

## تقدير التبخر - نتح المرجعي الشهري في منطقة صافيتا باستخدام الشبكة العصبية الصناعية

الدكتور غطفان عمّار\*

الدكتورة بادية حيدر\*\*

(تاريخ الإيداع 13 / 5 / 2013. قُبِلَ للنشر في 11 / 6 / 2013)

### ▽ ملخص ▽

يشكل التبخر-نتح أحد عناصر الدورة الهيدرولوجية، الذي يصعب قياس كمياته الفعلية في الشروط الحقلية، لذلك يجري تقديره انطلاقاً من علاقات تجريبية تعتمد على بيانات عناصر المناخ، وتتضمن تلك التقديرات أخطاء متنوّعة بسبب عمليات التقريب. ويهدف البحث إلى تقدير دقيق لكمية التبخر الشهري في منطقة صافيتا، ويعتمد البحث على تقانة الشبكة العصبية الصناعية، حيث بُني الأنموذج الرياضي باستخدام (nftool) Neural Fitting Tool إحدى أدوات الماتلاب، واعتمد الأنموذج على البيانات الشهرية لدرجة حرارة الهواء والرطوبة النسبية في محطة صافيتا، كما استُخدمت بيانات التبخر الشهري من حوض التبخر الأميركي صنف A لغرض التحقق من صحة أداء الشبكة، بعد تحويل الأنموذج إلى شكل قالب جاهز باستخدام تقانة Simulink المتاحة في حزمة برمجيات الماتلاب. أثبتت نتائج الدراسة أنّ الشبكة العصبية الصناعية متعددة الطبقات، وذات الانتشار العكسي للخطأ تعطي نتائج جيدة في تقويم التبخر الشهري، اعتماداً على مجموعة البيانات المستخدمة.

الكلمات المفتاحية: التبخر - نتح المرجعي، الشبكة العصبية الصناعية، الماتلاب.

\* أستاذ - قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

\*\* مدرسة - قسم الهندسة الإنشائية - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

## Estimation of Monthly Reference Evapotranspiration in Safita Area by using Artificial Neural Network

Dr. Ghatfan Ammar<sup>\*</sup>  
Dr. Badia Haidar<sup>\*\*</sup>

(Received 13 / 5 / 2013. Accepted 11 / 6 / 2013)

### ▽ ABSTRACT ▽

Evapotranspiration forms one of the hydrology cycle elements that it's hard to measure its actual amounts in the field conditions, so it's estimated by calculations of experimental relations that depend on climatic elements data. These estimations include different errors because of approximation processes. The research goals to accurate estimation of the monthly reference evapotranspiration amount in Safita area (on the east coast of the Mediterranean Sea), and the research depends on the technique of Artificial Neural Network (ANN), and the mathematical model was built by the (nftool), which is one of the Matlab tools, depending on monthly air temperature and relative humidity data which were taken from Safita meteorological station, and the data of monthly pan evaporation (Class A pan) has been used, after modifying its results, for the purpose of checking the performance accuracy of the network, by using Simulink technique, which is existing in Matlab Programs Package. The results of the research verify that a multi-layer ANN of error Back-propagation algorithm gives a good result in estimating monthly reference Evapo-transpiration for the used data group.

**Key words:** Reference Evapo-transpiration, Artificial Neural Network, Matlab

---

<sup>\*</sup> Professor, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

<sup>\*\*</sup> Assistant Professor, Department of Structural Engineering, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

**مقدمة:**

إنَّ استمرار زيادة النمو السكاني في العالم يستدعي تحقيق استغلال أمثل للموارد المائية المتاحة لمواجهة المتطلبات المتزايدة على الغذاء، فضلاً عن التحديات التي تفرضها محدودية هذه الموارد، فدراسة الموارد المائية في سورية هي إحدى العوامل الرئيسية المحددة لانتساع الرقعة الزراعية، وتُعدُّ من الأمور الملحة في الوقت الراهن لغرض تحقيق التوازن المطلوب بين النمو السكاني المتصاعد والأمن الغذائي الذي يُعدُّ هدفاً استراتيجياً لجميع شعوب العالم. تُشكِّل عملية التبخّر - نتح إحدى المركبات الأساسية للدورة الهيدرولوجية في الطبيعة، وعلى هذا الأساس فقد اجتذبت دراسة هذه العملية اهتمام الكثير من الباحثين، لاسيما في المناطق التي تعاني من شح في الموارد المائية، حيث استُخدمت طرائق مباشرة وغير مباشرة لمحاولة تقدير كميات المياه المفقودة بهذه الفعالية [1].

إذ يُعرّف التبخّر - نتح المرجعي بأنه أقصى كمية من البخار يمكن أن تتطلق من مساحة معينة من الأرض إلى الجو تحت تأثير العوامل الجوية الخاصة بتلك المنطقة تحديداً، وقد استنتج Doorenbos et al. بأنه يمكن اعتماد قيم التبخّر المقيسة من أحواض التبخّر على أنها تمثل التبخّر - نتح المرجعي بعد ضربها بقيمة معامل الحوض [3]، إذ تعتمد قيمة الأخير على نوعية الحوض وموضعه والمساحة المحيطة به [4].

كما عرّف التقرير الصادر عن منظمة الأغذية والزراعة الدولية التابعة للأمم المتحدة (FAO) التبخّر - نتح المرجعي، بأنه معدل التبخّر - نتح من سطح تربة مزروعة بغطاء نباتي أخضر مزدهر النمو وبارتفاع (8-15) سم وذو مورد مائي غير محدود. وقدّمت المنظمة مفهوم التبخّر - نتح المرجعي لدراسة التبخّر من السطوح المزروعة بشكل مستقل عن نوع المحصول ومستوى نموه والشروط البيئية والإدارية المحيطة [5]. وقد أقرت هذه المنظمة أربع طرائق لحساب التبخّر - نتح المرجعي وهي: طريقة بلاني - كريدل؛ طريقة الإشعاع؛ طريقة بنمان المعدلة وطريقة التبخّر من أحواض التبخّر.

وقد حاول العديد من الباحثين تقويم التبخّر في مناطق مختلفة من العالم باستخدام العديد من الطرائق غير المباشرة. فعلى سبيل المثال، تمكّن الباحثان Dogan and Demir من تقدير التبخّر في بحيرة Sapanca في تركيا باستخدام الشبكة العصبية الصناعية (Neural NetworkArtificial)، وطريقة الخوارزمية الجينية (AlgorithmGenetic)، فتوصلا إلى أن GA تعطي نتائج أكثر دقة من ANN في تقدير التبخّر في هذه المنطقة [6]. كما أجري تقويم للتبخّر في إيران من قبل Eslamian et al. باستخدام الشبكة العصبية الصناعية و (Support Vector Machines)، حيث وجدَ أن (SVM) تعطي نتائج أكثر دقة من (ANN) في تقويم التبخّر في منطقة أصفهان في إيران [7].

