

ارزیابی و مقایسه شبکه‌های عصبی GRNN، MLP و RBF در تخمین تبخیر- تفرق گیاه مرجع، خیار و گوجه‌فرنگی در شرایط گلخانه‌ای

وحید رضوردی نژاد*

تاریخ دریافت: ۹۳/۰۹/۰۸ تاریخ پذیرش: ۹۴/۰۳/۱۶

^۱ استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه

* مسئول مکاتبات، پست الکترونیکی: verdinejad@gmail.com

چکیده

در این مطالعه عملکرد شبکه‌های عصبی مصنوعی با تابع پایه شعاعی (RBF)، پرسپترون چندلایه (MLP) و رگرسیون تعمیم‌یافته (GRNN) در تخمین تبخیر- تفرق گیاه مرجع، خیار و گوجه‌فرنگی در محیط گلخانه ارزیابی و مقایسه گردید. برای این منظور هم‌زمان با اندازه‌گیری تبخیر- تفرق به‌روش لایسیمتری، عوامل اقلیمی مؤثر بر فرآیند تبخیر- تفرق شامل دما، رطوبت، فشار بخار هوا و تشعشع دریافتی اندازه‌گیری شد. نتایج نشان داد که در نظر گرفتن تمام عوامل اقلیمی به‌عنوان ورودی شبکه‌ها، باعث افزایش دقت مدل‌ها می‌گردد. بر اساس نتایج مدل GRNN در مقایسه با MLP و RBF، تبخیر- تفرق مرجع را با دقت بالاتری تخمین زد. متوسط خطای تخمین مرحله آزمون شبکه‌های MLP، RBF و GRNN به‌ترتیب برابر ۹/۴، ۱۳/۳ و ۹ درصد مطابق با ۰/۲۴، ۰/۲۷ و ۰/۲۰ میلی‌متر بر روز به‌دست آمد. در تخمین مقادیر تبخیر- تفرق گوجه‌فرنگی و خیار گلخانه‌ای نیز مدل GRNN عملکرد مناسب‌تری نشان داد. متوسط خطای تخمین مرحله آزمون تخمین تبخیر- تفرق خیار و گوجه‌فرنگی در مدل GRNN به‌ترتیب: ۱۱/۰ درصد (۰/۲۱ میلی‌متر بر روز) و ۱۰/۱ درصد (۰/۲۲ میلی‌متر بر روز)؛ شبکه MLP به‌ترتیب: ۱۱/۴ (۰/۲۲ میلی‌متر بر روز) و ۱۰/۹ (۰/۲۶ میلی‌متر بر روز) درصد و شبکه RBF به‌ترتیب: ۱۲/۳ (۰/۲۳ میلی‌متر بر روز) و ۱۳/۸ (۰/۲۸ میلی‌متر بر روز) درصد محاسبه گردید. بر اساس شاخص خطای نقطه ایده‌آل، مدل GRNN عملکرد دقیقی در تخمین تبخیر- تفرق گیاه در گلخانه نشان داد.

واژه‌های کلیدی: تبخیر- تفرق، تشعشع دریافتی، خیار، شبکه عصبی مصنوعی، فشار بخار هوا، گوجه‌فرنگی

Evaluation and Comparison of GRNN, MLP and RBF Neural Networks for Estimating Cucumber, Tomato and Reference Crops' Evapotranspiration in Greenhouse Condition

V Rezaverdinejad^{1*}

Received: 23 November 2014

Accepted: 6 June 2015

¹Assist. Prof., Dept. of Water Eng., Faculty of Agric., Urmia University

*Corresponding, Author Email: verdinejad@gmail.com

Abstract

In this study, the performance of multi-layer perceptron (MLP), radial basis function (RBF) and generalize regression neural networks (GRNN), were evaluated to estimate cucumber, tomato and reference crops' evapotranspiration (ET) in greenhouse environment. For this purpose, the lysimetric ET values along with the effective meteorological factors on evapotranspiration process, including air temperature, humidity, air vapor pressure, and incoming radiation were measured. The results indicated that introducing the all meteorological factors as artificial neural network models' inputs increased the models accuracy. Based on the results, the GRNN model estimated the reference evapotranspiration with the highest accuracy in comparison to the RBF and MLP models. The average estimation errors of MLP, RBF and GRNN networks for the test phase were 9.4, 13.3 and 9 percent corresponding to the values of 0.24, 0.27 and 0.20 mm d⁻¹, respectively. Performance of GRNN model in estimating cucumber and tomato evapotranspiration values also was appropriate. The average values of the errors for the estimated amounts of the cucumber and tomato evapotranspiration by the GRNN model, were 11.0 (0.21 mm d⁻¹) and 10.1 (0.22 mm d⁻¹) percent, while they were obtained by MLP and RBF models 11.4 (0.22 mm d⁻¹) and 10.9 (0.26 mm d⁻¹); and also 12.3 (0.23 mm d⁻¹) and 13.8 (0.28 mm d⁻¹) percent for MLP and RBF models, respectively. Based on ideal point error index, the GRNN model showed accurate performance in estimating crop evapotranspiration in greenhouse.

Keywords: Air vapor pressure, Artificial neural network, Cucumber, Evapotranspiration, Incoming radiation, Tomato

مقدمه

(۱۹۹۵) در تحقیقی بر روی تبخیر- تعرق گیاه علفی جربرا، دریافتند که گرمای محیط کشت گلخانه باعث افزایش آب مصرفی گیاه نسبت به محیط بیرون گلخانه می‌گردد. برای تعیین نیاز آبی گیاهان روش‌های متعدد از جمله مدل‌های ترکیبی نظیر پنمن مانتیث، مدل‌های تجربی و سنجش‌های مستقیم لایسیمتری وجود دارد. لایسیمترها و میکرو لایسمترهای وزنی دقیق‌ترین روش برای محاسبه تبخیر- تعرق در گلخانه می‌باشند، چرا که

پوشش گلخانه با جلوگیری از باد و افزایش رطوبت داخل گلخانه، تبخیر- تعرق را نسبت به بیرون گلخانه کاهش می‌دهد (کریمی و همکاران ۱۳۸۶). عوامل متعددی بر میزان تبخیر و تعرق گیاه دخالت دارند. علاوه بر مشخصه‌های گیاه (نوع گیاه و مرحله رشد آن)، پارامترهای هواشناسی از قبیل دما، تشعشع و رطوبت تأثیر به‌سزایی در مقدار تبخیر- تعرق گیاه دارند (عابدی کوپایی و همکاران ۱۳۹۰). مارتینز و همکاران

فائو، پنمن اصلاحی و تشت تبخیر کلاس A دارد. شایان‌نژاد و همکاران (۱۳۸۶) تبخیر-تعرق گیاه را از روش‌های رگرسیون فازی، شبکه عصبی مصنوعی و روش پنمن مانتیث تعیین نمودند. نتایج آن‌ها نشان داد که مدل رگرسیون فازی با ورودی‌های دمای کمینه و بیشینه، میانگین رطوبت نسبی، ساعات آفتابی و سرعت باد مدلی برتر در تخمین تبخیر-تعرق است. صیادی و همکاران (۱۳۸۸) عملکرد شبکه‌های عصبی پرسپترون چندلایه (MLP^۱) و با تابع پایه شعاعی (RBF^۲) را در تخمین تبخیر-تعرق گیاه مرجع مقایسه و به این نتیجه رسیدند که دقت شبکه‌های MLP نسبت به RBF بهتر است و تنها مزیت شبکه‌های RBF نیاز به زمان کمتر برای آموزش شبکه هست. مقدم‌نیا و همکاران (۲۰۰۹) مدل‌های ANN و فازی عصبی تطبیقی (ANFIS^۳) را جهت تخمین تبخیر-تعرق مقایسه و با استفاده از آزمون گاما، پارامترهای فشار بخار اشباع، سرعت باد و رطوبت نسبی را به‌عنوان ورودی مدل‌ها انتخاب کردند. نتایج آن‌ها حاکی از برتری ANN نسبت به ANFIS بود. زارع ایبانه و همکاران (۱۳۸۹) دقت شبکه عصبی پرسپترون چندلایه با الگوریتم پس انتشار خطا در پیش-بینی تبخیر-تعرق گیاه سیر بر اساس داده‌های لایسیمیتری را در منطقه همدان ارزیابی کرد. برای این منظور داده‌های هواشناسی دماهای بیشینه و کمینه هوا، مقادیر رطوبت نسبی بیشینه و کمینه، سرعت باد و ساعات آفتابی روزانه به‌عنوان ورودی در نظر گرفت و ریشه میانگین مربعات خطا (RMSE) شبکه عصبی برابر ۰/۰۸۸ میلی‌متر بر روز به‌دست آمد. در شرایط گلخانه، فتحی و کوچک‌زاده (۱۳۸۳) مقدار تعرق خیار گلخانه‌ای را با استفاده از شبکه‌های عصبی مصنوعی بررسی کردند. ورودی شبکه‌های عصبی مصنوعی مورد مطالعه آن‌ها که از نوع پرسپترون بود، میزان تشعشع و خروجی میزان تعرق مدنظر قرار گرفت. بر اساس نتایج آن‌ها شبکه‌های عصبی مصنوعی ابزاری مفید در تخمین تعرق بود و نسبت به مدل‌های تحلیلی غیرخطی، عملکرد

