

## پیش‌بینی متغیرهای داخلی یک گلخانه دوطرفه شیشه‌ای با ساختار ویژه با استفاده از مدل‌های شبکه عصبی (MLP و RBF)

مکیه حمدانی<sup>۱</sup>، مرتضی تاکی<sup>۲</sup>، مجید رهنما<sup>۳\*</sup>، عباس روحانی<sup>۳</sup>، مصطفی رحمتی جنیدآباد<sup>۴</sup>

تاریخ دریافت: ۱۳۹۷/۰۲/۰۷

تاریخ پذیرش: ۱۳۹۷/۰۶/۰۳

### چکیده

یکی از مهم‌ترین اقدامات به‌منظور ایجاد محیطی مناسب برای رشد بهینه گیاه گلخانه‌ای، کنترل دقیق متغیرهای داخلی گلخانه به‌منظور بهینه‌سازی میزان تبادلات انرژی بین گلخانه با محیط بیرون است. در این راستا یکی از ایده‌های جدید، هوشمندسازی گلخانه است. اولین قدم در این مسیر، پیش‌بینی تمامی متغیرهای تأثیرگذار یک گلخانه به حساب می‌آید. از این رو در این تحقیق از دو مدل شبکه عصبی (MLP-RBF) برای تخمین چهار متغیر تأثیرگذار (شامل دمای هوا، گیاه، سقف و رطوبت هوای داخل گلخانه) یک گلخانه دوطرفه شیشه‌ای با ساختار ویژه واقع در شهر ملائانی اهواز استفاده شد. بدین منظور از متغیرهای محیطی بیرونی شامل دما و رطوبت هوای بیرون و همچنین تابش روی سطح افق به‌عنوان فاکتورهای ورودی مدل‌ها، استفاده شد. داده‌برداری توسط حسگرهای مربوطه در گلخانه‌ای به مساحت (۱۲ مترمربع) و حجم هوای (۴۰ مترمکعب) انجام گرفت. نتایج نشان داد که مدل RBF از دقتی حدود ۵۰٪ بیش‌تر نسبت به مدل MLP برخوردار است. در این تحقیق قابلیت تعمیم‌پذیری هر دو مدل با ۸۰ و ۴۰ درصد از کل داده‌های آموزشی مورد بررسی قرار گرفت. نتایج به‌دست آمده نشان داد که مدل RBF قادر است با مجموعه داده‌های کم‌تر نسبت به مدل MLP، نتایج را بهتر و دقیق‌تر برآورد کند. دقت بالاتر و قابلیت کار با مجموعه داده‌های کم‌تر از مزایای شناخته شده مدل RBF در این تحقیق بود که می‌تواند در هوشمند کردن گلخانه‌های نسل جدید و کنترل آن‌ها مورد استفاده قرار گیرد.

واژه‌های کلیدی: شبکه عصبی، گلخانه دوطرفه، گلخانه‌های هوشمند، مدل‌سازی

### مقدمه

این راستا تحقیقات بسیار اندکی انجام گرفته است (Taki et al., 2018a). عامل دیگر که در اکثر تحقیقات مربوط به این حوزه کم‌تر به آن توجه می‌شود بحث مدیریت بهینه شرایط داخلی گلخانه است. در گلخانه‌های سنتی معمولاً از دماسنج و رطوبت‌سنج در وسط گلخانه به‌عنوان نماینده‌ای از کل حجم گلخانه استفاده می‌شود. این موضوع در گلخانه‌های پیشرفته از طریق جایگزینی حسگرها با انواع دماسنج‌ها و رطوبت‌سنج‌ها و همچنین افزایش تعداد آن‌ها تا حدی اصلاح شده است (Sethi and Dubey, 2008; Sethi, 2009). استفاده بیش‌تر از حسگرها سبب افزایش هزینه اولیه گلخانه و نهایتاً قیمت نهایی محصول برداشت شده می‌شود. در این راستا تحقیقات مختلفی از اوایل قرن بیستم به‌منظور هوشمند کردن گلخانه‌های کشاورزی و توجه بیش‌تر به مدیریت متغیرهای داخلی گلخانه (دما، رطوبت، شدت نور، CO<sub>2</sub> و غیره) انجام شده است که مبنای عمل‌گرا شدن تمامی این تحقیقات، مدل‌سازی اولیه شرایط گلخانه با توجه به متغیرهای خارجی از جمله دما، رطوبت، سرعت باد، میزان تابش و غیره است (Gupta et al., 2012; Van Straten et al., 2011; Van Ooteghem et al., 2007). مدل‌سازی‌های اولیه علاوه بر فراهم کردن شرایط بهتر مدیریتی در گلخانه، یکی از موارد اساسی به‌منظور استفاده از سایر تجهیزات پیشرفته و همچنین انرژی‌های تجدیدپذیر در گلخانه است. در این بین، از سال ۱۹۹۰ استفاده از

مصرف بی‌رویه انرژی در اکثر گلخانه‌های ایران، باعث افزایش قیمت تمام‌شده محصول، آلودگی محیط‌زیست و هدررفت منابع با ارزش فسیلی طی دهه‌های گذشته شده است. از طرفی، توسعه چشم‌گیر انواع گلخانه‌ها در کشور در حالی به‌وقوع پیوسته که به‌علت ضعف در فناوری‌های موجود، مصرف انرژی به‌ازای تولید هر واحد محصول، تا چندین برابر بیش‌تر از میانگین‌های جهانی است (Vadiei and Martin, 2013; Taki et al., 2016). یکی از دلایل اصلی بالا بودن مصرف انرژی در گلخانه‌های ایران، پوشش و اسکلت نامناسب و غیرعلمی در انواع گلخانه‌های مرسوم است. ابتدایی‌ترین اصول مهندسی در ساخت گلخانه‌های کشاورزی معمولاً مبتنی بر مدل‌سازی اولیه فرآیند انتقال حرارت و جرم می‌باشد که متأسفانه در

۱- دانشجوی کارشناسی ارشد، گروه مهندسی ماشین‌های کشاورزی و مکانیزاسیون، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان

۲- استادیار گروه مهندسی ماشین‌های کشاورزی و مکانیزاسیون، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان

۳- دانشیار گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه فردوسی مشهد

۴- استادیار گروه باغبانی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان

\*- نویسنده مسئول: (Email: rahnamam2002@asnruk.ac.ir)

DOI: 10.22067/jam.v10i2.72346

قرار گرفته است. در این تحقیق همراه با روش‌های مرسوم از نسبت‌های مختلف داده‌های آموزشی به‌منظور یافتن بهینه مقدار داده‌های آموزش مدل و همچنین از روش K-fold به منظور افزایش قابلیت اطمینان به نتایج شبکه عصبی نیز استفاده می‌شود که استفاده از این روش در این زمینه تحقیقاتی تقریباً نادر است. مقایسه بین این دو نوع مدل می‌تواند به درستی میزان خطا در هر دو نوع مدل را مشخص کرده و در آینده برای کنترل هوشمند گلخانه‌های کشاورزی در ایران با توجه به شرایط محیطی مورد استفاده قرار گیرد.

## مواد و روش‌ها

### ساختار گلخانه و محل اجرای تحقیق

این پژوهش با هدف مطالعه و بررسی روشی ارزان‌قیمت و مناسب برای تخمین متغیرهای داخلی یک گلخانه شیشه‌ای دوطرفه و هوشمندسازی آن با توجه به شرایط آب و هوایی در دانشگاه علوم کشاورزی و منابع طبیعی خوزستان واقع در شهرستان ملاتانی در ۳۵ کیلومتری شمال اهواز انجام شد. گلخانه مورد بررسی از نوع دوطرفه شیشه‌ای و جهت قرارگیری آن شرقی-غربی است. این گلخانه دارای ساختاری ویژه است که به دلیل قرارگیری در عمق ۱ متری سطح زمین در مناطق بسیار گرم یا بسیار سرد مورد استفاده قرار می‌گیرد. گلخانه مورد نظر دارای مساحت ۱۲ مترمربع و حجم هوای ۴۰ مترمکعب است. بدین منظور، داده‌های دما و رطوبت از داخل و بیرون گلخانه مورد نظر توسط حسگرهای دما (مدل SHT 11 ساخت شرکت CMOS آمریکا با دقت  $\pm 0.4$  درجه سانتی‌گراد و  $\pm 3$  درصد برای دما و رطوبت) برداشت شد. داده‌های تابش در داخل گلخانه، در یک سطح تراز شده زمین، توسط تابش‌سنج مدل TES132 برداشت شد. این نوع تابش‌سنج قادر است داده‌های تابش در محدوده طول موج ۴۰۰ تا ۱۱۰۰ نانومتر را با دقتی در حدود ۵٪ برداشت کند. داده‌های سرعت باد توسط بادسنج مدل DT186 با قابلیت ذخیره ۳۲۰۰۰ داده در بازه ۱/۱ تا ۲۰ متربرثانیه، برداشت شد. شکل ۱ نمای از گلخانه مربوطه همراه با انواع حسگرهای مورد استفاده را نشان می‌دهد. شکل ۲ محل نصب حسگرهای فوق را در نقاط مختلف گلخانه شیشه‌ای مورد نظر نشان می‌دهد.