كما استخدم Deswal et al. ANN في نمذجة التبخّر من حوض AnandSagar في Shegaon بإدخال كل من درجة حرارة الهواء وسرعة الرياح وساعات السطوع الشمسي والرطوبة النسبية، وتمت مقارنة هذه الطريقة مع طريقة الانحسار الخطي، فوجدَ أنه يمكن استخدام ANN في التنبؤ بفوائد التبخّر من الأحواض كبديل لطريقة الانحسار الخطي [8].

وفي دراسة قام بها Abedi-Koupai et al. في إيران لتقويم التبخّر - نتح المرجعي من البيت الزجاجي، أُجريت مقارنة بين ANN وكل من موديل Penman-Monteith و Fynn, Penman مع القياسات الفعلية للتبخّر - نتح المرجعي المقيسة بوساطة جهاز Lysimeter، أظهرت النتائج أن الشبكة العصبونية هي الأكثر دقة في تقويم التبخّر - نتح المرجعي اليومي مقارنةً مع الطرائق الأخرى [9].

كما قامت افتخار عبد الجواد بتشكيل نموذج لشبكة عصبية صناعية لتقدير التبخر - نتح المرجعي اليومي في منطقة الموصل بالاعتماد على كل من درجة الحرارة والإشعاع الشمسي وسرعة الرياح والرطوبة النسبية. إذ هدف هذا البحث بالإضافة لتشكيل النموذج إلى فحص نتائج الشبكة في حال فقدان بعض من المتغيرات الداخلة ومقارنتها مع حالة إدخال جميع المتغيرات. حيث أظهرت النتائج إمكانية استخدام هذه التقنية لتقويم التبخر - نتح المرجعي، كما توصلت إلى أن أداء الشبكة يزداد دقةً عندما تترافق درجة الحرارة مع سرعة الرياح والسطوع الشمسي في حين يكون للرطوبة النسبية تأثير محدود ولا سيما عندما تترافق مع درجة الحرارة [1].

وأجرى et alMoghaddamnia, A.. تقويماً للتبخر في منطقة Zabol في إيران، وذلك باستخدام ANN والنظام الضبابي العصبي التكيفي، كما أُجريت مقارنة بين نتائج الطريقتين السابقتين، ونتائج تقويم التبخر باستخدام الصيغ التجريبية. فأظهرت النتائج أن كل من ANN والنظام الضبابي العصبي التكيفي يعطي نتائج أفضل من الصيغ التجريبية في تقويم التبخر [10].

كما قامت ميس عليان بتشكيل نموذج لشبكة عصبية صناعية للتنبؤ بالتبخر - نتح المرجعي الشهري في منطقة طرطوس بالاعتماد على كل من درجة الحرارة الجافة والرطوبة النسبية، حيث أظهرت النتائج أن الشبكة العصبونية هي الأكثر دقة في التنبؤ بالتبخر - نتح المرجعي الشهري مقارنةً مع طريقة ايفانوف [2].

### أهمية البحث وأهدافه:

يُعدُّ التبخر - نتح عنصر أساسي من عناصر الموازنة المائية لأية منطقة، وتحديد دقته، باستخدام تقانة متطورة لوضع عناصر الموازنة بموثوقية عالية يمكن الاعتماد عليه لتخطيط الموارد المائية. لذلك فإن هدف هذه الدراسة هو بناء أنموذج رياضي لتقدير التبخر - نتح المرجعي الشهري باستخدام الشبكة العصبية الصناعية اعتماداً على عدد محدد من البارامترات الجوية، التي يمكن قياسها بدقة وثقة كبيرتين وبسهولة، وهي درجة الحرارة الجافة والرطوبة النسبية للهواء.

### موقع منطقة البحث:

تُشكّل منطقة الدراسة جزءاً من الساحل السوري حيث تبعد عن خط الشاطئ حوالي 30 كم (الشكل 1). جُمعت البيانات من محطة صافيتا المناخية الواقعة على ارتفاع 350 متر عن مستوى سطح البحر.

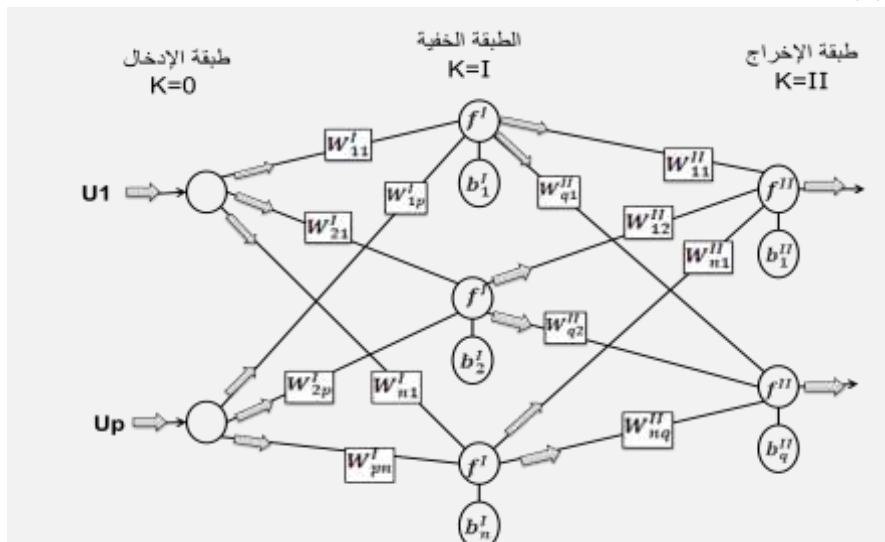
### طرائق البحث ومواده:

تعتمد هذه الدراسة على إنشاء أنموذج رياضي للشبكة العصبية الصناعية، التي تعرّف بأنها عبارة عن نظام لمعالجة البيانات بشكل يحاكي ويشابه الطريقة التي تقوم بها الشبكات العصبية عند الإنسان. حيث تتشابه الشبكة العصبية الصناعية مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب، وتخزن هذه المعرفة باستخدام قوى وصل داخل العصبونات تسمى الأوزان التشابكية. ويمكن تدريب الشبكة على إنجاز وظائف معينة من خلال ضبط قيم الأوزان التشابكية بين العناصر.



الشكل (1): خارطة الموقع العام لمنطقة البحث

تتكون الشبكات العصبية ذات التغذية الأمامية من نظام من الخلايا العصبية، التي تم ترتيبها في طبقات، حيث تتكون هذه الشبكات من طبقة على الأقل من الطبقات الخفية Hidden Layer فضلاً عن طبقة الإدخال وطبقة الإخراج، إذ يرتبط كل عصبون في كل طبقة مع كل عصبون في الطبقة التالية بوزن معين  $w$  الذي يتم ضبطه في أثناء التدريب الشكل (2).



