichier de données contenant ce dont le KENLAYER a besoin comme inputs entre autres le vecteur des Mr initiaux des différentes sous-couches. Ensuite il exécute le KENLAYER qui évalue les états de contrainte au niveau des couches et sous couches et génère un fichier output. Le fichier de résultat est par la suite parsé par le même programme C++ pour extraire les états de contrainte au niveaux des sous couches puis les enregistre dans un autre fichier. Enfin ce dernier servira comme fichier input pour la fonction Matlab qui va le traité puis l'utilise pour simuler le réseau qui évalue le nouveau vecteur des Mr correspondant aux états de contraintes et les enregistre dans un

fichier. La première itération étant ainsi bouclé, le programme est ré-exécuté pour la deuxième itération et ainsi de suite jusqu'à convergence du vecteur Mr

4.5 Résultats et discussion

L'analyse de la structure par les deux approches donne les deux distributions de Mr en fonction de la profondeur représentées sur la figure 4.5.

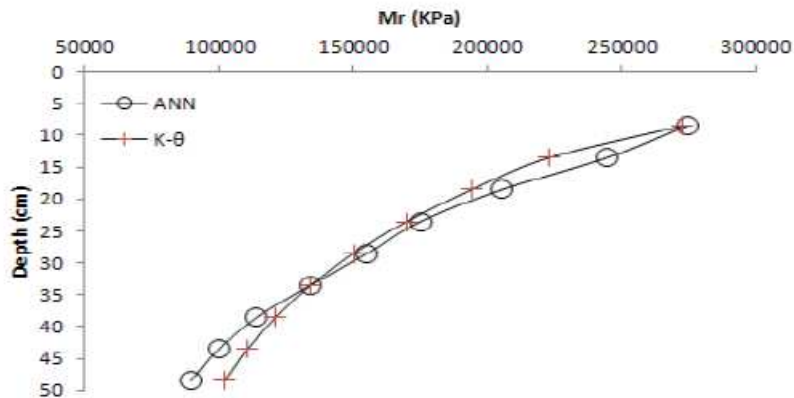


FIGURE 4.5 – Variation de Mr dans la structure selon le $K - \theta$ et le RNA

Les résultats de l'analyse sont résumés dans le tableau suivant :

TABLE 4.1 – Déformations aux interfaces BB/GNT et GNT/S.Support selon les deux approches

Déformation	RNA	$K - \theta$
ϵ_t	$-3.59 \cdot 10^{-4}$	$-3.70 \cdot 10^{-4}$
ϵ_v	$7.63 \cdot 10^{-4}$	$7.13 \cdot 10^{-4}$

Discussion :

La déformation verticale au niveau du sol support donné par le modèle $K - \theta$ est inférieure à celle donnée par le modèle RNA. Ceci s'explique par le fait que les valeurs du Mr pour les sous-couches profondes proches du sol support se trouvent dans un intervalle où le $K - \theta$ exagère le module.

D'autre part ; la déformation latérale évaluée par $K - \theta$ est supérieure à celle donnée par le RNA. Ceci est dû au fait que les sous couches supérieures analysées par le $K - \theta$ ont des modules réversibles plus faible que dans le cas du RNA.

Ceci se répercute sur la durée de vie de la chaussée c'est à dire le nombre de répétition de charges à ne pas dépasser afin d'éviter la mise hors état de service de la structure. Le tableau suivant donne le nombre de répétitions charges pour les deux analyses :

TABLE 4.2 – Nombre de répétition de charges pour les deux analyses

-	RNA	$K - \theta$
N_v	$1.8 \cdot 10^6$	$2.73 \cdot 10^6$
N_t	$7.24 \cdot 10^9$	$6.1 \cdot 10^9$

Conclusion

La durée de vie donnée par le modèle RNA est inférieure à celle donnée par le $K - \theta$. Ceci peut sembler pénalisant à première vue. Cependant, une interprétation judicieuse des résultats nous mène à conclure que le modèle RNA offre une analyse plus fiable que le modèle $K - \theta$ en raison de sa précision dans la prédiction du module réversible.