### شبکه‌های عصبی مصنوعی (MLP و RBF)

شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) در این تحقیق از لایه‌ی ورودی (متغیرهای محیطی خارج از گلخانه شامل دما و رطوبت هوا و همچنین تابش)، لایه مخفی و لایه خروجی (شامل چهار متغیر داخلی گلخانه) تشکیل شده است. شبکه MLP با دریافت بردار ورودی، بردار خروجی تولید خواهد کرد. هدف، اتخاذ

شبکه‌های عصبی مصنوعی در پیش‌بینی‌های داخلی گلخانه‌ها رونق گرفت و مطالعات متنوعی در این زمینه انجام شد. مطالعات اولیه به‌منظور معرفی این ابزار و روش کارکرد آن بود ولی به مرور تحقیقات متنوعی شامل کنترل شرایط محیطی داخل گلخانه (Hill, 2006)، مدل‌سازی فیزیکی گلخانه (Bot, 1983) و تخمین یا پیش‌بینی برخی از پارامترهای داخلی گلخانه انجام گرفت (Boaventura et al., 2000; Coelho et al., 2002; Manuel et al., 2005; Linker and Seginer, 2004; Taki et al., 2018b). در تحقیقی از شبکه‌های عصبی مصنوعی به‌منظور ابزاری برای جایگزین کردن انواع سنسورها در گلخانه استفاده شد (Ferreira et al., 2002). در این مطالعه به‌منظور تخمین دمای هوای داخل گلخانه از پارامترهایی همچون میزان تابش ورودی گلخانه، دمای هوای بیرون و همچنین میزان رطوبت هوای داخل گلخانه استفاده شد. نتایج نشان داد که استفاده از این ابزار به‌درستی قادر است میزان تغییرات دمای هوای داخل گلخانه‌ای با کشت هیدروپونیک را تخمین بزند ولی به‌منظور افزایش میزان دقت و همچنین جلوگیری از ریسک زیاد، وجود سنسورهایی با دقت متوسط و به تعداد کم در گلخانه توصیه شد. در تحقیقی به بررسی و مقایسه بین نتایج مدل‌های حرارتی، شبکه عصبی مصنوعی (MLP) و رگرسیون چندگانه به منظور پیش‌بینی دمای هوا، دمای پوشش گلخانه و میزان انرژی تلف شده در گلخانه‌ای نیمه‌خورشیدی، پرداخته شد (Taki et al., 2016). نتایج این تحقیق نشان داد که مدل شبکه عصبی قادر است مقادیر دمای هوا و پوشش گلخانه را با دقتی بالاتر از دو مدل دیگر تخمین بزند. در تحقیق دیگری، (Dariouchy et al., 2009)، از مدل شبکه عصبی و مدل‌های رگرسیونی برای پیش‌بینی درصد رطوبت و دمای هوای داخلی گلخانه‌ای در مراکش استفاده شد. در این تحقیق، رطوبت نسبی هوای بیرون گلخانه، شدت تابش خورشید روی سطح افق، جهت و سرعت باد و همچنین دمای هوای بیرون گلخانه به‌عنوان متغیرهای ورودی و دما و درصد رطوبت داخلی گلخانه به‌عنوان خروجی مدل در نظر گرفته شد. نتایج نشان داد که شبکه عصبی قادر است نتایج بهتری نسبت به انواع مدل‌های کلاسیک رگرسیونی نشان دهد. میزان خطا در پیش‌بینی دما و رطوبت نسبی داخل گلخانه در این تحقیق ۴/۲۳ و ۳/۸۵ درصد گزارش شد. نتایج سایر تحقیقات در این زمینه نیز برتری مدل‌های شبکه عصبی را تأیید می‌کنند (Taki et al., 2017; Taki et al., 2018b; Ben Ali et al., 2016; Feng et al., 2016; Lachouri et al., 2016).

با توجه به نتایج تحقیقات فوق، هدف از این مطالعه، مقایسه بین دو مدل شبکه عصبی (MLP-RBF) به‌منظور تخمین پارامترهای موثر یک گلخانه دوطرفه شیشه‌ای واقع در شهرستان اهواز است. ساختار این نوع گلخانه به دلیل واقع شدن در محیطی گرم و مرطوب به گونه‌ای است که در منابع داخلی و خارجی به‌ندرت مورد بررسی

پیش‌بینی است (Rohani *et al.*, 2011).

پارامترهای صحیح شبکه به‌منظور دستیابی به کم‌ترین خطای




گلخانه شیشه‌ای دوطرفه  
Uneven glass greenhouse



بادسنج  
Anemometer



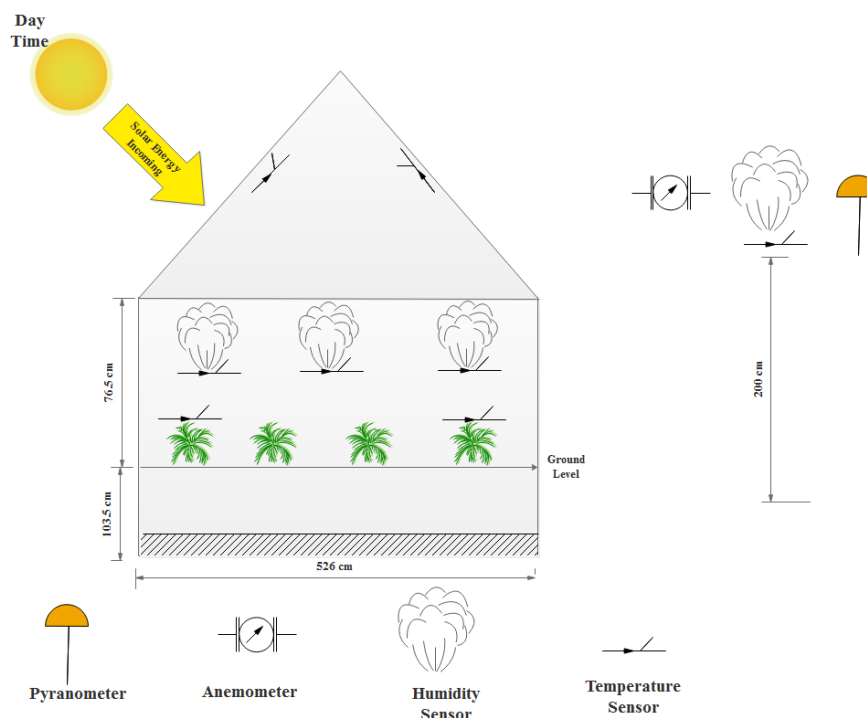
تابش‌سنج  
Solar meter



سنسور SHT11  
SHT11 Sensor

شکل ۱- نمایشی از گلخانه مورد نظر همراه با حسگرهای مورد استفاده

Fig.1. Case study with all the used sensors



شکل ۲- محل نصب حسگرهای دما، رطوبت، تابش و باد در داخل و خارج گلخانه

Fig.2. The location of temperature, humidity, solar and wind sensors inside and outside of greenhouse

که در آن،  $\sigma$  پارامتر توزیع<sup>۲</sup> است.

در این تحقیق به منظور افزایش اعتماد به خروجی شبکه عصبی از یک روش جدید و ابتکاری به نام اعتبارسنجی دسته‌ای<sup>۳</sup> استفاده شد (شکل ۳). در این روش، داده‌های بخش اعتبارسنجی بسته به نوع و تعداد آن‌ها به  $K$  دسته مختلف تقسیم می‌شوند و با هر الگوریتم، مورد بررسی قرار می‌گیرند. در واقع، در این نوع اعتبارسنجی، داده‌ها به  $K$  زیرمجموعه افراز می‌شوند. از این  $K$  زیرمجموعه، هر بار یکی برای اعتبارسنجی و  $K-1$  تای دیگر برای آموزش به کار می‌روند. این روال،  $K$  بار تکرار می‌شود و همه داده‌ها دقیقاً یک بار برای آموزش و یک بار برای اعتبارسنجی به کار می‌روند. در نهایت میانگین نتیجه این  $K$  بار اعتبارسنجی به عنوان یک تخمین نهایی برگزیده می‌شود (Rodriguez et al., 2010). مزیت استفاده از زیرمجموعه‌سازی تصادفی داده‌ها در این روش، تأثیر نحوه توزیع داده‌ها بر فرآیند مدل‌سازی است و باعث می‌شود که شبکه عصبی در حالت عادی به عنوان یک روش کاربردی با نتایج قابل قبول مورد استفاده قرار گیرد.

به منظور ارزیابی قابلیت مدل‌های مورد بررسی (شبکه عصبی) در پیش‌بینی متغیرهای داخلی گلخانه، از معیارهای درصد میانگین مطلق خطا<sup>۴</sup> (MAPE)، ریشه متوسط مربعات خطا<sup>۵</sup> (RMSE) و ضریب تبیین ( $R^2$ ) بین مقادیر پیش‌بینی شده توسط مدل‌ها و مقادیر واقعی آن‌ها استفاده شد (Taki et al., 2018a). از بین مدل‌های برآزش شده، مدلی بهترین است که دارای کمترین مقدار RMSE و MAPE و بیشترین مقدار  $R^2$  باشد. به منظور تحلیل روش شبکه عصبی در این تحقیق، از نرم‌افزار MATLAB نسخه ۲۰۱۷ استفاده شد.

