

کاربرد شبکه عصبی مصنوعی در پیش‌بینی تبخیر-تعرق با حداقل داده‌های هواشناسی  
(مطالعه موردی: شهر ارومیه)  
توحید علیقلی نیا، نگار رسولی مجد ، حسین رضایی و آناهیتا جباری

دوره ۲، شماره ۲، تابستان ۱۳۹۵، صفحات: ۱۲۲-۱۳۵

Vol. 2(2), Summer 2016, 122-135

Application of Artificial Neural  
Network to Predict the  
Evapotranspiration with the  
Minimum Meteorological Data  
(Case Study: Urmia City)

Aligholinia T. Rasouli Majd N. Rezaie H. and  
Jabbari A.



[www.jewe.ir](http://www.jewe.ir)

OPEN ACCESS

نحوه ارجاع به این مقاله: علیقلی نیا ت.، رسولی مجد ن.، رضایی ح و جباری آ. (۱۳۹۵). کاربرد شبکه عصبی مصنوعی در پیش‌بینی تبخیر-تعرق با حداقل داده‌های هواشناسی (مطالعه موردی: شهر ارومیه)، محیط زیست و مهندسی آب، جلد ۲، شماره ۲، صفحات: ۱۲۲-۱۳۵

**How to cite this paper:** Aligholinia T. Rasouli Majd N. Rezaie H. and Jabbari A. (2016). Application of Artificial Neural Network to predict the evapotranspiration with the minimum meteorological data (Case study: Urmia City), J. Environ. Water Eng. 2(2), 122-135

## کاربرد شبکه عصبی مصنوعی در پیش‌بینی تبخیر-تعرق با حداقل داده‌های هواشناسی

توحید علیقلی نیا<sup>۱\*</sup>، نگار رسولی مجد<sup>۲</sup>، حسین رضایی<sup>۳</sup> و آناهیتا جباری<sup>۴</sup>

۱- دانشجوی کارشناسی ارشد، مهندسی آب (آبیاری و زهکشی)، دانشگاه ارومیه

۲- دانشجوی دکتری، مهندسی منابع آب، دانشگاه ارومیه

۳- دانشیار گروه، مهندسی آب، دانشگاه ارومیه

۴- دانشجوی دکتری مهندسی آب (آبیاری و زهکشی)، دانشگاه ارومیه

\*نویسنده مسئول: tohid323@yahoo.com

تاریخ پذیرش: [۱۳۹۵/۳/۰۱]

تاریخ دریافت: [۱۳۹۴/۱۰/۰۵]

### چکیده

برآورد دقیق تبخیر-تعرق در اعمال مدیریت بهینه منابع آب، ضروری است. تبخیر-تعرق مؤلفه مهمی در توازن آب در مناطق مختلف به شمار می‌رود. مهندسیین آب با علم به اینکه چه مقدار از آب آبیاری به مصرف محصول می‌رسد، قادر به محاسبه مهمترین جزء آب در سیکل هیدرولوژیک یعنی تبخیر-تعرق خواهند بود. در مطالعه حاضر تبخیر-تعرق روزانه دشت ارومیه با استفاده از داده‌های هواشناسی طی دوره آماری ۱۳۹۰ - ۱۳۶۳ به روش فائو-پنمن-مونتیث محاسبه و مبنای کار قرار گرفت. سپس تبخیر-تعرق با استفاده از سناریوهای مختلف با پارامترهای ورودی متفاوت، با دو مدل MLP و RBF شبکه عصبی محاسبه شد. نتایج نشان دهنده برآورد تبخیر-تعرق روزانه با دقت قابل قبول ( $RMSE=0/985$ ) و  $R^2=0/963$  برای شبکه MLP و  $RMSE=0/537$  و  $R^2=0/963$  برای شبکه RBF) با استفاده از تنها سه پارامتر دمای متوسط، ساعت آفتابی و سرعت باد می‌باشند. همچنین با مشاهده و بررسی تمام سناریوها می‌توان گفت که معادله تبخیر-تعرق نسبت به پارامترهای ساعت آفتابی، سرعت باد و دما وابستگی بیشتری دارد. گرچه هر دو شبکه MLP و RBF با دقت بسیار بالایی مقدار تبخیر-تعرق را محاسبه می‌کنند، اما در کل دقت شبکه MLP نسبت به شبکه RBF بیشتر است.

