

# پیش‌بینی دمای خاک و رطوبت نسبی هوای داخلی گلخانه نیمه‌خورشیدی مجهز به دیواره سیمانی شمالی با استفاده از شبکه‌های عصبی مصنوعی مطالعه موردی: شهرستان تبریز

مرتضی تاقی<sup>۱</sup>، یحیی عجب‌شیرچی<sup>۱</sup>، سید فرامرز رنجبر<sup>۲</sup>، عباس روحانی<sup>۳\*</sup> و منصور مطلوبی<sup>۴</sup>

تاریخ دریافت: ۹۴/۵/۸ تاریخ پذیرش: ۹۴/۱۲/۲۵

- ۱- گروه آموزشی مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه تبریز
  - ۲- گروه آموزشی مهندسی مکانیک، دانشکده فنی مهندسی مکانیک، دانشگاه تبریز
  - ۳- گروه آموزشی مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه فردوسی مشهد
  - ۴- گروه آموزشی باغبانی، دانشکده کشاورزی، دانشگاه تبریز
- \*مسئول مکاتبه: E-mail: arohani@um.ac.ir

## چکیده

بوم‌شناسی در بر گیرنده بسیاری از جنبه‌های مهم کشاورزی است که متأسفانه تا الان به رشد قابل ملاحظه‌ای دست نیافته است. در این شاخه، گلخانه‌های کشاورزی به‌عنوان یکی از موثرترین روش‌های کشت، مورد توجه بسیار است. دست‌یابی به گلخانه‌های هوشمند با توان دریافت بیش‌ترین مقدار تابش خورشید و کم‌ترین تلفات حرارتی همیشه به‌عنوان یک هدف ایده‌آل مورد توجه محققان است. در این تحقیق از مدل شبکه عصبی مصنوعی به‌منظور تخمین دمای خاک و رطوبت نسبی هوای داخلی گلخانه نیمه‌خورشیدی با توجه به برخی پارامترهای داخلی و خارجی استفاده شد. بدین منظور، داده‌ها از گلخانه‌ای نیمه‌خورشیدی واقع در ایستگاه تحقیقاتی دانشکده کشاورزی دانشگاه تبریز، توسط حسگرهای دما، رطوبت، تابش‌سنج و بادسنج اخذ گردید. این گلخانه با توجه به شکل‌های رایج در منطقه و بر اساس دریافت بیش‌ترین میزان تابش و کم‌ترین تلفات حرارتی ساخته شده و در آن از برخی ویژگی‌های یک گلخانه خورشیدی استفاده شده است. شبکه عصبی پرسپترون تک لایه با الگوریتم آموزش لوبنبرگ-مارکوارت (LM) و تعداد نرون‌های مختلف در لایه پنهان مورد استفاده قرار گرفت. نتایج نشان دادند که ساختارهای ۱-۹-۴ و ۱-۶-۵ به ترتیب با ضرایب تبیین ۰/۹۹۴۵ و ۰/۹۹۷۱ قادرند به بهترین نحو برای پیش‌بینی دمای خاک و رطوبت نسبی هوای داخل گلخانه نیمه‌خورشیدی مورد استفاده قرار گیرند. برای ساختارهای فوق، پارامترهای MAPE و RMSE به ترتیب معادل ۱/۱۰۶۰ و ۱/۱۹۵۶ درصد، ۱/۰۳۵۳ و ۰/۲۵۰۲ درجه سانتی‌گراد محاسبه شدند. نتایج استفاده از مدل رگرسیونی نشان دادند که شبکه عصبی ابزاری قدرتمند و دقیق در مقایسه با مدل‌های ریاضی است. نتایج کلی تحقیق نشان دادند که ابزار شبکه‌های عصبی مصنوعی می‌تواند با اطمینان بالا در بحث کنترل خودکار گلخانه با هزینه کم‌تر از طریق کاهش استفاده از حسگرها در آینده مورد استفاده قرار گیرد.

واژه‌های کلیدی: گلخانه نیمه‌خورشیدی، شبکه عصبی مصنوعی، پرسپترون چندلایه، کنترل خودکار

## ۱- مقدمه

رسیدن به کشاورزی پایدار و کاهش تولید آلاینده‌های زیست‌محیطی است. یکی از راه‌های افزایش بهره‌وری گلخانه‌های کشاورزی توجه به بحث طراحی مناسب و دریافت بیش‌ترین میزان تابش خورشیدی است. در این زمینه با توجه به مستندات موجود تاکنون هیچ تحقیق جامع و کاملی در ایران صورت نگرفته است، این در حالی است که در اکثر

در گلخانه‌های ایران بیش‌تر از گازوئیل و گاز طبیعی آن‌هم به شکل نامطلوب به عنوان منبع انرژی گرمایش گلخانه استفاده می‌شود. این در حالی است که با توجه به نسل جدید گلخانه‌ها، دولت‌ها بیش‌تر به فکر استفاده از منابع انرژی تجدیدپذیر هستند؛ چون هم باعث کاهش مصرف فرآورده‌های باارزش نفتی می‌شود و هم کمک شایانی در جهت

کنترل شرایط محیطی داخلی گلخانه (بیکر و همکاران، ۱۹۹۴)، مدل-سازی فیزیکی گلخانه<sup>۲</sup> (بوت، ۱۹۹۱) و تخمین یا پیش‌بینی برخی از پارامترهای داخلی گلخانه است (بوآونتورا و همکاران، ۲۰۰۰؛ کولهو و همکاران، ۲۰۰۲؛ منوئل و همکاران، ۲۰۰۵؛ لینکر و سگینر، ۲۰۰۴). در تحقیقی از شبکه‌های عصبی مصنوعی به منظور ابزاری برای جایگزین کردن انواع حسگرها در گلخانه‌ای در کشور پرتقال استفاده شد (فریا و همکاران، ۲۰۰۲). در این مطالعه به منظور تخمین میزان دمای هوای داخل گلخانه از پارامترهایی همچون میزان تابش ورودی به 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 حسگرهایی با دقت متوسط و به تعداد کم در گلخانه توصیه می‌شود. این روش می‌تواند در آینده و با پیشرفت بیشتر علوم به‌عنوان جایگزینی برای انواع دماسنج‌ها و حسگرهای پرهزینه در انواع گلخانه‌ها مورد استفاده قرار گیرد.

دآریوچی و همکاران ۲۰۰۹، از مدل شبکه عصبی و مدل‌های رگرسیونی برای پیش‌بینی درصد رطوبت و دمای هوای داخلی گلخانه-ای در مراکش استفاده کردند. در این تحقیق، رطوبت نسبی هوای بیرون از گلخانه، شدت تابش خورشید در سطح افق، جهت و سرعت باد و دمای هوای خروجی به‌عنوان متغیرهای ورودی و دما و درصد رطوبت داخلی گلخانه به‌عنوان خروجی مدل در نظر گرفته شد. نتایج نشان داد که استفاده از ابزار شبکه‌های عصبی قادر است نتایج بهتری نسبت به انواع مدل‌های کلاسیک رگرسیونی نشان دهد. میزان خطا در پیش‌بینی دما و رطوبت نسبی داخلی گلخانه در این تحقیق ۴/۲۳ و ۳/۸۵ درصد گزارش شد. هی و ما (۲۰۱۰)، از الگوریتم پس انتشار<sup>۳</sup> خطا به صورت ترکیبی با روش تجزیه به مولفه‌های اصلی (PCA)<sup>۴</sup> به منظور پیش‌بینی میزان رطوبت هوای داخلی گلخانه‌ای در یکی از مناطق شمالی کشور چین استفاده کردند. مولفه‌های تاثیرگذار بر رطوبت نسبی هوای داخلی گلخانه در این تحقیق شامل دمای هوا و درصد رطوبت نسبی هوای بیرون، سرعت باد، میزان تابش در سطح افق، رطوبت نسبی هوای داخلی و میزان باز و بسته شدن دریچه‌های تهویه گلخانه بود. نتایج مقایسه میزان دقت در پیش‌بینی رطوبت نسبی هوای داخلی گلخانه با استفاده از شبکه عصبی و مدل‌های رگرسیونی نشان داد که شبکه‌های عصبی ابزای قدرتمندتر و در عین حال بادقت بیشتر است.

