

**Ecole Nationale Supérieure Agronomique El-Harrach Alger**  
Mémoire en vue de l'obtention du diplôme de magister en sciences agronomiques  
Département : Génie rural  
**Spécialité : Hydraulique Agricole**

***Modélisation de l'évapotranspiration de référence et du déficit hydrique par les réseaux de neurones artificiels à différent pas de temps***

**Réalisé par : BELOUZ Khaled**

M. DECHEMI .N Professeur à l'ENP, (Directeur de thèse)  
08-07-2009

Membres du Jury M. AIDAOUI .A Professeur, ENSA, Alger, (Président) M. CHABACA. MN Maître de conférences, ENSA, Alger, (Examineur) M. MOUHOUCHE.B Maître de conférences, ENSA, Alger, (Examineur) M. MERABET.B Maître de conférences, ENSA, Alger, (Examineur)



# Table des matières

Remerciements . . .	6
ص غ ل م ل ا . . .	7
Résumé . . .	8
Abstract . . .	9
LISTE DES ABREVIATIONS . . .	10
Introduction générale . . .	11
I. Synthèse bibliographique . . .	13
I.1. L'évapotranspiration ; Concepts généraux . . .	13
I.1.1. Notions liées à l'évapotranspiration . . .	13
I.1.2. L'évaluation de l'évapotranspiration de référence . . .	14
I.1.3. Modélisation de l'évapotranspiration ; synthèse bibliographique . . .	16
I.2. Notions générales sur le Sol-Plante-Atmosphère-Continuum (SPAC) . . .	17
I.2.1. Introduction . . .	17
I.2.2. L'eau dans le sol . . .	18
I.3. Bilan hydrique . . .	20
I.3.1. Définition . . .	20
I.3.2. Modélisation du bilan hydrique . . .	22
I.4. Le déficit hydrique . . .	24
I.4.1. Déficit hydrique climatique (DHC) . . .	24
I.4.2. Déficit hydrique d'alimentation DHa . . .	24
I.4.3. Déficit hydrique du sol . . .	24
II. Théorie des Réseaux de Neurones Artificiels . . .	26
II.1. Introduction . . .	26
II.2. Historique des réseaux de neurones artificiels . . .	26
II.3. Quelques domaines d'application des réseaux de neurones artificiels . . .	28
II.4. Réseau de neurones: fondement biologique . . .	28
II.4.1. Le neurone . . .	28
II.4.2. Le corps cellulaire . . .	29
II.4.3. Les dendrites . . .	29
II.4.4. L'axone . . .	29
II.5. Réseaux de neurones artificiels . . .	30
II.5.1. Principe général . . .	30
II.5.2. Structure d'un neurone artificiel (formel) . . .	30
II.5.3. Fonctionnement mathématique du neurone artificiel . . .	32
II.5.4. Classification des réseaux de neurones artificiels . . .	33
II.5.5. Avantages et inconvénients des réseaux de neurones artificiels . . .	40
II.5.6. Choix de paramètres du modèle neuronal . . .	42
II.5.7. Conclusion . . .	43
III. Matériels et Méthodes . . .	45
III. 1. La méthodologie de travail . . .	45

III.1.1. Introduction . . .	45
III.1.2. Situation géographique . . .	46
III.1.3. Acquisition des données météorologiques . . .	47
III.1.4. Brève description des formules d'estimation d'ET <sub>0</sub> utilisées . . .	47
III.2. Présentation de modèles de simulation du bilan hydrique utilisés pour estimer le déficit hydrique d'alimentation . . .	48
III.2.1. Le modèle Pluie – ETP . . .	49
III.2.2. Modèle Rojas . . .	49
III.2.3. Modèle d'Eldin et Lhomme . . .	50
III.2.4. Modèle de Lhomme et Katerji . . .	52
III.3. Programmation de logiciel de calcul . . .	56
III.4. Choix de la culture . . .	56
III.5. Critères d'évaluation de performance d'un modèle neuronal . . .	57
III.5.1. Critère graphique . . .	57
III.5.2. Critères statistiques . . .	57
III.6. Phases d'élaboration d'un modèle neuronal . . .	60
III.6.1. La collecte des données . . .	60
III.6.2. La séparation de la base de données (apprentissage-validation) . . .	60
III.6.3. Elaboration de la structure du réseau . . .	60
III.6.4. Apprentissage . . .	60
III.6.5. Validation . . .	61
III.6.6. Post validation ou phase de test . . .	61
III.7. Implémentation des réseaux de neurones artificiels (RNAs) . . .	61
III.7.1. Introduction . . .	61
III.7.2. Logiciel MATLAB . . .	61
III.7.3. Méthodologie d'implémentation . . .	62
IV .Résultats et discussions . . .	69
IV.1. Introduction . . .	69
IV.2. Comparaison et calibration de quelques formules utilisées pour estimer l'ET <sub>0</sub> . . .	69
IV.2.1. Introduction . . .	69
IV.2.2. Comparaison de quelques formules utilisées pour estimer l'ET <sub>0</sub> . . .	69
IV.2.3. Calibration locale de quelques formules utilisées pour estimer l'ET <sub>0</sub> : (1995-2004) . . .	70
IV.3. Estimation de l'ET <sub>0</sub> par la technique de régression linéaire multiple . . .	72
IV.3.1. Introduction . . .	72
IV.3.2. Régression linéaire multiple . . .	72
IV.3.3. Application de la technique de régression linéaire multiple à la série climatique d'Alger . . .	72
IV.3.4. Comparaison entre le modèle de régression multiple (RLM <sub>ET<sub>0</sub></sub> ) et la formule de Penman-Monteith modifiée . . .	73
IV.4. Résultats de simulation par les réseaux de neurones artificiels . . .	73
IV.4.1. Introduction . . .	73

IV.4.2. Obtention du nombre optimal de neurones dans la couche cachée . .	74
IV.4.3. Simulation de l'évapotranspiration de référence . .	74
IV.4.4. Simulation de déficit hydrique par les réseaux de neurones artificiels . .	110
Conclusion générale . .	117
Références Bibliographiques . .	121
Annexes . .	125

## Remerciements

Au terme de ce travail, je remercie Allah le tout Puissant qui m'a donné la force, la patience ainsi que le courage afin de parvenir à terminer ce travail.

Je tiens à remercier mon directeur de mémoire de magister Monsieur **N. Dechemi** Professeur à l'Ecole Nationale Polytechnique (ENP) de m'avoir intégré dans son équipe de recherche (Gestop), d'accepter la direction de ce mémoire, de m'avoir encadré, il a été pour moi un enseignant privilégié de par sa gentillesse, son expérience, je le remercie pour sa rigueur, ses encouragements ainsi que pour ses critiques et conseils constructifs pour aboutir à ce travail.

Je remercie aussi Monsieur le Professeur **A. Aidaoui**, non seulement parce qu'il a accepté de présider mon jury de soutenance mais pour tout ce qu'il a fait pour la réussite de la promotion de post-graduation hydraulique agricole (2006-2007), il mérite tous les remerciements.

Mes remerciements vont aussi à monsieur **B. Mouhouche** et monsieur **MN. Chabaca** et monsieur **B. Merabet** pour avoir accepté d'examiner ce travail.

Mes remerciements s'adressent également à toute la famille de spécialité Hydraulique Agricole (Enseignants, Etudiants et Bibliothécaires).

En fin je remercie toute personne ayant contribué de près ou de loin dans l'élaboration de ce mémoire.

## ص خل مل ا

إن العدهم الأساسى من عدا العمل هو تصييو و تطويق نماذج مؤسسه على تقنيه الشبكات العصبونيه الأطناعيه بعد تقييو بعض المتغيراتك العيدروولوجيه لترشيد الموارد المائيه في النبال الخلاجي.

وعد تو دراسه هدره الشبكات العصبونيه الأطناعيه على نمذجه النتج التبحري المرجعي المتحصل عليه بتطويق طرفه "بينمان-مونتايبك" المعدله.

كما تو استعمال عده تركيبات للمتغيرات المناخيه (على المدى اليومي، العشري و الشعري) و التي تتمثل في العوامل التاليه : حده الشمس، حراره الهواء، الرطوبه النسبيه، سرعه الريح و بعد استعماله كمدخل للشبكات العصبونيه الأطناعيه بفيه إيجاباد أحسن تركيبه للمتغيرات المناخيه اخذين بعين الأعتبار أفضل بنوه عصبونيه (عدد العصبونات في الطبقة الخفيه).

وهنا كدالقه بدراسه مدى نجاعه تقنيه الشبكات العصبونيه الأطناعيه على نمذجه العجز المائى على المدى اليومي العشري و الشعري.

### النتائج الخاله

الشبكات العصبونيه الأطناعيه ، النتج التبحري المرجعي العجز المائى نمذجه، نموذجي، تحدير الكفاءه كطأ، ربي، انحصار، طرفه بينمان-مونتايبك" المعدله.

## **Résumé**

L'objectif principal de ce travail consiste à concevoir et à appliquer des modèles basés sur la technique de Réseaux de Neurones Artificiels pour évaluer certains paramètres hydrologiques afin d'améliorer la gestion des ressources en eau en agriculture.

Le potentiel des réseaux de neurones de type Perceptron multicouches est étudié pour modéliser l'évapotranspiration de référence ( $ET_0$ ) obtenue par application de l'équation de Penman-Monteith modifiée par la FAO56. Différentes combinaisons de données climatiques (journalières, décadaires et mensuelles) ; telles que la durée d'insolation, température de l'air, humidité relative et vitesse du vent, sont utilisées en entrée des réseaux de neurones artificiels afin de déterminer la meilleure combinaison tout en choisissant la meilleure structure neuronale (nombre de neurones cachées).

Nous avons également étudié le potentiel des réseaux de neurones artificiels pour modéliser le déficit hydrique d'alimentation à différents pas de temps.

**Mots clés:** Réseaux de neurones artificiels ; évapotranspiration de référence ; déficit hydrique ; modélisation ; modèle ; évaluation de performance; Erreur; Penman-Monteith modifiée; Irrigation ; Régression.



## Abstract

The principal objective of this study is to conceive and apply various models based on Artificial Neural Networks technique in order to assess some hydrological parameters improving water resources management in agriculture.

The studied Artificial neural networks potential is of the type Percetron multi-layers. It serves to model reference evapotranspiration ( $ET_0$ ) obtained via Penman-Monteith modified equation through FAO 56. Various combinations of daily, decadal and monthly weather data (air temperature, relative humidity, wind speed and sunshine duration) are used throughout different time scales, in order to establish the best combination and choose good neural structure (number of neurons on hiddenlayers).

We have also studied artificial neural networks potential to model the deficit in water alimentation through different time scales.

**Keywords:** Artificial neural networks, reference evapotranspiration, water deficit, modelling, model, performance assessment, errors, Penman-Monteith modified, irrigation, regression.

## LISTE DES ABREVIATIONS

$\psi_s$  : Potentiel ou tension.  
ANN : Artificial neural networks.  
CC : Capacité au champ.  
D : Drainage.  
Da : Densité apparente du sol.  
DH : déficit hydrique  
DR : Drainage en dehors de la zone racinaire.  
ET : Evapotranspiration.  
ET<sub>0</sub> : Evapotranspiration de référence.  
ETM : Evapotranspiration maximale.  
ET<sub>opt</sub> : Evapotranspiration optimale.  
ETR : Evapotranspiration réelle.  
FAO : Food and Agriculture Organisation.  
Hc : humidité critique.  
Hcc : Humidité à la capacité au champ.  
H<sub>fp</sub> : Humidité au point de flétrissement.  
HR : Humidité relative  
I : Irrigation.  
Ins : Insolation (heures).  
Kc : Coefficient cultural.  
LM : Algorithme de Levenberg-Marquardt.  
ONM : Office nationale de la météorologie.  
P : Précipitation.  
Pe : Pluie efficace.  
PFP : Point de flétrissement permanent.  
PM : Penman-Monteith.  
R : Ruissellement.  
Rc : Remonté capillaire.  
Rc : Remontée capillaire.  
RDU : Réserve difficilement utilisable.  
RFU : Réserve facilement utilisable.  
RH : Réserve hydrique (mm m).

---

RNA : Réseau de neurones artificiels.  
RNA(5, 7, 1) : Réseau de neurones à cinq entrées, sept neurones cachés et une seule sortie  
RNA<sub>d</sub> : Réseau de neurones artificiels au pas de temps décadaire.  
RNA<sub>j</sub> : Réseau de neurones artificiels au pas de temps journalier.  
RNA<sub>m</sub> : Réseau de neurones artificiels au pas de temps mensuel.  
Rs : Rayonnement solaire global (ou Rg).  
RU : Réserve utile (mm m).  
SPAC : Sol-Plante-Atmosphère-Continuum.  
T : Température de l'air (C°).  
T<sub>max</sub> : Température maximale de l'air (C°).  
T<sub>min</sub> : Température minimale de l'air (C°).  
T<sub>moy</sub> : Température moyenne de l'air (C°).  
U<sub>z</sub> : Vitesse du vent (m/s) à 2m.  
W : Poids ou activation de neurones.  
Z : Profondeur racinaire en m.

---

# Introduction générale

L'eau en tant que ressource est primordiale, car nécessaire à toute vie au sein de la biosphère; dans l'environnement, elle est un bien fragile, largement utilisé et naturellement accaparé, voire dompté par les sociétés pour leur propre développement; à la fois don gratuit, dispensé par le jeu des climats à la surface des continents, et don cependant pas entièrement indépendant de l'activité des hommes. (Perrier, 2005).

La pression anthropique et les besoins humains en alimentation conduisent l'homme à monopoliser pratiquement toute l'eau disponible de la biosphère, en particulier pour conduire une agriculture irriguée ; cette pratique est en moyenne deux fois plus efficace que l'agriculture pluviale, d'où son attrait, mais son efficacité en eau décroît en fonction du milieu et de son aridité. (Perrier, 2005).

L'alimentation en eau est souvent le facteur limitant, à la fois du rendement et de la qualité de la production des espèces cultivées. Aujourd'hui, la disponibilité de l'eau est la contrainte principale pour le développement de l'agriculture.

La gestion de la ressource hydrique en agriculture, et plus particulièrement la conduite de l'irrigation se fait obligatoirement par la connaissance approfondie des besoins en eau des cultures afin de mettre en adéquation la ressource avec la demande, tout en évitant les situations de stress hydrique, l'évaluation des besoins en eau de cultures est réalisée à l'aide de l'évapotranspiration de référence.

L'évapotranspiration est un phénomène extrêmement complexe, faisant intervenir plusieurs paramètres aérodynamiques, énergétiques et biologiques, l'évaluation précise de l'évapotranspiration a une importance primordiale dans plusieurs domaines, tels que l'étude de bilan hydrique, la conception des réseaux d'irrigation et la gestion hydrologiques, la simulation de rendement, et la planification et l'aménagement des ressources en eau. L'évapotranspiration de référence et le déficit hydrique sont fortement non linéaires, ils sont régis par plusieurs paramètres interdépendants tel que la température, la vitesse du vent, l'humidité relative, l'insolation.

Leurs calculs restent encore soumis aux erreurs et leur mesure par lysimètres est très fastidieuse, elle exige une surveillance permanente et beaucoup de soin et de suivie. Cet outil (lysimètre) est encore réservé aux centres de recherche, donc les données lysimétriques sont rarement disponibles.

Ces deux processus s'avèrent fortement dépendant des conditions pédoclimatiques environnantes, le recours à la modélisation constitue une alternative attrayante pour évaluer la demande en eau des cultures à partir de l'évapotranspiration de référence ( $ET_0$ ) à différentes échelles d'espaces et du temps afin de pouvoir piloter les irrigations en se basant sur les données climatiques comme entrées.

Afin d'assurer une bonne précision d'estimation de l'évapotranspiration de référence et de déficit hydrique, nous avons recours à des solutions alternatives.

Avec l'accroissement continu de puissance des PC et l'expansion et le développement de technologies informatiques, de nombreux outils ont été conçus pour les chercheurs afin de créer leurs propres modèles qui servent à la gestion rationnelle de la ressource hydrique.

L'élaboration des modèles conceptuels est relativement difficile en raison de la nécessité de connaître la dynamique de processus et leur formulation mathématique, l'utilisation des modèles de type boîte-noire tel que les réseaux de neurones artificiels (modèles neuronaux) représente un choix intéressant et une méthode facile pour modéliser ces phénomènes.

Faisant partie de domaine de l'intelligence artificielle, les réseaux de neurones constituent des outils puissants pour la modélisation dite « par apprentissage », ils servent à résoudre les problèmes non linéaires dans presque tous les domaines, particulièrement, en hydrologie.

Le comportement fortement non linéaire du sol vis-à-vis du transfert hydrique rend difficile une représentation simple de ce transfert dans le sol. Dans ce cadre, la modélisation par les réseaux de neurones répond favorablement à cette non linéarité de flux hydrique de sol.

L'objectif de ce mémoire est d'étudier le potentiel des réseaux de neurones artificiels (PMC) afin de modéliser l' $ET_0$  et le déficit hydrique, en raison de leurs propriétés (généralisation et parcimonie).

En raison de la diversité des agents qui s'intéressent à la gestion et à la planification des ressources en eau (hydrologues, pédologues, agronomes etc.), nous avons fait notre étude à différentes pas de temps ; mensuel, décadaire et journalier.

Nous avons structuré ce mémoire en quatre chapitres :

- 1<sup>ère</sup> chapitre : Bibliographie, ayant pour objectif de faire une mise au point sur les aspects clés de notre thème à savoir l'évapotranspiration, le bilan hydrique, et le déficit hydrique.
- 2<sup>ème</sup> chapitre : Théorie des réseaux de neurones artificiels.
- 3<sup>ème</sup> chapitre : Matérielsetméthodes, permettant de présenter, la méthodologie de travail, le site d'étude (la plaine de la Mitidja) ainsi que les outils utilisés.
- 4<sup>ème</sup> chapitre : Résultatsetdiscussions, comportant les discussions concernant les différents aspects analysés.

Nous terminons ce mémoire par une conclusion générale dans laquelle nous présentons les résultats de notre travail, ainsi que les perspectives de recherche à développer.

---

# I. Synthèse bibliographique

## I.1. L'évapotranspiration ; Concepts généraux

### I.1.1. Notions liées à l'évapotranspiration

---

#### I.1.1.1. Introduction

La plante est constamment traversée par un flux d'eau à partir de sol vers l'atmosphère, il y a donc un échange continu de molécules d'eau entre le végétal et l'atmosphère, ce processus s'appelle la transpiration. Cependant, le sol libère des quantités en eau non négligeable par évaporation, la combinaison de ce deux termes donne l'évapotranspiration, elle est évaluée par  $m^3/ha$  ou encore en mm/j.

#### I.1.1.2. L'évapotranspiration potentielle ou l'évapotranspiration de référence

**Thornthwaite** (1948) est le premier à introduire le concept d'évapotranspiration potentielle, dans un contexte de classification du climat, il a surtout été utilisé par la suite dans des domaines tels que l'agriculture et l'hydrologie, comme calcul préliminaire au calcul de l'ETR. (Oudin, 2007). L'évapotranspiration potentielle (ETP) représente la quantité d'eau théoriquement maximale cédée à l'atmosphère (par transpiration de la plante et évaporation du sol) par une culture en pleine croissance, sur un sol pourvu en eau, elle caractérise l'énergie disponible conditionnant le pouvoir évaporant de l'air.


A l'époque du développement du concept d'ETP, le type et la forme de la végétation n'étaient pas pris en compte, cependant, les études initiales portaient sur des cultures de petites tailles (souvent du gazon), et de nouvelles méthodes ont été entreprises pour prendre en compte les caractéristiques de la végétation pour estimer l'ETP entendue en tant qu'évapotranspiration maximale d'une culture de référence ( $ET_0$ ), ensuite, les chercheurs (surtout les anglo-saxons) ont utilisé le vocable « évapotranspiration de référence » ( $ET_0$ ) pour désigner l'évapotranspiration potentielle.

Allen et al (1994) cités dans l'ouvrage « traité d'irrigation 1998 » ont défini l' $ET_0$  comme étant « l'évapotranspiration d'un couvert végétal "hypothétique" de référence ayant une hauteur de 12 cm, une résistance du couvert de 70 s/m et un albédo de 23%. Un couvert de gazon se développe activement sur une grande étendue régulièrement tendue, bien alimentée en eau et indemne de maladies ».

#### I.1.1.3. L'évapotranspiration réelle (ETR)

L'évapotranspiration réelle (ETR) correspond à la quantité d'eau réellement perdue par une culture, son importance dépend de la demande atmosphérique, des caractéristiques du couvert végétal et de son alimentation hydrique, elle atteint une valeur maximale (ETM) si l'alimentation hydrique n'est pas restrictive.

L'ETM est calculée à partir de l'évapotranspiration de référence 'ET<sub>0</sub>' en appliquant un coefficient cultural K<sub>c</sub> dépendant du type de culture et de son état de développement.



**Fig.1.1** : Courbe de coefficients culturaux (Doorenbos et Pruitt, 1975).

La figure.1.1 représente l'évolution du K<sub>c</sub> en fonction des stades phénologiques, il est minimum au début du développement de la culture, ensuite il augmente avec la croissance du végétal et l'augmentation de la couverture du sol, après il passe par un maximum au moment du stade adulte, pendant la phase reproductrice (floraison et formation du grain), enfin il décroît à l'approche de la maturation et de la récolte.

#### **1.1.1.4. Evapotranspiration optimale**

Parfois on soumet la culture sous contrainte hydrique et cela se fait en fonction des objectifs agronomiques et économiques fixés préalablement, le niveau de l'évapotranspiration qui correspond le mieux aux objectifs de production recherchés et aux moyens disponibles pour l'atteindre est appelé évapotranspiration optimale (ET<sub>opt</sub>). (Souag, 2007).


### **1.1.2. L'évaluation de l'évapotranspiration de référence**

L'évapotranspiration de référence peut être mesurée directement sur le terrain ou estimée indirectement à partir de paramètres climatiques.

#### **1.1.2.1. Mesure de l'évapotranspiration de référence**

Les cuves lysimétriques (lysimètres) sont l'une des plus fiables méthodes pour mesurer l'évapotranspiration. Le lysimètre est une cuve enterrée dans un sol, remplie d'une portion de terre, portant une culture à sa surface (généralement la culture de référence), présentant un système de drainage de telle façon que l'on peut évacuer et mesurer les eaux excédentaires.

L'évapotranspiration est évaluée par soustraction des apports aux pertes.



**Fig.1.2:** Cuve lysimétrique.

La mesure de l'évapotranspiration de référence ( $ET_0$ ) se fait en agronomie à l'échelle parcellaire avec une précision satisfaisante, mais il est difficile de l'utiliser à l'échelle du bassin versant, car il y a une grande différence entre la surface de la parcelle d'essai (dizaines de mètre), et celle du bassin versant (dizaines de  $km^2$ ).

### I.1.2.2. Estimation de l'évapotranspiration de référence

En raison de la difficulté de mesurer l' $ET_0$ , d'importantes formules ont été développées, dans des conditions climatiques diverses, permettant d'estimer l' $ET_0$  à partir de paramètres climatiques, mais elles se différencient par leur fondement théorique, et leurs données d'entrées exigées, le choix de la formule se fait alors en fonction de l'adéquation entre données nécessaires au calcul de l' $ET_0$  et données disponibles.

Ces formules sont classées en quatre types ; méthodes basées sur la température (Blaney et Criddle, Thornthwaite), méthodes basées sur le rayonnement (Hargreaves, Makkink..), méthodes basées sur l'évaporation des bacs (bac classe A, bac Colorado), et les méthodes combinées (Penman, Penman-Monteith, Penman-Monteith modifiée).

Jansen et al (1990), ont analysé la performance de vingt formules en se basant sur les données lysimétriques de onze stations situées dans différentes zones climatiques à travers le monde, les résultats obtenus ont prouvé que la formule de Penman-Monteith modifiée est la meilleure méthode pour estimer l'évapotranspiration de référence ( $ET_0$ ).

L'étude menée par les experts de la FAO ; Allen R.G et al (1998) in 'Crop Evapotranspiration, guideline for computing water requirements', a montré que :

- La méthode de Penman exige un calibrage local de la fonction vent pour avoir de résultats satisfaisants ;
- Les méthodes de rayonnement donnent de bons résultats en régions humides où le terme aérodynamique est suffisamment petit, mais elles sous estiment l'évapotranspiration en régions arides ;
- Les méthodes basées sur la température exigent le calibrage local afin d'obtenir de résultats satisfaisants ;

- Les méthodes basées sur l'évaporation de bac sont influencées par les conditions microclimatiques dans lesquelles les bacs sont placés, elles exigent beaucoup d'entretien et de suivi, elles sont donc déconseillées ;
- L'analyse et la comparaison de plusieurs méthodes d'estimation de l' $ET_0$  révèlent que celle de Penman-Monteith modifiée par la FAO est la plus recommandée dans les régions humides et arides, elle sert donc de référence si les données mesurées d' $ET_0$  sont absentes.

Dans cette étude on utilise les valeurs d' $ET_0$  obtenues par la formule de Penman-Monteith modifiée comme méthode de référence, en raison de sa performance et fiabilité et vu l'absence de données lysimétriques, l'évapotranspiration de référence peut s'écrire selon la formule de Penman-Monteith modifiée (Allen et al., 1994) :

$$ET_0 = \frac{0,408\Delta(R_n - G) + \gamma \frac{900}{T + 273} U_2 (e_s - e_a)}{\Delta + \gamma(1 + 0,34 U_2)}$$

Avec :

$ET_0$  : Evapotranspiration de référence journalière (mm/j) ;

$R_n$  : Rayonnement net à la surface de culture ( $M J/m^2/j$ ) ;

$G$  : Flux de chaleur échangé avec le sol ( $M J/m^2/j$ ) ;

$T$  : Température moyenne journalière ( $^{\circ}C$ ) ;

$U_2$  : Vitesse moyenne journalière du vent mesurée à 2 mètres du sol (m/s) ;

$e_s$  et  $e_a$  : Respectivement la pression de vapeur saturante, et la pression réelle de l'air à la même hauteur (kPa) ;

$\Delta$  : Pente de la courbe de pression de vapeur saturante à la température  $T$  (kPa / $^{\circ}C$ ) ;

$\gamma$  : Constante psychrométrique (kPa / $^{\circ}C$ ).

### **I.1.3. Modélisation de l'évapotranspiration ; synthèse bibliographique**

---

Les modèles de l'estimation de l'évapotranspiration se différencient de simples formules à des modèles complexes basés sur plusieurs approches tels que l'intelligence artificielle (modèles neuronaux, modèles neuro-flous, algorithmes génétiques), et modèles conceptuels.

La mesure directe de l'évapotranspiration par le biais de lysimètre est lourde et onéreuse, une alternative attirante, c'est l'utilisation des formules empiriques en utilisant les variables climatiques comme entrées, une autre alternative consiste à utiliser les réseaux de neurones artificiels (RNA), les modèles neuro-flous, les algorithmes génétiques.

Récemment, d'excellents résultats ont été obtenus par l'application des réseaux de neurones artificiels en hydrologie (évaporation et évapotranspiration), en raison de leur facilité d'application, ils sont devenus aujourd'hui un outil puissant en modélisation hydrologique avec un potentiel surprenant.



**Kumar** et al, (2002), ont conclu qu'un modèle neuronal de type Perceptron multicouches (PMC), entraîné avec les données lysimétriques de l' $ET_0$  est plus performant que la formule de Penman-Monteith modifiée dans l'estimation de l'évapotranspiration de référence ( $ET_0$ ).

**Sudher** et al, (2003), ont utilisé un réseau de neurones de type RBF (Radial Basic Function), entraîné avec les données lysimétriques, pour évaluer l'évapotranspiration de la culture de riz durant une période de cinq mois, les résultats obtenus par cette étude ont montré clairement l'aptitude des réseaux de neurones artificiels dans l'estimation de l'évapotranspiration réelle, avec une efficacité (critère de Nash) allant de 98% à 99%.

L'étude menée en Espagne par **Landras** et al, (2008), a mis en évidence que les réseaux de neurones artificiels entraînés avec les valeurs d' $ET_0$  obtenues par la formule de Penman-Monteith modifiée sont plus performants que les formules empiriques calibrées par régression linéaire en se basant sur les valeurs de cette dernière.

**Ali R.K.** (2008), a montré le potentiel de réseaux de neurones artificiels de type Perceptron multicouches (PMC) pour estimer l' $ET_0$  partir des températures minimales et maximales et les valeurs de l'évaporation de bac, il a conclu qu'on puisse convertir l'évaporation de bac en évapotranspiration de référence en utilisant les techniques de l'intelligence artificielle.

**Sungwon, k** et al, (2007), ont étudié le potentiel de RNAs de type « generalized regression neural networks models » (GRNNM) tout en intégrant les Algorithmes Génétiques (GA), en se basant sur les données lysimétriques de la culture de référence, dans ce cas là c'est la luzerne, en République de la Corée, pour estimer l' $ET_0$  (luzerne) et l'évaporation de bac à partir de paramètres climatiques, les résultats obtenus sont prometteurs avec un critère de performance root mean square error (RMSE) allant 0.3 à 0.5 mm/j.

Les réseaux de neurones artificiels ont été également utilisés pour la prévision hydrologique, **Trajkov** et al (2003) modélise l'évapotranspiration de référence  $ET_0(t+1)$  à partir de  $ET_0(t-11)$  et de  $ET_0(t-21)$  avec une bonne précision (t: c'est le temps en jour).

## I.2. Notions générales sur le Sol-Plante-Atmosphère-Continuum (SPAC)

### I.2.1. Introduction

---

On apprécie aujourd'hui le cycle de l'eau au champ en considérant l'ensemble des parties impliquées, à savoir le sol, les plantes et l'atmosphère. Celles-ci constituent du point de vue des transferts hydriques une entité physique dans laquelle divers processus de circulation se déroulent d'une manière interdépendante, comme les maillons d'une chaîne. Cette entité a été appelée le **SPAC** (sol-plante-atmosphère continuum) par Philip, 1966. Dans ce système, l'eau est présente sous forme liquide, vapeur et parfois solide (neige, glace).

Comment mieux maîtriser l'irrigation pour accroître son efficacité et mieux valoriser l'eau ? Une meilleure connaissance des relations sol-plante-atmosphère, ainsi que

l'évolution technologique des équipements permettent de mieux ajuster le choix des assolements, des matériels et des stratégies de conduite des arrosages.

Pour simplifier l'analyse des relations sol-plante-atmosphère, le cheminement de l'eau dans le continuum sol-plante-atmosphère peut être décomposé en quatre étapes successives dont la réalisation définit les conditions de l'alimentation hydrique d'une plante :

- Au départ la phase d'approvisionnement correspond à l'interception des flux d'eau par le système racinaire, cette interception se réalise par les transferts d'eau dans le sol (l'eau circule dans le sol, et du sol vers les racines), mais également par la croissance du système racinaire qui permet de coloniser des zones du sol non encore exploitées ;
- L'eau va ensuite passer du milieu extérieur (le sol en général) vers le milieu intérieur (les vaisseaux de xylème de la racine) : c'est la phase d'absorption ;
- Lors de la phase de transport, l'eau parvient jusqu'aux sites d'utilisation, et en particulier dans la feuille ;
- Elle est alors vaporisée et retourne vers le milieu extérieur : c'est la phase de transpiration (Loïc Pagès et al., 1998).

## **I.2.2. L'eau dans le sol**

---

Deux expressions importantes employées pour décrire l'état de l'eau dans le sol, la teneur en eau et le potentiel hydrique.

### **I.2.2.1. Teneur en eau**

La première expression, la teneur en eau qui est une mesure de la quantité de l'eau dans le sol en poids ou en volume, et elle est définie comme l'eau perdue du sol lors du séchage d'une masse du sol frais constant à 105°C° (Soil Science Society of America., 1997), elle s'exprime en unité de masse de l'eau par unité de masse du sol sec (kg/kg), ou par unité du volume de l'eau par unité volume du sol (m<sup>3</sup> / m<sup>3</sup>). (Kirkham, 2005).

### **I.2.2.2. Le Potentiel hydrique**

Le potentiel hydrique est formellement défini comme étant le travail qu'une quantité unitaire d'eau, dans un système sol- plante- atmosphère en équilibre, est capable de fournir quand elle se déplace à température constante de l'état référentiel à un autre point. L'état de référence est défini communément comme celui de l'eau pure (Badji et Feyen, 1994 in Souag, 2007).

L'eau du sol est soumise aux champs de force provenant de la présence de la phase solide (la matrice) ;le champ de la gravité ;leslluiuy les sels dissous

Le potentiel hydrique peut être exprimé soit en unité d'énergie par unité de masse, soit en unité d'énergie par unité de volume, soit en unité d'énergie par unité de poids.

### **I.2.2.3. Humidités caractéristiques du sol**

Plusieurs valeurs d'humidité (pondérales ou volumiques) permettent de caractériser un sol.

#### **I.2.2.3.1. Humidité à saturation**

On parle de l'humidité à saturation quand le sol est complètement gorgé d'eau, c'est-à-dire que l'espace poreux est plein, et cela aura lieu après une forte pluie ou une irrigation, cette humidité est supérieure à celle de la capacité au champ, dans ce cas là, l'eau circule librement sous l'effet de la gravité.

### **I.2.2.3.2. Humidité à la capacité au champ**

Pour définir la capacité au champ nous considérons ce qui suit, dans le sol, après une forte pluie ou une irrigation, l'eau commence immédiatement à s'écouler en profondeur, après un ou deux jours la teneur en eau dans le sol diminuera, avec le temps, on aura une valeur presque constante pour une profondeur donnée, cette valeur quelque peu arbitraire de teneur en eau, exprimée en pourcentage, s'appelle la capacité de champ, de façon pratique, on considère en général que la capacité au champ correspond à un potentiel hydrique compris entre -0,1 à -0.5 bar.

### **I.2.2.3.3. Humidité critique ( $H_c$ )**

C'est l'humidité du sol en dessous de laquelle la plante commence à souffrir d'une contrainte hydrique ( $ETR < ETM$ ) (Rojas, 1984), on constate que l'humidité critique est d'autant plus faible que la vitesse de dessèchement du sol est plus lente, c'est-à-dire que :

- L'évapotranspiration est moins forte ;
- Le volume du sol exploré par les racines est plus important.

Cette valeur de l'humidité est donc une notion importante, mais essentiellement fluctuante, puisqu'elle ne dépend pas seulement du sol, mais aussi du climat et des caractéristiques de la plante.

### **I.2.2.3.4. Humidité au point de flétrissement**

Le Point de flétrissement, est défini comme étant la quantité de l'eau par unité de poids ou par unité de volume de sol, exprimée en pourcentage, qui est retenue étroitement par la matrice de sol de telle façon que les racines ne puissent pas absorber cette eau, et la plante se flétrit, il correspond à un potentiel hydrique de -16 bars.

### **I.2.2.3.5. Humidité hygroscopique**

Le sol peut continuer à se dessécher au-delà du point de flétrissement, sans toutefois atteindre une sécheresse absolue, cette valeur d'humidité correspond à la quantité d'eau retenue par les particules du sol en équilibre avec le potentiel hydrique moyen de l'atmosphère (Hillel, 1982).

### **I.2.2.3.6. Eau de constitution**

Ce sont les molécules d'eau engagées dans les édifices chimiques des constituants du sol, elles ne disparaissent qu'à haute température (450° et plus) lorsque la matière subit des réarrangements moléculaires. (Souag, 2007).

### **I.2.2.4. Définition du réservoir sol (réserve utile)**

La réserve utile (RU) est définie comme la quantité d'eau disponible pour la végétation entre une valeur maximale atteinte à la capacité au champ ( $H_{cc}$ ) et une valeur minimale (point de flétrissement permanent ( $HP_{fp}$ )), atteinte lorsque l'on estime que la tranche de sol

considérée ne peut plus fournir d'eau à la végétation, elle comprend la réserve facilement utilisable (RFU) et la réserve difficilement utilisable (RDU).

$$RU = (H_{cc} - H_{pfp}) \cdot Da \cdot Z$$

$H_{cc}$  et  $H_{pfp}$ : humidité pondérales en %

$Da$  : Densité apparente

$Z$  : Profondeur racinaire

#### **1.2.2.4.1. Réserve facilement utilisable**

La réserve facilement utilisable (RFU) correspond à la fraction de la réserve utile (RU) où la plante peut extraire l'eau du sol sans trop d'efforts.

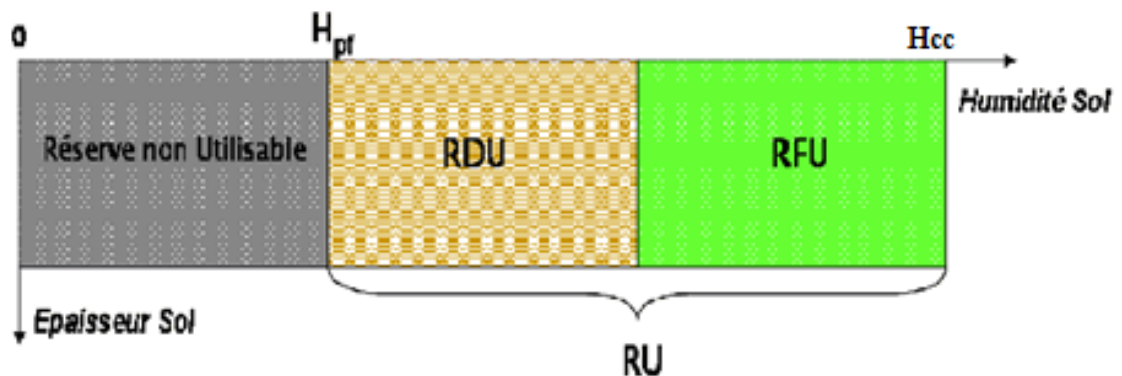
$$RFU = \alpha \cdot RU$$

**Le coefficient  $\alpha$  est fonction du type de sol.**

#### **1.2.2.4.2. Réserve difficilement utilisable**

La réserve difficilement utilisable (RDU) ou la réserve de survie correspond à la fraction de la réserve utile où la plante doit fournir un effort considérable pour extraire l'eau à partir du sol.

