



فصلنامه علوم محیطی، دوره هفدهم، شماره ۴، زمستان ۱۳۹۸

۲۱۳-۲۳۰

پیش‌بینی درازمدت تبخیر- تعرق مرجع ماهانه دوره‌ی ۲۰۱۸-۲۰۲۷، با استفاده از مدل‌های SARIMA و شبکه عصبی GRNN (مطالعه موردی: ایستگاه سینوپتیک رشت)

پویا عاقل پور، وحید ورشایان* و مهرانه خدامرادپور

گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران

تاریخ دریافت: ۱۳۹۷/۰۹/۲۷ تاریخ پذیرش: ۱۳۹۸/۰۲/۲۸

عاقل پور، پ. و. ورشایان و م. خدامرادپور. ۱۳۹۸. پیش‌بینی درازمدت تبخیر- تعرق مرجع ماهانه دوره‌ی ۲۰۱۸-۲۰۲۷، با استفاده از مدل‌های SARIMA و شبکه عصبی GRNN (مطالعه موردی: ایستگاه سینوپتیک رشت). فصلنامه علوم محیطی. ۱۷(۴): ۲۳۰-۲۱۳.

سابقه و هدف: تبخیر- تعرق، یک فرآیند کلیدی تعادل آب و همچنین یک عنصر مهم از تعادل انرژی است. بنابراین پیش‌بینی و تخمین تبخیر- تعرق در مدیریت آب زراعی، پیش‌بینی و نظارت بر خشکسالی و توسعه و بهره‌برداری از منابع‌های آبی موثر، می‌تواند بسیار با ارزش و کاربردی باشد. هدف از این مطالعه مدل‌سازی سری زمانی تبخیر- تعرق مرجع در ایستگاه سینوپتیک رشت توسط دو مدل SARIMA و GRNN در دوره ۱۹۵۶-۲۰۱۷، و پیش‌بینی آن برای سال‌های ۲۰۱۸-۲۰۲۷ می‌باشد.

مواد و روش‌ها: شهر رشت در منطقه معتدل و مرطوب شمال ایران و در نوار جنوبی دریای خزر واقع است. در این مطالعه از روش تورنت‌وایت اصلاح شده برای برآورد ET_0 استفاده شده است که پیشتر به نقل از محققان، در برآورد نرخ تبخیر- تعرق مرجع منطقه‌ی رشت عملکرد مطلوبی بیان کرده است. میزان تبخیر- تعرق در سال‌های ۱۹۵۶-۲۰۱۷ برآورد شد. دو مدل برای مدل‌سازی و اعتبارسنجی سری‌زمانی ET_0 انتخاب گردید. مدل SARIMA از مدل‌های استوکستیک فصلی و مدل GRNN بر پایه‌ی هوش مصنوعی استوار است.

ورودی‌های مدل‌ها تا ۳ گام زمانی قبل ماهانه و سالانه انتخاب شدند. ماتریس‌های ورودی- هدف، به دو بخش واسنجی (۷۵٪) و اعتبارسنجی (۲۵٪) تقسیم شدند. تابع ACF نشان‌دهنده وجود روند فصلی در سری ماهانه ET_0 ، با دوره‌بازگشت ۱۲ بود. با چهار مرتبه تفاضل‌گیری مشخص شد که بهترین درجه تفاضل‌گیری مدل SARIMA در مرتبه اول می‌باشد. دیگر عملگرهای SARIMA نیز، اعم از اتورگرسیو و میانگین متحرک فصلی و غیر فصلی، توسط سعی و خطا انتخاب شدند. بهینه‌سازی مدل GRNN نیز توسط سعی و خطای پارامتر گستره انجام شد.

در این مطالعه معیارهایی همچون RMSE، NS و R برای بررسی خطا و همبستگی خروجی‌های مدل استفاده شد.

نتایج و بحث: بهترین مدل از الگوی SARIMA، مدل $SARIMA(0,0,1)(0,1,1)_2$ معرفی شد. میزان RMSE و NS برای این مدل به ترتیب برابر با ۸/۸۹ میلی‌متر و ۰/۹۷ بود. مدل GRNN با اعمال کل ورودی‌ها بهترین نتیجه را نشان داد. مقادیر RMSE و NS در بهترین خروجی GRNN برابر با ۹/۲۲ میلی‌متر و ۰/۹۶ محاسبه شد. تفاوت دو مدل در برآورد کمینه‌ها (ماه‌های ژانویه و فوریه) گزارش شد که بنا

*Corresponding Author. Email Address: v.varshavian@basu.ac.ir

برآن SARIMA عملکرد بهتری داشت. برای مقایسه این دو مدل از دیاگرام تیلور نیز استفاده شد. دیاگرام تیلور نشان داد دقت SARIMA نه تنها در میزان خطا، بلکه در همبستگی و برآورد انحراف معیار مقادیر واقعی، کمی دقیقتر از GRNN عمل نموده است. پس از صحت‌سنجی مدل‌ها و ارزیابی عملکرد مطلوب آنها، بهترین مدل‌های مستخرج از SARIMA و GRNN، به جهت پیش‌بینی نرخ تبخیر-تعرق مرجع ۱۰ سال آینده برای (سال‌های ۲۰۱۸-۲۰۲۷) استفاده شدند.

نتیجه‌گیری: نتایج پیش‌بینی‌های بیان شده برای سال‌های آینده رشت، وجود روند صعودی شدید ET_0 در سال‌های ۲۰۱۸-۲۰۲۷ را (نسبت به دوره‌ی ۱۹۵۶-۲۰۱۷) نشان داده‌است. این موضوع افزایش سریع‌تر نرخ تبخیر-تعرق مرجع را در سال‌های آینده، برای منطقه مرطوب رشت هشدار می‌دهد. به جهت برنامه‌ریزی منابع آب سطحی و زیرزمینی برای استفاده‌های کشاورزی و زراعی، این مساله بسیار دارای اهمیت بوده و هشدار بسیار جدی برای کشاورزان و مدیران آب در این منطقه خواهد بود.

واژه‌های کلیدی: پیش‌بینی درازمدت، تورنت وایت اصلاح شده، دیاگرام تیلور، SARIMA، GRNN.

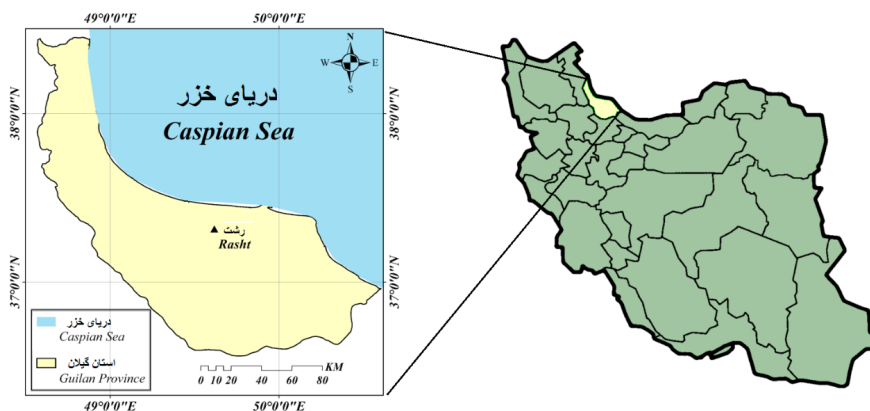
مقدمه

مقادیر تبخیر-تعرق را در مقیاس‌های هفتگی و ماهانه محاسبه و با استفاده از مدل SARIMA برای دوره ۱۳۶۶-۱۳۸۶ مدل‌سازی و اعتبار‌سنجی کردند. ایشان دقت این مدل را در پیش‌بینی کوتاه مدت تبخیر تعرق قابل قبول ارزیابی کردند. (Zare et al., 2016). نیز مقادیر تبخیر-تعرق را برای ۵ شهر در منطقه‌های نیمه خشک، خشک و فراخشک ایران به روش فائو پنمن-مانیث محاسبه و توسط مدل SARIMA مورد پیش‌بینی و اعتبار‌سنجی در مقیاس کوتاه مدت قرار دادند. ایشان با توجه به بیشترین جذر میانگین مربعات خطا در میان ایستگاه‌ها که معادل با ۰/۵۱۵ میلی متر در روز گزارش شد؛ دقت این مدل را بسیار خوب ارزیابی کردند. دیگر تحقیق‌های انجام شده در این زمینه بوسیله مدل سری‌های زمانی، همانند؛ (Babamiri et al., 2017); Azad et al. (2016); Azad et al. (2013); Fooladmand (2011); Zare et al. (2014) نیز، دقت بالای این مدل استوکستیک را در پیش‌بینی سری‌های زمانی تبخیر-تعرق تایید نمودند. در دهه‌های اخیر، با وجود مدل‌های رایج کلاسیک، روش‌های رایج هوشمندی همچون مدل‌های هوش مصنوعی^۱ مانند شبکه‌های عصبی مصنوعی^۲، سیستم استنتاج فازی^۳ و مدل‌های نروفازی^۴ نیز برای برآورد و پیش‌بینی متغیرهای هیدرولوژیکی استفاده شده است. از شبکه‌های عصبی می‌توان به مدل‌هایی همچون شبکه‌های عصبی پرسپترون چندلایه^۵، ماشین‌های بردار پشتیبان^۶، توابع شعاعی پایه^۷ و رگرسیون تعمیم یافته^۸ اشاره نمود. برای پیش‌بینی و همچنین تخمین تبخیر-تعرق توسط این مدل‌ها،

