

تقدير التبخر- النتح المرجعي اليومي لمنطقة الموصل باستخدام الشبكات العصبية الاصطناعية

افتخار عبد الجواد العاني كامل علي عبدالمحسن عبد ا لستار يونس الدباغ

أستاذ مساعد

طالبة دكتوراه

أستاذ

الخلاصة

اشتمل البحث الحالي على بناء نموذج رياضياتي يعتمد أسلوب الشبكات العصبية الاصطناعية لتطبيقه في تقدير التبخر- النتح المرجعي اليومي لمنطقة الموصل (شمال العراق) باعتماد بيانات مناخية يومية لمدة (٢١) سنة والمتضمنة العوامل المؤثرة على فعالية التبخر- النتح وهي: درجة الحرارة، الاشعاع الشمسي، سرعة الرياح، الرطوبة النسبية، إذ استخدمت كمدخلات للشبكة العصبية الاصطناعية فيما اعتمد التبخر كمرجات للشبكة المقترحة.

أظهرت نتائج هذا البحث أن هناك توافق خطي بين مخرجات الشبكة وبيانات التبخر الانائي الحقيقية بمعامل ارتباط مقداره (0.95) مما يبين امكانية استخدام هذه التقنية في تقدير التبخر- النتح المرجعي اليومي وذلك بضرب مخرجات الشبكة (التبخر) بمعامل التبخر الانائي. أضف إلى ذلك فان نتائج تحليل الحساسية التي تمت لاستقصاء مدى تأثير أي من مدخلات الشبكة على أداءها قد بينت أن هذا الأداء يتأثر بدرجة كبيرة عند ترافق درجة الحرارة بسرعة الرياح الشمسي، فيما تبين ان عامل الرطوبة النسبية ذا تأثير محدود خاصة عندما يترافق مع

الكلمات الدالة : - النتح المرجعي، شبكات عصبية اصطناعية، منطقة الموصل

Estimating Daily Reference Evapotranspiration for Mosul Area Using Artificial Neural Networks

Iftekhhar A. AL-Aani Dr. Kamel A. AL-Mohseen Dr. Abdul Sattar
Y. AL-Dabbagh

PhD. Candidate
Professor

Assistant Professor

Abstract

In the present study a mathematical model using Artificial Neural Network (ANN) was developed to estimate the daily reference evapotranspiration for Mosul area (northern part of Iraq) using daily meteorological data measured over 21 years, which are believed to influence the evapotranspiration process. The data are consisting of temperature, sun radiation, wind speed, and relative humidity. These variables have been used as inputs to the ANN, while the daily evaporation was adopted as an output.

The study reveals that there is a high linear correlation between the evaporation estimated by the proposed ANN and that measured using class A evaporation pan with a correlation coefficient of 0.95. This clearly indicates the possibility of using ANN technique for estimating the evapotranspiration component, which can be calculated by multiplying the output of ANN (i.e. evaporation) by the pan coefficient. Additionally, sensitivity analyses have been conducted to study the effects of the specific variables of inputs on the proposed network's performance. It is found that ANN's performance is highly affected when the temperature, sun radiation, and wind speed are concurrently acted, while the relative humidity was limited especially when it is accompanied by the temperature.

المقدمة

تعتبر عملية التبخر- نتح احدى المركبات الرئيسية للدورة الهيدرولوجية في الطبيعة، وعليه فقد اجتذبت اهتمام الكثير من الباحثين خاصة في المناطق التي تشح فيها الموارد المائية اذ يتطلب الامر الحفاظ على هذه الثروة الحيوية. لقد استخدمت طرق مباشرة وغير مباشرة لمحاولة تقدير كميات المياه المفقودة بهذه الفعالية ي - نتح المرجعي بأنه أقصى كمية من البخار التي يمكن ان تنطلق من مساحة معينة من الأرض إلى الجو تحت تأثير العوامل الجوية الخاصة تحديدا، فيما استنتج (Doorenbos and Pruitt) [1] بأنه يمكن اعتماد قيم التبخر المقاسة من أحواض التبخر على أنها تمثل التبخر- نتح المرجعي بعد ضربها بقيمة معامل تعتمد قيمة الاخير على نوعية الاناء وموضعه والمساحة المحيطة به [2].

كان لمنظمة الأغذية والزراعة التابعة للأمم المتحدة (FAO) باعا طويلا في تشجيع الدراسات التي تهتم بهذه الظاهرة الهيدرولوجية حيث عرف التقرير الصادر عنها [1] - نتح المرجعي بأنه معدل التبخر- نتح لسطح تربة مزروعة بغطاء نباتي أخضر مزدهر النمو وبارتفاع (-) سم ولايعاني من شحة المياه. وقد أقرت هذه المنظمة اربع طرق لحساب - نتح المرجعي وهي : طريقة بلاني وكريدل طريقة طريقة بنمان المعدلة طريقة التبخر الانائي فيما أوعزت [3] طريقة جديدة هي طريقة الفاو بنمان - مونتيث (FAO Penman - Montith) كطريقة قياسية تعمل تحت مختلف الظروف المناخية لحساب التبخر- . أن البحث الحالي هو محاولة لبناء نموذج رياضي

يعتمد أسلوب الشبكات العصبية الاصطناعية لتطبيقه في تقدير التبخر- في اليومي () وأستنباط أسلوب مبسط لتقدير كميات الخسائر المائية بالتبخر- نتج من خلال تحديد المتغيرات المناخية المتحكممة بهذه الفعالية واستخدامها كمدخلات إلى . كما أن هذ يتحرى حساسية الشبكة المقترحة لمدخلاتها خاصة عند هذه المتغيرات او اكثر من قائمة البيانات.

الشبكات العصبية الاصطناعية (Artificial Neural Networks)

لقد برز أسلوب الشبكات العصبية الاصطناعية (ANNs) خلال عقد التسعينات من القرن الماضي كاحد اساليب الذكاء الاصطناعي الذي يحاكي سريان ومعالجة المعلومات في العقل حفز الباحثين استغلال هذه الظاهرة في عمليات النمذجة الرياضية لمختلف المشاكل الهندسية التي استعصى حلها بطرق النمذجة التقليدية.