الشكل (2): بنوية الشبكة العصبية الصناعية

يُقصد بالتغذية الأمامية للشبكات انتشار البيانات الداخلة إلى الشبكة باتجاه الأمام دائماً من طبقة الإدخال باتجاه طبقة الإخراج، ومن الأمثلة على هذا النوع من الشبكات، الشبكة العصبية ذات الانتشار العكسي للخطأ Artificial Neural Network of Error Back Propagation، المستخدمة في هذه الدراسة. ويسمى هذا النوع من الشبكات شبكات الانتشار العكسي للخطأ؛ لأن المخرجات الحقيقية للشبكة تُقارن مع المخرجات المأمولة (الهدف)، كما أن الفرق في قيمهما يدعى بالخطأ، إذ تقوم الشبكة بنشر هذا الخطأ من طبقة المخرجات مروراً بالطبقة (الطبقات) الخفية باتجاه طبقة المدخلات؛ أي بآلية معكوسة لما يحدث في مرحلة احتساب المخرجات [7].

وفيما يأتي شرح لآلية عمل الشبكات العصبية ذات الانتشار العكسي للخطأ [11].

أولاً- مرحلة التغذية الأمامية:

حيث يرتبط الخرج  $Y_i^{K-1}$  للخلية العصبية (i) في الطبقة (k-1) لشبكة التغذية الأمامية مع الدخل من الخلية العصبية z في الطبقة اللاحقة k بواسطة عامل تحميل حقيقي  $(W_{ji}^k)$ .

حيث: k: دليل الطبقة (k=I, II)

i: دليل الخلية في الطبقة (K-1).

z: دليل الخلية في الطبقة (K).

لحساب الخرج  $Y_j^k$  فإن الخلية العصبية z للطبقة k [k=I, II] ينجز العملية الحسابية الآتية:

$$Y_j^k = f^k \left[ \sum_{i=1}^N (W_{ji}^k Y_i^{k-1}) + b_j \right] \quad (1)$$

$$Y_j^0 = u_j$$

$$Y_j = Y_j^{II}$$

حيث:

N : عدد الخلايا أو الوحدات في الطبقة k-1.

$f^k$ : دالة التحويل (Transfer Function).

يعد شعاع الانحياز ( $b_j$ ) bias بمنزلة الحد الثابت في معادلات كثيرات الحدود الذي يساعد في حل تلك المعادلات بصورة أسهل وأسرع.

هناك عدة أنواع من دوال التفعيل  $f^k$  ذات وظائف مختلفة، وكل واحدة منها تصلح لنوع معين من التطبيقات

اعتماداً على المدى المحدد لها. وفيما يأتي سرد لبعض منها بما فيها تلك التي تم استخدامها في البحث الحالي:

(a) دالة التحويل سيغمويد اللوغاريتمية Log-Sigmoid Transfer Function: تقوم هذه الدالة بمعالجة القيم بمدى يتراوح بين (0) و(1) بشكل انسيابي، مما يوفر توزيعاً ملائماً لهذه القيم، ويعبر عن هذه الدالة بالمعادلة:

$$a = f_{(n)} = \frac{1}{1 + e^{(-n)}} \quad (2)$$

(b) دالة التحويل سيغمويد لظل الزاوية Tan-Sigmoid Transfer Function: تتميز هذه الدالة بأن

القيم الخارجة عنها تكون بمدى يتراوح بين (1) و(-1)، ويعبر عنها بالمعادلة:

$$f_{(Net)} = \frac{2}{1 - e^{(-Net)}} - 1 \quad (3)$$

(c) دالة التحويل الخطية (Linear Transfer Function): تقع قيم المخرجات بين (0) و (1) ولذلك تدعى بدالة التحفيز الثنائي، ويعبر عنها بالمعادلة:

$$f_{(Net)} = x \text{ for all } x \leq 1 \quad (4)$$

ثانياً- مرحلة الانتشار العكسي للخطأ: حيث يتم احتساب الخطأ في وحدة المخرجات، ومعدل مربع الخطأ (MSE) ومعامل تصحيح الخطأ ( $\delta$ ) وفقاً للمعادلتين الآتيتين:

$$MSE = err = \frac{1}{2 \cdot q} \sum_{i=1}^{i=q} (y_i - a_2)^2 \quad (5)$$

$$\delta = - \frac{\partial err}{\partial a_{(2)}} \quad (6)$$

حيث:

err: معدل مربع الخطأ في وحدة المخرجات؛ Y : المخرجات المأمولة Target؛  $\delta$ : معامل تصحيح الخطأ.

ثالثاً- مرحلة تحديث الأوزان : حيث يتم تحديث الأوزان وعامل الانحياز كما هو معطى أدناه:

$$W_{(New)} = W_{(old)} + \Delta W \quad (7)$$

$$b_{(New)} = b_{(old)} + \Delta b \quad (8)$$

حيث:  $\Delta W$ : معامل تصحيح الوزن؛  $\Delta b$ : معامل تصحيح عامل الانحياز

وهناك طريقتان مختلفتان لعملية تحديث أوزان الشبكة العصبية الصناعية، وذلك بافتراض أن مدخلات الشبكة تكون على شكل مصفوفة رياضية مكونة من صفوف وأعمدة، وكل صف من هذه الصفوف يمثل متجهاً يحتوي على جميع المتغيرات المراد إدخالها إلى الشبكة، وهاتان الطريقتان هما:

1. طريقة تجزئة المدخلات Increment Model: يتم في هذه الطريقة إدخال المصفوفة صفافاً صفافاً، ومن ثم تُحدث الأوزان لتلك الصفوف تباعاً، لذلك تمتاز هذه الطريقة بحاجتها إلى ذاكرة محدودة.
2. طريقة الدفعة الواحدة للمدخلات Batch Model: تتضمن هذه الطريقة إدخال المصفوفة كاملةً ودفعةً واحدةً، حيث تحدث الأوزان لمرة واحدة وفقاً لذلك، وتمتاز هذه الطريقة بسرعة تنفيذها، غير أنها تحتاج إلى ذاكرة أكبر من الطريقة السابقة.

إنّ عملية تحديث الأوزان يمكن أن تعاد آلاف المرات في التطبيقات القياسية، ويتوقف التدريب عادةً عند الوصول إلى مستوى مقبول للخطأ، أو عند الوصول إلى عدد المكررات المحددة مسبقاً من المدرب.

