

شیه‌سازی شرایط داخلی و بررسی جریان انرژی یک گلخانه نیمه‌دو طرفه شیشه‌ای با هوش مصنوعی و مدل ریاضی

مکیه حمدانی^۱، مرتضی تاکی^{۲*}، مجید رهنما^۱، عباس روحانی^۳، مصطفی رحمتی جنیدآباد^۴

۱. دانش‌آموخته کارشناسی ارشد مکانیزاسیون کشاورزی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان (hamdany.1993@gmail.com)

۲. استادیار گروه مهندسی ماشین‌های کشاورزی و مکانیزاسیون، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان
(mortezataaki@gmail.com; mtaki@asnruk.ac.ir)

۳. استادیار گروه مهندسی ماشین‌های کشاورزی و مکانیزاسیون، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان
(rahnamam2002@yahoo.com)

۴. دانشیار گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه فردوسی مشهد (arohani@um.ac.ir)

۵. استادیار گروه باغبانی، دانشکده کشاورزی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان (mr.joneid@gmail.com)

چکیده

در این تحقیق، دو مدل شبکه عصبی (MLP-RBF) و رگرسیون چندگانه (MLR)، به منظور تخمین چهار متغیر تاثیرگذار شامل دمای هوا، دمای گیاه، دمای سقف و رطوبت هوای داخلی یک گلخانه دو طرفه شیشه‌ای مورد بررسی قرار گرفتند. همچنین میزان تبادل انرژی بین اجزای مختلف این گلخانه توسط مدل‌های تجربی انتقال حرارت، مورد بررسی قرار گرفت. بدین منظور، از فاکتورهای محیطی شامل دما و رطوبت هوای بیرون گلخانه و همچنین تابش در سطح افق، به عنوان ورودی مدل‌ها، استفاده شد. در این مطالعه از دو الگوریتم آموزش بایاس پس‌انتشار خطا (Bayesian regulation backpropagation) و لونبرگ ماکوارت پس انتشار خطا (Levenberg-Marquardt backpropagation) به منظور آموزش هر دو مدل شبکه عصبی استفاده شد. مدل‌های فوق با الگوریتم‌های نهایی موجود، با ۴۰٪ و ۸۰٪ از کل مجموعه‌ی داده‌ها مورد آموزش قرار گرفتند. در این تحقیق به منظور اعتماد هرچه بیشتر به نتایج مدل و همچنین افزایش قابلیت کاربردی بودن نتایج، از روش اعتبارسنجی K-fold استفاده شد. فاکتورهای تاثیرگذار مدل‌های فوق در هر مرحله مورد ارزیابی و بهبود قرار گرفتند. نتایج نشان داد، مدل RBF نسبت به دو مدل دیگر از توانایی بیش‌تری به منظور تخمین متغیرهای فوق، برخوردار است. دقت این مدل، حدود ۵۰٪ نسبت به دو مدل دیگر بیش‌تر بود و همچنین قابلیت کارکرد آن با مجموعه داده‌های کمتر نسبت به بقیه بیشتر بود. همچنین مدل RBF نسبت به سایرین با دقت بیش‌تری میزان تبادل انرژی بین اجزای گلخانه را تخمین زد و می‌تواند در هوشمندسازی این نوع گلخانه مورد استفاده قرار گیرد.

کلمات کلیدی: شبکه عصبی، گلخانه دو طرفه، مدل‌سازی، گلخانه‌های هوشمند، رگرسیون چندگانه

نویسنده مسئول: mortezataaki@gmail.com; mtaki@asnruk.ac.ir



شیبه‌سازی شرایط داخلی و بررسی جریان انرژی یک گلخانه نیمه‌دو طرفه شیشه‌ای با هوش مصنوعی و مدل ریاضی

مقدمه

مدل‌سازی یکی از روش‌های ذهنی بشر است که نه تنها برای اهداف علمی، بلکه برای انجام کارهای روزمره مورد استفاده قرار می‌گیرد. مدل‌ها انواع گوناگونی دارند و از آن‌ها در همه‌ی زمینه‌های علمی و فناوری استفاده می‌شود. اهداف مهم مدل‌سازی، تعیین روابط بین متغیرها، تعیین متغیرهای اثرگذار و پیش‌بینی شرایط مورد نظر است [۱]. یکی از کاربردهای مدل‌سازی در بخش کشاورزی، استفاده از آن‌ها به منظور تخمین پیامدهای پیش‌رو و آگاهی کشاورز از اوضاع قریب‌الوقوع است. آگاهی از شرایط پیش‌رو و مدیریت آن، نه تنها رشد گیاهان را تحت تاثیر قرار می‌دهد، بلکه عامل مهمی در کنترل آفات و بیماری‌هاست و از هدررفت انرژی نیز جلوگیری می‌کند [۲].

مصرف بی‌رویه انرژی در اکثر گلخانه‌های ایران، باعث افزایش قیمت تمام‌شده‌ی محصول، آلودگی محیط‌زیست و هدررفت منابع با ارزش فسیلی طی دهه‌های گذشته شده است [۳]. از طرفی، توسعه چشم‌گیر انواع گلخانه‌ها در کشور در حالی به وقوع پیوسته که به علت ضعف در فناوری‌های موجود، مصرف انرژی به ازای تولید هر واحد محصول، تا چندین برابر بیش‌تر از میانگین‌های جهانی است [۴ و ۵]. 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 این راستا تحقیقات بسیار اندکی انجام گرفته است [۶]. 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 [۷]. از طرفی کشاورز پس از مواجه شدن با شرایط بد آب و هوایی و کاهش دمای داخل گلخانه به فکر چاره می‌افتد و این درحالی است که بخش مهمی از انرژی داخلی گلخانه به هدر رفته است. 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، CO₂ و ...) 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 ... است [۸ و ۹].

مطالعات اولیه در زمینه مدل‌سازی شرایط داخلی گلخانه، بیش‌تر به‌منظور معرفی این ابزار و روش کارکرد آن بود ولی به مرور تحقیقات متنوعی شامل کنترل شرایط محیطی داخل گلخانه [۱۰]، مدل‌سازی فیزیکی گلخانه [۱۱] و پیش‌بینی برخی از پارامترهای داخلی گلخانه انجام گرفت [۱۲-۱۶]. در تحقیقی از شبکه‌های عصبی مصنوعی به منظور ابزاری برای جایگزین کردن انواع سنسورها در گلخانه استفاده شد [۱۷]. در این مطالعه به منظور 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 به درستی قادر است میزان تغییرات دمای هوای داخل گلخانه‌ای با کشت هیدروپونیک را تخمین بزند ولی به منظور 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 نیمه-خورشیدی، پرداخته شد [۵]. 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، از مدل شبکه عصبی و مدل‌های رگرسیونی برای پیش‌بینی درصد رطوبت و دمای هوای

داخلی گلخانه‌ای در مراکش استفاده شد [۱۸]. در این تحقیق، رطوبت نسبی هوای بیرون گلخانه، شدت تابش خورشید روی سطح افق، جهت و سرعت باد و همچنین دمای هوای بیرون گلخانه به عنوان متغیرهای ورودی و دما و درصد رطوبت داخلی گلخانه به عنوان خروجی مدل در نظر گرفته شد. نتایج نشان داد که شبکه عصبی قادر است نتایج بهتری نسبت به انواع مدل‌های کلاسیک رگرسیون 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 [۱۹-۲۱].

