

استخدام شبكة تكمي متجه التعلم في تقدير التبخر الإنائي

م. د. د. افتخار عبد الجواد العاني

تقنيات الموارد المائية

المعهد التقني

أ.م.د. كامل علي عبد المحسن

قسم هندسة الموارد المائية

جامعة الموصل

الخلاصة

اقترح البحث أسلوب جديد لدراسة فعالية التبخر التي تعتبر واحده من المركبات المهمة التي تشكل الدورة الهيدرولوجية للمياه في الطبيعة، إذ تضمن تخمين عمق التبخر الإنائي بالاعتماد على أربعة عوامل مناخية وهي درجة الحرارة، الرطوبة النسبية، السطوع الشمسي، وسرعة الرياح.

تم تبني شبكة عصبية اصطناعية (unsupervised) ومن النوع Linear Vector Quantization (LVQ) والتي لا تحتاج إلى إشراف مباشر خاصة في المراحل الأولية من تهيئة الشبكة للعمل كما هو الحال في نظيراتها من الشبكات التقليدية والتي شاع استخدامها مؤخراً. لقد أتمد أسلوب منهجي مبسط لغرض احتساب مخرجات الشبكة وذلك لمحاولة ردم الهوة الحاصلة بين تردد المستخدم في الاستفادة من الإمكانيات العالية لهذه الشبكات والتعقيد النسبي في آلية الاحتساب التي عادة ما تترافق مع هذا النوع من الشبكات العصبية الاصطناعية. بينت النتائج إمكانية تخمين عمق التبخر الإنائي وذلك بالاستفادة من هذه التقنية غير التقليدية في النمذجة خاصة عندما يتعلق الأمر بموضوعة الشبكات العصبية والتي عادة ما تحتاج إلى إشراف متواصل طوال فترة تدريبها، فقد أوضحت نتائج البحث توافقاً خطياً جيداً بين مخرجات الشبكة المقترحة والقيم المرصودة لعمق التبخر الإنائي وبمعامل ارتباط قدره (0.986).

Using Of Learning Vector Quantization Network for Pan Evaporation Estimation

Abstract

A modern technique is presented to study the evaporation process which is considered as an important component of the hydrological cycle. The Pan Evaporation depth is estimated depending upon four metrological factors viz. (temperature, relative humidity, sunshine, and wind speed). Unsupervised Artificial Neural Network has been proposed to accomplish the study goal, specifically, a type called Linear Vector Quantization, (LVQ). A step by step method is used to cope with difficulties that usually associated with computation procedures inherent in these kind of networks. Such systematic approach may close the gap between the hesitation of the user to make use of the capabilities of these type of neural networks and the relative complexity involving the computations procedures. The results reveal the possibility of using LVQ for of Pan Evaporation depth estimation where a good agreement has been noticed between the outputs of the proposed network and the observed values of the Pan Evaporation depth with a correlation coefficient of 0.986.

Key words :Evaporation, Neural network

المقدمة

الشبكة عند تغير الظروف المحيطة بالفعالية حيث تسمي مخرجات هذه الشبكة ذات طابع يختلف نسبياً عن مخرجاتها أبان فترة التدريب.

يهتم البحث الحالي بتبني نوع آخر مهم من أنواع الشبكات العصبية لم يسبق تحري إمكاناته في مجال الموارد المائية (على حد علم كاتب البحث) وهي من نوع الشبكات العصبية التي لا تحتاج إلى إشراف خاصة في المراحل الأولية من تهيئة الشبكة للعمل كما هو الحال في نظيرتها شبكة التغذية الأمامية. ويأمل الباحثان بفتح نافذة للاستفادة من هذه التقنية في معالجة بعض المشاكل التي يواجهها المهندس المختص.

تم تحري ودراسة إمكانية شبكة تكمي متجه التعلم (Learning Vector Quantization Neural Network - LVQNN) حيث إن بنية هذا النوع من الشبكات يتكون بشكل رئيسي من طبقتين، الأولى تنافسية والتي اقترحت من قبل Kohonen عام 1988^[6] والثانية خطية، والشكل (1) يوضح شبكة تكمي متجه التعلم المقترحة.