میزان آب مصرفی را به‌صورت مستقیم اندازه‌گیری می‌کنند (موجاهد ۲۰۰۷). بیشتر مدل‌های تخمین تبخیر-تعرق برای فضای خارج گلخانه توسعه یافته‌اند، اما با این حال مدل‌هایی نیز برای محیط گلخانه پیشنهاد شده‌اند (ویلاریل و همکاران ۲۰۱۲). استفاده از مدل‌ها جهت تخمین تبخیر-تعرق گیاهان در گلخانه بر اساس عواملی از قبیل تشعشع دریافتی، کمبود فشار بخار آب موجود در فضای گلخانه، دما و خصوصیات گیاهان مورد کشت در گلخانه از قبیل شاخص سطح برگ، ارتفاع گیاه و مقاومت روزنه‌ای، کارایی بیشتری نشان داده‌اند (امیری و همکاران ۱۳۹۰، عابدی کوپایی و همکاران ۱۳۹۰، فتحیلیان و همکاران ۱۳۸۸). نتایج نشان داده است که با توجه به زیاد بودن متغیرهای مؤثر بر پدیده تبخیر-تعرق، استفاده از مدل‌های رگرسیون در تخمین میزان تبخیر-تعرق گیاه همواره با خطا همراه بوده و در مواقعی مقدار این خطا قابل ملاحظه هست (عابدی کوپایی و همکاران ۱۳۹۰، بابتیستا و همکاران ۲۰۰۵، فازیلا ۲۰۰۹). ابزار شبکه‌های عصبی به‌عنوان یک رویکرد از هوش مصنوعی و محاسبات نرم، به‌طور گسترده در تخمین تبخیر-تعرق گیاه به‌ویژه در فضای خارج گلخانه به‌کار گرفته شده است. در شرایط افزایش تعداد متغیرهای مستقل، توسعه مدل‌های رگرسیون با محدودیت مواجه می‌گردند؛ لذا در این شرایط شبکه‌های عصبی مصنوعی ابزاری توانمند جهت مدل‌سازی می‌باشند (قهرمان و صامتی ۲۰۱۴). یکی از اهداف شبکه‌های هوشمند عصبی، مدل‌سازی به‌قصد پیش‌بینی است که بسیار مورد توجه قرار گرفته است. مطالعات زیادی جهت تعیین صحت و وسقم پیش‌بینی شبکه‌های عصبی مصنوعی برای تخمین تبخیر-تعرق صورت گرفته و نتایج رضایت‌بخش به‌دست آمده است (کیسی ۲۰۰۷). کومار و همکاران (۲۰۰۲) برتری و توانمندی شبکه‌های عصبی مصنوعی را در مقایسه با روش‌های معمول تخمین تبخیر-تعرق مانند جنسن و همکاران و پنمن-مانتیث فائو (۱۹۹۸) در کالیفرنیا گزارش کردند. چایوهان و شریواستاوا (۲۰۰۸) به این نتیجه رسیدند که شبکه‌های عصبی مصنوعی کمترین اختلاف را با نتایج پنمن‌مانتیث فائو در مقایسه با روش‌های تشعشعی

1 - Multi-Layer perceptron networks

2 - Radial basis function

3 - Adaptive neural fuzzy inference systems

کشت محصولات خیار و گوجه‌فرنگی از گلدان‌هایی به ارتفاع ۵۰ و قطر ۲۸ سانتی‌متر استفاده شد. برای بستر کشت محصولات، خاک مزرعه تحقیقاتی دانشکده کشاورزی دانشگاه ارومیه مدنظر قرار گرفت؛ اما با توجه به سنگین بودن بافت آن (دارا بودن حدود ۵۱ درصد رس)، با نسبت ۲۵، ۲۵ و ۵۰ درصد و به‌ترتیب از پیت ماس (ماده آلی)، شن دانه‌بندی شده و خاک مزرعه و به‌صورت یکنواخت مخلوط گردید تا اینکه ویژگی‌های فیزیکی و شیمیایی نیم‌رخ خاک، یکسان باشد. برای گیاه چمن سه گلدان و برای هر کدام از محصولات خیار و گوجه‌فرنگی شش گلدان در نظر گرفته شد که سه گلدان طی دوره رشد و برای اندازه‌گیری برخی از پارامترها از قبیل چگالی ظاهری، عمق توسعه ریشه و وزن بوته استفاده گردید. به‌این‌ترتیب آزمایش با سه تکرار انجام گردید. به‌منظور زهکشی سریع و آسان، کف گلدان‌ها به ارتفاع حدود ۳-۲ سانتی‌متر از شن درشت پر گردید. عمق خاک در تمام نمونه‌ها حدود ۴۵ سانتی‌متر در نظر گرفته شد و ۵ سانتی‌متر فضای خالی جهت سهولت آبیاری در نظر گرفته شد. بذر خیار به‌صورت مستقیم و کشت گوجه‌فرنگی به‌صورت نشاء انجام گرفت. بعد از تنک کردن بوته‌ها و قرار دادن یک عدد بوته در هر گلدان، فواصل کشت محصولات ۵۰ در ۷۰ سانتی‌متر (تراکم کشت حدود ۲/۵ بوته در مترمربع) تنظیم شد. بوته‌ها از تمامی شرایط بکار رفته برای کشت گلخانه‌ای، شامل دوره تنش، کوددهی و سم‌پاشی منظم، برخوردار گردید تا مقادیر تبخیر-تعرق اندازه‌گیری شده، مطابق با شرایط استاندارد باشد. برای تعیین خصوصیات شیمیایی و برخی از خصوصیات فیزیکی از قبیل بافت خاک، قبل از کاشت گیاه، نمونه‌برداری انجام گرفت. چگالی ظاهری خاک طی دوره رشد محصولات و با استفاده از گلدان‌های اضافی، به‌روش نمونه‌گیر مغزی اندازه‌گیری شد. با توجه به اهمیت رطوبت حد ظرفیت زراعی، به دو روش شامل استفاده از دستگاه صفحات فشاری و روش گلدانی، اقدام به اندازه‌گیری آن شد. بر اساس دستگاه صفحات فشاری، رطوبت FC و PWP به‌ترتیب برابر ۳۲/۶ و ۱۵/۷ درصد حجمی به‌دست آمد. رطوبت

بهتر داشت. عصاره و همکاران (۱۳۸۸) با استفاده از شبکه‌های عصبی مصنوعی با ساختار پرسپترون چندلایه نشان دادند که تبخیر-تعرق گیاه مرجع درون گلخانه را می‌توان بر اساس متغیرهای دما، تابش و فشار بخار با ریشه میانگین مربعات خطای ۱/۱ میلی-متر بر روز تخمین زد. در این مطالعه تبخیر-تعرق گیاه مرجع و گیاهان خیار و گوجه‌فرنگی به‌روش لایسمتری طی دوره رشد کامل آن‌ها در گلخانه اندازه‌گیری گردید. بر اساس بررسی‌های صورت گرفته متغیرهای مستقل مدل‌های شبکه عصبی و رگرسیون عمدتاً دما، تابش، رطوبت و فشار بخار مدنظر قرار گرفته است. در این مطالعه به‌منظور بررسی امکان تخمین دقیق‌تر تبخیر-تعرق در گلخانه، گستره وسیعی از عوامل اقلیمی مؤثر بر فرآیند تبخیر-تعرق در نظر گرفته شد. به‌منظور مدل‌سازی تبخیر-تعرق هر یک از گیاهان بر اساس شبکه‌های عصبی مصنوعی، پارامترهای هواشناسی مؤثر بر فرآیند تبخیر-تعرق با استفاده از دیتالاکرهای نصب‌شده در محیط گلخانه و هم‌زمان با اندازه‌گیری تبخیر-تعرق محصولات و گیاه مرجع، اندازه‌گیری گردید. سه نوع شبکه عصبی MLP، RBF و رگرسیون تعمیم‌یافته (GRNN^۴) در تخمین تبخیر-تعرق مرجع و گیاهان مورد مطالعه (گوجه‌فرنگی و خیار گلخانه‌ای)، در نظر و عملکرد آن‌ها مورد ارزیابی و مقایسه قرار گرفت.