هدف نهایی از این طرح، کنترل هوشمند گلخانه‌ای تمام خورشیدی در آینده‌ای نزدیک است. در این راستا توجه به بحث کنترل شرایط آب

کشورهای پیشرفته اروپایی و آمریکایی و حتی کشورهای حاشیه خلیج فارس از جمله عربستان، تحقیقات گسترده‌ای در این زمینه صورت گرفته و در برخی موارد تا بیش از ۵۰ درصد نیاز حرارتی گلخانه در فصل زمستان از منابع تجدیدپذیر فراهم شده است (عبدل غنی و هلال، ۲۰۱۱؛ عبدل قانی و کوزای، ۲۰۰۶؛ عبدل غنی، ۲۰۱۱؛ ال هلال و عبدل غنی، ۲۰۱۱؛ آلانسو و همکاران، ۲۰۱۲؛ ودیعه و مارتین، ۲۰۱۲ و ۲۰۱۳؛ زلبیتیز، ۲۰۱۱).

رطوبت داخلی گلخانه نتیجه ترکیب و انتقال پیچیده‌ای بین هوای داخلی و پارامترهایی از جمله گیاه، خاک و یا عوامل بیرونی شامل سرعت باد، دمای هوا و میزان تابش نور خورشید است (تریگویی و همکاران، ۱۹۹۹). رطوبت هوای داخلی یک گلخانه، در اثر تبخیر و تعرق گیاه، آبیاری و یا باتوجه به ساختار گلخانه، متغیر است و در صورت افزایش، باعث شیوع انواع قارچ‌ها، کاهش کلسیم گیاه و در نهایت کاهش کمیت و کیفیت محصول خروجی می‌شود (تریگویی و همکاران، ۱۹۹۹؛ کومستوک و اهلرینگر، ۱۹۹۳). برای خاک گلخانه نیز شرایط ذکر شده برقرار است. افزایش و یا کاهش دمای خاک می‌تواند منجر به تغییراتی در محصول نهایی شود (هی و ما، ۲۰۱۰). در گلخانه‌های سنتی معمولاً از دماسنج و رطوبت‌سنج در وسط گلخانه به‌عنوان نماینده‌ای از کل حجم گلخانه استفاده می‌شود. این موضوع در گلخانه-های پیشرفته از طریق جایگزینی حسگرها با انواع دماسنج‌ها و رطوبت-سنج‌ها 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 بیش‌تر حسگرها به خوبی توجیه می‌شود (ودیعه، ۲۰۱۱). افزایش تعداد حسگرها باعث افزایش هزینه‌های ثابت گلخانه شده و روند تبدیل گلخانه‌های سنتی به انواع مدرن را با مشکل جدی روبرو می‌کند.

امروزه مدل‌های شبکه عصبی مصنوعی<sup>۱</sup> (ANN)، در اکثر جنبه‌های علم مهندسی و کشاورزی مورد استفاده قرار می‌گیرند. این ابزار به دلیل قابلیت مدل‌سازی سیستم‌های خطی و غیرخطی و همچنین عدم نیاز به هیچ گونه پیش‌شرط، از علاقه‌مندان خاصی برخوردار است (دریفیوس و همکاران، ۲۰۰۴؛ هایکین، ۱۹۹۴؛ مارکوس و همکاران، ۱۹۹۲). استفاده از شبکه‌های عصبی مصنوعی در گلخانه، می‌تواند به کشاورز اجازه برقراری ارتباطی قوی بین پارامترهای داخلی گلخانه و متغیرهای بیرونی دهد (دریفیوس و همکاران، ۲۰۰۴؛ هایکین، ۱۹۹۴). نتایج استفاده از این ابزار قادر است کشاورز را از افزایش گرمای تابستانه و یا کاهش بیش از حد دما در زمستان آگاه سازد (سگینر، ۱۹۹۷؛ آکوستا و مارسلو، ۲۰۰۱؛ هورنیک و همکاران، ۱۹۸۹). مطالعات متنوعی در زمینه استفاده از شبکه‌های عصبی در گلخانه انجام شده است که شامل

<sup>2</sup>Physical modeling of greenhouse

<sup>3</sup>Back propagation algorithm

<sup>4</sup>Principal Component Analysis

<sup>1</sup>Artificial Neural Network

گلخانه خودداری شد و رفتار گلخانه شبیه به حالت گلخانه بسته در نظر گرفته شد (یعنی از بازکردن پنجره تهویه گلخانه در طول آزمایش خودداری شد که این کار سبب بالا رفتن دمای گلخانه در اواسط روز می‌شد). گلخانه ساخته شده دارای مساحت کف ۱۵/۳۶ مترمربع، حجم ۲۶/۴ مترمکعب، مساحت سقف ۱۷/۷ مترمربع، مساحت دیواره جنوبی ۳/۸۴ مترمربع، مساحت دیواره شمالی ۱۱/۵۲ مترمربع و دیواره‌های غربی و شرقی هرکدام ۵/۱۲ مترمربع بود. اسکلت گلخانه فلزی و نوع پوشش آن در سقف به صورت شیشه سکوریت به ضخامت ۴ میلی‌متر و دیواره‌ها از شیشه معمولی به ضخامت ۴ میلی‌متر بود که به صورت شرقی-غربی ساخته شده است.

## ۲- مواد و روش‌ها

### ۲-۱- نحوه انتخاب، نوع گلخانه و محل اجرای تحقیق


ایران از نظر دریافت میزان تابش خورشیدی و متوسط شدت تابش خورشیدی یکی از بهترین نقاط دنیا برای استفاده از انرژی پاک و بی-انتهای خورشیدی است ولی متأسفانه به دلیل ضعف تکنولوژی و همچنین وفور منابع فسیلی ارزان قیمت، رشد و شتاب حرکت به سمت منابع جایگزین فسیلی بسیار کم‌تر از سایر کشورهای مشابه است. یکی از روش‌های تبدیل انرژی خورشیدی به فرآورده‌های با ارزش غذایی استفاده از گلخانه‌های کشاورزی است. گلخانه در حالت کلی از نظر دریافت انرژی خورشیدی می‌تواند به انواع خورشیدی و مرسوم دسته بندی شود. در گلخانه‌های خورشیدی معمولاً انتخاب بهترین نوع گلخانه از نظر دریافت انرژی خورشیدی بارزترین شاخص است. مواردی از قبیل افزودن صفحه حرارتی داخلی و خارجی، کاهش میزان تلفات انرژی داخلی، انتخاب بهترین جنس از نظر دریافت و تلفات انرژی، افزودن منابع جذب انرژی خورشیدی (از جمله دیوار شمالی، کلکتور زمینی، آبخوان زیرزمینی و سایر منابع)، استفاده از منابع تجدیدپذیر به منظور تامین نیاز حرارتی گلخانه در فصل زمستان و در نهایت تامین تمامی نیاز حرارتی گلخانه از منابع تجدیدپذیر می‌تواند یک گلخانه مرسوم را به سمت گلخانه خورشیدی سوق دهد (ودیع و مارتین، ۲۰۱۳). در این تحقیق چون چندین عامل از مشخصه‌های یک گلخانه خورشیدی (بهترین شکل و جهت، دیواره سیمانی شمالی و صفحه حرارتی) به یک گلخانه مرسوم افزوده شد، لذا گلخانه مورد استفاده یک گلخانه نیمه-خورشیدی محسوب می‌شود (شکل ۱).