## نتایج و بحث

### انتخاب بهترین الگوریتم آموزش، تعداد نرون و فاکتور

#### پخش در دو مدل MLP و RBF

در این تحقیق، به دلیل سرعت کم باد و صفر بودن آن در اکثر موارد و در نتیجه اثر غیرقابل محسوس انتقال حرارت همرفتی آن بر میزان انتقال انرژی از جداره گلخانه، در آنالیز نهایی و مدل‌سازی، از اثر این فاکتور بر تغییرات متغیرهای داخلی گلخانه، چشم‌پوشی شد. داده‌های برداشت شده به دلیل تعداد زیاد، به صورت میانگین دقیقه‌ای برای هر مدل، مورد بررسی قرار گرفتند. به منظور تخمین دمای هوای داخل گلخانه ( $T_a$ )، دمای سقف گلخانه ( $T_H$ )، دمای گیاه ( $T_p$ ) و رطوبت هوای داخل گلخانه ( $Rh_a$ ) از دو مدل شبکه عصبی (MLP- RBF) استفاده شد. نتایج مقایسه بین دو الگوریتم آموزش Trainlm

قبل از به کارگیری داده‌های خام اولیه، باید عمل نرمال‌سازی داده‌ها انجام شود تا همگرایی شبکه تضمین شود. زمانی که از تابع فعال سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها  $[-0.9, 0.9]$  می‌باشد (Rohani et al., 2018). در این مطالعه از دو الگوریتم آموزش بایاس پس‌انتشار خطا (Bayesian regulation) و لوبرگ ماکوارت پس‌انتشار خطا (backpropagation or Trainbr) و لوبرگ ماکوارت پس‌انتشار خطا (Levenberg-Marquardt or Trainlm backpropagation) استفاده شد. بر اساس یک قانون جهانی، معمولاً بهترین شبکه‌ها با تعداد یک لایه پنهان مشخص می‌شوند (Taki et al., 2012). به همین دلیل در این تحقیق تمامی داده‌ها با شبکه‌های تک لایه مورد آزمایش قرار گرفتند. تعداد نرون‌های هر شبکه تا زمانی که نتایج رو به بهبودی میل می‌کند افزایش داده شد و پس از افزایش خطا، ثابت در نظر گرفته شد.

در کم‌تر پژوهشی از شبکه عصبی<sup>۱</sup> RBF در تخمین متغیرهای داخلی گلخانه‌های کشاورزی استفاده شده است. RBF مانند سایر شبکه‌های عصبی قادر به یادگیری رابطه بین متغیر وابسته و متغیرهای مستقل از روی مثال‌های مختلف از مجموعه داده‌های موجود می‌باشد. RBF تنها از یک لایه مخفی با تعدادی از نرون تشکیل شده است. در لایه ورودی، متغیرهای مستقل به شبکه داده می‌شود. در لایه مخفی، نرون‌ها، محاسباتی را روی مجموعه متغیرهای ورودی به منظور رسیدن به خروجی مطلوب انجام می‌دهند (شکل ۲).

در صورتی که شبکه RBF از تعداد کافی نرون برخوردار باشد، قادر به تخمین هر تابع پیچیده با هر دقت مورد نیاز است. RBF یک نوع شبکه عصبی با معلم است. هر نرون در لایه مخفی بر اساس یک تابع فعال‌ساز غیرخطی ( $\phi$ ) عمل می‌کند. وجود عامل بایاس به همگرا شدن شبکه عصبی RBF در طول مرحله آموزش و رسیدن به کمینه عمومی کمک می‌کند. خروجی شبکه عصبی RBF برای هر بردار ورودی  $x$  مطابق رابطه (۱) قابل محاسبه است (Rohani et al., 2018):

$$Y = W^T \Phi = \sum_{j=1}^{L_2} w_{ij} \phi(\|x - c_i\|) \quad (1)$$

که در آن،  $w_{ij}$  بردار وزن اتصالات بین لایه مخفی و خروجی،  $L_2$  تعداد نرون‌ها در لایه مخفی،  $c_i$  مرکز نرون‌ها در لایه مخفی و  $\phi$  تابع گوسین می‌باشد. مقدار ( $\phi$ ) نیز از رابطه (۲) قابل محاسبه است (Rohani et al., 2018):

$$\phi_i(x) = \exp\left(-\frac{\|x - c_i\|^2}{\sigma_i^2}\right) \quad (2)$$

2- Spread parameter

3- K-fold cross validation


4- Mean Absolute Percentage Error

5- Root Mean Squared Error

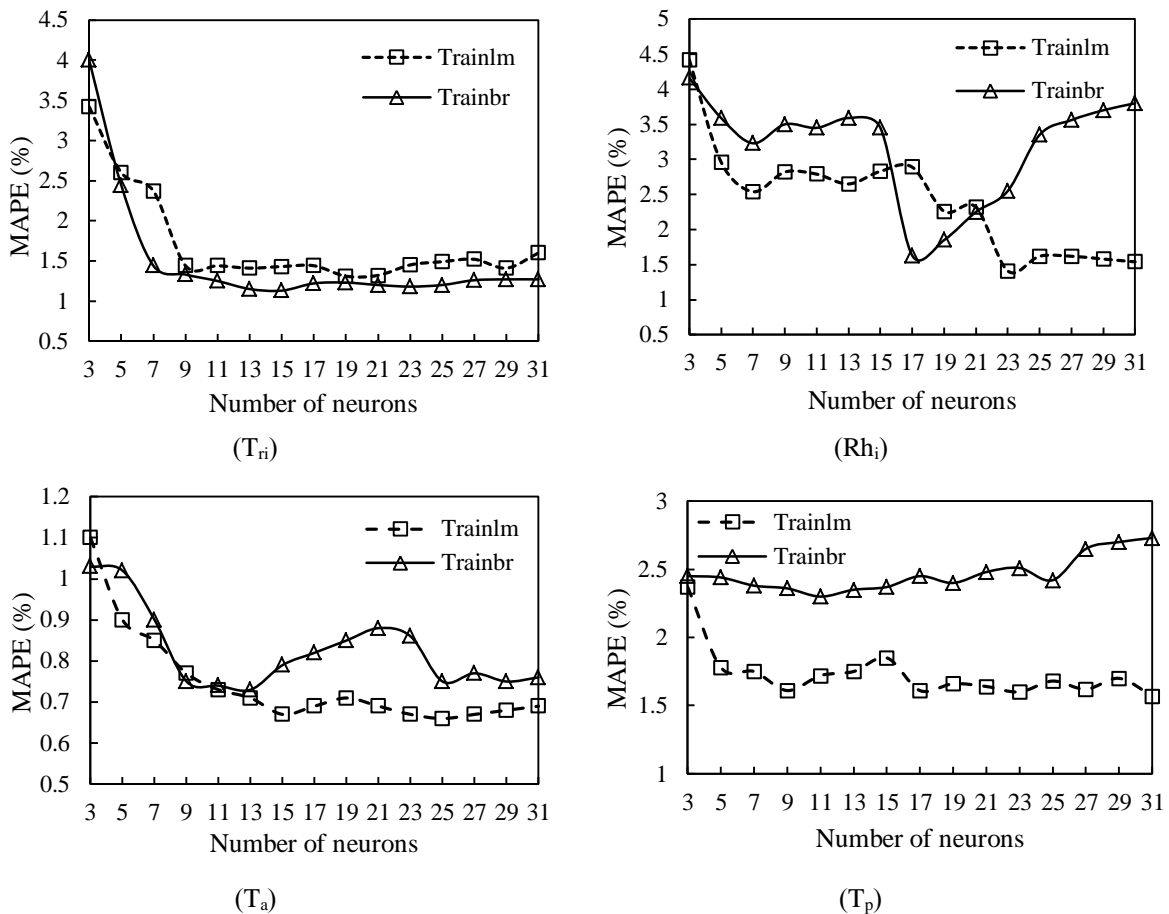
1- Radial Bias Function

شیشه‌ای دوطرفه با مدل MLP در شکل ۴ ارائه شده است.

و Trainbr با توجه به تعداد نرون‌های مختلف در لایه پنهان بر اساس آماره MAPE برای تخمین ۴ متغیر مورد بررسی در گلخانه



شکل ۳- روش اعتبارسنجی دسته‌ای (K-fold)  
Fig.3. K-fold crosses validation method




شکل ۴- نتایج حاصل از تخمین ۴ متغیر داخلی گلخانه شیشه‌ای با مدل MLP و دو نوع الگوریتم آموزش Trainbr و Trainlm  
Fig.4. The results of 4 inside variables estimation by MLP model with two different training algorithms (Trainlm and Trainbr)

هوای گلخانه ( $T_a$  و  $T_{ri}$ ) خطایی کم‌تر از الگوریتم Trainlm دارد (به‌ترتیب با مقدار MAPE معادل ۰/۶۷ و ۰/۶۰ درصد در مقابل ۰/۷۳ و ۰/۶۳ درصد). در مقابل، الگوریتم Trainlm در تخمین رطوبت هوای داخل گلخانه و دمای گیاه ( $T_p$  و  $Rh_i$ ) خطایی کم‌تر از Trainbr از خود نشان داده است (به‌ترتیب با مقدار MAPE معادل ۰/۶۵ و ۱/۳۹ درصد در مقابل ۰/۷۱ و ۱/۴۶ درصد). در تمامی مدل‌های بالا، بهترین تعداد نرون در لایه پنهان معادل ۱۳ به‌دست آمده است. یکی از فاکتورهایی که در شبکه RBF بسیار موثر و مورد توجه است، پارامتر پخش (Spread parameter) است. در این تحقیق میزان این پارامتر برای تخمین ۴ متغیر مورد بررسی با توجه به دو نوع الگوریتم (Trainbr و Trainlm)، مشخص شد. شکل ۶ میزان این پارامتر را برای تمامی متغیرها و الگوریتم‌های مورد بررسی نشان می‌دهد.