**واژه‌های کلیدی:** تبخیر-تعرق، روش فائو-پنمن-مونتیث، شبکه‌های عصبی مصنوعی، دشت ارومیه

## ۱- مقدمه

آب اصلی‌ترین عنصر چرخه هیدرولوژیک می‌باشد که به‌صورت مستقیم به‌وسیله تبخیر از سطح خاک و تعرق از گیاهان وارد این چرخه می‌شود. منظور از تعیین تبخیر - تعرق، برآورد مقدار آبی است که باید به یک پوشش گیاهی داده شود تا در طول دوره رویش، صرف تبخیر- تعرق نموده و بدون آنکه با تنش آبی مواجه شود، حداکثر بازدهی را داشته باشد. تبخیر- تعرق پتانسیل یکی از عوامل تأثیرگذار بر بیلان آب محسوب می‌گردد که در مدیریت بهینه آب حوزه آبخیز نقش اساسی دارد. در نشریه شماره ۲۴ آبیاری و زهکشی فائو برای کمک به کاربران با توجه به داده‌های موجود، چهار روش بلانی- کریدل، تابش، پنمن و تشتک تبخیر برای محاسبه تبخیر - تعرق پتانسیل ارائه شده است (Shahedi و Zareie، 2011). در این نشریه پنمن به‌عنوان روشی که بهترین نتایج را با حداقل خطا نسبت به گیاه مرجع ارائه می‌کند، در نظر گرفته شد. مطالعات مختلفی درباره تعیین تبخیر - تعرق و مقایسه روش‌های مختلف برآورد آن صورت گرفته است. Allen و Pruitt (1988) بعد از ارزیابی معادله پنمن گزارش کردند که بین تبخیر - تعرق اندازه‌گیری شده با لایسیمتر و برآوردهای روزانه از یک گیاه با ارتفاع ثابت و جزء مقاومت سطحی که با شاخص سطح برگ و تابش خالص روزانه تغییر می‌کند، همبستگی خوبی دارد. Kairu (1991) به بررسی روش‌های مختلف تخمین تبخیر - تعرق از جمله مدل همبستگی گردابی، مدل انتقال جرم، مدل آبرودینامیکی، مدل پنمن مقاومتی و مدل تعادل انرژی پرداخت. Amatya et al. (1995) نشان دادند که بین روش‌های مختلف تخمین تبخیر-تعرق، روش پنمن - مانیتیت نسبت به دیگر روش‌های معمول نتایج قابل‌اعتمادی به دست می‌دهد. Xu و Singh (1997) با بررسی ۱۳ نوع مدل مختلف تبخیر از سطح آزاد آب، بهترین مدل که با داده‌های تشتک تبخیر شمال غرب کانادا سازگاری داشت، انتخاب و آن را واسنجی کردند. Ventura et al. (1999) در مقاله‌ای معادلات تبخیر- تعرق را با اندازه‌گیری مستقیم با لایسیمتر مورد مقایسه قرار دادند. Odhiambo et al. (2001) با استفاده از معادله پنمن- مانیتیت - فائو مقدار تبخیر- تعرق روزانه را به‌وسیله شبکه عصبی مصنوعی تخمین زدند. Kumar et al. (2002) مقدار تبخیر - تعرق روزانه‌ی گیاه مرجع ( $ET_0$ ) را با استفاده از شبکه‌های عصبی مصنوعی تخمین زدند. سپس با مقایسه‌ی این مقادیر با نتایج حاصل از روش متداول محاسبه  $ET_0$ ، یعنی روش فائو - پنمن- مانیتیت، قابلیت شبکه‌های عصبی مصنوعی را برای محاسبه‌ی این پارامتر مورد ارزیابی قرار دادند. Sudheer (2003) با استفاده روش محاسبات عصبی برای محاسبه تبخیر- تعرق از داده‌های دمای هوا، ساعات آفتابی و تابش خورشیدی استفاده کردند و نتایج قابل قبولی را ارائه دادند. Kouchakzadeh و Bahmnai (2005) تحقیقی به‌منظور کاهش پارامترهای مورد استفاده در محاسبه تبخیر - تعرق گیاه مرجع به‌وسیله شبکه عصبی مصنوعی در منطقه مهرآباد تهران انجام دادند. Zanetti et al. (2007) برای تخمین تبخیر- تعرق گیاه مرجع با داده‌های حداکثر و حداقل دمای هوا و دو پارامتر تشعشع خورشیدی و ساعات آفتابی روزانه که خود تابعی از عرض جغرافیایی منطقه هستند با استفاده از شبکه‌های عصبی مصنوعی در آرژانتین مورد بررسی قرار دادند. Sayyadi et al. (2009) عملکرد شبکه‌های عصبی تابع پایه شعاعی و پرسپترون چندلایه را در برآورد مقدار تبخیر - تعرق مرجع با استفاده از داده‌های هواشناسی ایستگاه تبریز بررسی نمودند و نتیجه گرفتند که تنها با استفاده از دو پارامتر دمای میانگین و سرعت باد به‌عنوان ورودی می‌توان میزان تبخیر - تعرق گیاه مرجع را با استفاده از این دو نوع شبکه با دقت قابل قبولی تخمین زد. Sentelhas et al. (2010) با استفاده از اطلاعات ۱۲ ایستگاه هواشناسی واقع در جنوب کانادا مدل‌های HG، TW و PT را بر اساس نتایج مدل فائو - پنمن - مانیتیت ۵۶ واسنجی کردند. Zhai et al. (2010) داده‌های تبخیر از تشتک را با نتایج تخمین تبخیر- تعرق حاصل از یازده مدل تجربی در ده ایستگاه هواشناسی واقع در شمال چین، مقایسه کردند. Rahimikhoob et al. (2012) عملکرد و توصیف ویژگی‌های چهار معادله تخمین‌گر تبخیر - تعرق مرجع ( $ET_0$ ) هارگریوز، پریستلی- تیلور، تورک و مکینگ را در هشت ایستگاه هواشناسی در آب‌وهوای نیه گرمسیری ایران مورد ارزیابی قرار دادند. معادله پنمن- مانیتیت به‌عنوان استاندارد مقایسه و کالیبراسیون مورد استفاده قرار گرفت. آن‌ها مشاهده کردند معادله پریستلی- تیلور که فقط نیاز به حداکثر و حداقل درجه حرارت دارد، نتایج بهتر و دقیق‌تری نسبت به سایر روش‌ها ارائه می‌دهد. Aladenola و Madramootoo (2013) دقت نه مدل تخمینی تابش خورشیدی ( $R_s$ ) را با استفاده از داده‌های هشت ایستگاه هواشناسی در کانادا برای محاسبه تبخیر - تعرق بررسی کردند. آن‌ها برای ارزیابی دقت این روش‌ها از شاخص‌های آماری (RMSE) (میانگین مربعات


خطا)، (MBE) (میانگین خطای اریب) و (ME) (میانگین خطا) استفاده کردند. نتایج نشان دهنده دقت بالای مدل هارگریوز-سامانی (H-S) و دقت پایین مدل محمود-هوبارت (M-H) بود.

Baba-Amiri et al. (2013) به مقایسه و واسنجی هفت روش مختلف تخمین ETO که مبتنی بر تابش خورشیدی در مقیاس ماهانه در حوضه دریاچه ارومیه می باشد، پرداختند. نتایج آنها نشان داد که قبل از واسنجی، نتایج روش های مختلف اختلاف زیادی با نتایج نظیر روش فائو - پنمن - مانیتث ۵۶ دارند. بعد از واسنجی، روش دورنبوس- پرویت به عنوان بهترین روش در حوضه مورد مطالعه شناخته شد و میانه ارقام نظیر  $R^2$  معادل ۰/۹۸۲ بدست آمد. روش پریستلی - تیلور در رده دوم و سایر روش های مکینگ، جنسن- هیز، تورک، آبیته و مکگینز - بوردن به ترتیب در رده های بعدی قرار گرفتند. (Sattari et al. (2013) در مقاله ای با عنوان پیش بینی تبخیر - تعرق مرجع روزانه با استفاده از مدل شبکه عصبی مصنوعی و مدل درختی M5، به مقایسه این دو روش پرداختند. نتایج نشان داد که گرچه روش شبکه عصبی مصنوعی با اختلاف خیلی کمی در مقایسه با روش M5 پیش بینی نسبتاً دقیق تری از میزان تبخیر - تعرق مرجع انجام می دهد، اما روش M5 روابط ساده خطی، قابل فهم تر و کاربردی تری برای پیش بینی تبخیر - تعرق ارائه می کند. روش فائو - پنمن - مونیتث یک روش استاندارد برای محاسبه تبخیر - تعرق می باشد، اما برای محاسبه تبخیر - تعرق به پارامترهای متعددی نیاز دارد. هدف از این تحقیق مقایسه عملکرد و دقت شبکه عصبی تابع پایه شعاعی (RBF) و شبکه های پرسپترون چندلایه (MLP) در محاسبه و برآورد مقادیر تبخیر - تعرق روزانه و ارائه بهترین سناریو بر اساس کمترین پارامتر ورودی در روش مرجع فائو - پنمن - مانیتث است.

