

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur
et de la Recherche Scientifique

Université Akli Mohand Oulhadj - Bouira -

X•⊙V•εX •κ||ε Γ:κ:|A :||κ•X - X:⊙εO:εt -



وزارة التعليم العالي والبحث العلمي
جامعة أكلي محمد أولحاج
- البويرة -

FACULTE DES SCIENCES ET DES SCIENCES APPLIQUÉE

DEPARTEMENT DE GENIE MECANIQUE

PROJET DE FIN D'ETUDES

Présenté pour l'obtention du Diplôme de Master en Génie Mécanique

Option : **Énergétique**

Présenté par :

SAHTALI OUSSAMA et OSMANI AHMED AYOUB

Thème :

**MODELISATION PAR INTELEGENCE ARTIFICIEL DES PARAMETRES
D'ECHANGES CONVECTIFS DANS UN ECOULEMENTS AUTOUR DES
OBSTACLES**

Devant le jury composé de :

NOM et Prénom	Grade	Qualité
M^r. AZZOUG.M.O	MCB	Président
M^r. MOUSSAOUI. M	MCB	Encadreur
M^r. MESSAL.T	MAA	Examinateur

2022/2023



نموذج التصريح الشرفي الخاص بالالتزام بقواعد النزاهة العلمية لإنجاز بحث.

انا الممضي اسفله،

السيد(ة) نستاي أسامة الصفة: طالب، استاذ، باحث دألب

الحامل(ة) لبطاقة التعريف الوطنية: 408207178 والصادرة بتاريخ 01/08/2022

المسجل(ة) بكلية / معهد علوم و العلوم التطبيقية قسم هندسة ميكانيكية

والمكلف(ة) بإنجاز اعمال بحث(مذكرة، التخرج، مذكرة ماستر، مذكرة ماجستير، اطروحة دكتوراه).

عنوانها: Modelisation par intelligence artificiel des
parametre d'échange convectif

تحت إشراف الأستاذ(ة): هو مساري حيا م.م.م

أصرح بشرفي اني ألتزم بمراعاة المعايير العلمية والمنهجية الاخلاقيات المهنية والنزاهة الاكاديمية المطلوبة
في انجاز البحث المذكور أعلاه.

التاريخ: 2023 / 11 / 20

Salah توقيع المعني(ة)

رأي هيئة مراقبة السرقة العلمية:

Turnitin

%

29

النسبة:

مساعد رئيس قسم الهندسة الميكانيكية
مكلف بالتدريس والتعليم في التدرج بالنيابة

الامضاء: أ. مساري طارق

مساري طارق



نموذج التصريح الشرفي الخاص بالالتزام بقواعد النزاهة العلمية لإنجاز بحث.

انا الممضي اسفله،

السيد(ة) عبد المظفر أوجي الصفة: طالب، استاذ، باحث أ.أ.ب

الحامل(ة) لبطاقة التعريف الوطنية: AO 119312 والصادرة بتاريخ 25/11/2018

المسجل(ة) بكلية / معهد علوم وعلوم الأرض والعلوم التطبيقية قسم هندسة ميكانيكية

والمكلف(ة) بإنجاز اعمال بحث(مذكرة، التخرج، مذكرة ماستر، مذكرة ماجستير، اطروحة دكتوراه).

عنوانها: Modelisation par intelligence artificielle

des parametre d'echanges convectifs

تحت إشراف الأستاذ(ة): هو ساسي يحيى م.أ.د
أصرح بشرفي اني ألتزم بمراعاة المعايير العلمية والمنهجية الاخلاقيات المهنية والنزاهة الاكاديمية المطلوبة
في انجاز البحث المذكور أعلاه.

التاريخ: 20/11/2018

توقيع المعني(ة)

رأي هيئة مراقبة السرقة العلمية:

Turnitin

% 29

.النسبة:

م.أ.د. سعيد طارق
مساعد مدير التعليم في التدرج بالنيابة
قسم الهندسة الميكانيكية

الامضاء:

REMERCIEMENTS

On remercie dieu le tout puissant de nous avoir donné la force, le Courage et la patience d'entamer et de terminer ce modeste travail.

*Tout d'abord, ce travail ne serait pas aussi riche et n'aurait pas pu avoir le jour sans l'aide et l'encadrement de Mr. **MOUSSAOUI MOHAMMED**, on le remercie pour la qualité de son encadrement exceptionnel, pour sa patience, sa rigueur et sa disponibilité durant notre préparation de ce mémoire.*

Nos remerciements s'adressent également aux membres de jury et à tous nos professeurs du département de Génie Mécanique de l'Université de BOUIRA pour leurs générosités et la grande patience dont ils ont fait preuve malgré leurs charges académiques et professionnelles.

Enfin, je remercie très sincèrement tous ceux qui, de près ou de loin, ont contribué à la réalisation de

Ce travail.

OUSSAMA et AHMED

Dédicaces

Je dédie ce modeste travail,

*A la femme qui n'a jamais dit non aux âmes nécessiteuses
et qui n'a épargné aucun effort pour me rendre heureux :
mon adorable mère.*

*A l'homme, mon précieux offre de dieu, à qui je dois ma
vie, ma réussite et tout mon respect : mon cher père*

*A vous mes frères (amine et Ayoub) et mes sœurs qui
m'avez toujours soutenu et encouragé durant ces années
d'études.*

A mes chers amis, M. hamza, H. Adlan, Dj.younes,

OUSSAMA

Dédicaces

Je dédie ce modeste travail,

*A la femme qui n'a jamais dit non aux âmes nécessiteuses
et qui n'a épargné aucun effort pour me rendre heureux :
mon adorable mère.*

*A l'homme, mon précieux offre de dieu, à qui je dois ma
vie, ma réussite et tout mon respect : mon cher père*

*A vous mes frères (TAHER et MADJID) et mes sœurs qui
m'avez toujours soutenu et encouragé durant ces années
d'études.*

A mes chers amis, T.Amine, M.Yahia.

AHMED AYOUB

Sommaire

Introduction générale.....	1
Chapitre 1 : Généralités et étude bibliographie	
I.1 Introduction	2
I.2 Importance du transfert de chaleur dans la vie des ingénieurs	2
I.3 Les modes de Transfer de chaleur	3
I.3.1 La conduction thermique	3
I.3.2 Le rayonnement	4
I.3.3 La convection	5
I.3.4 Différentes lois de convection	7
I.4 Différents types des écoulements	9
I.4.1 Ecoulement incompressibles.....	9
I.4.2 Ecoulement compressibles.....	9
I.4.3 Ecoulement stable	10
I.4.4 Ecoulement instable.....	11
I.4.5 Ecoulement visqueux.....	11
I.4.6 Ecoulement non visqueux.....	12
I.5 Les régimes de l'écoulement : Il existe trois régimes sont :	12
I.5.1 Régime laminaire.....	12
I.5.2 Régime transitoire.....	13
I.5.3 Régime turbulent	13
I.6 Ecoulement autour des obstacles	14
I.7 Ecoulement autour d'un obstacle cylindrique.....	14
I.8 Etude Bibliographie dans un écoulement autour d'un obstacle	15
I.9 Conclusion :.....	16
Chapitre 2 _Réseaux de Neurones Artificiels	
II.1 Introduction	17
II.2 Historique :	17
II.3 Le Réseau de neurone biologique :.....	18
II.3.1 Le neurone biologique :.....	18
II.3.2 Fonctionnement du neurone biologique :.....	20
II.4 Réseau de neurone artificiel	21

II.4.1 Du neurone biologique au neurone formel	21
II.4.2 Domaines d'applications	23
II.4.3 Fonctionnement	24
II.4.4 Modélisation générale	25
II.5 Architecture du réseau de neurone.....	27
II.5.1 Réseau de neurones monocouches	28
II.5.2 Réseaux de neurones multicouches	29
II.6 Connexions du réseau de neurones	30
II.7 Réseaux propagation vers l'avant "Feed-Forward"	32
II.7.1 La Couche d'entrée	33
II.7.2 Couche de sortie	33
II.7.3 Couches cachées.....	34
II.7.4 Nombre de couches cachées	34
II.8 Nombre de neurones dans les couches cachées	35
II.9 Propriétés des réseaux de neurones	36
II.9.1 Apprentissage simple du perceptron (méthode du gradient et algorithme de Widrow-Hoff)	37
II.9.2 Apprentissage du perceptron multicouche	37
II.10 Algorithme d'apprentissage	38
II.11 Avantages et inconvénients des réseaux de neurones artificiels	38
II.11.1 Avantage des réseaux de neurones artificiels	38
II.11.2 Inconvénients des réseaux de neurones artificiels	39
II.12 Conclusion	40

Chapitre 3 Résultats et discussion

III.1. Introduction	41
III.2. Description de l'appareil	41
III.3. Procédure de Montage et Démontage de la Plaque de Transfert Thermique	43
III.4. Collection de la base de données	43
III.5. Utilisation de Matlab Neural Networks	44
III.6. Méthodologie de travail	45
III.7. Architecteur du réseau de neurone utilisé	45
III.7.1. Couche d'entrées	45
III.7.2. Couche caché	45
III.7.3. Couche sortie.....	45
III.7.4. Fonction d'activation	45

III.8. Préparation et partage la base des données :	46
III.9. Résultats expérimentale et discussion :	47
III.9.1. Choix du meilleur modèle	47
III.10. Estimation de la performance du meilleur modèle neuronale :	51
III.10.1. Comparaison graphique entre les valeurs	51
III.11. Analyse de performance	53
III.12 Conclusion	62
Conclusion générale.....	63
Référence bibliographique	64
ANNEXE	67

Liste figure

Figure I.1 conduction thermique	3
Figure I.2 Rayonnement	5
Figure I.3 Régime laminaire	12
Figure I.4 régime turbulent	13
Figure II.1 Schéma illustrant la structure d'un neurone	19
Figure II.2 Neurone formel.	22
Figure II.3 Différents types de fonctions d'activations pour le neurone	27
Figure II.4 structure D'un Réseau de neurones monocouches	28
Figure II.5 Réseaux de neurones multicouches	29
Figure II.6 Types de connexions.....	31
Figure II.7 Connexions entre deux couches, (a) Partielles, (b) Totales.	32
Figure III.1 appareil TD1005	41

Figure III.2 Un système d'acquisition de données polyvalent (VDAS)	42
Figure III.3 Plaque de Transfert Thermique	43
Figure III.4 méthodologie de travail - réseau de neurone	45
Figure III.5 modèle d'un Structure de RN.....	46
Figure III.6 Représentation graphique du la meilleure division de la base de données	46
Figure III.7 Régression linéaire entre le nombre de Nusselt calculée par le RNA et celle de l'expérimentale pour la phase d'apprentissage	51
Figure III.8 Régression linéaire entre le nombre de Nusselt calculée par le RNA et celle de l'expérimentale pour la phase de test	51
Figure III.9 Régression linéaire entre le nombre de Nusselt calculée par le RNA et celle de l'expérimentale pour la phase de validation.....	52
Figure III.10 Régression linéaire entre le nombre de Nusselt calculée par le RNA et celle de l'expérimentale pour tous les phase	52
Figure III.11 l'erreur moyen absolu pour le nombre de Nusselt	54
Figure III.12 représentation les valeurs de nombre de Nusselt expérimentale et celle calcule par le RNA en fonction de la vitesse (POWER 5W)	54
Figure III.13 représentation les valeurs de nombre de Nusselt expérimentale et celle calcule par le RNA en fonction de température moyen (POWER 5W)	55
Figure III.14 représentation les valeurs de nombre de Nusselt expérimentale et celle calcule par le RNA en fonction de la vitesse (POWER 45W)	55
Figure III.15 représentation les valeurs de nombre de Nusselt expérimentale et celle calcule par le RNA en fonction de température moyen (POWER 45W)	56
Figure III.16 représentation les valeurs de nombre de Nusselt expérimentale et celle calcule par le RNA en fonction de vitesse (POWER 70W)	56
Figure III.17 représentation les valeurs de nombre de Nusselt expérimentale et celle calcule par le RNA en fonction de température moyen (POWER 70W)	57
Figure III.18 Nombre de nusselt calcule et expérimental en fonction de la vitesse pour défirent power(5w-10w-20w).....	58
Figure III.19 Nombre de nusselt calcule et expérimental en fonction de la vitesse pour défirent power(30w-40w-45w).....	58
Figure III.20 Nombre de nusselt calcule et expérimental en fonction de la vitesse pour défirent power (50w-60w-70w).....	59
Figure III.21 Nombre de nusselt calcule et expérimental en fonction de température moyen pour défirent power (5w-10w-20w)	60
Figure III.22 Nombre de nusselt calcule et expérimental en fonction de temperateur moyen pour défirent power (30w-40w-45w)	60

Figure III.23 Nombre de nusselt calcule et expérimental en fonction de temperateur moyen pour défirent power (50w-60w-70w)	61
--	----

Liste des tableaux

Tableau II.1 équivalence RNB– RNA.....	22
Tableau II.2 détaille fonctions d'activations.....	26
Tableau III.1Partie de 12 Points de la base des données utilisé de ce travail.....	44
Tableau III.2 les résultats d'optimisation des architectures des RNA.....	48
Tableau III.3 Architecture du meilleur modèle obtenu.	50
Tableau III.4 autreerreurpour le nombre de Nusset	53

Nomenclature

φ : Flux de chaleur transmis par conduction (W).

λ : Conductivité thermique du milieu ($Wm^{-1} \text{ } ^\circ C^{-1}$).

x : Variable d'espace dans la direction du flux (m).

S : Aire de la section de passage du flux de chaleur (m^2).

σ : Constante de Stefan ($5,67 \cdot 10^{-8}$) ($Wm^{-2}K^{-4}$).

ϵ_p : Facteur d'émission de la surface.

T_p : Température de la surface (K).

T_∞ : Température du milieu environnant la surface (K) S Aire de la surface (m^2).

\dot{Q}_{Conv} : le taux de transfert de chaleur par convection (W/m^2).

H : constante de proportionnalité.

T_s : la température initiale du matériau.

T_∞ : la température finale du matériau.

Re : nombre de Reynolds.

W : la vitesse d'écoulement en m/s.

D : diamètre de la conduite en m.

ν : la viscosité cinématique en m^2/s .

μ : la viscosité dynamique en kg /ms.

h : coefficient de transfert thermique ou coefficient de convection ($W \cdot m^{-2} \cdot K^{-1}$)

λ : conductivité thermique ($W \cdot /m \cdot K$).

.

α : la diffusivité thermique ($\text{m}^2 \text{s}^{-1}$).

Cp : la capacité thermique massique à pression constante (en $\text{J kg}^{-1} \text{K}^{-1}$).

K : la conductivité thermique (en $\text{W m}^{-1} \text{K}^{-1}$).

g : est l'accélération de la pesanteur (m s^{-2}).

β : est le coefficient de dilatation (K^{-1}).

ΔT : est la différence de température entre la paroi et le fluide au repos à distance de la paroi (K).

ρ : est la masse volumique du fluide (kg m^{-3}).

E_i : Représente l'entrée i du neurone.

ω_i : Représente le poids attribué à l'entrée i .

F : Représente la fonction d'activation (Seuil) du neurone

S : Sortie du neurone.

NU : Nombre de Nusselt

\overline{NU}_{cal} : Nombre de Nusselt moyenne calculer par RNA

\overline{NU}_{exp} : Nombre de Nusselt expérimentale

Pr : Nombre de Prandtl.

Gr : Nombre de Grashof.

Ra : Nombre de Rayleigh

Mse : L'erreur moyen absolu

R : Le coefficient de corrélation

R^2 : Le coefficient de corrélation R^2

$MAARD$: L'erreur absolue moyenne relative

t_1 = température ambiante

t_2 = température de source

t_3 = température de sortie

المخلص

تهدف هذه الدراسة إلى توضيح إمكانات التقنيات الحديثة في مجال الذكاء الاصطناعي لتعزيز عملية نمذجة معاملات نقل الحرارة بالحمل الحراري. من خلال دمج البيانات التجريبية والرقمية مع خوارزميات التعلم الآلي، عملنا على تطوير أحد أفضل النماذج القادرة على التنبؤ بفعالية وتحليل سلوك العمليات الحرارية.

abstract

This study aims to elucidate the potential of modern techniques in the field artificial intelligence to enhance the process of modeling convective heat transfer parameters. By integrating experimental and numerical data with machine learning algorithms, we have worked towards developing one of the best models capable of effectively predicting and analyzing the behavior of thermal processes.

Résumé

Cette étude vise à clarifier le potentiel des technologies modernes dans le domaine de l'intelligence artificielle pour améliorer le processus de modélisation des coefficients de transfert de chaleur convectif. En intégrant des données expérimentales et numériques avec des algorithmes d'apprentissage automatique, nous avons développé l'un des meilleurs modèles capables de prédire et d'analyser efficacement le comportement des processus thermiques.

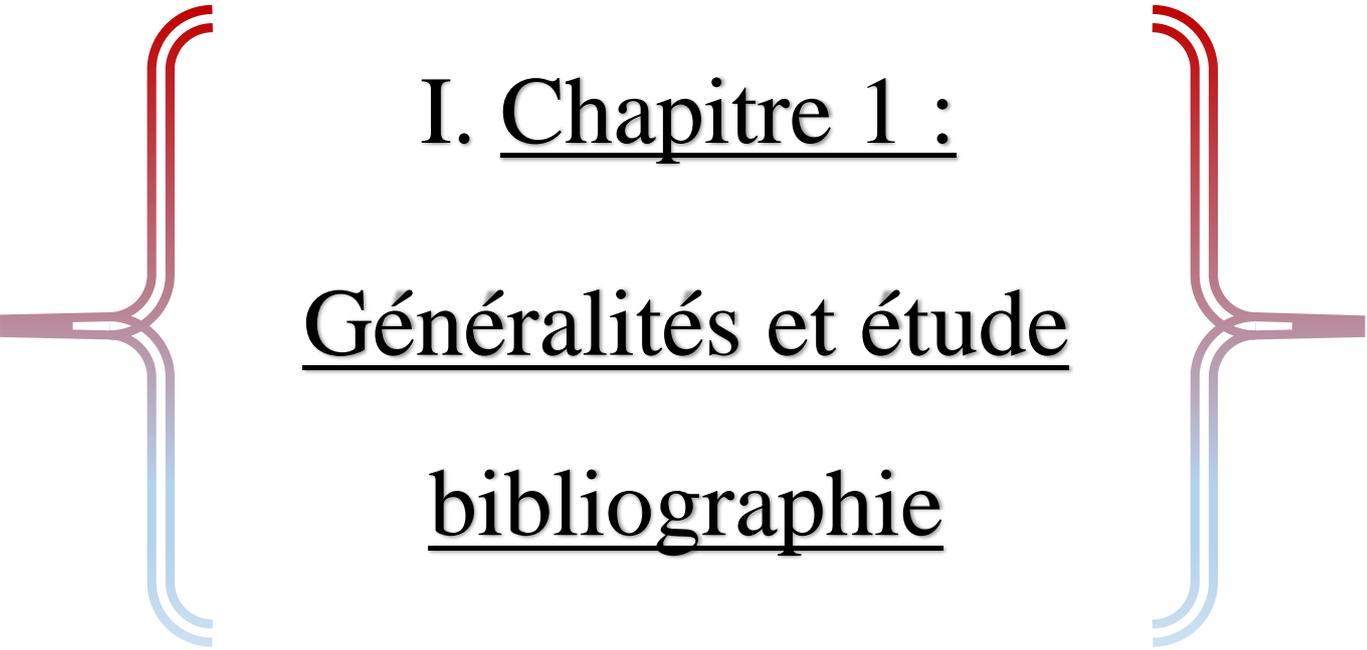
Introduction générale

Le phénomène de convection joue un rôle crucial dans de nombreux systèmes de transfert de chaleur, tels que les circuits de refroidissement de machines, les échangeurs de chaleur et les systèmes de chauffage. La modélisation précise des paramètres d'échanges convectifs dans un écoulement autour des obstacles est donc essentielle pour optimiser la performance de ces systèmes.

Dans cette optique, l'intelligence artificielle (IA) peut offrir une solution prometteuse. En effet, l'IA a récemment montré des capacités exceptionnelles pour modéliser des phénomènes complexes et non linéaires, ce qui en fait un outil potentiellement très puissant pour la modélisation des échanges convectifs.

Le but de ce mémoire est donc d'étudier la faisabilité et l'efficacité de l'utilisation de l'IA pour modéliser les paramètres d'échanges convectifs dans un écoulement autour des obstacles. Pour cela, nous allons nous appuyer sur des données expérimentales et numériques, ainsi que sur des algorithmes d'apprentissage automatique tels que les réseaux de neurones.

Nous commencerons par une revue de la littérature sur les modèles existants pour les échanges convectifs et sur les applications de l'IA dans le domaine de la modélisation thermique. Nous décrirons ensuite en détail les données que nous utiliserons pour entraîner et tester nos modèles, ainsi que les algorithmes d'apprentissage automatique que nous utiliserons. Nous présenterons ensuite les résultats de nos modèles, en comparant leurs performances à celles des modèles traditionnels. Enfin, nous discuterons des implications de nos résultats pour la conception de systèmes de transfert de chaleur optimisés.

The text is framed by two large, stylized brackets. The left bracket is on the left side, and the right bracket is on the right side. Both brackets are composed of two parallel lines: a red line on top and a blue line on the bottom. The brackets curve inward at the top and bottom, and have a horizontal bar across the middle.

I. Chapitre 1 :
Généralités et étude
bibliographie

I.1 Introduction

Les écoulements autour des obstacles sont un phénomène physique largement observé et étudié dans divers domaines technologiques tels que l'ingénierie navale, l'aéronautique et la météorologie. Comprendre ce problème classique revêt une importance pratique considérable pour les applications aérodynamiques et hydrodynamiques. Dans ce chapitre, nous avons abordé de manière générale le transfert de chaleur et les concepts liés à l'écoulement autour d'un obstacle. Enfin, nous procéderons à l'énumération de certaines recherches qui se sont penchées sur cette thématique.

I.2 Importance du transfert de chaleur dans la vie des ingénieurs

Le transfert de chaleur est un concept clé dans de nombreux domaines de l'ingénierie, car il est essentiel pour comprendre comment la chaleur se déplace entre différents composants et systèmes. Les ingénieurs doivent maîtriser les principes du transfert de chaleur pour concevoir des systèmes efficaces et économiques dans plusieurs domaines, notamment :

- **Systèmes de refroidissement** : Les ingénieurs doivent comprendre comment la chaleur est transférée entre différents composants d'un système pour concevoir des systèmes de refroidissement efficaces. Cela est crucial dans les domaines de l'électronique, de la production d'énergie et de l'industrie automobile, où les composants peuvent générer des quantités importantes de chaleur.
- **Systèmes de chauffage** : Les ingénieurs doivent également comprendre comment la chaleur est transférée dans les systèmes de chauffage pour concevoir des systèmes de chauffage efficaces et économiques. Cela est important dans les domaines du bâtiment, de la production d'énergie et de l'industrie chimique.
- **Systèmes de production d'énergie** : Le transfert de chaleur est également crucial dans la conception de systèmes de production d'énergie, tels que les centrales électriques, les réacteurs nucléaires et les turbines à gaz. Les ingénieurs doivent comprendre comment la chaleur est transférée dans ces systèmes pour maximiser l'efficacité énergétique et minimiser les pertes de chaleur.
- **Systèmes de traitement thermique** : Les ingénieurs doivent également comprendre le transfert de chaleur pour concevoir des systèmes de traitement thermique, tels que les fours industriels, les réacteurs chimiques et les stérilisateurs médicaux. Dans ces systèmes, la

chaleur est utilisée pour transformer ou traiter les matériaux, et les ingénieurs doivent comprendre comment la chaleur est transférée pour optimiser les processus de traitement.

I.3 Les modes de Transfer de chaleur :

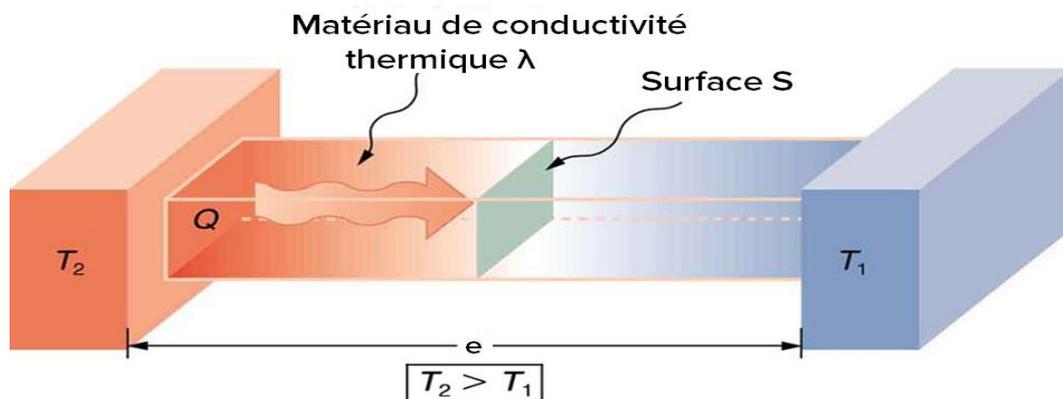
I.3.1 La conduction thermique :

La conduction thermique est un processus de transfert de chaleur qui se produit à travers un matériau ou entre des objets en contact direct. Il se produit lorsque les particules constitutives d'un matériau transmettent leur énergie thermique aux particules voisines par le biais de collisions.