CHAPITRE 5

Prédiction du module réversible et enrichissement de bases de données

Dans le présent chapitre, nous allons nous intéressés à la prédiction du module réversible pour des conditions non réalisés en essai à partir de résultats d'essais accumulés afin d'enrichir la base de données pour couvrir un plus large intervalle des facteurs influençant le module réversible des GNT et épargner ainsi la réalisation d'essais ultérieurs.

En premier lieu une présentation des facteurs retenus selon les données expérimentales disponibles seront présentés ainsi que les tendances physiques de leurs influences sur le module réversible. En second lieu, la démarche entreprise afin de sélectionner l'architecture ayant la meilleur *capacité à reconnaître la tendance physique* de l'évolution de Mr ainsi que la meilleure précision dans la prédiction sera présentée. enfin les résultats de la prédiction seront commentés suivis de la présentation de la nouvelle base de données enrichie.

5.1 Littérature

Plusieurs travaux expérimentaux effectués durant les quatre dernières décennies ont montré que le module réversible des grave non-traité est influencé par plusieurs paramètres.

L'état de contrainte étant bien évidemment le facteur ayant le plus d'influence sur Mr. Les études ont montré en effet qu'il y a une étroite dépendance entre le module réversible et la contrainte de confinement. Hicks (1970), Smith et Nair (1973) et Sweere (1990) ont montré que le module réversible croit avec l'augmentation de cette dernière : une augmentation de l'ordre de 500% a été observée pour une variation de la contrainte de confinement de 20 à 200kPa. Hicks (1970) a rapporté que la contrainte déviatorique n'a pas un effet significatif sur le module comparée à la contrainte de confinement.

Plusieurs études (Hicks 1970, Robinson 1974, and Rada and Witczak 1981) ont montré que module réversible croit avec l'augmentation de la densité de compactage. D'une autre part une augmentation de la teneur en eau a pour conséquence l'affaiblissement de la GNT donc une chute du module réversible(Hicks 1970, and Dawson et al. 1996).

5.2 Conception du réseau de neurones

Le problème étant un problème d'approximation d'une fonction, Il est bien entendu que les paramètres de l'architecture du réseau sont similaires aux paramètres fixés au chapitre 3 (type du réseau : perceptron multicouche ; fonction d'activation : tansig ; algorithme d'apprentissage :Levenberg-Marquardt) à l'exception de la structure du réseau. La structure du réseau diffère en premier lieu au niveau du nombre de neurones en couche d'entrée qui correspond au nombre de variables d'entrée c-à-d au nombre de facteurs d'influence retenus. Le nombre de neurones en couche cachée est déterminé par la machine d'apprentissage. En couche de sortie, il n'y a qu'un seul neurone vue qu'il n'y a qu'une seule variable de sortie.

En suivant la même démarche détaillé dans le chapitre 3, nous allons modéliser un réseau de neurones pour reproduire les effets des différents facteurs sur la réponse des GNT.

5.2.1 Choix des paramètres d'entrées (facteurs d'influence

En se basant sur les résultats des recherches présentés dans le paragraphe *Littérature*, et étant limités par la disponibilité des données expérimentales nous présentons ci-dessus les facteurs retenus :

- 1- La densité.
- 2- La teneur en eau.

3- La pression de confinement.

4- La contrainte déviatorique.

5.2.2 Architecture du réseaux de neurones

L'exécution de la machine d'apprentissage nous a permis développée nous a permis d'aboutir à la structure optimale suivante :




FIGURE 5.1 – Architecture du réseau de neurones.

5.3 Résultats du test du réseau retenu

Les résultats du test du réseau sont présentés sous forme de graphes illustrant les effets des facteurs considérés sur le module réversible selon le RNA.

La Figure 5.2 montre les résultats de prédiction obtenu pour une GNT testée sous une pression de confinement égale à 34.5kPa. Il est évident que le RNA est capable de reproduire l'effet connue de la teneur en eau sur le Mr. pour une augmentation de la teneur en eau on constate une chute du module réversible.




FIGURE 5.2 – Effet de la teneur en eau sur le module réversible

Rapporté par plusieurs chercheurs [e.g., Trollope et al. (1962), Hicks (1970), Robinson (1974), Rada et Witczak (1981), et Kolisoja (1997) Mitry (1964), Monismith et al. (1967), Smith et Nair (1973), Uzan (1985), et Sweere (1990)] le module réversible des GNT augmente en augmentant la densité, et aussi en augmentant l'état de contraintes. L'examen des figures 5.3 et 5.4, confirme encore la capacité des RNA a reproduire les tendances naturelles.




