

تقدير البخرنتح المرجعي لمنطقة سرت باستخدام الشبكات العصبية الاصطناعية

أحمد إبراهيم خمّاج¹، مصطفى بن زقطة²، يونس ضو الزليط¹، أبوبكر محمد شقّلب¹

1. قسم التربة والمياه - كلية الزراعة - جامعة طرابلس

2. كلية الزراعة - جامعة سرت

المستخلص

في هذه الورقة، تم تطوير طريقة جديدة مبنية على تقنية الشبكات العصبية لتقدير البخرنتح المرجعي بالاعتماد على متوسط درجة الحرارة، ومتوسط الرطوبة النسبية، وكذلك الإشعاع الشمسي لمنطقة سرت. ولمعرفة مدى دقة هذه الطريقة تمت مقارنتها مع طريقة بنمان مونثيت المعدلة (FAO - Penman-Monteith)، والتي استعملت كطريقة قياسية مقارنة، كما تمت مقارنتها مع بعض الطرائق التجريبية الأخرى، وهي طريقة بلاني كريدل المعدلة (Doorenbos and Pruitt, 1977)، وهارجريفس-سماني (Hargreaves and Samani, 1985) التجريبية. حيث تم استخدام البيانات المناخية المتوفرة لمنطقة سرت للفترة الزمنية من 1996 وحتى 2005. أظهرت النتائج المتحصل عليها المقاربة الدقيقة لتقدير الشبكات العصبية الاصطناعية للبخرنتح المرجعي مع طريقة بنمان مونثيت المعدلة. ويتضح ذلك من خلال قيم معايير اختبار أداء النماذج، وهي متوسط الخطأ المطلق (MAE)، والجذر التربيعي لمربع الخطأ (RMSE)، ومعامل ناش-ساتكليف (C^2)، حيث كانت قيم معايير اختبار أداء النماذج جيدة لتقديرات الشبكات العصبية مقارنة بالقيم المتحصل عليها من معادلة هارجريفس-سماني ومعادلة بلاني-كريدل المعدلة، ويظهر ذلك جليا من خلال قيم النسبة المئوية لانحراف القيم المتنبأ بها عن تلك المقدرة بطريقة بنمان مونثيت المعدلة، حيث بلغت +2% لتقدير الشبكات العصبية، بينما بلغت -18% لمعادلة هارجريفس-سماني و-10% لمعادلة بلاني-كريدل المعدلة، كما أكدت النتائج أن طريقة الشبكات العصبية الاصطناعية هي الأفضل في تقدير البخرنتح المرجعي مقارنة بمعادلة هارجريفس-سماني ومعادلة بلاني-كريدل المعدلة لمنطقة سرت.

الكلمات الدالة: البخرنتح المرجعي، الشبكات العصبية الاصطناعية. معادلة بلاني، كريدل، معادلة هارجريفس، سماني، سرت.

المقدمة

الري، التي بدورها تعتمد على التقديرات الصحيحة يعتمد نجاح واستدامة الزراعات المروية بدرجة أساسية على الإدارة الجيدة والمتكاملة لعمليات والدقيقة للاستهلاك المائي للمحاصيل المزروعة، وهذا يتطلب حساب قيم البخرنتح المرجعي

البخرنتح المرجعي لبيئة مناخية معينة. كما أوضح (Nandagiri *et al.*, 2006) أن أداء أغلب المعادلات التجريبية المستخدمة في تقدير البخرنتح المرجعي تتفاوت من منطقة مناخية إلى أخرى، ومن ثم فإنه من المفيد أن يتم تقدير البخرنتح المرجعي في المناطق التي تفتقر إلى البيانات المناخية بشكل أكثر دقة، وباستخدام طرائق تقدير تحتاج إلى أقل عدد من بيانات المتغيرات المناخية. ومن أهم تلك الطرائق الجديدة هي استخدام الشبكات العصبية الاصطناعية لتحديد البخرنتح المرجعي بالاعتماد على عدد محدود من العوامل المناخية.

تعرف الشبكات العصبية الاصطناعية (Artificial Neural Networks) أو اختصاراً (ANNs) على أنها نماذج أو برامج كمبيوتر مبسطة تحاكي النظام العصبي الحيوي في طريقة عملها، بحيث تتكون من نظام عمليات بتوزيع متوازي، ولها القابلية على التعلم، ومن ثم اكتساب المعرفة، وتجعلها جاهزة للاستخدام. تتميز الشبكات العصبية الاصطناعية بقدرتها على التعلم والتدرب على مجموعة من البيانات الخاصة بمشكلة معينة، والعمل على تصنيفها، وتشخيصها، واتخاذ القرار فيها، مع إمكانية التنبؤ والتوقع وحل أي مشكلة مشابهة قد تظهر مستقبلاً. تستخدم الشبكات العصبية الاصطناعية بنجاح لنمذجة الأنظمة غير الخطية والمشابهة لحد كبير لعملية البخرنتح التي تحدث في بيئة المحصول، حيث تكمن أهميتها في عمليات التقدير والتنبؤ، وكذلك في العمليات المتعلقة بمشاكل التصنيف للمدخلات، ويعزى انتشار استخدام الشبكات العصبية الاصطناعية إلى دقة التقديرات غير الخطية للمتغيرات التابعة لمتغيرات مستقلة لا يمكن وصف سلوكها رياضياً، والتي توفر مميزات

(Reference Evapotranspiration) بشكل دقيق خلال مواسم النمو في المناطق الزراعية. إن أهم مشكلة تواجه تقدير البخرنتح المرجعي هي قلة البيانات المناخية خصوصاً في المناطق المعزولة للبلدان النامية، وللتغلب على العجز في البيانات المناخية يتم اللجوء إلى معادلات تقدير البخرنتح المرجعي التي تتطلب متغيراتها بيانات مناخية متوفرة ومتاحة. عملياً، قد تكون النتائج المتحصل عليها لقيم البخرنتح المرجعي من استخدام بعض هذه المعادلات التجريبية مقبولة عندما لا تكون هناك بيانات مناخية كافية، مثل نماذج بلاني - كريدل المعدلة وهارجريفس - سماني (Lee *et al.*, 2004, and Jensen *et al.*, 1997).