La conduction thermique est régie par la loi de Fourier, qui établit que le flux de chaleur à travers un matériau est proportionnel à la différence de température à travers celui-ci, à la surface de contact et à la conductivité thermique du matériau. La conductivité thermique est une mesure de la capacité d'un matériau à conduire la chaleur.

Dans un solide, la conduction thermique se produit principalement par le biais des vibrations des atomes ou des électrons libres. Les matériaux conducteurs tels que les métaux ont une conductivité thermique élevée, ce qui leur permet de transférer rapidement la chaleur. En revanche, les isolants thermiques ont une conductivité thermique faible, ce qui limite le transfert de chaleur à travers eux.

Dans les fluides, tels que les liquides et les gaz, la conduction thermique se produit principalement par diffusion moléculaire. Les fluides ont généralement une conductivité thermique plus faible que les solides, ce qui rend la convection et le rayonnement thermique plus importants pour le transfert de chaleur dans ces milieux [1]



FigureI.1 conduction thermique [2]

Loi de Fourier : la densité de flux est proportionnelle au gradient de température :

$$\varphi = -\lambda s \text{grad}(T) \quad (\text{I.1})$$

- Ou sous forme algébrique : $\varphi = -\lambda s (dT/dx)$ (I.2)

I.3.2 Le rayonnement

Le rayonnement thermique est un mode de transfert de chaleur qui se produit lorsque des objets chauds émettent de l'énergie sous forme d'ondes électromagnétiques. Contrairement à la conduction et à la convection, qui nécessitent un milieu matériel pour se propager, le rayonnement thermique peut se déplacer à travers le vide.

Lorsqu'un objet est chauffé, il commence à émettre du rayonnement thermique en raison de l'agitation thermique de ses particules constitutives. La quantité de rayonnement thermique émis par un objet est régie par la loi de Stefan-Boltzmann, qui établit une relation proportionnelle entre l'énergie émise et la quatrième puissance de la température absolue de l'objet. Ainsi, plus la température de l'objet est élevée, plus l'intensité du rayonnement thermique émis est grande.

Le rayonnement thermique se compose d'un large spectre d'ondes électromagnétiques, allant des rayons gamma et des rayons X jusqu'aux rayons ultraviolets, à la lumière visible, aux infrarouges, aux micro-ondes et aux ondes radio. La répartition spectrale du rayonnement dépend de la température de l'objet, conformément à la loi de Planck sur le rayonnement du corps noir.

Lorsqu'il rencontre d'autres objets, le rayonnement thermique peut être absorbé, réfléchi ou transmis. L'absorption du rayonnement thermique par un objet entraîne son élévation de température, tandis que la réflexion le renvoie sans modification significative d'énergie. La transmission se produit lorsque le rayonnement traverse l'objet sans n'être absorbé ni réfléchi.

[3]

- Dans ce cas nous avons la relation : $\varphi = \sigma \epsilon p s (T_p^4 - T_\infty^4)$ (I.3)

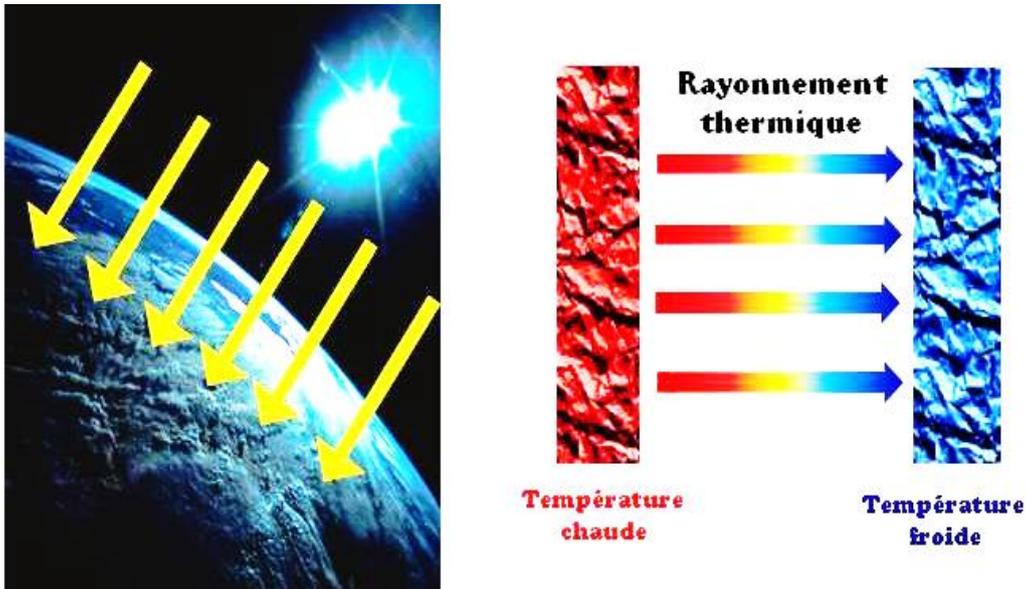


Figure I.2 Rayonnement [3]

I.3.3 La convection

La convection thermique est un mode de transfert de chaleur qui se produit par le déplacement d'un fluide, qu'il soit liquide ou gazeux. Ce processus se produit lorsque des zones de fluides chauds se déplacent vers des zones plus froides, transférant ainsi la chaleur.

La convection thermique peut être de deux types : la convection naturelle et la convection forcée sont : [4]

I.3.3.1 Convection naturelle :

La convection naturelle est un mode de transfert de chaleur qui se produit sans recourir à des dispositifs mécaniques tels que les pompes ou les ventilateurs. Elle est principalement induite par les variations de densité thermique à l'intérieur d'un fluide. Lorsque le fluide est chauffé, sa densité diminue, ce qui entraîne son ascension, tandis que le fluide plus froid et plus dense se déplace vers le bas pour prendre sa place.

Lorsqu'une différence de température se forme à l'intérieur du fluide, le fluide chaud s'élève en formant des courants ascendants, tandis que le fluide froid s'écoule vers le bas pour combler l'espace laissé par le fluide chaud. Ce mouvement de convection naturelle crée une circulation continue du fluide, favorisant ainsi le transfert de chaleur.

Un exemple courant de convection naturelle est l'air chaud qui monte près d'un radiateur. L'air en contact avec le radiateur est chauffé, devient moins dense et s'élève, créant un courant ascendant qui entraîne la circulation de l'air dans la pièce. De même, la chaleur émise par le soleil réchauffe l'air près de la surface terrestre, entraînant une convection naturelle et des mouvements atmosphériques.

La convection naturelle est présente dans de nombreux systèmes, qu'ils soient naturels ou industriels, tels que les systèmes de refroidissement passifs, les poêles à bois, les systèmes de chauffage solaire et même la circulation océanique. Une compréhension approfondie des principes de la convection naturelle est essentielle pour la conception de systèmes de refroidissement et de chauffage efficaces, ainsi que pour la prédiction des phénomènes météorologiques et océaniques. [4]

I.3.3.2 Convection Forcée :

La convection forcée est un mode de transfert de chaleur qui nécessite l'utilisation d'une source externe, telle qu'une pompe ou un ventilateur, pour provoquer le déplacement du fluide. Contrairement à la convection naturelle, qui est induite par les variations de densité thermique, la convection forcée permet un contrôle plus précis du transfert de chaleur.

Dans la convection forcée, le fluide est généralement contraint de circuler à travers un conduit ou un échangeur de chaleur à l'aide d'un dispositif mécanique. Le mouvement du fluide peut se produire verticalement, horizontalement ou selon une orientation spécifique, en fonction de l'application particulière. Ce mouvement du fluide entraîne un transfert de chaleur plus rapide et efficace que la convection naturelle, ce qui en fait un choix privilégié dans de nombreux systèmes de refroidissement et de chauffage.

La convection forcée est largement utilisée dans divers domaines tels que l'ingénierie thermique, la climatisation, la ventilation, les systèmes de chauffage et de refroidissement des bâtiments, ainsi que dans les industries de traitement des fluides. Des exemples courants incluent les radiateurs de voiture, les échangeurs de chaleur industriels, les systèmes de refroidissement par air et les ventilateurs de circulation.

Une compréhension approfondie des principes de la convection forcée est essentielle pour la conception et l'optimisation des systèmes de transfert de chaleur. Cela implique une connaissance des équations fondamentales, des propriétés du fluide, des coefficients de transfert de chaleur et de la géométrie des échangeurs de chaleur. Les ingénieurs et les professionnels spécialisés dans le domaine de l'ingénierie thermique utilisent ces connaissances pour concevoir

des systèmes efficaces et rentables répondant aux exigences spécifiques de chaque application.[5]

I.3.4 Différentes lois de convection

La loi de Newton de refroidissement : Dans le domaine de la thermodynamique, il existe une loi fondamentale qui permet de déterminer la quantité de chaleur échangée entre une surface solide et un fluide en mouvement. Cette loi, dite "loi de transfert de chaleur", revêt une grande importance dans de nombreux domaines scientifiques et industriels.

Selon cette loi, la quantité de chaleur transférée est directement proportionnelle à la différence de température entre la surface solide et le fluide environnant. En d'autres termes, plus cette différence de température est importante, plus la quantité de chaleur échangée sera élevée. Cette relation est tout à fait logique, car elle traduit le fait que les échanges de chaleur tendent à s'équilibrer lorsque les températures des deux milieux se rapprochent.

$$\dot{Q}_{\text{Conv}} = h (T_s - T_{\infty}) \quad (\text{I.4})$$

Nombre de Nusselt :

La compréhension et l'utilisation du nombre de Nusselt (Nu) revêtent une importance capitale dans l'étude des transferts de chaleur par convection entre une surface solide et un fluide en mouvement. Ce paramètre fondamental permet de caractériser ce transfert en établissant le rapport entre le produit du coefficient de transfert de chaleur h et de la longueur caractéristique D , et la conductivité thermique λ du fluide.

La valeur du nombre de Nusselt est essentielle pour analyser et prédire les transferts de chaleur par convection. En prenant en considération des variables telles que la vitesse du fluide, la géométrie de la surface solide, la différence de température et les propriétés thermiques du fluide, il permet d'évaluer l'efficacité de ce transfert.
$$\text{Nu} = \frac{h D}{\lambda} . \quad (\text{I.5})$$

Nombre de Reynolds :

La loi de Reynolds est l'un des principes clés en mécanique des fluides pour étudier et comprendre le comportement des écoulements. Son utilisation permet de distinguer si un écoulement est de nature laminaire ou turbulent, en fonction de divers paramètres tels que les propriétés du fluide, la géométrie du système et la vitesse de l'écoulement. [6]

$$\mathbf{Re} = \frac{V * D}{\nu} = \frac{\rho * V * D}{\mu} \quad (\mathbf{I.6})$$

Nombre de Prandtl :

La loi de Prandtl, un principe fondamental en mécanique des fluides, trouve son application essentielle dans l'étude des écoulements à couche limite. Elle repose sur la notion clé selon laquelle la couche limite, une fine région voisine d'une surface solide, joue un rôle crucial dans les transferts de chaleur et de quantité de mouvement.

Cette loi établit une relation précise entre les gradients de vitesse et de température à l'intérieur de la couche limite. Elle affirme que le rapport entre la diffusivité de quantité de mouvement (exprimée par la viscosité cinématique ν) et la diffusivité thermique α demeure constant à l'intérieur de cette couche limite. Mathématiquement, cette relation peut être formulée comme suit :

$$\mathbf{Pr} = \frac{\nu}{\alpha} = \frac{\mu * C_p}{k} \quad (\mathbf{I.7})$$

Nombre de Grashof :

La Nombre de Grashof constitue un pilier fondamental en mécanique des fluides, employé pour l'analyse des écoulements, qu'ils soient naturels ou forcés, et pour évaluer le rôle de la convection par rapport à la conduction thermique.

Cette loi joue un rôle essentiel dans la compréhension des transferts de chaleur et de masse dans les fluides, en particulier lorsque des différences de densité sont présentes. Elle repose sur le nombre de Grashof (Gr), un paramètre adimensionnel qui permet de quantifier la relation entre les forces de flottabilité et les forces visqueuses dans un écoulement.

$$\mathbf{Gr} = \beta g \frac{(\Delta T) \cdot D^3}{\nu^2} \quad (\mathbf{I.8})$$

Nombre de Rayleigh :

La loi de Rayleigh occupe une place centrale en mécanique des fluides et en thermique, où elle est largement utilisée pour analyser les phénomènes de convection naturelle et évaluer les transitions entre les différents modes de convection.

$$Ra = \frac{\beta \cdot \Delta T \cdot g \cdot Lc^3}{\alpha \cdot \nu} \quad (I.9)$$

I.4 Différents types des écoulements

Il y a une variété de types d'écoulements en mécanique des fluides, et chacun possède des caractéristiques et des comportements spécifiques qui lui sont propres. Voici quelques exemples parmi les types d'écoulements les plus fréquemment observés.[7]

I.4.1 Ecoulement incompressibles

Les écoulements incompressibles sont une catégorie essentielle en mécanique des fluides, caractérisée par une variation de densité du fluide négligeable. Dans ce type d'écoulement, la densité du fluide reste pratiquement constante, ce qui signifie que les effets de compression induits par la vitesse du fluide sont insignifiants.

Les écoulements incompressibles sont fréquemment observés dans les liquides, car leur compressibilité est très faible par rapport aux gaz. Par conséquent, ils sont largement utilisés pour modéliser les écoulements dans diverses applications, notamment les systèmes hydrauliques, les conduites d'eau, les tuyaux, les canaux, et bien d'autres, où la densité du fluide ne subit pas de variations significatives.

Dans l'étude des écoulements incompressibles, on applique les principes fondamentaux de conservation de la masse et de conservation de la quantité de mouvement. Ces principes permettent d'analyser et de prédire le comportement du fluide en tenant compte de facteurs tels que la viscosité, la pression, la vitesse et la géométrie du système.

En somme, les écoulements incompressibles constituent un modèle simplifié mais précieux pour étudier les fluides, offrant une approche pratique pour de nombreux scénarios d'ingénierie où la compressibilité du fluide peut être négligée. Toutefois, il convient de noter que dans certaines situations particulières, telles que les écoulements à très grande vitesse ou les conditions où les variations de densité sont significatives, il est nécessaire de prendre en compte la compressibilité du fluide et d'utiliser des modèles plus complexes. [7]

I.4.2 Ecoulement compressibles

Les écoulements compressibles sont un type particulier d'écoulement rencontré en mécanique des fluides, où les variations de densité du fluide ne peuvent être négligées. Contrairement aux écoulements incompressibles, les écoulements compressibles se caractérisent par des

changements significatifs de densité en réponse à des variations de pression, de température et de vitesse.

Ces écoulements sont couramment observés dans les gaz, car leur compressibilité est nettement plus élevée que celle des liquides. Ils se produisent dans des conditions où les variations de densité jouent un rôle crucial, notamment dans les écoulements supersoniques, les écoulements autour des ailes d'avion ou dans les tuyères de fusées.

L'analyse des écoulements compressibles fait appel aux équations de conservation de la masse, de la quantité de mouvement et de l'énergie, qui prennent en compte les variations de densité. Ces équations sont plus complexes que celles utilisées pour les écoulements incompressibles, car elles nécessitent de prendre en considération les effets de compressibilité du fluide.[6]

I.4.3 Ecoulement stable

Les écoulements stables, également appelés écoulements stationnaires, sont des situations d'écoulement en mécanique des fluides où le fluide se déplace de manière constante et régulière, sans subir de perturbations significatives. Dans ce type d'écoulement, les propriétés du fluide, telles que la vitesse, la pression et la densité, demeurent constantes le long de la trajectoire de l'écoulement.

Ces écoulements stables peuvent être observés dans différents contextes, tels que les conduites, les canaux, les rivières, ainsi que dans d'autres systèmes où les conditions environnementales sont relativement constantes et les perturbations externes sont minimales. Ils se caractérisent par des lignes de courant régulières et lisses, formant des motifs prédictibles et ordonnés. Les écoulements stables servent souvent de référence dans les analyses et les calculs en mécanique des fluides, permettant de mieux comprendre les comportements dynamiques des fluides.

L'étude des écoulements stables repose sur les principes fondamentaux de la conservation de la masse, de la quantité de mouvement et de l'énergie. Ces principes sont appliqués pour analyser le comportement du fluide en prenant en compte des facteurs tels que la viscosité, la pression, la géométrie du système et les conditions aux limites. Cette approche permet de prédire et de quantifier les propriétés de l'écoulement, facilitant ainsi la conception et l'optimisation des systèmes hydrauliques, des circuits de fluides et d'autres dispositifs où la stabilité de l'écoulement est essentielle. [7]

I.4.4 Écoulement instable

Les écoulements instables sont un fascinant domaine d'étude en mécanique des fluides, où le comportement du fluide devient turbulent, imprévisible et complexe. Contrairement aux écoulements stables, qui sont caractérisés par un flux régulier et prévisible, les écoulements instables sont marqués par des perturbations, des fluctuations et des tourbillons dans le mouvement du fluide.

Ces écoulements se manifestent dans différentes situations et conditions. Lorsque les conditions d'écoulement deviennent instables, par exemple en raison de changements brusques de pression ou de vitesse, le fluide peut entrer dans un régime instable. De plus, des forces extérieures telles que des turbulences atmosphériques ou des perturbations mécaniques peuvent également perturber le flux, donnant lieu à des écoulements instables. [7]

I.4.5 Écoulement visqueux

Les écoulements visqueux sont des types d'écoulement en mécanique des fluides qui sont caractérisés par la présence de forces de viscosité. L'un de ces écoulements est l'écoulement visqueux plan, également connu sous le nom d'écoulement de Poiseuille plan.

L'écoulement de Poiseuille plan se produit dans un plan bidimensionnel, où le fluide s'écoule entre deux surfaces parallèles. Dans ce type d'écoulement, la vitesse du fluide varie de manière linéaire avec la distance par rapport aux surfaces, et les lignes de courant sont parallèles et régulières.

Un autre exemple d'écoulement visqueux est l'écoulement de Poiseuille dans une conduite rectiligne, également connu sous le nom d'écoulement de Poiseuille cylindrique. Dans ce cas, le fluide s'écoule à travers une conduite cylindrique avec une pression constante à l'entrée et à la sortie. La vitesse du fluide varie de manière parabolique, étant maximale au centre de la conduite et diminuant vers les parois.

Ces écoulements visqueux sont importants à étudier car ils fournissent des modèles mathématiques utiles pour comprendre les propriétés du fluide et les effets de la viscosité. Par exemple, l'écoulement de Poiseuille plan est utilisé pour analyser le comportement des fluides visqueux tels que les liquides à faible vitesse. L'écoulement de Poiseuille cylindrique est utilisé pour étudier les écoulements dans les conduites et les tuyaux, fournissant des informations sur la résistance au débit et les pertes de pression. [8]

I.4.6 Écoulement non visqueux

L'écoulement non visqueux est un concept théorique en mécanique des fluides où la viscosité du fluide est supposée être nulle. Dans ce type d'écoulement, le fluide est considéré comme parfaitement "glissant" et sans aucune résistance interne à l'écoulement.

L'écoulement non visqueux est souvent utilisé comme une simplification mathématique pour analyser le comportement des fluides dans certaines situations. Par exemple, il peut être appliqué pour étudier les écoulements à haute vitesse, les écoulements autour d'objets aérodynamiques ou les écoulements dans des conditions idéalisées.

Dans un écoulement non visqueux, les lignes de courant sont lisses et régulières, sans aucune déformation due à la viscosité. De plus, la résistance au mouvement du fluide est considérée comme négligeable, ce qui permet d'obtenir des solutions analytiques plus simples pour les équations de conservation de la masse, de la quantité de mouvement et de l'énergie.

Il convient de noter que l'écoulement non visqueux est une approximation idéale et que dans la réalité, tous les fluides ont une certaine viscosité. Cependant, dans certaines conditions spécifiques où la viscosité est très faible par rapport aux autres forces en jeu, l'écoulement non visqueux peut être une bonne approximation pour décrire le comportement du fluide. [8]

I.5 Les régimes de l'écoulement : Il existe trois régimes sont :

I.5.1 Régime laminaire

En mécanique des fluides, l'écoulement laminaire est le type de flux d'un fluide où la totalité du liquide s'écoule généralement dans une direction cohérente, sans que les variations locales interfèrent (contrairement au régime turbulent, caractérisé par des tourbillons qui se perturbent mutuellement).

Lorsque le nombre de Reynolds est inférieur à 2000, le régime est considéré comme laminaire.

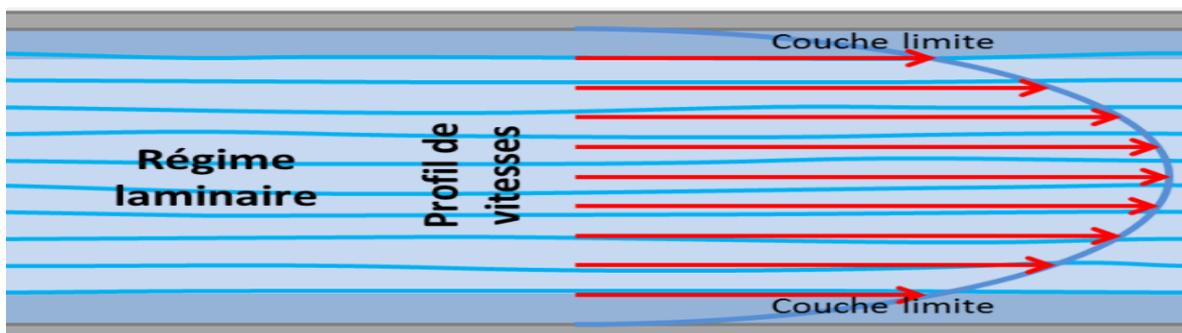


Figure I.3 . Régime laminaire [9]

I.5.2 Régime transitoire

Le régime transitoire se réfère à la période de transition d'un système entre deux états d'équilibre ou conditions initiales. C'est une phase pendant laquelle les variables du système fluctuent et atteignent des valeurs différentes de celles en régime permanent. Le régime transitoire est caractérisé par des phénomènes tels que les dépassements, les oscillations et les temps de montée et de descente. Il permet d'évaluer la rapidité avec laquelle le système atteint son nouvel état stable et de déterminer sa stabilité et sa performance. En résumé, le régime

Transitoire est la période de transition avant que le système n'atteigne un nouvel état stable.[9]

Lorsque le nombre de Reynolds se situe entre 2000 et 3000, le régime est considéré comme transitoire.

I.5.3 Régime turbulent

Le régime turbulent est l'un des régimes d'écoulement des fluides les plus complexes et les plus agités. Il se produit lorsque le nombre de Reynolds (Re) dépasse un certain seuil critique, généralement supérieur à 3000, bien que cela puisse varier en fonction du système étudié.

Dans un écoulement turbulent, le fluide se caractérise par des tourbillons turbulents, des fluctuations aléatoires et une agitation intense. Ces tourbillons se forment à différentes échelles et interagissent entre eux, transférant de l'énergie d'une échelle à une autre. Cela crée un écoulement chaotique et irrégulier, avec des variations rapides de la vitesse, de la pression et des autres propriétés du fluide.

L'écoulement turbulent est associé à une résistance plus élevée au mouvement du fluide par rapport à l'écoulement laminaire, ce qui entraîne une augmentation des pertes de charge et de la turbulence dans les systèmes de transport de fluides tels que les tuyaux, les canaux ou les conduites. [9]

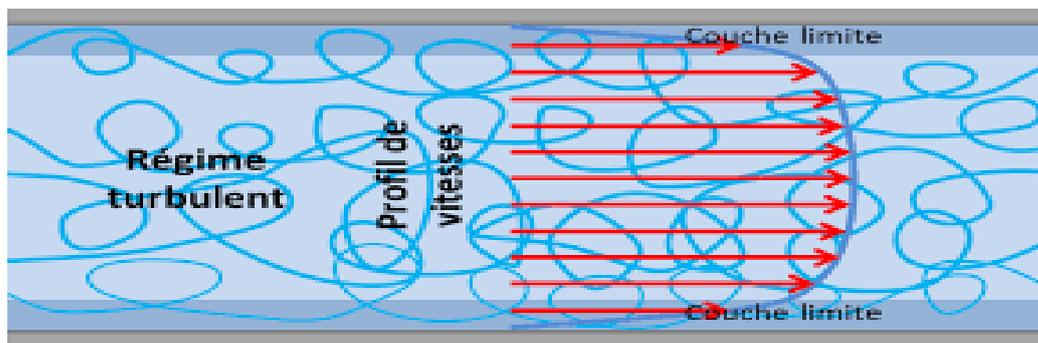


Figure I.4 régime turbulent [9]

I.6 Ecoulement autour des obstacles

Lorsqu'un fluide se heurte à un obstacle solide et doit le contourner, un phénomène d'écoulement se produit, donnant lieu à des interactions complexes. Ce phénomène, connu sous le nom d'écoulement autour des obstacles, se manifeste dans divers contextes, tels que le déplacement d'air autour d'une voiture en mouvement, le cheminement de l'eau autour d'un bateau ou encore le flux sanguin s'adaptant à une valve cardiaque.