## ۲- مواد و روش ها

### ۲-۱- منطقه مورد مطالعه

دشت ارومیه واقع در استان آذربایجان غربی و در محدوده ای بین مدارات ۴۵ درجه و ۴ دقیقه غربی و ۳۷ درجه و ۳۲ دقیقه شمالی قرار دارد. این دشت از سمت شمال به شهرستان سلماس، از غرب به کشور ترکیه، از جنوب به اشنویه و از سمت شرق نیز به دریاچه ارومیه محدود شده است. شکل (۱) موقعیت محدوده مطالعاتی را نشان می دهد.




شکل ۱- موقعیت محدوده مطالعاتی.

## ۲-۲- داده‌های مورد استفاده

در این پژوهش به‌منظور محاسبه تبخیر - تعرق از داده‌های هواشناسی ایستگاه سینوپتیک ارومیه در دوره آماری ۱۳۹۰ - ۱۳۶۳ استفاده گردید. داده‌های تهیه‌شده شامل پارامترهای میانگین دما، حداقل و حداکثر دما، حداقل و حداکثر رطوبت نسبی، ساعت آفتابی و سرعت باد در مقیاس روزانه می‌باشند. روش مبنا برای محاسبه مقدار تبخیر - تعرق روزانه روش فائو - پنمن - مونتیث می‌باشد. جهت برآورد مقدار تبخیر - تعرق روزانه از دو مدل شبکه عصبی پرسپترون چندلایه (MLP) و تابع پایه شعاعی (RBF) استفاده شد. به‌منظور برآورد دقیق با استفاده از دو مدل ذکرشده، ۷۵ درصد داده‌ها جهت آموزش و ۲۵ درصد بقیه جهت آزمون در این شبکه‌ها اختصاص یافت. ترکیب‌های متنوعی از داده‌های هواشناسی تحت سناریوهای مختلف به‌عنوان ورودی مدل شبکه عصبی مصنوعی و مقادیر محاسبه شده متناظر  $E_T$ ، به‌عنوان خروجی مدل شبکه عصبی مصنوعی در نظر گرفته شد. تعداد لایه‌های مورد استفاده در این شبکه، دو لایه و تعداد کل نرون‌های مورد استفاده ۲۰ نرون می‌باشد. جهت ارزیابی و انتخاب برترین سناریو از تحلیل‌های آماری و شاخص‌هایی همچون ضریب همبستگی (R)، جذر میانگین مربعات خطا (RMSE)، (MAE) و (SEE) استفاده گردید.

## ۲-۳- ساختار شبکه عصبی مصنوعی

محققان با توجه به شبکه عصبی طبیعی و اجزای آن، موفق به ساخت شبکه عصبی مصنوعی شدند که کوچک‌ترین واحد  $ANN^1$  می‌باشد. شبکه عصبی مصنوعی متشکل از سه مؤلفه وزن (W)، بایاس (b) و تابع انتقال (F) است. این سه جزء برای هر عصبی منحصربه‌فرد می‌باشد. شکل (۲) ساختار شماتیک شبکه عصبی مصنوعی را نشان می‌دهد.



شکل ۲- شماتیک شبکه عصبی مصنوعی

در شکل (۲)،  $a$  و  $p$  ورودی و خروجی می‌باشند. پارامتر  $n$  ورودی خالص است که وارد  $f$  می‌شود تا خروجی ایجاد شود. نمایش ریاضی از شبکه عصبی مصنوعی را می‌توان به‌صورت روابط (۱) و (۲) نمایش داد (Menhaj, 1998):

$$n = wp + b \quad (1)$$

$$a = f(n) = f(wp + b) \quad (2)$$

در فرآیند آموزش‌های عصبی، پارامترهای  $W$  و  $b$  تا زمانی که بهترین تقریب برای عضو خروجی مربوط به عضو ورودی به دست آید تغییر می‌کنند (Menhaj, 1998).


## ۲-۴- پرسپترون چندلایه

هرچند نحوه مدل کردن نرون جزء اساسی‌ترین مفاهیم در یک شبکه عصبی مصنوعی می‌باشد اما نحوه برقراری اتصالات و چیدمان شبکه نیز بسیار با اهمیت است. یکی از بهترین چیدمان‌های پیشنهادی برای مدل کردن عصب‌های واقعی، مدل پرسپترون چندلایه  $MLP^2$  می‌باشد. در ساختار پرسپترون چندلایه علاوه بر لایه‌های ورودی و خروجی، چندلایه بین این لایه‌ها وجود دارد که لایه‌های

<sup>1</sup> Artificial Neural Network

<sup>2</sup> Multilayer Perceptron

پنهان نامیده می‌شوند. به طوری که این لایه‌ها از محیط جدا و خروجی نیز تولید نمی‌کنند. وضعیت این ساختار در شکل (۳) نشان داده شده است.



شکل ۳- شبکه پرسپترون چندلایه با اتصالات کامل

در حالت کلی نحوه عمل شبکه پرسپترون چندلایه مشابه پرسپترون تک لایه‌ای است. بدین صورت که الگویی به شبکه عرضه می‌شود و خروجی آن محاسبه می‌گردد. مقایسه خروجی واقعی و خروجی مطلوب باعث می‌گردد که ضرایب وزنی و بایاس شبکه تغییر یابد، به طوری که در دفعات (Menhaj و Seifipour, 1998): بعد خروجی درست‌تری حاصل شود. عملکرد این شبکه می‌تواند از طریق معادلات (۳) و (۴) مشخص گردد


$$1 \leq j \leq S_1 \quad a_j^1(t) = F \left[ \sum_{i=1}^R w_{j,i}^1 P_i(t) + b_k^2 \right] \quad (3)$$

$$1 \leq k \leq S_2 \quad a_k^2(t) = G \left[ \sum_{j=1}^{S_1} w_{k,j}^2 a_j^1(t) + b_k^2 \right] \quad (4)$$

که در این معادلات R تعداد سیگنال ورودی، P جزء ورودی،  $W_1$  و  $W_2$  ماتریس به ترتیب در لایه‌های پنهان و خروجی،  $S_1$  و  $S_2$  تعداد نرون،  $b_1$  و  $b_2$  بردار بایاس به ترتیب در لایه‌های پنهان و خروجی،  $a^1$  و  $a^2$  اجزای خروجی لایه‌های متناظر و F و G توابع انتقال عصبی در لایه‌های پنهان و خروجی می‌باشند.