با توجه به نتایج تحقیقات فوق، هدف از این مطالعه، مقایسه بین دو مدل شبکه عصبی (MLP-RBF) با رگرسیون خطی چندگانه (MLR) به منظور تخمین پارامترهای موثر یک گلخانه نیمه 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 به ندرت مورد بررسی قرار گرفته است. در این تحقیق همراه با روش‌های مرسوم از نسبت‌های مختلف داده‌های آموزشی به منظور یافتن بهینه مقدار داده‌های آموزش مدل و همچنین از روش K-fold به منظور افزایش قابلیت اطمینان به نتایج نیز استفاده می‌شود. در قسمت بعدی، نتایج این بررسی و مدل‌سازی، به منظور تخمین میزان انرژی بین اجزای مختلف این سازه گلخانه‌ای با استفاده از روابط انتقال حرارت، مورد بررسی قرار خواهد گرفت. مقایسه بین این دو نوع مدل (ریاضی با هوش مصنوعی) می‌تواند به درستی میزان خطا در هر دو نوع مدل را مشخص کرده و در آینده برای کنترل هوشمند گلخانه‌های کشاورزی و پیشگیری از اتلاف حرارت 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 (یک گلخانه نیمه دوطرفه که در عمق یک و نیم متری زمین احداث شده 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 ± 0.4 درجه سانتی‌گراد و ± 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 بادقتی در حدود ۵٪ برداشت کند. داده‌های سرعت باد توسط بادسنج مدل DT186 با قابلیت ذخیره ۳۲۰۰۰ داده در بازه ۱/۱ تا ۲۰ متربرثانه، برداشت شد.

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 پارامترهای صحیح شبکه به منظور دستیابی به کم‌ترین خطای پیش‌بینی است

[۲۲]. قبل از به‌کارگیری 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 [۰/۹ - ۰/۱] می‌باشد [۲۳]. در این مطالعه از دو الگوریتم آموزش بایاس پس-انتشار خطا (Bayesian regulation backpropagation or Trainbr) و لونبرگ ماکوارت پس انتشار خطا (Levenberg-Marquardt or Trainlm backpropagation) استفاده شد. بر اساس یک قانون جهانی، معمولاً بهترین شبکه‌ها با تعداد یک لایه پنهان مشخص می‌شوند [۲۴]. 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 RBF^۱ 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. 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 (Φ) 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 [۲۳]:

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

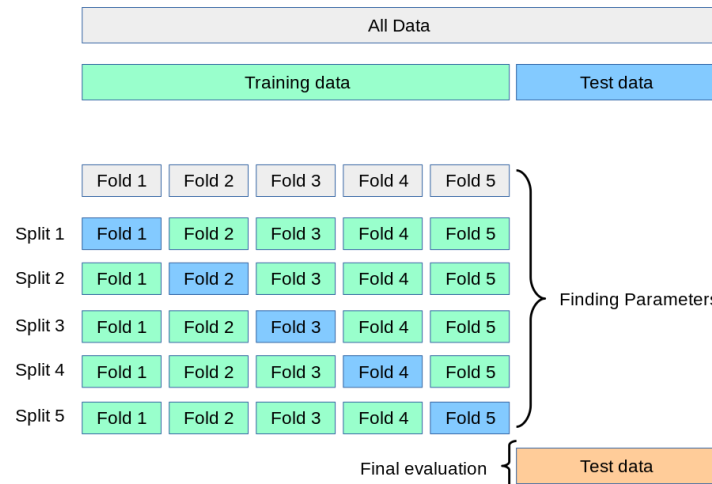
که در آن، w_{ij} بردار وزن اتصالات بین لایه مخفی و خروجی، L_2 تعداد نرون‌ها در لایه مخفی، c_i مرکز نرون‌ها در لایه مخفی و Φ تابع گوسین می‌باشد. مقدار (Φ) نیز از رابطه زیر قابل محاسبه است [۲۳]:

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

که در آن، σ پارامتر توزیع^۳ است.

در این تحقیق به منظور افزایش اعتماد به خروجی شبکه عصبی از یک روش جدید و ابتکاری به نام اعتبارسنجی دسته‌ای^۴ استفاده شد (شکل ۱). 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 افزای 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 [۲۵]. 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.

1-Radial Bias Function
1-Spread parameter
2-K-fold cross validation



شکل ۱- روش اعتبارسنجی دسته‌ای (K-fold)

پس از جمع‌آوری اطلاعات مورد نیاز، از مدل رگرسیون خطی چندگانه به منظور تخمین متغیرهای مورد بررسی استفاده شد. بدین منظور متغیرهای مستقل مدل رگرسیونی برای تشخیص دمای هوا، گیاه، سقف و رطوبت گلخانه شامل: دمای هوای بیرون گلخانه، شدت تابش روی سطح افق، سرعت باد و رطوبت هوای بیرون گلخانه نظر گرفته شد. در رگرسیون ساده، رابطه زیر مورد استفاده قرار می‌گیرد:

$$Y = \beta_0 + \beta_r \sum_{r=1}^3 x_r \quad (3)$$

در رابطه فوق، β_0 مقدار ثابت عرض از مبدا، x_r متغیرهای مستقل و β_r مقادیر ضرایب آن‌هاست [۲۶].

قسمت دوم این تحقیق به بررسی استفاده از نتایج مدل رگرسیونی در تخمین میزان تبادلات انرژی بین اجزای مختلف گلخانه مورد بررسی می‌پردازد. در این راستا از برخی مدل‌های مرسوم انتقال حرارت در گلخانه‌های شیشه‌ای استفاده شد. هدف این بخش مقایسه بین نتایج پیش‌بینی مدل‌ها با مقادیر واقعی و بررسی میزان اختلاف و تخمین تقریبی میزان انرژی تبادل شده در گلخانه است. در این رابطه سه نوع مدل ریاضی به شرح زیر مورد بررسی قرار گرفت:

۱. انتقال حرارت همرفتی مابین سطح گیاه و هوای داخلی گلخانه (Q_{a-p}) که از رابطه زیر بدست آمد [۲۷]:

$$Q_{a-p} = A_p \times \alpha_{a-p} (T_a - T_p) \quad (4)$$

در این معادله T_p و T_a به ترتیب دمای هوای گلخانه و دمای سطح گیاه می‌باشند. مساحت سطح گیاه (A_p) بر اساس شاخص سطح برگ $LAI \left\{ m^2 \{leaf\} / m^2 \{soil\} \right\}$ که یک شاخص بی‌بعد است محاسبه شد:

$$A_p = 2 \times LAI \times A_s \quad (5)$$

در رابطه فوق، A_s معادل مساحت سطح خاک گلدان بر حسب مترمربع است. شاخص سطح برگ معادل سطح برگ گیاه به سطح زمینی است که توسط گیاه اشغال شده است. برای مثال اگر شاخص سطح برگ گیاهی ۳ باشد یعنی در یک متر مربع از سطح زمین، سه مترمربع سطح برگ گیاه وجود دارد. شاخص سطح برگ از ۳ تا ۱۰ برای گیاهان مختلف، متفاوت است و هرچه مقدار آن بیشتر باشد، مقدار تبخیر و تعرق گیاه نیز افزایش می‌یابد [۲۷]. عدد ۲ در معادله فوق بیان‌گر این است که در محاسبه مساحت سطح گیاه باید به هر دو طرف برگ توجه داشت. این درحالی است که LAI فقط مربوط به یک سمت گیاه است. ضریب انتقال حرارت بین هوای داخل گلخانه و سطح گیاه (α_{a-p}) از رابطه زیر محاسبه شد [۲۶]:

$$\alpha_{a-p} = \rho_a \times c_{p-a} / R_{b-heat} \quad (6)$$

در این رابطه، ρ_a چگالی هوا و c_{p-a} ظرفیت گرمای ویژه آن است. R_{b-heat} مقاومت لایه مرزی برگ در مقابل انتقال حرارت توسط همرفت می‌باشد که از رابطه زیر محاسبه شد [۲۶]:

$$R_{b-heat} = \frac{1174\sqrt{l_f}}{(l_f \times |T_p - T_a| + 207v_a^2)^2} \quad (۷)$$

در رابطه فوق l_f میانگین عرض برگ گیاه کشت شده و v_a نیز سرعت باد داخل گلخانه می‌باشد که برای گلخانه‌های بدون سیستم تهویه اجباری عدد ۰/۰۹ متر بر ثانیه در نظر گرفته می‌شود [۲۶].