بُنيت الشبكة العصبية الصناعية في هذه الدراسة بالاعتماد على برنامج MATLAB والأدوات الملحقة به nftool Box نظراً لكفاءته العالية في هذا المضمار. ولغرض الحصول على أفضل هيكلية للشبكة العصبية الصناعية يجب تحديد عدد عصبونات الطبقة الخفية، وبناء طبقات المدخلات والمخرجات والطبقات الخفية.

إنّ النشرات المتعلقة بالشبكات العصبية الصناعية تشير إلى عدم وجود أسلوب قياسي في تحديد عدد الطبقات الخفية أو عدد عصبونات، وإنما يجري اختيار هذا العدد حسب رؤية من يبني الأنموذج. ومما تجدر الإشارة إليه، أنه عند بناء الشبكة العصبية الصناعية يُحدد نوع دالة التفعيل المستخدمة في كل وحدة، علماً أنه ليس من الضروري امتلاك جميع الوحدات لدالة التفعيل نفسها. لكن مكتبة nftool Box تحوي طبقة خفية واحدة ودالة التحويل السيمغودية في الطبقة الخفية والدالة الخطية في طبقة الإخراج.

- كما يعتمد تدريب شبكات الانتشار العكسي للخطأ بشكل عام على مجموعة خوارزميات نذكر منها الآتي [12]:
- i. خوارزمية ((Variable Learning Rate (GDA,GDX)): وهي خوارزمية تعلم متغير لشبكة الانتشار العكسي للخطأ التي تُعد من أسرع طرائق تدريب الشبكات العصبية.
  - ii. خوارزمية ((Resilient BackPropagation(RP)): وهي خوارزمية تدريب بسيطة تحتاج إلى ذاكرة خزن قليلة، وتتميز هذه الخوارزمية بالسرعة الفائقة في عملية الاقتراب من الهدف.
  - iii. خوارزمية ((Conjugate Gradient (CG)Fletcher–Powell)): وهي خوارزمية تدريب تستلزم متطلبات خزن صغيرة من الذاكرة.
  - iv. خوارزمية ((Scaled Conjugate Gradient (SCG)): وهي خوارزمية تدريب جيدة للأغراض العامة.
  - v. خوارزمية ((Levenberg Marquardt(LM)): وهي خوارزمية تدريب سريعة لشبكة ذات حجم قابل للتحديث وذات ذاكرة مختزلة، ويمكن الإفادة منها في التدريبات التي تتطلب بيانات ضخمة.
- تستخدم مكتبة NN-Ftool Box خوارزمية ((Levenberg Marquardt (LM) لتدريب الشبكة المشكلة. ولغرض التحقق من الأداء الأفضل للشبكة تُستخدم معايير مختلفة مثل معدل مربع الخطأ (MSE) ومعامل الارتباط المستخدمين في هذه الدراسة.

## النتائج والمناقشة:

### 1- إدخال البيانات وبناء الشبكة العصبية الصناعية

بغرض الحصول على أفضل هيكلية للشبكة العصبية الصناعية، أُدخلت البيانات المتوفرة (1965-1996) على شكل مصفوفة مكونة من صفين يمثلان درجة حرارة الهواء والرطوبة النسبية و383 عموداً، كما أُدخلت بيانات المخرجات لمجموعة التدريب على شكل مصفوفة مكونة من صف واحد يتضمن قيم التبخر الشهري المقاسة و383 عموداً. ثم قُسمت هذه البيانات عشوائياً من خلال مكتبة nftool المتاحة في حزمة برمجيات الماتلاب إلى ثلاث مجموعات هي: مجموعة التدريب ومجموعة التحقق ومجموعة الاختبار، وذلك بنسبة 70% لمجموعة التدريب و15% لمجموعتي التحقق والاختبار. ومن ثم شكّلت شبكة عصبية صناعية تتضمن طبقة مدخلات مكونة من عصبونين يمثلان درجة حرارة الهواء والرطوبة النسبية، وطبقة مخرجات مكونة من عصبون واحد يمثل التبخر الشهري، في حين حُدّد عدد العصبونات في الطبقة الخفية بالتجريب، وذلك بتغيير عدد عصبونات الطبقة الخفية وتدريب الشبكة لغاية الحصول على أقل معدل مربع خطأ معياري لدورات تكرارية ثابتة العدد Epochs مقدارها (1000).

### 2- تدريب الشبكة العصبية الصناعية المقترحة


إنّ الهدف من تدريب الشبكة هو تغيير أوزانها للحصول على الإخراج المأمول للمدخلات المعطاة. إذ يجري في أثناء عملية التدريب احتساب قيم المخرجات ومقارنتها مع قيم المخرجات المأمولة في كل خطوة، فيما يتم انتشار الخطأ عكسياً طبقة بعد طبقة ابتداءً من طبقة المخرجات باتجاه طبقة المدخلات، بحيث تُحدّث الأوزان لجميع الطبقات في اللحظة نفسها بعد تقديم كل مدخلات التدريب المعطاة، وذلك باعتماد طريقة الدفعة الواحدة وبأسلوب تقانة الانتشار العكسي. ولتحقيق هدف عملية التدريب للشبكة العصبية الصناعية المقترحة، لابد من الوصول إلى حالة من التوازن بين قابليتها على الاستجابة الصحيحة لبيانات المدخلات المستخدمة في عملية التدريب التي يجري تخزينها في الشبكة



لعملية التذكير، وبين قابليتها على إعطاء استجابة جيدة لمدخلات مشابهة، لكنها غير مطابقة لتلك المدخلات المستخدمة في عملية التدريب (عملية التنبؤ). لذلك تم الاعتماد على طريقة التوقف المبكر، بغية التوصل إلى صفة التعميم الكفاء، وذلك بتقسيم البيانات إلى ثلاث مجموعات كما ذكر سابقاً.