تبخیر-تعرق یک فرایند کلیدی تعادل آب و همچنین یک عنصر مهم از تعادل انرژی است. بنابراین برآورد دقیق آن نه تنها اهمیت حیاتی برای مطالعه تغییرهای اقلیمی و ارزیابی منابع آب دارد، بلکه دارای ارزش بسیار کاربردی در مدیریت آب زراعی، پیش‌بینی و نظارت بر خشکسالی، توسعه و بهره‌برداری از منابع آبی موثر و غیره می‌باشد (Zhao et al., 2013). پیش‌بینی و برآورد دقیق تبخیر-تعرق در منطقه‌های متنوع آب و هوایی، از اهمیت حیاتی برای طراحی و مدیریت سیستم‌های آبیاری، شبیه‌سازی عملکرد محصول و دستیابی به عملکرد بالاتر برای سیستم‌های آبیاری برخوردار است (Torres et al., 2011). از جمله ابزارهای مناسب پیش‌بینی پدیده‌های هواشناسی استفاده از روش سری‌های زمانی می‌باشد. در روش‌های پیش‌بینی سری زمانی، پیش‌بینی کننده با استفاده از اطلاعات به‌دست آمده از گذشته و با فرض ادامه الگو در آینده، الگویی قابل تعمیم را به‌دست می‌آورد (Azad et al., 2016). در متغیرهای هواشناسی، مدل SARIMA نشان داده است در اقلیم‌های ایران، می‌تواند پیش‌بینی قابل قبولی را از میانگین دمای ماهانه (که همبستگی بسیار قوی با نرخ تبخیر-تعرق ماهانه دارد) نمایش دهد (Aghelpour and Nadi, 2019). تاکنون با استفاده از مدل SARIMA، تحقیق‌های بسیاری برای پیش‌بینی تبخیر-تعرق صورت گرفته است. (Shirvani and Honar (2011) با استفاده از روش فائو پنمن-مانیث^۱ در ایستگاه دانشگاه شیراز، سری زمانی

در تحقیق‌های داخلی استفاده‌های زیادی شده است (Azad *et al.*, 2011; Sattari *et al.*, 2013; Shirzad and Asadzadeh, 2016; Verdinejad, 2015; Zare *et al.*, 2009). Eslamian *et al.* (2008) به مقایسه دقت دو شبکه عصبی MLP و SVM جهت برآورد تبخیر پرداختند. در این تحقیق هر دو مدل دقتی مطلوب از خود نشان دادند که مدل SVM نسبت به MLP دقت بهتری را نشان داد. Goyal *et al.* (2014) برای برآورد تبخیر روزانه تشت از مدل‌های هوش مصنوعی بهره گرفتند. ایشان در تحقیق خود از ورودی‌های هواشناسی شامل بیشترین بارش روزانه، بیشینه و کمینه دمای هوا، بیشینه و کمینه رطوبت نسبی و ساعت آفتابی و جهت مدل سازی از شبکه عصبی MLP، مدل ANFIS و رگرسیون بردار پشتیبان استفاده کردند. بهترین ورودی مدل توسط آزمون گاما انتخاب شد و در نهایت مدل‌های ANFIS و SVR مدل‌های موفقتری را در برآورد تبخیر تشت بیان کردند. در مطالعات دیگر نیز دقت خوب این مدل‌ها بویژه MLP در تخمین و پیش‌بینی تبخیر-تعرق (Abdullah and Malek, 2016; Alves *et al.*, 2018; Torres *et al.*, 2011; Traore

(*et al.*, 2008; Huo *et al.*, 2012; Laaboudi *et al.*, 2012 Ladlani, Feng *et al.* (2017) در مطالعات GRNN از مدل GRNN (2011) و Kisi (2006) به جهت تخمین نرخ تبخیر-تعرق مرجع روزانه استفاده شده است. در مطالعات داخلی از مدل GRNN تنها برای تخمین تبخیر-تعرق خیار و گوجه فرنگی در شرایط گلخانه ای استفاده شده است که عملکرد آن مطلوب، و در مقایسه با مدل‌های MLP و RBF دقیقتر گزارش گردید (Verdinejad, 2015). در همه پژوهش‌های یاد شده برای محاسبه تبخیر-تعرق، از روش فائو پنمن - مانیت و یا هارگریوز استفاده شده است. بر مبنای نتایج تحقیق‌های پیشین روش تورنت وایت اصلاح شده^{۱۱} در اقلیم مرطوب رشت، عملکرد خوبی در برآورد نرخ تبخیر-تعرق مرجع نشان می‌دهد (Dinpashoh, 2006). همچنین بررسی مطالعات پیشین نشان داد که روش ATW برای محاسبه تبخیر-تعرق مرجع و مدل GRNN تاکنون برای پیش‌بینی تبخیر-تعرق مرجع ماهانه استفاده نشده است. همچنین برای پیش‌بینی درازمدت مقادیر ماهانه این متغیر برای سال‌های آینده نیز، مطالعه ای در اقلیم مرطوب صورت نگرفته است. در این تحقیق مدل‌های SARIMA و GRNN، بمنظور مدل سازی سری‌های زمانی تبخیر-تعرق ماهانه، مقایسه این



شکل ۱- موقعیت جغرافیایی ایستگاه سینوپتیک رشت
Fig. 1- Geographical Position of Rasht's Synoptic Station

۵ متر از سطح آب‌های آزاد می‌باشد. رشته کوه البرز در قسمت جنوبی شهر و قله درفک به ارتفاع ۲۷۳۳ متر نزدیکترین قله مرتفع به آن است. این شهر از شمال در همسایگی مرداب انزلی و دریای خزر می‌باشد (Aghelpour and Nadi, 2018). رشت در طبقه‌بندی اقلیمی به روش دومارتن گسترش یافته^{۱۲} در کلاس معتدل و بسیار مرطوب نوع A قرار می‌گیرد

دو مدل در پیش‌بینی، و همچنین پیش‌بینی مقادیر ET_0 برای سال‌های ۲۰۱۸-۲۰۲۷ بکار گرفته شده است.

مواد و روش‌ها منطقه مورد مطالعه

شهر رشت دارای ۱۸۰ کیلومتر مربع مساحت و میانگین ارتفاع

جدول ۱- مختصات ایستگاه و ویژگی‌های آماری داده‌های تبخیر- تعرق مورد مطالعه
 Table 1. Station's coordinates & statistical characteristics of the evapotranspiration data

مختصات جغرافیایی Geographical coordinates			مشخصات آماری تبخیر- تعرق ماهانه Statistical characteristics of monthly evapotranspiration					
عرض (درجه) Latitude(°)	طول (درجه) Longitude(°)	ارتفاع (متر) Elevation(m)	میانگین Mean	بیشینه Max.	کمینه Min.	انحراف معیار St.Dev.	چولگی Skewness	کشیدگی Kurtosis
37.25	49.60	-6.9	72.46	183.74	0.6	54.06	0.41	-1.26

$$L_{d,i} = \frac{N_{d,i}}{30} \times \frac{N_i}{12} \quad (5)$$

در نهایت ET_0 اصلاح شده یا ATW، با ضرب کردن $L_{d,i}$ در $ET_{0,i}$ حاصل می‌گردد (Dinpashoh, 2006).

