



République algérien démocratique et populaire
Ministre de l'enseignement supérieur et de la
recherche scientifique



Université Mohamed Boudiaf – M'sila

Faculté : technologie

Département : Génie électrique

MEMOIRE DE FIN D'ETUDE
En vue de l'obtention du diplôme de :

MASTER

En Génie électrique

Option : Hydrogène vert vecteur d'énergie

Thème

Prédiction de la performance du procédé de séchage en
utilisant les méthodes intelligentes

Soutenu devant le jury composé de :

Djerioui Ali

Zemmit Abderrahim

Université Mohamed Boudiaf de M'Sila

Université Mohamed Boudiaf de M'Sila

Par :


- Abdelli Mohammed El Amine

- Marouf Youcef Amine

Enseignant encadré :

- Pr. Ihaddadene Razika

Année Universitaire : 2024 / 2025



Dédicace

Je dédie cet humble travail à :

*Ma mère Allah yarhamha et mon père avant tout, qu'ALLAH Que
Dieu le protège et prolonge sa vie
Lui accorde santé et bien-être, et il m'a aidé au cours de cette
longue étude.*

*Ma mère et mon père avant tout, qu'ALLAH les protège et
prolonge leur vie et
Leur procure santé et bien-être, qui m'ont aidé tout au long de
cette longue étude.*

*Merci pour tout le soutien que vous m'avez apporté
Aux lecteurs de ce mémoire, pour qui, je l'espère, leur sera utile.*

*A mes parents, qu'ALLAH les protège, et prolonge leur vie et
leur procure santé et bien-être, qui m'ont aidé tout au long de cette
longue étude.*

A mes frères et sœurs, merci pour vos encouragements ;

Merci pour tout le soutien que vous m'avez apporté.

Remerciements

Nous remercions Allah, qui nous a aidés à accomplir cet humble travail, et exprimons notre sincère gratitude au Professeur Ihaddadene Razika qui nous a conseillé, guidé et orienté tout au long de la préparation de ce travail, des instructions et une bonne orientation tout au long de la période de préparation de ce travail.

Nous adressons également nos sincères remerciements et notre gratitude aux membres jurys pour nous avoir donné part de leur temps et accepté l'étude et la discussion de notre mémoire à bras ouverts.

Nous remercions tous ceux qui nous ont soutenus dans la préparation de ce mémoire, que ce soit par la prière ou par l'information, que Dieu les récompense et les bénisse.

TABLE DES MATIERES

Dédicace	i
Remerciements	ii
Table des Matières	iii
Liste des Figures	vii
Liste des Tableaux	viii

INTRODUCTION GENERALE	1
------------------------------------	----------

CHAPITRE I – Etat de l’art sur le séchage des produits alimentaires.

Introduction	3
Partie I : Généralités sur le procédé de séchage.....	3
I.1 Définition du séchage.....	3
I.2 Le but de séchage	3
I.3 Les méthodes de séchage	3
I.4 Les modes de séchage.....	4
I.4.1 Séchage par conduction	4
I.4.2 Séchage par convection (ou par entrainement)	5
I.4.3 Séchage par rayonnement infrarouge.....	5
I.4.4 Séchage sous vide	6
I.4.5 Séchage par lyophilisation	6
I.4.6 Séchage par pertes diélectriques	7
I.4.7 Séchage solaire	7
I.5 Les avantages et les inconvénients du Séchage	9
I.5.1 Les avantages	9
I.5.2 Inconvénients	9
I.6 L’efficacité d’une technique de séchage	9
I.6.1 La qualité du produit séché	9
I.6.2 La performance du procédé	9

I.7 La cinétique de séchage.....	10
I.8 Modélisation mathématique de la cinétique de séchage	10
<u>Partie2 : Méthodes intelligentes</u>	11
Les réseaux de neurones	11
I.1 Historique de réseau de neurone	12
I.2 Réseaux de neurones et régression non linéaire.....	12
I.3 Réseaux de neurones et modélisation de processus.....	14
I.3.1 Modélisation du processus non linéaire statique.....	14
I.3.2 Modélisation du processus non linéaire dynamique.....	14
I.3.3 Modèles de connaissance et modèles "boîte noire"	14
I.3.3.1 Modèles dynamiques "boîtes noires".....	15
I.3.3.2 Modèles neuronaux de connaissances.....	15
I.3.4 Réseaux neuronaux et l'architecture des réseaux.....	16
I.3.4.1 Définition et éléments caractéristiques d'un neurone	16
I.3.4.2 Neurone à une entrée simple	17
I.3.4.3 Neurone à des entrées multiples.....	17
I.3.4.4 Réseaux de neurones	18
I.3.4.4.1 Réseaux de neurones bouclés (feedback networks)	19
I.3.4.4.2 Réseaux de neurones non-bouclés (feed-forward networks)	19
I.3.4.4.3 Architecture en couches de neurones	20
I.3.4.4.4 Réseau de type Perceptron multicouche (PMC).....	21
I.3.5 Fonctions de transfert du Perceptron Multi-Couche.....	22
I.3.6 Mise en œuvre des réseaux de neurones.....	22
I.3.6.1 Protocole d'utilisation	22
I.3.6.2 Optimisation du réseau de neurones.....	22

I.3.6.3 Algorithme de rétro-propagation	23
I.3.6.4 Apprentissage, généralisation, sur-apprentissage et minimums locaux	24
I.4 Critères de validation des modèles.....	24
Conclusion	25

CHAPITRE II– Matériels et méthodes.

Introduction	26
II.1 Les données utilisées	26
II.2 Les méthodes empiriques	27
II.3 Analyse statistique	28
II.3.1 Coefficient de Détermination.....	28
II.3.2 Racine de l'Erreur Quadratique Moyenne (RMSE)	29
II.3.3 L'Erreur Moyenne Absolue (MAE - Mean Absolute Error).....	29
II.4 Méthode les réseaux de neurone	30
Conclusion	31

CHAPITRE III – Résultats et discussion.

Introduction	32
III.1 Méthodes empiriques	32
III.1.1 Coefficients des modèles testés.....	32
III.1.2 Evolution des différents modèles.....	33
III.1.3 Comparaison des modèles empiriques.....	35
III.2 Méthode les réseaux de neurone.....	37
III.2.1 Convergence.....	37
III.2.2 Etat d'entraînement	38
III.2.3 Histogramme d'erreur	39

III.2.4 Régression	40
III.2.4 Performance	41
Conclusion.....	42
CONCLUSION GENERALE	43
Références bibliographiques.....	44
Résumé.....	47
Mots clés.....	48

Liste des Figures

Figure I.1 : Séchage par conduction	04
Figure I.2 : Séchage par convection.....	05
Figure I.3 : Séchage par rayonnement IR.....	05
Figure I.4 : Séchage sous vide.....	06
Figure I.5 : Séchage par lyophilisation.....	06
Figure I.6 : Séchage par pertes diélectriques.....	07
Figure I.7 : Séchage solaire (séchage direct)	08
Figure I.8 : Séchage solaire (séchage indirect)	08
Figure I.9 : Modèle d'un neurone artificiel à une entrée simple.....	17
Figure I.10 : Modèle d'un neurone artificiel à entrées multiples simple.....	18
Figure I.11 : Taxonomie d'architectures du réseau neurone non-bouclé. Simple.....	18
Figure I.12 : Schéma de réseau de neurones bouclé.....	19
Figure I.13 : Schéma d'un réseau de neurones non bouclé.....	20
Figure I.14 : Réseau de neurones à une couche simple.....	20
Figure I.15 : Réseau de neurones à deux couches cachées simple.....	21
Figure I.16 : Perceptron multicouches (PMC).....	21
Figure I.17 : Fonctions de transfert d'un réseau de neurones.....	22
Figure II.1 : Dispositif expérimental.....	26
Figure II.2 : Schéma du réseau de neurone utilisé.....	30
Figure III.1 : Evolution de MR selon le modèle Henderson and Pabis.....	33
Figure III.2 : Evolution de MR selon le modèle Logarithmique	33

Figure III.3 : Evolution de MR selon le modèle Newton.....	34
Figure III.4 : Evolution de MR selon le modèle Page.....	34
Figure III.5 : Comparaison des modèles empiriques.....	37
Figure III.6 : courbe de performance.....	38
Figure III.7 : Résultats de Etat d'entraînement.....	39
Figure III.8 : Résultats de Histogramme d'erreur.....	40
Figure III.9 : Résultats de Régression.....	41
Figure III.10 : Résultats du modèle de réseau de neurone.....	42

List of tables :

Tableau I.1: Modèles mathématiques de la cinétique du séchage.....	11
Tableau I-2 : Réseaux de neurones et statistiques conventionnelles.....	13
Tableau III.1 : Coefficients de chaque modèle.....	32
Tableau III.2 : Analyse statistique des différents modèles.....	36

Introduction générale

Introduction générale :

Le séchage est une opération unitaire fondamentale dans les industries agroalimentaire et pharmaceutique, visant à éliminer l'humidité des produits afin d'en améliorer la conservation, la stabilité et la qualité. Ce procédé, essentiel pour prolonger la durée de vie des aliments et des médicaments, repose sur des mécanismes complexes de transfert de chaleur et de masse, qui peuvent être réalisés par diverses techniques telles que le séchage par convection, conduction ou rayonnement.

De nombreux produits alimentaires sont séchés afin de réduire leur poids et leur volume finaux, d'augmenter leur durée de conservation, de diminuer les coûts d'emballage et de réduire considérablement les coûts de transport et de stockage. L'intérêt pour la production de tomates séchées augmente en raison de la possibilité de les utiliser dans les salades, les pizzas, les soupes, les salades et autres plats. Il est possible de sécher les tomates sous forme de moitiés, de tranches, de quartiers et de poudre.

De nombreuses techniques de séchage solaire peuvent être utilisées pour réaliser le processus de séchage. Il existe plusieurs méthodes de séchage des tomates qui affectent la qualité du produit final, notamment la variété de tomates, la taille, la forme et l'épaisseur de la tomate, la température de l'air, l'humidité de l'air, la vitesse de l'air, la vitesse de séchage et l'efficacité du processus de séchage. Le séchage à air chaud par convection est la technique la plus appropriée au niveau commercial. Cette technique a montré sa supériorité sur d'autres méthodes applicables en termes de préservation de la qualité (couleur et teneur en caroténoïdes) et de faible coût d'exploitation.

Durant cette étude, on s'intéresse à étudier la possibilité de sécher par rayonnement, contrairement à la convection à haute température, la méthode la plus répandue. Le rayonnement solaire a été simulé par une lampe halogène et les expériences ont été réalisées en laboratoire. La modélisation de l'évolution du taux d'humidité (MR) a été effectuée en utilisant deux types de méthodes ; les méthodes empiriques et les méthodes intelligentes (réseaux de neurone).

Ce mémoire est divisé en trois chapitres, le premier est divisé en deux parties, la première comporte des notions générales sur le séchage à savoir ; le but de séchage, les méthodes de séchage, les modes de séchage, les avantages et les inconvénients, l'étude de la cinétique de séchage et sa modélisation en utilisant les méthodes empiriques. La deuxième partie est consacrée à la méthode des réseaux de neurone.

Le deuxième chapitre regroupe les données utilisées durant cette étude et une description détaillée des méthodes citées dans le chapitre1 (méthodes empiriques (Newton, Page, Henderson et Pabis, et Logarithmique) et la méthode des réseaux de neurone (le perceptron multicouche (MLP)). En plus de l'analyse comparative de ces méthodes en utilisant les indices statistiques tels que R^2 , RMSE et MAE.

Le dernier chapitre est consacré regroupe les résultats obtenus de la modélisation de MR en fonction du temps en utilisant les deux méthodes (empiriques et réseaux de neurone) et leur discussion. A la fin une conclusion clôture ce mémoire.

Chapitre I : Etat de l'art sur le séchage des produits alimentaires.

Introduction :

Le séchage constitue une opération unitaire essentielle dans les industries agroalimentaire et pharmaceutique, visant à éliminer l'humidité des produits pour en améliorer la conservation et la stabilité. Ce chapitre présente une étude exhaustive des principes fondamentaux, méthodes classiques et approches innovantes du séchage. Il aborde d'abord les aspects théoriques du procédé, incluant les mécanismes de transfert de chaleur et de masse, ainsi que les différentes techniques disponibles (séchage par convection, conduction, rayonnement, etc.). La seconde partie introduit les méthodes intelligentes, particulièrement les réseaux de neurones artificiels, comme outils modernes pour modéliser ces processus complexes. En combinant connaissances traditionnelles et technologies émergentes, ce chapitre établit les bases théoriques nécessaires pour comprendre et optimiser les opérations de séchage, tout en ouvrant des perspectives pour des applications industrielles plus efficaces. Les concepts présentés serviront de fondement aux analyses expérimentales et modélisations approfondies développées dans les chapitres suivants.

Partie 1 : Généralités sur le procédé de séchage

I.1 Définition du séchage :

Le séchage est une étape cruciale dans les secteurs agro-alimentaire et industriel. Il implique l'élimination partielle ou totale de l'eau contenue dans un produit humide par évaporation [1], réduisant la croissance des micro-organismes et des réactions chimiques non désirées telles que le brunissement enzymatique afin d'augmenter la durée optimale d'utilisation du produit [2]. Le produit humide peut être solide ou liquide, mais le produit final est solide [3]. Il s'agit d'une technique qui met en jeu des transferts simultanés de chaleur et de masse entre le produit et l'air environnant [4].

L'objectif du séchage d'un produit est de réduire sa teneur en eau afin de diminuer son activité de l'eau à un niveau qui permet sa conservation à température ambiante sur de longues périodes (de l'ordre de l'année). Cette réduction peut être réalisée par des méthodes mécaniques (pressage, centrifugation) ou thermiques (évaporation, déshydratation) [5].

I.2 Le but de séchage :

L'objectif du séchage est de supprimer ou d'évaporer la teneur en eau grâce à l'action de la chaleur [6]. Le liquide associé à un solide vise soit à restaurer ses propriétés mécaniques ou physico-chimiques d'origine, soit à favoriser son stockage et sa conservation dans des conditions ambiantes [7].