إن آلية عمل شبكة LVQ المقترحة تتلخص بقيام الطبقة التنافسية بتصنيف متجهات الإدخال وذلك بتبني أسلوب (Kohonen) ، والذي ينتج عنه فوز احد وحدات الشبكة ذات الوزن الأقرب لمتجه المدخلات لكي يتم تحديثه حسب الصيغة التالية:

الوزن الجديد للشبكة = الوزن القديم + مد * (متجه الإدخال - الوزن القديم)

إذ أن:

مد: معدل التدريب

إن الوحدة الفائزة ستعطي مخرجاتها على شكل الرقم (1) بينما تخسر بقية الوحدات المنافسة وتعطي مخرجاتها على شكل الرقم (0)، ومن هنا جاء اسم الطبقة والتي تدعى بالطبقة التنافسية. إن قرب وبعد وزن وحدة معينة عن قيم متجه المدخلات يتم بإيجاد

تعتبر فعالية التبخر واحدة من المركبات الرئيسية للدورة الهيدرولوجية للمياه في الطبيعة، وبناء على ذلك فقد اجتذبت دراستها اهتمام الكثير من الباحثين لاسيما في المناطق التي تشح فيها الموارد المائية مما يتطلب الأمر الحفاظ على هذه الثروة الحيوية، ولغرض التعرف بشكل تفصيلي على ميكانيكية هذه الفعالية والقوانين الفيزيائية التي تتحكم بها وأهم الطرق المتبعة لتقدير كمياتها يمكن الرجوع إلى [2،1] وغيرهم من الباحثين.

لقد اكتسبت تقنيات الشبكات العصبية الاصطناعية زخماً متصاعداً من ناحية اتساع استخداماتها وذلك لإمكاناتها في حل الكثير من المشاكل الهندسية والتي استعصى حلها بطرق النمذجة التقليدية. بيد أن المتبع لاستخدام هذه التقنيات سرعان ما يكتشف اقتصر تطبيقاتها على نوع واحد تقريباً من أنواع الشبكات العصبية وهي شبكات التغذية الأمامية (Feed Forward Networks) والتي من مميزات أن الخطأ الناتج والمتمثل (بمجموع مربع الفروقات) بين ما هو مرصود فعلياً وما هو محسوب من قبل الشبكة ينتشر انتشاراً ارتجاعياً عبر الشبكة (Back Propagation) لتتم معالجته بتوزيعه على وحدات الشبكة جميعاً وجعله أقل ما يمكن. لقد أُولى هذا النوع من الشبكات اهتماماً واسعاً وسُلط عليه الضوء في كثير من التطبيقات التي تخص أنظمة الموارد المائية [3،4،5] غير إن من أهم مميزات شبكات التغذية الأمامية هو وجوب معرفتها معرفة تامة بفضاء العينة للبيانات المتوفرة عن الفعالية المراد دراستها، إذ تتعلم الشبكة من خلال التدريب وبذلك تقتصر إمكاناتها على ما تعلمته خلال هذه المرحلة فقط ، في حين لا تتوفر لها القدرة على التميز التام عند تعرضها لمدخلات لم يسبق أن تدربت عليها أي وجود ضعف في عملية تكيف

لغرض توضيح آلية عمل الشبكة المقترحة في هذا البحث تم سرد تفاصيل للحسابات التي تقوم بها الشبكة لأجل إعطاء القارئ فكرة واضحة عن كيفية عملها وتسلسل خطواتها. لقد تم انتخاب قيم معدل التبخر الانائي الشهري لمنطقة الموصل لمدة عام وهو العام 2004 لتصنيفها كهدف للشبكة، فيما تم استخدام المعدل الشهري للمتغيرات المناخية (نسبة الرطوبة، و درجة الحرارة، والسطوح الشمسي، وسرعة الرياح) كمدخلات لشبكة LVQ المقترحة. كما تم تمثيل مدخلات الشبكة بمصفوفة (عدد الأشهر × عدد المتغيرات) أما مصفوفة الهدف فتضم (عدد الأشهر × عدد الأصناف).