مواد و روش‌ها

جمع‌آوری اطلاعات موردنیاز

به‌منظور جمع‌آوری داده‌های میدانی، یک آزمایش کشت گلخانه‌ای در گلخانه تحقیقاتی دانشکده کشاورزی دانشگاه ارومیه به‌مدت شش ماه انجام گردید. محصولات مورد مطالعه خیار و گوجه‌فرنگی بوده و برای تعیین تبخیر و تعرق مرجع در محیط گلخانه، گیاه چمن در نظر گرفته شد. بر اساس تعریف، گیاه مرجع باید دارای پوشش یکنواخت، شاداب، تراکم خوب بوده و بدون محدودیت آب، تبخیر و تعرق کند. همین شرایط نیز برای محیط گلخانه ایجاد گردید. برای

4- Generalize regression neural networks

آزمایش‌های فیزیکی و شیمیایی خاک در جدول ۱ ارائه شده است. همچنین تقویم زراعی محصولات مورد مطالعه مطابق جدول ۲ هست. اندازه‌گیری عوامل هواشناسی و اندازه‌گیری‌های مربوط به تبخیر-تعرق از تاریخ کاشت نشاء گوجه‌فرنگی انجام گرفت.

حجمی حد زراعی به‌روش گلدانی با شش تکرار انجام گرفت. مقدار متوسط رطوبت حجمی حد زراعی در روش گلدانی ۳۳/۷ درصد حجمی محاسبه گردید. با توجه به انحراف استاندارد شش نمونه که ۰/۴ درصد حجمی به‌دست آمد، نتایج روش گلدانی مبنای محاسبات و برنامه‌ریزی آبیاری قرار گرفت. خلاصه نتایج

جدول ۱- نتایج تجزیه فیزیکی و شیمیایی خاک مورد استفاده.

بافت خاک	رس (%)	سیلت (%)	شن (%)	pH (1:1)	EC (dS m ⁻¹)	چگالی ظاهری (g cm ⁻³)	رطوبت حد FC (cm ³ cm ⁻³)	رطوبت حد PWP (cm ³ cm ⁻³)
رسی	۴۰/۰	۲۲/۰	۳۸	۶/۶۵	۱/۶۳	۱/۳۵	۰/۳۳۷	۰/۱۵۷

جدول ۲- تقویم زراعی و رقم محصولات مورد مطالعه.

محصول	کاشت	کاشت نشاء	آخرین برداشت	نوع رقم
خیار	۹۲/۴/۱	**	۹۲/۸/۱۷	گلخانه‌ای-DF1
گوجه‌فرنگی	۹۲/۳/۲۵	۹۲/۴/۲۲	۹۲/۱۰/۵	گلخانه‌ای-YF1
چمن	*	*	*	Lolium perenne

* چمن به‌صورت آماده تهیه و در گلدان‌های مربوطه قرار گرفت.

** کشت خیار به‌صورت مستقیم در گلدان انجام گردید.

گیاه چمن با هرس روزانه در ارتفاع ۱۲ سانتی-متر حفظ و آبیاری با هدف افزایش رطوبت تا حد ظرفیت زراعی و با دور دو روز انجام گردید. قبل از کشت محصولات، گلخانه به ابزارهای لازم برای اندازه-گیری داده‌های هواشناسی مؤثر بر تبخیر-تعرق، مجهز گردید. عوامل هواشناسی در داخل گلخانه با تنظیم فواصل زمانی هر ۱۰ دقیقه ثبت یک داده و با استفاده از ابزارهای ثبت اطلاعات شامل دماسنج، رطوبت‌سنج، فشارسنج و لوکس‌متر، در یک دیتالاگرهای مربوطه ثبت گردید. در این مطالعه متغیرهای تبخیر-تعرق و عوامل هواشناسی، در مقیاس روزانه مورد بررسی قرار گرفت. بر اساس مقادیر ثبت‌شده، عوامل مربوط به دما شامل: مجموع دما-ساعت روزانه (T_{sum})، دمای بیشینه (T_{max})، کمینه (T_{min}) و متوسط روزانه (T_{ave})؛ رطوبت شامل: رطوبت کمینه (RH_{min})، بیشینه (RH_{max}) و متوسط روزانه (RH_{ave})؛ عوامل فشار شامل: متوسط روزانه فشار بخار هوا (ES) و متوسط کمبود فشار بخار اشباع روزانه (VPD)؛ لوکس‌متر شامل: مجموع تشعشع-

برای محاسبه میزان تبخیر-تعرق، از گلدان‌ها به‌عنوان لایسیمتر وزنی استفاده شد. آبیاری با دور دو روز و توزین آن‌ها به‌صورت روزانه انجام شد. حجم آب موجود در خاک قبل از وزن کردن روزانه، از رابطه زیر محاسبه و بر اساس آن آب موردنیاز هر گلدان با هدف رساندن رطوبت خاک به حد ظرفیت زراعی در هر نوبت آبیاری (از طریق وزن کردن)، محاسبه گردید (عابدی کوپایی و همکران ۱۳۹۰):

$$W_{AW} = W_d \left(\theta_{m-fc} - \frac{W_{ty} - W_t}{W_d} \right) \quad [1]$$

که در آن W_d وزن خاک خشک (آون خشک) درون گلدان در ابتدای آزمایش (kg)، θ_{m-fc} رطوبت وزنی خاک در حد ظرفیت زراعی ($g\ g^{-1}$)، W_t وزن گلدان و محتویات آن قبل از هر آبیاری (kg)، W_{ty} وزن گلدان و محتویات آن بعد از آبیاری (و احیاناً بعد از زهکشی آب مازاد) (kg) و W_{AW} مقدار آب قابل‌استفاده (kg) می‌باشند.

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad [۳]$$

که در آن J ماتریس ژاکوبین (مشتقات جزئی مرتبه اول) تابع چند متغیره خطای شبکه (تابع عملکرد)، e بردار خطاهای شبکه، I ماتریس یک و μ اسکالر هست.

شبکه‌های RBF

شبکه‌های RBF نوعی شبکه عصبی پیش‌خور بوده و ساختار آن‌ها شبیه شبکه‌های MLP هست. شبکه‌های RBF نیازمند نرون‌های بیشتری نسبت به شبکه‌های استاندارد پیش‌خور با الگوریتم پس‌انتشار خطا می‌باشند ولی این شبکه‌ها را می‌توان در زمانی کوتاه‌تر نسبت به شبکه‌های پیش‌خور آموزش داد (کالرا و همکاران ۲۰۰۵). این نوع شبکه الگوی ورودی n بعدی را با استفاده از گره‌های واقع در لایه مجاور به یک الگوی خروجی z بعدی نگاشت می‌کند. لایه ورودی مقادیر ورودی را به هر یک از گره‌های لایه پنهان ارسال می‌کند. هر یک از گره‌های واقع در لایه پنهان (نرون‌ها) با یک تابع انتقال (f) مشخص می‌شوند که سیگنال ورودی را انتقال می‌دهند. برای p امین الگوی ورودی (X^p) پاسخ زامین گره پنهان (y_j) برابر است با (کالرا و همکاران ۲۰۰۵):

$$y_j = f \left(\frac{\|X^p - U_j\|}{2\sigma_j^2} \right) \quad [۴]$$

که در آن $\| \cdot \|$ نرم اقلیدسی، U_j مرکز زامین تابع پایه شعاعی و σ شاخص گسترش یا واریانس توابع پایه شعاعی هست که توسط کاربر تعریف می‌گردد. خروجی شبکه با استفاده از مجموع وزن‌دار خطی پاسخ‌های لایه‌ی پنهان در هر یک از گره‌های خروجی به‌دست می‌آید. خروجی k امین گره در لایه خروجی (z_{kj}) از رابطه زیر محاسبه می‌شود:

$$z_{pk} = \sum_{j=1}^L y_j w_{kj} \quad [۵]$$

که در آن w_{kj} وزن پیوند بین گره‌های پنهان و خروجی و L تعداد گره لایه پنهان هست. از متداول‌ترین توابع انتقال RBF، گاوسی و سیگموئیدی می‌باشند.

ساعت روزانه (R_{hu}) و تشعشع روزانه دریافتی (R_n)، استخراج گردید. شدت نور (یا میزان تشعشع) بر حسب لوکس متر ثبت شد. ۱۰۰ لوکس برابر ۱ وات بر مترمربع بوده که با محاسبه مساحت زیر منحنی شدت نور- زمان طی یک روز، به مگاژول بر مترمربع بر روز تبدیل گردید.

شبکه‌های عصبی مصنوعی

در این مطالعه سه شبکه از پرکاربردترین شبکه‌های عصبی شامل شبکه MLP، RBF و GRNN استفاده شد و عملکرد آن‌ها در تخمین تبخیر- تعرق گیاه در گلخانه با یکدیگر مقایسه گردید.

