

Estimating Soil Temperature from Metrological Data Using Extreme Learning Machine, Artificial Neural Network and Multiple Linear Regression Models

HOSSEIN ZADMEHR¹, AHMAD FARROKHIAN FIROUZI^{1*}

1. Department of Soil Science, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

(Received: Dec. 16, 2019- Revised: Jan. 10, 2020- Accepted: Jan. 11, 2020)

ABSTRACT

Soil temperature (T_s) is a key factor controlling the soil physical, chemical and biological properties and processes and consequently affects agricultural crop productions. The objective of this study was to estimate T_s from meteorological data using different machine learning methods. For this purpose, meteorological data and soil temperature at different depths (5, 10, 20, 30, 50 and 100 cm from the soil surface) for 25 years (1994-2018) were collected from 17 synoptic stations in Khuzestan province, Iran. Air temperature, wind speed, relative humidity, evaporation, precipitation, and vapor pressure were used as inputs to train the models. Multiple Linear Regression (MLR), Multilayer Perceptron Neural Network (MLPNN) and Extreme Learning Machine (ELM) models were used to predict soil temperature from metrological data. The results indicated that all models predicted temperature of the top layer (0-30 cm) better than the ones in sublayers. on the other hand, by increasing soil depth the accuracy of the models diminished; so that, the best and worst T_s predictions were belong to 5 cm and 100 cm depth, respectively. The results revealed that MLR, MLPNN and ELM models provided desirable performance in modeling T_s at all depths, with R^2 values ranging 0.700-0.864, 0.967-0.997, and 0.967-99, RMSE values ranging 2.557-2.873, 0.034-0.072, and 0.028-0.078 °C, and MAE values ranging 1.398-1.529, 0.023-0.063, and 0.023-0.065 °C, respectively. Overall, the results showed that MLPNN and ELM models had approximately similar performance and better accuracy than MLR model. However, because of the high computational speed of the ELM model, it is recommended to use MLPNN model for estimation of soil profile T_s .

Keywords: Khuzestan province, Meteorological parameters, Multiple Linear Regression, Multilayer Perceptron Neural Network, Extreme Learning Machine.

برآورد دمای خاک از داده‌های هواشناسی با استفاده از مدل‌های یادگیری ماشین سریع، شبکه عصبی مصنوعی و رگرسیون خطی چندگانه

حسین زادمهر^۱، احمد فرخیان فیروزی^{۱*}

۱. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، اهواز، ایران.
(تاریخ دریافت: ۱۳۹۸/۹/۲۵ - تاریخ بازنگری: ۱۳۹۸/۱۰/۲۰ - تاریخ تصویب: ۱۳۹۸/۱۰/۲۱)

چکیده

دمای خاک عامل کلیدی است که فرآیندها و خصوصیات فیزیکی، شیمیایی و بیولوژیکی خاک را کنترل می‌کند؛ لذا بر کمیت و کیفیت تولید محصولات کشاورزی تأثیر می‌گذارد. هدف از انجام این پژوهش برآورد دمای خاک با استفاده از پارامترهای هواشناسی به روش‌های مختلف ماشین یادگیری بوده است. بدین منظور داده‌های هواشناسی و دمای خاک در عمق‌های ۵، ۱۰، ۲۰، ۳۰، ۵۰ و ۱۰۰ سانتی‌متری از ۱۷ ایستگاه سینوپتیک استان خوزستان مربوط به ۲۵ سال (۱۹۹۴ تا ۲۰۱۸) گردآوری شد. مدل‌های شبکه عصبی پرسپترون چندلایه (MLPNN)، ماشین یادگیری سریع (ELM) و رگرسیون خطی چندگانه (MLR) برای برآورد دمای خاک استفاده شدند. داده‌های دمای هوا، سرعت باد، رطوبت نسبی هوا، فشار بخار، تبخیر و بارندگی به‌عنوان ورودی برای آموزش مدل‌ها استفاده شدند. نتایج نشان داد که تمام مدل‌ها برآوردی بهتری از دمای لایه سطحی خاک (عمق ۰-۳۰ سانتی‌متری) داشته و با افزایش عمق دقت آن‌ها کاهش می‌یابد، به‌طوری‌که بهترین دقت برآورد دمای خاک مربوط به عمق ۵ و کمترین آن مربوط به عمق ۱۰۰ سانتی‌متری بود. نتایج نشان داد مدل‌های MLPNN، ELM و عملکردی مطلوب در مدل‌سازی دمای خاک در تمام عمق‌ها داشتند. برای مدل‌های MLPNN، ELM، MLPNN به ترتیب مقادیر R^2 از ۰/۷۰۰-۰/۸۶۴، ۰/۹۶۷-۰/۹۹۷ و ۰/۹۶۷-۰/۹۹۶، مقادیر RMSE از ۲/۸۲۳-۲/۵۵۷، ۰/۳۴-۰/۰۷۲ و ۰/۲۸-۰/۰۷۸ درجه سلسیوس و مقادیر MAE از ۱/۳۹۸-۱/۵۲۹، ۰/۰۶۳-۰/۰۲۳ و ۰/۰۶۵-۰/۰۲۳ درجه سلسیوس بود. نتایج نشان داد که دو مدل MLPNN و ELM دارای عملکردی تقریباً مشابه و بهتر از مدل رگرسیون خطی چندگانه بودند؛ اما به دلیل سرعت محاسبات بسیار بالای مدل ELM، پیشنهاد می‌گردد از مدل MLPNN برای تخمین دمای نیم‌رخ خاک استفاده شود.