انتقال حرارت همرفت مابین هوای گلخانه با بخش داخلی سقف (Q_{a-ri}) که از رابطه زیر محاسبه شد [۲۷]:

$$Q_{a-ri} = A_r \times \alpha_{a-ri}(T_a - T_{ri}) \quad (۸)$$

در این رابطه T_a و T_{ri} به ترتیب دمای هوای داخل گلخانه و دمای قسمت داخلی سقف گلخانه و A_r مساحت سقف گلخانه است. ضریب انتقال حرارت مابین هوای داخل گلخانه و قسمت داخلی سقف از رابطه زیر محاسبه شد [۸]:

$$\alpha_{a-ri} = 3|T_a - T_{ri}|^{1/3} \quad (۹)$$

انتقال حرارت تابشی بین قسمت داخلی سقف گلخانه و سطح گیاه (Q_{ri-p}) را می‌توان توسط رابطه زیر محاسبه کرد [۸]:

$$Q_{p-ri} = A_r \times E_{ri} \times E_p \times F_{ri-p} \times \sigma(T_{ri}^4 - T_p^4) \quad (۱۰)$$

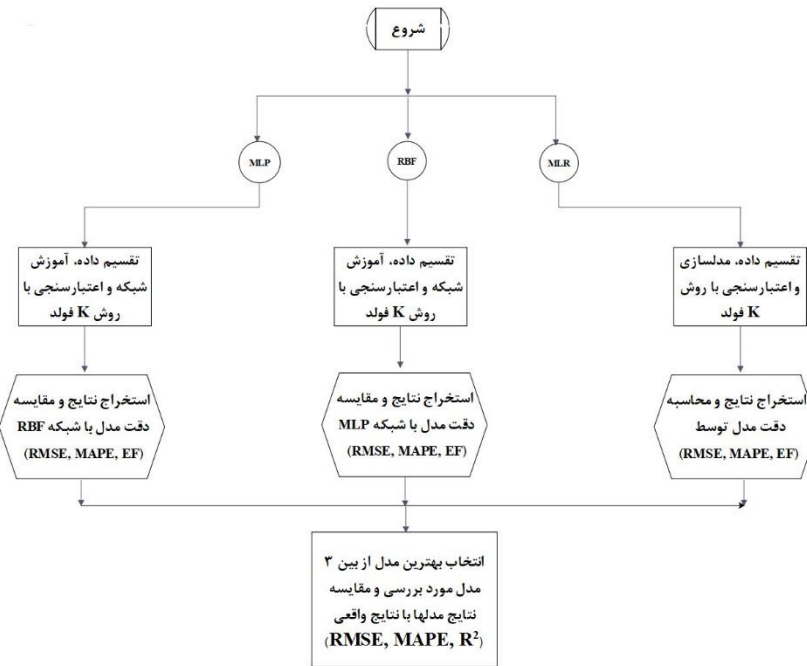
در رابطه فوق A_r مساحت سقف گلخانه و F_{ri-p} فاکتور دید بین قسمت داخلی سقف گلخانه و گیاه است که برای گلخانه شیشه‌ای دوطرفه ۰/۹ در نظر گرفته می‌شود [۲۶]. در رابطه فوق، E_{ri} ضریب صدور نور برای قسمت داخلی سقف گلخانه E_p ضریب صدور نور برای گیاه است که به ترتیب وابسته به جنس گلخانه و نوع گیاه مورد استفاده است

به منظور ارزیابی قابلیت مدل‌های مورد بررسی (شبکه عصبی) در پیش‌بینی متغیرهای داخلی گلخانه، از معیارهای درصد میانگین مطلق خطا^۵ (MAPE)، ریشه متوسط مربعات خطا^۶ (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. شکل ۲ روند اجرای کلی مطالعه حاضر را نشان می‌دهد.

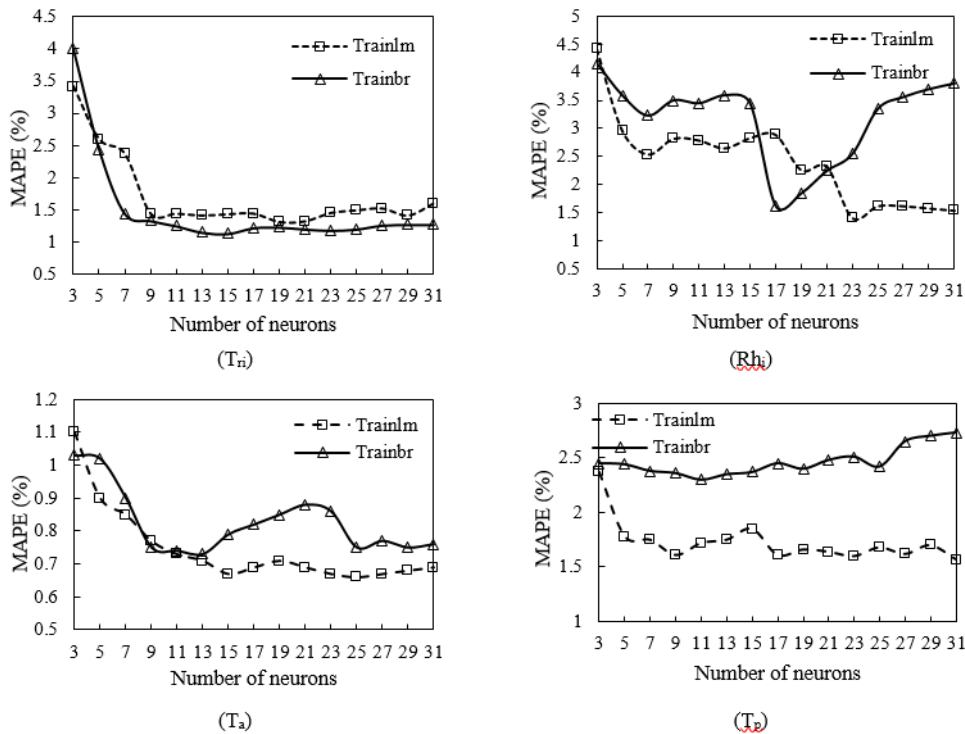
نتایج و بحث

هوش مصنوعی (مدل‌های 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_{ri})، 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 و Trainbr با توجه به تعداد نرون‌های مختلف در لایه پنهان بر اساس آماره MAPE برای تخمین ۴ متغیر مورد بررسی در گلخانه شیشه‌ای با مدل MLP در شکل ۳ ارائه شده است.