Lorsque le fluide atteint l'obstacle, plusieurs phénomènes se produisent de manière simultanée. Initialement, le fluide se déplace de façon régulière et ordonnée, suivant un écoulement laminaire, jusqu'à ce qu'il se trouve face à l'obstacle. À cet instant, des tourbillons se forment à l'arrière de l'obstacle, accompagnés de zones de basse pression, tandis que des zones de haute pression émergent à l'avant. Ces tourbillons et variations de pression entraînent des forces de traînée sur l'objet et ont également une influence sur le comportement global de l'écoulement.

La compréhension et la modélisation de l'écoulement autour des obstacles revêtent une importance cruciale dans de nombreux domaines, tels que l'aérodynamique, l'hydrodynamique, la conception de structures, la conception de véhicules et même la médecine. Des techniques d'analyse numérique, telles que la simulation par éléments finis et la dynamique des fluides computationnelle, sont fréquemment utilisées pour étudier et prédire le comportement de l'écoulement autour des obstacles dans divers scénarios.

En prenant en compte ces éléments, il devient possible de mieux appréhender les mécanismes complexes qui régissent l'écoulement des fluides lorsqu'ils rencontrent des obstacles solides. Une meilleure compréhension de ce phénomène permet de développer des applications plus performantes dans les domaines de l'aéronautique, de l'ingénierie navale, de l'architecture, des transports et même de la santé, contribuant ainsi à des avancées significatives dans ces différents secteurs. [11]

I.7 Ecoulement autour d'un obstacle cylindrique

L'écoulement autour d'un obstacle cylindrique est un phénomène d'écoulement des fluides qui se produit lorsque le fluide rencontre un cylindre solide et doit contourner cet obstacle. Ce type d'écoulement se rencontre dans de nombreux contextes, tels que l'aérodynamique d'un avion, l'hydrodynamique d'un navire, ou même dans des applications industrielles où des cylindres sont présents.

Lorsque le fluide rencontre le cylindre, plusieurs phénomènes se produisent. Initialement, le fluide s'écoule de manière régulière et laminaire autour du cylindre jusqu'à ce qu'il atteigne la surface du cylindre. À ce stade, le fluide se divise en deux courants principaux : l'un s'écoule sur la surface supérieure du cylindre (la zone dite "d'écoulement supérieur") et l'autre s'écoule sur la surface inférieure (la zone dite "d'écoulement inférieur").

Dans la zone d'écoulement supérieur, le fluide accélère en se rapprochant de la surface du cylindre, atteint sa vitesse maximale au point le plus proche de celle-ci, puis ralentit à nouveau en s'éloignant. Cela crée une région de basse pression à l'avant du cylindre et une région de haute pression à l'arrière, générant ainsi des forces de traînée sur le cylindre.

Dans la zone d'écoulement inférieur, le fluide se comporte de manière similaire, mais inversée par rapport à la zone supérieure. Il s'écoule plus lentement à l'approche de la surface inférieure du cylindre, atteint sa vitesse minimale au point le plus proche, puis accélère à nouveau en s'éloignant. Cela crée également des variations de pression, mais de sens opposé à celles de la zone supérieure.

L'étude de l'écoulement autour d'un obstacle cylindrique est essentiel dans de nombreux domaines, tels que l'aérodynamique des véhicules, la conception de structures, la production d'énergie éolienne, et bien d'autres. Des techniques de modélisation numérique, telles que les simulations par éléments finis ou les méthodes des vortex, sont souvent utilisées pour étudier et prédire le comportement de l'écoulement autour du cylindre dans différents scénarios. [12]

I.8 Etude Bibliographie dans un écoulement autour d'un obstacle

Il existe plusieurs travaux de recherche pertinents dans le domaine de la modélisation de l'écoulement autour des obstacles. Voici quelques exemples :

"Von Kármán Vortex Street" (1911) : Ce travail fondateur par le physicien hongrois Theodore von Kármán a étudié les tourbillons alternés qui se forment derrière un cylindre placé dans un écoulement. Cela a jeté les bases de la compréhension des phénomènes de traînée et de formation de tourbillons.

"Flow Around Circular Cylinders" (1969) : Ce livre de J.N. Sorensen a présenté une compilation des recherches sur l'écoulement autour de cylindres circulaires. Il a examiné les différents régimes d'écoulement, les forces exercées sur le cylindre et les phénomènes de traînée.

"Large Eddy Simulation of Turbulent Flow Over and Around a Cube" (1998) : Cette étude menée par J.P. Monty et al. a utilisé la simulation des grandes échelles (LES) pour modéliser l'écoulement turbulent autour d'un cube. Les résultats ont montré les structures tourbillonnaires et ont permis de comparer les simulations numériques aux données expérimentales.

"Vortex Shedding from Circular Cylinders" (2003) : Ce livre de T.J. Pedley et J. T. Stuart a examiné en détail le phénomène de "vortex shedding" (formation de tourbillons) derrière un cylindre circulaire. Il a présenté des analyses théoriques et des expériences qui ont contribué à la compréhension de ce phénomène.

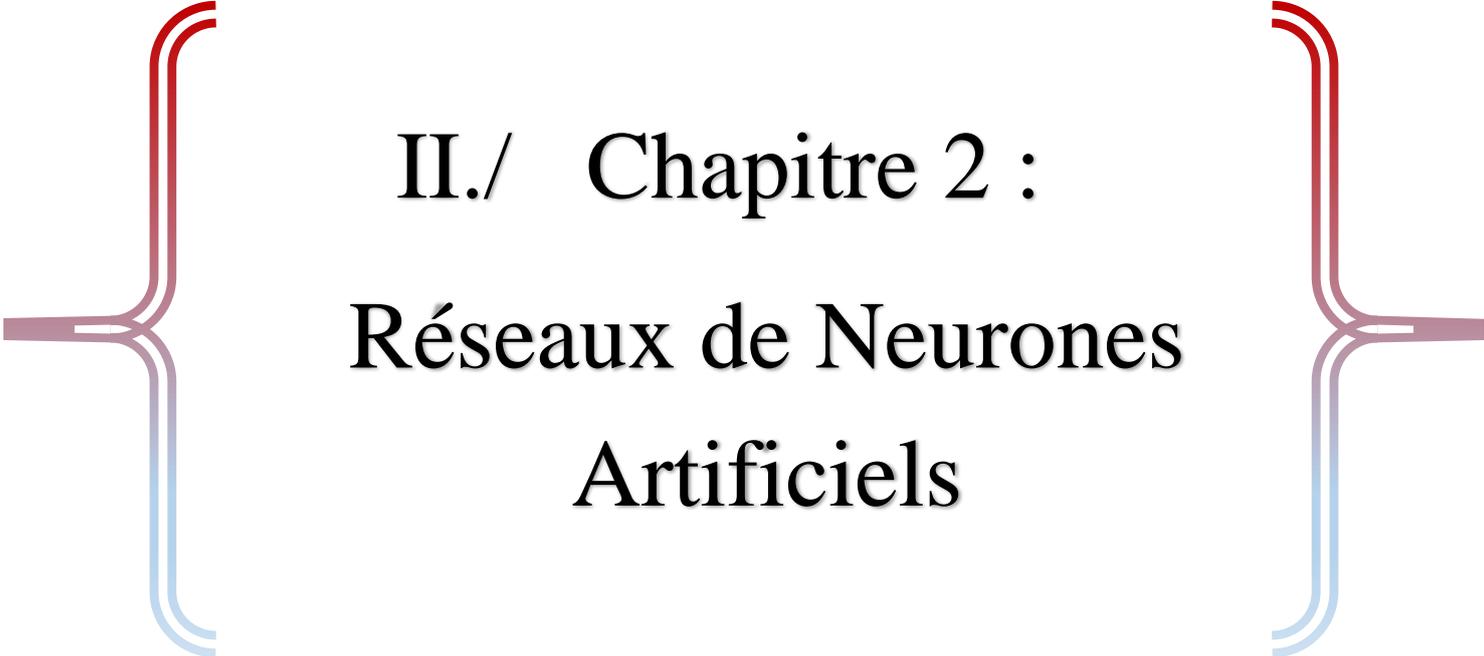
"Drag Reduction by Riblets" (2008) : Cette étude menée par G.H. Jansen et al. s'est concentrée sur l'utilisation de "riblets" (petites rainures) pour réduire la traînée autour d'un obstacle. Les expériences ont montré que les rainures orientées dans le sens de l'écoulement pouvaient réduire la traînée en perturbant les structures tourbillonnaires.

"Large-Scale Experiments on Flow Past Rough Cylinders" (2016) : Cette recherche menée par R. Vinuesa a réalisé des expériences à grande échelle pour étudier l'écoulement autour de cylindres rugueux. Les résultats ont fourni des données détaillées sur les caractéristiques de l'écoulement turbulent et ont permis de valider les modèles numériques.

Ces travaux, parmi d'autres, ont contribué à l'avancement de la modélisation de l'écoulement autour des obstacles en combinant des approches expérimentales et numériques. Ils ont permis de mieux comprendre les phénomènes d'écoulement, d'améliorer les méthodes de prédiction et d'explorer des stratégies pour réduire la traînée et optimiser la conception des structures.

I.9 Conclusion :

Dans ce chapitre, nous avons abordé différents concepts théoriques fondamentaux liés au transfert de chaleur et aux écoulements autour d'obstacles de forme carrée et cylindrique. Ainsi que quelques expériences de certains chercheurs sur ce phénomène.

The title is framed by two large, stylized brackets. The left bracket is on the left side, and the right bracket is on the right side. Both brackets are composed of two parallel lines: a red line on top and a blue line on the bottom. They curve inward at the top and bottom, and extend horizontally to the left and right respectively.

II./ Chapitre 2 :
Réseaux de Neurones
Artificiels

II.1 Introduction

L'intelligence artificielle (IA) est un domaine de l'informatique qui vise à développer des machines et des programmes informatiques capables d'accomplir des tâches qui requièrent normalement l'intelligence humaine. Ces tâches peuvent inclure la reconnaissance vocale, la vision, l'apprentissage, la prise de décision et la résolution de problèmes. L'IA utilise diverses techniques telles que les réseaux de neurones artificiels, les algorithmes génétiques, l'apprentissage automatique, les systèmes experts et la logique floue.

Les Réseaux de Neurones Artificiels (RNA) sont des outils puissants qui trouvent leur application dans de nombreux domaines scientifiques tels que le traitement du signal, la vision, la parole, la prévision, la modélisation et l'aide à la décision. Leur grande adaptabilité et leur capacité d'intégration dans des systèmes matériels, tels que des circuits intégrés, ou sous forme de logiciels via des programmes informatiques, font d'eux des éléments clés de la technologie moderne.

Ce chapitre se consacre entièrement à l'étude des Réseaux de Neurones Artificiels. Il propose une vue d'ensemble historique de leur développement, mettant en évidence les avancées significatives dans ce domaine. De plus, il analyse en détail le principe de base utilisé dans ces réseaux, mettant en évidence les mécanismes de propagation de l'information et d'apprentissage. Différents types de réseaux, sont également décrits en détail, soulignant leurs caractéristiques spécifiques et leurs applications courantes.

II.2 Historique :

Les réseaux de neurones artificiels (RNA) ont une histoire fascinante qui remonte aux années 1940. Leur développement a été marqué par des avancées significatives et une évolution constante au fil des décennies.

L'histoire des RNA commence avec les travaux pionniers de Warren McCulloch et Walter Pitts en 1943. Ils ont introduit le concept de neurone artificiel en proposant un modèle mathématique inspiré du fonctionnement des neurones biologiques. Ce modèle constituait une unité de traitement élémentaire capable de recevoir des signaux d'entrée, de les combiner et de produire une sortie en fonction d'une fonction d'activation.

Dans les années 1950 et 1960, d'autres chercheurs ont contribué au développement des RNA. Frank Rosenblatt a notamment introduit le perceptron en 1957, un type spécifique de réseau de

neurones à une seule couche capable de reconnaître des formes. Cependant, les limites du perceptron ont été mises en évidence dans les années 1960, ce qui a conduit à un certain désintérêt pour les RNA.

Cependant, l'intérêt pour les RNA a été ravivé dans les années 1980 et 1990 grâce à des avancées majeures. L'algorithme de rétropropagation du gradient, développé indépendamment par plusieurs chercheurs, est devenu une méthode clé pour entraîner les réseaux de neurones à plusieurs couches. Cela a permis d'ajuster les poids du réseau en fonction de l'erreur entre la sortie prédite et la sortie désirée, améliorant ainsi considérablement les performances des RNA.

Au cours des dernières décennies, les RNA ont connu une ascension fulgurante grâce à l'augmentation de la puissance de calcul, à la disponibilité de grandes quantités de données et aux avancées dans les algorithmes d'apprentissage automatique. Ils sont devenus des outils incontournables dans de nombreux domaines, tels que la vision par ordinateur, le traitement du langage naturel, la reconnaissance vocale, la prédiction et l'analyse de données.

Plus récemment, les réseaux de neurones profonds, tels que les réseaux de neurones à convolution (CNN) et les réseaux de neurones récurrents (RNN), ont connu un succès remarquable dans des tâches complexes telles que la classification d'images, la traduction automatique et la génération de texte. Grâce à leur capacité à extraire des caractéristiques hiérarchiques et à modéliser des dépendances temporelles, ces réseaux ont révolutionné de nombreux domaines de l'intelligence artificielle.

Aujourd'hui, les réseaux de neurones artificiels continuent de progresser et de repousser les limites de ce qui est possible en termes de traitement de l'information. Leur utilisation est devenue omniprésente dans de nombreux domaines, et ils jouent un rôle crucial dans des applications telles que la reconnaissance d'images, la recommandation de produits, l'analyse prédictive et la médecine personnalisée [13].

II.3 Le Réseau de neurone biologique :

II.3.1 Le neurone biologique :

II.3.1.1 Définition :

Le neurone, en tant qu'unité fondamentale du système nerveux, présente une structure complexe et spécialisée qui lui permet d'assurer la transmission et le traitement de l'information. Voici les principales composantes d'un neurone :

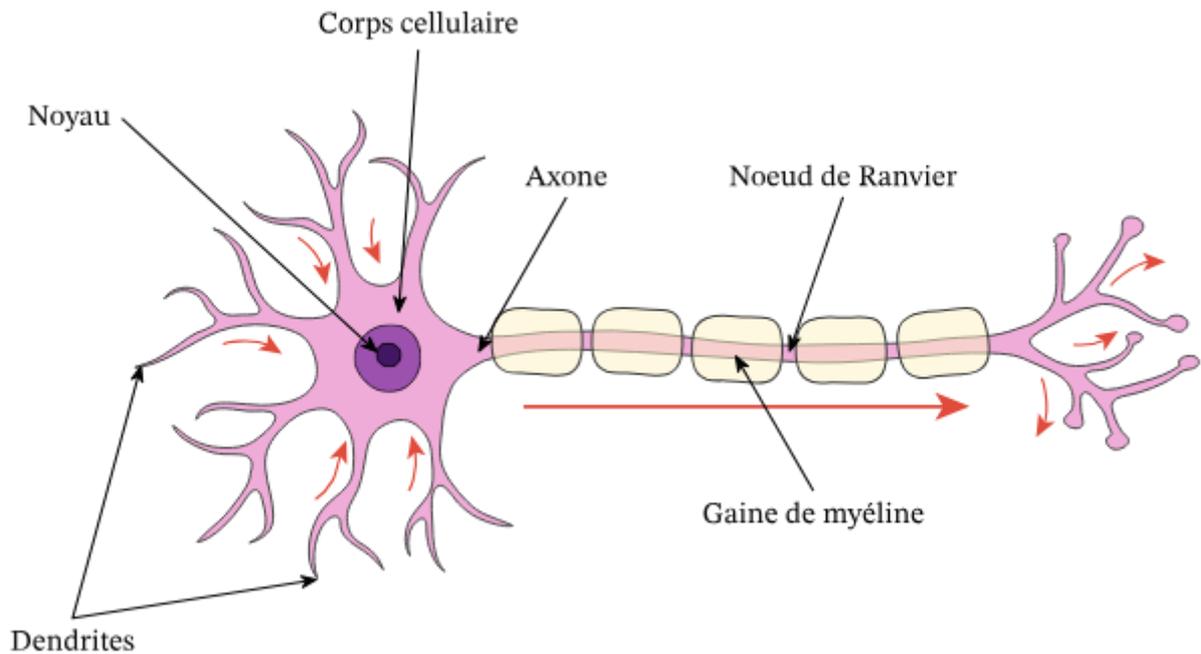


Figure II.1 Schéma illustrant la structure d'un neurone [14]

Le corps cellulaire : également connu sous le nom de soma, constitue la partie centrale du neurone. C'est là que se trouve le noyau, qui contient l'ADN et les organites cellulaires nécessaires à la synthèse des protéines et aux processus métaboliques. Le corps cellulaire joue un rôle crucial dans l'intégration des signaux provenant des dendrites.

Les dendrites : sont des prolongements ramifiés qui émergent du corps cellulaire. Leur fonction principale est de recevoir les signaux électriques et chimiques provenant d'autres neurones ou de cellules sensorielles, et de les transmettre vers le corps cellulaire. Les dendrites augmentent la surface de réception du neurone, lui permettant de recevoir et d'intégrer une grande quantité d'informations.

L'axone : est une longue extension du corps cellulaire qui transmet les signaux électriques du neurone vers d'autres neurones ou vers les cellules effectrices, telles que les muscles ou les glandes. Il est recouvert d'une gaine de myéline, produite par les cellules de Schwann, qui isole et accélère la transmission des signaux électriques le long de l'axone. La myéline forme des interruptions appelées noeuds de Ranvier, qui permettent une propagation plus rapide des signaux.

Les terminaisons axonales : également appelées boutons synaptiques, se trouvent à l'extrémité de l'axone. Ce sont de petites structures spécialisées qui établissent des connexions avec d'autres neurones au niveau des synapses. Les terminaisons axonales sont responsables de la libération

de neurotransmetteurs, des substances chimiques qui permettent la transmission des signaux d'un neurone à l'autre.

Les synapses : sont les zones de contact entre les neurones. Elles sont essentielles à la transmission des signaux électriques et chimiques. Les signaux électriques se transforment en signaux chimiques grâce à la libération de neurotransmetteurs au niveau des synapses. Les neurotransmetteurs se lient à des récepteurs spécifiques sur la membrane des neurones cibles, déclenchant ainsi de nouvelles réactions électriques. [15]

II.3.2 Fonctionnement du neurone biologique :

Le fonctionnement d'un neurone biologique est crucial pour la transmission et le traitement de l'information au sein du système nerveux. Voici une description détaillée de son fonctionnement :

Réception des signaux : Les dendrites, qui sont des prolongements ramifiés du neurone, captent les signaux électriques et chimiques provenant d'autres neurones ou de cellules sensorielles. Ces signaux sont transmis sous forme de courants électriques à travers les membranes des dendrites.

Intégration des signaux : Les signaux reçus par les dendrites sont acheminés vers le corps cellulaire du neurone, également appelé soma. À ce stade, les signaux sont analysés et combinés pour déterminer si le seuil d'excitation nécessaire à la génération d'un signal de sortie est atteint.

Génération du potentiel d'action : Si la somme des signaux dépasse le seuil d'excitation, le neurone génère un potentiel d'action. Ce potentiel d'action est un signal électrique qui se propage le long de l'axone du neurone.

Transmission du signal : L'axone est une longue extension du neurone chargée de la transmission du potentiel d'action. Il est revêtu d'une gaine de myéline, qui isole électriquement l'axone et accélère la vitesse de transmission du signal électrique. Le potentiel d'action se propage de manière unidirectionnelle le long de l'axone, du corps cellulaire vers les terminaisons axonales.

Communication entre les neurones : Les terminaisons axonales, aussi connues sous le nom de boutons synaptiques, établissent des connexions avec d'autres neurones au niveau des synapses. Lorsque le potentiel d'action atteint les terminaisons axonales, il déclenche la libération de neurotransmetteurs dans l'espace synaptique.

Transmission du signal chimique : Les neurotransmetteurs sont des substances chimiques libérées par les terminaisons axonales. Ils se lient aux récepteurs présents sur les dendrites des neurones postsynaptiques, ce qui provoque l'ouverture de canaux ioniques et génère un nouveau signal électrique dans le neurone suivant.

Répétition du processus : Le signal électrique est ainsi transmis de neurone en neurone, formant des réseaux neuronaux complexes qui permettent la transmission de l'information à travers tout le système nerveux. [16]

II.4 Réseau de neurone artificiel

II.4.1 Du neurone biologique au neurone formel :

La transition du neurone biologique au neurone formel marque une avancée majeure dans le domaine des réseaux de neurones artificiels. Voici un aperçu du processus de modélisation du neurone biologique en un neurone formel :

Compréhension approfondie du neurone biologique : Les scientifiques se sont attelés à étudier en détail la structure et le fonctionnement des neurones biologiques afin de comprendre leur rôle dans la transmission et le traitement de l'information.

Identification des éléments clés : Les caractéristiques essentielles du neurone biologique, telles que le corps cellulaire, les dendrites, l'axone, les synapses et le potentiel d'action, ont été identifiées comme les éléments fondamentaux à prendre en compte lors de la modélisation du neurone formel.

Modélisation mathématique : Les chercheurs ont développé des modèles mathématiques visant à représenter le comportement du neurone biologique. Parmi ces modèles, le modèle de McCulloch-Pitts, introduit en 1943, est l'un des plus utilisés. Il décrit le neurone formel comme une unité de traitement binaire qui est activée ou désactivée en fonction des signaux d'entrée qu'il reçoit.

Fonction d'activation : Afin de reproduire la fonction d'activation observée dans les neurones biologiques, différentes fonctions mathématiques ont été proposées, telles que la fonction seuil, la fonction sigmoïde et la fonction tangente hyperbolique. Ces fonctions déterminent la sortie du neurone formel en fonction de la somme pondérée de ses entrées.

Pondération des connexions synaptiques : Les connexions synaptiques entre les neurones sont représentées par des poids synaptiques qui déterminent la force de connexion entre eux.

Ces poids sont ajustés lors de la phase d'apprentissage du réseau de neurones artificiels, permettant ainsi de pondérer l'influence des signaux d'entrée sur la sortie du neurone formel.

Réseaux de neurones artificiels : En interconnectant plusieurs neurones formels, les chercheurs ont créé des réseaux de neurones artificiels capables d'accomplir des tâches de traitement de l'information, telles que la classification de données ou la prédiction.

Grâce à la modélisation du neurone biologique en un neurone formel et à la création de réseaux de neurones artificiels, il devient possible de reproduire certaines capacités du système nerveux et de réaliser des tâches complexes de traitement de l'information. [17]

$$S = F \left(\sum_n^i \omega_i E_i \right) + b_i \quad (II.1)$$

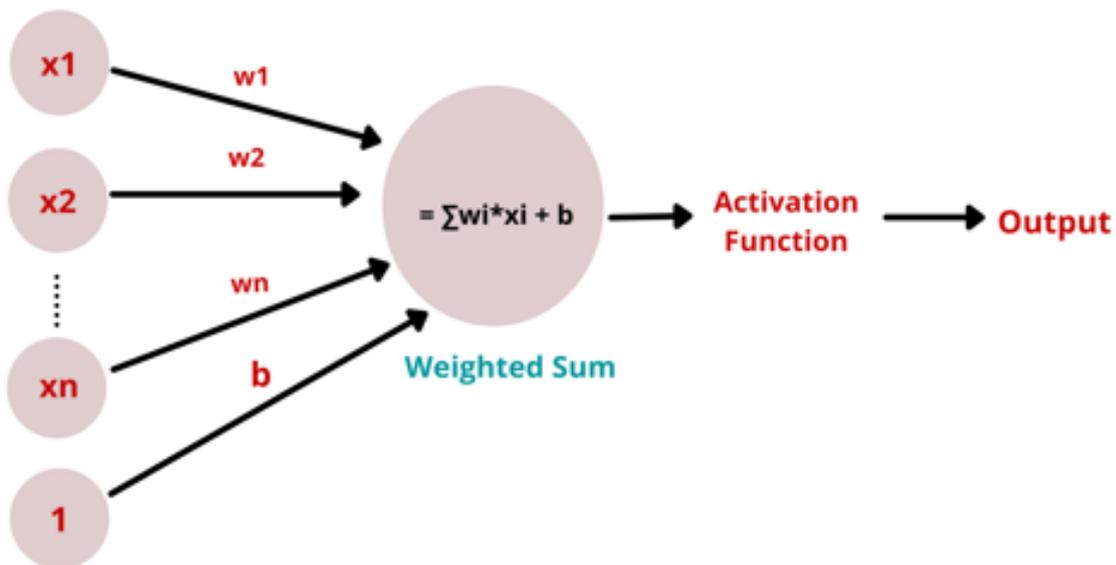


Figure II.2 Neurone formel.