يعد حقل دراسة الشبكات العصبية الاصطناعية حقل متشعب من ناحيتي التطور والتطبيق وقد ابتدأ بالتطبيقات العملية لمفهوم الشبكات العصبية الاصطناعية على مختلف النواحي المتعلقة بالموارد المائية حديثا حيث تم استخدامها على نماذج الأمطار- السيج [4, 5] بالجريان [6] نمذجة المياه الجوفية [7] حول نوعية المياه ، نماذج لسياسة ادارة الموارد المائية ، تحليل السلاسل الزمنية الهيدرولوجية وتطبيقات على تشغيل الخزانات المائية . وللمزيد من المعرفة حول التطبيقات الهيدرولوجية للشبكات العصبية الاصطناعية يمكن الاستعانة بالمصدرين [8, 9]. تعمل الشبكات العصبية الاصطناعية بطريقة مشابهة لاصغر الوحدات العصبية في الكائنات الحية او مايد . تنتقل الإشارات () بين إذ تترافق هذه الخطوط باوزان معينه (قيم عددية) حيث تمثل هذه القيم المعلومات الابتدائية التي ستبدأ بها الشبكة حل المشكلة والتي يتم تجديدها لاحقا بتقدم عملية تدريب الشبكة. لعصبية الاصطناعية من الخبرة الناتجة من تجارب حيث تعمم هذه الخبرة على تجارب جديدة وتستخلص خواص استجاباتها من التي قد تكون منتظمة او غير منتظمة [10]. يمكن للشبكات العصبية الاصطناعية ان تحور سلوكها تبعا للبيئة التي تعمل فيها. فعلى سبيل المثال دخلات معينة إلى الشبكة (مرغوب فيها(هدف)) فان الشبكة ستقوم باصلاح ارتباطاتها (اوزانها) تصبح استجابتها مت

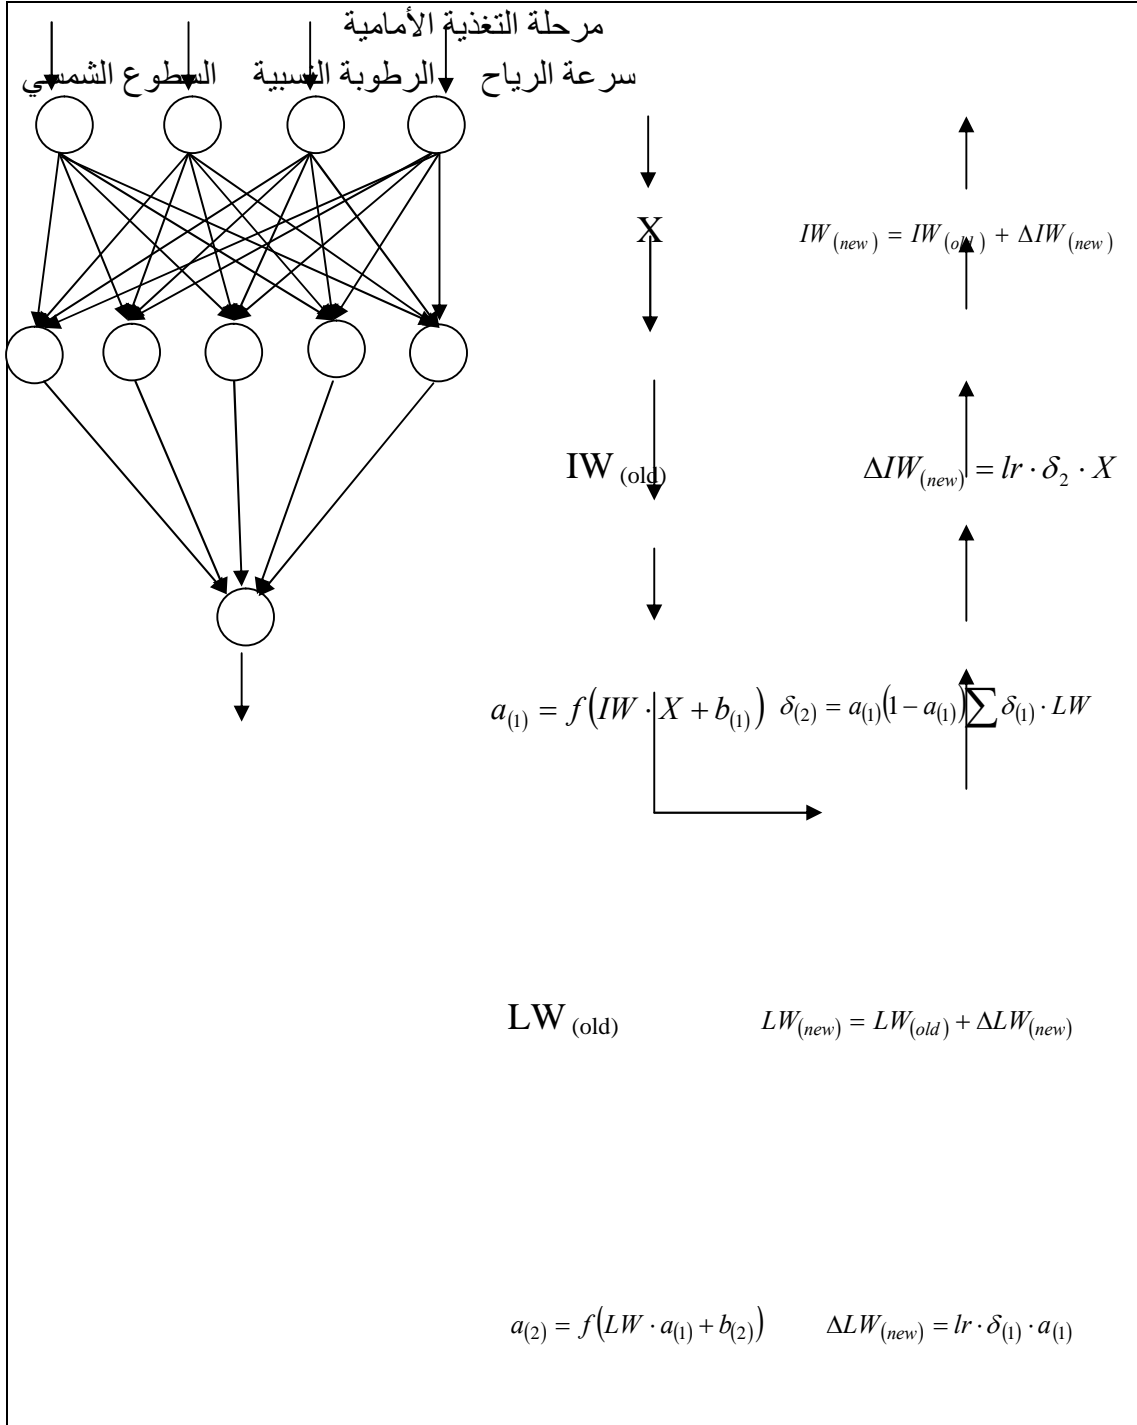
آلية تدريب الشبكة العصبية الاصطناعية تتم بادخال متجهات متتابعة الى الشبكة حيث تقوم بتقويم (تحويل) زان الارتباط الخاصة بها وفق اسلوب معرف مسبقا. ومن خلال عملية التدريب فان قيم اوزان الارتباط ستتجدد في كل دورة من دورات التعلم الى ان تصل الى قيم مناسبة والتي بمجملها ستؤدي الى اقل خط (قيمة مقبولة محددة مسبقا) بين ، وقيمة الهدف [11]. تصنف الشبكات العصبية الاصطناعية بناء على الاتجاه المزمع تبنيه في عملية اجراء الحسابات المطلوبة لغرض احتساب ، خرجات النموذج . فان تمت هذه الحسابات بشكل منهجي مبتداء بطبقة الادخال مروراً بالطبقة (تغذية الخفية وصولاً الى طبقة ال

