

Predictions of greenhouse soil moisture using artificial neural network and wireless network sensing

Faezeh Behzadipour¹, Mahmoud Ghasemi Nejad Raeini^{1*}, Saman Abdanan Mehdizadeh¹,
Morteza Taki¹, Bijan Khalili Moghadam², Mohammadreza Zare-Bavani³

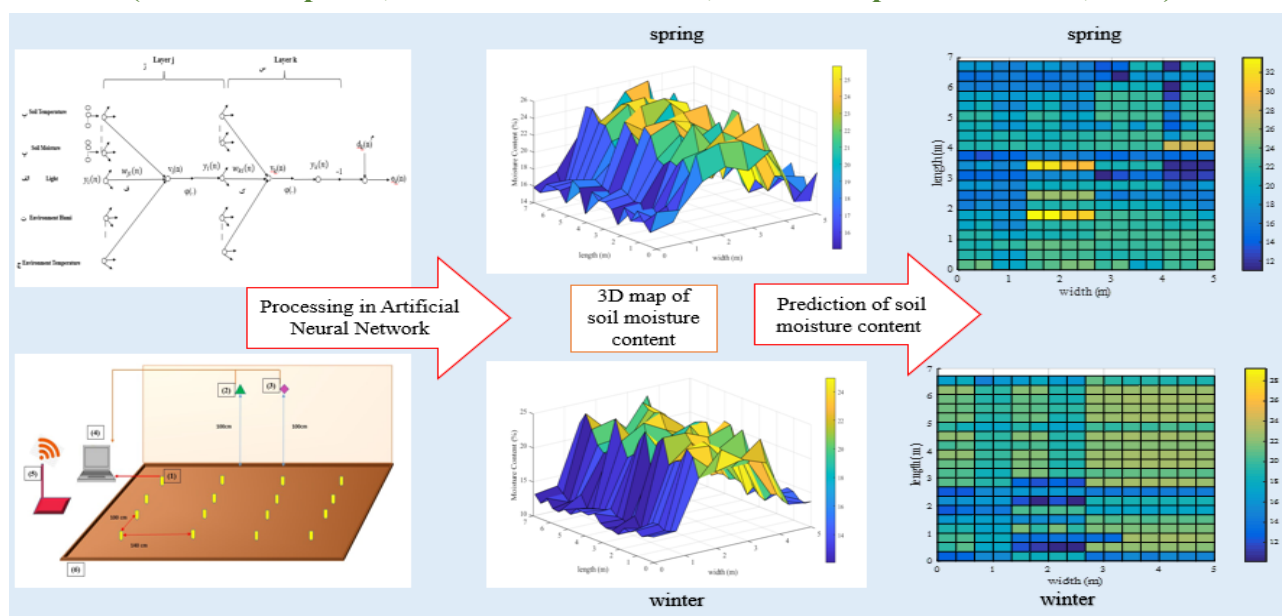
1. Department of Agricultural Machinery and Mechanization Engineering, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Natural Resources University of Khuzestan, Mollasani, Iran

*Corresponding Author's Email: ghasemi.n.m@asnrkh.ac.ir

2. Department of Soil Science, Faculty of Agriculture, Agricultural Sciences and Natural Resources University of Khuzestan, Mollasani, Iran

3. Department of Horticultural Science, Faculty of Agriculture, Agricultural Sciences and Natural Resources University of Khuzestan, Mollasani, Iran

(Received: Apr. 22, 2022- Revised: Feb. 21, 2023- Accepted: March 11, 2023)



Abstract: Soil moisture is one of the main factors determining the better growth of plants which are widely well-received today, especially in greenhouses. Measuring the soil moisture and the environmental factors has high costs continuously and annually, in addition to being time-consuming. Therefore, one of the intelligent predictive tools that have a vast position in agricultural science is the neural network tool with the least amount of error. In this study, soil moisture and temperature percentage, light, ambient temperature, and humidity in a greenhouse located in northeastern Khuzestan were Measured and recorded during two seasons of winter and spring to control soil moisture by a moisture prediction map based on an artificial neural network. The results show an accurate forecast of soil moisture map in winter and spring between actual values that were measured and values that were predicted with the lowest standard error (1.12 and 1.71) and the highest coefficient of determination (R^2) of 0.94 and 0.78, respectively, and the highest coefficient of determination were 0.87 and 0.93, respectively, by the artificial neural network in the experimental stage for winter and spring. Therefore, the remarkable accuracy in the prediction of soil moisture by this software shows its importance and high reliability in agriculture and greenhouses which makes it easier to control soil moisture and less moisture stress occurs for soil and the plant consequently.

Keywords: Forecast, Artificial Neural Network, Greenhouse, Soil Moisture Map, Smart

پیش‌بینی رطوبت خاک گلخانه با استفاده از شبکه عصبی مصنوعی و حسگرهای شبکه بی‌سیم

فائزه بهزادی پور^۱، محمود قاسمی نژاد رائینی^{۱*}، سامان آبدانان مهدی زاده^۱، مرتضی تاکی^۱، بیژن خلیلی مقدم^۲، محمدرضا زارع بوانی^۳

۱. گروه مهندسی ماشین‌های کشاورزی و مکانیزاسیون، دانشکده مهندسی زراعی و عمران روستایی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، ملاتانی، ایران

* ایمیل نویسنده مسئول: ghasemi.n.m@asnrukh.ac.ir

۲. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، ملاتانی، ایران

۳. گروه علوم و مهندسی باغبانی، دانشکده کشاورزی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، ملاتانی، ایران

(تاریخ دریافت: ۱۴۰۱/۲/۲ - تاریخ بازنگری: ۱۴۰۱/۱۲/۲ - تاریخ تصویب: ۱۴۰۱/۱۲/۲۰)

چکیده: رطوبت خاک یکی از اصلی‌ترین عوامل تعیین‌کننده برای رشد بهتر گیاهان به ویژه در گلخانه‌ها که امروزه بصورت گسترده‌ای مورد استقبال قرار گرفته‌اند، می‌باشد. اندازه‌گیری رطوبت خاک و عوامل محیطی بصورت پیوسته و سالانه، علاوه بر وقتگیر بودن، هزینه‌های زیادی را در پی دارد. از این‌رو یکی از ابزارهای پیش‌بینی‌کننده هوشمند که امروزه با کمترین میزان خطا جایگاه وسیعی در علم کشاورزی به خود اختصاص داده، ابزار شبکه عصبی می‌باشد. در این پژوهش به منظور کنترل رطوبت خاک توسط نقشه پیش‌بینی رطوبت مبتنی بر شبکه عصبی مصنوعی، درصد رطوبت و دمای خاک، میزان نور، دما و رطوبت محیط در گلخانه‌ای واقع در شمال شرقی خوزستان، طی دو فصل زمستان و بهار اندازه‌گیری و ثبت گردید. نتایج نشان از پیش‌بینی دقیق نقشه رطوبتی خاک در فصل زمستان و بهار به ترتیب با کمترین میزان خطای استاندارد (۱/۱۲ و ۱/۷۱) و بالاترین ضریب تعیین (R^2) به ترتیب ۰/۹۴ و ۰/۷۸ بین مقادیر اندازه‌گیری شده واقعی و مقادیر پیش‌بینی شده در مرحله آموزش و بالاترین ضریب تعیین در مرحله آزمایش برای فصل زمستان و بهار به ترتیب ۰/۸۷ و ۰/۹۳ توسط شبکه عصبی مصنوعی داشتند. بنابراین دقت قابل توجه در پیش‌بینی رطوبت خاک توسط این نرم‌افزار نشان از اهمیت و قابلیت اطمینان بالای آن در امور کشاورزی و گلخانه‌ای دارد که به موجب آن، کنترل رطوبت خاک آسان‌تر گردیده و تنش‌های رطوبتی کمتری برای خاک و به تبع آن برای گیاه رخ می‌دهد.

