



## Using Unsupervised Estimator Technique to Predict Reference Crop Evapotranspiration

F. Farsadnia<sup>1\*</sup>, S. Zahmati<sup>2</sup>, B. Ghahreman<sup>3</sup>  
and A. Moghaddam Nia<sup>4</sup>

### Abstract

Evapotranspiration is the main component of hydrologic cycle and has an important role in crop water requirement estimations, water balances studies, and water resource management. There are a lot of direct and indirect methods to estimate reference crop evapotranspiration, but each has some limitations. For example, limitations that can be mentioned for direct measuring are the insufficient precision in measuring devices and the scale problems. An indirect method like Penman-Monteith on the other hand needs a lot of daily climatic parameters. This research tried to use self-organizing maps as an unsupervised artificial neural network method to predict evapotranspiration by minimum meteorological data input. Based on fuzzy clustering indices, evapotranspiration values in the study area, Mashhad plain, are divided into two clusters with low and high  $ET_0$  coincided with the climate of the area. Also, in order to validate the model, statistical indices containing root mean square error, determination coefficient, and Nash-Sutcliffe model efficiency coefficient are used and the results are compared with the experimental models output. The results showed that even the simplest SOM model which employs mean temperature and maximum sunshine duration as input have less errors compared to the experimental equations.

**Keywords:** Self-organizing map; FAO-Penman-Monteith equation; Crop reference evapotranspiration; Mashhad plain.

Received: December 13, 2014

Accepted: August 27, 2015

## ارایه تکنیک پیش‌بینی غیر-نظارت شونده در برآورد تبخیر-تعرق گیاه مرجع

فرهاد فرسادنیا<sup>۱\*</sup>، سعیده زحمتی<sup>۲</sup>، بیژن قهرمان<sup>۳</sup>  
و علیرضا مقدم‌نیا<sup>۴</sup>

### چکیده

تبخیر-تعرق از اجزاء اصلی چرخه هیدرولوژی است و در تعیین نیاز آبی گیاه، مطالعات بیلان آبی و مدیریت منابع آب نقش مهمی دارد. تاکنون روش‌های مستقیم و غیر مستقیم متعددی برای برآورد تبخیر-تعرق گیاه مرجع ارائه شده است، اما هر یک از این روش‌ها دارای محدودیت‌هایی هستند. به عنوان مثال، از محدودیت‌های روش‌های اندازه‌گیری مستقیم می‌توان به عدم دقت وسایل اندازه‌گیری و مسائل مربوط به مقیاس اشاره کرد، در حالیکه روش‌های غیر مستقیم نظیر معادله پنمن-مانتیت، به پارامترهای اقلیمی روزانه زیادی نیاز دارند. در این تحقیق سعی گردید از روش نگاشت خود-سامان به عنوان یک روش شبکه عصبی مصنوعی غیر نظارت شونده در پیش‌بینی تبخیر-تعرق با حداقل پارامترهای هواشناسی به عنوان ورودی، استفاده گردد. براساس شاخص‌های ارزیابی خوشه‌بندی فازی، مقادیر  $ET_0$  در مشهد به دو خوشه با تبخیر-تعرق کم و زیاد تقسیم شد که با اقلیم منطقه مطابقت نشان داد. همچنین به منظور ارزیابی کارایی مدل ارائه شده از معیارهای آماری شامل (ریشه میانگین مربعات خطا، ضریب تعیین و معیار ناش-سنتکلیف) استفاده گردید و نتایج حاصله با برآوردهای حاصل از مدل‌های تجربی مقایسه گردید. نتایج حاصله نشان داد که حتی ساده‌ترین مدل نگاشت خود-سامان با ترکیب متوسط دمای هوا و حداکثر ساعات آفتابی به عنوان ورودی نیز خطای کمتری نسبت به معادلات تجربی دارد.

**کلمات کلیدی:** نگاشت خود-سامان؛ معادله فائو-پنمن-مانتیت؛ تبخیر-تعرق گیاه مرجع؛ دشت مشهد.

تاریخ دریافت مقاله: ۹۳/۹/۲۲

تاریخ پذیرش مقاله: ۹۴/۶/۵

1- Ph.D. Student in irrigation and drainage, Department of Water Engineering, College of Agriculture, Ferdowsi University of Mashhad, Mashhad, Iran. farhadfarsadnia@stu.um.ac.ir

2- M.Sc. Student, Department of Water Engineering, College of Agriculture, Ferdowsi University of Mashhad, Mashhad, Iran.

3- Professor, Department of Water Engineering, College of Agriculture, Ferdowsi University of Mashhad, Mashhad, Iran.

4- Associate Professor of Hydrology, Faculty of Natural Resources, University of Tehran, Karaj, Iran.

\*- Corresponding Author

۱- دانشجوی دکتری آبیاری و زهکشی، دانشکده کشاورزی، دانشگاه فردوسی مشهد، ایران.  
۲- دانشجوی کارشناسی ارشد آبیاری و زهکشی، دانشکده کشاورزی، دانشگاه فردوسی مشهد، ایران.

۳- استاد گروه مهندسی آب، دانشکده کشاورزی، دانشگاه فردوسی مشهد، ایران.  
۴- دانشیار هیدرولوژی، دانشکده منابع طبیعی، گروه احیای مناطق خشک و کوهستانی، دانشگاه تهران، ایران.

\*- نویسنده مسئول

## ۱- مقدمه

برخلاف روش‌های نظری، اطلاعات مورد نیاز در روش‌های تجربی زیرمجموعه‌ای از اطلاعات هواشناسی (معمولاً دمای هوا) است. استفاده از روش‌های تجربی ساده است، اما ماهیت تجربی این روش‌ها باعث شده نتایج حاصله مختص به مکان و شرایط اقلیمی باشد که معادله تجربی در آن توسعه یافته است. اگرچه می‌توان با واسنجی<sup>۲</sup> معادلات تجربی از آنها در نقاط اقلیمی مختلف استفاده کرد، اما این معادلات هنوز جایگزینی مناسب برای روش‌های نظری نیستند.

ماهیت پیچیده و غیرخطی فرآیند تبخیر-تعرق منجر به استفاده پژوهشگران از مدل‌های هوش مصنوعی<sup>۳</sup> به منظور تخمین تبخیر-تعرق با حداقل داده‌های اقلیمی شده است. تکنیک‌های AI مانند شبکه‌های عصبی مصنوعی<sup>۴</sup> قادر به نگاشت روابط غیرخطی، بدون نیاز به مشخص کردن صریح مدل ریاضی هستند. در دو دهه اخیر روش‌های متعددی جهت مدل‌سازی ANN بمنظور برآورد تبخیر-تعرق ارائه شده است. تفاوت اصلی این مدل‌ها، استفاده از الگوریتم‌های متفاوت جهت آموزش ANN و تفاوت در متغیرهای اقلیمی ورودی به مدل‌ها می‌باشد. Kumar et al. (2010) مطالعه گسترده‌ای در زمینه مدل‌های شبکه عصبی نظارت شونده<sup>۵</sup> جهت برآورد تبخیر-تعرق انجام داده‌اند. هرچند این مدل‌ها با حداقل داده‌های اقلیمی، تبخیر-تعرق را به خوبی برآورد می‌کنند. با این حال، می‌تواند تحت تأثیر وجود داده‌های مفقود یا پرت قرار گیرند. در واقع، مشخص شده در جایی که اغتشاش‌هایی در داده‌ها وجود داشته باشد، این نوع شبکه‌ها نتایج غیر واقعی تولید می‌کنند (Rustum et al., 2007).

الگوریتم نگاشت خود-سامان<sup>۶</sup> (Kohonen, 1982) مدلی اکتشافی برای مجسم ساختن و کشف روابط خطی و غیرخطی در مجموعه داده‌ها با ابعاد زیاد، تحت الگوریتم یادگیری غیر-نظارت شونده<sup>۷</sup> است. تاکنون SOM در بسیاری از مطالعات هیدرولوژیکی بکار رفته است. به عنوان نمونه می‌توان به خوشه‌بندی و دستیابی به مناطق مشابه براساس رواناب (Ley et al., 2011)؛ دستیابی به مناطق همگن هیدرولوژیکی (Farsadnia et al., 2014)؛ میان‌یابی بارندگی ماهانه (Kaltch and Berndtsson, 2007)؛ بررسی کارایی مدل‌های هیدرولوژیکی با استفاده از جمع‌بندی شاخص‌های کارایی<sup>۸</sup> (Herbst and Casper, 2008) و تعیین پارامترهای مدل‌های شبکه عصبی برپایه توابع شعاعی<sup>۹</sup> جهت برآورد جریان ورودی به مخزن (Lin and Wu, 2011) اشاره نمود.