این تحقیق در ایستگاه تحقیقاتی دانشکده کشاورزی دانشگاه تبریز واقع در جاده باسمنج انجام گرفت. بدین منظور در ابتدا از انواع طرح-های متداول و مرسوم گلخانه در منطقه، بهترین آن‌ها با توجه به دریافت حداکثری میزان تابش خورشید بر اساس داده‌های مربوط به ایستگاه هواشناسی شهرستان تبریز، انتخاب و ساخته شد. در این تحقیق به دلیل کار در فصل تابستان و نیاز به برودت بالای گلخانه، از کشت در محیط

### ۲-۲- نحوه جمع‌آوری داده‌ها

در این تحقیق برای جمع‌آوری داده‌های مربوط به دما، رطوبت، سرعت باد و تابش خورشید از انواع حسگرها و دستگاه‌های مربوطه استفاده شد. داده‌های دما و رطوبت توسط حسگرهای SHT11 ساخت شرکت CMOS آمریکا برداشت شد. این حسگر از دو نوع حسگر دما و رطوبت مجزا تشکیل شده که خروجی آن‌ها به یک مبدل ۱۴ بیتی آنالوگ به دیجیتال متصل شده است. دقت این حسگر در جمع‌آوری دما و رطوبت به ترتیب  $\pm 0.4$  درجه سانتی‌گراد و  $\pm 3$  درصد است (شکل ۲). مزیت این نوع حسگر نسبت به انواع RT1000، PT100 و یا LM35 علاوه بر دقت بالا قابلیت تبدیل مستقیم خروجی آنالوگ به دیجیتال و ذخیره‌سازی داده‌ها در کارت حافظه مورد حسگر است. در تحقیقات مختلف از انواع حسگرهای LM35 یا PT100 استفاده می‌شود که معمولاً هزینه لازم برای قطعه واسطه و مبدل آنالوگ به دیجیتال سبب کاهش تعداد حسگرهای مورد استفاده می‌شود (ودیع، ۲۰۱۱). از این نوع حسگر به منظور جمع‌آوری داده‌های مربوط به دمای خاک داخل گلخانه ( $T_{is}$ )، دمای هوای داخل گلخانه ( $T_{ia}$ )، دمای قسمت داخلی سقف گلخانه ( $T_{ir}$ ) و دمای هوای بیرون ( $T_{oa}$ ) استفاده شد. میزان رطوبت نسبی هوای داخل ( $RH_{ia}$ ) و خارج گلخانه ( $RH_{oa}$ ) نیز با این نوع حسگر اندازه‌گیری شد. این حسگرها همراه با بورد میکروکنترلر در قسمت‌های مختلف داخل و خارج از گلخانه قرار گرفتند و بر اساس برنامه‌نویسی انجام شده به صورت دقیقه‌ای داده‌های دما و رطوبت مربوطه را برداشت می‌کردند. محل نصب حسگرهای تشخیص دما و رطوبت نسبی هوای داخلی گلخانه در دو نقطه وسط گلخانه بود که

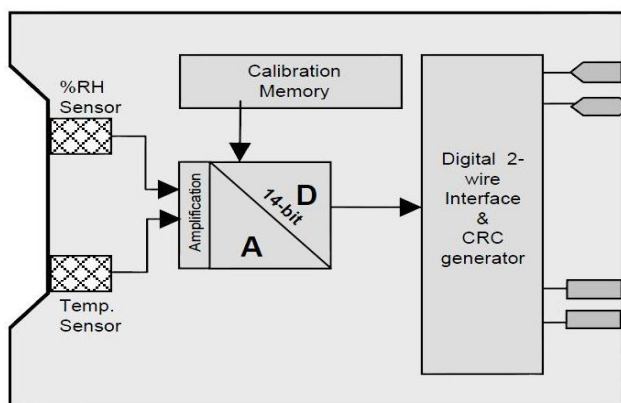
<sup>1</sup>Interface




شکل ۱- گلخانه نیمه‌خورشیدی مجهز به دیواره سیمانی شمالی

داخل گلخانه نیز برداشت گردید. سرعت باد در خارج از گلخانه نیز توسط بادسنج مدل YK-2004AH در ارتفاعی حدود دو متر از سطح زمین با دقتی در حدود  $\pm 0.1$  برداشت شد. شکل (۳) محل قرارگیری ابزارهای موجود در برداشت دما، رطوبت، شدت تابش و سرعت باد در خارج و داخل گلخانه را نشان می‌دهد.

پس از ضبط داده‌ها از آن‌ها میانگین‌گیری به عمل آمد. هم‌چنین حسگر خاک گلخانه، روی سطح خاک و در وسط گلخانه قرار گرفت. به‌منظور برداشت داده‌های تابش در خارج از گلخانه، در ارتفاع یک متری و تراز شده زمین، از تابش‌سنج مدل TES 1333 استفاده شد. این نوع تابش‌سنج قادر است داده‌های تابش در محدوده طول موج ۴۰۰ تا ۱۱۰۰ نانومتر را بادقتی در حدود ۰.۵٪ برداشت کند. در این تحقیق داده‌های مربوط به شدت تابش خورشید روی سقف گلخانه و



شکل ۲- حسگر SHT11 به هنگام دریافت داده‌های دما و رطوبت و نحوه تبدیل داده‌ها به دیجیتال



شکل ۳- محل قرارگیری حسگرهای دما، رطوبت و ابزارهای موجود برای ثبت شدت تابش خورشید، دما، رطوبت و سرعت باد در داخل و خارج از گلخانه

### ۳-۲- شبکه‌های عصبی مصنوعی

شبکه MLP با دریافت بردار ورودی  $X^q$ ، بردار خروجی  $Z^q$  را برای هر  $q (q = 1, 2, 3, \dots, Q)$  تولید خواهد کرد. هدف، اتخاذ پارامترهای صحیح شبکه به منظور دستیابی به خروجی واقعی  $Z^q$  است که تا جای ممکن نزدیک به خروجی مطلوب  $d^q$  متناظر با خودش باشد (روحانی و همکاران، ۲۰۱۱). برای آموزش شبکه از الگوریتم پس انتشار اصلی<sup>۱</sup> (BB) استفاده شد. در این تحقیق، جمع‌آوری داده‌ها در حواصل ساعت ۸:۴۰ دقیقه صبح تا ۱۸ عصر انجام گرفت که در نهایت برای تمامی پارامترها حدود ۵۶۰ داده جمع‌آوری شد. در ابتدا به‌طور تصادفی داده‌ها به دو دسته مجموعه آموزش با ۳۳۶ عضو (۶۰ درصد کل داده‌ها) و مجموعه آزمایش با ۲۲۴ عضو (۴۰ درصد کل داده‌ها) تقسیم بندی شد. البته اگر این تقسیم‌بندی منجر به نتایج مطلوب نشود، می‌توان این مرحله را مجدداً تکرار کرد (ژانگ و فاه، ۱۹۹۸).