بالتغذية الامامية، والاسميت بالشبكة ذات التغذية العكسية (Feed Back) [12].

الحالي نظرا لسعة استخدامه في بناء الشبكات المتعلقة بموضوع الموارد المائية

[13, 14]. (MSE) الذي تم حسابه في المرحلة السابقة

يتم انتشار الخطأ عكسيا طبقة بعد طبقة ابتداء من طبقة الـ باتجاه طبقة الـ
هذه المرحلة يتم تعديل الاوزان باجراء هبوط تدريجي في قيمة الوزن وهذا التدرج يتم حسابه
باستخدام تقنية الانتشار الـ وعملية التعديل في الأوزان، حيث يتم تطبيق
[15]. يعد التدريب بهذه التقنية معالجة متكررة وكل
تكرار يتكون من عدد من الخطوات، و () يوضح المخطط لخطوات الاشتقاق لخوارزمية
، إذ يبين آلية التغذية الأمامية ثم مرحلة احتساب الخطأ وانتشاره عكسيا
وعملية التعديل في الأوزان.



$$\delta_{(1)} = a_{(2)}(1 - a_{(2)})^{Y - a_{(2)}}$$

() مخطط اشتقاق خوارزمية الانتشار العكسي للخطأ
دللت النشريات المهمة بهذا الموضوع على ان الكثير من الباحثين قد اقترحوا خوارزميات
خاصة بتدريب الشبكات العصبية [17, 16] غير لكل من هذه الخوارزميات عناصر ضعف
على نوع المشكلة المراد حلها. وبشكل عام فان تصميم الشبكات
العصبية يمر بنفس المراحل التي تتطلبها عملية النمذجة التقليدية تتضمن المراحل التالية:

- . اقتراح هيكلية الشبكة (البنية الهندسية) مناسبة من حيث عدد الطبقات الخفية وعدد
العصبونات في كل طبقة ومعادلة المناقلة (Transformation) وخوارزمية
(Topology)
- . مرحلة التدريب (Training)
- . مرحلة التحقق وتشخيص (Validation)
- . (Testing)
- . هيكلية الشبكة المستخدمة واسلوب التعلم المناسب

لغرض الحصول على هيكلية للشبكة العصبية الاصطناعية يجب اختيار خوارزمية
التعلم المناسبة وبناء طبقات والطبقات الخفية. ذلك فقد تم استخدام
بيانات سنة كاملة تحليل حساسية الشبكة المقترحة من ناحية خوارزمية التعلم الملائمة
وعدد الطبقات الخفية المستخدمة مما يجدر ذكره .

وعدد العصبونات الخاصة بالشبكة العصبية تتحدد بطبيعة المشكلة
المراد حلها، فعلى سبيل المثال فان المشكلة التي تحت
(بعد المتغيرات المؤثرة على عملية التبخر)، في حين ا

تقتصر على طبقة واحدة بعصبون منفرد يمثل (عملية التبخر). النشريات المتعلقة بالشبكات
العصبية تشير عدم وجود اسلوب قياسي في تحديد عدد الطبقات الخفية ا عدد عصبوناتها
وانما يتم اختيار هذا العدد حسب رؤية القائم على بناء النموذج [18, 19]. تم تثبيت القيم الأولية
لضمان البدء بمعدل مربع . (MSE) ذا قيم متساوية لكافة الخوارزميات
المستخدمة في تدريب الشبكة العصبية وباستخدام خوارزميات تدريب مختلفة المميزات من ناحية
بنائها الرياضي والمتغيرات الواجب تعريفها قبل البدء بالتدريب. الهدف من هذه العملية هو
إمكانية كل خوارزمية بناء على سرعة وصولها ا اقل معدل ،
لدورات تكرارية ثابتة العدد (Epochs) وبذلك سيتمكن تبني الخوارزمية والبنية الهندسية
الملائمتين. سرد موجز للخوارزميات التي تم تجربتها في هذ [20].

- خوارزمية ((Gradient Descent (GD)): إحدى خوارزميات تدريب شبكة الانتشار
والتي تستخدم أسلوب الانحدار التدريجي .