إن تحديد عدد الأصناف التي تضمها مصفوفة الهدف وعدد وحدات التنافس في الشبكة تم اختيارها بعد محاولات عديدة اعتماداً على أداء الشبكة المعياري والمتمثل بمعدل مربع الخطأ (MSE) وقد استخدمت خمسة عشر وحدة تنافسية وثلاثة أصناف للهدف. الشكل (3) أدناه يبين أداء هذه الشبكة، ومما يبدو من الشكل فإن أداءها يعتبر شبه نموذجي (يلاحظ أن قيمة MSE قد انخفضت من 0.45 إلى الصفر خلال 41 مكرر) فيما لا يتسع المجال لإظهار بقية المحاولات في اختيار عدد الوحدات التنافسية أو عدد أصناف الهدف. إن آلية عمل شبكة تكمي متجه التعلم (LVQ) تتم وفق الخطوات المنهجية الملخصة وكما يلي:

شبكة الانتظام الذاتي SOM (لغرض التصنيف)

- 1- إيجاد أدنى مسافة اقليديسية باستخدام المعادلة (1).
- 2- بين قيم معدل التبخر الانائي الشهري (P_{SOM}) وقيم أوزان متجهات التصنيف (IW_{SOM})
- 3- المصفوفة الناتجة من الخطوة أعلاه هي مصفوفة الهدف (Y_{SOM}) (عدد الأصناف × عدد الأشهر) بالنظام الثنائي والموضحة أدناه:

قيمة المسافة الاقليديسية بين المتجهين في الطبقة التنافسية ومن ثم يتم اختيار الوحدة الفائزة التي تمتلك اقل مسافة وكما في العلاقة التالية:

$$d = \sqrt{\sum_{allinput} (P - IW)^2} \quad \text{--- (1)}$$

إذ أن:

d : قيمة المسافة الاقليديسية

P : قيم متجهة المدخلات

IW : قيم أوزان المدخلات

تصنيف الهدف Target Classification

إن من متطلبات شبكة (LVQ) هو أن يتم تصنيف مجموعة البيانات التي تعبر عن المخرجات المرصودة للفعالية المراد دراستها (التبخر الانائي في هذه الحالة) والتي غالباً ما تدعى (بالهدف). ولغرض إتمام عملية التصنيف فإن هنالك بعض الطرق الإحصائية التي يمكن استخدامها مثل (Histogram, k-mean, Clustering) وغيرها، وما دنا بصدد موضوعة الشبكات العصبية فقد وقع الاختيار على شبكة الانتظام الذاتي (Self Organizing Map) لغرض إتمام عملية التصنيف. إن آلية عمل شبكة (SOM) يشابه عمل الطبقة التنافسية في شبكة (LVQ) المنوه عنها أعلاه، ما عدا أنها تأخذ بانتظامية متجه المدخلات بنظر الاعتبار (أي الوحدات المجاورة للوحدة الرابحة مضافاً إليها الانتظام الذي تتخذه عناصر متجه المدخلات) والشكل (2) يوضح بنية شبكة (SOM) 46 وباختصار فإن عملية تحديث الأوزان ترتب بشكل يعزز قدرة الشبكة على التخلص من ظاهرة الوحدات الميتة (الوحدات التي غالباً ما تخسر المنافسة) [7]. أضف إلى ذلك، فإن شبكة الانتظام الذاتي تتميز بكون قيم أوزان وحداتها تمثل قيم أصناف الهدف.