شبکه‌های MLP

شبکه‌های MLP از چندلایه تشکیل می‌شوند که هر لایه، ورودی لایه بعدی را (به‌صورت پیش‌خور^۵) تولید می‌کند. ساختار یک شبکه MLP با تعیین تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، تابع محرک (کنترل‌کننده خروجی هر نرون)، روش آموزش، الگوریتم تصحیح وزن‌ها و نوع مدل، تعیین می‌شود (کیسی ۲۰۰۷). در تحقیق حاضر دو ساختار سه و چهار لایه در نظر و از میان روش‌های مختلف آموزش، الگوریتم لونیبرگ مارکوورت، به‌دلیل همگرایی سریع‌تر در آموزش شبکه انتخاب گردید. همچنین توابع محرک لوگ-سیگموئید (Log-Sigmoid) و تانژانت-سیگموئید (Tan-Sigmoid) در لایه پنهان و تابع محرک خطی (Purline) در لایه خروجی بکار گرفته شد. در این شبکه‌ها الگوریتم پس انتشار خطا (رابطه ۲)، وزن‌های شبکه و مقادیر بایاس را در جهتی تغییر می‌دهد که تابع عملکرد شبکه با سرعت بیشتری کاهش یابد:

$$x_{k+1} = x_k - \alpha_k g_k \quad [۲]$$

که در آن x_k بردار وزن‌ها و بایاس در تکرار k ام، α_k نرخ آموزش در تکرار k ام و g_k شیب در تکرار k ام می‌باشند. برای دستیابی به آموزش سریع‌تر شبکه الگوریتم لونیبرگ- مارکوورت (رابطه ۳) بسط داده شده است:

گردید: سناریو ۱: T_{ave} , RH_{ave} , VPD و R_n ; سناریو ۲: VPD و R_n ; سناریو ۳: RH_{ave} و T_{ave} ; سناریو ۴: T_{ave} و R_n . یک سناریو دیگر (سناریوی پنجم) نیز در این مطالعه تعریف گردید که در آن یازده پارامتر اندازه‌گیری شده به‌عنوان ورودی مدل‌ها در نظر گرفته شد. در جدول ۳ متغیرهای مستقل ورودی برای هر یک از مدل‌های شبکه‌های عصبی تخمین تبخیر-تعرق ارائه شده است.

ارزیابی عملکرد مدل‌های شبکه عصبی

برای بررسی کارایی هر یک از مدل‌ها در تخمین تبخیر-تعرق، از معیارهای ریشه میانگین مربعات خطا (RMSE)، میانگین نسبی خطا (MRE)، ضریب همبستگی (r) و میانگین خطای مطلق (MAE) استفاده گردید (داوسون و همکاران ۲۰۱۲):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n [(ET_p)_i - (ET_m)_i]^2} \quad [6]$$

$$MRE = \frac{1}{N} \sum_{i=1}^n \frac{|(ET_p)_i - (ET_m)_i|}{|(ET_m)_i|} \quad [7]$$

$$r = \frac{\text{cov}(ET_p, ET_m)_i}{\sqrt{\text{var}(ET_p) \times \text{var}(ET_m)}} \quad [8]$$

$$MAE = \frac{1}{N} \sum_{i=1}^n |(ET_p)_i - (ET_m)_i| \quad [9]$$

که در آن ET_p تبخیر-تعرق تخمین زده شده، ET_m تبخیر-تعرق اندازه‌گیری شده، N تعداد اندازه‌گیری‌ها، i اندیس مربوط به روز و cov و var به ترتیب کواریانس و واریانس داده‌ها می‌باشند. گاهی اوقات نتایج به دست آمده از چهار معیار فوق متفاوت می‌باشند. شاخص بدون بعد خطای نقطه ایده‌آل (IPE) به صورت ترکیبی از شاخص‌ها بوده و در انتخاب مدل مناسب کمک می‌کند. بر اساس شاخص IPE، فضای n بعدی ورودی‌ها (n تعداد آماره‌ها برای ارزیابی مدل)، به یک نقطه ایده‌آل استاندارد می‌گردد (داوسون و همکاران ۲۰۱۲):

$$IPE = \left[0.25 \left(\left(\frac{RMSE_i}{\max(RMSE)} \right)^2 + \left(\frac{MRE_i}{\max(MRE)} \right)^2 + \left(\frac{MAE_i}{\max(MAE)} \right)^2 + \left(\frac{r_i - 1}{1/\max(r)} \right)^2 \right) \right]^{0.5} \quad [10]$$

مدل‌های GRNN

این شبکه‌ها در طبقه‌بندی، جزء دسته شبکه‌های عصبی احتمالاتی^۶ قرار می‌گیرند. شبکه‌های احتمالاتی قادرند با تعداد نمونه آموزشی محدود، به سرعت به سمت تابع عملکرد همگرا شوند که این، خود مزیتی در مقایسه با شبکه‌های عصبی بازخوردی^۷ محسوب می‌شود. یک شبکه رگرسیون تعمیم‌یافته، شامل چهار لایه ورودی‌ها، الگو^۸، تجمیع^۹ و خروجی است. اولین لایه به طور کامل به لایه الگو متصل است، جایی که هر واحد، نماینده یک الگوی آموزشی بوده و خروجی آن، فاصله از ورودی ذخیره شده در الگوها هست. هر واحد در لایه الگو، به دو نرون در لایه تجمیع متصل است: نرون تجمیع S و نرون تجمیع D. نرون S جمع وزنی خروجی‌های لایه الگو را محاسبه می‌کند، درحالی‌که نرون D خروجی‌های غیر وزنی نرون‌های الگو را محاسبه می‌کند. وزن بین یک نرون در لایه الگو و نرون S برابر با مقدار خروجی مربوط به ورودی لایه الگو هست. در مورد نرون D، این وزن برابر یک است. لایه خروجی، خروجی مربوط به هر نرون S را به خروجی نرون D تقسیم و خروجی نهایی مربوط به یک بردار ورودی ناشناخته را به دست می‌دهد. عملکرد نرون تجمیع D، تابع پارامتر گسترش هست که تعیین مقدار بهینه آن با سعی و خطا امکان‌پذیر است.

پارامترهای ورودی شبکه‌های عصبی

در این مطالعه عمده عوامل تأثیرگذار بر فرآیند تبخیر-تعرق گیاه از جمله: مجموع دما-ساعت روزانه: T_{sum} ، دمای متوسط، بیشینه و کمینه روزانه: T_{max} ، T_{min} و T_{ave} ؛ رطوبت متوسط، بیشینه و کمینه: RH_{max} ، RH_{ave} و RH_{min} ؛ متوسط فشار بخار هوا و کمبود فشار بخار اشباع روزانه: ES و VPD؛ مجموع تشعشع-ساعت روزانه و تشعشع روزانه دریافتی: R_n و R_{hu} اندازه‌گیری گردید. مطابق بررسی‌ها و مطالعات صورت گرفته، چهار سناریوی پارامترهای مؤثر (به‌عنوان ورودی) برای تخمین تبخیر-تعرق گیاه در محیط گلخانه تعریف

1-Probabilistic Neural Networks
2-Backpropagation
3-Pattern layer
4-Summation layer

1-IPE: Ideal point error

گیری شده به عنوان ورودی مدل در نظر گرفته شده است. همچنان که ذکر شد، در تمام موارد شبکه پرسپترون دو لایه (با یک لایه پنهان)، شبکه بهینه بوده و افزایش تعداد لایه پنهان تأثیر معنی داری در افزایش عملکرد شبکه نداشته است. توابع انتقال تانژانت-سیگموئید و خطی، به ترتیب توابع بهینه برای لایه پنهان و خروجی بوده و در تمام موارد الگوریتم لوبنرگ-مارکوات (LM)، الگوریتم بهینه برای آموزش شبکه به دست آمد. مقدار RMSE این سناریو ۰/۳۱ میلی متر بر روز و مقدار خطای نسبی برابر ۹/۴ درصد به دست آمد. بعد از سناریوی S₅ از نظر دقت تخمین، سناریوی S₁ هست که بر اساس چهار پارامتر: تشعشع روزانه، متوسط دما، رطوبت و کمبود فشار بخار روزانه، تبخیر-تعرق گیاه مرجع تخمین زده شد. RMSE مرحله آزمون سناریوی S₂، ۰/۳۵ میلی متر بر روز و مقدار خطای نسبی برابر ۱۲/۶ درصد به دست آمد. مقایسه مقادیر تبخیر-تعرق مرجع اندازه گیری و تخمین زده شده با مدل شبکه MLP و برای سناریوی بهینه این شبکه (S₅) در شکل ۱ ارائه شده است. در این شکل نتایج تخمین و اندازه گیری شده برای مرحله آموزش و آزمون به صورت مجزا نشان داده شده است. بر این اساس در بیشتر موارد عملکرد شبکه در تخمین تبخیر-تعرق مرجع در محیط گلخانه مناسب بوده ولی در پاره ای از موارد نیز خطای قابل ملاحظه ای نشان داده است.

که در آن برای مدل n ، $\max(x)$ بیشینه مقدار آماره x در میان گروه مدل های تحت بررسی هست. مقدار شاخص IPE، بین صفر تا یک متغیر بوده و هر اندازه به صفر نزدیک تر باشد، مدل مناسب هست.