- خوارزمية ((Gradient Descent with Momentum (GDM))): خوارزمية تدريب والتي تستخدم أسلوب الانحدار التدريجي السلس مع الزخم.
 - خوارزمية ((Variable Learning Rate (GDX,GDA))): خوارزمية تُعَلِّم متغير لشبكة وهي من أسرع طرق تدريب الشبكات العصبية.
 - خوارزمية ((Resilient Backpropagation (RP))): وهي خوارزمية تدريب بسيطة وتحتاج إلى ذاكرة خزن قليلة وتكون هذه الخوارزمية سريعة في عملية الاقتراب من الهدف.
 - خوارزمية ((Scaled Gradient (CGF))): وهي خوارزمية تدريب لها متطلبات خزن صغيرة في الذاكرة.
 - خوارزمية ((Scaled Conjugate (SCG))): وهي خوارزمية تدريب جيدة للأغراض .
 - خوارزمية ((Levenberg Marquardt (LM))): وهي خوارزمية تدريب سريعة لشبكة ذات حجم قابل للتحديث وذات ذاكرة مختزلة تفيد في التدريبات ذات الحجم الواسع.
- ولمعرفة المزيد من التفاصيل عن الطرائق الرياضياتية المتعلقة بخوارزميات التعلم المذكورة اعلاه يرجى مراجعة المصدر (MATLAB ;Version 6.5, User Manual, 2002) يبين لكل طريقة ميزات الخاصة في عملية التدريب كما أن لها معالم يجب تحديدها قبل بدء عملية تدريب الشبكة.

منطقة البحث والبيانات

الرشيدية، إحدى ضواحي مدينة الموصل الشمالية (43 ° 09) (36 ° 19) (222.6) (فوق مستوى سطح البحر)
والخارطة المبينة في الشكل () تبين الموقع الجغرافي لمنطقة ا

تركز البحث ناء نموذج رياضي يعتمد أسلوب الشبكات العصبية الاصطناعية لتطبيقه في تقدير التبخر- نتح المرجعي لمنطقة الموصل () ولهذا الغرض فقد تم الحصول على بيانات مناخية يومية من محطة الانواء الجوية في منطقة الرشيدية () المتغيرات التي استخدمت ك للشبكة العصبية الاصطناعية وهي: (مئوية)، الاشعاع الشمسي () الرياح على ارتفاع مترين (/ ثانية)، الرطوبة النسبية (%).

توفر قيم حقيقية للتبخر- يس نباتات مزروعة في منطقة الا فقد تم الحصول على بيانات التبخر الانائي اليومي (Class A Pan) سابقا لاستخدامها ك خرجات مرغوب فيها (او كهدف) لغرض التحقق من صحة اداء الشبكة . نلاحظ في هذه المرحلة ان الشبكة المقترحة ستقوم بتقدير التبخر فيما سيتم لاحقا ضرب القيم المستحصلة بمعامل التبخر الانائي لغرض الحصول على قيم التبخر- نتح المرجعي موضوع



الشكل (٢) الموقع الجغرافي لمنطقة البحث

معالجة البيانات

لقد تم اجراء عملية التقييس (Scaling) لكل من قيم متجهها قيم عناصر الإدخال والخراج قريبة بعضها من البعض الاخر أي ضمن مدى قصير نسبيا لتقليل قيم الخطأ بين القيم المستحصلة من الشبكة والقيم المرصودة (بين 0, 1 في هذه الحالة) [12, 21] وذلك لتحسين كفاءة العمليات الحسابية ولتحسين أداء الشبكة العصبية الاصطناعية.

تأثير طريقة التقييس المعتمدة على اداء

تمت عملية التقييس بعدة طر

وهذه الطرائق هي :

• طريقة (Kumar) [22]

$$X_{\text{norm}} = 0.5 * ((X - X_{\text{mean}}) / (X_{\text{max}} - X_{\text{min}})) + 0.5 \text{ -----(1)}$$

X : القيم الأصلية

X_{norm} : القيم المعدلة

X_{mean} : معدل القيم الداخلة

X_{min} : قيمة داخلة

X_{max} : أقصى قيمة داخلة

• طريقة (AL-Hatem) [23]

$$X_{\text{norm}} = (X - X_{\text{min}}) / (X_{\text{max}} - X_{\text{min}}) \text{ ----- (2)}$$

• طريقتي (Demuth and Beale) [20]

$$X_{\text{norm}} = (X - X_{\text{mean}}) / (X_{\text{max}} - X_{\text{min}})^{.5} \text{ ----- (3)}$$

$$X_{\text{norm}} = 2(X - X_{\text{min}}) / (X_{\text{max}} - X_{\text{min}}) - 1 \text{ ----- (4)}$$

(MSE) والذي يساوي معدل مربع الفرق بين

لغرض قياس دقة كل طريقة كما في المعادلة الآتية:

الشبكة والهدف

$$E = \sum_{i=1}^n \sum_{i=1}^k \frac{(d - Y)^2}{2n} \text{ ----- (5)}$$

Y : قيم الـ خرجات الفعلية.

d : قيم الـ خرجات المرغوب بها (Target)

: n

: k

النتائج والمناقشة

حساسية الشبكة من ناحية الهيكلية والتعلم

يشير الجدول () لى تأثير استخدام الخوارزميات المختلفة على الشبكة القيمة ل
 يتبين أن خوارزمية التعلم (Levenberg Marquardt (LM) قيمة ل
 لخطأ بقيمة لدورات تكرارية ثابتة العدد (Epochs) لجميع الخوارزميات المستعملة
 وبأوزان ابتدائية تم تثبيتها مسبقا ، فيما يوضح الشكل () تدريب الشبكة العصبية
 الاصطناعية المقترحة باستخدام خوارزمية التدريب (LM) وليينات يومية للفترة من (-
) حيث يبين عدد الدورات اللازمة للوصول الى الهدف المعرف مسبقا.