شکل ۴ نشان می‌دهد که الگوریتم Trainbr فقط در تخمین دمای سقف گلخانه، دقتی بیش‌تر از الگوریتم Trainlm داشته است (۱/۱۳ در مقابل ۱/۳۱ درصد). در بقیه موارد، الگوریتم Trainlm با دقت بیش‌تر می‌تواند مورد استفاده قرار گیرد. با توجه به شکل ۴، بهترین توپولوژی مدل MLP در تخمین دمای سقف، رطوبت هوای داخل، دمای هوای داخل و دمای گیاه عبارتند از: (۳-۱۵-۱)، (۳-۲۳-۱)، (۳-۱۵-۱) و (۳-۲۳-۱). یعنی برای تخمین دمای سقف و دمای هوای داخل گلخانه، ۲۳ نرون و برای تخمین رطوبت هوای داخل گلخانه و دمای گیاه به ۱۵ نرون در لایه مخفی شبکه MLP نیاز است.


شکل ۵ به بررسی بهترین الگوریتم آموزش در مدل RBF و همچنین تعیین بهترین تعداد نرون در لایه پنهان می‌پردازد. نتایج شکل ۵ نشان می‌دهد که الگوریتم Trainbr در تخمین دمای سقف و



شکل ۵- نتایج حاصل از تخمین ۴ متغیر داخلی گلخانه شیشه‌ای با مدل RBF و دو نوع الگوریتم آموزش Trainbr و Trainlm  
**Fig.5.** The results of 4 inside variables estimation by RBF model with two different training algorithms (Trainlm and Trainbr)

تخمین بقیه متغیرها ( $T_a$  و  $Rh_i$ ،  $T_{ri}$ ) این فاکتور برای هر دو نوع الگوریتم آموزش، تقریباً یکسان است (به‌ترتیب ۰/۲۵، ۰/۲۵ و ۰/۷۵).

همان‌طور که نتایج شکل ۶ نشان می‌دهد، نتایج مقایسه فاکتور پخش در دو الگوریتم Trainbr و Trainlm فقط برای تخمین دمای گیاه ( $T_p$ ) با هم متفاوت است (۱/۰۴ در مقابل ۱/۳۲) ولی برای



شکل ۶- تغییرات میزان پارامتر پخش (Spread parameter) در مدل RBF با توجه به نوع الگوریتم آموزش (Trainbr و Trainlm)  
**Fig.6.** Changes in spread parameter in RBF model based on training algorithm (Trainlm and Trainbr)

زیرزمینی<sup>۲</sup> پرداخته شد (Shukla *et al.*, 2006). نتایج نشان داد که مدل ریاضی قادر به پیش‌بینی دمای داخل گلخانه با دقتی بسیار کم‌تر از نتایج شبکه عصبی است (MAPE=۱۰/۲٪ و R=۰/۸۱). در تحقیق دیگری از مدل‌سازی انتقال حرارت و جرم برای تعیین میزان تلفات حرارتی و انتقال انرژی بین اجزای مختلف یک گلخانه مرسوم در کشور هند استفاده شد (Singh and Tiwari, 2010). نتایج نشان داد مدل ریاضی استفاده شده قادر است دمای داخل گلخانه را با دقت قابل‌قبولی تخمین بزند (MAPE=۱۱/۳۲٪ و RMSE=۶/۰۶°C). توجه به این نتایج لزوم استفاده بیشتر از ابزار شبکه عصبی به جای مدل‌های کلاسیک ریاضی در معادلات گلخانه‌ای را نشان می‌دهد. در روشی ترکیبی می‌توان ابتدا برای تخمین پارامترهای داخلی گلخانه از شبکه عصبی مصنوعی استفاده کرد و سپس نتایج به‌دست آمده را در معادلات ریاضی قرار داد و میزان انتقال حرارت بین اجزای گلخانه و همچنین دریافت انرژی و

### بهترین برازش داده‌های پیش‌بینی شده توسط دو مدل MLP و RBF با مجموعه داده‌های متفاوت

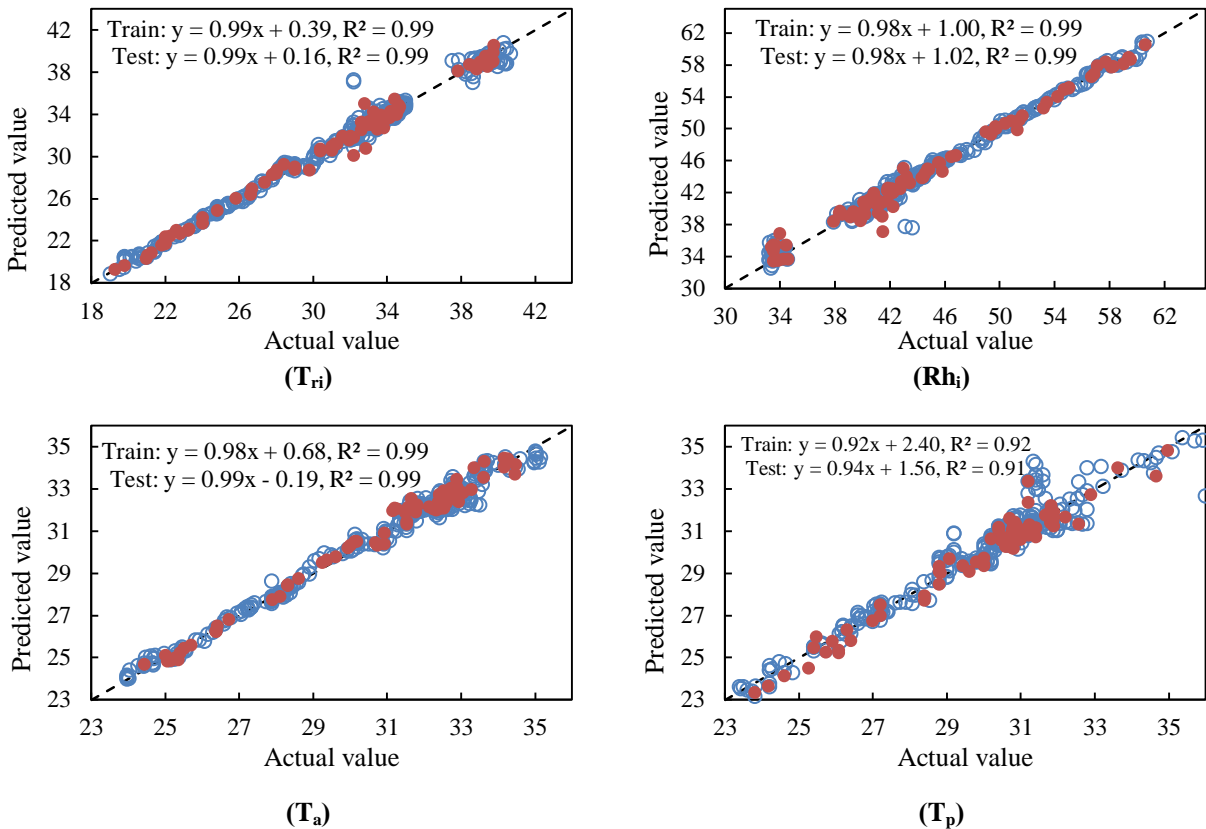
پس از تعیین بهترین الگوریتم آموزش و تعداد نرون برای هر دو مدل MLP و RBF، امکان وجود بهترین برازش ممکن، برای تخمین چهار متغیر داخلی گلخانه شیشه‌ای، مورد بررسی قرار گرفت. شکل‌های ۷ و ۸ نتیجه این برازش‌ها را نشان می‌دهند. همان‌طور که نتایج این شکل‌ها نشان می‌دهند، هر دو مدل MLP و RBF توانسته‌اند با دقت نسبتاً زیادی متغیرهای داخلی گلخانه را به‌درستی تخمین بزنند. با مقایسه بین نتایج به‌دست آمده از شکل‌های ۷ و ۸ با تحقیقات صورت گرفته در زمینه مدل‌سازی و تخمین دما در نقاط مختلف گلخانه توسط روابط ریاضی انتقال حرارت و جرم، می‌توان دریافت که کارایی شبکه عصبی در پیش‌بینی، بسیار بهتر، با دقت بیشتر و خطای کم‌تر است. مثلاً در تحقیقی به بررسی مدل‌سازی انتقال حرارت در گلخانه‌ای مجهز به صفحه حرارتی<sup>۱</sup> و آبخوان

2- Underground aquifer

1- Thermal screen

نسل آینده حتماً از ترکیب روش‌های مختلف شبکه عصبی و کلاسیک به‌منظور تخمین شرایط داخلی خود و فراهم کردن شرایط مطلوب گیاه برای رشد و نمو استفاده خواهند کرد (Taki *et al.*, 2018b).