أوصت منظمة الأغذية والزراعة (FAO) حديثاً، باعتبار طريقة بنمان مونيت المعدلة ذات الأساس الفيزيائي كطريقة قياسية لتقدير البخرنتح المرجعي عندما تتوفر بيانات دقيقة عن كل العوامل المناخية ولفترات زمنية طويلة (Grazhani and Ahmeti, 2010). وعلى الرغم من الدقة العالية للنتائج المتحصل عليها من استخدام هذه الطريقة، إلا أنه قد تظهر صعوبات في تطبيقها لعدم توفر بعض البيانات المناخية عن بعض المتغيرات مثل صافي الإشعاع، وقياسات الرطوبة النسبية، وساعات السطوع الفعلية، بالإضافة إلى سرعة الرياح النهارية واليومية (Arca *et al.*, 2004)، هذا بالإضافة إلى بيانات حول الغطاء النباتي وقيم المقاومة الإيرووديناميكية، والتي في حال غيابها قد تؤثر سلباً على دقة تقديرات طريقة بنمان مونيت المعدلة (Ventura *et al.*, 1999). ووفقاً إلى (Wang *et al.*, 2008) فإنه لا يوجد إجماع عام على مدى ملائمة أي من المعادلات المستخدمة في تقدير

الدراسة لكونها تمثل أهم المناطق التي تحتوي على العديد من المشاريع الزراعية المروية، بالإضافة إلى توفر معظم البيانات المناخية فيها، بحيث تسهل عملية المقارنة والحساب لجميع المعادلات التجريبية المدروسة مع نموذج الشبكات العصبية الاصطناعية المطبق. وتقع محطة الإحصاء المناخي بسرت على خط عرض "20° 16' 20" شمالاً وخط طول: "31° 20' شرقاً، ويبلغ ارتفاع المحطة حوالي 16 متر عن سطح البحر.

تم تجميع البيانات المناخية للمحطة لفترة عشرة سنوات (2005 - 1996) على أساس شهري، وشملت البيانات المجموعة متوسط درجة الحرارة ومتوسط الرطوبة النسبية، وكذلك سرعة الرياح بالإضافة إلى متوسط ساعات السطوع الفعلية. إن هذه البيانات تجعل بالإمكان حساب البخرنتح المرجعي باستخدام معادلة بنمان مونتيت المعدلة ومعادلة هارجريفس-سماني، بالإضافة إلى معادلة بلاني - كريدل المعدلة، كما أنها تمكن من تطوير نموذج الشبكات العصبية الاصطناعية لتقدير البخرنتح المرجعي.

حساب البخرنتح المرجعي المقارن:

نظراً لعدم وجود بيانات فعلية لقياسات البخرنتح المرجعي والذي يتأتى عبر استخدام الطرائق المباشرة مثل الليزمترات، تم اللجوء إلى استخدام معادلة بنمان مونتيت المعدلة كطريقة مقارنة لتقدير البخرنتح المرجعي كما أشارت العديد من الدراسات من أمثلتها (Allen et al., 1998; Alexandris et al., 2006 and Georgiou and Papamichail, 2008). حيث تم تقدير البخرنتح المرجعي الشهري لكامل المدة المدروسة باستخدام معادلة بنمان مونتيت المعدلة (Allen et al., 1998) على النحو التالي:

عديدة عن تلك المقاربات التحليلية التقليدية (Schultz et al., 1995; Dowla and Rogers, 1995, Arca et al., 1998, Ventura et al., 1999; Patter-Son, 1996; and Paruelo and Tomasel, 1997).

تم تطبيق الشبكات العصبية الاصطناعية بنجاح على مجموعة من المتغيرات المناخية المختلفة لنمذجة عملية البخرنتح المرجعي، ومن أمثلة هذه التطبيقات قيام (Sudheer et al., 2003) باختبار قدرة الشبكات العصبية على تقدير البخرنتح الفعلي من بيانات مناخية محدودة، واقترحوا أنه بالإمكان حساب البخرنتح للمحصول باستخدام الشبكات العصبية الاصطناعية، وذلك باستعمال البيانات المتوفرة عن درجات الحرارة فقط، بينما وجد (Zanetti et al., 2007) أنه بالإمكان استخدام كلا من متوسط درجات الحرارة الصغرى والعظمى للهواء الجوي كمدخلات لتقدير البخرنتح المرجعي باستعمال الشبكات العصبية الاصطناعية. وخلاصة الأمر، فإن استخدام الشبكات العصبية قد يوفر بديلاً أكثر دقة من المعادلات التجريبية خصوصاً عند توفر عدد قليل من بيانات العوامل المناخية، كما هو واقع الحال في معظم مناطق ليبيا مما يتيح الرفع من درجة تقدير البخرنتح المرجعي والتخطيط الجيد للري ودراسات المياه بشكل عام للعديد من المناطق في ليبيا وبداية بمنطقة سرت التي استهدفتها هذه الدراسة.

المواد وطرائق البحث

منطقة الدراسة والبيانات المناخية

تقع منطقة الدراسة في نطاق المناطق الجافة بمعدلات أمطار سنوية لا تزيد عن 150 ملم، وتمتد على الساحل الشمالي الوسطي لليبييا، وتم اختيار منطقة

البخرنتح المرجعي وفقا لمعادلة بنمان مونتييت المعدلة.

$$ET_{o-PM} = \frac{(0.408\Delta(R_n - G) + c \frac{900}{T + 273} U_2 (e_s - e_a))}{(\Delta + c(1 + 0.3U_2))}$$


حساب البخرنتح المرجعي باستخدام نموذج

الشبكات العصبية الاصطناعية

تم اختيار ثلاثة متغيرات مناخية لتمثيل المدخلات في الشبكات العصبية، تلك المتغيرات هي متوسط درجة الحرارة الشهرية (T_{mean})، ومتوسط الرطوبة النسبية شهريا (RH_{mean})، وكذلك متوسط الإشعاع الشمسي الشهري (R_s). إن اختيار المتغيرات الثلاثة تم بناءً على دراسة (Ekhmaj, 2012)، والذي أوضح من خلال دراسته على البخرنتح المرجعي لكل من مدينة الزاوية ومدينة الزهراء أن لتلك المتغيرات ارتباطا قويا مع معدل البخرنتح المحسوب من طريقة حوض البخر. أما قيم البخرنتح المرجعي فإنها ستمثل في طبقة المخرجات، ويوضح الشكل (1) مكونات الشبكة العصبية المستخدمة.