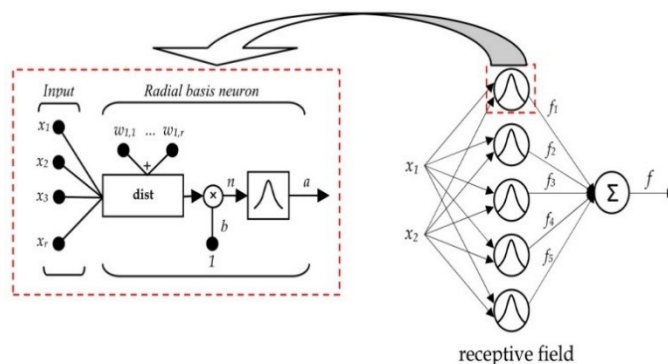
## ۲-۵- شبکه عصبی تابع پایه شعاعی

تابع پایه شعاعی متشکل از یک شبکه سه لایه است. نمونه‌ای از این شبکه در شکل (۴) نشان داده شده است.



شکل ۴- شبکه عصبی تابع پایه شعاعی

لایه ورودی، اولین لایه در شبکه عصبی RBF است که متغیرهای ورودی در این لایه قرار دارد. لایه دوم یا لایه پنهان، یک انطباق غیرخطی مابین فضای ورودی و یک فضای معمولاً با بعد بزرگ‌تر برقرار می‌کند و نقش مهمی در تبدیل الگوهای غیرخطی به الگوهای تفکیک‌پذیر خطی دارد. لایه سوم، جمع وزنی را به همراه یک خروجی خطی تولید می‌کند (شکل ۵).



شکل ۵- شماتیکی از پردازش در لایه پنهان

## ۲-۶- معادله فائو - پنمن - مونتیث

یکی از معادلاتی که به صورت تئوری بر اساس توازن روی یک سطح مرطوب پوشیده از گیاه ارائه گردیده معادله موسوم به فائو - پنمن - مونتیث است که به عنوان دقیق‌ترین روش برای برآورد تبخیر - تعرق گیاه مرجع که در حال حاضر اساس محاسبات نیاز آبی می‌باشد، معرفی گردیده است (Alizadeh, 2009). در این تحقیق نیز روش فائو - پنمن - مونتیث به عنوان یک روش مینا انتخاب گردید. علت این انتخاب این است که Allen et al. (1998) مدل مذکور را به عنوان یک روش استاندارد برای تخمین تبخیر - تعرق پتانسیل پیشنهاد کردند. آنچه در معادله فائو - پنمن - مونتیث محاسبه می‌شود نیاز آبی مرجع و یا نیاز آبی یک گیاه فرضی معرف است. هرچند این گیاه فرضی با چمن شباهت زیادی دارد اما نباید آن را چمن در نظر گرفت (Alizadeh, 2009). معادله فائو - پنمن - مونتیث به صورت زیر می‌باشد:

$$ET_o = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T+237} U_2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34 U_2)} \quad (5)$$

که در آن  $ET_o$  تبخیر - تعرق مرجع [ $\text{mm day}^{-1}$ ],  $R_n$  تابش خالص در سطح پوشش گیاهی [ $\text{MJ m}^{-2} \text{day}^{-1}$ ],  $T$  متوسط دمای هوا در ارتفاع ۲ متری از سطح زمین [ $^{\circ}\text{C}$ ],  $U_2$  متوسط سرعت باد در ارتفاع ۲ متری از سطح زمین [ $\text{m s}^{-1}$ ],  $e_s - e_a$  کمبود فشار بخار در ارتفاع ۲ متری [ $\text{kPa}$ ],  $\Delta$  شیب منحنی فشار بخار [ $\text{kPa}^{\circ}\text{C}^{-1}$ ],  $\gamma$  ضریب رطوبتی [ $\text{kPa}^{\circ}\text{C}^{-1}$ ],  $G$  شار گرما به داخل خاک [ $\text{MJ m}^{-2} \text{day}^{-1}$ ] می‌باشند.

## ۲-۷- شاخص‌های تحلیل آماری

برای محاسبه میزان خطا می‌توان از روابط (۶) تا (۹) استفاده کرد (Madadzadeh, 2014). رابطه خطای استاندارد برآورد:

$$SEE = \left[ \frac{\sum_{i=1}^R (ET_{ob} - ET)}{n-1} \right]^{0.5} \quad (6)$$

در این رابطه  $SEE$  خطای استاندارد برآورد،  $ET_{ob}$  مقادیر تبخیر - تعرق از روش پنمن - مونتیث،  $\overline{ET}$  مقادیر تبخیر - تعرق از هر یک از روش‌های مورد استفاده و  $n$  تعداد کل داده‌ها می‌باشند. رابطه (۷) متوسط ریشه مجذور خطاها را بیان می‌کند.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [(ET_{om})_i - (ET_{os})_i]^2} \quad (7)$$

$n$  تعداد مشاهدات،  $ET_{om}$  مقدار محاسبه شده تبخیر - تعرق از روش پنمن - مونتیث،  $ET_{os}$  مقدار تخمینی از شبکه عصبی است. خطای نسبی به وسیله رابطه (۸) بیان می‌شود.

$$RE = RMSE / \bar{O} \quad (8)$$

$\bar{O}$  متوسط تبخیر - تعرق محاسبه شده از روش پنمن - مونتیث است. شاخص مطابقت ویلموت (۱۹۸۷) از رابطه (۹) محاسبه می شود.

$$d = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i| + O_i)^2} \quad (9)$$

که در این شاخص  $P_i$  مقادیر داده های پیش بینی شده و  $O_i$  مقادیر داده های مشاهداتی می باشد. کمیت  $d$  همواره در محدوده صفر و ۱ قرار می گیرد و با توجه به جدول (۱)، دقت مدل موردنظر مشخص می گردد.