On en déduit l'équivalence suivante :

Tableau II.1 équivalence RNB– RNA

Réseaux de neurones biologique	Réseaux de neurones artificiels
Soma	Neurone
Dendrite	Entrée
Axone	Sortie
Synapse	Poids

II.4.2 Domaines d'applications :

Les réseaux de neurones, en tant que modèle de traitement de l'information inspiré du cerveau, ont connu une adoption croissante dans de nombreux domaines d'application. Leur capacité à apprendre à partir de données et à modéliser des relations complexes en fait des outils puissants pour résoudre divers problèmes. Voici un aperçu des domaines dans lesquels les réseaux de neurones trouvent des applications significatives :

Vision par ordinateur : Les réseaux de neurones convolutifs (CNN) sont couramment utilisés dans la vision par ordinateur pour des tâches telles que la détection d'objets, la reconnaissance faciale, la segmentation d'images et la classification d'images. Ces réseaux sont capables d'apprendre à extraire des caractéristiques visuelles significatives à partir des images, ce qui les rend particulièrement adaptés à ces tâches.

Traitement du langage naturel : Les réseaux de neurones récurrents (RNN) et les réseaux de neurones à attention sont utilisés dans le traitement du langage naturel. Ils permettent de réaliser des tâches telles que la traduction automatique, la génération de texte, la classification de textes et l'analyse des sentiments. Ces réseaux sont capables de capturer la structure et les dépendances séquentielles dans les données textuelles.

Reconnaissance de la parole : Les réseaux de neurones récurrents, en particulier les LSTM, sont largement utilisés pour la reconnaissance automatique de la parole. Ils permettent de convertir des signaux audios en texte et sont utilisés dans les systèmes de commande vocale, les applications de transcription audio, etc.

Apprentissage automatique : Les réseaux neuronaux profonds (DNN) sont au cœur de nombreux algorithmes d'apprentissage automatique. Ils sont utilisés pour des tâches telles que la classification, la régression, la prédiction et la recommandation. Ces réseaux sont capables d'apprendre des représentations hiérarchiques complexes des données, ce qui les rend efficaces pour résoudre des problèmes complexes.

Médecine et biologie : Les réseaux de neurones sont utilisés dans le domaine médical pour la détection de maladies, la segmentation d'images médicales, l'analyse de données génétiques et la prédiction de résultats cliniques. Ils permettent de traiter de grandes quantités de données médicales et d'extraire des informations utiles pour le diagnostic et le traitement.

Finance et économie : Les réseaux de neurones sont utilisés pour la prévision des marchés financiers, la détection de fraude, l'analyse de données économiques et la modélisation de séries temporelles. Ils permettent d'identifier des schémas complexes dans les données financières et d'obtenir des prévisions plus précises.

Robotique et automatisation : Les réseaux de neurones sont utilisés dans la robotique pour la planification de mouvement, la perception des robots, l'apprentissage par renforcement et la manipulation d'objets. Ils permettent aux robots d'interagir de manière plus intelligente avec leur environnement et d'effectuer des tâches complexes.

II.4.3 Fonctionnement

Les réseaux de neurones sont des modèles de traitement de l'information inspirés du fonctionnement du cerveau. Ils sont composés de nombreux neurones artificiels interconnectés, organisés en couches, et leur fonctionnement repose sur plusieurs étapes clés. Voici une description approfondie du fonctionnement d'un réseau de neurones :

Architecture du réseau : Un réseau de neurones est structuré en plusieurs couches, comprenant généralement une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Chaque couche est constituée de multiples neurones qui effectuent des calculs et transmettent les informations entre elles.

Propagation avant (feedforward) : Lors de la phase de propagation avant, les données d'entrée sont transmises à travers le réseau, de la couche d'entrée à la couche de sortie. Chaque neurone reçoit des signaux d'entrée pondérés, les combine en utilisant des fonctions d'activation spécifiques, puis transmet le résultat à la couche suivante du réseau.

Calcul des poids : Chaque connexion entre les neurones est associée à un poids synaptique, qui représente la force de l'influence d'un neurone sur un autre. Initialement, ces poids sont généralement définis de manière aléatoire. Cependant, lors de l'apprentissage du réseau, ils sont ajustés de manière itérative pour améliorer les performances du réseau en fonction de la tâche spécifique.

Fonction d'activation : Chaque neurone utilise une fonction d'activation pour déterminer sa sortie en fonction de la somme pondérée de ses entrées. Les fonctions d'activation couramment utilisées incluent la fonction sigmoïde, la fonction seuil, la fonction tangente hyperbolique, et bien d'autres. Ces fonctions introduisent une non-linéarité dans le réseau, permettant ainsi de modéliser des relations complexes entre les données.

Rétropropagation de l'erreur : Une fois que la sortie du réseau est obtenue, elle est comparée à la sortie attendue pour calculer l'erreur. Cette erreur est ensuite propagée en sens inverse à travers le réseau, de la couche de sortie à la couche d'entrée, en utilisant un algorithme appelé rétropropagation de l'erreur. Cela permet d'ajuster les poids synaptiques de manière à réduire progressivement l'erreur et à améliorer les performances globales du réseau.

Apprentissage et ajustement des poids : L'apprentissage d'un réseau de neurones se fait par itérations successives. À chaque itération, les poids synaptiques sont ajustés en utilisant des algorithmes d'optimisation, tels que la descente de gradient. L'objectif principal est de minimiser l'erreur entre les sorties réelles du réseau et les sorties attendues, ce qui permet d'obtenir un réseau capable de produire des prédictions précises pour de nouvelles données. [18]

II.4.4 Modélisation générale

L'architecture d'un réseau de neurones n'est souvent que partiellement déterminée par la tâche à accomplir. Le concepteur a la liberté de fixer les entrées, l'état et les sorties du réseau en fonction de cette tâche, ainsi que le type et la connectivité des neurones (comme illustré dans la figure ci-dessous).

On peut modéliser un réseau de neurones en utilisant des éléments fondamentaux, tels que :

La nature des entrées qui peuvent être binaires (0 ou 1), (-1, 1) ou réelles appartenant généralement à un intervalle borné $[a, b]$.

La fonction des entrées qui définit le prétraitement effectué sur ces dernières.

La fonction d'activation (seuil), qui représente la limite à partir de laquelle le neurone s'active. La sortie du neurone dépend d'une fonction de transfert.[19]

Tableau II.2 détaille fonctions d'activations.

Nom de la fonction	Relation entrée/sortie	Graphe de la Fonction	Fonction dans 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 $n < 0$ $a=1$ si $n \geq 0$		Poslin
Logistique (Sigmoidale logarithmique)	$a = \frac{1}{1+e^{-n}}$		Logsig
Tangente hyperbolique	$a = \frac{e+n - e-n}{e+n + e-n}$		Tansig
Triangulaire de base	$a = 1 - n , -1 \leq n \leq +1$ $a=0$, autrement		Tribas

II.5 Architecture du réseau de neurone

La configuration d'un réseau de neurones dépend intimement de la stratification de ses couches, et plus particulièrement, de la trame des connexions qui les unit. Chaque strate, tissée avec une précision minutieuse, dévoile un panorama complexe d'interconnexions neuronales. La profondeur du réseau, dictée par le nombre de ses couches, constitue un paramètre essentiel, conférant une dimension hiérarchique à la transmission de l'information.

L'architecture résultante est le fruit d'une délicate orchestration, où la structure des connexions entre les neurones joue un rôle central. Chaque lien, chaque synapse, devient une voie potentielle de communication, dessinant un réseau dense d'interactions. La disposition et la force de ces connexions déterminent la capacité du réseau à apprendre et à généraliser, définissant ainsi sa capacité à traiter des informations complexes.

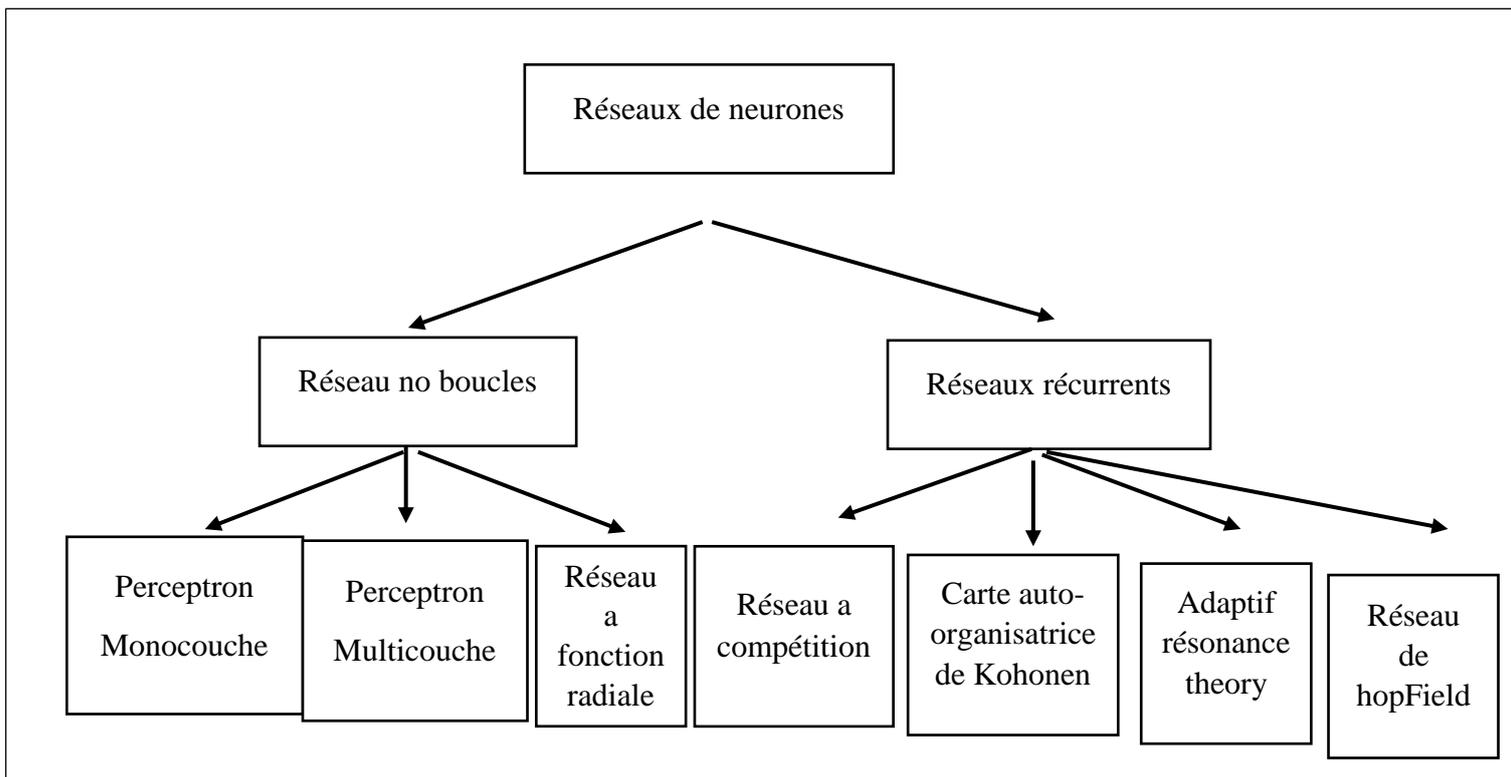


Figure II.3 Différents types de fonctions d'activations pour le neurone

La figure précédente (figure II.3), représenté les topologies des réseaux de neurones artificiels.

Il existe plusieurs types d'architectures, on peut citer :

- ❖ multicouches
- ❖ monocouches
- ❖ Réseaux à connexion locale
- ❖ Réseaux à connexion complète. [20]

II.5.1 Réseau de neurones monocouches

Un réseau de neurones monocouche, également appelé perceptron monocouche, est une architecture simple de RNA qui se compose d'une seule couche de neurones. Cette couche, connue sous le nom de couche de sortie, est responsable de la génération des prédictions ou des sorties du réseau.

Dans un réseau de neurones monocouche, chaque neurone est connecté à toutes les entrées du réseau. Chaque connexion entre un neurone et une entrée possède un poids associé qui détermine l'importance de cette connexion lors du calcul de la sortie du réseau.

Le fonctionnement d'un réseau de neurones monocouche est relativement simple. Chaque neurone reçoit les valeurs des entrées et les multiplie par les poids correspondants. Ces produits pondérés sont ensuite sommés, et une fonction d'activation est appliquée à cette somme pour produire la sortie du neurone.

Traditionnellement, la fonction d'activation utilisée dans les réseaux de neurones monocouches est la fonction seuil, qui attribue une sortie binaire en fonction d'un seuil fixe. Cependant, des fonctions d'activation plus sophistiquées, telles que la fonction sigmoïde ou la fonction ReLU (Rectified Linear Unit), peuvent également être utilisées.

Les réseaux de neurones monocouches sont généralement utilisés pour des tâches simples de classification ou de régression où la relation entre les entrées et les sorties est linéaire. Pour des problèmes plus complexes nécessitant la capture de relations non linéaires plus sophistiquées, les RNA multicouches, qui comportent plusieurs couches de neurones, sont souvent préférés. [21]

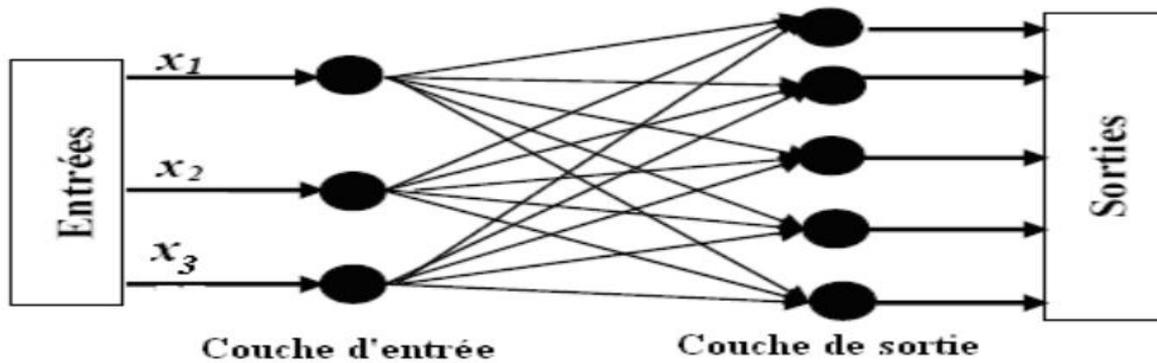


Figure II.4 Structure D'un Réseau de neurones monocouches

II.5.2 Réseaux de neurones multicouches

Un réseau multicouche est un concept fondamental en apprentissage profond. Il s'agit essentiellement d'une architecture composée de plusieurs couches interconnectées, disposées de gauche à droite, où les sorties d'une couche sont transmises en tant qu'entrées à la couche suivante. Cette structure hiérarchique permet de traiter et d'abstraire des informations de manière progressive.

Chaque couche d'un réseau multicouche est constituée de neurones interconnectés. Comme illustré dans la figure II.5, ces neurones sont organisés en couches superposées. Il est important de noter qu'il n'y a généralement pas de connexions directes entre les neurones d'une même couche. Au lieu de cela, les connexions sont établies uniquement avec les neurones des couches suivantes.

Cette organisation en couches permet au réseau multicouche d'apprendre des représentations complexes des données. Les premières couches, proches de l'entrée, captent des caractéristiques bas-niveau, tandis que les couches suivantes combinent ces caractéristiques pour former des représentations de plus en plus abstraites. Finalement, la dernière couche du réseau produit une sortie qui correspond à la prédiction ou à la tâche souhaitée.

En utilisant des algorithmes d'apprentissage appropriés, les poids des connexions entre les neurones sont ajustés afin que le réseau puisse apprendre à partir des exemples d'entraînement. Ce processus d'apprentissage itératif permet au réseau multicouche de s'adapter aux modèles sous-jacents des données et de généraliser pour effectuer des prédictions précises sur de nouvelles entrées. [20]

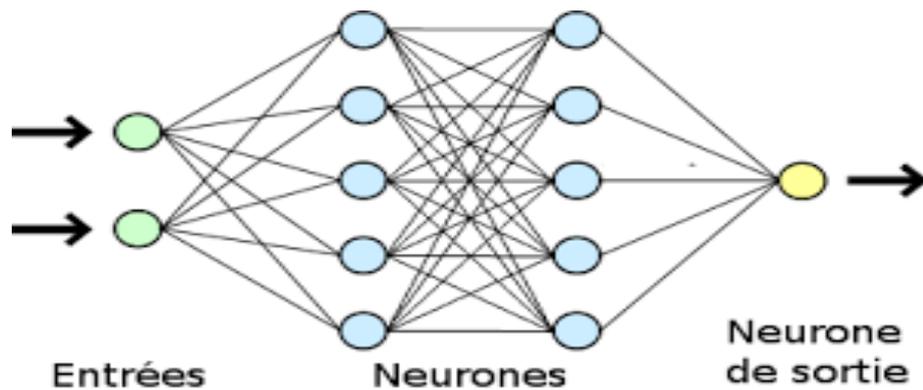


Figure II.5 Réseaux de neurones multicouches [22]

II.6 Connexions du réseau de neurones

La structure et les connexions d'un réseau neuronal déterminent la manière dont les neurones sont interconnectés et la direction du transfert d'informations. Il existe différents types de connexions, comme décrit dans le texte source.

Tout d'abord, nous avons les connexions directes, qui se produisent entre une couche d'indice inférieur et une couche d'indice supérieur dans le réseau. Cette configuration est illustrée dans la **figure II.6a**. Les sorties des neurones d'une couche sont transmises directement en tant qu'entrées aux neurones de la couche suivante. Cette disposition unidirectionnelle permet de transférer les informations de manière séquentielle et de traiter progressivement les caractéristiques des données.

Ensuite, nous avons les connexions récurrentes, représentées dans la **figure II.6b**. Ces connexions se produisent lorsque les sorties des neurones d'une couche sont réinjectées comme entrées à une couche d'indice inférieur. Contrairement aux connexions directes, les connexions récurrentes permettent un flux d'informations rétrograde dans le réseau. Cela permet au réseau de tenir compte des informations contextuelles et de prendre des décisions basées sur l'historique des données traitées.

Ces deux types de connexions, directes et récurrentes, ont leurs propres avantages et applications. Les connexions directes sont couramment utilisées dans les réseaux multicouches traditionnels, où les informations circulent de manière unidirectionnelle pour extraire des caractéristiques de plus en plus abstraites. Les connexions récurrentes, quant à elles, sont utilisées dans des architectures telles que les réseaux de neurones récurrents (RNN) qui sont efficaces pour traiter des séquences de données et capturer des dépendances temporelles.

Il est important de choisir judicieusement le type de connexions en fonction de la tâche à accomplir et des propriétés des données. Les réseaux neuronaux sont hautement flexibles et peuvent être adaptés en fonction des besoins spécifiques, en modifiant les connexions et l'architecture globale. Cette adaptabilité permet aux réseaux neuronaux de relever une grande variété de défis et d'accomplir des tâches complexes dans des domaines tels que la vision par ordinateur, le traitement du langage naturel et bien d'autres encore.

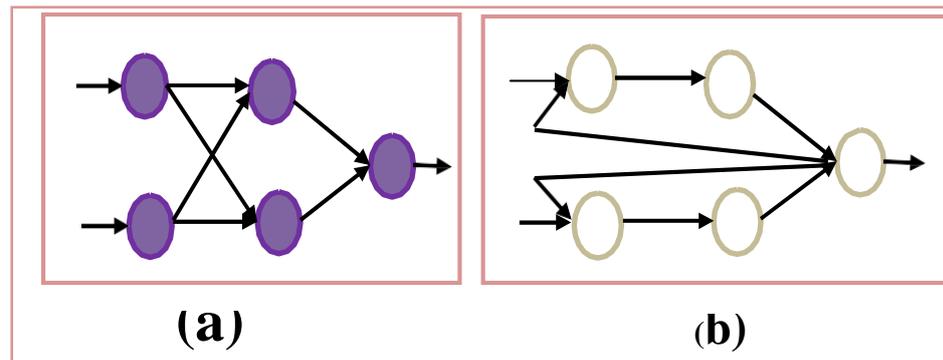


Figure II.6 Types de connexions.

Dans la conception d'un réseau neuronal, les connexions entre deux couches peuvent varier en termes de leur étendue. Selon le contexte et les besoins spécifiques du réseau, les connexions peuvent être partielles ou totales, ce qui est illustré dans les figures II.6 (a) et II.6 (b).

Tout d'abord, examinons les connexions partielles, comme représentées dans la figure II.7(a). Dans ce cas, seules certaines zones spécifiques de la couche précédente sont connectées à des neurones de la couche suivante. Ces connexions sélectives permettent de regrouper des régions spécifiques du réseau pour effectuer des fonctions spécialisées. Par exemple, dans le domaine de la vision par ordinateur, cela peut signifier que certains neurones d'une couche détectent des bords ou des textures, tandis que d'autres neurones se concentrent sur la détection d'objets ou de formes plus complexes. Cette approche de connexion partielle permet au réseau de traiter des caractéristiques spécifiques de manière plus efficace et de réduire la complexité globale du modèle.

D'un autre côté, les connexions totales, comme montré dans la figure II.7(b), signifient que tous les neurones de la couche précédente sont connectés à tous les neurones de la couche suivante. Dans ce type de configuration, les informations circulent librement et intégralement entre les couches, ce qui permet une communication complète et une combinaison globale des caractéristiques. Les connexions totales peuvent être utiles lorsque chaque neurone de la couche précédente contribue de manière significative à la fonction de la couche suivante. Cela se

produit souvent dans des tâches où une représentation globale des données est nécessaire, comme la classification d'images ou la traduction automatique.

Le choix entre les connexions partielles et totales dépend des exigences de la tâche et de la nature des données. Les connexions partielles permettent une spécialisation et une efficacité accrues, tandis que les connexions totales favorisent une intégration complète des informations. Les architectes de réseaux doivent prendre en compte ces facteurs lors de la conception d'un réseau neuronal afin d'optimiser ses performances pour la tâche donnée.

Il convient de souligner que les figures II.7(a) et II.7(b) mentionnées dans le texte source sont spécifiques au contexte où elles ont été présentées. Les références exactes et les détails spécifiques peuvent varier en fonction de la source à laquelle vous faites référence.

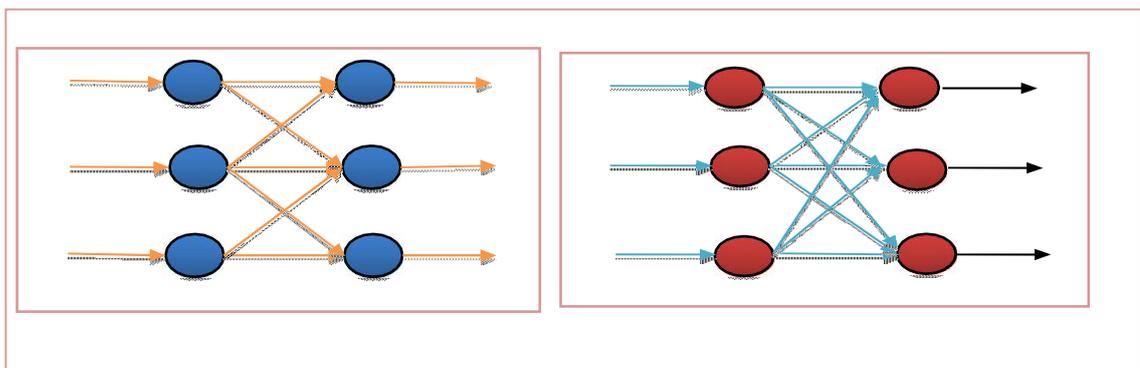


Figure II.5 Connexions entre deux couches, (a) Partielles, (b) Totales. [18]

II.7 Réseaux propagation vers l'avant "Feed-Forward"

Un réseau de neurones "Feed-forward" est un type de réseau non bouclé, unidirectionnel et statique, composé d'un ensemble de neurones interconnectés. Cette architecture utilise la technique d'apprentissage appelée rétropropagation du gradient (backpropagation) pour entraîner le réseau.