کلمات کلیدی: پیش‌بینی، شبکه عصبی مصنوعی، گلخانه، نقشه رطوبت خاک، هوشمند

مقدمه: مشکل مهم جهانی محسوب می‌گردند. آب در روش‌های در جهان امروزی، انرژی و آب مورد نیاز گیاهان، دو سنتی آبیاری، بدون توجه به نیازهای آبی گیاهان توزیع

توسعه الگوریتم‌های یادگیری، تخمین و تصمیم‌گیری، مطالعاتی مربوط به کاربرد این الگوریتم‌ها در زمینه کشاورزی انجام شده است (Yang et al., 1997; Alavi et al., 2010; Veronez et al., 2010). پژوهش‌هایی با استفاده از الگوریتم‌های کنترل و تخمین، برآورد رطوبت خاک را در چندین پارامتر انجام داده‌اند (Ahmad et al., 2010; Ramirez-Beltran et al., 2010). این مطالعات معمولا شبکه‌های عصبی مصنوعی (ANN)، منطق فازی و الگوریتم‌های ژنتیکی یا ترکیبی از این الگوریتم‌ها را آزمایش نمودند (Barikloo et al., 2017; Khanali et al., 2018). شبکه عصبی مصنوعی نه تنها در آبیاری بلکه در کوددهی، و کنترل و پیش بینی مواد شیمیایی خاک نیز استفاده می شود (Akbarzadeh et al., 2009; Dursun and Karaman, 2009). شبکه عصبی مصنوعی از دقیق ترین روش ها برای تعیین توزیع رطوبت خاک است. در پژوهشی با تخمین ضرایب رطوبتی خاک با شبکه عصبی مصنوعی، مقدار خطای استاندارد را در مرحله آموزش برابر با ۱/۹ گزارش نمودند (Hafezi et al., 2014)، همچنین در بررسی محتوای رطوبتی خاک با چند روش از جمله شبکه عصبی مصنوعی بوسیله تصاویر تلفن همراه، با استفاده از ۲۲ نقطه پیش‌بینی کننده، میزان ضریب تعیین و خطای استاندارد را ۰/۷۷ و ۱۲/۴۳ گزارش نمودند بنابراین با توجه به تحقیقات صورت گرفته دقت شبکه عصبی توسعه یافته در مرحله آموزش قابل قبول می‌باشد (Taneja et al., 2021). در پژوهشی دیگر، چهار ترکیب از خاک برای پیش‌بینی ظرفیت زراعی و نقطه پژمردگی خاک با استفاده از شبکه عصبی مصنوعی مورد بررسی قرار گرفت که ضریب تعیین و خطای استاندارد در مرحله آموزش برای ظرفیت زراعی به ترتیب ۰/۸۵ و ۹/۹۶ و در مرحله آموزش به ترتیب ۰/۷۷ و ۹/۳۶ بود همچنین برای پیش‌بینی نقطه پژمردگی خاک میزان ضریب تعیین و خطای استاندارد را به ترتیب ۰/۸۲ و ۱۱/۹۷ در مرحله آموزش و ۰/۷۳ و ۱۳/۷۷ در مرحله آموزش ثبت کردند (Yamaç et al., 2020). در پژوهشی سیستم آبیاری هوشمند با استفاده

می‌شود؛ این در حالی است که توزیع رطوبت در خاک یکنواخت نبوده و نیاز آبی گیاهان یکسان نیست. در آبیاری مرسوم، بخش‌هایی از باغ یا مزرعه را به صورت غیرضروری آبیاری می‌شود که این امر سبب کاهش در راندمان آب و انرژی می‌گردد. به همین دلیل استفاده کارآمد از آب و انرژی در سامانه‌های آبیاری قطره‌ای در کشاورزی اهمیت بالایی دارد. از آنجا که مصرف آب در آبیاری قطره‌ای برای تولید محصولات زراعی کمتر است استفاده از این سامانه آبیاری نسبت به دیگر روش‌ها (بارانی، غرقابی و ...) ارجح می‌باشد (Dursun & Ozden, 2012). به منظور کاهش هزینه‌های نصب و استفاده بهینه از انرژی، تخمین دقیق میزان تقاضای آب و رطوبت در ساختار خاک لازم است.

در سال‌های اخیر، سامانه‌های آبیاری محلی (سایت‌های مخصوص) برای افزایش کارایی مصرف آب و انرژی به منظور جلوگیری از آبیاری غیرضروری یا توزیع نامناسب آب توسعه یافته‌اند. این روش نه تنها کاهش در هزینه‌های عملیاتی (انرژی، آب) را فراهم می‌کند بلکه منجر به افزایش کارایی محصول نیز می‌گردد (Wang et al., 2014; Kim and Evans, 2009; Aqeel-ur et al., 2006). از جمله این سامانه‌ها می‌توان به استفاده از فناوری‌های شبکه بی‌سیم به منظور جمع‌آوری و پردازش داده‌های سنسورهای مختلف در مزارع با ساختار ناهمگون خاک یا دارای گیاهان متفاوت اشاره نمود (Charoenhirunyingyos et al., 2011). با وجود قابلیت بالای این حسگرها، توسعه شبکه‌های حسگر بی‌سیم بدلیل هزینه بالای نصب آنها غیر اقتصادی محسوب می‌گردند. این در حالی است که مطالعات متعددی بر کاهش هزینه‌های این سامانه‌ها متمرکز شده است به گونه‌ای که پیاده‌سازی این سامانه‌ها را از نظر اقتصادی مقرون به‌صرفه می‌نماید (Dursun & Karaman, 2009; Angelopoulos et al, 2011; Ozden & Dursun, 2011).

الگوریتم‌ها و برنامه‌های مختلفی برای تعیین مقادیر رطوبت خاک با یا بدون سنسورها وجود دارد. با

بوسیله کانال آنالوگ میکروکنترلر جمع آوری شد. اطلاعات نقطه‌ای و مقادیر رطوبت خاک ارسال شده به واحد مرکزی، روی کامپیوتر بوسیله نرم افزار متلب ۲۰۱۸ ثبت شدند. شکل (۱) شماتیک مدار الکترومکانیکی سامانه آبیاری را نمایش می‌دهد.

در این مطالعه از ۱۶ عدد سنسور رطوبت خازنی (مدل SEN0193، کشور چین) با دقت ۰/۱ که مقدار آب حجمی خاک را به کمک ویژگی‌های دی الکتریک آب اندازه‌گیری می‌نمود، استفاده گردید. این ماژول به دلیل اندازه‌گیری آنالوگ، به صورت بدون وقفه، مقدار رطوبت را اندازه‌گیری می‌نماید. بعلاوه از ماژول دماسنج مادون قرمز غیرتماسی (مدل MLX90615، کشور چین) با دقت ۰/۰۲ درجه سلسیوس، ۱۶ عدد حسگر دمای بستر (DS18B22، کشور تایوان) با دقت ۰/۱ درجه سلسیوس و حسگر نوری (MAX44009، کشور چین) با دقت ۰/۰۱ نیز در سامانه آبیاری استفاده گردید. ۱۶ حسگر مربوط به دما و رطوبت خاک، به منظور جمع‌آوری داده‌ها بصورت محلی، در ۱۶ نقطه از محیط گلخانه در فواصل ۱۰۰*۱۴۰ سانتی‌متر (شکل ۲) نصب شدند، دما و رطوبت خاک برای بقیه نقاط مد نظر (از ۱۵*۲۱ نقطه) در فواصل ۳۳ سانتی‌متر، بصورت دستی (دستگاه مجهز به حسگر رطوبت و دمای خاک دستی) اندازه‌گیری و ثبت شدند. همچنین حسگرهای نور، دما و رطوبت محیط در ارتفاع یک متری از سطح خاک قرار گرفتند (Taki et al., 2016).