واژه‌های کلیدی: استان خوزستان، پارامترهای هواشناسی، رگرسیون خطی چندگانه، شبکه عصبی پرسپترون چندلایه، ماشین یادگیری سریع.

مقدمه

فیزیکی، شیمیایی و بیولوژیکی در علوم خاک و گیاه تأثیر دارد. همچنین ویژگی‌های هیدرولیکی خاک نیز تحت تأثیر درجه حرارت خاک قرار می‌گیرند (Bachmann, et al., 2002). دمای خاک، تبخیر و تعرق، جوانه‌زنی، تولید و تجزیه مواد مغزی، تهویه خاک، رشد گیاه، فعالیت ریشه و میکروارگانیسم‌های خاک را تحت تأثیر قرار می‌دهد (Alavipanah, 2006; Jacobs et al., 2011). بسیاری از این فرایندها در محدوده مشخصی از درجه حرارت به حداکثر مقدار خود رسیده و در درجه حرارت‌های بیشتر و کمتر از این محدوده، کاهش می‌یابند. به بیان بهتر، درجه حرارت نهایی یعنی درجه حرارت بسیار بالا و بسیار پایین تأثیری مخرب بر حیات گیاه و در نهایت بر کشاورزی و تولید محصولات کشاورزی دارد. رشد بهینه گیاه بستگی به دمای مطلوب خاک دارد، به‌گونه‌ای که دمای خاک، زمان کاشت بذر را تحت تأثیر قرار می‌دهد. به‌طورمعمول اندازه‌گیری دمای خاک در

دمای خاک و چگونگی تغییرات آن نسبت به زمان و مکان یک عامل بسیار مهم است که نه تنها تبادل ماده و انرژی را در خاک تحت تأثیر قرار می‌دهد، بلکه میزان و جهت تمامی فرایندهای فیزیکی خاک به‌طور مستقیم و غیرمستقیم وابسته به دمای خاک است (Mazidi and Fallah zadeh, 2011; Alizadeh, 2014). دمای خاک به‌طور مستقیم بر فعالیت‌های گیاهی اثر دارد و در برخی موارد اهمیت بیشتری نسبت به دمای هوا در رشد گیاهان دارد. به‌طورکلی گرم شدن خاک و افزایش و کاهش دمای آن بستگی به تابش ورودی خورشید به سطح زمین و فرایندهای تبادل گرما در داخل خاک دارد. کلیه این فرایندها توسط ویژگی‌های دیگر خاک مانند جرم مخصوص، درصد رطوبت، ساختمان و بافت خاک کنترل می‌شود (Alizadeh, 2014). درواقع درجه حرارت خاک از مهم‌ترین عواملی است که بر فرایندهای مهم

از الگوریتم تکاملی خودسازگار (SaE) برای بهبود عملکرد ماشین یادگیری افراطی (ELM) استفاده کردند و نتایج آن را با ماشین یادگیری افراطی پایه مقایسه کردند. نتایج آن‌ها نشان داد که هر دو مدل ELM پایه و ELM بهینه‌سازی شده دارای نتایج دقیقی بودند اما ELM بهینه‌سازی شده به صورت جزئی دارای نتایجی بهتر نسبت به ELM پایه در برآورد دمای خاک بود. *Abyaneh et al.* (2016) در پژوهشی به منظور تخمین دمای خاک در عمق‌های مختلف با استفاده از دمای هوا در دو منطقه گرگان در شمال ایران با آب‌وهوای مرطوب و زابل در جنوب شرقی ایران با آب‌وهوای خشک از شبکه عصبی مصنوعی (ANN) و سیستم استنتاج عصبی-فازی فعال (CANFIS) استفاده کردند. مقایسه عملکرد مدل در مناطق خشک و مرطوب نشان داد که هر دو مدل ANN و CANFIS در مناطق خشک عملکرد خوب دارند و مشاهده کردند که با افزایش عمق دقت پیش‌بینی هر دو مدل کاهش یافته است و قابلیت‌های ANN نسبت به CANFIS در پیش‌بینی دمای خاک در مناطق خشک و مرطوب بهتر است. *Ismail Beekey* (2017) در پژوهشی به تخمین دمای خاک بر اساس پارامترهای اقلیمی در یک دوره آماری ۱۰ ساله با استفاده از مدل‌های شبکه عصبی مصنوعی و الگوریتم هیبریدی کرم شبتاب در استان آذربایجان شرقی پرداختند. نتایج آن‌ها نشان داد که مدل‌سازی دمای خاک با استفاده از الگوریتم هیبریدی کرم شبتاب-شبکه عصبی مصنوعی به مراتب بهتر و دقت آن از شبکه عصبی مصنوعی بیشتر است. *Citakoglu* (2017) در پژوهشی به منظور پیش‌بینی دمای خاک ماهانه در اعماق مختلف از طریق پارامترهای هواشناسی ۲۶۱ ایستگاه واقع در ترکیه، از شبکه‌های عصبی مصنوعی (ANN)، سیستم استنتاج عصبی-فازی سازگار (ANFIS) و مدل‌های رگرسیون خطی چندگانه (MLR) استفاده کردند. نتایج آن‌ها نشان داد که مدل ANFIS نسبت به مدل‌های ANN و MLR نتایج بهتری را ارائه می‌دهد *Samadianfard et al.* (2018) در مطالعه‌ای با استفاده از شبکه‌های عصبی مصنوعی (ANN)، شبکه‌های عصبی موجک (WNN) و برنامه‌نویسی بیان ژن (GEP) به پیش‌بینی دمای کوتاه‌مدت خاک در اعماق مختلف در ایستگاه سینوپتیک تبریز پرداختند. نتایج آن‌ها نشان داد که مدل WNN در تمام اعماق در نظر گرفته شده بهترین عملکرد را در پیش‌بینی دمای خاک داشته است. *Feng et al.* (2019) به منظور برآورد دمای خاک در عمق‌های مختلف با استفاده از داده‌های هواشناسی در منطقه لاس پلاتو در چین از مدل‌های یادگیری ماشین سریع (ELM)، شبکه‌های عصبی رگرسیون تعمیم‌یافته (GRNN)، شبکه‌های عصبی پس انتشار (BPNN) و جنگل‌های تصادفی (RF) استفاده کردند. آن‌ها به این نتیجه