آلية عمل شبكة LVQ مع نموذج الحسابات

$$P_{sow} = [1.1742 \ 1.75 \ 2.72 \ 4.49 \ 6.82 \ 9.98 \ 10.77 \ 9.95 \ 7.68 \ 4.84 \ 2.01 \ 1.419]$$

$$IW_{sow} = [8.4249 \ 5.292 \ 2.5868]$$

$$Y_{sow} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 \end{bmatrix}$$

أما مصفوفة حسابات المسافات الاقليدية (d) فتمثل:

$$d = \begin{bmatrix} 7.25 & 6.67 & 5.7 & 3.93 & 1.6 & 1.55^* & 2.34^* & 1.52^* & .74^* & 3.58 & 6.41 & 7 \\ 4.11 & 3.54 & 2.57 & .80^* & 1.52^* & 4.68 & 5.47 & 4.65 & 2.38 & .45^* & 3.28 & 3.87 \\ 1.41^* & .83^* & .13^* & 1.90 & 4.23 & 7.39 & 8.18 & 7.36 & 5.09 & 2.25 & .57^* & 1.16^* \end{bmatrix}$$

* = أقل مسافة وتمثل الصنف الفائز

الموضحة في المصفوفة (P_{LVQ}) والمخرجات المتضمنة مصفوفة الهدف (Y_{SOM}) المصنفة في الخطوات السابقة. وبذلك تكون الشبكة جاهزة لعملية التدريب. انظر الشكل (3) رجاءً. كما تبين المصفوفة (IW_{LVQ}) الأوزان النهائية للطبقة التنافسية لشبكة LVQ أما المصفوفة (LW_{LVQ}) فتمثل أوزان الطبقة الخطية للشبكة. إن توقف عملية

التدريب تتم حين الحصول على أقل فرق معياري (MSE) بين الهدف ومخرجات الشبكة. حيث يبين الشكل (3) الخاص بأداء الشبكة انخفاض قيمة معدل مربع الخطأ عن قيمته الأصلية (0.45) إلى الصفر بعدد تكررات مقدارها 41 مكرر.

4- ومن مصفوفة الهدف (Y_{SOM}) يمكن احتساب نسب وقوع عناصر الهدف في الصنف المعين، فعلى سبيل المثال فإن أربعة قيم من متجهة المدخلات تقع في الصنف الأول (وحدات فائزة تتمثل بالرقم 1) وبهذا تكون نسبتها 4/12=1/3 بينما نسبة ما يقع في الصنف الثاني (1/4=3/12) فيما يضم الصنف الثالث (5/12) إذ أن هذه النسب هي من متطلبات عمل شبكة (LVQ).

شبكة تكمي متجه التعلم LVQ

يتم تجهيز شبكة LVQ بالمدخلات المتضمنة المتغيرات المؤثرة على التبخر الانائي (درجة الحرارة، الرطوبة النسبية، السطوع الشمسي، سرعة الرياح)

$$P_{LVQ} = \begin{bmatrix} 7.85 & 72.28 & 5.08 & .68 \\ 8.66 & 68.2 & 4.61 & .74 \\ 13.66 & 64.8 & 6.99 & .76 \\ 19.79 & 58.0 & 7.91 & 1.15 \\ 24.50 & 46.58 & 9.61 & 1.117 \\ 30.14 & 32.35 & 11.67 & .59 \\ 34.91 & 29.04 & 11.77 & 1.16 \\ 34.44 & 29.62 & 11.02 & 1.40 \\ 28.90 & 33.85 & 10.43 & .635 \\ 22.31 & 39.82 & 8.46 & .863 \\ 14.31 & 57.02 & 7.16 & 1.05 \\ 11.91 & 68.32 & 5.59 & .279 \end{bmatrix}$$