داده‌های ثبت شده برای آموزش و ارزیابی شبکه عصبی مصنوعی استفاده شدند (شکل ۲). پارامترهای رطوبت و دمای خاک (مربوط به ۱۶ حسگر نصب شده)، شدت نور، دما و رطوبت محیط بعنوان پارامترهای ورودی شبکه عصبی مصنوعی قرار گرفتند (Dursun & Ozden, 2012). برای ارتباطات وای‌فای از ماژول ESP8266 (مدل ESP-01، کشور چین) بهره گرفته شد. این ماژول کم مصرف با استفاده از فرکانس ۲/۴ گیگاهرتز امکان اتصال وای‌فای تا ۴۰۰-۵۰۰ متر در فضای باز را فراهم می‌آورد. به منظور اندازه‌گیری مصرف آب از یک حسگر

از شبکه عصبی عمیق مورد توسعه و ارزیابی قرار گرفت. آنها از روش یادگیری k-نزدیکترین همسایه (KNN) برای رفع مشکل از دست دادن داده برای مجموعه و نیز از CPU و RAM استفاده نمودند. بنابر نتایج، مدل‌های پیش‌بینی شده در این پژوهش، کارایی رضایت بخشی داشتند و باعث بهبود صرفه‌جویی در مصرف آب آبیاری شدند همچنین آنها اذعان نمودند که این مدل‌ها قادر به اجرا در زمینه اینترنت اشیا نیز می‌باشند. (Cordeiro et al., 2022).

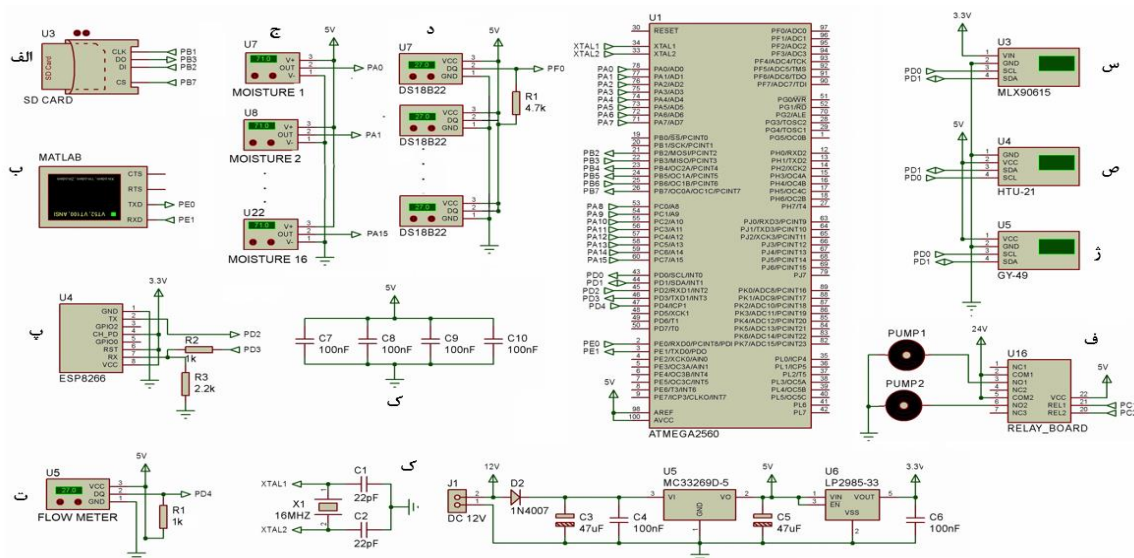
در این پژوهش با بکارگیری یکی از روش‌های جدید سنجش و تخمین رطوبت خاک که امکان استفاده کارآمدتر از انرژی و منابع آب پاک را بطور روزانه کاهش می‌دهد، نقشه توزیع رطوبتی خاک پیش‌بینی گردید؛ این نقشه کمک شایانی به کشاورز در جهت کاهش مصرف آب و کنترل رطوبت خاک مطابق با شرایط محیطی حاکم بر گلخانه می‌کند. توزیع رطوبت خاک در منطقه‌ای با مقیاس کوچک با استفاده از اطلاعات رطوبتی به دست آمده توسط حسگرهای رطوبتی که در خاک قرار داده شده بود از طریق شبکه عصبی مصنوعی تخمین زده شد و از آن برای کنترل یک سامانه کامل آبیاری استفاده گردید. با استفاده از سامانه توسعه یافته، اندازه‌گیری رطوبت به صورت پیوسته و برخط انجام و میزان آب مورد نیاز نیز مطابق با شرایط متغیر دما و رطوبت گلخانه و دمای سطح و عمق خاک کنترل شد.

مواد و روش‌ها

این مطالعه در منطقه شمال شرقی استان خوزستان مستقر در دانشگاه علوم کشاورزی و منابع طبیعی خوزستان انجام شد. در این مطالعه، گلخانه‌ی شیشه‌ای نیمه دوطرفه شرقی-غربی (در عمق ۱,۵ متری زمین) با متراژ ۳۵ مترمربع (۷×۵ متر) در نظر گرفته شد که به ترتیب ۲۱ و ۱۵ نقطه با فواصل ۳۳ سانتیمتر در طول و عرض گلخانه برای اندازه‌گیری رطوبت خاک ایجاد گردید. مقادیر رطوبت خاک توسط سنسورهای نصب شده در محل‌های معین بدست آمد. مقادیر رطوبتی


با فواصل زمانی ۵ ساعته در فصل زمستان و بهار، انتخاب و در نرم افزار IBM SPSS Statistics 26.0.0.1 مورد بررسی و تجزیه و تحلیل قرار گرفت.

چرخشی (مدل YF-S201، کشور چین) با دقت ۰/۱ به همراه حسگر اثر هال استفاده شد. مراحل ثبت داده توسط حسگرها بصورت پیوسته صورت گرفت که به منظور بررسی تاثیر زمان بر میزان رطوبت خاک، ۵ داده



شکل ۱- شماتیک مدار الکترومکانیکی سامانه آبیاری، (الف) (SD CARD): کارت حافظه، (ب) (MATLAB): پورت سریال، (پ) (ESP8266): ماژول ارتباط با وای فای، (ت) (U5): دبی سنجر، (ج) (U7-U22): سنسورهای دمای خاک، (د) (DS18B22): سنسورهای دمای خاک، (س) (MLX90615): سنسور دمای گیاه، (ر) (HTU21): سنسور دما و رطوبت محیط، (و) (GY-49): سنسور نور، (ف) (PUMP(1,2) & RELAY-BOARD): پمپ ها و شیرهای برقی، (ک) (خازن های C1-C7): مدار راه انداز میکروکنترلر

Figure 1- Schematic of the electromechanical circuit of the irrigation system, (a) (SD CARD): memory card, (b) (MATLAB): serial port, (p) (ESP8266): Wi-Fi connection module, (t) (U5): flow meter, (g) (U7-U22): sensor of soil moisture, (d) (DS18B22): sensor of soil temperature, (s) (MLX90615): sensor of plant temperature, (r) (HTU21): Ambient temperature and humidity sensor, (v) (GY-49): light sensor, (f) (PUMP 1,2) & RELAY-BOARD): Pumps and solenoid valves, (k) (CAPACITOR C1-C7): Microcontroller driver circuit



شکل ۲- شماتیک حسگرهای نصب شده در گلخانه، (۱) حسگر دما و رطوبت بستر خاک (۲) حسگر نور (۳) حسگر دما و رطوبت محیط (۴) رایانه (۵) وای فای (۶) بستر خاک

Figure 2- Schematic of sensors installed in the greenhouse, (1) soil temperature and humidity sensor (2) light sensor (3) ambient temperature and humidity sensor (4) laptop (5) wi-fi (6) soil bed

رطوبت خاک، نیاز به کالیبراسیون این حسگر با رطوبت واقعی خاک می باشد. به جهت کالیبراسیون سنسورهای رطوبت خاک، ابتدا ۵ ظرف محتوی خاک وزن شد سپس


کالیبراسیون حسگر رطوبت خروجی حسگر رطوبت آنالوگ ولتاژ خروجی آن بین صفر تا ۳ ولت است. لذا به منظور تحلیل دقیق میزان

مغز انسان نیاز است مانند یادگیری، طبقه‌بندی، پیش‌بینی عملکرد و غیره استفاده نمود (Izgi et al., 2012). در شکل ۳، یک مدل شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) که دارای یک خروجی و ورودی‌های متعدد است، ارائه شده است. در این پژوهش، شبکه عصبی پرسپترون چند لایه (MLP) با یک لایه پنهان، شش ورودی و یک خروجی در نظر گرفته شد. به منظور آموزش شبکه عصبی، پارامترهای ورودی شبکه (مطابق با شکل ۲) متشکل از رطوبت و دمای خاک (اعداد ثبت شده مربوط به ۱۶ حسگر نصب شده در محل‌های مشخص در محیط گلخانه)، شدت نور، دما و رطوبت محیط بودند و پارامتر خروجی شامل رطوبت خاک (در نقاط میانی و بین حسگرهای نصب شده در نظر گرفته شد که بصورت دستی در فواصل ۳۳ سانتی‌متر اندازه‌گیری گردید) بود. شایان ذکر است که به منظور تعیین توپولوژی مناسب برای شبکه، تعداد نورون‌ها در لایه پنهان به روش سعی و خطا تعیین گردید (Cai et al, 2020).