I.3 Les méthodes de séchage :

Cette opération peut être réalisée grâce à différentes méthodes, telles que l'exposition directe au soleil, le stockage dans un lieu sec, ou encore l'utilisation d'air chauffé par le rayonnement solaire comme source de chaleur. Ce dernier procédé s'effectue dans une chambre thermiquement isolée afin de garantir la continuité du processus de séchage. Il existe plusieurs méthodes de séchage selon les besoins (l'aspect du produit a séché) :

a) Séchage mécanique : C'est l'élimination du liquide par des forces purement mécanique (Pressage, centrifugation, compression et filtration) [8].

b) Séchage chimique : C'est un procédé basé sur l'utilisation des produits déshydratants par équilibre osmotique pour extraire l'eau (Chlorure de calcium, ...) [9].

c) Séchage thermique : Ce type d'opération est essentiellement un transfert de masse nécessitant au préalable une « activation » de l'eau par une certaine quantité d'énergie apportée par un transfert de chaleur. Les deux transferts se dédoublent en une phase externe et une phase interne [10] :

- Transfert de chaleur externe, de la source de chaleur vers la surface du produit ;
- Transfert de chaleur interne, de la surface vers le cœur du produit ;
- Transfert de masse interne, du cœur vers la surface du produit ;
- Transfert de masse externe, de la surface du produit vers le milieu extérieur.

I.4 Les modes de séchage :

Le critère de classification le plus couramment employé se base sur le mécanisme de transfert de chaleur entre le produit et la source de chaleur, ou encore sur la méthode de chauffage appliquée à la matière à sécher [11]. On distingue les modes de séchage suivants :

I.4.1 Séchage par conduction :

Le matériau à sécher est placé en contact direct avec une surface solide chauffée, permettant un transfert de chaleur par conduction à travers cette paroi, puis par conduction au sein du produit lui-même, comme illustré sur la Figure I.1. Cette méthode de séchage est largement répandue dans les secteurs industriels tels que le textile et la papeterie [12].




Figure I.1 : Séchage par conduction. [12]

I.4.2 Séchage par convection (ou par entrainement) :

Cette méthode repose sur le transfert de chaleur au produit via un flux d'air chaud. Ce mode de séchage, qui représente plus de 85 % des séchoirs industriels [13], est particulièrement répandu dans le secteur agroalimentaire. Un exemple de ce type de séchoir est illustré sur la Figure I.2.




Figure I.2 : Séchage par convection. [13].

I.4.3 Séchage par rayonnement infrarouge :

Un rayonnement infrarouge (IR) est dirigé vers le produit, permettant un chauffage rapide des couches minces (jusqu'à 500 μm). Ce rayonnement est généré soit par des dispositifs électroniques, comme les micro-ondes (où le transfert de chaleur s'effectue par propagation d'une onde électromagnétique via un générateur de micro-ondes), soit par l'élévation de la température d'un émetteur IR. Ce procédé de séchage est particulièrement efficace pour éliminer l'eau, notamment lorsque le produit n'est pas thermosensible [14]. Il est largement utilisé dans l'industrie des peintures. Un exemple est présenté sur la Figure I.3.




Figure I.3 : Séchage par rayonnement IR. [14]

I.4.4 Séchage sous vide :

La réduction de la pression entraîne une baisse du point d'ébullition d'un liquide. Ainsi, le séchage sous vide provoque une vaporisation rapide du liquide à éliminer. Ce processus, basé sur la vaporisation, est accéléré, ce qui réduit considérablement le temps de séjour du matériau dans le séchoir. Cette méthode (Figure I.4) permet de sécher des substances thermosensibles, qui seraient difficiles à traiter à pression normale en raison de leur exposition prolongée à des températures élevées [15].



Figure I.4 : Séchage sous vide. [15]

I.4.5 Séchage par lyophilisation :

La lyophilisation est un procédé de séchage qui s'effectue sous une pression extrêmement basse, combinant l'action du froid et du vide pour permettre la sublimation. Cette technique, bien que coûteuse, est réservée à des matériaux spécifiques en raison de leur sensibilité à la chaleur, les rendant incompatibles avec les méthodes de séchage conventionnelles. Elle est notamment utilisée pour des substances biologiques (comme le plasma sanguin ou les cellules), des produits pharmaceutiques (tels que les antibiotiques) et des denrées alimentaires (comme le café, le lait ou les jus de fruits) [16]. Les cristaux de glace formés sont ensuite éliminés de la chambre de séchage à l'aide de pompes à vide mécaniques ou d'éjecteurs à jet de vapeur. Un exemple est illustré sur la Figure I.5.




Figure I.5 : Séchage par lyophilisation. [16]

I.4.6 Séchage par pertes diélectriques :

Le séchage par pertes diélectriques (Figure I.6) repose sur le principe du chauffage électrique des matériaux isolants (diélectriques). Ce procédé est réalisé en exposant la matière à sécher à un champ électrique alternatif de très haute fréquence (entre 1 et 30 MHz). Un tel champ est généré entre les plaques d'un condensateur plan connecté à un générateur. Sous l'influence de ce champ, les molécules du diélectrique se polarisent et sont forcées d'inverser leur polarité à chaque cycle. Cette inversion de polarité induit des vibrations mécaniques des dipôles moléculaires, entraînant des frictions à l'échelle atomique et moléculaire, ce qui produit de la chaleur. Cette chaleur est ensuite utilisée pour chauffer uniformément la matière [17].



Figure I.6 : Séchage par pertes diélectriques. [17]

I.4.7 Séchage solaire :

Il consiste simplement à chauffer le produit en utilisant directement le rayonnement solaire (séchage direct (Figure I.7)) ou en passant par un capteur solaire conçu pour capter et/ou concentrer les rayons du soleil afin d'augmenter la température de l'air (séchage indirect (Figure I.8)). Cette méthode de séchage est particulièrement répandue dans le secteur agroalimentaire.

Les méthodes de séchage mentionnées précédemment, à l'exception du séchage solaire, sont très énergivores (représentant 10 à 15 % de la consommation énergétique industrielle mondiale [18]). Par ailleurs, ces procédés sont complexes à mettre en œuvre, surtout dans les zones rurales où l'accès aux sources d'énergie (électricité, gaz, etc.) est souvent limité. Ainsi, le recours à l'énergie solaire, gratuite et abondante, s'avère avantageux et permet de réduire les coûts du processus, en particulier dans les pays en développement.



Figure I.7 : Séchage solaire (séchage direct). [18]




Figure I.8 : Séchage solaire (séchage indirect). [18]

I.5 Les avantages et les inconvénients du Séchage :

I.5.1 Les avantages :

Les principaux atouts du procédé de séchage sont les suivants [19] :

- La simplicité de la méthode, souvent associée à un rendement élevé.
- Une durée de conservation des aliments séchés pouvant s'étendre sur plusieurs mois.
- La neutralisation des enzymes responsables de la détérioration des aliments.
- L'inhibition de la prolifération des micro-organismes grâce à la diminution de l'activité de l'eau.
- Son potentiel d'utilisation à des fins commerciales, contribuant à réduire les pertes post-récolte.
- La réduction des coûts financiers et environnementaux liés au transport des marchandises, grâce à la diminution de leur masse.

I.5.2 Inconvénients :

Le séchage, comme tout autre traitement thermique, peut engendrer plusieurs effets indésirables, notamment [20] :

- Une diminution des arômes, des vitamines et des pigments,
- Des réactions de brunissement et un durcissement de la surface, ainsi que des altérations irréversibles de la texture, affectant ainsi la capacité de réhydratation,
- Une évaporation des composants volatils et une modification de la distribution de l'humidité au sein du produit.
- De plus, ce procédé est énergivore et donc coûteux. Il est donc essentiel de comprendre les facteurs influençant le séchage, en particulier la vitesse de séchage, afin d'optimiser cette opération et d'en réduire les coûts.

I.6 L'efficacité d'une technique de séchage :

L'efficacité d'une technique de conservation se mesure à deux niveaux, à savoir la qualité du produit obtenu et la performance du procédé utilisé.

I.6.1 La qualité du produit séché :

La qualité (hygiénique, nutritionnelle, praticité, sensorielle comme flaveur, couleur, texture...) du produit séché dépend du processus adopté, des prétraitements éventuels (il s'agit principalement de l'imprégnation pour les légumes et fruits), du taux d'élimination de l'eau, de l'état du fruit ou du légume impliquant le degré de maturité, mais également la taille des découpes (entiers, coupées, purée), ainsi que du matériau d'emballage utilisé [21].

I.6.2 La performance du procédé :

L'objectif des recherches a toujours été de trouver des procédés simples, rapides et surtout aussi pratiques que possible. La performance d'un procédé de séchage est évaluée en termes de consommation d'énergie, cinétique, coût d'équipements et coût total ainsi qu'en termes de son impact sur l'environnement [22].

I.7 La cinétique de séchage :

La cinétique de séchage est un meilleur moyen de caractériser expérimentalement le comportement au séchage d'un produit [23]. La courbe de la cinétique de séchage est obtenue expérimentalement en suivant l'évolution de la masse du produit au cours du séchage par des pesées successives jusqu'à stabilisation de la masse du produit [24].

Cette courbe de séchage est déterminée en exprimant soit :

- la variation de la teneur en eau en fonction du temps : $M = f(t)$;
- la variation de la vitesse de séchage en fonction du temps : $- dM/dt = f(t)$;
- la variation de la vitesse de séchage en fonction de la teneur en eau : $- dM/dt = f(M)$;

Le taux d'humidité des échantillons pendant le séchage est exprimé par l'équation suivante :

$$MR = \frac{M_t - M_{eq}}{M_0 - M_{eq}} \quad (I.1)$$

Avec :

M_t : est la teneur en humidité ou la teneur en eau à tout moment de séchage t (kg d'eau/kg de m.s), elle exprimée par la relation suivante :

$$M_t = \frac{m_t - m_s}{m_s} \quad (I.2)$$

m_t et m_s expriment la masse du produit séché au temps t et la masse sèche du produit séché.

M_0 : est la teneur en humidité initiale ou la teneur initiale en eau (kg d'eau/kg de m.s) ;

M_{eq} : est la teneur en humidité d'équilibre ou la teneur en eau à l'équilibre (kg d'eau/kg de m.s).

Généralement cette équation est simplifiée sous cette forme :

$$MR = \frac{M_t}{M_0} \quad (I.3)$$

La vitesse de séchage exprime la variation de la teneur en humidité en fonction du temps avec un signe moins, elle est donnée par la formule suivante :

$$DR = - \frac{M_{t+\Delta t} - M_t}{M_t} \quad (I.4)$$

I.8 Modélisation mathématique de la cinétique de séchage :

L'approche empirique des courbes de séchage en couche mince est largement utilisée en raison de sa simplicité de mise en œuvre et de sa fiabilité pour décrire le séchage en couche mince des produits agricoles ainsi que des plantes aromatiques et médicinales. Par conséquent, plusieurs modèles mathématiques semi-empiriques et empiriques ont été employés pour représenter la cinétique de séchage de ces produits [25]. Le Tableau I.1 regroupe les modèles mathématiques qui décrivent l'évolution du teneur en eau réduite en fonction du temps.

Tableau I.1: Modèles mathématiques de la cinétique du séchage.

Modèles	Equations
Newton	$MR = \exp(-kt)$ (5)
Page	$MR = \exp(-kt^n)$ (6)
Henderson and Pabis	$MR = a \exp(-kt)$ (7)
Logarithmic	$MR = a \exp(-kt) + c$ (8)
Wang and Singh	$MR = 1 + at + bt^2$ (9)
Two-Term Exponential	$MR = a \exp(-kt) + (1 - a) \exp(-kat)$ (10)
Page modifié	$MR = \exp(-(kt)^n)$ (11)
Approche Diffusionnelle	$MR = a \exp(-kt) + (1 - a) \exp(-kbt)$ (12)

Avec, MR représente la teneur en eau réduite, t le temps et k, n, a, b, c les coefficients associés à chaque modèle.

Partie2 : Méthodes intelligentes

Les réseaux de neurones :

Les réseaux de neurones sont des systèmes mathématiques inspirés du fonctionnement du cerveau humain. Leur conception s'appuie sur les avancées en neurosciences, permettant ainsi des progrès significatifs dans leur développement.

Grâce aux avancées théoriques et pratiques récentes, ces modèles sont désormais largement employés dans divers secteurs (industrie, finance, services). Ils continuent néanmoins de susciter un vif intérêt dans la communauté scientifique, où les chercheurs cherchent à optimiser leurs performances et élargir leurs domaines d'application [26].

L'une des propriétés clés des réseaux de neurones est leur capacité d'approximation universelle parcimonieuse, ce qui en fait un outil mathématique particulièrement efficace pour la modélisation statique et dynamique de processus non linéaires. Si les neurones sigmoïdaux ont d'abord été choisis pour leur ressemblance biologique, cette justification s'est avérée moins pertinente dans les applications modernes de traitement du signal ou de modélisation. Ainsi, l'exploration d'autres architectures neuronales s'impose [27].

Ce chapitre propose une présentation générale des réseaux de neurones artificiels. Nous y abordons les concepts fondamentaux de modélisation, les différents types de réseaux, ainsi que les méthodologies

de conception. Enfin, nous illustrons leur application dans le domaine du séchage solaire, démontrant leur utilité dans ce contexte spécifique.

I.1 Historique de réseau de neurone :

L'histoire des réseaux de neurones s'est construite grâce à des avancées interdisciplinaires en psychologie, neurophysiologie et informatique. Les fondations ont été posées entre la fin du 19^{ème} siècle et le début du 20^{ème} siècle :

- **1890** : William James introduit le concept de mémoire associative, précurseur de la loi de Hebb [28]
- **1943** : Mc Culloch et Pitts créent le premier modèle mathématique du neurone [29]
- **1949** : Donald Hebb formule sa célèbre règle d'apprentissage synaptique [30]
- **1958** : Rosenblatt développe le perceptron, premier système capable d'apprentissage [31]
- **1960-1980** : Période de scepticisme suivie d'un renouveau avec :
 - Les réseaux adaptatifs de Widrow-Hoff
 - Les mémoires associatives de Kohonen et Anderson
 - L'algorithme de rétropropagation (Rumelhart, LeCun) [32]
- **1990s** : Essor des réseaux RBF (Moody-Darken) et cadre théorique de Vapnik [33]
- **2006** : Geoffrey Hinton et al. Introduisent l'apprentissage profond (deep learning) en Utilisant des réseaux de neurones profonds avec pré-entraînement couche par couche, marquant Le renouveau de l'intelligence artificielle modern [34]
- **2015-2016** : Développement des architectures ResNet, LSTM et Transformer (Vaswaniet al.), qui ont transformé les domaines de la vision par ordinateur et du traitement du langage naturel [35]
- **2025** : Développement de réseaux neuronaux efficaces et bio-inspirés, avec un accent [36]

Sur :

- L'intégration de l'IA dans les objets du quotidien.
- L'apprentissage auto-supervisé (Self-supervised learning) et continu (Continual learning).
- L'utilisation croissante de modèles hybrides combinant règles logiques et réseaux Neuronaux.

