

Prediction of Temperature in a Greenhouse Covered with Polyethylene Plastic Using Artificial Neural Networks, Case Study: Jiroft Region

ELHAM BOLANDNAZAR¹, HASSAN SADRNIA^{*1}, ABBAS ROHANI¹, MORTEZA TAKI²

1. Biosystems Engineering Department, Faculty of Agriculture, Ferdowsi University of Mashhad, Mashhad, Iran.
2. Department of agricultural machinery and mechanization, Agricultural Sciences and Natural Resources University of Khuzestan, Mollasani, Iran.

(Received: Nov. 5, 2019- Revised: Nov. 22, 2019- Accepted: Dec. 22, 2019)

ABSTRACT

Internal temperatures of greenhouse and its control is one of the important parameters in greenhouses and plays a key role in the economics of production. Although the greenhouse is a closed environment, it is not completely isolated from the outside. Therefore, the conditions inside the greenhouse are constantly changing under the influence of outside climate change. The purpose of this study was to estimate the internal air temperature of polyethylene greenhouse with respect to the external parameters of the greenhouse including air temperature (T_{out}), air relative humidity (H_{out}), solar radiation (S) and wind speed (V). For this purpose, different method of artificial neural networks including Multilayer Perceptron (MLP), Radial Basis Function (RBF) and Adaptive Neuro Fuzzy Inference System (ANFIS) were used. Comparison between different neural network models showed that RBF method had better prediction performance than MLP and ANFIS with higher coefficient of determination ($R^2=0.93$) and lower error (RMSE=2.25). The results of the RBF model estimation for the prediction future temperature indicated an acceptable error in the prediction by the model for the next two hours and thus, the farmers had enough time to provide the necessary measures to prevent the greenhouse temperature rise in the future and save in energy consumption.

Keywords: Greenhouse temperature, Polyethylene cover, Artificial neural network, Modeling

* Corresponding Author's Email: hassan.sadrnia@um.ac.ir

پیش‌بینی دمای هوای یک گلخانه با پوشش پلی اتیلن با استفاده از شبکه‌های عصبی مصنوعی، مطالعه موردی: منطقه جیرفت

الهام بلندنظر^۱، حسن صدرنیا^{۱*}، عباس روحانی^۱، مرتضی تاکی^۲

۱. گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه فردوسی مشهد، مشهد، ایران.

۲. گروه مهندسی ماشین‌های کشاورزی و مکانیزاسیون، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، ملاتانی، ایران.

(تاریخ ارسال: ۱۳۹۸/۸/۱۴ - تاریخ بازنگری: ۱۳۹۸/۹/۱۹ - تاریخ تصویب: ۱۳۹۸/۱۰/۱)

چکیده

دما و کنترل آن در گلخانه یکی از پارامترهای مهم در گلخانه‌ها بوده و نقش اساسی در اقتصادی بودن تولید دارد. با وجود این که گلخانه یک محیط بسته است ولی کاملاً از محیط بیرون ایزوله نیست. بنابراین شرایط داخل گلخانه تحت تأثیر تغییرات آب و هوایی بیرون دائماً تمایل به تغییر دارد. هدف از اجرای این تحقیق، تخمین دمای هوا در یک گلخانه با پوشش پلی اتیلن با توجه به پارامترهای خارجی گلخانه شامل دمای هوا (T_{out})، رطوبت نسبی هوا (H_{out})، شدت تابش خورشید (S) و سرعت باد (V) با استفاده از روش‌های مختلف شبکه‌های عصبی مصنوعی شامل پرسپترون چند لایه (MLP)، تابع شعاع مدار (RBF) و عصبی-فازی (ANFIS) می‌باشد. مقایسه بین مدل‌های مختلف شبکه‌های عصبی نشان داد که روش RBF با ضریب تبیین بالاتر ($R^2=0.93$) و خطای کمتر ($RMSE=2.25$) نسبت به دو روش MLP و ANFIS دارای عملکرد بهتر در پیش‌بینی بود. نتایج ارزیابی مدل RBF برای پیش‌بینی دما در ساعات آینده بیانگر خطای قابل قبول در پیش‌بینی توسط این مدل تا دو ساعت آینده بود و بنابراین کشاورزان زمان کافی برای فراهم نمودن تمهیدات لازم جهت جلوگیری از افزایش دما در گلخانه در ساعات آینده و صرفه جویی در مصرف انرژی خواهند داشت.

واژه‌های کلیدی: دمای گلخانه، پوشش پلی اتیلن، شبکه‌های عصبی مصنوعی، مدل سازی

مقدمه

محیط گلخانه یک سامانه دینامیکی خیلی پیچیده است که با مواد نازک و شفاف پوشیده شده است. این سامانه شرایط قابل قبولی برای رشد گیاه فراهم می‌کند، اما به دلیل تأخیرهای زمانی و اختلالات شدید محیطی مانند تابش خورشید، سرعت باد، دما و رطوبت هوای بیرون مشکلاتی در کنترل محیط گلخانه به وجود می‌آید (Taki et al., 2016a). برای جبران این اثرات لازم است تجهیزات کنترلی متعددی در گلخانه نصب و تعبیه شود و دما و رطوبت از مهم‌ترین پارامترهایی هستند که بایستی در یک گلخانه کنترل شوند (Omid and Shafaei, 2004). این موضوع در گلخانه‌های پیشرفته از طریق جایگزینی حس‌گرها با انواع دماسنج‌ها و رطوبت‌سنج‌ها مورد استفاده در گلخانه‌های سنتی و همچنین افزایش تعداد حس‌گرها تا حدی اصلاح شده است. ولی به دلیل تغییرات میزان رطوبت و دما در نقاط مختلف گلخانه و اثر مستقیم آن بر کیفیت و کمیت محصول، لزوم استفاده بیش-تر حس‌گرها به خوبی توجیه می‌شود (Vadiei et al., 2011). از آنجایی که افزایش تعداد حس‌گرها باعث افزایش هزینه‌های ثابت

گلخانه شده و روند تبدیل گلخانه‌های سنتی به انواع مدرن را با مشکل جدی روبرو می‌کند. روش‌های مدل‌سازی می‌تواند به عنوان جایگزینی برای انواع دماسنج‌ها و حس‌گرهای پرهزینه در انواع گلخانه‌ها مورد استفاده قرار گیرد (Ferreira et al., 2002). امروزه شبکه‌های عصبی مصنوعی ابزاری قدرتمند جهت مدل‌سازی حالت‌هایی هستند که روابط بین ویژگی‌ها و خروجی مدل، پیچیده و غیرخطی می‌باشند. با توجه به پیچیدگی محیط گلخانه از این ابزار در تحقیقات متنوعی برای مدل‌سازی فیزیکی گلخانه (Bot, 1983) و پیش‌بینی برخی از پارامترهای داخلی گلخانه استفاده شد. تاکی و همکاران (۲۰۱۶)، برخی مدل‌های ریاضی (مدل انتقال حرارت و رگرسیون خطی چندگانه) و روش نوین (شبکه عصبی مصنوعی) برای مدل‌سازی دمای هوای داخل و سقف گلخانه در یک گلخانه نیمه خورشیدی در شهرستان تبریز مورد بررسی قرار دادند (Taki et al., 2016a). عملکرد MLP (پرسپترون چند لایه) برای تخمین تلفات انرژی در گلخانه نیمه خورشیدی نشان داد که این مدل قادر است نتایج دقیق‌تری نسبت به سایر مدل‌های مورد استفاده در این تحقیق ارائه کند.