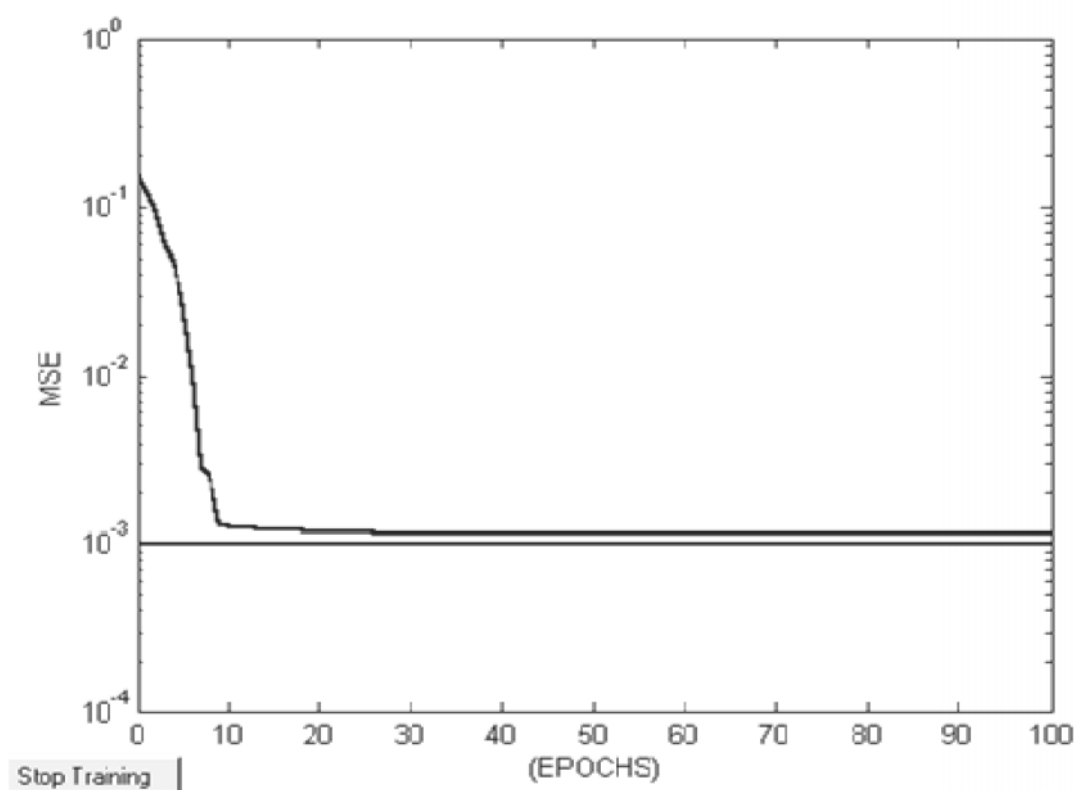
الجدول (١) نتائج استخدام خوارزميات التدريب المختلفة

خوارزمية التعلم	عدد المكررات EPOCHS	معدل مربع الخطأ الابتدائي MSE	معدل مربع الخطأ النهائي MSE
GD	100	0.26	0.26
GDM	100	0.26	0.26
GDA	100	0.26	0.2681
GDX	100	0.26	0.268
SCG	100	0.26	0.001312
	١٠٠٠		0.00126
RP	100	0.26	unstable
LM	100	0.26	0.00123
	1000		0.001158

يبين الجدول () تأثير استخدام دالات تفعيل مختلفة وعدد عصبونات مختلف على
 العصبية حيث يلاحظ أن استخدام دالة التفعيل (Tansigmoid) في الطبقة الخفية تتبع بدالة

تفعيل من نوع (Logsigmoid) في طبقة الإخراج هي ا
 قيمة للمعيار (MSE) (0.001132) بدورات تكرارية ثابتة العدد وأوزان ابتدائية ثابتة أيضا.
 () يدل على أن هيكلية الشبكة العصبية الاصطناعية (1-5-4))
 عصبونات في طبقة المد - عصبونات في الطبقة الخفية - عصبون واحد لطبقة
 مخرجات) هي الأفضل في ا اعتمادا على قيمة MSE المستنتجة والمساوية الى
 (0.00105).

يلخص الجدول () تأثير استخدام طر بيس (Scaling) هيكليتها . ومن ملاحظة النتائج يظهر أن استخدام الطريقة الأولى المعتمدة من قبل المصدر



[22] قد أعطت أفضل أداء للشبكة حيث كانت قيمة المعيار المعتمد (MSE=0.001132).

() دالات التفعيل المختارة وتأثيرها على أداء الشبكة العصبية الاصطناعية

دالة التفعيل للطبقة الخفية	دالة التفعيل لطبقة الإخراج	هيكلية الشبكة المقترحة	عدد المكررات	MSE

LOG	TAN	4-4-1	100	0.001166
TAN	TAN	4-4-1	100	0.00134
LOG	LOG	4-4-1	100	0.001175
TAN	LOG	4-4-1	100	0.001132
			١٠٠٠	0.001127
			٣٠٠٠	0.001109
		4-2-2-1	100	0.00133
		4-5-1	100	0.00105

بيس المختلفة للبيانات

()

أسلوب التقييس المستخدم	MSE	هيكلية الشبكة
$0.5(X-X_{\text{mean}})/(X_{\text{max}}-X_{\text{min}})+0.5$	٠.001132	4-4-1
$(X-X_{\text{min}})/(X_{\text{mix}}-X_{\text{min}})$	٠.00472	4-4-1
$(X-X_{\text{mean}})/(X_{\text{max}}-X_{\text{min}})^{0.5}$	٠.997	4-4-1
$2(X-X_{\text{min}})/(X_{\text{max}}-X_{\text{min}}) - 1$	٠.5104	4-4-1

تقسيم البيانات على مختلف فعاليات الشبكة

ان أكثر ما يميز الشبكات العصبية هو قدرتها على التمييز والتعميم (Generalize) الى هذه الفائدة فقد تم تقسيم البيانات الى ثلاث مجاميع [24] والغرض من ذلك هو قياس كفاءة الشبكة العصبية الاصطناعية ولمعرفة ما اذا تم تدريب الشبكة العصبية الاصطناعية بشكل صحيح ام لا.

مجموعة التدريب (Training): تضمنت البيانات اليومية للفترة من (-)
واستخدما لتدريب الشبكة العصبية الاصطناعية غايتها الوصول الى شبكة مع اقل مستوى

مجموعة التحقق (Validation): تضمنت البيانات اليومية للفترة من (- 1998)
استخدمت لتحقيق للشبكة العصبية الاصطناعية على عينات ادخال لم يتم التعرف
عليها من قبل الشبكة خلال مرحلة التدريب.