La disponibilité de l'eau dépend de la texture de sol, certains chercheurs signalent certains que l'eau disponible pour une argile lourde est supérieure de dix fois qu'un sable.




*Fig.1.3: Disponibilité de l'eau d'une couche de sol pour les plantes.*

## **1.3. Bilan hydrique**

### **1.3.1. Définition**

Le bilan hydrique est traduit par l'énoncé de la loi de conservation de la matière qui stipule que la matière ne peut être ni créée ni détruite, mais qu'elle passe seulement d'un état à l'autre, ainsi la teneur en eau d'un volume du sol donné ne peut augmenter sans un apport

venant de l'extérieur (par infiltration ou remontée capillaire par exemple) et ne peut diminuer à moins que de l'eau ne soit pas transportée vers l'atmosphère par évapotranspiration ou en profondeur par drainage ( Hillel, 1980).



**Fig.I.4:** Principaux termes du bilan hydrique.

Le bilan hydrique est une représentation de la réalité mais il ne demande qu'un nombre limité de données pour son utilisation, le but de ce bilan est d'estimer la réserve en eau dans la zone racinaire par le biais de l'équation de conservation de la masse.

Le bilan hydrique qui détermine l'évolution du stock d'eau jour après jour, (selon le fonctionnement physiologique de l'interface), il renseigne sur l'évolution instantanée de la disponibilité en eau (Perrier, 1996).

L'équation générale du bilan hydrique exprime la conservation de la masse d'eau dans le système sol plante atmosphère, sous sa forme simplifiée, entre deux dates, il s'écrit :

$$RH_j = RH_{j-1} + Pe_j + Rc_j - ETR_j - DR_j$$

**Avec**

$RH_j$  : Réserve hydrique du sol le jour (j) ;

$RH_{j-1}$  : Réserve hydrique du sol le jour (j-1) ;

$Pe_j$  : Pluie efficace le jour (j) ;

$Rc_j$  : Remontée capillaire le jour (j) ;

$ETR_j$  : Evapotranspiration réelle le jour (j) ;

$DR_j$  : Drainage en dehors de la zone racinaire le jour (j).

C'est une équation de récurrence permettant d'estimer la réserve hydrique du sol au cours du temps par itérations successives, cette équation permet également de déceler le moment où le déficit hydrique atteint un niveau critique.

### I.3.2. Modélisation du bilan hydrique

---

Un modèle est une représentation simplifiée, relativement abstraite, d'un processus, ou d'un système, en vue de le décrire, de l'expliquer ou de le prévoir. La modélisation hydrologique est donc une représentation, partielle ou totale, du cycle de l'eau, dans ce travail, on se limite à l'étude des modèles du bilan hydrique.

La réserve hydrique du sol est tributaire des conditions agrométéorologiques environnantes, et sa teneur en eau est dépendante des gains (précipitations et des remontés capillaires) et des pertes (évapotranspiration et percolation profonde), donc le recours à la modélisation du bilan hydrique constitue une alternative attirante afin de mieux gérer les ressources hydriques.

L'équation de conservation de la masse d'eau est valable à toutes les échelles de temps et d'espace. Chacun des termes du bilan hydrique obéit à des lois biophysiques, qu'il est possible de préciser jusqu'à des niveaux de détail élevés (dans le cas d'approches mécanistes lourdes), mais dont des approches simplifiées et empiriques offrent aussi des niveaux de précision acceptable pour une application donnée. Dans ce cadre la littérature fournit une multitude d'approches qui se distinguent les unes des autres par le niveau de simplification des phénomènes biophysiques élémentaires qu'elles prétendent représenter.

L'assemblage de différents modules (termes) liés organiquement par le fait qu'on leur impose de satisfaire l'équation de bilan hydrique forme un modèle de bilan hydrique. (Bernard M. et al., 1996).

L'objectif de l'utilisation des modèles de bilan hydrique est de suivre le niveau de la réserve en eau du sol  $[RH(t)]$  au cours du temps. Il est alors possible d'estimer l'ETR et son évolution afin de comparer l'état de satisfaction des besoins en eau de la culture aux objectifs fixés, selon les stades de végétation.

Dans l'analogie réservoir du sol, la réserve en eau  $RH(t)$  évolue en fonction des apports et des pertes en eau, elle constitue une des composantes de base dans la modélisation du bilan hydrique. Dans tout modèle de bilan hydrique, le calcul de l'évolution au cours du temps de la réserve en eau du sol constitue une des premières finalités du modèle (Choisnel, 1992). Le sol peut être considéré comme un réservoir unique (Forest, 1984 ; Lhomme et Eldin, 1985), un réservoir double (Choisnel, 19985) ou une série de couches (Resnoble, 2002).

#### I.3.2.1. Approches de la modélisation de bilan hydrique

D'après Choisnel (1992) Différentes approches de calcul du bilan hydrique font apparaître la possibilité de choisir un certain nombre d'options de modélisation, chacune correspondant à un degré plus ou moins élevé de complexité. Deux fonctions principales attribuées à un modèle de calcul du bilan hydrique ressortent : *la fonction de gestion de la réserve en eau au cours du temps et la fonction de régulation de l'évapotranspiration réelle ETR par rapport à son niveau maximal (ETM)*. Les modèles de bilan hydrique se différencient par leur façon de réaliser ces deux fonctions, ils sont classés en deux catégories : modèles mécanistes et modèles empiriques.

##### I.3.2.1.1. Modèles mécanistes ou complexes

Les modèles mécanistes décrivent avec précision le processus de diffusion de l'eau dans le sol avec un pas de temps généralement plus petit qu'un jour. Ils exigent les solutions aux écoulements de l'eau dans le sol par des méthodes numériques (Lhomme et Katerji, 1991).

Ces modèles considèrent le sol comme étant une succession de couches superposées de caractéristiques et d'épaisseurs propres à chacune, permettant de définir un profil hétérogène d'humidité du sol.

### I.3.2.1.2. Modèles empiriques

Les modèles empiriques sont basés sur des hypothèses simplificatrices de réalité de terrain, mais ils présentent un niveau de précision acceptable pour une application donnée, généralement ils sont appelés '*modèles agrométéorologiques*' du fait qu'ils n'exigent que certains paramètres météorologiques et agronomiques. Le sol est considéré comme un réservoir qui se remplit et se vide en fonction des apports et des pertes (sol monocouches).

Les modèles agrométéorologiques du bilan hydrique sont constitués d'un ensemble de sous modèles ou modules, chacun simule un terme de bilan hydrique : la disponibilité en eau dans le sol, et l'évapotranspiration de la plante ou drainage (Lhomme et Katerji, 1991).

### I.3.2.2. Initialisation de bilan hydrique

Choisnel (1992) fait la distinction entre trois cas différents :

- 1<sup>er</sup> cas : la simulation du bilan hydrique est pluriannuelle, on ne fait alors qu'une seule initialisation, le 1<sup>er</sup> janvier de la première année simulée, on suppose alors qu'à cette date :  $R(t) = RU$ .
- Si les résultats de la première année simulée sont influencés par cette hypothèse parfois optimiste, cette initialisation sera oubliée dès la seconde année de simulation (Choisnel, 1992 in Souag ,2007).
- 2<sup>ème</sup> cas : On ne simule qu'une période de végétation, dans ce cas, on peut en général, en climat tempéré, et sauf anomalie négative exceptionnelle de pluviométrie au cours de l'automne et de l'hiver précédent, faire l'hypothèse  $R(t) = RU$  au 1<sup>er</sup> mars, sachant qu'en général, il n'y a pas de désaturation de réservoir en janvier et février car à cette époque les précipitations sont en moyenne supérieures à l'évapotranspiration potentielle. En climat tropical sec, par contre, on fera l'hypothèse que la réserve en eau du sol est nulle à la fin de la saison sèche (Choisnel, 1992 in Souag ,2007).
- 3<sup>ème</sup> cas : Initialisation à une date quelconque, c'est le cas où l'on simule une parcelle particulière dont on a déterminé in situ l'état hydrique moyen dans le sol à cette date.

### I.3.2.3. Pas de temps

Il dépend de l'unité de temps choisie lors de la constitution des fichiers climatologiques. Trois pas de temps sont principalement utilisés : l'heure, le jour et la décade. Il est difficile de travailler à un pas de temps de l'ordre du mois, car on perd alors toute notion de simultanéité des événements météorologiques et d'interdépendance des variables météorologiques entre elles (Choisnel, 1992), l'avantage du pas de temps journalier par rapport à celui du

pas de temps décadaire est de mieux pouvoir tenir compte de la succession des épisodes pluvieux et de l'intermittence de ceux-ci.

## **I.4. Le déficit hydrique**

Le déficit hydrique est un élément clé dans la gestion des ressources hydrique en agriculture, il permet de connaître la quantité en eau que l'on doit apporter pour mettre la culture dans une situation de confort hydrique, on parle de déficit hydrique quand la plante est sous contrainte hydrique, et celle-ci pénalise le rendement, plusieurs modalités sont considérées pour caractériser le déficit hydrique.

### **I.4.1. Déficit hydrique climatique (DHC)**

---

Pour une culture et une région données, le déficit hydrique climatique peut être évalué comme étant égal à la différence entre la pluie et l'évapotranspiration potentielle. En zone aride et semi-aride, ce déficit est généralement négatif, indiquant que la pluviométrie ne couvre que partiellement les besoins en eau des cultures, cette méthode a l'avantage de ne nécessiter aucune hypothèse sur la réserve utile du sol, mais elle suppose implicitement que le sol ne contribue pas, par sa propre réserve en eau, à l'évapotranspiration (Choisnel., 1985).

### **I.4.2. Déficit hydrique d'alimentation DHa**

---

Le suivie du bilan hydrique pour une culture donnée peut être réalisé à l'aide d'un indicateur de déficit hydrique d'alimentation (*ETM-ETR* ou encore le rapport *ETM/ETR*), l'irrigation se fait dès que certain seuil de déficit, déterminé préalablement soit atteint.

La différence *ETM-ETR* est considérée comme étant la dose d'irrigation, si on procède au calcul au pas de temps décadaire.

La valeur de déficit hydrique d'alimentation doit être maintenue dans un niveau admissible, en fonction des stades de développement, des objectifs fixés, afin que le rendement ne soit pas pénalisé.

### **I.4.3. Déficit hydrique du sol**

---

C'est la quantité en eau manquante dans la tranche de sol considérée pour que la réserve utile de sol soit remplie, la variation de ce déficit hydrique du sol doit se faire à l'intérieur de l'intervalle [0, RFU].

$$DH_j = RU - RH_j \iff DH_j = RU - (RH_{j-1} + P_j - ETR_j - D_j)$$
$$DH_j = DH_{j-1} + ETR_j + D_j - P_j$$

C'est une équation de récurrence permettant d'estimer le déficit hydrique jour après jour par itérations successives en faisant recours au calcul de bilan hydrique, l'initialisation



du calcul débute quand la réserve utile du sol est complètement remplie ( $DH_{j-1}=0$ ), ou entièrement asséchée ( $DH_{j-1}=RU$ ).

## II. Théorie des Réseaux de Neurones Artificiels

### II.1. Introduction

L'homme n'a rien inventé mais il a essayé depuis l'Antiquité de mimer la nature pour améliorer ses conditions de vie. La fabrication de l'avion en imitant les oiseaux, ensuite la modification de la séquence d'ADN des plantes après avoir découvert les processus biotechnologiques chez l'*Agrobacterium tumefaciens*, l'invention de système d'irrigation par aspersion en simulant les pluies, dernièrement, il a essayé de reproduire la réflexion humaine en créant par analogie du système nerveux biologique ce que l'on appelle les réseaux de neurones artificiels (RNA) qui servent à résoudre diverses fonctions ou problèmes non linéaires, récemment, il a inventé les algorithmes génétiques (AG) par analogie du processus génétiques qui se déroulent chez les êtres vivants.

Les réseaux de neurones artificiels sont des modèles inspirés de la neurobiologie qui imitent le fonctionnement du cerveau. Ils sont basés sur la fonction neuronale, parce que les neurones sont identifiés comme éléments cellulaires responsables du traitement de l'information dans le cerveau. Les réseaux de neurones artificiels se sont donc basés sur l'hypothèse disant que le raisonnement intelligent des êtres humains a pour origine la structure de système nerveux et donc on peut l'inculquer à un ordinateur en lui implémentant un réseau de neurones artificiels pour le rendre « intelligent », tout en sauvegardant sa puissance et sa rapidité d'exécution.

L'approche neuronale s'est développée avec l'expansion de l'utilisation des outils informatiques qui facilitent l'analyse numérique de l'information et la mise en œuvre de cette méthode.

### II.2. Historique des réseaux de neurones artificiels

Un bref historique des travaux menés sur le réseau de neurones est énuméré ci-dessous dans l'ordre chronologique.

Rashevsky (1938) lance des études sur la neurodynamique, également connues sous le nom de théorie neurale de champ, représentant l'activation et la propagation dans les réseaux neurologiques sous forme d'équations différentielles.

McCulloch et Pitts (1943) montrent que le réseau de neurones artificiels peut, en principe, calculer n'importe quelle fonction arithmétique et logique, ces travaux sont souvent considérés comme l'origine des réseaux de neurones artificiels (Martin T et Hargan Haward B., 1996).

Landahl, McCulloch, et Pitts (1943) ont montré que beaucoup d'opérations arithmétiques et logiques peuvent être mises en application en utilisant des méthodes basant sur les modèles neuronaux de McCulloch et de Pitts.

Wiener (1948) présente une approche mathématique en neurodynamique, prolongeant le travail lancé par Rashevsky.

En 1949, dans "The Organization of Behavior", un livre influent, Hebb suit les suggestions de Lashley et de Cajal, et il présente sa règle célèbre d'apprentissage : l'activation répétée d'un neurone par les autres, à travers une synapse particulière, augmente sa conductibilité.

Cragg et Temperly (1954) reformulent le réseau de McCulloch et de Pitts sous forme de modèle "spin glass" bien connu chez les physiciens.

Taylor (1956) présente un réseau de mémoire associative en utilisant la règle de Hebb.

Beurle (1956) analyse le déclenchement et la propagation de l'activité de cerveau à grande échelle.

Von Neumann (1956) montre comment présenter la redondance et la tolérance de fautes dans les réseaux de neurones, et il montre comment l'activation synchrone de beaucoup de neurones peut être employée pour représenter chaque bit de données.

Uttley (1956) démontre que les réseaux de neurones avec les connections modifiables pourraient apprendre à classifier des modèles avec les poids synaptiques représentant des probabilités conditionnelles, il développe un séparateur linéaire dans lequel des poids sont ajustés en utilisant la mesure de l'entropie de Shannon.

Rosenblatt (1958) invente la "perceptron" présentant une méthode d'étude pour le modèle neuronal de McCulloch et de Pitts.

Widrow et Hoff (1960) présentent "l'Adaline", un réseau simple qualifié par une règle de descente de gradient pour réduire au minimum l'erreur carrée moyenne.

Rosenblatt (1961) propose la Backpropagation pour l'apprentissage des réseaux multicouches; cette tentative était non réussie parce qu'il a employé des fonctions non différentiables. (Kishan et al., 1996).

Hubel et Wiesel (1962) ont entrepris des études biologiques importantes sur les propriétés des neurones dans le cortex visuel des chats, stimulant le développement des modèles neuronaux artificiels à organisation automatique qui ont simulé ces propriétés. (Kishan et al., 1996).

Minsky et Papert (1969) publient le livre Perceptrons dans lequel ils utilisent une solide argumentation mathématique pour démontrer les limitations des réseaux de neurones à une seule couche. Ce livre a une influence telle que la plupart des chercheurs quittent le champ de recherche sur les réseaux de neurones, et c'était un grand tournant dans la modélisation par les réseaux de neurones, entre 1969 à 1985, la recherche s'est complètement arrêté, et que les grandes sociétés n'ont pas daigné financer la recherche dans ce domaine.

Rumelhart, Hinton et Williams (1986) publient l'algorithme de la rétropropagation de l'erreur qui permet d'optimiser les paramètres d'un réseau de neurones à plusieurs couches, c'est elle qui a permis de donner un nouvel élan aux réseaux de neurones artificiels. À partir de ce moment, la recherche sur les réseaux de neurones connaît un essor fulgurant et les applications commerciales de ce succès académique suivent au cours des années 90.

Aujourd'hui, les réseaux de neurones artificiels possèdent un fondement théorique solide, constituent un ensemble d'opérateurs linéaires et non linéaires permettant grâce à leurs caractéristiques fonctionnelles une large utilisation dans différentes disciplines scientifiques.

En hydrologie, vu la non linéarité du processus de l'évapotranspiration et du déficit hydrique, plusieurs auteurs ont utilisé les réseaux de neurones artificiels pour modéliser ces phénomènes à différents pas de temps (Landras et al., 2008, Ozgur., 2006, Ali Khoob., 2008, Sungwon et al., 2008, Souag., 2007).

## **II.3. Quelques domaines d'application des réseaux de neurones artificiels**

On utilise les réseaux de neurones artificiels dans différents domaines (informatique, électronique, science cognitive, hydrologie, neurobiologie), l'étude des réseaux de neurones est une voie prometteuse de l'Intelligence Artificielle, qui a des applications dans de nombreux domaines:

- Industrie : contrôle qualité, diagnostic de panne, corrélations entre les données fournies par différents capteurs, analyse de signature ou d'écriture manuscrite.
- Finance : prévision et modélisation du marché (cours de monnaies...), sélection d'investissements, attribution de crédits.
- Télécommunications et informatique : analyse du signal, reconnaissance de formes (bruits, images, paroles), compression de données.
- Environnement : évaluation des risques, analyse chimique, prévisions et modélisation météorologiques et hydrologiques, gestion des ressources.

## **II.4. Réseau de neurones: fondement biologique**

Les modèles neuronaux ont été développés par analogie avec les neurones biologiques, il est donc important de rappeler au préalable son fonctionnement.

### **II.4.1. Le neurone**

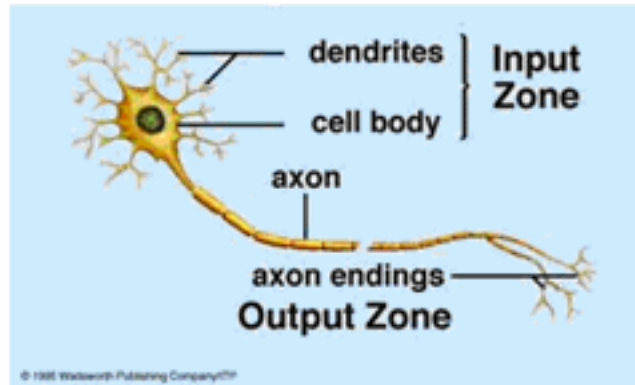
---

Les cellules nerveuses, appelées neurones, constituent les éléments structuraux et fonctionnels du système nerveux central, l'Organisme humain possède environ cent milliards de neurones. Celles-ci sont des cellules somatiques et ont plusieurs points en commun dans leurs organisations avec les autres cellules, cependant elles sont extrêmement spécialisées, puisqu'elles assurent plusieurs fonctions :

- Recevoir des signaux en provenance de neurones voisins ;
- Intégrer ces signaux ;
- Engendrer un flux nerveux ;
- Conduire le flux nerveux et le transmettre à un autre neurone capable de le recevoir.

Du point de vue anatomique, le neurone est une cellule composée d'un corps cellulaire et d'un noyau, d'un axone, le corps cellulaire se ramifie pour former les dendrites.

C'est par les dendrites que les informations sont acheminées de l'extérieur vers le soma, qui présente le corps du neurone.



*Fig.II.1 : Neurone biologique*

### II.4.2. Le corps cellulaire

---

Il contient le noyau du neurone et effectue les transformations biochimiques nécessaires à la synthèse des enzymes et des autres molécules qui assurent la vie du neurone. Sa forme est pyramidale ou sphérique dans la plupart des cas, elle dépend souvent de sa position dans le cerveau.

### II.4.3. Les dendrites

---

Chaque neurone possède une « chevelure » de dendrites, celles-ci sont de fines extensions tubulaires, elles se ramifient, ce qui les amènent à former une espèce d'arborescence autour du corps cellulaire, elles sont les récepteurs principaux du neurone pour capter les signaux qui leur parviennent.

### II.4.4. L'axone

---

L'axone, qui est la fibre nerveuse, sert de moyen de transport pour les signaux émis par le neurone. Il se distingue des dendrites par sa forme et par les propriétés de sa membrane externe. En effet, il est généralement plus long que les dendrites, et se ramifie à l'extrémité, là où il communique avec d'autres neurones, alors que les ramifications des dendrites se produisent plutôt près du corps cellulaire.

Pour former le système nerveux, les neurones sont connectés les uns aux autres suivant des répartitions spatiales complexes, les connexions entre deux neurones se font en des endroits appelés synapses où ils sont séparés par des espaces synaptiques.

La communication entre les neurones à travers l'espace synaptique se fait par des substances chimiques appelées « neurotransmetteurs ».

## II.5. Réseaux de neurones artificiels

### II.5.1. Principe général

Les réseaux de neurones artificiels (RNA) sont des modèles mathématiques non linéaires, de type « boîte noire », capables de déterminer des relations entre données par la présentation (l'analyse) répétée d'exemples (à savoir des couples constitués par des informations d'entrée et une valeur de sortie que l'on voudrait approcher par le modèle).




Fig.II.2 : modèle neuronal.

*Fig.II.2 : modèle neuronal.*

La modélisation à l'aide de réseaux de neurones artificiels suppose l'adaptation des paramètres du réseau, afin de mettre en évidence les relations qui portent sur les exemples présentés. Les réseaux de neurones artificiels sont constitués d'un ensemble d'éléments de calcul (neurones artificiels), organisés dans une structure spécifique, les paramètres du réseau (les poids) étant représentés par les valeurs associées aux connexions de ces éléments de calcul, un élément de calcul du réseau de neurone artificiel (RNA) comporte plusieurs entrées et une sortie.

La valeur de sortie est obtenue par l'application d'une relation mathématique (fonction d'activation) sur la somme pondérée d'entrées.


Dans la modélisation à l'aide de réseaux de neurones artificiels, on peut choisir le type de fonctions d'activation, le nombre de neurones et l'arrangement de leurs connexions (à savoir la structure du réseau). Généralement, on utilise des fonctions d'activation de type sigmoïde (Adrian D et al., 2002).

### II.5.2. Structure d'un neurone artificiel (formel)

Un neurone formel, ou neurone, au sens informatique du terme, est une fonction algébrique non linéaire et bornée, dont la valeur dépend de paramètres appelés coefficients ou poids. Les variables de cette fonction sont habituellement appelées « entrées » du neurone, et la valeur de la fonction est appelée sortie. Un neurone est donc avant tout un opérateur mathématique.

La figure II.3 montre la structure d'un neurone artificiel, ce dernier est un processeur élémentaire, il reçoit un nombre de variable d'entrées en provenance de neurones précédents. A chacune de ces entrées est associée un poids  $w$  représentatif de la force de

la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones avals, à chaque connexion est associée un poids (Heddam, 2006).



**Fig.II.3:** Mise en correspondance neurone biologique / neurone artificiel.

Le tableau suivant représente une comparaison entre les deux réseaux de neurones (biologique et artificiel).

**Tableau II.1: Analogie entre les neurones biologiques et artificiels**

Neurone biologique	Neurone artificiel	Représentation symbolique
Soma	Neurone	
Dendrite	Intrant ou entrée ( <i>Input</i> )	$x_i, x$ (intrant net)
Axone	Extrant ou sortie ( <i>Output</i> )	$Y$
Synapse	Poids (weight)	$w_i$

Chaque neurone artificiel reçoit un nombre variable d'entrées ( $x_i$ ) en provenance de neurone amont. A chacune de ces entrées est associé un poids ( $w_i$ ) représentatif de la force de la connexion.

Un poids d'un neurone artificiel représente donc l'efficacité d'une connexion synaptique, un poids négatif vient inhiber une entrée, alors qu'un poids positif vient l'accentuer (Benkaci, 2006).




Fig.II.4 : Neurone formel.

### II.5.3. Fonctionnement mathématique du neurone artificiel

Le fonctionnement mathématique du neurone artificiel est contrôlé par deux fonctions à savoir :

- La fonction de base (fonction discriminant) ;
- Et la fonction dynamique.

#### II.5.3.1. Fonction de base (fonction discriminant)

Elle définit l'activité du neurone, la plus utilisée est la fonction linéaire (la somme pondérée), elle est définie par :

$$\phi(w_i, x_i) = w_1 * x_1 + \dots + w_n * x_n - b = \sum_{i=1}^n (x_i * w_i) - b$$

**Avec :**

$x_1, x_2, \dots, x_n$  : Entrées, ou encore les excitations ;

$w_1, w_2, \dots, w_n$  : Coefficients synaptiques ou poids synaptiques ;

$b$  : Représente le biais (constant).

Avec :

$x_1, x_2, \dots, x_n$  : Entrées, ou encore les excitations ;  $w_1, w_2, \dots, w_n$  : Coefficients synaptiques ou poids synaptiques ;


$b$  : Représente le biais (constant).

#### V.5.3.2. Fonction dynamique



C'est la fonction dite d'activation (transfert) qui a pour objectif de rendre l'activité du neurone bornée. Cette fonction doit être nonlinéaire, continue dérivable et monotone. La fonction d'activation calcule la valeur de l'état du neurone. C'est cette valeur qui sera transmise aux neurones avals (Benkaci, 2006). Le choix d'une fonction de transfert se révèle être un élément constitutif important des réseaux de neurones.

Il existe de nombreuses formes possibles pour la fonction de transfert, les plus courantes sont les fonctions linéaires, binaires, sigmoïdes, et radiales (gaussiennes).



**Fig.II.5:** Différents types de fonctions de transfert.

On remarquera qu'à la différence des neurones biologiques dont l'état est binaire, la plupart des fonctions de transfert sont continues, offrant une infinité de valeurs comprises dans l'intervalle.

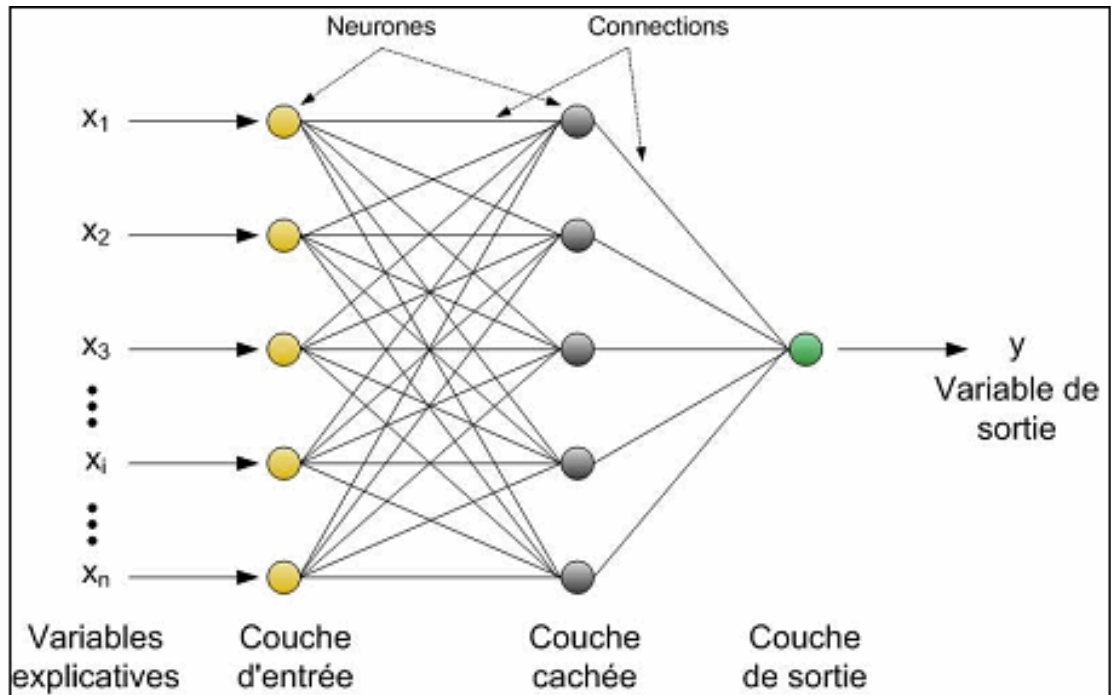
$$[-1, +1] ; [0, +1] \text{ ou même } [-\infty, +\infty].$$

## II.5.4. Classification des réseaux de neurones artificiels

Il existe de nombreux types de réseaux de neurones, on peut les classer selon leur architecture et leur mode d'apprentissage.

### II.5.4.1. Architecture générale des réseaux de neurones

Un réseau de neurones est un maillage de plusieurs neurones, généralement organisé en couches, effectuant un calcul selon une fonction d'activation (neurones) et des connections reliant les neurones entre eux (poids).




*Fig.II.6 : Réseau de neurones artificiel.*

Selon l'architecture, les réseaux de neurones peuvent être classés en deux types, Les réseaux de neurones bouclés et les réseaux de neurones non bouclés (en couches).

#### II.5.4.1.1. Réseaux de neurones dynamiques

Ils sont appelés aussi, réseaux de neurones bouclés ou récurrents, contrairement aux réseaux de neurones non bouclés, les réseaux de neurones bouclés peuvent avoir une topologie de connexions quelconque, comprenant notamment des boucles qui ramènent aux entrées la valeur d'une ou plusieurs sorties.



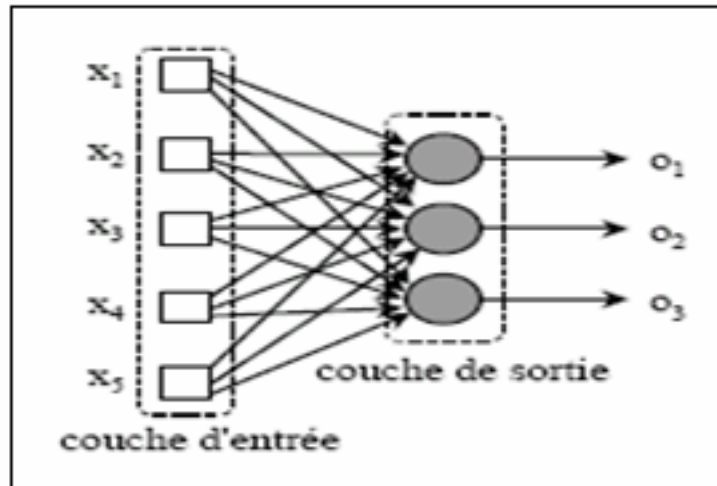
*Fig.II.7 : Réseau bouclé.*

#### II.5.4.1.2. Réseaux de neurones non bouclés ou en couches (Perceptron)

Appelés aussi " réseaux "Feed-Forward", ce sont des réseaux dans lesquels l'information se propage de couche en couche sans retour en arrière possible (feed back).

### II.5.4.1.2.1. Le Perceptron monocouche

C'est historiquement le premier RNA, c'est le Perceptron de Rosenblatt. C'est un réseau simple, puisque il ne se compose que d'une couche d'entrée et d'une couche de sortie. Il est calqué, à la base, sur le système visuel et de ce fait a été conçu dans un but premier de reconnaissance des formes. Cependant, il peut aussi être utilisé pour faire de la classification et pour résoudre des opérations logiques simples (telle "ET" ou "OU"). Sa principale limite est qu'il ne peut résoudre que des problèmes linéairement séparables. Il suit généralement un apprentissage supervisé selon la règle de correction de l'erreur (ou selon la règle de Hebb).



*Fig.II.8 : Réseaux à une seule couche.*

### II.5.4.1.2.2. Le Perceptron multicouches

Le Perceptron multicouches est sans doute le plus simple et le plus connu des réseaux des neurones, la structure est relativement simple : une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées. Chaque neurone n'est relié qu'aux neurones de couche précédente.

Réseau multicouche : les neurones sont arrangés par couche. Il n'y a pas de connexion entre neurones d'une même couche et les connexions ne se font qu'avec les neurones de couches avales. Habituellement, chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et celle-ci seulement. Ceci nous permet d'introduire la notion de sens de parcours de l'information (de l'activation) au sein d'un réseau et donc définir les concepts de neurone d'entrée, neurone de sortie. Par extension, on appelle couche d'entrée l'ensemble des neurones d'entrée, couche de sortie l'ensemble des neurones de sortie, les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelées couches cachées.

Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante (excepté pour les couches d'entrée et de sortie) et il n'y a pas de connexions entre les cellules d'une même couche. Les fonctions d'activation utilisées dans ce type de réseaux sont principalement les fonctions à seuil ou sigmoïdes, il suit aussi un apprentissage supervisé selon la règle de correction de l'erreur.




Fig.II.9 : Réseaux "FeedForward" multicouches.

#### II.5.4.1.2.3. Perceptron Multi-Couches (PMC) et approximation de fonctions

Les réseaux de neurones artificiels sont un outil extrêmement précieux pour résoudre les problèmes non linéaires, surtout si on dispose d'un large ensemble d'apprentissage.

Lorsque l'on veut modéliser un processus à partir des données, on cherche toujours à obtenir les résultats les plus satisfaisants possibles avec un nombre minimum de paramètres ajustables.

Dans cette optique, Hornik [Hornik, 1994, in Rajai., 2002] a montré que :

« Si le résultat de l'approximation (c'est à dire la sortie du réseau de neurones) est une fonction non linéaire des paramètres ajustables, elle est plus parcimonieuse que si elle était une fonction linéaire de ces paramètres. De plus, pour des réseaux de neurones à fonction d'activation sigmoïdale, l'erreur commise dans l'approximation varie comme l'inverse du nombre de neurones cachés, et elle est indépendante du nombre de variables de la fonction à approcher. Par conséquent, pour une précision donnée, le nombre de paramètres du réseau est proportionnel au nombre de variables de la fonction à approcher ».

Ces résultats s'appliquent aux Perceptrons Multi-Couches à fonction d'activation sigmoïdale.

Ces propriétés (approximation et parcimonie) sont démontrées de manière générale à condition d'avoir une architecture adéquate. Dans le cas où l'architecture ne serait pas adaptée, celles-ci ne peuvent pas s'appliquer, elles constituent néanmoins une justification fondamentale de l'utilisation des Perceptrons Multi-Couches.

#### II.5.4.2. Apprentissage des réseaux de neurones

Le calage (apprentissage) : au sens strict du terme, c'est l'opération qui consiste à trouver les valeurs des paramètres du modèle qui minimisent l'erreur de modélisation.

L'apprentissage du modèle neuronal est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié en réaction avec les stimuli qu'il reçoit de son environnement jusqu'à l'obtention du comportement désiré. Généralement, les paramètres modifiés sont les poids synaptiques qui relient les neurones entre eux.

L'objectif de l'apprentissage est de réduire l'erreur globale jusqu'à l'obtention d'une erreur acceptable.

Il existe plusieurs règles d'apprentissage qui peuvent être regroupées en trois grandes catégories, l'apprentissage non supervisé et l'apprentissage semi-supervisé ou par renforcement et l'apprentissage supervisé, (Dreyfus et al., 2004).

### **II.5.4.2.1. Apprentissage non supervisé**

Il s'agit d'apporter au réseau de neurone les entrées sans faire appel à la réponse désirée.

Dans ce cas, les exemples présentés à l'entrée provoquent une autoadaptation du réseau afin de produire des valeurs de sortie. Ce type d'apprentissage est moins utilisé par rapport aux autres modes d'apprentissage.

Un réseau de neurones non bouclé peut être utilisé dans un but de visualisation ou d'analyse de données : on dispose d'un ensemble de données, représentées par des vecteurs de grande dimension, et l'on cherche à les regrouper, selon des critères de ressemblance qui sont inconnus a priori. Ce type de tâches est connu en statistique sous le nom de méthodes « d'agrégation » (en anglais clustering). (Dreyfus et al., 2004).

### **II.5.4.2.2. L'apprentissage semi-supervisé ou par renforcement**

L'apprentissage semi-supervisé ou par renforcement (apprentissage par Récompense et Pénalité) : représente une technique nouvelle, dans ce cas on fournit des exemples au réseau et sur le résultat des indications par un superviseur qui est régi par un de degrés de performance (vrai ou faux). (Benkaci, 2005).