دقیقه طول جغرافیایی قرار دارد. جنوب کرمان (شامل شهرستان- های جیرفت، کهنوج، عنبر آباد، منوجان، رودبار جنوب، قلعه گنج و فاریاب) برطبق آخرین آمارنامه سازمان جهاد کشاورزی در سال ۱۳۹۶ دارای سطح زیر کشت ۱۴۰۷/۵ هکتار محصول خیار گلخانه‌ای و تولید ۲۸۰۱۰۵ تن می‌باشد. این منطقه مقام دوم را از نظر سطح زیر کشت و مقام سوم را از نظر تولید این محصول دارد (Anonymous, 2019).

این تحقیق با هدف پیش بینی دما در یک گلخانه با راستای شمالی-جنوبی به مساحت ۹۰ متر مربع (طول ۱۰ متر و عرض ۹ متر) و ارتفاع ۴/۵ متر در شهرستان جیرفت با توجه به متغیرهای محیط بیرون گلخانه انجام شد. برای جمع‌آوری داده‌های مربوط به متغیرهای بیرونی شامل دما، رطوبت، سرعت باد و تابش خورشید از انواع حس‌گرها و دستگاه‌های مربوطه استفاده شد. به منظور برداشت داده‌های دما و رطوبت از داخل و بیرون گلخانه مورد نظر از حس‌گرهای دما و رطوبت دیجیتال مدل AM2303 در مدار الکترونیکی طراحی شده با دقت ۰/۱ درجه سلسیوس برای دما و ۱/۲ درصد برای رطوبت نسبی هوا استفاده شد. داده‌های تابش در یک سطح تراز شده زمین در بیرون گلخانه 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 متر بر ثانیه، برداشت شد. سرعت باد در خارج از گلخانه نیز توسط بادسنج در ارتفاعی حدود ۴/۵ متر بالاتر از سطح زمین برداشت شد تا اثر انواع موانع در کاهش سرعت باد برطرف شود. شکل (۱) محل نصب حس‌گرهای فوق را در نقاط مختلف گلخانه مورد بررسی را نشان می‌دهد. داده‌برداری در یک گلخانه با پوشش پلی اتیلن که گیاه خیار در داخل گلخانه وجود داشت، انجام گرفت و در نتیجه‌های اطراف گلخانه برای تهویه هوا باز بودند. ثبت داده‌ها به مدت یک ماه (۱۵ آبان ماه تا ۱۵ آذرماه) از ساعت ۸ صبح تا ۱۶ بعد از ظهر انجام شد.

شبکه‌های عصبی مصنوعی

در این تحقیق از روش‌های شبکه‌های عصبی مصنوعی به منظور پیش‌بینی دمای هوای گلخانه استفاده شد. مدل‌سازی توسط انواع مختلف روش‌های شبکه‌های عصبی مصنوعی شامل پرسپترون چند لایه (MLP)، تابع شعاع مدار (RBF) و عصبی-فازی (ANFIS) صورت گرفت. ساختار روش‌های شبکه عصبی

در تحقیق دیگری دمای هوای گلخانه توسط روش‌های رگرسیون کمترین مربعات جزئی (PLSR) و شبکه عصبی پس انتشار خطا (BPNN) تخمین زده شد (Feng et al., 2016). نتایج مقایسه پیش‌بینی در این پژوهش نشان داد که روش BPNN نسبت به PLSR دارای دقت بیشتری می‌باشد. تاکی و همکاران ۲۰۱۸، از روش‌های شبکه‌های عصبی مصنوعی (MLP و RBF) و ماشین بردار پشتیبان (SVM) برای پیش‌بینی دمای هوا، خاک و گیاه در یک گلخانه با پوشش پلی اتیلن در استان شیراز استفاده کردند. نتایج این تحقیق نشان داد که استفاده از روش RBF قادر است نتایج بهتری نسبت به سایر روش‌های مورد استفاده داشته باشد (Taki et al., 2018). در پژوهشی دمای هوای داخل گلخانه در حالت‌های بدون تهویه و با استفاده از سامانه‌ی سرمایه‌ی تبخیری با روش شبکه‌های عصبی مصنوعی و مدل رگرسیونی تخمین زده شد (Shojaei et al., 2018). ارزیابی نتایج این تحقیق نشان داد روش شبکه عصبی مصنوعی نسبت به مدل رگرسیونی دقت بالاتری دارد.

با توجه به اینکه شهرستان جیرفت با تنوع اقلیمی کاملاً ویژه و استثنایی جزء یکی از مناطق ویژه کشاورزی در جهان بوده و یکی از مناطق مهم حاصلخیز ایران از نظر تولید محصولات گلخانه‌ای می‌باشد (Anonymous, 2019)، در این تحقیق به پیش‌بینی پارامترهای داخلی گلخانه در این شهرستان توسط روش‌های مختلف شبکه عصبی مصنوعی پرداخته شد. همچنین با توجه به گرم شدن هوا در برخی از فصول سال در این منطقه و احتمال آسیب رسیدن به گیاه، مطالعه مورد نظر برای پیش‌بینی دما در ساعات آینده مورد بررسی قرار گرفت تا کشاورزان این شهرستان قبل از بالا رفتن دما تمهیداتی جهت کاهش دما فراهم نمایند. همچنین نتایج این تحقیق می‌تواند در آینده به هوشمندی سازی گلخانه‌های کشاورزی این منطقه از نظر کنترل شرایط محیطی و در نتیجه صرفه‌جویی در مصرف انرژی، کاهش مشکلات زیست محیطی و توسعه کشاورزی پایدار کمک شایانی نماید.


مواد و روش‌ها

مشخصات گلخانه

شهرستان جیرفت با وسعت ۸۶۰۲ کیلومتر مربع معادل ۴/۶۵ درصد استان کرمان را به خود اختصاص داده است. این شهرستان در ۲۸ درجه و ۴۰ دقیقه عرض جغرافیایی و ۵۷ درجه و ۴۴

عامل تأثیرگذار بردار ورودی (لایه ورودی) بودند و دمای هوای گلخانه به عنوان متغیر لایه خروجی بود

مصنوعی از لایه‌ی ورودی، لایه مخفی و لایه خروجی تشکیل شده است. دمای هوای خارج گلخانه، رطوبت نسبی هوای خارج گلخانه، شدت تابش خورشید بیرون گلخانه و سرعت باد چهار



شکل ۱- محل نصب حس‌گرهای دما، رطوبت، تابش و باد در داخل و خارج گلخانه

پاسخ خواهد داد (برای $q = 1, 2, \dots, Q$). هدف دنبال کردن پارامتر-های شبکه به منظور به دست آوردن خروجی واقعی z^q نزدیک به خروجی مورد نظر مربوطه (برای $q = 1, 2, \dots, Q$) می‌باشد. در روش RBF هر نرون در لایه مخفی بر اساس یک تابع فعال‌ساز غیرخطی (ϕ) عمل می‌کند. در طول مرحله آموزش و رسیدن به کمینه عمومی از عامل بایاس برای همگرا شدن شبکه عصبی RBF استفاده می‌شود. براساس رابطه (۲) برای هر بردار ورودی x خروجی شبکه عصبی RBF رابطه محاسبه می‌شود (Rohani et al., 2018):

$$Y = W^T \Phi = \sum_{j=1}^{L_2} w_{ij} \phi(\|x - c_i\|) \quad (\text{رابطه ۲})$$

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 ϕ تابع گوسین می‌باشد که براساس رابطه (۳) محاسبه می‌گردد (Rohani et al., 2018):

$$\phi_i(x) = \exp\left(-\frac{\|x - c_i\|^2}{\sigma_i^2}\right) \quad (\text{رابطه ۳})$$

در این رابطه σ پارامتر توزیع است. شکل طرحواره از شبکه عصبی به روش MLP و RBF در شکل (۲) نشان داده شده است.


