

تقدير التبخر اليومي في الساحل السوري باستخدام برمجة التعبير الجيني ونظام الاستدلال العصبي الضبابي التكيفي

ماريا يوسف عباس، غطفان عبد الكريم عمار، منذر علي حماد
قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سوريا.
maria.abbass1985@gmail.com

Received:20/06/2020
Accepted:20/07/2020

المستخلص- يُعتبر التبخر مكوناً رئيسياً للدورة الهيدرولوجية، ومن الضروري تقديره بدقة من أجل تنمية وإدارة الموارد المائية، فهو يؤثر على كمية الجريان، وحجم التخزين السطحي، وعلى الاحتياج المائي للنبات. ويتطلب تقديره معرفة العديد من العناصر المناخية. على الرغم من أن هناك صيغاً تجريبية متوفرة لتقدير التبخر، لكن بعض هذه الطرائق صالحة فقط في ظروف مناخية محددة ولا يمكن تطبيقها في ظروف مختلفة. لذلك يهدف هذا البحث إلى تقييم دقة برمجة التعبير الجيني (GEP) ونظام الاستدلال العصبي الضبابي التكيفي (ANFIS)، في تقدير التبخر اليومي في المنطقة الهضابية في الساحل السوري، ومقارنة نتائجها مع نتائج معادلة إيفانوف المعتمدة في سوريا لحساب التبخر في الساحل السوري. ومن أجل ذلك قمنا ببناء نماذج GEP و ANFIS باستخدام بيانات مناخية متوفرة، أخذت من خمس محطات مناخية موزعة على كامل مساحة المنطقة المدروسة ومتوزعة على ارتفاعات مختلفة. وكانت المعايير الإحصائية المستخدمة لتقييم دقة النماذج هي: جذر متوسط مربع الخطأ (RMSE) ومعامل الارتباط (R)، وقد بينت نتائج المقارنة تفوق GEP على ANFIS في تقدير التبخر الإثنائي. وتفوق كلا النموذجين على معادلة إيفانوف. وأعطى النموذج الذي مدخلاته متوسط درجة الحرارة والرطوبة النسبية وعدد ساعات السطوح الشمسي والارتفاع أفضل تقديراً للتبخر اليومي، حيث بلغت قيمة RMSE و R لمجموعة الاختبار في نموذجي GEP و ANFIS القيم التالية على الترتيب (RMSE=0.55mm/day)، $R = 0.94$ ، (RMSE=0.7mm/day)، $R = 0.92$. توصي الدراسة بالتوسع في استخدام GEP في دراسة الموارد المائية بغرض تحقيق الإدارة المثلى لها.

الكلمات المفتاحية: التبخر، برمجة التعبير الجيني، تقدير، الاستدلال العصبي الضبابي التكيفي.

ABSTRACT-The evaporation is one of the basic components of the hydrologic cycle. It is necessary to accurately estimate it for the development and management of water resources, it affects the amount of runoff, the capacity of surface reservoirs, and the plant's need for water, and it requires knowledge of many climatic variables. Although, there are many empirical formulas available for evaporation estimate, but their performances are not all satisfactory due to the complicated nature of the evaporation process. Therefore, the aim of this research is to evaluate the accuracy of Gene Expression Programming (GEP) and Adaptive Neuro-Fuzzy Inference System (ANFIS) for estimating daily evaporation in the Syrian coast, and compare their results with the results of the Ivanov equation. For this, we built GEP and ANFIS models using available climate data, taken from five climatic stations spread over the studied entire area and located at different heights. The statistical parameters used to evaluate the accuracy of the models were: Root Mean Squared Error (RMSE) and correlation coefficient (R). Comparative results showed that GEP is better than ANFIS for estimating pan evaporation. Both models outperformed the Ivanov equation. the model which including temperature, relative humidity, solar radiation and elevation is the best for estimating daily evaporation in the Syrian coast, where the values of RMSE and R for the test group in GEP and ANFIS models were respectively (0.55mm / day), $R = 0.94$, (0.7mm/ day), $R = 0.92$.

مقدمة

الشمسي، سرعة الرياح، والرطوبة النسبية بتأخر زمني ليوم واحد، يزيد من دقة نماذج GEP، ANFIS و ANN^[4]. قام Ghorbani, M. A. et al (2012) بنمذجة التبخر اليومي باستخدام البرمجة الجينية (GP)، اعتماداً على خمسة متغيرات مناخية تتمثل بدرجة حرارة الهواء، الإشعاع الشمسي، سرعة الرياح، الضغط والرطوبة، لمحطتين مناخيتين في كاليفورنيا، الولايات المتحدة الأمريكية. ومن خلال مقارنة وتقييم أداء نماذج GP مع أداء نموذجين جاهزين للكفاء الاصطناعي (ANN) و (ANFIS)، ونموذج (SS) Stephen-Stewart، باستخدام مجموعة من المعايير الإحصائية متضمنة معامل التحديد (R^2)، متوسط مربع الخطأ (MSE)، متوسط الخطأ النسبي المطلق (MARE)، تبين أن نموذج GP قادر على نمذجة التبخر بدقة جيدة^[5].