### **II.5.4.2.3. Apprentissage supervisé des réseaux de neurones artificiels**

Dans ce cas on apporte au modèle neuronal les entrées mais aussi la ou les sorties désirées c'est-à-dire qu'on présente au réseau un ensemble de couples (entrées-sorties désirées), L'apprentissage neuronal fait appel donc à des exemples de comportement. La réponse de neurone de sortie est alors comparée aux valeurs attendues. Le but de L'apprentissage supervisé est d'inculquer un comportement de référence au réseau.

#### **II.5.4.2.3.1. Algorithmes d'apprentissage supervisé**

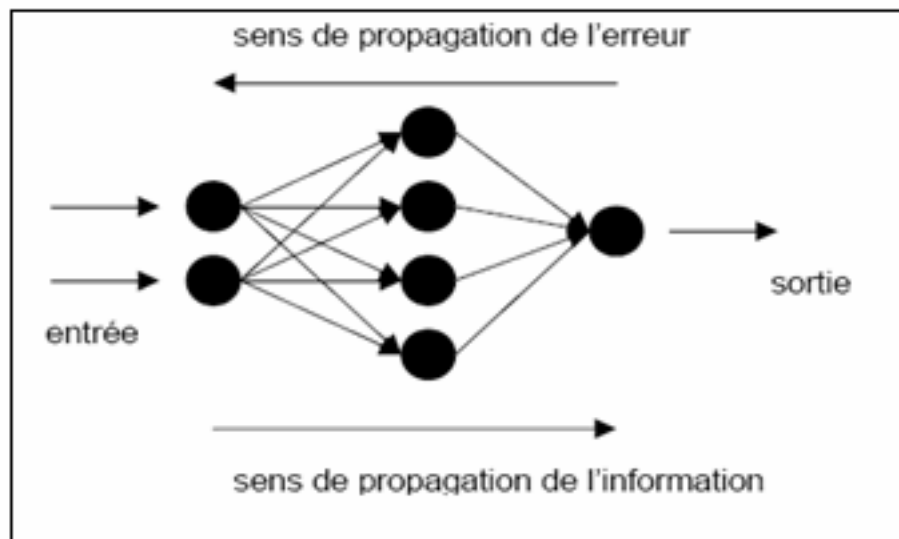
Les algorithmes d'apprentissage itératifs utilisés dans les réseaux de neurones explorent l'espace des paramètres (i.e. poids et biais du réseau) à partir d'un point de départ fixé par les valeurs initiales de ces paramètres et selon une trajectoire qui sera fonction de l'algorithme utilisé et des données.

L'apprentissage "supervisé", pour les réseaux de neurones formels, consiste à modifier les coefficients (poids synaptique  $W$ ) de telle manière que les sorties du réseau de neurones soient, pour les exemples utilisés lors de l'apprentissage, aussi proches que possible des sorties "désirées", qui peuvent être la valeur de la fonction que l'on veut approcher ou de la sortie du processus que l'on veut modéliser, ou encore la sortie souhaitée du processus à commander. La plupart des algorithmes d'apprentissage des réseaux de neurones formels sont des algorithmes d'optimisation, s cherchent à minimiser, par des méthodes d'optimisation non linéaire, une fonction de coût qui constitue une mesure de l'écart entre les réponses réelles du réseau et ses réponses désirées.

- Cette optimisation se fait de manière itérative, en modifiant les poids en fonction du gradient de la fonction de coût: le gradient est estimé par une méthode spécifique aux réseaux de neurones, dite dans notre cas, la méthode de rétropropagation, puis il est utilisé par l'algorithme d'optimisation proprement dit. Les poids sont initialisés aléatoirement avant l'apprentissage, puis modifiés itérativement jusqu'à obtention d'un compromis satisfaisant entre la précision de l'approximation sur l'ensemble d'apprentissage et la précision de l'approximation sur un ensemble de test disjoint du précédent. Contrairement à des affirmations maintes fois répétées, l'apprentissage des réseaux de neurones n'est pas spécialement lent: il existe des algorithmes d'optimisation non linéaires extrêmement rapides qui permettent de faire des développements industriels sur de simples PC. L'apprentissage des réseaux de neurones bouclés (pour réaliser des modèles dynamiques) est très semblable à celui des réseaux non bouclés.

#### **II.5.4.2.3.1.1. La Backpropagation**

La rétro propagation du gradient était à la base de la réussite réalisée par les réseaux de neurones artificiels, c'est la méthode la plus utilisée aujourd'hui dans les algorithmes d'apprentissage des réseaux multicouches. Il s'agit d'une méthode d'apprentissage supervisée fondée sur la modification des poids synaptiques dans le sens inverse de propagation de l'information dans le réseau et en fonction de l'erreur produite, d'où la nomenclature de rétro propagation ou Backpropagation.



**Fig.II.10** :. rétro- propagation des gradients

La rétro- propagation des gradients se fait "en amont" dès la couche de sortie vers la couche d'entrée.

#### **II.5.4.2.3.1.1.a. Algorithme de Backpropagation**

L'algorithme de rétropropagation du gradient est un algorithme itératif, les poids sont modifiés à chaque étape selon les instructions suivantes :

1. Initialiser les poids synaptiques à de petites valeurs aléatoires comprises en général entre  $-1$  et  $1$ .
2. Présenter un nouvel exemple  $X_p$  à l'entrée du réseau.

Calculer la sortie du réseau et l'erreur en sortie :

$$E_p = \sum_{i=1}^{n_s} (d_i^p - y_i^p)^2$$

Où  $i$  parcourt les indices des neurones de sortie,  $d_i$  et  $y_i$  représentent respectivement l'activation mesurée et l'activation désirée pour les neurones ;

1. les poids du réseau sont modifiés suivant la règle :

$$[\Delta w_{ij}^l] = \eta f'(u_i^l(t)) \delta_i^l y_j^{l-1}$$

Où  $\eta$  est une constante positive appelée pas du gradient (Taux d'apprentissage), et contrôle la vitesse de l'apprentissage.

$$\text{Avec : } \delta_i^l = \begin{cases} (d_i^p - y_i^p) & \text{Pour les neurones de la couche de sortie} \\ \sum_{k=1}^{k_{l+1}} \delta_k^{l+1} w_{ki}^{l+1} & \text{Pour les neurones des autres couches.} \end{cases}$$

S'il s'agit d'un Data Learning (FFN pattern), réadapter les poids :

$$4) \text{ Poser : } \Delta w_{ij}^l(t) = [\Delta w_{ij}^l(t)]_p$$

S'il s'agit d'un Block Learning (FFN Batch):

Aller à 5.

Si  $p \neq M$  ( $M$  étant le nombre d'exemple d'entraînement), retourner à 1.

$$\text{Sinon : } \Delta w_{ij}^l(t) = \sum_{p=1}^{p=M} [\Delta w_{ij}^l(t)]_p$$

Réadapter les poids.

$$\Delta w_{ij}^l(t+1) = w_{ij}^l(t) + \Delta w_{ij}^l(t)$$

Répéter de 1 à 5. Autant de fois que nécessaire jusqu'à convergence vers le seuil d'erreur fixé.

L'apprentissage avec cet algorithme (réadaptation des poids) se fait par deux manières différentes, à savoir Block Adaptive Learning, et l'apprentissage par données Data Adaptive Learning.

Block Adaptive Learning (Batch learning):

En Batch Training les poids et les biais de réseau de neurones ne sont ajustés qu'après le passage total sur la base d'entraînement. Les gradients calculés à chaque passage sur la base d'entraînement sont ajoutés ensemble pour déterminer le changement des poids et des biais. La fonction de coût qui calcule l'erreur est :

$$E_p = \sum_{i=1}^{nL} (d_i^p)^2 - \sum_{i=1}^{nL} (y_i^p)^2$$

Cette méthode est jugée plus robuste, cependant les données simulées correspondent à une moyenne de données observées (Benkaci, 2006).

Data Adaptive Learning (Incremental Learning):

Les poids sont ajustés itérativement après chaque exemple. Lors du passage sur la base d'entraînement et le calcul des erreurs, ces dernières sont présentées immédiatement pour adapter les poids, sans accumuler tous les changements jusqu'à la fin de l'itération (David et al., 2006). Pour cette méthode d'apprentissage, les poids sont réadaptés au passage de chaque exemple :

$$E_p = \sum_{i=1}^{nL} (d_i^p - y_i^L)^2$$

#### **II.5.4.2.3.1.1.a. b. Méthode d'optimisation avec la Backpropagation**

Il existe de nombreuses méthodes (variantes) d'optimisation avec la Backpropagation, on cite à titre indicatif celle de Levenberg-Marquardt (la commande *trainlm* in Matlab).

· L'algorithme de Levenberg-Marquardt

C'est une variante de l'algorithme d'apprentissage de rétropropagation du gradient (Backpropagation) visant à améliorer les performances de cet algorithme. Il est utilisé par défaut sous MATLAB. C'est la méthode la plus rapide dans la « boîte à outils » de réseau de neurones (ANN toolbox), mais elle exige de large espace de mémoire.

Une étude menée par l'auteur de guide d'utilisateur de la boîte à outil de réseaux de neurones sous Matlab (*Neural Network Toolbox User's Guide*) a montré que dans les problèmes d'approximation de fonction et pour les réseaux qui contiennent jusqu'à quelques centaines de poids synaptiques, l'algorithme de Levenberg-Marquardt aura la convergence la plus rapide. L'avantage est particulièrement apparent si l'apprentissage très précis est exigé. Dans beaucoup de cas, l'algorithme de Levenberg-Marquardt permet d'obtenir des erreurs quadratiques moyennes inférieures à celles trouvées par d'autres algorithmes utilisés. Cependant, à mesure que le nombre de poids dans le réseau augmente, l'avantage de l'algorithme de Levenberg-Marquardt diminue.

Dans ce travail, vu ses propriétés, on va utiliser cette variante de Backpropagation.

### **II.5.5. Avantages et inconvénients des réseaux de neurones artificiels**

---



### II.5.5.1. Avantages des réseaux de neurones artificiels

Récemment, les réseaux de neurones artificiels sont appliqués en modélisation météorologique, agro écologique et hydrologique ; la plupart de publications éditées dans la littérature concernent l'estimation, la prédiction et la classification. Les applications de RNA sont rapidement diffusées vu leurs caractéristiques fonctionnelles, qui fournissent de nombreux avantages par rapport aux approches analytiques traditionnelles. (Demetris, 2007).

1. Les réseaux de neurones artificiels deviennent populaires ces dernières années, cette popularité peut être attribuée à leur apparente facilité d'utilisation. Comme pour d'autres modèles dits « boîtes noires » et contrairement aux modèles « conceptuels » la construction d'un modèle pour une étude de cas particulier ne demande pas d'analyse détaillée et de compréhension des relations entre variables de forçage et variables dépendantes. Ce sont les algorithmes d'apprentissage (de calage) des réseaux qui analyseront automatiquement ces relations. D'autre part, comme les fonctions polynomiales, et contrairement au modèle linéaire, les réseaux de neurones sont des interpolateurs universels (universel approximators) ce qui veut dire qu'ils sont capables d'approcher n'importe quelle fonction continue et ceci quel que soit le niveau d'approximation souhaité (Hornik et al., 1989 in Eric, 2000).
2. Une propriété fondamentale de l'apprentissage réalisé concerne les capacités de généralisation de ces réseaux. Dans le cas où l'architecture initiale est correctement choisie, on constate généralement que les exemples ne sont pas appris, mais que le réseau est capable d'étendre les connaissances acquises à des exemples proches ou intermédiaires (généralisation=interpolation + extrapolation) ( Benkaci, 2006).
3. Les réseaux de neurones artificiels offrent des avantages significatifs par rapport à la régression linéaire multiple et d'autres méthodes conventionnelles dans la prévision de l'évapotranspiration parce qu'il n'est pas nécessaire d'indiquer la forme du modèle mathématique avant d'adapter les données. C'est important puisque beaucoup de processus agronomiques de système ont des facteurs multiples qui changent avec le temps. En conséquence il est souvent difficile de trouver un modèle mathématique approprié pour décrire ces processus. Cependant que ces réseaux neuronaux devront être examinés contre d'autres modèles et avec des données climatiques variées provenant de diverses régions climatiques et géographiques , nous nous sentons que ce réseau neuronal est une technique prometteuse à aider dans des processus de compréhension dans les systèmes agronomiques compliqués et dynamiques. (Huien H & Peter F, 1997).
4. L'avantage pratique des réseaux de neurones par rapport aux techniques classiques de modélisation non linéaire réside donc dans leur capacité à réaliser des modèles de précision équivalente avec moins de données expérimentales (ou dans leur capacité à constituer des modèles plus précis à partir du même nombre d'exemples). De manière générale, les réseaux de neurones permettent de tirer le meilleur parti des données numériques disponibles, pour construire des modèles à plusieurs entrées ; c'est la propriété parcimonieuse de RNA (Dreyfus, 2004).
5. Daniell et al (1991) a utilisé les réseaux de neurones pour la prévision de la demande en eau de la ville de Camberra en Australie. Le modèle neuronal utilisé est un PMC avec 5 variables d'entrées, 7 neurones sur la couche cachée, et 1 neurone de sortie d'où la notation RNA(5, 7, 1). L'apprentissage est effectué à l'aide de l'ARP standard. Les résultats obtenus sont comparés à ceux d'un modèle de régression linéaire. L'auteur remarque que la tolérance du modèle neuronal aux lacunes et aux

erreurs liées aux données est excellente par rapport à celle du modèle régressif. Il en conclut que l'optimisation des procédures d'apprentissage et de configuration des RNA constitue un domaine de recherche attractif et d'avenir pour la modélisation hydrologique. (Paulin Coulibaly, François Anctil et Bernard Bobée, 1998).

### **II.5.5.2. Inconvénients des réseaux de neurones artificiels**

1. Malgré les avantages marqués, les RNAs comportent certains inconvénients.
2. La performance de modèle neuronal est souvent tributaire à son architecture. Or, le choix de l'architecture est un problème difficile à résoudre, l'inconvénient majeur de réseaux de neurones artificiels est l'absence d'une méthodologie permettant de déterminer le nombre de couches cachées, le nombre de neurones par couche cachée et le nombre d'itérations, seule les essais permettent de répondre à ces questions, et on ne sait pas si l'optimum sera atteint. Un autre inconvénient c'est le choix de la méthode d'apprentissage, celle-ci doit également être choisie de façon judicieuse.
3. les réseaux de neurones artificiels comme les autres modèles « boîte noire » ont un inconvénient majeur par rapport aux modèles conceptuels simples : on ne maîtrise pas leur comportement en extrapolation pour des valeurs de variables de forçage sortant considérablement de la gamme utilisée pour le calage du modèle.
4. Si la fonction d'activation des neurones de la couche cachée est la fonction sigmoïde et le neurone de la couche de sortie est linéaire, alors la donnée de sortie du réseau est nécessairement bornée. Ceci peut poser un problème lorsque le réseau simule des données non bornées. Il ne peut pas être en mesure de simuler des valeurs nettement supérieures aux valeurs présentes dans l'échantillon de données utilisé pour le calage du réseau de neurones. (Eric, 2000).
5. On ne maîtrise pas l'évolution des variables de sortie du réseau de neurones lorsque les variables de forçage sortent sensiblement de la gamme des valeurs pour lesquelles le modèle a été calé. (Eric, 2000)
6. Les réseaux de neurones artificiels (RNA) présentent l'avantage de ne requérir qu'une structure de modélisation formelle pour être ajustés aux données expérimentales ; cependant, leur principal inconvénient est la perte de transparence du modèle (de type « boîte noire »), et le manque d'indicateurs pour l'évaluation de la précision et de la fiabilité de la réponse des RNA quand on est en présence de comportements nouveaux. (Alessandro, 1997).
7. Les modèles de type « boîte noire » tel que les RNAs ne conviennent pas à l'analyse du fonctionnement interne du bassin versant, ils sont donc peu utilisés à cette échelle (Benkaci, 2006).

## **II.5.6. Choix de paramètres du modèle neuronal**

---

### **II.5.6.1. Choix d'un réseau de neurones**

Il existe un grand nombre de types de réseaux de neurones qui sont utilisés dans de nombreux domaines, mais chaque type a son domaine propice d'utilisation, cependant, l'utilisation de plusieurs types et la comparaison entre eux constituent le seul moyen pour déterminer le meilleur type en fonction de champs de recherche.

D'après des recherches récentes (Kumar et al., 2002, Landras et al., 2008, Ali RK, 2008, Kumar et al., 2008, Seema Chauhan R.K. Shrivastava, 2008), les PMC apportent de

bon résultats pour l'estimation de l'évapotranspiration de référence à partir des variables climatiques.

### II.5.6.2. Choix de nombre de couches cachées :

Les résultats obtenus par plusieurs chercheurs (Kumar et al., 2002, Landras et al., 2008), en utilisant le PMC avec l'algorithme de Backpropagation, variante de Levenberg-Marquardt, et les variables climatiques comme entrées de réseaux pour estimer l' $ET_0$ , confirment que les modèles neuronaux à une seule couche cachée sont suffisants pour rendre compte à la relation non linéaire existante entre les données climatiques et l' $ET_0$  correspondante.

### II.5.6.3. Choix de nombre de neurones par couche cachée:

Le nombre d'unités cachées joue un rôle crucial dans le contrôle de la capacité du réseau de neurones.

L'erreur commise par un réseau de neurones est inversement proportionnel au nombre de neurones cachés (Dreyfus, 2004) malheureusement, ce résultat, comme d'autres considérations théoriques n'est pas constructif, en ce sens qu'il ne peut que donner des estimations, ou des bornes larges, du nombre de neurones cachés nécessaires. Il n'existe pas, à l'heure actuelle, de résultat théorique permettant de prévoir le nombre de neurones cachés nécessaires pour obtenir une performance spécifiée du modèle, compte tenu des données disponibles. Il faut donc nécessairement mettre en oeuvre une procédure numérique de conception de modèle (Dreyfus, 2004).

### II.5.6.4. Paramètres d'apprentissage

Les paramètres d'apprentissage sont :

- La fonction coût est l'erreur quadratique, inférieure ou égale à 0.01.
- Taux d'apprentissage : L'exécution de l'algorithme de Backpropagation est très sensible au taux d'apprentissage. S'il est très grand, l'algorithme peut osciller et devient instable, s'il est trop petit, l'algorithme mettra longtemps avant de converger. Le taux d'apprentissage est fixé à 0.7 (selon les travaux de Kumar et al., 2002).
- Le nombre d'itération est un paramètre très important, il influence considérablement les résultats obtenus. Le nombre d'itération optimum est celui qui permettra d'atteindre un minimum sur l'erreur commise. Il n'y a pas de règle utilisée pour déterminer ce nombre, les essais et la comparaison (*trial-and-error, step-by-step, one-by-one*) constituent une méthode fiable afin de le déterminer.

## II.5.7. Conclusion

---

Dans ce chapitre nous avons mis en évidence la démarche de recherche dans le domaine des réseaux des neurones artificiels, ainsi que leur mode de fonctionnement.

L'utilisation de réseaux de neurones artificiels est avantageuse chaque fois que l'on cherche à établir une relation non linéaire entre les valeurs numériques à condition que l'on dispose de données suffisamment nombreuses et représentatives.

Les réseaux de neurones artificiels ouvrent une nouvelle ère dans la modélisation des phénomènes non linéaires tel que l' $ET_0$ , il suffit d'entraîner le RNA en se basant sur les entrées et les targets (sorties désirées) et par la suite on n'apporte au RNA que les entrées,

il va prédire les sorties et tout ça se fait sans connaître le formalisme intérieurs de RNA d'où le nom de modèle « boîte noire » ou encore « black box », ils sont également appelés « data-driven-models ».

---

## III. Matériels et Méthodes

### III. 1. La méthodologie de travail

#### III.1.1. Introduction

---

Dans ce travail on étudie l'évapotranspiration de référence, et le déficit hydrique estimé par certains modèles agrométéorologiques de bilan hydrique, tout en adoptant l'utilisation des réseaux de neurones artificiels pour les deux cas (évapotranspiration et déficit hydrique).

La détermination de l'évapotranspiration de référence ( $ET_0$ ) est un facteur clé dans le pilotage des irrigations et le calcul du bilan hydrique.

L'évapotranspiration peut être mesurée directement par des techniques météorologiques coûteuses (lysimètre), ou estimée par des modèles mathématiques. L'équation combinée de Penman-Monteith modifiée par Allen et al [Allen, R.G., Pereira, L.S., Raes, D., Smith, M., 1998. Crop evapotranspiration. Guidelines for computing crop water requirements. FAO Irrigation and Drainage, Paper no. 56. FAO, Rome], est la référence pour estimer l' $ET_0$  (Landeras G et al., 2008). Cette méthode est également adéquate pour caler les autres équations de l'estimation de l' $ET_0$ .

L'utilisation des ces équations calées à partir de celle de PM56 est fortement recommandée en l'absence de certaines données ou paramètres météorologiques nécessaires pour appliquer le modèle de Penman-Monteith modifiée.

En plus de l'utilisation des équations classiques de l' $ET_0$ , l'adoption des modèles de réseaux de neurones artificiels (RNA) pour l'estimation de l'évapotranspiration de référence vont être étudiés dans ce travail. Les réseaux de neurones artificiels (RNA) sont des modèles mathématiques dont l'architecture est inspirée de réseaux de neurones biologiques. Ils sont fortement adaptés dans la modélisation des processus non linéaires comme l'évapotranspiration, l'avantage principal de la méthode de réseaux de neurones artificiels par rapport aux méthodes conventionnelles est sa capacité à résoudre des problèmes qui sont difficiles à formaliser.

Plusieurs réseaux de neurones (avec différentes combinaisons de données d'entrée et de nombre de neurones cachées) vont être implémentés et comparés avec l'équation standard de Penman-Monteith modifiée (qui utilise les paramètres météorologiques comme entrées).

Les comparaisons vont être basées sur le traitement statistique des résultats tels que le coefficient de détermination et le root mean square error (RMSE).

La connaissance du bilan hydrique et ses composantes sont cruciales pour la gestion des ressources hydriques à l'échelle parcellaire. La quantification des eaux d'irrigation et leurs répartitions spatio-temporelles durant la saison de la culture a une importance primordiale pour le développement de la culture et la planification des ressources hydriques en agriculture, particulièrement dans les régions arides et semi aride où l'eau constitue le facteur limitant principale vis-à-vis la production agricole. (Xi-Bin Ji et Er-Si Kang., 2007).

Le bilan hydrique permet de déterminer l'état des réserves en eau du sol. Il est alors possible d'estimer l'ETR et son évolution afin de comparer l'état de satisfaction des besoins en eau de la culture aux objectifs fixés, selon les stades de végétation.

Un outil puissant d'analyse et de gestion des ressources hydriques c'est la modélisation du bilan hydrique, un modèle inclut plusieurs composantes ou modules (réserve en eau du sol, ETR, drainage).

Aujourd'hui plusieurs modèles agrométéorologiques du bilan hydrique ont été décrits dans la littérature, dont on va étudier le modèle de Rojas, d'Eldin et Lhomme.

En plus de l'utilisation de ceux-ci, nous avons adopté les réseaux de neurones artificiels (RNA) pour estimer le déficit hydrique d'alimentation en se basant sur les déficits obtenus par ces modèles agrométéorologiques de bilan hydrique.

Les résultats de déficit hydrique obtenus par les modèles du bilan hydrique vont être confrontés et comparés avec ceux établis par les réseaux de neurones artificiels (RNA), en se basant sur les traitements statistiques tels que le coefficient de détermination ( $R^2$ ) et le root mean square error (RMSE).

### **III.1.2.Situation géographique**

---

La zone d'étude se situe dans la plaine de la Mitidja qui est une vaste étendue de terres agricoles fertiles située dans le Nord et répartie sur quatre Wilayas: Alger, Blida, Tipaza, et Boumerdès, elle couvre une superficie de 145km<sup>2</sup>avec une longueur moyenne de 100km, une largeur variant de 10 à 18 km et une altitude moyenne de 100 m. elle est située entre les longitudes 2°32'00" à 3°19'00" et latitudes 36°25'17" à 36°47'40", elle présente des potentialités énormes pour le développement de l'agriculture.



*Source : (Imache A., 2004).*

**Fig.I.1. : Plaine de la Mitidja.**

**Source :** (Imache A., 2004).

### III.1.3. Acquisition des données météorologiques

Les données météorologiques sont fournies par la station météorologique de Dar El-Beida, dont les coordonnées sont comme suit :

Tableau.III.1 : Coordonnées de la station de Dar El-Beida.

Latitude	36.72°N
Longitude	3.25°E
Altitude ( m )	24.0

La série climatique utilisée dans ce travail concerne la station de Dar El-Beida (région d'Alger), s'étalant sur une période de dix années, allant de 1995 jusqu'au 2004, contenant les paramètres climatiques journaliers suivants: la température (moyenne, maximale et minimale), vitesse du vent, l'humidité relative, précipitation et la durée d'insolation.

En raison de l'absence des données lysimétriques, les valeurs d'évapotranspiration de référence sont estimées à l'aide de l'équation combinée de Penman-Monteith modifiée, en utilisant un programme écrit sous MATLAB permettant de calculer celle-ci à partir des paramètres climatiques.

Les paramètres statistiques de la série climatique utilisée sont représentés dans le tableau.III.2.

Variable climatique	Unités	Moyenne	Ecart-type	Coefficient de variation	Corrélation Avec ET <sub>0</sub>
ET <sub>0</sub>	mm	2,70	1,5	1,8	1,000
T <sub>mov</sub>	°C	18,1	5,9	3,1	0,802
T <sub>max</sub>	°C	24,4	6,2	3,9	0,776
T <sub>min</sub>	°C	11,6	6,0	1,9	0,711
Ins	Heures	7,60	3,7	2,0	0,497
HR	%	71,7	9,7	7,4	-0,518
U <sub>2</sub>	m/s	2,30	1,6	1,5	0,356
P	mm	1,60	5,4	0,3	

Tableau.III.2 : Paramètres statistiques de la série utilisée au pas de temps journalier.

ET<sub>0</sub> : Evapotranspiration de référence ; T<sub>moy</sub> : Température moyenne ; T<sub>max</sub> : Température maximale ; T<sub>min</sub> : Température minimale ; Ins : Durée d'insolation ; HR : Humidité relative ; U<sub>2</sub> : Vitesse du vent ; P : Précipitation.

Le tableau.III.2 montre que l'évapotranspiration de référence est fortement corrélée à la température (moyenne, minimale et maximale), et moyennement corrélée à la durée d'insolation, et faiblement corrélée à la vitesse de vent, elle est par contre négativement corrélée à l'humidité relative, puisque l'augmentation de l'humidité de l'air diminue le pouvoir évaporateur de l'air.

### III.1.4. Brève description des formules d'estimation d'ET<sub>0</sub> utilisées

Le tableau suivant décrit l'équation de Penman–Monteith modifiée (Allen et al., 1998) ainsi que les autres équations d'ET<sub>0</sub> utilisées dans cette étude.

Dans le tableau.III.3 nous avons classé les équations en deux catégories, équation de référence et équations d'ET<sub>0</sub>, l'équation de Penman–Monteith modifiée (Allen et al., 1998) est la référence de comparaison et de calibrage des autres équations ; les équations de Penman, Jensen et Haise, Hargreaves– Samani, Makkink, et Priestley–Taylor sont des équations d'ET<sub>0</sub>.

Groupe	modèle	inputs	Equation	L'expression Mathématique
• Equation référence • Equation d'ET <sub>0</sub>	EPM56	Tmax,min, moy y Ra, HR,u2	PM modifiée par la FAO56	$ET_e = \frac{0,408 \Delta (R_n - G) + \gamma \frac{900}{T + 273} U_z (e_s - e_a)}{\Delta + \gamma(1 + 0,34 U_z)}$
	EH/S	Tmax, min,moy	Hargreaves et Samani (1983)	$ET_e = 0.408 + 0.0023 * (T_{max} + 17.8) * \sqrt{(T_{max} - T_{min})} * R_s$
	EP/T	Tmax, min,moy Ra	Priestley et Taylor(1972)	$ETP = 0,408 \alpha \times \left[ \frac{\Delta}{\Delta + \gamma} \right] \times (R_n - G)$
	EJ/H	Tmoy Ra,Ra	Jensen et Haise(1963)	$ETP = (0.025 \times t + 0.08) \frac{R_s}{2.45}$
	E Mak	Tmin,max,moy Ra,	Makkink	$ET_e = 0.61 \frac{\Delta}{\Delta + \gamma} \cdot \frac{R_s}{2.45} - 0.12$
	EP	Tmoy,Ra,u2, H	Penman 1948	$ET_0 = \frac{\Delta}{\Delta + \gamma} * (R_n - G) + \frac{\gamma}{\Delta + \gamma} E_a$
24RD..... .....			FAO24	$ET_0 = a + b \left[ \frac{\Delta}{\Delta + \gamma} R_s \right]$

**Tableau.III.3.** Formules d'évapotranspiration de référence utilisées.

## III.2. Présentation de modèles de simulation du bilan hydrique utilisés pour estimer le déficit hydrique d'alimentation

Plusieurs modèles de bilan hydrique ont été conçus, et sont considérés comme étant une méthode de gestion et d'aide à la décision dans le domaine hydro agricole.

Dans ce qui suit on présente quelque modèles agrométéorologiques de simulation de bilan hydrique :



- Le modèle Pluie – ETP ;
- Modèle de Rojas ;
- Modèle d'Eldin et Lhomme ;
- Modele de Lhomme et Katerji.

### III.2.1. Le modèle Pluie – ETP

Ce bilan potentiel ne représente qu'une écriture très simplifiée du bilan hydrique réel. Cette méthode ne prend en considération ni le drainage en profondeur, ni le ruissellement de surface, deux paramètres qui sont pourtant importants pour une estimation précise de l'ETR d'une culture. Ce bilan ne prend également pas en compte le rôle du réservoir que joue le sol en stockant et en restituant l'eau pluviale. En effet c'est une méthode qui permet l'estimation du bilan hydrologique et non pas hydro agricole car elle ne caractérise en aucun cas les conditions d'alimentation en eau de la plante. (Souag, 2007).

En utilisant les valeurs journalières de la pluie et de l'évapotranspiration potentielle, la méthode du bilan simplifiée Pluie – ETP permet le calcul des ETR et par la suite des déficits hydriques.

Pour l'ETR journalière on distingue deux cas :

- Si  $P_j > ETP_j$   $ETR_j = ETP_j$

Si  $P_j < ETP_j$   $ETR_j = P_j$

Le déficit hydrique journalier est alors :

$$Dh_j = P_j - ETP_j$$

### III.2.2. Modèle Rojas

C'est un modèle agro météorologique basé sur le calcul du bilan hydrique à partir de la pluie, l'évapotranspiration et de la réserve hydrique du sol, il fonctionne au pas du temps journalier.

Le but est d'obtenir à partir de la matrice des pluies journalières  $\{p(m,365)\}$  et du vecteur des moyennes interannuelles journalières de l'ETP (ETP(365)) (cette pratique est justifiée par le fait que l'ETP varie peu d'une année à une autre), la matrice des quantités d'eau stockées dans le sol (RH(m, 365)).

#### III.2.2.1. Pluies efficaces

Une pluie assez faible ( $P < P_m$ ) qui tombe sur un sol très sec ( $RH < RDU$ ) est considérée évaporée immédiatement sans réussir à rejoindre les racines. La valeur de  $P_m$  est égale à  $1\text{mm.j}^{-1}$ .

- $Pe_j = P_j$  Si  $\{P_j \geq P_m\}$  où  $\{P_j < P_m \text{ et } RH_{j-1} > RDU\}$
- $Pe_j = 0$  Si  $\{P_j < P_m \text{ et } RH_{j-1} < RDU\}$

OÙ  $RH_{j-1}$  est la quantité d'eau stockée avant le jour considéré et j un indice qui représente le numéro du jour.

#### III.2.2.2. Evapotranspiration maximale

L'évapotranspiration maximale est calculée par la formule classique suivante :

$$ETM_j = K_c \cdot ETP_j$$

OÙ  $K_c$  est le coefficient cultural.

### **III.2.2.3. Evapotranspiration réelle (ETR)**

L'évapotranspiration est fonction de la réserve utile du sol,  $RH_j$ , et elle varie comme suit:

- $ETR_j = ETM_j$  Si  $\{RH_{j-1} \geq RDU\}$
- $ETR_j = ETM_j \times RH_{j-1} / RDU$  Si  $\{RH_{j-1} < RDU\}$ .

La 1<sup>ère</sup> condition signifie que la plante est dans une situation de confort hydrique si la réserve d'hier ( $j-1$ ) est  $\geq$  à la réserve difficilement utilisable, tandis que la 2<sup>ème</sup> signifie que celle-ci est sous contrainte hydrique si la réserve d'hier ( $j-1$ ) est  $<$  à  $RDU$ .

### **III.2.2.4. Equation du bilan hydrique**

Etablir un bilan, c'est donc calculer la différence entre les apports et les pertes, donc le bilan hydrique s'exprime par la formule :

$$RU_j = RH_{j-1} + P_e - ETR_j$$

Et va servir comme relation récurrente avec les conditions suivantes :

- Si  $RH_j \leq 0$  on prend la valeur  $RH_j = 0$ .
- Si  $RH_j > RU$  on prend la valeur  $RH_j = RU$ .

## **III.2.3. Modèle d'Eldin et Lhomme**

---

Le modèle est basé sur les données enregistrées du réseau météorologique, cherche à mieux caractériser les conditions d'alimentation en eau des plantes, à travers une simulation de l'évolution de la réserve hydrique du sol. Ce modèle est récurrent et opère au pas de temps journalier.

Les données climatiques qui servent d'entrée au modèle sont d'une part les précipitations journalières qui apparaissent sous la forme d'une matrice  $P_j$  ( $m, 365$ ),  $m$  représentant le nombre d'années d'enregistrement, d'autre part les valeurs moyennes interannuelles de l'évapotranspiration potentielle mises sous la forme d'un vecteur journalier  $E_{pj}$  ( $365$ ). A côté de ces données climatiques apparaîtront certains paramètres d'ajustement aux conditions spécifiques considérées, paramètres concernant le sol et la nature (Chourghal, 2003).

Le modèle peut être utilisé pour caractériser les risques de sécheresse ou d'excès d'eau d'une part, et d'autre part pour déterminer la date de semis d'une culture annuelle.

### **III.2.3.1. Evolution de la réserve utile**

Pour caractériser l'évolution de la réserve utile, le modèle utilise deux paramètres, d'une part la valeur  $RU_x$  de la réserve utile juste avant la récolte, donc, au maximum d'enracinement, d'autre part un coefficient  $C1$  qui définira « une réserve utile maximale », notée  $RU_n$ ,

$RU_n = C_1$  avec ( $0 < C_1 < 1$ ).  $RU_n$  représente dans le cas du sol nu, la quantité d'eau maximale pouvant être stockée dans la tranche du sol qui est censé contribuer à l'évapotranspiration.

Entre la date de semis notée  $S$  et la date de récolte notée  $R$ , la réserve va croître de  $RU_n$  à  $RU_x$ . Pour traduire mathématiquement de la façon la plus simple possible ce phénomène, le modèle choisit une loi de variation linéaire de la réserve utile entre les dates  $S$  et  $R$  en fonction du numéro du jour. Si  $DS_j$  représente la durée exprimée en nombre de jour, qui sépare la date  $S$  du jour  $j$  et  $DSR$  celle qui sépare les deux dates  $S$  et  $R$  (c'est-à-dire la longueur du cycle),  $RU_j$  représente la réserve utile du jour  $j$  et s'écrit (Chourghal, 2003) :

$$RU_j / RU_x = A_j = C_1 + (1 - C_1) \cdot DS_j / DSR$$

Sur l'année entière, la réserve utile va évoluer selon les équations suivantes :

$$\text{> } RU_j = C_1 RU_x \quad \text{si } j \in ]R, S[$$

$$\text{> } RU_j = A_j RU_x \quad \text{si } j \in [S, R]$$

Dans le cas d'une culture pérenne, l'hypothèse de la constance de la réserve utile à un niveau égal à  $RU_x$  est admise, ce qui revient à  $C_1 = 1$ .

### III.2.3.2. Evolution de l'évapotranspiration maximale

L'ETM est fonction de l'ETP et du taux du recouvrement du sol par la culture, alors :

$ETM = C_0 \cdot ETP$ , avec  $C_0$  étant un coefficient réducteur compris entre 0 et 1 de la date de semis  $S$  à la date  $C$ , que l'on définira comme celle à partir de laquelle la culture couvre à peu près complètement le sol. L'ETM évolue de  $C_0 ETP$  jusqu'à  $ETP$  et se maintiendra à ce niveau de la date  $C$  jusqu'à la date de récolte  $R$ . Entre  $S$  et  $R$ , l'ETM évolue linéairement par rapport à l'ETP en fonction du numéro du jour, comme dans le cas de la réserve utile :

$$ETM_j / ETP_j = B_j = C_0 + (1 - C_0) \cdot DS_j / DSC$$

Sur l'année entière, l'ETM va évoluer comme suit :

$$\text{> } ETM_j / ETP_j = 1, \text{ si } j \in [C, R]$$

$$\text{> } ETM_j / ETP_j = C_0, \text{ si } j \in [R, S]$$

$$\text{> } ETM_j / ETP_j = B_j, \text{ si } j \in [S, C]$$

Pour une culture pérenne,  $ETM = ETP$  tout au long de l'année.