نتایج و بحث

تخمین تبخیر-تعرق مرجع

تبخیر-تعرق مرجع برای سناریوهای مختلف از متغیرهای مستقل توسط مدل های مختلف شبکه عصبی تخمین زده شد. به منظور یافتن ساختار بهینه شبکه های عصبی مصنوعی با الگوریتم های مختلف، پارامترهایی همانند تعداد نرون ها (۵ تا ۱۰۰ نرون) در لایه های پنهان، توابع محرک مختلف در لایه های پنهان و خروجی در هر الگوریتم و تعداد لایه های پنهان، به روش سعی و خطا مورد آزمون قرار گرفت. نتایج نشان داد که افزایش تعداد لایه های پنهان از یک به دو لایه پنهان تأثیری در افزایش دقت شبکه ها در تخمین تبخیر-تعرق ندارد. محققان مختلفی از جمله صیادی و همکاران (۱۳۸۸) نیز این شرایط را گزارش نمودند. مشخصات مدل بهینه شبکه عصبی مصنوعی MLP و پارامترهای آماری محاسبه شده جهت تخمین تبخیر-تعرق مرجع مطابق جدول ۴ هست. بر اساس نتایج حاصل از آزمایش (آزمون) شبکه های MLP، دقیق ترین حالت، سناریوی S₅ هست که در آن تمام پارامترهای اندازه-

جدول ۳- متغیرهای مستقل ورودی برای هریک از مدل های شبکه های عصبی برای تخمین تبخیر-تعرق.**

ورودی مدل (متغیرهای مستقل)											سناریو
R _n	R _{hu}	RH _{min}	RH _{max}	RH _{ave}	T _{sum}	T _{min}	T _{max}	T _{ave}	ES	VPD	
*				*				*		*	۱
*				*				*		*	۲
				*				*		*	۳
*				*				*		*	۴
*	*	*	*	*	*	*	*	*	*	*	۵

** علامت * نشان دهنده در نظر گرفتن متغیر در مدل به عنوان ورودی هست.

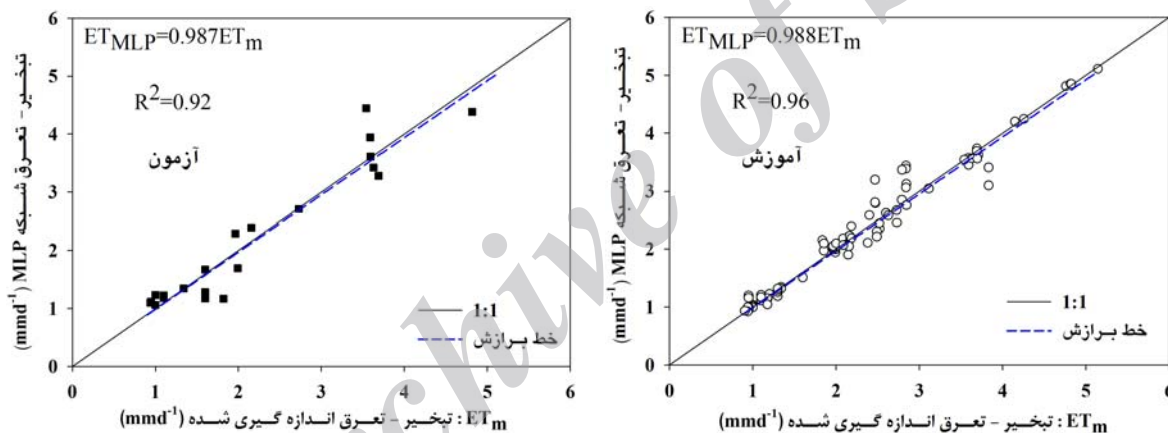
نرون‌ها زیاد در نظر گرفته شود، شبکه RBF به خوبی آموزش می‌بیند ولی توانایی تعمیم آن کاهش یافته و عملکرد مناسبی در داده‌های آزمون نخواهد داشت. برعکس هر اندازه تعداد نرون‌ها کمتر لحاظ گردد، فرآیند آموزش دچار مشکل می‌گردد.

عملکرد شبکه RBF در تخمین تبخیر-تعرق گیاه مرجع در جدول ۵ ارائه شده است. تعداد نرون‌های لایه پنهان در تمام سناریوهای شبکه RBF برابر ۲۵ در نظر گرفته شد. بیشینه تعداد نرون‌های لایه پنهان در شبکه‌های RBF برابر تعداد داده‌ها هست. در صورتی که تعداد

جدول ۴- مشخصات شبکه MLP بهینه و پارامترهای آماری محاسبه شده در تخمین تبخیر-تعرق مرجع در محیط گلخانه.

سناریو	ساختار مدل بهینه	آموزش					آزمون				
		r (%)	RMSE (mm ^{d-1})	MAE (mm ^{d-1})	MRE (%)	IPE (-)	r (%)	RMSE (mm ^{d-1})	MAE (mm ^{d-1})	MRE (%)	IPE (-)
S ₁	[LM, Tansig, Purelin, 65]**	۹۸	۰/۲۱	۰/۱۶	۸/۵	۰/۵۱	۹۶	۰/۳۵	۰/۲۷	۱۲/۶	۰/۵۹
S ₂	[LM, Tansig, Purelin, 55]	۹۸	۰/۲۴	۰/۱۷	۸/۱	۰/۵۳	۹۱	۰/۴۷	۰/۳۶	۱۷/۹	۰/۸۱
S ₃	[LM, Tansig, Purelin, 65]	۹۸	۰/۲۰	۰/۱۵	۷/۵	۰/۴۷	۹۱	۰/۴۰	۰/۲۹	۱۳/۱	۰/۶۵
S ₄	[LM, Tansig, Purelin, 60]	۹۸	۰/۱۹	۰/۱۴	۷/۱	۰/۴۴	۹۰	۰/۴۴	۰/۳۵	۱۵/۸	۰/۷۵
S ₅	[LM, Tansig, Purelin, 85]	۹۸	۰/۲۰	۰/۱۶	۸/۸	۰/۵۱	۹۷	۰/۳۱	۰/۲۴	۹/۴	۰/۵۰

** به ترتیب الگوریتم آموزش شبکه، تابع انتقال لایه پنهان، تابع انتقال لایه خروجی و تعداد نرون‌های لایه پنهان می‌باشند.



شکل ۱- مقایسه مقادیر تبخیر-تعرق مرجع اندازه‌گیری و تخمینی با شبکه MLP برای سناریو S₅.

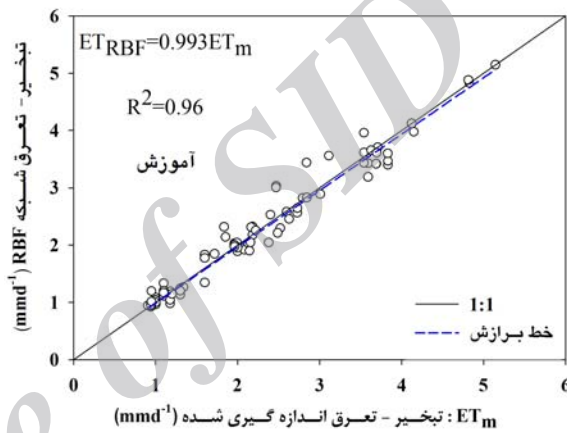

مقایسه عملکرد شبکه RBF و MLP نشان می‌دهد که هر دو شبکه در مرحله آموزش، دقت مناسبی داشته و به خوبی آموزش دیده‌اند، اما عملکرد شبکه MLP نسبت به RBF در مرحله آزمون بهتر بوده و قابلیت تعمیم شبکه MLP بهتر هست. در سناریوی S₅ (دقیق‌ترین سناریو برای هر دو شبکه MLP و RBF)، شاخص خطای نقطه ایده‌آل برای RBF برابر ۰/۶۱ و برای شبکه MLP برابر ۰/۵ به دست آمد که نشان‌دهنده عملکرد مناسب‌تر شبکه MLP هست.

بر اساس مطالعات صورت گرفته دامنه مناسب نرون‌های (توابع انتقال) شبکه RBF حدود ۲۰ تا ۳۰ درصد کل داده‌ها پیشنهاد شده است (کالرا و همکاران ۲۰۰۵). مطابق جدول ۵، بهترین عملکرد شبکه RBF مربوط به سناریوی S₅ هست. در سناریوی مذکور و برای مرحله آزمون شبکه RBF، مقادیر ریشه میانگین مربعات خطا و خطای نسبی به ترتیب ۰/۳۷ میلی‌متر و ۱۳/۳ درصد محاسبه گردید. مقایسه مقادیر تبخیر-تعرق مرجع اندازه‌گیری و تخمین زده شده با مدل شبکه RBF برای سناریو S₅، در شکل ۲ ارائه گردیده است.

جدول ۵- مشخصات شبکه RBF بهینه و پارامترهای آماری محاسبه شده برای تخمین تبخیر- تعرق مرجع.