قسمت البيانات المتوفرة عن منطقة الدراسة إلى مجموعتين رئيسيتين، الأولى لغرض تدريب ومعالجة الشبكات العصبية، حيث استخدمت عند هذه

حيث تمثل ET_{o-PM} البخرنتح المرجعي (مم/ يوم)، كما تم حسابه من معادلة بنمان مونتييت المعدلة و (R_n يوم/ مم)، R_n تمثل صافي الإشعاع عند سطح المحصول (ميغاجول/ متر مربع. يوم)، G كثافة الفيض الحراري للتربة (ميغاجول/ متر مربع. يوم)، و Δ تمثل ميل منحني العلاقة بين الضغط البخاري التشبعي ودرجة حرارة الهواء (كيلوباسكال/ م²)، و U_2 تمثل سرعة الرياح عند ارتفاع 2 متر (متر/ ثانية)، e_s تمثل الضغط البخاري التشبعي (كيلوباسكال)، و e_a الضغط البخاري الفعلي (كيلوباسكال) و α الثابت السيكرومتري (كيلوباسكال/ م²)، و T المتوسط اليومي لدرجة حرارة الهواء عند ارتفاع 2 متر (م²). في هذه الدراسة تم استخدام برنامج (CROPWAT 8.0 for Windows) والذي تم تطويره من قبل منظمة الأغذية والزراعة (FAO) لحساب



شكل 1. مكونات الشبكة العصبية المستخدمة في الدراسة

تم حساب معدل البخرنتح المرجعي من البيانات المناخية المجمعة، باستخدام طريقة بلاني - كريدل وذلك وفقاً للتعديل الذي اقترحه (-1977Dooren) الذي تضمن إدخال معاملات تصحيح تشمل معدلات قيم الرطوبة النسبية الصغرى، وسرعة الرياح أثناء النهار، وكذلك النسبة بين ساعات السطوع الفعلية إلى ساعات السطوع الممكنة، وذلك وفقاً للمعادلة التالية:

$$ET_{o-BC} = \left[a + (bP \left(\frac{T}{2.19} + 8.13 \right)) \right] \quad (5)$$

$$a = 0.0043(RH_{min}) - \left(\frac{n}{N} \right) - 1.41 \quad (6)$$

$$b = 0.81917 - 0.0040922(RH_{min}) + 1.0705 \left(\frac{n}{N} \right) + 0.065649(U_{day}) - 0.0059684(RH_{min}) \left(\frac{n}{N} \right) - 0.0005967(RH_{min})(U_{day}) \quad (7)$$

حيث تمثل ET_{o-BC} البخرنتح المرجعي (مم/يوم) كما تم حسابه باستخدام معادلة بلاني - كريدل المعدلة، T المتوسط الشهري لدرجة الحرارة المقاسة (m)، P تمثل نسبة مجموع ساعات السطوع السنوية خلال الشهر، a و b عوامل تعتمد على معدلات قيم الرطوبة النسبية الصغرى، سرعة الرياح أثناء النهار وكذلك النسبة بين ساعات السطوع الفعلية إلى ساعات السطوع الممكنة، RH_{min} النسبة المئوية للرطوبة النسبية الصغرى، n/N نسبة ساعات السطوع الفعلية إلى ساعات السطوع الممكنة. U_{day} تمثل سرعة الرياح أثناء النهار مقاسة على ارتفاع 2 متر.

تقدير البخرنتح المرجعي باستخدام معادلة هارجريفس - سماني التجريبية

تم حساب معدل البخرنتح المرجعي باستخدام معادلة هارجريفس - سماني (Hargreaves and Samani, 1985) لتقدير البخرنتح المرجعي، والتي

المجموعة البيانات المناخية الشهرية لثمان سنوات، من 1996 حتى سنة 2003، بينما استخدمت المجموعة الثانية والمثلة بالبيانات المناخية لسنتي 2004 و 2005 لغرض التقييم، بحيث حجت البيانات المستعملة في هذا القسم تماماً عن الشبكات العصبية في مرحلتي التدريب والمعالجة، كما تم اختيار الشبكة العصبية ذات الارتداد العكسي لكفاءتها العالية في تمثيل العلاقات غير الخطية. تم معالجة البيانات المستخدمة وجعلها في الشكل المعياري (-Normali zation) بعد توزيع وترتيب البيانات عشوائياً، وتم استخدام دالة التعلم (Traingdx) ودالة (Learnngdm) لحساب الأوزان، واستخدمت كلا من دالة التنشيط (Hyperbolic Tangent function) في الطبقة المخفية حيث يمكن كتابتها على النحو التالي:

$$\tanh(S_j) = \frac{1 + e^{-S_j}}{1 - e^{-S_j}} \quad (2)$$

كما استخدمت الدالة Log-sigmoid في طبقة المخرجات، والتي بالإمكان كتابتها على النحو التالي:

$$\log(S_j) = \frac{1}{1 + e^{-S_j}} \quad (3)$$

حيث تمثل S_j قيمة جمع المدخلات الموزونة والتي بالإمكان كتابتها على الصورة التالية:

$$S_j = X_1 W_{1j} + X_2 W_{2j} + \dots X_n W_{nj} + W_{0j} \quad (4)$$

وتمثل (X_1, X_2, X_n) قيم المدخلات، و (W_{1j}, W_{2j}, W_{nj}) أوزان تلك المدخلات. كما تمثل (W_{0j}) قيمة الانحياز. ولتنفيذ نموذج الشبكات العصبية تم الاستعانة ببرنامج (Artificial Neural Network Matlab toolbox) الإصدار 7.4.0.287 (Demuth and Beale, 1998) تقدير البخرنتح المرجعي باستخدام معادلة بلاني - كريدل المعدلة التجريبية