شکل ۲- روند اجرای مطالعه حاضر

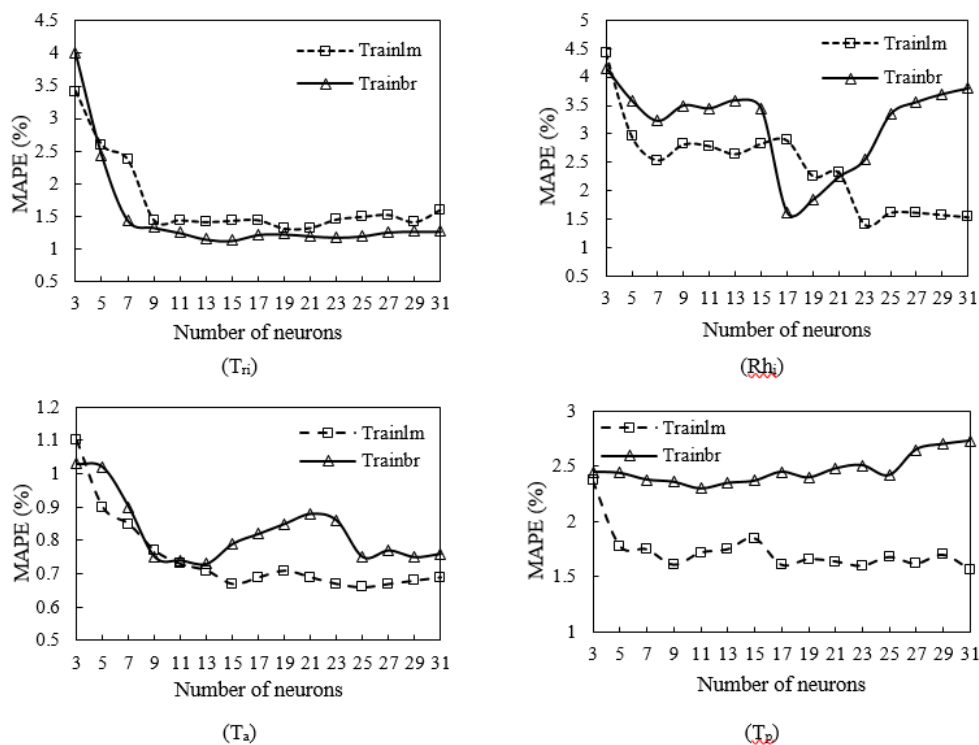


شکل ۳- نتایج حاصل از تخمین ۴ متغیر داخلی گلخانه شیشه‌ای با مدل MLP و دو نوع الگوریتم آموزش Trainbr و Trainlm

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 ۳، بهترین توپولوژی مدل MLP در تخمین دمای سقف، رطوبت هوای داخل، دمای هوای داخل و دمای گیاه عبارتند از: (۳-۲۳-۱)، (۳-۱۵-۱)، (۳-۱۳-۱)

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 ۴ 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 هوای گلخانه (T_a و T_{in}) خطایی کم‌تر از الگوریتم Trainlm (به ترتیب 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 (به ترتیب 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 به دست آمده است.



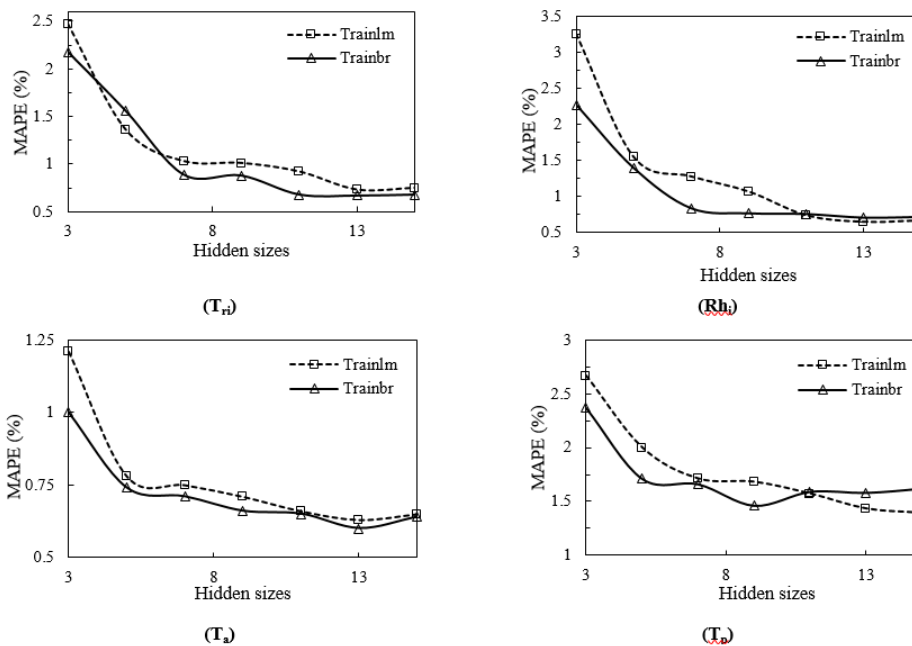
شکل ۴- نتایج حاصل از تخمین ۴ متغیر داخلی گلخانه شیشه‌ای با مدل RBF و دو نوع الگوریتم آموزش Trainbr و Trainlm

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 ۵ میزان این پارامتر را برای تمامی متغیرها و الگوریتم‌های مورد بررسی نشان می‌دهد.

بهترین برازش داده‌های پیش‌بینی شده توسط دو مدل هوش مصنوعی (MLP و RBF) و رگرسیون چندگانه (MLR) با مجموعه داده‌های متفاوت

پس از تعیین بهترین الگوریتم آموزش و تعداد نرون برای هر دو مدل هوش مصنوعی (MLP و RBF) و رگرسیون چندگانه (MLR)، امکان وجود بهترین برازش ممکن، برای تخمین چهار متغیر داخلی گلخانه شیشه‌ای، مورد بررسی قرار گرفت. شکل‌های ۶، 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 به درستی تخمین بزنند. با مقایسه بین نتایج به دست آمده از شکل های ۷ و ۸ با تحقیقات صورت گرفته در زمینه مدل سازی و تخمین دما در نقاط مختلف گلخانه توسط روابط ریاضی انتقال حرارت و جرم، می توان دریافت که کارایی شبکه عصبی در پیش بینی، بسیار بهتر، با دقت بیشتر و خطای کم تر است. مثلاً در تحقیقی به بررسی مدل سازی انتقال حرارت در گلخانه ای مجهز به صفحه حرارتی^۷ و آبخوان زیرزمینی^۸ پرداخته شد (Shukla et al., 2006). نتایج نشان داد که مدل ریاضی قادر به پیش بینی دمای داخل گلخانه با دقتی بسیار کم تر از نتایج شبکه عصبی است (MAPE=۱۰/۲٪ و R=۰/۸۱).




شکل ۵- تغییرات میزان پارامتر پخش (Spread parameter) در مدل RBF با توجه به نوع الگوریتم آموزش (Trainbr و Trainlm)

در تحقیق دیگری از مدل سازی انتقال حرارت و جرم برای تعیین میزان تلفات حرارتی و انتقال انرژی بین اجزای مختلف یک گلخانه مرسوم در کشور هند استفاده شد [۲۷]. نتایج نشان داد مدل ریاضی استفاده شده قادر است دمای داخل گلخانه را با دقت قابل قبولی تخمین بزند (MAPE=۱۱/۳۲٪ و RMSE=۶/۰۶°C). توجه به این نتایج لزوم استفاده بیش تر از ابزار شبکه عصبی به جای مدل های کلاسیک ریاضی در معادلات گلخانه ای را نشان می دهد. در روشی ترکیبی می توان ابتدا برای تخمین پارامترهای داخلی گلخانه از شبکه عصبی مصنوعی استفاده کرد و سپس نتایج به دست آمده را در معادلات ریاضی قرار داد و میزان انتقال حرارت بین اجزای گلخانه و همچنین دریافت انرژی و تلفات کلی گلخانه را به دست آورد. لزوم آمادگی یک گلخانه هوشمند نسبت به تغییرات محیطی پیش روی می تواند بهترین دلیل برای توسعه مدل های هوش مصنوعی برای تخمین شرایط داخلی گلخانه ها با توجه به تغییرات محیطی پیرامون خود باشد. گلخانه های هوشمند نسل آینده حتماً از ترکیب روش های مخت لف شبکه عصبی و کلاسیک به منظور تخمین شرایط داخلی خود و فراهم کردن شرایط مطلوب گیاه برای رشد و نمو استفاده خواهند کرد [۱۶].