### III.2.3.3. Calcul de pluie efficace

Dans ce cas, les pluies trop faibles ( $P < P_n$ ), sont évaporées immédiatement et ne contribuent pas à la reconstitution de la réserve hydrique, si  $P$  désigne la pluie enregistrée et  $P_e$  la pluie efficace :

- $P_e = P$ , si  $P \geq P_n$
- $P_e = 0$ , si  $P < P_n$ .

Le sol est considéré horizontal de façon à pouvoir annuler le ruissellement, si l'intensité de la pluie est supérieure à la capacité d'infiltration, l'eau qui ne s'infiltré pas sera sur place à l'état libre jusqu'au moment où elle s'infiltré ou s'évapore.

### **III.2.3.4. Calcul du drainage**

Si la quantité de pluie tombée le jour  $j$  excède la capacité d'infiltration du sol, il y aura drainage (percolation hors de la zone racinaire). La capacité de rétention du sol le jour  $j$ , notée  $CR_j$ , correspond à la différence entre la réserve utile du jour  $j$  et la réserve hydrique effective du jour précédent :

$$CR_j = RU_j - RH_{j-1}$$

La quantité d'eau perdue par drainage s'écrit :

- $DR_j = P_j - CR_j$ , si  $P_j > CR_j$
- $DR_j = 0$ , si  $P_j \leq CR_j$

### **III.2.3.5. Calcul de l'évapotranspiration réelle**

Le rapport  $ETR/ETM$  représente le taux de satisfaction des besoins en eau des cultures, il est fonction de l'état de la réserve hydrique du sol.

Le modèle émet l'hypothèse que le rapport  $ETR/ETM$  croit linéairement de 0 à 1 en fonction de la réserve hydrique  $RH$  du sol. Ce rapport est inférieur à 1 lorsque la réserve hydrique est comprise entre 0 et  $RDU$ , et qu'il se maintient à 1 lorsque la réserve fluctue entre  $RDU$  et  $RU$ .  $RH_{j-1}$  représentant l'état de la réserve à la fin du jour  $j-1$  et donc le début du jour  $j$  :

- $ETR/ETM = 1$  Si  $RH_{j-1} \geq RDU_j$
- $ETR/ETM = RH_{j-1}/RDU_j$

La réserve facilement utilisable est calculée par la formule suivante :

$$RFU = C_2 RU$$

Dans laquelle  $C_2$  représente un coefficient d'ajustement ( $0 < C_2 < 1$ ), il constitue un autre paramètre d'entrée du modèle. De cette manière on définit la  $RDU$ , qui est le complémentaire de la  $RFU$  par rapport à la  $RU$  :

$$RU = RFU + RDU$$

### **III.2.3.6. Calcul du déficit hydrique journalier**

$$DH_j = ETM - ERT_j$$

### **III.2.3.7. Equation du bilan hydrique**

$$RH_j = RH_{j-1} + P_{ej} - ETR_j - DR_j$$

Cette équation va servir de relation de récurrence pour calculer les réserves hydriques journalières successives. On peut se baser sur les considérations suivantes pour initialiser le processus : si le jour  $n^{\circ}1$  se trouve en pleine saison des pluies,  $RH_0 = RU$ , si non, on prend une valeur moyenne  $RH_0 = RU/2$ .

## **III.2.4. Modele de Lhomme et Katerji**

---

C'est un modèle du bilan hydrique agro météorologique qui gère l'irrigation dans le cas des grandes cultures au pas de temps journalier, et utilise la pluie et les évapotranspirations

calculées comme des entrées climatiques. Il prend en compte la variation des coefficients culturaux et de la réserve utile à travers les différents stades phénologiques de la culture.

### III.2.4.1. Evolution de la réserve utile

La Ru varie entre la valeur minimale  $RU_n$  (quelques jours après le semis) et une valeur maximale  $RU_x$  correspondant au maximum d'enracinement. La valeur maximale du réservoir est supposée atteinte lorsque la culture couvre complètement le sol.

Lorsque la variation de la profondeur d'enracinement est inconnue (le cas le plus souvent), il est possible de choisir une loi de variation linéaire en fonction du nombre du jour  $j$  entre la date de levée  $j_1$  et la date de couverture complète du sol par la culture  $j_2$ . La valeur maximale de la RU reste constante jusqu'à la date de récolte  $j_4$ .

Ce modèle est formulé comme suit:

- $RU_j = RU_n + (RU_x - RU_n) (j - j_1) / j_{d1}$      Si  $j \in ]j_1, j_2]$
- $RU(j) = RU_x$      Si  $j \in ]j_2, j_4]$
- $RU(j) = RU_n$      Si  $j \in ]j_4, j_1]$

La variation de la réserve hydrique s'écrit comme suite :

$$RH(j) - RH(j-1) = \sum W_s(j) - \sum W_l(j) + \delta RU_x(j)$$

Dans laquelle :

$\sum W_s(j)$  : Valeur totale des entrées (gain) d'eau durant le jour ;

$\sum W_l(j)$  : Valeur totale des pertes d'eau durant le jour  $j$  ;

$RH(j)$  : Etat de la réserve hydrique au jour  $j$  ;

$RH(j-1)$  : Etat de la réserve hydrique au jour  $j-1$  ;

$\delta RU_x(j)$  : eau apportée par capillarité  $(RU_x(j) - RU_x(j-1))$ .

Lors de la croissance racinaire maximale, la réserve utile est égale à la réserve utile maximale.

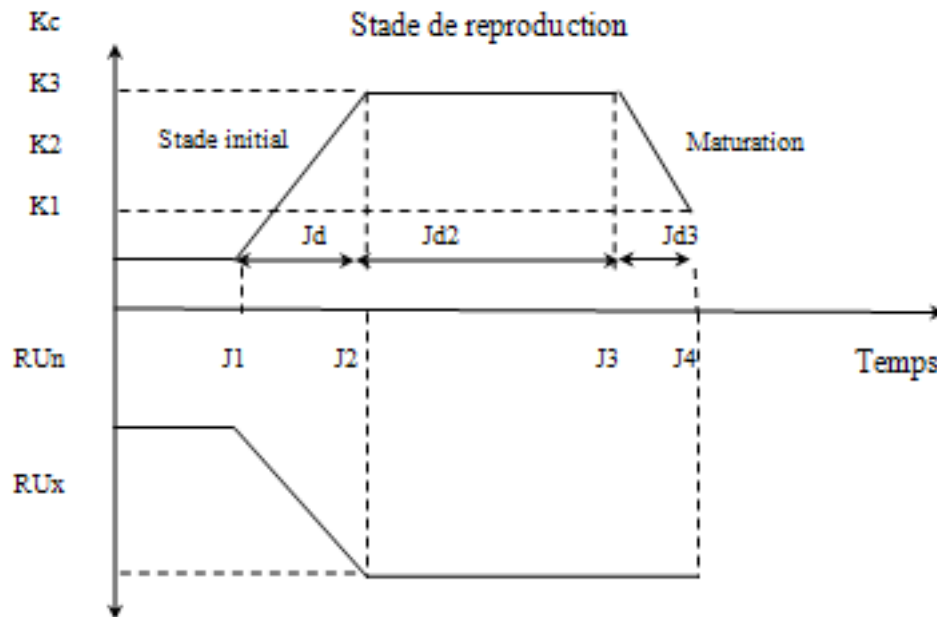


Fig .III.1 : Variation du coefficient culturel et de la réserve utile à travers les différents stades de la culture

### III.2.4.2. Pluies efficaces

Les apports d'eau au réservoir sol proviennent essentiellement des précipitations (P) et des irrigations (I). Cependant, elles ne sont pas entièrement efficaces du fait qu'une part d'eau est perdue par ruissellement de surface et une autre par drainage en profondeur (D) (Chourghal, 2003) :

$$\sum W_s(j) = (P+I) - (R+D)$$

Il est difficile d'évaluer le drainage D et le ruissellement R du fait de leurs dépendances des conditions pédoclimatiques. Dans une première approximation, on peut utiliser le présent modèle qui considère que le ruissellement est proportionnel à la quantité de pluie quand elle excède une certaine valeur  $P_0$ . (Forest., 1984 in Chourghal, 2003) ;

- $R(j) = [P(j)-P_0]$ , Si  $P(j) > P_0$
- $R(j) = 0$ , Si  $P(j) \leq P_0$ .
- Les coefficients B et  $P_0$  sont deux paramètres du modèle qui sont fonction de la pente et des pratiques culturales (pour un sol cultivé, avec une pente inférieure à 3%, Forest propose  $P_0 = 25$  mm et  $B = 0.15$ ).

Pour un jour j, on doit définir la valeur de l'humidité à la capacité de rétention :

$$HCR(j) = RH(j) - RH(j-1)$$

Quelque soit la valeur de pluie tombée durant le jour j, elle contribue à la recharge du réservoir sol au début, puis percole en profondeur si sa valeur est supérieure à l'humidité

à la capacité de rétention (Fitzpatrick et Nix, 1969 in Chourghal). Dans ce cas le drainage en profondeur peut s'écrire :

- $D(j) = 0$ , Si  $P(j) \leq HCR(j)$
- $D(j) = P(j) - HCR(j)$ , Si  $P(j) > HCR(j)$

### III.2.4.3. L'évapotranspiration

L'ETP est calculée par la formule de Penman et considérée comme une entrée de modèle.

L'ETR évolue en fonction de l'ETM, donc de la valeur d'eau stockée dans le sol.

Si  $K_1, K_2, K_3$  sont, respectivement, les valeurs des coefficients culturaux correspondant aux stades initiale, reproduction et de maturité et si  $jd_1, jd_2$  et  $jd_3$  sont les durées de ces stades ;

$$\text{➤ } ETM(j)/ETP(j) = K_1 + (K_2 - K_1)(j - 1), \quad \text{Si } j \in [j_1, j_2]$$

$$\text{➤ } ETM(j)/ETP(j) = K_2, \quad \text{Si } j \in [j_2, j_3]$$

$$\text{➤ } ETM(j)/ETP(j) = K_1 + (K_3 - K_2)(j - j_3)/jd_3, \quad \text{Si } j \in [j_1, j_2]$$

L'ETR est fonction de la réserve hydrique du sol ;

$$\text{➤ } ETR = ETM, \quad \text{Si } RH(j-1) \geq RDU(j-1)$$

$$\text{➤ } ETR(j) = ETM(j) * RU(j-1)/RDU(j-1), \quad \text{Si } RH(j-1) < RDU(j-1)$$

Fig .III.2. : Variation du rapport ETR/ETM en fonction de la réserve utile RU




Fig .III.2. : Variation du rapport ETR/ETM en fonction de la réserve utile RU

### III.2.4.4. L'équation du bilan hydrique

Pour un jour  $j$ , l'équation du bilan hydrique s'écrit :

$$RH(j) - RH(j-1) = P(j) - ETR(j) - R(j) + \delta RU(j)$$

Cette équation est une relation de récurrence qui permet de calculer les valeurs successives de la réserve hydrique. Pour l'initialisation du système, il est toujours possible de mettre  $RU(0) = RU$ , à la fin de la saison pluvieuse. Dans le cas général on prend :  $RU(0) = RU_x$  qui est une entrée du modèle.

#### **III.2.4.5. Calcul du déficit hydrique journalier**

Le déficit hydrique est estimé par la formule suivante :

$$DH(j) = ETM(j) - ERT(j)$$

### **III.3. Programmation de logiciel de calcul**

Nous avons élaboré un programme sous MATLAB v7.4 permettant, à la fois, d'estimer l'évapotranspiration potentielle par le biais de plusieurs formules empiriques à partir de données climatiques, et d'évaluer les différents termes de chaque modèle de bilan hydrique (ETP-Pluie, Rojas, Eldin-et-Lhomme et Katerji et Lhomme), en faisant le lien Excel-MATLAB pour faciliter l'importation de données vers *MATLAB* et l'exportation des résultats vers Excel.

Les données d'entrées sont classées en trois catégories :

- **Données climatiques** : tel que la température de l'air (minimale, maximale et moyenne), l'humidité relative, la vitesse du vent, la durée d'insolation, la pluviométrie (station de Dar El-Beida).
- **Les données pédologiques** : les données pédologiques ont été prises à partir d'un mémoire portant sur l'étude pédologique et cartographique de l'INA (mémoire du Abib et Haddab, 1995).
- Type de sol : limoneux argileux (Abib et Haddab, 1995).
- La réserve utile correspondant au maximum d'enracinement (200mm/m), la réserve difficilement utilisable (67mm/m), la réserve hydrique au début de simulation (200mm), le coefficient définissant la limite de l'efficacité des pluies (selon le modèle utilisé).
- **Caractéristiques culturales** : la profondeur racinaire maximale (1m).

### **III.4. Choix de la culture**

Nous avons choisi la culture pérenne de ray-grass (gazon de référence) qui sert à la fois de référence pour l' $ET_0$  et l'estimation de bilan hydrique.

Le bilan hydrique se fait en continu, sans arrêt, le bilan du jour (j) dépend du jour (j-1) et ainsi de suite, c'est pour cela que le calcul se fait par itérations successives. La culture pérenne (gazon de référence) répond favorablement à cette continuité, le bilan hydrique s'effectue en continu sans interruption d'une année à l'autre au cours de l'hiver (cas admis pour les modèles utilisés), contrairement aux cultures annuelles, qui présentent une certaine période où elles ne sont pas mises en place (entre la récolte et le semis).



Le coefficient  $K_c$  n'intervient donc pas, l'ETM de la culture de référence est alors constamment égale à l' $ET_0$  et à l'ETR si le sol est saturé en surface.

Nous rappelons que nous avons utilisé ces modèles de bilan hydrique pour estimer le déficit hydrique de la culture (ici gazon de référence), et par la suite nous allons étudier le potentiel de réseaux de neurones artificiels (RNA) à le reproduire, mais le problème qui se pose est comment convertir le déficit hydrique de la culture de référence à d'autres cultures.

**Ali RK** (2008) a montré qu'on peut convertir l'évaporation de bac en évapotranspiration de référence par le biais d'un modèle neuronal de type PMC.

Par analogie et en raison de la capacité de généralisation de réseaux de neurones artificiels, on peut convertir les valeurs de déficit hydrique de la culture de référence à d'autres cultures à condition qu'on possède quelques données expérimentales de la culture considérée, malheureusement nous n'avons pas ces données (données lysimétriques de l'évapotranspiration).

## III.5. Critères d'évaluation de performance d'un modèle neuronal

Le seul critère de conformité et de performance d'un modèle est son adéquation avec la réalité physique de terrain.

Après avoir implémenté un modèle neuronal, une tâche délicate c'est l'estimation de ses qualités et sa capacité à reproduire d'autres événements hydrologiques, on utilise généralement la méthode de double échantillon, qui consiste à diviser les données d'entrée en deux catégories, la première catégorie sert à caler le modèle et l'autre pour le tester (valider).

La durée de ces deux phases est sujette à l'expérience et aux essais (par tâtonnement et analyse des résultats).

La performance des modèles neuronaux utilisés pour rendre compte au non linéarité des processus hydrologique est évaluée par plusieurs critères graphiques et statistiques.

### III.5.1. Critère graphique

---

Ce critère donne une idée générale sur la performance de modèle du fait qu'il apporte un jugement visuel sur la qualité de modèle à reproduire fidèlement la réalité. Une superposition entre la courbe portant les valeurs simulées et celle portant les valeurs observées, signifie une parfaite performance de modèle et vice-versa. Mais ce critère n'est pas suffisant d'où la nécessité de faire appel aux critères statistiques.

### III.5.2. Critères statistiques

---

Consistent à déterminer une fonction qui va minimiser l'erreur entre les données simulées par le modèle, et celles observées. (Benkaci, 2006).

Concernant ces critères statistiques, nous citons :

- Coefficient de détermination ( $R^2$ ) ;
- Critère RMSE (Root Mean Square Error);
- Erreur moyenne absolue (mean absolute error : MAE) ;
- Critère de Nash (E).

### III.5.2.1. Le coefficient de détermination ( $R^2$ )

Le coefficient de détermination mesure la précision de la modélisation hydrologique. Il est généralement utilisé pour la comparaison des modèles alternatifs. (Sungwon, Hung, 2007).

Celui-ci évalue le degré d'association entre deux variables et juge de la qualité de l'ajustement des valeurs observées et simulées, il varie entre 0 et 1.

Un coefficient de détermination égal à 1 indique une corrélation parfaite de l'échantillon (aucune différence entre les valeurs  $Y$  simulées et observées). A l'inverse, un coefficient de détermination égal à 0 (zéro) indique que l'équation de régression ne peut servir à prévoir aucune valeur.

$$R^2 = \left[ \frac{\frac{1}{N} \sum_{i=1}^N (Y_{iobs} - \bar{Y}_{obs})(Y_{sim} - \bar{Y}_{sim})}{\sigma_{obs} \cdot \sigma_{sim}} \right]^2$$

**Avec :**

$Y_{iobs}$  : Valeur observée ;

$Y_{sim}$  : Valeur calculée par le modèle ;

$\bar{Y}_{obs}$  : Moyenne de la variable observée ;

$\bar{Y}_{sim}$  : Moyenne de la variable calculée.

Un coefficient de détermination proche de l'unité signifie que le modèle élaboré est très efficace.

### III.5.2.2. Root Mean Square Error (RMSE): (la racine de l'erreur quadratique moyenne)

C'est un indicateur de la performance de modèle hydrologique, le RMSE est défini comme étant la racine carrée des valeurs moyennes des écarts quadratiques entre les valeurs observées et simulées. Un RMSE très bas (proche de zéro) implique une bonne performance de modèle, et vice versa. Une parfaite concordance entre les valeurs observées et celles simulées est donnée par un RMSE=0. Nous présentons ci-après la fonction racine d'erreur quadratique moyenne RMSE qui est la plus utilisée pour l'apprentissage des RNA, mais d'autres fonctions de coût peuvent aussi être utilisées.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Y_{obs} - Y_{sim})^2}{N}}$$

### III.5.2.3. Le coefficient de Nash-Sutcliffe (E)

Le coefficient de Nash-Sutcliffe est le coefficient de l'efficacité de modèle. Il indique l'estimation relative de performance de modèle, il est adimensionnel. Un coefficient de Nash très élevé (égal à 100%), implique une parfaite concordance entre les valeurs observées et celles simulées, et vice versa. Il peut prendre des valeurs négatives. Il est calculé par l'équation suivante :

$$Nash = \left( 1 - \frac{\sum_{i=1}^n (Y_{obs} - Y_{sim})^2}{(Y_{obs} - Y_{moy})^2} \right) * 100$$

En fonction des valeurs de critère de Nash-Sutcliffe, on peut définir la performance de modèle, lorsqu'il est proche de 100%, le modèle est performant et vice versa.

### III.5.2.4. L'Erreur moyenne absolue (mean absolute error : MAE)

L'Erreur moyenne absolue définit la valeur moyenne de la différence absolue entre les valeurs simulées et observées. Un MAE bas signifie une bonne performance de modèle. Une parfaite concordance entre les valeurs observées et celles simulées produit un MAE=0. Le MAE est calculée par :

$$MAE = \left| \frac{\sum_{i=1}^N (Y_{sim} - Y_{obs})}{N} \right|$$

## III.6. Phases d'élaboration d'un modèle neuronal

Elles se subdivisent en cinq étapes, chacune dépend de la performance de la phase précédente.

### III.6.1. La collecte des données

---

L'acquisition des données est la phase essentielle de toute recherche appliquée. La qualité des données est une condition *sine qua non* de la qualité d'une étude. En modélisation, les données servent non seulement à élaborer un modèle mais aussi à le tester. Sans données en quantité et qualité suffisantes, le modèle aura donc peu de chances d'être performant et opérationnel (Oudin, 2004).

L'objectif est à la fois de caler et valider le modèle. Il consiste à rassembler un nombre de données suffisant pour constituer une base représentative nécessaire à la modélisation.

### III.6.2. La séparation de la base de données (apprentissage-validation)

---

L'un des avantages majeurs des réseaux de neurones artificiels est leur aptitude de généralisation ; extrapolation pour les valeurs proches et interpolation pour les valeurs intermédiaires. Pour avoir une bonne généralisation, la base de donnée doit être devisée en deux parties, la première sert pour l'apprentissage (calage), et la deuxième servant pour la validation de RNA (performances du modèle). Il n'y a pas de règle pour estimer la longueur de chacune des deux parties, il faut effectuer donc plusieurs essais afin de trouver la meilleure combinaison (calage-validation).

### III.6.3. Elaboration de la structure du réseau

---

La structure du réseau dépend étroitement du type des échantillons. Il faut d'abord choisir le type de réseau.

Les réseaux de neurones utilisés dans ce mémoire sont de type « Perceptron multicouches », la fonction de transfert de la ou les couches cachées est sigmoïde par contre la fonction de la couche de sortie est de type linéaire.

Il est intéressant de signaler qu'on va jouer sur plusieurs paramètres: le nombre de couches cachées (1 ou 2), le nombre des inputs (combinaison entres les inputs), le nombre de neurones de la ou les couches cachées afin de mettre en évidence la meilleure structure neuronale.

### III.6.4. Apprentissage

---

L'apprentissage est l'avant dernière phase d'élaboration d'un réseau de neurones. Elle consiste tout d'abord à calculer les pondérations optimales des différentes liaisons, en utilisant un échantillon constitué de couples (entrées-sorties désirées).

L'apprentissage utilisé est de type supervisé, l'Algorithme de rétro propagation de l'erreur (backpropagation), variante de Livenberg-Marquardt en raison de sa rapidité de convergence et ses performances de généralisation. Il consiste en la modification des poids

des connexions entre les différentes couches par rapport à une erreur calculée en sortie de réseau.

### III.6.5. Validation

---

Une fois le réseau de neurone est entraîné (apprentissage), une tâche délicate c'est l'évaluation de ses capacités de généralisation, c'est-à-dire il faut voir s'il est prêt pour l'usage, pour cela on va le tester sur une base de données différente de celle utilisée pour l'apprentissage. Durant cette phase on n'apporte au réseau que les entrées (données climatiques), sans faire appel à la sortie désirée (target). Ce test permet d'apprécier les performances du modèle élaboré.

Si le modèle neuronal élaboré n'est pas performant, il faudra modifier la structure de réseau ou modifier la base d'apprentissage (la longueur de celle-ci).

### III.6.6. Post validation ou phase de test

---

Parfois on divise la base de données en 3 ensembles l'un pour l'apprentissage (calage du modèle), l'autre pour le valider, et le dernier pour le test, cette phase nous permet de bien confirmer la performance du modèle élaboré durant les deux phases citées auparavant, pendant celle-ci on n'apporte au réseau que les entrées (sans target).

## III.7. Implémentation des réseaux de neurones artificiels (RNAs)

### III.7.1. Introduction

---

Pour les applications pratiques des réseaux de neurones, l'utilisateur doit comprendre les concepts théoriques de base, mais il doit également utiliser des outils appropriés afin d'obtenir de bons résultats.

Depuis le développement théorique des réseaux de neurones à la fin des années 1980-1990, plusieurs outils ont été mis à la disposition des utilisateurs. Les fonctionnalités et les statuts de ces outils sont très variables. (Dreyfus, 2004).

- Aujourd'hui, les outils d'implémentation disponibles se divisent en deux catégories :
- Des outils spécifiques développés incluant une méthodologie complète (simulateurs neuronaux), qui ne demandent aucun effort de programmation, on cite à titre d'exemple NeuroOne6 ; ce genre d'outils ne fournit pas une flexibilité mais il donne des résultats fiables dans un temps court.
- Les boîtes à outils de réseaux neurones telle que « artificial neural network toolbox in Matlab » qui est un sous programme (built-in) intégré dans le logiciel MATLAB.

### III.7.2. Logiciel MATLAB

---

Pour l'estimation de l'évapotranspiration potentielle et du déficit hydrique à l'aide de réseaux de neurones artificiels, nous avons choisi de travailler sous environnement MATLAB 7.4, dans ce que suit nous donnons un aperçu sur ce logiciel.

Le logiciel MATLAB version 7.4 élaboré par la firme américaine Matwork Laboratory, est un langage de programmation et de calcul numérique, simple et très efficace, optimisé pour le traitement des matrices, d'où son nom. Pour le calcul numérique, MATLAB est beaucoup plus concis que les "vieux" langages (C, Pascal, Fortran, Basic). On peut traiter la matrice comme une simple variable, MATLAB contient également une interface graphique puissante, ainsi qu'une grande variété d'algorithmes scientifiques et de vingtaines de toolboxes.

Ce logiciel dispose d'un sous programme réservé aux réseaux de neurones artificiels (artificial neural network toolbox) permettant l'implémentation facile de différents types de RNA tel que les Perceptron multicouches, en utilisant soit l'interface graphique d'utilisateurs (graphical user interface ; GUI) soit la programmation des RNA dans la fenêtre de commandes ou en M-file. La description de cette boîte à outils et leur mode d'utilisation sont présentés ci-après.

### **III.7.3. Méthodologie d'implémentation**

---


#### **III.7.3.1. Interface graphique de la boîte à outils de réseaux des neurones**

L'interface utilisateur graphique (Graphical User Interface, GUI) est conçue pour être simple et facile à utiliser, nous donnons un exemple simple:

L'exemple suivant traite un réseau de neurones de type Perceptron multicouches "FeedForward", où nous passons par toutes les étapes de créer un réseau, le visualiser, l'entraîner, le simuler, et même exporter les valeurs de sortie, ou importer les valeurs d'entrée ou encore les sauvegarder.

##### **III.7.3.1.1. La création du RNA de type PMC ; Feed-Forward**

Pour commencer, taper la commande *nntool* dans la ligne de commande de MATLAB. La fenêtre suivante apparaît.



**Fig.III.3. :** Interface graphique de Boîtes à outils de réseaux des neurones artificiels.

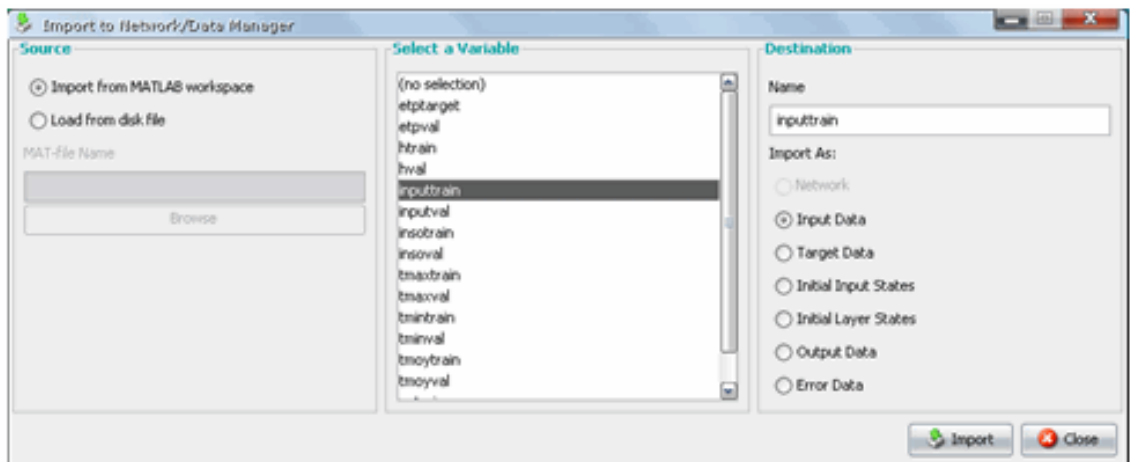
On voit que l'interface graphique est constituée de plusieurs champs (Input Data, Target Data, Networks, Output Data..) et des onglets (boutons).

#### III.7.3.1.1.a. Première étape: importation des données

Avant de créer un réseau il faut d'abord introduire :

- La matrice de données d'entrée d'apprentissage (**inputtrain**) qui renferme dans notre cas la température moyenne, minimum, maximum, (tmoy, tmin, tmax), l'humidité relative, la vitesse du vent et l'insolation, permettant l'apprentissage du réseau.
- **Targets:** ce sont les valeurs cibles qui doivent être atteintes par le réseau lors de l'apprentissage, dans notre cas les valeurs d' $ET_0$  (**etptarget**).
- La matrice de données d'entrée de validation (**inputval**), qui contient les variables climatiques servant à la validation du réseau.

Pour introduire ces données, cliquer sur l'onglet **Import** de l'interface graphique, une nouvelle fenêtre apparaît.



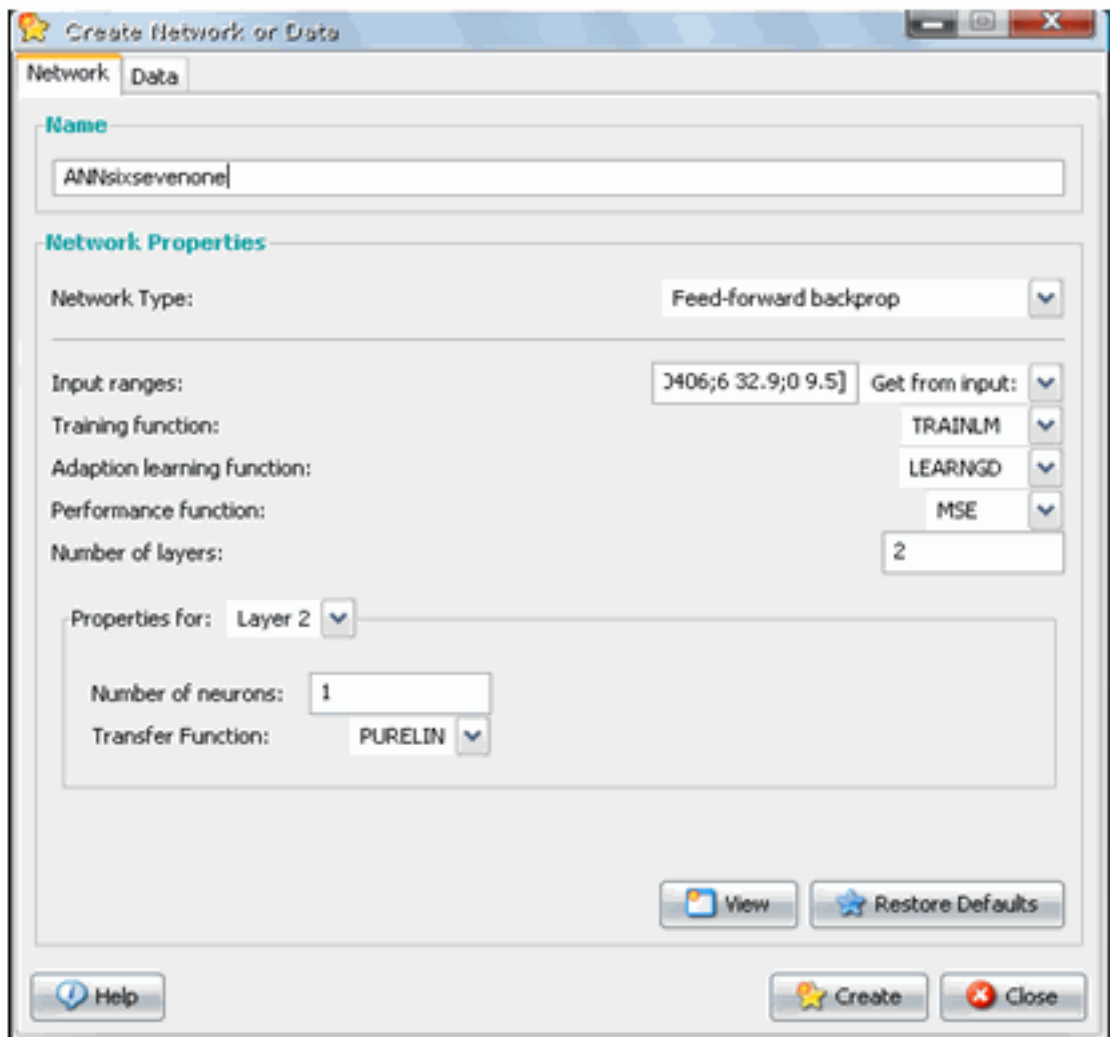
**Fig.III.4.** : Fenêtre d'importation de données.

On sélectionne la matrice des variables d'entrée d'apprentissage (**inputtrain**) puis on sélectionne la case **Input Data**, ensuite on clique sur l'onglet **Import**, on répète la même chose pour le target (**etptarget**) et la matrice d'entrée de validation (**inputval**).

#### **III.7.3.1.1.b. Deuxième étape: Création du réseau**

Pour créer un réseau, on clique sur le bouton **New** dans la fenêtre interface graphique, la fenêtre **Create New Network or Data** apparaît (FigIII.5), on donne un nom au réseau, puis on choisit le type de réseau préprogrammé. Le Feed-forward Backpropagation (réseau multicouche Feed-Forward entraîné par l'algorithme de rétropropagation de gradient) est tout désigné pour ses propriétés de convergence et ses capacités d'approximations. Ensuite on sélectionne le domaine des données d'entrée.





*Fig.III.5. : Fenêtre Create New Network or Data.*

On choisit les composants du réseau: l'algorithme d'apprentissage, la fonction d'adaptation, la fonction de performance (MSE), le nombre de couches, les fonctions d'activation ainsi que le nombre de neurones dans chaque couche.

Ensuite on clique sur l'onglet **Create** pour créer le réseau, puis on va Cliquer sur l'onglet **View**, on aura la fenêtre décrivant l'architecture du réseau.

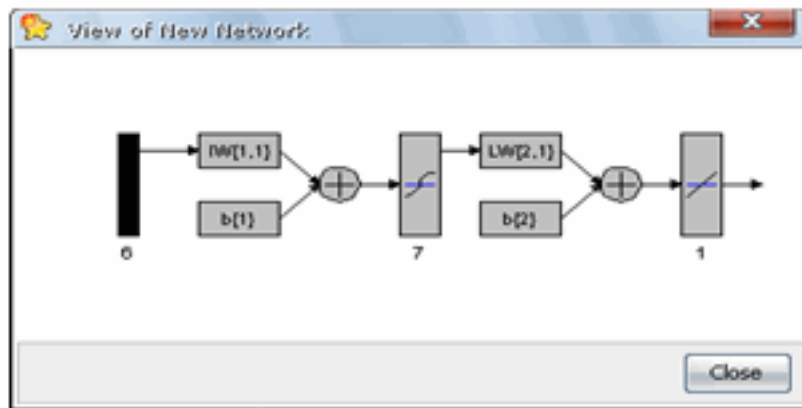


Fig.III.6. : Fenêtre d'affichage d'architecture du réseau et leurs paramètres.

### III.7.3.1.1.c. Troisième étape: Apprentissage du réseau

On sélectionne le nom de réseau sur le champ **Networks** de l'interface graphique, on clique maintenant sur l'onglet **Open**, une nouvelle fenêtre apparaît (Fig.III.7).