روش‌های پرسپترون چند لایه (MLP) و شبکه‌های عصبی شعاعی (RBF)

شبکه عصبی MLP یکی از روش‌های پیش‌بینی است و حداقل از سه لایه تشکیل شده است. لایه اول لایه ورودی است که اندازه آن معادل تعداد ورودی‌های مدل در نظر گرفته شده برای پیش‌بینی است. در این روش معادل وزنی برابر با هر ورودی وجود دارد (Taki et al., 2016a). لایه مخفی از چندین نرون تشکیل شده است و با توجه به اینکه هدف این مقاله پیش‌بینی دمای هوای گلخانه می‌باشد لایه خروجی نیز از یک نرون (دمای هوای گلخانه) تشکیل شده است.

بر طبق نتایج تحقیقات قبلی شبکه عصبی با تابع انتقال سیگموئید در لایه مخفی و تابع انتقال خطی در لایه خروجی، قادر به تقریب هر تابع پیچیده‌ای می‌باشد (Hagan et al., 1996). بنابراین در این تحقیق از این توابع انتقال در لایه مخفی و لایه خروجی برای روش MLP استفاده گردید. تابع انتقال سیگموئید براساس رابطه (۱) برای لایه مخفی استفاده شد (Rohani et al., 2011):

$$f_{\theta} = \frac{1}{1 + e^{-\theta}} \quad (\text{رابطه ۱})$$

این شبکه مسئول نقشه‌برداری بردار می‌باشد، یعنی با وارد کردن بردار ورودی، x^q ، شبکه از طریق بردار z^q خروجی آن را



شکل ۲- ساختار کلی مدل‌های MLP (a) و RBF (b)

(۱) مشخصات آن‌ها آمده، به‌منظور تعیین بهترین مدل مورد بررسی قرار گرفتند. با توجه به اینکه یک شبکه عصبی با یک لایه مخفی و به اندازه کافی تعداد زیادی از نرون‌ها می‌تواند به طور کامل هر تابع پیوسته دلخواه را تقریب بزند (Haykin, 1994)، عملکرد روش‌های MLP و RBF با تغییر تعداد نرون‌ها از ۳ تا ۲۵ نرون در یک لایه مخفی بررسی و بهینه‌ترین ساختار جهت تخمین دمای گلخانه انتخاب گردید.

به منظور آموزش شبکه و اصلاح وزن‌ها تا رسیدن به یک خطای معنادار در دو مدل MLP و RBF روش‌های بسیاری زیادی وجود دارد. یکی از مشهورترین این روش‌ها، الگوریتم پس انتشار خطا (BP) است (Menhaj, 2000). در این روش در هر گام خروجی شبکه محاسبه شده و برحسب میزان اختلاف آن با خروجی مطلوب، وزن‌ها تصحیح می‌گردد تا در نهایت این خطا، مینیمم شود. لذا در این مطالعه از این روش برای اصلاح وزن‌ها استفاده شد و برای آموزش روش‌های شبکه عصبی مصنوعی MLP و RBF، ۱۳ تابع آموزشی پس انتشار خطا که در جدول

جدول ۱- مشخصات انواع توابع آموزشی مورد استفاده در روش‌های MLP و RBF برای پیش بینی دمای گلخانه

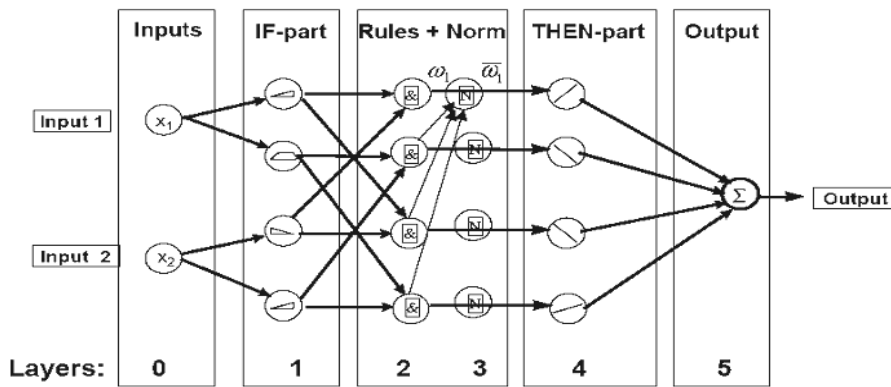
نام کامل تابع	تابع آموزشی	ردیف
Bayesian regularization back-propagation	Trainbr	۱
BFGS quasi-Newton back-propagation	Trainbfg	۲
Powell-Beale conjugate gradient back-propagation	Traincgb	۳
scaled conjugate gradient back-propagation	Trainscg	۴
Fletcher-Powell conjugate gradient back-propagation	Traincgf	۵
one step secant back-propagation	Trainoss	۶
Polak-Ribiere conjugate gradient back-propagation	Traincgp	۷
Levenberg-Marquardt back-propagation	Trainlm	۸
resilient back-propagation	Trainrp	۹
gradient descent w/momentum and adaptive lr back-propagation	Traingdx	۱۰
gradient descent with adaptive lr back-propagation	Traingda	۱۱
gradient descent with momentum back-propagation	Traingdm	۱۲
gradient descent back-propagation	Traingd	۱۳

برخوردار است (Basarir A. 2003; Grzesiak et al., 2006; Yang, 2003; Pulido-Calvo, 2009). ANFIS که برگرفته از عبارت سامانه استنتاج فازی-تطبیقی می‌باشد که تنها تفاوت آن

روش ANFIS
در میان روش‌های نوین مدل‌سازی، سامانه‌های فازی از جایگاه ویژه‌ای در زمینه‌های مختلف و به‌خصوص علوم کشاورزی

تا کاگی-سوگنو-کانگ به صورت ساختار شبکه‌ای پیش‌رونده به-کار می‌برند. اگر خروجی هر لایه به صورت O_k^l (خروجی k امین گره از لایه ۱) باشد، ساختار مدل ANFIS با دو ورودی x و y و یک خروجی z در پایگاه قوانین آن از دو قانون زیر از نوع سوگنو استفاده می‌شود که در شکل (۳) به صورت شماتیک دیده می‌شود.