قبل از به‌کارگیری داده‌های خام اولیه در آموزش و آزمایش شبکه، باید عمل نرمال‌سازی داده‌ها صورت گیرد، زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد و نتایج مطلوب تولید نخواهد شد. زمانی که از تابع فعال سیگموئیدی استفاده می‌شود،

بهترین دامنه تبدیل داده‌ها  $[0/1 - 0/9]$  می‌باشد. از نرمالیزاسیون خطی برای تبدیل داده‌ها استفاده شد (روحانی و همکاران، ۱۳۸۸):

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \times (r_{\max} - r_{\min}) + r_{\min} \quad (1)$$

در اینجا  $X$  داده خام اولیه،  $X_n$  داده نرمالیزه شده،  $X_{\min}$  و  $X_{\max}$  به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه و  $r_{\max}$  و  $r_{\min}$  به ترتیب حد بالایی و پایینی دامنه تغییرات داده‌های تبدیل شده است. برای هر مجموعه داده‌ها این روش‌ها ارزیابی شد و بهترین آن‌ها بر اساس عملکرد شبکه انتخاب شدند. سپس داده‌ها توسط الگوریتم آموزش لونیبرگ مارکوآرت<sup>۲</sup> (LM) مورد آموزش قرار گرفتند. بر اساس یک قانون جهانی، معمولاً بهترین شبکه‌ها با تعداد یک لایه پنهان مشخص می‌شوند (داریوچی و همکاران، ۲۰۰۹). به‌همین 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. شکل ۴ ساختار شبکه MLP با یک لایه پنهان به منظور تخمین میزان دمای خاک و رطوبت نسبی هوای داخل گلخانه را نشان می‌دهد.

به‌منظور ارزیابی قابلیت شبکه عصبی چندلایه پرسپترون در پیش‌بینی میزان دمای خاک و رطوبت نسبی هوای داخلی گلخانه نیمه خورشیدی،

<sup>2</sup>Levenbergmarquart algorithm

<sup>1</sup>Basic Back Propagation

تحلیل مدل رگرسیون چندگانه از نرم افزار Minitab نسخه ۱۷ استفاده شد.

### ۳- نتایج و بحث

#### ۳-۱- مدل شبکه عصبی MLP

در این پژوهش برای پیش بینی درصد رطوبت نسبی هوا و دمای خاک گلخانه، از شبکه عصبی مدل پرسپترون چندلایه (MLP) استفاده شد. بدین ترتیب الگوریتم آموزش LM در شبکه های تک لایه با تعداد نرون ۴ تا ۱۰ مورد استفاده قرار گرفت. برای تعیین مناسب ترین توپولوژی شبکه (تعداد نرون ها در لایه مخفی) از روش آزمون و خطا استفاده گردید. بدین ترتیب تا زمانی که دقت شبکه با افزایش نرون ها بهبود پیدا کند، روند ازدیاد نرون ها در لایه مخفی ادامه می یابد. جدول ۱ نتایج حاصل از تغییرات نرون در لایه پنهان بر میزان تغییرات پارامترهای آماری شبکه را نشان می دهد. همان طور که از جدول ۱ مشخص است، شبکه با ساختار ۱-۹-۴ (یعنی دارای ۴ ورودی، ۹ نرون در لایه مخفی و یک خروجی) دارای بهترین میزان ضریب تبیین ( $R^2=0/9945$ ) و کم ترین مقدار خطا ( $MAPE=1/1060\%$ ) و  $RMSE=1/1956^\circ C$  است و می تواند به عنوان بهترین شبکه در پیش بینی دمای خاک داخل گلخانه مورد استفاده قرار گیرد. همچنین نتایج این جدول نشان می دهد که شبکه با ساختار ۱-۶-۵ (یعنی شبکه ای با ۵ ورودی، ۶ نرون در لایه پنهان و نهایتاً یک خروجی) دارای بیش ترین مقدار ضریب تبیین ( $R^2=0/9971$ ) و کم ترین میزان خطا ( $MAPE=1/0353\%$ ) و  $RMSE=0/2502$  درجه سانتی گراد) است و می تواند به عنوان بهترین شبکه در پیش بینی درصد رطوبت نسبی هوای داخل گلخانه مورد استفاده قرار گیرد. برخی ویژگی های آماری داده های استفاده شده در فاز آموزش و آزمایش مربوط به مقادیر پیش بینی شده دمای خاک و درصد رطوبت نسبی هوای داخل گلخانه در جدول های ۲ و ۳ ارائه شده است.

نتایج این جدول نشان می دهد که بین ویژگی های آماری داده های واقعی و مقادیر تخمینی توسط شبکه عصبی تفاوت معنی داری دیده نمی شود. بنابراین می توان نتیجه گرفت که ابزار شبکه عصبی برای تخمین فاکتورهای داخلی گلخانه می تواند با دقت زیاد مورد استفاده قرار گیرد. با مقایسه بین نتایج به دست آمده از جدول های ۱، ۲ و ۳ و تحقیقات صورت گرفته در زمینه مدل سازی و تخمین دما در نقاط مختلف گلخانه توسط روابط ریاضی انتقال حرارت و جرم، می توان

از معیارهای متوسط قدرمطلق خطا<sup>۱</sup> (MAPE)، ریشه متوسط مربعات خطا<sup>۲</sup> (RMSE) و ضریب تبیین معادله خطی بین مقادیر پیش بینی شده توسط شبکه عصبی مصنوعی و مقادیر واقعی آن ها ( $R^2$ ) استفاده شد:

$$MAPE = \frac{1}{n} \sum_{j=1}^n \left| \frac{d_j - p_i}{d_j} \right| \times 100 \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{j=1}^n (d_j - p_i)^2}{n}} \quad (3)$$

$$R^2 = \frac{\left[ \sum_{j=1}^n (d_j - \bar{d})(p_j - \bar{p}) \right]^2}{\sum_{j=1}^n (d_j - \bar{d})^2 \times \sum_{j=1}^n (p_j - \bar{p})^2} \quad (4)$$

در اینجا،  $d_j$  مولفه  $j$  ام از خروجی واقعی مربوط به الگوی  $j$  ام،  $p_i$  مولفه  $i$  ام از خروجی پیش بینی شده توسط شبکه مربوط به الگوی  $i$  ام،  $\bar{d}$  و  $\bar{p}$  به ترتیب متوسط خروجی های واقعی و پیش بینی شده توسط شبکه و  $n$  تعداد الگوهای خروجی است (ظریف نشاط و همکاران، ۲۰۱۲). به منظور تحلیل روش شبکه عصبی از نرم افزار MATLAB نسخه ۲۰۰۹ استفاده شد.

#### ۴-۲- مدل رگرسیون چندگانه


در این تحقیق از مدل رگرسیون چندگانه به منظور ایجاد مقایسه با نتایج حاصل از مدل شبکه عصبی استفاده شد. بدین منظور متغیرهای مستقل مدل رگرسیونی برای تشخیص دمای خاک گلخانه شامل: دمای هوای داخل گلخانه ( $T_{ia}$ )، دمای سقف ( $T_{ri}$ )، شدت تابش دریافتی داخل گلخانه ( $I_s$ ) و رطوبت نسبی هوای گلخانه ( $RH_{ia}$ ) در نظر گرفته شد. به منظور تخمین رطوبت نسبی هوای گلخانه نیز از متغیرهای مستقل شامل: دمای هوای گلخانه، دمای هوای بیرون ( $T_{oa}$ )، دمای سقف، سرعت باد بیرون گلخانه ( $V_o$ ) و تابش خورشید روی سقف گلخانه ( $I_r$ ) استفاده شد. رابطه زیر به منظور استفاده از مدل رگرسیونی مورد استفاده قرار گرفت:

$$Y = \beta_0 + \beta_r \sum_{r=1}^5 X_r \quad (5)$$

در رابطه فوق،  $\beta_0$  مقدار ثابت عرض از مبدا،  $X_r$  متغیرهای مستقل و  $\beta_r$  مقادیر ضرایب آن هاست (روحانی و همکاران، ۱۳۸۸). به منظور

<sup>1</sup>Mean Absolute Percentage Error

<sup>2</sup>Root Mean Squared Error



شکل ۴- شبکه MLP با یک لایه مخفی به منظور تخمین دمای خاک (الف) و رطوبت نسبی هوای داخل گلخانه نیمه خورشیدی (ب)