$$IW_{LVQ} = \begin{bmatrix} 31.0635 & 34.8665 & 10.8979 & 1.0609 \\ 21.443 & 50.5224 & 8.2021 & 0.95092 \\ 21.412 & 50.5125 & 8.1956 & 0.9418 \\ 21.4772 & 50.5227 & 8.212 & 0.94625 \\ 21.4572 & 50.5185 & 8.202 & 0.94776 \\ 21.434 & 50.6704 & 8.1973 & 0.94691 \\ 21.1313 & 49.3576 & 8.5136 & 0.98422 \\ 21.4572 & 50.5185 & 8.202 & 0.94776 \\ 12.39 & 64.0428 & 6.1338 & 0.71173 \\ 21.412 & 50.5125 & 8.1956 & 0.9418 \\ 21.412 & 50.5125 & 8.1956 & 0.9418 \\ 21.412 & 50.5125 & 8.1956 & 0.9418 \\ 21.412 & 50.5125 & 8.1956 & 0.9418 \\ 21.412 & 50.5125 & 8.1956 & 0.9418 \\ 21.412 & 50.5125 & 8.1956 & 0.9418 \end{bmatrix}$$

$$LW_{LVQ} = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix}$$

. في حين تم اختيار (15) وحدة في الطبقة التنافسية وبعد عدة محاولات.

فيما اشتملت مرحلة اختبار الشبكة فترة الخمس سنوات الأخرى الغير مستخدمة في التدريب لمقارنة مخرجات شبكة LVQ المقترحة مع البيانات المرصودة ودللت على حسن الأداء بمعامل ارتباط مقداره (0.9858) وكما مبين في الشكل (5).

الاستنتاجات و التوصيات

1- بينت النتائج إمكانية نمذجة الشبكة العصبية نوع LVQ في تخمين التبخر الانائي وهي خروج عن الطرق التقليدية في نمذجة الشبكات العصبية التي تعتمد في أدائها على أسلوب التغذية الأمامية والتي تحتاج في تدريبها إلى إشراف.

التطبيق ومناقشة النتائج

تم تطبيق النموذج المقترح لشبكة LVQ على البيانات المرصودة والمرتبطة بظاهرة التبخر الانائي لمنطقة الموصل والشكل (4) يبين الموقع الجغرافي لمنطقة الدراسة. تضمنت فترة رصد البيانات (10) سنوات امتدت بين عامي (1990-2000) إن سبب اختيار هذه الفترة هو توفر جميع القراءات للسلسلة المرصودة وكذلك شمولها لمديات واسعة تضم معظم المعطيات المرتبطة بفعالية التبخر الانائي.

اتبعت الخطوات المذكورة أعلاه والتي تشتمل إعداد مدخلات الشبكة البالغ عددها (60) قيمة لكل متغير ولمدة خمسة سنوات بدلاً من إل (12) قيمة لكل متغير المستخدمة في نموذج الحسابات وتم التوصل بعد عدة محاولات إلى اعتماد (10) أصناف للهدف تغطي مديات فعالية التبخر الانائي وتعطي أفضل أداء للشبكة

2. Allen, R. G., Pereira, L. S., Raes, D., and Smith, M. (1998), "Crop Evapotranspiration: Guidelines for Computing Crop Water Requirement." Irrigation and Drainage paper No. 56, Food and Agriculture Organization of the United Nations (FAO), Rome.
3. AL-Hatem, N. T. ,(2004), "Rainfall-Discharge Modeling of Tigris Basins Using Artificial Neural Network", Ph. D. Thesis, College of Engineering, Mosul University.
4. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology , (2000), "Artificial Neural Networks in Hydrology: Hydrology Applications", Journal of Hydrologic Engineering, ASCE, 5(3): 124-137.
5. Jain, S. K., and Sing, V. P. ,(2003), "Application of Artificial Neural Networks to Water Resources", Water and Environment International Conference on 15-18 Dec. Bhopal, M.P., India.
6. Kohonen, T. 1988, "Self-organization and Associative Memory", Springer-Verlag, New York.
7. Demuth, H., and Beale, M. , (2002), Neural Network Tool Box For Use With Matlab. The Mathwork, Inc., MA. USA.

2-أوضحت النتائج مدى التوافق الخطي بين مخرجات الشبكة المقترحة مع القيم المرصودة لفعالية التبخر الانائي بمعامل ارتباط عالي نسبياً مقداره (0.9858).