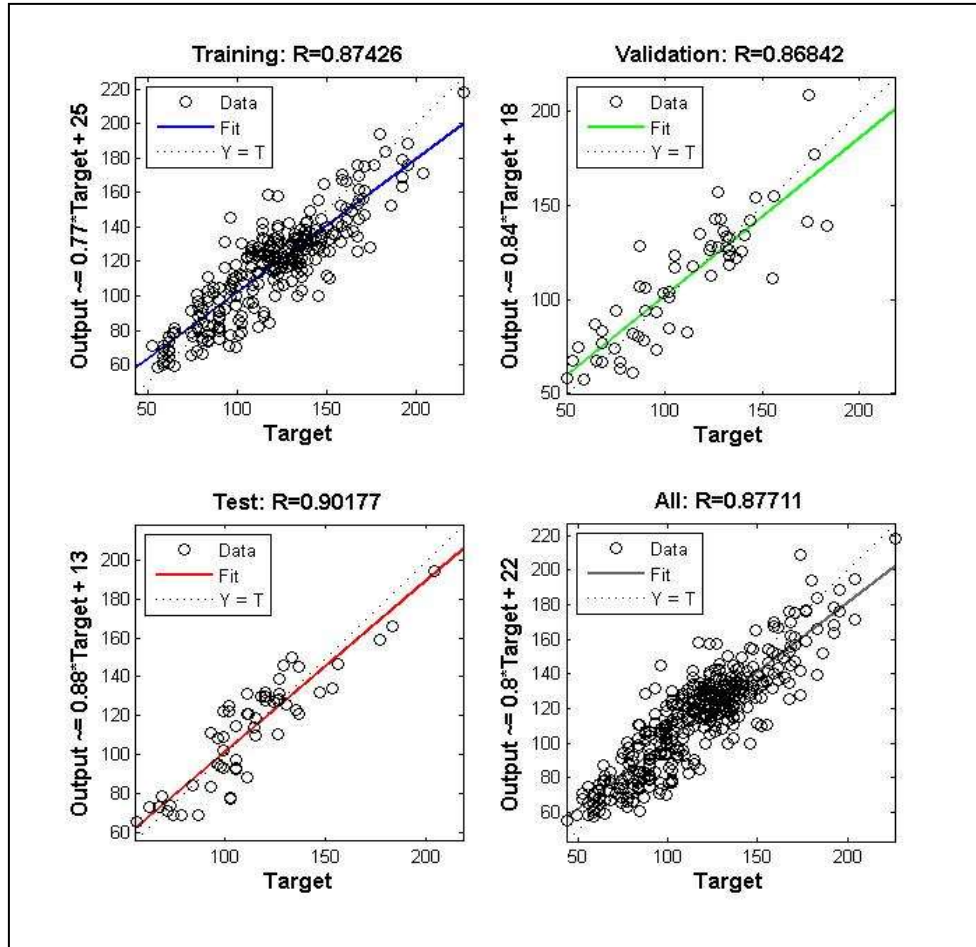
وبعد إجراء عدد كبير من التجارب تم التوصل إلى أن الشبكة العصبية الصناعية ذات الهيكلية (1-5-2) تعطي أقل قيمة لمتوسط الخطأ ويساوي (2.3 mm) لمجموعة التدريب و(2.5 mm) لمجموعة التحقق و(-0.07 mm) لمجموعة الاختبار، مع استخدام دالة التفعيل Transfer Function Logsigmoid في الطبقة الخفية تُتبع بدالة تفعيل Linear Transfer Function في طبقة الإخراج وبالاعتماد على خوارزمية التعلم (LM) Levenberg (Marquardt).

يبين الشكل (6) أداء الشبكة العصبية الصناعية للمجموعات الثلاث، حيث يوضح نقطة توقف التدريب لدورات تكرارية أقل عدداً من الدورات التكرارية في حال الاعتماد على مجموعة التدريب فقط بمتوسط خطأ يساوي إلى 2.5 mm) لمجموعة التحقق.



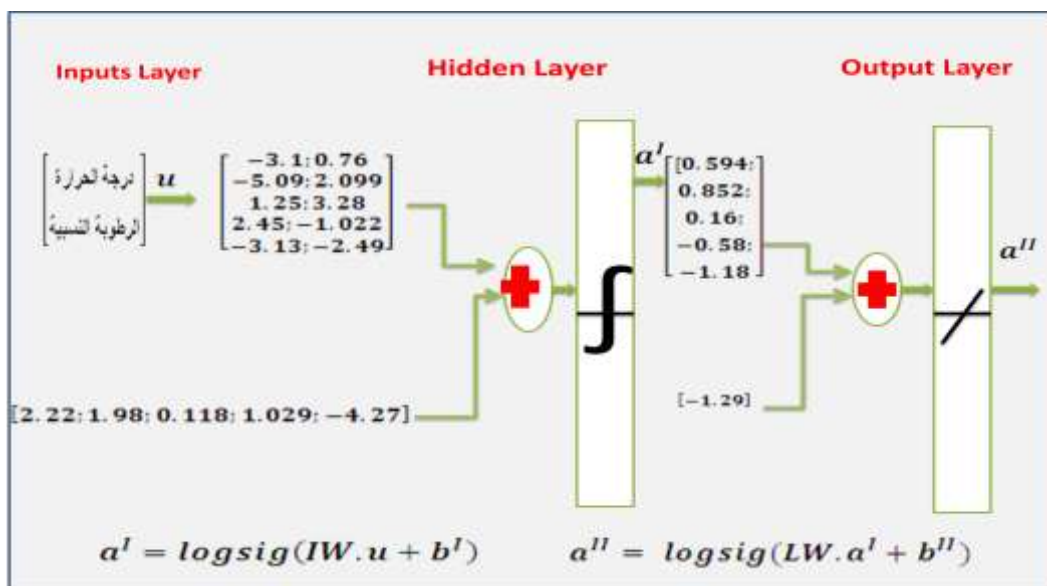
الشكل (6): يبين أداء الشبكة العصبية الصناعية للمجموعات الثلاث

كما كانت معاملات الارتباط للمجموعات الثلاث هي: 0.87 لمجموعة التدريب و 0.86 لمجموعة التحقق و 0.907 لمجموعة الاختبار كما هو موضح في الشكل (7).



الشكل (7): معاملات الارتباط للمجموعات الثلاث (التدريب - التحقق - الاختبار)

بعد إنهاء تدريب الشبكة على بيانات المدخلات والأهداف المأمولة تم التوصل إلى الأوزان النهائية الآتية:

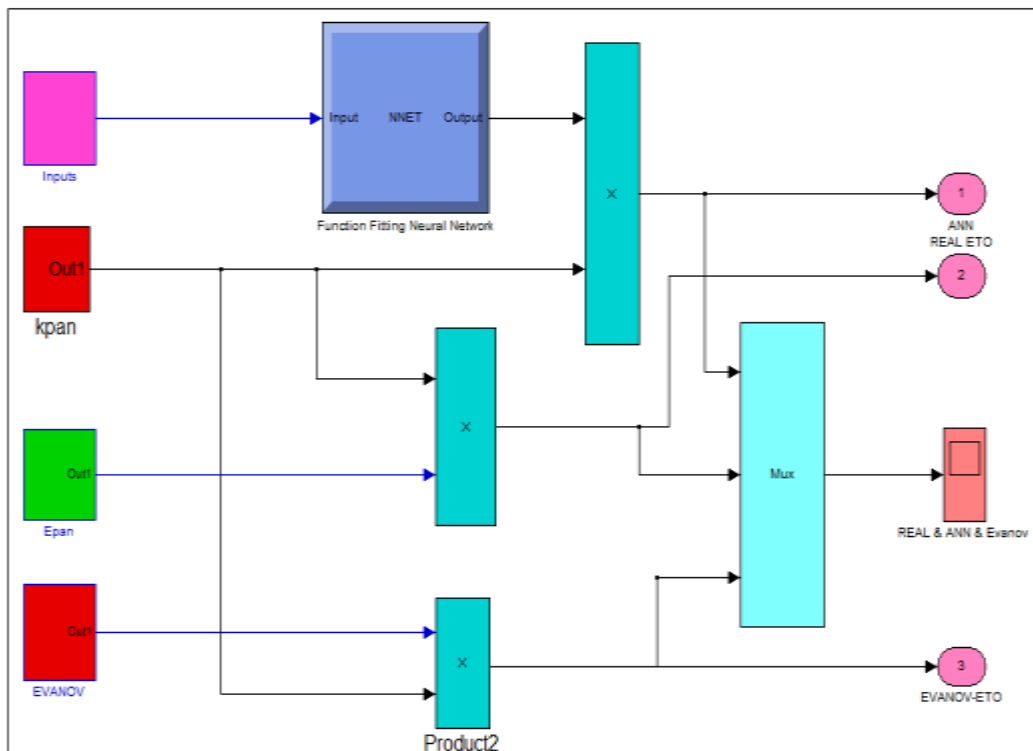


الشكل (8): الشبكة العصبيّة الصنعيّة الناتجة من التدريب على بيانات البحث

### 3- تقويم أداء الشبكة العصبية الصناعية المقترحة

يعدُّ فحص أداء أي نموذج رياضي مقترح من التطبيقات الاعتيادية والتقليدية في عملية النمذجة الرياضية، حيث يُفَيِّمُ حسنُ الأداء باستخدام الأساليب الإحصائية المعروفة، كاحتساب قيمة معامل الارتباط (R). ولغرض الاستفادة من التقانات الحديثة في إظهار المقارنة على شكل مرسمات، اقترح بناء نموذج المحاكاة بالاستفادة من تقانة SIMULINK المتاحة في حزمة برمجيات MATLAB، حيث اختُصِرَ نموذج المقارنة بوضع الشبكة العصبية الصناعية على شكل قالب جاهز بسيط BLOCK، يحتوي على جميع مفردات الشبكة المقترحة في حزمة قوالب ثانوية يمكن إظهارها بسهولة، فيما تم إضافة نموذج إيفانوف كقالب بسيط آخر إضافة إلى البيانات المقيسة للتبخر كقالب ثالث. حيث أُجريت عملية المحاكاة بشكل متزامن وذلك باعتبار المتغيرين الآتيين (درجة الحرارة والرطوبة النسبية)، وبهذا يمكن مراقبة عملية المحاكاة من خلال قوالب الإظهار Display التي يمكن إضافتها إلى أي جزء من أجزاء النموذج. ولابد من التنكير أنَّ المدخلات الخاصة بالشبكة العصبية الصناعية المقترحة سينتج منها مخرجات متعلقة بفعالية التبخر فقط، وهذا يتطلب ضرب المخرجات بمعامل الحوض (Kpan)؛ لأنَّ الهدف النهائي هو تقدير التبخر - نتج المرجعي الذي ستجرى عليه آلية المقارنة.

يبين الشكل (9) كيفية تركيب وبناء نموذج المحاكاة باستخدام تقانة Simulink حيث يظهر النموذج آلية ضرب معامل الحوض بكلِّ من قيم التبخر المقدَّر، وقيم التبخر المقيسة وقيم التبخر المحسوبة بوساطة معادلة إيفانوف، حيث تُجمَعُ النتائج في قالب يسمى Mux، وبذلك يمكن ربطها بمرسم واحد.




الشكل (9): تركيب وبناء نموذج المحاكاة باستخدام تقانة Simulink

## 4- الأنظمة الثانوية لأنموذج المحاكاة

## • قالب الشبكة العصبية الصناعية

يبين الشكل (10) النظام الثانوي لقالب الشبكة العصبية الصناعية، حيث يظهر ربط المدخلات بالطبقة الخفية ومن ثم طبقة الخرج.



الشكل (10): قالب الشبكة العصبية الصناعية

## • قالب معامل الحوض Kpan

وضعت آلية لاحتساب معامل الحوض Kpan، الذي يُعبّر عنه بالمعادلة الآتية:

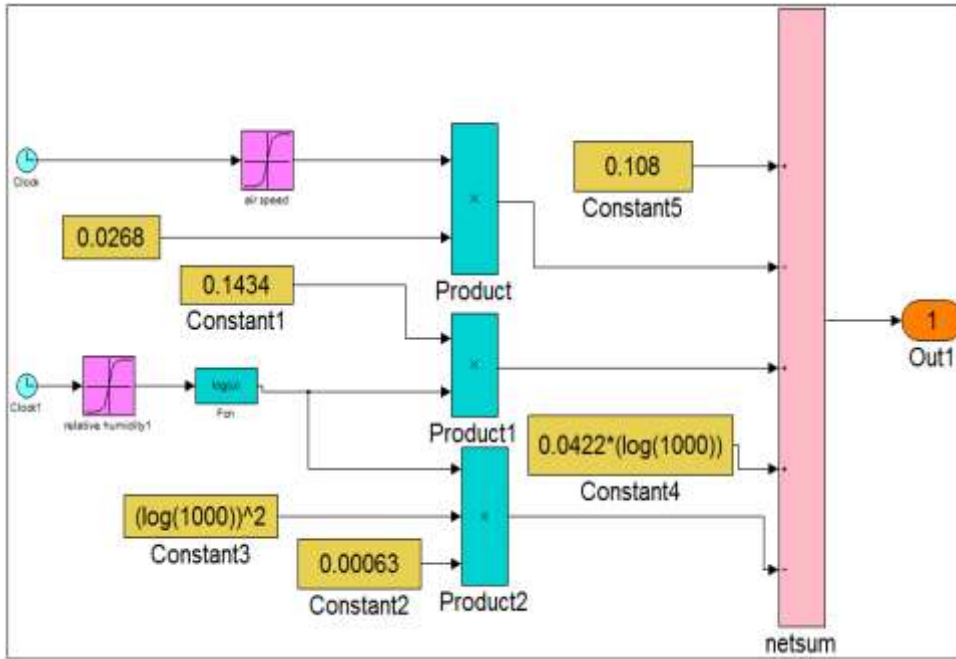
$$Kpan = 0.108 - 0.0268 (U) + 0.0422 \cdot (\ln(1000)) + 0.1434 \cdot (\ln(RH_{mean})) - 0.00063 (\ln(1000))^2 \cdot \ln(RH_{mean}) \quad (9)$$

حيث:

U: سرعة الرياح الشهرية المتوسطة م/ثانية.