باشد، فرضیه صفر را نمی‌توان رد کرد (روحانی و همکاران، ۱۳۸۸). به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون  $F$ ،  $t$  و کولموگروف-اسمیرنو استفاده شد. مقادیر  $p$  مقایسه شده برای درصد رطوبت نسبی و دمای خاک در جدول ۴ نشان داده شده است. این نتایج نشان می‌دهند که مقایسه میانگین، واریانس و توزیع آماری مقادیر واقعی و پیش‌بینی شده دمای خاک و درصد رطوبت نسبی هوای داخل گلخانه از نظر آماری اختلاف معنی‌داری باهم ندارند و روش شبکه عصبی می‌تواند با قابلیت بالا برای تخمین پارامترهای فوق مورد استفاده قرار گیرد. همچنین با کمی دقت در نتایج این جدول می‌توان دریافت که مقادیر  $p$  برای تحلیل آماری دمای خاک از مقادیر متناظر برای درصد رطوبت نسبی بیشتر است. بنابراین می‌توان نتیجه گرفت که استفاده از شبکه عصبی برای تخمین دمای خاک موفق‌تر از تخمین درصد رطوبت نسبی هوای داخلی گلخانه عمل کرده است.

### ۳-۲- مدل رگرسیون چندگانه

در جدول ۵ نتایج حاصل از کاربرد روش رگرسیون چندگانه در تخمین پارامترهای خروجی ( $T_{is}$  و  $RH_{ia}$ ) با استفاده از مقادیر ورودی ( $T_{ia}$ ,  $I_s$ ,  $T_{ir}$ ,  $RH_{ia}$ ,  $I_r$ ,  $T_{ir}$ ,  $V_o$ ,  $T_{oa}$ ) آورده شده است. تمام ضرایب روابط رگرسیونی در این جدول در سطح احتمال ۵٪ معنی‌دار هستند. شکل ۵، هم‌بستگی بین مقادیر پیش‌بینی شده درصد رطوبت نسبی هوای گلخانه و همچنین دمای خاک با استفاده از مدل شبکه عصبی و رگرسیونی را نشان می‌دهد. همان‌طور که از این شکل‌ها به وضوح مشخص است، میزان ضریب تبیین بین داده‌های واقعی و مقادیر پیش‌بینی شده توسط شبکه عصبی برای رطوبت نسبی و دمای خاک بسیار بالاست (به ترتیب ۰/۹۹۴۵ و ۰/۹۹۷۱) و این مقادیر برای مدل رگرسیونی به ترتیب معادل ۰/۹۶۳۰ و ۰/۹۵۰۰ می‌باشد.

دریافت که کارایی شبکه عصبی در پیش‌بینی داده‌ها بسیار بهتر، بادقت بیشتر و خطای کم‌تر است. مثلاً در تحقیقی توسط شوکلا و همکاران ۲۰۰۶ به بررسی مدل‌سازی انتقال حرارت در گلخانه‌ای مجهز به صفحه حرارتی<sup>۱</sup> و آبخوان زیرزمینی<sup>۲</sup> پرداخته شد. 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 (سینک و تیواری، ۲۰۱۰). نتایج نشان داد مدل ریاضی استفاده شده قادر است دمای داخل گلخانه را با دقت قابل قبولی تخمین بزند (MAPE=۱۱/۳٪ و  $RMSE=۶/۰۶^{\circ}C$ ). توجه به این نتایج لزوم استفاده بیشتر از ابزار شبکه عصبی به‌جای 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 تلفات کلی گلخانه را به‌دست آورد.

برای بررسی بیشتر قابلیت روش شبکه عصبی مصنوعی در تخمین درصد رطوبت نسبی هوای داخل گلخانه و دمای خاک، میانگین، واریانس و توزیع آماری مقادیر واقعی و پیش‌بینی شده آن‌ها از مجموعه داده‌های فاز آزمایش، از نظر آماری مقایسه گردید. در این‌جا فرضیه صفر، بر تساوی میانگین، واریانس و توزیع آماری هر دو سری داده دلالت دارد. هر فرضیه در سطح احتمال ۹۵ درصد به کمک پارامتر  $p$  آزمایش گردید. بنابراین اگر  $p$  محاسبه شده برای هر مقایسه بیش‌تر از ۰/۰۵

<sup>۱</sup>Thermal screen

<sup>۲</sup>Under ground aquifer

جدول ۱- تغییرات پارامترهای آماری با توجه به افزایش تعداد نرون‌ها در لایه پنهان

تعداد نرون‌ها در لایه پنهان							پارامترهای آماری	مدل
۱۰	۹	۸	۷	۶	۵	۴		
۰/۹۹۱۴	۰/۹۹۴۵	۰/۹۹۲۶	۰/۹۹۳۱	۰/۹۹۲۹	۰/۹۹۰۹	۰/۹۹۱۲	$R^2$	$T_{is} = f(T_{ia}, I_s, T_{ir}, RH_{ia})$
۱/۳۴۱۵	۱/۰۶۷۹	۱/۳۴۰۰	۱/۳۳۱۸	۱/۲۱۰۲	۱/۳۵۴۹	۱/۲۵۱۴	RMSE (°C)	
۱/۴۲۱۲	۱/۱۰۶۰	۱/۳۳۹۳	۱/۲۷۹۱	۱/۳۵۸۷	۱/۴۶۹۳	۱/۴۳۱۲	MAPE (%)	
۰/۹۹۱۵	۰/۹۹۶۲	۰/۹۹۵۰	۰/۹۹۶۶	۰/۹۹۷۱	۰/۹۹۵۵	۰/۹۹۱۳	$R^2$	$RH_{ia} = f(T_{ir}, I_r, T_{ia}, T_{oa}, V_o)$
۰/۳۹۷۴	۰/۲۸۲۶	۰/۳۰۳۵	۰/۲۶۱۰	۰/۲۵۰۲	۰/۳۰۲۸	۰/۴۱۹۴	RMSE(°C)	
۱/۳۵۱۷	۱/۰۷۲۵	۱/۲۴۵۳	۱/۰۵۸۳	۱/۰۳۵۳	۱/۲۲۳۲	۱/۴۰۱۷	MAPE (%)	

جدول ۲- ویژگی‌های آماری مقادیر واقعی و پیش‌بینی شده درصد رطوبت هوا و دمای خاک در فاز آموزش

ویژگی‌های آماری							نوع داده‌ها	مدل
ske	kur	max	min	std	var	av		
-۰/۹۸۰	-۰/۴۰۴	۸۶/۲۰۰	۳۹/۰۰۰	۱۴/۲۱۲	۲۰۱/۹۹۴	۷۲/۰۵۶	داده‌های واقعی	
-۱/۰۰۸	-۰/۳۳۷	۸۰/۴۶۸	۴۱/۰۳۵	۱۴/۲۸۹	۲۰۴/۱۹۲	۷۲/۰۱۰	داده‌های پیش‌بینی شده	$T_{is} = f(T_{ia}, I_s, T_{ir}, RH_{ia})$
۰/۵۳۷	-۱/۱۷۶	۲۸/۵۵۰	۱۱/۰۰۰	۴/۵۱۶	۲۰/۳۹۵	۱۷/۷۵۷	داده‌های واقعی	
۰/۵۳۳	-۱/۱۹۹	۲۲/۵۹۳	۸/۰۸۵	۴/۴۸۵	۲۰/۱۲۰	۱۷/۷۴۴	داده‌های پیش‌بینی شده	$RH_{ia} = f(I_r, T_{ir}, V_o, T_{oa}, T_{ia})$

توضیحات: av: میانگین، var: واریانس، std: انحراف معیار، min: کمینه، max: بیشینه، kur: کشیدگی، ske: چولگی