سری‌های زمانی

یک سری زمانی، مجموعه‌ای از مشاهده‌های ثبت شده از یک متغیر مانند X_t در طول زمان بصورت $X_1, X_2, X_3, \dots, X_N$ با فاصله زمانی مساوی می‌باشد (Gautam and Sinha, 2016). مدل SARIMA که می‌توان از آن بمنظور شبیه سازی رفتار تصادفی سری‌های زمانی پیروی کرد، یک مدل استوکستیک پارامتری خطی است که فرم ضربدری آن بصورت $SARIMA(p,d,q) \times (P,D,Q)_w$ نمایش داده می‌شود. این مدل با دوره تناوب w و مرتبه‌های اتورگرسیو، تفاضل گیری و میانگین متحرک غیر فصلی d, q و فصلی P, D و Q از رابط‌های کلی به شکل رابطه ۶ تبعیت می‌کند (Salas *et al.*, 1988):

$$\Phi_p(B^w)\phi_p(B)\nabla_w^d\nabla^d X_t = \theta_q(B)\Theta_Q(B^w)\varepsilon_t \quad (6)$$

که در این روابط X_t متغیر تصادفی نرمال شده و ε_t یک متغیر تصادفی نرمال با میانگین μ و واریانس σ_ε^2 است. پارامترهای $B, \Phi, \phi, \nabla^d, \Theta, \theta$ به ترتیب نشانگر عملگرهای پسرو، اتورگرسیو فصلی، اتورگرسیو غیر فصلی، تفاضل گیری فصلی و تفاضل گیری غیر فصلی، میانگین متحرک فصلی و میانگین متحرک غیر فصلی می‌باشند که معادلات آن‌ها در روابط ۷ تا ۱۲ تشریح شده است (Salas *et al.*, 1988).

$$\Phi_p(B^w) = (1 - \Phi_1 B^{w \times 1} - \dots - \Phi_p B^{w \times p}) \quad (7)$$

$$\Phi_p(B) = (1 - \Phi_1 B^1 - \dots - \Phi_p B^p) \quad (8)$$

$$\nabla_w^D (1 - B^w)^D \quad (9)$$

(Rahimi *et al.*, 2013). موقعیت جغرافیایی ایستگاه سینوپتیک رشت در شکل ۱ قابل مشاهده است. همچنین ویژگی‌های ایستگاه سینوپتیک رشت و همچنین ویژگی‌های آماری تبخیر- تعرق ماهانه در این ایستگاه در جدول ۱ نشان داده شده است.

روش تورنت وایت اصلاح شده در محاسبه تبخیر- تعرق مرجع

روش تورنت وایت اصلاح شده که توسط Pereira and Pruitt (2004) معرفی شد؛ بصورت رابطه ۱ بیان می‌گردد:

$$ET_{0,i} = \begin{cases} -415,85 + 32,24 TC_i - 0,43 TC_i^2, & (1) \\ 16(10TC_i / I)^a, & \\ 0, & TC_i > 26^\circ C \\ 0^\circ C < TC_i \leq 26^\circ C & \\ TC_i \leq 0^\circ C & \end{cases}$$

که در آن $ET_{0,i}$ تبخیر تعرق گیاه مرجع، و TC_i میانگین درازمدت دمای موثر که توسط رابطه ۲ محاسبه می‌گردد:

$$TC_i = 0,5 k(3T_{max,i} - T_{min,i}) \quad (2)$$

که در آن k برابر با $0,72$ بوده و اندیس i نشان دهنده شماره ماه می‌باشد (Dinpashoh, 2006). در رابطه ۱، I از معادله ۳ حاصل می‌شود:

$$I = \sum_{i=1}^{12} (0,2TC_i)^{1,514}, \quad TC_i > 0^\circ C \quad 0^\circ C < I = \sum \quad (3)$$

با در دست داشتن I ، نیز می‌توان a را به وسیله رابطه ۴ برآورد نمود:

$$a = 6,75 \times 10^{-7} I^3 - 7,71 \times 10^{-5} I^2 + 1,7912 \times 10^{-2} I + 0,49239 \quad (4)$$

ضریب اصلاح آن ($L_{d,i}$) نیز، که وابسته به طول روز (N_i) و تعداد روزهای ماه مورد نظر ($N_{d,i}$) می‌باشد، با استفاده از رابطه ۵ قابل استخراج است:

شکل رابطه ۱۴ می‌باشد (Araghinejad, 2013).

$$f(X_r, b) = e^{-I^2}, I = \|X_r - X_b\| \times 0,8326/h \quad (14)$$

در این رابطه X_r بردار ورودی به شبکه با خروجی نامشخص، X_b مقادیر ورودی مشاهداتی در زمان b و h پارامتر گستره شعاع می‌باشد. با تغییر h مقدار جمع و بازشدگی تابع تغییر خواهد نمود بطوری که تابع بهترین برآزش را بر روی داده‌ها پیدا کند. مقادیر خروجی این تابع در بازه صفر تا یک قرار داشته به شکلی که هر قدر فاصله اقلیدسی دو بردار X_r و X_b به صفر نزدیک شود، مقدار تابع به یک نزدیک شده و هرچه این فاصله بیشتر شود، مقدار تابع به صفر نزدیک می‌گردد. شبکه عصبی GRNN برای محاسبه خروجی از رابطه ۱۵ استفاده می‌نماید (Araghinejad, 2013).

$$Y_r = \frac{1}{\sum_{b=1}^n f(x_r, b)} \sum_{b=1}^n [f(x_r, b) \times T_b] \quad (15)$$

در این رابطه T_b مقدار خروجی مشاهداتی متناظر با بردار ورودی b امین داده و n تعداد داده‌های مشاهداتی است. ساختار شبکه عصبی GRNN در شکل ۲ نمایش داده شده است.

در این پژوهش مدل سازی و پیش‌بینی تبخیر تعلق مرجع توسط مدل GRNN، بوسیله کدنویسی در نرم افزار MATLAB انجام شده است.

معیارهای ارزیابی

در این پژوهش برای مقایسه عملکرد مدل‌ها و پیش‌بینی‌ها با داده‌های اصلی از جذر میانگین مربعات خطا^{۱۴} (RMSE)، ضریب همبستگی پیرسون^{۱۵} (R) و ضریب نش ساتکلیف^{۱۶} (NS) بهره گرفته شده است که معادلات آن‌ها در روابط ۱۶ تا ۱۸ نشان داده شده است.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - P_i)^2} \quad (16)$$

$$R = \frac{\sum_{i=1}^N (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2} * \sqrt{\sum_{i=1}^N (P_i - \bar{P})^2}}, \quad -1 < R < 1 \quad (17)$$

$$NS = 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2}, \quad \infty < NS < 1 \quad (18)$$

$$\Theta_Q(B^0) = (1 - \Theta_1 B^{0 \times 1} - \dots - \Theta_Q B^{0 \times Q}) \quad (11)$$

$$\theta_q(B) = (1 - \theta_1 B^1 - \dots - \theta_q B^q) \quad (12)$$

از نرم افزار Minitab 16 در این تحقیق برای مدل سازی سری‌های زمانی استفاده شد.

تابع خود همبستگی^{۱۳}

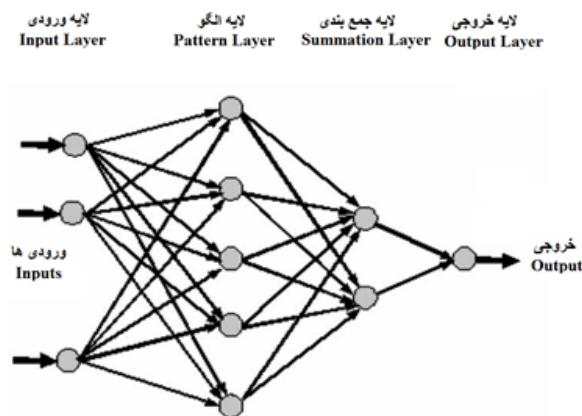
تابع خود همبستگی تابعی بسیار مهم در تحلیل سری‌های زمانی بویژه سری‌های زمانی پی‌یودیک می‌باشد که از کاربردهای آن‌ها می‌توان به نمایش و تحلیل روندهای فصلی در داده‌ها و همچنین تشخیص دوره بازگشت اشاره کرد. تابع خود همبستگی یا همبستگی نگار نمونه از ترسیم ضرایب خودهمبستگی، که یک معیار بدون بعد از وابستگی خطی مقادیر سری زمانی در گام‌های مختلف زمانی می‌باشد، در مقابل گام زمانی K به دست می‌آید.

$$r_k = \frac{\sum_{t=1}^{N-K} (x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^N (x_t - \bar{x})^2} \quad (13)$$

که در آن N طول نمونه، K گام زمانی مورد نظر و میانگین سری زمانی می‌باشد. چنانچه در خروجی‌های تابع در نمودار روند فصلی مشاهده شد؛ می‌بایست با چند بار تفاضل گیری فصلی با تاخیری برابر با دوره بازگشت داده‌ها این روند را در سری به حداقل نزدیک نمود (Salas et al., 1993).