قانون دوم: اگر x است A_1 و B_1, y است، آنگاه $f_1 = p_1x + q_1y + r_1$
 قانون اول: اگر x است A_2 و B_2, y است، آنگاه $f_2 = p_2x + q_2y + r_2$



شکل ۳- لایه‌های مختلف در یک مدل انفیس با دو ورودی و یک خروجی

که در آن \bar{W}_k ، درجه فعالیت نرمال شده قانون k ام می‌باشد.

لایه چهارم: (گره‌های نتیجه) در این لایه خروجی هر گره برابر است با:

$$O_k^4 = \bar{W}_k f_k = \bar{W}_k (p_k x + q_k y + r_k) \quad (\text{رابطه ۷})$$

$r = 1, 2$

لایه پنجم: (گره‌های خروجی) در این لایه هر گره مقدار خروجی نهایی را به صورت زیر محاسبه می‌نماید (تعداد گره‌ها برابر تعداد خروجی‌هاست):

$$O_k^5 = \sum_{k=1}^N \bar{W}_k f_k \quad (\text{رابطه ۸})$$

از نظر عملی، جهت تعیین ساختمان از دانستنی‌های تجربی (ورودی‌های مربوطه، تعداد توابع عضویت هر ورودی، تعداد قوانین، نوع مدل فازی و ...) و از داده‌های عددی جهت شناسایی پارامترها (تعیین مقادیر پارامترهایی که بهترین عملکرد را تولید می‌کنند) استفاده می‌شود (Fatehi Marj, 2000).

در این پژوهش به منظور تحلیل انواع روش‌های شبکه‌های عصبی از نرم‌افزار MATLAB نسخه 2015b استفاده گردید. بر این اساس داده‌های موجود (۵۰۶ داده) به دو دسته آموزش و آزمایش تقسیم شدند. عملکرد دو روش MLP و RBF با در نظر گرفتن

این است که با کاربرد الگوریتم پس انتشار خطا به حداقل سازی خطا پرداخته می‌شود. (Jang et al., 1997).

پنج مرحله‌ای که در فرایند استنباط فازی بایستی انجام گیرد عبارتند از: (۱) فازی‌سازی متغیرهای ورودی، (۲) به‌کار بردن عملگرهای (و؛ یا) در بخش مقدمه، (۳) استنتاج از مقدمه به نتیجه، (۴) ترکیب نتایج قوانین و (۵) غیرفازی کردن (Hesami Rostami et al., 2005).

غالباً سامانه‌های ANFIS را با استفاده از یک سامانه فازی

پنج لایه این نوع مدل به شرح زیر تشکیل می‌شود:

لایه اول: (گره‌های ورودی) در این لایه درجه عضویت گره‌های ورودی به بازه‌های مختلف فازی با استفاده از تابع عضویت مشخص می‌گردد:

$$O_k^1 = \mu_{A_k}(x) \quad k = 1, 2 \quad (\text{رابطه ۴})$$

$$O_k^1 = \mu_{B_{k-2}}(y) \quad k = 3, 4$$

که در آن $\mu_{A_k}(x)$ ، درجه عضویت x در مجموعه فازی A_k ، $\mu_{B_{k-2}}(y)$ ، درجه عضویت y در مجموعه فازی B_{k-2} می‌باشد. توابع عضویت می‌توانند به صورت تابع زنگوله‌ای، مثلثی، گوسی و انواع دیگر باشند.

لایه دوم: (گره‌های قاعده) هر گره در این لایه درجه فعالیت یک قانون را محاسبه می‌کند:

$$O_k^2 = W_k = \mu_{A_k}(x) \times \mu_{B_k}(y) \quad k = 1, 2 \quad (\text{رابطه ۵})$$

که در آن $\mu_{B_k}(y)$ ، درجه عضویت y در مجموعه فازی B_k و W_k درجه فعالیت قانون k ام است.

لایه سوم: (گره‌های میانگین) در این لایه k امین گره، نسبت درجه فعالیت قانون k ام، را به مجموع درجه فعالیت کلیه قوانین به صورت زیر نرمال‌سازی می‌کند:

$$O_k^3 = \bar{W}_k = \frac{W_k}{\sum_{k=1}^N W_k} \quad k = 1, 2 \quad (\text{رابطه ۶})$$

تخمین دمای داخل گلخانه می توان استفاده کرد. زیرا استفاده از این سه متغیر منجر به ایجاد خطای پیش بینی کمتر (RMSE و MAPE کمتر) در مقایسه با سایر ترکیبات حس گری بود. لذا در ادامه برای مدل سازی و ارائه نتایج از داده های این سه حس گر به عنوان سه متغیر ورودی مدل های شبکه های عصبی (MLP، RBF و ANFIS) استفاده خواهد شد.

جدول ۲- انتخاب بهترین گروه متغیرها برای پیش بینی دمای داخل گلخانه توسط مدل MLP

متغیرهای خروجی گلخانه	RMSE	MAPE	TSSE
سرعت باد (V)	۵/۳۳	۱۵/۳۰	۱۴۳۵۰/۵۸
تابش خورشید (S)	۳/۳۴	۹/۶۹	۵۶۳۲/۳۲
دمای هوای بیرون گلخانه (T _{out})	۲/۹۲	۸/۱۷	۴۳۱۹/۸۹
رطوبت هوای خارج گلخانه (H _{out})	۳/۸۲	۱۱/۰۸	۷۳۹۸/۷۰
T _{out} , S	۲/۴۶	۶/۳۳	۳۰۵۷/۱۶
H _{out} , S	۲/۹۳	۸/۲۹	۴۳۳۶/۲۳
H _{out} , T _{out}	۲/۸۷	۷/۵۶	۴۱۷۱/۴۳
H _{out} , T _{out} , S	۲/۲۵	۵/۷۵	۲۵۵۸/۷۴

نتایج مدل MLP و RBF

براساس نتایج مشاهده شده در جدول (۲) بهترین متغیرهای ورودی برای پیش بینی روش MLP شامل دمای هوای خارج گلخانه، رطوبت نسبی هوای خارج گلخانه و شدت تابش خورشید بودند. به منظور اطمینان از دستیابی به قابلیت تعمیم پذیری و ممانعت از بیش برازشی مدل های شبکه عصبی مصنوعی MLP و RBF در سطح های مختلفی از مجموعه آموزش و تست استفاده شد که نتایج این ارزیابی در جدول (۳) آورده شده است. همان طور که نتایج نشان می دهد کاهش مجموعه داده های آموزش منجر به افزایش خطا می شود، لذا بهتر است از مجموعه داده بیشتر یعنی ۸۰ درصد استفاده شود. مقایسه نتایج مدل MLP و RBF نشان می دهد که مدل RBF در مقایسه با مدل MLP از قابلیت تعمیم پذیری بالاتری برخوردار است. تاکی و همکاران (۲۰۱۶)، در تحقیقی مشابه برای پیش بینی دمای هوا و دمای سقف واقع در گلخانه نیمه خورشیدی داده ها را به چهار گروه برای آموزش روش شبکه عصبی مصنوعی تقسیم کردند و بهترین درصد از کل داده ها برای آموزش با توجه به خطای پایین تر انتخاب شد (Taki et al., 2016a). بررسی نتایج تحقیق فوق با تغییر مجموعه داده ها نشان داد در نظر گرفتن میزان ۸۰ درصد از داده ها برای آموزش مدل موجب خطای کمتر می گردد.