بالإمكان كتابتها على النحو التالي:

$$MAE = \frac{1}{n} \sum_{i=1}^n |ET_{O-PM} - ET_{O-Predicted}| \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (ET_{O-PM} - ET_{O-Predicted})^2} \quad (10)$$

$$C^2 = 1 - \left(\frac{F}{F_0} \right) \quad (11)$$

$$F = \sum_{i=1}^n (ET_{O-PM} - ET_{O-Predicted})^2 \quad (12)$$

$$F_0 = \sum_{i=1}^n (ET_{O-PM} - ET_{O-mean-PM})^2 \quad (13)$$

حيث تمثل ET_{O-PM} ، $ET_{O-Predicted}$ ، معدل البخرنتح المرجعي (مم/ اليوم) المتنبأ به والمحسوبة وفقا لطريقة بنمان مونتيت المعدلة، على التوالي. بينما تمثل $ET_{O-mean-PM}$ متوسط معدل البخرنتح (مم/ اليوم) كما تم حسابه بطريقة بنمان مونتيت المعدلة. بالإضافة إلى تلك المعايير السابقة، تم استخدام تقنية تحليل الانحدار لتقدير انحراف القيم المتنبأ بها عن القيم المحسوبة لمعدل البخرنتح المرجعي والتي حسبت باستخدام طريقة بنمان مونتيت المعدلة، ويمكن كتابة صيغة معادلة الانحدار المستعملة في المقارنة كما يلي:

$$ET_{O-Predicted} = \alpha ET_{O-PM} \quad (14)$$

حيث تمثل α قيمة ميل العلاقة بين ET_{O-PM} و $ET_{O-Predicted}$ ، ووفقا للمعادلة السابقة فعند تساوي قيم كلا من ET_{O-PM} و $ET_{O-Predicted}$ فإن قيمة $\alpha = 1$. ويظهر معامل التحديد R^2 معيار آخر لتقييم أداء النماذج المختلفة، فكلما كانت قيمة معامل التحديد (R^2) قريبة من الواحد الصحيح كانت دليلاً على ارتفاع كفاءة النموذج وحسن تفاعله مع البيانات المتاحة.

النتائج والمناقشة

المقارنة بين طريقتي بلاني - كريدل المعدلة وطريقة هارجريفس - سباني اعتمدت الدراسة على استخدام طريقة بنمان مونتيت المعدلة كطريقة قياسية لتقدير البخرنتح المرجعي.

$$ET_{O-HGS} = 0.0023R_a(T_{mean} + 17.8)(T_{max} - T_{min})^{0.5} \quad (8)$$

حيث تمثل ET_{O-HRG} معدل البخرنتح المرجعي كما تم حسابه باستخدام معادلة هارجريفس - سباني (مم/ يوم)، R_a الإشعاع الشمسي مقاسا فوق الغلاف الجوي (مم/ يوم) ويعتمد على كل من خط العرض والزمن، وتمثل T_{max} ، T_{mean} و T_{min} متوسط درجة الحرارة و متوسط درجة الحرارة العظمى والصغرى ($^{\circ}C$)، على التوالي.

تقييم أداء نموذج الشبكات العصبية والمعادلات التجريبية

تم تقييم واختبار دقة النتائج المتحصل عليها من استخدام كلا من طريقة بلاني - كريدل المعدلة وطريقة هارجريفس - سباني بالإضافة إلى النموذج الذي تم تطويره باستخدام الشبكات العصبية الاصطناعية ومقارنتها بطريقة بنمان مونتيت المعدلة القياسية لتقدير البخرنتح المرجعي وذلك باستخدام عدة معايير إحصائية، وهي متوسط الخطأ المطلق (MAE)، الجذر التربيعي لمربع الخطأ (RMSE)، معامل ناش - ساتكليف (Nash and) (C^2) (Sutcliffe, 1970).

إن القيم المثالية لكل من (MAE) و (RMSE) هي الصفر، حيث تتساوي فيه القيم الفعلية مع القيم المتنبأ بها، بينما تعني قيمة معامل ناش - ساتكليف التي تتساوي فيها الواحد أن النموذج له قدرة عالية على التنبؤ، وتوضح المعادلات التالية الصيغ الرياضية للمعايير السابقة:

تقدير البخرنتح المرجعي يعتمد بدرجة أساسية على الظروف المناخية والموقع الجغرافي، ففي حين أن تقديرات البخرنتح المرجعي في المناطق شبه الجافة كانت عالية عند استخدام طريقة بلاني - كريدل المعدلة، إلا أن طريقة هارجريفس - سماني كانت تقديراتها منخفضة، وهذا يتطابق مع العديد من الدراسات المشابهة في المناطق شبه الجافة مثل (Fontenot, 2004 and George et al., 2002).