شبکه عصبی رگرسیونی تعمیم یافته (GRNN)

این نوع شبکه عصبی یکی از انواع شبکه‌های عصبی شعاعی پایه و تقریب زنده‌ای همه منظوره برای توابع هموار است و توانایی تقریب زدن هرگونه تابع هموار با داده‌های کافی را دارد. GRNN یک شبکه عصبی سه لایه است که در آن تعداد نورون‌های موجود در لایه اول و آخر همانند دیگر شبکه‌های عصبی به ترتیب برابر با ابعاد بردارهای ورودی و خروجی است ولی برخلاف دیگر شبکه‌ها، تعداد نورون‌های لایه پنهان مدل GRNN برابر با تعداد داده‌های مشاهداتی می‌باشد. این نوع شبکه عصبی از تابع کارایی نرمال در هر یک از نورون‌های لایه پنهان استفاده می‌کند و داده ورودی به این تابع برای هر نورون عبارتست از فاصله اقلیدسی میان داده ورودی و مشاهداتی مربوط به آن نورون، که این تابع به



شکل ۲- ساختار فیزیکی شبکه عصبی
Fig. -۲ Physical structure of GRNN

داده شد. همانگونه که مشخص است، با تفاضل گیری، روند معنی دار فصلی داده‌های ET_0 از بین رفته است. همچنین این نمودار نشان می‌دهد که با افزایش درجات تفاضل گیری میزان تجاوز از خطوط معنی داری (خط چین‌های قرمز) بیشتر می‌گردد که در تاخیر فصلی مرتبه ۴ بیشترین معنی داری را داراست. کمترین میزان تجاوز از خطوط معنی داری متعلق به تفاضل گیری فصلی مرتبه ۱ بوده است. بنابراین پارامتر D در الگوی اصلی SARIMA برابر با یک در نظر گرفته شد. دیگر پارامترهای مدل $SARIMA(p,d,q) \times (P,D,Q)_w$ نیز توسط سعی و خطا در مدل سازی استخراج گردید. در مدل سازی و پیش‌بینی کوتاه مدت، ۷۵ درصد داده‌ها برای واسنجی یا آموزش و ۲۵ درصد داده‌ها برای اعتبارسنجی یا آزمون در نظر گرفته شدند. برای عملگرهای درجات فصلی و غیرفصلی اتورگرسیو و میانگین متحرک در مدل SARIMA، از ۰ تا ۳ بصورت آزمون و خطا جای گذاری شد. بهترین مدل‌ها بر اساس معیارهای ارزیابی RMSE و NS انتخاب گردید و در جدول ۲ درج شدند.

برای این ایستگاه، عملگرهای فصلی و غیرفصلی میانگین متحرک عملکرد به نسبت بهتری از اتورگرسیو نشان دادند. با افزایش درجات میانگین متحرک دقت مدل تا حدود کمی افزایش داشت. کمترین خطای کل متعلق به دو مدل $SARIMA(0,0,1)(0,1,3)_{12}$ و $SARIMA(0,0,3)(0,1,1)_{12}$ بود. ولی باتوجه به اصل امساک^{۱۷} (Salas et al., 1993)، درمقایسه مدل‌های دارای دقت نزدیک، مدلی که دارای پارامتر کمتری باشد بعنوان بهترین مدل برگزیده می‌شود.

در معیارهای بالا O_i ، P_i به ترتیب داده‌های مشاهده‌ای و برآورد شده، \bar{O} و \bar{P} به ترتیب میانگین‌های داده‌های مشاهده‌ای و برآورد شده، و N تعداد داده‌ها می‌باشند.

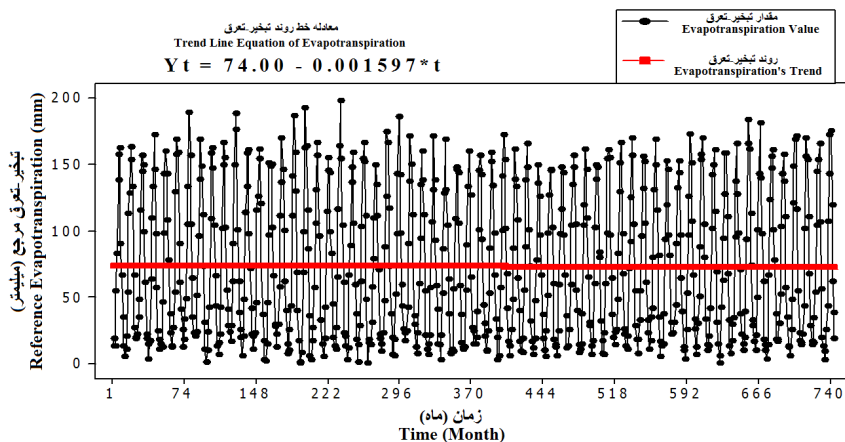
نتایج و بحث

در ابتدا داده‌های ET_0 از جهت وجود روند کلی مورد بررسی قرار گرفت (شکل ۳). نتایج نشان داد که داده‌های تبخیر-تعرق رشت در طول دوره ۱۹۵۶ تا ۲۰۱۷ دارای روند معنی دار افزایشی یا کاهشی نمی‌باشد.

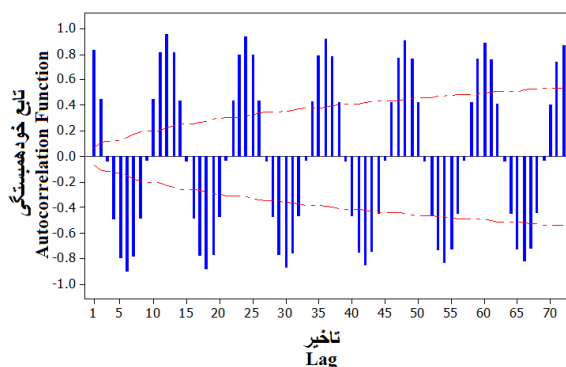
پس از بررسی روند کلی و برای تعیین پارامترهای مدل SARIMA، از تابع ACF استفاده شد که نمودار آن در شکل ۴ آمده است. تاخیر این نمودار ۷۲ عدد انتخاب شده، که پیش فرض نرم افزار Minitab بوده و توسط رابطه $45 + \sqrt{n}$ انتخاب می‌شود. در این رابطه n تعداد داده‌ها می‌باشد.

در نمودار ACF در درجه‌ی اول وجود روند فصلی معنی‌دار در داده‌های تبخیر-تعرق به روشنی مشخص است. روند تغییرهای فصلی دارای پریود بازگشت ۱۲ می‌باشد که نشان می‌دهد در الگوی اصلی $SARIMA(p,d,q) \times (P,D,Q)_w$ ، پارامتر w می‌بایست برابر با ۱۲ در نظر گرفته شود. از این نمودار می‌توان پارامتر D را نیز استخراج نمود که در شکل ۵ به آن پرداخته شده است.

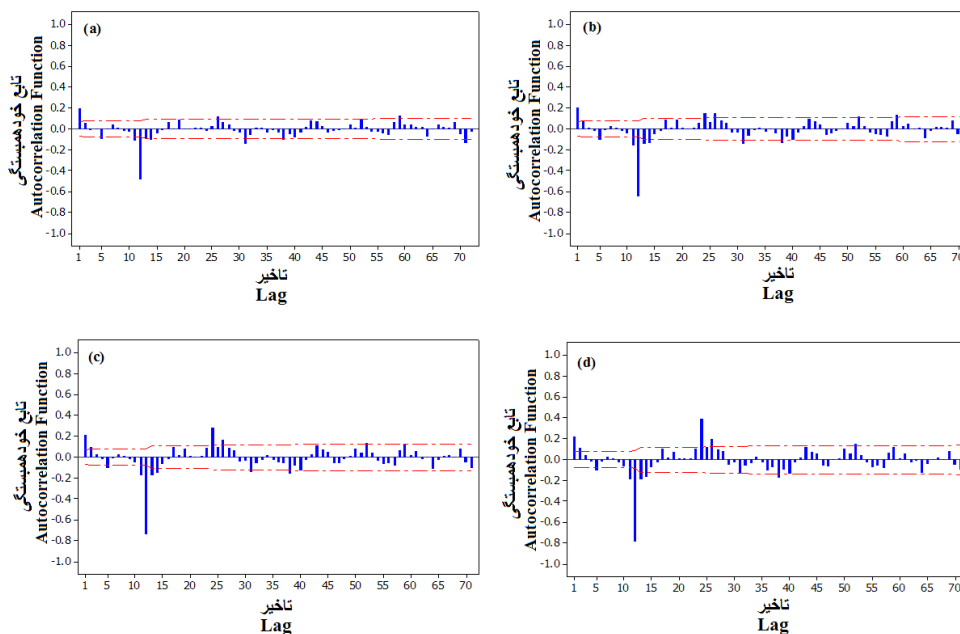
رفع روند فصلی از داده‌ها با تفاضل گیری در مرتبه فصلی انجام شد. این عملیات عبارت است از تفاضل گیری داده‌ها در تاخیری برابر با w . این عمل در ۴ مرتبه انجام شد و خروجی‌های تابع ACF برای آنها در نمودار شکل نمایش



شکل ۳- سری زمانی داده‌های ET_0 مورد بررسی به همراه روند
 Fig. 3- ET_0 Time series with its trend line



شکل ۴- نمودار تابع ACF برای ET_0
 Fig. 4- ACF plot of ET_0



شکل ۵- نمودار تابع ACF برای ET_0 در درجات تفاضل گیری فصلی (a) ۱، (b) ۲، (c) ۳ و (d) ۴
 Fig. 5- ACF plot of ET_0 in seasonal differencing degrees 1(a), 2(b), 3(c) & 4(d)