۸۰، ۷۰ و ۶۰ درصد برای آموزش (۲۰، ۳۰ و ۴۰ درصد برای آزمایش) مورد ارزیابی قرار گرفت و بهترین مجموعه برای آموزش و آزمایش در این دو روش انتخاب گردید. تقسیم بندی مجموعه داده ها برای مدل ANFIS براساس نتایج دو مدل MLP و RBF بود. در این مطالعه برای مدل سازی مقدار ضریب یادگیری ۰/۷ و تعداد تکرار ۵۰۰ در نظر گرفته شد. همچنین مقدار ضریب یادگیری معیارهای ضریب تبیین (R²)، جذر میانگین مربعات خطا (RMSE)، میانگین درصد خطای مطلق (MAPE) و مجموع کل مربعات خطا (TSSE) به عنوان مبنا جهت تحلیل نتایج این روش ها مورد استفاده قرار گرفتند.

نتایج و بحث

با توجه به اینکه کنترل دمای گلخانه به منظور بالا بردن عملکرد و کیفیت، کاهش هزینه ها، کنترل آفات و بیماری ها و ... ضروری می باشد، لذا در این تحقیق به پیش بینی دما توسط مدل های مختلف شبکه های عصبی مصنوعی پرداخته شد. از آنجایی که در شهرستان جیرفت در برخی از فصول سال دمای هوا بالاست و بنابراین دمای گلخانه های این منطقه به تبعیت از هوای محیط بیرون افزایش می یابد، می توان با توجه به نتایج حاصل از این تحقیق و پیش بینی دما در آینده علاوه بر مدیریت مناسب و به موقع، هدررفت انرژی را کاهش داد. لذا در نتیجه استفاده مؤثر از انرژی در گلخانه های این منطقه مشکلات زیست محیطی کاهش و کشاورزی پایدار به عنوان یک سامانه تولیدی اقتصادی توسعه می یابد.

انتخاب حس گرهای مؤثر در تخمین دمای داخل گلخانه

با توجه به هزینه های بالای حس گرها و همچنین کاربردی تر کردن روش های مورد استفاده در این تحقیق با ورودی های کمتر و راحت تر از تحلیل حساسیت در مدل MLP به عنوان یک نمونه برای ارزیابی قابلیت هر یک از حس گرها در تخمین دمای داخل گلخانه استفاده شد. از ترکیبات مختلف متغیرهای محیطی شامل سرعت باد (V)، تابش خورشید (S)، دمای هوای بیرون گلخانه (T_{out})، رطوبت هوای خارج گلخانه (H_{out}) در تخمین دمای داخل گلخانه به کمک مدل MLP استفاده شد. همان طور که نتایج جدول (۲) نشان می دهد متغیر سرعت باد سبب ایجاد بیشترین خطا در روش MLP می شود و این نشان دهنده جریان هوای آرام در روزهای آزمایش و در نتیجه کاهش خطر همرفتی بود. بنابراین از بین حس گرهای استفاده شده از حس گرهای تابش سنج، دماسنج و رطوبت سنج به عنوان بهترین ترکیب حس گرها جهت


جدول ۳- ارزیابی قابلیت تعمیم پذیری دو مدل MLP و RBF

RBF			MLP			درصد داده‌ها برای آموزش (%)
TSSE	MAPE	RMSE	TSSE	MAPE	RMSE	
۴۸۴/۵۸	۲/۹۹	۰/۹۸	۳۴۳۲/۸۳	۷/۱۵	۲/۶۵	۶۰
۴۰۵/۷۳	۲/۳۸	۰/۹۰	۳۳۲۹/۲۰	۶/۹۳	۲/۵۷	۷۰
۳۱۷/۳۵	۲/۲۳	۰/۷۹	۲۵۵۸/۷۴	۵/۷۵	۲/۲۵	۸۰


پیش‌بینی دما توسط الگوریتم آموزش LM با تعداد ۱۹ و ۲۱ نرون در لایه مخفی به ترتیب برای روش MLP و RBF بدست آمد. بنابراین شبکه با ساختار ۱-۱۹-۳ برای مدل MLP و ۱-۲۱-۳ برای مدل RBF دارای کمترین میزان خطا ($RMSE=2/1^{\circ}C$) برای فاز آموزش و $RMSE=2/48^{\circ}C$ برای فاز آزمایش در مدل MLP و $RMSE=0/82^{\circ}C$ برای فاز آموزش و $RMSE=0/89^{\circ}C$ برای فاز آزمایش در مدل RBF می‌باشد و می‌تواند به عنوان بهترین ساختار شبکه در پیش‌بینی دمای داخل گلخانه مورد استفاده قرار گیرد. در تحقیقی مشابه توسط تاکی و همکاران (۲۰۱۶، در شهرستان تبریز دمای خاک و رطوبت نسبی هوای یک گلخانه نیمه خورشیدی توسط مدل MLP تخمین زده شد، Taki et al., 2016b). نتایج آن‌ها نشان داد که شبکه عصبی با ساختار ۱-۹-۴ با مقدار $RMSE$ برابر با ۱/۱۹۵۶ درجه سلسیوس برای پیش‌بینی دمای خاک و شبکه عصبی با ساختار ۱-۹-۴ با مقدار $RMSE$ برابر با ۱/۲۵۰۲ درصد برای پیش‌بینی رطوبت نسبی هوا به عنوان بهترین ساختار می‌تواند استفاده شود. مقایسه خطای ایجاد شده توسط روش MLP و RBF مورد استفاده در هر دو تحقیق نشان داد که مدل RBF دارای دقت بیشتر در پیش‌بینی می‌باشد. بنابراین استفاده از این روش برای هوشمندسازی گلخانه‌های شهرستان جیرفت دارای ارجحیت می‌باشد.

به منظور آموزش شبکه و اصلاح وزن‌ها تا رسیدن به یک خطای قابل قبول از الگوریتم‌های آموزشی استفاده می‌شود. در این تحقیق ۱۳ تابع آموزشی برای روش الگوریتم آموزشی پس انتشار خطا مورد بررسی قرار گرفت. همان طور که در شکل (۴) مشاهده می‌شود مقادیر ضریب تبیین (R^2) حاصله از به‌کارگیری تابع LM (لونبرگ مارکوات) نسبت به سایر توابع (مقدار ضریب تبیین برابر ۰/۸۲ برای روش MLP و مقدار ضریب تبیین برابر ۰/۹۳ برای روش RBF) بالاتر بود. در تحقیق دیگر که توسط شجاعی و همکاران ۲۰۱۸ انجام شد، نتایج مقایسه سه الگوریتم LM، BR و SCG نشان داد که الگوریتم LM بهترین تخمین را برای دمای گلخانه در حالت مجهز به سامانه سرمایش تبخیری داشت (Shojaei et al., 2018).