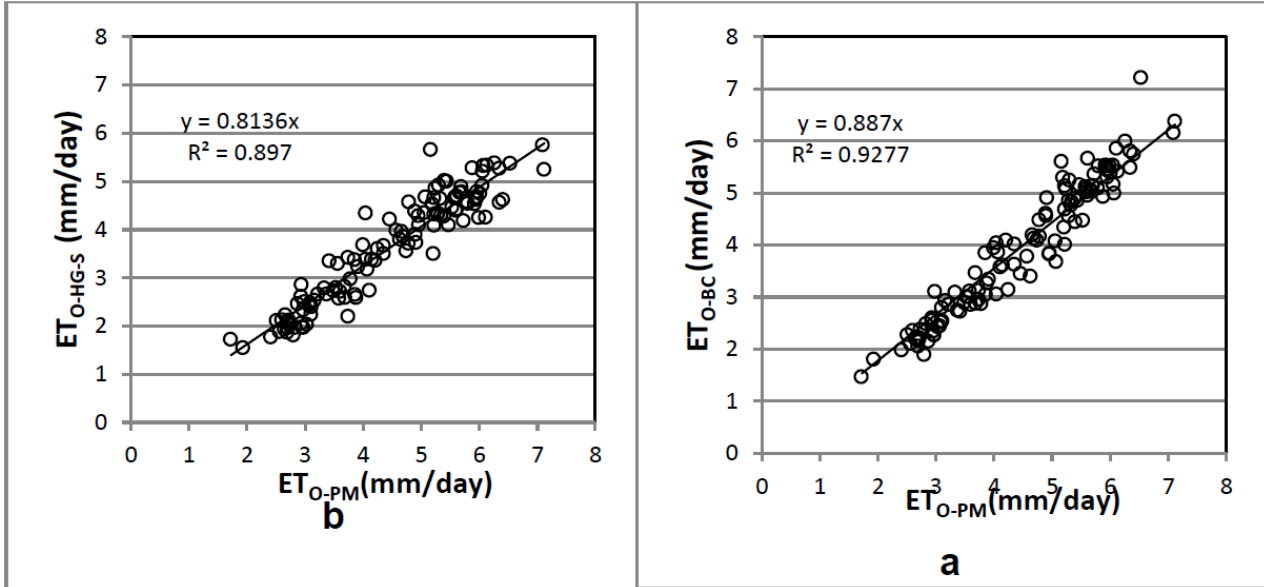
نموذج الشبكات العصبية الاصطناعية

تم استخدام الشبكات العصبية الاصطناعية متعددة الطبقات لتطوير الشبكة العصبية، حيث احتوت شبكة المدخلات ثلاثة عناصر مناخية، بينما احتوت الطبقة المخفية على عدد 3 طبقات، أما طبقة المخرجات فإنها احتوت على مخرج واحد وهو معدل البخرنتح المرجعي، وبالتالي فإنه بالإمكان كتابة بنية الشبكة العصبية على النحو التالي (3-3-1)، ويوضح الشكل (3) بنية الشبكة العصبية التي استعملت في هذه الدراسة.


يوضح الشكل (4) النتائج المتحصل عليها من خلال تطبيق الشبكات العصبية الاصطناعية لتقدير البخرنتح المرجعي خلال مرحلة التدريب، والتي تم استعمال فيها البيانات الشهرية المتاحة موزعة توزيعاً عشوائياً خلال الفترة الزمنية بين سنة 1996 وسنة 2003، ويتضح من خلال الشكل المقاربة الدقيقة لتقدير الشبكات العصبية الاصطناعية مع طريقة بنمان مونيتت المعدلة مقارنة بطريقة هارجريفس - سماني وطريقة بلاني - كريدل المعدلة.

إن مقارنة أداء النماذج السابقة في تقدير البخرنتح مع أداء نموذج الشبكات العصبية خلال مرحلة التدريب وفقاً للمعايير الإحصائية التي تم الإشارة إليها سابقاً يوضح درجة الاختلاف بين الطرائق

فلقد تم تقدير البخرنتح المرجعي باستخدام كلا من طريقة بنمان مونيتت المعدلة وطريقة بلاني - كريدل المعدلة وطريقة هارجريفس - سماني، للفترة الزمنية 1996 وحتى 2005. يوضح الشكل (2) قيم البخرنتح المرجعي كما تم تقديره باستخدام طريقة بلاني - كريدل المعدلة وطريقة هارجريفس - سماني مقارنة بطريقة بنمان مونيتت المعدلة. كما أظهرت نتائج المقارنة أنه على الرغم من انخفاض تقديرات البخرنتح المرجعي لكلا الطريقتين عن تلك المقدرة باستخدام طريقة بنمان مونيتت المعدلة، إلا أن طريقة بلاني - كريدل المعدلة أظهرت دقة عالية في التقدير مقارنة بطريقة هارجريفس - سماني، ويتضح ذلك من خلال قيم معايير اختبار أداء النماذج حيث كانت قيم MAE ، $RMSE$ ، C^2 ، α ، R^2 تساوي 0.55 (مم/يوم)، 0.62 (مم/يوم)، 0.89، 0.75 و 0.93، على التوالي. وذلك عند استخدام طريقة بلاني - كريدل المعدلة. أما قيم معايير اختبار الأداء عند استخدام طريقة هارجريفس - سماني فكانت 0.85 (مم/يوم)، 0.81 (مم/يوم)، 0.45، 0.94، 0.90 وذلك لقيم كل من MAE ، $RMSE$ ، C^2 ، α ، R^2 ، على التوالي. إن ارتفاع دقة طريقة بلاني - كريدل المعدلة مقارنة بطريقة هارجريفس - سماني تعزى إلى احتواء طريقة بلاني - كريدل المعدلة على معاملات تعديل يدخل في حسابها تأثير بعض العوامل التي تضمنتها طريقة بنمان مونيتت المعدلة والتي تشمل سرعة الرياح عند ارتفاع 2 متر، والنسبة المئوية للرطوبة النسبية بالإضافة إلى نسبة ساعات السطوع الفعلي إلى ساعات السطوع الممكنة، بينما لا تتضمن معادلة هارجريفس - سماني إدخال أي من العوامل السابقة كمعاملات تعديل. إن أداء طريقة بلاني - كريدل المعدلة وطريقة هارجريفس - سماني في



شكل 2. مقارنة قيم البخرنتج المقدرة بطريقة بلاني - كريدل المعدلة (a) وطريقة هارجريفس - سماني (b) مع قيم البخرنتج المرجعي المحسوب من معادلة بنهان مونيتيت المعدلة لنفس البيانات