تلفات کلی گلخانه را به‌دست آورد. لزوم آمادگی یک گلخانه هوشمند نسبت به تغییرات محیطی پیش‌روی می‌تواند بهترین دلیل برای توسعه مدل‌های هوش مصنوعی برای تخمین شرایط داخلی گلخانه‌ها با توجه به تغییرات محیطی پیرامون خود باشد. گلخانه‌های هوشمند



شکل ۷- مقایسه بین مقادیر واقعی و پیش‌بینی شده ۴ متغیر داخلی گلخانه توسط مدل MLP

Fig.7. Comparison between actual and predicted values of 4 inside variables in the greenhouse by MLP model

دمای هوای داخل گلخانه، دمای داخلی سقف گلخانه و گیاه با توجه به نتیجه نهایی آماره MAPE و RMSE قابل مشاهده است. این ادعا فقط برای پیش‌بینی رطوبت هوای داخل گلخانه صادق نیست. در مورد این متغیر، هنگامی که از داده‌های کم‌تری برای آموزش شبکه استفاده می‌شود، نتیجه نهایی مدل‌سازی دقت بیشتری را نشان می‌دهد. آماره MAPE در این حالت نسبت به حالت ۸۰٪ داده‌ها، ۰/۳ درصد کمتر است. دلیل وجود این حالت می‌تواند نوسانات رطوبتی زیاد ناشی از فرار هوای داخل گلخانه و یا باز و بسته شدن درب ورودی و در مواردی آبیاری گیاهان داخل گلخانه باشد. در این حالت داده‌های رطوبت با نوسانات زیادی روبه‌رو می‌شوند و در نهایت دقت نهایی مدل‌سازی با داده‌های بیشتر، کمتر خواهد شد.

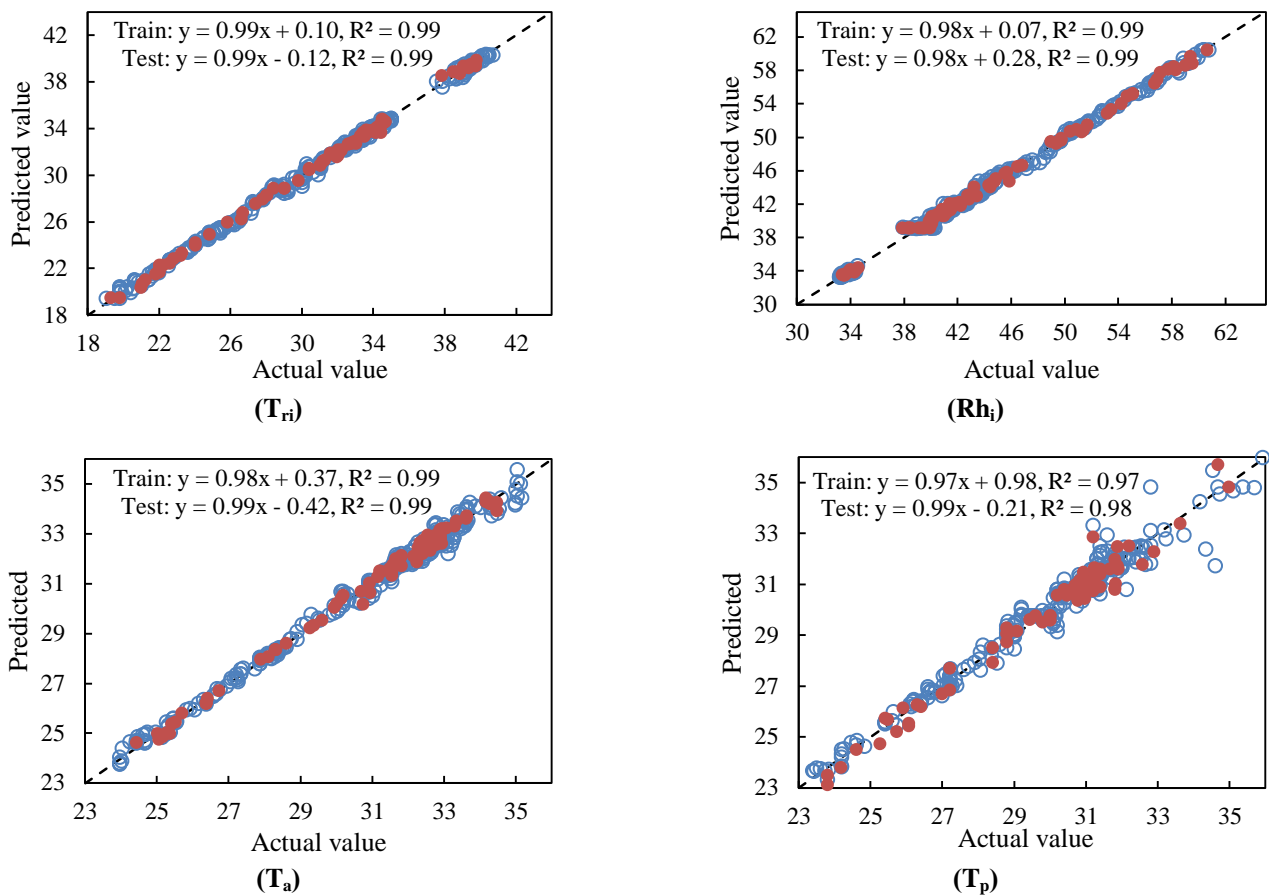
جدول ۱ نشان می‌دهد که مدل RBF با الگوریتم آموزشی Trainlm در تمامی حالات مختلف مجموعه داده، نتایج بهتری

به‌منظور بررسی قابلیت کارکرد شبکه‌های MLP و RBF مورد نظر با مجموعه داده‌های متفاوت و همچنین انتخاب بهترین مدل برای پیش‌بینی چهار متغیر داخلی گلخانه در این تحقیق، بررسی این دو نوع مدل با دو ترکیب متفاوت از مجموعه‌ی داده‌ها انجام گرفت. بدین منظور، دو مدل فوق با الگوریتم‌های نهایی موجود، با ۴۰ و ۸۰٪ از کل مجموعه‌ی داده‌ها مورد آموزش قرار گرفتند. نتایج این آزمون، در جدول ۱ ارائه شده است. نتایج این جدول نشان می‌دهد که در اکثر موارد برای هر دو مدل MLP و RBF، الگوریتم آموزشی Trainlm نتایجی با دقت بیشتر ارائه کرده است. نتایج این جدول نشان می‌دهد که در مدل MLP، هنگامی که از مجموعه داده‌های بیشتر (یعنی ۸۰٪ داده‌ها) برای آموزش شبکه استفاده شود، نتیجه نهایی مدل و دقت نهایی بیشتر از زمانی است که از داده‌های کم‌تر (یعنی ۴۰٪ داده‌ها) برای آموزش شبکه استفاده شود. این حالت برای پیش‌بینی



مدل RBF نسبت به MLP است چون در برخی موارد به دلیل اشتباهات انسانی یا عدم وجود وسایل دقیق اندازه‌گیری، امکان برداشت داده‌های زیاد برای مدل‌سازی شبکه وجود ندارد و لزوم استفاده از داده‌های کم‌تر در این موارد می‌تواند به انتخاب مدل RBF نسبت به MLP منجر شود.

نسبت به الگوریتم آموزشی Trainbr کسب می‌کند. نتایج این جدول نشان می‌دهد که مدل RBF حساسیت زیادی نسبت به اندازه مجموعه داده‌های آموزشی ندارد و نتایج نهایی مدل‌سازی در حالت ۸۰٪ و ۴۰٪ مجموعه داده‌های آموزشی، اختلاف نسبتاً اندکی با هم دارند ولی در کل هرچه‌قدر میزان آموزش شبکه با داده‌های بیشتری باشد، نتایج بهتری را از خود نشان می‌دهد. این حالت یکی از مزایای



شکل ۸- مقایسه بین مقادیر واقعی و پیش‌بینی شده ۴ متغیر داخلی گلخانه توسط مدل RBF

Fig.8. Comparison between actual and predicted values of 4 inside variables in the greenhouse by RBF model

استفاده از این مدل با داده‌های نه چندان زیاد، دو دلیل بزرگ برای استفاده از این مدل در هوشمند کردن گلخانه‌های نسل جدید محسوب می‌شود. در تحقیقی از مدل شبکه عصبی MLP و همچنین مدل رگرسیون چندگانه به‌منظور تخمین دما و رطوبت نسبی هوای داخلی گلخانه‌ای مرسوم در کشور مراکش استفاده شد. نتایج نشان داد شبکه عصبی هم در فاز آموزش و هم آزمایش نتایج بهتری نسبت به مدل رگرسیونی دارد.

### انتخاب بهترین مدل و آنالیز حساسیت دو مدل MLP و RBF نسبت به داده‌های ورودی

در این قسمت با توجه به اطلاعات کلی مرحله قبل و بر اساس نتایج جدول ۲ مدل RBF با دقت بیش‌تری به‌عنوان بهترین مدل برای تخمین تمامی متغیرهای داخلی گلخانه شیشه‌ای مورد بررسی انتخاب می‌شود. نتایج این جدول نشان می‌دهد که در اکثر موارد دقت مدل RBF دو برابر مدل MLP است (پارامتر MAPE مدل RBF تقریباً ۲ برابر مدل MLP است). دقت بیش‌تر مدل RBF و امکان

جدول ۱- نتایج استفاده از دو مجموعه داده با اندازه متفاوت بر میزان دقت دو مدل MLP و RBF

Table 1- The results of MLP and RBF model with two different data set for training and two training algorithms