سناریو	ساختار مدل بهینه	آموزش					آزمون				
		r (%)	RMSE (mmd ⁻¹)	MAE (mmd ⁻¹)	MRE (%)	IPE (-)	r (%)	RMSE (mmd ⁻¹)	MAE (mmd ⁻¹)	MRE (%)	IPE (-)
S ₁	[1.0, 25, Gaussian]**	۹۸	۰/۲۲	۰/۱۵	۸/۱	۰/۵۰	۸۸	۰/۵۰	۰/۳۵	۱۳/۹	۰/۷۷
S ₂	[1.1, 25, Gaussian]	۹۸	۰/۲۱	۰/۱۳	۵/۹	۰/۵۱	۹۳	۰/۴۱	۰/۳۱	۱۴/۶	۰/۶۹
S ₃	[1.1, 25, Gaussian]	۹۷	۰/۲۴	۰/۱۷	۷/۶	۰/۵۳	۹۲	۰/۴۴	۰/۳۷	۲۰/۵	۰/۸۳
S ₄	[1.0, 25, Gaussian]	۹۸	۰/۲۱	۰/۱۵	۸/۱	۰/۴۹	۹۲	۰/۴۹	۰/۳۵	۱۵/۵	۰/۷۸
S ₅	[0.8, 25, Gaussian]	۹۸	۰/۲۰	۰/۱۴	۷/۱	۰/۴۵	۹۸	۰/۳۷	۰/۲۷	۱۳/۳	۰/۶۱

** به ترتیب شاخص گسترش، تعداد نرون‌های شبکه و تابع انتقال می‌باشند.

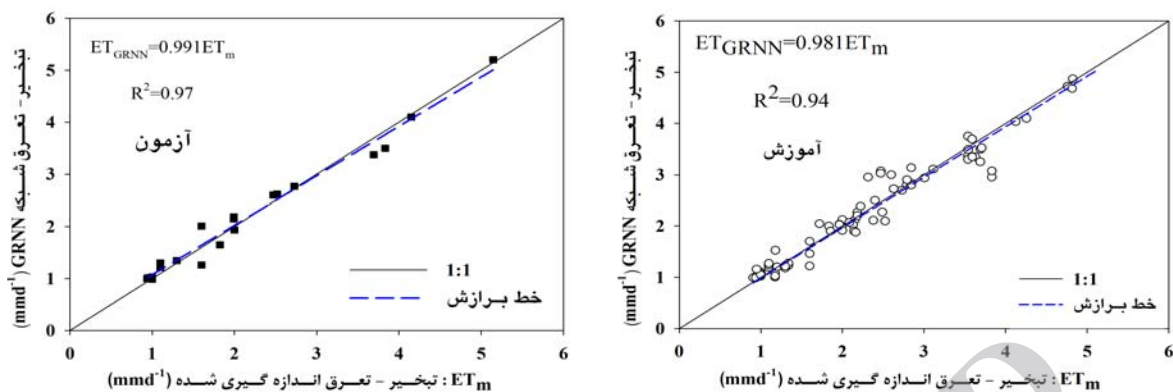
شکل ۲- مقایسه مقادیر تبخیر- تعرق مرجع اندازه‌گیری و تخمینی با شبکه RBF برای سناریو S₅.

تحت سناریوی S₅ مقادیر RMSE و MRE به ترتیب ۰/۳۲ و میلی‌متر بر روز و ۹ درصد به دست آمد که نشان‌دهنده عملکرد دقیق‌تر این شبکه نسبت به MLP و RBF است. مقایسه کلی عملکرد هر سه شبکه MLP، RBF و GRNN طی دوره رشد گیاه چمن (داده‌های آموزش و آزمون) مطابق شکل ۴ است. بر این اساس، مدل GRNN دارای کمینه خطا و شبکه RBF دارای بیشینه خطا در تخمین تبخیر- تعرق گیاه مرجع در محیط گلخانه است.

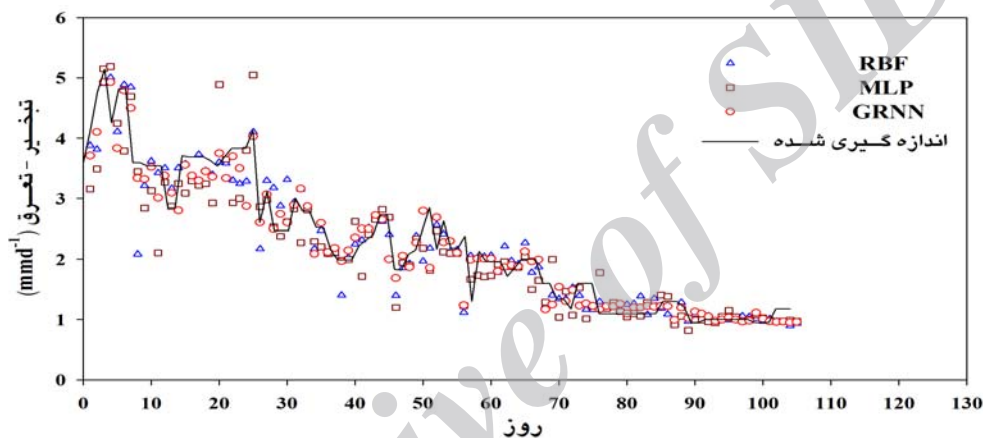
نتایج حاصل از آموزش و آزمون مدل GRNN در تخمین تبخیر- تعرق مرجع، استخراج و مطابق جدول ۶ است. همچنین مقایسه مقادیر تبخیر- تعرق مرجع اندازه‌گیری و تخمین زده شده با مدل GRNN در سناریو S₅، مطابق شکل ۳ ارائه شده است. مطابق جدول ۶، شاخص IDE برای مدل GRNN و سناریوی S₅ برابر ۰/۴۶ محاسبه گردید. با مقایسه مقادیر IDE برای هر سه مدل، GRNN نسبت به MLP و RBF از دقت بالایی در تخمین مقدار تبخیر- تعرق مرجع برخوردار است.

جدول ۶- مشخصات مدل GRNN بهینه و پارامترهای آماری محاسبه شده جهت تخمین تبخیر- تعرق مرجع.

سناریو	شاخص گسترش	آموزش					آزمون				
		r (%)	RMSE (mmd ⁻¹)	MAE (mmd ⁻¹)	MRE (%)	IPE (-)	r (%)	RMSE (mmd ⁻¹)	MAE (mmd ⁻¹)	MRE (%)	IPE (-)
S ₁	۰/۴	۹۵	۰/۳۱	۰/۲۲	۱۲/۲	۰/۷۳	۹۶	۰/۳۰	۰/۲۱	۱۱/۱	۰/۴۹
S ₂	۰/۴	۹۴	۰/۳۸	۰/۲۷	۱۲/۶	۰/۸۴	۹۸	۰/۲۲	۰/۱۹	۱۳/۳	۰/۴۶
S ₃	۰/۵	۹۷	۰/۳۵	۰/۲۶	۱۲/۸	۰/۸۱	۹۴	۰/۳۶	۰/۳۶	۱۲/۷	۰/۶۸
S ₄	۱/۵	۹۵	۰/۳۶	۰/۲۸	۱۳/۱	۰/۸۵	۹۳	۰/۳۸	۰/۳۱	۱۳/۵	۰/۶۶
S ₅	۰/۳	۹۶	۰/۳۰	۰/۲۱	۱۱/۷	۰/۷۱	۹۸	۰/۳۲	۰/۲۰	۹/۰	۰/۴۶



شکل ۳- مقایسه مقادیر تبخیر-تعرق مرجع اندازه‌گیری و تخمینی با مدل GRNN برای سناریو S₅.



شکل ۴- مقایسه عملکرد شبکه‌های عصبی MLP، RBF و GRNN در تخمین تبخیر-تعرق گیاه مرجع برای سناریو S₅.

تخمین تبخیر-تعرق خیار S₁ هست. شاخص IPE سناریوی S₁ برای هر دو مدل GRNN و MLP برابر ۰/۳۹ محاسبه گردید که نشان از دقت مشابه این دو شبکه در تخمین تبخیر-تعرق خیار دارد. در تخمین تبخیر-تعرق گوجه‌فرنگی نیز عملکرد مدل GRNN نسبت به دو شبکه دیگر دقیق‌تر بود. بهترین وضعیت تخمین تبخیر-تعرق گوجه‌فرنگی در هر سه شبکه در سناریوی S₅ به دست آمد. تحت سناریوی S₅، برای شبکه‌های MLP، RBF و GRNN مقادیر IPE به ترتیب برابر ۰/۳۳، ۰/۴۰ و ۰/۳۱ میلی‌متر بر روز محاسبه گردید.

تخمین تبخیر-تعرق گوجه‌فرنگی و خیار

عملکرد سه شبکه MLP، RBF و GRNN مورد بررسی قرار گرفت و نتایج عملکرد آن‌ها مطابق جدول‌های ۷ تا ۹ هست. در تخمین تبخیر-تعرق خیار گلخانه‌ای، عملکرد دو مدل GRNN و MLP تقریباً مشابه بوده اما شبکه‌های RBF خطای بیشتری نسبت به دو شبکه دیگر نشان داد. بر اساس شاخص خطای نقطه ایده‌آل، بهترین عملکرد برای تخمین تبخیر-تعرق خیار مربوط به سناریوی S₅ (با مقدار ۰/۳۴) حاصل شد. هرچند شبکه MLP نیز در این سناریو (S₅) تا حد زیادی دقیق عمل نمود و شاخص خطای نقطه ایده‌آل آن ۰/۳۵ به دست آمد. بعد از سناریوی S₅، دقیق‌ترین سناریوی

جدول ۷- مشخصات شبکه MLP بهینه برای سناریوهای مختلف و پارامترهای آماری جهت تخمین تبخیر- تعرق محصولات.