ایستگاه‌های سینوپتیک با انواع حسگر و یا دماسنج‌های معمولی صورت می‌گیرد که اندازه‌گیری دمای خاک با حسگر هزینه‌بر بوده و به نیروی انسانی ماهر و پایش مداوم نیاز دارد (*Parsafar et al.*, 2011)؛ با توجه به وجود مشکلات فراوان در ثبت دمای خاک و اهمیت دمای خاک در مسائل کشاورزی پژوهشگران همواره در پی یافتن رابطه‌ای میان دمای خاک و متغیرهای هواشناسی هستند تا بتوانند با بالاترین دقت دمای خاک را برآورد کنند؛ بنابراین با توجه به محدودیت‌های موجود در اندازه‌گیری تغییرات دمای خاک در عمق‌های مختلف، ارائه روش‌های آماری و تجربی که قادر به ارائه نتایج قابل قبولی در برآورد دمای خاک باشد می‌تواند راه‌حلی سریع و کم‌هزینه با دقت مناسب در پیش‌بینی و برآورد دمای خاک باشد. (*Plauborg*, 2002). تا کنون بررسی‌ها و مطالعات متعددی به منظور برآورد دمای خاک در عمق‌های مختلف پروفیل خاک از طریق داده‌های هواشناسی با استفاده روش‌های مختلف صورت گرفته است. *Singh and Kim* (2014) در مطالعه‌ای عملکرد سیستم استنتاج عصبی فازی تطبیقی (ANFIS) و مدل شبکه عصبی پرسپترون چندلایه (MLPNN) را به منظور برآورد دمای روزانه خاک در ایستگاه‌های شامپین و اسپرینگفیلد واقع در ایلینویز را ارزیابی کردند. آن‌ها مشاهده کردند که نتایج MLPNN برای هر دو ایستگاه از ANFIS بهتر است. *Gill and Singh* (2015) در مطالعه‌ای از مدل الگوریتم ژنتیک مبتنی بر شبکه عصبی (GA) برای پیش‌بینی دمای خاک روزانه خاک در سه عمق ۵، ۱۰ و ۳۰ سانتی‌متری در لودینا واقع در کشور هند استفاده کردند. نتایج آن‌ها نشان داد که کاربرد مدل جدید، دمای خاک را به خوبی برآورد می‌کند. *Kisi et al.* (2015) در مطالعه‌ای توانایی شبکه عصبی پرسپترون چندلایه (MLPNN)، شبکه عصبی پایه شعاعی (RBNN)، شبکه‌های عصبی رگرسیون تعمیم‌یافته (GRNN) و رگرسیون خطی چندگانه (MLR) در مدل‌سازی دمای خاک ماهانه با استفاده از پارامترهای هواشناسی در ایستگاه مرسین ترکیه را بررسی و مقایسه کردند. آن‌ها مشاهده کردند که مدل RBNN در عمق ۵ سانتی‌متری نسبت به مدل‌های GRNN، MLPNN و MLR نتایج بهتری ارائه می‌دهد؛ در حالی که مدل‌های MLR و GRNN به ترتیب در عمق‌های ۵۰ و ۱۰۰ سانتی‌متر عملکردی بهتر داشتند. *Tabari et al.* (2015) در پژوهشی از شبکه عصبی مصنوعی (ANN) برای پیش‌بینی دمای کوتاه‌مدت خاک با استفاده از دمای هوا در ۶ عمق مختلف در دو ایستگاه مرطوب و خشک واقع در ایران استفاده کردند. نتایج حاکی از توان مطلوب ANN برای پیش‌بینی دمای کوتاه‌مدت خاک است. *Nahvi et al.* (2016) در پژوهشی به منظور تخمین دمای روزانه خاک در ۶ عمق مختلف

و اقلیم نیمه مرطوب مدیترانه می‌باشد (I.R.OF IRAN Meteorological Organization).