جدول ۱- محدوده پارامترهای RE و  $d$  برای تعیین دقت پیش بینی

محدوده پارامترهای $d$	محدوده پارامترهای RE	دقت پیش بینی
$d \geq 0.95$	$RE \leq 0.1$	خیلی خوب
$d \geq 0.95$	$0.15 \geq RE > 0.1$	خوب
$d \geq 0.95$	$0.2 \geq RE > 0.15$	قابل قبول
$d \geq 0.95$	$0.25 \geq RE > 0.2$	کم

شاخص ضریب همبستگی از رابطه (۱۰) محاسبه می شود.

$$R^2 = \frac{[\sum_{i=1}^n (P_i - P_{av})(O_i - O_{av})]^2}{\sum_{i=1}^n (P_i - P_{av})^2 \sum_{i=1}^n (O_i - O_{av})^2} \quad (10)$$

که در آن  $n$  تعداد مشاهدات،  $Q_i$  مقدار  $ET_0$  واقعی محاسبه شده با روش فائو-پنمن-مونتیث،  $P_i$  مقدار  $ET_0$  برآورد شده با سناریوهای موردبررسی در این تحقیق،  $O_{av}$  میانگین مقادیر  $ET_0$  محاسبه شده با روش فائو-پنمن-مونتیث (متوسط  $Q_i$  ها) و  $P_{av}$  میانگین مقادیر  $ET_0$  محاسبه شده با سناریوها (متوسط  $P_i$  ها) می باشند. در این تحقیق به منظور تخمین تبخیر - تعرق گیاه مرجع، تعداد ۱۱ سناریو برای پارامترهای مؤثر در برآورد آن با استفاده از Application شبکه های عصبی در نرم افزار متلب (MATLAB)، تعریف گردید. لازم به ذکر است که سناریوها طوری انتخاب شدند که مهم ترین پارامترها و در دسترس ترین آن ها جهت پیش بینی مورد استفاده گردند. جدول (۲) پارامترهای ورودی به شبکه عصبی برای هر سناریو را نشان می دهد.

جدول ۲- پارامترهای ورودی سناریوهای مختلف

سناریو	پارامترها
۱	بارندگی، حداکثر دما، حداقل دما، دمای متوسط، حداقل رطوبت، حداکثر رطوبت، ساعت آفتابی، سرعت باد
۲	بارندگی، حداکثر دما، حداقل دما، دمای متوسط، حداکثر رطوبت، ساعت آفتابی، سرعت باد
۳	بارندگی، حداکثر دما، حداقل دما، حداکثر رطوبت، ساعت آفتابی، سرعت باد
۴	حداکثر دما، حداقل دما، حداکثر رطوبت، ساعت آفتابی، سرعت باد
۵	بارندگی، حداکثر دما، حداقل دما، دمای متوسط، ساعت آفتابی، سرعت باد
۶	حداکثر دما، حداقل دما، حداقل رطوبت، حداکثر رطوبت، ساعت آفتابی
۷	حداکثر دما، حداقل دما، حداقل رطوبت، حداکثر رطوبت، سرعت باد
۸	حداکثر دما، حداقل دما، ساعت آفتابی، سرعت باد
۹	حداکثر دما، ساعت آفتابی، سرعت باد
۱۰	دمای متوسط، ساعت آفتابی، سرعت باد
۱۱	دمای متوسط، سرعت باد



## ۳- نتایج و بحث

با بررسی سناریوهای متفاوت برای شبکه‌های MLP و RBF، جهت انتخاب بهترین سناریو و مقایسه آن‌ها از شاخص‌های آماری RMSE، MAE و SEE استفاده گردید. جداول (۳) و (۴) مقادیر این شاخص‌ها را نشان می‌دهند.

جدول ۳- مقادیر شاخص‌های آماری برای شبکه MLP

سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	
۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	
۰/۹۹۲	۰/۹۸۳	۰/۹۸۴	۰/۹۷۰	۰/۹۷۰	۰/۹۳۲	۰/۹۸۳	۰/۹۶۸	۰/۹۶۵	۰/۹۶۳	۰/۹۳۵	R <sup>2</sup>
۰/۰۷۹	۰/۲۵۴	۰/۱۵۴	۱/۳۷۵	۰/۶۰۸	۰/۴۳۲	۰/۰۳۳	۰/۶۸۹	۰/۴۴۵	۰/۹۵۸	۱/۶۷۹	RMSE
۰/۰۰۱	۰/۰۰۳	۰/۰۰۲	۰/۰۱۵	۰/۰۰۶	۰/۰۰۵	۰/۰۰۰	۰/۰۰۷	۰/۰۰۵	۰/۰۱۰	۰/۰۱۸	MAE
۰/۰۲۹	۰/۰۵۲	۰/۰۴۱	۰/۱۲۱	۰/۰۸۱	۰/۰۶۸	۰/۰۱۹	۰/۰۸۶	۰/۰۶۹	۰/۱۰۱	۰/۱۳۴	SEE

جدول ۴- مقادیر شاخص‌های آماری برای شبکه RBF

سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	
۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	
۰/۹۱۶	۰/۹۱۶	۰/۹۷۶	۰/۹۷۶	۰/۹۶۸	۰/۳۵۶	۰/۹۸	۰/۹۶۷	۰/۹۶۷	۰/۹۴۴	۰/۹۶۳	R <sup>2</sup>
۰/۸۱۷	۰/۸۱۷	۰/۴۳۲	۰/۴۳۴	۰/۵۰۷	۰/۶۳۶	۰/۳۹۷	۰/۵۱۱	۰/۵۱۲	۰/۶۶۷	۰/۵۳۷	RMSE
۰/۵۶۸	۰/۵۶۸	۰/۲۹۹	۰/۳۰۱	۰/۳۵۶	۰/۴۱۶	۰/۲۶۲	۰/۳۶	۰/۳۶۱	۰/۴۷۹	۰/۳۸۲	MAE
۰/۷۵۴	۰/۷۵۴	۰/۵۴۷	۰/۵۴۹	۰/۵۹۷	۰/۶۴۵	۰/۵۱۲	۰/۶۰۰	۰/۶۰۱	۰/۶۹۲	۰/۶۱۸	SEE