Le réseau de neurones Feed-forward est caractérisé par une architecture multicouche, où la couche d'entrée est connectée à une couche cachée, qui peut elle-même être connectée à une autre couche cachée ou directement reliée à la couche de sortie. Cela permet une transmission séquentielle des informations à travers les différentes couches du réseau.

En général, on trouve souvent une seule couche cachée dans ce type d'architecture, bien qu'il soit possible d'avoir plus de deux couches cachées. Mathématiquement, l'ajout de couches supplémentaires n'affecte pas fondamentalement le fonctionnement du réseau, mais cela peut permettre de capturer des représentations plus complexes des données.

L'apprentissage du réseau de neurones Feed-forward se fait en ajustant les poids des connexions à l'aide de la rétropropagation du gradient. Cette technique permet de calculer l'erreur entre la sortie prédite par le réseau et la sortie attendue, puis de propager cette erreur en sens inverse à travers le réseau pour mettre à jour les poids de manière à minimiser cette erreur.

Bien que le réseau Feed-forward soit une architecture couramment utilisée, il convient de noter qu'il existe d'autres types d'architectures de réseaux neuronaux, tels que les réseaux de neurones récurrents (RNN) qui permettent des connexions récurrentes pour le traitement des séquences, et les réseaux de neurones convolutifs (CNN) qui sont efficaces pour le traitement des données structurées telles que les images.

En résumé, les réseaux de neurones Feed-forward sont des architectures populaires dans le domaine de l'apprentissage profond, utilisant la rétropropagation du gradient pour l'apprentissage. Bien que généralement composés d'une seule couche cachée, ils peuvent être étendus à plusieurs couches pour capturer des représentations plus complexes des données. [18]

II.7.1 La Couche d'entrée

La couche d'entrée dans un réseau de neurones artificiels (RNA) joue un rôle fondamental en tant que porte d'entrée permettant au monde extérieur de présenter un modèle au RNA. Lorsque ce modèle est introduit à l'entrée du réseau, les couches de sortie se chargent de produire un autre modèle, résultant des transformations effectuées par le RNA.

La couche d'entrée doit être conçue de manière à représenter les conditions pour lesquelles le réseau est en cours d'entraînement. Chaque neurone de la couche d'entrée doit correspondre à une variable indépendante qui a une influence sur la sortie du réseau. Cela signifie que chaque neurone capture une caractéristique spécifique des données d'entrée et la présente au réseau pour qu'il puisse effectuer son traitement.

Chaque neurone de la couche d'entrée est connecté aux neurones de la couche suivante, généralement appelée couche cachée, par des poids qui seront ajustés pendant le processus d'apprentissage. Ces poids permettent de moduler l'influence de chaque neurone d'entrée sur les neurones de la couche cachée, ce qui permet au réseau d'apprendre les relations entre les variables d'entrée et la sortie souhaitée.[23]

II.7.2 Couche de sortie

La couche de sortie dans les réseaux de neurones artificiels est très importante dans la communication entre le modèle et l'environnement extérieur. Elle est responsable de fournir les

résultats finaux du réseau, et chaque résultat peut être attribué à des influences directes de la couche d'entrée. La configuration de la couche de sortie est étroitement liée à la fonction spécifique du réseau neuronal.[23]

II.7.3 Couches cachées

Les couches cachées dans un réseau de neurones sont des éléments fondamentaux de son architecture. Elles jouent un rôle essentiel dans le processus d'apprentissage et de représentation des informations. Situées entre la couche d'entrée et la couche de sortie, ces couches intermédiaires sont appelées "cachées" car elles ne sont pas directement accessibles depuis l'extérieur du réseau.

La principale fonction des couches cachées est de permettre au modèle d'effectuer des transformations non linéaires et d'apprendre des caractéristiques abstraites et complexes à partir des données d'entrée. Grâce à ces transformations successives, les couches cachées permettent au réseau de neurones de capturer des informations de plus en plus significatives et de les représenter de manière hiérarchique.[23]

II.7.4 Nombre de couches cachées

Les réseaux de neurones à deux couches cachées sont connus pour leur capacité à représenter des fonctions avec une forme arbitraire. En effet, ces réseaux peuvent modéliser des relations complexes entre les données d'entrée et les résultats souhaités. Cependant, il convient de noter qu'il n'y a pas d'utilité théorique à utiliser des réseaux avec plus de deux couches cachées.

En pratique, de nombreux problèmes peuvent être résolus avec succès en utilisant uniquement une couche cachée. Cette couche supplémentaire permet d'introduire une certaine flexibilité dans la représentation des données et d'apprendre des caractéristiques plus abstraites. Cela peut être particulièrement bénéfique dans des tâches telles que la classification d'images, la reconnaissance de la parole ou la traduction automatique.

Cependant, il est important de noter que l'ajout de couches cachées supplémentaires peut entraîner une complexité accrue du modèle et une augmentation du temps de calcul lors de l'entraînement du réseau. De plus, l'ajout de couches supplémentaires ne garantit pas toujours une amélioration significative des performances du réseau. Dans de nombreux cas, une seule couche cachée peut suffire à capturer les caractéristiques essentielles des données et à résoudre efficacement le problème donné.

Il est donc essentiel d'évaluer attentivement les besoins spécifiques du problème à résoudre avant de décider du nombre optimal de couches cachées à utiliser dans un réseau neuronal. Une approche pragmatique consiste à commencer par une seule couche cachée et à augmenter progressivement la complexité du modèle si nécessaire, en effectuant des expérimentations et des évaluations approfondies des performances du réseau. [23]

II.8 Nombre de neurones dans les couches cachées

Le choix du nombre de neurones dans la couche cachée est une étape cruciale lors de la conception de l'architecture d'un réseau neuronal. Bien que ces couches ne soient pas directement connectées à l'environnement extérieur, elles ont une influence considérable sur la sortie finale du réseau.

Utiliser un nombre trop faible de neurones dans la couche cachée peut entraîner un phénomène appelé "Underfitting", où le réseau n'est pas en mesure de détecter les signaux présents dans l'ensemble de données. En d'autres termes, le réseau ne parvient pas à capturer la complexité des relations entre les entrées et les sorties souhaitées.

D'un autre côté, utiliser un nombre excessif de neurones cachés peut conduire à un problème d'"Overfitting". Cela se produit lorsque la base de données d'entraînement n'est pas suffisamment représentative pour entraîner efficacement tous les neurones des couches cachées. Cela peut entraîner une augmentation du temps d'apprentissage et de traitement des données, et le réseau peut finir par ne plus être en mesure de généraliser correctement les données nouvelles.

Il est donc nécessaire de trouver un compromis. Voici quelques règles couramment utilisées pour guider le choix du nombre de neurones cachés :

Le nombre de neurones cachés doit se situer entre la taille de la couche d'entrée et la taille de la couche de sortie.

Le nombre de neurones cachés peut être établi à environ $2/3$ de la taille de la couche d'entrée, plus la taille de la couche de sortie.

Le nombre de neurones cachés doit être inférieur au double de la taille de la couche d'entrée.

Ces règles ne servent de points de départ pour choisir le nombre optimal de neurones dans la couche cachée, mais il existe également d'autres méthodes et approches pour affiner cette sélection. Certaines techniques utilisent des algorithmes d'optimisation ou des analyses plus avancées pour trouver la configuration optimale du réseau.

En ce qui concerne les fonctions d'activation, l'interface graphique de Matlab propose trois options :

Tansig : une fonction de transfert tangent sigmoïde hyperbolique, qui est non linéaire et varie entre -1 et 1.

Logsig : une fonction de transfert sigmoïde, qui est également non linéaire et varie entre 0 et 1.

Purelin : une fonction de transfert linéaire, où la sortie est identique à l'entrée.

Ces différentes fonctions d'activation permettent d'introduire de la non-linéarité dans le réseau et de modéliser des relations plus complexes entre les neurones.

En résumé, le choix du nombre de neurones dans la couche cachée est une étape cruciale dans la conception d'un réseau neuronal. Il faut trouver un équilibre entre la capacité du réseau à capturer la complexité des données et la nécessité de limiter la complexité excessive du modèle. Différentes règles et méthodes peuvent être utilisées pour guider ce choix, et les fonctions d'activation permettent d'introduire de la non-linéarité dans le réseau.

II.9 Propriétés des réseaux de neurones

L'une des propriétés les plus fondamentales des réseaux de neurones est leur capacité à apprendre à partir de leur environnement et à améliorer leurs performances grâce à un processus d'apprentissage.

L'objectif de l'apprentissage est d'améliorer les performances futures du réseau en se basant sur les connaissances acquises au fil des expériences passées. On distingue trois familles d'apprentissage en fonction de la nature des informations disponibles et des objectifs recherchés .

L'apprentissage supervisé, qui nécessite un ensemble de couples de données comprenant les entrées du réseau et les sorties désirées correspondantes. Ce type d'apprentissage permet d'ajuster les poids synaptiques en fonction des écarts entre les sorties réelles du réseau et les sorties désirées.

L'apprentissage semi-supervisé ou par renforcement, où seule une mesure d'erreur qualitative est disponible. Dans ce cas, l'apprentissage se base sur des feedbacks positifs ou négatifs qui guident les ajustements des poids synaptiques.

L'apprentissage non supervisé, qui se caractérise par l'absence de réponse désirée. Dans ce type d'apprentissage, le réseau doit découvrir des structures ou des régularités dans les données sans

disposer d'une supervision explicite. Une architecture appropriée, notamment le choix du nombre de neurones cachés, joue un rôle crucial dans ce type d'apprentissage.

Les réseaux multicouches sont connus pour leur capacité à approximer n'importe quelle fonction, ce qui constitue une autre propriété fondamentale de l'apprentissage. Cela signifie que, avec une architecture adéquate et un apprentissage approprié, ces réseaux peuvent représenter et généraliser des relations complexes entre les entrées et les sorties.

La capacité de généralisation est essentielle dans l'apprentissage des réseaux de neurones. Elle permet au réseau de faire des prédictions précises sur de nouvelles données qui n'ont pas été utilisées pendant la phase d'apprentissage. Une bonne généralisation est un indicateur de la capacité du réseau à s'adapter à des situations inconnues et à fournir des résultats cohérents et précis.

En résumé, les réseaux de neurones ont la capacité d'apprendre et d'améliorer leurs performances grâce à l'ajustement des poids synaptiques. Ils peuvent apprendre de manière supervisée, semi-supervisée ou non supervisée, en fonction des informations disponibles. Les réseaux multicouches sont capables d'approximer n'importe quelle fonction, tandis que la capacité de généralisation leur permet de faire des prédictions précises sur de nouvelles données. [21]

II.9.1 Apprentissage simple du perceptron (méthode du gradient et algorithme de Widrow-Hoff)

Il existe deux principaux algorithmes utilisés pour entraîner un réseau de neurones monocouche afin de favoriser son apprentissage. Le premier est appelé "descente de gradient", une méthode simple mais efficace. L'autre algorithme, connu sous le nom d'"algorithme de Widrow-Hoff" en l'honneur des deux scientifiques qui l'ont développé, est généralement considéré comme encore plus performant.

Ces deux approches consistent à évaluer la différence entre les résultats attendus pour chaque exemple et les résultats obtenus, puis à réduire cette erreur sur l'ensemble des exemples. Cependant, il existe bien sûr des différences subtiles entre ces deux méthodes.

II.9.2 Apprentissage du perceptron multicouche

Tout comme le perceptron monocouche, le perceptron multicouche est également capable d'apprentissage. En effet, il existe un algorithme spécifique qui permet d'ajuster les poids en

fonction d'un ensemble d'exemples donnés. Cet algorithme est connu sous le nom d'algorithme de rétropropagation du gradient. [24]

II.10 Algorithme d'apprentissage

Le processus de détermination de l'architecture d'un réseau neuronal artificiel (RNA) pour un problème donné consiste à prendre des décisions éclairées concernant la taille du réseau, le nombre de couches et de neurones, la répartition des données et les fonctions de transfert. Ces choix dépendent de l'utilisateur et il n'existe pas encore suffisamment de données dans la littérature pour déterminer de manière précise les paramètres à adopter pour résoudre un problème spécifique.

Les différentes techniques présentées par divers auteurs visent à résoudre des cas particuliers. Le choix d'utiliser un perceptron multicouche (PMC) et l'algorithme de rétropropagation est principalement dû à leur popularité dans la gestion des relations non linéaires entre les variables.

L'algorithme d'apprentissage de rétropropagation se déroule en deux étapes principales. Tout d'abord, les données d'entrée sont propagées vers l'avant à travers le réseau jusqu'à ce qu'une sortie calculée soit obtenue. Ensuite, la sortie calculée est comparée à la sortie réelle connue.

Les poids sont alors ajustés de manière à minimiser l'erreur entre la sortie calculée et la sortie réelle lors de la prochaine itération. Cette modification des poids est effectuée en prenant en compte la présence de couches cachées et en rétro-propageant l'erreur vers l'arrière jusqu'à la couche d'entrée, tout en ajustant les pondérations.

Ce processus est répété sur tous les exemples jusqu'à ce qu'une erreur de sortie considérée comme négligeable soit atteinte. [18]

II.11 Avantages et inconvénients des réseaux de neurones artificiels :

II.11.1 Avantage des réseaux de neurones artificiels :

Capacité d'apprentissage automatique : Grâce à des méthodes spécifiques d'apprentissage automatique, ces réseaux sont capables d'apprendre et de s'adapter aux données fournies. Leur puissance réside dans leur aptitude à identifier des motifs complexes présents dans les données et à réaliser des tâches de classification ou de prédiction.

Performances élevées : Leur utilisation a démontré des résultats remarquables et supérieurs à ceux des méthodes traditionnelles dans diverses applications.

Adaptabilité : Ces systèmes sont conçus pour s'adapter à différents types de données et pour résoudre une variété de problèmes, ce qui en fait des outils polyvalents dans de nombreux domaines

Capacité à extraire des caractéristiques : Les réseaux de neurones peuvent apprendre à extraire automatiquement des caractéristiques pertinentes à partir des données brutes, ce qui peut être bénéfique lorsque les caractéristiques manuelles sont difficiles à définir ou à mesurer.

II.11.2 Inconvénients des réseaux de neurones artificiels :

Bien que les réseaux de neurones artificiels présentent de nombreux avantages, ils sont également confrontés à certains inconvénients à prendre en compte

Besoin de grandes quantités de données : Les réseaux de neurones profonds sont particulièrement sensibles à la quantité de données disponibles lors de leur phase d'entraînement. Ils ont besoin d'un nombre significatif d'exemples d'entraînement pour généraliser efficacement et produire des résultats fiables. Si les données sont rares ou difficiles à obtenir, cela peut limiter les performances du réseau de neurones.

Temps et ressources de calcul : L'entraînement d'un réseau de neurones peut nécessiter des ressources de calcul importantes, notamment des unités de traitement graphique (GPU) et des clusters de calcul haute performance. Cela peut rendre les réseaux de neurones coûteux en termes de temps et d'infrastructure.

Complexité et interprétabilité : Les réseaux de neurones profonds peuvent être très complexes, avec des milliers, voire des millions de paramètres. Comprendre comment ces réseaux prennent des décisions peut être difficile, ce qui limite leur interprétabilité.

Sensibilité aux données d'entraînement : est l'un des aspects à prendre en compte lors de l'utilisation des réseaux de neurones artificiels. Les performances de ces réseaux peuvent être fortement influencées par la qualité et la représentativité des données utilisées pour l'entraînement.

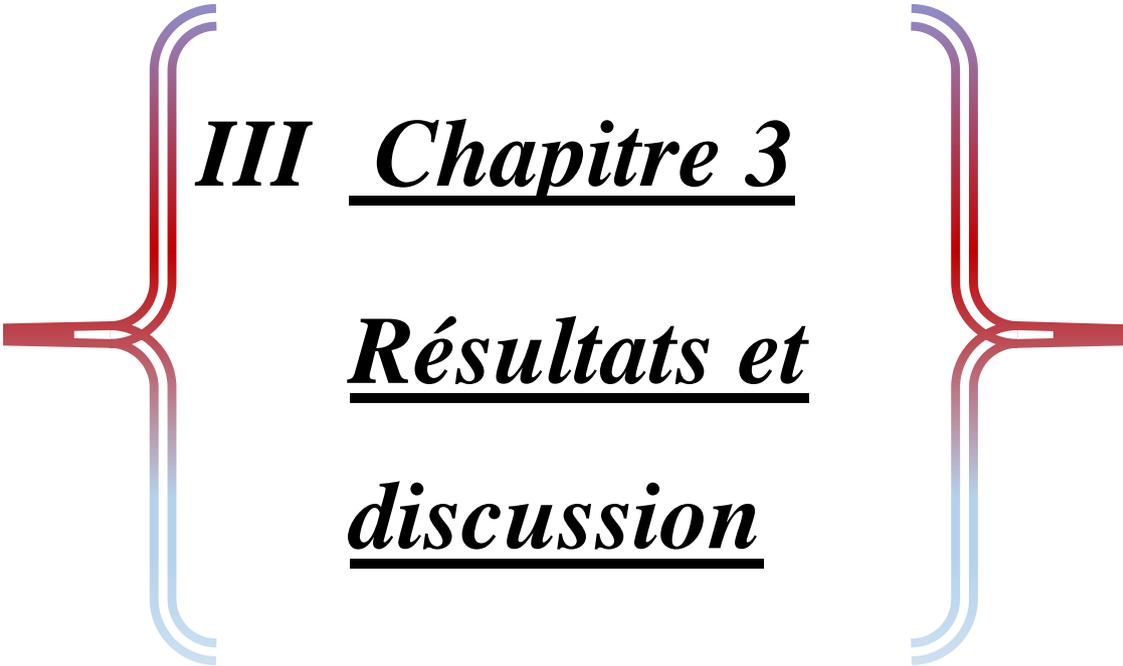
Si les données d'entraînement sont biaisées, c'est-à-dire qu'elles ne représentent pas fidèlement la diversité des situations réelles, cela peut conduire à des résultats incohérents ou biaisés. Par exemple, si un réseau de neurones est entraîné sur des données provenant d'une source spécifique ou d'un groupe restreint de personnes, il peut avoir du mal à généraliser et à fournir des prédictions précises pour des cas différents.

II.12 Conclusion

Les réseaux de neurones artificiels constituent une avancée majeure dans le domaine de l'intelligence artificielle. Inspirés de la fonction des réseaux de neurones biologiques, ils visent à résoudre des problèmes complexes en imitant le processus d'apprentissage du cerveau humain.

Les réseaux de neurones artificiels ont démontré leur capacité à traiter de grandes quantités de données, à reconnaître des modèles et des relations complexes et à prendre des décisions intelligentes. Grâce à leur architecture en couches et à leur capacité à ajuster les poids de connexion en fonction des données d'entrée, ils peuvent effectuer des tâches telles que la classification, la reconnaissance d'images, la traduction automatique, la prédiction.

Une caractéristique clé des réseaux de neurones est leur capacité à apprendre des exemples fournis pendant la phase de formation. En utilisant des techniques d'optimisation telles que la rétropropagation de gradient, un réseau de neurones peut ajuster ses paramètres internes pour minimiser l'erreur entre les prédictions et les étiquettes de sortie attendues.



III ***Chapitre 3***

Résultats et

discussion

III.1. Introduction :

Dans ce chapitre nous présentons les résultats de la modélisation de nombre de Nusselt par les réseaux de neurone artificiel. Ce travail est basé sur des données expérimentales d'après l'appareil TD1005. Nous allons décrire la base de données élaborée dans le cadre de ce travail, l'algorithme utilisé pour l'élaboration des programmes de calcul MATLAB. Nous présentons ensuite les résultats de calcul et leur interprétation.

Bien que les réseaux de neurones, souvent considérés comme des boîtes noires, représentent des relations empiriques entre des ensembles d'entrées et de sorties. Leur efficacité dépend du choix stratégique des variables d'entrée et de sortie. Bien que ces réseaux capturent des schémas complexes, le caractère déterministe des modèles classiques peut être approché en sélectionnant soigneusement ces variables. Ainsi, l'équilibre entre la flexibilité inhérente aux boîtes noires et la nécessité de prévisibilité guide le réseau vers des résultats plus déterministes, illustrant la symbiose complexe entre empirisme et détermination.

III.2. Description de l'appareil :

Un appareil expérimental pour examiner la convection libre et forcée d'une plaque plate, d'une plaque avec des ailettes et d'une plaque avec des tiges.

L'équipement de montage sur paillasse comprend un conduit vertical qui contient la surface de transfert de chaleur choisie et tous les instruments nécessaires.

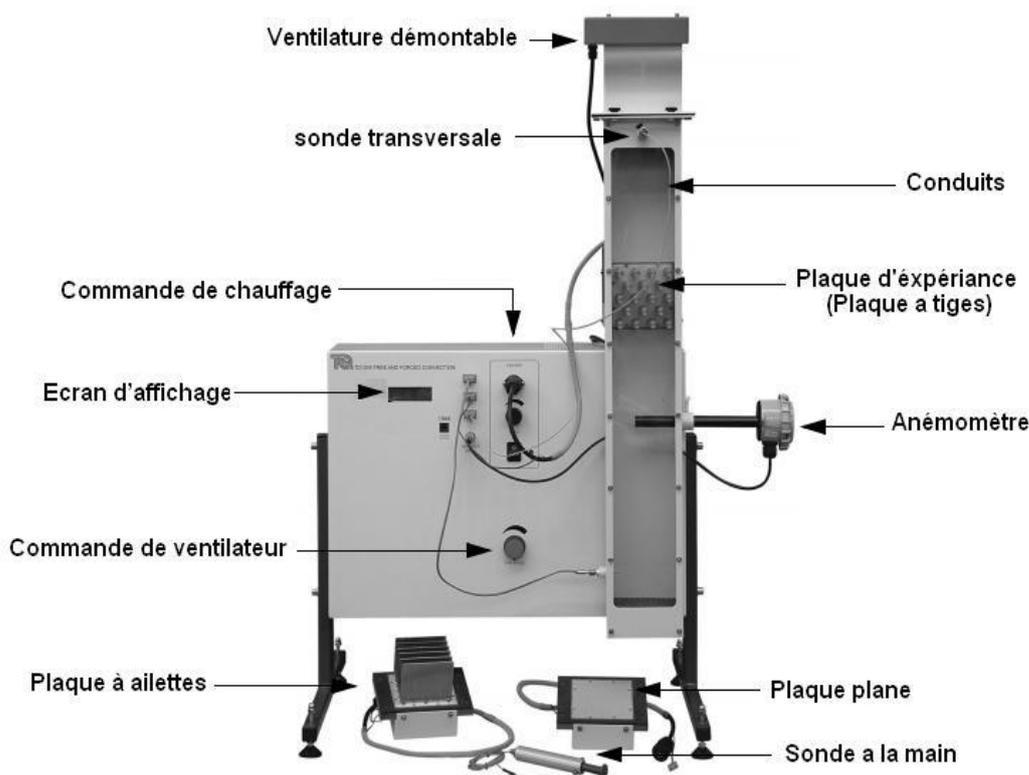


Figure III.1 appareil TD1005

- ❖ Pour les essais de convection libre, l'air chauffé monte de la surface et remonte le conduit. Pour les tests de convection forcée, un ventilateur à vitesse variable aspire l'air à travers le conduit et sur la surface. Les thermocouples mesurent la température de l'air en amont et en aval de la surface et la température à la surface de transfert de chaleur. La sonde en aval se déplace dans un mécanisme transversal pour mesurer la répartition de la température dans le conduit, permettant le calcul de la température de sortie globale. Une sonde supplémentaire permet aux étudiants de mesurer la répartition de la température le long des surfaces étendues des surfaces de transfert de l'élément chauffant à goupilles et à ailettes. Un anémomètre sensible mesure la vitesse de l'air.
- ❖ Deux commandes permettent aux étudiants de régler différentes vitesses d'air et puissances de chauffage pour une gamme complète de tests.
- ❖ Un affichage numérique indique la puissance du réchauffeur, la vitesse de l'air et les températures mesurées par les thermocouples.
- ❖ Vous pouvez faire des tests avec ou sans ordinateur connecté. Cependant, pour des tests plus rapides avec un enregistrement plus facile des résultats, Equipment peut fournir le système d'acquisition de données polyvalent (VDAS®) en option. Cela donne une capture, une surveillance et un affichage précis des données en temps réel, un calcul et une représentation graphique de toutes les lectures importantes sur un ordinateur.