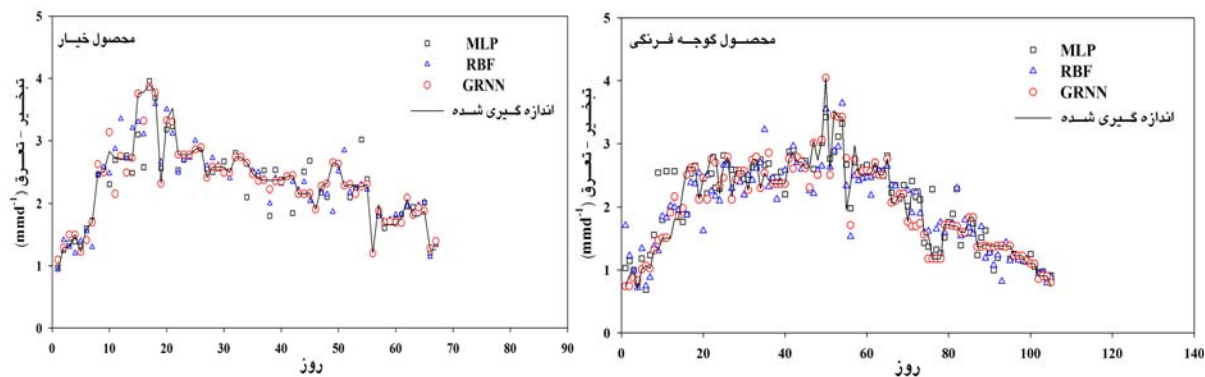
گیاه	سناریو	ساختار مدل بهینه	آموزش					آزمون				
			r (%)	RMSE (mmd ⁻¹)	MAE (mmd ⁻¹)	MRE (%)	IPE (-)	r (%)	RMSE (mmd ⁻¹)	MAE (mmd ⁻¹)	MRE (%)	IPE (-)
چغندر	S1	[LM, Tansig, Purelin, 60]	۹۶	۰/۱۸	۰/۱۱	۴/۳	۰/۴۶	۸۷	۰/۲۵	۰/۲۱	۱۲/۳	۰/۳۹
	S2	[LM, Tansig, Purelin, 55]	۹۷	۰/۲۱	۰/۱۴	۷/۱	۰/۵۸	۷۵	۰/۵۵	۰/۳۸	۱۵/۷	۰/۶۸
	S3	[LM, Tansig, Purelin, 55]	۹۸	۰/۲۰	۰/۱۵	۷/۵	۰/۵۸	۷۹	۰/۴۵	۰/۳۲	۱۴/۴	۰/۵۷
	S4	[LM, Tansig, Purelin, 55]	۹۶	۰/۲۰	۰/۱۳	۶/۰	۰/۵۴	۷۷	۰/۵۶	۰/۵۱	۲۵/۳	۰/۸۵
	S5	[LM, Tansig, Purelin, 75]	۹۸	۰/۱۱	۰/۰۴	۲/۰	۰/۵۶	۹۰	۰/۲۲	۰/۲۲	۱۱/۴	۰/۳۵
گوجه‌فرنگی	S1	[LM, Tansig, Purelin, 80]	۹۷	۰/۲۰	۰/۱۵	۸/۹	۰/۳۶	۹۴	۰/۳۴	۰/۲۶	۱۱/۹	۰/۵۱
	S2	[LM, Tansig, Purelin, 75]	۹۶	۰/۲۶	۰/۱۹	۹/۹	۰/۴۳	۹۰	۰/۴۸	۰/۳۸	۱۹/۱	۰/۷۶
	S3	[LM, Tansig, Purelin, 75]	۹۷	۰/۲۳	۰/۱۸	۸/۱	۰/۳۸	۸۹	۰/۴۲	۰/۳۱	۱۳/۷	۰/۶۲
	S4	[LM, Tansig, Purelin, 75]	۹۶	۰/۲۲	۰/۱۶	۸/۵	۰/۳۷	۸۹	۰/۴۶	۰/۳۷	۱۶/۲	۰/۷۱
	S5	[LM, Tansig, Purelin, 80]	۹۷	۰/۲۲	۰/۱۷	۹/۴	۰/۳۹	۹۴	۰/۳۳	۰/۲۶	۱۰/۹	۰/۵۰

جدول ۸- مشخصات شبکه RBF بهینه برای سناریوهای مختلف و پارامترهای آماری جهت تخمین تبخیر- تعرق محصولات.

گیاه	سناریو	ساختار مدل بهینه	آموزش					آزمون				
			r (%)	RMSE (mmd ⁻¹)	MAE (mmd ⁻¹)	MRE (%)	IPE (-)	r (%)	RMSE (mmd ⁻¹)	MAE (mmd ⁻¹)	MRE (%)	IPE (-)
چغندر	S1	[0.9, 15, Gaussian]	۹۴	۰/۲۲	۰/۱۶	۷/۵	۰/۶۲	۸۸	۰/۴۵	۰/۱۷	۱۴/۵	۰/۵۰
	S2	[1.0, 15, Gaussian]	۹۶	۰/۲۰	۰/۱۳	۶/۲	۰/۵۴	۸۲	۰/۶۰	۰/۱۹	۱۶/۶	۰/۶۳
	S3	[1.1, 15, Gaussian]	۹۷	۰/۲۲	۰/۱۷	۹/۱	۰/۶۶	۸۰	۰/۴۹	۰/۳۳	۱۶/۲	۰/۶۲
	S4	[1.0, 15, Gaussian]	۹۶	۰/۲۱	۰/۱۴	۶/۸	۰/۵۸	۸۰	۰/۵۱	۰/۴۹	۲۴/۲	۰/۸۱
	S5	[1.0, 15, Gaussian]	۹۶	۰/۱۹	۰/۱۱	۵/۰	۰/۴۹	۸۹	۰/۲۱	۰/۲۳	۱۲/۳	۰/۳۹
گوجه‌فرنگی	S1	[1.1, 25, Gaussian]	۹۶	۰/۲۴	۰/۱۶	۸/۷	۰/۳۸	۸۹	۰/۵۲	۰/۳۹	۱۸/۱	۰/۷۸
	S2	[1.1, 25, Gaussian]	۹۶	۰/۲۴	۰/۱۶	۸/۴	۰/۳۸	۹۰	۰/۴۸	۰/۳۷	۲۰/۱	۰/۷۷
	S3	[1.1, 25, Gaussian]	۹۵	۰/۲۷	۰/۲۰	۱۱/۱	۰/۴۶	۹۰	۰/۵۱	۰/۴۴	۲۲/۸	۰/۸۶
	S4	[1.1, 25, Gaussian]	۹۴	۰/۲۵	۰/۱۸	۱۳/۰	۰/۴۷	۸۹	۰/۵۱	۰/۳۶	۱۷/۳	۰/۷۴
	S5	[0.8, 25, Gaussian]	۹۵	۰/۲۱	۰/۱۴	۸/۴	۰/۳۵	۹۱	۰/۴۰	۰/۲۸	۱۳/۸	۰/۵۹

جدول ۹- مشخصات مدل GRNN بهینه برای سناریوهای مختلف و پارامترهای آماری جهت تخمین تبخیر- تعرق محصولات.

گیاه	سناریو	پارامتر گسترش	آموزش					آزمون				
			r (%)	RMSE (mmd ⁻¹)	MAE (mmd ⁻¹)	MRE (%)	IPE (-)	r (%)	RMSE (mmd ⁻¹)	MAE (mmd ⁻¹)	MRE (%)	IPE (-)
چغندر	S1	۰/۲۵	۹۶	۰/۱۹	۰/۱۴	۸/۵	۰/۵۹	۹۰	۰/۲۴	۰/۲۲	۱۳/۱	۰/۳۹
	S2	۰/۲۵	۹۶	۰/۲۳	۰/۱۷	۱۰/۲	۰/۷۱	۷۹	۰/۵۱	۰/۳۵	۱۵/۱	۰/۶۳
	S3	۰/۳۰	۹۶	۰/۲۲	۰/۱۷	۱۱/۱	۰/۷۲	۸۱	۰/۴۴	۰/۳۱	۱۴/۲	۰/۵۶
	S4	۰/۳۰	۹۶	۰/۲۳	۰/۱۵	۸/۱	۰/۶۵	۷۹	۰/۵۲	۰/۵۰	۲۳/۸	۰/۸۱
	S5	۰/۱۸	۹۷	۰/۱۵	۰/۱۰	۷/۱	۰/۴۷	۹۲	۰/۲۰	۰/۲۱	۱۱/۰	۰/۳۴
گوجه‌فرنگی	S1	۰/۲۵	۹۲	۰/۳۳	۰/۲۵	۱۴/۴	۰/۵۸	۸۸	۰/۳۵	۰/۲۶	۱۴/۳	۰/۵۵
	S2	۰/۲۸	۹۳	۰/۴۵	۰/۳۲	۱۶/۶	۰/۷۴	۸۹	۰/۲۶	۰/۲۲	۱۵/۱	۰/۴۹
	S3	۰/۳۰	۹۲	۰/۴۰	۰/۳۱	۱۵/۴	۰/۶۸	۸۹	۰/۳۸	۰/۳۷	۱۴/۹	۰/۶۵
	S4	۰/۳۰	۹۲	۰/۵۱	۰/۳۸	۲۰/۲	۰/۸۷	۸۵	۰/۴۱	۰/۳۷	۱۶/۸	۰/۶۹
	S5	۰/۳۰	۹۴	۰/۳۲	۰/۲۴	۱۳/۱	۰/۵۵	۹۰	۰/۳۱	۰/۲۲	۱۰/۱	۰/۴۵



شکل ۵- مقایسه عملکرد شبکه‌های عصبی MLP، RBF و GRNN در تخمین تبخیر-تعرق گوجه‌فرنگی و خیار گلخانه‌ای.