با توجه به جداول (۳) و (۴) برای شبکه MLP سناریوهای ۱، ۳ و ۷ دارای کمترین مقدار متوسط ریشه مجذور خطاها (RMSE) در بین سناریوهای دیگر و برای شبکه RBF نیز سناریوهای ۳، ۴ و ۷ دارای کمترین مقدار (RMSE) می‌باشند. در سناریوهای ۱، ۲ و ۳ به بررسی تأثیر پارامترهای دما و رطوبت که از اساسی‌ترین مؤلفه‌ها در ارزیابی تبخیر-تعرق هستند، پرداخته شد. بررسی این سناریوها حاکی از کاهش دقت مدل با حذف پارامتر حداقل رطوبت در مدل MLP می‌باشد. این در حالی است که پارامتر حداقل رطوبت در مدل RBF تأثیر ندارد. با بررسی سناریو ۴ می‌توان دریافت که حذف پارامتر بارش در مدل RBF تأثیر ندارد. حال آنکه حذف این پارامتر باعث ایجاد خطای پیش‌بینی بیشتر در مدل MLP شد. سناریو ۵ نیز تأثیر پارامتر رطوبت را در شبکه‌ها نشان می‌دهد.

با مقایسه این سناریو با سناریوهای دیگر می‌توان دریافت که پارامتر رطوبت کم تأثیرترین پارامتر در بین سایر پارامترها برای پیش‌بینی مدل‌ها می‌باشد. با مقایسه سناریوهای ۶ و ۷ می‌توان به تأثیر پارامترهای سرعت باد و ساعت آفتابی پی برد. نتایج این سناریوها نشان دادند که مدل به سرعت باد بسیار حساس بوده به طوری که با حذف این پارامتر در سناریو ۶ برآورد داده‌ها با بیشترین خطا صورت می‌گیرد. سناریوهای ۸، ۹ و ۱۰ نیز به منظور ارزیابی تأثیر پارامتر دما تعریف شده‌اند. در سناریو ۹، با حذف پارامتر حداقل دما میزان خطا به مقدار اندکی در هر دو مدل RBF و MLP کاهش می‌یابد. این در حالی است که حداکثر دما به طور مشترک در هر دو مدل

تعریف شده است. با حذف هر دو پارامتر حداقل و حداکثر دما تنها با باقی ماندن دمای میانگین در سناریو ۱۰ از دقت مدل‌ها کاسته می‌شود و این نشان‌دهنده تأثیر بیشتر دو پارامتر دمای حداقل و حداکثر در مقابل دمای میانگین می‌باشد. سناریو ۱۱ نیز دقت مدل را نسبت به ساعت آفتابی نشان می‌دهد.

در کل با مشاهده و بررسی تمام سناریوها می‌توان گفت که معادله تبخیر و تعرق نسبت به پارامترهای ساعت آفتابی، سرعت باد و دما وابستگی بیشتری دارد. با توجه به جداول مشاهده می‌گردد که برای هر دو مدل MLP و RBF، گرچه سناریوی ۷ از دقت بالایی برخوردار است اما به دلیل زیاد بودن تعداد پارامترهای به کار رفته در این سناریو باعث پیچیده شدن شبکه می‌گردد. مسلماً سناریوی ۱۰ که در آن پارامترهای کمتر هواشناسی نیاز بوده و دقت بالایی داشته باشد، از نظر کاربردی مطلوب‌تر خواهد بود. از این رو سناریوی ۱۰ با تنها سه پارامتر ورودی دمای متوسط، ساعت آفتابی و سرعت باد نتایج به نسبت قابل قبولی را ارائه می‌دهد. به منظور بیان کیفی نتایج سناریوها نیز از شاخص‌های RE و d استفاده گردید. نتایج حاصل از این شاخص‌ها در جداول (۵) و (۶) نشان داده شده است.

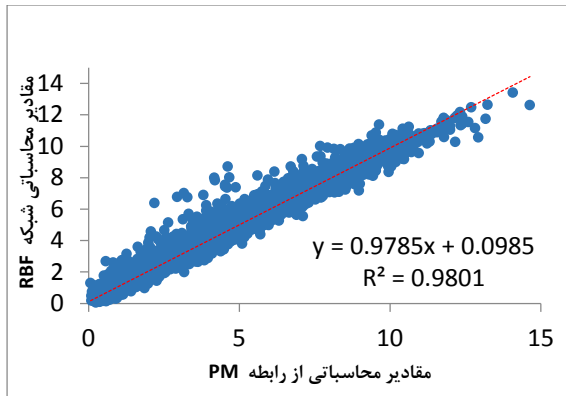
جدول ۵- مقادیر شاخص‌های RE و d محاسبه شده برای شبکه MLP

سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	
۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	
۰/۰۱۹	۰/۰۶۱	۰/۰۳۷	۰/۳۳۰	۰/۱۴۶	۰/۱۰۳	۰/۰۰۸	۰/۱۶۵	۰/۱۶۵	۰/۱۰۷	۰/۲۳۰	RE
۰/۹۹۸	۰/۹۹۶	۰/۹۹۶	۰/۹۹۶	۰/۹۹۲	۰/۹۸۲	۰/۹۹۶	۰/۹۹۲	۰/۹۹۱	۰/۹۹۰	۰/۹۸۳	d
خیلی خوب	خیلی خوب	خیلی خوب	کم	خوب	خوب	خیلی خوب	قابل قبول	قابل قبول	خوب	کم	دقت پیش‌بینی

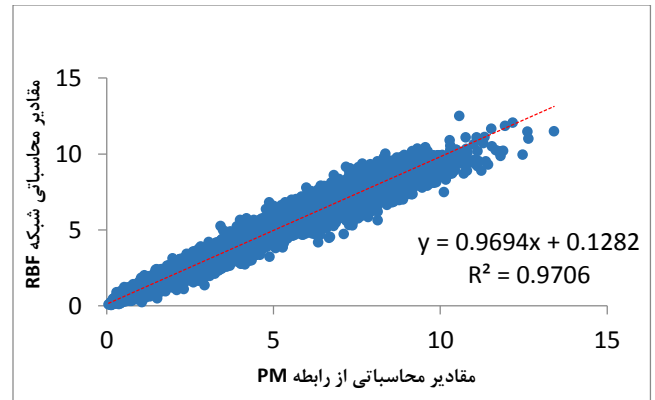
جدول ۶- مقادیر شاخص‌های RE و d محاسبه شده برای شبکه RBF

سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	سناریو	
۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	
۰/۱۹۶	۰/۱۹۶	۰/۱۰۴	۰/۱۰۴	۰/۱۲۲	۰/۱۵۲	۰/۰۹۵	۰/۱۲۲	۰/۱۲۳	۰/۱۲۹	۰/۱۶۰	RE
۰/۹۷۸	۰/۹۷۸	۰/۹۹۴	۰/۹۹۴	۰/۹۹۲	۰/۹۸۷	۰/۹۹۵	۰/۹۹۱	۰/۹۹۱	۰/۹۹۱	۰/۹۸۵	d
قابل قبول	قابل قبول	خوب	خوب	خوب	قابل قبول	خیلی خوب	خوب	خوب	خوب	قابل قبول	دقت پیش‌بینی


بر اساس جداول فوق، سناریوی ۷ در هر دو مدل دارای دقت پیش‌بینی خیلی خوب می‌باشد. همچنین می‌توان دریافت که برای شبکه MLP، سناریوهای ۱، ۲ و ۳ نیز دارای دقت پیش‌بینی خیلی خوب می‌باشند. این در حالی است که این سناریوها در شبکه RBF دارای دقت مناسب می‌باشند. نتایج محاسبه مقادیر تبخیر - تعرق به وسیله‌ی رابطه‌ی فائو - پنمن - مونتیت و مقادیر به‌دست‌آمده از مدل شبکه عصبی مصنوعی در سناریوهای ۷ و ۱۰ در شکل (۶) نمایش داده شده است. مقادیر ضریب همبستگی بیانگر قابلیت بالای هر دو مدل برای برآورد تبخیر - تعرق می‌باشد. در شکل (۷) نیز میزان انطباق بین تبخیر - تعرق روش استاندارد پنمن - مونتیت روزانه و مقادیر برآورد شده به وسیله‌ی دو مدل MLP و RBF شبکه عصبی مصنوعی برای سناریوی ۷ نشان داده شده است.




الف- RBF برای سناریو ۷



ج- RBF برای سناریو ۱۰




ب- MLP برای سناریو ۷




د- RBF برای سناریو ۱۰

شکل ۶- مقایسه نتایج شبکه عصبی با مقادیر محاسبه شده به وسیله رابطه پنمن - مونتیث در سناریوهای مختلف الف- RBF برای سناریو ۷،

ب- MLP برای سناریو ۷، ج- RBF برای سناریو ۱۰ و د- RBF برای سناریو ۱۰



الف- مدل MLP



ب- مدل RBF

شکل ۷- مقایسه مقادیر تبخیر - تعرق برآوردی روزانه توسط الف- مدل MLP و ب- مدل RBF و روش استاندارد پنمن - ماتیت

شکل (۷) نشان می دهد که همبستگی خوبی بین تبخیر-تعرق برآوردی و واقعی وجود دارد. یکسانی رفتار هر دو مدل MLP و RBF در سناریو ۷ با توجه به انطباق داده‌های حاصل از تبخیر-تعرق مرجع کاملاً مشهود است و این نشان می دهد که می توان با حداقل داده‌های مورد استفاده (دما، رطوبت و سرعت باد) تبخیر-تعرق مرجع را با دقت بسیار بالا پیش‌بینی نمود و از نتایج آن برای نقاطی که امکان داده‌برداری میسر نیست، به کاربرد.

#### ۴- نتیجه‌گیری

تخمین دقیق مقدار آب مورد نیاز گیاهان سبب طراحی مناسب دستگاه‌های آبیاری و بهره‌برداری بهینه از منابع آب در بخش کشاورزی می‌شود. در این تحقیق تبخیر-تعرق مرجع روزانه دشت ارومیه با استفاده از دو مدل MLP و RBF شبکه عصبی مورد ارزیابی قرار گرفت. بدین منظور سناریوهای مختلف با پارامترهای ورودی متفاوت به شبکه معرفی و مقادیر تبخیر - تعرق روزانه برآورد گردید. نتایج نشان دادند که با استفاده از سه پارامتر دمای متوسط، ساعت آفتابی و سرعت باد (سناریو ۱۰) می‌توان با دقت قابل قبولی تبخیر-تعرق روزانه را محاسبه کرد. میزان خطا (RMSE) در این سناریو برای شبکه MLP برابر ۰/۹۵۸ و برای شبکه RBF، ۰/۵۳۷ به دست آمد. با مقایسه سناریوها می‌توان دریافت که پارامتر رطوبت کم‌تأثیرترین پارامتر در بین سایر پارامترها برای پیش‌بینی تبخیر-تعرق می‌باشد. همچنین نتایج نشان می‌دهند که مدل به سرعت باد بسیار حساس است. به طوری که با حذف این پارامتر در سناریو ۶، برآورد داده‌ها با بیشترین خطا صورت می‌گیرد. همچنین سناریو ۷ با پنج پارامتر ورودی حداکثر دما، حداقل دما، رطوبت، حداکثر رطوبت و سرعت باد به‌عنوان بهترین سناریو با میزان خطا RMSE برابر ۰/۰۳۳ برای شبکه MLP و ۰/۳۹۷ برای شبکه RBF انتخاب گردید. با مشاهده و بررسی تمام سناریوها می‌توان گفت که معادله تبخیر - تعرق نسبت به پارامترهای ساعت آفتابی، سرعت باد و دما وابستگی بیشتری دارد. هر دو شبکه MLP و RBF با دقت مناسبی مقدار تبخیر-تعرق را محاسبه می‌کنند. ضمن اینکه دقت شبکه MLP نسبت به شبکه RBF بیشتر است.