كما استُخدم نموذج الاستدلال الضبابي العصبي التكيفي في تقدير التبخر في أنطاليا وأنطاكية في تركيا^[6]، كما بينت دراسة تفوق ANFIS على ANN في تقدير التبخر في ولاية إلينوي الأمريكية^[7]، وتوقفاً على معادلة بنمان التجريبية في تقدير التبخر اليومي في جنوب غرب تركيا^[8]، وماليزيا^[9]. وفي ولايتين في كوريا الجنوبية، حيث كانت نتائج نماذج ANN المتضمنة بيانات ذات تأخر زمني هي الأفضل^[10].

أهمية البحث وأهدافه

التبخر ظاهرة معقدة وغير خطية وتتأثر بالعديد من العناصر المناخية، ومن الضروري تقديره بدقة من أجل تنمية وإدارة الموارد المائية. لذلك فإن هدف هذه الدراسة إيجاد علاقة باستخدام برمجة التعبير الجيني (GEP) ونظام الاستدلال العصبي الضبابي التكيفي (ANFIS)، لتقدير التبخر اليومي في المنطقة الهضابية في الساحل السوري، ومقارنة نتائجها مع نتائج معادلة إيفانوف المعتمدة في سوريا لحساب التبخر في الساحل السوري، وذلك اعتماداً على بيانات مناخية متوفرة (درجة الحرارة، الرطوبة النسبية، عدد ساعات السطوع الشمسي والتبخر)، أخذت من خمس محطات مناخية (محطة سد بلوران، محطة سد 16 تشرين، محطة اللاذقية، محطة سد السخابة ومحطة سد الباسل)، موزعة على كامل مساحة المنطقة المدروسة ومتوضعة على ارتفاعات مختلفة.

منطقة البحث

تقع المنطقة الساحلية بين خطي عرض $34^{\circ} 34'$ / 35° شمالاً وخطي طول $35^{\circ} 42'$ / $36^{\circ} 26'$ شرقاً، والمساحة الكلية للمنطقة 5070 km^2 . يحدها من الشمال تركيا

التبخر هو العملية التي يتم فيها تحويل المياه السائلة إلى بخار ماء. ويُعتبر التبخر مكوناً رئيسياً للدورة الهيدرولوجية، ومن الضروري تقديره بدقة من أجل تنمية وإدارة الموارد المائية، فهو يؤثر على كمية الجريان، وحجم التخزين السطحي، وعلى الاحتياج المائي للنبات^[11].

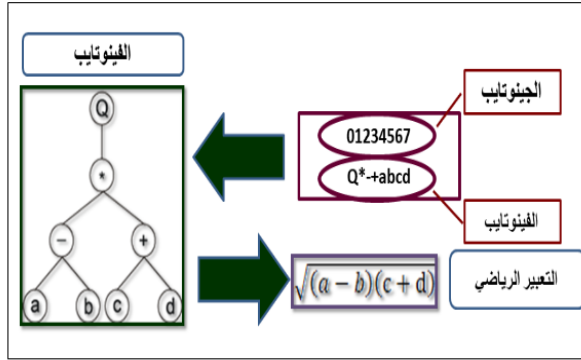
يُقدَّر التبخر بالطرائق المباشرة، متمثلةً بحوض التبخر، والذي يوفر قياساً للتأثير المتكامل، للإشعاع الصافي، والرياح، ودرجة الحرارة، والرطوبة، على التبخر من المسطحات المائية المفتوحة. والطرائق غير المباشرة، متمثلةً بالصيغ التجريبية، والتي تستخدم البيانات المناخية (حرارة، رطوبة، إشعاع شمسي وسرعة رياح) لتقدير التبخر. بعض الطرائق صالحة فقط في ظروف مناخية محددة ولا يمكن تطبيقها في ظروف مختلفة^[11].

الدراسات المرجعية

في الآونة الأخيرة برزت تقانات الذكاء الاصطناعي، مما حفَّز الباحثين على استخدام هذه التقانات في عمليات النمذجة الرياضية لمختلف المشكلات الهندسية^[2]، بما في ذلك عملية التبخر، حيث طوّر Terzi, O. and Keskin, M. E. (2005) نموذجاً لتقدير التبخر اليومي من بحيرة Egridir، باستخدام برمجة التعبير الجيني (GEP)، حيث استُخدمت درجة حرارة الهواء، الإشعاع الشمسي والرطوبة النسبية، كمدخلات لبناء النموذج، وتمت مقارنة نتائج النموذج مع قيم التبخر اليومي المقدر من معادلة بنمان. بينت النتائج إمكانية اعتماد نموذج GEP (الذي يتطلب بيانات مناخية أقل من معادلة بنمان) كبديل لمعادلة بنمان^[3].