اندازه داده (%) Size of data (%)	متغیر Variable	مدل Model*	آموزش Train		آزمایش Test		مجموع Total		
			RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	
80	T <sub>ri</sub>	MLP1	<b>0.83±0.25</b>	<b>1.62±0.46</b>	<b>0.88±0.30</b>	<b>1.73±0.48</b>	<b>0.85±0.24</b>	<b>1.65±0.45</b>	
		MLP2	1.42±0.44	2.89±0.93	1.49±0.40	2.96±0.87	1.44±0.42	2.91±0.92	
	Rh <sub>i</sub>	MLP1	<b>1.00±0.34</b>	<b>1.59±0.60</b>	<b>1.11±0.38</b>	<b>1.75±0.64</b>	<b>1.04±0.31</b>	<b>1.62±0.60</b>	
		MLP2	1.90±0.51	3.32±0.99	1.93±0.58	3.38±1.06	1.91±0.52	3.33±1.00	
	T <sub>a</sub>	MLP1	<b>0.31±0.04</b>	<b>0.74±0.09</b>	<b>0.35±0.05</b>	<b>0.83±0.11</b>	<b>0.32±0.03</b>	<b>0.76±0.75</b>	
		MLP2	0.37±0.08	0.92±0.21	0.39±0.08	0.94±0.19	0.38±0.07	0.92±0.20	
	T <sub>p</sub>	MLP1	<b>0.87±0.05</b>	<b>1.61±0.05</b>	<b>0.96±0.13</b>	<b>1.80±0.19</b>	<b>0.89±0.04</b>	<b>1.65±0.15</b>	
		MLP2	1.07±0.07	2.35±0.20	1.06±0.15	2.35±0.23	1.07±0.05	2.35±0.19	
	40	T <sub>ri</sub>	MLP1	0.76±0.39	1.54±0.85	1.05±0.31	2.03±0.76	0.95±0.33	1.83±0.78
			MLP2	<b>0.79±0.29</b>	<b>1.60±0.65</b>	<b>1.04±0.25</b>	<b>1.97±0.62</b>	<b>0.95±0.24</b>	<b>1.83±0.62</b>
Rh <sub>i</sub>		MLP1	<b>0.77±0.22</b>	<b>1.23±0.30</b>	<b>1.21±0.16</b>	<b>1.81±0.24</b>	<b>1.06±0.14</b>	<b>1.57±0.24</b>	
		MLP2	0.98±0.27	1.55±0.42	1.36±0.23	1.98±0.37	1.81±0.37	1.23±0.20	
T <sub>a</sub>		MLP1	<b>0.29±0.03</b>	<b>0.69±0.07</b>	<b>0.38±0.05</b>	<b>0.87±0.08</b>	<b>0.35±0.03</b>	<b>0.79±0.06</b>	
		MLP2	0.35±0.05	0.85±0.13	0.39±0.04	0.95±0.11	0.37±0.04	0.92±0.12	
T <sub>p</sub>		MLP1	<b>0.89±0.09</b>	<b>1.71±0.23</b>	<b>1.03±0.14</b>	<b>2.07±0.21</b>	<b>0.98±0.09</b>	<b>1.92±0.18</b>	
		MLP2	1.03±0.12	2.19±0.33	1.05±0.07	2.32±0.87	1.05±0.06	2.27±0.25	
80		T <sub>ri</sub>	RBF1	<b>0.26±0.01</b>	<b>0.66±0.03</b>	<b>0.26±0.03</b>	<b>0.64±0.06</b>	<b>0.26±0.01</b>	<b>0.66±0.03</b>
			RBF2	0.26±0.01	0.67±0.03	0.26±0.02	0.68±0.06	0.26±0.01	0.68±0.03
	Rh <sub>i</sub>	RBF1	<b>0.38±0.01</b>	<b>0.64±0.03</b>	<b>0.38±0.02</b>	<b>0.65±0.03</b>	<b>0.38±0.01</b>	<b>0.65±0.02</b>	
		RBF2	0.38±0.02	0.66±0.03	0.38±0.03	0.66±0.05	0.38±0.01	0.66±0.02	
	T <sub>a</sub>	RBF1	<b>0.25±0.01</b>	<b>0.59±0.02</b>	<b>0.25±0.03</b>	<b>0.60±0.05</b>	<b>0.25±0.01</b>	<b>0.60±0.02</b>	
		RBF2	0.26±0.02	0.61±0.03	0.26±0.03	0.63±0.06	0.26±0.01	0.62±0.01	
	T <sub>p</sub>	RBF1	<b>0.59±0.09</b>	<b>1.09±0.14</b>	<b>0.60±0.15</b>	<b>1.14±0.16</b>	<b>0.59±0.08</b>	<b>1.10±0.08</b>	
		RBF2	0.68±0.08	1.28±0.10	0.69±0.14	1.31±0.18	0.69±0.07	1.29±0.10	
	40	T <sub>ri</sub>	RBF1	<b>0.27±0.03</b>	<b>0.67±0.04</b>	<b>0.27±0.02</b>	<b>0.67±0.04</b>	<b>0.27±0.02</b>	<b>0.67±0.03</b>
			RBF2	0.27±0.02	0.69±0.04	0.27±0.01	0.69±0.04	0.27±0.01	0.69±0.02
Rh <sub>i</sub>		RBF1	<b>0.38±0.02</b>	<b>0.65±0.04</b>	<b>0.38±0.02</b>	<b>0.65±0.03</b>	<b>0.38±0.01</b>	<b>0.65±0.03</b>	
		RBF2	0.37±0.02	0.65±0.03	0.38±0.03	0.65±0.04	0.38±0.01	0.65±0.02	
T <sub>a</sub>		RBF1	<b>0.25±0.02</b>	<b>0.59±0.05</b>	<b>0.25±0.01</b>	<b>0.59±0.02</b>	<b>0.25±0.01</b>	<b>0.59±0.01</b>	
		RBF2	0.26±0.01	0.61±0.04	0.26±0.02	0.64±0.05	0.25±0.02	0.62±0.02	
T <sub>p</sub>		RBF1	<b>0.62±0.13</b>	<b>1.13±0.14</b>	<b>0.57±0.08</b>	<b>1.08±0.09</b>	<b>0.59±0.08</b>	<b>1.10±0.08</b>	
		RBF2	0.73±0.12	1.32±0.16	0.69±0.13	1.31±0.19	0.71±0.11	1.32±0.16	

\* اعداد ۱ و ۲ در کنار دو مدل RBF و MLP، نشان‌دهنده دو نوع الگوریتم Trainlm و Trainbr است. همچنین ردیف‌های بولد شده حاوی بهترین نتایج هستند.

( Number 1 and 2 next to RBF and MLP models show the Trainlm and Trainbr, respectively. Also the bold rows have )  
\* (the best results.

این پارامتر دقت بیش‌تری دارد. ضریب تبیین بین داده‌های واقعی با نتایج شبکه عصبی و مدل رگرسیونی به‌ترتیب معادل ۰/۸۸۴۲ و ۰/۷۵۴۸ گزارش شد (He and Ma, 2010). در تحقیق دیگری، از سه مدل MLP، RBF و SVM به‌منظور تخمین دمای هوا، خاک و گیاه در یک گلخانه‌ی پلاستیکی مرسوم استفاده شد. نتایج نشان داد که مدل RBF به دلیل خطای کم‌تر، قابل اعتمادتر است (Taki et al., 2018a).

ضریب تبیین مدل شبکه عصبی و رگرسیون به‌منظور پیش‌بینی دمای داخل گلخانه در فاز آزمایش به‌ترتیب ۰/۹۷۲ و ۰/۹۳۲ گزارش شد. این پارامتر برای رطوبت نسبی هوای داخل گلخانه به‌ترتیب معادل ۰/۹۸۹ و ۰/۹۵۸ به‌دست آمد. (Dariouchy et al., 2009). در تحقیقی مشابه در کشور چین، میزان رطوبت نسبی هوای داخل گلخانه‌ای پلاستیکی توسط شبکه عصبی مصنوعی و مدل رگرسیونی مورد بررسی قرار گرفت. نتایج نشان داد که شبکه عصبی در تخمین

جدول ۲- مقایسه مدل RBF و MLP برای تخمین متغیرهای داخلی گلخانه شیشه‌ای

Table 2- Comparison between RBF and MLP for prediction the inside variables in glass greenhouse

مدل Model	متغیر Variable	متغیر Variable			
		T <sub>ri</sub>	Rh <sub>i</sub>	T <sub>a</sub>	T <sub>p</sub>
MLP	MAPE	1.65±0.45	1.57±0.24	0.76±0.75	1.65±0.15
	RMSE	0.85±0.24	1.06±0.14	0.32±0.03	0.89±0.04
RBF	MAPE	0.66±0.03	0.65±0.02	0.60±0.02	1.10±0.08
	RMSE	0.26±0.01	0.38±0.01	0.25±0.01	0.59±0.08

در پایان، به منظور تعیین اثر هر یک از متغیرهای ورودی (T<sub>o</sub>, I<sub>o</sub>) و (Rh<sub>o</sub>) بر تخمین پارامترهای داخلی گلخانه، آنالیز حساسیت برای هر دو مدل MLP و RBF انجام گرفت. نتایج این آنالیز حساسیت در جدول ۳ ارائه شده است.