داده‌های مورد استفاده

این مطالعه با استفاده از اطلاعات ساعتی ثبت شده در ایستگاه‌های هواشناسی سینوپتیک (۱۷ ایستگاه) در استان خوزستان انجام شد. برای این منظور از داده‌های هواشناسی شامل دمای خاک، دمای هوا (دمای کمینه، دمای بیشینه، دمای تر و میانگین دمای هوا)، رطوبت نسبی هوا، تبخیر، فشار بخار، سرعت باد و مقدار بارندگی اندازه‌گیری شده در ایستگاه‌های هواشناسی سینوپتیک استان در طی دوره آماری بلندمدت استفاده شد. ایستگاه‌های آبادان، اهواز، ایذه، امیدیه، بهبهان، بستان، بندر ماهشهر، رامهرمز، مسجد سلیمان، صفی‌آباد و شوشتر با طول دوره آماری ۲۵ ساله (۲۰۱۸-۱۹۹۴)، ایستگاه هندیجان با طول دوره آماری ۱۸ ساله (۲۰۱۸-۲۰۰۱)، ایستگاه‌های حسینیه و دهدز با دوره آماری ۱۴ ساله (۲۰۱۸-۲۰۰۵)، ایستگاه لالی با طول دوره آماری ۱۲ ساله (۲۰۱۸-۲۰۰۷) و ایستگاه‌های شادگان و گتوند با طول دوره آماری ۱۰ ساله (۲۰۱۸-۲۰۰۹) می‌باشند. در جدول (۱) و شکل (۱) مشخصات محل ایستگاه‌های مورد مطالعه نشان داده شده است.

در ایستگاه‌های سینوپتیک کشور دمای خاک معمولاً در عمق‌های ۵، ۱۰، ۲۰، ۳۰، ۵۰ و ۱۰۰ سانتی‌متری در ساعات ۶:۳۰، ۱۲:۳۰ و ۱۸:۳۰ به‌وقت محلی (۳، ۹، ۱۵ به‌وقت گرینویچ) اندازه‌گیری می‌شود؛ بنابراین به‌منظور انجام این پژوهش ابتدا داده‌های ساعتی دمای خاک در سه نوبت میانگین‌گیری و میانگین این سه مقدار در هر عمق مشخص به‌عنوان میانگین دمای خاک در آن روز حساب شد. همچنین از داده‌های ساعتی دمای هوا (دمای کمینه، دمای بیشینه، دمای تر و میانگین دمای هوا)، رطوبت نسبی هوا، تبخیر، فشار بخار، سرعت باد و بارندگی در برنامه Excel 2013 به‌صورت روزانه میانگین‌گیری شد و در ادامه از داده‌های روزانه به‌صورت ماهانه میانگین‌گیری صورت گرفت و به‌منظور مدل‌سازی دمای خاک تنظیم و مرتب شد.

در این پژوهش به‌منظور برآورد و مدل‌سازی دمای خاک در عمق‌های مختلف، از داده‌های هواشناسی شامل دمای هوا (دمای کمینه، دمای بیشینه، دمای تر و متوسط دمای هوا)، رطوبت نسبی، تبخیر، فشار بخار آب، سرعت باد و میزان بارندگی اندازه‌گیری شده در ایستگاه‌های هواشناسی به‌عنوان متغیر ورودی برای آموزش مدل‌ها به‌منظور برآورد دمای خاک استفاده شدند.

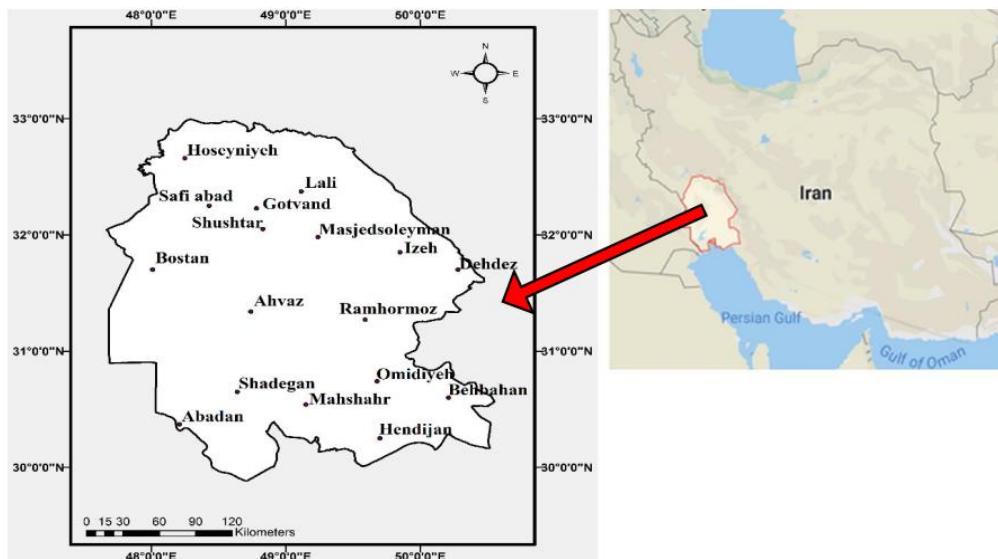
رسیدند که مدل ELM دارای عملکردی بهتر و همچنین سرعت محاسبه بهتری نسبت به GRNN، BPNN و همچنین مدل‌های RF در بازه‌های زمانی ساعتی است، بنابراین کاربرد مدل ELM برای تخمین دمای خاک در اعماق مختلف توصیه نمودند. هر چند تاکنون از روش‌های مختلف یادگیری ماشین برای برآورد دمای نیم‌رخ خاک با استفاده از داده‌های هواشناسی استفاده شده است اما مدل ELM اندک استفاده شده است.