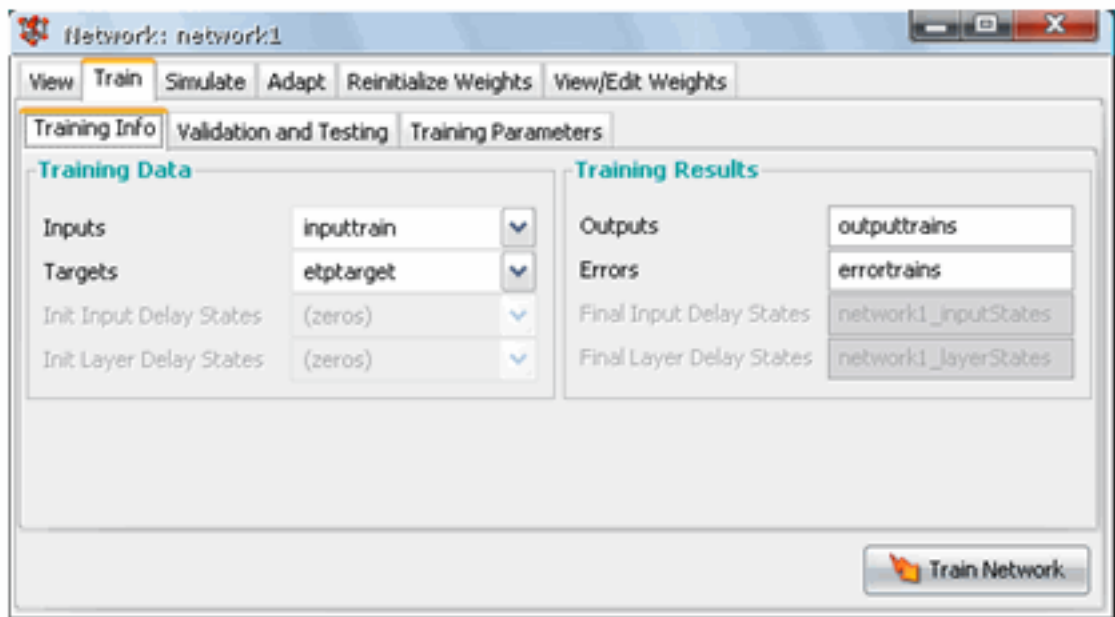
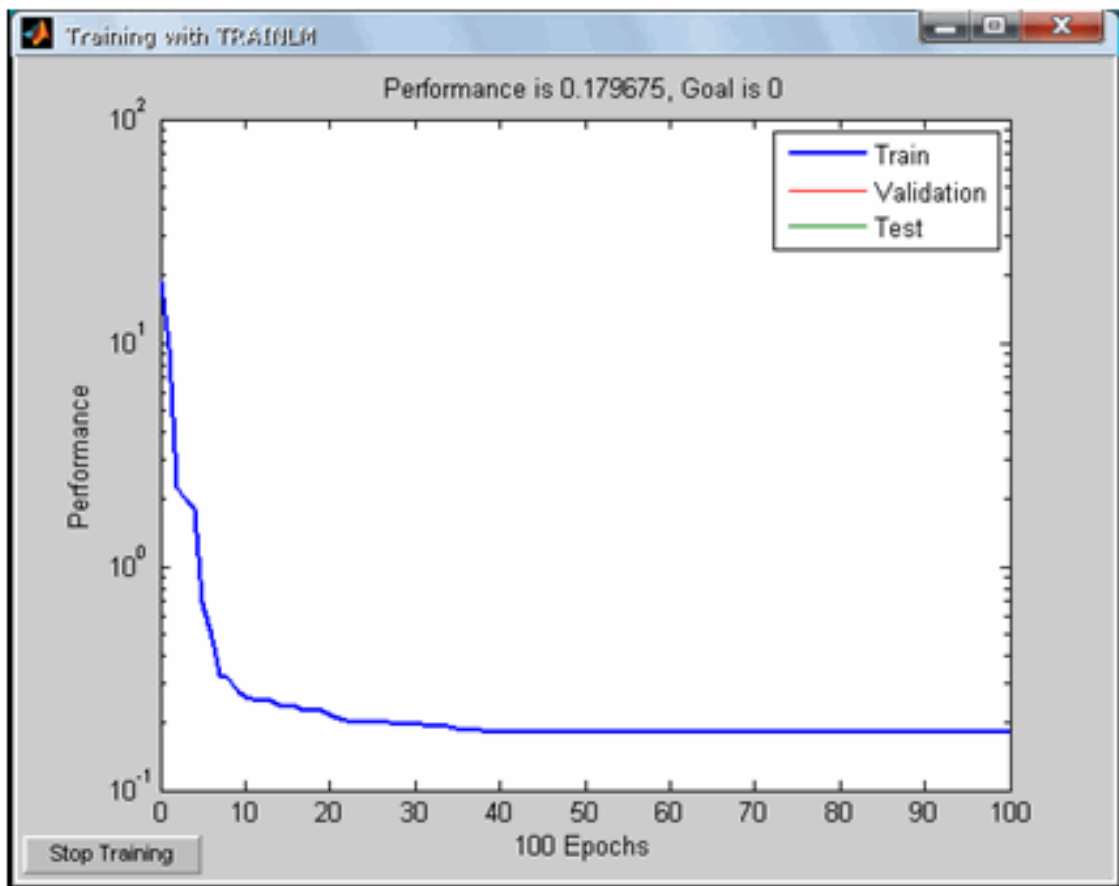


Fig.III.7 : Fenêtre d'apprentissage du réseau.

A chaque Onglet de la fenêtre on sélectionne les données appropriées, qui nous permettent alors d'entraîner, simuler le réseau.

On clique maintenant sur **Train Network** pour entraîner le réseau de Feed-forward. Lors de l'apprentissage un graphique apparaît automatiquement présentant l'état d'avancement de l'apprentissage (Fig.III.8.). Ce dernier est arrêté automatiquement après avoir atteint une valeur constante de performance (MSE).




**Fig.III.8.** : Graphique de l'évolution de l'apprentissage.

Ce graphique représente l'évolution de critère de performance en fonction du nombre d'itérations (Epochs) lors d'apprentissage.

#### III.7.3.1.1.d. Quatrième étape: exportation des résultats

On sélectionne le nom de la sortie sur le champ **Output Data**, on clique maintenant sur l'onglet **Open**, la fenêtre des résultats apparaît (Fig.III.9).



**Fig. III.9.** : La fenêtre des résultats.

Ces valeurs représentent les résultats obtenus lors de l'apprentissage ( $ET_0$  simulées).

On va copier ces valeurs et les coller dans un fichier Workspace de Matlab, ensuite on va mettre la transposée pour rendre ces valeurs verticales. Ensuite, on les transfère vers un fichier Excel afin de faciliter la tâche (graphisme et calcul de critères de performance).

On répète presque les mêmes étapes lors de la validation du réseau.

---

# IV .Résultats et discussions

## IV.1. Introduction

Nous rappelons que l'objectif de notre travail consiste à étudier le potentiel des réseaux de neurones artificiels (RNA) pour estimer l'évapotranspiration de référence et le déficit hydrique d'alimentation à différents pas de temps.

Nous avons divisé cette section en quatre chapitres:

- Comparaison et calibration de quelques formules utilisées pour estimer l' $ET_0$ .
- Estimation de l' $ET_0$  par la technique de régression linéaire multiple.
- Simulation de l'évapotranspiration de référence par les réseaux de neurones artificiels.
- Simulation du déficit hydrique par les réseaux de neurones artificiels.

Pour ce faire, nous disposons d'une série climatique de la station météorologique de Dar El-Beida s'étalant sur une période de dix années allant de 1995 à 2004 renfermant tous paramètres climatiques nécessaires.

## IV.2. Comparaison et calibration de quelques formules utilisées pour estimer l' $ET_0$

### IV.2.1. Introduction

Dans les régions où les séries de données disponibles ne comportent pas tous les paramètres climatiques, le recours aux formules qui n'exigent pas beaucoup de paramètres constituent une solution attirante, mais le problème qui se pose est que ces formules ne sont pas précises que celle de Penman-Monteith modifiée, une alternative intéressante c'est la calibration (calibrage) de ces formules par régression linéaire simple en se basant sur le modèle de Penman-Monteith modifié.

Dans ce qui suit nous présentons une brève étude de comparaison et de calibration de quelques formules d'estimation de l'évapotranspiration de référence.

### IV.2.2. Comparaison de quelques formules utilisées pour estimer l' $ET_0$

D'après plusieurs chercheurs (Landras G et Amaia Ortiz-Barredo., 2008, Allen RG., 1996), la formule standardisée de Penman-Montheith modifiée, est la méthode la plus fiable, dans les conditions climatiques humides et arides pour estimer l'évapotranspiration de référence si les données lysimétriques sont absentes. Elle va servir donc de référence pour comparer et calibrer les autres formules (Irmak et al. 2003; Utset et al. 2004; Gavilan et al. 2006).

Il est important de signaler que les valeurs d' $ET_0$  utilisées dans cette étude sont obtenues par le biais d'un programme informatique que l'on a écrit sous MATLAB en faisant les liens Matlab-Excel afin de faciliter l'apport des inputs et l'analyse des outputs.

Nous allons comparer les valeurs d' $ET_0$  obtenues via les formules de Priestly et Taylor, Hargreaves et Samani, la FAO Radiation, Makkink, Jensen et Haise et Penman originale avec celle de Penman-Montheith modifiée en se basant sur les critères statistiques tel que le coefficient de détermination ( $R^2$ ) et le critère RMSE (Root Mean Square Error).

Les résultats de comparaison viennent dans ce qui suit.

Modèle	RMSE	$R^2$	$\frac{\sum E(\text{modèle})}{\sum E(\text{PM56})}$
Makkink	0.841	0.721	0.918
Radiation (FAO24)	1.156	0.801	1.278
Priestly-Taylor	0.786	0.786	0.922
Hargreaves et S	1.237	0.769	1.344
Jensen et Haise	1.362	0.795	1.323
Penman originale	0.540	0.989	1.323

**Tableau.IV.1. : Sommaire de l'analyse statistique des équations d' $ET_0$  citées auparavant par rapport à la formule de PM56 pour la période 1995-2004.**

La performance des équations d' $ET_0$  est illustrée dans le tableau.IV.1 pour la période 1995-2004. La formule de Penman originale donne la meilleure performance avec un RMSE de 0.540, et 17.86% de surestimation de l' $ET_0$  en moyenne. Puis viennent en seconde place les formules de Priestly-Taylor et de Makkink avec un RMSE de 0.786 et 0.841 respectivement, et en dernier lieu les formules de 24 RD (FAO radiation), Hargreaves-Samani et Jensen-Haise avec des RMSE de 1.156, 1.237 et 1.362 successivement.

D'après les résultats de ce tableau, les valeurs de l' $ET_0$  varient d'une formule à une autre.

### **IV.2.3. Calibration locale de quelques formules utilisées pour estimer l' $ET_0$ :(1995-2004)**

La formule standardisée de Penman-Monteith modifiée présente l'inconvénient qu'elle exige plusieurs paramètres climatiques sachant que les stations météorologiques ne sont pas toutes munies de tous les instruments de mesures, une alternative attirante c'est le calibrage des formules d' $ET_0$  qui n'exigent pas beaucoup de paramètres climatiques.

Allen et al. (1994) recommandent que les méthodes empiriques doivent être localement calibrées en utilisant PM56 puisqu'on peut rencontrer beaucoup de situations avec un manque de certains paramètres météorologiques nécessaires pour l'évaluation d'évapotranspiration moyennant la formule de Penman-Monteith modifiée. Dans tous ces cas, l'utilisation des équations alternatives d' $ET_0$  est recommandée, mais encore plus préconisée si ces équations ont été localement calibrées (en utilisant Penman-Monteith modifiée).

Le calibrage des équations locales d'ET<sub>0</sub> améliore la performance des équations, et est un outil utile, non seulement pour l'estimation de l'ET<sub>0</sub> en temps réel mais aussi pour la réalisation des études historiques d'ET<sub>0</sub> (Landras G et al., 2008). L'ET<sub>0</sub> calibrée est calculée comme suit :

$$ET_0 = a + b \cdot E_{\text{Modèle}}$$

Avec :

**ET<sub>0</sub>** : l'évapotranspiration de référence estimée par la formule PM56 (E<sub>PM56</sub>).

**E Modèle** : c'est l'évapotranspiration évaluée par n'importe quelle équation d'ET<sub>0</sub>.

**a** et **b** sont les constantes de régression.

Tableau.IV.2. : les paramètres de régression linéaire utilisés dans le calibrage des formules.

Modèle	b	a	R <sup>2</sup>
Makkink Radiation (FAO24)	1.034 0.712	0.132 0.239	0.6192-0.1301-0.9261-0.389
Priestly-Taylor	0.834 0.790		
Hargreaves et S Jensen et Haise Penman originale	0.675 0.892		

fin de connaître est-ce que les formules calibrées améliorent leurs performances, on utilise le critère « ratio du RMSE » (RaRMSE) basé sur les équations d'ET<sub>0</sub> calibrées comparées à celles non calibrées pour la période 1995-2004, le RaRMSE est donné par :

$$RaRMSE = 1 - \frac{RMSE_{ET_0 \text{ calibrée}}}{RMSE_{ET_0 \text{ noncalibrée}}}$$

Un ratio (RaRMSE) proche de l'unité signifie une amélioration considérable de la formule calibrée, donc la performance de celle-ci.

Tableau.IV.3. : le critère RMSE des formules non calibrées, calibrées et le ratio RaRMSE.

Modèle	RMSE non calibrées	RMSE calibrées	RaRMSE
Makkink	0,840	0,810	0,036
Radiation (FAO24)	1,155	0,684	0,407
Pierstely-Taylor	0,786	0,708	0,098
Hargreaves et Samani	1,237	0,736	0,404
Jensen et Haise	1,362	0,694	0,490
Penman originale	1,237	0,736	0,704

En général, les formules apportent une petite amélioration de leurs performances après calibrage par régression linéaire simple. En premier lieu, la formule de Penman originale présente une amélioration avec un RMSE allant de 1.237 à 0.736, puis en deuxième lieu viennent les formules de Jensen et Haise, Radiation (FAO24), et Hargreaves-Samani avec des RMSE variant de (1.362 à 0.694), (1.156 à 0.684), (1.237 à 0.736) respectivement, et

en dernière place on trouve celles de Makkink et de Pierstly-Taylor avec de RMSE allant de (0.840 à 0.810) et (0.786 à 0.708) successivement.

## **IV.3. Estimation de l'ET<sub>0</sub> par la technique de régression linéaire multiple**

### **IV.3.1. Introduction**

---

L'objectif de ce chapitre est de trouver une expression polynomiale permettant d'estimer l'évapotranspiration de référence par la technique de régression linéaire multiple, en utilisant les paramètres climatiques classiques tels que la température (moyenne, minimale et maximale), l'humidité relative, l'insolation et la vitesse du vent.

### **IV.3.2. Régression linéaire multiple**

---

Soient  $y$  une variable dépendante et  $x_1, x_2, \dots, x_n$  des variables indépendantes, l'équation de régression linéaire multiple est donnée comme suit :

$$y = a + b_1 x_1 + b_2 x_2 + \dots + b_i x_i$$

Avec :  $a$  et  $b_i$  sont des constantes.

### **IV.3.3. Application de la technique de régression linéaire multiple à la série climatique d'Alger**

---

Soit  $ET_0$  la lame d'eau évapotranspirée ; elle s'explique certainement en grande partie par la température moyenne, la température minimale et la température maximale, mais aussi par l'humidité relative, la durée d'insolation et la vitesse du vent. Sur dix ans et au pas de temps journalier, nous avons trouvé sous Excel l'équation de régression multiple suivante :

$$ET_{0-RLM} = 0,0120(t_{min}) - 0,0190(t_{max}) + 0,165(t_{moy}) - 0,027(HR) + 0,290(U_2) + 0,128(Inso) + 0,360.$$

Avec :

$t_{min}$ ,  $t_{max}$ ,  $t_{moy}$  : température minimale, maximale et moyenne ;

HR : Humidité relative ;

$U_2$  : Vitesse de vent à 2 m de hauteur ;

Inso : Durée d'insolation.

Cette équation est considérée comme étant un modèle permettant d'estimer l'ET<sub>0</sub>, mais il nous faut évaluer leur performance.



### IV.3.4. Comparaison entre le modèle de régression multiple (RLM<sub>ET0</sub>) et la formule de Penman-Monteith modifiée

Le tableau suivant représente les critères de performance de modèle de RLM par rapport au modèle de référence de Penman-Monteith modifiée.

Tableau.IV.4. : Critère de performance de modèle RLM <sub>ET0</sub>.

Modèle	R <sup>2</sup>	RMSE
RLM <sub>ET0</sub>	0,8384	0,61727629

D'après les résultats de ce tableau, les critères de performance de modèle **RLM** <sub>ET0</sub> sont médiocres avec un R<sup>2</sup> de 0.838 et de RMSE de 0,617, donc la technique de régression multiple n'est pas recommandée pour estimer l'ET<sub>0</sub>.

En conclusion, on peut dire que la technique de régression linéaire simple n'apporte pas une grande amélioration de performance de formules calibrées (calées), ainsi que la méthode de régression linéaire multiple (modèle **RLM** <sub>ET0</sub>) donne des résultats médiocres, c'est pour cela nous avons adopté l'utilisation de la technique de l'intelligence artificielle, dans ce qui suit on va présenter les résultats de modélisation de l'ET<sub>0</sub> par les réseau de neurones artificiels.

## IV.4. Résultats de simulation par les réseaux de neurones artificiels

### IV.4.1. Introduction

Inspirés de la neurobiologie, les réseaux de neurones artificiels deviennent aujourd'hui un outil puissant pour résoudre les problèmes non linéaires dont le formalisme est discret et dans plusieurs domaines de recherche, particulièrement en hydrologie.

En raison de non linéarité du processus de l'évapotranspiration de référence (ET<sub>0</sub>) et du déficit hydrique, nous essayons à travers ces derniers chapitres d'exploiter le mieux les réseaux de neurones artificiels et de juger leur utilité dans la modélisation de ces phénomènes.

Plusieurs chercheurs ont évalué le potentiel de la technique des réseaux de neurones pour modéliser l'évapotranspiration de référence (ET<sub>0</sub>) obtenue par application de l'équation FAO Penman-Monteith (Kumar et al., 2008, Ali R K., 2008, Özgür K., 2007).

Les réseaux de neurones artificiels (PMC) se sont avérés donc capable à modéliser les relations non linéaires telle que:

$$ET_0 = F(\text{paramètres climatiques}) \text{ et Déficit hydrique} = G(\text{Pluies, } ET_0).$$

## IV.4.2. Obtention du nombre optimal de neurones dans la couche cachée

---

Le nombre optimal de neurones de la couche cachée est déterminé par approximations successives, par ce qu'il n'y a pas de règle à suivre pour définir le nombre optimal de neurones pour une application spécifique. Les modèles neuronaux sont entraînés sous MATLAB en utilisant l'algorithme de rétro propagation, variante de Levenverg–Marquardt avec 2, 3...5...i+1, i+2.....2i.....30 neurones, tel que i : c'est le nombre des entrées. Le RMSE et le  $R^2$  sont calculés en utilisant les sorties dans la phase de l'apprentissage et celle de validation.

Il faut choisir un réseau (avec un nombre de neurones) dont les critères de performance, le root mean square error et le coefficient de détermination (RMSE et  $R^2$ ) sur l'ensemble d'apprentissage et sur l'ensemble de validation soient du même ordre de grandeur et les plus petits possibles (Dreyfus, 2004).

On ne prend en compte que les RMSE et les  $R^2$  calculés sur l'ensemble de validation car la capacité de généralisation du réseau est estimée durant cette phase, elle est considérée comme le début d'exploitation du modèle neuronal, et sur la base de critères de performance de cette dernière qu'on va accepter ou refuser le modèle neuronal calé.

## IV.4.3. Simulation de l'évapotranspiration de référence

---

### IV.4.3.1. Modèles neuronaux à six entrées (six inputs)

#### IV.4.3.1.1. Modèles neuronaux au pas de temps journalier

Ces modèles neuronaux sont de type perceptron monocouche, avec l'apprentissage supervisé par l'Algorithme de rétro propagation de l'erreur (backpropagation).

Nous avons pris les estimations faites par la formule classique de FAO56 P-M comme valeurs de références ou sorties désirées (target), car les données lysimétriques ne sont pas disponibles.

L'ensemble d'apprentissage : 70% de base de données (7ans) ; méthode de « trial-and-error, step-by-step, one-by-one ».

L'ensemble de validation : 30% de base de données (3ans).

Les modèles neuronaux concernant la modélisation de l' $ET_0$  exigent les entrées suivantes: Température moyenne, température minimale, température maximale, humidité relative, insolation et la vitesse du vent, et l'évapotranspiration de référence comme paramètre de sortie (schéma ci-après)




Fig. IV.1. : Modèle neuronal à six entrées.


Architecture	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
PMC : 6-2-1	0,51	0,888	0,52	0,880
PMC : 6-3-1	0,46	0,908	0,49	0,893
PMC : 6-4-1	0,47	0,905	0,50	0,890
PMC : 6-5-1	0,45	0,913	0,48	0,879
PMC : 6-6-1	0,49	0,897	0,52	0,899
PMC : 6-7-1	0,44	0,917	0,48	0,879
PMC : 6-8-1	0,48	0,902	0,52	0,892
PMC : 6-9-1	0,45	0,913	0,49	0,898
PMC : 6-10-1	0,43	0,919	0,48	0,899
PMC : 6-11-1	0,43	0,921	0,47	0,872
PMC : 6-12-1	0,43	0,920	0,47	0,901
PMC : 6-13-1	0,43	0,921	0,54	0,893
PMC : 6-14-1	0,43	0,920	0,49	0,898
PMC : 6-15-1	0,42	0,924	0,48	0,895
PMC : 6-16-1	0,42	0,923	0,49	0,891
PMC : 6-17-1	0,42	0,922	0,49	0,901
PMC : 6-18-1	0,42	0,924	0,47	0,887
PMC : 6-19-1	0,42	0,925	0,50	0,901
PMC : 6-20-1	0,42	0,924	0,47	0,886
PMC : 6-21-1	0,41	0,928	0,51	0,871
PMC : 6-22-1	0,41	0,928	0,54	0,896
PMC : 6-23-1	0,43	0,922	0,48	0,885
PMC : 6-24-1	0,41	0,926	0,51	0,881
PMC : 6-25-1	0,41	0,929	0,52	0,872
PMC : 6-26-1	0,42	0,924	0,54	0,900
PMC : 6-27-1	0,42	0,925	0,47	0,885
PMC : 6-28-1	0,41	0,929	0,51	0,863
PMC : 6-29-1	0,40	0,932	0,56	0,880
PMC : 6-30-1	0,41	0,929	0,52	0,870

**Tableau.IV.5. : Résultats de modèles journaliers en périodes d'apprentissage et de validation.**

En examinant les résultats de tableau. IV.5, nous remarquons que les performances des modèles neuronaux varient d'un modèle à un autre.

Après avoir entraîné quelques modèles, chacun avec un nombre différent d'unités cachées, on peut comparer les erreurs d'entraînement et de validation. On obtient le résultat suivant : l'erreur d'entraînement généralement diminue au fur et à mesure que le nombre d'unités cachées augmente.

Concernant l'erreur de validation, elle est toujours supérieure à celle d'entraînement, décroît avec l'augmentation du nombre d'unités cachées, atteint un minimum pour un certain nombre optimal d'unités cachées, puis croît lorsque le nombre d'unités devient trop grand. C'est donc l'utilisation d'un ensemble de validation, distinct de l'ensemble d'entraînement, qui nous permet de choisir le nombre optimal d'unités cachées ou neurones. La figure suivante présente l'évolution de l'erreur de validation en fonction du nombre de neurones cachés.

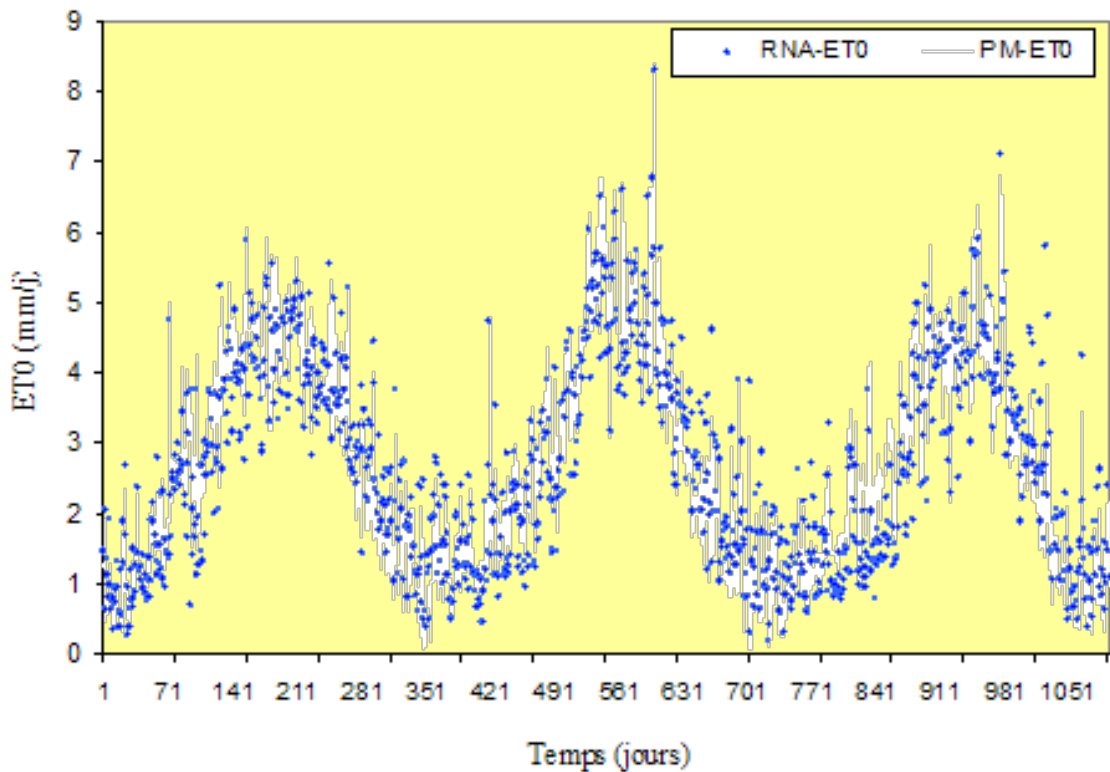


**Fig.IV.2. : Evolution de RMSE en fonction de nombre de neurones de la couche cachée (phase de validation)**

La figure.IV.2 présente l'influence du nombre de neurones de la couche cachée sur la performance du modèle neuronal de type PMC au pas de temps journalier. Les critères de performance varient de (0,4751 mm/j à 0,5651 mm/j) et de (0,863 à 0.901) pour le root mean square error (RMSE) et le coefficient de détermination ( $R^2$ ) respectivement. Il est évident que le nombre de neurones a un effet remarquable sur la performance des modèles neuronaux.

Le meilleur résultat est obtenu par un réseau PMC à structure: 6-12-1 avec un RMSE de 0,4751mm/j et un  $R^2$  de 0.901 pour la station météorologique de Dar El-Beida au pas de temps journalier. Afin de bien illustrer les résultats de modélisation obtenus par le meilleur

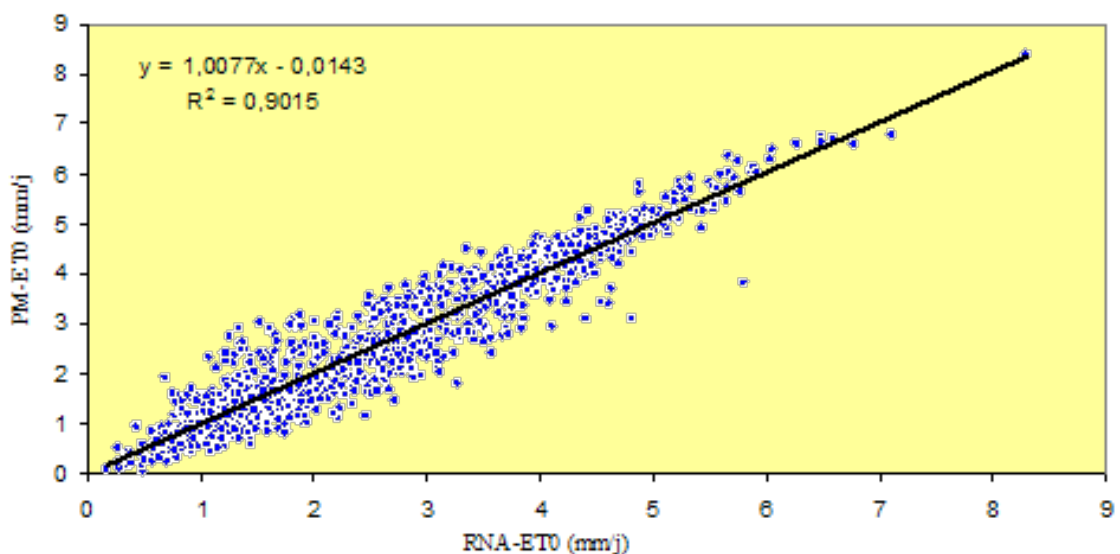
modèle neuronal journalier ( $RNA_j$  : 6-12-1), nous avons tracé les deux graphismes ci-après.



**Fig.IV.3.** : Les  $ET_0$  simulées par le  $RNA_j$  et celles estimées par la formules de PM

L'observation visuelle de ce graphisme montre que les valeurs de PM- $ET_0$  et celles simulées par le réseau de neurone ( $RNA_j$  : 6-12-1) sont très proches et presque superposées et les différences oscillent autour de 0 à 1 mm/j.

La corrélation entre les valeurs de l'évapotranspiration de référence estimées par la formule de Penman-Monteith modifiée et celles simulées est donnée par le graphe suivant :



**Fig.IV.4. : Régression linéaire entre les ET<sub>0</sub> estimées (PM) et celles simulées par RNA (phase de validation)**

La corrélation étant si étroite et la pente voisine de un, il paraît raisonnable de confondre les valeurs de ces deux méthodes. Nous avons donc enregistré une bonne corrélation existant entre la série estimée et simulée avec un coefficient de détermination de  $R^2=0.901$  et un RMSE=0.47 durant la phase de validation, ce qui donne une idée sur le potentiel de ce réseau dans la modélisation des évapotranspirations de référence au pas de temps journalier.

Généralement on évalue la performance de modèle calé sur une base de données d'événements qui n'a pas servi pour le calage (apprentissage). Cette étape est nécessaire pour évaluer la capacité de généralisation du modèle, mais ça nous a paru insuffisant, pour cela nous avons divisé la base de donnée en trois parties, l'une pour le calage, l'autre pour la validation et la dernière sert pour la phase dite de 'post validation', dans une optique de bien évaluer la performance et la robustesse du meilleur modèle choisi auparavant (**RNA<sub>j</sub> :6-12-1**).

La longueur de ces trois ensembles est choisie comme suit : quatre années pour l'apprentissage, trois années pour la validation et trois années pour la post validation.

Les résultats obtenus par le modèle neuronal journalier (**RNA<sub>j</sub> : 6-12-1**), sont dans ce qui suit.

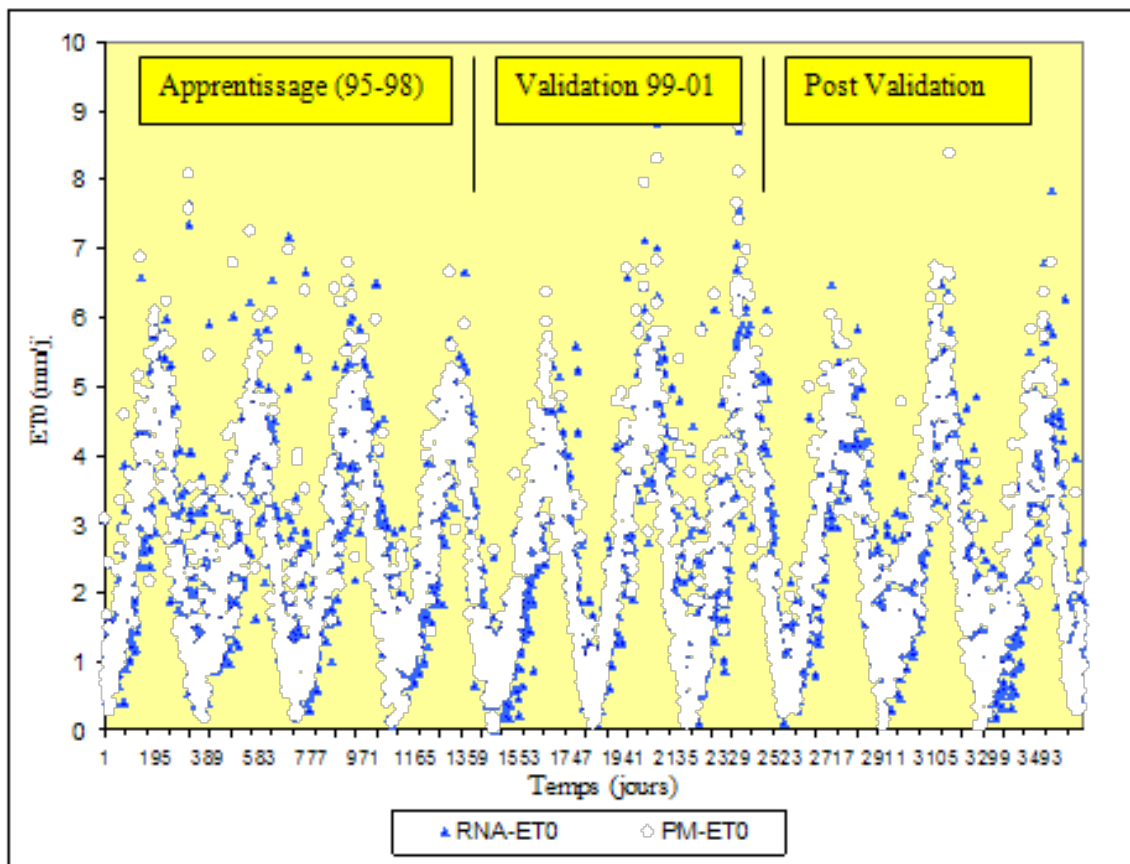
**Tableau.IV.6. : Critères de performance de modèle (RNA<sub>j</sub> : 6-12-1) en phases d'apprentissage, de validation et de post validation.**

Modèle	Apprentissage		Validation		Post validation	
	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>
<b>RNA<sub>j</sub> : 6-12-1</b>	0.43	0.914	0.56	0.879	0.55	0.866

Nous avons enregistré une petite détérioration de qualité de simulation en phases de validation et de post validation de l'ordre de 0.11 à 0.13 mm/j par rapport aux résultats obtenus en apprentissage.

D'après les résultats du tableau précédent, les critères de performance de ce modèle (RMSE et R<sup>2</sup>) sur l'ensemble d'apprentissage, sur les ensembles de validation et de post validation sont relativement bas et du même ordre de grandeur, et cela confirme la qualité de simulation en phase de validation et de post validation, donc le modèle neuronal (**RNA<sub>j</sub> : 6-12-1**) est robuste et performant, il nous permet d'estimer l'ET<sub>0</sub> avec une bonne précision en utilisant les techniques modernes de l'intelligence artificielle.

A titre d'ultime vérification et pour bien visualiser la variation des ET<sub>0</sub> estimées et celles simulées par le (RNA<sub>j</sub> : 6-12-1) au cours de la période 1995-2004, nous avons tracé le graphe suivant :



**Fig.IV.5. :** Les ET<sub>0</sub> simulées et observées (modèle à six entrées)

Les valeurs d'ET<sub>0</sub> simulées et celles estimées sont presque confondues, donc les critères graphiques réaffirment la performance et la qualité de simulation de ce modèle neuronal.

#### IV.4.3.1.2. Modèles neuronaux aux pas de temps décadaire

Les modèles neuronaux au pas de temps décadaire sont de type PMC, 6inputs, l'algorithme de rétro propagation de l'erreur, variante de L-M, longueur des ensembles (5ans-5ans), avec 300 itérations (trial-and-error, step-by-step, one-by-one).

Les entrées : les paramètres climatiques classiques.

La sortie : les cumuls des ET<sub>0</sub> estimées par la formule Penman-Monteith modifiée.

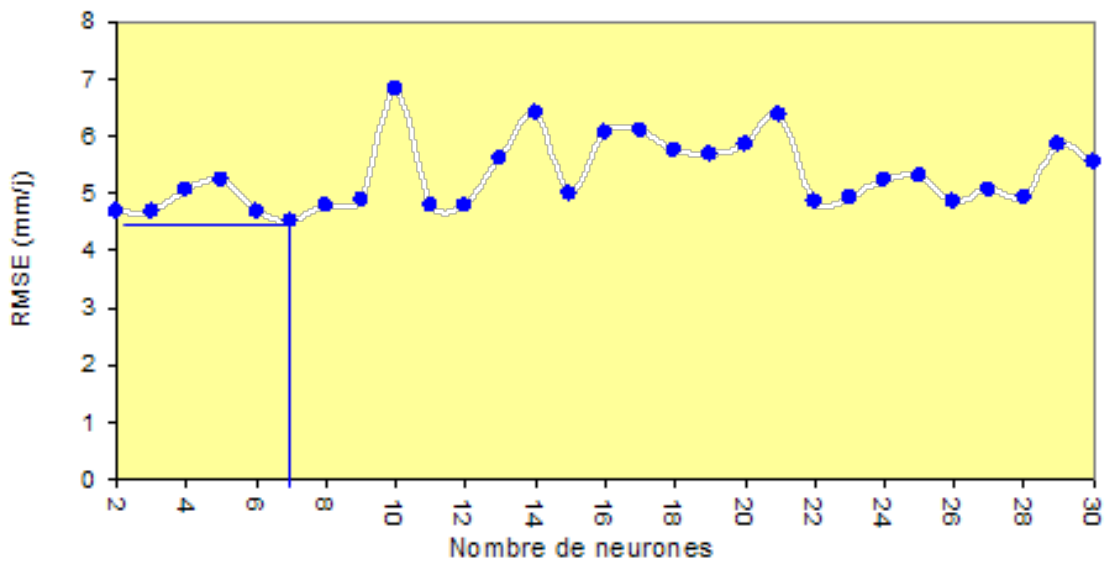
Architecture	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
PMC : 6-2-1	4,29	0,893	4,67	0.902
PMC : 6-3-1	4,19	0.898	4,67	0.906
PMC : 6-4-1	4,10	0.902	5,05	0.890
PMC : 6-5-1	3,79	0.916	5,23	0.881
PMC : 6-6-1	3,97	0.908	4,67	0.911
PMC : 6-7-1	4,23	0.896	4,50	0.912
PMC : 6-8-1	3,46	0.930	4,80	0.895
PMC : 6-9-1	4,05	0.905	4,91	0.892
PMC : 6-10-1	5,76	0.808	6,81	0.786
PMC : 6-11-1	4,01	0.907	4,80	0.896
PMC : 6-12-1	4,07	0.904	4,79	0.896
PMC : 6-13-1	3,92	0.911	5,61	0.860
PMC : 6-14-1	4,29	0.893	6,41	0.810
PMC : 6-15-1	3,72	0.920	4,99	0.891
PMC : 6-16-1	4,30	0.893	6,06	0.832
PMC : 6-17-1	3,42	0.932	6,10	0.834
PMC : 6-18-1	3,18	0.941	5,76	0.845
PMC : 6-19-1	3,86	0.913	5,68	0.859
PMC : 6-20-1	3,72	0.920	5,85	0.841
PMC : 6-21-1	4,73	0.869	6,38	0.818
PMC : 6-22-1	3,21	0.940	4,86	0.892
PMC : 6-23-1	3,20	0.940	4,94	0.887
PMC : 6-24-1	3,10	0.944	5,24	0.874
PMC : 6-25-1	3,87	0.913	5,29	0.884
PMC : 6-26-1	3,68	0.921	4,86	0.893
PMC : 6-27-1	2,80	0.954	5,07	0.880
PMC : 6-28-1	3,23	0.939	4,92	0.887
PMC : 6-29-1	3,09	0.944	5,85	0.843
PMC : 6-30-1	2,94	0.949	5,56	0.857

**Tableau.IV.7. : Résultats de modèles décadaires en périodes d'apprentissage et de validation.**

D'après ce tableau, nous remarquons que les modèles donnent des résultats relativement différents, en fonction du nombre de neurones cachés. En effet, les critères de performance en phase de validation (RMSE et R<sup>2</sup>) varient de (4,50 et 0.912) à (6,38 et 0.818) pour le RMSE et le R<sup>2</sup> respectivement.