ظروف به مدت ۲۴ ساعت در آون، حرارت دیده و خاک کاملاً خشک گردید. ظروف محتوی خاک خشک، مجدداً وزن شدند. میزان آب اضافه شده به خاک‌ها به ترتیب ۰، ۲۰، ۴۰، ۶۰ و ۸۰ میلی‌لیتر بود که ظرف اول بصورت کاملاً خشک (صفر میلی‌لیتر) و ظرف پنجم بصورت اشباع (۸۰ میلی‌لیتر) منظور گردیدند (Moravejalahkami and Baghshahi, 2020). در ادامه، به منظور رسم نمودار کالیبراسیون از نرم‌افزار Excel. 2016 استفاده گردید.

مدل و شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی برنامه‌های رایانه‌ای هستند که با الهام از فیزیولوژی مغز انسان، توانایی مدسازی فرآیندهای پیچیده را دارند. شبکه‌های عصبی دارای مکانیسم‌های خود یادگیری هستند و علاوه بر این، توانایی ایجاد روابط بین حافظه و اطلاعات خود را نیز دارند (Moreno et al., 2011). شبکه‌های عصبی را می‌توان با موفقیت در مسائلی که به ویژگی‌های عملکردی مشابه



شکل ۳- مدل شبکه عصبی مصنوعی، $y_i(n)$: ورودی‌های شبکه شامل الف) Light: نور (ب) soil temperature: دمای خاک، (پ) soil Moisture: رطوبت خاک، (ت) Environmental Humidity: رطوبت محیط، (ج) Environmental temperature: دمای محیط، (و) Layer j: لایه میانی اول، (س) Layer k: لایه میانی دوم، (ف) $w_{ji}(n)$: وزن ورودی‌ها در لایه میانی اول، (ک) $w_{ki}(n)$: وزن ورودی‌ها در لایه میانی دوم، (م) $d_k(n)$: لایه خروجی

Figure 3- Artificial neural network model, $y_i(n)$: Network inputs including (a) light, (b) soil temperature, (p) soil Moisture, (t) Environmental Humidity, (j) Environmental temperature, (v) Layer j: The first middle layer, (s) Layer k: The second middle layer, (f) $w_{ji}(n)$: The weight of the inputs in the first middle layer, (k) $w_{ki}(n)$: The weight of the inputs in the second middle layer, (m) $d_k(n)$: output layer

مقدار خروجی هدف و $e_k(n)$ میزان خطا می‌باشد. با دانستن اینکه m تعداد نورون در لایه پنهان است، مقدار

که در این شکل، n تعداد تکرار، $y_i(n)$ مقادیر ورودی، $w_{ji}(n)$ مقادیر وزنی i و j : $\phi(\cdot)$ تابع فعالساز، $d_k(n)$

(رابطه ۵)

$$R^2 = \frac{(\sum_{i=1}^N (y_i - \tilde{y}_i)(\tilde{y}_i - \hat{y}_i))^2}{\sum_{i=1}^N (y_i - \tilde{y}_i)^2 \sum_{i=1}^N (\tilde{y}_i - \hat{y}_i)^2}$$

که در این رابطه Y_i مقدار اندازه گیری شده، \tilde{y}_i مقدار پیش بینی شده توسط مدل و n تعداد داده‌ها است که برای محاسبه خطای استاندارد در مرحله آموزش، تعداد ۴۰۰ داده و در مرحله آزمون، تعداد ۱۹۸ داده در نظر گرفته شد.

در پایان، بررسی‌های آماری با نرم افزار IBM Spss Statistics 26.0.0.1 و Excel 2016 انجام و نتایج بصورت جدول و نمودار ارائه گردید. همچنین نقشه پیش‌بینی رطوبت خاک پس از آموزش و آزمایش شبکه عصبی مصنوعی در نرم افزار Matlab R2018a رسم شد (Dursun & Ozden, 2012).

نتایج و بحث

شکل ۴ (الف و ب) نقشه سه بعدی توزیع محتوای رطوبتی خاک (رطوبت داخلی خاک) برای فصل زمستان و بهار را نشان داده است. به منظور بررسی و نمایش تغییرات در میزان رطوبت خاک، بازه زمانی آبیاری خاک (بین ساعات ۱۰-۹ صبح) مدنظر قرار گرفت و نقشه سه بعدی مربوط به رطوبت خاک در این بازه زمانی، رسم گردید (Dursun & Ozden, 2014).

در شکل ۴ (الف و ب) رنگ‌بندی رطوبت خاک از رنگ آبی تیره (رطوبت کمتر) به سمت رنگ زرد (رطوبت بیشتر) متغیر است بنابراین همانطور که در نقشه نمایان است، اثرات حاشیه‌ای گلخانه بر رطوبت خاک تاثیرگذار بوده و با توجه به اینکه تاثیر انرژی تابشی خورشید بر گرمایش گلخانه، از نواحی مجاور پوشش آغاز و به تدریج به سمت مرکز گلخانه توسعه می‌یابد لذا آهنگ افزایش رطوبت خاک در حاشیه گلخانه کمتر است که این کاهش درصد رطوبت در عرض ۰-۵ و طول ۰-۷ متر قابل مشاهده می‌باشد. از سویی دیگر درصد بالاتر رطوبت

واقعی خروجی متعلق به یک نورون در شبکه پیشخور^۱ از رابطه (۱) بدست می‌آید (Dursun & Ozden, 2014):

$$y_i(n) = \varphi\left(\sum_{j=0}^m w_{ji}(n)y_j(n) + b_i(n)\right)$$

در این پژوهش به ترتیب از تابع انتقال تانژانت هایپربولیک^۲ و خطی به عنوان تابع انتقال میان ورودی و لایه پنهان و میان لایه پنهان و خروجی استفاده شد. در ضمن به منظور به روز رسانی مقادیر وزن و به حداقل رساندن خطا و بایاس مقادیر وابسته به مقدار خطا از الگوریتم پس‌انتشار خطا استفاده گردید (رابطه ۲) (Dursun & Ozden, 2014).

(رابطه ۲)

$$w_{ij}^l(n+1) = w_{ij}^l(n) + \alpha [w_{ij}^l(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n)$$

در رابطه (۳)، η نشان دهنده ضریب یادگیری و δ نمایانگر شیب محلی^۳ است. یکی از بزرگترین معایب الگوریتم پس انتشار، همگرایی آهسته آن است. همانطور که در رابطه (۲) نشان داده شده است، این عیب با افزودن بخش اصطلاحی ممنوم (α) از بین می‌رود. آموزش ممنوم با افزایش سرعت، همگرایی را پایدارتر می‌نماید. بعلاوه، از گیرافتادن شبکه در حداقل محلی جلوگیری می‌کند (Dursun & Karaman, 2009). شیب محلی $\delta_k(n)$ همانطور که در رابطه (۳) نشان داده شده است، محاسبه می‌گردد (Dursun & Ozden, 2014):

$$\delta_k(n) = e_k(n) \varphi'(v_k(n))$$


(رابطه ۳)

به منظور ارزیابی شبکه عصبی پرسپترون چند لایه و بررسی میزان خطا بین مقادیر اندازه‌گیری و پیش‌بینی شده توسط آن، خطای استاندارد (RMSE) و ضریب تبیین (R^2) از رابطه (۴) و (۵) محاسبه گردید (Merdun et al., 2006; zhang et al., 2021).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \tilde{y}_i)^2}$$


(رابطه ۴)

در قسمت میانی گلخانه (رنگ‌های سبز، نارنجی و زرد) قرار دارد. بعلاوه دامنه رطوبتی خاک در زمستان حداکثر ۲۶ تا ۲۵ درصد (محدوده بین ۱۶-۲۶ درصد) و در بهار حداکثر ۲۵ تا ۲۵ درصد (محدوده بین ۱۴-۲۵ درصد) است.