كما قام Shiri, J. and Kisi, O. (2011) بتطوير نماذج مختلفة لتقدير التبخر الإنثائي اليومي في Khozestan جنوب غرب إيران، باستخدام برمجة التعبير الجيني GEP، نظام الاستدلال العصبي الضبابي التكيفي ANFIS والشبكات العصبية ANN، وذلك اعتماداً على بيانات التبخر اليومي، درجة الحرارة، الإشعاع الشمسي، الرطوبة النسبية وسرعة الرياح. كما تمت مقارنة هذه النماذج مع نموذجي (SS) Stephen-Stewart و Christiansen. بينت نتائج المقارنة تفوق نماذج GEP، ANFIS و ANN على نموذجي SS و Christiansen، وتفوق GEP على ANFIS و ANN، لقدرته على إعطاء تعبير رياضي يربط بين التبخر والمتغيرات المناخية، إضافةً إلى دقته العالية. وأشارت الدراسة إلى أن إضافة درجة حرارة الهواء، الإشعاع

وتأخذ من البرمجة الجينية التراكيب الشجرية (كيانات غير خطية) بأحجام وأشكال مختلفة. تعمل الكروموسومات الخطية في نظام GEP كجينوتايب، بينما تمثل التراكيب الشجرية الفينوتايب. تكمن أهمية نظام الجينوتايب-الفينوتايب في خلق الكروموسومات البسيطة للبرامج، بحيث تضمن الصلابة الهيكلية للبرامج المرزومة، وتكون التعابير الناتجة عنها تعابير صحيحة. ويتم استنتاج التعبير الرياضي من الفينوتايب باستخدام لغة Karva، يوضح الشكل (2) مثالاً عن الجينوتايب والفينوتايب في GEP [15].



الشكل 2: مثال عن الجينوتايب والفينوتايب في GEP

من أهم ميزات برمجة التعبير الجيني أنها لا تقترض أي شكل مسبق لتتابع الحل، وقادرة على إيجاد معادلة أو صيغة للعلاقة بين متغيرات الدخل والخرج [13]. تلخص الخطوات الأساسية لبرمجة التعبير الجيني كما يلي [16] [17]:

- أ. اختيار مجموعة المحطات الطرفية ومجموعة الدوال لخلق الكروموسومات للمجتمع الأولي.
- ب. اختيار تابع الملائمة.
- ت. اختيار البنية الهيكلية للكروموسومات.
- ث. اختيار تابع الوصل.
- ج. اختيار العمليات الجينية (الطفرة، التبديل، العكس وإعادة التجميع).

نظام الاستدلال العصبي الضبابي التكيفي ANFIS

ANFIS هو أحد أنظمة الذكاء الاصطناعي وعبارة عن نظام هجين من الشبكات العصبية الاصطناعية والمنطق الضبابي. يُستخدم نظام ANFIS لنمذجة التوابع غير الخطية، والتنبؤ بسلسلة زمنية [18] [19].

ومن الجنوب لبنان، وتمتد منطقة الدراسة بشكل موازي لشاطئ البحر بطول 120km (عدا منطقة اسكندرون) ويعرض وسطي 45km، ويتدرج الارتفاع من المنسوب (0) عند شاطئ البحر، ويصل حتى ارتفاع 1350m في المرتفعات الجبلية وبعض القمم إلى ارتفاع 1575m. ويوضح الشكل رقم (1) منطقة الساحل السوري، وتوزع المحطات المناخية الست (محطة سد بلوران، محطة سد 16 تشرين، محطة اللاذقية، محطة سد الثورة، محطة سد السخابة ومحطة سد الباسل)، والتي أُخذت منها البيانات المناخية المستخدمة في هذه الدراسة (حرارة، رطوبة، إشعاع شمسي وتبخّر). حيث استُخدمت البيانات المأخوذة من محطة سد الثورة للتحقق من دقة النماذج التي تم بناؤها.




الشكل 1: منطقة الدراسة (الساحل السوري)

طرائق البحث ومواد

برمجة التعبير الجيني GEP

تعرف برمجة التعبير الجيني بأنها خوارزمية تطويرية، تخلق برامج حاسوبية أو نماذج، هذه النماذج الحاسوبية عبارة عن تراكيب شجرية معقدة تتعلم وتتكيف بتغيير حجمها، أشكالها وتركيبها مثل الكائن الحي. ترمز هذه البرامج، مثل الكائنات الحية، في كروموسومات خطية بسيطة بطول ثابت. لذلك تعتبر GEP نظام جينوتايب-فينوتايب، الجينوتايب (الكروموسومات متعدد الجينات) لإجراء التعديلات الجينية (الطفرة، التكرار، إعادة التجميع...)، والفينوتايب (برامج) لاستكشاف البيئة والتكيف معها [11] [12] [13] [14] [15]. وتعتبر GEP الأكثر تطوراً بين الخوارزميات التطورية [11] [13]، اشتقت طرائق بنائها من الخوارزميات الجينية (GA) والبرمجة الجينية (GP) [10] [16] [17]. حيث تأخذ برمجة التعبير الجيني من الخوارزمية الجينية الكروموسومات الخطية بطول ثابت،