اخیراً SOM مستقیماً به عنوان ابزار تخمین گر قوی و غیرحساس به داده‌های مفقود بکار گرفته شده است. Mwale et al. (2012) SOM به منظور تخمین داده‌های مفقود در سری‌های زمانی بارندگی

تبخیر-تعرق گیاه مرجع ( $ET_0$ ) به عنوان یکی از مهمترین مولفه‌های چرخه هیدرولوژیکی، در طراحی سیستم‌های آبیاری، برنامه‌ریزی آبیاری، مدل‌سازی بارش-رواناب و مدیریت منابع آب کاربرد دارد. بدلیل اهمیت برآورد صحیح  $ET_0$ ، روش‌های متعددی جهت اندازه‌گیری مستقیم و برآورد غیرمستقیم آن ارائه شده است. هرچند هر یک از این روش‌ها محدودیت‌هایی دارند. به‌عنوان مثال، روش‌های اندازه‌گیری مستقیم  $ET_0$  مبتنی بر اندازه‌گیری میدانی با استفاده از انواع لایسیمتر، نیازمند صرف وقت، دقت بالا و هزینه‌ی نسبتاً زیاد هستند و تنها در کارهای تحقیقاتی و واسنجی ضرایب سایر فرمول‌های تجربی تخمین  $ET_0$  به کار می‌روند.

بنابراین فعالیت‌های پژوهشی محققان بر روی تکنیک‌های تخمین غیرمستقیم  $ET_0$ ، براساس اطلاعات هواشناسی متمرکز است که به دو دسته‌ی روش‌های تحلیلی و روش‌های تجربی تقسیم می‌شوند. اولین روش تحلیلی که براساس فرآیندهای فیزیکی بنا نهاده شده، معادله پنمن (1948) Penman است که با ترکیب معادله بیلان انرژی و روش انتقال جرم، مقدار تبخیر از سطح آزاد آب را محاسبه می‌کند. سپس Monteith (1965) مقاومت روزنه‌ای گیاه را وارد معادله پنمن نمود و معادله‌ای تحت عنوان پنمن-مانتیت جهت محاسبه  $ET_0$  ارائه نمود. تحقیقات متعددی به منظور اعتبارسنجی معادله پنمن-مانتیت در سراسر جهان انجام شده است (Allen, 1986). از جمله می‌توان به تحقیقی که توسط Jensen et al. (1990) انجام شد اشاره کرد که با مقایسه نتایج حاصل از معادله ترکیبی پنمن-مانتیت و روش‌های تجربی با نتایج لایسیمتر در ۱۱ نقطه‌ی جهان با اقلیم‌های متفاوت، نشان دادند روش ترکیبی پنمن-مانتیت بهترین نتایج را در تمام اقلیم‌ها دارد.

سازمان جهانی غذا و کشاورزی<sup>۱</sup> توصیه می‌کند در جایی که متغیرهای اقلیمی مورد نیاز در دسترس هستند،  $ET_0$  با استفاده از معادله اصلاح شده پنمن-مانتیت محاسبه شود. در واقع معادله فائو-پنمن-مانتیت حالت خاصی از معادله پنمن-مانتیت با تغییر پارامترهای آیرودینامیک و مقاومت سطحی برای گیاه مرجع چمن است (Shuttleworth, 1993). بزرگترین محدودیت روش فائو-پنمن-مانتیت، نیازمندی آن به مجموعه کاملی از اطلاعات هواشناسی روزانه از جمله تابش خورشیدی، دمای هوا، سرعت باد و رطوبت نسبی است. عدم وجود اطلاعات کافی در بیش‌تر کشورهای در حال توسعه و محاسبات پیچیده و وقت‌گیر این معادله، منجر به توسعه معادلات تجربی گردیده است.

پاسکال)؛  $\Delta$  شیب منحنی فشار بخار (کیلو پاسکال بر درجه سلسیوس) و  $\gamma$  ضریب سایکرومتری (کیلو پاسکال بر درجه سلسیوس) است.

صورت کسر معادله (۱) از دو جمله انرژی (تابش) و آیرودینامیکی تشکیل شده است. به این دلیل است که این روش را ترکیبی می‌نامند زیرا ترکیبی از انرژی و جنبه‌های آیرودینامیکی را در محاسبه تبخیر-تعرق گیاه مرجع لحاظ می‌کند. برای جزئیات بیشتر در مورد معادله فائو-پنمن-مانتیت می‌توان به آلن و همکاران (۱۹۹۸) مراجعه کرد.

## ۲-۲- مدل‌های تجربی برآورد تبخیر-تعرق گیاه مرجع

اگرچه  $ET_{FPM}$  معادله‌ای توصیه شده است، اما مدل‌های دیگری نیز تکامل یافته‌اند که تا حد زیادی تجربی بوده و برای موقعیت‌های استفاده می‌شوند که در آن تنها یک زیر مجموعه از داده‌های مورد نیاز برای استخراج  $ET_{FPM}$  موجود است. در نتیجه می‌توان تخمین‌های  $SOM$  را در برابر عملکرد برخی مدل‌های تجربی موجود مقایسه نمود. بنابراین، تجزیه و تحلیل مقایسه‌ای مدل‌های مبتنی بر  $SOM$  و چهار مدل تبخیر-تعرق تجربی معمول، انجام می‌شود. این مدل‌ها عبارت‌اند از، مدل‌های تجربی هارگریوز-سامانی، پرستلی-تیلر، ماکینگ و تورک. جزئیات این مدل‌ها در جدول ۱ خلاصه شده است. اگر چه فرمول‌های مختلفی برای این مدل‌ها در طول سال‌ها پدید آمده است، اما فرمول ارائه شده در جدول ۱ از طرف  $FAO$  توصیه می‌شود (آلن و همکاران، ۱۹۹۸).

## ۲-۳- منطقه مورد مطالعه و داده‌های مورد استفاده

به منظور بررسی کارایی مدل از داده‌های ایستگاه هواشناسی مشهد (عرض جغرافیایی  $36^{\circ}16'N$  و طول جغرافیایی  $59^{\circ}38'E$  و ارتفاع ۹۹۹/۲ متر) که واقع در اقلیم سرد و خشک است، استفاده گردید. داده‌های مورد استفاده با احتساب روزهایی که آمار در ایستگاه هواشناسی برداشت نشده برابر ۱۰۳۶۷ کد بردار<sup>۱۲</sup> بین سال‌های ۱۹۸۱ تا ۲۰۱۰ می‌باشد. خلاصه آماری متغیرها در نمودار جعبه‌ای<sup>۱۳</sup> شکل (۱) الف) نشان داده شده است. برای محاسبه  $ET_0$  با روش‌های تجربی و فائو-پنمن-مانتیت از نرم افزار REF-ET استفاده شد. الگوریتم استفاده شده در این نرم افزار برگرفته از دستورالعمل  $ASCE$  و نشریه فائو ۵۶ (Allen et al., 1998) می‌باشد. مقادیر محاسبه شده  $ET_0$  به روش  $FPM$  در ماه‌های مختلف سال در شکل (ب) نشان داده شده است. بطور متوسط  $ET_0$  سالانه در منطقه مورد مطالعه ۳/۹ میلی‌متر در روز است.

و جریان رودخانه پرداختند. نتایج آنها نشان داد که این تکنیک از توانایی خوبی جهت برآورد داده‌های مفقود هیدرولوژیکی برخوردار است. Rustum et al. (2008) مدل شبکه عصبی براساس  $SOM$  به منظور پیش‌بینی سریع تقاضای اکسیژن بیوشیمیایی<sup>۵</sup> روزه<sup>۱۰</sup> ارائه کردند. نتایج مدل ارائه شده توسط آنها توافق خوبی با مقادیر اندازه‌گیری شده توسط روش سنتی داشت. با توجه به وابستگی تبخیر-تعرق به پارامترهای متعدد و احتمال مفقود بودن هر یک از آنها، می‌توان  $SOM$  را برای برآورد تبخیر-تعرق گیاه مرجع با داده‌های مفقود بکار برد.