جدول ۲- ارزیابی بهترین مدل های SARIMA
Table 2. Evaluating the best SARIMA models

مدل Model	ریشه میانگین مربعات خطا (میلیمتر) RMSE(mm)			ضریب نش - ساتکلیف NS		
	واسنجی Calibration	اعتبارسنجی Validation	کل All	واسنجی Calibration	اعتبارسنجی Validation	کل All
SARIMA(0,0,1)(0,1,1) ₁₂	8.83	9.09	8.89	0.97	0.96	0.97
SARIMA(0,0,2)(0,1,1) ₁₂	8.82	9.08	8.88	0.97	0.97	0.97
SARIMA(0,0,3)(0,1,1) ₁₂	8.82	9.07	8.87	0.96	0.96	0.96
SARIMA(0,0,1)(0,1,2) ₁₂	8.81	9.07	8.88	0.97	0.95	0.96
SARIMA(0,0,1)(0,1,3) ₁₂	8.83	9.07	8.87	0.97	0.96	0.97

جدول ۳- پارامترهای مدل SARIMA(0,0,1)(0,1,1)₁₂
Table 3. SARIMA (0,0,1) (0,1,1)₁₂ Parameters

θ_1	Θ_1	ε_t
-0.120777	0.908091	0.266601

زمانی i ماه قبل، یا همان عملگرهای اتورگرسیو می باشند، و ε_{t-i} ها عملگرهای میانگین متحرک برای تاخیرهای زمانی i می باشند. پارامتر بهینه کننده مدل GRNN گستره شعاع i می باشد. این پارامتر بوسیله آزمون و خطا برای مدل سازی انتخاب شده است. همچنین برای ورودی های این مدل ۳ ماتریس متشکل از مقادیر ماقبل غیرفصلی و همچنین فصلی سری تبخیر- تعرق ماهانه تا ۳ گام ماقبل می باشد (جدول ۴). دلیل این انتخاب برای ورودی های GRNN، استفاده از ورودی های همسان با SARIMA، برای مقایسه منطقی نتایج دو مدل در انتها می باشد. در جدول ۳، اندیس های $t-i$ نشان دهنده مقدار تبخیر- تعرق محاسبه شده در i ماه قبل می باشد. نتایج مدل سازی GRNN، با پارامترهای بهینه شده برای هر ماتریس ورودی در جدول ۵ آمده است.

پارامتر گستره، بصورتی انتخاب شده است که کمترین خطای کل را داشته باشد، در عین حال که کمترین اختلاف خطا بین دو دوره واسنجی و اعتبارسنجی وجود داشته باشد. در اولین نگاه واضح است که در دومین ورودی دقت بالاتر از ورودی اول، و در سومین ورودی، دقت بیشتر از دو ورودی دیگر می باشد. در واقع با افزودن گام های بیشتر در ماتریس ورودی، به دقت مدل افزوده می شود. در نهایت بهترین مدل در ورودی سوم، گستره ۳۳، با میزان جذر میانگین مربعات خطای ۹/۱۶، ۹/۴۰ و ۹/۲۲ میلیمتر، و ضریب نش - ساتکلیف ۰/۹۶، ۰/۹۷ و ۰/۹۶، به ترتیب در

بنابراین مدل SARIMA(0,0,1)(0,1,1)₁₂، که دارای درجه اتورگرسیو فصلی و غیرفصلی صفر، و درجات میانگین متحرک فصلی و غیرفصلی یک است، بعنوان بهترین مدل SARIMA برای مدل سازی و پیش بینی کوتاه مدت مقادیر ET_0 در رشت انتخاب گردید. میزان جذر میانگین مربعات خطا در دوره های واسنجی، اعتبارسنجی و کل، به ترتیب برابر با ۸/۸۳، ۹/۰۹ و ۸/۸۹ میلیمتر، و ضریب نش - ساتکلیف در این دوره ها برابر با ۰/۹۷، ۰/۹۶ و ۰/۹۷ محاسبه شده است که با توجه به اینکه مقدار ضریب نش - ساتکلیف بزرگتر از ۰/۷۵ است؛ دقت مدل SARIMA بسیار خوب ارزیابی می گردد. پارامترهای مدل SARIMA(0,0,1)(0,1,1)₁₂ در جدول ۳ نشان داده شده است.

در جدول ۳، θ_1 نشان دهنده ضریب میانگین متحرک غیر فصلی مرتبه ۱، Θ_1 نشان دهنده ضریب میانگین متحرک فصلی مرتبه ۱ و ε_t نشان دهنده ضریب ثابت مدل است که برای بهینه سازی سری زمانی ET_0 ، در الگوی اصلی مدل SARIMA(0,0,1)(0,1,1)₁₂ بکار گرفته شده اند. این مقادیر توسط نرم افزار Minitab بهینه سازی شده است. بنابر پارامترها و الگوی اصلی SARIMA، مدل پیش بینی سری زمانی تبخیر- تعرق ماهانه ایستگاه رشت به شکل رابطه ۱۹ استخراج می شود:

$$X_t = 0,266601 + (-0,120777 \times \varepsilon_{t-1}) + (0,908091 \times \varepsilon_{t-12}) - (0,120777 \times 0,908091 \times \varepsilon_{t-13}) - X_{t-12} \quad (19)$$

در این معادله X_{t-i} ها مقادیر تبخیر- تعرق برای تاخیرهای

جدول ۴- متغیرهای ورودی و هدف برای مدل GRNN
Table 4. Input & target variables for GRNN

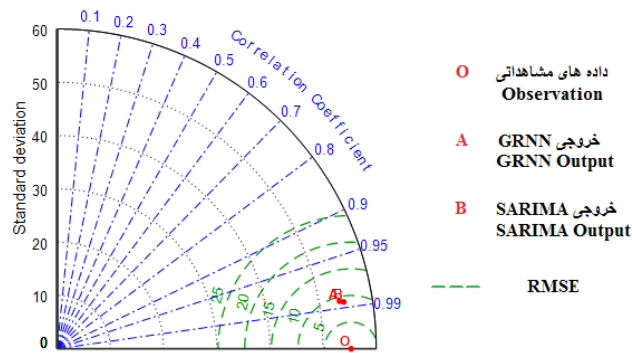
نام ورودی Input's Name	ماتریس ورودی Input Matrix	متغیر هدف Target Variable
Input 1	ET_{t-1}, ET_{t-12}	ET_t
Input 2	$ET_{t-1}, ET_{t-2}, ET_{t-12}, ET_{t-24}$	ET_t
Input 3	$ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-12}, ET_{t-24}, ET_{t-36}$	ET_t

جدول ۵- ارزیابی بهترین مدل های GRNN
Table 5. Evaluating the best GRNN models

ورودی Input	گستره Spread	ریشه میانگین مربعات خطا (میلیمتر) RMSE(mm)			ضریب نش - ساتکلیف NS		
		واسنجی Calibration	اعتبارسنجی Validation	کل All	اعتبارسنجی Validation	واسنجی Calibration	کل All
Input 1	18	10.32	10.39	10.34	0.95	0.96	0.95
Input 2	27	9.50	9.64	9.53	0.96	0.96	0.96
Input 3	33	9.16	9.40	9.22	0.96	0.97	0.96

نزدیکتر به این خطچین بودند. مقایسه انحراف معیار خروجی ها با داده‌های مشاهداتی نیز، نشان دهنده عملکرد این دو مدل در برآورد مطلوب انحراف معیار ET_0 مشاهده ای می‌باشد. خروجی مدل ها به همراه مقادیر مشاهده ای، به تفکیک دوره‌های واسنجی و اعتبارسنجی در شکل های ۷ و ۸ نشان داده شده است. دو مدل در پیش‌بینی بیشینه مقادیر ET_0 در تعدادی از سال ها کم برآورد داشته اند که این مقادیر مرتبط با ماه‌های جولای در این سال ها بوده است. تفاوت در پیش‌بینی کمینه ET_0 ماه ها نیز قابل مشاهده است. در پیش‌بینی این مقادیر که در ماه ژانویه ثبت گردیده‌اند، مدل SARIMA تا حدودی موفق تر از GRNN عمل نموده است. دلیل این امر را تا حدودی می‌توان در همبستگی خطی بالا میان تاخیرهای مختلف ورودی برای متغیر تبخیر- تعرق، در مقایسه با همبستگی غیرخطی، در این اقلیم دانست. بنابراین می‌توان گفت، مدل خطی SARIMA در مقایسه با مدل غیر خطی GRNN کمی قویتر عمل نموده است. این مقدار اختلاف محسوس نبوده، و دقت هر دو مدل در واسنجی و اعتبارسنجی (که همان پیش‌بینی کوتاه مدت می باشد) بسیار مطلوب و قابل قبول است. پس از انتخاب بهترین مدل، و بهترین ورودی ها و پارامترها برای هر کدام از مدل ها، اقدام به پیش‌بینی درازمدت ET_0 برای ۱۰ سال آینده، یعنی سال های ۲۰۱۸-۲۰۲۷ شد. بصورتی که با استفاده از مدل استخراج شده، مقدار ET_0 در ژانویه ۲۰۱۸