RHmean: الرطوبة النسبية المتوسطة %.

وبيّن الشكل (11) آلية الاحتساب باستخدام تقانة Simulink، التي يمكن ربطها إلى أنموذج المحاكاة الرئيس بسهولة. إذ يبين القالب (U) السلسلة الزمنية الخاصة بسرعة الرياح والمرتبطة بالعداد Clock الذي يسيطر على عملية المحاكاة الرئيسة. كما يبين الشكل القالب الخاص بمتغير الرطوبة النسبية RHmean الذي يحتوي السلسلة الزمنية الخاصة بهذا المتغير.



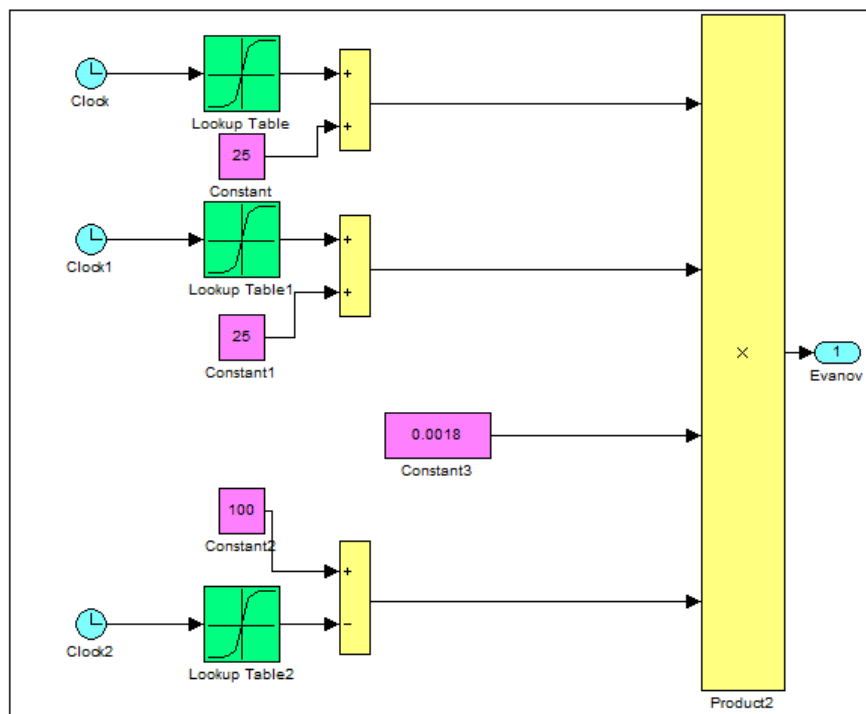
الشكل (11) قالب معامل الحوض

• قالب معادلة إيفانوف

يبين الشكل(12) قالب معادلة إيفانوف المستخدمة لحساب التبخر،التي تعطى بالشكل الآتي:

$$E = 0.0018 (T + 25)^2 (100 - Rh) \quad (10)$$

حيث: T: درجة الحرارة  $^{\circ}C$ . E : التبخر في الشهر (mm).

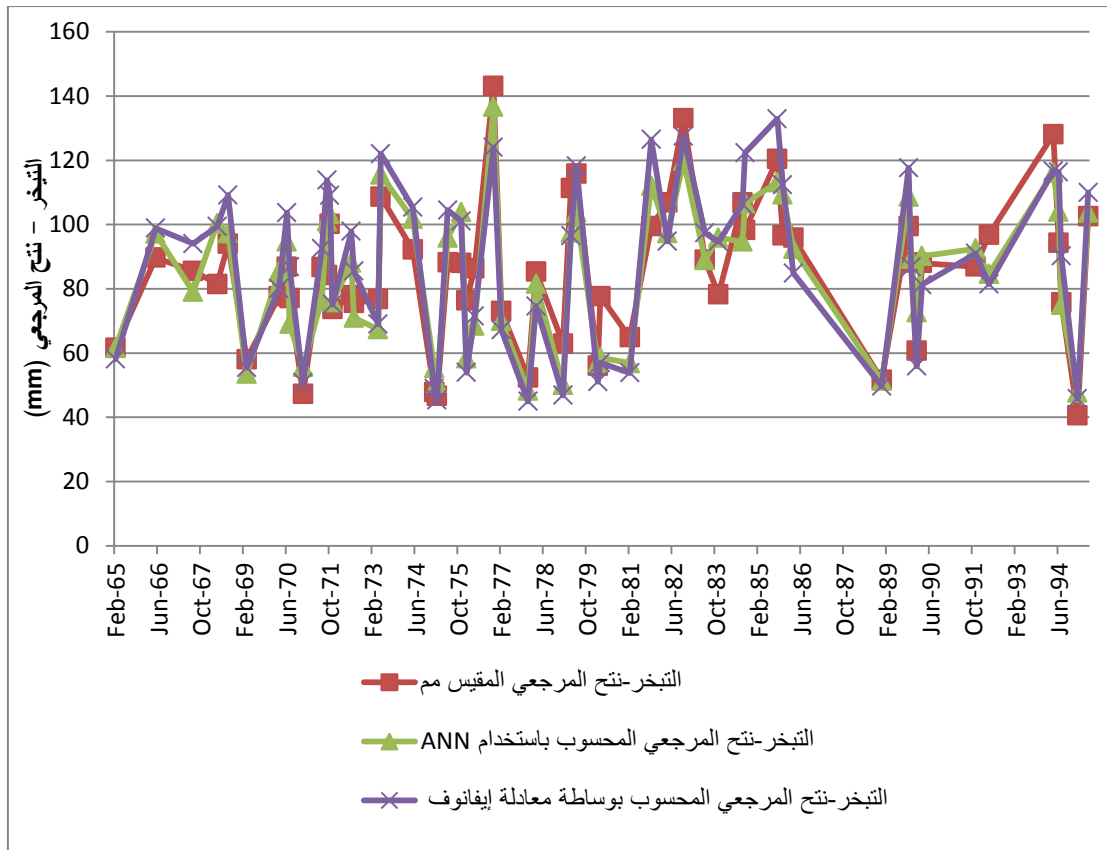


الشكل(12) قالب معادلة إيفانوف


## 5- نتائج أنموذج المحاكاة

بموازنة قيم التبخر-نتح المرجعي الشهري لمنطقة صافيتا لمجموعة الاختبار العشوائية التي اختارها البرنامج بشكل عشوائي والمقيسة بوساطة حوض التبخر الأميركي صنف A والمحسوبة بطرائق الشبكة العصبية الصناعية، مع قيم التبخر - نتح المحسوبة بمعادلة إيفانوف، نلاحظ أنّ قيم الخطأ بين نتائج معادلة إيفانوف، وقيم التبخر- نتح المرجعي المقيسة أكبر بالمقارنة مع الأخطاء في نتائج الشبكة العصبية الصناعية، إذ يصل متوسط الخطأ للأولى إلى (-0.07) مم في حين يكون هذا الخطأ مساوياً ل (-2.79) مم بالنسبة لمعادلة إيفانوف وذلك من أجل ذات المجموعة.