Figure III.2 *Un système d'acquisition de données polyvalent (VDAS)*

III.3. Procédure de Montage et Démontage de la Plaque de Transfert Thermique :

1. Débrancher l'alimentation électrique, et vérifier que la commande de chauffage est au minimum.
2. Insérer soigneusement la plaque de transfert thermique dans le trou carré sur le conduit et fixer avec les quatre écrous.
3. Relier les câbles de chauffage et de thermocouple de la plaque de transfert thermique à la prise sur le panneau de commande.
4. Inverser les étapes précédentes pour le démontage de la plaque.

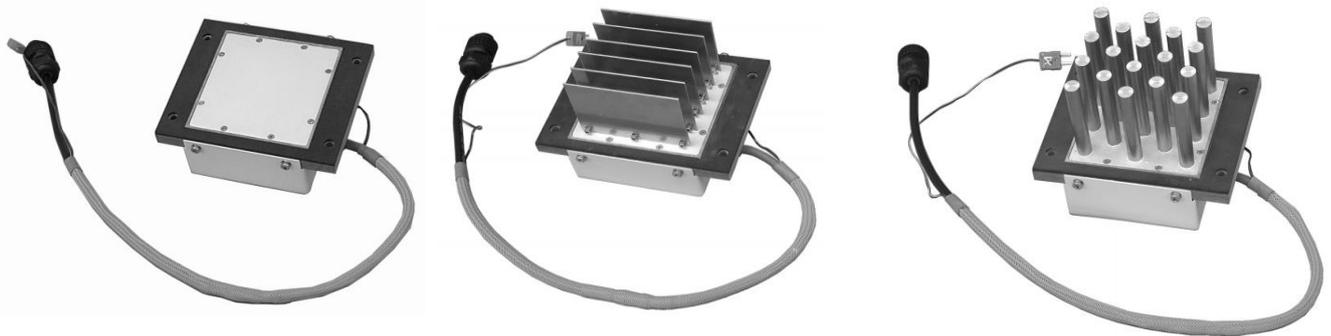


Figure III.3 Plaque de Transfert Thermique

III.4. Collection de la base de données

1. Placer le ventilateur sur le conduit.
2. Place la plaque de transfert thermique.
3. Créer un tableau de calcul ou utiliser Système d'Acquisition de Données VDAS.
4. Fixer la vitesse du ventilateur à 0.5 m. s^{-1} .
5. Fixer la puissance à (de 5 à 50 Watts).
6. Attendre la stabilisation de la température.
7. Enregistrer la température de surface(T_2) et la température d'entrée(T_1) et température de sortie(T_3).
8. Ont Répété l'expérience pour les valeurs de vitesse d'air suivantes ($0.5 ; 1 ; 1.5 ; 2 ; 2.5$ et 3 m. s^{-1}).

9. Calcule la valeur de température moyen par la relation $T_m = \frac{T_3 - T_1}{\ln \frac{T_2 - T_1}{T_2 - T_3}}$ (III.1)

10. Après on a calculé la valeur du coefficient de transfert de chaleur h par la relation :

$$h = \frac{\phi}{S \cdot Tm} \quad (III.2)$$

Avec $s = 0.092 \text{ m}^2$

11. Enfin on a calculé la valeur de nombre de Nusselt par la relation :

$$Nu = \frac{h \cdot D}{\lambda} \quad (III.3)$$

Avec : $D = 0.012 \text{ m}$

12. On déduire ce tableau :

Tableau III.1 Partie de 12 Points de la base des données utilisé de ce travail

p	v	t1	t2	t3	Tm	h	Nu
5	0,5	22,3	30,8	23,9	7,6722	7,0837	3,294744
5	1	22,1	28	22,8	5,5426	9,8054	4,560651
5	1,5	22	26,8	22,4	4,5971	11,8222	5,498698
5	2	22,1	26,2	22,2	3,9992	13,5898	6,320837
5	2,5	22,1	25,7	22,2	3,5498	15,3103	7,12107
5	3	22,1	25,5	22,3	3,299	16,4741	7,662372
70	0,5	20,1	92,8	30,5	67,3663	11,2945	5,315059
70	1	20,1	83,9	26,7	60,44	12,5889	5,924188
70	1,5	20,1	78,2	24,4	55,9224	13,6058	6,402729
70	2	19,8	72,1	22,8	50,7852	14,9821	7,0504
70	2,5	19,8	67,5	21,9	46,6421	16,3129	7,676659
70	3	20,2	64,3	21,7	43,3457	17,5535	8,260471

III.5. Utilisation de Matlab Neural Networks :

- ❖ Matlab Neural Network Toolbox fournit des outils pour concevoir, implémenter, visualiser et simuler des réseaux de neurones. Il prend en charge les réseaux feed-forward, les réseaux de base radiaux, les réseaux dynamiques, les cartes auto-organisatrices et d'autres paradigmes de réseau éprouvés.

III.6. Méthodologie de travail :

❖ On a schématisé comme celui :

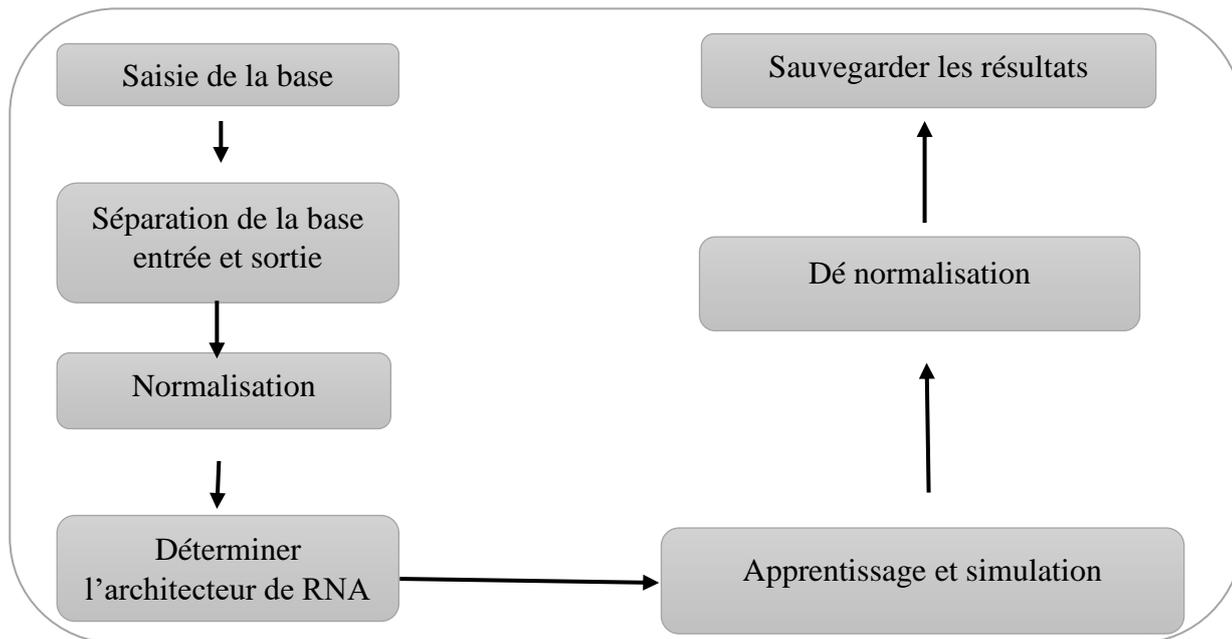


Figure III.4 Méthodologies de travail - réseau de neurone

III.7. Architecteur du réseau de neurone utilisé :

La structure de base retenue est un perceptron multicouche à trois couches : une couche d'entrée, une couche cachée, une couche de sortie

III.7.1. Couche d'entrées

Le nombre de neurones dans cette couche est un reflet direct du contenu de la matrice, et cette relation dynamique témoigne de la capacité du réseau neuronal à s'ajuster intelligemment en fonction de la nature changeante des données qu'il traite. (La table d'apprentissage)

III.7.2. Couche caché

Le nombre de neurone de cette couche est choisie après plusieurs essais le meilleur nombre étant celui qui donne les meilleurs résultats.

III.7.3. Couche sortie

Un résultat pour chaque colonne de la matrice.

III.7.4. Fonction d'activation

On a choisi la fonction tansig pour couche caché et purelin pour couche sortie

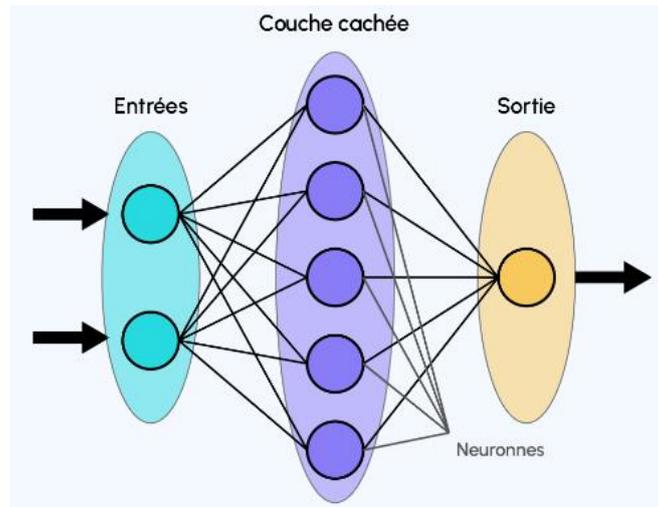


Figure III.5 Modèle d'un Structure de RN

III.8. Préparation et partage la base des données :

Afin de développer une application à base de réseau de neurone, il est nécessaire de disposer de trois bases de données : une base pour effectuer l'apprentissage et une base pour le test et l'autre de validation.

Apprentissage

Celui-ci va absorber la grande quantité de données. En effet, c'est sur cet ensemble que le réseau va itérer pour adapter les paramètres des réseaux (poids et biais) et les ajuster au mieux.

Validation

Cette phase est appelée à la fin de chaque itération d'entraînement pour une seule fois, elle est composée de 10% à 20% des données, afin de nous permettre d'équilibrer le modèle. c.-à-d. affiner les paramètres du modèle, lors de la phase d'ajustement de modèle sur l'ensemble de données d'entraînement.

Test

Ce dernier est composé de 10% à 20% des données, (dans il a un rôle qui est différent des autres phases, puisqu'il ne servira pas à ajuster les données, En effet, il va avoir pour rôle d'évaluer le réseau sous sa forme finale, et de voir comment il arrive à prédire [29].

III.9. Résultats expérimentale et discussion :

III.9.1. Choix du meilleur modèle

Le choix du meilleur modèle est basé sur deux critères : L'erreur (MAARD) et le coefficient de corrélation R. Ce choix s'effectue selon la règle test at erreur tel que MAARD plus proche de 0 et R tant vers 1.

L'erreur moyen absolu :

$$MSE = \frac{1}{N} \sum_{i=1}^N (Nu_{exp} - Nu_{cal})^2 \quad (III.4)$$

Le coefficient de corrélation R :

$$R = \frac{\sum_{k=1}^N (Nu_{exp} - \overline{Nu}_{exp})(Nu_{cal} - \overline{Nu}_{cal})}{\sqrt{\sum_{k=1}^N (Nu_{exp} - \overline{Nu}_{exp})^2 \sum_{k=1}^N (Nu_{cal} - \overline{Nu}_{cal})^2}} \quad (III.5)$$

Coefficient de Le corrélation R2 :

$$R^2 = 1 - \frac{\sum_{i=1}^N (Nu_{cal} - Nu_{exp})^2}{\sum_{i=1}^N (Nu_{exp} - \overline{Nu}_{exp})^2} \quad (III.6)$$

L'erreur absolue moyenne relative :

$$MAARD = \frac{1}{n} \sum_{i=1}^n \left(\frac{|Nu_{exp} - Nu_{cal}|}{|Nu_{exp}|} \right) 100 \quad (III.7)$$

Tableau III.2 les résultats d'optimisation des architectures des RNA

Division	Itération	RN optimal	Erreur	R	Fonction de transfert CC	Fonction de transfert CS
60 :20:20	50	2-5-1	App=0.61391 Test=0.65498 Val=0.69336 All=0.61348	0.99993 0.99996 0.99995 0.99993	Tansig	Purelin
	100	2-7-1	App=0.13210 Test=0.28855 Val=0.32723 All=0.23047	1.00000 0.99994 0.99994 0.99997	Logsig	Purelin
	150	2-10-1	App=0.41494 Test=0.39693 Val=0.45420 All=0.43681	0.99997 0.99997 0.99996 0.99996	Tansig	Purelin
	200	2-12-1	App=0.18765 Test=0.71141 Val=0.50225 All=0.66521	1.00000 0.99963 0.99977 0.99987	Logsig	Purelin
	300	2-15-1	App=0.11977 Test=0.51347 Val=0.67920 All=0.39253	1.00000 0.99985 0.99965 0.99988	Tansig	Purelin
	350	2-20-1	App=0.00141 Test=1.69999 Val=1.10648 All=1.11209	1.00000 0.99893 0.99980 0.99971	Logsig	Purelin
	400	2-22-1	App=0.87426 Test=1.50871 Val=1.20630 All=1.59974	0.99996 0.99911 0.99945 0.99945	Tansig	Purelin
	500	2-25-1	App=0.00966 Test=2.26182 Val=1.04024 All=0.98533	1.00000 0.99938 0.99971 0.99982	Logsig	Purelin
70 :15:15	50	2-5-1	App=0.54569 Test=0.40326 Val=0.42884 All=0.51602	0.99995 0.99995 0.99996 0.99995	Tansig	Purelin
	100	2-8-1	App=0.27467 Test=0.62190 Val=0.42545 All=0.47619	0.99999 0.99986 0.99989 0.99996	Logsig	Purelin
	200	2-10-1	App=0.50660 Test=0.37645	0.99995 0.99996	Tansig	Purelin

			Val=0.31660 All=0.47284	0.99998 0.99996		
	250	2-12-1	App=0.29104 Test=0.39256 Val=0.65590 All= 0.61782	0.99999 0.99989 0.99968 0.99991	Logsig	Purelin
	300	2-15-1	App=0.19190 Test=0.56275 Val=0.53425 All= 0.36337	1.00000 0.99981 0.99985 0.99995	Tansig	Purelin
	350	2-20-1	App=0.24259 Test=0.59766 Val=0.58875 All=0.60847	0.99998 0.99982 0.99990 0.99993	Logsig	Purelin
	400	2-22-1	App=0.04521 Test=1.27522 Val=0.66545 All=0.90379	1.00000 0.99835 0.99948 0.99963	Tansig	Purelin
	500	2-25-1	App=0.18706 Test=0.93236 Val=0.37180 All=0.54172	1.00000 0.99951 0.99997 0.99991	Logsig	
80 :10:10	50	2-5-1	App=0.62734 Test=0.68767 Val=0.58902 All = 0.60732	0.99994 0.99994 0.99996 0.99994	Tansig	Purelin
	100	2-8-1	App=0.28087 Test=0.30695 Val=0.29343 All = 0.31699	0.99999 0.99995 0.99993 0.99997	Logsig	purelin
	200	2-7-1	App=0.13083 Test=0.30554 Val=0.32432 All= 0.18907	1.00000 0.99992 0.99994 0.99998	Tansig	Purelin
	200	2-12-1	App=0.61595 Test=0.47245 Val=0.72805 All=0.67450	0.99997 0.99994 0.99990 0.99995	Logsig	Purelin
	250	2-15-1	App=0.17953 Test=0.57849 Val=0.69134 All=0.41261	1.00000 0.99997 0.99998 0.99999	Tansig	Purelin
	300	2-20-1	App=0.06461 Test=0.79272 Val=0.61069 All=0.45344	1.00000 0.99990 0.99990 0.99997	Logsig	Purelin
	400	2-22-1	App=1.93267 Test=1.85734 Val=0.72298 All=2.03564	0.99979 0.99983 0.99996 0.99978	Tansig	Purelin

	500	2-25-1	App=0.84240 Test=0.93669 Val=0.64522 All= 0.74222	0.99998 0.99982 0.99996 0.99995	Logsig	Purelin
--	-----	--------	--	--	--------	---------

D’après le tableau 2 la meilleure architecture du RNA est de 2- [7] -1 pour la division 80%, 10%, 10%.

Les modèles neuronaux conçues et optimisés possèdent des valeurs de MAARD relativement acceptables pour le paramètre de nombre de Nusselt, pour les trois sous-ensembles (apprentissage, test et validation). Les valeurs des coefficients de corrélation R des modèles neuronaux conçues et optimisés sont proches de l’unité montrant ainsi la grande performance de la méthodologie neuronale développée dans cette étude.

Tableau III.3 Architecture du meilleur modèle obtenu.

Couches	Nombre de neurones	Fonctions d’activation	Valeurs de R et MAARD	
			R^{APP}	1.00000
Couche d’entrée	2	(Aucun)	R^{test}	0.99992
Couche cachée	7	Tansig	R^{val}	0.99994
			R^{ALL}	0.99998
Couche de sortie	1	purelin	$MAARD^{APP}$	0.13083
			$MAARD^{TEST}$	0.30554
Algorithme d’App		Trainlm	$MAARD^{VAL}$	0.32432
Fonction d’erreur		MSE	$MAARD^{ALL}$	0.18907

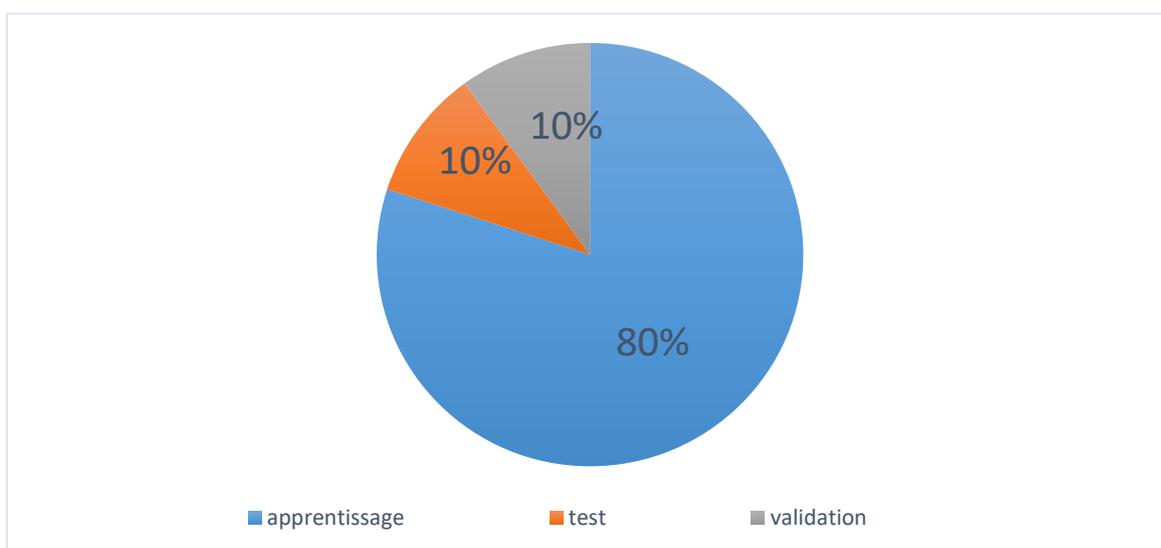


Figure III.6 Représentation graphique de la meilleure division de la base de données

III.10. Estimation de la performance du meilleur modèle neuronale :

III.10.1. Comparaison graphique entre les valeurs

La comparaison entre les valeurs de Nombre de Nusselt (NU)expérimentales et celle calculées par le meilleur modèle neuronal obtenu est illustrées sur (le tableau 5).

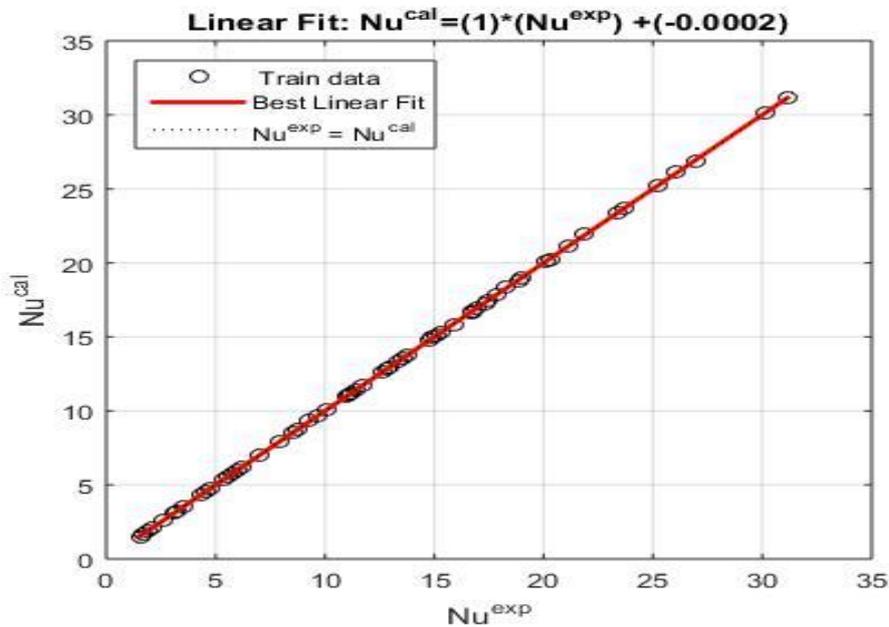


Figure III.7 Régression linéaire entre le nombre de Nusselt calculée par le RNA et celle de l'expérimentale pour la phase d'apprentissage

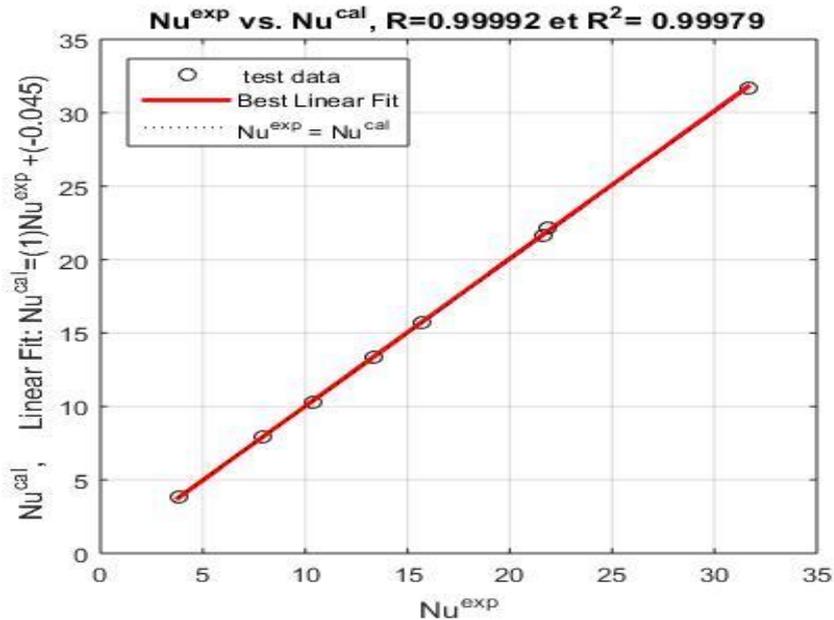


Figure III.8 Régression linéaire entre le nombre de Nusselt calculée par le RNA et celle de l'expérimentale pour la phase de test

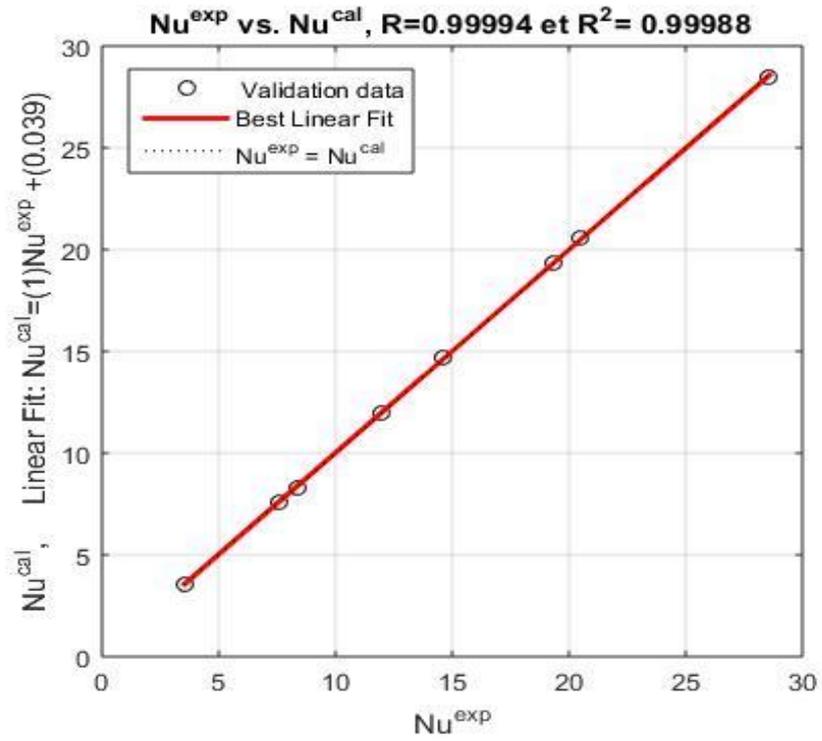


Figure III.9 Régression linéaire entre le nombre de Nusselt calculée par le RNA et celle de l'expérimentale pour la phase de validation

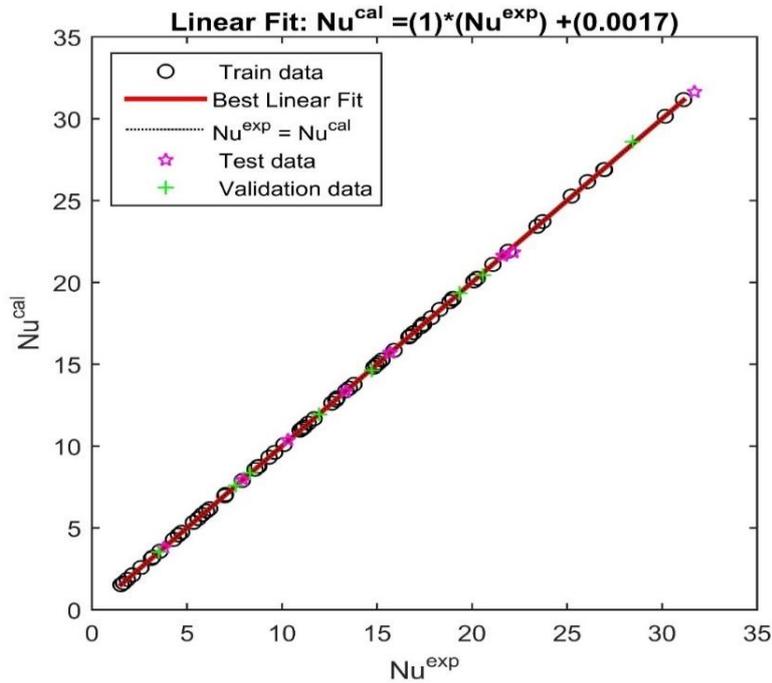


Figure III.10 Régression linéaire entre le nombre de Nusselt calculée par le RNA et celle de l'expérimentale pour tous les phase

Les figures III.7-8-9 illustre la régression linéaire entre le nombre de Nusselt calculé par le réseau de neurones et le nombre de Nusselt expérimental. Cette représentation graphique permet de visualiser la corrélation entre ces deux variables. Sur l'axe horizontal, nous avons les valeurs du nombre de Nusselt expérimental, tandis que sur l'axe vertical, nous trouvons les valeurs correspondantes du nombre de Nusselt calculé par le réseau de neurones. Cette analyse met en évidence la capacité du réseau à estimer de manière précise le nombre de Nusselt à partir des données expérimentales fournies. La linéarité observée dans les figures indique que le réseau de neurones parvient à capturer les tendances et les relations entre les variables, fournissant ainsi des résultats cohérents et fiables.