I.2 Réseaux de neurones et régression non linéaire :

En pratique, l'utilisation de régressions linéaires, non linéaires ou de réseaux de neurones pour approximer des fonctions déjà connues présente peu d'intérêt. Dans un contexte de modélisation, l'enjeu principal réside généralement dans le traitement d'un ensemble de mesures de variables $\{x_i\}$, issues d'un processus (physique, chimique, économique, financier, etc.), ainsi que du résultat associé (y_p). Modéliser ces données suppose l'existence d'une relation déterministe entre les variables et la grandeur observée. L'objectif est alors d'identifier une formulation mathématique de cette relation, valable dans le domaine d'étude couvert par les mesures [34].

Cependant, les conditions expérimentales introduisent plusieurs limites : les données disponibles sont en quantité finie, souvent bruitées, et certaines variables influençant le résultat peuvent ne pas être mesurées. Dans ce cadre, la construction d'un modèle revient à estimer une relation uniquement à partir des observations accessibles : on parle alors d'une approche "boîte noire". L'objectif est d'approcher la fonction inconnue reliant (y_p) aux variables $\{x_i\}$, c'est-à-dire celle qui serait obtenue avec une infinité de mesures exhaustives. Statistiquement, cela correspond à estimer la fonction de régression de la variable cible. Bien que cette fonction soit inaccessible, il est possible d'en proposer une approximation à partir des données disponibles.

Lorsque la relation sous-jacente est non linéaire, les réseaux de neurones se révèlent particulièrement adaptés pour cette tâche. Ainsi, comme évoqué précédemment, ils constituent une méthode avancée de régression non linéaire, étendant les techniques classiques de régression (linéaire ou multilinéaire) disponibles dans les logiciels d'analyse de données [35]. Contrairement aux idées reçues, la modélisation par réseaux de neurones ne relève pas de l'intelligence artificielle au sens traditionnel, mais s'inscrit plutôt dans le champ des statistiques appliquées. Le tableau I.1. illustre d'ailleurs les correspondances entre terminologie statistique et celle des réseaux de neurones [34].

En résumé, les réseaux de neurones sont avant tout des outils statistiques. Leur dénomination, inspirée de la biologie, et l'emploi du terme "apprentissage" ont parfois entretenu une certaine confusion sur leur nature réelle.

Tableau I-2 : Réseaux de neurones et statistiques conventionnelles

Réseaux de neurones	Statistiques conventionnelles
Choix de l'architecture	Choix de la famille de fonctions destinées à approcher la fonction de régression
Ensemble d'apprentissage	Observations
Apprentissage	Estimation des paramètres de l'approximation de la fonction de régression
Généralisation	Interpolation, extrapolation

I.3 Réseaux de neurones et modélisation de processus :

Les réseaux de neurones constituent une méthode performante pour modéliser des processus non linéaires, qu'ils soient statiques ou dynamiques. Leur efficacité repose principalement sur leur capacité à approximer des fonctions complexes avec une relative parcimonie (*approximation universelle*). Cette propriété en fait un outil privilégié. Par ailleurs, leur force réside aussi dans la nature générique des algorithmes d'apprentissage, qui s'adaptent à une grande variété de problèmes.

I.3.1 Modélisation du processus non linéaire statique :

Comme mentionné auparavant, la capacité des réseaux de neurones à approximer de manière parcimonieuse des fonctions universelles peut être judicieusement exploitée pour modéliser divers phénomènes statiques non linéaires. Cette propriété explique en grande partie leur adoption croissante dans les sciences de l'ingénieur. Afin de répondre à ce besoin de modélisation, des architectures non récurrentes, dites statiques, ont été développées. Globalement, ces réseaux établissent une correspondance algébrique non linéaire entre leurs variables d'entrée et de sortie. Dans le cadre du

traitement du signal et de l'automatique, un tel réseau agit comme un filtre transverse non linéaire en temps discret.

I.3.2 Modélisation du processus non linéaire dynamique :

Toujours grâce à leur remarquable capacité d'approximation universelle parcimonieuse, les réseaux de neurones se prêtent également à la modélisation de processus dynamiques. Pour ce faire, des architectures récurrentes, dites dynamiques, peuvent être conçues. Un tel réseau agit comme un filtre récursif non linéaire en temps discret. Cependant, il est possible de le représenter sous une forme canonique équivalente, composée exclusivement de neurones statiques.

I.3.3 Modèles de connaissance et modèles "boîte noire" :

Les réseaux de neurones sont fréquemment employés comme des modèles de type « boîte noire ». Cependant, ils peuvent également intégrer des connaissances a priori sur le phénomène étudié, offrant ainsi une solution intermédiaire idéale entre les approches purement data-driven et les modèles physiques explicites. On distingue classiquement [34] :

1. **Les modèles de connaissance** : leur formulation mathématique, caractérisée par un nombre restreint de paramètres ajustables, découle directement d'une analyse théorique (physique, chimique, économique, etc.) du processus.
2. **Les modèles « boîte noire »** : construits exclusivement à partir de données expérimentales, sans incorporation de connaissances externes sur le système.

I.3.3.1 Modèles dynamiques "boîtes noires" :

Pour modéliser un système dynamique, l'utilisation de réseaux récurrents (ou bouclés) s'impose, car ces architectures sont intrinsèquement dynamiques. L'apprentissage du réseau correspond alors à l'estimation des paramètres du modèle. Contrairement à une approche classique visant à annuler l'erreur de prédiction, l'objectif ici n'est pas de reproduire les perturbations non mesurables présentes dans les données expérimentales. Il s'agit plutôt de minimiser la variance de l'erreur de prédiction pour qu'elle corresponde à celle du bruit. Atteindre cet objectif signifie que le réseau est capable de capturer uniquement le comportement déterministe du processus, tout en ignorant les perturbations aléatoires. Ainsi, même si l'apprentissage s'effectue sur des données bruitées, le réseau peut reproduire la

dynamique idéale du système étudié. Des résultats théoriques [35] confirment la faisabilité de cette approche, et de nombreuses applications pratiques en démontrent l'efficacité.

I.3.3.2. Modèles neuronaux de connaissances :

Un atout méconnu des réseaux de neurones réside dans leur capacité à intégrer des connaissances mathématiques issues de l'analyse physico-chimique des processus, directement dans leur architecture. Bien que souvent négligée, cette approche hybride permet d'exploiter judicieusement les informations partielles ou complètes disponibles sur le système étudié. En combinant ainsi la transparence des modèles analytiques avec la puissance d'adaptation des réseaux neuronaux, on obtient une modélisation optimale. Comme l'ont démontré (Rivals et al., 1995), (Dreyfus, 1998) et (Ploix et Dreyfus, 1997), ces architectures deviennent alors de véritables modèles neuronaux de connaissance, bien loin du simple statut de "boîte noire".

I.3.4 Réseaux neuronaux et l'architecture des réseaux :

I.3.4.1 Définition et éléments caractéristiques d'un neurone :

Par définition un neurone formel est un petit automate de décision qui reçoit un nombre variable d'entrée et fournit une sortie unique par le biais d'une fonction d'activation ou de transfert généralement non-linéaire.

Un neurone artificiel, noté (i) est caractérisé par le couple suivant :

$$(P_i(t), W_i(t), n_i(t), f, g, h) \quad (1)$$

Avec :

$P_i(t) = (p_1(t), p_2(t), \dots, p_N(t)) \in \mathbb{R}_N$, \longrightarrow vecteur d'entrée à l'instant (t).

$W_i(t) = (w_1(t), w_2(t), \dots, w_N(t)) \in \mathbb{R}_N$, \longrightarrow vecteur des poids à l'instant (t).

$n_i(t) \in \mathbb{R}_N$ \longrightarrow état d'activation du neurone à l'instant (t). C'est l'état actuel du neurone.

Les trois fonctions qui caractérisent le neurone se définissent de la manière suivante :

$h : \mathbb{R}_N \times \mathbb{R}_N$, \longrightarrow \mathbb{R} , $s_i(t) = h(P_i(t), W_i(t))$, fonction de propagation qui génère le signal d'entrée $s_i(t)$. Cette fonction décrit le traitement de l'information qui est fait par le neurone

;

$g : \mathbb{R} \times \mathbb{R}$, \longrightarrow \mathbb{R} , $n_i(t) = g(s_i(t), n_i(t-1))$, fonction d'activation, qui calcule l'état

d'activation $n_i(t)$ à l'instant t . Cette fonction sert au calcul de la transformation de l'état d'activation à un instant ultérieur $(t + 1)$;

$f : \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$, $a_i(t) = f(n_i(t))$, fonction de sortie, qui donne la sortie $a_i(t)$ du neurone (i) à l'instant t . Elle calcule la valeur de sortie d'un neurone en fonction de son état d'activation.

Selon la qualité des données d'entrée, on distingue le neurone à une entrée simple et le neurone à entrées multiples.

I.3.4.2 Neurone à une entrée simple :

Le modèle de neurone de la figure I.9, est le modèle de base d'un neurone à une entrée simple. La donnée d'entrés est un scalaire "p ". Dans le fonctionnement du neurone, la donnée d'entrée "p" est multiplié par un poids "w" et additionné à un scalaire ou biais "b". La somme de sortie "n" ou entrée du réseau passe dans la fonction de transfert "f " qui produit la donnée de sortie "a".




Figure I-9 : Modèle d'un neurone artificiel à une entrée simple.

I.3.4.3 Neurone à des entrées multiples :


Pour ce modèle de neurone, schématisé par la figure I.10, l'entrée est un vecteur "p" d'entrées individuelles "pi". Chaque scalaire d'entrée est pondéré par un poids "w_{1.i}". L'ensemble de ces poids constitue une matrice "W ". L'entrée "n", obtenue ajoutant la constante "b" ou biais, est donnée par la formule suivante :

$$n = W_p + b \quad (2)$$

La sortie du neurone est donnée par la formule suivante :

$$a = f(n) \quad (3)$$

Les neurones sont les composantes de base des structures plus complexes appelées réseaux de neurones.



$$a = f(W_p + b)$$

Figure I-10 : Modèle d'un neurone artificiel à entrées multiples simple.

I.3.4.4 Réseaux de neurones :

Un réseau de neurones artificiels se compose de trois couches principales comme suit : une couche d'entrée, N-couche (s) cache (s) et une couche de sortie. Chaque couche est interconnectée avec l'autre couche par des neurones, également appelés nœuds.

Habituellement, l'établissement du modèle neuronal artificiel passe par trois étapes, qui sont l'apprentissage, la validation et le test. Au cours de ces étapes, le traitement des données passe des neurones de la couche émettrice vers les neurones de la couche réceptrice sous forme des poids et des biais. En outre, le signal de retour d'erreur permet de mapper entre les variables d'entrée et de sortie afin de réussir le résultat désiré. Un réseau de neurones peut être regroupé en deux catégories :

- Un réseau avec une architecture non bouclée (Feed-forward) (Figure I-11).
- Un réseau avec une architecture bouclée (Recurrent).

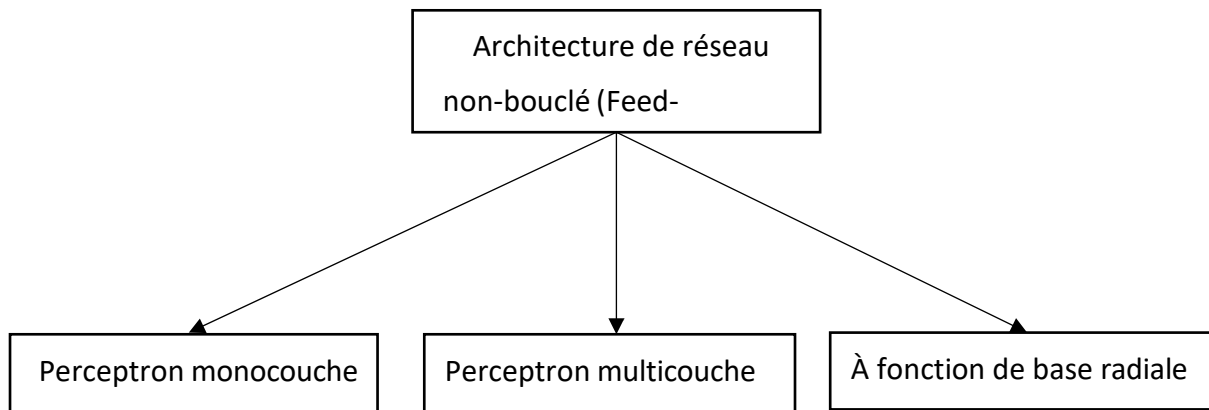


Figure I-11 : Taxonomie d'architectures du réseau neurone non-bouclé. Simple.

I.3.4.4.1 Réseaux de neurones bouclés (feedback networks) :

Un réseau est bouclé, ou dynamique, si son graphe possède au moins un cycle. Il constitue un filtre récuratif non linéaire à temps discret. Comme pour les réseaux non bouclés, il y a un intérêt, pour l'apprentissage, à mettre le réseau sous une forme canonique, constituée de neurones statiques. En effet, tout réseau de neurones bouclé à temps discret, peut être mis sous une forme canonique comprenant un réseau de neurones statiques. Ainsi, les propriétés générales des réseaux de neurones, bouclés ou non, dépendent donc des propriétés des réseaux de neurones non bouclés. La détermination de cette forme canonique n'est en général pas univoque.

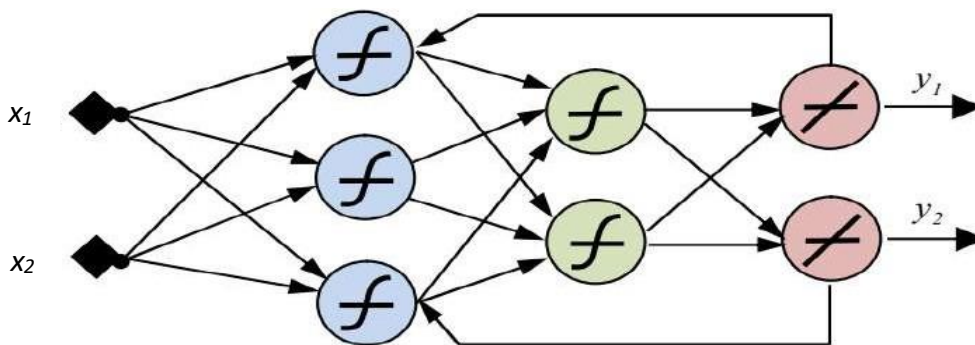


Figure I-12 : Schéma de réseau de neurones bouclé. [36]

I.3.4.4.2 Réseaux de neurones non-bouclés (feed-forward networks) :

Un réseau de neurones est dit non bouclé, ou statique lorsque son graphe ne possède pas de cycle. Un tel réseau, réalise donc une transformation entrée-sortie non linéaire paramétrée. Pour faciliter l'apprentissage, la transformation du réseau sous une forme équivalente, dite forme canonique est indispensable. Cette forme a l'avantage de faire apparaître les entrées effectives du réseau à chaque instant, et d'uniformiser toutes les connexions. L'architecture d'un réseau non bouclé, la plus générale est celle du réseau complètement connecté. Tous les neurones cachés

et les neurones de sortie sont connectés aux unités d'indice inférieur. Une architecture historiquement très utilisée, surtout en raison de sa pertinence en classification, est celle du réseau à couches : les neurones cachés sont répartis en couches successives, les neurones appartenant à une couche donnée n'étant commandés que par les neurones de la couche précédente, et ceux de la première couche n'étant connectés qu'aux entrées externes.