الشكل 3: البنية الهيكلية لـ ANFIS

النتائج والمناقشة

اختيار بارامترات بناء النماذج

بُنيت نماذج GEP و ANFIS، بعد جمع البيانات اللازمة من ست محطات مناخية موزعة على كامل مساحة الساحل السوري، ومتوزعة على ارتفاعات مختلفة، متمثلةً بمحطات سد 16 تشرين، سد بلوران، اللاذقية، سد السخابة وسد الباسل، وسوف يتم تحقيق النموذج على بيانات محطة سد الثورة التي لم تدخل في بناء النماذج، ومقارنة نتائجها مع نتائج معادلة إيفانوف، ويوضح الجدول (1) موقع المحطات وارتفاعاتها. تضمنت البيانات المستخدمة القيم اليومية لكل من متوسط درجة الحرارة T_{avg} ، متوسط الرطوبة النسبية RH_{avg} ، وعدد ساعات السطوع الشمسي n والتبخر الإنشائي اليومي E_p ، للفترة الممتدة من 2007/10/1 إلى 2017/12/31.

تم بناء نماذج ANFIS، باستخدام برنامج الماتلاب، حيث استُخدم نهج sugeno الضبابي للحصول على قيم متغيرات الخرج من متغيرات الدخل المقدمة إلى بنية نظام الاستدلال العصبي الضبابي التكيفي، وتم اختيار تابع العضوية "gaussmf" لمتغيرات الدخل، وعدد توابع العضوية لكل متغير (4).

أما نماذج GEP فقد بُنيت باستخدام برنامج GeneXprotools، حيث تضمنت المرحلة الأولى لبناء النماذج اختيار المحطات الطرفية متمثلةً بالبيانات المناخية من T_{avg} و RH_{avg} و n ، ومجموعة الدوال لخلق الكروموسومات الأولية فكانت (+, -, tanh, x^2 , x^3 , $\ln(x)$, \div , \times). تتضمن المرحلة الثانية اختيار تابع الملاءمة، وهنا تم اختيار جذر متوسط مربع الخطأ لتقويم الملائمة. وفي المرحلة الثالثة تم اختيار البنية الهيكلية للكروموسومات، عدد الكروموسومات 50، طول الرأس في الجين 8، وعدد الجينات في كل كروموسوم 3. أما المرحلة الرابعة

الفكرة الأساسية من دمج الشبكة العصبية مع النظام الضبابي هو تصميم نظام يستخدم النظام الضبابي لتمثيل المعرفة البشرية وعمليات التفكير بطريقة قابلة للتفسير على شكل قواعد ضبابية if-then، وتكون لديه القدرة على التعلم من الشبكة العصبية التي يمكنها ضبط بارامترات توابع العضوية والقواعد اللغوية مباشرة من البيانات من أجل تحسين أداء النظام [20].

الشبكة التكيفية ANFIS عبارة عن شبكة عصبية بخمس طبقات أمامية التغذية مكونة من العقد والوصلات الاتجاهية، الشكل (3)، يتم تحديد سلوك المدخلات والمخرجات بشكل عام من خلال قيم مجموعة من البارامترات القابلة للتعديل التي يتم توصيل العقد من خلالها. يستخدم نظام ANFIS خوارزمية التعلم الهجين لتحديد البارامترات لنظام الاستدلال الضبابي نوع Sugeno. وهذه الخوارزمية تدمج بين طريقة المربعات الصغرى وطريقة انحدار التدرج العكسي لتدريب بارامترات تابع العضوية FIS لمحاكاة مجموعة بيانات التدريب المعطاة [18] [21].

وتتعلم الشبكة في مرحلتين رئيسيتين: في المرحلة الأمامية من خوارزمية التعلم، يتم حساب مخرجات الخلايا العصبية طبقة بعد طبقة، ويتم تحديد البارامترات التابعة بواسطة طريقة المربعات الصغرى (LSE) للحصول على مخرج نهائي وحيد. وفي المرحلة الخلفية، تنتشر إشارات الخطأ، وهي مشتقات الخطأ التريبي المتعلقة بخرج كل عقدة، إلى الوراء من طبقة المخرجات إلى طبقة الدخل. في هذا التمرير العكسي، يتم تحديث البارامترات المفروضة من خلال خوارزمية تدرج الانحدار. مرحلة التعلم أو التدريب في الشبكة العصبية هي عملية لتحديد قيم بارامترات توابع العضوية لنتناسب مع بيانات التدريب [20] [22].

معادلة إيفانوف

تعطى معادلة إيفانوف بالشكل التالي [23]:

$$E_{pan} = 0.0018 (t + 25)^2 (100 - h_r)$$

حيث أن t : متوسط درجة الحرارة الشهرية ($^{\circ}\text{C}$)، h_r : متوسط الرطوبة النسبية الشهرية (%).