نتایج این مطالعه نشان داد که امکان تخمین نسبتاً دقیق تبخیر-تعرق گیاه مرجع، خیار و گوجه‌فرنگی توسط چهار متغیر تشعشع، دما، رطوبت و کمبود فشار بخار روزانه داخل گلخانه وجود دارد. جهت تخمین تبخیر-تعرق مرجع با مدل GRNN، لحاظ تمام پارامترهای اندازه‌گیری شده نسبت به S_1 ، باعث کاهش خطا از $11/1$ به 9 درصد گردید. نتایج این مطالعه نشان داد که با توجه به متفاوت بودن شرایط داخل گلخانه نسبت به شرایط باز، ممکن است استفاده از مدل‌های آیرودینامیک و بیلان انرژی، نتایج متفاوتی نسبت به مقادیر واقعی داشته باشند؛ لذا استفاده از شبکه‌های عصبی مصنوعی ابزار قوی برای تخمین تبخیر-تعرق در گلخانه هست.

نتیجه‌گیری کلی

نتایج نشان داد که مدل GRNN قادر است با کمترین میزان خطا تبخیر-تعرق گیاه مرجع، خیار و گوجه‌فرنگی را در شرایط گلخانه تخمین بزند. خطای نسبی این شبکه تخمین تبخیر-تعرق گیاه مرجع، خیار و گوجه‌فرنگی به ترتیب برابر 9 ، 11 و $10/1$ درصد به دست آمد. عملکرد مدل MLP نیز به ویژه سناریوهای S_1 و S_5 در سطح مطلوبی ارزیابی گردید. اما شبکه‌های RBF علیرغم تخمین دقیق مقادیر تبخیر-تعرق گیاه مرجع، خیار و گوجه‌فرنگی در مرحله آموزش، در مرحله آزمون عملکرد ضعیف نسبت به دو شبکه MLP و GRNN داشت و قابلیت تعمیم این شبکه در قیاس با دو شبکه مذکور، ضعیف و خطای آن بیشتر از دو مدل دیگر بود.

منابع مورد استفاده

- امیری م، ج، عابدی کوپایی ج و اسلامیان س، س، ۱۳۹۰. ارزیابی استفاده از تشت‌های تبخیر در محیط گلخانه. مجله علوم و فنون کشت‌های گلخانه‌ای، جلد ۲، شماره ۵، صفحه‌های ۶۳ تا ۷۳.
- زارع ابیانه ح، بیات ورکشی م، معروفی ص و امیری چایجان ر، ۱۳۸۹. ارزیابی سیستم‌های هوشمند عصبی در کاهش پارامترهای تخمین تبخیر-تعرق گیاه مرجع. نشریه آب‌وخاک، جلد ۲۴، شماره ۲، صفحه‌های ۲۹۷ تا ۳۰۵.
- شایان‌نژاد م، ساداتی نژاد س ج و فهمی ه، ۱۳۸۶. تعیین تبخیر-تعرق بالقوه با استفاده از رگرسیون فازی. مجله تحقیقات منابع آب ایران، جلد ۳، شماره ۳، صفحه‌های ۹ تا ۱۹.
- صیادی ح، اولاد غفاری ا، فعالیان ا و صدرالدینی ع، ۱۳۸۸. مقایسه عملکرد شبکه‌های عصبی MLP و RBF در برآورد تبخیر-تعرق گیاه مرجع. مجله دانش آب‌وخاک، جلد ۱۹، شماره ۱، صفحه‌های ۱ تا ۱۲.
- عابدی کوپایی ج، اسلامیان س، س و زارعیان م، ج، ۱۳۹۰. اندازه‌گیری و مدل‌سازی نیاز آبی و ضریب گیاهی خیار، گوجه‌فرنگی و فلفل با استفاده از میکروولایسیمتر در گلخانه. مجله علوم و فنون کشت‌های گلخانه‌ای، جلد ۲، شماره ۷، صفحه‌های ۵۱ تا ۶۳.

- عصاری م، کوچکزاده م، شهابی فر م و بیات ک، ۱۳۸۸. تخمین تبخیر- تعرق گیاه مرجع درون گلخانه با استفاده از شبکه‌های عصبی مصنوعی، مجله پژوهش‌های حفاظت آب و خاک، جلد ۱۶، شماره ۱، صفحه‌های ۱۰۷ تا ۱۲۱.
- فتحعلیان ف، موزن‌زاده ر و نوری امام‌زاده‌یی م، ۱۳۸۸. ارزیابی و برآورد تبخیر - تعرق خیار گلخانه‌ای در مراحل مختلف رشد. نشریه آب و خاک، جلد ۲۳، شماره ۴، صفحه‌های ۱۶ تا ۲۷.
- فتحی پ و کوچکزاده م، ۱۳۸۳. تبخیر- تعرق خیار گلخانه‌ای با استفاده از شبکه‌های عصبی مصنوعی. مجله علوم آب و خاک، جلد ۱۸، شماره ۲، صفحه‌های ۲۰۸ تا ۲۱۷.
- کریمی نو، ناظمی اح، صدرالدینی سع ا، فرسادی‌زاده د، حسین‌زاده دلیر ع و دهقانی ف، ۱۳۸۶. نیاز آبی خیار در کشت گلخانه‌ای در شرایط اقلیمی یزد. پژوهش کشاورزی، جلد ۷، شماره ۴-الف، صفحه‌های ۱۵۱ تا ۱۶۰.
- Babstista JF, Bailey BJ and Meneses JF, 2005. Measuring and modeling transpiration versus evapotranspiration of a tomato crop grown on soil in a Mediterranean greenhouse. *Acta Horticulturae* 691: 313-319.
- Chauhan S and Shrivastava RK, 2008. Performance evaluation of reference evapotranspiration estimation using climate baseds method and artificial neural networks. *Water Resource Management* 23(5): 825-1023.
- Dawson CW, Mount NJ, Abrahart RJ and Shamseldin AY, 2012. Ideal point error for model assessment in data-driven river flow forecasting. *Hydrology and Earth System Sciences* 16: 3049-3060.
- Fazilah WF, 2009. Evapotranspiration models in greenhouse. M.Sc. thesis, Wageningen University, the Netherlands.
- Ghahreman N and Sameti M, 2014. Comparison of M5 model tree and artificial neural network for estimating potential evapotranspiration in semi-arid climates. *DESERT* 19(1): 75-81.
- Kisi O, 2007. Streamflow forecasting using different artificial neural network algorithms. *Journal of Hydrologic Engineering* 12 (5): 532-539.
- Kalra R, Deo MC, Kumar R and Agarwal KV, 2005. RBF network for spatial mapping of wave heights. *Marine Structures* 18: 289-300.
- Kumar M, Raghuvanshi NS, Singh R, Wallender WW and Pruitt WO, 2002. Estimating evapotranspiration using artificial neural network. *Journal of Irrigation and Drainage Engineering* 128(4): 224-233.
- Martinez PE, Abdol Fattah YMM, Maloupa E and Gerasopoulos D, 1995. Effect of substrate warming in soil less culture in Gerbera crop performance under seasonal variations. *Acta Horticulturae* 408: 31-40.
- Moghaddamnia A, Ghafari Gousheh M, Piri J, Amin S and Han D, 2009. Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources* 32(1): 89-97.
- Mujahed H, 2007. Estimation of crop water requirement for cucumber (*Cucumis sativus*) grown in green houses. M.Sc. thesis, College of Graduate Studies and Academic Research. Hebron University, Palestine.
- Villarreal FG, Kacira M, Fitz RE, Kubota C, Giacomelli GA, Linker R and Arbel A, 2012. Comparison of three evapotranspiration models for a greenhouse cooling strategy with natural ventilation and variable high pressure fogging. *Scientia Horticulturae* 134: 210-221.