جدول ۳- ویژگی‌های آماری مقادیر واقعی و پیش‌بینی شده درصد رطوبت هوا و دمای خاک در فاز آزمایش

ویژگی‌های آماری							نوع داده‌ها	مدل
ske	kur	max	min	std	var	av		
-۰/۹۵۴	-۰/۳۹۱	۸۳/۵۰۰	۳۶/۰۰۰	۱۴/۱۴۶	۲۰۰/۱۲۰	۷۰/۱۲۰	داده‌های واقعی	
-۰/۹۸۱	-۰/۳۵۵	۸۶/۷۳۹	۳۹/۱۱۷	۱۴/۰۲۷	۱۹۶/۷۶۳	۷۲/۲۵۶	داده‌های پیش‌بینی شده	$T_{is} = f(T_{ia}, I_s, T_{ir}, RH_{ia})$
۰/۵۸۱	-۱/۰۳۸	۳۰/۰۰۰	۱۲/۶۵۰	۴/۵۹۶	۲۱/۱۲۶	۱۷/۸۹۳	داده‌های واقعی	
۰/۶۰۰	-۱/۰۰۰	۳۰/۳۷۱	۱۲/۶۵۸	۴/۵۶۳	۲۰/۸۲۹	۱۷/۸۵۲	داده‌های پیش‌بینی	$RH_{ia} = f(I_r, T_{ir}, V_o, T_{oa}, T_{ia})$

توضیحات: av: میانگین، var: واریانس، std: انحراف معیار، min: کمینه، max: بیشینه، kur: کشیدگی، ske: چولگی

جدول ۴- مقایسه‌های آماری مقادیر واقعی و پیش‌بینی شده درصد رطوبت هوا و دمای خاک در فاز آزمایش

تحلیل آماری			نوع روش	خروجی
مقایسه توزیع	مقایسه واریانس	مقایسه میانگین		
۱/۰۰	۰/۹۷۸	۰/۹۶۴	شبکه عصبی MLP	$T_{is} = f(T_{ia}, I_s, T_{ir}, RH_{ia})$
۱/۰۰	۰/۹۳۴	۰/۹۱۴	شبکه عصبی MLP	$RH_{ia} = f(I_r, T_{ir}, V_o, T_{oa}, T_{ia})$

خاک با مدل شبکه عصبی به ترتیب ۰/۲۵، ۰/۳۳، ۰/۲۵ و ۰/۵۰ مقادیر مشابه توسط مدل رگرسیونی است. برتری دیگر روش شبکه عصبی پیش‌بینی هم‌زمان هر دو مقدار خروجی (درصد رطوبت نسبی هوا و دمای خاک) است ولی در روش رگرسیونی باید برای هر مقدار خروجی یک مدل برازش شود زیرا در تکنیک رگرسیون تنها یک متغیر خروجی یا وابسته با یک یا چند متغیر ورودی یا مستقل در نظر گرفته می‌شود. نتایج سایر تحقیقات در زمینه استفاده از شبکه عصبی مصنوعی و مدل‌های رگرسیونی در تخمین پارامترهای داخلی گلخانه نیز مطالب فوق را

در جدول ۶ معیارهای عملکردی دو روش شبکه عصبی MLP و مدل رگرسیونی چندگانه از نظر پارامترهای متوسط قدرمطلق درصد خطا، ضریب تبیین و نیز ریشه متوسط مربعات خطا در فاز آزمایش مقایسه شده است. مقایسه این دو روش بر اساس معیارهای ذکر شده، نشان از برتری مطلق شبکه عصبی چندلایه پرسپترون در مقابل مدل رگرسیونی دارد زیرا متوسط قدر مطلق درصد خطا و ریشه متوسط مربعات خطای شبکه عصبی برای تخمین درصد رطوبت نسبی و دمای



قرار گرفت. نتایج نشان داد که شبکه عصبی در تخمین این پارامتر دقت بیش تری دارد. ضریب تبیین بین داده‌های واقعی با نتایج شبکه عصبی و مدل رگرسیونی به ترتیب معادل ۰/۸۸۴۲ و ۰/۷۵۴۸ گزارش شد. در این تحقیق مدل رگرسیونی از بین مولفه‌های تاثیرگذار بر رطوبت نسبی هوای داخل گلخانه (شامل دمای هوا و رطوبت نسبی هوای بیرون، سرعت باد، میزان تابش در سطح افق، رطوبت هوای داخلی و میزان باز و بسته شدن دریچه‌های تهویه گلخانه) تغییرات دمای داخل گلخانه را بر تغییرات میزان رطوبت نسبی هوای داخل گلخانه بی تاثیر دانست. با مقایسه بین نتایج تحقیق حاضر و تحقیق هی و ما ۲۰۱۰ می‌توان به روشنی دریافت که ضریب تبیین در تخمین درصد رطوبت نسبی هوا در تحقیق حاضر توسط مدل شبکه عصبی و رگرسیونی به ترتیب حدود ۱۲ و ۲۵ درصد بیش تر است که این می‌تواند به دلایل مختلف از جمله نوع ورودی‌های و یا نحوه آموزش شبکه عصبی باشد.

تایید می‌کنند. در تحقیقی توسط داریوچی و همکاران ۲۰۰۹ از مدل شبکه عصبی MLP و همچنین مدل رگرسیون چندگانه به منظور 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. میزان ضریب تبیین برای مدل شبکه عصبی و رگرسیونی به منظور پیش‌بینی دمای داخل گلخانه در فاز آزمایش به ترتیب ۰/۹۷۲ و ۰/۹۳۲ گزارش شد. این پارامتر برای رطوبت نسبی هوای داخل گلخانه به ترتیب معادل ۰/۹۸۹ و ۰/۹۵۸ حاصل شد. نتایج کلی این تحقیق نشان داد که شبکه‌های عصبی مصنوعی می‌توانند با دقت زیاد در آینده برای پیش‌بینی پارامترهای داخلی گلخانه‌های هوشمند استفاده شود. در تحقیقی مشابه توسط هی و ما ۲۰۱۰ در کشور چین، میزان رطوبت نسبی هوای داخل گلخانه‌ای پلاستیکی توسط شبکه عصبی مصنوعی و مدل رگرسیونی مورد بررسی

جدول ۵- نتایج حاصل از مدل رگرسیون چندگانه به منظور پیش‌بینی دمای خاک و رطوبت نسبی هوای گلخانه نیمه خورشیدی