بناء وتقييم النماذج

فُتِّمَت البيانات إلى مجموعتين بنسبة 70% لمجموعة التدريب و 30% لمجموعة الاختبار، حيث تمت دراسة تحليل الحساسية لمدخلات النموذج، وتحديد البارامترات الأكثر تأثيراً على تقدير التبخر، وذلك من خلال إعداد تسعة نماذج بمُدخلات مختلفة، موضحة في الجدول (3). وقُيِّمَت دقة النماذج باستخدام المعايير الإحصائية متمثلةً بمعامل الارتباط R وجذر متوسط مربع الخطأ $RMSE$.

كانت النتائج متقاربة جداً في نماذج ANFIS ونماذج GEP، حيث بيَّنت النتائج أن درجة الحرارة هي العنصر الأكثر تأثيراً على تقدير التبخر، يليها عدد ساعات السطوع الشمسي، بينما كانت الرطوبة النسبية الأقل تأثيراً. كما تبيَّن أن درجة الحرارة وعدد ساعات السطوع الشمسي هما العنصران الأكثر تأثيراً على تقدير التبخر اليومي. وعند إدخال ارتفاع كل محطة مناخية عن سطح البحر، كأحد مدخلات النموذج، حسن ذلك بشكل كبير من أداء النماذج. ويُفسَّر ذلك، بأن الارتفاع هو أحد العوامل التي تؤثر على الضغط الجوي، الذي يؤثر بدوره على التبخر. حيث أنه كلما زاد الارتفاع عن سطح البحر قل الضغط والعكس صحيح. وهناك علاقة عكسية بين مقدار الضغط الجوي وسرعة عملية التبخر، حيث يؤدي ارتفاع الضغط الجوي إلى التقليل من سرعة انطلاق جزيئات الماء إلى الجو، بينما يساعد انخفاضه على زيادة هذه السرعة، وبالتالي زيادة نشاط التبخر [24].

فقتضمن اختيار تابع الوصل الذي يربط الجينات ضمن كل كروموسوم، ومن الممكن أن يكون الجمع أو الضرب، وهنا تم اختيار الجمع (+). تتضمن المرحلة الأخيرة اختيار العمليات الجينية، مثل الطفرة والتبديل وإعادة التجميع والعكس. ويوضح الجدول (2) البارامترات الخاصة ببناء النموذج.

الجدول 1: مواقع المحطات المناخية وارتفاعها عن سطح البحر

المحطة	الارتفاع (m)	خط الطول	خط العرض
سد بلوران	86	35° 54' 04"	35° 45' 53"
سد 16 تشرين	127	35° 55' 03"	35° 38' 21"
اللاذقية	3	35° 46' 07"	35° 32' 26"
سد الثورة	163	35° 58' 54"	35° 32' 07"
سد السخابة	182	36° 01' 38"	35° 19' 40"
سد الباسل	141	36° 04' 17"	34° 45' 35"

الجدول 2: بارامترات بناء النموذج في GEP

البارامتر	قيمته	البارامتر	قيمته
عدد الكروموسومات	50	معدل الطفرة	0.00138
طول الرأس	8	معدل التبديل	0.00277
عدد الجينات في كل كروموسوم	3	معدل العكس	0.00546
تابع الملائمة	RMSE	معدل إعادة التجميع	0.00277

الجدول 3: القيم الإحصائية (R , $RMSE$) الخاصة بنماذج ANFIS و GEP

رقم النموذج	مدخلات النموذج	GEP		ANFIS							
		مجموعة التدريب		مجموعة الاختبار		مجموعة التدريب				مجموعة الاختبار	
		R	RMSE (mm/d)	R	RMSE (mm/d)	R	RMSE (mm/d)			R	RMSE (mm/d)
1	T_{avg}	0.67	1.21	0.66	1.21	0.72	1.21	0.88	1.19		
2	n	0.57	1.36	0.53	1.36	0.53	1.36	0.39	1.3		
3	RH_{avg}	0.1	1.59	0.12	1.63	0.2	1.63	0.2	1.54		
4	T_{avg}, n	0.75	1.09	0.74	1.08	0.77	1.08	0.86	1.06		
5	T_{avg}, RH_{avg}	0.66	1.22	0.67	1.19	0.71	1.19	0.88	1.17		
6	T_{avg}, RH_{avg}, n	0.74	1.09	0.75	1.08	0.74	1.08	0.84	1.02		
7	T_{avg}, n, Z	0.933	0.58	0.93	0.6	0.95	0.6	0.87	0.52		
8	T_{avg}, RH_{avg}, Z	0.934	0.58	0.93	0.6	0.95	0.6	0.89	0.52		
9	T_{avg}, RH_{avg}, n, Z	0.94	0.55	0.94	0.52	0.92	0.7	0.89	0.46		

الاختبار في نموذج GEP، في حين كانت قيم RMSE و R (0.46mm/day) و (0.89) لمجموعة التدریب، و (0.7mm/day) و (0.92) لمجموعة الاختبار في نموذج ANFIS. كما نلاحظ تفوق نموذج GEP على نموذج ANFIS في مجموعة الاختبار. يبين الجدول (4) معادلة الحساب الخاصة بنماذج GEP (7)، (8)، (9)، والتي أعطت أفضل النتائج.