جدول ۳- آنالیز حساسیت مدل MLP و RBF نسبت به سه متغیر ورودی

Table 3- Sensitivity analysis for MLP and RBF models relative to the 3 variables

متغیر Variable	مدل Model	MLP			RBF		
		RMSE	MAPE	R <sup>2</sup>	RMSE	MAPE	R <sup>2</sup>
T <sub>ri</sub>	All	<b>0.62</b>	<b>1.23</b>	<b>0.99</b>	<b>0.25</b>	<b>0.66</b>	<b>0.99</b>
	All exclude x1	1.02	1.84	0.97	0.75	1.25	0.98
	All exclude x2	0.87	1.69	0.98	0.56	1.01	0.99
	All exclude x3	0.84	1.65	0.98	0.56	1.18	0.99
Rh <sub>i</sub>	All	<b>0.81</b>	<b>1.24</b>	<b>0.99</b>	<b>0.36</b>	<b>0.61</b>	<b>0.99</b>
	All exclude x1	1.66	2.72	0.95	0.84	1.07	0.99
	All exclude x2	0.90	1.29	0.98	0.67	0.89	0.99
	All exclude x3	1.39	2.19	0.96	0.56	0.99	0.99
T <sub>a</sub>	All	<b>0.34</b>	<b>0.83</b>	<b>0.99</b>	<b>0.24</b>	<b>0.59</b>	<b>0.99</b>
	All exclude x1	0.34	0.85	0.99	0.32	0.77	0.99
	All exclude x2	0.32	0.76	0.99	0.29	0.70	0.99
	All exclude x3	0.37	0.91	0.98	0.32	0.76	0.99
T <sub>p</sub>	All	<b>0.87</b>	<b>1.59</b>	<b>0.92</b>	<b>0.48</b>	<b>1.04</b>	<b>0.97</b>
	All exclude x1	0.89	1.68	0.92	0.79	1.31	0.93
	All exclude x2	1.06	1.99	0.88	0.63	1.27	0.96
	All exclude x3	1.03	1.64	0.89	0.60	1.26	0.96

\* در مدل‌های فوق x<sub>1</sub>، x<sub>2</sub> و x<sub>3</sub> به ترتیب عبارتند از: I<sub>o</sub>، T<sub>o</sub> و Rh<sub>o</sub>

(In above models, x<sub>1</sub>, x<sub>2</sub> and x<sub>3</sub> are: I<sub>o</sub>, T<sub>o</sub> and Rh<sub>o</sub>, respectively)

از شبکه‌های عصبی مصنوعی علاوه بر تخمین پارامترهای داخلی گلخانه، می‌توان برای پیش‌بینی سایر متغیرها از جمله میزان CO<sub>2</sub>، عملکرد گیاه گلخانه‌ای و یا حتی میزان تبخیر و تعرق گیاه در گلخانه نیز استفاده کرد. به‌عنوان نمونه از شبکه عصبی MLP به‌منظور پیش‌بینی میزان تبخیر و تعرق گیاه گلخانه‌ای در کشور استرالیا استفاده شد (Falamarzi *et al.*, 2014). متغیرهای ورودی شامل بیشینه و کمینه دمای بیرون و همچنین سرعت باد خارج از گلخانه بود. این مقادیر طی سال‌های ۲۰۰۹ تا ۲۰۱۲ توسط مرکز هواشناسی استرالیا جمع‌آوری شده بودند. میزان تبخیر و تعرق گیاه گلخانه‌ای طبق فرمول معروف روش پنمن مانیتیت (PM56) محاسبه شد. نتایج این تحقیق نشان داد که می‌توان از شبکه عصبی به‌عنوان ابزاری مفید برای تخمین میزان تبخیر و تعرق گیاه گلخانه‌ای استفاده کرد.

نتایج این جدول نشان می‌دهد که برای تخمین هر چهار متغیر داخلی گلخانه، بهترین مدل با بیش‌ترین دقت بر اساس سه فاکتور RMSE، MAPE و R<sup>2</sup>، مدلی است که از هر سه پارامتر بیرونی (I<sub>o</sub>، Rh<sub>o</sub> و T<sub>o</sub>) استفاده کند. بر این اساس، در تمام مدل‌سازی‌های مراحل بعدی از هر سه پارامتر بیرونی به‌عنوان نهاده‌های ورودی دو مدل MLP و RBF استفاده می‌شود. استفاده از آنالیز حساسیت در مدل‌سازی به محقق اجازه می‌دهد که از دخالت فاکتورهای بی‌اثر یا کم‌اثر در نتیجه‌گیری نهایی جلوگیری کند و مدلی با کم‌ترین تعداد نهاده ورودی و بیش‌ترین دقت ایجاد کند. از این روش در پژوهش‌های دیگری نیز استفاده شده است (Rohani *et al.*, 2018; Taki *et al.*, 2018b).

عصبی با دو مجموعه متفاوت از داده‌ها (۴۰٪ و ۸۰٪ از کل داده‌ها) مورد آموزش قرار گرفتند. نتایج نشان داد که حساسیت مدل RBF نسبت به تغییر اندازه مجموعه داده‌های آموزشی بسیار کم است. به عبارتی عملکرد مدل RBF با تغییر اندازه مجموعه داده‌های آموزشی تغییر چندانی نمی‌کند. نتایج کلی این تحقیق با توجه به دو آماره MAPE و RMSE نشان داد که مدل RBF قادر است با دقت بالایی هر چهار متغیر داخلی گلخانه مورد نظر را پیش‌بینی کند. پیشنهاد می‌شود نتایج مدل شبکه عصبی مصنوعی با رگرسیون چندگانه و مدل‌های ریاضی انتقال حرارت و جرم در گلخانه مورد نظر، مقایسه شود. استفاده از این نوع ابزار قادر است بسیاری از هزینه‌های مربوط به خرید و نصب انواع ابزارهای اندازه‌گیری در گلخانه‌ها را کاهش دهد و گلخانه را به سمت هوشمند شدن و عملگری مستقل از اپراتور سوق دهد.

### سپاسگزاری

بدین‌وسیله از معاونت پژوهشی فناوری دانشگاه علوم کشاورزی و منابع طبیعی خوزستان به دلیل مساعدت‌های مالی در اجرای این تحقیق که بخشی از پایان‌نامه کارشناسی ارشد رشته مکانیزاسیون کشاورزی است، کمال تشکر و قدردانی می‌شود.

ساختار بهترین شبکه به صورت ۱-۲-۶ با مقدار  $R=0.89$  و  $RMSE=1.03mm/day$  به دست آمد. در تحقیق دیگری از ابزار شبکه عصبی مصنوعی به منظور تخمین میزان عملکرد، رشد و همچنین مقدار آب مصرفی در کشت گوجه‌فرنگی در کشور کانادا استفاده شد (Ehret et al., 2011). داده‌های دما و میزان تابش روزانه و هفتگی از گلخانه‌ای خودکار و توسط سنسورهای حساس برداشت شد. نتایج این کار نیز حاکی از توانمندی این روش در تخمین روابط غیرخطی بین متغیرهاست.

### نتیجه‌گیری

در این تحقیق از دو مدل شبکه عصبی مصنوعی (MLP و RBF) به منظور پیش‌بینی ۴ متغیر مهم ( $T_a$ ,  $T_p$ ,  $T_{ri}$ ,  $Rh_a$ ) یک گلخانه‌ی شیشه‌ای دوطرفه با ساختار ویژه در شهر ملائانی استفاده شد. داده‌های اولیه توسط سنسورهای دما، رطوبت و تابش سنج به دست آمد. از دو الگوریتم آموزش Trainlm و Trainbr با یک لایه مخفی و تعداد نرون‌های مختلف با سه متغیر ورودی مشخص ( $I_0$ ,  $T_0$  و  $Rh_0$ ) استفاده شد. نتایج نشان داد که الگوریتم آموزشی Trainlm در اکثر موارد در هر دو مدل MLP و RBF دقت بیشتری نسبت به الگوریتم Trainbr دارد. در این تحقیق هر دو مدل شبکه

### References

- Ben Ali, R. E., M. Aridhi, and A. Mami. 2016. Fuzzy Logic Controller of temperature and humidity inside an agricultural greenhouse. *IEEE Journals & Magazines*.
- Boaventura, L., C. Couto, and A. E. B. Ruano. 2000. A greenhouse climate multivariable predictive controller, *Acta Horticulturae*, ISHS 534: 269-276.
- Bot G. P. A. 1983. Greenhouse Climate: From Physical Processes to a Dynamic Model. Ph.D. dissertation, Wageningen Agricultural University, Wageningen, The Netherlands, 240 pp.
- Coelho, J. P., J. Boaventura, and P. B. Moura Oliveira. 2002. Solar radiation prediction methods applied to improve greenhouse climate control, in: *World Congress of Computers in Agriculture and Natural Resources*, 13-15 March, pp. 154-161.
- Dariouchy, A., E. Aassif, K. Lekouch, L. Bouirden, and G. Maze. 2009. Prediction of the intern parameters tomato greenhouse in a semi-arid area using a time-series model of artificial neural networks. *Measurement* 42: 456-463.
- Ehret, D., L. Hill, B. D. T. Helmer, and D. R. Edward. 2011. Neural network modeling of greenhouse tomato yield, growth and water use from automated crop monitoring data. *Computers and Electronics in Agriculture* 79: 82-89.
- Falamarzi, Y., N. Palizdan, Y. F. Huang, and T. S. Lee. 2014. Estimating evapotranspiration from temperature and wind speed data using artificial and wavelet neural networks (WNNs). *Agricultural Water Management* 140: 26-36.
- Feng, L. X., Q. L. Lin, M. G. Qi, and W. Gang. 2016. Modeling Greenhouse Temperature by Means of PLSR and BPNN. 35<sup>th</sup> Chinese Control Conference. July 27-29, Chengdu, China.
- Ferreira, P. M., E. A. Faria, and A. E. Ruano. 2002. Neural network models in greenhouse air temperature prediction. *Neurocomputing* 43 (1-4): 51-75.
- Gupta, R., G. N. Tiwari, G. N. Kumar, and Y. Gupta. 2012. Calculation of total solar fraction for different orientation of greenhouse using 3D-shadow analysis in Auto-CAD. *Energy and Buildings* 47: 27-34.
- He, F., and C. Ma. 2010. Modeling greenhouse air humidity by means of artificial neural network and principal component analysis. *Computers and Electronics in Agriculture* 71S (2010): S19-S23.
- Hill, J. 2006. Dynamic modeling and energy use in a nursery greenhouse. MSc thesis.
- Lachouri, C. E., K. H. Mansouri, M. M. Lafifi, and A. Belmeguenai. 2016. Adaptive Neuro-Fuzzy Inference Systems for Modeling Greenhouse Climate. *International Journal of Advanced Computer Science and Applications* 7: 12-18.