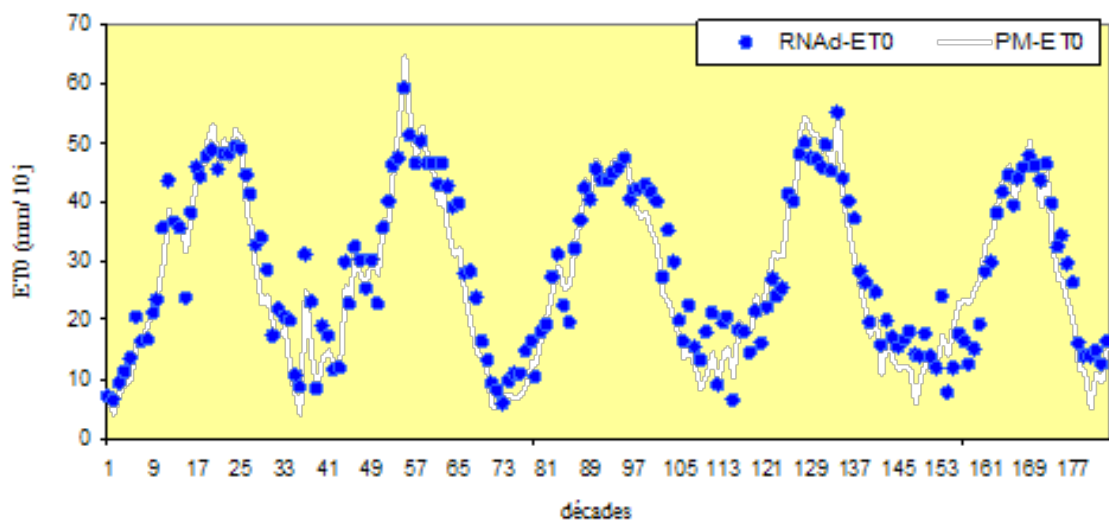
En période de validation, il est à signaler une détérioration de la simulation de tous les modèles. La figure suivante représente l'évolution de critère de performance (RMSE) en fonction du nombre de neurones dans la couche cachée durant la phase de validation.



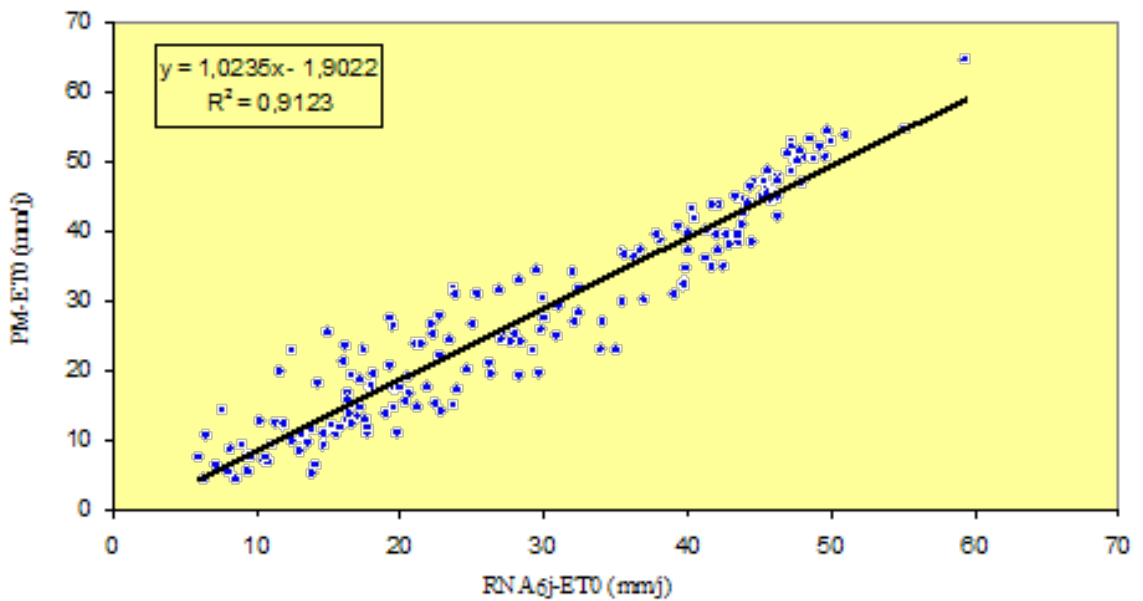


**Fig.IV.6.** : Evolution de critère de performance (RMSE) des modèles neuronaux de type PMC en fonction de nombre de neurones au pas de temps décadaire

Selon ce graphisme, le meilleur résultat est donné par un modèle neuronal décadaire de type PMC, avec une structure (PMC : 6-7-1).



**Fig.IV.7.** : ETO simulées et observées (modèle à six entrées RNAi)



**Fig.IV.8.** : Régression linéaire entre les ET<sub>0</sub> observées (PM) et celles simulées par RNA à six entrées

La régression linéaire entre les valeurs d'ET<sub>0</sub> décadaires simulées et celles estimées montre une bonne concordance entre ces deux méthodes, avec une pente proche de un et un coefficient de détermination de 0.912. Donc le modèle (RNA<sub>d</sub> : 6-7-1) donne de valeurs décadaires acceptables d'ET<sub>0</sub> en simulation.

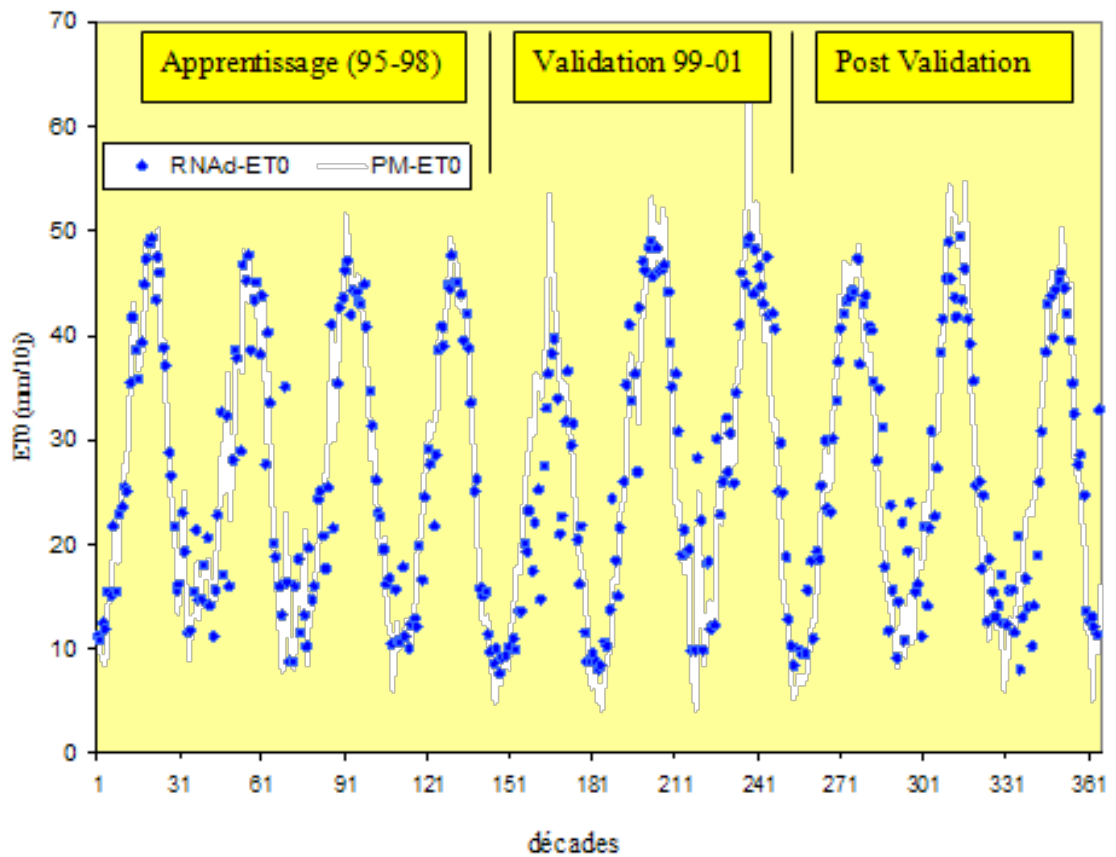
Afin de bien confirmer ces résultats nous avons passé à l'étape de post validation en divisant la base de données en trois ensembles, avec une longueur de 4ans, 3ans et 3 ans pour chacune.

**Tableau.IV.8.** : Résultats de modèle (RNA<sub>d</sub> : 6-7-1), en phases d'apprentissage, de validation, et de post validation.

Modèle	Apprentissage		Validation		Post validation	
	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>
RNA <sub>d</sub> : 6-7-1	3,55	0,927	7,91	0,744	6,29	0,804

On observe une petite détérioration de simulation en périodes de validation et de post validation. Les critères de performance augmentent en phases d'apprentissage, de validation, ensuite diminuent en post validation.

Pour bien visualiser la variation des ET<sub>0</sub> estimées et celles simulées par le (RNA<sub>d</sub> : 6-7-1) au cours de la période 1995-2004, nous avons tracé le graphe suivant.



*Fig.IV.9. : ET<sub>0</sub> simulées et observées (modèle à six entrées)*

#### IV.4.3.1.3. Modèles neuronaux au pas de temps mensuels


Ce sont les modèles neuronaux utilisés afin de quantifier l'ET<sub>0</sub> mensuelle. Ils sont de type PMC, 6inputs, l'algorithme de rétro propagation de l'erreur, variante de L-M, longueur des ensembles (5ans-5ans), avec 300 itérations.

Architecture	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
PMC : 6-2-1	27,4	0.516	30,2	0.546
PMC : 6-3-1	13,7	0.878	26,1	0.660
PMC : 6-4-1	14,2	0.869	18,7	0.824
PMC : 6-5-1	10,1	0.933	18,2	0.827
PMC : 6-6-1	11,6	0.912	14,0	0.910
PMC : 6-7-1	11,3	0.917	14,1	0.898
PMC : 6-8-1	13,9	0.874	25,2	0.782
PMC : 6-9-1	11,5	0.915	14,8	0.903
PMC : 6-10-1	10,8	0.923	16,4	0.880
PMC : 6-11-1	19,8	0.745	20,9	0.770
PMC : 6-12-1	10,9	0.923	16,7	0.854
PMC : 6-13-1	9,02	0.947	14,5	0.910
PMC : 6-14-1	20,4	0.731	23,9	0.722
PMC : 6-15-1	11,2	0.918	15,4	0.899
PMC : 6-16-1	12,6	0.896	16,1	0.868
PMC : 6-17-1	14,0	0.872	19,0	0.821
PMC : 6-18-1	12,5	0.899	17,7	0.839
PMC : 6-19-1	16,7	0.820	20,3	0.799
PMC : 6-20-1	11,0	0.921	16,3	0.894
PMC : 6-21-1	13,0	0.891	20,0	0.798
PMC : 6-22-1	11,4	0.915	15,6	0.895
PMC : 6-23-1	13,4	0.883	17,6	0.838
PMC : 6-24-1	17,4	0.805	21,3	0.800
PMC : 6-25-1	16,4	0.826	19,8	0.800
PMC : 6-26-1	15,5	0.843	17,6	0.849
PMC : 6-27-1	16,8	0.818	22,3	0.753
PMC : 6-28-1	17,1	0.811	26,3	0.637
PMC : 6-29-1	10,5	0.928	19,3	0.843
PMC : 6-30-1	12,4	0.899	16,9	0.876

**Tableau.IV.9. : Résultats de modèles mensuels en périodes d'apprentissage et de validation.**


Les critères de performances au pas de temps mensuel sont généralement inférieurs à ceux enregistrés pour les autres pas de temps (journalier et mensuel). Le RMSE varie de 14,0187 à 30,2089 mm/mois pour la phase de validation.

Comme d'habitude les critères de performance augmentent de calage en validation.




**Fig.IV.10. :** Evolution de critère de performance (RMSE) de modèles neuronaux en fonction de nombre de neurones cachée (pas du temps mensuel)

Selon la figure.IV.10, le modèle (RNA<sub>m</sub> : 6-6-1) donne le meilleur résultat au pas de temps mensuel avec un RMSE de 14,018et un R<sup>2</sup> de 0.91.



**Fig.IV.11. :** ET0 simulées et observées (modèle à six entrées RNA<sub>m</sub>)



**Fig.IV.12. :** Régression linéaire entre les  $et_0$  estimées (PM) et celles simulées par le RNAm (six entrées)


Il apparaît clairement dans les deux figures précédentes que les résultats obtenus par les modèles au pas de temps mensuel, sont relativement faibles par rapport aux autres pas de temps, quelque soit le nombre de neurones introduits dans les modèles.

Du point de vue pratique le modèle (**RNA<sub>m</sub> : 6-6-1**) donne de valeurs acceptables, il permet d'estimer l' $ET_0$  mensuelle avec une précision tolérable ( $R^2=91$ ).

**Tableau.IV.10. :** Résultats du modèle (RNA<sub>m</sub> : 6-6-1), en périodes d'apprentissage, de validation, et de post validation, au pas de temps mensuel.

Modèle	Apprentissage		Validation		Post validation	
	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>
RNA <sub>m</sub> : 6-6-1	8,0	0,968	22,2	0,868	15,6	0,888

On note ici une détérioration de simulation considérable en périodes de validation et de post validation avec des RMSE de l'ordre de 22 et 15 mm/mois pour les deux dernières phases respectivement. Les critères de performance (RMSE) augmentent d'apprentissage en validation, puis diminuent en post validation.



*Fig.IV.13. : Les ET<sub>0</sub> simulées et observées, périodes d'apprentissage, validation et de post validation au pas de temps mensuel*

#### IV.4.3.2. Les modèles neuronaux alternatifs pour estimer l'ET<sub>0</sub>

##### IV.4.3.2.1. Objectifs

L'objectif de ce chapitre est de trouver la meilleure méthode alternative permettant d'évaluer l'ET<sub>0</sub> dans la plaine de la Mitidja quand les paramètres climatiques sont insuffisants pour l'application de la formule universelle de FAO-56-PM. Ces méthodes ont un intérêt primordial pour les études d'aménagement hydro agricole en l'absence de quelques paramètres climatiques.

Les séries climatiques renferment certaines lacunes pour quelques variables climatiques le long de la série ou durant certaines périodes, et cela dû probablement à l'absence de quelques instruments de mesure, ou à une cassure de matériel pendant une durée bien connue.

La formule classique de FAO-56-PM est certainement la meilleure méthode pour estimer l'ET<sub>0</sub> dans les régions humides et arides (Crop water requirement FAO56). Cependant les données nécessaires à l'utilisation de cette formule ne sont disponibles qu'en un nombre restreint de postes climatologiques. Pour améliorer la couverture spatiale, il nous paraît intéressant de valoriser les informations climatiques disponibles, le recours aux méthodes alternatives constitue un outil puissant pour estimer l'ET<sub>0</sub> à différentes échelles d'espace et de temps et pour combler les lacunes existantes le long de la série

d'ET<sub>0</sub>. L'application des réseaux de neurones artificiels en utilisant un nombre minimal de paramètres comme entrées est l'une de ces méthodes alternatives.

**IV.4.3.2.2. Implémentation des modèles neuronaux alternatifs**

Nous avons implémenté ces modèles neuronaux en utilisant l'algorithme de rétro propagation, la longueur des ensembles d'apprentissage-validation est de (7ans-3ans), (5ans-5ans) et (5ans-5ans) aux pas de temps journalier, décadaire et mensuel respectivement.

Différentes combinaisons de données climatiques, en l'occurrence de la durée d'insolation, température de l'air, humidité relative et vitesse du vent, sont utilisées en entrée des réseaux de neurones artificiels afin d'évaluer l'influence de chacune de ces variables sur l'ET<sub>0</sub>.

Il est important de signaler que le choix de meilleur modèle neuronal se fait sur la base de résultats obtenus durant la phase de validation (début d'exploitation de modèle).

Plusieurs RNAs sont entraînés dont la description est présentée dans le tableau suivant :

Données d'entrées	RNA <sub>1</sub>	RNA <sub>2</sub>	RNA <sub>3</sub>	RNA <sub>4</sub>	RNA <sub>5</sub>	RNA <sub>6</sub>	RNA <sub>7</sub>	RNA <sub>8</sub>	RNA <sub>9</sub>
T <sub>max</sub>	●	●	●	●	●	●	●	●	●
T <sub>min</sub>	●	●	●	●	●	●	●	●	●
T <sub>moy</sub>		●		●	●	●	●	●	
Ins				●		●	●		
HR				●		●	●		
U <sub>2</sub>			●		●	●		●	
							●	●	●

**Tableau.IV.11.** Combinaison de différents paramètres climatiques utilisés comme entrées pour l'implémentation de chaque modèle neuronal alternatif:

Note:

T<sub>max</sub> (température maximale), T<sub>min</sub> (température minimale), T<sub>moy</sub> (température moyenne), Ins (durée d'insolation), HR (l'humidité relative), U<sub>2</sub> (la vitesse du vent à 2m de hauteur).

Afin d'indiquer le pas de temps pour chaque modèle, on ajoute les lettres (j), (d) et (m) à la fin de la nomenclature de modèle comme indice, par exemple RNA<sub>1(j)</sub>, RNA<sub>1(d)</sub> et RNA<sub>1(m)</sub>.

**IV.4.3.2.3. Résultats de simulation par les réseaux de neurones artificiels**



#### IV.4.3.2.3.1. Résultats de simulation au pas de temps journalier

Pour élaborer ce chapitre nous avons entraîné **86** réseaux de neurones en faisant varier le nombre d'entrées et le nombre de neurones, et les résultats sont exposés dans ce qui suit.

##### IV.4.3.2.3.1.1. Modèles à deux entrées (Tmax, Tmin) : (RNA<sub>1j</sub>)

Ces modèles ont été implémentés sous MATLAB en se basant sur les valeurs journalières de température minimale et maximale comme entrée, avec une seule couche cachée, le nombre de neurones optimal de la couche cachée est déterminé par approximation successive. Le tableau suivant illustre l'évolution de critères de performances (RMSE et R<sup>2</sup>) durant les phases d'apprentissage et de validation en fonction du nombre de neurones cachés.

Modèles	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
RNA <sub>1j</sub> : (2-2-1)	0,94	0.626	0,88	0.657
RNA <sub>1j</sub> : (2-3-1)	0,93	0.636	0,88	0.660
RNA <sub>1j</sub> : (2-4-1)	0,93	0.635	0,88	0.659
RNA <sub>1j</sub> : (2-5-1)	0,93	0.632	0,88	0.657
RNA <sub>1j</sub> : (2-6-1)	0,93	0.635	0,88	0.659
RNA <sub>1j</sub> : (2-7-1)	0,93	0.635	0,88	0.659

**Tableau.IV.12. : Résultats des modèles de type (RNA 1j ).**

Le tableau IV.12. Représente les valeurs de critères statistiques obtenues avec les modèles neuronaux de type **RNA 1j** (T<sub>max</sub>, T<sub>min</sub> comme entrées), les valeurs de RMSE pour la phase de validation sont de l'ordre de 0,88mm/j.

La meilleure structure obtenue est le: **RNA 1(j) : (2-3-1)**, c'est-à-dire un réseau contenant deux neurones dans la couche d'entrée, 3 neurones dans la couche cachée, un seul neurone de sortie, avec un RMSE de 0,88 et un R<sup>2</sup>=0.66.

Pour illustrer ce modèle (RNA<sub>1(j)</sub> : (2-3-1)), on va visualiser ces résultats en faisant appel au graphisme suivant:

Le graphe IV.14représente l'évolution des évapotranspirations de référence simulées par le RNA<sub>1j</sub> et estimées durant la période 2002-2005 concernant la région d'Alger.




Fig.IV.14. : ET0 simulées et observées (deux entrées RNA1j)

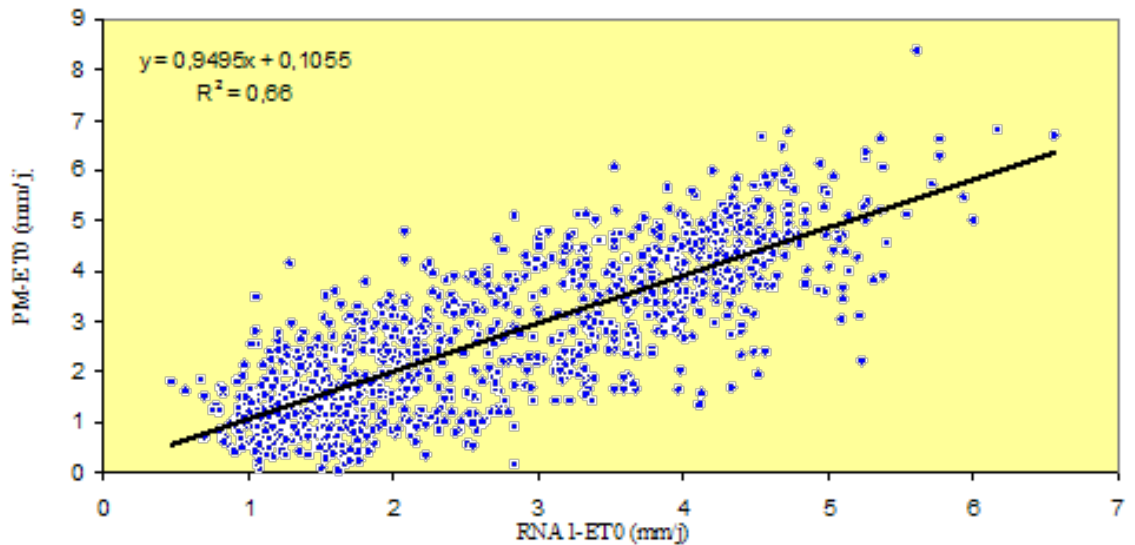


Fig.IV.15. : Régression linéaire entre les ET0 estimées (PM) et celles simulées par RNA1j (deux entrées)

#### IV.4.3.2.3.1.2. Modèles à trois entrées

##### IV.4.3.2.3.1.2.1. Modèles RNA<sub>2j</sub>


La démarche que nous nous proposons d'utiliser est de choisir un RNA (PMC) valable pour l'Algérie du Nord (plaine de la Métidja), qui permette au mieux de retrouver l'ET<sub>0</sub>-PM à partir des températures moyennes, maximales et minimales. Pour ce faire nous avons implémenté

différents modèles neuronaux de type **RNA 2j** dont on cherche le nombre optimal de neurones cachés.

Modèles	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
RNA <sub>2j</sub> : (3-3-1)	0,87	0.681	0,93	0.633
RNA <sub>2j</sub> : (3-4-1)	0,93	0.633	0,88	0.639
RNA <sub>2j</sub> : (3-5-1)	0,89	0.668	0,92	0.642
RNA <sub>2j</sub> : (3-6-1)	0,86	0.684	0,89	0.687
RNA <sub>2j</sub> : (3-7-1)	0,86	0.684	0,90	0.650


**Tableau.IV.13. :Résultats des modèles de type (RNA 2j )**

D'après les résultats de ce tableau, la structure choisie est celle de **RNA 2(j)** : (3-4-1), ça veut dire un modèle neuronal contenant 3 neurones dans la couche d'entrée, 4 neurones dans la couche cachée, et un seul neurone de sortie.



**Fig.IV.16. : ET0 simulées et observées (modèle à trois entrées RNA2j)**

On voit ici que les valeurs d'ET0 simulées et celles observées suivent la même tendance générale au cours de l'année, ça veut dire que la variation saisonnière de l'ET0 est respectée, mais les écarts à l'échelle de la journée sont remarquables, cette tendance est confirmée encore une fois par la droite de régression et les critères statistiques de performance.



**Fig.IV.17.** : Régression linéaire entre les ET0 estimées (PM) et celles simulées par RNA2j (3 entrées)


#### IV.4.3.2.3.1.2.2. Modèles RNA<sub>3j</sub>

Modèles	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
RNA <sub>3j</sub> : (3-3-1)	0,93	0.631	0,88	0.661
RNA <sub>3j</sub> : (3-4-1)	0,93	0.635	0,88	0.661
RNA <sub>3j</sub> : (3-5-1)	0,93	0.632	0,88	0.661
RNA <sub>3j</sub> : (3-6-1)	0,93	0.634	0,88	0.664
RNA <sub>3j</sub> : (3-7-1)	0,93	0.634	0,88	0.660


**Tableau.IV.14.** : Résultats des modèles de type (RNA 3j )

D'après les résultats de ce tableau, la structure choisie est celle de **RNA 3(j)** : (3-6-1), ça veut dire un modèle neuronal contenant 3 neurones dans la couche d'entrée, 6 neurones dans la couche cachée, et un seul neurone de sortie.

Afin de bien visualiser ces résultats on trace les graphes suivants :



**Fig.IV.18.** : ET0 simulées et observées ( modèle à trois entrées RNA3j)



**Fig.IV.19.** : Régression linéaire entre les ET0 estimées (PM) et celles simulées par RNA3j (trois entrées)

#### IV.4.3.2.3.1.2.3. Modèles RNA<sub>9j</sub>

Modèles	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
RNA <sub>9j</sub> : (3-2-1)	0,75	0.761	0,73	0.776
RNA <sub>9j</sub> : (3-3-1)	0,74	0.765	0,74	0.772
RNA <sub>9j</sub> : (3-4-1)	0,72	0.777	0,71	0.788
RNA <sub>9j</sub> : (3-5-1)	0,72	0.781	0,71	0.788
RNA <sub>9j</sub> : (3-6-1)	0,71	0.783	0,71	0.786
RNA <sub>9j</sub> : (3-7-1)	0,71	0.783	0,71	0.787
RNA <sub>9j</sub> : (3-8-1)	0,72	0.782	0,71	0.786

Tableau.IV.15. Résultats des modèles de type (RNA 9j )

La meilleure structure obtenue est le **RNA 9(j) (3-6-1)** , c'est-à-dire un réseau contenant trois neurones dans la couche d'entrée, 6 neurones dans la couche cachée, un seul neurone de sortie, avec un RMSE de 0,71et un R<sup>2</sup> de 0.786.





Fig.IV.20. : ETO simulées et observées (modèles à trois entrées RNA9j).



**Fig.IV.21.** : Régression linéaire entre les ET0 observées (PM) et celles simulées par RNA9j (trois entrées)

#### IV.4.3.2.3.1.3. Modèles à quatre entrées

##### IV.4.3.2.3.1.3.1. Modèles RNA<sub>4j</sub>

Modèles	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
RNA <sub>4j</sub> : (4-3-1)	0,74	0.767	0,74	0.758
RNA <sub>4j</sub> : (4-4-1)	0,73	0.773	0,73	0.767
RNA <sub>4j</sub> : (4-5-1)	0,73	0.774	0,99	0.576
RNA <sub>4j</sub> : (4-6-1)	0,72	0.778	0,73	0.767
RNA <sub>4j</sub> : (4-7-1)	0,72	0.781	0,71	0.777
RNA <sub>4j</sub> : (4-8-1)	0,72	0.782	0,73	0.768
RNA <sub>4j</sub> : (4-9-1)	0,72	0.777	0,71	0.776
RNA <sub>4j</sub> : (4-10-1)	0,71	0.783	0,73	0.765
RNA <sub>4j</sub> : (4-11-1)	0,73	0.776	0,75	0.757
RNA <sub>4j</sub> : (4-12-1)	0,71	0.788	0,72	0.773
RNA <sub>4j</sub> : (4-13-1)	0,70	0.789	0,70	0.784
RNA <sub>4j</sub> : (4-14-1)	0,71	0.787	0,72	0.770
RNA <sub>4j</sub> : (4-15-1)	0,70	0.792	0,77	0.749

**Tableau.IV.16.** : Résultats des modèles de type (RNA 4j )

La meilleure structure obtenue est le: **RNA 4(j) : (2-13-1)**, c'est-à-dire un réseau contenant quatre neurones dans la couche d'entrée, 13 neurones dans la couche cachée, un seul neurone de sortie, avec un RMSE de 0,70 et un R<sup>2</sup> de 0.784 en phase de validation.






Fig.IV.22. : ET0 simulées et observées (modèle à 4 entrées RNA4j)




Fig.IV.23. : Régression linéaire entre les ET0 estimées (PM) et celles simulées par RNA4j (4 entrées)


#### IV.4.3.2.3.1.3.2. Modèles RNA5j




Modèles	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
RNA <sub>5j</sub> : (4-3-1)	0,9365	0.6327	0,8882	0.658
RNA <sub>5j</sub> : (4-4-1)	0,9337	0.6348	0,8868	0.659
RNA <sub>5j</sub> : (4-5-1)	0,8010	0.7313	0,8807	0.675
RNA <sub>5j</sub> : (4-6-1)	0,7841	0.7425	0,8709	0.684
RNA <sub>5j</sub> : (4-7-1)	0,7894	0.7390	0,8044	0.724
RNA <sub>5j</sub> : (4-8-1)	0,7815	0.7442	0,8469	0.700
RNA <sub>5j</sub> : (4-9-1)	0,7873	0.7404	0,8308	0.710
RNA <sub>5j</sub> : (4-10-1)	0,7937	0.7361	0,8610	0.693
RNA <sub>5j</sub> : (4-11-1)	0,7804	0.7449	0,8419	0.702
RNA <sub>5j</sub> : (4-12-1)	0,7938	0.7361	0,8524	0.697
RNA <sub>5j</sub> : (4-13-1)	0,8151	0.7217	0,8346	0.706

**Tableau.IV.17. : Résultats des modèles de type (RNA 5j )**

La meilleure structure obtenue est le: **RNA 4(j) : (4-7-1)**, c'est-à-dire un réseau contenant quatre neurones dans la couche d'entrée, 7 neurones dans la couche cachée, un seul neurone de sortie, avec un RMSE de 0,8044 et un R<sup>2</sup> de 0.724 en phase de validation.



**Fig.IV.24. : ETO simulées et observées (modèle à 4 entrées RNA5j)**



**Fig.IV.25.** Régression linéaire entre les ET0 observées (PM) et celles simulées par RNA5j (4 entrées)


#### IV.4.3.2.3.1.4. Modèles à cinq entrées

##### IV.4.3.2.3.1.4.1. Modèles RNA<sub>6j</sub>


Modèles	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
RNA <sub>6j</sub> : (5-4-1)	0,93	0.633	0,88	0.660
RNA <sub>6j</sub> : (5-5-1)	0,94	0.629	0,88	0.658
RNA <sub>6j</sub> : (5-6-1)	0,93	0.633	0,88	0.658
RNA <sub>6j</sub> : (5-7-1)	0,93	0.636	0,88	0.660
RNA <sub>6j</sub> : (5-8-1)	0,93	0.636	0,88	0.658
RNA <sub>6j</sub> : (5-9-1)	0,92	0.639	0,88	0.659
RNA <sub>6j</sub> : (5-10-1)	0,93	0.637	0,88	0.660
RNA <sub>6j</sub> : (5-11-1)	0,93	0.637	0,88	0.659
RNA <sub>6j</sub> : (5-12-1)	0,92	0.639	0,88	0.661
RNA <sub>6j</sub> : (5-13-1)	0,60	0.845	0,67	0.813
RNA <sub>6j</sub> : (5-14-1)	0,60	0.845	0,67	0.812
RNA <sub>6j</sub> : (5-15-1)	0,60	0.844	0,69	0.802
RNA <sub>6j</sub> : (5-30-1)	0,57	0.859	0,71	0.792

**Tableau.IV.18.** Résultats des modèles de type (RNA 6j )

D'après les résultats du tableauIV.18 la structure choisie est celle de RNA 6(j) : (5-13-1), ça veut dire un modèle neuronal contenant 3 neurones dans la couche d'entrée, 6 neurones dans la couche cachée, et un seul neurone de sortie.



**Fig.IV.26.** : ET0 simulées et observées (modèle à cinq entrées RNA6j)



**Fig.IV.27.** : Régression linéaire entre les ET0 observées (PM) et celles simulées par RNA6j (cinq entrées)

Le modèle **RNA 6j** : (5-13-1) apporte de résultats médiocres en apprentissage et en validation.

#### IV.4.3.2.3.1.4.2. Modèles RNA7j

Modèles	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
RNA <sub>7j</sub> : (5-4-1)	0,55	0.873	0,58	0.852
RNA <sub>7j</sub> : (5-5-1)	0,54	0.874	0,54	0.877
RNA <sub>7j</sub> : (5-6-1)	0,54	0.873	0,55	0.866
RNA <sub>7j</sub> : (5-7-1)	0,54	0.877	0,58	0.851
RNA <sub>7j</sub> : (5-8-1)	0,55	0.871	0,54	0.871
RNA <sub>7j</sub> : (5-9-1)	0,53	0.881	0,54	0.872
RNA <sub>7j</sub> : (5-10-1)	0,53	0.879	0,54	0.874
RNA <sub>7j</sub> : (5-11-1)	0,52	0.882	0,55	0.867
RNA <sub>7j</sub> : (5-12-1)	0,52	0.882	0,63	0.833
RNA <sub>7j</sub> : (5-13-1)	0,52	0.882	0,54	0.872
RNA <sub>7j</sub> : (5-14-1)	0,52	0.884	0,56	0.863
RNA <sub>7j</sub> : (5-15-1)	0,52	0.885	0,56	0.864
RNA <sub>7j</sub> : (5-30-1)	0,50	0.893	0,57	0.859

Tableau.IV.19. :Résultats des modèles de type (RNA 7j )





Fig.IV.28. Les ET0 simulées et observées (modèle à 5 entrées RNA7j)



**Fig.IV.29. :** Régression linéaire entre les  $ET_0$  observées (PM) et celles simulées par RNA7j (5 entrées)

La figure.IV.29. Montre une régression entre les valeurs estimées par la formule de  $ET_0$ -PM et celles obtenues par le réseau de neurones ( $ET_0$ -RNA7j) durant la phase de validation de modèle.

La relation obtenue (voir Fig.IV.29) montre un coefficient de détermination significatif de 0.877, on peut dire qu'il y a une bonne corrélation entre les  $ET_0$  de la méthode de PM et celles de réseau de neurones (RNA7j).

Ces résultats suggèrent qu'on peut utiliser le modèle neuronal (RNA7j) pour estimer l'évapotranspiration de référence journalière si les valeurs de l'humidité relative sont manquantes de la série climatique.

#### IV.4.3.2.3.1.4.3. Modèles RNA8j

Modèles	RMSE (apprentissage)	R <sup>2</sup> (apprentissage)	RMSE (validation)	R <sup>2</sup> (validation)
RNA <sub>8j</sub> : (5-3-1)	0,71	0.787	2,50	0.360
RNA <sub>8j</sub> : (5-4-1)	0,65	0.820	0,69	0.797
RNA <sub>8j</sub> : (5-5-1)	0,66	0.815	0,71	0.780
RNA <sub>8j</sub> : (5-6-1)	0,62	0.835	0,75	0.758
RNA <sub>8j</sub> : (5-7-1)	0,62	0.837	0,70	0.791
RNA <sub>8j</sub> : (5-8-1)	0,63	0.832	0,73	0.774
RNA <sub>8j</sub> : (5-9-1)	0,62	0.836	0,73	0.776
RNA <sub>8j</sub> : (5-10-1)	0,64	0.823	0,70	0.784
RNA <sub>8j</sub> : (5-11-1)	0,61	0.843	0,74	0.763
RNA <sub>8j</sub> : (5-12-1)	0,61	0.843	0,71	0.784
RNA <sub>8j</sub> : (5-13-1)	0,60	0.846	0,72	0.777
RNA <sub>8j</sub> : (5-14-1)	0,60	0.844	0,74	0.756
RNA <sub>8j</sub> : (5-15-1)	0,60	0.847	0,72	0.774

Tableau.IV.20. : Résultats des modèles de type (RNA<sub>8j</sub>)





Fig.IV.30. : ET<sub>0</sub> simulées et observées (modèle à 5 entrées RNA<sub>8j</sub>)



**Fig.IV.31.** : Régression linéaire entre les ET0 observées (PM) et celles simulées par RNA8j (5 entrées)

La figure.IV.31 montre une régression entre les valeurs estimées par la formule de  $ET_0$ -PM et celles obtenues par le réseau de neurones ( $ET_0$ -RNA8j) durant la phase de validation de modèle.

Afin de bien comparer entre les modèles neuronaux choisis en fonction de nombre d'entrées, nous avons tracé le tableau ci-après.