با وجود نقش و اهمیت دمای خاک در تولید محصولات کشاورزی، تا کنون مطالعات جامع و دقیقی در مورد برآورد دمای خاک با استفاده از داده‌های هواشناسی در کل استان خوزستان که یکی از قطب‌های اصلی تولید محصولات کشاورزی در کشور می‌باشد انجام نشده است؛ بنابراین با توجه به تأثیر زیاد دمای عمق‌های مختلف خاک در تولید محصولات کشاورزی و نقش و جایگاه استان خوزستان به‌عنوان یکی از اصلی‌ترین قطب‌های تولید محصولات کشاورزی، لازم و ضروری است که به بررسی و تخمین دمای خاک در عمق‌های مختلف در این استان پرداخته شود. لذا در این پژوهش تلاش بر آن بوده با استفاده از داده‌های ۱۷ ایستگاه‌های سینوپتیک استان خوزستان مربوط به ۲۵ سال، دمای نیم‌رخ خاک به سه روش رگرسیون خطی چندگانه (MLR)، شبکه عصبی پرسپترون چندلایه (MLPNN) و ماشین یادگیری سریع (ELM) برآورد و بهترین مدل ارائه گردد.

مواد و روش

منطقه مورد مطالعه

استان خوزستان با مساحتی حدود ۶۴۲۳۶ کیلومتر مربع وسیع‌ترین استان در نیمه غربی کشور است. این استان بین ۴۷ درجه و ۴۱ دقیقه تا ۵۰ درجه و ۳۹ دقیقه طول شرقی از نصف‌النهار گرینویچ و ۲۹ درجه و ۵۸ دقیقه تا ۳۳ درجه و ۴ دقیقه عرض شمالی از خط استوا قرار دارد. استان خوزستان از نظر پستی و بلندی به دو منطقه کوهستانی و جلگه‌ای تقسیم می‌شود. این جلگه که وسیع‌ترین جلگه ایران است با شیبی ملایم به‌طرف خلیج فارس کشیده شده است. در مناطق کوهستانی و مرتفع، تابستان‌های معتدل وجود دارد و در نواحی پست جلگه‌ای هرچه به سمت جنوب و جنوب غرب پیش می‌رویم خصوصیات آب‌وهوا از نیمه بیابانی به بیابانی کناره‌ای تبدیل می‌شود. عمدتاً زمستان‌های این ناحیه کوتاه و معتدل و تابستان‌ها طولانی و گرم است. بر اساس روش‌های طبقه‌بندی معمول مانند روش‌های طبقه‌بندی کوپن و دومارتن، اقلیم‌های موجود در استان خوزستان شامل اقلیم فرا خشک، گرم، اقلیم گرم خشک، اقلیم نیمه‌خشک