1- Thermal screen
2- Underground aquifer




(T_m)



(R_{h1})




(T_a)




(T_p)


شکل ۶- مقایسه بین مقادیر واقعی و پیش‌بینی شده ۴ متغیر داخلی گلخانه توسط مدل MLP




(T_m)



(R_{h1})



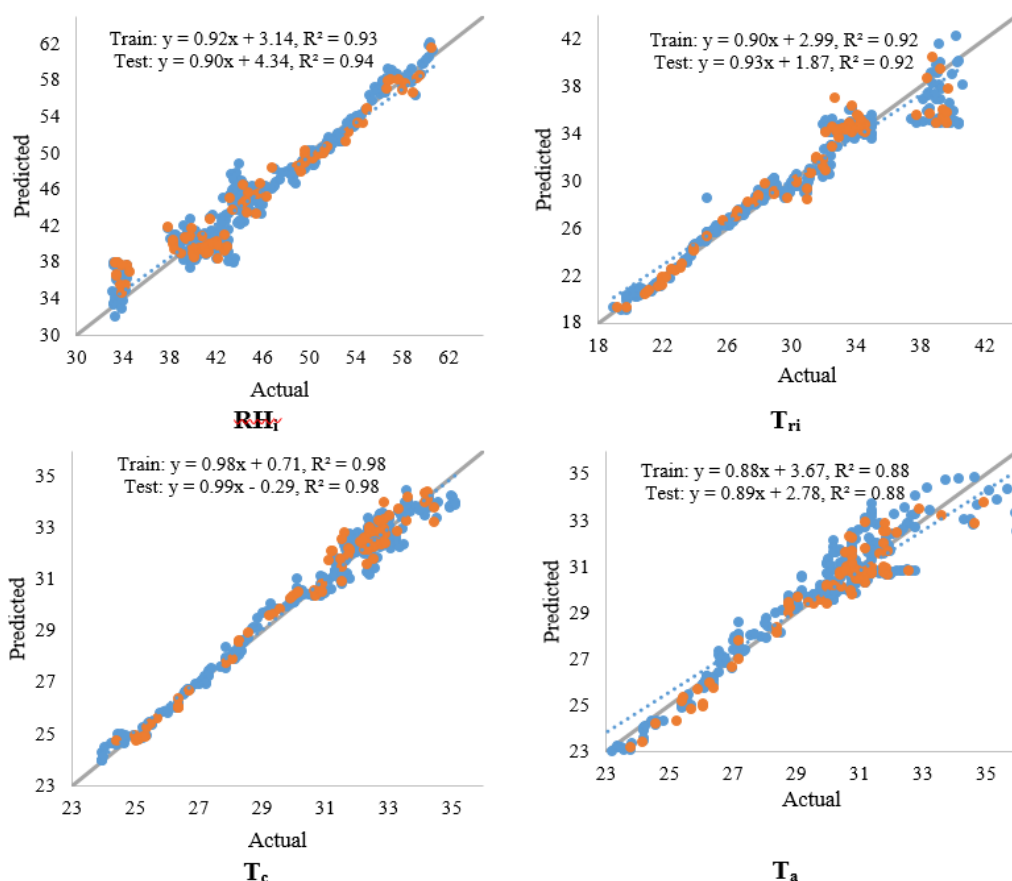
(T_a)



(T_p)

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

به منظور بررسی قابلیت کاربرد 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 کنیم، نتیجه نهایی مدل و دقت نهایی بیش‌تر از زمانی است که از داده‌های کم‌تر (یعنی ۴۰٪ داده‌ها) برای آموزش شبکه استفاده می‌کنیم. این حالت برای پیش‌بینی دمای هوای داخل، دمای سقف 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 می‌کنیم، نتیجه نهایی مدل‌سازی دقت بیش‌تری را نشان می‌دهد. آماره MAPE در این حالت نسبت به حالت ۸۰٪ داده‌ها، ۰/۰۳ درصد کم‌تر است.



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

دلیل وجود این حالت می‌تواند نوسانات رطوبتی زیاد ناشی از فرار هوای داخل گلخانه و یا باز و بسته شدن درب ورودی و در موارى آبیاری گیاهان داخل گلخانه باشد. در این حالت داده‌های رطوبت با نوسانات زیادی روبرو می‌شوند و در نهایت دقت نهایی مدل‌سازی با داده‌های بیش‌تر، کم‌تر خواهد شد. شبیه به آنالیز صورت گرفته در جدول ۱، برای مدل MLR در جدول ۲ ارائه شده است.



همانطور که نتایج جدول ۲ نشان می‌دهد، مدل رگرسیون چندگانه با نسبت‌های مختلف از داده‌ها، نتایجی با دقت کم‌تر نسبت به هر دو مدل هوش مصنوعی (MLP و RBF) ارائه می‌دهد. بنابراین بر اساس این جدول، این مدل در رقابت با دو مدل هوش مصنوعی حذف می‌شود.

مصرف انرژی

یکی از اهداف این تحقیق بررسی مصرف انرژی در نتیجه داده‌های حاصل از مدل‌های مورد بررسی است. در این قسمت با توجه به مقادیر اندازه‌گیری شده توسط سنسور دما، رطوبت و تابش و مقادیر پیش‌بینی شده حاصل از مدل‌های شبکه عصبی مصنوعی (MLP- RBF) و رگرسیون چندگانه (MLR)، به مقایسه‌ی مقادیر واقعی و پیش‌بینی شده در هر مدل پرداخته شده است. شکل‌های ۹-۱۱ مقایسه بین مقادیر انتقال حرارت همرفتی (Qa-p و Qa-ri) و تابش (Qri-p) محاسبه شده توسط مدل‌های MLP، RBF و MLR با نتایج واقعی را نشان می‌دهد. همانطور که این نمودارها نشان می‌دهند، مدل RBF نتایجی دقیق‌تر نسبت به سایر مدل‌ها ارائه کرده است. در این نمودارها، انتقال حرارت بین دمای هوای گلخانه و دمای سقف گلخانه، انتقال حرارت بین دمای سقف گلخانه و گیاه و انتقال حرارت بین هوای داخل گلخانه و گیاه توسط داده‌های واقعی و داده‌های پیش‌بینی شده با مدل‌های شبکه عصبی (MLP- RBF) و رگرسیون چندگانه (MLR) مقایسه شده است. همانطور که این شکل‌ها نشان می‌دهند، میزان اختلاف مقادیر مدل RBF از مقادیر واقعی نسبت به سایر دو مدل کمتر است و این گویای این نکته است که استفاده از مدل RBF نسبت به دو مدل دیگر می‌تواند با دقت بیش‌تر و خطای کم‌تر میزان تلفات حرارتی را تخمین بزند. نتایج عددی این شکل‌ها بطور میانگین در جدول ۳ نشان داده شده است. نتایج این جدول نشان می‌دهد که مدل RBF اختلاف انرژی کمتری نسبت به مدل‌های MLP و MLR دارد. این به این معناست که مقادیر پیش‌بینی با مقادیر واقعی اختلاف زیادی نداشته و می‌توان از این مدل برای کنترل شرایط گلخانه استفاده کنیم و در این حالت پرت حرارتی کمتری نسبت به دو مدل مورد بررسی خواهیم داشت.