مجموعة الاختبار (Testing): تضمنت البيانات اليومية للفترة من (-)
دائي لتدريب الشبكة.

() يصور أداء الشبكة العصبية للمجموعات الثلاث المذكور علما ان مجموعتي
التحقق والاختبار هما عبارة عن عينات لم يتم التعرف عليها من قبل الشبكة خلال
مرحلة التدريب. ان اجراء عمليتي التحقق والاختبار هي لغرض من التوا
للشبكة ولمنع حدوث مبالغة بالتدريب (Over Training) للشبكة المقترحة بغية
الوصول الى الاوزان التي تربط مدخلات الشبكة بمخرجاتها بامثل شكل.

تم اجراء تحليل تحليل الارتباط (Regression Analysis) لإيجاد
الخطي بين جات الشبكة المقترحة وبيانات التبخر الانائي الحقيقية لسنة ()
هذين المعلمين يرتبطان بمعامل ارتباط مقداره (0.95) هو عليه في الشكل ().

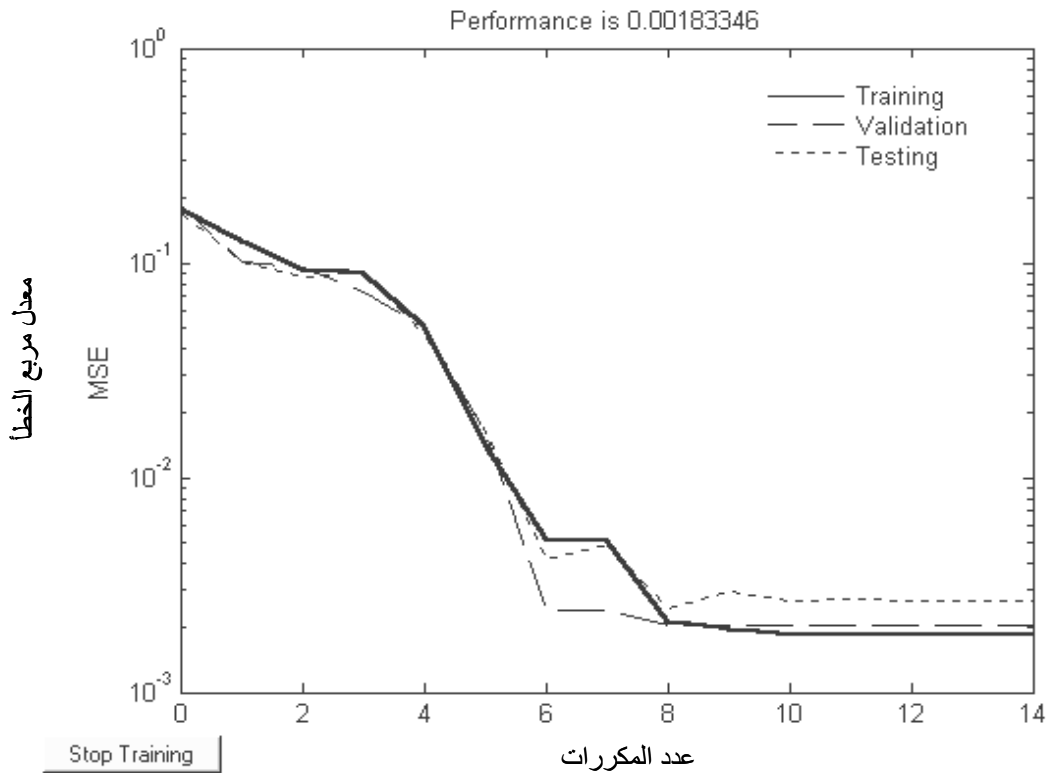
يبين الشكل () قيم التبخر نتح المرجعي اليومي لمنطقة الموصل للفترة من (- -)
ولغاية (- -) والمحسوبة بطريقتي الشبكة العصبية الاصطناعية المقترحة
(Etnet) والتبخر الانائي (Etpan) يلاحظ التوافق الأدائي بين الطريقتين حيث يكون
المنحنين منخفضين خلال الأشهر من السنة ثم يأخذان بالزيادة التدريجية وذلك بسبب
تأثير العوامل المناخية مجتمع (ارتفاع درجات الحرارة وانخفاض الرطوبة النسبية وزيادة
سرعة الرياح وساعات السطوع الشمسي) على عملية التبخر نتح المرجعي حتى يصل
معدل لهما خلال شهري تموز تقريبا ثم يد ن بعد ذلك بالانخفاض حتى يصل الى قيم قريبة
من القيم الابتدائية في نهاية .

تحليل الحساسية للمتغيرات الداخلة للشبكة العصبية الاصطناعية المقترحة:

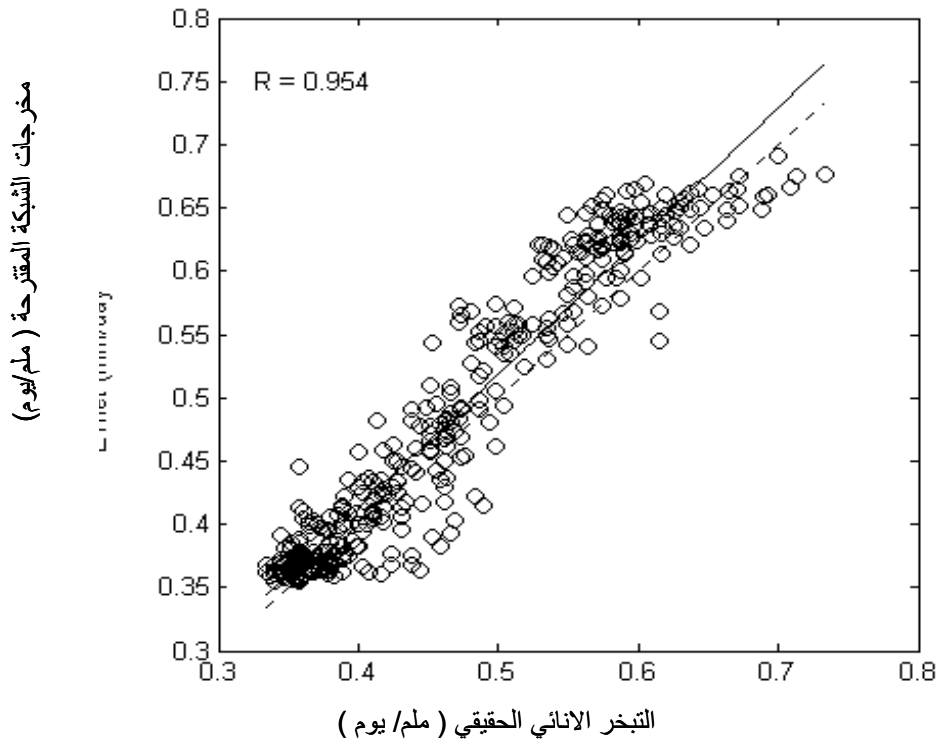
تم دراسة تأثير غياب أي من مدخلات الشبكة الموصوفة بالمتغيرات (درجة الحرارة،
سرعة الرياح، السطوع الشمسي والرطوبة النسبية) أدائها، اختير معدل مربع الخطأ
(MSE) كمعيار لهذا الأداء. ولقد قسم هذا التحليل إلى أربعة مراحل إذ اشتملت المرحلة الأولى
على فحص أداء الشبكة العصبية الاصطناعية لمتغير منفرد وغياب الثلاث متغيرات الأخرى
وتبين () قيم معدل مربع الخطأ (MSE) لهذه المرحلة.
سرعة الرياح كانت العامل الأقل تأثيرا على الأداء بغياب العوامل الأخرى عندما أعطت أكبر
(.) فيما بين الفحص درجة الحرارة أعطت أقل قيمة
للمعيار ذاته وبالغلة (.) الفحوصات ألاحقة والمتمثلة بالمرحل الثلاث الأخرى

بينت هذا الاستنتاج دائما صحيح فيما يخص متغير درجة متغير سرعة الرياح يمس تأثيره أكبر من تأثير متغير الرطوبة النسبية عندما يترافقان مع درجة الحرارة (كلا على (وكما هو معروض في الحقول الستة التالية من الجدول (). وعلى أية حال فإن تأثير درجة الحرارة مترافقة مع تأثير السطوع الشمسي أشرت أقل قيمة للمعيار ومقدارها (.) . أما المرحلة الثالثة فقد بينت ترافق درجة الحرارة وسرعة الرياح والسطوع الشمسي أدت إلى أقل قيمة لمعيار الخطأ (.) وهو مقارب لقيمه في المرحلة الرابعة أي عند إدخال الأربع متغيرات (.) مما يؤيد صحة الاستنتاج بأن عامل الرطوبة النسبية يقل تأثيره عندما يكون مترافقا مع متغير درجة الحرارة وهذا يتفق مع ما تم التوصل إليه من [25].

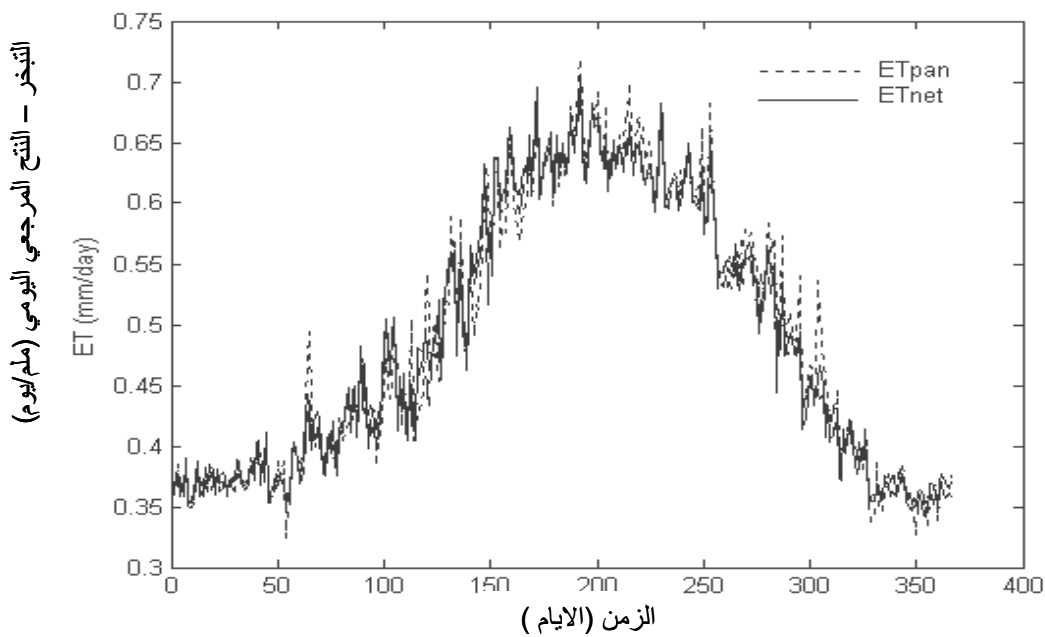
يتضح من هذا البحث أن هناك توافق خطي بين مخرجات الشبكة وبيانات التبخر الانائي الحقيقية بمعامل ارتباط مقداره (0.95) مما يبين إمكانية استخدام هذه التقنية في تقدير التبخر- المرجعي اليومي. ل طرائق التدريب للشبكة المقترحة هي طريقة (Levenberg Marquardt (LM) أنها طرائق التدريب في الوصول للهدف مع نتائج دقيقة. ويمكن اعتبار شبك الانتشار الخلفي للخطأ (Back Propagation (BP) مناسبة للاستخدام في تقدير قيم التبخر - تحسين الشبكة العصبية الاصطناعية وكذلك تحسين كفاءة العمليات الحسابية يعتمد على استخدام طرق تقيس مناسبة. ويبين تحليل الحساسية الشبكة العصبية يتأثر بدرجة كبيرة عند ترافق درجة الحرارة بسرعة الرياح و بينما وجد أن عامل الرطوبة النسبية ذا تأثير محدود خاصة عندما يترافق مع