## References

- Aladenola O.O. and Madramootoo C.A. (2013). Evaluation of solar radiation estimation methods for reference evapotranspiration estimation in Canada. *Theor. Appl. Clim.*, 118(3), 377-385.
- Alizadeh A. (2007). *Irrigation System Design (Vol.1)*, Ferdowsi University of Mashhad, Astan-e-Quds-Razawi, Mashhad, Iran [in Persian].
- Allen R.G., Pereira L.S., Raes D. and Smith, M. (1998). Crop evapotranspiration – guidelines for computing crop water requirements, *Irrigation and drainage paper* 56, 300(9), 305.
- Allen R. G., and Pruitt W. O. (1988). Closure to rational use of the FAO Blany- Criddle formula, *J. Irrig. Drain.*, 114(2), 375-380.
- Amatya D.M., Skaggs R.W. and Gregory J.D. (1995). Comparison of methods for estimating REF-ET. *J. Irrig. Drain.*, 121(6), 427-435.
- Baba-Amiri O., Dinpashoh Y. and Asadi E. (2012). Calibration and evaluation of seven radiation-based reference crop evapotranspiration methods at Urmia Lake Basin, *Water Soil Sci.*, 24(3) 143-158 [In Persian].
- Eslami A. and Gahreman B. (2013). Sensitivity analysis and uncertainty parameters affecting in the estimation of reference evapotranspiration in models with different mathematical structure, *Iranian J. Irrig. Drain.*, 1(7), 68-79 [In Persian].
- Kairu, E. N. (1991). A review of methods for estimating evapotranspiration. *Geo J.*, 25(4), 371-379.
- Kumar M., Raghuwanshi N.S., Singh R., Wallender W.W. and Pruitt, W.O. (2002). Estimating evapotranspiration using artificial neural network *J. Irrig. Drain.*, 128(4), 224-233.
- Kouchakzadeh M. and Bahmani A. (2005). Assessment of artificial neural networks revenue in reducing required parameters for estimation of reference evapotranspiration. *J. Agri. Sci.*, 4, 87-97.
- Madadzadeh F. (2014). The difference between statistical concepts as standard deviation and standard error and how to correct their report in the medical articles, *Iranian J. Med. Edu.*, 15(44), 353-355 [In Persian].
- Menhaj M.B. (1998). *Artificial neural networks basis*, Vol. 1. Tehran, Iran [in Persian].
- Menhaj M.B. and Seifipour, N. (1998). *Application of artificial intelligence in control*, Part. 2. Professor Hesabi Publications, Tehran, Ira. [In Persian].
- Odhiambo L.O., Yoder R.E., Yoder D.C. and Hines J.W. (2001). Optimization of fuzzy evaporation model through neural training with input-output examples, *Trans. ASAE*, 44(6), 1625.
- Rahimikhoob A., Behbahani M.R. and Fakheri J. (2012). An evaluation of four reference evapotranspiration models in a subtropical climate. *Water Resour. Manag.*, 26(10), 2867-2881.

- Sattari M. T., Rezazadeh Joudi A. and Nahrein F. (2014). Monthly rainfall prediction using Artificial Neural Networks and M5 model tree (Case Study: Station of Ahar). *Phys. Geogr. Res. Quarterly*, 46(2), 247-260 [in Persian].
- Sayyadi H., Oladghaffari A., Faalian A. and Sadraddini A. A. (2009). Comparison of RBF and MLP neural networks. Performance of reference crop evapotranspiration, *Water Soil Knowl.*, (1), 1-12 [In Persian].
- Sentelhas P., Gillespie T. and Santos E.A. (2010). Evaluation of FAO Penman-Monteith and alternative methods for estimating reference evapotranspiration with missing data in southern Ontario, Canada. *Agri. Water Manag.*, (97), 635-644.
- Shahedi K. and Zarei M. (2011). Assessment of potential evapotranspiration estimation methods in Mazandaran Province. *Irrig. Water Eng.*, 1(3), 12-21 [in Persian].
- Singh V. P., and Xu C. Y. (1997). Evaluation and generalization of 13 mass transfer equations for determining free water evaporation, *Hydrol. Proc.*, (11), 311-323.
- Sudheer, K. P., Gosian, A. K. and Ramasarti, K. S. (2003). Estimating actual evapotranspiration from limited climatic data using neural computing technique. *J. Irrig. Drain. Eng.*, 129(3), 214- 218.
- Ventura F., Spano D., Duce P. and Snyder R. L. (1999). An evaluation of common evapotranspiration equations. *Irrig. Sci.*, (18), 163–170.
- Zanetti S.S., Sousa E.F., Oliveira V.P.S., Almeida F.T. and Bernardo S. (2007). Estimating evapotranspiration using artificial neural network and minimum climatological data. *J. Irrig. Drain. Eng.*, 133 (2), 83-89.
- Zhai L., Feng Q., Li Q., and Xu C. Y. (2010). Comparison and modification of equations for calculating evapotranspiration (ET) with data from Gansu province, northwest China. *J. Irrig. Drain. Eng.*, (59), 477- 490.

## Application of Artificial Neural Network to Predict the Evapotranspiration with the Minimum Meteorological Data

Tohid Aligholinia<sup>1\*</sup>, Negar Rasouli Majd<sup>2</sup>, Hossein Rezaie<sup>3</sup> and Anahita Jabbari<sup>4</sup>

<sup>1</sup> M.Sc. Student of Water Engineering (Irrigation and Drainage), Department of Water Engineering. Urmia University, Urmia, Iran

<sup>2</sup> Ph.D Student of Water Resources Engineering, Department of water Engineering. Urmia University, Urmia, Iran

<sup>3</sup> Associate Prof, Department of Water Engineering. Urmia University, Urmia, Iran

<sup>4</sup> Ph.D Student, Water Engineering (Irrigation and Drainage), Department of Water Engineering. Urmia University, Urmia, Iran

\*Corresponding Author: [tohid323@yahoo.com](mailto:tohid323@yahoo.com)

Received: Jan, 17, 2016

Accepted: May 08, 2016

### Abstract

Accurate estimating evapotranspiration is crucial for water resource management. Evapotranspiration is an important component in water balance in different areas. Knowing the amount of water consumed per product, water engineers are able to calculate evapotranspiration as the most important component of hydrological cycle. In this study, the daily evapotranspiration of Urmia Plain was calculated using meteorological data during the period of 1984-2011 using FAO - Penman - Monteith as a base method. Then, evapotranspiration was calculated with the help of MLP and RBF neural network models using different scenarios with different input parameters. The results indicated that the daily evapotranspiration could be predicted with acceptable accuracy (RMSE = 0.985 and  $R^2 = 0.963$  for MLP network and RMSE = 0.537 and  $R^2 = 0.963$  for RBF network) using only three parameters: average temperature, sunshine hours, and wind speed. In general, it can be observed that evapotranspiration equation is more depended on the sunshine hours, wind speed, and temperature. Both MLP and RBF networks could be used for calculating the amount of evapotranspiration with high accuracy, but total accuracy of MLP network is more than RBF network.

**Keywords:** Evapotranspiration, Penman – Monteith Method, Artificial Neural Networks, Urmia Plain