در زمینه کاربرد  $SOM$  برای برآورد تبخیر-تعرق می‌توان به دو مطالعه Chang et al. (2010) و Adeloye et al. (2011) اشاره نمود. et Chang al. (2010) روش‌های مختلف تخمین غیرمستقیم از تشتک تبخیر، از جمله  $SOM$ ، FFANN<sup>۱۱</sup>، معادله پنمن اصلاح شده و معادله پنمن-مانتیت را بررسی کردند و متوجه شدند که  $SOM$  بهترین نتیجه را دارد. Adeloye et al. (2011) به بررسی ترکیب داده‌های مختلف آب و هوایی به‌عنوان ورودی  $SOM$  در دو منطقه آب و هوایی معتدل ادینبورگ در انگلستان و دیگری نیمه خشک آدیپور واقع در هندوستان پرداختند و دریافتند که تخمین‌های مبتنی بر  $SOM$  حتی با تعداد متغیر ورودی کم نیز از دقت قابل قبولی برخوردار است.

در این مقاله، با به‌کارگیری تکنیک  $SOM$  برای توسعه و بررسی مدل تخمین‌گر تبخیر-تعرق گیاه مرجع با حداقل داده‌های هواشناسی، از داده‌های ایستگاه هواشناسی مشهد برای بررسی صحت و دقت مدل ارائه شده استفاده گردید. در نهایت کارایی مدل ارائه شده با چندین روش تجربی مقایسه شد.

## ۲- مواد و روش‌ها

### ۲-۱- معادله فائو-پنمن-مانتیت

معادله فائو-پنمن-مانتیت ( $FPM$ ) برای محاسبه تبخیر-تعرق گیاه مرجع به صورت زیر بیان شده است:

$$ET_{FPM} = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (1)$$

$ET_{FPM}$  تبخیر-تعرق گیاه مرجع (میلی‌متر بر روز)؛  $R_n$  تابش خالص ورودی به سطح گیاه (مگاژول بر متر مربع بر روز)؛  $G$  شار گرمای خاک (مگاژول بر متر مربع بر روز)؛  $T$  میانگین روزانه دمای هوا در ارتفاع دومتری (درجه سلسیوس)؛  $u_2$  میانگین روزانه سرعت باد در ارتفاع دو متری (متر بر ثانیه)؛  $e_s$  فشار بخار اشباع (کیلو پاسکال)؛  $e_a$  فشار بخار واقعی (کیلو پاسکال)؛  $e_s - e_a$  کمبود فشار بخار اشباع (کیلو

## ۲-۴- نگاشت خود-سامان (SOM)

شامل تعداد زیادی خصوصیات با واحدها و بزرگی‌های متفاوتی نسبت به یکدیگرند، از رابطه (۲) برای نرمال‌سازی مقادیر ورودی جهت بهبود مدل‌سازی استفاده می‌شود.

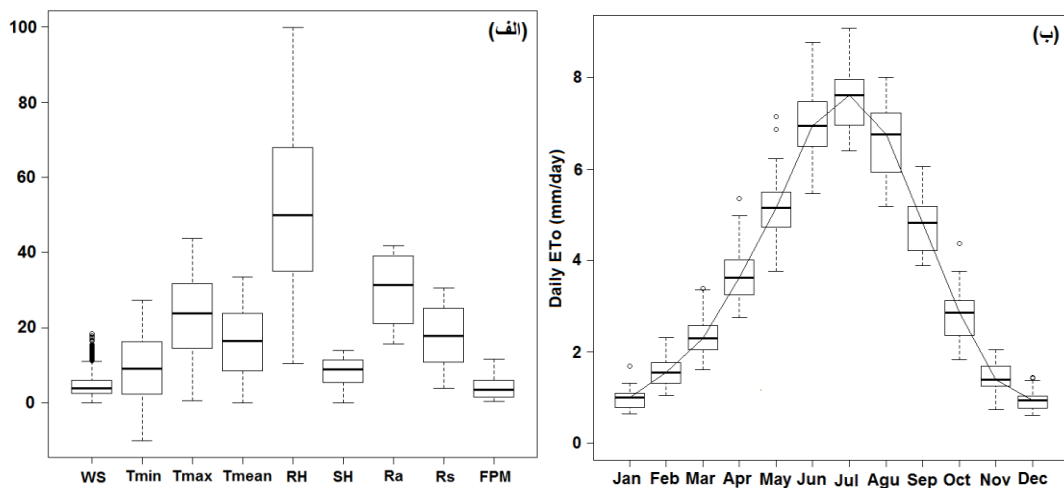
$$X' = (X_i - \bar{X}) / \sigma_x \quad (2)$$

$X_i$  (i=1,2,...,m) یک متغیر ورودی باشد،  $\bar{X}$  میانگین و  $\sigma_x$  انحراف معیار متغیر  $X_i$  می‌باشند. نرمال‌سازی داده‌ها باعث می‌شود تا میانگین مجموعه داده‌ها صفر و انحراف معیار آنها یک شود. تعداد نرون‌های خروجی SOM (یا اندازه نقشه) در یافتن انحراف داده‌ها مهم است. اگر اندازه نقشه خیلی کوچک باشد، نمی‌تواند برخی تفاوت‌های مهم را آشکار کند.

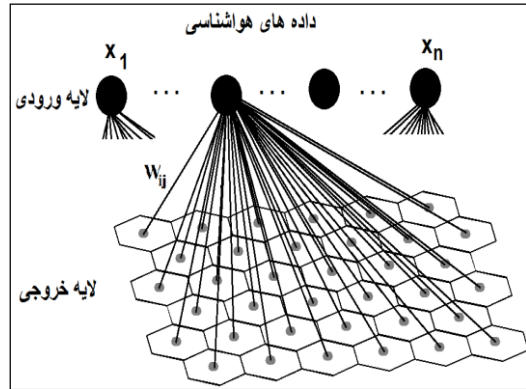
نگاشت خود-سامان تابع چگالی احتمال از داده‌های ورودی تحت الگوریتم یادگیری غیر-نظارت شونده است، که به‌عنوان روشی موثر جهت خوشه‌بندی، خلاصه‌سازی و بصری نمودن داده‌ها به‌کار می‌رود (Kohonen, 2001). این الگوریتم دارای خصوصیات حفاظت از همسایگی و تجزیه و تحلیل فضای ورودی متناسب با توزیع داده‌ها است (Kohonen, 2001, 1982). SOM شامل دو لایه است: یک لایه ورودی متشکل از مجموعه گره‌ها<sup>۱۴</sup> (در این مطالعه داده‌های هواشناسی بمنظور تخمین تبخیر-تعرق گیاه مرجع) و یک لایه خروجی (یا لایه کوهونن) که توسط گره‌هایی که در شبکه‌ای دو بعدی قرار گرفته‌اند، است (شکل ۲). با توجه به اینکه داده‌های خام ورودی