الشكل (٤) أداء الشبكة العصبية المقترحة في المراحل الثلاثة (التدريب، التحقق، والاختبار)



الشكل (٥) التوافق الخطي بين مخرجات الشبكة المقترحة وبيانات التبخّر الانائي الحقيقية لسنة (٢٠٠٤)



- () - نتح المرجعي اليومي لمنطقة الموصل للفترة من (- -) ولغاية
 (- -) ريفتي الشبكة العصبية الاصطناعية والتبخر الانائي
 () يبين تحليل الحساسية للمتغيرات الداخلة للشبكة العصبية الاصطناعية المقترحة

المتغيرات	معدل مربع الخطأ (MSE)
سرعة الرياح	0.013632
السطوع الشمسي	0.005954
الرطوبة النسبية	0.006169
درجة الحرارة	٠.٠٠٢٧٧٦
درجة الحرارة، السطوع الشمسي	0.002265
درجة الحرارة، سرعة الرياح	٠.٠٠٢٣١٨
سرعة الرياح، السطوع الشمسي	0.005172
درجة الحرارة، الرطوبة النسبية	0.002484
سرعة الرياح، الرطوبة النسبية	0.004978
الرطوبة النسبية، السطوع الشمسي	0.004196
درجة الحرارة، سرعة الرياح، السطوع الشمسي	0.001870
درجة الحرارة، الرطوبة النسبية، السطوع الشمسي	0.002187
درجة الحرارة، سرعة الرياح، الرطوبة النسبية	0.002141
الرطوبة النسبية، سرعة الرياح، السطوع الشمسي	0.003514
درجة الحرارة، سرعة الرياح، الرطوبة النسبية، السطوع الشمسي	0.001799

1. Doorenbos, J., and Pruitt, W. O. (1977) "Guide lines for Predicting Crop Water Requirement." Irrigation and Drainage Paper No. 24, Food and Agriculture Organization of the United Nations (FAO), Rome, pp.156.
2. Grismer, M. E., Orang, M., Snyder, R., and Matyac, R. (2002) "Pan Evaporation to Reference Evapotranspiration Conversion Methods." Journal of Irrigation and Drainage Engineering, 128(3): 180-183.
3. 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.
4. French, M. N., Krajewski, W. F., and Cuykendall, R. R. (1992) "Rainfall Forecasting in Space and Time Using a Neural Network." Journal of Hydrology, 137(1-4): 1-31.
5. Minns, A. W., and Hall, M. J. (1996) "Artificial Neural Networks as Rainfall Runoff Models." Hydrological Sciences Journal, 41(3), 399-418.
6. Campolo, M., Andreussi, P., and Soldati, A. (1999) "River Flood Forecasting With a Neural Network Model." Water Resources Research, 35(4): 1191-1197.
7. Jain. S. K., Das, A., and Srivastava, D. K. (1999) "Application of ANN for Reservoir inflow prediction and operation." Journal of Water Resources Planning and Management, ASCE, 125 (5): 263-271.
8. 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.
9. 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.
10. Wasserman, P. D. (1989) Neural Computing Theory and Practice. Van. Nostrand Reinhold, New York.
11. Trajkovi , S., Todorovic, B., and Stankovic, M. (2001) "Estimation of FAO Penman C Factor by RBF Networks." Architecture and Civil Engineering, Vol. 2(3):185-191.
12. Zurada, J. M. (1996) Introduction to Artificial Neural System. Jaico Publishing House, Mumbai.
13. Arca, B., Benincasa, F., De Vincenzi, M. and Ventura, A. (1998) "Neural Network to Simulate Evaporation from Class A Pan." 23rd Conference of Agricultural and Forest Meteorology, 2-7 November, Albuquerque.

14. Arca, B., Benincasa, F., and De Vincenzi, M. (2001) "Evaluation of Neural Network Techniques for Estimating Evapotranspiration." arca@imaes.ss.cnr.it
 15. Fu, L. (1994) Neural Networks in Computer Intelligence. McGraw-Hill Inc. New York.
 16. Principe, J. C., Euliani, N. R., and Lefebvre, W. C. (2000) Neural and Adaptive Systems: Fundamentals Through Simulation. John Wiley and Sons, Inc.
 17. Caruana, R., Lawrence, S., and Giles, L. (2000). "Overfitting in Neural Networks: Backpropagation, Conjugate Gradient, and Early Stopping." Neural Information Processing Systems, Denver, Colorado, November 28-30.
 18. Lopez, G., Rubio, M. A., Martinez, M. and Bahles, F. J. (2001) "Estimation of Hourly Global Photosynthetically Active Radiation Using Artificial Neural Network Models." Agricultural and Forest Meteorology, 107:279-291. www.elsevier.com/locate/agrformet .
 19. Terzi, O., and Keskin, M. E. (2003) "Cross Comparison of Activation Function Used in Artificial Neural Network Models." <http://www.norwa.org/?p210>.
 20. Demuth, H., and Beale, M. (2002) Neural Network Tool Box for Use with MATLAB. The Mathwork, Inc., MA. USA.
 21. Shi, J. (2000). "Reducing Prediction Error by Transforming Input Data for Neural Networks." Journal of Computing in Civil Engineering, Vol. 14(2):109-116.
 22. Kumar, M., Raghuwansh, S., Singh, R., Wallender, W. W., and Pruitt, W. O. (2002) "Estimating Evapotranspiration Using Artificial Neural Network." Journal of Irrigation and Drainage Engineering, ASCE 128(4): 224- 233.
 23. AL-Hatem, N. (2004) Rainfall-Discharge Modeling of Tigris Basins Using Artificial Neural Network. Ph. D. Thesis, College of Engineering, Mosul University.
 24. Shahin, M. A., Holger, R. M., and Jaksa, M. B. (2004) "Data Division for Developing Neural Networks Applied to Geotechnical Engineering." Journal of Computing in Civil Engineering, Vol. 18(2): 105-114.
- الجبوري، شفيقة سلطان عبد الله حسين () . "تقييم معادلة الفاو بنمان - مونتيث الاستهلاك المائي المرجعي ببيانات مناخية كاملة وناقصة في العراق". رسالة ماجستير، كلية الهندسة، جامعة الموصل.