Figure I-13 : Schéma d'un réseau de neurones non bouclé. [36]

I.3.4.4.3 Architecture en couches de neurones :

Les réseaux performants sont généralement constitués de plusieurs entrées et de plusieurs neurones en parallèle. Un ensemble de neurones parallèles constitue une couche de neurones, comme indiqué par la figure I.14.

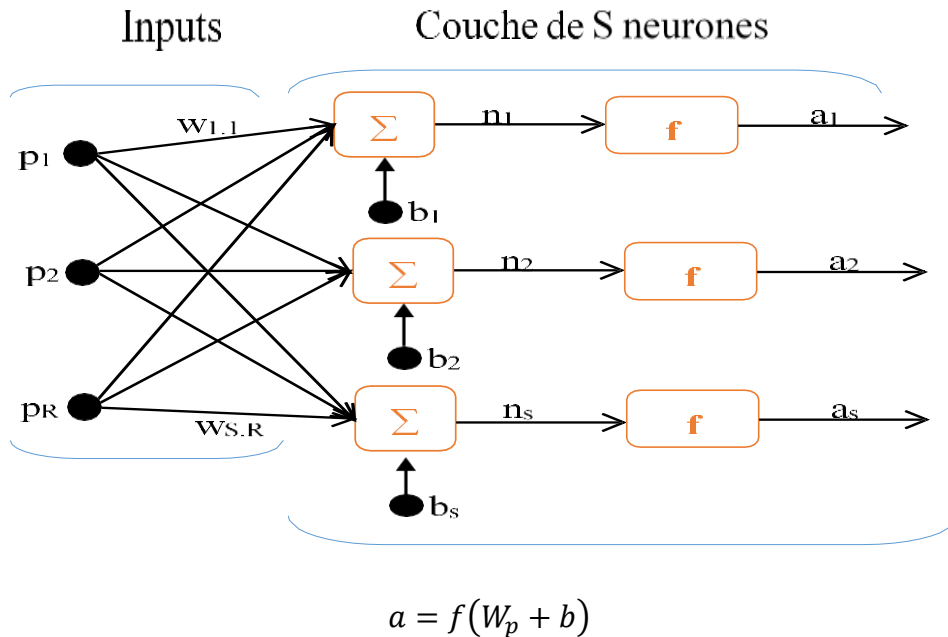


Figure I-14 : Réseau de neurones à une couche simple.

Un réseau de neurones peut comporter plusieurs couches : une couche de sortie et une ou plusieurs couches cachées, intermédiaires entre l'entrée et la sortie. Les réseaux multicouches sont plus puissants que les réseaux à simple couche. Dans la pratique, un réseau ne comporte que 2 à 3 couches. Un réseau à trois couches cachées est illustré sur la figure I.15.

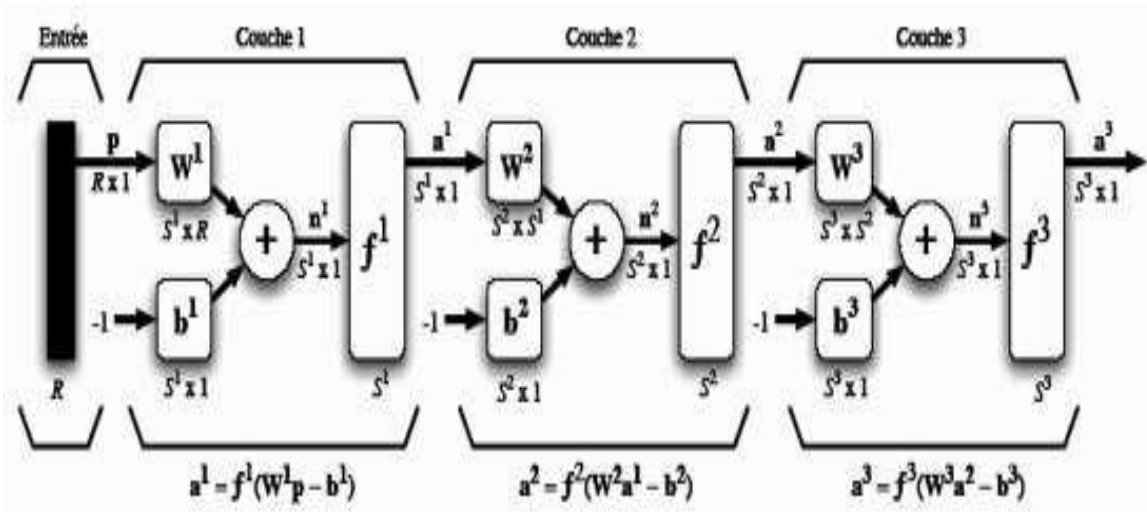


Figure I-15 : Réseau de neurones à deux couches cachées simple.

I.3.4.4 Réseau de type Perceptron multicouche (PMC) :

Le perceptron multicouche est un type de réseau de neurones (figure I.16), qui se présente en couches successives et continues de neurones, de l'entrée à la sortie. Pour des neurones de même couche, il n'existe pas de connexions latérales.




Figure I-16 : Perceptron multicouches (PMC).

Le perceptron multicouche est principalement utilisé pour effectuer les tâches suivantes : l'approximation de fonction, la classification, la modélisation de processus statiques non linéaire. L'apprentissage d'un tel réseau, requiert une optimisation paramétrique, dans un espace multidimensionnel. La méthode utilisée est celle de la retro-propagation du gradient [37].

I.3.5 Fonctions de transfert du Perceptron Multi-Couche :




Figure I-17 : Fonctions de transfert d'un réseau de neurones. [36]

Pour réaliser les différentes opérations dans les neurones, la majorité des logiciels dispose de plusieurs fonctions de transfert, offrant une infinité de valeurs possibles dans l'intervalle $[-1, +1]$. La figure I.17 représente, les trois fonctions les plus utilisées :

- (a) la fonction escalier [37].
- (b) la fonction linéaire [38].
- (c) la fonction sigmoïde [31].

I.3.6 Mise en œuvre des réseaux de neurones :

I.3.6.1 Protocole d'utilisation :

Lorsque le réseau de neurones a été créé, son utilisation doit suivre les trois étapes énumérées ci-dessous :

- Initialisation des poids et biais.
- Apprentissage selon une base de données connue.
- Modélisation avec de nouvelles données.

Avant l'utilisation de nouvelles données pour la simulation, l'optimisation du réseau de neurones s'impose. De cette optimisation dépendra, en grande partie sa performance.

I.3.6.2 Optimisation du réseau de neurones :

Après le choix des neurones d'entrées, l'optimisation du réseau demande de procéder :

- Aux choix du nombre de couches cachées ;
- Au choix du nombre de neurones par couches cachées ;
- Au choix de la fonction de transfert ;
- Au choix des paramètres d'apprentissage ;

L'optimisation de l'apprentissage est une entreprise difficile. Il faut, réaliser entre ces différents paramètres, un équilibre, bien fragile. En général le choix de la fonction de transfert ne pose aucun problème, car il est limité. Malheureusement, il n'existe pas de travaux théoriques conséquents sur le dimensionnement de la couche cachée. Dans une démarche empirique, certains auteurs proposent certaines solutions, qui consistent à prendre un nombre de neurones de la couche cachée égal :

- Au nombre de neurones de la couche d'entrée ;
- Aux trois quarts du nombre neurones de la couche d'entrée ;
- À la racine carrée du produit des nombres de neurones d'entrée et de sortie.

En définitive cette optimisation relève encore de l'expérience. L'apprentissage achevé, le réseau devient un outil viable pour la simulation.

I.3.6.3 Algorithme de rétro-propagation :

L'algorithme de rétro-propagation du gradient utilise de manière itérative la méthode du gradient pour minimiser un critère quadratique d'erreur, entre la sortie calculée et la sortie attendue du réseau.

Par la propagation avant de l'information, nous calculons pour chaque exemple de la base d'apprentissage, les états X_i de chaque neurone et de chaque couche, de l'entrée vers la sortie. L'algorithme de rétro-propagation commence, en considérant à la base, un neurone "i" de la couche "j" et d'état n_i^j pour lequel on a :

$$n_i^j = f(u_i^j) \quad (4)$$

$$u_i^j = \sum_k w_{ik}^j n_k^{j-1} \quad (5)$$

Avec u_i^j l'activation totale reçue par le neurone i , des autres neurones de la couche précédente ($j-1$), f , la fonction d'activation et w_{ik}^j le poids de connexion entre le neurone i de la couche j et

Le neurone k de la couche ($j-1$).

La fonction d'activation du neurone doit être une fonction indéfiniment dérivable. En général nous utilisons la fonction sigmoïde. Ensuite, on peut procéder au calcul de l'erreur du réseau :

- de la couche de sortie par la formule suivante :

$$e_k^{(q)} = f'(u_k^{(q)})(t_k^{(q)} - n_k^{(q)}) \quad (6)$$

Avec : $t_k^{(q)}$ la sortie désirée du neurone k de la couche de sortie.

- sur chaque couche intermédiaire j :

$$e_k^{(j)} = f'(u_k^{(j)}) \sum_i w_{ki}^{(j+1)} e_i^{(j+1)} \quad (7)$$

Enfin, on peut procéder une mise à jour des poids w_{ik} selon la formule suivante :

$$\Delta w_{ik}^{(j)} = \omega e_i^{(j)} x_k^{(j-1)} \quad (8)$$

Avec ω le pas d'apprentissage.

Le processus est répété tant que l'erreur en sortie n'est pas inférieure à une limite fixée. Le processus peut aussi s'arrêter lorsque le nombre d'itérations ou époques atteint le nombre maximum d'itérations choisi.

I.3.6.4 Apprentissage, généralisation, sur-apprentissage et minimums locaux :

Dans le fonctionnement d'un réseau de neurones, il faut considérer deux phases importantes : l'apprentissage et la généralisation.

A partir d'une base d'apprentissage, constituée par un ensemble fini de couples (d'entrées-sorties mesurés), le processus d'apprentissage sert à faire correspondre les entrées et les sorties en adaptant les poids des connexions progressivement, de manière itérative. Ainsi l'apprentissage constitue en réalité un processus d'optimisation qui permet de trouver des coefficients du réseau, tout en minimisant une fonction de coût. Il doit en effet engendrer une très faible erreur d'apprentissage.

Pendant la généralisation, le réseau de neurones utilise les valeurs des poids des connexions retenus grâce à l'apprentissage, pour traiter des données différentes. La performance du réseau de neurones sera jugée par son pouvoir de généralisation élevé, en générant une erreur test très faible.

Une bonne généralisation doit être précédée d'un bon apprentissage. La phase d'apprentissage est donc essentielle. Sa performance peut s'accroître non seulement par une taille suffisante de la base d'apprentissage mais aussi, en considérant un nombre important d'itérations, lors de l'apprentissage. Mais la génération d'un nombre important d'itérations, peut provoquer l'apparition du phénomène de sur-apprentissage, avec une erreur test élevée et du phénomène du minimum local, dont les plus significatifs se situent dès les premières itérations. Il faut donc trouver une méthode permettant de déterminer le nombre de neurones approprié dans la couche cachée, tout en remédiant aux phénomènes de sur-apprentissage et de minimums locaux [39].

I.4 Critères de validation des modèles :

Il existe plusieurs paramètres statistiques pour valider le modèle mathématique avec les résultats expérimentaux. Pour ce travail, nous pouvons retenir les paramètres suivants :

- Le coefficient de corrélation R^2 C'est l'un des premiers paramètres pour évaluer une bonne modélisation. Plus il est proche de l'unité, plus le modèle est satisfaisant.

- Le paramètre statistique RMSE ou erreur systématique moyenne [40].
- Il est utilisé par plusieurs auteurs. Il quantifie le bruit dans les données [41].

$$R^2 = 1 - \frac{\sum(MR_{exp} - MR_{pred})^2}{\sum(MR_{exp} - \overline{MR_{exp}})^2} \quad (7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (MR_{exp} - MR_{pred})^2} \quad (8)$$

Le paramètre MSE ou erreur quadratique moyenne. Au sujet de cette grandeur [42], soulignent qu'il est identique au paramètre khi carré réduit X^2 D'ailleurs, certains auteurs comme [43]. Ont préféré utiliser dans leurs études, cette seconde désignation, en parlant du même paramètre. Ainsi, les deux paramètres, plutôt identiques, se définissent par la formule suivante :

$$MAE = \frac{1}{N} \sum_{i=1}^N |MR_{exp} - MR_{pred}| \quad (9)$$

Avec :

N : ne nombre de points expérimentaux.

Conclusion :

La modélisation des processus de séchage révèle une complexité intrinsèque, nécessitant la prise en compte de multiples interactions entre transferts de chaleur et de masse, ainsi que des propriétés variables des produits. Face à ces défis, les réseaux de neurones émergent comme une solution innovante, remplaçant les approches analytiques rigides par une modélisation adaptative basée sur les données. Leur capacité à capturer des relations non linéaires et à s'ajuster aux spécificités expérimentales en fait des outils particulièrement efficaces pour prédire la cinétique de séchage et optimiser les performances des systèmes, comme en témoignent les applications récentes dans le domaine des énergies renouvelables et de l'agroalimentaire. Ces avancées ouvrent la voie à une industrialisation plus efficace et durable des procédés de séchage.

Chapitre II : Matériels et méthodes.