Modèles	Variables d'entrée	Nombre de neurones cachés	R <sup>2</sup>		RMSE	
			apprentissage	validation	apprentissage	validation
RNA <sub>10</sub>	Tmax	3	0.636	0.660	0,88	0,93
	Tmin					
RNA <sub>20</sub>	Tmax	4	0.635	0.659	0,88	0,93
	Tmin					
	Tmoy					
RNA <sub>30</sub>	Tmax	6	0.634	0.664	0,88	0,93
	Tmin					
	HR					
RNA <sub>60</sub>	Tmax	6	0.783	0.786	0,71	0,71
	Tmin					
	Insolation					
RNA <sub>90</sub>	Tmax	13	0.789	0.784	0,70	0,70
	Tmin					
	Tmoy					
	Insolation					
RNA <sub>9j</sub>	Tmax	7	0.739	0.724	0,78	0,80
	Tmin					
	Tmoy					
	U <sub>2</sub>					
RNA <sub>9j</sub>	Tmax	13	0.845	0.813	0,60	0,67
	Tmin					
	Tmoy					
	HR					
	Insolation					
RNA <sub>7j</sub>	Tmax	5	0.874	0.877	0,54	0,54
	Tmin					
	Tmoy					
	U <sub>2</sub>					
	Insolation					
RNA <sub>9j</sub>	Tmax	4	0.820	0.797	0,65	0,69
	Tmin					
	Tmoy					
	U <sub>2</sub>					
	HR					

**Tableau.IV.21.** :Résumé des résultats obtenus par les modèles neuronaux alternatifs

Ce tableau montre :

Généralement le nombre de neurones augmente en fonction du nombre d'entrées.

La performance de modèle neuronal augmente en fonction du nombre d'entrées, et le meilleur résultat est donné par le modèle **RNA 7j :5-5-1** (voir tableau. IV.21). Certains modèles apportent des résultats relativement médiocres.

#### IV.4.3.2.3.2. Résultats de simulation au pas de temps décadaire

Les résultats sont résumés sous forme de tableau, et de courbes, le tableau permet d'apprécier les valeurs des différents critères ( $R^2$  et root mean square error), les courbes interviennent au niveau de la comparaison des évapotranspirations simulées et observées (critère graphique), mais nous n'avons tracé que les courbes correspondant aux modèles qui donnent de bons résultats.




Modèles	Variables d'entrée	Nombre de neurones cachés	R <sup>2</sup>		RMSE	
			apprentissage	validation	apprentissage	validation
RNA <sub>5d</sub>	Tmax	5	0.725	0.762	6,8	7,1
	Tmin					
RNA <sub>7d</sub>	Tmax	7	0.727	0.759	6,8	7,2
	Tmin					
	Tmoy					
RNA <sub>6d</sub>	Tmax	6	0.721	0.760	6,9	7,5
	Tmin					
	HR					
RNA <sub>9d</sub>	Tmax	3	0.835	0.845	5,3	7,1
	Tmin					
	Insolation					
RNA <sub>8d</sub>	Tmax	8	0.876	0.842	4,6	5,8
	Tmin					
	Tmoy					
	Insolation					
RNA <sub>13d</sub>	Tmax	13	0.735	0.778	6,7	6,9
	Tmin					
	Tmoy					
	U <sub>2</sub>					
RNA <sub>12d</sub>	Tmax	12	0.878	0.887	4,5	5,8
	Tmin					
	Tmoy					
	HR					
	Insolation					
RNA <sub>5d</sub>	Tmax	5	0.908	0.890	3,9	5,3
	Tmin					
	Tmoy					
	U <sub>2</sub>					
	Insolation					
RNA <sub>6d</sub>	Tmax	6	0.840	0.808	5,2	7,5
	Tmin					
	Tmoy					
	U <sub>2</sub>					
	HR					

**Tableau.IV.22. :Résumé des résultats obtenus par les modèles neuronaux alternatifs :**

Au pas de temps décadaire, la performance du modèle neuronal augmente en fonction du nombre d'entrées, et les meilleurs résultats sont obtenus par le modèle **RNA 6d :5-12-1** et le modèle **RNA 7d :5-5-1** avec un coefficient de détermination de 0.887 à 0.890 respectivement.

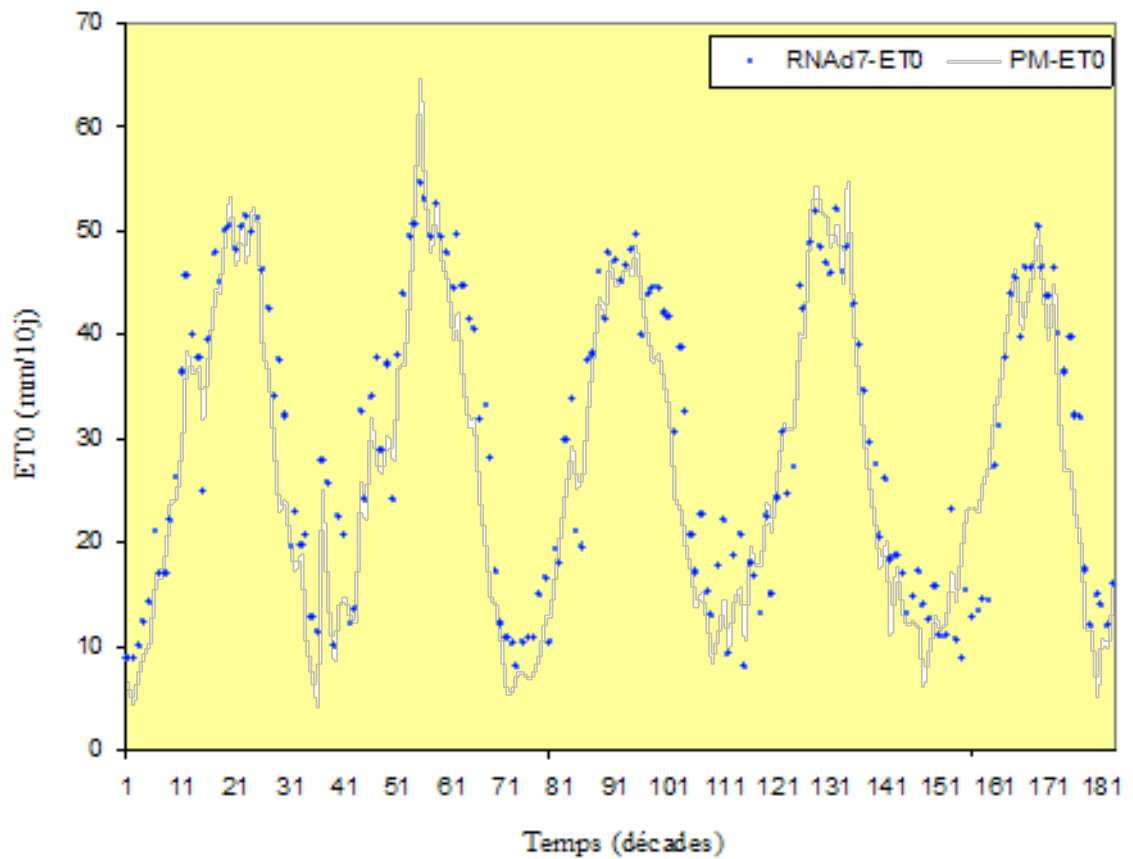
En absence de la vitesse du vent on utilise le modèle **RNA d6 :5-12-1**, alors en absence de l'humidité relative on fait appel au modèle **RNA d7 :5-5-1** pour estimer l'évapotranspiration de référence. On serait donc tenté de dire que les simulations réalisées à l'aide des modèles **RNA d6 :5-12-1** et **RNA d7 :5-5-1** peuvent restituer les valeurs d'ET<sub>0</sub> de manière assez bonne en calage qu'en validation.

Les autres modèles neuronaux présentés dans le tableau précédent apportent des résultats médiocres et ils ne parviennent pas à restituer les valeurs d'ET<sub>0</sub> escomptées.



**Fig.IV.32.** : Les ET0 simulées et observées (modèle à 5 entrées RNA d6)

La fig.IV.32. Montre que les valeurs de l'évapotranspiration de référence sont bien simulées durant la phase de validation, celle-ci est considérée comme étant le début de l'exploitation de modèle. On note cependant des petits décalages entre les valeurs observées et celles simulées, les écarts (RMSE) sont de l'ordre de 5,84mm/décade qui est une valeur acceptable pour la décade.



**Fig.IV.33.** : ET0 simulées et observées (modèle à 5 entrées RNA7)

La fig.IV.33. Montre également que les valeurs de l'évapotranspiration de référence sont bien simulées en validation, avec des écarts d'environ 5,30 mm/10 jour, le critère graphique confirme les résultats obtenus auparavant(critères statistiques).

#### IV.4.3.2.3.3. Résultats de simulation au pas de temps mensuel

La combinaison de différents paramètres climatiques utilisés comme entrées pour l'implémentation de chaque modèle neuronal alternatif au pas de temps mensuel tout en choisissant le nombre optimal de neurones cachés, nous a permis de tracer le tableau suivant.

Modèles	Variables d'entrée	Nombre de neurones cachés	R <sup>2</sup>		RMSE	
			apprentissage	validation	apprentissage	validation
RNA <sub>1d</sub>	Tmax	5	0.725	0.762	6,8	7,1
	Tmin					
RNA <sub>2d</sub>	Tmax	7	0.727	0.759	6,8	7,2
	Tmin					
	Tmoy					
RNA <sub>3d</sub>	Tmax	6	0.721	0.760	6,9	7,5
	Tmin					
	HR					
RNA <sub>3d</sub>	Tmax	3	0.835	0.845	5,3	7,1
	Tmin					
	Insolation					
RNA <sub>4d</sub>	Tmax	8	0.876	0.842	4,6	5,8
	Tmin					
	Tmoy					
	Insolation					
RNA <sub>5d</sub>	Tmax	13	0.735	0.778	6,7	6,9
	Tmin					
	Tmoy					
	U <sub>2</sub>					
RNA <sub>6d</sub>	Tmax	12	0.878	0.887	4,5	5,8
	Tmin					
	Tmoy					
	HR					
	Insolation					
RNA <sub>7d</sub>	Tmax	5	0.908	0.890	3,9	5,3
	Tmin					
	Tmoy					
	U <sub>2</sub>					
	Insolation					
RNA <sub>8d</sub>	Tmax	6	0.840	0.808	5,2	7,5
	Tmin					
	Tmoy					
	U <sub>2</sub>					
	HR					

**Tableau.IV.23.** :Résumé des résultats obtenus par les modèles neuronaux alternatifs :


Tableau.IV.23 résume les valeurs de critères de performance (R<sup>2</sup> et RMSE respectivement) pour les modèles optimisés en calage et en validation, au pas de temps mensuel.

Les modèles neuronaux choisis sont :

Le modèle **RNA m4 (4-11-1)** dont les critères de performance en validation sont de l'ordre de 0.894 et 14,82 mm/mois pour le coefficient de détermination et le root mean square error, on utilise ce modèle si l'humidité relative et la vitesse du vent ne sont pas disponibles.

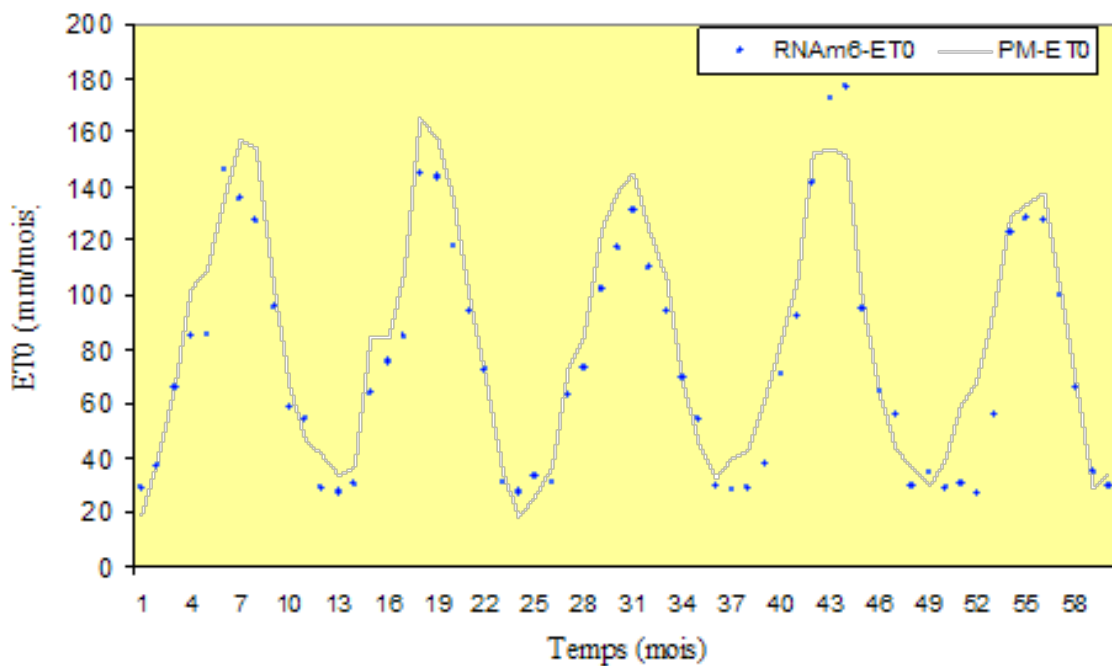
Le modèle **RNA m6 (5-21-1)** avec des critères de performance de l'ordre de 0.914 et 15.05 mm/mois pour le coefficient de détermination et le root mean square error respectivement, on fait appel à ce modèle si les valeurs de la vitesse du vent sont absentes.

Le modèle **RNA m7 (5-12-1)** dont le coefficient de détermination est de 0.907 et le root mean square error est de 15,27mm/mois en phase de validation. On recommande l'utilisation de ce modèle si les valeurs de la durée d'insolation sont manquantes.



**Fig.IV.34. :** ET0 simulées et observées (modèle à 4 entrées RNAm4)

La Fig.IV.34 montre que la modélisation par le réseau de neurones artificiel RNAm4 donne une bonne corrélation entre les valeurs observées et les valeurs simulées en phase de validation puisque les écarts sont négligeables.



**Fig.IV.35. :** ET0 simulées et observées (modèle à 5 entrées RNAm6)




Fig.IV.36. : Les ET<sub>0</sub> simulées et observées (modèle à 5 entrées RNAm7).

Les graphismes Fig.III.34 et Fig.III.35 montrent que les valeurs de l'ET<sub>0</sub> simulées et celles observées sont presque confondues, ce qui donne une idée sur la qualité de simulation de modèle RNA m4 (4-11-1) et le modèle RNA m7 (5-12-1), donc les critères graphiques confirment les résultats obtenus dans le tableau.III.18.

#### IV.4.4. Simulation de déficit hydrique par les réseaux de neurones artificiels


##### IV.4.4.1. Introduction

Nous rappelons que l'objectif de ce chapitre consiste à étudier le potentiel de réseaux de neurones artificiels pour simuler ou reconstituer le déficit hydrique d'alimentation ( $DH=ETM-ETR$ ) obtenu par différents modèles agrométéorologiques de bilan hydrique (Rojas, Eldin et Lhomme, Katerji et Lhomme), et à différents pas de temps, mais avant de l'entamer nous devons élucider ces modèles en comparant les réserves en eau du sol  $[RH(t)]$  obtenues par chacun.

##### IV.4.4.2. Evolution de la réserve en eau du sol par les différents modèles de bilan hydrique

Nous allons discuter ici les réserves en eau du sol simulées pour les trois modèles afin d'analyser l'effet de la sécheresse sur le stockage de l'eau du sol et de mettre en évidence la différence existante entre ces modèles. Nous rappelons que les valeurs de la réserve discutées ici correspondent à une profondeur racinaire maximale de 1 m.

Le graphique IV.87 montre l'évolution des réserves pour les modèles de Rojas, d'Eldin et Lhomme et de Katerdji et Lhomme durant l'année (2004), au pas de temps journalier:



**Fig.IV.37. :** Comparaison des réserves en eau du sol obtenues par différents modèles de bilan hydrique

La tendance générale de l'évolution de la réserve hydrique en eau du sol obtenue par ces modèles est en concordance avec la variation saisonnière de la disponibilité de l'eau au cours de l'année, on note ici un profil humide (proche à la capacité au champ) durant l'hiver et le printemps, par contre en été on enregistre un profil sec. Les modèles de Rojas et de Katerdji et Lhomme donnent des valeurs assez proches en eux.

Ce graphique montre clairement les écarts entre les trois modèles de bilan hydrique concernant la réserve hydrique, et cela est dû aux différentes hypothèses de départ utilisées afin d'estimer chaque terme de bilan hydrique pour chacun (voir description de modèles).

#### IV.4.4.3. Résultats de simulation du déficit hydrique par les réseaux de neurones artificiels

##### IV.4.4.3.1. Simulation de déficit hydrique au pas de temps journalier


Nous avons implémenté plusieurs modèles neuronaux servant à simuler le déficit hydrique obtenu par différents modèles de bilan hydrique à partir de quelques paramètres climatiques et édaphiques.

La série climatique a été divisée en deux parties, la première (7 ans) pour l'apprentissage du RNA et s'étale de 1995-1999, la deuxième (3 ans) sert à la validation (trial and error), les résultats obtenus par ces modèles neuronaux sont affichés dans ce qui suit.

##### IV.4.4.3.1.1. Modèles neuronaux à deux entrées

Nous avons implémenté sous Matlab trois modèles neuronaux de type Perceptron monocouche, à structure (2-4-1), c'est-à-dire 2 entrées, une seule couche cachée avec 4 neurones, une seule sortie (déficit hydrique), la fonction de transfert de la couche cachée est sigmoïde tandis que celle de la sortie est de type linéaire.

Données d'entrées : les pluies, les  $ET_0$  ; la sortie : le déficit hydrique.



**Fig.IV.38.** : Schéma de modèle neuronal à 2 entrées (pour estimer le déficit hydrique)

**Tableau.IV.24.** : Critères de performance de modèles neuronaux pour la simulation du déficit hydrique (à deux entrées), au pas de temps journalier.

Modèles	Apprentissage		Validation	
	$R^2$	RMSE	$R^2$	RMSE
RNA <sub>j</sub> (Rojas) :2-4-1	0.650	1,03	0.699	0,99
RNA <sub>j</sub> (Eldin) :2-4-1	0.784	0,83	0.843	0,74
RNA <sub>j</sub> (Katerdji) :2-4-1	0.645	1,04	0.709	0,98

Note : RNA<sub>j</sub> (Rojas), RNA<sub>j</sub> (Eldin), RNA<sub>j</sub> (Katerdji) : Modèles neuronaux utilisés pour reconstituer le déficit hydrique obtenu via le modèle de Rojas, modèles d'Eldin et Lhomme, le modèle de Katerdji et celui de Lhomme respectivement.

D'après les résultats de tableau .IV.24, ces trois modèles donnent de résultats un peu différents d'un modèle à l'autre. Les critères de performance ( $R^2$  et RMSE) sont médiocres pour les trois modèles neuronaux avec un RMSE allant de 0.833 à 1, d'où la nécessité de les améliorer en ajoutant l'état hydrique du sol comme une troisième entrée.

#### **IV.4.4.3.1.2. Modèles neuronaux à trois entrées**

Donc ce cas là, les sorties simulées par les modèles de bilan hydrique, telle que l'humidité du sol, ont été introduites comme entrées aux modèles neuronaux afin d'améliorer leur performance.

Données d'entrées : les pluies, les  $ET_0$ , l'état hydrique du sol (le stock en eau du sol).

La sortie : le déficit hydrique journalier pour chaque modèle.




Tableau.IV.25. : Critères de performance de modèles neuronaux pour la simulation de déficit hydrique (à trois entrées).

Modèles	Apprentissage		Validation	
	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE
RNA <sub>j</sub> (Rojas) :3-6-1	0,999	0,0356	0,999	0,0297
RNA <sub>j</sub> (Eldin) : 3-6-1	0,999	0,0358	0,999	0,0401
RNA <sub>j</sub> (Katerdji) : 3-6-1	01	0,0005	01	0,0005

Le tableau.IV.25 montre que les modèles neuronaux (RNA<sub>j</sub> (Rojas) :3-6-1, RNA<sub>j</sub> (Eldin) : 3-6-1,

RNA<sub>j</sub> (Katerdji) : 3-6-1) donnent de meilleurs résultats, donc les réseaux de neurones qui font appel à l'état hydrique du sol sont recommandés afin de simuler le déficit hydrique avec une bonne précision, puisque les critères de performance de ces modèles sont excellentes avec un R<sup>2</sup> qui oscille entre 0,999 à 1, et un RMSE allant de 0,0005 à 0,0401 (proche de zéro).

Afin de bien visualiser ces résultats, nous présentons dans le graphique suivant décrivant les résultats obtenus par le modèle RNA<sub>j</sub>(Eldin) :3-6-1 durant l'année 2004.



**Fig.IV.39.** : Comparaison entre les valeurs de déficit hydrique simulées par un réseau de neurones à 3 entrées et celles produites par le modèle D'Eldin et L'homme au pas de temps journalier

Cette figure montre que le critère graphique de performance de modèle est en concordance avec les critères statistiques cités dans le tableau précédent, puisqu'on observe une superposition entre les deux séries de déficit hydrique.

#### IV.4.4.3.2. Simulation de déficit hydrique par les RNAs au pas de temps décadaire

##### IV.4.4.3.2. 1. Modèles neuronaux à deux entrées

**Tableau.IV.26 : Critères de performance de modèles neuronaux pour la simulation de déficit hydrique (à deux entrées), aux pas de temps décadaire.**

Modèles	Apprentissage		Validation	
	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE
RNA <sub>d</sub> (Rojas) :2-4-1	0.728	8,9	0.7579	8,8
RNA <sub>d</sub> (Eldin) :2-4-1	0.5031	10,9	0.3158	13,1
RNA <sub>d</sub> (Katerdji) :2-4-1	0.7247	8,8	0.767	8,5

Ce tableau montre clairement que les critères de performance de ces modèles neuronaux en apprentissage sont médiocres, ensuite ils se détériorent considérablement en validation, on peut donc conclure que les modèles neuronaux à 2 inputs (ET<sub>0</sub>, pluies) au pas de temps décadaires sont déconseillés à utiliser pour modéliser le déficit hydrique.


#### **IV.4.4.3.2. 2. Modèles neuronaux à trois entrées**

**Tableau.IV.27. : critères de performance de modèles neuronaux pour la simulation de déficit hydrique (à trois entrées), aux pas de temps décadaire.**

Modèles	Apprentissage		Validation	
	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE
RNA <sub>d</sub> (Rojas) :3-6-1	0.982	2,2	0.991	1,6
RNA <sub>d</sub> (Eldin) : 3-6-1	0.985	1,8	0.988	1,7
RNA <sub>d</sub> (Katerdji) : 3-6-1	0.987	1,8	0.991	1,7

En examinant les résultats tableau .IV.27.les modèles à 3 inputs simulent le déficit hydrique avec une marge d'erreur assez faible, puisque les critères de performance de ces modèles sont excellents en apprentissage et en validation, donc le fait d'ajouter l'état hydrique du sol comme étant une troisième entrée, améliore considérablement la performance de ces modèles neuronaux.

Afin de bien visualiser ces résultats, nous présentons dans le graphisme suivant décrivant les résultats obtenus par le modèle RNA<sub>d</sub> (Eldin) :3-6-1 durant la période de validation, au pas de temps décadaire.



**Fig.IV.40.** : Comparaison entre les valeurs de déficit hydrique simulées par un réseau de neurones à 3 entrées et celles produites par le modèle D'Eldin et Lhomme au pas de temps décadaire

#### IV.4.4.3.3.Simulation de déficit hydrique par les RNAs au pas de temps mensuel

##### IV.4.4.3.3.1. Modèles neuronaux à deux entrées

Tableau.IV.28. : Critères de performance de modèles neuronaux pour la simulation de déficit hydrique (à deux entrées), aux pas de temps mensuel.

Modèles	Apprentissage		Validation	
	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE
RNA <sub>m</sub> (Rojas) :2-4-1	0.797	22,9	0.666	31,1
RNA <sub>m</sub> (Eldin) :2-4-1	0.600	28,9	0.176	44,9
RNA <sub>m</sub> (Katerdji) :2-4-1	0.764	24,5	0.787	24,3

Comme au pas de temps décadaire, les modèles neuronaux à deux entrées au pas de temps mensuel apportent de mauvais résultats en apprentissage et en validation, donc la qualité de simulation pour ces modèles est médiocre.


##### IV.4.4.3.3.2.Modèles neuronaux à trois entrées

Tableau.IV.29. : critères de performance de modèles neuronaux pour la simulation de déficit hydrique (à trois entrées), aux pas de temps mensuel.

Modèles	Apprentissage		Validation	
	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE
RNA <sub>m</sub> (Rojas) :3-6-1	0.920	14,3	0.935	13,7
RNA <sub>m</sub> (Eldin) : 3-6-1	0.932	11,8	0.914	14,2
RNA <sub>m</sub> (Katerdji) : 3-6-1	0.945	11,8	0.967	9,60

Au pas de temps mensuel, la qualité de simulation de modèles qui font appel à l'état hydrique de sol (3 inputs) est excellente, puisque le R<sup>2</sup> en période de validation oscille entre 0.914 et 0.967 pour les modèles (RNA<sub>m</sub> (Eldin) : 3-6-1) et (RNA<sub>m</sub> (Katerdji) : 3-6-1) respectivement.

Afin de bien visualiser ces résultats, nous présentons dans le graphisme suivant décrivant les résultats obtenus par le modèle RNA<sub>d</sub> (Eldin) :3-6-1 durant la période de validation, au pas de temps mensuel.



**Fig.IV.41.** :Comparaison entre les valeurs de déficit hydrique simulées par un réseau de neurones à 3 entrées et celles produites par le modèle D'Eldin et L'homme au pas de temps mensuel

#### IV.4.4.4. Conclusion

Les réseaux de neurones artificiels constituent une alternative attirante pour simuler le déficit hydrique mais il est nécessaire d'élaborer le meilleur modèle neuronal qui apporte des résultats acceptables. Les modèles neuronaux à 2 entrées (pluie, ET<sub>0</sub>) donnent des résultats médiocres, par contre les modèles neuronaux à 3 entrées (pluie, ET<sub>0</sub>, état hydrique) apportent d'excellents résultats quelque soit le pas de temps considéré. On peut dire que le déficit hydrique dépend largement de l'état hydrique du sol, alors on peut modéliser le déficit hydrique d'alimentation avec exactitude par les RNA en apportant une information sur l'état hydrique du sol à différents pas de temps.

# Conclusion générale

Il est devenu aujourd'hui inévitable de modéliser, que l'on recherche à analyser, comprendre ou prédire des phénomènes affectant le milieu naturel, ces modélisations sont facilitées par la capacité de plus en plus importante des ordinateurs et par le développement des codes numériques de plus en plus sophistiqués.

Inspirés de la neurobiologie, les réseaux de neurones artificiels deviennent aujourd'hui un outil puissant de modélisation dite « par apprentissage », ils servent à résoudre les problèmes non linéaires dont le formalisme est discret, dans plusieurs domaines de recherche, particulièrement en hydrologie.

Ces réseaux sont dotés d'un pouvoir de généralisation (interpolation et extrapolation) non-linéaire et agissent par apprentissage de données et permettent ainsi de simuler les processus de l'évapotranspiration de référence et de déficit hydrique à travers des paramètres appelés poids, constitués dans chaque neurone, et dans chaque couche cachée.

L'avantage principal des modèles neuronaux par rapport aux méthodes classiques est qu'ils n'exigent pas de calage local, puisque le fait d'apprendre « par cœur » les données d'entrées collectées localement (réadaptation des poids de réseau) par le modèle neuronal, cela est considéré comme étant un calage local de ce dernier, en plus de ça s'ajoute les propriétés de généralisation et la parcimonie.

L'approche neuronale s'est développée avec l'expansion de l'utilisation des outils informatiques qui facilitent l'analyse numérique de l'information et la mise en œuvre de cette technique, en particulier avec l'apparition de logiciels d'implémentations neuronales telles que MATLAB, DELPHI.

La modélisation par les réseaux de neurones artificiels a abouti aux conclusions suivantes :

- Concernant les simulations de l'évapotranspiration de référence  $ET_0$  :
- Pour la station de Dar-El-Beida, nous avons montré le potentiel des réseaux de neurones artificiels à simuler l'évapotranspiration de référence à partir des paramètres climatiques classiques à différents pas de temps.
- Les résultats obtenus révèlent que les réseaux de neurones artificiels de type PMC avec une seule couche cachée sont suffisants pour rendre compte à la relation non linéaire existante entre les paramètres climatiques et l'évapotranspiration de référence correspondante.
- Pour les modèles à six entrées, les meilleures structures neuronales choisies sont : **RNA<sub>j</sub> :6-12-1, RNA<sub>d</sub> :6-7-1, RNA<sub>m</sub> :6-6-1** pour les pas de temps journalier, décadaire et mensuel respectivement, mais il faut noter qu'il n'y a pas de règle pour trouver la structure optimale d'où la nécessité de suivre la méthode dite en Anglais « trial and error, step by step, one by one ».
- Les modèles neuronaux alternatifs permettent d'estimer l'évapotranspiration dans le cas où un ou plusieurs paramètres climatiques sont manquants:

- Au pas de temps journalier nous avons conçu et développé le modèle **RNA 7 :5-5-1** (température minimale, maximale et moyenne, vitesse du vent, insolation comme entrées) permettant d'estimer l'évapotranspiration de référence avec un coefficient de détermination de 0.877, dans le cas où les capteurs mesurant l'humidité relative sont manquants au niveau de la station.
- Au pas de temps décadaire nous avons conçu et développé deux modèles neuronaux, l'un est le modèle **RNA d6 :5-12-1**, servant à évaluer l' $ET_0$  si la vitesse du vent n'est pas disponible, l'autre c'est le modèle **RNA d :5-5-1**, permettant d'estimer l' $ET_0$  dans le cas où les valeurs de l'humidité relative sont manquantes.

Au pas de temps mensuel nous avons conçu et développé trois modèles neuronaux, le modèle **RNA m4 (4-11-1)** dont les critères de performance en validation sont de l'ordre de 0.894 et 14,82 mm/mois pour le coefficient de détermination et le root mean square error, on utilise ce modèle si l'humidité relative et la vitesse du vent ne sont pas disponibles, le modèle **RNA m6 (5-21-1)** avec des critères de performance de l'ordre de 0.914 et 15.05 mm/mois pour le coefficient de détermination et le root mean square error respectivement, on fait appel à ce modèle si les valeurs de la vitesse du vent sont absentes, le modèle **RNA m7 (5-12-1)** dont le coefficient de détermination est de 0.907 et le root mean square error est de 15,27mm/mois en phase de validation. On recommande l'utilisation de ce modèle si les valeurs de la durée d'insolation sont manquantes.

Ces résultats révèlent que les meilleures performances sont observées quand on inclut tous les paramètres climatiques affectant l'évapotranspiration en entrée de modèles neuronaux (température minimale, maximale et moyenne, vitesse du vent, insolation et l'humidité relative). Du point de vue pratique on peut utiliser les modèles neuronaux alternatifs cités auparavant pour évaluer l' $ET_0$  dans la région de la Mitidja.

L'application de modèles de réseaux de neurones artificiels dans le domaines de pilotage des irrigations n'est pas vraiment connu par rapport aux équations classiques d' $ET_0$ , cependant ces modèles constituent une alternative intéressante qui doit être prise en compte par les agents qui s'intéressent à la gestion de ressource en eau en agriculture. En cas d'absence de données lysimétriques d' $ET_0$ , les valeurs obtenues par l'application de la formule de Penman-Monteith donnent de bons résultats.

- Concernant les simulations de déficit hydrique d'alimentation :
- Nous avons également montré le potentiel des réseaux de neurones à simuler le déficit hydrique obtenus via trois modèles agrométéorologiques de bilan hydrique à différents pas de temps.
- Les modèles neuronaux qui font appel à l'évapotranspiration de référence et la pluie seulement donnent des résultats médiocres quelque soit la structure neuronale choisie.
- Les modèles neuronaux qui font appel à l'évapotranspiration de référence et la pluie et l'état hydrique du sol (réserve en eau du sol) donnent d'excellents résultats. A partir de là, on peut dire que les RNAs sont capables de réaliser ce qu'on appelle l'analyse de sensibilité de processus (phénomène) vis-à-vis les paramètres explicatifs.

Vu les résultats obtenus, on peut donc dire que la modélisation par réseaux de neurones artificiels est un domaine qui mérite d'être prospecté par les hydrologues, les agronomes etc.

Mais comment arriver à optimiser l'architecture des réseaux de neurones en tenant compte de la complexité du problème à résoudre ? Cette problématique reste encore sans réponse.

### **Perspectives :**

Les techniques de l'intelligence artificielle sont devenues très utilisées pour faciliter la modélisation en plusieurs domaines, particulièrement en hydrologie, l'une de ces techniques est les réseaux de neurones artificiels (RNAs), ils ouvrent une nouvelle ère dans la modélisation des processus hydrologiques.

Le présent travail nous a permis d'ouvrir les perspectives suivantes :

- Si on dispose de données lysimétriques sur l' $ET_0$ , on peut concevoir des modèles neuronaux permettant d'évaluer l'évapotranspiration de référence à partir des paramètres climatiques classiques avec une précision supérieure à celle enregistrée par le biais de la formule de Penman-Monteith modifiée par la FAO56 (Kumar et al., 2002), alors on aura une meilleure estimation des besoins en eau des cultures (une estimation très proche de la réalité, et cela grâce aux capacités de généralisation des RNAs).
- On peut également convertir l'évaporation de bac en évapotranspiration de référence moyennant un modèle neuronal de type PMC en utilisant les paramètres climatiques classiques et les valeurs de l'évaporation de bac en entrée du modèle.
- Habituellement, l'évapotranspiration d'une culture particulière bien alimentée (ETM) en eau est estimée en utilisant l'évapotranspiration d'une culture de référence (gazon de référence ou la luzerne) ( $ET_0$ ) et le coefficient cultural ( $k_c$ ), ce passage de l' $ET_0$  à l'ETM peut engendrer des erreurs en estimation des besoins en eau des cultures (ou des variétés), l'utilisation des modèles neuronaux entraînés avec les données lysimétriques de l'évapotranspiration de la culture concernée (apprentissage) apportent de bon résultats en validation (exploitation) si on utilise les données climatiques comme entrées du modèle, sans faire recours à l' $ET_0$  (Trajkov, 2005).
- Dans le domaine du pilotage des irrigations la température de la surface végétalisée est l'un des indicateurs utilisés pour révéler le début de stress hydrique, cette température de surface est fonction de la température de l'air, l'humidité relative, vitesse du vent et les précipitations, dans la cas où on possède les valeurs de la température de surface (thermomètre infrarouge) et les paramètres climatiques cités (phase d'apprentissage), on peut développer des modèles neuronaux permettant d'estimer la température de la surface à partir des données climatiques classiques (phase d'exploitation) et donc on aura un pilotage des irrigations.
- Si on possède des données mesurées sur l'état hydrique du sol (humidité du sol) et le potentiel matriciel (tensiomètre), on peut concevoir des modèles neuronaux permettant d'évaluer l'humidité du sol à partir des valeurs de potentiel matriciel (conversion de potentiel en humidité du sol).
- Les réseaux de neurones artificiels sont très utilisés en prévisions hydrologiques, économiques (prévision des marchés).

Le champ de l'intelligence artificielle est très vaste, il englobe plusieurs techniques dont on peut citer les réseaux de neurones artificiels, la logique floue, et les algorithmes génétiques,

il nous semble très intéressant d'exploiter ces deux dernières techniques dans le domaine de la gestion des ressources en eau en agriculture.



# Références Bibliographiques

- ALAIN P., ANDREE T., 2005.** Le cycle de l'eau et les activités au sein de l'espace rural. Enjeux globaux, solutions locales et régionales. *C. R. Geoscience* 337 (2005) 39–56.
- ALASSANDRO M., 1997.** Integrating artificial neural networks and empirical correlation for the prediction of water-sub cooled critical heat flux. [Revue Générale de Thermique](#) Vol 36, Issue 11 , pp 799-806.
- Ali R.K., 2008.** Artificial neural network estimation of reference evapotranspiration from pan evaporation in a semi-arid environment. *Irrig Sci* (2008) 27:35-39.
- Ali R.K., 2008.** Comparative study of Hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. *Journal of Irrigation Science*, Vol.26, No.3, pp. 253-259.
- ALLEN R.G., PEREIRA L.S., RAES D. SMITH M. , 1998.** Crop evapotranspiration. Guidelines for computing crop water requirements. FAO irrigation and drainage paper, Rome, Italy, No56, 300p.
- ANDREE T., ALAIN P., 1998.** Les besoins en eau des cultures : analyse et applications, in : J.-R. Tiercelin (Ed.), *Traité d'irrigation*, Lavoisier, Paris, 1998, pp. 147–255, chap. III.
- BACHISIO A ., FABRIZIO B ., MATTEO D., 2000.** Evaluation of neural network techniques for estimating Evapotranspiration. National Research Council – ResearchInstitute for the Monitoring of Agroecosystems (IMAes), via Funtana di Lu Colbu 4/A, 07100 Sassari, Italy.
- BENKACI A T., 2006.** Modélisation pluie-debit mensuelle et journalière par les modèles conceptuels et les systèmes neuro-flous (application aux bassins algériens). Thèse doctorat, INA. EL-Harrach, 242 p.
- BERNARD M., BRUNO L., FLORENT M., 1998.** Généralité sur le bilan hydrique et sa modélisation, in : J.-R. Tiercelin (Ed.), *Traité d'irrigation*, Lavoisier, Paris, 1998, pp. 147–255, chap. III.
- CHOISNEL E., 1985.** Un modèle agrométéorologique opérationnel de bilan hydrique utilisant des données climatiques. In les besoins en eau des cultures, Ed. INRA.
- CHOISNEL E., 1992.** Le calcul de bilan hydrique du sol, options de modélisation et niveaux de complexité. *Science du sol*, 30(1), pp15-30.
- CHOURGHAL N., 2003.** Modélisation agrométéorologique du bilan hydrique par simulation de la pluviométrie et de l'évapotranspiration potentielle de la région d'Alger. Thèse Magister, INA. EL-Harrach, 221p.
- DAVID E., GOLDBERG J., KOZA R., 2006.** Adaptive Learning of Polynomial Networks. *Genetic Programming, Backpropagation and Bayesian Methods*. 328p.
- DEMETRIS K ., 2007.** Discussion of “Generalized regression neural networks for evapotranspiration modelling”. *Hydrological Sciences–Journal*, Vol 51, Issue 6.