با توجه به اینکه شبکه عصبی در صورت داشتن داده‌های کافی در مرحله آموزش تنها با یک لایه مخفی و تعداد نرون‌های کافی قادر به تخمین هر تابع پیوسته با دقت قابل قبول می‌باشد (Hykin, 1994)، عملکرد هر دو مدل MLP و RBF با الگوریتم آموزش LM برای دو فاز آموزش و آزمایش در شبکه‌های تک لایه با تعداد ۳ تا ۲۵ نرون مورد ارزیابی قرار گرفت. برای تعیین مناسب‌ترین توپولوژی شبکه (تعداد نرون‌ها در لایه مخفی) از روش آزمون و خطا استفاده گردید. با توجه به شکل (۵) و نتایج بدست آمده از جذر میانگین مربعات خطا می‌توان گفت مناسب‌ترین



شکل ۴- ارتباط بین الگوریتم‌های یادگیری و ضریب تبیین در دو مدل MLP و RBF



(a)



(b)

شکل ۵- ارتباط بین تعداد نرون ها در لایه مخفی و RMSE توسط دو مدل MLP (a) و RBF (b)

در هر سه روش توابع عضویت گوسی و خطی به ترتیب به عنوان توابع ورودی و خروجی دارای عملکرد بهتری بود. نتایج نشان داد که از بین سه روش ساخت سامانه استنتاج فازی روش SC به عنوان بهترین گزینه انتخاب شد. در تحقیقی که توسط آتیا و همکاران ۲۰۱۶ انجام شد از روش فازی-عصبی تطبیقی (ANFIS) برای تنظیم دمای داخلی گلخانه به مقدار مورد نیاز استفاده شد. نتایج شبیه سازی نشان گر این امر بود که کنترلر انفیس (ANFIS) به دلیل مقدار MAE و RMSE به ترتیب برابر با ۰/۰۰۷۴ و ۰/۱۹۷۷ به عنوان روشی سریع و مؤثر خواهد بود (Atia *et al.*, 2016).

مقایسه عملکرد مدل های شبکه های عصبی مصنوعی

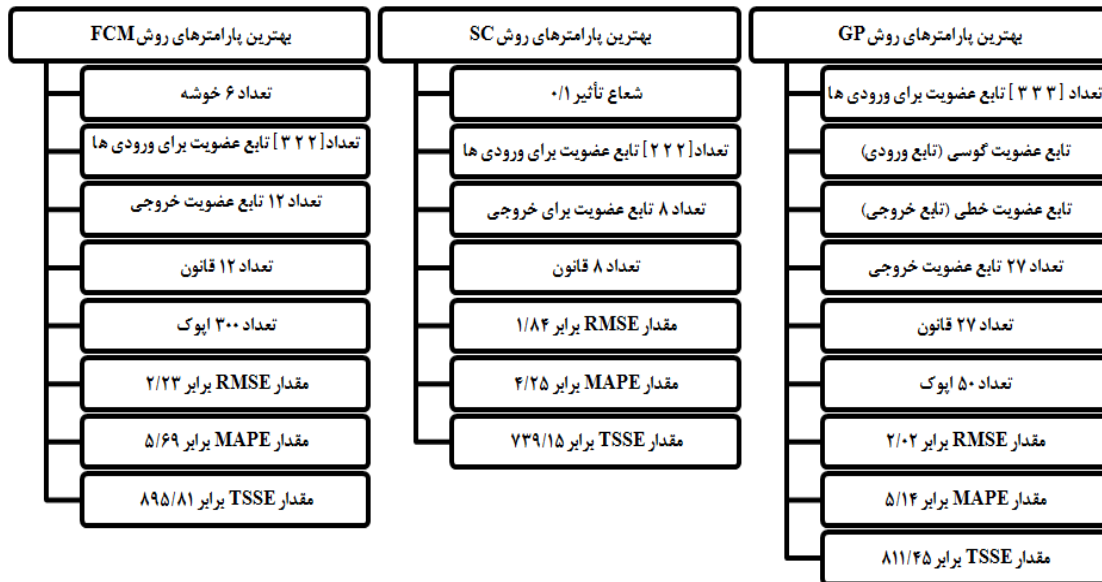
بر اساس نتایج بدست آمده پارامترهای بهینه هر یک از سه مدل MLP، RBF و ANFIS، در این بخش برای انتخاب بهترین مدل پیش بینی کننده دمای داخل گلخانه از معیار توافق بین مقادیر آزمایشگاهی و پیش بینی شده استفاده شد. بر اساس این معیار هر چه ضریب تبیین به یک و شیب خط و عرض از مبدأ خط رگرسیونی مابین داده های واقعی و پیش بینی شده به یک و صفر نزدیک باشد، بهترین نتیجه حاصل می گردد. بر این اساس و مطابق شکل (۷)، مدل RBF به دلیل ضریب تبیین نزدیک به یک (۰/۹۳)، میزان عرض از مبدأ ۲/۰۲ و میزان شیب خط ۰/۹۳ دارای نتایج بهتر بوده و بنابراین مقدار خطا در پیش بینی کمتر و استفاده از این روش برای پیش بینی دمای داخل گلخانه قابل اطمینان تر می باشد. در مطالعه ای حمدانی و همکاران ۱۳۹۷، از دو مدل شبکه عصبی مصنوعی MLP و RBF برای تخمین دمای هوا و گیاه، سقف و رطوبت هوای داخل در یک گلخانه دوطرفه شیشه ای واقع در شهر ملائانی اهواز استفاده کردند (Hamdani