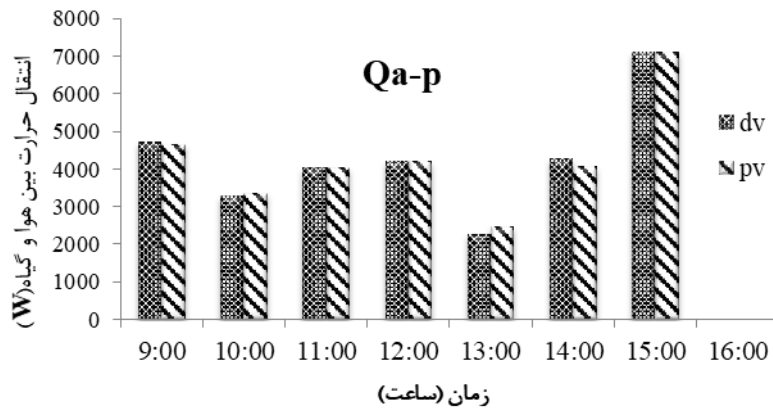
جدول ۱- نتایج استفاده از دو مجموعه داده با اندازه متفاوت بر میزان دقت دو مدل MLP و RBF

آموزش		تست		مجموع		مدل	متغیر	سایز داده %
MAPE	RMSE	MAPE	RMSE	MAPE	RMSE			
۱/۶۲±۰/۴۶	۰/۸۳±۰/۲۵	۱/۷۳±۰/۴۸	۰/۸۸±۰/۳۰	۱/۶۵±۰/۶۵	۰/۸۵±۰/۲۴	MLP1	T _{ri}	۸۰
۲/۸۹±۰/۹۳	۱/۴۲±۰/۴۴	۲/۹۶±۰/۸۷	۱/۴۹±۰/۴۰	۲/۹۱±۰/۹۲	۱/۴۴±۰/۴۲	MLP2		
۱/۵۹±۰/۶۰	۱/۰۰±۰/۳۴	۱/۷۵±۰/۶۴	۱/۱۱±۰/۳۸	۱/۶۲±۰/۶۰	۱/۰۴±۰/۳۱	MLP1	Rh _i	۸۰
۳/۳۲±۰/۹۹	۱/۹۰±۰/۵۱	۳/۳۸±۱/۰۶	۱/۹۳±۰/۵۸	۳/۳۳±۱/۰۰	۱/۹۱±۰/۵۲	MLP2		
۰/۷۴±۰/۰۹	۰/۳۱±۰/۰۴	۰/۸۳±۰/۱۱	۰/۳۵±۰/۰۵	۰/۷۶±۰/۷۵	۰/۳۲±۰/۰۳	MLP1	T _a	۸۰
۰/۹۲±۰/۲۱	۰/۳۷±۰/۰۸	۰/۹۴±۰/۱۹	۰/۳۹±۰/۰۸	۰/۹۲±۰/۲۰	۰/۳۸±۰/۰۷	MLP2		
۱/۶۱±۰/۰۵	۰/۸۷±۰/۰۵	۱/۸۰±۰/۱۹	۰/۹۶±۰/۱۳	۱/۶۵±۰/۱۵	۰/۸۹±۰/۰۴	MLP1	T _p	۸۰
۲/۳۵±۰/۲۰	۱/۰۷±۰/۰۷	۲/۳۵±۰/۲۳	۱/۰۶±۰/۱۵	۲/۳۵±۰/۱۹	۱/۰۷±۰/۰۵	MLP2		
۱/۵۴±۰/۸۵	۰/۷۶±۰/۳۹	۲/۰۳±۰/۷۶	۱/۰۵±۰/۳۱	۱/۸۳±۰/۷۸	۰/۹۵±۰/۳۳	MLP1	T _{ri}	۴۰
۱/۶۰±۰/۶۵	۰/۷۹±۰/۲۹	۱/۹۷±۰/۶۲	۱/۰۴±۰/۲۵	۱/۸۳±۰/۶۲	۰/۹۵±۰/۲۴	MLP2		
۱/۲۳±۰/۳۰	۰/۷۷±۰/۲۲	۱/۸۱±۰/۲۴	۱/۲۱±۰/۱۶	۱/۵۷±۰/۲۴	۱/۰۶±۰/۱۴	MLP1	Rh _i	۴۰
۱/۵۵±۰/۴۲	۰/۹۸±۰/۲۷	۱/۹۸±۰/۳۷	۱/۳۶±۰/۲۳	۱/۲۳±۰/۲۰	۱/۸۱±۰/۳۷	MLP2		
۰/۶۹±۰/۰۷	۰/۲۹±۰/۰۳	۰/۸۷±۰/۰۸	۰/۳۸±۰/۰۵	۰/۷۹±۰/۰۶	۰/۳۵±۰/۰۳	MLP1	T _a	۴۰
۰/۸۵±۰/۱۳	۰/۳۵±۰/۰۵	۰/۹۵±۰/۱۱	۰/۳۹±۰/۰۴	۰/۹۲±۰/۱۲	۰/۳۷±۰/۰۴	MLP2		
۱/۷۱±۰/۲۳	۰/۸۹±۰/۰۹	۲/۰۷±۰/۲۱	۱/۰۳±۰/۱۴	۱/۹۲±۰/۱۸	۰/۹۸±۰/۰۹	MLP1	T _p	۴۰
۲/۱۹±۰/۳۳	۱/۰۳±۰/۱۲	۲/۳۲±۰/۸۷	۱/۰۵±۰/۰۷	۲/۲۷±۰/۲۵	۱/۰۵±۰/۰۶	MLP2		
۰/۶۶±۰/۰۳	۰/۲۶±۰/۰۱	۰/۶۴±۰/۰۶	۰/۲۶±۰/۰۳	۰/۶۶±۰/۰۳	۰/۲۶±۰/۰۱	RBF1	T _{ri}	۴۰
۰/۶۷±۰/۰۳	۰/۲۶±۰/۰۱	۰/۶۸±۰/۰۶	۰/۲۶±۰/۰۲	۰/۶۸±۰/۰۳	۰/۲۶±۰/۰۱	RBF2		
۰/۶۴±۰/۰۳	۰/۳۸±۰/۰۱	۰/۶۵±۰/۰۳	۰/۳۸±۰/۰۲	۰/۶۵±۰/۰۲	۰/۳۸±۰/۰۱	RBF1	Rh _i	۴۰
۰/۶۶±۰/۰۳	۰/۳۸±۰/۰۲	۰/۶۶±۰/۰۵	۰/۳۸±۰/۰۳	۰/۶۶±۰/۰۲	۰/۳۸±۰/۰۱	RBF2		
۰/۵۹±۰/۰۲	۰/۲۵±۰/۰۱	۰/۶۰±۰/۰۵	۰/۲۵±۰/۰۳	۰/۶۰±۰/۰۲	۰/۲۵±۰/۰۱	RBF1	T _a	۸۰
۰/۶۱±۰/۰۳	۰/۲۶±۰/۰۲	۰/۶۳±۰/۰۶	۰/۲۶±۰/۰۳	۰/۶۲±۰/۰۱	۰/۲۶±۰/۰۱	RBF2		
۱/۰۹±۰/۱۴	۰/۵۹±۰/۰۹	۱/۱۴±۰/۱۶	۰/۶۰±۰/۱۵	۱/۱۰±۰/۰۸	۰/۵۹±۰/۰۸	RBF1	T _p	۸۰
۱/۲۸±۰/۱۰	۰/۶۸±۰/۰۸	۱/۳۱±۰/۱۸	۰/۶۹±۰/۱۴	۱/۲۹±۰/۱۰	۰/۶۹±۰/۰۷	RBF2		
۰/۶۷±۰/۰۴	۰/۲۷±۰/۰۳	۰/۶۷±۰/۰۴	۰/۲۷±۰/۰۲	۰/۶۷±۰/۰۳	۰/۲۷±۰/۰۲	RBF1	T _{ri}	۴۰
۰/۶۹±۰/۰۴	۰/۲۷±۰/۰۲	۰/۶۹±۰/۰۴	۰/۲۷±۰/۰۱	۰/۶۹±۰/۰۲	۰/۲۷±۰/۰۱	RBF2		
۰/۶۵±۰/۰۴	۰/۳۸±۰/۰۲	۰/۶۵±۰/۰۳	۰/۳۸±۰/۰۲	۰/۶۵±۰/۰۳	۰/۳۸±۰/۰۱	RBF1	Rh _i	۴۰
۰/۶۵±۰/۰۳	۰/۳۷±۰/۰۲	۰/۶۵±۰/۰۴	۰/۳۸±۰/۰۳	۰/۶۵±۰/۰۲	۰/۳۸±۰/۰۱	RBF2		
۰/۵۹±۰/۰۵	۰/۲۵±۰/۰۲	۰/۵۹±۰/۰۲	۰/۲۵±۰/۰۱	۰/۵۹±۰/۰۱	۰/۲۵±۰/۰۱	RBF1	T _a	۴۰
۰/۶۱±۰/۰۴	۰/۲۶±۰/۰۱	۰/۶۴±۰/۰۵	۰/۲۶±۰/۰۲	۰/۶۲±۰/۰۲	۰/۲۵±۰/۰۲	RBF2		
۱/۱۳±۰/۱۴	۰/۶۲±۰/۱۳	۱/۰۸±۰/۰۹	۰/۵۷±۰/۰۸	۱/۱۰±۰/۰۸	۰/۵۹±۰/۰۸	RBF1	T _p	۴۰
۱/۳۲±۰/۱۶	۰/۷۳±۰/۱۲	۱/۳۱±۰/۱۹	۰/۶۹±۰/۱۳	۱/۳۲±۰/۱۶	۰/۷۱±۰/۱۱	RBF2		