الف

a



ب

b

شکل ۴. نقشه سه بعدی پیش بینی توزیع محتوای رطوبتی خاک (درصد) (رنگ آبی: رطوبت کمتر، رنگ زرد: رطوبت بیشتر)، length: طول گلخانه (متر)، width: عرض گلخانه (متر) الف. در فصل زمستان ب. در فصل بهار

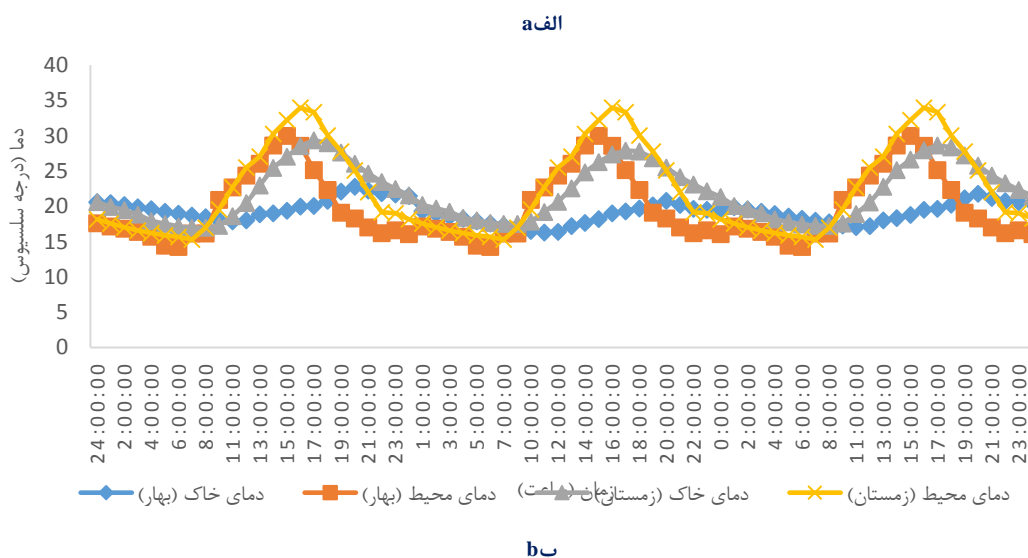

Figure 4. Predicted 3D map of soil moisture content (%) (Blue color: minimum of soil moisture, yellow color: maximum of soil moisture), length: length of greenhouse (m), width: width of greenhouse (m), (a) in winter season (b) in spring season

گردید، هرچند با اعمال آبیاری سعی در تعدیل نوسان رطوبتی خاک گردید. با نگاهی به تغییرات دمای محیط و رطوبت خاک برای فصل بهار، با افزایش دمای محیط بین ساعات گرمتر روز (۱۱ صبح تا ۱۹ عصر)، نوسانات رطوبتی خاک بیشتر شده و با کاهش دمای محیط، رطوبت خاک روندی تقریباً یکنواخت را طی می‌کند. مطابق با شکل ۵، نوسانات رطوبتی بیشتری در خاک برای فصل بهار نسبت به فصل زمستان مشاهده

به منظور بررسی دقیقتر اثر زمان بر تغییرات دما و رطوبت خاک شکل ۵ (الف و ب) طی ۲۴ ساعت شبانه روز ترسیم گردید. با توجه به شکل ۵ (الف)، اختلاف دمای چشمگیری بین ساعات ۱۱ صبح تا ۱۷ عصر و ساعات ۱ شب تا ۷ صبح مشاهده می‌شود که کاهش یا افزایش میزان رطوبت خاک ناشی از تغییرات دمای محیط در بازه زمانی مطرح شده بود و این مساله در طول مدت پژوهش طی یک روز داده‌برداری مشاهده

تغییرات رطوبت خاک بین ساعات ۱۳ تا ۱۶ ظهر در فصل بهار و زمستان به ترتیب ۹ درصد و ۴ درصد کاهش بود که کاهش بیشتر رطوبت خاک در فصل بهار بدلیل نوسانات رطوبتی بیشتر می باشد.

می گردد؛ دلیل نوسانات بیشتر در فصل بهار اختلاف بیشتر دما نسبت به فصل زمستان می باشد به صورتیکه بیشترین و کمترین دما در فصل بهار ۳۴ و ۱۵ درجه سلسیوس و بیشترین و کمترین دما در فصل زمستان به ترتیب ۳۰ و ۱۴ درجه سلسیوس مشاهده گردید. درصد



شکل ۵ الف. تغییرات دمای محیط و رطوبت خاک در فصل زمستان و بهار ب. تغییرات دمای محیط و دمای خاک در فصل زمستان و بهار
 Figure 5. a. Changes in environment temperature and soil moisture in winter and spring season b. Changes in environment temperature and soil temperature in winter and spring season

خاک در فصل بهار نسبت به زمستان کمتر است؛ تغییرات دمای محیط در فصل بهار بین ساعات ۱۳ تا ۱۶ ظهر که دارای روند افزایشی ۲۵ درصدی بود باعث افزایش ۱۸ درصدی تغییرات دمای خاک گردید اما در فصل زمستان، تغییرات دمای محیط روند افزایشی ۹ درصدی داشت که باعث افزایش ۶۳ درصدی تغییرات

تغییرات دمای محیط و تغییرات دمای خاک را به ترتیب در فصل زمستان و بهار بر حسب زمان طی ۲۴ ساعت نمایش می دهد. بر این اساس با افزایش دمای محیط طی ساعات شبانه روز، دمای خاک نیز دچار روندی افزایشی شده و با کاهش دمای محیط، روند کاهش دمای خاک مشاهده گردید. تغییرات دمایی

سانتی متری کاهش یافت، همچنین بین پارامتر رطوبت نسبی هوا و دمای خاک ارتباط معکوس مشاهده شد (Baaghiddeh et al., 2019).

در این پژوهش، به منظور بررسی اثر زمان در طی شبانه روز بر میزان رطوبت خاک، ابتدا از ۵ داده ثبت شده توسط حسگرها استفاده گردید و اثر زمان بر رطوبت خاک مورد بررسی آماری قرار گرفت. نتایج مقایسات میانگین در سطح معنی داری ۰/۰۵ با آزمون توکی حاکی از عدم تاثیر معنی دار زمان بر میزان رطوبت خاک در هر دو فصل زمستان و بهار (جدول ۱) بود بدین معنی که تفاوتی بین زمان ثبت داده‌ها در طی شبانه روز نبوده و می‌توان بجای ثبت ۵ داده مربوط به رطوبت خاک، از ۱ داده برای تعیین میزان رطوبت، تصمیم گیری برای آبیاری و همچنین آموزش شبکه عصبی مصنوعی بهره جست.