يوضح الجدول (3) قيم المعاملات الإحصائية لكل نموذج على الترتیب. حيث بیئت النتائج أن النموذج رقم (9) والذي تتضمن مدخلاته متوسط درجة الحرارة، ومتوسط الرطوبة النسبية، وعدد ساعات السطوع الشمسي والارتفاع، هو النموذج الأفضل لتقدير التبخر اليومي في المنطقة الهضابية في الساحل السوري، حيث بلغت قيمة كلٍ من RMSE و R (0.52mm/day) و (0.94) لمجموعة التدریب، و (0.55mm/day) و (0.94) لمجموعة

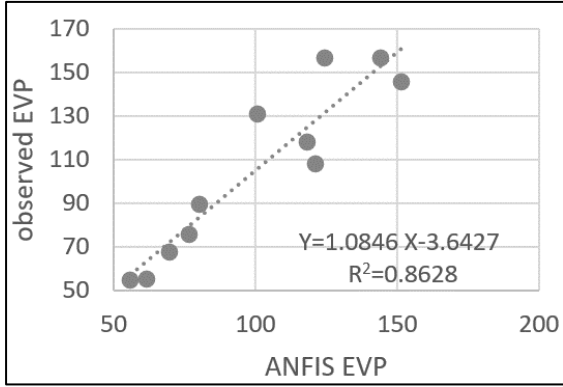
الجدول 4: معادلة الحساب الخاصة بكل نموذج

معادلة الحساب	مدخلات النموذج	رقم النموذج
$E_{pan} = 0.16T_{avg} + \tanh\left(\frac{T_{avg} \cdot n}{Z - 86.32}\right) - 0.083 * n * \tanh(2.38 - Z)$	T_{avg}, n, Z	7
$E_{pan} = \exp[0.055 * T_{avg} * \tanh(0.146 * Z)] + 10^{-6}(T_{avg} + 5.5)^4 + \tanh\left[\tanh\left(\frac{RH_{avg} + Z}{RH_{avg} - Z} + \frac{Z - 9.135}{T_{avg}}\right)\right]$	T_{avg}, RH_{avg}, Z	8
$E_{pan} = 0.2\left(\frac{T_{avg} - 15.33}{Z - 6.09} + T_{avg}\right) + \tanh\left(236.6\frac{n^2}{Z^2}\right) + \tanh(Z - T_{avg} - RH_{avg} - 12.43) - \tanh(Z)$	T_{avg}, RH_{avg}, n, Z	9

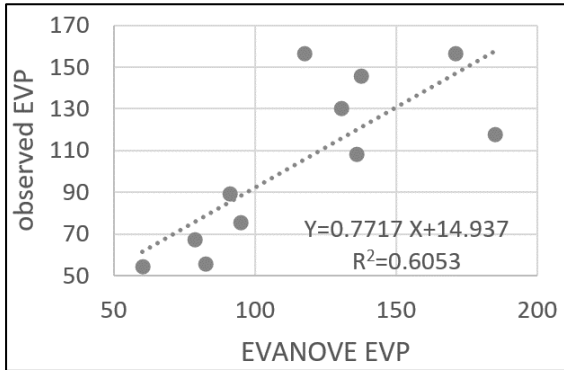
تعطي قيم التبخر الشهري، لذلك جمعت قيم التبخر اليومي الفعلي، وقيم التبخر المحسوبة من نمودجي (GEP-8) و (ANFIS-8) لكل شهر، من أجل المقارنة. يوضح الشكل (4) قيم التبخر الشهري الفعلي، والقيم المحسوبة من نمودجي (GEP-8) و (ANFIS-8) ومن معادلة إيفانوف، في محطة سد الثورة، ونلاحظ أن نمودجي (GEP-8) و (ANFIS-8) يعطيان قيمة أقرب، إلى القيم الفعلية المقیسة، من معادلة إيفانوف، حيث كانت أكبر قيمة للخطأ النسبي في نمودج (GEP-8) (20%)، والتي قابلها خطأ نسبياً مقداره (22.7%) في نمودج (ANFIS-8). في حين وصلت قيمة الخطأ النسبي في معادلة إيفانوف إلى (57.1%). ويعتبر أداء النمودج جيداً عندما لا تتجاوز قيمة الخطأ النسبي 20%^[1]. ويبين الشكل (5) العلاقة بين القيم المقیسة للتبخر الشهري الفعلي، وقيم التبخر الشهري المحسوبة من نماذج (GEP-8)، (ANFIS-8) ومعادلة إيفانوف في محطة سد الثورة.