Introduction :

Ce chapitre aborde la modélisation du taux d'humidité (MR) des tomates durant leur séchage, en combinant des approches empiriques et une méthode avancée basée sur les réseaux de neurones artificiels. Les méthodes empiriques retenues (Newton, Page, Henderson et Pabis, et Logarithmique) permettent de décrire la cinétique de séchage à travers des équations paramétriques, ajustées à l'aide d'un programme MATLAB. Parallèlement, un modèle de perceptron multicouche (MLP) est développé pour capturer les relations complexes et non linéaires entre le temps de séchage et le MR. Les données utilisées, issues d'un dispositif expérimental simulant le rayonnement solaire avec une lampe halogène, sont analysées à l'aide d'indicateurs statistiques (R^2 , RMSE, MAE) afin d'évaluer la performance des différents modèles. Cette étude vise à identifier la méthode la plus précise pour prédire l'évolution de l'humidité, offrant ainsi des perspectives utiles pour l'optimisation des procédés de séchage dans l'industrie agroalimentaire.

II.1 Les données utilisées :

Le séchage des tomates a été effectué en utilisant une lampe halogène d'une puissance de 1000 W. Cette lampe fait partie du banc d'essai ET 200 qui existe au niveau des laboratoires de génie mécanique de l'université de M'sila. Les données de l'évolution de taux d'humidité (MR) en fonction du W pour simuler le rayonnement solaire [44]. Le schéma du dispositif expérimental est illustré sur la Figure II.1. Ces temps pour les tomates locales sous une intensité de rayonnement de 1360 Wm^2 ont été extraites à partir du travail d'Ihaddadene et al. 2025[44]. Ces données regroupent un nombre de 129 valeurs avec 5 minutes d'intervalle.



Figure II.1 : Dispositif expérimental [44].

La mesure de la variation de la masse des tomates séchées est un paramètre crucial pour comprendre le processus de séchage (la cinétique de séchage) [45]. Dans l'étude de la cinétique de séchage, on s'intéresse à l'étude de la teneur en humidité (M_t) et le taux d'humidité (MR).

- **Le teneur en eau des tomates** (M_t) à l'instant t est exprimée selon la formule suivante :

$$M_t = \frac{(mt - ms)}{ms} \quad (1)$$

Avec:

mt : la masse des tomates au temps t ;

ms : la masse sèche des tomates ;

- **Le taux d'humidité des tomates** (MR) à l'instant t est donné par la formule suivante :

$$MR = \frac{M_t}{M_0} \quad (2)$$

Avec:

M_0 : la teneur en eau initiale des Tomates.

II.2 Les méthodes empiriques :

Dans cette étude on a choisie 4 méthodes empiriques à savoir ; la méthode de Newton, la méthode de Page, la méthode de **Henderson et Pabis** et la méthode **Logarithmique pour décrire la cinétique de séchage des tomates. Ci-méthodes sont décrites comme :**

Méthode 1 : Méthode de Newton

Ce modèle d'écrit l'évolution de MR en fonction du temps en utilisant l'équation suivante [46] :

$$MR = e^{(-k \times t)} \quad (3)$$

Avec :

k : Constante de séchage.

t temps (min)

Méthode 2 : Méthode de Page

MR en fonction du temps utilisant li équation suivante [47] :

$$MR = e^{(-k \times t^n)} \quad (4)$$

Avec :

k : Constante de séchage.

n : Exposant de courbure.

Méthode 3 : Méthode de Henderson et Pabis

MR en fonction du temps utilisant li équation suivante [48] :

$$MR = a \times e^{(-k \times t)} \quad (5)$$

Les coefficients a et k sont les coefficients empiriques e ce modèle.

a,k, Coefficients empiriques.

Méthode 4 : Méthode Logarithmique

MR en fonction du temps utilisant li équation suivante [49] :

$$MR = a \times e^{(-k \times t)} + c \quad (6)$$

Les coefficients a,k et c sont les coefficients empiriques e ce modèle.

Afin de terminaison les coefficients (a,k,c,n) de chaque équation(selon le cas) utilisée par ajuster le modèle avec la courbe expérimentale de l'évolution de MR en fonction de temps des tomates, un programme en MATLAB a été développé.

II.3 Analyse statistique :

Les indicateurs statistiques R^2 , RMSE et MAE permettent d'évaluer et de comparer la performance des différentes méthodes de modélisation.

Le coefficient de détermination R^2 (proche de 1) mesure la proportion de variance expliquée par le modèle, indiquant sa capacité à reproduire les tendances des données.

Le RMSE (Root Mean Square Error) quantifie l'écart moyen quadratique entre les valeurs prédites et réelles, pénalisant davantage les grandes erreurs.

Le MAE (Mean Absolute Error) représente l'erreur absolue moyenne, offrant une interprétation plus directe des écarts.

Une méthode optimale affichera un R^2 élevé (idéalement >0.9), accompagné de faibles valeurs de RMSE et MAE, signe à la fois de précision et de robustesse. La comparaison de ces indicateurs entre différents modèles (comme MLP, modèles linéaires ou autres architectures de réseaux de neurones) permet d'identifier la méthode la plus fiable pour prédire la cinétique de séchage.

II.3.1 Coefficient de Détermination (R^2) :

- **Définition** : Mesure la proportion de la variance expliquée par le modèle ($0 \leq R^2 \leq 1$) [50].
- **Équation** :

$$R^2 = 1 - \frac{\sum(MR_{exp} - MR_{pred})^2}{\sum(MR_{exp} - \overline{MR_{exp}})^2} \quad (7)$$

Avec :

- MR_{exp} = Valeur expérimentale,

- MRpred = Valeur prédite par le modèle,

- **Interprétation :**

- $R^2 \approx 1$ → Excellent ajustement.
- $R^2 < 0.9$ → Modèle peu fiable.

II.3.2 Racine de l'Erreur Quadratique Moyenne (RMSE) :

- **Définition :** Mesure l'écart moyen entre les valeurs expérimentales et prédites [51].
- **Équation :**

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (MR_{exp} - MR_{pred})^2} \quad (8)$$

Où :

- N= Nombre de points de données.

- **Interprétation :**

- **RMSE faible** → Précision élevée.
- **RMSE élevé** → Forte dispersion des erreurs

II.3.3 L'Erreur Moyenne Absolue (MAE - Mean Absolute Error) :

- **Définition :** Mesure l'écart moyen entre les valeurs expérimentales et prédites [52].
- **Équation :**

$$MAE = \frac{1}{N} \sum_{i=1}^N |MR_{exp} - MR_{pred}| \quad (9)$$

- **Interprétation :**

- **MAE faible** → Modèle précis (erreurs faibles).
- **MAE élevé** → Fortes divergences entre théorie et expérience.
- **Unité :** La même que la grandeur mesurée (ex : g au/g matière sèche).

Nous avons développé un programme pour comparer MR_{pred} et MR_{exp} pour chaque modèle.

II.4 Méthode les réseaux de neurone :

Dans cette étude, un réseau de neurones artificiels (RNA) a été développé sous MATLAB afin de modéliser l'évolution du rapport d'humidité (MR) des tomates en fonction du temps de séchage. L'objectif principal était de proposer une approche non linéaire et performante permettant d'estimer avec précision la dynamique de séchage à partir des données expérimentales.

Le réseau utilisé est illustré sur la Figure II.2, c'est un réseau de type perceptron multicouche (MLP – Multilayer Perceptron), comportant une couche d'entrée, une ou plusieurs couches cachées, et une couche de sortie. La variable d'entrée était MR et la sortie attendue était le MR correspondant. Les données expérimentales ont été normalisées entre 0 et 1 afin d'assurer une meilleure convergence de l'algorithme d'apprentissage.

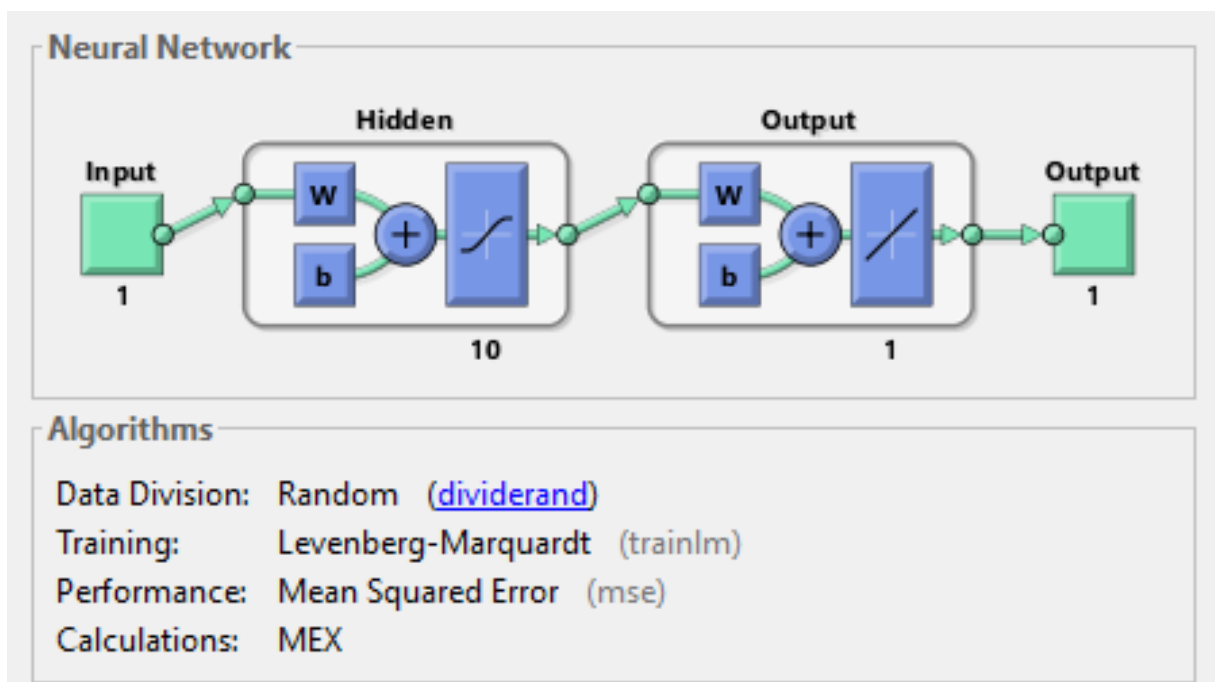


Figure II.2 Schéma du réseau de neurone utilisé.

Après avoir normalisé les données (temps et teneur en eau), le réseau est configuré avec une architecture personnalisable (nombre de couches et neurones), une fonction d'apprentissage ajustable (comme 'trainlm' pour Levenberg-Marquardt) et une répartition définie des données (80% entraînement, 10% validation, 10% test). Une fois entraîné, le modèle évalue ses performances via des métriques telles que le RMSE, MAE et R^2 , puis affiche graphiquement une comparaison entre les valeurs réelles et prédites de la teneur en eau. Cette approche permet

une modélisation flexible et précise du processus complexe et non linéaire du séchage des fraises.

L'architecture optimale du réseau a été déterminée de manière empirique en testant plusieurs configurations. Le modèle final comprenait :

- Une couche d'entrée avec un seul neurone (MR),
- Une couche cachée, chacune avec X neurones (à adapter selon le cas),
- Une fonction d'activation sigmoïde (logsig) dans les couches cachées,
- Une couche de sortie avec un neurone linéaire (purelin), représentant le MR.

L'apprentissage a été réalisé en utilisant l'algorithme de rétropropagation avec la méthode de Levenberg-Marquardt (trainlm), réputée pour sa rapidité de convergence et sa robustesse pour les problèmes de régression. La base de données a été divisée en trois sous-ensembles : 80 % pour l'apprentissage, 10 % pour la validation, et 10 % pour le test.

L'évaluation des performances du modèle a été réalisée à l'aide de plusieurs indicateurs statistiques, notamment :

- L'erreur quadratique moyenne (MSE),
- Le coefficient de détermination (R^2),

Les résultats de ces différentes méthodes seront regroupés et discutés dans le chapitre 3.

Conclusion :

Dans cette étude, on s'intéresse au séchage des tomates (4 mm d'épaisseur) sous un rayonnement solaire simulé de 1360 W/m^2 dans le laboratoire dans le but d'étudier sa cinétique. Les données de l'évolution de MR en fonction de temps ont été enregistrées chaque 5 minute, ces données comportent 129 valeurs.

Dans ce chapitre nous avons proposé deux méthodes pour l'étude de la cinétique de séchage des tomates à savoir ; les méthodes empiriques et la méthode utilisant le réseau de neurones (MLP). Les méthodes empiriques regroupent le modèle de Newton, le modèle de Page, le modèle de Henderson et Pabis, et le modèle Logarithmique. La validation de ces modèles a été effectué en se basant sur les indices statistiques (R^2 , RMSE et MAE).

Chapitre III :

Résultats et discussion.

Introduction :

Ce chapitre présente une analyse comparative des méthodes utilisées pour modéliser la cinétique de séchage des tomates sous rayonnement halogène. Deux approches principales sont étudiées : les **modèles empiriques** (Henderson and Pabis, Logarithmique, Newton et Page) et une **méthode basée sur les réseaux de neurones artificiels (RNA)**. Les modèles empiriques, caractérisés par leur simplicité et leur interprétabilité physique, sont évalués à travers leurs coefficients et leurs performances statistiques (R^2 , RMSE, MAE). Parallèlement, l'approche par RNA, plus complexe mais capable de capturer des relations non linéaires, est examinée en détail via des indicateurs de convergence, d'erreur et de régression.

III.1 Méthodes empiriques :

Durant notre étude, on a testé quatre modèles empiriques ; le modèle de Henderson and Pabis, modèle Logarithmique, modèle de Newton et le modèle de Page pour déterminer l'évolution du taux d'humidité(MR) en fonction du temps des tomates séchées en utilisant une lampe halogène.

III.1.1 Coefficients des modèles testés :

Le tableau III.1 regroupe les coefficients de chaque modèle (Henderson and Pabis, Logarithmique, Newton et Page) testés durant notre étude. Notant que les modèles de Henderson and Pabis et Page sont à deux paramètres (a, k) et (n, k) respectivement. Le modèle de Newton est à un seul paramètre et le modèle Logarithmique est à quatre paramètres (n, a, k, et c).

Tableau III.1 : Coefficients de chaque modèle.

Modèles	n	a	k	c
Henderson and Pabis	1	1	0.1	0
Logarithmique	1	0.1	1	0.1
Newton	1	1	0.1	0
Page	1	1	0.1	0

III.1.2 Evolution des différents modèles

Après avoir déterminé les coefficients de chaque modèle, on a tracé chaque modèle dans un graphe avec les valeurs expérimentales du taux d'humidité ; le modèle de Henderson and Pabis (Figure III.1), le modèle Logarithmique (Figure III.2), le modèle Newton (Figure III.3) et le modèle de Page (Figure III.3). On constate que les différents modèles évoluent différemment.