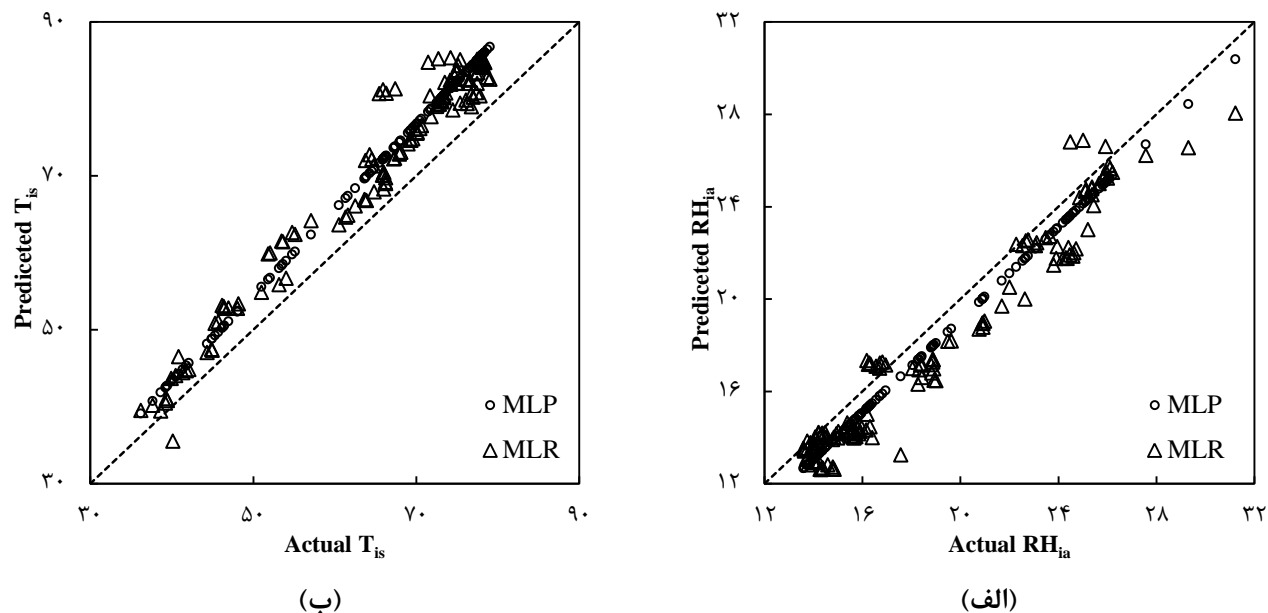
مدل	رابطه رگرسیونی	R <sup>2</sup>
$T_{is} = f(T_{ia}, I_s, T_{ir}, RH_{ia})$	$T_{is} = -14.466 + (1.665 \times T_{ia}) + (0.023 \times I_s) - (0.503 \times T_{ir}) - (0.012 \times RH_{ia})$	۰/۹۶۳
$RH_{ia} = f(I_r, T_{ir}, V_o, T_{oa}, T_{ia})$	$RH_{ia} = 45.425 - (0.086 \times T_{ia}) + (0.008 \times I_r) - (0.230 \times T_{ir}) - (0.741 \times V_o) - (0.411 \times T_{oa})$	۰/۹۵۰

جدول ۶- مقایسه پارامترهای آماری بین مدل شبکه عصبی و رگرسیونی در فاز آزمایش

نوع مدل	خروجی	پارامترهای آماری		
		R <sup>2</sup>	RMSE	MAPE (%)
MLP Regression	$T_{is} = f(T_{ia}, I_s, T_{ir}, RH_{ia})$	۰/۹۹۷۱	۱/۱۰۶۰	۱/۱۹۵۶
MLP Regression	$RH_{ia} = f(I_r, T_{ir}, V_o, T_{oa}, T_{ia})$	۰/۹۵۰۰	۲/۸۰۷۷	۳/۰۳۴۵
		۰/۹۹۴۵	۰/۲۵۰۲	۱/۰۳۵۲
		۰/۹۶۳۰	۱/۰۱۹۵	۴/۶۶۰۹

بهترین شبکه به صورت ۱-۲-۶ با مقدار R=۰/۸۹ و RMSE=۱/۰۳ میلی-متر در روز به دست آمد. در تحقیق دیگری از ابزار شبکه عصبی مصنوعی به منظور تخمین میزان عملکرد، رشد و هم‌چنین مقدار آب مصرفی در کشت گوجه فرنگی در کشور کانادا استفاده شد (اهرت و همکاران، ۲۰۱۱). داده‌های دما و میزان تابش روزانه و هفتگی از گلخانه‌ای خودکار و توسط حسگرهای حساس برداشت شد. نتایج این کار نیز حاکی از توانمندی این روش در تخمین روابط غیرخطی بین متغیرهاست. لینکر و همکاران ۱۹۹۸، از این روش به منظور تخمین میزان CO<sub>2</sub> موجود در یک گلخانه کوچک تحقیقاتی استفاده کردند. نتایج نشان داد که این روش می‌تواند در آینده نیاز کشاورزان به خرید حسگرهای گران‌قیمت CO<sub>2</sub> در گلخانه‌های کشاورزی را برطرف کند.

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. به عنوان نمونه از شبکه عصبی MLP به منظور پیش‌بینی میزان تبخیر و تعرق گیاه کاشته شده در گلخانه در کشور استرالیا استفاده شد (فلامرزی و همکاران، ۲۰۱۴). 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 مانیت (PM56) محاسبه شد. نتایج این تحقیق نشان داد که می‌توان از شبکه عصبی به عنوان ابزاری مفید برای تخمین میزان تبخیر و تعرق گیاه گلخانه‌ای استفاده کرد. ساختار



شکل ۵- مقایسه بین مدل شبکه عصبی با رگرسیون چندگانه در تخمین داده‌های (الف) درصد رطوبت نسبی هوای گلخانه و (ب) تغییرات دمای خاک گلخانه نیمه‌خورشیدی

#### ۴- نتیجه‌گیری کلی و پیشنهادات

در این تحقیق از ابزار شبکه عصبی مصنوعی و مدل رگرسیون چندگانه به منظور پیش‌بینی دمای خاک و رطوبت نسبی هوای داخل گلخانه‌ای نیمه‌خورشیدی در منطقه باسمنج شهرستان تبریز استفاده شد. داده‌های اولیه توسط حسگرهای دما، رطوبت، تابش‌سنج و بادسنج به دست آمد. از مدل پرسپترون چندلایه با یک لایه مخفی و تعداد نرون‌های مختلف و الگوریتم آموزش LM با تعداد ورودی و خروجی مشخص استفاده شد. نتایج نشان داد ساختار ۱-۹-۴ و ۱-۶-۵ به ترتیب بهترین توپولوژی برای تخمین دمای خاک گلخانه و رطوبت نسبی هوای داخل گلخانه است که به ترتیب دارای ضرایب تبیین ۰/۹۹۴۵ و ۰/۹۹۷۱ می‌باشند. نتایج حاصل از مدل رگرسیون چندگانه نشان داد که این روش در مقابل شبکه عصبی از کارایی کم‌تری برخوردار است. ضریب تبیین حاصله برای تخمین داده‌های مربوط به دمای خاک و رطوبت نسبی هوای گلخانه با این روش به ترتیب معادل ۰/۹۵۰ و ۰/۹۶۳ به دست آمد. نهایتاً می‌توان نتیجه گرفت که ابزار شبکه عصبی می‌تواند در کنترل خودکار گلخانه‌های نسل آینده مورد استفاده بسیاری قرار گیرد. پیشنهاد می‌شود نتایج مدل شبکه عصبی مصنوعی و رگرسیون چندگانه با 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.

#### سپاس‌گزاری

بدین وسیله از معاونت پژوهش و فناوری دانشگاه تبریز به دلیل مساعدت‌های مالی در اجرای این تحقیق صمیمانه تشکر و قدردانی می‌شود. هم‌چنین از زحمات و راهنمایی‌های سودمند دکتر اوتقم<sup>۱</sup> از دانشگاه واگنینگن هلند در بررسی اولیه و هم‌چنین اجرای این تحقیق کمال تشکر و قدردانی را دارد.