دوره‌های واسنجی، اعتبارسنجی و کل گزارش شد. دقت مدل GRNN نیز همچون SARIMA در پیش‌بینی ET_0 ، با توجه به ضرایب نش - ساتکلیف بسیار خوب ارزیابی شد. در ادامه خروجی‌های دو مدل برای مقایسه، در دیاگرام تیلور نشان داده شده است (شکل ۶). دیاگرام تیلور نموداری است که برای مقایسه چندین خروجی مدل سازی در یک نمودار استفاده می‌گردد. در این دیاگرام میزان خطا، همبستگی و همچنین انحراف معیار خروجی‌های مدل ها با مقادیر واقعی مقایسه می‌گردد (Taylor, 2001). خطچین‌های کمائی مقادیر RMSE را نشان می‌دهد که در مرکزیت دوایر آن، داده‌های مشاهده ای قرار داده شده است. خروجی‌های SARIMA و GRNN نیز با فاصله از دوایر آن رسم شده است. نقاط خروجی‌های مدل، اختلاف اندکی دارند و در واقع دقت دو مدل کمابیش یکسان ارزیابی می‌شود. تمامی خروجی ها در زیر خطچین ۱۰ میلیمتر از نظر جذر میانگین مربعات خطا واقع شده‌اند. با این تفاوت که مقداری جزئی، خروجی‌های SARIMA به مقادیر واقعی نزدیکتر می‌باشد. خطچین‌هایی که شعاع‌های ربع دایره دیاگرام تیلور هستند، مقادیر ضریب همبستگی پیرسون یا R را نشان می‌دهند. خروجی‌های دو مدل بسیار نزدیک به خطچین ضریب همبستگی پیرسون برابر با ۰/۹۹ بوده که بسیار خوب ارزیابی می‌گردد. خروجی‌های SARIMA اندکی



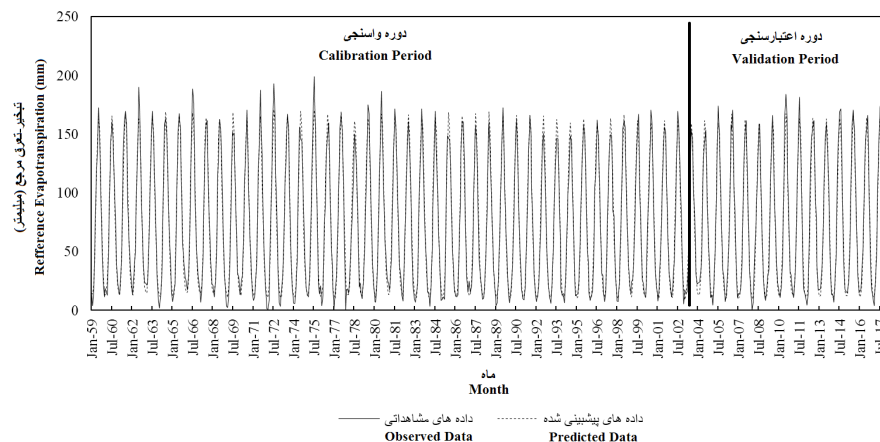
شکل ۶- دیاگرام تیلور در مقایسه دو مدل GRNN و SARIMA
Fig. 6- Taylor diagram to compare SARIMA & GRNN

ماه گزارش شد، نشان می‌دهد مقادیر تبخیر تفرق ماهانه در ۱۰ سال آینده، در حدود ۲۰ برابر با سرعت بیشتری در حال افزایش خواهد بود. پیش‌بینی‌های GRNN شبیهی برابر با $0.104/0$ میلیمتر در روز را برای ET_0 در ۱۰ سال آینده گزارش می‌کند. این مقدار ۶ برابر شیب سال‌های ۱۹۵۶-۲۰۱۷ است. خروجی‌های GRNN در مقایسه با SARIMA سرعت کمتری را برای افزایش ET_0 نشان می‌دهد. ولی این افزایش سرعت به نسبت سال‌هایی که تاکنون سپری شده اند چند برابر گزارش می‌شود. این موضوع با خود هشدار جدی برای فعالیت‌های کشاورزی و زراعی منطقه را در بر دارد.

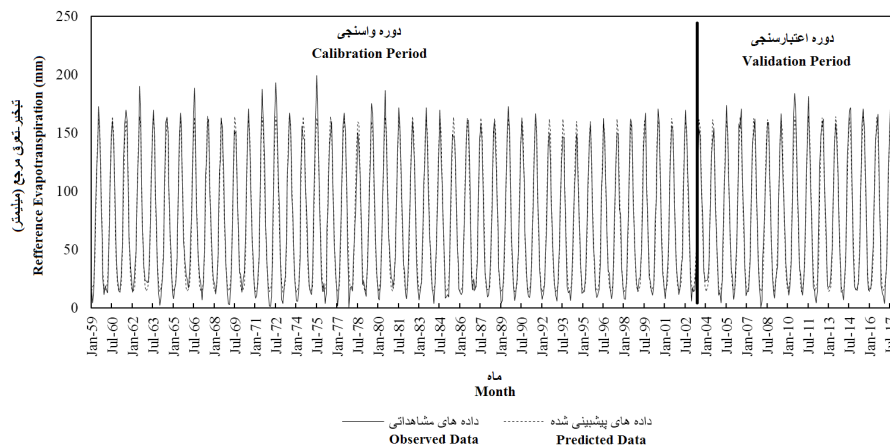
تحقیقاتی که در راستای استفاده از مدل‌های هوش مصنوعی برای تخمین تبخیر و تفرق مرجع صورت گرفته، همانند پژوهش حاضر نتایج این مدل‌ها را مطلوب ارزیابی نموده‌اند (Feng et al., 2017; Adamala et al.,

پیش‌بینی شد. سپس همین مقدار بعنوان ورودی در مدل استفاده شد و ET_0 در فوریه ۲۰۱۸ پیش‌بینی گردید. این عمل ادامه یافت و مقادیر ET_0 تا دسامبر ۲۰۲۷ پیش‌بینی گردید. خروجی دو مدل مورد استفاده، در شکل ۹ نشان داده شده است.

با توجه به شکل ۹، مشاهده می‌شود مدل‌های پیش‌بینی کننده توانسته‌اند روند پرریودیک سینوسی داده‌های ET_0 را در پیش‌بینی بخوبی تشخیص دهند. پیش‌بینی‌های هر دو مدل در اوجها (جولای و آگوست) بسیار نزدیک بوده ولی در کمینه‌ها (ژانویه و فوریه) مقدار اندکی تفاوت دیده می‌شود. بنابراین شکل، خروجی هر دو مدل این مساله را گواهی می‌کند که روند تغییرات تبخیر-تفرق در رشت، در ۱۰ سال آینده صعودی خواهد بود. شیب خط روند پیش‌بینی‌های SARIMA برابر با $0.321/0$ میلیمتر در ماه است. در مقایسه با شیب روند داده‌های ET_0 در سال‌های ۱۹۵۶-۲۰۱۷ که برابر با $0.1597/0$ میلیمتر در



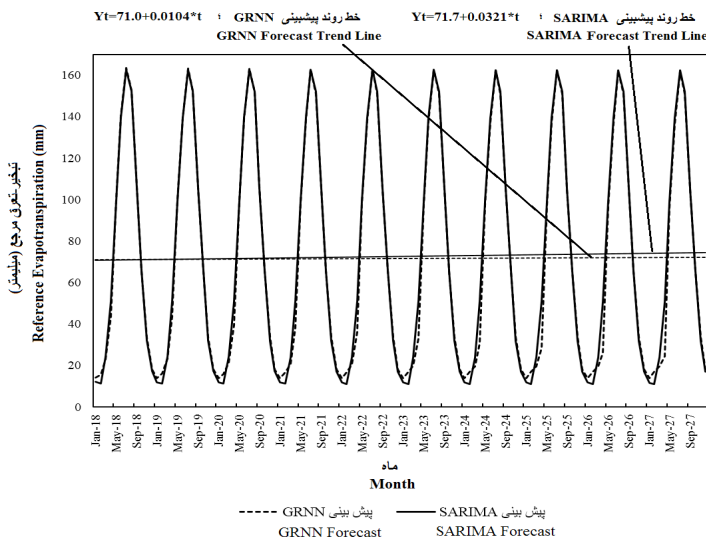
شکل ۷- مقایسه خروجی‌های SARIMA با مقادیر مشاهداتی
Fig. 7- Comparison of SARIMA outputs with the observations



شکل ۸- مقایسه خروجی های GRNN با مقادیر مشاهداتی
 Fig. 8- Comparison of GRNN outputs with the observations