FIGURE 5.3 – L'effet de la densité sur le module réversible comme prédit par RNA




FIGURE 5.4 – L'effet de σ_3 sur le module réversible comme prédit par RNA

5.4 Application : Enrichissement de la base de données

En étant assurés que le réseau a bien appris les effets des différents facteurs sur le module réversible, le réseau peut être exploité pour enrichir la base de données du laboratoire. Pour la GNT Étudiée la base de données originale qui comportait 26 résultats de expérimentaux a été enrichie pour contenir un large tas de données couvrant la variation des différentes variables avec un incrément de 1% pour la densité, 0.25% pour la teneur en eau, et 1kPa pour σ_3 et σ_1 . Un échantillon de la base de données illustrant l'enrichissement de la base de données est présenté dans le tableau 5.1.

TABLE 5.1 – Base de données enrichie

σ_1 (kPa)	σ_3 (kPa)	w	Mr (MPa)
20.7	20.6	7.25	106.67
20.7	20.6	7.5	101.72
20.7	20.6	7.75	97.204
20.7	20.6	8	93.202
20.7	20.6	8.25	89.756
20.7	20.6	8.5	86.869
20.7	20.6	8.75	84.512
20.7	20.7	2	<u>215.8</u>
20.7	20.7	2.25	205.59
20.7	20.7	2.5	196.44
20.7	20.7	2.75	188.16
20.7	20.7	3	180.71
20.7	20.7	3.25	<u>174.13</u>
20.7	20.7	3.5	168.47
20.7	20.7	3.75	163.71
20.7	20.7	4	159.69
20.7	20.7	4.25	156.21
20.7	20.7	4.5	<u>153.04</u>
20.7	20.7	4.75	149.96
20.7	20.7	5	146.78
20.7	20.7	5.25	143.35
20.7	20.7	5.5	<u>139.56</u>
20.7	20.7	5.75	135.34
20.7	20.7	6	130.71
20.7	20.7	6.25	125.69
20.7	20.7	6.5	<u>120.41</u>
20.7	20.7	6.75	114.99
20.7	20.7	7	109.6
20.7	20.7	7.25	104.42
20.7	20.7	7.5	99.585
20.7	20.7	7.75	95.215
20.7	20.7	8	91.38
20.7	20.7	8.25	88.106

Conclusion

Les résultats obtenus montrent incontestablement l'aptitude des réseaux de neurones artificiels à reproduire les effets de plusieurs paramètres à la fois sur le module réversible avec précision, ce qui peut être utilisé afin d'enrichir une base de données expérimentale. Ceci présente un intérêt économique considérable dans la mesure où l'on évite la réalisation d'essai tri-axiaux pour des conditions non-réalisées en essai et dans la mesure où l'on épargne aux petites juridictions le recours aux essai tri-axiaux qui sont coûteux afin de caractériser leurs matériaux non traités locaux.

Conclusion générale

Au terme de notre projet de fin d'étude qui a porté sur l'application des réseaux de neurones artificiels à l'analyse des chaussées souples, les résultats obtenus affirment la supériorité de cet outil sur le modèle analytique le plus utilisé $K - \theta$ et sa capacité à reproduire judicieusement la loi de comportement des Graves non traitées, chose qui confère plus de fiabilité à l'analyse et donc corrélativement au dimensionnement des structures de chaussées.

En outre, la faculté des réseaux de neurones artificiels à reproduire aisément et d'une manière précise les effets de plusieurs facteurs à la fois sur le module réversible présente un intérêt économique considérable dans la mesure où ils épargnent le recours aux essais tri-axiaux qui sont onéreux.

Par dessus tout, nous pouvons conclure que le principal atout qu'offrent les réseaux de neurones artificiels c'est qu'ils permettent de s'affranchir de la nécessité de modèles analytiques pour décrire une loi de comportement même complexe et l'influence de plusieurs paramètres sur cette dernière.