نتایج مدل ANFIS

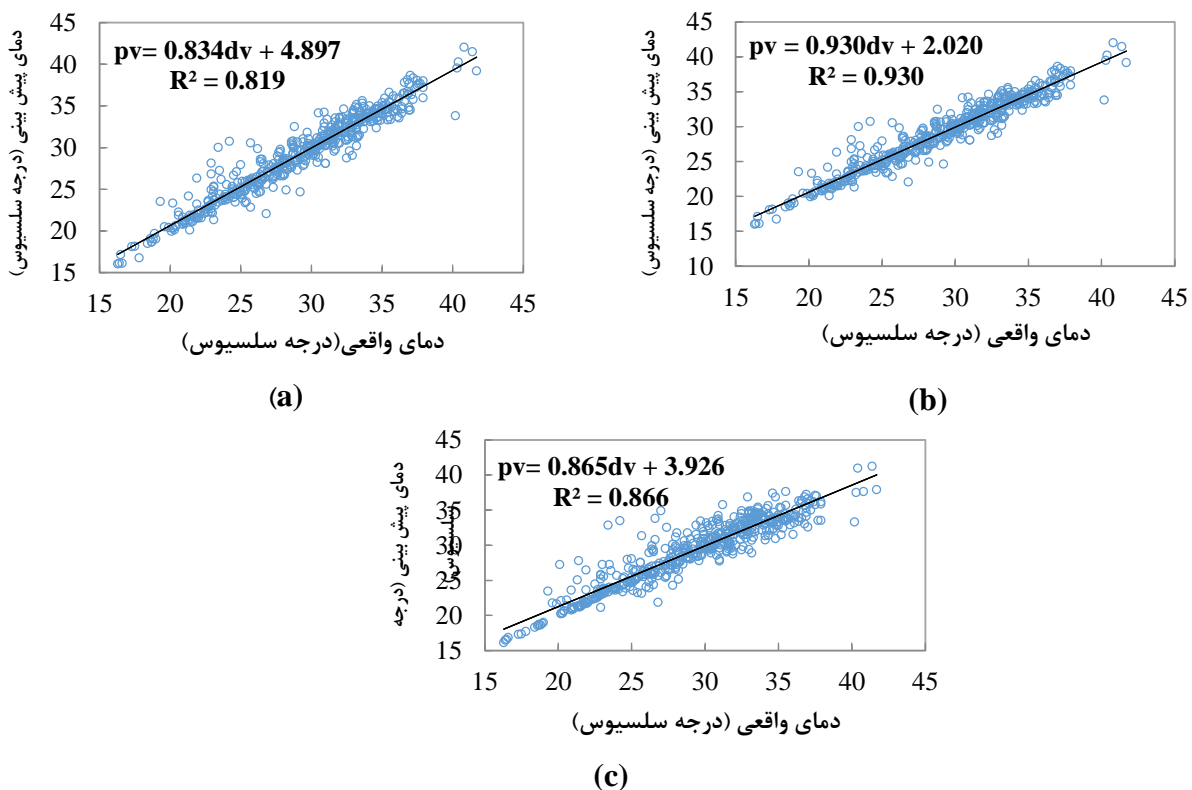
استخراج دمای داخل گلخانه بر اساس قوانین فازی در مدل انفیس با در نظر گرفتن سه متغیر ورودی شامل تابش خورشید، دمای هوا و رطوبت بیرون گلخانه (همانند دو روش MLP و RBF) صورت گرفت. در این تحقیق، روش های گسسته سازی شبکه-ای (GP)، خوشه بندی کاهشی^۲ (SC) و خوشه بندی فازی (FCM) برای ساختار^۳ FIS مورد استفاده قرار گرفت. برای ارزیابی هر یک از روش های مذکور، پارامترهای جداگانه و ترکیبات مختلف آن ها مورد بررسی قرار گرفت و نتایج آن در شکل (۶) نشان داده شده است. در روش GP با بهره گیری از الگوریتم گسسته سازی شبکه ای، برای پارامترهای ورودی مدل انفیس با به کار بردن سه نوع از توابع عضویت مثلثی (trimf)، زنگوله ای (gbellmf) و گوسی (gaussmf) برای دو تعداد از توابع عضویت (۲ و ۳ عدد) مقادیر خطا محاسبه گردید. باتوجه به نتایج حاصله، تابع گوسی به عنوان بهترین تابع عضویت برای پیش بینی دمای داخل گلخانه بود و از بین دو تابع خطی و ثابت در نظر گرفته شده به عنوان توابع عضویت خروجی، تابع خطی نتیجه ای بهتر داشت. ارزیابی عملکرد روش SC با مقایسه شاخص های خطای بدست آمده حاصل از آزمایش و خطا نشان داد که شعاع بهینه برای داشتن بهترین ساختار سامانه استنتاج تطبیقی فازی مقدار برابر ۰/۵ می باشد که قادر است دمای داخل گلخانه را با خطای کمتر پیش بینی نماید. روش خوشه بندی فازی برای پیش بینی دمای گلخانه با تغییر تعداد خوشه های متفاوت برای ایجاد بهترین ساختار انجام شد. نتایج بیانگر آن است که مناسب ترین تعداد خوشه ها به جهت بهترین پیش بینی شش می باشد که توانسته دمای داخل گلخانه را با خطای کمتر پیش بینی نماید.

برای فاز آموزش و آزمایش برای تخمین دمای سقف از دقت بیش‌تری نسبت به مدل MLP برخوردار است.

(*et al.*, 2018). نتایج این تحقیق نشان داد که مدل RBF با ضریب تبیین ۰/۹۹ برای تخمین دمای هوا و گیاه و رطوبت هوا برای هر دو فاز آموزش و آزمایش و ضریب تبیین ۰/۹۷ و ۰/۹۸ به ترتیب



شکل ۶- نتایج حاصل از اجرای روش های مختلف انفیس




شکل ۷- مقایسه بین مقدار واقعی و پیش‌بینی شده مدل های MLP (a)، RBF (b) و ANFIS (c)

گردد می‌رسد، در حالی که متوسط دمای بهینه برای رشد گیاه خیار ۲۰ تا ۲۵ درجه سانتی‌گراد می‌باشد، به ارزیابی پیش‌بینی دما در چند ساعت آینده در گلخانه مورد بررسی پرداخته شد.


ارزیابی عملکرد مدل RBF در پیش‌بینی دما در ساعات آینده با توجه به اینکه در طول مدت زمان داده‌برداری برای انجام این تحقیق، در برخی از ساعات روز دما به بیش از ۴۰ درجه سانتی

باعث افزایش خطا می‌گردد. با توجه به نتایج و در نظر گرفتن خطای قابل قبول برای پیش‌بینی، می‌توان بیان کرد که مدل RBF قابلیت پیش بینی دما را تا دو ساعت آینده در گلخانه دارد و کشاورز می‌تواند با اطمینان با توجه به نتایج این مدل، دو ساعت قبل از بالا رفتن دما در گلخانه با انجام عملیات‌هایی از قبیل باز کردن دریچه‌ها، کاهش ورود نور به گلخانه از طریق پرده‌های سایه انداز و یا استفاده از رنگ و یا مواد گچی، سامانه مه‌پاش، آب پاشی روی سقف گلخانه و سایر روش‌ها از بالا رفتن دما جلوگیری و در مصرف انرژی صرفه جویی نماید.


پیش بینی دما در ساعات پیشین به گلخانه‌داران کمک می‌کند که قبل از افزایش دما تمهیدات لازم برای پایین آوردن دما و ایجاد شرایط مطلوب برای رشد گیاه را فراهم نمایند. لذا در این تحقیق جهت بررسی این امر پس از شناسایی بهترین مدل (RBF) برای پیش‌بینی دما در گلخانه، عملکرد این مدل به مدت ۳۰ روز در فواصل زمانی ۱ ساعت آینده، ۲ ساعت آینده، ۴ ساعت آینده و ۶ ساعت آینده مورد ارزیابی قرار گرفت. همان‌طوری که در شکل (۸) مشاهده می‌شود، در نظر گرفتن دمای هوای گلخانه برای فواصل زمانی طولانی‌تر در آینده




A ($R^2=0.91$)



B ($R^2=0.89$)



C ($R^2=0.83$)



D ($R^2=0.75$)

شکل ۸- نتایج پیش‌بینی مدل RBF برای فواصل زمانی مختلف یک ساعت آینده (A)، دو ساعت آینده (B)، چهار ساعت آینده (C)، شش ساعت آینده (D)

روش MLP از نظر تعمیم‌پذیری و ممانعت از بیش‌برازشی نشان داد در نظر گرفتن ۸۰ درصد از مجموع داده‌ها برای آموزش این مدل باعث کاهش خطا می‌گردد. در این تحقیق ۱۳ تابع آموزشی برای روش الگوریتم پس انتشار خطا برای آموزش دو روش MLP و RBF مورد بررسی قرار گرفتند. بهترین تابع برای آموزش هر دو مدل، تابع LM (لونبرگ مارکوات) با مقدار ضریب تبیین برابر ۰/۹۳ برای مدل RBF و ۰/۸۲ برای مدل MLP بود. پس از انتخاب الگوریتم مناسب، ارزیابی عملکرد هر دو مدل MLP و RBF با تغییر تعداد نرون‌ها در لایه مخفی نشان داد که شبکه با ساختار ۳-۱۹-۱ برای مدل MLP و ۳-۲۱-۱ برای مدل RBF