کرده‌اند. Babamiri *et al.* (2017) خطای SARIMA را در پیش‌بینی تبخیر-تعرق تبریز، در بازه ۱۴/۸۵-۱۵/۵۲ میلیمتر در ماه گزارش کردند. دقت این مدل در برآورد ET_0 ایستگاه رشت بسیار بالاتر (۸/۸۹ میلیمتر در ماه) بود. دلیل این اختلاف دقت، می‌تواند ناشی از تفاوت اقلیم تبریز باشد که در منطقه نیمه خشک سرد قرار گرفته است. Zare *et al.* (2016) نیز برای تبخیر-تعرق در شهرهای شیراز، کرمان، یزد، اصفهان و سمنان، دقت پیش‌بینی SARIMA را بترتیب ۰/۴۱، ۰/۳۷، ۰/۳۳، ۰/۴۵ و ۰/۵۱ میلیمتر در روز گزارش کردند. در مقایسه با دقت روزانه این مدل در رشت که ۰/۲۹ میلیمتر در روز اندازه‌گیری

2018; Lu *et al.*, 2018; Shiri, 2019; Abrishami *et al.*, (2019; Keshtegar *et al.*, 2019; Saggi and Jain, 2019 با این تفاوت که در این مطالعات، محاسبه ET_0 به روش فائو پنمن - ماننیت انجام شده است. ولی در مطالعات پیشین، از GRNN جهت پیش‌بینی ET_0 استفاده نشده است. با استفاده از SARIMA، مطالعاتی برای مدل-سازی سری‌های زمانی ET_0 در ایران انجام شده است Babamiri *et al.*, 2017; Fooladmand, 2011; Shirvani and Honar, 2011; Zare *et al.*, 2016; Zare *et al.*, 2014) که هم جهت با تحقیق جاری، دقت SARIMA را در دوره‌های مدل‌سازی و اعتبارسنجی مطلوب ارزیابی



شکل ۹- پیش‌بینی مدل های SARIMA و GRNN، در سال های ۲۰۱۸-۲۰۲۷، به همراه روند
 Fig. 9- SARIMA & GRNN forecasts, for 2018-2027 period, with trend line

بسیار دارای اهمیت بوده، و هشدارهای بسیار جدی به کشاورزان و مدیران آب در این منطقه اعلام می‌کند. پیشنهاد می‌گردد از این مدل‌ها در پیش‌بینی مقادیر ماهانه ET_0 حاشیه جنوبی دریای خزر، بویژه ایستگاه‌های واقع در منطقه‌ای مرطوب و بسیار مرطوب استفاده گردد.

پی‌نوشت‌ها

- ¹ FAO Penman- Montith
- ² Artificial Intelligence Models
- ³ Artificial Neural Networks
- ⁴ Fuzzy Inference System
- ⁵ Adaptive Neuro-fuzzy Inference System
- ⁶ Multilayer Perceptron
- ⁷ Support Vector Machines
- ⁸ Radial Basis Function
- ⁹ Generalized Regression Neural Network
- ¹⁰ Reference EvapoTranspiration
- ¹¹ Adjusted Thornthwaite
- ¹² Extended De Martonne
- ¹³ Autocorrelation Function
- ¹⁴ Root Mean Squared Error
- ¹⁵ Pearson Correlation Coefficient
- ¹⁶ Nash-Sutcliff Coefficient
- ¹⁷ Principle of Parsimony

شده است، می‌توان گفت که SARIMA در مدل‌سازی و اعتبارسنجی سری‌های زمانی ET_0 اقلیم‌های مرطوب، عملکرد بهتری به نسبت منطقه‌های نیمه خشک، خشک و فراخشک بیان می‌کند. همچنین بررسی مطالعات گذشته نشان داد که پیش‌بینی بلندمدت ماهانه این متغیر برای سال‌های آینده صورت نگرفته است.

نتیجه‌گیری

نتایج گویای روند صعودی شدید نرخ تبخیر-تعرق در رشت، در سال‌های ۲۰۱۸-۲۰۲۷، به نسبت دوره ۱۹۵۶-۲۰۱۷ است. با توجه به پیش‌بینی دقیق‌تر مقادیر کمینه‌ی ET_0 (در ماه‌های ژانویه و فوریه) توسط مدل SARIMA در دوره واسنجی و اعتبارسنجی و همین‌طور ارزیابی این ماه‌ها در دوره پیش‌بینی درازمدت، مشاهده می‌شود که در این دوره نیز SARIMA توانسته است کمینه‌های دوره‌ی ۲۰۱۸-۲۰۲۷ را بهتر از GRNN برآورد نماید. بنابراین استفاده از SARIMA برای پیش‌بینی ET_0 در رشت بیشتر توصیه شده و پیش‌بینی آن در مقایسه با GRNN مطلوب‌تر ارزیابی می‌گردد. یافته‌های تحقیق حاضر افزایش سریع روند تبخیر-تعرق در سال‌های آینده برای منطقه مرطوب رشت گزارش می‌کند. این موضوع برای برنامه‌ریزی منابع آب سطحی و زیرزمینی برای استفاده‌های کشاورزی و زراعی،

منابع

- Abdullah, S.S., and Malek, M.A., 2016. Empirical Penman-Monteith equation and artificial intelligence techniques in predicting reference evapotranspiration: a review. *International Journal of Water*. 10, 1.55-66.
- Abrishami, N., Sepaskhah, A.R. and Shahrokhnia, M.H., 2019. Estimating wheat and maize daily evapotranspiration using artificial neural network. *Theoretical and Applied Climatology*. 135(3-4), 945-958.
- Adamala, S., Raghuvanshi, N.S. and Mishra, A., 2018. Development of Generalized Higher-Order Neural Network-Based Models for Estimating Pan Evaporation. In *Hydrologic Modeling*. Springer, Singapore, pp. 55-71.
- Aghelpour, P. and Nadi, M., 2018. Comparing the Performance of Autoregressive and Moving Average Models in Predicting Maximum and Minimum Daily Temperature. In *Proceeding of 1st National Conference on Water Resources Management and Environmental Challenges*. Apr30-May1. Sari Agricultural Sciences and Natural Resources University. Sari. Iran.

- Aghelpour, P. and Nadi, M., 2019. Evaluating SARIMA Model Accuracy in Modeling and Long-Term Forecasting of Average Monthly Temperature in Different Climates of Iran. *Journal of Climate Research*. 35, 113-126. (In Persian with English abstract)
- Alves, W.B., Rolim, G.D.S. and Aparecido, L.E.D.O., 2017. Reference evapotranspiration forecasting by artificial neural networks. *Engenharia Agrícola*. 37(1), 116-1125.
- Araghinejad, S., 2013. Data-driven modeling: using MATLAB® in water resources and environmental engineering (Vol. 67). Springer Science & Business Media.
- Azad, T.N., Behmanesh, J. and Montaseri, M., 2013. Predicting potential evapotranspiration using time series models (case study: Urmia). *Journal of Water & Soil*. 27(1), 213-223. (In Persian with English abstract).
- Azad, T.N., Behmanesh, J., Montaseri, M. and Verdinejad, V.R., 2016. Comparison of Time Series Methods and Artificial Neural Networks in Reference Evapotranspiration Prediction (Case Study: Urmia). *Irrigation Science & Engineering*. 38, 4.75-85. (In Persian with English abstract).
- Babamiri, O., Nowzari, H., and Maroufi, S., 2017. Potential Evapotranspiration Estimation using Stochastic Time Series Models, Watershed Management Research. 8(15), 137-146. (In Persian with English abstract).
- Behmanesh, J., Azad, T.N., Montaseri, M. and Besharat, S., 2015. Comparison of Linear and Nonlinear (Bilinear) Time Series Models in Reference Crop Evapotranspiration Prediction in Urmia Synoptic Station. *Journal of Water Research in Agriculture*. 28(1), 85-96. (In Persian with English abstract).
- Dinpashoh, Y., 2006. Study of reference crop evapotranspiration in IR of Iran. *Agricultural Water Management*. 84(1-2), 123-129.
- 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*. 8(19), 3497-3502.
- Feng, Y., Peng, Y., Cui, N., Gong, D. and Zhang, K., 2017. Modeling reference evapotranspiration using extreme learning machine and generalized regression neural network only with temperature data. *Computers and Electronics in Agriculture*. 136, 71-78.
- Fooladmand, H. R., 2011. Monthly Prediction of Reference Crop Evapotranspiration in Fars Province. *Water and Soil Science*. 20, 4.157-169. (In Persian with English abstract).
- Gautam, R. and Sinha, A.K., 2016. Time series analysis of reference crop evapotranspiration for Bokaro District, Jharkhand, India. *Journal of Water and Land Development*. 30(1), 51-56.
- Goyal, M.K., Bharti, B., Quilty, J., Adamowski, J. and Pandey, A., 2014. Modeling of daily pan evaporation in sub-tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS. *Expert systems with applications*. 41(11), 5267-5276.
- Hasan-Bagloee, M. and Maghsodi, E., 2003. Selection of a suitable method for prediction of reference evapotranspiration of Rasht region. In *Proceedings of the 8th national conference on irrigation and evaporation reduction*, Shahid Bahonar University, Kerman, Islamic Republic of Iran. pp. 34-43.
- Huo, Z., Feng, S., Kang, S. and Dai, X., 2012. Artificial neural network models for reference