Bibliographie

- [1] J. M. A.K. Jain and K. Mohiuddin, "Artificial neural network : A tutorial," *IEEE*, 1996.
- [2] J. Ekblad, "Statistical evaluation of resilient models characterizing coarse granular materials," *Materials and Structures*, vol. 41, pp. 509–525, 2008.
- [3] K. Gopalakrishnan, "Effect of training algorithms on neural networks aided pavement diagnosis," *International Journal of Engineering, Science and Technology*, vol. 2, pp. 83–92, 2010.
- [4] K. Gopalakrishnan, "Neural networks analysis of airfield pavement heavy weight deflectometer data," *The Open Civil Engineering Journal*, vol. 2, pp. 15–23, 2008.
- [5] H. Adeli, "Neural networks in civil engineering : 1989-2000," *Computer-Aided Civil and Infrastructure Engineering*, vol. 16, pp. 126–142, 2001.
- [6] Y. H. Huang, *Pavement analysis and design*. Pearson Prentice Hall, 2004.
- [7] M. S. K. Hornik and H. White, "multilayer feedforward networks are universal approximators : Neural networks," vol. 2, pp. 359–366, 1989.
- [8] M. T. M. Saltan and M. Karasahin, "Artificial neural network application for flexible pavement thickness modeling," *Journal of Environmental Engineering and Science*, vol. 26, pp. 243–248, 2000.
- [9] S. Terzi, "Modeling the pavement serviceability ratio of flexible highway pavements by artificial neural networks," *Construction builtin materials*.
- [10] D. T. Thube, "Artificial neural network (ann) based pavement deterioration models for low volume roads in india," *International Journal of Pavement Research and Technology*, vol. 5, pp. 115–120, 2012.
- [11] D. V. Venayagamoorthy and G. K. Venayagamoorthy, "Network based classification fo road pavement structures," in *International Conference on Intelligent Sensing and Information Processing*, 2004.

- [12] A. H. Chouaib, "Simulation numérique du comportement non-linéaire des chaussées souples à base de matériaux granulaires non-traités," Master's thesis, ENP, 2012.
- [13] B. M. Y. et RAHAL Moncef Razine, "Utilisation des réseaux de neurones pour la simulation du comportement des matériaux : réalisation d'un ciment à prise réglable.," Master's thesis, ENP, 2012.
- [14] F. Z. GHESSAB, "Application des réseaux de neurones dans la prévision du comportement des ponts renforcés par matériaux composites.," Master's thesis, Université de Blida, 2012.

Annexe

Réseaux de neurones artificiel Toolbox sur MATLAB

On y accède en tapant la commande "nntool" sur l'interface MATLAB.

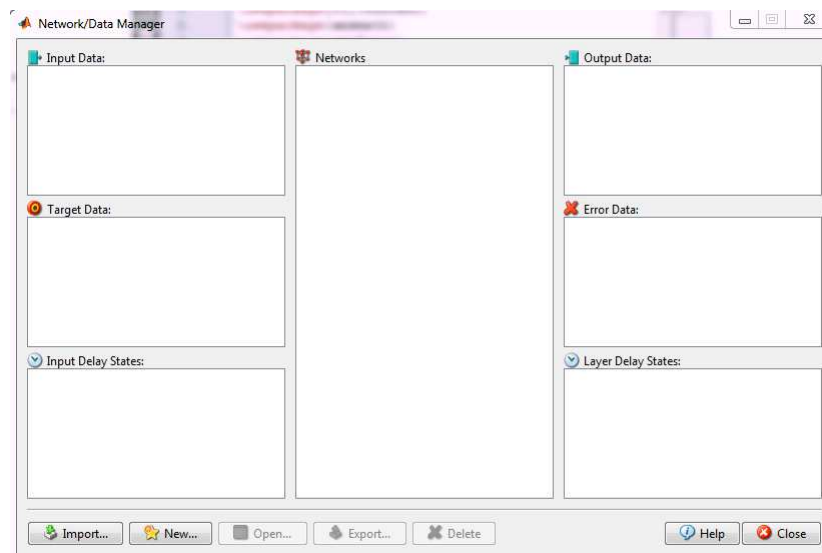


FIGURE 5.5 – RNA toolbox sur MATLAB

En cliquant sur "New" on accède à l'interface graphique qui permet de créer un réseau de neurone en fixant les paramètres voulus : type du réseau,