<sup>1</sup> Oothghem

## منابع مورد استفاده

- روحانی، ع.، ا. رنجبر، ی. عجبشیرچی، م. ح. عباسپور و م. ولیزاده. ۱۳۸۸. پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور دو چرخ محرک با استفاده از شبکه‌های عصبی مصنوعی و مقایسه آن با رگرسیون. مجله علوم کشاورزی و منابع طبیعی. جلد ۱۶، شماره ۱.
- Abdel-Ghany, A. M. and I. M. Helal. 2011. **Solar Energy Utilization by a Greenhouse: General Relations**. Renewable Energy. 36: 189-196.
- Abdel-Ghany, A. M and T. Kozai. 2006. **Dynamic Modeling of the Environment in a Naturally Ventilated, Fog-Cooled Greenhouse**. Renewable Energy. 31:1521-1539
- Abdel-Ghany, A. M. 2011. **Solar Energy Conversions in the Greenhouses**. Sustainable Cities and Society. 1: 219– 226.
- Acosta, G. and T. Marcelo. 2001. **A Firmware Digital Neural Network for Climate Prediction Applications**, in: Proceedings of the 2001 IEEE International Symposium on Intelligent Control ISIC'01, pp. 127–131.
- Al-Helal, I. M and A .M. Abdel-Ghany. 2011. **Energy Partition and Conversion of Solar and Thermal Radiation into Sensible and Latent Heat in a Greenhouse Under Arid Conditions**. Energy and Buildings. 43: 1740–1747
- Alonso J. P, M. P. Garcia, M. P. Romera and A. J. C. Ferre. 2012. **Performance Analysis and Neural Modeling of a Greenhouse Integrated Photovoltaic System**. Renewable and Sustainable Energy Reviews. 16: 4675–4685.
- Bakker, J. C, G. P. A. Bot, H. Chella and N. J. Van de Braak. 1994. **Greenhouse Climate Control**, WageningenPers Publishers, Wageningen.
- Boaventura, L., C. Couto, and A. E. B. Ruano. 2000. **A Greenhouse Climate Multivariable Predictive Controller**. ActaHorticulturae. ISHS 534: 269–276.
- Bot G.P.A. 1991. **Physical Modeling of Greenhouse Climate**, in: Proceeding of the IFAC/ISHS Workshop, 7–12.
- Coelho, J. P., J. Boaventura and P. B. de Moura Oliveira. 2002. **Solar Radiation Prediction Methods Applied to Improve Greenhouse Climate Control**, World Congress of Computers in Agriculture and Natural Resources. 13–15 March. pp. 154–161.
- Comstock, J. and J. Ehleringer. 1993. **Stomata Response to Humidity in Common Bean: Implication for Maximum Transpiration Rate, Water-Use Efficiently and Productivity**. Australian Journal of Plant Physiology 20 (6): 669–691.
- 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.
- Dreyfus, G., J.M. Martinez, M. Samuelides, M.B. Gorden, F. Badran, S. Thiria, and L. Héroult. 2004. **Réseaux de neuronesméthodologieet applications**, second ed., ISBN: 2-212-11464-8.
- Ehret D.L, B.D. Hill, T. Helmer and D.R. Edwards. 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 speeddata using artificial and wavelet neural networks (WNNs)**. Agricultural Water Management 140: 26-36.

- 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.
- Haykin, S. 1994. **Neural Networks**, MacMillan, New York.
- 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* 71: S19–S23.
- Hornik, K., M. Stinchcombe and H. White. 1989. **Multilayer feed forward networks are universal approximators,** *Neural New.* 2: 359–366.
- 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.
- 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 44th IEEE Conference on Decision and Control, and the European Control Conference, CDC-ECC'05*, pp. 4158–4162.
- Marcos, S., O. Macchi, C. Vignat, G. Dreyfus, L. Personnaz and P. Roussel- Ragot. 1992. **A unified framework for gradient algorithms used for filter adaptation and neural network training.** *Int. J. Circuit Theory Appl.* 20:159–200.
- Rohani, A., M.H. Abbaspour-Fard and S. Abdolahpour. 2011. **Prediction of tractor repair and maintenance costs using artificial neural network.** *Expert Sys. Applications* 38: 8999–9007.
- Seginer, I. 1997. **Some artificial neural network applications to greenhouse environmental control.** *Computers and Electronics in Agriculture.* 18: 167–186.
- Shukla, A., G.N. Tiwari and M.S. Sodh. 2006. **Thermal modeling for greenhouse heating by using thermal curtain and an earth–air heat exchanger.** *Building and Environment* 41 (7): 843–850.
- Singh, R.D. and G.N. Tiwari. 2010. **Energy conservation in the greenhouse system: A steady state analysis.** *Energy* 35: 2367-2373.
- Trigui, M., S.F. Barrington and L. Gauthier. 1999. **Effects of humidity on tomato water uptake, yield, and dehumidification cost.** *Canadian Agricultural Engineering* 41 (3): 135–140.
- Vadiee A. 2011. **Energy Analysis of the Closed Greenhouse Concept -Toward one Sustainable Energy Pathway.** KTH School of Industrial Engineering and Management Department of Energy Technology Division of Heat and Power Technology SE-100 44 STOCKHOLM.
- Vadiee, A. and V. Martin. 2012. **Energy management in horticultural applications through the closed greenhouse concept, state of the art.** *Renewable and Sustainable Energy Reviews* 16: 5087–5100.
- Vadiee, 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>.
- Zabeltitz C.V. 2011. **Integrated Greenhouse Systems for Mild Climates.** Springer-Verlag Berlin Heidelberg. DOI 10.1007/978-3-642-14582-7-1.
- Zarifneshat, S., A. Rohani, H.R. Ghasemzadeh, M. Sadeghi, E. Ahmadi, and M. Zarifneshat. 2012. **Predictions of apple bruise volume using artificial neural network.** *Computers and Electronics in Agriculture* 82: 75–86.
- Zhang, Y.F., and J.Y.H. Fuh. 1998. **A neural network approach for early cost estimation of packaging products.** *Computers and Industrial Engineering* 34: 433-50.

# Prediction of Soil Temperature and Inside air Humidity in a Semi-Solar Greenhouse Equipped with Cement North Wall by Artificial Neural Network; Case study: Tabriz city

M. Taki\*, Y. Ajabshirchi<sup>1</sup>, S. F. Ranjbar<sup>2</sup>, A. Rohani<sup>3</sup> and M. Matloobi<sup>4</sup>

Receive: 17 Jul 2015

Accept: 15 Mar 2016

<sup>1</sup>Department of Biosystems Engineering, Faculty of Agriculture, University of Tabriz

<sup>2</sup>Department of Mechanical Engineering, Mechanical Engineering Faculty, University of Tabriz

<sup>3</sup>Department of Biosystems Engineering, Faculty of Agriculture, Ferdowsi University of Mashhad

<sup>4</sup>Department of Horticultural Science, Faculty of Agriculture, University of Tabriz

\*Corresponding author: E-mail: [arohani@um.ac.ir](mailto:arohani@um.ac.ir)

## Abstract

The ecological domain includes some aspects of agriculture that has not a good development until now. Commercial greenhouse is one of the most effective cultivation methods need to more attentions. Researches are on intelligent greenhouses with some important aspects such as receiving the maximum solar radiation and having the minimum heat loss. In recent study, the application of Artificial Neural Network models to predict inside air humidity and soil temperature beside on some inside and outside parameters were investigated. For this purpose, data was recorded from a semi-solar greenhouse located at agricultural faculty of Tabriz University using several temperature and humidity sensors, solar meter and hot wire. This greenhouse has the best structure between all typical kinds of greenhouse and furthermore has the best situation about heat lost and gain the most solar radiation between all types of greenhouses in this region. Single layer multilayer perceptron (MLP) models with LM learning rule and different neurons in hidden layer were used. The results showed that 4-9-1 and 5-6-1 topology with  $R^2=0.9945$  and  $0.9971$  have the highest precision to predict the soil temperature and inside air humidity in semi-solar greenhouse. For these topologies, MAPE and RMSE were 1.1060, 1.1956% and 1.0353,  $0.2502^\circ\text{C}$ , respectively. Comparison between the results of ANN and multiple linear regression (MLR) models showed that ANN is more powerful than mathematical models in this subject. Also results showed that Artificial Neural Network can be used to control automatically the greenhouse environmental parameters with minimum cost in the future.

**Key words:** Semi-solar greenhouse, Artificial Neural Network, Multilayer perceptron, Automatic control