جدول ۱- آنالیز اثر زمان بر رطوبت خاک در زمستان و بهار

Table 1- Analysis of the effect of time on soil moisture in winter and spring

معنی داری	میانگین توان دوم	درجه آزادی	میانگین توان دوم
۰/۹۹ ^{n.s}	۵/۱۷	۴	زمستان
۰/۱۸ ^{n.s}	۱۴/۹۴	۴	بهار


n.s: عدم معنی داری در سطح احتمال ۵ درصد

به منظور آموزش شبکه عصبی، از هفتاد درصد داده‌های اندازه‌گیری شده در فصل زمستان و بهار استفاده گردید (Sanuade et al., 2020). با آموزش شبکه توسط مقادیر بدست آمده از حسگرهای مستقر در منطقه، نقشه توزیع رطوبت در خاک با استفاده از شبکه عصبی مصنوعی تعیین و پیش‌بینی گردید که تعداد نورون‌های بهینه، ۱۱ نورون در لایه میانی بود. در مرحله آموزش به منظور ارزیابی شبکه عصبی میان خروجی (داده‌های پیش‌بینی شده) آن و داده‌های واقعی (اندازه‌گیری شده) و برازش خطی صورت پذیرفت (شکل ۶ الف و ب) و ضریب تعیین و میزان خطای استاندارد

دمایی خاک گردید. در خاک‌های با رطوبت بیشتر بدلیل نقش خنک‌کنندگی رطوبت برای خاک، سرعت انتقال و توزیع انرژی حرارتی در خاک کند می‌شود (Sabziparvar et al., 2010). همچنین با افزایش عمق خاک، به تدریج ارتباط دمای خاک با پارامترهای دمای کاهش می‌یابد هرچند عوامل متعددی همچون ویژگی‌های پروفیل خاک، بافت خاک، هدایت گرمایی، گرمای ویژه و غیره می‌توانند منجر به تغییر دمای خاک شوند (Baaghiddeh et al., 2019). از سویی دیگر همانطور که ذکر گردید تغییرات رطوبتی خاک در فصل بهار نسبت به زمستان بیشتر بود، می‌توان چنین بیان نمود که کاهش رطوبت خاک در فصل بهار باعث کاهش نوسانات دمایی شده همچنین رطوبت بیشتر هوا در فصل بهار نسبت به هوای سرد و خشک زمستان عاملی برای کاهش توزیع حرارتی بیشتر در خاک می‌باشد و بدین ترتیب تغییرات دمایی خاک در فصل بهار نسبت به زمستان کمتر بود. در پژوهشی به بررسی رطوبت خاک در چند لایه با استفاده از ماشین بینایی پرداخته شد، میانگین دمای سطح زمین با میانگین رطوبت خاک در روز، ارتباط معنی داری نداشت اما در شب دارای ارتباط معنی داری بود (Karthikeyan & Mishra, 2021). همچنین در پژوهشی دیگر که به بررسی رابطه دمای سطح زمین و رطوبت خاک در طول شب و صبح زود پرداختند، انحراف استاندارد دمای سطح زمین در طول روز با میانگین رطوبت خاک، همبستگی منفی معنی داری داشت در حالیکه در طول شب، همبستگی معنی داری مشاهده نگردید (Zhao et al., 2018). در بررسی ارتباط خاک در عمق‌های مختلف با پارامترهای هواشناسی چنین گزارش شد که پارامترهای دمایی تعیین کننده وضعیت دمای عمق خاک بوده و نیز با افزایش عمق خاک، این ارتباط به تدریج کاهش می‌یابد بدین صورت که ضریب تعیین بین دمای خاک و پارامترهای آب و هوایی از ۰/۹۱ در عمق ۵ و ۲۰ سانتی متر به ۰/۸۱ در عمق ۵۰

ضرایب رطوبتی خاک با شبکه عصبی مصنوعی، مقدار خطای استاندارد را در مرحله آموزش برابر با ۱/۹ گزارش نمودند (Hafezi et al., 2014). در پژوهشی دیگر به بررسی محتوای رطوبتی خاک با چند روش از جمله شبکه عصبی مصنوعی بوسیله تصاویر تلفن همراه پرداخته شد. مطابق با نتایج بدست آمده با استفاده از ۲۲ نقطه پیش‌بینی کننده، میزان ضریب تعیین و خطای استاندارد ۰/۷۷ و ۱۲/۴۳ بدست آمد. با توجه به تحقیقات صورت گرفته دقت شبکه عصبی توسعه یافته در مرحله آموزش قابل قبول می‌باشد (Taneja et al., 2021).

برای فصل زمستان و بهار محاسبه گردید. با توجه به نمودارها، میزان ضریب تعیین (R^2) برای آموزش شبکه برابر با ۰/۹۴ و میزان خطای استاندارد برابر با ۱/۱۲ در فصل زمستان و میزان ضریب تعیین و خطای استاندارد برای آموزش شبکه مربوط به فصل بهار به ترتیب برابر با ۰/۷۸ و ۱/۷۱ بدست آمد. در پژوهشی دمای خاک و رطوبت نسبی محیط داخلی گلخانه با ابزار شبکه عصبی مصنوعی پیش‌بینی گردید. مطابق با نتایج، میزان خطا بین مقادیر اندازه‌گیری و پیش‌بینی شده RMSE محاسبه گردید که این میزان خطا ۱/۵۸ بدست آمد (Taki et al., 2016). در پژوهشی دیگر به منظور تخمین



شکل ۶. خط برازش رسم شده میان مقادیر واقعی و مقادیر پیش‌بینی شده رطوبت خاک توسط شبکه عصبی مصنوعی در مرحله آموزش الف) در فصل زمستان و ب) بهار


Figure 6- The line drawn between the real values and the predicted values of soil moisture by the artificial neural network in the training phase. a) winter season, b) spring season

برابر با ۱/۱۵ و در فصل بهار به ترتیب ضریب تعیین و خطای استاندارد ۰/۹۳ و ۱/۳۰ بدست آمد. ضریب تعیین بالای بدست آمده در هر دو مرحله آموزش و آزمون شبکه عصبی، بیانگر عملکرد دقیق شبکه عصبی مصنوعی در پیش‌بینی رطوبتی خاک می‌باشد. در


همچنین از ۳۰ درصد داده‌ها برای آزمایش شبکه استفاده شد که در شکل ۷ (الف و ب)، خط برازش میان داده‌های واقعی و پیش‌بینی شده رسم و ضریب تعیین محاسبه گردید که ضریب تعیین برای بخش آزمایش شبکه در فصل زمستان ۰/۸۷ و میزان خطای استاندارد

پژوهشی با بررسی ۴ ترکیب از خاک برای پیش‌بینی ظرفیت زراعی و نقطه پژمردگی خاک با استفاده از شبکه عصبی مصنوعی چنین گزارش نمودند که ضریب تعیین و خطای استاندارد در مرحله آموزش برای ظرفیت زراعی به ترتیب ۰/۸۵ و ۹/۹۶ و در مرحله آزمایش به ترتیب ۰/۷۷ و ۹/۳۶ بود (Yamaç et al, 2020). همچنین برای پیش‌بینی نقطه پژمردگی خاک میزان ضریب تعیین و خطای استاندارد را به ترتیب ۰/۸۲ و ۱۱/۹۷ در مرحله آموزش و ۰/۷۳ و ۱۳/۷۷ در مرحله آزمایش ثبت کردند.

پژوهشی با بررسی ۴ ترکیب از خاک برای پیش‌بینی ظرفیت زراعی و نقطه پژمردگی خاک با استفاده از شبکه عصبی مصنوعی چنین گزارش نمودند که ضریب تعیین و خطای استاندارد در مرحله آموزش برای ظرفیت زراعی به ترتیب ۰/۸۵ و ۹/۹۶ و در مرحله آزمایش به ترتیب ۰/۷۷ و ۹/۳۶ بود (Yamaç et al, 2020). همچنین برای پیش‌بینی نقطه پژمردگی خاک میزان ضریب تعیین و خطای استاندارد را به ترتیب ۰/۸۲ و ۱۱/۹۷ در مرحله آموزش و ۰/۷۳ و ۱۳/۷۷ در مرحله آزمایش ثبت کردند.