- evapotranspiration in an arid area of northwest China. *Journal of arid environments*. 82, 81-90.
- Keshtegar, B., Kisi, O. and Zounemat-Kermani, M., 2019. Polynomial chaos expansion and response surface method for nonlinear modelling of reference evapotranspiration. *Hydrological Sciences Journal*. 64(6), 720-730.
- KIŞI, Ö., 2006. Generalized regression neural networks for evapotranspiration modelling. *Hydrological Sciences Journal*. 51(6), 1092-1105.
- Laaboudi, A., Mouhouche, B. and Draoui, B., 2012. Neural network approach to reference evapotranspiration modeling from limited climatic data in arid regions. *International Journal of Biometeorology*. 56(5), 831-841.
- Ladlani, I., Houichi, L., Djemili, L., Heddami, S. and Belouz, K., 2012. Modeling daily reference evapotranspiration (ET₀) in the north of Algeria using generalized regression neural networks (GRNN) and radial basis function neural networks (RBFNN): a comparative study. *Meteorology and Atmospheric Physics*. 118(3-4), 163-178.
- Lu, X., Ju, Y., Wu, L., Fan, J., Zhang, F. and Li, Z., 2018. Daily pan evaporation modeling from local and cross-station data using three tree-based machine learning models. *Journal of Hydrology*. 566, 668-684.
- Pereira, A.R. and Pruitt, W.O., 2004. Adaptation of the Thornthwaite scheme for estimating daily reference evapotranspiration. *Agricultural Water Management*. 66(3), 251-257.
- Rahimi, J., Ebrahimpour, M. and Khalili, A., 2013. Spatial changes of extended De Martonne climatic zones affected by climate change in Iran. *Theoretical and Applied Climatology*. 112(3-4), 409-418.
- Saggi, M.K. and Jain, S., 2019. Reference evapotranspiration estimation and modeling of the Punjab Northern India using deep learning. *Computers and Electronics in Agriculture*. 156, 387-398.
- Salas, J.D., Delleur, W., Yevjevich, V. and Lane, W.L., 1988. Applied modeling of hydrologic time series. Water Resources Publications. Littleton, Colorado, U.S.A. p. 484.
- Salas, J.D., 1993. Analysis and modelling of hydrologic time series. In *Handbook of hydrology*, Maidment, D. R. McGraw-Hill. New York.
- Sattari, M.T., Nahrein, F. and Azimi, V., 2013. M5 Model Trees and Neural Networks Based Prediction: of Daily ET₀ (Case Study: Bonab Station). *Iranian Journal of Irrigation and Drainage*. 7(1), 104-113. (In Persian with English abstract).
- Shiri, J., 2019. Evaluation of a neuro-fuzzy technique in estimating pan evaporation values in low-altitude locations. *Meteorological Applications*. 26(2), 204-212.
- Shirvani, A. and Honar, T., 2011. Application of time series models for evapotranspiration forecasting in Bajgah station. *Iranian Water Research*. 5(8), 135-142. (In Persian with English abstract).
- Shirzad, M. and Asadzadeh, B., 2016. Estimating Evapotranspiration Using Meteorological Data by Three Methods: Artificial Neural Network, FAO Penman-Montith and GIS (Case Study: Kurdistan Province). The 2nd International Congress on Earth Science & Urban Development. 12th May, East Azarbaijan Province Jahad Research Center. Tabriz. Iran. (In Persian with English abstract).
- Taylor, K.E., 2001. Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres*. 106(7), 7183-7192.

Torres, A.F., Walker, W.R. and McKee, M., 2011. Forecasting daily potential evapotranspiration using machine learning and limited climatic data. *Agricultural Water Management*. 98(4), 553-562.

Traore, S., Wang, Y.M. and Kerh, T., 2008. Modeling reference evapotranspiration by generalized regression neural network in semiarid zone of Africa. *WSEAS Transactions on Information Science & Applications*. 6(5), 991-1000.

Verdinejad, V.R., 2015. Evaluation and Comparison of GRNN, MLP and RBF Neural Networks for Estimating Cucumber, Tomato and Reference Crops' Evapotranspiration in Greenhouse Condition. *Water and Soil Science*. 25(4), 123-136. (In Persian with English abstract).

Zare, A.H., Afrouzi, A., Mirzaei, M. and Bagheri, H., 2016. Forecasting the Reference Evapotranspiration Using Time Series Model. *Journal of Water & Soil*. 30(1), 99-111. (In Persian with English abstract).

Zare, A.H., Ghasemi, A., Bayat, V.M. and Maroufi, S., 2009. Assessment of artificial neural network (ANN) in prediction of garlic evapotranspiration (ETc) with lysimeter in Hamedan. *Journal of Water & Soil*. 23(3), 176-185. (In Persian with English abstract).

Zare, A.H., Saghaei, S., Ershad-Fath, F. and Nozari, H., 2014. Modelong and Forecasting of Reference Crop Evapotranspiration Using Time Series, Case Study: Kermanshah Province. *Agricultural Meteorology*. 2(1), 45-56. (In Persian with English abstract)

Zhao, L., Xia, J., Xu, C.Y., Wang, Z., Sobkowiak, L. and Long, C., 2013. Evapotranspiration estimation methods in hydrological models. *Journal of Geographical Sciences*. 23(2), 359-369.





Environmental Sciences Vol.17/ No.4 /winter 2020

213-230

Long-term forecast of monthly reference evapotranspiration of the period 2018-2027 using SARIMA and GRNN models (Case study: Rasht Synoptic Station)

Pouya Aaghelipoor, Vahid Varshavian* and Mehraneh Khodamoradpoor

Department of Water Science and Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

Received: 2018.12.18 Accepted: 2019.05.18

Aaghelipoor, P., Varshavian, V. and Khodamoradpoor, M., 2020. Long-term forecast of monthly reference evapotranspiration of the period 2018-2027 using SARIMA and GRNN models (Case study: Rasht Synoptic Station). *Environmental Sciences*. 17(4): 213-230.

Introduction: Evapotranspiration is a key principle of water balance and an important element of energy balance. Therefore, forecasting and estimation of evapotranspiration in agricultural water management, forecasting and monitoring drought, and the development and exploitation of effective water resources might be valuable and practical. The purpose of this study was to model the Reference Evapotranspiration time series (ET_0) at Rasht Synoptic Station with two SARIMA and GRNN models during 1956-2017 and its forecast for 2018-2027.

Material and methods: Rasht is located in the temperate and humid parts of northern Iran and in the southern strip of the Caspian Sea. In this study, the Adjusted Thornthwaite method (ATW) was used to estimate ET_0 , the credibility of which was previously confirmed by researchers for estimation of reference evapotranspiration rate in Rasht. Evapotranspiration values were estimated for the time period of 1956-2017. Two models were selected for modeling and validation of the ET_0 series. The SARIMA model is based on seasonal stochastic models, and the GRNN model is based on artificial intelligence. The models' inputs were selected on the basis of three previous monthly and yearly. The target-input matrices were divided into calibration (75%) and validation (25%) sections. Autocorrelation Function (ACF) indicated a seasonal trend in the ET_0 monthly series, with a return period of 12. Four times seasonal differentiation, revealed that the best degree of SARIMA's seasonal integrated degree was the first-order. Other SARIMA operators, including seasonal and non-seasonal autoregressive, and average seasonal and non-seasonal moving, were selected by trial and error. Optimization of the GRNN model was accomplished by trying and error of the spread parameter. In this study, criteria such as RMSE, NS, and R were used to check the error and correlate the outputs of the model.

Results and discussion: The best model of SARIMA pattern was SARIMA (0, 0, 1) (0, 1, 1)₁₂ which has RMSE and NS values of 8.89 mm and 0.97, respectively. The GRNN model had its best performance by applying the total

*Corresponding Author. *Email Address:* v.varshavian@basu.ac.ir

inputs. The RMSE and NS values were 9.22 and 0.96, respectively, for GRNN's best output. The difference between the two models was reported in predicting the year's minima (January-February), which showed SARIMA's better performance. To compare these two models, the Taylor diagram was also used, which showed that the accuracy of SARIMA not only in error but also in the correlation and estimation of the true deviation of the real values was slightly more accurate than GRNN. After evaluating the models and assessing their acceptable performances, best extracted models from both SARIMA & GRNN were used for ET₀'s long-term forecasting up to the next ten years (for the period of 2018-2027).

Conclusion: The results of the forecasts for Rasht's future showed a sharp ascending trend in the rate of evapotranspiration in the years 2018-2027 (compared to the period of 1956-2017). This is a warning of a rapid increase in the evapotranspiration rate in the years ahead, in the wet area of Rasht. This issue is very important for the surface water and groundwater resources planning, agricultural uses, and will be a serious warning to farmers and water managers in this area.

Keywords: Adjusted ThornthWaite, GRNN, Long-term forecast, SARIMA, Taylor diagram.