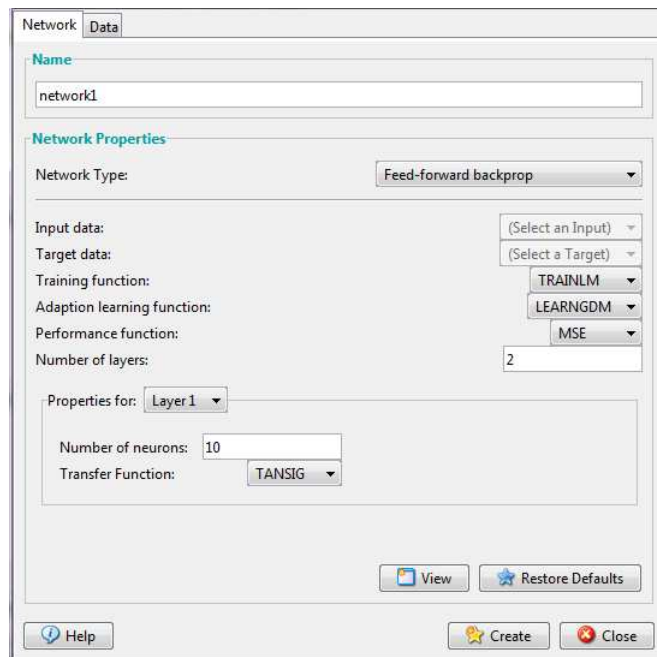


FIGURE 5.6 – Interface graphique pour la création d'un réseau de neurones

Le MATLAB propose aussi une interface spécifique à l'approximation de fonction. On y accède en saisissant la commande "nftool"

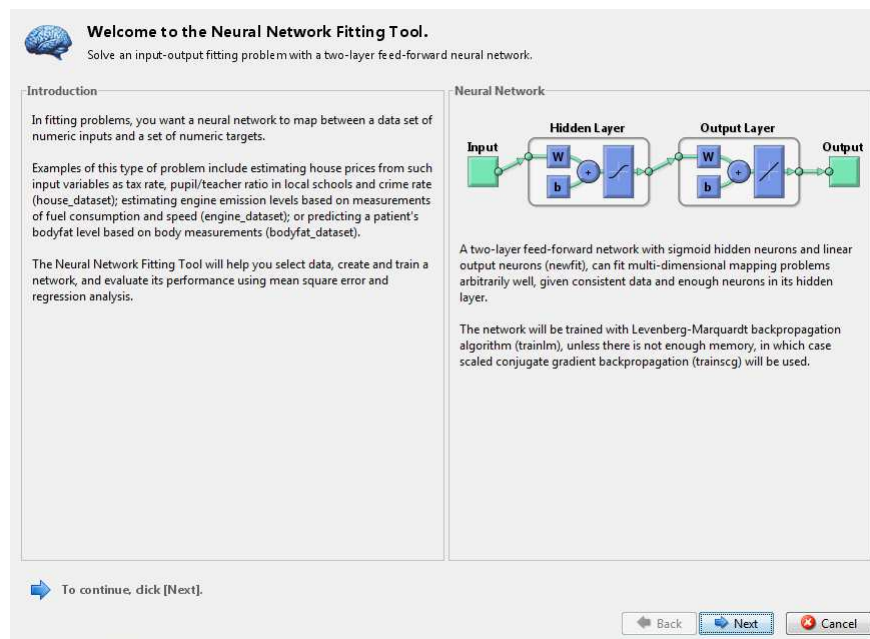


FIGURE 5.7 – Interface graphique pour l'approximation de fonctions

On présente ci-dessus quelques commandes de base nécessaires afin de manipuler les réseaux de neurones en dehors de l'interface graphiques (utiles notamment pour la programmation) :

`newfit(input, output, number of neurons)` : pour créer un réseau de neurone pour l'approximation de fonction (à une seule couche cachée)

`mse(E)` : pour calculer la moyenne quadratique d'un ensemble de valeurs. `getx(ann)` : pour sauvegarder les paramètres d'un réseau de neurones (poids et biais) sous forme de vecteur.

`setx(ann,X)` : charger les paramètres d'un réseau sauvegardé.

`sim(ann, E)` : pour simuler un réseau de neurones avec un ensemble d'entrées `E`.