جدول ۱- روابط تجربی برآورد تبخیر-تعرق گیاه مرجع

$T_{min}$ ، $T_{max}$ و $T_{mean}$ حداقل، حداکثر و متوسط دمای هوا؛ $Ra$ تابش برون زمینی؛ $R_n$ تابش خالص ورودی به سطح گیاه؛ $G$ شار گرمای خاک؛ $\Delta$ شیب منحنی فشار بخار؛ $\gamma$ ضریب سایکرومتری؛ $\lambda$ گرمای نهان تبخیر ( $MJ/kg$ )؛ $a_T$ ضریب معادله تورک که تابعی از رطوبت نسبی است.	$ET_o = 0.0023(T_{max} - T_{min})^{0.5}(T_{mean} + 17.8)R_a$	هارگریوز-سامانی (Hargreaves and Samani, 1985)
$Ra$ تابش برون زمینی؛ $R_n$ تابش خالص ورودی به سطح گیاه؛ $G$ شار گرمای خاک؛ $\Delta$ شیب منحنی فشار بخار؛ $\gamma$ ضریب سایکرومتری؛ $\lambda$ گرمای نهان تبخیر ( $MJ/kg$ )؛ $a_T$ ضریب معادله تورک که تابعی از رطوبت نسبی است.	$ET_o = 1.26 \frac{\Delta}{\Delta + \gamma} \frac{R_n - G}{\lambda}$	پرستلی-تیلر (Priestley and Taylor, 1972)
$R_n$ تابش خالص ورودی به سطح گیاه؛ $G$ شار گرمای خاک؛ $\Delta$ شیب منحنی فشار بخار؛ $\gamma$ ضریب سایکرومتری؛ $\lambda$ گرمای نهان تبخیر ( $MJ/kg$ )؛ $a_T$ ضریب معادله تورک که تابعی از رطوبت نسبی است.	$ET_o = 0.61 \frac{\Delta}{\Delta + \gamma} \frac{R_s}{2.45} - 0.12$	ماکینگ (Makkink, 1957)
$T_{mean}$ ؛ $R_s$ تابش خالص ورودی به سطح گیاه؛ $G$ شار گرمای خاک؛ $\Delta$ شیب منحنی فشار بخار؛ $\gamma$ ضریب سایکرومتری؛ $\lambda$ گرمای نهان تبخیر ( $MJ/kg$ )؛ $a_T$ ضریب معادله تورک که تابعی از رطوبت نسبی است.	$ET_o = a_T 0.013 \frac{T_{mean}}{T_{mean} + 15} \frac{23.8856 R_s + 50}{\lambda}$	تورک (Turc, 1961)

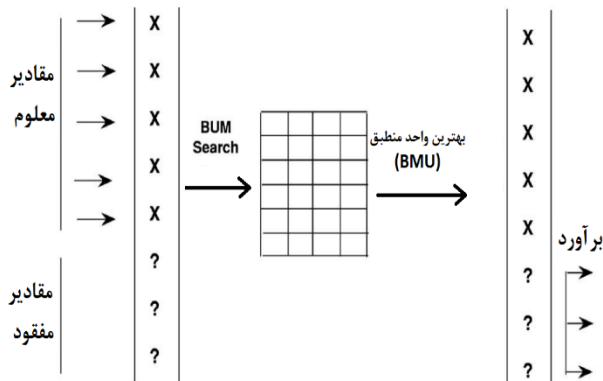


شکل ۱ (الف) نمودار جعبه‌ای مجموعه داده‌های آب و هوایی موجود. WS: سرعت باد؛ Tmin: حداقل دمای هوا؛ Tmax: حداکثر دمای هوا؛ Tmean: میانگین دمای هوا؛ RH: رطوبت نسبی؛ SH: تابش خورشیدی؛ Ra: تابش برون زمینی؛ Rs: تابش طول موج کوتاه و FPM: تبخیر-تعرق گیاه مرجع محاسبه شده به روش فائو-پنمن-مانتیت (ب) مقادیر تبخیر-تعرق گیاه مرجع محاسبه شده با روش فائو-پنمن-مانتیت در ماه‌های مختلف



شکل ۲- طرح شماتیک از ساختار نگاشت خود سامان

*SOM* کاربرد زیادی در زمینه‌های مختلف مانند شناسایی گفتار، مدل‌سازی زیستی، فشردن داده‌ها، پردازش سیگنال، داده کاوی و درون‌یابی و برون‌یابی غیرخطی (پیش‌بینی) دارد (Kohonen, 2001). استفاده از *SOM* برای پیش‌بینی، که هدف اصلی این مطالعه است در شکل ۳ نشان داده شده است. ابتدا، مدل با استفاده از زیر مجموعه داده‌های موجود، آموزش داده می‌شود. سپس برداری ناقص یعنی برداری فاقد مقادیر *ETo* جهت شناسایی بهترین واحد منطبق<sup>۱۵</sup>، براساس فاصله اقلیدسی به مدل ارائه می‌شود. سپس مقادیر متغیر مفقود (*ETo*) از مقدار متناظر آن در *BMU*، در نظر گرفته می‌شود.



شکل ۳- پیش‌بینی مقادیر مفقود در بردار ورودی با استفاده از نگاشت خود-سازمانده (مرجع: (Rustum and Adeloye (2007)).

## ۲-۵- ارزیابی کارایی مدل

کارایی مدل در مراحل آموزش و اعتبارسنجی با استفاده از معیارهای آماری زیر مورد بررسی قرار گرفت.

- جذر میانگین مربعات خطا<sup>۱۶</sup> که بصورت زیر نوشته می‌شود:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (ET_{FPM} - ET_{predict})^2} \quad (4)$$

که در آن  $ET_{FPM}$  -تخیر-تغرق گیاه مرجع حاصل از معادله *FPM*;  $ET_{predict}$  -تخیر-تغرق گیاه مرجع حاصل از مدل است. این شاخص معیاری برای دقت نتایج است و معمولاً هرچه مدل بهتر بر داده‌ها منطبق باشد، مقدار آن کمتر می‌شود.

- ضریب تعیین<sup>۱۷</sup> ( $R^2$ ) بیانگر میزان احتمال هم‌بستگی میان مقادیر مشاهده شده و پیش‌بینی شده می‌باشد. مقدار  $R^2$  بین ۰ و ۱۰ متغیر است و مقدار  $R^2$  برای پیش‌بینی مناسب باید برابر ۱ باشد.

- معیار کارایی مدل ناش-ساتکلیف<sup>۱۸</sup> بیانگر رابطه بین مقادیر مشاهده شده و پیش‌بینی شده می‌باشد و در بازه  $-\infty$  تا  $+\infty$  تغییر می‌کند. هر چه این معیار نزدیک‌تر به  $+\infty$  باشد نشان دهنده رابطه قوی بین دو متغیر است (Nash and Sutcliffe, 1970).

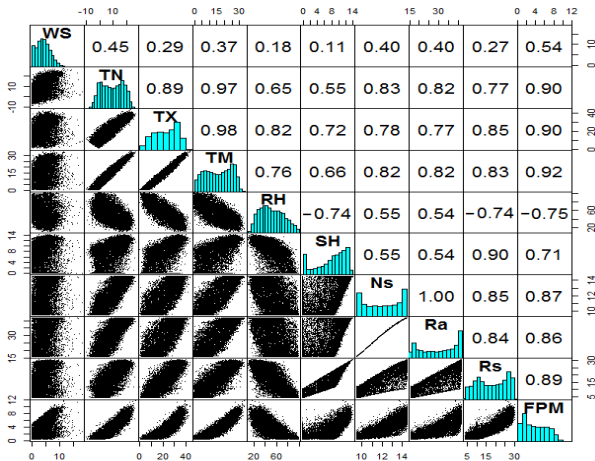
در مقابل، اگر اندازه نقشه خیلی بزرگ باشد، تفاوت‌ها خیلی کم می‌شود (Wilppu, 1997). می‌توان تعداد نرون‌های خروجی در *SOM* را با استفاده از روش ابتکاری پیشنهاد شده توسط Vesanto et al (2000) انتخاب کرد. تقریباً تعداد بهینه‌ی واحدهای نقشه برابر  $5 \times \sqrt{N}$  می‌باشد که  $N$  تعداد نمونه‌ها در مجموعه داده‌ها هستند.

هر گره در لایه ورودی توسط شبکه‌ی سیناپسی به هر گره در لایه خروجی متصل است. هر گره خروجی دارای بردار ضرایب (وزن یا شدت اتصال،  $W$ ) است که متصل به داده‌های ورودی است. زمانی که برداری از ورودی ( $X'$ ) به *SOM* وارد شود، گره‌ها در لایه خروجی با یکدیگر رقابت کرده و گره برنده (گره‌ای که فاصله‌ی تمامی وزن‌هایش از بردار ورودی حداقل است) انتخاب می‌شود. براساس قاعده یادگیری کوهونن، بردار وزن گره برنده و همسایه‌های از پیش تعریف شده‌اش در الگوریتم به روز رسانی می‌شوند:

$$W_{ij}(t+1) = W_{ij}(t) + \alpha(t) \cdot h_{jc}(t) [X_i(t) - W_{ij}(t)] \quad (3)$$

که  $W_{ij}(t)$  وزن بین گره  $i$  در لایه ورودی و گره  $j$  در لایه خروجی در زمان تکرار  $t$  است و  $\alpha(t)$  فاکتور سرعت یادگیری است که تابعی نزولی از زمان تکرار  $t$  و تابع همسایگی (هسته اصلی هموار سازی تعریف شده روی نقاط شبکه) است که مقدار همسایگی از گره برنده  $(c)$  در طی فرآیند یادگیری بروز رسانی می‌شود. فرآیند یادگیری تا زمانی که معیار توقف (معمولاً زمانی که بردار وزن ثابت شود و/یا زمانی که تعداد تکرارها کامل شود) معرفی شود، ادامه می‌یابد. در این روش هر گره در نگاشت توانایی تشخیص بردارهای ورودی مشابه خود را دارد. این ویژگی را خود-سازمان یابندگی می‌گویند، چرا که هیچ اطلاعات خارجی برای طبقه‌بندی نیاز نیست (Penn, 2005). برای جزئیات بیشتر در مورد الگوریتم *SOM* می‌توان به Haykin (2003) مراجعه کرد.