جدول ۲- نتایج استفاده از سه مجموعه داده با اندازه متفاوت بر میزان دقت مدل MLR


کل	آزمایش		اعتبارسنجی		آماره		
	MAPE	RMSE	MAPE	RMSE			
	۳/۲۳	۱/۵۹	-	-	T_{ri}		
	۳/۶۳	۱/۸۶	-	-	RH_i		
	۱/۰۷	۰/۴۴	-	-	T_a		
	۲/۲۶	۱/۰۶	-	-	T_c		
	$۳/۲۵ \pm ۰/۰۵$	$۱/۵۹ \pm ۰/۰۱$	$۳/۳۴ \pm ۰/۲۵$	$۱/۶۳ \pm ۰/۱۴$	$۳/۲۲ \pm ۰/۰۷$	$۱/۵۸ \pm ۰/۰۳$	T_{ri}
	$۳/۶۳ \pm ۰/۰۲$	$۱/۸۷ \pm ۰/۰۱$	$۳/۷۱ \pm ۰/۳۶$	$۱/۹۰ \pm ۰/۱۶$	$۳/۶۱ \pm ۰/۰۹$	$۱/۸۶ \pm ۰/۰۴$	RH_i
	$۱/۰۷ \pm ۰/۰۱$	$۰/۴۴ \pm ۰/۰۱$	$۱/۱۳ \pm ۰/۱۳$	$۰/۴۷ \pm ۰/۰۷$	$۱/۰۷ \pm ۰/۰۳$	$۰/۴۴ \pm ۰/۰۱$	T_a
	$۲/۲۵ \pm ۰/۰۳$	$۱/۰۶ \pm ۰/۰۱$	$۲/۲۹ \pm ۰/۱۷$	$۱/۰۶ \pm ۰/۱۵$	$۲/۲۵ \pm ۰/۰۷$	$۱/۰۶ \pm ۰/۰۳$	T_c
	$۳/۳۶ \pm ۰/۲۲$	$۱/۶۷ \pm ۰/۲۶$	$۳/۴۶ \pm ۰/۳۰$	$۱/۷۳ \pm ۰/۳۸$	$۳/۲۱ \pm ۰/۲۱$	$۱/۵۵ \pm ۰/۰۷$	T_{ri}
	$۳/۶۹ \pm ۰/۰۷$	$۱/۹۲ \pm ۰/۰۵$	$۳/۷۸ \pm ۰/۱۵$	$۱/۹۶ \pm ۰/۰۹$	$۳/۵۶ \pm ۰/۱۹$	$۱/۸۴ \pm ۰/۰۹$	RH_i
	$۱/۱۰ \pm ۰/۰۲$	$۰/۴۶ \pm ۰/۰۲$	$۱/۱۵ \pm ۰/۰۶$	$۰/۴۹ \pm ۰/۰۳$	$۱/۰۳ \pm ۰/۰۷$	$۰/۴۲ \pm ۰/۰۳$	T_a
	$۲/۳۳ \pm ۰/۱۲$	$۱/۰۸ \pm ۰/۰۳$	$۲/۳۷ \pm ۰/۱۲$	$۱/۰۹ \pm ۰/۰۷$	$۲/۲۶ \pm ۰/۲۲$	$۱/۰۶ \pm ۰/۰۹$	T_c








شکل ۹- مقایسه مقادیر واقعی و پیش‌بینی شده در مدل RBF





شکل ۱۰- مقایسه مقادیر واقعی و پیش‌بینی شده در مدل MLP





شکل ۱۱- مقایسه مقادیر واقعی و پیش‌بینی شده در مدل MLR

جدول ۳- مقادیر انرژی واقعی و پیش‌بینی شده در مدل MLP و MLR و RBF

	Q_{a-ri}	Q_{ri-p}	Q_{a-p}
MLP	۵۹۸۹/۹۰۸۲	-۱/۳۰۱۶	۶۰۸۵/۲۰۹۲
RBF	۵۹۹۲/۹۶۷۵	-۱/۲۷۰۸	۶۲۷۲/۱۹۴۱
MLR	۶۴۹۵/۲۱۷۷	-۱/۱۱۰۴	۸۲۷۶/۹۹۰۹
DV	۶۱۴۶/۶۵۸۷	-۰/۹۶۰۲	۸۲۱۹/۲۰۸۶

با تبدیل واحد وات ساعت به انرژی (معادل بشکه نفت) و محاسبه‌ی ارزش آن در خواهیم یافت که به کمک این مدل‌های ارائه شده می‌توان چه میزان در مصرف انرژی صرفه جویی کرد. در مدل RBF با تبدیل اختلاف مقادیر واقعی و پیش‌بینی شده‌ی Q_{a-ri} ، Q_{ri-p} و Q_{a-p} به بشکه نفت به ترتیب مقادیر ۰/۰۰۰۶۱۱، ۰/۱۰۰۱ و ۰/۰۰۰۲۷۵ به دست آمد که نسبت به مقادیر به دست آمده از مدل‌های MLP و MLR کمتر است و نشان دهنده‌ی این است که مصرف انرژی این مدل نسبت به دو مدل دیگر به صرفه‌تر است. تحقیق انجام شده در یک گلخانه با مساحت کم انجام شده است و مقادیر به دست آمده ناچیز است اما در صورتی که از مدل RBF در مزارع گلخانه‌ای استفاده شود مقدار انرژی صرفه جویی شده بسیار بیشتر و هزینه‌ی انرژی صرف شده کمتر خواهد بود.