III.11. Analyse de performance

Pour analyser plus précisément et avec avantages les performances, l'écart relatif moyen (MSE) est calculé pour Nombre de Nusselt (Nu). Les résultats de calcul sont indiqués par le tableau (III-7) et la Figure (22) Résultats de calcul

Tableau III.4 autre erreur pour le nombre de Nusselt

Nombre de Nusselt	R²	RMSE
Apprentissage	1.00000	0.0233
Teste	0.9998	0.1227
Validation	0.9999	0.0828
ALL	0.9999	0.0616

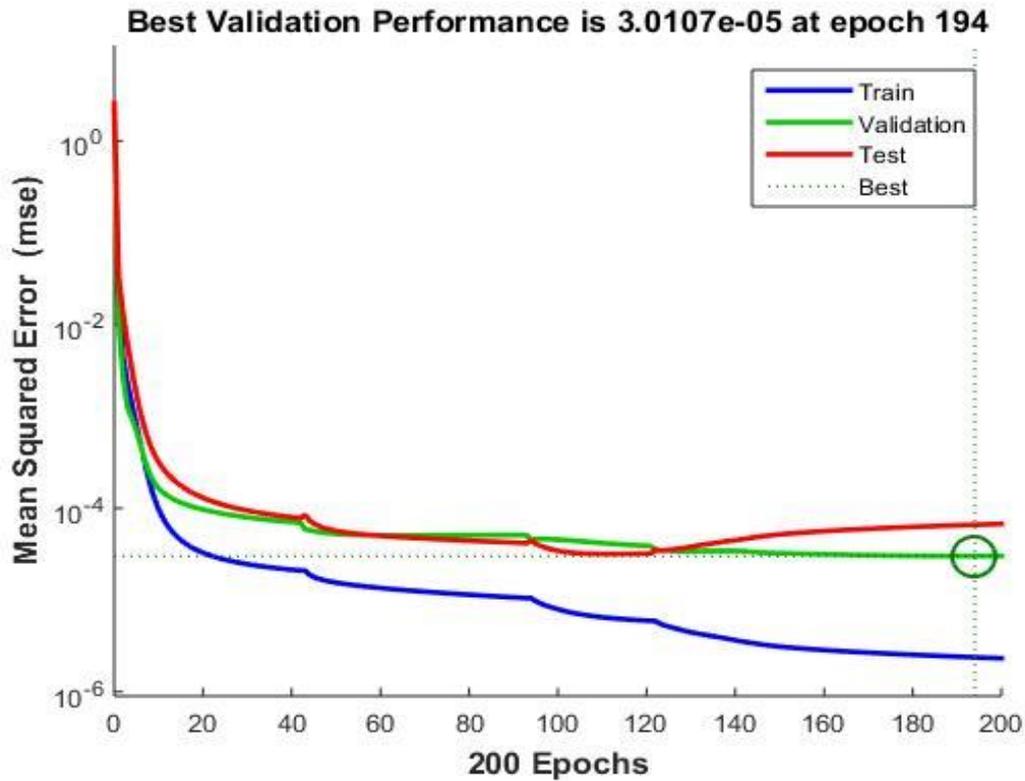


Figure III.11 L'erreur moyen absolu pour le nombre de Nusselt

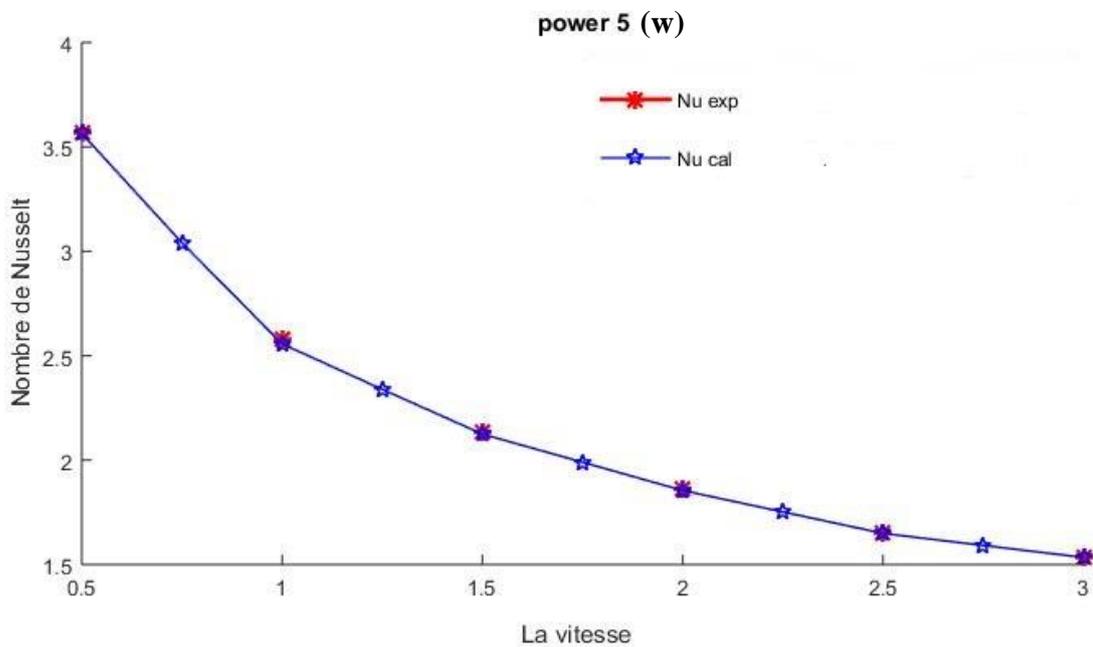


Figure III.12 représentations les valeurs de nombre de Nusselt expérimentale et celle calculé par le RNA en fonction de la vitesse (POWER 5W)

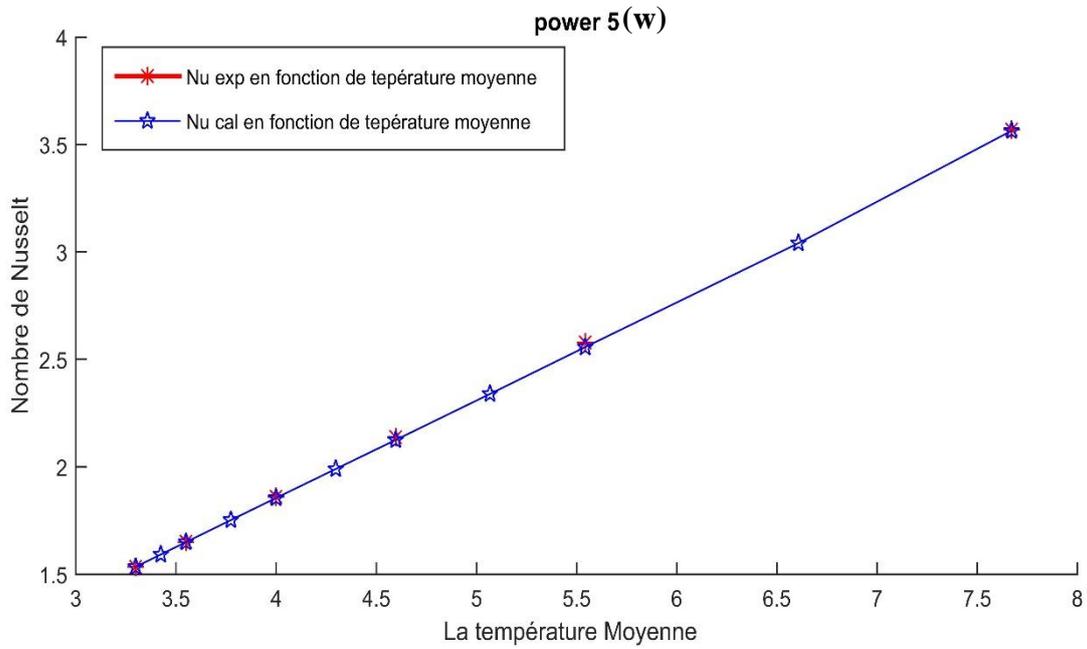


Figure III.13 représentations les valeurs de nombre de Nusselt expérimentale et celle calcule par le RNA en fonction de température moyen (POWER 5W)

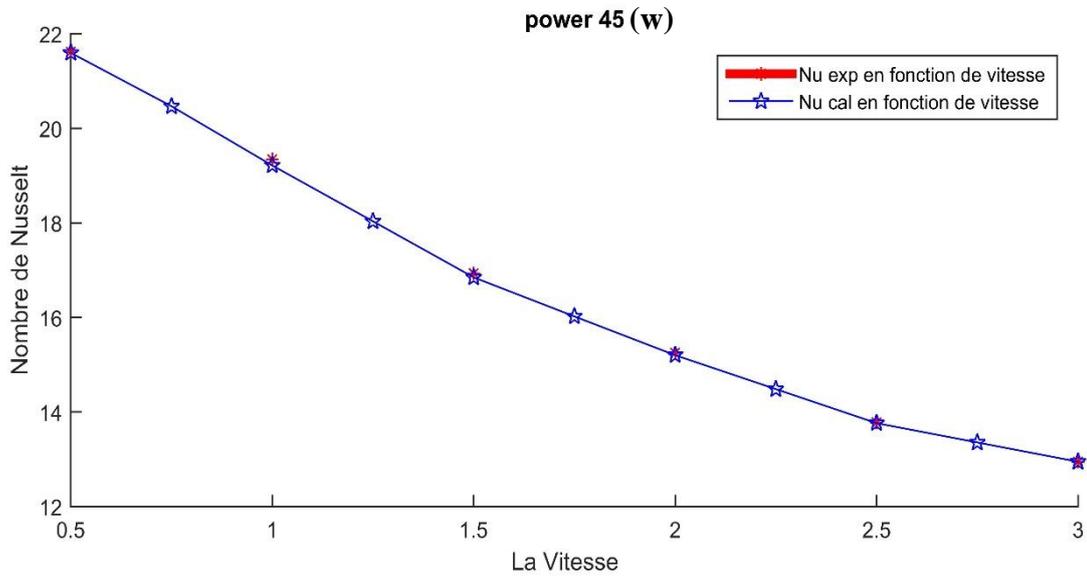


Figure III.14 représentations les valeurs de nombre de Nusselt expérimentale et celle calcule par le RNA en fonction de la vitesse (POWER 45W)

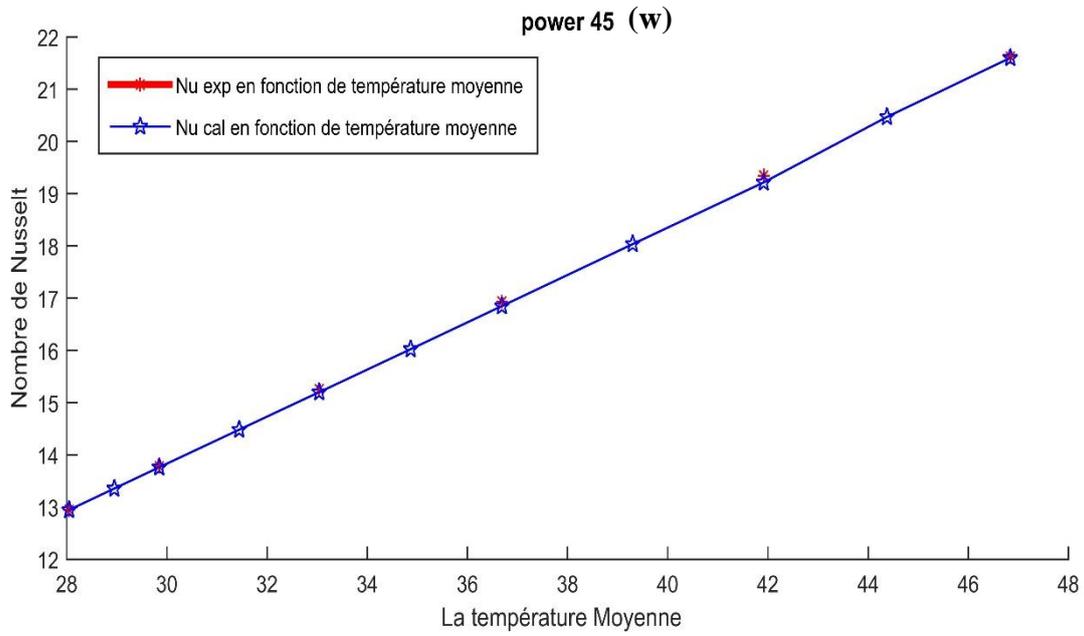


Figure III.15 représentations les valeurs de nombre de Nusselt expérimentale et celle calculé par le RNA en fonction de température moyen (POWER 45W)

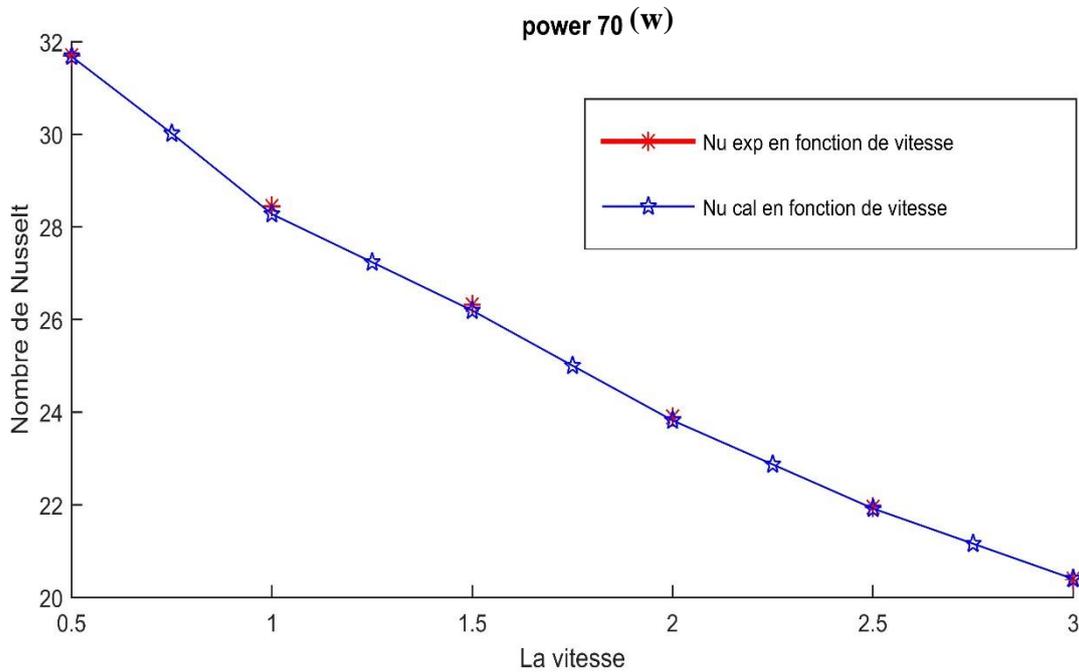


Figure III.16 représentations les valeurs de nombre de Nusselt expérimentale et celle calculé par le RNA en fonction de vitesse (POWER 70W)

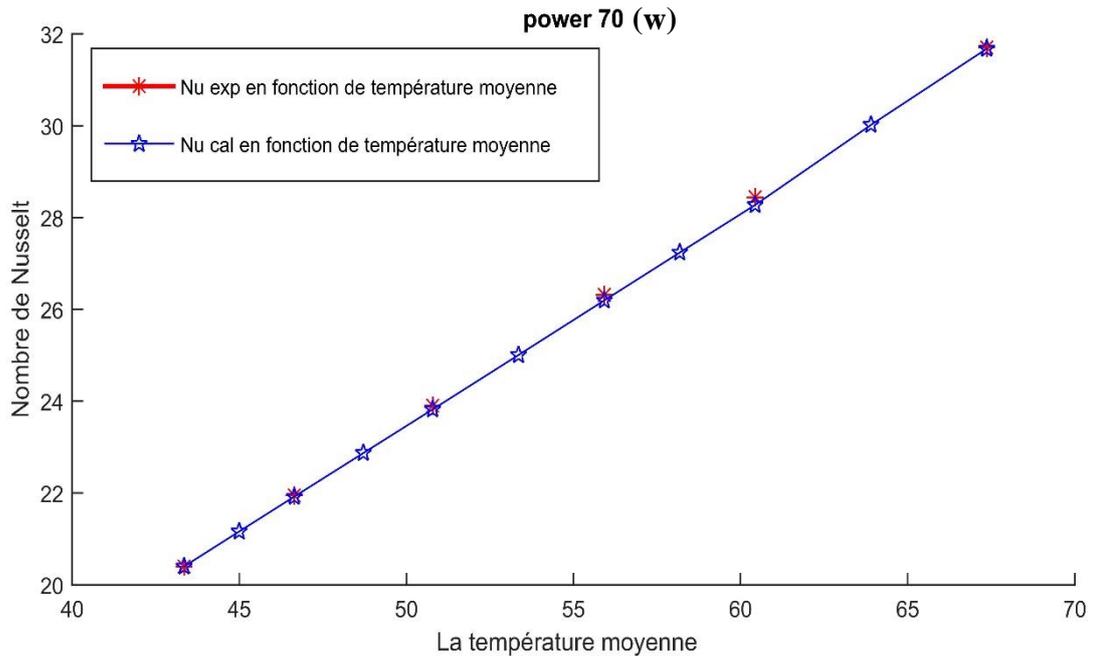


Figure III.17 représentations les valeurs de nombre de Nusselt expérimentale et celle calculée par le RNA en fonction de température moyen (POWER 70W)

Les valeurs expérimentales du nombre de Nusselt et celles calculées par le RNA en fonction de la vitesse et de température moyen sont utilisées pour représenter les données. Ces valeurs sont essentielles pour évaluer l'efficacité de la modélisation et de la prédiction des échanges convectifs. En comparant les résultats expérimentaux avec ceux obtenus à l'aide du réseau de neurones artificiels (RNA), nous pouvons déterminer la précision et l'exactitude du modèle. Cette comparaison permet également d'identifier d'éventuelles erreurs ou divergences entre les deux ensembles de données. En utilisant le RNA, nous espérons obtenir des valeurs de Nusselt calculées qui se rapprochent le plus possible des valeurs expérimentales, ce qui indiquerait une modélisation réussie des phénomènes de transfert de chaleur dans le système étudié.

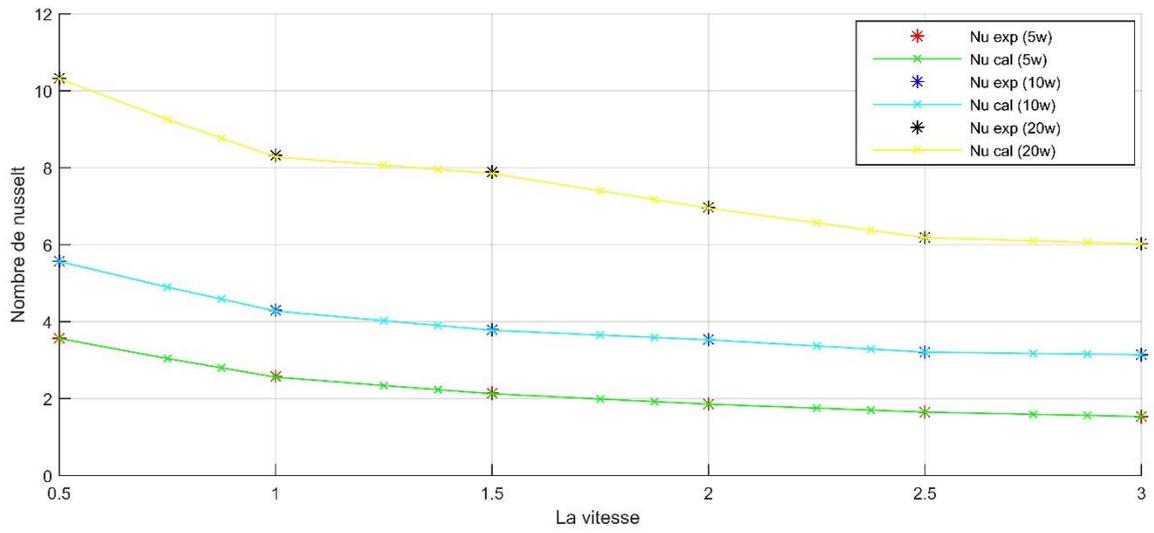


Figure III.18 Nombre de Nusselt calcule et expérimental en fonction de la vitesse pour défrent power(5w-10w-20w)

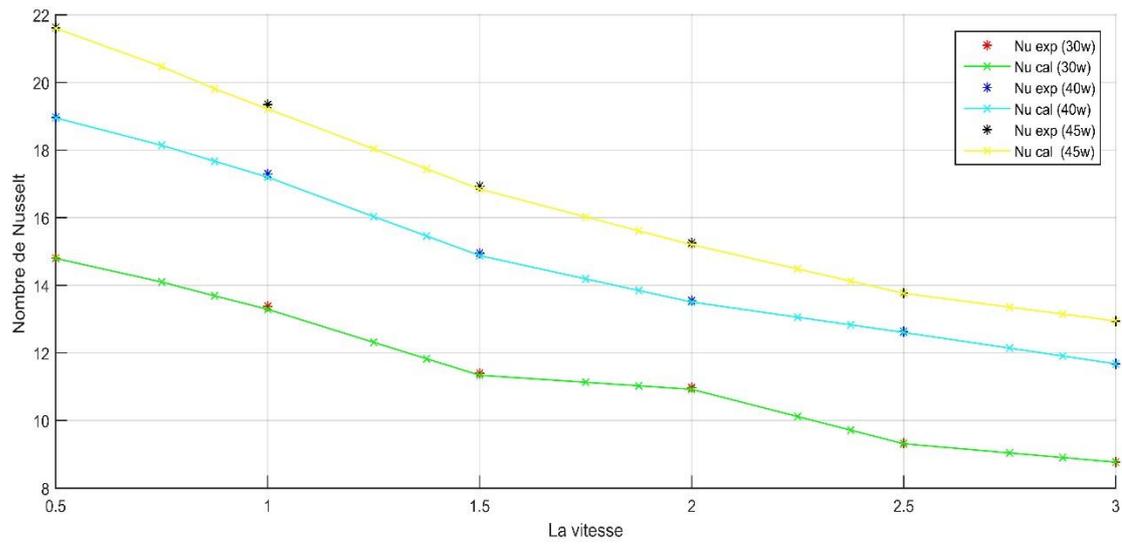


Figure III.19 Nombre de Nusselt calcule et expérimental en fonction de la vitesse pour défrent power(30w-40w-45w)

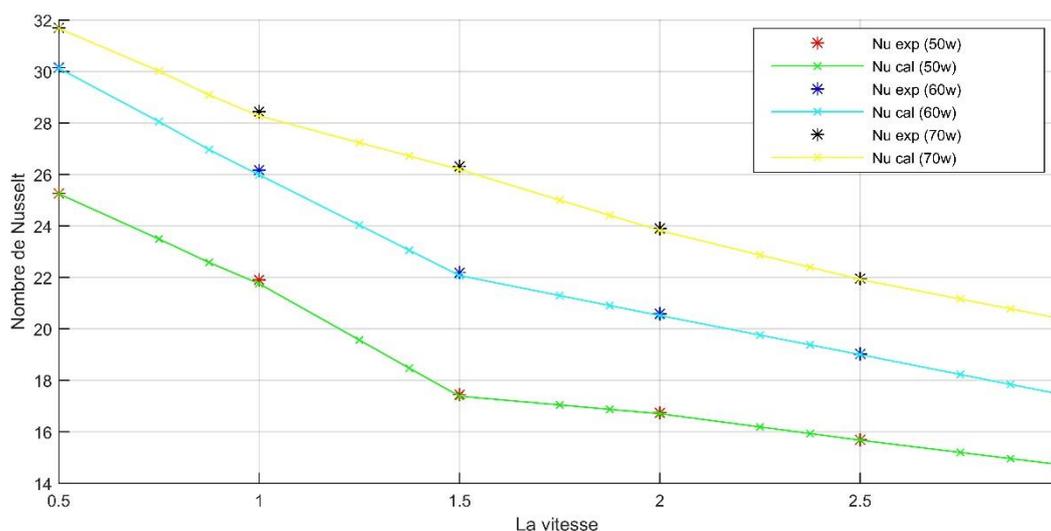


Figure III.20 Nombre de Nusselt calcule et expérimental en fonction de la vitesse pour différent power (50w-60w-70w)

Les figure III.18-19-20 illustre le comportement des courbes du nombre de Nusselt en fonction de la vitesse pour différentes puissances. Cette représentation graphique nous permet de tirer des conclusions intéressantes. En effet, nous constatons une tendance inverse entre la vitesse et le nombre de Nusselt. Plus précisément, à mesure que la vitesse du fluide augmente, le nombre de Nusselt diminue. Cela suggère que la convection joue un rôle important dans le transfert de chaleur, car une augmentation de la vitesse réduit le flux de chaleur conductif.