هواشناسی است که در تمام ایستگاه‌های هواشناسی اندازه‌گیری می‌گردد. همچنین دما و حداکثر ساعات آفتابی در بیش‌تر مدل‌های تجربی نیز به عنوان متغیر ورودی استفاده شده و قابلیت مقایسه مدل SOM3 با مدل‌های تجربی را می‌دهد.



شکل ۴- ماتریس ضرایب همبستگی، هیستوگرام و نمودار نقطه‌ای خصوصیات آب و هوایی در مجموعه داده‌های آموزش (WS) سرعت باد؛ TN حداقل دمای هوا؛ TX حداکثر دمای هوا؛ TM متوسط دمای هوا؛ RH رطوبت نسبی؛ SH تابش خورشیدی؛ Ns حداکثر ساعات آفتابی؛ Ra تابش برون زمینی؛ Rs تابش طول موج کوتاه و FPM تبخیر تعرق گیاه مرجع محاسبه شده به روش فائو-پنمن-مانتیت

### ۳-۲- آموزش مدل SOM

متغیرهای ورودی سه مدل ذکر شده دارای واحدها و بزرگی متفاوتی نسبت به یکدیگر هستند و متغیرهایی که دارای مقادیر بزرگتری هستند، نقش مهمتری در فرآیند به روزرسانی وزن‌ها ایفا می‌کنند. بنابراین نرمالیزه کردن بردار ورودی می‌تواند در بهبود مدل کمک کند. به منظور آموزش شبکه متغیرهای ورودی مدل‌ها نرمالیزه شدند. دو سوم داده‌های موجود برای آموزش (۶۹۱۱ روز) و یک سوم برای اعتبارسنجی (۳۴۵۶ روز) مدل استفاده شدند. نرخ یادگیری برابر  $\alpha_0 = 0.5$  انتخاب گردید و اندازه نقشه<sup>۱۹</sup> براساس فرمول پیشنهادی Vesanto et al (2000) در مدل SOM1 برابر  $14 \times 36$ ، در مدل SOM2 برابر  $11 \times 41$  و در مدل SOM3 برابر  $11 \times 46$  انتخاب گردید. به‌واسطه فرآیند یادگیری SOM، بردار وزن متناسب با چگالی احتمال داده‌ها تخمین زده شد. شکل ۵ تا ۷ توزیع تدریجی داده‌های هواشناسی را در نقشه آموزش یافته SOM را به‌صورت بصری نشان می‌دهد. مقدار هر داده هواشناسی در واحدهای خروجی SOM اهمیت آنرا در هر واحد<sup>۲۰</sup> نشان می‌دهد. در شکل‌های ۵ تا ۷ رنگ تیره نشان دهنده مقایره زیاد هر داده و رنگ سفید کمترین مقادیر را نشان می‌دهد. به‌عنوان نمونه در مدل SOM1 مقادیر تبخیر-تعرق گیاه مرجع که با معادله FPM محاسبه شده در قسمت راست-پایین شکل ۵ بیشترین

$$NS = I - \frac{\sum_{i=1}^n (ET_{FPM} - ET_{predict})^2}{\sum_{i=1}^n (ET_{FPM} - \overline{ET_{FPM}})^2} \quad (5)$$

### ۲-۶- خوشه‌بندی واحدهای SOM

در این مطالعه از ماتریس وزن‌های خروجی SOM به‌عنوان ورودی در الگوریتم خوشه‌بندی فازی (Bezdek, 1981) برای مشخص کردن خوشه‌ها روی نقشه آموزش یافته به کار رفت. جزئیات خوشه‌بندی فازی توسط Farsadnia et al. (2014) توضیح داده شده است.

یکی از مهمترین مسایل در خوشه‌بندی فازی انتخاب تعداد خوشه‌ی مناسب می‌باشد. بدین منظور باید هر خوشه بیشترین فشردگی را داشته باشند و بین خوشه‌ها حداکثر فاصله وجود داشته باشد. براساس توصیه Farsadnia et al. (2014) از دو شاخص (Xie and Beni, 1991) و (Kwon, 1998) جهت تعیین تعداد خوشه مناسب استفاده شد. کمترین مقادیر این دو شاخص نشان دهنده تعداد خوشه بهینه می‌باشد.

### ۳- نتایج و بحث

#### ۳-۱- پیش پردازش و انتخاب ورودی مدل SOM

به منظور تعیین ورودی مدل SOM، سه سناریو براساس دسترسی و سهولت اندازه‌گیری متغیرها و مقدار ارتباط بین متغیرها با  $ET_{FPM}$  مد نظر قرار گرفت. در سناریوی (۱) از تمام متغیرهای ورودی معادله FPM استفاده گردید تا بتوان عملکرد مدل را نسبت به روش مرجع که توسط فائو توصیه شده، ارزیابی نمود. در سناریوی (۲) از متغیرهای در دسترس که حداکثر همبستگی با  $ET_{FPM}$  را دارند، استفاده گردید. به این منظور همبستگی بین داده‌های هواشناسی و  $ET_{FPM}$  تعیین شد (شکل ۴). با توجه به همبستگی بالای دمای حداقل، حداکثر و میانگین با  $ET_{FPM}$ ، می‌بایست متغیر دما انتخاب گردد، اما با توجه به همبستگی بالا بین متغیرهای دما با یکدیگر، به منظور کاهش بعد متغیرهای ورودی با همبستگی بالا، تنها از دمای میانگین به‌عنوان ورودی در سناریو ۲ و ۳ استفاده شد. همبستگی تابش برون زمینی و تابش طول موج کوتاه نیز با  $ET_{FPM}$  بالا (بترتیب  $0.86$  و  $0.89$ ) است. با توجه به اینکه تابش برون زمینی نیاز به اندازه‌گیری نداشته و می‌تواند با محاسبه به‌دست آید، به‌عنوان ورودی بعدی مدل انتخاب گردید. متغیر بعدی حداکثر ساعات آفتابی است که نیاز به اندازه‌گیری نداشته و همبستگی بالایی ( $0.87$ ) با  $ET_{FPM}$  نشان می‌دهد. به‌طور کلی سه متغیر میانگین دمای هوا، تابش برون زمینی و حداکثر ساعات آفتابی به‌عنوان ورودی سناریوی (۲) انتخاب شد. در سناریوی (۳) از متغیر دما و حداکثر ساعات آفتابی به‌عنوان ورودی مدل استفاده شد، زیرا دما ساده‌ترین داده




### ۳-۳- خوشه‌بندی فازی واحدهای SOM


راهی دقیق برای شناسایی تعداد خوشه‌های واحدهای خروجی SOM، استفاده از C-میانگین فازی<sup>۲۱</sup> است. الگوریتم FCM براساس بهینه‌سازی تابع هدف با تکرار است و با روش سعی و خطا تعداد مناسب خوشه‌ها تعیین می‌شود. برای مشخص کردن تعداد بهینه خوشه‌ها توابع مختلفی تعریف شده است که می‌توان با استفاده از آنها تعداد خوشه‌ها را مشخص کرد.

در این مطالعه بنا به توصیه‌ی (Farsadnia et al. (2014) برای تعیین تعداد بهینه خوشه‌های فازی (C) از شاخص‌های ارزیابی وون و زی-بنی استفاده شده است. افزاز بهینه مربوط به حداقل مقادیر شاخص‌های ارزیابی وون (Kwon, 1998) یا زی-بنی (Xie and Beni, 1991) است، که به فشردگی و نیز جدایی خوب خوشه‌ها بستگی دارد.