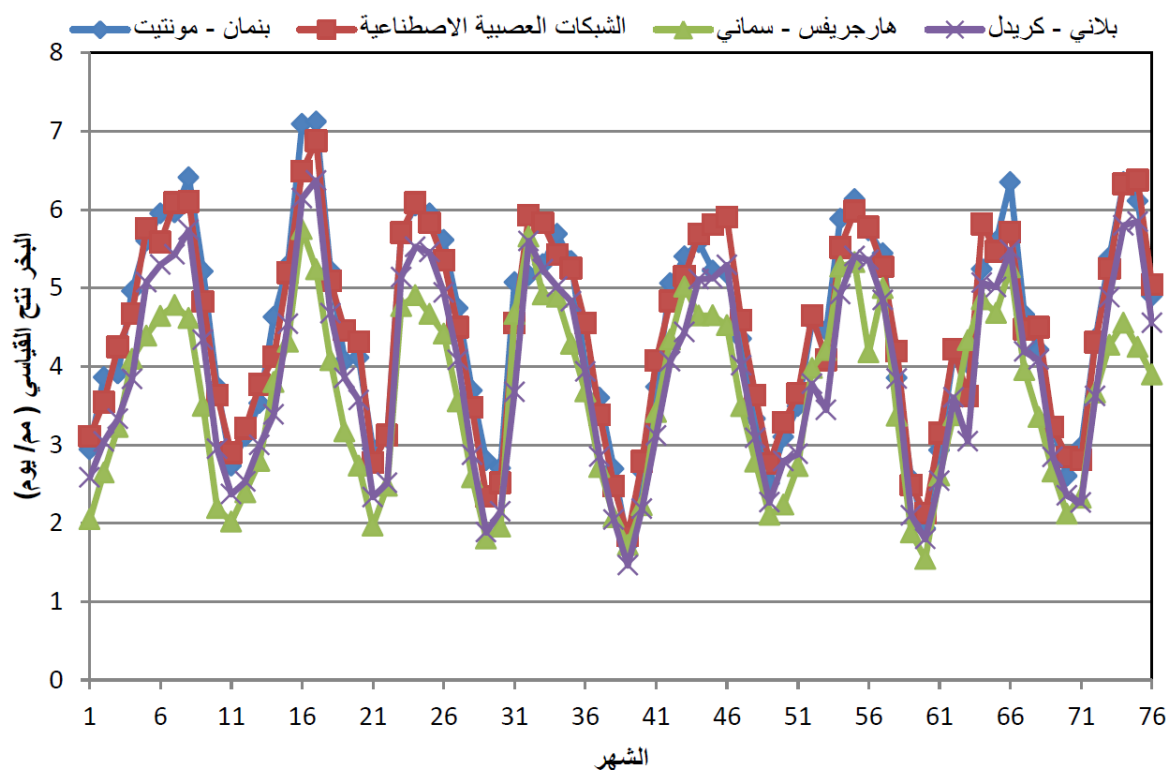
شكل 3. بنية الشبكة العصبية

المختلفة، ويوضح الجدول (1) قيم تلك المعايير الإحصائية، من خلال تلك المعايير يتضح جلياً الأداء العالي للشبكات العصبية الاصطناعية خلال مرحلة التدريب لتقدير البخرنتح المرجعي، ومن ثم فانه بالإمكان استعمال تلك الشبكات العصبية الاصطناعية التي تم تطويرها لتقدير البخرنتح المرجعي، وحتى يصبح بالإمكان إجراء تقييم أكثر فاعلية، تم استقطاع جزءاً من البيانات الشهرية المتاحة، بحيث يتم استعمالها لغرض اختبار أداء النموذج المطور. إن تلك البيانات لم يتم استعمالها خلال مرحلة التدريب، ومن ثم فإنها توفر إمكانية إجراء اختبار للشبكات العصبية التي تم تطويرها. في هذا الصدد، تم اختيار البيانات الشهرية المتوفرة لسنتي 2004 و2005، حيث تم إدخال بيانات المدخلات والتي اشتملت على متوسط درجة الحرارة الشهرية، ومتوسط الرطوبة النسبية شهرياً، وكذلك متوسط الإشعاع الشمسي. يوضح الشكلين (5) و(6) النتائج المتحصل عليها لقيم البخرنتح المرجعي من الشبكات العصبية الاصطناعية ومن النماذج المختلفة، والمتمثلة في بنمان مونتيت المعدلة وهارجريفس - سماني وبلاني - كريدل المعدلة لسنتي 2004 و2005، على التوالي، من خلال الشكلين يتضح مدى تطابق نتائج الشبكات العصبية الاصطناعية مع تلك المتحصل عليها من طريقة بنمان مونتيت المعدلة القياسية مقارنة بالطرائق الأخرى وذلك خلال أشهر السنة المختلفة، ففي حين يلاحظ تطابق نتائج طريقة بلاني - كريدل المعدلة مع طريقة بنمان مونتيت المعدلة في بعض الأشهر، إلا أن طريقة هارجريفس - سماني تبدي سلوكاً أقل دقة من الطرائق الأخرى.

الخلاصة

نظر لصعوبة تقدير البخرنتح المرجعي بالطرائق المباشرة بسبب طول وقت التجارب اللازمة لتقديره وتكلفتها العالية، يلجأ المهتمون بحساب البخرنتح المرجعي إلى استخدام الطرائق غير المباشرة والتي تعتمد درجة دقتها على مدى توفر البيانات للعوامل المناخية المختلفة. إلا أن توفر البيانات المناخية لكامل عوامل المناخ يعد مشكلة كبيرة في الدول النامية ومنها ليبيا، وللتغلب على هذه المشكلة تم اللجوء إلى طرائق تقدير البخرنتح المرجعي التي تتطلب متغيراتها بيانات مناخية

تقييم أداء النماذج المستعملة في تقدير البخرنتح المرجعي (جدول 2)، فإن طريقة الشبكات العصبية أظهرت دقة عالية تليها طريقة بلاني - كريدل المعدلة ثم طريقة هارجريفس - سماني، فعلى سبيل المثال فإن قيم RMSE كانت 0.33 مم/ يوم، و0.85 مم/ يوم، و0.56 مم/ يوم وذلك وفقاً لطريقة الشبكات العصبية الاصطناعية، هارجريفس - سماني و بلاني- كريدل المعدلة على التوالي، ومن خلال معاينة معامل معادلة الانحدار (α) فإن النسبة المئوية لانحراف القيم المتنبأ بها كانت $+2\%$ ، -18% و -10% وذلك وفقاً لطريقة الشبكات العصبية الاصطناعية، هارجريفس - سماني وبلاني - كريدل المعدلة، على التوالي. إن الدقة العالية للشبكات العصبية الاصطناعية في تقدير معدل البخرنتح المرجعي يعزى إلى قدرتها وخصائصها التركيبية والوظيفية في نمذجة العلاقات غير الخطية، فلقد أوضح كل من (Sudheer et al., 2003, and Kumar et al., 2002) أن كفاءة الشبكات العصبية الاصطناعية لتقدير البخرنتح المرجعي أعلى من الطرائق التقليدية.