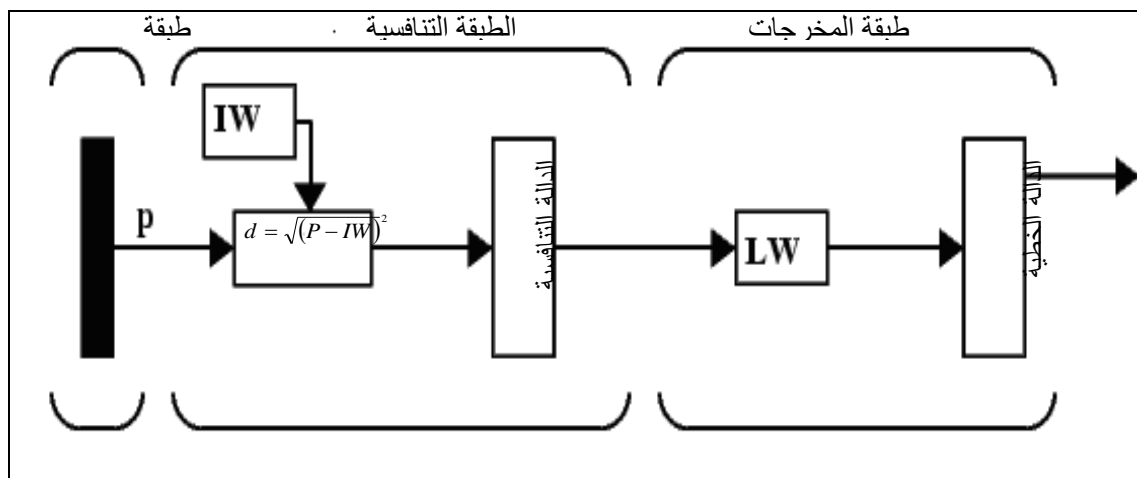
3-كان هدف هذه الدراسة تثبيت أسلوب منهجي لطريقة الحسابات التي تتم ضمن هذا النوع من الشبكات وتتميز بتعقيدها نسبياً. تم سرد طريقة الاحتساب بشكل واضح بحيث يسد الفجوة بين إمكانية الشبكة من نوع LVQ وتردد المستخدم في الاستفادة منها.

4- من مميزات هذا النوع من الشبكات هو إدخال البيانات بشكلها الاعتيادي دون إجراء عمليات معايرة وتقييس عليها.

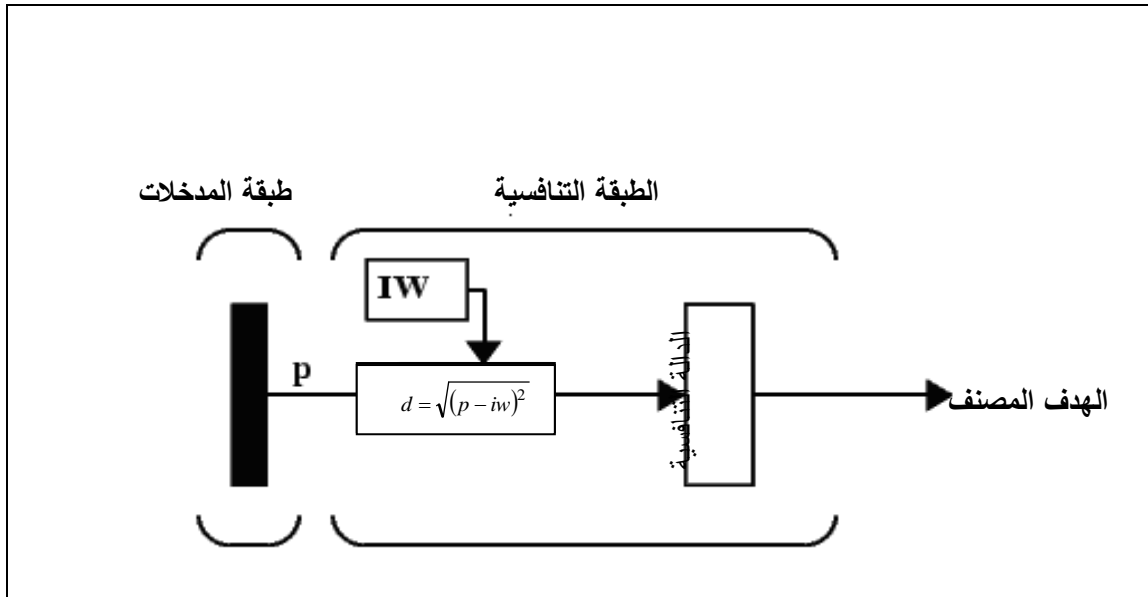
ومن التوصيات التي يوصي بها الباحثان استخدام شبكة LVQ للتنبؤ (Forecasting) وفحص أماكنها عند فقدان قسم من المدخلات وكذلك فحص أماكنها استخدامها لفعاليات أخرى تقع ضمن حقل الموارد المائية.