مقادیر و در قسمت بالا، کمترین مقادیر را داد. در مقابل آن، مقادیر میانگین رطوبت نسبی قرار دارد که در پایین نقشه‌ی خروجی کمترین مقادیر و بالعکس در بالای آن بیشترین مقادیر را دارد. این موضوع با توجه به همبستگی منفی (۰/۷۵-) بین این دو متغیر توجیه می‌شود. به همین ترتیب شیب رنگ در نقشه خروجی SOMI برای  $ET_{FPM}$  به موازات متغیرهای  $R_s$ ،  $TN$  و  $TX$  است. با توجه به شکل ۴ می‌توان همبستگی مثبت و بالای این متغیرها را دید. از سوی دیگر، شیب رنگ خاکستری  $ET_{FPM}$  و  $WS$  چندان از روند خاصی پیروی نمی‌کند، که نشان دهنده همبستگی پایین‌تر این دو متغیر (۰/۵۴-) است. این موضوع کاربرد SOM در خوشه‌بندی و بصری نمودن نتایج را نشان می‌دهد. بعبارت دیگر، الگوریتم SOM مقادیر مشابه را در نقشه‌ی خروجی SOM کنار هم قرار می‌دهد.



شکل ۵- توزیع داده‌های هواشناسی در نقشه آموزشی یافته مدل SOM1



شکل ۶- توزیع داده‌های هواشناسی در نقشه آموزشی یافته مدل SOM2



شکل ۷- توزیع داده‌های هواشناسی در نقشه آموزشی یافته مدل SOM3

مشاهده می‌شود. عملکرد برای مجموعه داده‌های اعتبارسنجی برای مدل‌های ۲ و ۳ در مشهد برابر  $R^2 = 0/9168$  و  $R^2 = 0/9176$  است. در واقع،  $SOM3$  که تنها از میانگین درجه حرارت و ساعات آفتابی روزانه استفاده می‌کند، در طول آموزش و اعتبارسنجی، بهتر از  $SOM2$  عمل می‌کند و این امر استفاده از ساعات آفتابی را به جای تابش خورشیدی، توجیه می‌کند. این موضوع با نتایج مطالعه‌ی (Adeloye et al. (2011) سازگاری نشان می‌دهد. همچنین پراکندگی نقاط برای هر سه مدل نسبت به خط ۱:۱ در داده‌های آموزش و اعتبارسنجی یکنواخت است. با توجه نمودارهای داده‌های اعتبارسنجی مدل‌های  $SOM2$  و  $SOM3$  می‌توان دید که به ازاء مقادیر زیاد  $ET_{FPM}$ ، کمی نسبت به خط ۱:۱ کم برآورد نشان می‌دهند. البته با توجه به اینکه از داده‌های در دسترس و کمی نسبت به  $FPM$  استفاده می‌کنند، دقت بدست آمده قابل قبول است.

### ۳-۵- مقایسه نتایج مدل SOM با فرمول‌های تجربی

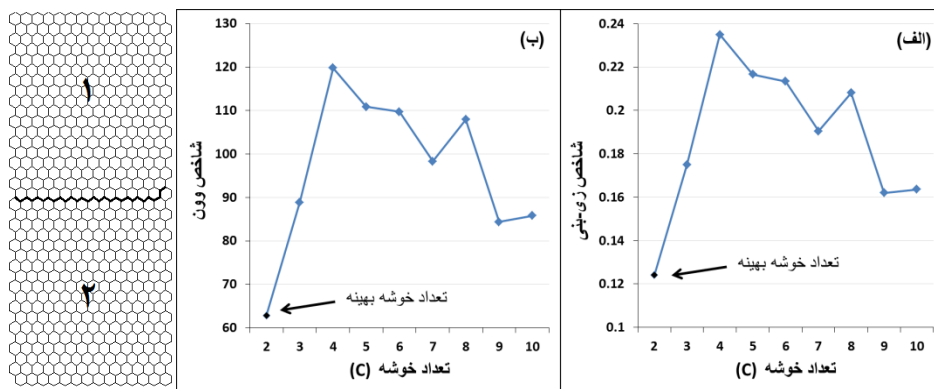
نتایج بخش (۳-۵) نشان داد که مدل  $SOM1$  توانایی لازم برای برآورد  $ET_{FPM}$  با حداقل خطا را داراست. همچنین مدل‌های  $SOM2$  و  $SOM3$  مدلهایی دقیق با حداقل داده‌های هواشناسی بعنوان ورودی هستند که می‌توان از آنها در شرایط کمبود داده استفاده کرد. در این بخش کارایی این مدل‌ها در مقایسه با مدل‌های تجربی مورد بررسی قرار می‌گیرد.

مقادیر شاخص‌های زی-بنی و وون مقابل تعداد خوشه‌ها در شکل (۸) الف و ب) رسم شد. کمترین مقادیر این دو شاخص در  $C=2$  حاصل شد. بنابراین واحدهای خروجی  $SOM1$  به دو خوشه تقسیم شد (شکل ۸ پ).

با در کنار هم قرار دادن شکل‌های ۵ و ۸ مشخص است خوشه‌بندی واحدهای  $SOM1$  خروجی آن را به دو فصل با مقادیر زیاد و کم  $ET_{FPM}$  تقسیم کرده است و این موضوع با اقلیم مشهد تطابق دارد. خوشه اول مربوط به فصل زمستان با مقادیر پایین  $ET_o$  و دمای هوا و مقادیر بالای رطوبت نسبی است. خوشه دوم شامل مقادیر بالای  $ET_o$  و تابش طول موج کوتاه و مربوط به فصول گرم سال است.

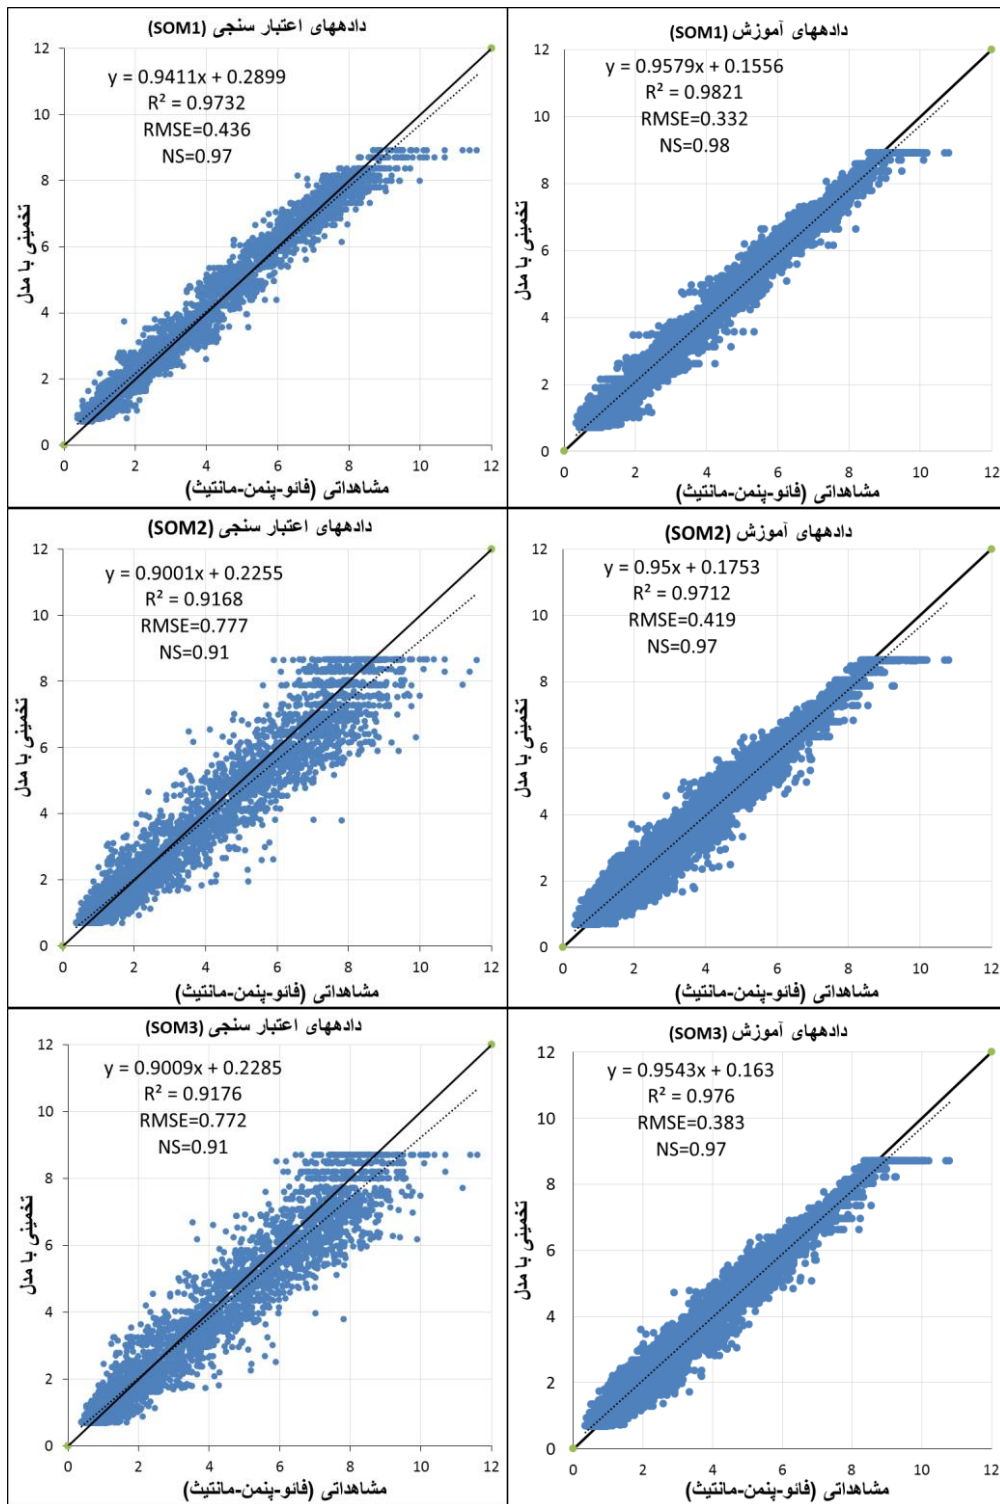
### ۳-۴- ارزیابی کارایی مدل SOM برای برآورد $ET_o$