شكل 4. البخرنتج المرجعي المقدر باستخدام الشبكات العصبية الاصطناعية خلال مرحلة التدريب مقارنة بطريقة بنمان مونتيت المعدلة كطريقة قياسية وطريقة بلاني - كريدل المعدلة وهارجريفس - سماني.

جدول 1. أداء الشبكات العصبية الاصطناعية لتقدير البخرنتج المرجعي خلال مرحلة التدريب مقارنة بالطرائق الأخرى


الطريقة	متوسط الخطأ المطلق (مم / يوم)	الجذر التربيعي لمربع الخطأ (مم / يوم)	معامل ناش-ساتكليف (نسبة)	معامل الانحدار	معامل التحديد (%)
الشبكات العصبية الاصطناعية	0.25	0.30	0.94	0.995	0.94
هارجريفس سماني المعدلة	0.85	0.94	0.45	0.815	0.88
بلاني كريدل المعدلة	0.44	0.55	0.81	0.882	0.94

جدول 2. أداء الشبكات العصبية الاصطناعية لتقدير البخرنتج المرجعي خلال مرحلة التحقق مقارنة بالطرائق الأخرى

الطريقة	متوسط الخطأ المطلق (مم / يوم)	الجذر التربيعي لمربع الخطأ (مم / يوم)	معامل ناش-ساتكليف (نسبة)	معامل الانحدار	معامل التحديد (%)
الشبكات العصبية الاصطناعية	0.25	0.33	0.92	1.02	0.94
هارجريفس سماني المعدلة	0.80	0.85	0.52	0.82	0.93
بلاني كريدل المعدلة	0.47	0.56	0.80	0.90	0.93



شكل 5. البخرنتح المرجعي المقدر باستخدام الشبكات العصبية الاصطناعية خلال مرحلة التحقق مقارنة بطريقة بنان مونتيت المعدلة كطريقة قياسية وطريقة بلاني - كريدل المعدلة وهارجريفس - سماني لسنة 2004.



شكل 6. البخرنتح المرجعي المقدر باستخدام الشبكات العصبية الاصطناعية خلال مرحلة التحقق مقارنة بطريقة بنان مونتيت المعدلة كطريقة قياسية وطريقة بلاني - كريدل المعدلة وهارجريفس - سماني لسنة 2005.

المراجع

1. Alexandris, S., Kerkides, P., and Liakatas, A. 2006. Daily reference evapotranspiration estimates by the "Co-pais" approach. Agricultural Water Management. 82: 371-386.
2. Allen. R.G., Pereira L. S., Raes D. and Smith M. 1998. FAO Irrigation and Drainage Paper, No. 56. Food and Agriculture Organization. Rome, pp. 300.
3. Arca, B., Benincasa, F., Vincenzi, M. de., and Ventura, A. 1998. Neural networks for simulation of evaporation from class- A pan. Irrigazione e Drenaggio. 45(1): 55-60.
4. Arca, B., Pellizzaro, G., Canu, A. and Vargiu, A. 2004. Use of Neural Networks to short- term forecast of airborne pollen data. 16th Biometeorology and Aerobiology. American Meteorological Society. Vancouver, BC. 1-13
5. Chowdhary, A., and Shrivastava, R. K. 2010. Reference crop evapotranspiration estimation using Artificial Neural Networks. International Journal of Engineering Science and Technology. 2(9): 4205-4212.
6. Demuth, H., and Beale, M. 1998. Neural network toolbox for use with MATLAB. The Math Works Inc. Natick., Mass, pp. 422.
7. Doorenbos, J., and Pruitt W.O. 1977. Guidelines for predicting crop water requirements. FAO Irrigation and Drainage Paper. No. 24. Food and Agriculture Organization. Rome, pp. 156.
8. Dowla, F.U., and Rogers L. L. 1995. Solving problems in environmental engineering and geoscience with artificial neural networks, The MIT Press., Cambridge, pp. 310.
9. Ekhmaj A.I. 2012. Prediction of Evapotranspiration using Artificial Neural Networks Model. Buhri Arifin, Siti Nur`Afifah Jaafar and Sayed Mohamed. Universiti Malaysia Terengganu. Terengganu, Malaysia. 937- 943.
10. Food and Agricultural Organization (FAO). 2000. Crop-Wat 8.0 for Windows, Food and Agriculture Organization. Rome, Italy. Software.
11. Fontenot, R. L. 2004. An evaluation of reference evapotranspiration models in Louisiana. Master Thesis, Louisiana State University. Louisiana State, USA.
12. French, M. N., Krajewski, W. F., and Cuykendall, R. R. 1992. Rainfall forecasting in space and time using a

قليلة بحيث تكون متوفرة ومتاحة. إلا أن استخدام هذه المعادلات التجريبية يكون في الغالب على حساب درجة الدقة في التقدير، حيث تتفاوت هذه المعادلات في مدى دقتها، وفي هذه الدراسة تم استخدام الشبكات العصبية الاصطناعية من أجل تحسين تقدير البخرنتح قياسي باستخدام بيانات متوسط درجات الحرارة والرطوبة النسبية والإشعاع الشمسي لتقدير البخرنتح المرجعي، وتمت مقارنتها بقيمة البخرنتح المرجعي المحسوب بطريقة بلاني - كريدل المعدلة وطريقة هارجريفس - سماني، حيث استعملت البيانات المتوفرة من محطة الأرصاد لمدينة سرت. وقد أظهرت النتائج أنه بالاعتماد على طريقة بنمان مونتيت المعدلة كطريقة قياسية لتقدير البخرنتح المرجعي، إن طريقة بلاني - كريدل المعدلة كانت أكثر دقة من طريقة هارجريفس - سماني. وأوضحت النتائج أن نموذج الشبكات العصبية الاصطناعية الذي تم تطويره في هذه الدراسة أظهر دقة وقابلية عالية للتنبؤ بالبخرنتح المرجعي وذلك مقارنة بطريقتي بلاني - كريدل المعدلة وهارجريفس - سماني. توصي الدراسة باختبار نموذج الشبكات العصبية الاصطناعية على بيانات مناخية مجمعة من كامل ليبيا، وباستخدام متغيرات مناخية متاحة بحيث يمكن تطوير نموذج فعال يمكن استخدامه وبدقة عالية في كل المناطق بليبيا.