نتیجه‌گیری کلی

در این تحقیق از دو مدل شبکه عصبی مصنوعی (MLP و RBF) و رگرسیون چندگانه (MLR) به منظور پیش‌بینی ۴ متغیر مهم (T_a ، T_p ، T_{ri} ، R_{ha}) یک گلخانه‌ی شیشه‌ای دوطرفه با ساختار ویژه در شهر ملاثانی استفاده شد. داده‌های اولیه توسط سنسورهای دما، رطوبت، تابش سنج و بادسنج به دست آمد. از دو الگوریتم آموزش $Trainlm$ و $Trainbr$ با یک لایه مخفی و تعداد نرون‌های مختلف با سه متغیر ورودی مشخص (To و Rho ، Jo) استفاده شد. نتایج نشان داد که الگوریتم آموزشی $Trainlm$ در اکثر موارد در هر دو مدل MLP و RBF دقت بیش‌تری نسبت به الگوریتم $Trainbr$ فراهم می‌کند. در این تحقیق هر دو مدل شبکه 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. 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 دقتی 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 بررسی قرار گیرد. 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.

منابع

1. Kay, JW. and Titterington, DM. 2000. Statistics and Neural Networks. Technometrics 42(4): 443-447.
2. تاکی، مرتضی، عجب‌شیری، یحیی، رنجبر، فرامرز، روحانی، عباس. و مطلوبی، منصور. ۱۳۹۶. ارزیابی مدل‌های ریاضی انتقال حرارت و رگرسیون چندگانه در پیش‌بینی متغیرهای داخلی گلخانه نیمه‌خورشیدی. نشریه مکانیزاسیون کشاورزی. جلد هفتم چاپ اول. ۲۲۰-۲۰۴.
3. تاکی، مرتضی، عجب‌شیری، یحیی، رنجبر، فرامرز، روحانی، عباس. و مطلوبی، منصور. ۱۳۹۴. پیش‌بینی دمای خاک و رطوبت نسبی هوای داخلی گلخانه نیمه‌خورشیدی مجهز به دیواره‌ی سیمانی شمالی با استفاده از شبکه عصبی مصنوعی مطالعه موردی: شهرستان تبریز. نشریه مکانیزاسیون کشاورزی. جلد سوم چاپ اول ۸۳-۷۱.
4. Vadiee, A. and Martin, V. 2013. Energy management in horticultural applications through the closed greenhouse concept, state of the art. Renewable and Sustainable Energy Reviews 16: 5087-5100.
5. Taki, M., Ajabshirchi, Y., Ranjbar, S. F., Rohani, A. and Matloobi, M. 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.
6. Taki, M., Rohani, A., Soheili Fard, F. and Abdesahi, A. 2018a. Assessment of energy consumption and modeling of output energy for wheat production by neural network (MLP and RBF) and Gaussian process regression (GPR) models. Journal of Cleaner production (172): 3028- 3041.
7. Sethi, V.P. 2009. On the selection of shape and orientation of a greenhouse: thermal modeling and experimental validation. Solar Energy 83: 21-38.
8. Van Ooteghem, R. J. C. 2007. Optimal Control Design for a Solar Greenhouse, Systems and Control. Wageningen: Wageningen University.
9. 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.
10. Hill, J. 2006. Dynamic modeling and energy use in a nursery greenhouse. Msc thesis.
11. 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.
12. Linker, R. and Seginer, I. 2004. Greenhouse temperature modeling: a comparison between sigmoid neural networks and hybrid models. Mathematics and Computers in Simulation 65: 19-29.

13. Manuel, A., Francisco, R., Armando, R. and Manuel, B. 2005. Discrete-time nonlinear FIR models with integrated variables for greenhouse indoor temperature simulation, in: Proceedings of the 44th IEEE Conference on Decision and Control, and the European Control Conference, CDC-ECC'05, pp. 4158-4162.
14. Coelho, J. P., Boaventura, J. and de Moura Oliveira, P. B. 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.
15. Boaventura, L., C. Couto, and A. E. B. Ruano. 2000. A greenhouse climate multivariable predictive controller, Acta Horticulturae, ISHS 534: 269-276.
16. Taki, M., Rohani, A. and Rahmati-Joneidabad, M. 2018b. Solar thermal simulation and applications in greenhouse. Information Processing in Agriculture 5: 83-113.
17. Ferreira, P. M., Faria, E. A. and Ruano, A. E. 2002. Neural network models in greenhouse air temperature prediction. Neurocomputing 43 (1-4), 51-75.
18. Dariouchy, A., Aassif, E., Lekouch, K., Bouriden, L. and Maze, G. 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.
19. [Ben Ali, R. E., M. Aridhi, and A. Mami. 2016. Fuzzy Logic Controller of temperature and humidity inside an agricultural greenhouse. IEEE Journals & Magazines.
20. Feng, L. X., Q. L. Lin, M. G. Qi, and W. Gang. 2016. Modeling Greenhouse Temperature by Means of PLSR and BPNN. 35th Chinese Control Conference. July 27-29, Chengdu, China.
21. 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.
22. Rohani, A., M. H. Abbaspour-Fard, and Sh. Abdollahpour. 2011. Prediction of tractor repair and maintenance costs using artificial neural network. Expert Sys. Applications 38: 8999-9007.
23. 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
24. 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.
25. 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.
26. Taki M, Abdanan Mehdizadeh S, Rohani A, Rahnama M, Rahmati-Joneidabad M. 2018c. Applied machine learning in greenhouse simulation; new application and analysis. Information Processing in Agriculture. 5: 253-268.
27. 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.
28. Singh, R. D., and G. N. Tiwari. 2010. Energy conservation in the greenhouse system: A steady state analysis. Energy 35: 2367-2373.



دانشگاه شهید چمران اهواز



انجمن مهندسی ماشین‌های کشاورزی و مکانیزاسیون ایران



دوازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران

۱۶ - ۱۸ بهمن ماه ۱۳۹۸

دانشگاه شهید چمران اهواز



Simulation the inside environment and energy flow assessment of an uneven span greenhouse by artificial intelligence and mathematical models

Makieh Hamdani¹, Morteza Taki^{2*}, Majid Rahnama², Abbas Rohani³, Mostafa Rahmati-Joneidabad⁴

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 (* - Corresponding Author Email: Mortezataaki@gmail.com; mtaki@asnrukh.ac.ir)

3- Associate Prof., Department of Agricultural Machinery Engineering, Faculty of Agriculture, Ferdowsi University of Mashhad

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

Abstract

In this research, two models of Neural Network (MLP-RBF) and Multiple Linear Regression (MLR) were used to estimate four effective variables including air and plant temperature, roof temperature and internal air humidity in a double glass greenhouse. Also the energy exchange between the different elements of this structure was assessment. For this purpose, environmental factors including outside temperature and humidity as well as outside radiation, were used as inputs. In this study, two algorithms include: Bayesian regulation backpropagation (Trainbr) and Levenberg-Marquardt backpropagation (Trainlm) were used in the learning phase. The above models were trained with the final algorithms, with 40% and 80% of the total data set. In this research, K-fold cross validation was used to increase the rely and applicability of the results. The effective factors of these models were evaluated and improved at each stage. The results showed that the RBF model has more ability than others to estimate the above variables. The accuracy of the RBF model was about 50% higher than other models, and it was more capable of working with a smaller set of data than the rest. The results of energy evaluation in this greenhouse showed that, RBF model can use with more accuracy and this approach can be used in the intelligence version of this greenhouse.

Key words: Artificial Neural Network, Even span Greenhouse, Modeling, Smart greenhouses, Multilayer regression

*Corresponding author

Mortezataaki@gmail.com; mtaki@asnrukh.ac.ir