- DOORENBOS J., PRUITT W.O., 1998.** Les besoins en eau des cultures, Bulletin de la FAO d'irrigation et de drainage N°24, 196p.
- DREYFUS G., SAMUELIDES M., MARTINEZ J., GORDON M., BADRAN F., THIRIA S., HERAULT L. 2004). Réseaux de neurones - Méthodologies et applications. Editions Eyrolles, 200 p.
- ERIC G., 2000.** Un parcours dans l'étude des phénomènes extrêmes en hydrologie. Mémoire d'habilitation à diriger des recherches, 269p.
- GAVILAN P., LORITE I.J., TORNERO S., BERENGENA J., 2006.** Regional calibration of Hargreaves equation for estimating reference ET in a semiarid environment. *Agric Wat Manage*, [Vol 81, Issue 3](#) , 24, pp 257-281.
- HEDDAM. S., 2006.** Contribution à la modélisation de la qualité des eaux par les réseaux de neurones. Thèse magister, INA. EL-Harrach, 95p.
- HILLEL D., 1980.** L'eau et le sol: Principe et processus physiques, 294p.
- H OWARD D., MARK B., MARTIN H., 2008.** Neural Network Toolbox™ 6 User's Guide (on MATLAB). 907p.
- HUIEN H ., PETER F., 1997.** Estimation of daily soil water evaporation using an artificial neural network. *Journal of Arid Environments* (1997) 37: 251–260.
- IRMAK S. , ALLEN RG., WHITTY EB., 2003.** Daily grass and alfalfa reference evapotranspiration estimates and alfalfa-to-grass evapotranspiration ratios in Florida. *J Irrig Drain Eng* 129(5):360–370.
- JOARDER K ., REZAUL K.B., RUHUL A.S., 2006.** Articial Neural Networks in Finance and Manufacturing. 299p.
- JUAN R., JULIÁN D., 2006.** The artificial neural network in the Real-life applications. 320p.
- KIRKHAM M.B., 2005.** Principles of soil and plantes relations. 512p.
- KISHAN M., CHILUKURI K M ., SANJAY R., 1996.** Elements of Artificial Neural Networks. 337p.
- KUM AR M., RAGHUWANSHI NS., SINGH R., BANDYOPADHYAY M N., 2008.** Comparative study of conventional and artificial neural network-based ETo estimation models. *Irrig Sci*, Vol.26, No.6, pp. 531-544.
- KUMAR M, SANGHUWASHI R SINGH, WALLENDER W W, PRUITT W O., 2002.** Estimating evapotranspiration using artificial neural network. *J Irrg Drain Eng* 128(4):224–233.
- LABORDE J.P., TOUAZI M, BHIRY N., 2004.**Modelling rainfall-discharge at a mean inter-yearly scale in northern Algeria. *Journal of Hydrology* 296 (2004) 179–191.
- LABORDE J.P., 1997.** Atlas de cartes des températures et d'évapotranspirations potentielles de l'Algérie du nord (accompagne d'une notice de 35 pages).
- LABORDE J.P., 2003.** Eléments d'hydrologie de surface. ANRH Editions, 200 p.
- LAHSEN R., 2005 .**Contribution à la modélisation de l'évapotranspiration potentielle par les réseaux de neurones. Mémoire d'ingénieur d'Etat ENP,79p.

- LANDERAS G., AMAIA O B., JOSE J L., 2008.** Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain). *agricultural water management* 95 (2008):553 – 565.
- LOÏC P., CLAUDE D., GILLES V., LAURENT B., ROBERT H., 1998.** Connaissances de base des systèmes : Sol, plante, atmosphère : Relation sol-plante et absorption hydrique, in : J.-R. Tiercelin (Ed.), *Traité d'irrigation*, Lavoisier, Paris, 1998, pp. 45–89, chap. II.
- MARC PARIZEAU., 2004.** Réseaux De Neurones. 124p.
- MARTIN T ET HARGAN H B., 1996. *Neural network design*. 734p.
- LOUDIN L., HERVIEU F, MICHEL C, PERRIN C, ANDRÉASSIAN V, ANCTIL F, LOUMAGNE C., 2006.** Which potential evapotranspiration input for a lumped rainfall–runoff model? *Journal of Hydrology* (2006) 328, 612– 624.
- LOUDIN L., 2004.** Recherche d'un modèle d'évapotranspiration potentielle pertinent comme entrée d'un modèle pluie-débit global. Thèse de Doctorat Cemagref/ ENGREF, 495p.
- ÖZGÜR K., 2006.** Generalized regression neural networks for evapotranspiration modelling. *Hydrological Sciences Journal*, Vol.51, No.6, 2006, pp. 1092-1104.
- ÖZGÜR K., 2006.** Daily pan evaporation modelling using a neuro-fuzzy computing technique. *Journal of Hydrology* (2006) 329, 636– 646.
- PAULIN COULIBALY, FRANÇOIS ANCTIL ET BERNARD BOBEE., 1998.** Préviation hydrologique par réseaux de neurones artificiels : état de l'art. *Can. J. Civ. Eng.* 26: 293–304.
- RAJAI M.E., 2002.** Modélisation cognitive et prédictive du comportement dynamique de l'activité électrique du coeur par approches neuronales. Thèse doctorat, Institut national des sciences appliquées de Lyon, 180p.
- RUELLE P., SPECTY R., DEUMIER J. M. 1995.** L'eau, la plante, le sol et le climat. La conduite de l'irrigation – de la stratégie au pilotage de l'irrigation, RNED-HA, 21-33.
- SEEMA C.R., SHRIVASTAVA K., 2008.** Performance Evaluation of Reference Evapotranspiration Estimation Using Climate Based Methods and Artificial Neural Networks. *Wat Resour Manage.*30(2):175–189.
- SOUAG D., 2007.** Développement d'outils pour la gestion des barrages réservoirs basés sur la simulation et la prévision des paramètres hydrométéorologiques. USTHB-FGC, 215p.
- SUNGWON K., HUNGO S K., 2008.** Neural networks and genetic algorithm approach for nonlinear evaporation and evapotranspiration modelling. *Journal of Hydrology* (2008) 351, 299– 317.
- TRAJKOVIC S., 2005.** Temperature-based approaches for estimating reference evapotranspiration, *Journal of Irrigation and Drainage Engineering*, Vol.131, No.4, 2005, pp. 316-323.
- TRAJKOVIC S., TODOROVIC B., STANKOVIC M., 2003.** Forecasting of reference evapotranspiration by artificial neural networks. *J. Irrig. Drain. Eng.* , Vol.129, No.6, 2003, pp. 454-457.

**UTSET A., FARRE I., MARTINEZ-COB A., CAVERO J ., 2004.** Comparing Penman–Monteith and Priestley–Taylor approaches as reference evapotranspiration inputs for modelling maize water use under Mediterranean conditions. *Agric Water Manage* 66(3):205–219.

**Xi-Bin J ., Er-Si K.,2007.** A mathematical model for simulating water balances in cropped sandy soil with conventional flood irrigation applied. *Journal of Hydrology* (2007) 351, 284– 295.

**YU-MIN W, SEYDOU T, AND TIENFUAN K., 2008.** Neural Network Approach for Estimating Reference Evapotnspiration from Limited Climatic Data in Burkina Faso. WSEAS TRANSACTIONS on COMPUTERS. Volume 7, Issue 6.

# Annexes

## Rayonnement:

### Concepts :

#### Rayonnement extraterrestre (Ra) :

Quantité de rayonnement solaire reçue au sommet de l'atmosphère. Il est fonction de la latitude et de l'époque de l'année. Le rayonnement extraterrestre  $R_a$ , pour chaque jour de l'année et pour différentes latitudes peut être estimé par le constant solaire et la déclinaison du soleil par (Allen RG., 1998) :

$$R_a = \frac{24(60)}{\pi} G_{sc} d_r [\omega_s \sin(\varphi) \sin(\delta) + \cos(\varphi) \cos(\delta) \sin(\omega_s)]$$

Avec :

$R_a$  : Rayonnement extraterrestre ( $\text{MJ.m}^{-2}.\text{jour}^{-1}$ ),

$G_{sc}$  : Constant solaire =  $0.0820 \text{ MJ.m}^{-2}.\text{min}^{-1}$ ,

$d_r$  : l'inverse de la distance relative terre-soleil,

$\omega_s$  : Angle horaire du soleil (rad), (the sunset hour angle),

$\delta$  : Déclinaison solaire (rad),

$\varphi$  : Latitude (rad),

- La latitude exprimée en radian est positive pour l'hémisphère nord, et négative pour l'hémisphère sud. La conversion de degré décimal en radian est donnée par (Allen R.G., 1998) :

$$[\text{Radins}] = \frac{\pi}{180} [\text{degré décimal}]$$

- L'inverse de la distance relative terre-soleil  $d_r$ :

$$d_r = 1 + 0.033 \cos\left(\frac{2\pi}{365} J\right)$$

- La déclinaison solaire  $\delta$  :

$$\delta = 0.409 \sin\left(\frac{2\pi}{365} J - 1.39\right)$$

J est le numéro du jour dans l'année, de 1 pour le 1er janvier à 365 (ou 366) pour le 31 Décembre. Les valeurs de J pour chaque jour de l'année sont données par une équation dans l'annexe n°2 (tab2.5) in FAO56 : Crop evapotranspiration.

➤ L'angle horaire du soleil  $\omega_s$

$$\omega_s = \arccos [-\tan(\phi) \tan(\delta)]$$

Comme la fonction arccos n'est pas disponible dans tous les langages des ordinateurs, the sunset hour angle peut être également calculé en utilisant la fonction arctan :

$$\omega_s = \frac{\pi}{2} - \arctan \left[ \frac{-\tan(\phi) \tan(\delta)}{X^{0.8}} \right]$$

Où :

$$X = 1 - [\tan(\phi)]^2 [\tan(\delta)]^2$$

$$\text{Et } X = 0.00001 \text{ si } X \leq 0$$

Avec :

$\delta$  : La déclinaison solaire

$$\delta = 0.409 \sin \left( \frac{2\pi}{365} J - 1.39 \right)$$

$\phi$  : Latitude (rad)

#### Rayonnement solaire $R_s$ :

Quantité de rayonnement de courte longueur d'onde reçue à la surface de la terre.

$$R_s = (a + b * n / N) * R_a$$

La radiation solaire  $R_s$  a été estimée à partir des données d'insolation par la formule suivante :

Dans laquelle :

$n/N$  : la fraction de l'insolation

$a$  et  $b$  sont deux coefficients obtenus statistiquement dont les valeurs varient selon les zones climatiques. En Algérie du Nord on prend les valeurs de 0.23 et 0.46 respectivement pour  $a$  et  $b$  (Issolah, 1984 in Chourghal, 2003). Donc  $R_s$  s'exprime par :

$$R_s = (0.23 + 0.46 * n / N) * R_a$$

Où  $R_a$  est la radiation solaire extra-terrestre [ $Mj.m^{-2}.j^{-1}$ ],  $n$  la durée d'insolation [ $h.j^{-1}$ ],  $N$  la durée maximale possible d'insolation [ $h.j^{-1}$ ] (Doorenbos et Pruitt, 1997).

· Estimation de la durée astronomique du jour  $N$  :

$$N = \frac{24}{\pi} \omega_s$$

Avec :

$\omega_s$  : Angle horaire du soleil en (rad) ; (the sunset hour angle)

#### **Le rayonnement solaire quand le ciel est clair (Clear-sky radiation) (R<sub>so</sub>) :**

Le rayonnement solaire quand le ciel est clair (R<sub>so</sub>) est employé dans le calcul du rayonnement net (R<sub>n</sub>). Il est défini comme étant la quantité de rayonnement solaire reçue dans la station de mesure en condition de ciel dégagé. (Richard G. Allen., 2004).

Le calcul de R<sub>so</sub>, quand n=N, est nécessaire pour l'estimation du rayonnement de grande longueur d'onde. R<sub>so</sub> est fonction de la latitude et du temps.

Si les valeurs calibrées de (a<sub>S</sub>) et (b<sub>S</sub>) sont disponibles :

$$R_{so} = (a_S + b_S) \cdot R_a$$

Où:

R<sub>so</sub> : le rayonnement solaire quand le ciel est dégagé [MJ.m<sup>-2</sup>.j<sup>-1</sup>]

a<sub>S</sub> + b<sub>S</sub>: la fraction de rayonnement extraterrestre qui atteint la terre quand le ciel est dégagé (n=N).

Si les valeurs calibrées de a<sub>S</sub> et b<sub>S</sub> ne sont pas disponible :

$$R_{so} = (0.75 + 2 \cdot 10^{-5} z) \cdot R_a$$

Avec :

Z : l'élévation de la station (m)

#### **Rayonnement net de courte longueur d'onde (R<sub>ns</sub>) :**

C'est la différence entre le rayonnement de courte longueur d'onde reçu à la surface de la terre et le rayonnement réfléchi par le sol, la surface de la culture ou de l'eau (Doorenbos et Pruitt, 1979). Le rayonnement net de courtes longueurs d'onde s'obtient en corrigeant le rayonnement solaire pour tenir compte de la réflectivité du couvert végétal, soit:

$$R_{ns} = (1 - a) R_S$$

#### **Rayonnement net de grande longueur d'onde (R<sub>nl</sub>):**

Représente la différence entre le rayonnement de grandes longueurs d'onde reçu et réfléchi. Le rayonnement réfléchi est normalement supérieur, il y a donc pertes supplémentaires de rayonnement à la surface de la terre; le rayonnement net de grandes longueurs d'onde constitue donc une perte d'énergie.

$$R_{nl} = \sigma \left[ \frac{T_{\max, k}^4 + T_{\min, k}^4}{2} \right] (0.34 - 0.14 \sqrt{e_s}) \left( 1.35 \frac{R_s}{R_{so}} - 0.35 \right)$$

Dans laquelle :

$R_{nl}$  : Rayonnement net de grande longueur d'onde [ $\text{MJ.m}^{-2}.\text{j}^{-1}$ ] ;

$\sigma$  : Constant de Stefan-Boultzman [ $4.903 \cdot 10^{-9} \text{ MJ.k}^{-4} .\text{m}^{-2}.\text{j}^{-1}$ ] ;

$T_{\max, k}$  : température maximale absolue [ $\text{k} = ^\circ\text{C}+273.16$ ] ;

$T_{\min, k}$  : température minimale absolue [ $\text{k} = ^\circ\text{C}+273.16$ ] ;

$e_s$  : la pression de vapeur réelle [KPa] ;

$R_s$  : rayonnement solaire [ $\text{MJ.m}^{-2}.\text{j}^{-1}$ ] ;

$R_{so}$ : Clear-sky radiation [ $\text{MJ.m}^{-2}.\text{j}^{-1}$ ].

#### Rayonnement net:

Le rayonnement total net représente la différence entre le rayonnements reçus de courte longueur d'onde ( $R_{ns}$ ) et celles perdus de grandes longueur d'onde ( $R_{nl}$ ) (Allen R.G., 1998). Il s'agit du bilan entre l'énergie absorbée et réfléchie au niveau du sol.

$$R_n = R_{ns} - R_{nl}$$

#### Formules de calcul de l'évapotranspiration potentielle :

L'évapotranspiration potentielle :

**Définition** : L'évapotranspiration potentielle (ETP) représente la quantité d'eau théoriquement maximale cédée à l'atmosphère (par transpiration de la plante et évaporation du sol) par une culture en pleine croissance, sur un sol pourvu en eau, (**Jean-Paul.G et al.,1999**). Elle caractérise l'énergie disponible conditionnant le pouvoir évaporant de l'air.

En pratique, l'ETP représente la quantité d'eau théoriquement maximale demandée par le climat et estimée par des formules mathématique dont l'intérêt essentiel est de limiter le nombre de paramètre à utiliser ; elles sont généralement établies à partir de corrélation avec des mesures directes d'ETP.

Le choix de la méthode dépend en premier lieu du type de données climatiques disponibles (**Doorenbos J et Pruitt WO., 1986**)

Formule de JENSEN et HAISE (J/H 1963) :

Elaboré pour les régions arides et semi-arides, et dans la formule est la suivante (**Toumi F., 2001 in Lahsen R., 2005**) :

$$ETP = (0.025 \times t + 0.08) \frac{R_s}{2.45}$$

Avec :

- ETP : Evapotranspiration potentielle en (mm/jour).
- $R_s$  : rayonnement solaire (courte longueur d'onde) en ( $\text{MJ.m}^{-2}.\text{jour}^{-1}$ ) ;
- $R_s = R_a (0.23 + 0.46 n/N)$  (formule de Black);



- Ra: rayonnement extraterrestre en ( $\text{MJ.m}^{-2}.\text{jour}^{-1}$ ).
- t : température moyenne journalière en ( $^{\circ}\text{C}$ ).
- NB :  $1\text{mm/jour} = 2.45 \text{ MJ.m}^{-2}.\text{jour}^{-1}$

#### Formule de Priestley et Taylor (P/T 1972) :

Priestley et Taylor proposent une version plus simplifiée de l'équation combinée de Penman- Monteith pour l'utilisation dans les conditions humides. La partie aérodynamique a été éliminée et la partie énergétique a été multipliée par 1,26, elle s'écrit comme suit (Royce L.F., 1998) :

$$\text{ETP} = 0,408 \alpha \times \left[ \frac{\Delta}{\Delta + \gamma} \right] \times (R_n - G)$$

Dans laquelle :

ETP : évapotranspiration potentielle en mm

$\Delta$  : pente de la courbe de pression de vapeur saturante à la température T ( $\text{kPa}/^{\circ}\text{C}$ ),

$\gamma$  : Constante psychrométrique ( $\text{kPa}/^{\circ}\text{C}$ ),

$R_n$  : rayonnement net à la surface de culture ( $\text{MJ}/\text{m}^2/\text{j}$ ),

G : flux de chaleur échangé avec le sol ( $\text{MJ}/\text{m}^2/\text{j}$ ) ; qui est à l'échelle de journée pratiquement nul, en effet le gain diurne de chaleur par le sol équilibre la perte nocturne.

$\alpha = 1.26$

NB :  $1 \text{ MJ}/\text{m}^2/\text{j} = 0.408 \text{ mm/jour}$

#### Détermination de différents termes de l'équation de Priestley et Taylor :

- $\alpha = 1.26$
- pente de la courbe de pression de vapeur saturante à la température T ( $\Delta$ ) en ( $\text{kPa}/^{\circ}\text{C}$ ) :

$$\Delta = \frac{4098 \left[ 0.6108 \exp\left(\frac{17.27T}{T+237.3}\right) \right]}{(T+237.3)^2}$$

- Constante psychrométrique ( $\gamma$ ) : ( $\text{kPa}/^{\circ}\text{C}$ )

$$\gamma = 0,6605 - 0,826 \cdot 10^{-4} \cdot z$$

Avec :

$z$  altitude du lieu en mètres,  $\gamma$  en millibar par ° Celsius, en fait on prendra  $\gamma \approx \text{Cte} = 0,66$ )

Pour passer de millibar en KPa il faut multiplier par  $10^{-1}$ , alors  $\gamma = 0,066 \text{ KPa}/^\circ\text{C}$ .

On peut également calculer la Constante psychrométrique ( $\gamma$ ) par la formule suivante :

$$\gamma = 0.665 * 10^{-3} * P$$

Avec :

$\gamma$  : Constante psychrométrique en  $\text{KPa}/^\circ\text{C}$ .

$P$  : pression atmosphérique en KPa ;

$$P = 101.3 \left( \frac{293 - 0.0065z}{293} \right)^{5.26}$$

Dans laquelle :

$z$  altitude du lieu en mètres.

**NB** : on prend généralement la valeur de  $\gamma \approx \text{Cte} = 0,066 \text{ KPa}$ .

Flux de chaleur échangé avec le sol ( $G$ ) ( $\text{M J}/\text{m}^2/\text{j}$ ) ; qui est à l'échelle de journée pratiquement nul, en effet le gain diurne de chaleur par le sol équilibre la perte nocturne.

Le rayonnement net ( $\text{M J}/\text{m}^2/\text{j}$ ) ;

**Formules de Hargreaves-Samani (1995) :**

Elle utilise la température et le rayonnement pour estimer  $\text{ET}_0$  ( $\text{mm}/\text{jour}$ ), qui s'écrit :

$$\text{ET}_0 = 0.408 * 0.0023 * (T_{\text{moy}} + 17.8) * \sqrt{(T_{\text{max}} - T_{\text{min}})} * R_A$$

Avec :

$R_A$  : Rayonnement extraterrestre ( $\text{MJ} \cdot \text{m}^{-2} \cdot \text{jour}^{-1}$ ) ;

$T_{\text{max}}$ ,  $T_{\text{min}}$  : c'est la température maximale et la température minimale ( $^\circ\text{C}$ ).

La valeur de  $R_A$  dépend uniquement de la latitude.  $R_A$  peut être exprimé en  $\text{cal} \cdot \text{cm}^{-2} \cdot \text{jour}^{-1}$  ou en  $\text{MJ} \cdot \text{m}^{-2} \cdot \text{jour}^{-1}$  et  $1 \text{cal} \cdot \text{m}^{-2} \cdot \text{jour}^{-1} = 4,1868 \cdot 10^{-2} \text{ MJ} \cdot \text{m}^{-2} \cdot \text{jour}^{-1}$  et  $1 \text{mm} \cdot \text{jour}^{-1} = 2.45 \text{ MJ} \cdot \text{m}^2 \cdot \text{jour}^{-1}$  et  $1 \text{ MJ} \cdot \text{m}^2 \cdot \text{jour}^{-1} = 0.408 \text{ mm} \cdot \text{jour}^{-1}$ . (Hamadi H., Chiraz M-C)

**Pas de temps**: journalier

**Critique** : Quand les données de rayonnement solaire, de l'humidité relative et de vitesse du vent sont manquantes, on doit utiliser la formule de **Hargreaves-Samani (1985)** comme un alternatif pour estimer l' $\text{ET}_0$ . (Allen RG., 1998).

**La méthode de FAO24 rayonnement (24RD) :**

On suggère la méthode du rayonnement pour des régions où les données climatiques disponibles comprennent des mesures de températures de l'air et de l'insolation ou de la nébulosité ou du rayonnement pour prédire l'effet du climat sur les besoins en eau des cultures (**Doorenbos J. et Pruitt WP., 1986**). La forme de l'équation **24RD** donnée par Jansen et al. (1990) est décrite comme suite (Royce LF., 2004):

$$ET_o = a + b \left[ \frac{\Delta}{\Delta + \gamma} R_s \right]$$

Où :

$ET_o$ : Evapotranspiration de référence en mm/j et représente la valeur moyenne de la période considérée (30 ou 10 jours).

$R_s$ : rayonnement solaire. Il est exprimé en évaporation équivalente ou en mm/j.

$\Delta$  : pente de la courbe de pression de vapeur saturante à la température T (KPa/°C),

$\gamma$  : représente la constante psychrométrique (KPa/°C)

a et b : sont des coefficients.

**NB** : On met généralement  $W = \frac{\Delta}{\Delta + \gamma}$  ;

**Avec W** : facteur de pondération qui dépend de la température et de l'altitude

**Détermination de différents termes de la formule 24RD :**

·  $a = -0.3$

·  $b = 1.066 - 0.13 \times 10^{-2} RH_{moy} + 0.045 U_d - 0.20 \times 10^{-3} RH_{moy} U_d - 0.315 \times 10^{-4} RH_{moy}^2$

$0.11 \times 10^{-2} U_d^2$

Dans laquelle :  $U_d$  : la vitesse du vent (m/s),  $RH_{moy}$  : humidité moyenne (%).

- $\Delta$  : pente de la courbe de pression de vapeur saturante à la température T (KPa /°C)

$$\Delta = \frac{4098 \left[ 0.6108 \exp\left(\frac{17.27T}{T+237.3}\right) \right]}{(T+237.3)^2}$$

- Constante psychrométrique ( $\gamma$ ) : (kPa /°C)

$$\gamma = 0,6605 - 0,826 \cdot 10^{-4} \cdot z$$

Avec :

z altitude du lieu en mètres,  $\gamma$  en millibar par ° Celsius, en fait on prendra  $\gamma \approx \text{Cte} = 0,66$ )

Pour passer de millibar en KPa il faut multiplier par  $10^{-1}$ , alors  $\gamma = 0.066 \text{ KPa}/^\circ\text{C}$ .

- Rayonnement solaire en  $\text{MJ}\cdot\text{m}^{-2}\cdot\text{j}^{-1}$  :

$$R_s = (0,23 + 0,46 \cdot n/N) R_a$$

Avec :

n/N: rapport entre le nombre réel d'heure d'insolation et la durée astronomique possible d'insolation, on effectuera sur place des observations concernant le nombre d'heures journalières d'insolation effective par l'héliographe Campbell-Stokes.

$R_a$  : rayonnement extraterrestre en  $\text{MJ}\cdot\text{m}^{-2}\cdot\text{j}^{-1}$  ;

$$R_a = \frac{24(60)}{\pi} G_{sc} d_s [\omega_s \sin(\varphi) \sin(\delta) + \cos(\varphi) \cos(\delta) \sin(\omega_s)]$$

Pour convertir  $R_s$  de  $\text{MJ}\cdot\text{m}^{-2}\cdot\text{j}^{-1}$  en  $\text{mm}\cdot\text{j}^{-1}$ , il faut multiplier par 0,408.

**Pas de temps** : journalier (ETP: Evapotranspiration potentielle en mm/j et représente la valeur moyenne de la période considérée (30 ou 10 jours)).

**Critique :**

Cette méthode est plus fiable que celle de Blaney-Criddle, notamment pour les zones équatoriales, les petites îles et les hautes altitudes. Même si l'on ne dispose pas de mesure du rayonnement, de l'insolation ou d'observation sur la nébulosité, on doit pouvoir trouver les données relatives au rayonnement en consultant les cartes du rayonnement solaire. **(Doorenbos J et Pruitt W.O).**

**Formule de Makkink (Mak1957) :**

L'équation représentée par Makkink a été conçue dans les Pays bas comme une modification de l'équation de Penman en comparant celle-ci avec les données lysimétriques (Allen RG., 2003 in Royce LF., 2004). Elle concerne l'évapotranspiration du gazon ( $ET_0$ ).

$$ET_o = 0.61 \frac{\Delta}{\Delta + \gamma} \cdot \frac{R_s}{2.45} - 0.12$$

Avec :

$ET_o$  : L'évapotranspiration du gazon en (mm/jour).

$R_s$  : rayonnement solaire en  $MJ.m^{-2}$

$\Delta$  : Pente de la courbe de vapeur d'eau saturante au voisinage de la température de l'air en  $KPa^{\circ}C^{-1}$ .

$\gamma$  : Constante psychrométrique en  $KPa^{\circ}C^{-1}$ .

#### Détermination de différents termes de la formule de Makink :

- pente de la courbe de pression de vapeur saturante à la température T ( $\Delta$ ) en ( $kPa/^{\circ}C$ ) :

$$\Delta = \frac{4098 \left[ 0.6108 \exp\left(\frac{17.27T}{T+237.3}\right) \right]}{(T+237.3)^2}$$

- Constante psychrométrique ( $\gamma$ ) : ( $kPa/^{\circ}C$ )

$$\gamma = 0,6605 - 0,826 \cdot 10^{-4} \cdot z$$

Avec :

z altitude du lieu en mètres,  $\gamma$  en millibar par  $^{\circ}$  Celsius, en fait on prendra  $\gamma \approx Cte = 0,66$ )

Pour passer de millibar en KPa il faut multiplier par  $10^{-1}$ , alors  $\gamma = 0.066 KPa/^{\circ}C$ .

- Rayonnement solaire  $R_s$  :

$$R_s = (0.23 + 0.46 \cdot n / N) \cdot R_a$$

Avec :

$R_a$  : rayonnement extraterrestre.

$\frac{n}{N}$  : Le ratio de l'ensoleillement réel sur l'ensoleillement potentiel pour une journée

**Pas de temps** : journalier.

**Criquer** : la formule de Makkink a été conçue dans les climats froids (pays bas), donc leur utilisation dans d'autres climats peut être une source d'erreur dans l'estimation de l'ETP.

#### Estimation de l'ETP par la méthode de Penman (P 1948) :

C'est la formule la plus utilisée, elle est une modélisation de phénomènes énergétiques et climatologiques complexes.

Penman propose d'évaluer l'ETP à partir d'un bilan énergétique simple :

$$ET_0 = \frac{\Delta}{\Delta + \gamma} (R_n - G) + \frac{\Delta}{\Delta + \gamma} E_a$$

Dans laquelle :

ETP : évapotranspiration potentielle en mm/j ;

$\Delta$  : Pente de la courbe de tension de vapeur saturante pour la température de l'air T ;

$\gamma$  : constante psychrométrique ;

Ea : est appelé pouvoir évaporant de l'air et représente la quantité d'eau qui serait évaporée par la surface considérée si elle était saturée et avait la même température que l'air au niveau de référence, il est estimé par la formule suivante :

$$E_a = 0.263 (1 + 0.54.U) (e_s - e_a)$$

U : Vitesse moyenne journalière du vent mesuré à 2 mètres au dessus de la surface évaporante et exprimée en m/s.

**Pas de temps** : journalier.

**Critique** : cette formule exige plusieurs paramètres, mais elle donne de bons résultats.

**Formule de FAO Penman – Monteith (56 PM):**

La formule de Penman-Monteith se distingue parmi les différentes formules par son origine théorique dérivée du bilan de flux énergétique à la surface de couvert végétal, dans un souci de normalisation, la FAO, à travers son groupe d'experts opérants dans différents contextes climatiques, a adapté la formule de Penman-Monteith aux conditions d'un couvert de gazon et propose la formule dérivée comme la nouvelle définition de l'évapotranspiration de référence.

Allen et al (1994) cité in traité d'irrigation (1998) ont défini l'ET<sub>0</sub> comme « l'évapotranspiration d'un couvert végétal "hypothétique" de référence ayant une hauteur de 12 cm, une résistance du couvert de 70 s/m et un albédo de 23%. Un couvert de gazon se développe activement sur une grande étendue régulièrement tondu, bien alimenté en eau et indemne de maladies ».

L'évapotranspiration de référence peut s'écrire selon la formule (Allen et al., 1994 in Ammar Boujelal A., et Bamoune R., 2006) :

$$ET_0 = \frac{0,408\Delta(R_n - G) + \gamma \frac{900}{T + 273} U_2 (e_s - e_a)}{\Delta + \gamma(1 + 0,34 U_2)}$$

Avec :

ET<sub>0</sub> : évapotranspiration de référence journalière (mm/j),

R<sub>n</sub> : rayonnement net à la surface de culture (M J/m<sup>2</sup>/j),

G : flux de chaleur échangé avec le sol (M J/m<sup>2</sup>/j) ; qui est à l'échelle de journée pratiquement nul, en effet le gain diurne de chaleur par le sol équilibre la perte nocturne.

T : température moyenne journalière (°C),

$U_2$  : vitesse moyenne journalière du vent mesuré à 2 mètres (m/s),

$e_s$  et  $e_a$  : respectivement la pression de vapeur saturante et la pression réelle de l'air à la même hauteur (kPa) ;

$\Delta$  : pente de la courbe de pression de vapeur saturante à la température T (kPa /°C),

$\gamma$  : constante psychrométrique (kPa /°C),

900 coefficient pour la culture de référence (kg K/ kJ) liées aux unités utilisées a la distribution de variables  $\rho$ ,  $c_p$  et  $r_a$ ,

0,34 : coefficient de vent pour la culture de référence (kg K/ kJ) résultant du rapports  $r_s / r_a$ ,

0,408 inverse de  $\lambda = 2,45$  MJ/ kg

#### Détermination de différents termes de la formule :

- Constant psychrométrique  $\gamma$  :

$$\gamma = 0,6605 - 0,826 \cdot 10^{-4} \cdot z$$

Avec :

$z$  altitude du lieu en mètres,  $\gamma$  en millibar par ° Celsius, en fait on prendra  $\gamma \approx \text{Cte} = 0,66$ )

Pour passer de millibar en KPa il faut multiplier par  $10^{-1}$ , alors  $\gamma = 0.066 \text{ KPa}/^\circ\text{C}$ .

- Pression de vapeur saturante ( $e_s$ ) et la pression réelle de l'air ( $e_a$ ) à la même hauteur (kPa) :

$$e_s = 6.107 \cdot 10^{\left(\frac{7.5 \cdot t}{233+t}\right)} \quad (e_s \text{ en Millibars, } t \text{ en } ^\circ \text{ Celsius})$$

$$\text{Et } e_a = e_s \cdot \text{HR}/100 \Rightarrow e_a = 0,061 \cdot \text{Hr} \cdot 10^{\left(\frac{7.5 \cdot t}{233+t}\right)} \quad (\text{en Millibars})$$

Pour passer de millibar en KPa, on multiplie par  $10^{-1}$ .

- Pente de la courbe de pression de vapeur saturante à la température T (kPa /°C) :  $\Delta$  :

$$\Delta = \frac{6.149}{T} \exp\left(19.511 \frac{t}{T}\right) \left(\frac{6463}{T} - 3.927\right)$$

( $\Delta$  en millibars par ° Celsius,  $t$  en ° Celsius,  $T$  en ° Kelvin)

Pour passer de millibar en KPa, on multiplie par  $10^{-1}$ .

On peut également déterminer la pente de la courbe de la pression de vapeur saturante  $\Delta$  en [Kpa.°C<sup>-1</sup>] par :

$$\Delta = \frac{4098 \left[ 0.6108 \exp\left(\frac{17.27T}{T+237.3}\right) \right]}{(T+237.3)^2}$$

La radiation solaire  $R_s$  a été estimée à partir des données d'insolation par la formule suivante:

$$R_s = (0.23 + 0.46 * n / N) * R_a$$

Où  $R_a$  est la radiation solaire extra-terrestre [ $Mj.m^{-2}.j^{-1}$ ],  $n$  la durée d'insolation [ $h.j^{-1}$ ],  $N$  la durée maximale possible d'insolation [ $h.j^{-1}$ ]

### III. Comparaison entre les différentes méthodes d'estimation de l'évapotranspiration potentielle :

Plusieurs formules permettent d'évaluer l'ETP à partir de différentes mesures climatologiques. La plus complète et la plus complexe est certainement la formule de Penman basée sur la notion de bilan énergétique. Cependant, le nombre de paramètres utilisés par cette formule (différentes températures, hygrométrie, rayonnement global, albédo, etc.) font que son emploi est rarement possible compte tenu des mesures disponibles (**Laborde J.P., 2004**).

Les experts de la FAO (1992), s'accordent sur le fait que la formule de Penman-Monteith est la meilleure approche et l'équation combinée la plus performante donnant les résultats les plus fiables, lorsque les données climatiques et culturales essentielles sont disponibles. La fiabilité de la formule de Penman-Monteith est devenue de plus en plus étudiée (Amatya et al., 1995 in Chourghal N., 2003). la méthode a été testée dans de larges domaines géographiques et pour différents climats, entre autre les climats méditerranéens. (**Rana et al., 1995 ; Dechmi N et al., 1997 in Chourghal N., 2003**).

Le tableau suivant représente les formules citées et leurs données météorologiques.

**Tableau n° : Données météorologiques exigées pour chaque formule :**

Modèle	Données météorologiques exigées
J/H 1963 P/ T 1972 C/ H1966 24RD 1948 56 PM	Température, Rayonnement solaire ( $R_s$ ), rayonnement extraterrestre ( $R_a$ ) Température, Rayonnement net Température, humidité relative, insolation, rayonnement solaire ( $R_s$ ) Température, humidité relative, rayonnement solaire ( $R_s$ ), vitesse du vent Température, rayonnement solaire ( $R_s$ ) Température, rayonnement extraterrestre ( $R_a$ ), vitesse du vent, humidité Température, rayonnement net ( $R_n$ ), vitesse du vent, humidité

Programme de calcul écrit sous MATLAB :