كما يبين الشكل (13) التوافق الأدائي بين الطرائق الثلاث، حيث يلاحظ التوافق الخطي بين التبخر- نتح المرجعي الشهري بطريقة التبخر من حوض التبخر ETpan، والتبخر- نتح المرجعي بطريقة الشبكة العصبية الصناعية لمجموعة الاختبار بمعامل ارتباط قدره 0.901 كما هو موضح في الشكل (14). في حين يبين الشكل (15) التوافق الخطي بين التبخر- نتح المرجعي الشهري بطريقة التبخر من حوض التبخر ETpan، والتبخر- نتح المرجعي بطريقة إيفانوف لنفس المجموعة بمعامل ارتباط قدره 0.86.



الشكل(13): قيم التبخر الشهري لمنطقة صافيتا لبيانات مجموعة الاختبار المحسوبة بطرائق الشبكة العصبية الصناعية والتبخر من حوض التبخر ومعادلة إيفانوف



الشكل(14): التوافق الخطي بين التبخر-نتح المرجعي الشهري بطريقة التبخر والتبخر-نتح المرجعي الشهري بطريقة الشبكة الصناعية لبيانات مجموعة الاختبار



الشكل(15): التوافق الخطي بين التبخر-نتح المرجعي الشهري بطريقة التبخر والتبخر-نتح المرجعي الشهري بطريقة إيفانوف لبيانات مجموعة الاختبار

**الاستنتاجات والتوصيات:**

- ✓ يمكن استخدام الشبكات العصبية الصناعية متعددة الطبقات وذات الانتشار العكسي للخطأ في تقدير التبخر - نتح المرجعي الشهري في منطقة صافيتا بمتوسط خطأ يساوي إلى  $2.3 \text{ mm}$ .
- ✓ يوجد توافق خطي بين مخرجات الشبكة العصبية الصناعية وبيانات التبخر المقيسة بوساطة حوض التبخر بعد ضربها بقيم معامل الحوض، بمعامل ارتباط مقداره (0.9)، مما يبيّن إمكانية استخدام هذه التقنية في تقدير التبخر - نتح المرجعي الشهري في منطقة صافيتا.
- ✓ بمقارنة طريقتي الشبكة العصبية الصناعية وطريقة إيفانوف يتبين أن الشبكة العصبية الصناعية تعطي نتائج أكثر دقة من معادلة إيفانوف في تقدير التبخر - نتح المرجعي.
- ✓ إنّ استخدام تقانة Simulink في بناء أنموذج المقارنة يتميّز بفائدة هندسية كبيرة من حيث السرعة والكفاءة العالية في بناء النماذج.
- واعتماداً على نتائج البحث يمكن وضع التوصيات الآتية:
- ✓ إجراء قياسات حقلية للتبخر - نتح الحقيقي باستخدام مقاييس التسرب (Lysimeter) لتوفير بيانات حقلية، يمكن الاعتماد عليها في تطوير نماذج الشبكات العصبية لتقدير التبخر - نتح الحقيقي.
- ✓ توسيع بناء شبكة عصبية صناعية لتقدير التبخر - نتح المرجعي بافتراض أسلوب التدريب دون إشراف.
- ✓ التوسع في استخدام الشبكات العصبية لدراسة مسائل متنوعة تتعلق بالموارد المائية في سورية.



## المراجع:

1. عبد الجواد، افتخار؛ العاني، عبد الحميد. *أتمودج شبكة عصبية اصطناعية لتقدير التبخر نتح المرجعي اليومي لمنطقة الموصل*. رسالة دكتوراه، 2007، بإشراف أ. د. عبد الستار يونس الدباغ، أ. د. كامل علي عبد المحسن الجبوري. جامعة الموصل.
2. عليان، ميس. *أتمودج شبكة عصبية صناعية للتنبؤ بالتبخر نتح المرجعي الشهري في منطقة طرطوس*. رسالة ماجستير، 2012، بإشراف أ. د. غطفان عمار، أ. د. علي الأسعد. جامعة تشرين، اللاذقية، سورية.
3. DOORENBOS, J.; PRUITT, W.O. *GuideLines for Predicting Crop Water Requirement*. Food and Agriculture Organization of the United Nations (FAO). N°. 24, 1977, 156.
4. RAGHUWANSHI, N.S.; WALLENDER, W.W. *Converting from pan Evaporation to Evapotranspiration*. Journal of Irrigation and Drainage Engineering. Vol. 124, 1998, 275-277.
5. FAO Corporate Document Repository. *Crop Evapotranspiration*. Natural Resources Management and environment Department, 2008.
6. DOGAN, E.; DEMIR, S.A. *Evaporation Amount Calculation of Sapanca Lake by using Genetic Algorithm Neural Networks*. Sakarya University Turkey, May. 2006, 1239-1250. <<<http://www.google.com/search?hl=ar&lr=&q=estimating+evaporation+usingartificial+neural+network&start=20&sa=N>>>
7. GOHARI, S.A.; ESLAMIAN, S.S.; MALEKIAN, R.; BIABANAKI, M. *Estimation of Monthly Pan Evaporation Using Artificial Neural Networks and Support Vector Machines*. Journal of Applied Sciences Iran. Vol. 8, N°. 19, 2008, 3497-3502.
8. DESWAL, S.; PAL, M. *Artificial Neural Network based Modeling of Evaporation Losses in Reservoir*. World Academy of Science Shegaon, vol. 29, May. 2008, 279-283. <<<http://www.waset.org/pwaset/v29/v29-51.pdf>>>
9. ABEDI-KOUPAI, J.; AMIRI, M.J.; ESLAMIAN, S.S. *Comparison of Artificial Neural Network and Physically Based Models for Estimating of Reference Evapotranspiration in Greenhouse*. Australian Journal of Basic and Applied Sciences Iran, Vol. 3, N°. 3, 2009, 2528-2535.
10. MOGHADDAMNIA, A. et, al. *Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques*. ScienceDirect U. S. A. Vol. 32, 2009, 88-97.
11. TAYLOR, J.G. *Neural Network and Their Applications*. John Wiley and Sons England, 1996.
12. DEMUTH, H.; BEALE, M. *Neural Network Toolbox*, U. S. A, 2002, 840.