تقييم نماذج GEP و ANFIS ومعادلة إيفانوف في تقدير التبخر في محطة سد الثورة

من أجل اختبار دقة وصلاحيّة النماذج التي تم التوصل إليها، والتحقق من إمكانية تعميمها على منطقة الساحل السوري، استُخدمت البيانات اليومية لمحطة سد الثورة، للفترة الممتدة من 1/1/2009 إلى 30/11/2009، حيث لم يتم إدخال هذه البيانات في بناء النماذج السابقة. تقع هذه المحطة على ارتفاع 163m فوق مستوى سطح البحر، ونظراً لتوفر بيانات القيم اليومية لدرجات الحرارة، والرطوبة النسبية والتبخر فقط، تم اختبار أداء النمودج رقم (8)، والذي تضمنت مدخلاته (درجة الحرارة اليومية والرطوبة النسبية اليومية والارتفاع)، تمت مقارنة قيم التبخر المحسوبة من نمودجي (GEP-8) و (ANFIS-8)، مع قيم التبخر الفعلي، المقیسة بواسطة حوض التبخر الأمريكي نوع A، وقيم التبخر المحسوبة باستخدام معادلة إيفانوف. وبما أن معادلة إيفانوف



(ب)



(ج)

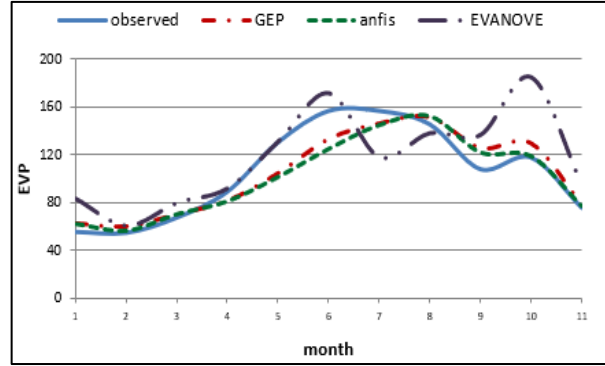
الشكل 5: العلاقة بين القيم المقيسة للتبخر الشهري الفعلي، وقيم التبخر الشهري المحسوبة من نماذج (أ) (GEP-8) ، (ب) (ANFIS-8) و (ج) معادلة إيفانوف في محطة سد الثورة.

الاستنتاجات

إمكانية تقدير التبخر الإنائى اليومي في المنطقة الهضابية في الساحل السوري باستخدام نماذج GEP و ANFIS، اعتماداً على البيانات اليومية لدرجة حرارة الهواء، الإشعاع الشمسي، الرطوبة النسبية وارتفاع المنطقة. حيث أن إدخال ارتفاع كل محطة مناخية عن سطح البحر، كأحد مُدخلات النموذج، حسّن بشكلٍ كبير من أداء النماذج. كما تفوق نموذج (GEP-8) على نموذج (ANFIS-8) ومعادلة إيفانوف في تقدير التبخر، حيث لم تتجاوز قيمة الخطأ النسبي 20% في نموذج (GEP-8)، في حين وصلت إلى 22.7% في نموذج (ANFIS-8)، و 57.1% في معادلة إيفانوف.

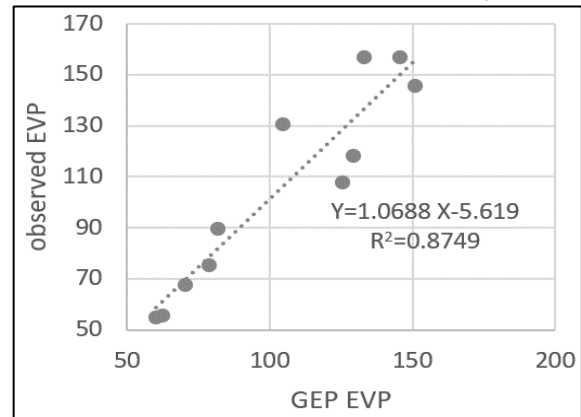
المراجع

[1] Allen et al., (1998). "Crop Evapotranspiration - Guidelines for Computing Crop Water Requirements. FAO Irrigation and Drainage", Paper No. 56, 300. Rome



الشكل 4: قيم التبخر الشهري الفعلي، و لمحسوب من نموذجي (GEP-8) و (ANFIS-8) ومعادلة إيفانوف في محطة سد الثورة.

بينت نتائج المقارنة تفوق GEP على ANFIS في تقدير التبخر الإنائى، وتفوق كلا النموذجين على معادلة إيفانوف. حيث بلغت قيمة معامل التحديد R^2 للعلاقة بين قيم التبخر الفعلية المقيسة وقيم التبخر المحسوبة لنموذجي GEP، ANFIS ومعادلة إيفانوف القيم 0.875، 0.863 و 0.605 على الترتيب. كما تمتاز برمجة التعبير الجيني بقدرتها على إعطاء معادلة للنموذج يمكن تطبيقها لتقدير التبخر في أي نقطة من الساحل السوري بغض النظر عن قيم درجات الحرارة والرطوبة والارتفاع عن سطح البحر، بينما نظام الاستدلال العصبي الضبابي التكميلي غير قادر على إعطاء معادلة للحساب وإنما يحتاج إلى إعداد واجهة للمستخدم، إضافة إلى أن تقدير التبخر فيه يكون مقيداً بمجالات متغيرات الدخل (القيم العظمى والصغرى) التي تم بناء النموذج اعتماداً عليها. وهذا يؤكد على إمكانية اعتماد نموذج (GEP-8) بدلاً من نموذج (ANFIS-8) ومعادلة إيفانوف، لتقدير التبخر الإنائى في المنطقة الهضابية في الساحل السوري.