شکل ۹ مقادیر پارامترهای ارزیابی عملکرد (میانگین مربعات خطا، ضریب تعیین و معیار ناش-ساتکلیف) سه مدل  $SOM$  را طی آموزش و اعتبارسنجی نشان می‌دهد و همه آنها بر برتری مدل  $SOM1$  برای داده‌های آموزش و اعتبارسنجی صحنه می‌گذارند. با این حال در شکل ۹ قابل توجه است که حتی مدل‌های  $SOM2$  و  $SOM3$  که تنها از یک زیرمجموعه از متغیرهای ورودی مورد نیاز برای محاسبه  $ET_{FPM}$  استفاده می‌کنند، هنوز هم در مجموعه داده‌های آموزش همبستگی بسیار بالایی بین داده‌های مشاهداتی و پیش‌بینی شده تبخیر-تعرق (به ترتیب با  $R^2 = 0/9712$  و  $R^2 = 0/976$  برای مدل‌های ۲ و ۳)



شکل ۸- شاخص‌های زی-بنی (الف) و وون (ب) به ازای مقادیر مختلف تعداد خوشه؛ (ب) نقشه خروجی  $SOM1$  خوشه‌بندی شده با روش FCM





شکل ۹ نمودار نقطه‌ای، خط ۱:۱ و خط رگرسیونی بین  $ET_{FPM}$  محاسباتی با معادله  $FPM$  و مدل‌های  $SOM1$ ،  $SOM2$ ،  $SOM3$  برای مجموعه داده‌های آموزش و اعتبارسنجی

شده با معادله مرجع فائو-پنمن-مانتیت ترسیم شده است. همانطور که در شکل دیده می‌شود، سه مدل  $SOM$  مطابقت نزدیکی با  $FPM$  برای هر دو مجموعه داده‌های آموزش و اعتبارسنجی دارند، در حالی

مقادیر  $ET_{FPM}$  با استفاده از نرم افزار Ref-ET (Allen, 2001) محاسبه شد. در شکل (۱۰، الف و ب) متوسط ماهانه  $ET_{FPM}$  برآورد شده با ۴ مدل تجربی و مدل‌های  $SOM$  در مقایسه با  $ET_{FPM}$  محاسبه

ورودی در مشهد استفاده شد. ماتریس همبستگی برای تعیین بهترین ورودی مدل SOM بکار رفت. با توجه به مقادیر همبستگی بین متغیرهای هواشناسی و در دسترس بودن این متغیرها، سه مدل SOM با ورودی‌های مختلف توسعه یافت.

بر اساس شاخص‌های ارزیابی خوشه‌بندی فازی، تعداد خوشه بهینه برای نقشه خروجی SOM برابر ۲ تعیین شد. تقسیم  $ET_o$  مشهد به دو خوشه با تبخیر-تعرق کم و زیاد، با اقلیم منطقه مطابقت نشان داد. خوشه اول مربوط به فصل زمستان با مقادیر پایین  $ET_o$  و دمای هوا و مقادیر بالای رطوبت نسبی است. خوشه دوم شامل مقادیر بالای  $ET_o$ ، دما و تابش طول موج کوتاه و مربوط به فصول گرم سال است.

مقادیر پارامترهای ارزیابی عملکرد (میانگین مربعات خطا، ضریب تعیین و معیار ناش-ساتکلیف) مدل‌های SOM با ورودی‌های مختلف، طی آموزش و اعتبارسنجی نشان از برتری مدل SOM1 داد. با توجه به اینکه مدل SOM1 از پارامترهای هواشناسی متعددی به عنوان ورودی استفاده می‌کند، این موضوع قابل انتظار بود.

نتایج هر سه مدل SOM به طرز خیره کننده‌ای نزدیک به مقادیر بدست آمده از معادله فانو-پنمن-مانتیت بود. حتی مدل‌های ۲ و ۳ که تنها از میانگین دمای روزانه به عنوان تنها پارامتر اندازه‌گیری شده در ایستگاه هواشناسی، به عنوان ورودی استفاده کردند نیز از دقت مناسبی برخوردار بودند. در مقایسه با مدل‌های تجربی برآورد تبخیر-تعرق مرجع (حتی با انجام واسنجی) نیز مدل ۲ و ۳ با پارامترهای هواشناسی محدود به عنوان ورودی، نتایج بهتری ارائه کردند. بنابراین در شرایط کمبود داده‌های هواشناسی نیز استفاده از مدل SOM نسبت به مدل‌های تجربی برتر است.

که هیچ یک از چهار مدل تجربی هارگریوز-سامانی، پریستلی-تیلر، ماکینگ و تورک نتوانسته‌اند  $ET_{FPM}$  را به ویژه در ماه‌های تابستان بدرستی تخمین بزنند. علت این امر آن است که مدل‌های تجربی وابسته به مکان خاصی هستند و برای موقعیت‌های متفاوت ممکن است نتیجه مطلوب نداشته باشند و قبل از استفاده، نیازمند واسنجی در شرایط اقلیمی متفاوتند. واسنجی انجام شده بر اساس معادله کلی استوار زیر استوار است:

$$ET_{FPM} = a + b \times ET_{exp} \quad (5)$$

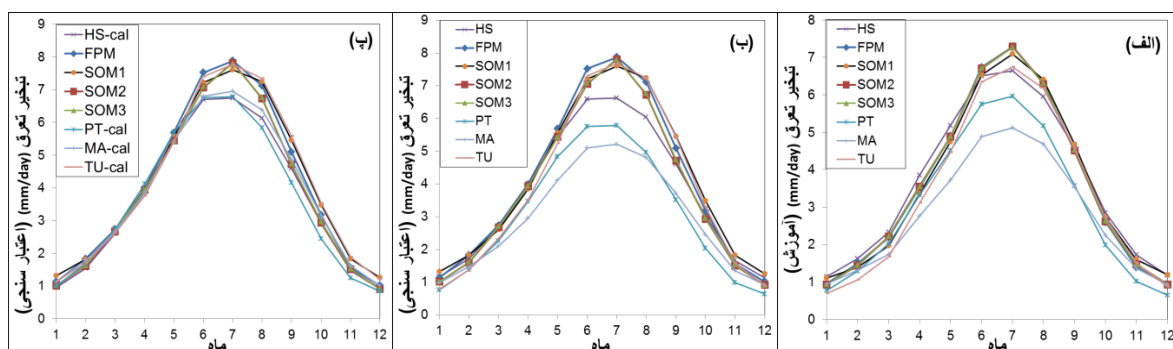
که در آن  $ET_{exp}$  نشان دهنده روش محاسبه تبخیر و تعرق و  $a$ ،  $b$  پارامترهای معادله می‌باشد. مقادیر پارامترهای واسنجی برای چهار مدل تجربی در جدول ۲ نشان داده شده است. با این حال، حتی پس از واسنجی تنها روش تجربی تورک، توانست عملکردی مشابه با مدل SOM داشته باشد (شکل ۱۰ پ).