D'autre part, nous remarquons également une relation positive entre la puissance et le nombre de Nusselt. En augmentant la puissance, le flux de chaleur convectif augmente, ce qui se traduit par une augmentation du nombre de Nusselt. Cela indique que l'apport d'énergie dans le système a un impact significatif sur l'efficacité du transfert de chaleur par convection.

En somme, l'analyse de cette figure met en évidence l'importance de la vitesse et de la puissance dans le phénomène de transfert de chaleur par convection. Une vitesse élevée réduit le nombre de Nusselt, tandis qu'une puissance plus élevée favorise un meilleur transfert de chaleur par convection. Ces observations ont des implications pratiques dans la conception et l'optimisation des systèmes de refroidissement et de chauffage, où la maîtrise de ces paramètres peut améliorer l'efficacité globale du transfert de chaleur.

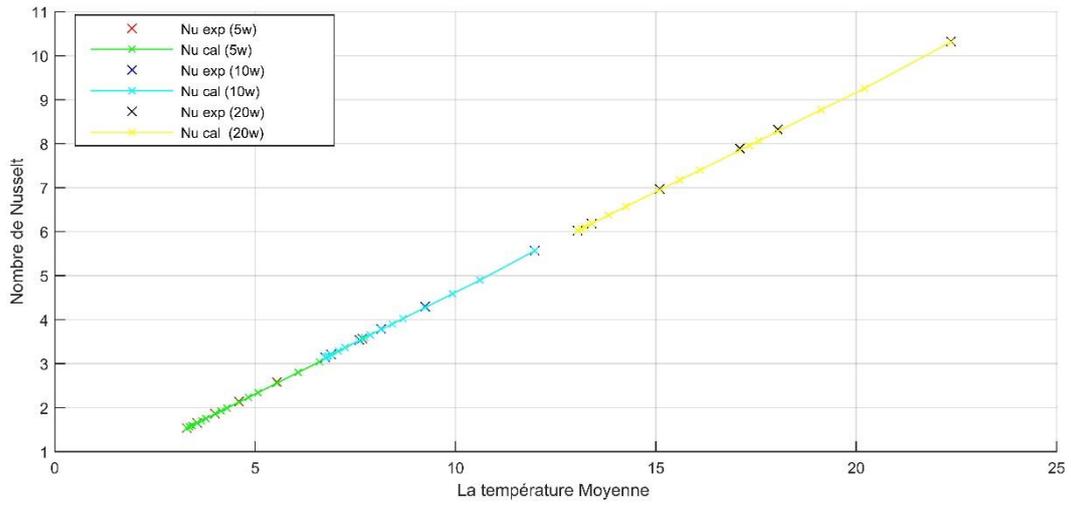


Figure III.21 Nombre de Nusselt calcule et expérimental en fonction de température moyen pour différent power (5w-10w-20w)

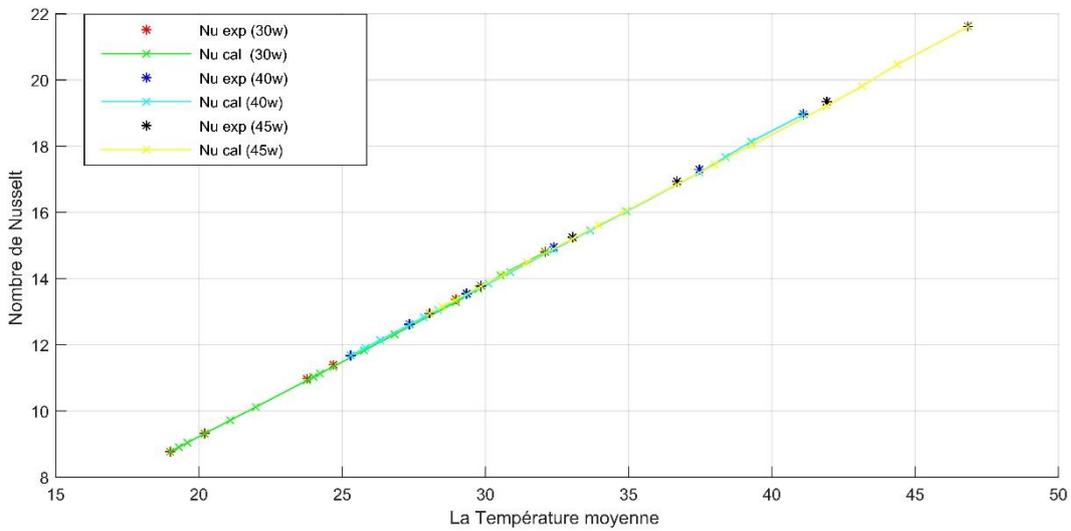


Figure III.22 Nombre de Nusselt calcule et expérimental en fonction de température moyen pour différent power (30w-40w-45w)

Fig

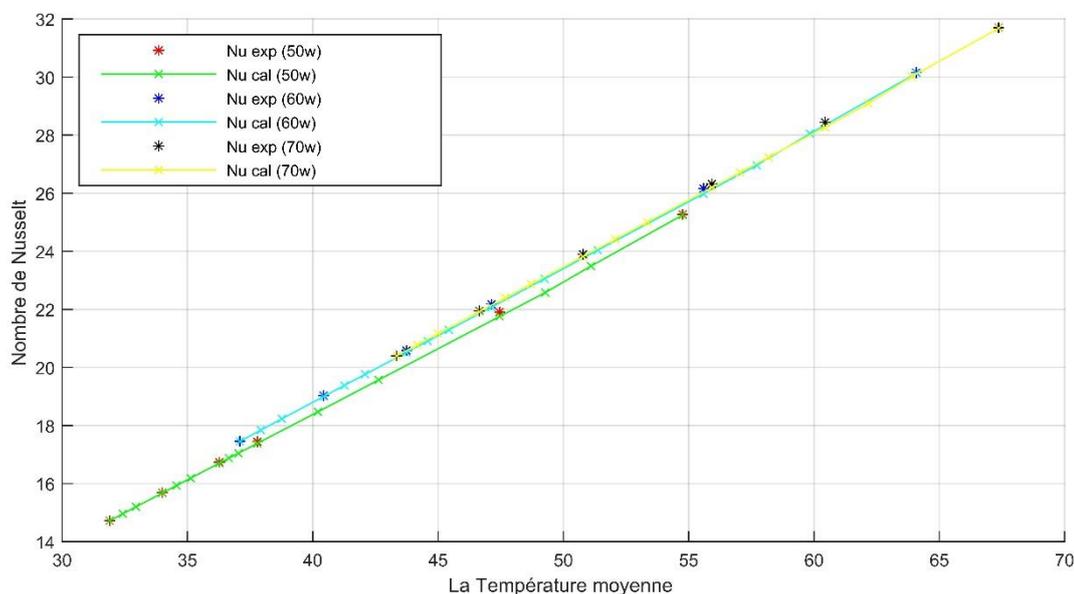


Figure III.23 Nombre de Nusselt calculé et expérimental en fonction de température moyenne pour différentes puissances (50w-60w-70w)

Les figures III.21-22-23 représentent le comportement des courbes du nombre de Nusselt en fonction de la température moyenne pour différentes puissances (5 watts, 10 watts et 20 watts) (30 watts, 40 watts et 45 watts). (50 watts, 60 watts et 70 watts), Plus précisément, nous constatons que lorsque la température moyenne du fluide augmente, le nombre de Nusselt augmente également.

Cette observation suggère une corrélation positive entre la température moyenne et le nombre de Nusselt. En d'autres termes, à mesure que la température du fluide augmente, le transfert de chaleur par convection devient plus efficace, ce qui se traduit par une augmentation du nombre de Nusselt. Cela peut être dû à une augmentation de la différence de température entre la surface d'échange et le fluide, favorisant ainsi un transfert de chaleur plus important.

Cette relation entre la température moyenne et le nombre de Nusselt est importante pour comprendre le comportement du transfert de chaleur dans différents systèmes. Elle peut être utilisée pour optimiser les dispositifs de refroidissement ou de chauffage, en ajustant la température du fluide pour améliorer l'efficacité du transfert de chaleur par convection.

Une fois que le modèle neuronal a été développé, il est possible de représenter son équation de la manière suivante.

$$Nu = f_R \left(\sum_{k=1}^7 \left(w_k \times f_h \left(\sum_{j=1}^2 (w_{kj} \times X_j) + b_h \right) \right) + b_k \right)$$

7 est le nombre de neurones dans la couche cachée.

2 est le nombre de neurones dans la couche d'entrée.

1 est le nombre de neurones dans la couche de sortie.

w_{kj} b_h sont les poids et biais de la couche cachée.

b_k sont les poids et biais de la couche de sortie.

f_R est la fonction d'activation "tansig" utilisée dans la couche cachée.

f_h est la fonction d'activation "purelin" utilisée dans la couche de sortie.

III.12 Conclusion :

Grâce à l'utilisation de techniques d'apprentissage automatique avancées, nous avons pu développer un modèle de réseau neuronal statique optimisé. Les performances obtenues ont été exceptionnelles, avec un coefficient de corrélation R de 0,99998 la sortie étudiée. De plus, l'erreur absolue moyenne relative (MAARD) était seulement de 0,18907. Ces résultats solides confirment la robustesse de notre modèle neuronal.

Conclusion générale

En conclusion, notre étude démontre clairement le potentiel et l'efficacité des réseaux neuronaux artificiels dans la modélisation des paramètres d'échange convective autour d'un obstacle, En utilisant des techniques avancées d'apprentissage automatique et en combinant des données expérimentales, nous avons pu développer des modèles précis capables de prédire et d'analyser le comportement des processus thermiques de manière efficace.

Cette approche offre de nouvelles perspectives pour améliorer notre compréhension des mécanismes de transfert thermique et pour concevoir des solutions innovantes dans divers domaines industriels et scientifiques. Les résultats obtenus confirment la solidité de notre modèle et son aptitude à fournir des prédictions fiables.

Il est important de souligner que notre étude ne se limite pas à la modélisation des paramètres d'échange convectif, mais elle offre également des opportunités d'exploration et d'adaptation à d'autres paramètres d'intérêt, ouvrant ainsi la voie à de futures avancées dans le domaine.

Nous sommes convaincus que l'utilisation de l'intelligence artificielle, en particulier des réseaux neuronaux, pour la modélisation des phénomènes de transfert thermique, contribuera à l'avancement des connaissances et à l'amélioration des technologies dans ce domaine crucial. Nous espérons que notre étude servira de base solide pour de nouvelles recherches et applications visant à optimiser les systèmes de transfert de chaleur et à relever les défis thermiques de manière plus efficace.

Référence bibliographique

- [1] BAAISSA.I. EVALUATION DU COEFFICIENT DE TRANSFERT CONVECTIF 'h' ENTRE UNE SURFACE PLANE ET UN FLUIDE EN ECOULEMENT, CAS PLUSIEURS LIQUIDES ET GAZ. Université Mohamed Khider de Biskra.2018/2019
- [2] <https://cdn.kastatic.org/ka-perseus-images/677525f42ad89d613877fb6fa6d092f2a38f3e24.jpg>
- [3] https://costeno16.alwaysdata.net/06_Rayonnement.html
- [4] BENABDERRAHMANE.f . ETUDE DE LA CONVECTION NATURELLE EN RÉGIME TURBULENT DANS UNE SERRE HORTICOLE. Memoire Magister. Université des sciences et de la Technologie Mohamed Boudiaf (USTO) Oran.2010/2011
- [5] Benacer.B. Etude de la convection forcée en régime laminaire sur une plaque plane chaude pour différents angles d'attaque. Université Mohamed Khider de Biskra.2018/2019
- [6] **R. Belakroum, M. Khadja, H. Zibouche.** *Simulation numérique du phénomène d'éclatement tourbillonnaire dans la zone de sillage d'un obstacle de section circulaire.* International Conférence on Energetics and pollution Constantine. 2007.
- [7] Amara.O,Zerouki.C . Simulation numérique d'un écoulement de fluide autour d'un obstacle carré : Influence de l'angle d'inclinaison. Université Ibn Khaldoun de Tiaret.2019/2020.
- [8] **Y.H. Madani, M.Abidat.** *Etude numérique de l'écoulement d'un fluide visqueux Incompressible autour de corps profilés par une méthode combinée d'ordre $O(h^2)$ et $O(h^4)$.* Séminaire international de Génie Mécanique. 2002
- [9] Amara. O, Zerouki. C. Simulation numérique d'un écoulement de fluide autour d'un obstacle carré : Influence de l'angle d'inclinaison. Université Ibn Khaldoun de Tiaret. Memoire Master .2019/2020
- [9] Dr YOUCEFI Sarra mécanique des fluides cours et applications Année Universitaire 2016-2017
- [10] ION Paraschivoiu, Aérodynamique subsonique Editions de l'école polytechnique de

Montréal (Québec), Canada, 1998.

[11] ATTABLI, BENTOUTAH. A, SIMULATION DES paramètres d'échange convectifs dans un écoulement autour des obstacles. Université Akli Mohand Oulhadj BOUIRA .2021/2022

[12] BEDJEGHIT.h , ETUDE EXPERIMENTALE ET NUMERIQUE D'UN ECOULEMENT AUTOUR D'OBSTACLES CARRE ET CYLINDRIQUE, MAGISTER, 2009/2010

[13] D. FRIDJA, « Entrainement des réseaux de neurones artificiel par l'algorithme fast error back propagation, application à la modélisation des NMOSFET a enrichissement ». Mémoire de master domaine : sciences et technologie filière : génie électrique, option : instrumentation et maintenance industriel. 2012.

[14] <https://images.nagwa.com/figures/explainers/629169837052/1.svg>

[15] MO COSTANDI, The Discovery of The Neuron, History of Neuroscience, Neuroscience, Tuesday, August 29, 2006

[16] WARREN S. MCCULLOCH, WALTER PITTS, A logical calculus of the ideas immanent in nervous activity, University of illinois, College of medicine, Department of psychiatry at the illinois neuropsychiatric institute, and the university of chicago, Bulletin of mathematical biophysics Volume 5, 1943.

[17] Gana.m, Implémentation d'un réseau de neurones dans un microcontrôleur, Mémoire Master, 2015/2016

[18] M.Y. Ammar, « Mise en oeuvre de réseau de neurones pour la modélisation de cinétique réactionnelles en vue de la transposition batch/continu », Thèse de doctorat, École Nationale d'Ingénieurs de Sfax, Tunisie,2007.

[19] Torche.s, Modélisation par les réseaux de neurones et simulation d'un biocapteur à base de FET,magister, Université de Batna,2008

[20] A. Nouicer, E. Nouicer, M. Feliachi,«A Neural Network for Incorporating the Thermal Effect on the Magnetic Hysteresis of the 3F3 Material using the Jiles –Atherton Model», Journal of Magnetism and Magnetic Materials, Vol.373, pp 240-243, January 2015.

[21] Y. Benda oud, « Prédiction Des Résistances Mécaniques Des Bétons à Base Des Ciments Composés En Utilisant Les Réseaux Neurones Artificiels », Mémoire de Magister, Université

deConstantine,2014.

[22]https://encryptedtbn0.gstatic.com/images?q=tbn:ANd9GcSdXh27dFCv4JVxjxyTeOeB_k9CIvBT8l957w&usqp=CAU

[23] H.Yonaba,« Modélisation hydrologique hybride réseau de neurones –modèle conceptuel », Thèse de doctorat, Université de Laval Québec, 2009.

[24] D. Kadous, « Utilisation des réseaux de neurones comme outil du datamining : Génération de modèle comportemental d'un processus physique à partir de données », mémoire de master, Université de Tlemcen, 2012.

ANNEXE

➤ La base des données obtenu expérimentalement :

p	v	t1	t2	t3	tm	h	Nu
5	0,5	22,3	30,8	23,9	7,6722	7,0837	3,294744
5	1	22,1	28	22,8	5,5426	9,8054	4,560651
5	1,5	22	26,8	22,4	4,5971	11,8222	5,498698
5	2	22,1	26,2	22,2	3,9992	13,5898	6,320837
5	2,5	22,1	25,7	22,2	3,5498	15,3103	7,12107
5	3	22,1	25,5	22,3	3,299	16,4741	7,662372
10	0,5	22,3	35,2	24,1	11,9775	9,075	4,22093
10	1	22,1	31,8	23	9,2427	11,7602	5,46986
10	1,5	22,1	30,5	22,6	8,1474	13,3411	6,205163
10	2	22	29,8	22,4	7,5982	14,3054	6,653674
10	2,5	21,8	28,9	22,2	6,8981	15,7574	7,329023
10	3	22	28,8	22,1	6,7499	16,1034	7,489953
15	0,5	21,9	42,5	25,4	18,7957	8,6745	4,034651
15	1	22,2	38,2	23,9	15,1341	10,7733	5,010837
15	1,5	21,8	34,8	22,8	12,4933	13,0504	6,069953
15	2	21,6	33,5	22,4	11,4959	14,1834	6,59693
15	2,5	22	32,4	22,4	10,1987	15,9867	7,435674
15	3	22	32	22,3	9,8492	16,5539	7,699488
20	0,5	25,5	49,4	28,5	22,3665	9,7195	4,485923
20	1	25,5	44,1	26,6	18,0444	12,0476	5,560431
20	1,5	25,5	42,2	26,1	17,0982	12,7142	5,868092
20	2	25,3	40,6	25,7	15,0991	14,3976	6,645046
20	2,5	25,2	38,7	25,4	13,3998	16,2235	7,487769
20	3	25,1	38,2	25,2	13,0499	16,6584	7,688492
25	0,5	25,4	55	29	27,7611	9,7885	4,517769
25	1	25,2	50,5	27,4	24,1833	11,2326	5,184277
25	1,5	25,1	46,5	26,2	20,8452	13,0361	6,016662
25	2	25,3	44,2	25,9	18,5984	14,6109	6,743492
25	2,5	25,1	42,2	25,9	17,1992	15,7995	7,292077
25	3	25,2	41,7	25,4	16,3998	16,5697	7,647554
30	0,5	25	59,6	29,9	32,0877	10,1624	4,690338
30	1	25,1	55,5	27,9	28,9775	11,2531	5,193738
30	1,5	25,2	50,5	26,4	24,6951	13,2045	6,094385
30	2	25,1	47,5	22,3	23,7725	13,717	6,330923
30	2,5	25,1	45,5	25,5	20,1993	16,1434	7,4508
30	3	25,2	44,3	25,4	18,9998	17,1626	7,9212
35	0,5	23,6	66,5	30	39,6139	9,6036	4,449544
35	1	23,9	58,1	26,9	32,6771	11,6423	5,373369
35	1,5	23,6	53,4	25,3	28,9417	13,1449	6,066877
35	2	23,9	50,3	24,9	25,8968	14,6904	6,780185
35	2,5	24,5	48,1	23,7	23,9978	15,8529	7,316723

35	3	25,1	47,1	25,4	21,8497	17,4115	8,036077
40	0,5	25,3	69	30,4	41,0973	10,5794	4,8828
40	1	25,4	64,7	29	37,4712	11,6031	5,355277
40	1,5	25	58,3	26,8	32,3917	13,4227	6,195092
40	2	24,7	54,6	25,8	29,3466	14,8155	6,837923
40	2,5	25,4	53,1	26,1	27,3485	15,8979	7,337492
40	3	25,4	50,9	25,8	25,2995	17,1854	7,931723
45	0,5	24,2	74	30	46,8402	10,4425	4,819615
45	1	24,2	68,2	28,3	41,9166	11,6691	5,385738
45	1,5	24,1	61,9	26,3	36,689	13,3318	6,153138
45	2	25,2	59	26,7	33,0443	14,8023	6,831831
45	2,5	24,7	54,9	25,4	29,8486	16,387	7,563231
45	3	25	53,3	25,5	28,0493	17,4383	8,048446
50	0,5	24,1	82,9	32	54,755	9,9256	4,581046
50	1	24,3	74,3	29,3	47,4561	11,4522	5,285631
50	1,5	23,7	62,5	25,7	37,7912	14,3811	6,637431
50	2	24,1	62,2	27,7	36,2702	14,9841	6,915738
50	2,5	24,3	58,8	25,3	33,9975	15,9858	7,378062
50	3	24,1	56,4	24,9	31,8983	17,0358	7,862677
55	0,5	24,4	87,3	33,4	58,2842	10,2571	4,734046
55	1	24,3	77,8	29,7	50,7521	11,7793	5,4366
55	1,5	24,5	69,8	27,3	43,8851	13,6225	6,287308
55	2	25,4	64,8	26,9	38,6451	15,4696	7,139815
55	2,5	26	62,6	27	36,0977	16,5613	7,643677
55	3	25,9	60,7	26,8	34,348	17,405	8,033077
60	0,5	18,9	87,9	28,5	64,0802	10,1775	4,789412
60	1	19,2	77,8	25,1	55,5978	11,7302	5,520094
60	1,5	19,3	68	22,4	47,133	13,8369	6,511482
60	2	19	63,8	21,1	43,7416	14,9097	7,016329
60	2,5	19	60,2	20,7	40,434	16,1653	7,6072
60	3	19,6	57,3	20,8	37,0968	17,5803	8,273082
65	0,5	19,7	91,1	29,8	66,2217	10,669	5,020706
65	1	19,4	79,3	24,8	57,1575	12,361	5,816941
65	1,5	19,7	71,7	22,9	50,3831	14,023	6,599059
65	2	19,7	65,6	21,8	44,8418	15,7559	7,414541
65	2,5	19,4	62,9	21	42,695	16,5481	7,787341
65	3	19,6	60,2	20,8	39,997	17,6644	8,312659
70	0,5	20,1	92,8	30,5	67,3663	11,2945	5,315059
70	1	20,1	83,9	26,7	60,44	12,5889	5,924188
70	1,5	20,1	78,2	24,4	55,9224	13,6058	6,402729
70	2	19,8	72,1	22,8	50,7852	14,9821	7,0504
70	2,5	19,8	67,5	21,9	46,6421	16,3129	7,676659
70	3	20,2	64,3	21,7	43,3457	17,5535	8,260471