شکل ۱- موقعیت ایستگاه‌های سینوپتیک مورد مطالعه استان خوزستان

جدول ۱- مشخصات ایستگاه‌های مورد مطالعه استان خوزستان

ایستگاه	عرض جغرافیایی (N)	طول جغرافیایی (E)	ارتفاع از سطح دریا (M)	میانگین دما هوا (°C)	میانگین بارندگی (mm)	میانگین رطوبت (%)	میانگین سرعت باد (M/S)
آبادان	۳۰/۳۷	۴۸/۲۱	۶/۶	۲۶/۱۶۲	۱۱۸/۷۷	۴۲/۴۷	۳/۰۲
اهواز	۳۱/۳۴	۴۸/۷۴	۲۲/۵	۲۶/۳۱	۱۸۷/۳۸	۴۱/۴۳	۲/۶۶
ایذه	۳۱/۸۵	۴۹/۸۵	۷۶۷	۲۳/۲۷	۵۶۸/۳۵	۳۸/۱۰۷	۲/۰۴
امیدیه	۳۰/۷۴	۴۹/۶۸	۲۷	۲۶/۳۰	۲۱۷/۷۵	۴۱/۳۲	۳/۰۲
بستان	۳۱/۷۰	۴۸/۰۱	۷/۸	۲۴/۹۰	۱۵۴/۳۸	۴۴/۱۳	۳/۴۰
بهبهان	۳۰/۶۰	۵۰/۲۱	۳۱۳	۲۵/۰۵	۳۱۴/۲۶	۴۴/۵۷	۱/۶۷
رامهرمز	۳۱/۲۷	۴۹/۵۹	۱۵۰/۵	۲۷/۹۶	۲۶۱/۱۷	۳۴/۷۴	۲/۰۱
ماهشهر	۳۰/۵۴	۴۹/۱۵	۶/۲	۲۶/۰۰۶	۱۷۴/۰۵	۴۵/۷۰	۳/۶۹
شوشتر	۳۲/۰۵	۴۸/۸۳	۶۷	۲۸/۰۱	۴۱/۷۰	۳۶/۶۸	۲/۴۰
صفی آباد	۳۲/۲۵	۴۸/۴۳	۸۲/۹	۲۴/۴۵	۲۶۹/۲۹	۵۱/۰۳	۱/۴۹
مسجدسلیمان	۳۱/۹۸	۴۹/۲۴	۳۲۰/۵	۲۹/۲۶	۳۵۶/۷۳	۶۲/۱۸	۱/۷۴
هندیجان	۳۰/۲۵	۴۹/۷۰	۳	۲۷/۵۷	۱۹۵/۸۳	۴۱/۷۱	۴/۷۵
دهدز	۳۱/۷۰	۵۰/۲۸	۱۴۵۷	۱۹/۷۶	۵۸۸/۵۷	۳۷/۷۱	۳/۰۷
حسینیه	۳۲/۶۶	۴۸/۲۵	۳۵۴	۲۷/۳۸	۴۰۶/۳۰	۳۳/۷۳	۴/۰۸
لالی	۳۲/۳۳	۴۹/۰۹	۳۶۵	۲۶/۷۴	۳۶۲/۳۴	۳۸/۰۵	۳/۲۰
شادگان	۳۰/۶۵	۴۸/۶۴	۳	۲۷/۶۶	۸۴۸/۲۲	۴۰/۹۶	۳/۵۴
گتوند	۳۲/۲۲	۴۸/۸۰	۷۰	۲۶/۹۱	۲۴۹/۴۴	۴۴/۹۵	۱/۷۰

غیرقابل قبول در نتایج شود؛ بنابراین در روش رگرسیون، رابطه بین متغیرها به صورت تابعی از متغیر وابسته است که متغیرهای مستقل را پیش‌بینی می‌کند. در این روش ابتدا همبستگی بین متغیرهای هواشناسی و دمای خاک در اعماق ۵، ۱۰، ۲۰، ۳۰، ۵۰ و ۱۰۰ سانتی‌متری تعیین شد و بعد با استفاده از رگرسیون خطی چندگانه تحت نرم‌افزار SPSS نسخه ۲۰۱۸ روابط بین متغیرهای هواشناسی در هر عمق به صورت جداگانه بررسی شد.

روش رگرسیون خطی چندگانه

با استفاده از روش‌های چند متغیره این امکان فراهم می‌شود که به صورت هم‌زمان به تحلیل و بررسی و ارتباط بین چند متغیر با هدف موردنظر پرداخت. به منظور به دست آوردن نتایج دقیق و مطلوب در این روش‌ها نیاز به استفاده از نمونه‌های دقیق و فراوان است چرا که این روش‌ها حساسیت بالایی در برابر اطلاعات نادرست داشته و ممکن است باعث به وجود آمدن خطاهای

داده‌های ورودی به ماشین یادگیری سریع شامل داده‌های واقعی اندازه‌گیری شده که هدف مطالعه است و داده‌های مؤثر بر آن می‌باشند. در طول آموزش فاکتورهای تأثیر و نتایج مربوط به آموزش از طریق تکرار تا فرایند یادگیری کامل به ELM آموزش داده خواهد شد. سپس به منظور پیش‌بینی نتایج به‌وسیله ELM آموزش دیده فقط نیاز به ورودی و مجموعه داده‌های آموزشی مشابه عوامل تأثیرگذار در خروجی موردنظر است؛ بنابراین مدل ELM می‌تواند خروجی مورد نظر را بر اساس حافظه پیش‌بینی کند. الگوریتم ELM تنها نیاز به تنظیم تعداد گره‌های لایه پنهان دارد. در فرایند اجرای الگوریتم برخلاف شبکه عصبی مصنوعی نیازی نیست که وزن‌های ورودی شبکه و لایه‌های پنهان را تنظیم کرده و یک‌راه حل بهینه منحصر به فرد با مزایای سرعت یادگیری سریع و عملکرد تعمیم ایجاد کرد (Ding et al., 2015). به‌طور خلاصه با توجه به یک مجموعه آموزشی \tilde{N} و تابع فعالیت $f(x)$ ، $(x_i, t_i) \in R^n \times R^M$ ($i=1,2,\dots,N$) گره پنهان، فرایند الگوریتم ELM را به سه مرحله زیر می‌توان خلاصه کرد: مرحله (۱): شامل تعیین تعداد گره‌های پنهان \tilde{N} که به‌طور تصادفی وزن‌های ورودی a_i و بایاس لایه پنهان b_i تعیین می‌شود. مرحله (۲): محاسبه ماتریس خروجی لایه پنهان H . مرحله (۳) با توجه به معادله $\hat{\beta} = H^+T$ وزن خروجی β محاسبه می‌شود. شایان ذکر است که قبل از وارد کردن داده‌ها در مدل ELM، داده‌های ورودی از طریق رابطه (۴) نرمال‌سازی شدند که لازم کار با ماشین یادگیری سریع است. سپس به‌منظور آموزش مدل، ۷۰ درصد داده‌های ورودی جهت آموزش و ۳۰ درصد داده‌ها جهت آزمون انتخاب شد. (Deng et al., 2010). ادامه با تعیین و تنظیم تعداد گره‌های لایه پنهان و با استفاده از تابع عملکرد تانژانت سیگموئید خروجی مناسب گرفته شد.