Figure III.1 : Evolution de MR selon le modèle Henderson and Pabis.




Figure III.2 : Evolution de MR selon le modèle Logarithmique.

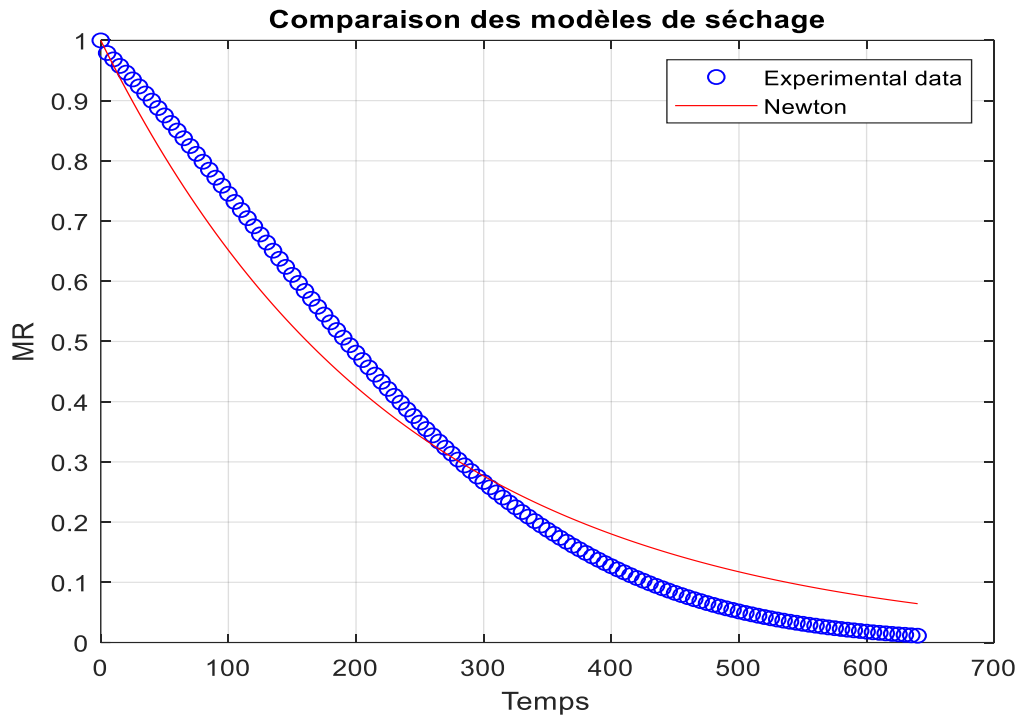


Figure III.3 : Evolution de MR selon le modèle Newton.

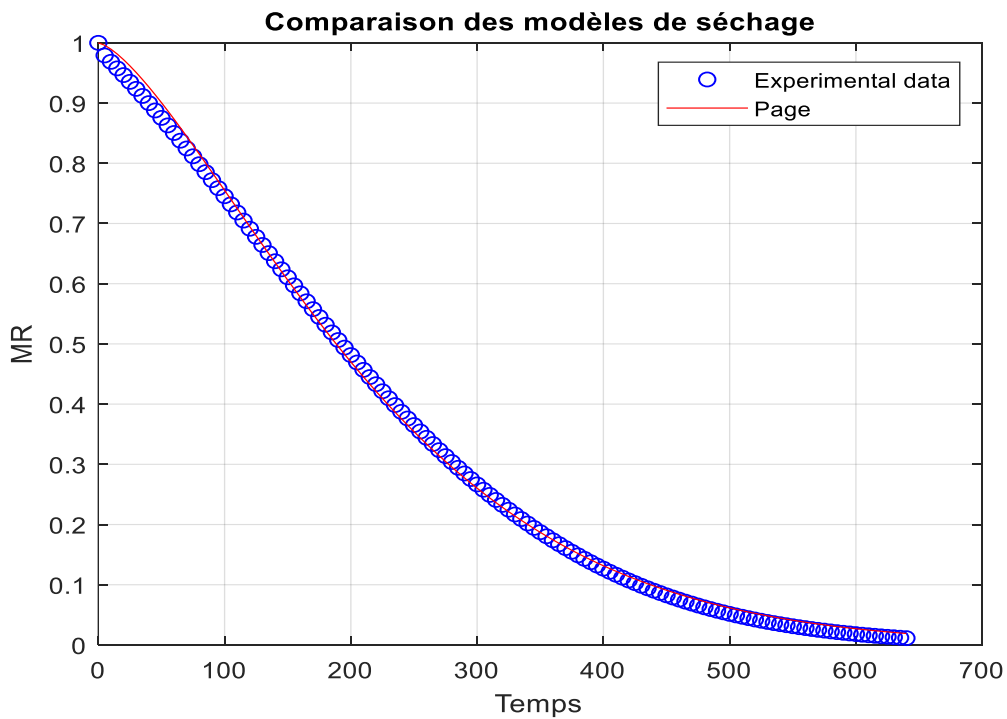


Figure III.4 : Evolution de MR selon le modèle Page.

L'analyse du modèle Henderson and Pabis montre qu'il offre une approximation raisonnable mais imparfaite de la cinétique de séchage des tomates comme décrit dans la Figure III.1. Le modèle reproduit correctement la tendance générale de diminution de la MR, passant de 1,2 à 0 sur 700 minutes, mais présente des écarts notables par rapport aux données expérimentales. En phase initiale (0-50 min), il tend à surestimer légèrement le taux de séchage, tandis qu'en fin de processus (>300 min), les prédictions s'éloignent progressivement des valeurs réelles.

Le modèle Logarithmique démontre une performance remarquable pour la prédiction des cinétiques de séchage, comme en témoigne son excellente adéquation avec les données expérimentales comme décrit dans la Figure III.2. Il capture parfaitement les trois phases clés du processus : la déshydratation rapide initiale (0-200 min), la transition progressive vers un régime plus lent (200-500 min), et la stabilisation finale (>500 min). Mais on note une petite divergence au début et à la fin du séchage.

Le modèle de Newton suit globalement la tendance exponentielle des données réelles comme indiqué sur la Figure III.3, avec une diminution progressive de la teneur en eau de 1 à 0. Cependant, plusieurs écarts significatifs sont observables : dans la phase initiale (0-250 min), le modèle sous-estime légèrement MR ; entre 200 et 400 minutes, l'accord est meilleur ; tandis qu'en fin de processus (>350 min), des divergences réapparaissent et le modèle surestime MR.

La courbe de prédiction du modèle de Page montre un accord exceptionnel avec les données expérimentales de séchage des tomates sur l'ensemble des 700 minutes comme décrit dans la Figure III.4. Le modèle reproduit avec une fidélité remarquable la décroissance progressive de la teneur en eau, depuis la valeur initiale de 1 jusqu'à l'état sec. Contrairement aux autres modèles comme celui de Newton, Henderson and Pabis et Logarithmique, la courbe de Page épouse parfaitement les points expérimentaux à toutes les étapes du processus, sans déviation notable ni en phase initiale accélérée, ni lors du ralentissement final.

III.1.2 Comparaison des modèles empiriques

Pour faire la comparaison des quatre modèles (Henderson and Pabis, Logarithmique, Newton et Page) une analyse statistique en utilisant R^2 , RMSE et MAE a été effectuée, ces résultats sont regroupés dans le tableau III.1.2.

Tableau III.2 : Analyse statistique des différents modèles.

Modèles	R ²	RMSE	MAE
Henderson and Pabis	0.97743	0.0021482	0.041675
Logarithmique	0.99407	0.00056454	0.020637
Newton	0.96311	0.003511	0.054094
Page	0.99865	0.00012826	0.0095196

De même, la Figure III.5 illustre les données de MR issues des quatre modèles testés (Page, Newton, Henderson & Pabis, Logarithmique) et les données expérimentales en fonction du temps (0 à 700 mins). Les courbes montrent que tous les modèles convergent vers MR=0, mais avec des dynamiques différentes : le modèle Henderson and Pabis présente des écarts intermédiaires, particulièrement au début et à la fin du séchage où leur courbe s'éloigne légèrement des points expérimentaux. Ces limitations, qui reflètent la nature simplifiée de cette approche semi-empirique, expliquent ses performances intermédiaires (R²=0,977, RMSE=0.0021482 et MAE=0.041675). Le modèle Henderson and Pabis ne soit pas optimal pour des applications nécessitant une haute précision, il conserve un intérêt certain pour des estimations rapides et des analyses préliminaires, grâce à sa simplicité mathématique et sa facilité d'implémentation.

Le modèle Logarithmique semble suivre de près les données réelles sur l'ensemble de la plage temporelle, avec un coefficient de détermination R² de 0,994, une erreur RMSE de seulement 0,00056 et une erreur MEA de 0.020637, ce modèle se distingue par sa précision et sa fiabilité. Cette performance s'explique par la capacité de l'équation logarithmique à intégrer les différents mécanismes physiques impliqués dans le transfert d'humidité. Comparé aux autres modèles empiriques, il présente l'avantage d'allier simplicité mathématique et grande précision prédictive, ce qui en fait un outil particulièrement adapté pour l'application du séchage nécessitant un contrôle précis des paramètres de séchage.

Le modèle de Newton pourrait surestimer MR en phase initiale et sous-estimer MR en phase finale. Ces limitations sont visibles sur la Figure III.3 et la Figure III.5, confirment les résultats de l'analyse statistique (R²=0,963, RMSE=0,0035 et MEA= 0.054094) et expliquent pourquoi le modèle de Newton, bien qu'utile pour une première approximation, présente une précision inférieure à d'autres modèles. Le modèle de Newton étant adapté pour des estimations rapides mais moins fiable pour un contrôle précis du procédé de séchage.

Le modèle de Page apparaissant comme le plus précis comme illustré sur la Figure III.4 ou la Figure III.5, bien qu'avec les indicateurs statistiques ; R^2 (0.99865), RMSE (0.000128) et MAE (0.0095196). Le R^2 présente la valeur la plus élevée de tous les modèles et RMSE et MAE les valeurs les plus faibles, ce qui justifie son bon ajustement des données expérimentaux.

De ce fait, le modèle de Page capture idéalement les mécanismes complexes du séchage. La formulation mathématique de ce modèle, qui intègre à la fois les phénomènes de diffusion et les transferts de surface, explique sa supériorité pour ce type d'application. Ces résultats suggèrent que le modèle de Page devrait être privilégié pour optimiser les procédés de séchage de tomates en utilisant une lampe halogène, où une prédiction précise de la cinétique est essentielle pour garantir la qualité du produit tout en minimisant les coûts énergétiques.




Figure III.5 : Comparaison des modèles empiriques.

III.2 Méthode les réseaux de neurone :

III.2.1 Convergence :

Le Figure III.6 présente les résultats d'entraînement d'un modèle d'apprentissage automatique évalué sur 15 époques, avec une mesure d'erreur quadratique moyenne (MSE). La meilleure performance de validation est atteinte à la 9ème époque avec une MSE extrêmement faible de **4,3397e-06**, indiquant une grande précision du modèle. Les courbes d'entraînement, de validation et de test montrent une décroissance rapide de l'erreur avant de se stabiliser, sans

signe de sur-apprentissage, ce qui suggère une bonne généralisation. Ces résultats démontrent l'efficacité du modèle pour la tâche concernée




Figure III.6 : courbe de performance.

III.2.2 Etat d'entraînement :

La Figure III.7 présente trois indicateurs clés du processus d'entraînement d'un réseau de neurones. La valeur du gradient ($9.6677e-06$) à l'epoch 15 indique que l'algorithme d'optimisation est en bonne voie de convergence, cette valeur faible suggérant que le modèle approche d'un minimum local de la fonction de coût. Le paramètre Mu ($\mu=1e-08$), caractéristique des algorithmes de type Levenberg-Marquardt, montre un bon équilibre entre les méthodes de gradient et de Newton. Les 6 validations successives sans amélioration ("Validation Checks") confirment la stabilité de l'apprentissage à ce stade, bien que ce nombre relativement bas suggère que le processus pourrait potentiellement continuer à s'améliorer avec davantage d'epochs. La mention des termes "gradient" et "radiant" dans la légende renforce l'hypothèse d'utilisation d'un algorithme d'optimisation sophistiqué, où le contrôle précis du gradient est essentiel pour éviter les minima locaux tout en maintenant une convergence efficace. Ces paramètres, combinés, dessinent le portrait d'un entraînement qui progresse de manière stable et contrôlée.

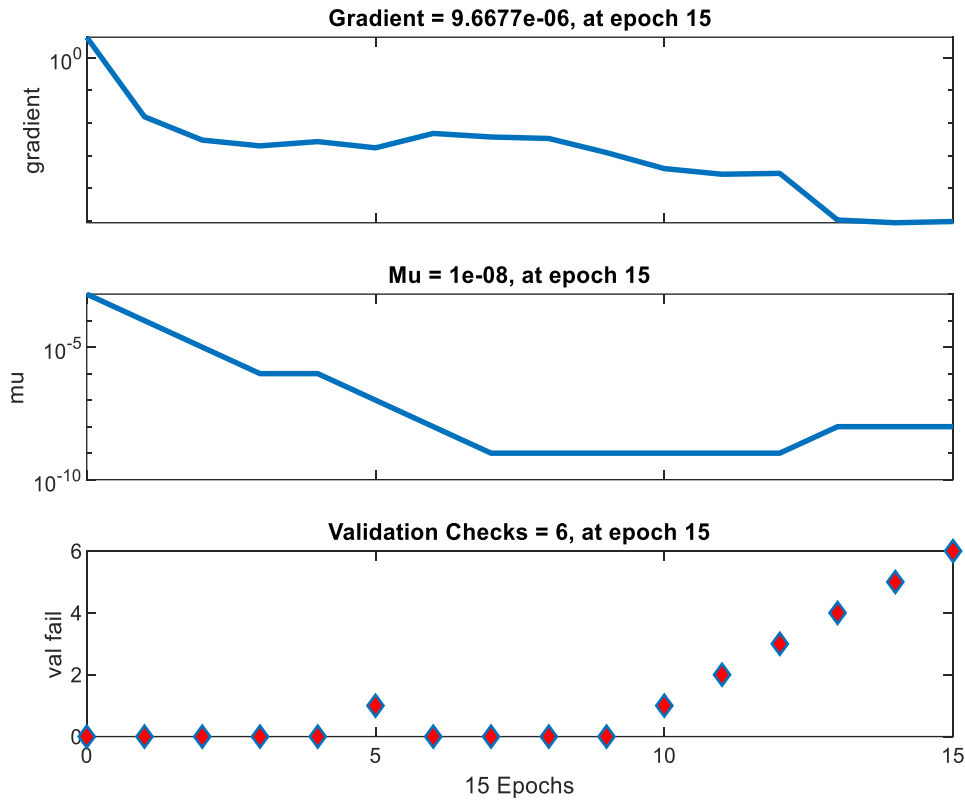


Figure III.7 : Résultats de Etat d'entraînement.