الف



ب

شکل ۷. خط برازش رسم شده میان مقادیر واقعی و مقادیر پیش‌بینی شده رطوبت خاک توسط شبکه عصبی مصنوعی در مرحله آزمایش الف) فصل زمستان ب) فصل بهار

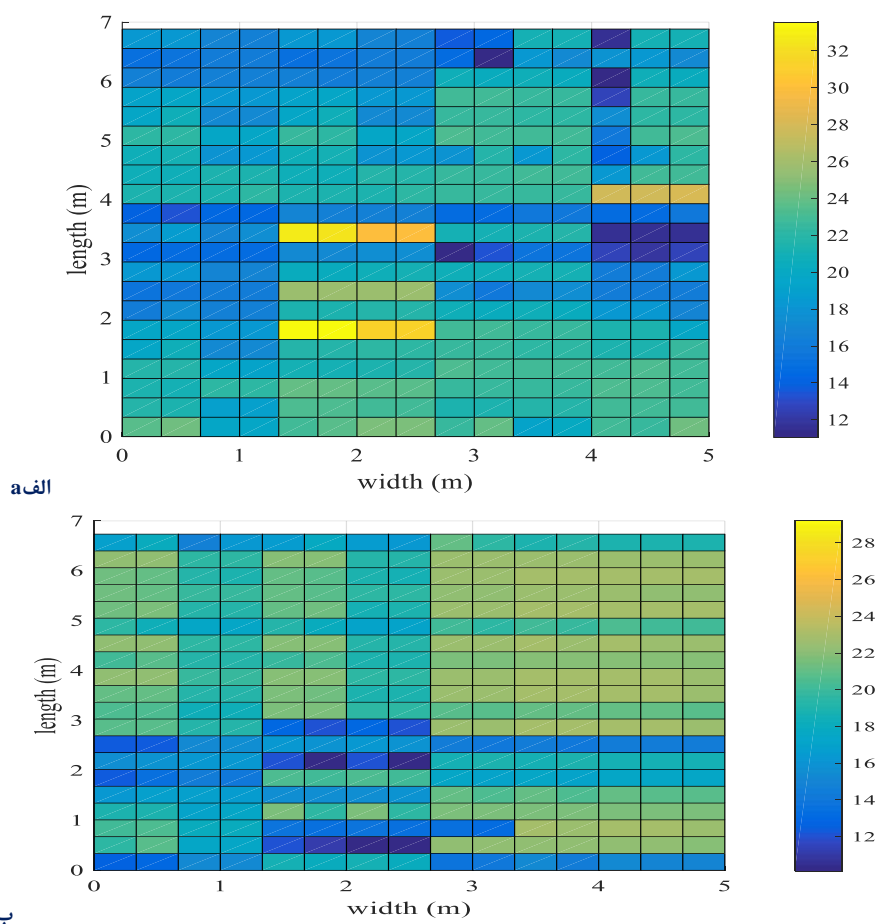
Figure 7- The line drawn between the real values and the predicted values of soil moisture by the artificial neural network in the test phase. a) winter season, b) spring season

در این نقشه هر مربع مساحتی معادل ۹۰۰ سانتیمتر مربع را پوشش می‌دهد. با توجه به اینکه در مترآزهای وسیع گلخانه‌ای، افزایش تعداد حسگرها برای کاهش خطای آبیاری، باعث هزینه‌های اضافی خواهد شد، با

نقشه پیش‌بینی محتوای رطوبتی خاک برای فصل زمستان و بهار در شکل ۸ (الف و ب) نشان داده شده است. به منظور نمایش و سهولت در تصمیم‌گیری نقشه پیش‌بینی رطوبتی خاک با ماتریس ۱۵×۲۱ ارائه گردید؛

عصبی مصنوعی، منطق فازی و ماشین بردار پشتیبان به بررسی رطوبت خاک پرداخته شد که مطابق با نتایج، هر سه روش بصورت قابل قبولی توانایی مدلسازی رطوبت خاک را داشتند اما شبکه عصبی مصنوعی قابلیت بهتری از خود ارائه داد. همچنین میزان خطای استاندارد در مرحله آموزش برای شبکه عصبی، منطق فازی و ماشین بردار پشتیبان به ترتیب ۰/۰۱۳، ۰/۰۱۱ و ۰/۰۱۶۰ و در مرحله آزمون به ترتیب ۰/۰۱۵، ۰/۰۱۶ و ۰/۰۱۳ بود (Sanuade et al., 2020).

تکیه بر نقشه پیش‌بینی آبیاری، می‌توان این نقص را از میان برداشت. مطابق با پژوهشی، به منظور کاهش تعداد حسگرها در منطقه وسیع باغی، نقشه رطوبتی برای خاک با ابزار شبکه عصبی مصنوعی، پیش‌بینی گردید که دقت بالای پیش‌بینی، کاهش ۳۸ درصدی مصرف آب در ساعت را نتیجه داد (Ozden and Dursun, 2014). در پژوهشی دیگر، نقشه رطوبتی خاک با نرم افزار شبکه عصبی مصنوعی پیش‌بینی گردید و مطابقت قابل قبولی بین نقشه پیش‌بینی و مقادیر اندازه‌گیری شده حاصل شد (Zhang et al., 2021). در پژوهشی با سه روش شبکه



شکل ۸- پیش بینی محتوای رطوبتی خاک در گلخانه (درصد) (مساحت هر مربع برابر ۹۰۰ سانتیمترمربع) (رنگ آبی: رطوبت کمتر خاک، رنگ زرد: رطوبت بیشتر خاک) الف: در فصل بهار ب: در فصل زمستان

Figure 8- Prediction of soil moisture content in greenhouse (%) (area of each square is equal 900 cm²) (Blue color: minimum of soil moisture, yellow color: maximum of soil moisture), a: spring, b: winter

معنی داری میان داده‌های واقعی و پیش‌بینی شده وجود ندارد که این امر بیانگر دقت روش پیشنهادی در پیش‌بینی میزان رطوبت خاک از روی پارامترهای اندازه‌گیری شده محیطی است.

همچنین برای ارزیابی اختلاف میان داده‌های واقعی و پیش‌بینی شده در فصل بهار و زمستان، مقایسه آماری با آزمون t زوجی در سطح اطمینان ۹۵ درصد صورت گرفت (جدول ۲). مطابق با نتایج، تفاوت آماری

جدول ۲- آنالیز آماری بین داده واقعی و پیش‌بینی شده با آزمون t زوجی برای فصل زمستان و بهار

Table 2- Statistical analysis between actual and predicted data by paired t-test for winter and spring

T	معنی داری (دوطرفه)	میانگین خطای استاندارد	انحراف معیار	میانگین	داده‌های واقعی و پیش‌بینی شده	زمستان
۱/۱۸	۰/۲۴	۰/۱۲	۰/۵۶	۰/۱۴	داده‌های واقعی و پیش‌بینی شده	زمستان
۰/۴۴	۰/۶۶	۰/۰۷	۰/۳۲	۰/۰۳	داده‌های واقعی و پیش‌بینی شده	بهار

نتیجه گیری کلی:

نصب ابزارآلات و هدر رفت آب آبیاری می‌گردد و هم استفاده کارآمدتر از منابع آبی را بهبود می‌بخشد؛ ازسویی دیگر، کنترل رطوبت خاک در گلخانه‌ها، باعث عملکرد بهتر خاک در تامین رطوبت و دستیابی به محصول با کیفیت‌تر می‌گردد. بنابراین توصیه می‌شود با تجهیز گلخانه‌ها به چنین سامانه‌های هوشمندی، تمام موارد قابل اندازه‌گیری و ارزیابی را بررسی نموده تا به عملکرد و بهره‌وری بیشتری بتوان دست یافت.

تشکر و قدردانی

این مقاله بخشی از رساله دکتری گروه مهندسی مکانیزاسیون و ماشین‌های کشاورزی از دانشگاه علوم و منابع طبیعی خوزستان می‌باشد. با تشکر از دانشگاه مربوطه که حمایت مالی این پژوهش را برعهده گرفت. هیچگونه تعارض منافع بین نویسندگان وجود ندارد.