المصادر

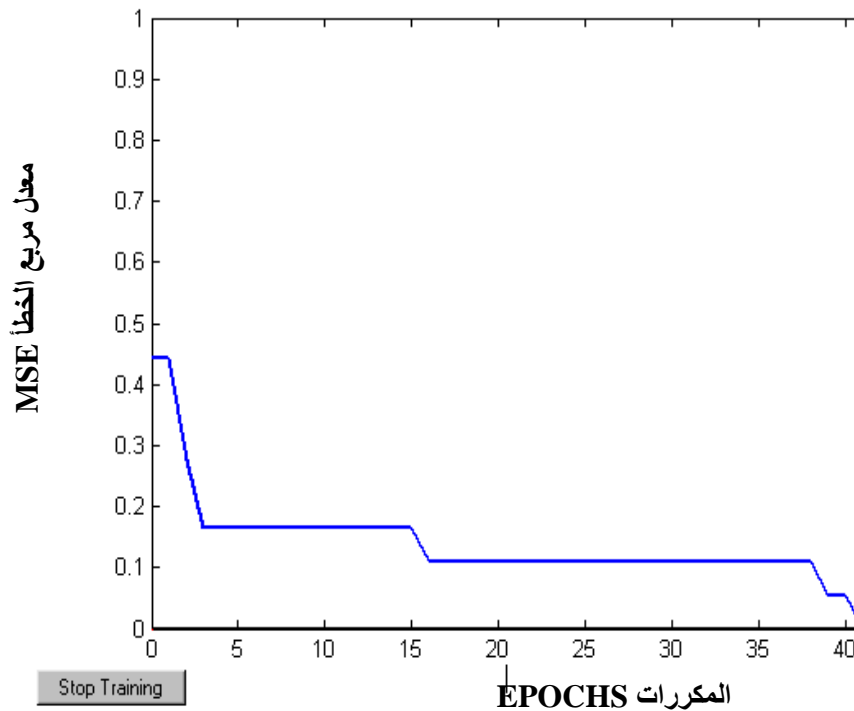
- 1- العاني، افتخار عبد الجواد عبد الحميد (2007). "أنموذج شبكة عصبية اصطناعية لتقدير التبخر - نتج المرجعي لمنطقة الموصل". أطروحة دكتوراه، كلية الهندسة، جامعة الموصل.



شكل (1) مخطط توضيحي لبنية شبكة تكمي متجه التعلم LVQ




الشكل (2) مخطط توضيحي لبنية شبكة الانتظام الذاتي (SOM)



شكل (3): أداء شبكة تكمي متجه التعلم (LVQ) أثناء تدريبها



الشكل (4) الموقع الجغرافي لمنطقة الدراسة



الشكل (5) التوافق الخطي بين مخرجات الشبكة المقترحة والبيانات المرصودة