شاخص‌های آماری

به‌منظور ارزیابی دقت پیش‌بینی مدل شبکه عصبی مصنوعی، ماشین یادگیری سریع و همچنین برای ارزیابی دقیق روابط تجربی ارائه‌شده از طریق رگرسیون چند متغیره خطی از شاخص‌های آماری ضریب تعیین (R^2)، ضریب همبستگی (R)، جذر میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) استفاده شد (روابط ۳ تا ۶).

ضریب تعیین نشان می‌دهد که چند درصد تغییرات متغیر وابسته به‌وسیله متغیر مستقل تعیین می‌شوند یا به‌عبارت‌دیگر نشان‌دهنده این است که چه مقدار از تغییرات متغیر وابسته تحت تأثیر متغیر مستقل مربوطه بوده است و مابقی تغییرات متغیر

همچنین به‌منظور وارد کردن متغیرها در رگرسیون چندگانه از روش گام‌به‌گام استفاده شد. در این روش متغیرهای مستقل یکی‌یکی به معادله رگرسیون اضافه می‌شوند و اگر نقش معنی‌داری در رگرسیون نداشته باشند از آن حذف می‌شوند (Momeni and Faal Qayyumi, 2010). حالت کلی رگرسیون خطی چندگانه به‌صورت معادله (۱) است که در آن Y متغیر پیش‌بینی شونده (دمای خاک در عمق‌های مختلف)، x_1 تا x_n متغیرهای پیش‌بینی کننده و a و b ضرایب ثابت معادله هستند.

(رابطه ۱)

$$Y = a + b_1x_1 + b_2x_2 + \dots + b_nx_n$$

شبکه عصبی مصنوعی

در این پژوهش به‌منظور برآورد و مدل‌سازی دمای خاک از مدل شبکه عصبی پرسپترون چندلایه (MLPNN) با استفاده نرم‌افزار MATLAB نسخه ۲۰۱۸ استفاده شد. ساختار مورد استفاده این مدل شامل یک لایه ورودی دو لایه میانی (مخفی) با تابع فعالیت تانژانت سیگموئید و یک لایه خروجی با تابع فعالیت خطی است. همچنین از روش آموزش پس انتشار خطا برای آموزش شبکه استفاده شد. به‌منظور به‌دست آوردن خروجی مناسب داده‌های موجود به دو قسمت داده‌های آموزش و داده‌های آزمون تقسیم شد. ۷۰ درصد داده‌های استاندارد شده برای آموزش و ۳۰ درصد مابقی داده به‌منظور فرایند ارزیابی دقت یا فرایند آزمون انتخاب شد. همچنین قبل از آموزش برای وارد کردن داده‌ها به شبکه عصبی برای استانداردسازی و یکسان‌سازی واحدها، داده‌ها استانداردسازی یا نرمال شدند، زیرا اگر داده‌ها به‌صورت خام وارد شوند به‌علت تغییر زیاد داده‌ها خروجی متفاوتی به‌دست می‌آید. فرایند نرمال‌سازی از کوچک شدن بیش از حد وزن‌ها و همچنین از اشباع سریع نرون‌ها جلوگیری می‌کند؛ بنابراین داده‌ها باید معیار سازی شوند، یعنی بین ۰ و ۱ استاندارد شوند تا خروجی مناسب به‌دست آید. به‌منظور نرمال‌سازی داده‌های ورودی شبکه عصبی از فرمول (۴) استفاده شده است. در این رابطه X_i نشان‌دهنده مقدار اولیه داده‌ها، X_{\min} و X_{\max} به‌ترتیب نشان‌دهنده حداکثر و حداقل داده‌ها و N نشان‌دهنده مقدار نرمال می‌باشد.

$$N = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (\text{رابطه ۲})$$

ماشین یادگیری سریع (ELM)

به‌منظور کاربرد ماشین یادگیری سریع ابتدا به آن آموزش داده می‌شود و بر اساس این آموزش خروجی موردنظر به‌دست می‌آید.

مدل MLR به ترتیب مقدار R^2 از ۰/۸۶۴-۰/۷۰۰، مقدار R از ۰/۹۲۹-۰/۸۲۳ مقدار RMSE از ۲/۵۵۷-۲/۸۲۳ و درجه سلسیوس و مقادیر MAE از ۱/۵۲۹-۱/۳۹۸ درجه سلسیوس می‌باشد.