در این مطالعه، نقشه پیش‌بینی رطوبتی خاک در گلخانه در مرحله آموزش توسط داده‌های حاصل از ۱۶ حسگر رطوبتی در خاک، ۱۶ حسگر اندازه‌گیری دمای خاک و حسگرهای ثبت نور، دما و رطوبت محیط با کمک ابزار شبکه عصبی مصنوعی بدست آمد. طبق نتایج بدست آمده نقشه پیش‌بینی حاصل از آموزش شبکه با ضریب تعیین قابل قبول (۰/۹۴ و ۰/۷۸ به ترتیب در فصل زمستان و بهار) و کمترین میزان خطا (۱/۱۲ و ۱/۷۱ به ترتیب در فصل زمستان و بهار) حاصل گردید. همچنین بررسی آماری میان داده‌های واقعی و پیش‌بینی شده توسط شبکه عصبی، نشان از نبود اختلاف معنی‌دار میان آن‌ها و دقت بالای این شبکه داشت. توزیع رطوبتی و نقشه پیش‌بینی بدست آمده، هم باعث کاهش هزینه‌ها و کنترل آبیاری، ابزارهای مورد نیاز در گلخانه، هزینه

REFERENCES

- Ahmad, S., Kalra, A. & Stephen, H. (2010). Estimating soil moisture using remote sensing data: a machine learning approach. *Advances in Water Resource*. 33 (1). 69–80.
- Akbarzadeh, A., Mehrjardi, R.T., Lake, H.R. & Ramezani, H. (2009). Application of artificial intelligence in modeling of soil properties (Case study: Roodbar Region, North of Iran). *Environmental Research Journal*. 3 (2). 19–24.
- Alavi, A.H., Gandomi, A.H., Mollahassani, A., Heshmati, A.A. & Rashed, A. (2010). Modeling of maximum dry density and optimum moisture content of stabilized soil using artificial neural networks. *Journal of Plant Nutrition and Soil Science*. 173 (3). 368–379.
- Angelopoulos, C.M., Nikolettseas, S. & Theofanopoulos, G.C. (2011). A smart system for garden watering using wireless sensor networks. In: *9th Association for Computing Machinery (ACM) International Symposium on Mobility Management and Wireless Access*. 167–170.
- Aqeel-ur, R., Shaikh, Z.A., Yousuf, H., Nawaz, F., Kirmani, M. & Kiran, S. (2014). Crop irrigation control using Wireless Sensor and Actuator Network (WSAN). In: *International Conference on Information and Emerging Technologies (ICIET)*. 1–5.
- Baaghdeh, M., Entezari, A. & Kordi, A. (2019). Investigation of the Relationship between Soil Temperature and Climate Parameters in the Northwest of Iran (1992-2015). *Journal of*

- Geography and Regional Development Research*. 16(1). 279-307. (In Farsi).
- Barikloo, A., Alamdari, P., Moravej, K. & Servati, M. (2017). Prediction of Irrigated Wheat Yield by using Hybrid Algorithm Methods of Artificial Neural Networks and Genetic Algorithm. *Journal of Water and Soil*. 31(3). 715-726. (In Farsi).
- Cai, W., Ruihua, W., Xu, L. & Ding, X. (2020). A method for modelling greenhouse temperature using gradient boost decision tree. *Information Processing in Agriculture*. 1-12.
- Charoenhirunyingyos, S., Honda, K., Kamthonkiat, D. & Ines, A.V.M. (2011). Soil moisture estimation from inverse modeling using multiple criteria functions. *Computers and Electronics in Agriculture*. 75(2). 278-287.
- Cordeiro, M., Markert, C., S.Araujo, S., G.S. Campos, N., S.Gondim, R., L.Coelho da silva, T. & R. da Rocha, A. (2022). Towards smart farming: fog-enabled intelligent irrigation system using deep neural networks. *Future Generation computer systems*. 129. 115-124.
- Dursun, M. & Özden, S. (2014). An efficient improved photovoltaic irrigation system with artificial neural network based modeling of soil moisture distribution – A case study in Turkey. *Computer and Electronics in Agriculture*. 102. 120- 126.
- Dursun, M. & Karaman, M.R. (2009). Artificial neural network based modeling of spatial distribution of phosphorus on the tomato area. *Asian Journal of Chemistry*. 21 (1). 239-247.
- Hafezi, N., Sheikhdavoodi, M. J., Sajadiye, A. M. & Khorasani Ferdavani, M. E. (2014). Neural modeling for predicting the moisture content of potato slices in a vacuum-radiant dryer. *Journal of Agricultural Engineering*. 39(1). 39-53. (In Farsi).
- Izgi, E., Oztopal, A., Yerli, B., Kaymak, M.K. & Sahin, A.D. (2012). Short-mid-term solar power prediction by using artificial neural networks. *Journal of the International Solar Energy*. 86 (2). 725- 733.
- Karthikeyan, L. & Mishra, A. K. (2021). Multi-layer high-resolution soil moisture estimation using machine learning over the United States. *Remote Sensing of Environment*. 266(112706). 1-19.
- Khanali, M., Mobli, H., Ghasemi Mobtaker, H. & Sherafat, M. (2018). Modeling of Energy Consumption and Environmental Indices of Production and Processing of Tea with Regression and Artificial Neural Network Models. *Journal of Agricultural Mechanization*. 4(1). 15-25. (In Farsi).
- Kim, Y. & Evans, R.G. (2009). Software design for wireless sensor-based site-specific irrigation. *Computer and Electronics in Agriculture*. 66 (2). 159-165.
- Merdun, H., Çınar, Ö., Meral, R. & Apan, M. (2006). Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil and Tillage Research*. 90. 108-116.
- Moravejalakhkami, B. & Baghshahi, M. (2020). Feasibility Study of the Construction and Evaluation of a Soil Moisture Sensor in Different Soil Textures. *Iran- Water Resources Research*. 16(1). 135-145. (In Farsi).
- Moreno, A., Gilabert, M.A. & Martinez, B. (2011). Mapping daily global solar irradiation over Spain: a comparative study of selected approaches. *Journal of the International Solar Energy*. 85(9). 2072-2084.
- Ozden, S. & Dursun, M. (2011). Remote monitoring and control of PV powered drip irrigation system with soil moisture sensors. In: *The Third International Conference on Computer Engineering and Technology (ICCET)*. 239-244.
- Ramirez-Beltran, N.D., Calderon-Arteaga, C., Harmsen, E., Vasquez, R. & Gonzalez, J. (2010). An algorithm to estimate soil moisture over vegetated areas based on in situ and remote sensing information. *International Journal of Remote Sensing*. 31 (10). 2655-2679.
- Sabziparvar, A. A., Tabari, H. & Aeini, A. (2010). Estimation of Mean Daily Soil Temperature by Means of Meteorological Data in Some Selected Climates of Iran. *Journal of Science and Technology of Agriculture and Natural Resources (Water and Soil Science)*. 14(52). 125-137. (In Farsi).
- Sanuade, O. A., Hassan, A. M., Akanji, A. O., Olajo, A. A., Oladunjoye, M. A. & Abdulraheem, A.

- (2020). New empirical equation to estimate the soil moisture content based on thermal properties using machine learning techniques. *Arabian Journal of Geosciences*. 13-377.
- Taki, M., Ajabshirchi, Y., Ranjbar, S. F., Rohani, A. & Matloobi, M. (2016). 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). 76-89. (In Farsi).
- Taneja, P., Vasava, H. K., Daggupati, P. & Biswas, A. (2021). Multi-algorithm comparison to predict soil organic matter and soil moisture content from cell phone images. *Geoderma*. 385 (114863). 1-15.
- Veronez, M.R., Wittmann, G., Reinhardt, A.O. & Da Silva, R.M. (2010). Surface temperature estimation using artificial neural network. In: *International Society for Photogrammetry and Remote Sensing (ISPRS) TC VII Symposium*. 612–617.
- Wang, N., Zhang, N.Q. & Wang, M.H. (2006). Wireless sensors in agriculture and food industry – recent development and future perspective. *Computer and Electronics in Agriculture*. 50 (1). 1–14.
- Yamaç, S. S., Şeker, C. & Negiş, H. (2020). Evaluation of machine learning methods to predict soil moisture constants with different combinations of soil input data for calcareous soils in a semiarid area. *Agricultural Water Management*. 234(106121). 1-11.
- Yang, C.C., Prasher, S.O. & Mehuys, G.R. (1997). An artificial neural network to estimate soil temperature. *Canadian Journal of Soil Science*. 77 (3). 421–429.
- Zhang, J., Liu, K. & Wang, M. (2021). Downscaling groundwater storage data in China to a 1-km resolution using machine learning methods. *Remote Sensing*. 13(3). 1-19.
- Zhao, W., Sanchez, N., Lu, H. & Li, A. (2018). A spatial downscaling approach for the SMAP passive surface soil moisture product using random forest regression. *Journal of Hydrology*. 563. 1009–1024.