(أ)

- [12] Savic, D. A.; Walters, G. A. and Davidson, J. W. (1999), "A Genetic Programming Approach to Rainfall-Runoff Modelling" *Water Resources Management*, Vol. 13, 219–231.
- [13] Ferreira, C. (2001), "Gene Expression Programming: A New Adaptive Algorithm for Solving Problems", *Complex Systems*, Vol. 13, No. 2, 87–129.
- [14] Jayawardena, A. W.; Muttil, N. and Fernando, T.M.K.G. (2005), "Rainfall-Runoff Modelling Using Genetic Programming". 1841–1847.
- [15] Mitchell, M. (1996), "An Introduction to Genetic Algorithm". The MIT Press, 158.
- [16] Ferreira, C. (2006), "Automatically Defined Functions in Gene Expression Programming". Springer-Verlag, Vol. 13, 21–56.
- [17] Ferreira, C. (2006), "Gene Expression Programming: Mathematical Modeling by an Artificial Intelligence", Springer, Berlin, 478pp.
- [18] Walla et al. (2015), "ANFIS: Adaptive Neuro-Fuzzy Inference System- A Survey" *International Journal of Computer Applications*, Vol. 123, No. 13, 32–39.
- [19] Fuller, R. (1995), "Neural Fuzzy Systems", Abo Akademi University, Finland, 346pp.
- [20] Hamdan, H. (2013), "An Exploration of the Adaptive Neuro-Fuzzy Inference System (ANFIS) in Modelling Survival", Doctor of Philosophy in Computer Science, The University of Nottingham, United Kingdom.
- [21] Aqil et al. (2007), "Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool" *Journal of Environmental Management*, Vol. 85, 215–223.
- [22] Roy, S. S. (2005), "Design of Adaptive Neuro-Fuzzy Inference System for Predicting Surface Roughness in Turning Operation". *Journal of Science and Industrial Research*, Vol. 64, 653–659.
- [23] Alasaad, A. and Ammar, G. (2007), *Hydrology. Civil Engineering*, Tishreen University, 405pp, Syria.
- [24] Ozgur, E. and Kocak, K. (2015), "The Effects of the Atmospheric Pressure on Evaporation", *Acta Geobalcanica*, Vol. 1, No. 1, 17-24.
- [2] Eslamian, S. S.; Gohari, S. A.; Biabanaki, M. and Malekian, R. (2008). "Estimation of Monthly Pan Evaporation Using Artificial Neural Networks and Support Vector Machines". *Journal of Applied Sciences*, Vol. 8, 3497-3502.
- [3] Terzi, O and Keskin, M. E. (2005), "Evaporation Estimation Using Gene Expression Programming", *Journal of Applied Sciences*, Vol. 5, No. 3, 508-512.
- [4] Shiri, J.; Kisi, O. (2011), "Application of Artificial Intelligence to Estimate Daily Pan Evaporation Using Available and Estimated Climatic Data in the Khozestan Province (South Western Iran)", *Journal of Irrigation and Drainage Engineering*, Vol. 137, No. 7, 412-425.
- [5] Ghorbani, M. A.; Singh, V. P.; Daneshfaraz, R. and Kashani, M. H. (2012), "Modeling Pan Evaporation Using Genetic Programming" *Journal of Statistics: Advances in Theory and Applications*, Vol. 8, No. 1, 2012, 15-36.
- [6] Kisi, O.; Mansouri, I.; Hu, J. W. (2017), "A New Method for Evaporation Modeling: Dynamic Evolving Neural-Fuzzy Inference System" *Advances in Meteorology*, Vol. 2017, 9.
- [7] Shiri et al. (2011), "Estimating Daily Pan Evaporation from Climatic Data of the State of Illinois, USA Using Adaptive Neuro-fuzzy Inference System (ANFIS) and Artificial Neural Network (ANN)" *Hydrology Research*, Vol. 42, No. 6, 491-502.
- [8] Terzi et al. (2006), "Estimating Evaporation Using ANFIS" *Journal of Irrigation and Drainage Engineering*, Vol. 132, 503-507.
- [9] Allawi, M. F.; El-shafie, A. (2016), "Utilizing RBF-NN and ANFIS Methods for Multi-Lead ahead Prediction Model of Evaporation from Reservoir" *Water Resour Manage*, 30, 4773 – 4788.
- [10] Kim et al. (2013), "Estimating Daily Pan Evaporation Using Different Data-Driven Methods and Lag-Time Pattern". *Water Resour Manage*, Vol. 27, 2267-2286.
- [11] Bărbulescu, A. and Băutu, E. (2009), "Time Series Modeling Using an Adaptive Gene Expression Programming Algorithm" *International Journal of Mathematical Models and Methods in Applied Science*, Vol. 3, No. 2, 85-93.