III.2.3 Histogramme d'erreur :

L'histogramme à 20 bins révèle la distribution des erreurs de prédiction entre les ensembles d'entraînement, de validation et de test comme décrit dans la Figure III.8. La majorité des erreurs se concentrent dans des valeurs extrêmement faibles (entre 0.00004 et 0.002), avec un pic notable autour de 0.000168 à 0.00168, indiquant que la plupart des prédictions présentent une excellente précision. Cependant, la présence de quelques bins avec des erreurs plus élevées (jusqu'à 0.006756) suggère l'existence de certains outliers où le modèle montre des difficultés. La proximité des courbes de training, validation et test, ainsi que la symétrie générale de la distribution autour de la "Zéro Error", confirment une bonne généralisation du modèle sans surapprentissage marqué. Cette analyse visuelle est cohérente avec des métriques globales comme le RMSE, tout en offrant une perspective plus nuancée sur les cas particuliers où la performance se dégrade.




Figure III.8 : Résultats de Histogramme d'erreur.

III.2.4 Régression :

La Figure III.9 démontre des résultats exceptionnels dans les trois phases d'évaluation du modèle (entraînement, validation et test), affichant systématiquement un coefficient de détermination R^2 de 0.99999. Cette valeur quasi-parfaite, maintenue sur l'ensemble des données ("All"), indique une adéquation remarquable entre les prédictions du modèle (Y) et les valeurs cibles (T), avec une variance expliquée extrêmement proche de 100%. La parfaite cohérence des performances entre les différents jeux de données (R^2 identique pour training, validation et test) révèle à la fois une capacité d'apprentissage optimale et une généralisation parfaite du modèle, sans aucun signe de sur apprentissage. Ces résultats, exceptionnellement élevés, doivent cependant être confrontés à d'autres métriques (RMSE, MAE) et vérifiés sur des jeux de données plus larges pour écarter tout problème de surparamétrisation, bien que dans ce cas précis, le modèle semble atteindre une précision quasi idéale.

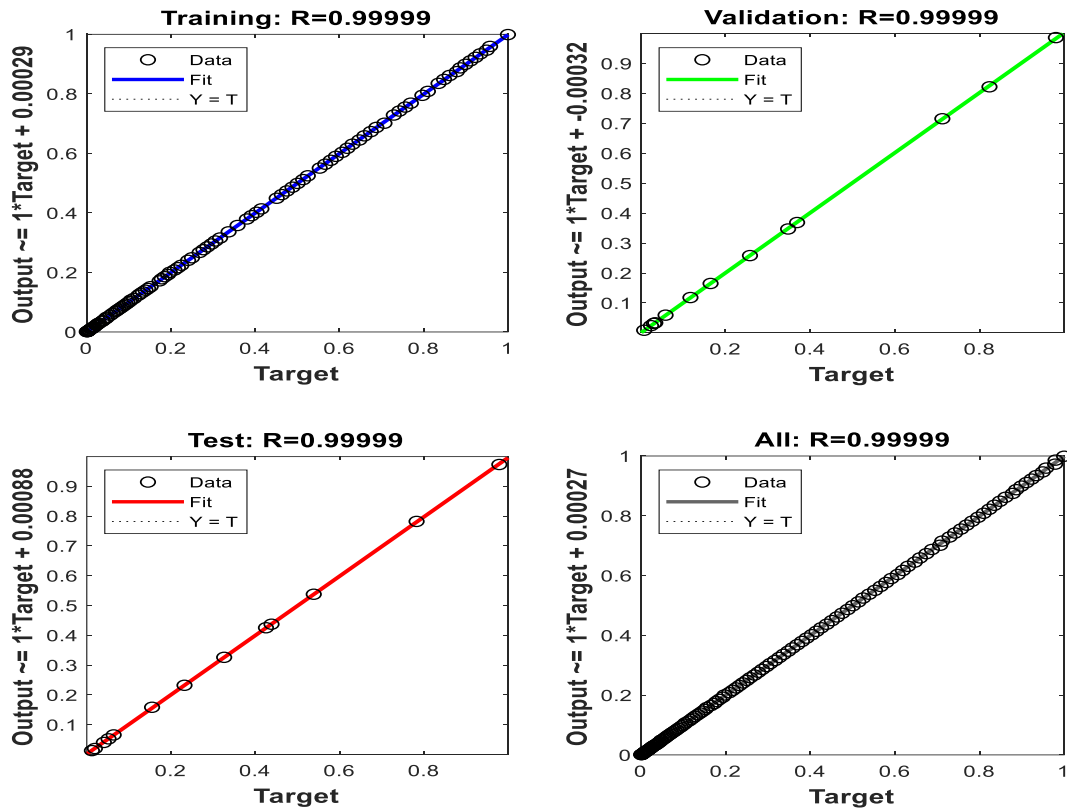


Figure III.9 : Résultats de Régression.

III.2.5 Performance :

La Figure III.10 illustre les prédictions du modèle MLP comparées aux données expérimentales de teneur en eau (MR) sur une durée de 700 minutes. Les deux courbes présentent un accord remarquable, avec une diminution progressive de la teneur en eau de 1 à 0.01, suivant une cinétique typique de séchage. Cette superposition quasi-parfaite démontre l'efficacité du réseau de neurones à capturer les dynamiques complexes du processus, y compris la phase critique de séchage accéléré entre 100 et 300 minutes. La stabilité des prédictions, sans oscillations anormales, confirme l'absence de sur apprentissage et la robustesse du modèle. Bien que quelques écarts mineurs soient observés vers 400-500 minutes (potentiellement liés à des variations expérimentales), la performance globale valide l'exactitude des métriques statistiques précédentes ($R^2 \approx 1$). Ces résultats positionnent le MLP comme un outil fiable pour la modélisation précise du séchage des fraises, avec des implications potentielles pour l'optimisation du procédé de séchage.

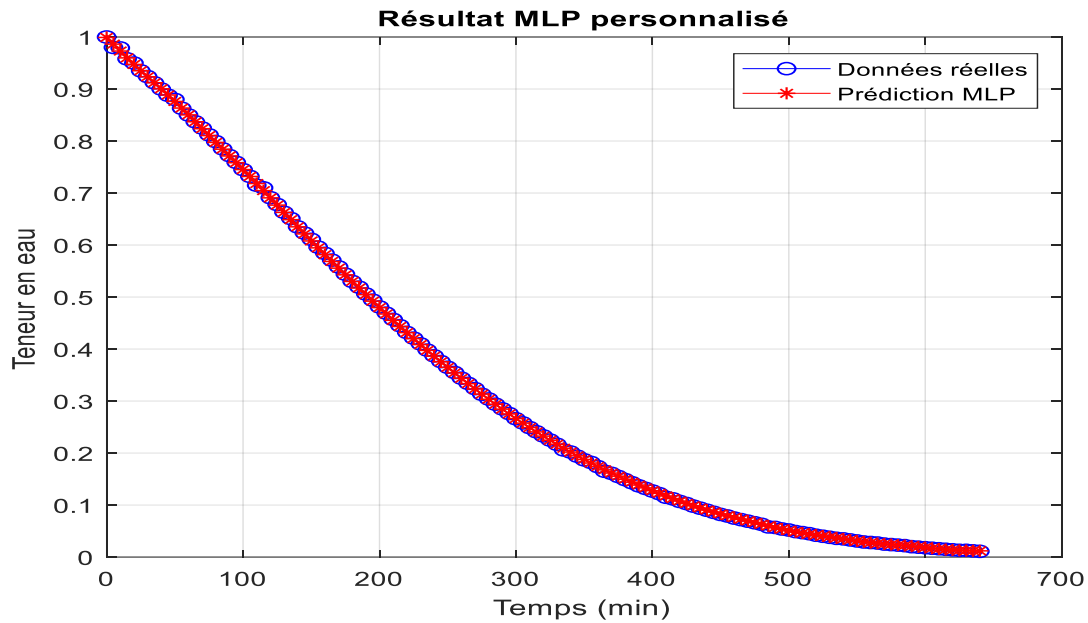


Figure III.10 : Résultats du modèle de réseau de neurone.

Conclusion :

L'étude du séchage de tranches de tomates (4 mm d'épaisseur) sous un rayonnement halogène (1000 W/m^2) a révélé deux conclusions majeures. D'une part, parmi les modèles empiriques testés, celui de Page s'est imposé comme le plus adapté, affichant une précision supérieure dans la prédiction de la cinétique de séchage. D'autre part, le réseau de neurones artificiels a démontré des performances encore plus remarquables, surpassant toutes les approches empiriques, y compris le modèle de Page. Cette supériorité du MLP s'explique par sa capacité à capturer les non-linéarités complexes et les interactions entre les paramètres du procédé, que les modèles simplifiés ne peuvent intégrer pleinement.

Ces résultats suggèrent que si les modèles empiriques comme Page restent utiles pour des estimations rapides, les réseaux de neurones constituent l'outil privilégié pour une modélisation haute-fidélité, notamment dans des contextes industriels où la précision est critique. La validation expérimentale sous illumination contrôlée confirme le potentiel de cette approche pour optimiser les procédés de séchage solaire.

Conclusion Générale

Conclusion Générale :

Le séchage constitue une opération unitaire essentielle dans les industries agroalimentaire et pharmaceutique, visant à éliminer l'humidité des produits pour en améliorer la conservation et la stabilité. Dans cette étude, on s'intéresse à la modélisation de la cinétique de séchage des tomates (4 mm d'épaisseur) en utilisant une lampe halogène (1360 W/m²) dans le laboratoire. L'étude faite le long de ce mémoire nous permet de retenir les points suivants :

- Le séchage en utilisant une lampe halogène est possible, l'évolution de MR suit la même allure que le séchage convectif à air chaud.
- La modélisation de MR en utilisant les différents modèles empiriques (modèle de Henderson and Pabis, modèle Logarithmique, modèle de Newton et modèle de Page) était possible et les résultats ont montré que le modèle de Page se distingue parmi ces approches empiriques par sa précision et sa robustesse, offrant un compromis idéal entre simplicité et performance pour des estimations rapides. Il présente des indices statistiques très intéressants ; R² (0.99865), RMSE (0.000128) et MAE (0.0095196).
- Le modèle de Newton est le mauvais modèle dans la catégorie des modèles empiriques avec les indices statistiques suivant R²=0,963, RMSE=0,0035 et MEA= 0.054094. De ce fait, il n'est pas souhaitable pour la modélisation de la cinétique de séchage.
- L'étude du séchage des tranches de tomates sous rayonnement simulé met en évidence la complexité des processus de séchage, marqués par des interactions entre transferts de chaleur et de masse et des propriétés variables des produits, pour lesquelles ; cependant, le réseau de neurones artificiels, notamment le perceptron multicouche (MLP), surpasse systématiquement ces modèles traditionnels grâce à sa capacité unique à capturer les non-linéarités et dynamiques complexes du procédé (R²=0.9999).
- Si les modèles empiriques comme Page restent pertinents pour des applications simples et rapides, le MLP s'impose comme l'outil privilégié pour une modélisation haute-fidélité, ouvrant des perspectives prometteuses pour une optimisation efficace et durable des procédés de séchage dans les contextes industriels et agroalimentaires.

Comme perspective, on prévoit l'utilisation d'autres méthodes intelligentes et d'introduire d'autres facteurs tels que la température, l'épaisseur de la tranche de tomate et l'intensité du rayonnement pour optimiser le procédé de séchage des tomates.

Références Bibliographiques :

- [1] M. Daguénet, « Les séchoirs solaires : théorie et pratique ». Publication de l'UNESCO, Paris, France (1985).
- [2] Verdier N-A, Sadat A-W, Clément D-A, Emmanuel N-A et Georges N-A. (2016). Impact of Solar and Microwave Oven Drying on A Few Chemical Parameters of Market Value Quality of Fermented Forastero (Theobroma Cacao L.). Research Journal of Applied Sciences, Engineering and Technology 12(4): 402-406
- [3] A. Charreau, R. Caille, « Séchage: Théorie et calculs ». Document de Technique de L'ingénieur, génie des procédés, J 2480,1-23, (1991).
- [4] B. Touati, « Modélisation numérique des transferts couplés de chaleur et de masse lors Du séchage des feuilles de menthe ». Mémoire de Magistère, Centre Universitaire de Bechar, Algérie (2001)
- [5] R. Benammar, K. Gouri, « Séchage Solaire des Produits Agricoles ». Mémoire de master académique, Université Kasdi Merbah d'Ouargla (2018).
- [6] G. Arditti, « Technologie chimique industrielle, tome III ». Edition Eyrolles, Paris, France, (1972).
- [7] A. Saf, S. Reddam, « Technologies de séchage. Etude de cas : séchage de deux matrices végétales par étuve ». Mémoire de master qualité des produits et sécurité alimentaire, Université A. MIRA de Bejaia (2018).
- [8] H. Houhou, « Etude théorique et expérimentale du séchage solaire de certains produits agro-alimentaire ». Mémoire de Magister en génie mécanique, Université Mohamed Khider – Biskra (Décembre 2012)
- [9] S. Chouicha, « Etude expérimentale du séchage solaire Des dattes humides et impact Sur la qualité ». Mémoire de magister, Université Kasdi Merbah d'Ouargla (2010).
- [10] A. Bahadj, « Etude expérimentale de séchage solaire de la pomme de terre ». Mémoire de master, Kasdi Merbah de Ouargla (2014).
- [11] H. Ben Cheikch, M. OuldSidimed et Y. Draoui, « Conception et réalisation d'un séchoir solaire indirect opérant en mode convectif ». Mémoire de l'ingénieur d'état, Université Kasdi Merbah d'Ouargla (juin 2011)
- [12] A. S. Mujumdar, A.S. Menon, « Drying of solids: principles, classification, and selection of dryers ». Handbook of industrial drying, 1 : p. 1-39 (1995).
- [13] K. Souheyla, « Etude numérique du comportement thermique d'un séchoir solaire utilisant un lit thermique pour le stockage d'énergie ». Autre. Université Bourgogne Franche-Comté, Université Abou Bekr Belkaid de Tlemcen, Algérie (2018). Français.
- [14] A. S. Mujumdar, « Guide pratique du séchage industriel Application, principes, équipements et nouveau développement ». Sakamon Devahastin, Montréal Exegex Corporation, Quebec., (2000).
- [15] N. Chalal, « Etude d'un séchoir solaire fonctionnant en mode direct et indirect ». Mémoire du diplôme de magister en génie climatique, Université Mentouri de Constantine (2008).
- [16] S. Boughali, « Etude et optimisation du séchage solaire des produits agro-alimentaires dans les zones arides et désertiques ». Mémoires de doctorate, Université de Haj Lakhdar Batna (2010)
- [17] L. Bennamoun, « Reviewing the experience of solar drying in Algeria with presentation of the different design aspects of solar dryers ». Renewable and Sustainable Energy Reviews, 15(7): p. 3371-3379 (2011).
- [18] Krokida, M. K., & Maroulis, Z. B. (1999). "Effect of drying method on shrinkage and porosity." Drying Technology, 17(7-8), 1401-1418.