نتیجه‌گیری

هدف از این تحقیق تخمین تغییرات دمای داخل یک گلخانه با پوشش پلی اتیلن در شهرستان جیرفت واقع در استان کرمان براساس داده‌های حاصل از حس‌گرهای بادسنج، تابش سنج، دماسنج و رطوبت‌سنج به عنوان متغیرهای ورودی بود. برای مدل‌سازی دما ابتدا با تحلیل حساسیت توسط روش MLP به انتخاب حس‌گرهای مؤثر در تخمین دمای داخل گلخانه پرداخته و داده‌های حس‌گری که باعث ایجاد خطا در پیش‌بینی می‌گردید نادیده گرفته شد. از سه روش شبکه‌های عصبی مصنوعی شامل RBF، MLP و ANFIS به منظور پیش‌بینی دما استفاده شد. ارزیابی

آینده نشان داد که این مدل قابلیت پیش بینی دما را تا دو ساعت آینده با میزان خطای قابل قبول دارد و کشاورز می‌تواند با توجه به نتایج این مدل دو ساعت قبل از افزایش دما در گلخانه تمهیدات لازم را جهت جلوگیری از بالا رفتن دما و ایجاد شرایط مطلوب برای گیاه فراهم نماید. امید است نتایج این تحقیق در آینده در هوشمندسازی گلخانه‌های کشاورزی شهرستان جیرفت از نظر کنترل شرایط محیطی و در نتیجه صرفه‌جویی در مصرف انرژی مفید واقع شود.

دارای کمترین میزان خطا می‌باشد و می‌تواند به عنوان بهینه‌ترین ساختار شبکه در پیش‌بینی دمای داخل گلخانه مورد استفاده قرار گیرد. مقایسه سه روش به کار گرفته در این تحقیق با در نظر گرفتن آماره ضریب تبیین (R^2)، بیانگر این امر بود که مدل RBF با مقدار ضریب تبیین $0/93$ نسبت به سایر روش‌های مورد استفاده قادر است با دقت بالاتر متغیر دمای داخلی گلخانه مورد نظر را پیش‌بینی نماید. پس از انتخاب مدل RBF به عنوان بهترین مدل، ارزیابی عملکرد این مدل برای پیش‌بینی دما در ساعات

REFERENCES

- Anonymous. (2019). *Statistics of Agricultural Jihad*, From <http://amar.kr.ir/>.
- Atia, D.M & El-madany, H.T. (2016). Temperature control based on ANFIS. *Journal of Electrical Systems and Information Technology*, 1331–15.
- Basarir, A. (2003). Goals of Beef Cattle and Dairy Producers: A Comparison of the Fuzzy Pair -Wise Method and Simple Ranking Procedure. *the Southern Agricultural Economics Association Annual Meeting*, Mobile, AL February 1-5.
- Bot, G.P.A. (1983). Greenhouse Climate: From Physical Processes to a Dynamic Model. *Ph.D. dissertation*, Wageningen Agricultural University, Wageningen, The Netherlands, 101-108.
- Fatehi Marj, H. (2000). Investigating the chaos in dynamic systems. *Master thesis*, Ferdowsi university of mashhad.
- Feng, L.X., Lin, Q.L., Qi, M.G. & Gang, W. (2016). Modeling Greenhouse Temperature by Means of PLSR and BPNN. *35th Chinese Control Conference*, July 27-29, Chengdu, China.
- Ferreira, P.M., Faria, E.A & Ruano, A.E. (2002). Neural network models in greenhouse air temperature prediction. *Neurocomputing*, 43(1), 51–75.
- Grzesiak, W., Blaszczyk, P. & Lacroix R. (2006). Methods of predicting milk yield in dairy cows- Predictive capabilities of Wood's lactation curve and artificial neural networks (ANNs). *Computers and Electronics in Agriculture*, 54(2), 69-83.
- Hagan, MT., Demuth, HB. & Beale, MH. (1996). Neural network design. *PWS Publishing*, Boston, 151-9.
- Hamdani, M., Taki, M., Rahnama, M., Rohani, A. & Rahmati-Joneidabad, M. (2018). Prediction the inside variables of even-span glass greenhouse with special structure by artificial neural network (MLP-RBF) models. *Journal of Agricultural Machinery* (accepted).
- Haykin, S. (1994). *Neural Networks*. MacMillan, New York.
- Hesami Rostami, R., Afshar, A., Mousavi, J. (2005). Flood prediction model using adaptive neural fuzzy inference system and comparison with regression method with case study of Karkheh River. *First annual conference on water resources management in Iran*, Tehran.
- Jang, J.S.R., Sun, C.T. Mizutani, E. (1997). Neuro-fuzzy and soft computing. *Practice Hall, Englewood Cliffs*, NJ, U.S.A.
- Menhaj, M.B. (2000). Basics of Artificial Neural Networks. *Amir Kabir University of Technology Publications*, Tehran, Iran.
- Omid, M. & Shafaei, A. (2004). Investigation of temperature and humidity variations within a greenhouse using a computer based data acquisition sytem. *Journal of pajooresh and sazandeghi*, 17(3), 67-73. (in Farsi)
- Pulido-Calvo, I. & Gutierrez-Estrada, J.C. (2009). Improved irrigation water demand forecasting using a soft- computing hybrid model. *Biosystems Engineering*, 102(2), 202–18.
- Rohani, A., Abbaspour-Fard, M.H. & Abdollahpour, Sh. (2011). Prediction of tractor repair and maintenance costs using artificial neural network. *Expert Systems with Applications*, 38(7), 8999-9007.
- Rohani, A., Taki, M. & Abdollahpour, M. (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.
- Shojaei, M.H., Mortezapour, H., JafariNaimi, K. & Maharlooei, M.M. (2018). Temperature Prediction of a Greenhouse Equipped with Evaporative Cooling System Using Regression Models and Artificial Neural Network (Case Study in Kerman City). *Iranian Journal of Biosystems Engineering*, 49(4), 567-576. (In Farsi)
- Taki, M., AbdananMehdizadeh, S., Rohani, A., Rahnama, M. & Rahmati-Joneidabad, M. (2018). Applied machine learning in greenhouse simulation; new application and analysis. *Information processing in agriculture*, 5(2), 253-268.
- Taki, M., Ajabshirchi, Y., Ranjbar, S.F., Rohani, A. & Matloobi, M. (2016a). 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.
- Taki, M., Ajabshirchi I, Y., Ranjbar, S. F., Rohani, A. & Matloobi, M. (2016b). Prediction of Soil Temperature and Inside air Humidity in a

SemiSolar Greenhouse Equipped with Cement North Wall by Artificial Neural Network; Case study: Tabriz city. *Journal of Agricultural Mechanization*, 3(1), 71-83.

Vadiei, A. (2011). Energy Analysis of the Closed Greenhouse Concept -Toward one Sustainable Energy Pathway. *KTH Industrial Engineering and Management*, Department of Energy Technology,

Division of Heat and Power Technology, SE-100 44 STOCKHOLM.

Yang, C.C., Prasher, S.O., Landry, J.A. & Ramaswamy, H.S. (2003). Development of an herbicide application map using artificial neural networks and fuzzy logic. *Agricultural Systems*, 76(2), 561–574.