14. Linker, R., and I. Seginer. 2004. Greenhouse temperature modeling: a comparison between sigmoid neural networks and hybrid models. *Mathematics and Computers in Simulation* 65: 19-29.
15. Manuel, A., R. Francisco, R. Armando, and B. Manuel. 2005. Discrete-time nonlinear FIR models with integrated variables for greenhouse indoor temperature simulation, in: *Proceedings of the 44<sup>th</sup> IEEE Conference on Decision and Control, and the European Control Conference, CDC-ECC'05*, pp. 4158-4162.
16. Rodriguez, J. D., A. Perez, and J. A. Lozano. 2010. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: *Proceeding of the international joint conference on artificial intelligence*, 32: 569-575.
17. Rohani, A., M. Taki, and M. Abdollahpour. 2018. A novel soft computing model (Gaussian process regression with K-fold cross validation) for daily and monthly solar radiation forecasting (Part: I). *Renewable Energy* 115: 411-422.
18. Rohani, A., M. H. Abbaspour-Fard, and Sh. Abdolhahpour. 2011. Prediction of tractor repair and maintenance costs using artificial neural network. *Expert Sys. Applications* 38: 8999-9007.
19. Sethi, V. P. 2009. On the selection of shape and orientation of a greenhouse: thermal modeling and experimental validation. *Solar Energy* 83: 21-38.
20. Sethi, V. P., and R. K. Dubey. 2008. Optimal space utilization of a greenhouse using multi-rack tray system: Thermal modeling and experimental validation. *Energy Conversion and Management* 49: 2890-2899.
21. Shukla, A., G. N. Tiwari, and M. S. Sodha. 2006. Thermal modeling for greenhouse heating by using thermal curtain and an earth-air heat exchanger. *Building and Environment* 41 (7): 843-850.
22. Singh, R. D., and G. N. Tiwari. 2010. Energy conservation in the greenhouse system: A steady state analysis. *Energy* 35: 2367-2373.
23. Taki, M., A. Rohani, M. Rahmati-Joneidabad. 2018b. Solar thermal simulation and applications in greenhouse. *Information Processing in Agriculture* 5: 83-113.
24. Taki, M., S. Abdanan Mehdizadeh, A. Rohani, M. Rahnama, and M. Rahmati-Joneidabad. 2018a. Applied machine learning in greenhouse simulation; new application and analysis. *Information Processing in Agriculture*, <https://doi.org/10.1016/j.inpa.2018.01.003>.
25. Taki, M., Y. Ajabshirchi, and A. Mahmoudi. 2012. Prediction of output energy for wheat production using artificial neural networks in Esfahan province of Iran. *Journal of Agricultural Technology* 8 (4): 1229-1242.
26. Taki, M., Y. Ajabshirchi, S. F. Ranjbar, A. Rohani, and M. Matloobi. 2017. Evaluation of heat transfer mathematical models and multiple linear regression to predict the inside variables in semi-solar greenhouse. *Journal of Agricultural Machinery* 7 (1): 2014-220. (In Farsi).
27. Taki, M., Y. Ajabshirchi, S. F. Ranjbar, A. Rohani, and M. Matloobi. 2016. Heat transfer and MLP neural network models to predict inside environment variables and energy lost in a semi-solar greenhouse. *Energy and Buildings* 110: 314-329.
28. Vadiiee, A., and V. Martin. 2013. Energy analysis and thermo economic assessment of the closed greenhouse – The largest commercial solar building. *Applied Energy* <http://dx.doi.org/10.1016/j.apenergy.2013.06.051>.
29. Van Ooteghem, R. J. C. 2007. *Optimal Control Design for a Solar Greenhouse*, Systems and Control. Wageningen: Wageningen University.
30. Van Straten, G., G. Van Willigenburg, E. Van Henten, and R. Van Oothghem. 2011. *Optimal control of greenhouse cultivation*. CRC press, Taylor and Francis, New York.

## Prediction the inside Variables of Even-span Glass Greenhouse with Special Structure by Artificial Neural Network (MLP-RBF) Models

M. Hamdani<sup>1</sup>, M. Taki<sup>2</sup>, M. Rahnama<sup>2\*</sup>, A. Rohani<sup>3</sup>, M. Rahmati-Joneidabad<sup>4</sup>

Received: 27-04-2018

Accepted: 25-08-2018

### Introduction

Controlling greenhouse microclimate not only influences the growth of plants, but is also critical in the spread of diseases inside the greenhouse. The microclimate parameters are inside air, roof, crop and soil temperature, relative humidity, light intensity, and carbon dioxide concentration. Predicting the microclimate conditions inside a greenhouse and enabling the use of automatic control systems are the two main objectives of greenhouse climate model. The microclimate inside a greenhouse can be predicted by conducting experiments or by using simulation. Static and dynamic models and also artificial neural networks (ANNs) are used for this purpose as a function of the metrological conditions and the parameters of the greenhouse components. Usually thermal simulation has a lot of problems to predict the inside climate of greenhouse and the error of simulation is higher in literature. So the main objective of this paper is comparison between two types of artificial neural networks (MLP and RBF) for prediction 4 inside variables in an even-span glass greenhouse and help the development of simulation science in estimating the inside variables of intelligent greenhouses.

### Materials and Methods

In this research, different sensors were used for collecting the temperature, radiation, humidity and wind data. These sensors were used in different positions inside the greenhouse. After collecting the data, two types of ANNs were used with LM and Br training algorithms for predicting the inside variables in an even-span glass greenhouse in Mollasani, Ahvaz. MLP is a feed-forward layered network with one input layer, one output layer, and some hidden layers. Every node computes a weighted sum of its inputs and passes the sum through a soft nonlinearity. The soft nonlinearity or activity function of neurons should be non-decreasing and differentiable. One type of ANN is the radial basis function (RBF) neural network which uses radial basis functions as activation functions. An RBF has a single hidden layer. Each node of the hidden layer has a parameter vector called center. This center is used to compare with the network input vector to produce a radially symmetrical response. Responses of the hidden layer are scaled by the connection weights of the output layer and then combined to produce the network output. There are many types of cross-validation, such as repeated random sub-sampling validation, K-fold cross-validation, K×2 cross-validation, leave-one-out cross-validation and so on. In this study, we pick up K-fold cross-validation for selecting parameters of model. The K-fold cross-validation is a technique of dividing the original sample randomly into K sub-samples. Different performance criteria have been used in the literature to assess model's predictive ability. The mean absolute percentage error (MAPE), root means square error (RMSE) and coefficient of determination ( $R^2$ ) are selected to evaluate the forecast accuracy of the models in this study.

### Results and Discussion

The results of neural network optimization models with different networks, dependent on the initial random values of the synaptic weights. Thus, the results in general will not be the same in two different trials, even if the same training data have been used. Therefore, in this research K-fold cross validation was used and different data samples were made for train and test of ANN models. The results showed that Trainlm for both of MLP and RBF models has the lower error than Trainbr. Also MLP and RBF were trained with 40 and 80% of total data and results indicated that RBF has the lowest sensitivity to the size data. Comparison between RBF and MLP model showed that, RBF has the lowest error for prediction all the inside variables in the greenhouse (Ta, Tp, Tri, Rha). In this paper, we tried to indicate the fact that innovative methods are simpler and more accurate than physical heat and mass transfer method to predict the environment changes. Moreover, this method can use to predict other changes in greenhouse such as final yield, evapotranspiration, humidity, cracking on the fruit, CO<sub>2</sub> emission and so on. So the future research will focus on the other soft computing models such as ANFIS, GPR,

1- MSc student, Department of Agricultural Machinery and Mechanization, Agricultural Sciences and Natural Resources University of Khuzestan

2- Assistant Prof., Department of Agricultural Machinery and Mechanization, Agricultural Sciences and Natural Resources University of Khuzestan

3- Associate Prof., Department of Biosystems, Faculty of Agriculture, Ferdowsi University of Mashhad

4- Assistant Prof., Department of Horticulture, Agricultural Sciences and Natural Resources University of Khuzestan

(\*- Corresponding Author Email: rahnamam2002@asnrkh.ac.ir)

Time Series and select the best one for modeling and finally online control of greenhouse in all climate and different environment.

### **Conclusions**

This research presents a comparison between two models of Artificial Neural Network (RBF-MLP) to predict 4 inside variables ( $T_a$ ,  $T_p$ ,  $T_{ri}$ ,  $R_{ha}$ ) in an even-span glass greenhouse. Comparison of the models indicated that RBF has lower error. The range of RMSE and MAPE factors for RBF model to predict all inside variables were between 0.25-0.55 and 0.60-1.10, respectively. Besides the results showed that RBF model can estimate all the inside variables with small size of data for training. Such forecasts can be used by farmers as an appropriate advanced notice for changes in temperatures. Thus, they can apply preventative measures to avoid damage caused by extreme temperatures. More specifically, predicting a greenhouse temperature can not only provide a basis for greenhouse environmental management decisions that can reduce the planting risks, but also could be as a basic research for the feedback-feed-forward type of climate control strategy.

**Keywords:** Even-span greenhouse, Intelligent greenhouses, Modeling, Neural network