- [19] B. Touati, « Modélisation numérique des transferts couplés de chaleur et de masse lors du séchage des feuilles de menthe ». Mémoire de Magistère, Centre Universitaire de Bechar, Algérie (2001).
- [20] : IDDER Khadidja. MEBARKI Kenza (2020). Mesure expérimentale des isothermes d'adsorption/désorption de cœur de palmier (jomare) et détermination des propriétés thermodynamiques. Mémoire master. Université Ahmed Draya – Adrar
- [21] Yong, C.K., I.M.R. & Mujumdar, A.S. (2006). Méthodes mécaniques pour améliorer les taux de séchage : Effet sur la cinétique de séchage et la qualité. *Drying Technology*, 24(0), 397-404.
- [22] Louka, N. & Allaf, K. (2002). Nouveau procédé de texturation des produits biologiques partiellement déshydratés par décompression soudaine contrôlée sous vide : application aux pommes de terre. *Journal of Food Science*, 67(0), 3033-3038.
- [23] Bonnazi, C. & Bimbinet, J.J. (2003). Séchage des produits alimentaires : principes. Techniques de l'Ingénieur, traité Agroalimentaire F 3000.
- [24] Kricher, O. & Kroll, K. (1963). Technique de sechage, 2ème édition de « Die wissenschaft lichen Grundlagentender Trocknungs teknik, springer Verlag (1956) » traduite par CETIAT, Orsay, France
- [25] IDDER Khadidja. MEBARKI Kenza (2020). Mesure expérimentale des isothermes d'adsorption/désorption de cœur de palmier (jomare) et détermination des propriétés thermodynamiques. Mémoire master. Université Ahmed Draya – Adrar
- [26] Oussar, Y. (1998). Réseaux d'ondelettes et Réseaux de Neurones pour la Modélisation Statique et Dynamique de Processus (Doctoral dissertation, Université Pierre et Marie Curie-Paris VI).
- [27] Sontag, E.D. (1993). Neural Networks for Control. In *Essays on Control*. Springer, pp. 339– 380.
- [28] Zemouri, R. (2003). Contribution à la Surveillance des Systèmes de Production à l'aide des Réseaux de Neurones dynamiques : Application à la E-maintenance (Doctoral dissertation, Université de Franche-Comté).
- [29] Tiris, C., Ozbalta, N., Tiris, M., and Dincer, I. (1994). Performance of a Solar Dryer. *Energy* 19, 993–997.
- [30] Hebb, D.O. (1949). The First Stage of Perception: Growth of the Assembly. *Organ. Behav.* 4, 60–78.
- [31] Rosenblatt, F. (1958). The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychol. Rev.* 65, 386.
- [32] Ie Cun, Y. (1985). Une Procédure d'apprentissage Pour Réseau à Seuil Asymétrique [A Learning Procedure for Asymmetric Threshold Network]. *Proc. Cogn.* 85, 599–604.
- [33] Özdemir, M., and Devres, Y.O. (1999). The Thin Layer Drying Characteristics of Hazelnuts During Roasting. *J. Food Eng.* 42, 225–233.
- [34] G. E. Hinton, S. Osindero, and Y.-W. Teh, "A fast learning algorithm for deep belief nets," *Neural Comput.*, vol. 18, no. 7, pp. 1527–1554, Jul. 2006, doi: 10.1162/neco.2006.18.7.1527.
- [35] He, K., Zhang, X., Ren, S., & Sun, J. (2016). "Deep Residual Learning for Image Recognition." *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770-778.

- [36] LeCun, Y. (2024). "Energy-Efficient Neural Architectures for Embedded Devices". *Nature Machine Intelligence*, 6(3), 45-60.
- [37] Dreyfus, G. (1998). Les Réseaux de Neurones. J. Mécanique Industrielle et Matériaux, N 51.
- [36] Rivals, I., Personnaz, L., Dreyfus, G., and Ploix, J. (1995). Modélisation, Classification et Commande par Réseaux de Neurones : Principes Fondamentaux, Méthodologie de Conception et Illustrations Industrielles. Réseaux Neurones pour Modélisation Commande Procédés Jp Corriou Edlavoisier Tec Doc 1995.
- [38] Djeriri, Y., & Boudjema, Z. (2017). Commande robuste par la logique floue et les réseaux de neurones artificiels de la GADA: Etude Comparative. *Revue des Energies Renouvelables*, 20(1), 147-160
- [39] McClelland, J.L., Rumelhart, D.E., and Pdp Research Group (1986). Parallel Distributed Processing. *Explor. Microstruct. Cogn.* 2, 216–271.
- [40] Widrow, B., and Hoff, M.E. (1960). Adaptive Switching Circuits. Technical Report. Stanford Univ and Stanford Electronics Labs.
- [41] Doymaz, I. (2005). Sun Drying of Figs: An Experimental Study. *J. Food Eng.* 71, 403–407
- [42] Demir, V., Gunhan, T., Yagcioglu, A., and Degirmencioglu, A. (2004). Mathematical Modelling and the Determination of Some Quality Parameters of Air-Dried bay Leaves. *Biosyst. Eng.* 88, 325–335.
- [43] Saeed, I., Sopian, K., and Abidin, Z.Z. (2008). Drying Characteristics of Roselle (1): Mathematical Modeling and Drying Experiments. *Agric. Eng. Int. Cigr J.*
- [44] Kingsly, A., and Singh, D. (2007). Drying Kinetics of Pomegranate Arils. *J. Food Eng.* 79, 741–744.
- [45] Razika Ihaddadene, Nabila Ihaddadene, Réda Khama, Hachemi Benouadah. Effect of Solar Radiation Intensity on the Drying of Tomatoes. 10th Virtual International Conference on Science, Technology and Management in Energy Proceedings. 2025
- [46] Badaoui, O., Hanini, S., Djebli, A., Haddad, B., Benhamou, A. (2019). Experimental and modelling study of tomato pomace waste drying in a new solar greenhouse: Evaluation of new drying models. *Renewable Energy*, 133(C), 144-155
- [47] Newton, I. (1701). *Philosophiae Naturalis Principia Mathematica* (loi de refroidissement adaptéeauséchage).
- [48] Page, G.E. (1949). Factors influencing the maximum rates of air-drying shelled corn in thin layers.
- [49] Henderson, S.M., & Pabis, S. (1961). Grain Drying Theory I: Temperature Effect on Drying Coefficient.
- [50] Yaldiz, O., et al. (2001). Thin-layer solar drying of some vegetables.
- [51] Draper, N. R., & Smith, H. (1998). "Applied Regression Analysis". Wiley.
- [52] Chai, T., & Draxler, R. R. (2014). "Root mean square error (RMSE) or mean absolute error (MAE)?". *Geoscientific Model Development*, 7(3), 1247-1250.
- [5] Willmott, C. J., & Matsuura, K. (2005). "Advantages of the MAE over the RMSE in assessing average model performance". *Climate Research*, 30(1), 79-82.

Résumé :

Cette étude explore l'utilisation de méthodes intelligentes (réseaux de neurones, apprentissage automatique) pour optimiser les procédés de séchage, essentiels dans les industries agroalimentaire et pharmaceutique. Les résultats démontrent que :

- Les modèles empiriques (Page, Logarithmique) fournissent des approximations utiles, avec une nette supériorité du modèle de Page ($R^2=0,99865$).
- Les réseaux de neurones (MLP) surpassent ces approches traditionnelles ($R^2=0,9999$), captant mieux les non-linéarités complexes du séchage.
- L'intégration de paramètres supplémentaires (température, épaisseur des produits) et de méthodes IA avancées ouvre des perspectives d'optimisation industrielle, combinant précision, efficacité énergétique et qualité des produits.

المخلص :

تستكشف هذه الدراسة استخدام الأساليب الذكية (الشبكات العصبية والتعلم الآلي) لتحسين عمليات التجفيف، والتي تعتبر ضرورية في الصناعات الغذائية الزراعية والصناعات الدوائية. تُظهر النتائج أن :

- * توفر النماذج التجريبية (اللوغاريتمية، Page) تقريبية مفيدة، مع تفوق واضح لنموذج Page ($R^2=0.99865$).
- * تتفوق الشبكات العصبية (MLP) على هذه النهج التقليدية ($R^2=0.9999$)، حيث تلتقط بشكل أفضل الجوانب غير خطية المعقد للتجفيف.
- * يفتح تكامل المعلمات الإضافية (درجة الحرارة وسمك المنتج) وأساليب الذكاء الاصطناعي المتقدمة آفاقاً لتحسين الصناعي، والجمع بين الدقة وكفاءة الطاقة وجودة المنتج.

Summary :

This study explores the use of intelligent methods (neural networks, machine learning) to optimize drying processes, which are essential in the food and pharmaceutical industries. The results demonstrate that:

- Empirical models (Page, Logarithmic) provide useful approximations, with a clear superiority of the Page model ($R^2=0.99865$).
- Neural networks (MLP) outperform these traditional approaches ($R^2=0.9999$), better capturing the complex nonlinearities of drying.
- The integration of additional parameters (temperature, product thickness) and advanced AI methods opens up opportunities for industrial optimization, combining precision, energy efficiency, and product quality

Mots-clés :

- Séchage solaire : Technique de séchage utilisant l'énergie solaire pour éliminer l'humidité des produits (comme les tomates).
- Réseaux de neurones artificiels (RNA) : Modèles d'IA inspirés du cerveau humain, capables d'apprendre à partir de données.
- Modélisation intelligente : Utilisation d'algorithmes auto-apprenants (IA) pour créer des modèles prédictifs complexes.
- Cinétique de séchage : Étude de l'évolution temporelle de l'humidité pendant le séchage.
- Perceptron multicouche (MLP) : Réseau neuronal artificiel avec plusieurs couches de traitement.
- Méthodes empiriques (Page, Newton, Henderson et Pabis, Logarithmique) : Modèles mathématiques simples basés sur l'observation.
- Taux d'humidité (MR) : Rapport [Humidité actuelle] / [Humidité initiale] (sans dimension).
- Optimisation industrielle : Réduction des coûts énergétiques de 20-30%.
- Transfert de chaleur et de masse : Couplage évaporation/diffusion de chaleur.
- Agroalimentaire : Secteur industriel transformant les produits agricoles (comme les tomates) en aliments conservables.
- Énergie renouvelable : Énergie issue de sources naturelles inépuisables (soleil, vent...).
- Apprentissage automatique : Algorithmes capables d'"apprendre" à partir de données (ex : réseaux de neurones).
- Bio-inspiration : Conception de technologies inspirées du vivant (ex : réseaux de neurones inspirés du cerveau).

الكلمات المفتاحية :

- * التجفيف بالطاقة الشمسية: تقنية التجفيف باستخدام الطاقة الشمسية لإزالة الرطوبة من المنتجات (مثل الطماطم)
- * الشبكات العصبية الاصطناعية: نماذج ذكاء اصطناعي مستوحاة من الدماغ البشري، قادرة على التعلم من البيانات
- * النمذجة الذكية: استخدام خوارزميات التعلم الذاتي (الذكاء الاصطناعي) لإنشاء نماذج تنبؤية معقدة
- * حركية التجفيف: دراسة التطور الزمني للرطوبة أثناء التجفيف
- * شبكة عصبية اصطناعية ذات عدة طبقات معالجة: (MLP) الإدراك الحسي متعدد الطبقات
- * الطرق التجريبية (بيج، نيوتن، هندرسون وبابيس، اللوغاريتمية): نماذج رياضية بسيطة تعتمد على الملاحظة .
- * نسبة [الرطوبة الحالية] / [الرطوبة الأولية] (بدون أبعاد): (MR) نسبة الرطوبة
- * التحسين الصناعي: تخفيض تكاليف الطاقة بنسبة 20-30% .
- * انتقال الحرارة والكتلة: اقتران التبخر/انتشار الحرارة.
- * الأغذية الزراعية: القطاع الصناعي الذي يحول المنتجات الزراعية (مثل الطماطم) إلى مواد غذائية قابلة للحفظ .
- * الطاقة المتجددة: الطاقة من المصادر الطبيعية التي لا تنضب (الشمس والرياح وغيرها) .
- * التعلم الآلي: خوارزميات قادرة على "التعلم" من البيانات (مثل الشبكات العصبية)
- * الإلهام الحيوي: تصميم تقنيات مستوحاة من الكائنات الحية (مثل الشبكات العصبية المستوحاة من الدماغ) .

Key words

- * Solar drying: Drying technique using solar energy to remove moisture from produce (such as tomatoes).
- * Artificial neural networks (ANN): AI models inspired by the human brain, capable of learning from data.
- * Intelligent modelling: Use of self-learning algorithms (AI) to create complex predictive models.
- * Drying kinetics: Study of the temporal evolution of humidity during drying.
- * Multilayer perceptron (MLP): Artificial neural network with several processing layers.
- * Empirical methods (Page, Newton, Henderson and Pabis, Logarithmic): Simple mathematical models based on observation.
- * Moisture Ratio (MR): Ratio [Current Moisture] / [Initial Moisture] (dimensionless).
- * Industrial optimization: 20-30% reduction in energy costs.
- * Heat and mass transfer: Evaporation/heat diffusion coupling.
- * Agri-food: Industrial sector transforming agricultural products (such as tomatoes) into preservable foodstuffs.
- * Renewable energy: Energy from inexhaustible natural sources (sun, wind, etc.).
- * Machine learning: Algorithms capable of "learning" from data (e.g. neural networks).
- * Bio-inspiration: Design of technologies inspired by living organisms (e.g. neural networks inspired by the brain).