جدول ۲- مقادیر ضرایب واسنجی معادلات تجربی و ضریب همبستگی

	$R^2$	$b$	$a$
			۰/۲۷۸۶
هارگریوز-سامانی	۰/۸۶۷۹	۱/۰۵۸۸	-
پریستلی-تیلر	۰/۸۸۸۶	۱/۱۵۵۷	۰/۱۰۲۶
			۰/۲۴۴۲
ماکینگ	۰/۸۷۲۱	۱/۳۷۸۸	-
تورک	۰/۸۷۴۸	۰/۹۶۲۵	۰/۳۶۷۸

#### ۴- نتیجه گیری

در این مطالعه از ویژگی پیش‌بینی روش نگاهت خود-سامان به عنوان یک روش شبکه عصبی مصنوعی غیر نظارت شونده جهت برآورد تبخیر-تعرق گیاه مرجع با حداقل پارامترهای هواشناسی به عنوان



شکل ۱۰- مقایسه مقادیر میانگین  $ET_{FPM}$  ماهانه برآورد شده با مدل‌های SOM و معادلات تجربی

- Haykin S (2003) Neural networks: A comprehensive foundation. Fourth Indian Reprint, Pearson Education, Singapore, p. 842.
- Herbst M and Casper MC (2008) Towards model evaluation and identification using Self-Organizing Maps. *Hydrology and Earth System Sciences* 12: 657-667.
- Jensen ME, Burman RD and Allen RG (1990) Evapotranspiration and irrigation water requirements. ASCE Manual and Report on Engineering Practice No.7. New York.
- Kalteh AM and Berndtsson R (2007) Interpolating monthly precipitation by self-organizing map (SOM) and multilayer perceptron (MLP). *Hydrology Science Journal* 52: 305-317.
- Kohonen T (1982) Self-organized formation of topologically correct feature maps. *Biological Cybernetics* 43: 59-69.
- Kohonen T (2001) *Self-Organizing Maps*. Springer, Berlin, Germany.
- Kumar M, Raghuwanshi NS and Singh R (2011) Artificial neural networks approach in evapotranspiration modeling: a review. *Irrigation Science* 29(1):11-25.
- Kwon SH (1998) Cluster validity index for fuzzy clustering. *Electronics Letters* 34 (22): 2176-2177.
- Ley R, Casper MC, Hellebrand H and Merz R (2011) Catchment classification by runoff behavior with self-organizing maps (SOM). *Hydrology and Earth System Sciences* 15(9): 2947-2962.
- Lin GF and Wu MC (2011) An RBF network with a two-step learning algorithm for developing a reservoir inflow forecasting model. *Journal of Hydrology* 405 (3-4): 439-450.
- Makkink GF (1957) Testing the Penman formula by means of lysimeters. *International Journal of Water Engineering* 11(3): 277-288.
- Monteith JL (1965) The state and movement of water in living organisms. *Proc., Evaporation and Environment, XIXth Symp., Soc. For Exp. Biol., Swansea, Cambridge University Press, New York*, 205-234.
- Mwale FD, Adeloje AJ and Rustum R (2012) Infilling of missing rainfall and streamflow data in the Shire River basin, Malawi – A self-organizing map approach. *Physics and Chemistry of the Earth* 50: 34-43.
- Nash JE and Sutcliffe JV (1970) River flow forecasting through conceptual models part I: A discussion of principles. *Journal of Hydrology* 10 (3): 282-290.
- 1-Food and Agriculture Organization (FAO)  
2-Calibration  
3-Artificial Intelligence (AI)  
4-Artificial Neural Network (ANN)  
5-Supervised ANNs  
6-Self-Organizing Map (SOM)  
7-Unsupervised ANNs  
8-Performance Measures  
9-Radial Basis Functions (RBF)  
10-Biochemical Oxygen Demand (BOD<sub>5</sub>)  
11-Feed-Forward Artificial Neural Network  
12-Code Vector  
13-Box Plot  
14-Nodes  
15-Best Matching Unit (BMU)  
16-Root Mean Square Error (RMSE)  
17-coefficient of determination ( $R^2$ )  
18-Nash-Sutcliffe model efficiency coefficient  
19-Map Size  
20-Unit  
21-Fuzzy C-Means (FCM)

## ۵- مراجع

- Adeloje AJ, Rustum R and Kariyama ID (2011) Kohonen self-organizing map estimator for the reference crop evapotranspiration. *Water Resource Research* 47 (8).
- Allen RG (1986) A penman for all season. *Irrigation and Drainage* 122 (4): 348-368.
- Allen RG (2001) REF-ET= Reference evapotranspiration calculation software.
- Allen RG, Pereira LS, Raes D and Smith M (1998) *Crop evapotranspiration: Guidelines for computing crop water requirements-FAO Irrigation and Drainage Paper 56*, Food and Agriculture Organization of the United Nations, Rome.
- Bezdek JC (1981) *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum, New York.
- Chang FJ, Chang LC, Kao HS and Wu GR (2010) Assessing the effort of meteorological variables for evaporation estimation by self-organizing map neural network. *Journal of Hydrology* 384:118-129.
- Farsadnia F, Rostami Kamrood M, Moghaddam Nia A, Modarres R, Bray MT and Han D, Sadatinejad J (2014) Identification of homogeneous regions for regionalization of watersheds by two-level self-organizing feature maps. *Journal of Hydrology* 509: 387-397.
- Hargreaves GH and Samani ZA (1985) Reference crop evapotranspiration from temperature. *Applied Engineering in Agriculture* 2: 96-99.

- Shuttleworth WJ (1993) Evaporation, in Handbook of Hydrology, edited by Maidment DR, Chapter 4, McGraw Hill, New York.
- Turc L (1961) Evaluation des besoins en eau d'irrigation, évapotranspiration potentielle, formule climatique simplifiée et mise à jour. (in French). Ann. Agron 12:13-49.
- Vesanto J, Himberg J, Alhoniemi E and Parhankangas J (2000) SOFM Toolbox for Matlab 5. Technical Report A57. Neural Networks Research Centre, Helsinki University of Technology, Helsinki, Finland.
- Wilppu R (1997) The visualization capability of self organizing maps to detect deviation in distribution control. TUCS Technical Report No. 153. Turku Centre for Computer Science, Finland.
- Xie XL and Beni G (1991) A validity measure for fuzzy clustering. IEEE Transactions on pattern analysis and machine intelligence 13 (8): 841–847.
- Penman HL (1948) Natural evaporation from open water, bare soil and grass. Proceedings of the Royal Society of London 193 (1032): 120–146.
- Penn BS (2005) Using self-organizing maps to visualize high dimensional data. Computers & Geosciences 31(5): 531–544.
- Priestley CHB and Taylor RJ (1972) On the assessment of surface heat flux and evaporation using large-scale parameters, Mon. Weather Rev 100 (2): 81–92.
- Rustum R, Adeloje AJ and Scholz M (2008) Applying Kohonen Self-Organizing Map as a software sensor to predict biochemical oxygen demand. Water Environment Research 80(1): 32-40.
- Rustum R, Adeloje AJ and Simala A (2007) Kohonen self-organizing map (KSOM) extracted features for enhancing MLP-ANN prediction models for BOD5. IAHS-AISH Publication 314: 181–178.