23. Patterson, D.W.1996. Artificial Neural Networks: theory and applications, Simon and Schuster., Singapore, pp. 477.
24. Schultz, A., Wieland, R. and Baumann, A. 1995. The use of neural networks in agroecological modelling. IFAC. Elsevier Science and Technology. Wageningen. 55-60.
25. Shukla, M. B., Kok, R., Prasher, S. O., Clark, G., and Larcroix, R. 1996. Use of artificial neural network in transient drainage design. Transactions of the ASAE. 39(1):119–124.
26. Smith, M.1992. Report on the expert consultation on revision of FAO methodologies for crop water requirements. Food Agriculture Organization. Rome, pp.54
27. Sudheer, K. P., Gosain, A. K., and Ramasastri, K. S. 2003. Estimating actual evapotranspiration from limited climatic data using Neural Computing Technique. Journal of Irrigation and Drainage Engineering. 129(3): 214-218.
28. Ventura, F., Spano, D., Duce, P., and Snyder, R. L. 1999. An evaluation of common evapotranspiration equations. Irrigation Sciences.18:163–170.
29. Wang, Y. M., Traore, S., and Kerh, T. 2008. Neural Network approach for estimating reference evapotranspiration from limited climatic data in Burkina Faso. Wseas Transactions on Computers. 6(7): 704-713.
30. Yang, C., Prasher, S., Sreekanth, S., Patni, N. K., and Masse, L. 1997. An artificial neural network for simulating pesticide concentration in soil. Transactions of the ASAE. 40:1285–1294.
31. Yang, C., Larcroix, R., and Prasher, S. O. 1996. Application of artificial neural network to land drainage engineering. Transactions of the ASAE. 39: 525–533.
32. Zanetti, S. S., Sousa, E. F., Oliveira, V. P., Almeida, F. T., and Bernardo, S. 2007. Estimating evapotranspiration using Artificial Neural Network and minimum climatological data. Journal of Irrigation and Drainage Engineering. 133(2): 83-89.
- neural network. Journal of Hydrology. 137(1-4):1-31.
13. George, B.A., Reddy, B. R. S., Raghuwanshi, N. S., and Wallender, W. W. 2002. Decision support system for estimating reference evapotranspiration. Journal of Irrigation and Drainage Engineering. 128:1-10.
14. Georgiou, P.E., and Papamichail, D.M. 2008. Optimization model of an irrigation reservoir for water allocation and crop planning under various weather conditions. Irrigation Science. 26: 487-504. Grazhdanis. and Ahmeti, A. 2010. Estimating reference evapotranspiration using two different models of Penman-Monteith method for climatic conditions of Albania. Balwos 2010, Artificial Intelligence in Agriculture. Ohrid, Republic of Macedonia.1-11.
15. Hargreaves, G.H., and Samani, Z. A. 1985. Reference crop evapotranspiration from temperature. Applied Engineering in Agriculture. 1(2): 96-99.
16. Jensen, M. E., Burman, R. D. and Allen, R. G. 1990. Evapotranspiration and irrigation water requirements, ASCE Manuals and Reports on Engineering Practice n° 70., New York, pp. 332.
17. Jensen, D.T., Hargreaves, G.H., Temesgen, B., and Allen, R.G. 1997. Computation of ETo under nonideal conditions. Journal of Irrigation and Drainage Engineering.123(5): 394 - 400.
18. Kumar. M., Raghuwanshi, N., Singh, S. R., Wallender, W. W., and Pruitt, W. O. 2002. Estimating evapotranspiration using Artificial Neural Network. Journal of Irrigation and Drainage Engineering. 128(4): 224-233.
19. Lee, T. S., Najim, M. M., and Aminul, M. H. 2004. Estimating evapotranspiration of irrigated rice at the West coast of the Peninsular of Malaysia. Journal of Applied Irrigation Science. 39: 103-117.
20. Nandagiri, L., and Kovoo, G. R. 2006. Performance evaluation of reference evapotranspiration equations across a range of Indian climates. Journal of Irrigation and Drainage Engineering.132(3): 238-249.
21. Nash, J.E., and Sutcliffe, J. V.1970. River flow forecasting through conceptual models; part I – a discussion of principles. Journal of Hydrology.10: 282–290.
22. Paruelo, M., and Tomasel, F. 1997. Prediction of functional characteristics of ecosystems: a comparison of artificial neural networks and regression models. Ecological Modelling. 98: 173-186.



Estimation of the Reference Evapotranspiration in Sirt Region Using an Artificial Neural Networks

Ahmed Ibrahim Ekhmaj¹, Mustafa ben Zagta², Younes Daw Ezlit¹
and Abubaker Mohamed Shagheb¹

1. Department of Soil and Water - Faculty of Agriculture - University of Tripoli, Libya

2. Faculty of Agriculture - University of Sirt - Libya

Abstract

In this paper, a new method based on Artificial Neural Networks technique has been developed to estimate the reference evapotranspiration (ET₀) in Sirt area. The new method utilizes the average of temperature, relative humidity, and the solar radiation as input data. The ANNs method was compared with Modified Penman Monteith ((FAO – Penman–Monteith), as a standard method. The comparison was also performed with Hargreaves–Samani (1985) and modified Blaney–Criddle (Doorenbos and Pruitt, 1977) methods. Climatic data sourced from Sirt weather station for the period from 1996 until 2005. The results showed very good agreements between ANNs prediction and FAO – Penman Monteith output. This result is evident from the values of standard performance indices, which are mean absolute error (MAE), the root mean square error (RMSE), and coefficient of Nash – Sutcliffe (C₂). The standard performance indices were also better for ANNs compared to the poor values obtained for both Hargreaves–Samani and Blaney–Criddle equations. The percentage of deviation values was +2 % for the ANNs, while it reached –18 % and –10 % for Hargreaves–Samani and Blaney–Criddle equations, respectively. In conclusion, the results showed that the ANNs performed well and confirmed that ANNs method was best to estimate ET₀ compared to Hargreaves – Samani and Blaney–Criddle equations in Sirt area.

Key words: Reference evapotranspiration, artificial neural networks, penman-montheith, hargreaves-samani, blany-criddle, Sirt.