همان‌طور که مشاهده می‌شود به ترتیب بیش‌ترین و کم‌ترین ضریب همبستگی (R) و ضریب تعیین (R^2) خطی چندگانه بین دمای خاک و پارامترهای هواشناسی مربوط به عمق‌های ۵ و ۱۰۰ سانتی‌متری است و نتایج نشان داده است که با افزایش عمق خاک مقدار این ضرایب کاهش یافته است؛ اما مقدار این ضرایب از عمق ۵ تا ۳۰ سانتی‌متری بسیار نزدیک به هم بوده است و کاهش جزئی داشته است. نتایج نشان داده است که با افزایش عمق مقدار آماره‌های خطا MAE و RMSE افزایش یافته است، اما مقدار آن‌ها بسیار نزدیک به یکدیگر بوده است. با توجه به ضرایب به دست آمده در معادلات رگرسیونی مشاهده گردید که تبخیر، فشار بخار، سرعت باد و بارندگی به ترتیب بیش‌ترین تأثیر را نسبت به سایر متغیرهای اقلیمی بر دمای خاک داشت است. مطابق انتظار نتایج نشان داد که با افزایش عمق، تأثیر تبخیر و سرعت باد بر دمای خاک کاهش یافته است. با افزایش مقدار تبخیر از سطح خاک به دلیل اثر خنک‌کنندگی که بر خاک دارد، کاهش دما در طول نیم‌رخ خاک صورت می‌گیرد. از سوی دیگر با افزایش عمق خاک از سطح به طرف لایه‌های زیرین، به دلیل تبادلات کم‌تر گرما با محیط، مقدار دمای خاک کاهش پیدا می‌کند. از طرفی نتایج نشان می‌دهد با افزایش عمق تأثیر بارندگی تقریباً ثابت بوده است. در شکل (۲) همبستگی دمای خاک برآورد شده با دمای خاک اندازه‌گیری شده به روش رگرسیون خطی چندگانه در عمق‌های مختلف آمده است. همان‌طوری که ملاحظه می‌گردد با افزایش عمق کاهش یافته است؛ اما این همبستگی در لایه ۵ تا ۳۰ سانتی‌متری بسیار نزدیک و مشابه است ولی از عمق ۵۰ سانتی‌متری به بعد این همبستگی کاهش یافت. با افزایش عمق، نوسانات دمایی خاک کاهش و پراکنش داده‌ها در اطراف خط ۱:۱ بیشتر شد که نشان‌دهنده این است که با افزایش عمق اثر پارامترهای هواشناسی بر دمای خاک کاهش یافته است و بیش‌ترین تأثیر این پارامترها مربوط به لایه ۵ تا ۳۰ سانتی‌متری بوده است و همچنین نشان‌دهنده کاهش دقت مدل رگرسیون در برآورد دمای خاک در عمق‌های بیشتر است. *Yusefi et al.* (2020) به‌طور مشابه دریافتند که با افزایش عمق مقدار دما خاک روند نزولی داشته است و همبستگی بین دمای خاک با پارامترهای هواشناسی کاهش یافته است. مطالعات *Chow et al.* (2011) در هنگ کنگ کنگ نشان داد که درجه حرارت خاک به شدت به دمای هوا وابسته است درحالی‌که ارتباط آن با رطوبت نسبی، بارش و سرعت باد بسیار کم است. نتایج مطالعات *Yazdani et al.* (2012) نشان

وابسته مربوط به سایر عوامل می‌باشند. مقدار آن بین صفر و یک می‌باشد. اگر همبستگی زیاد باشد (نزدیک به یک)، مدل داده‌ها را خوب برازش کرده است، اگر همبستگی پایین (نزدیک به صفر) باشد، مدل برازش خوبی از داده‌ها ارائه نداده است.

ضریب همبستگی، همبستگی یک متغیر وابسته به متغیرهای مستقل را نشان می‌دهد. درواقع منظور از همبستگی قابلیت پیش‌بینی متغیر وابسته از طریق متغیرهای مستقل می‌باشد. این ضریب بین ۱ و -۱ است. $R=1$ به معنای همبستگی کامل منفی بین دو متغیر است، $R=0$ به معنای عدم وجود همبستگی مثبت بین دو متغیر است و $R=0$ مقدار RMSE نشان‌دهنده این است که مقادیر پیش‌بینی شده تا چه حد اندازه‌گیری را بیشتر یا کم‌تر تخمین زده‌اند. بهترین حالت برای RMSE این است که مقادیر پیش‌بینی شده و اندازه‌گیری شده باهم برابر باشند یعنی برابر با صفر باشد. آماره MAE، میانگین قدر مطلق تفاضل بین مقدار پیش‌بینی و واقعی را محاسبه می‌کند. MAE برابر صفر نشان‌دهنده تطبیق کامل مقادیر اندازه‌گیری شده و برآورد شده است.

$$R^2 = \frac{\left(\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \right)^2}{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2} \quad \text{(رابطه ۳)}$$

$$R = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad \text{(رابطه ۴)}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - X_i)^2} \quad \text{(رابطه ۵)}$$

$$MAE = \frac{\sum_{i=1}^n |X_i - Y_i|}{n} \quad \text{(رابطه ۶)}$$

در تمامی روابط بالا X_i و Y_i به ترتیب نشان‌دهنده i امین داده واقعی و برآورد شده، \bar{X} و \bar{Y} به ترتیب نشان‌دهنده میانگین داده‌های X_i و Y_i و n تعداد نمونه‌ها هستند.

نتایج و بحث

رگرسیون خطی چندگانه

جدول (۲) روابط رگرسیون خطی چندگانه بین دمای خاک در عمق‌های مختلف و پارامترهای هواشناسی به همراه ضرایب همبستگی و آماره‌های خطا را نشان می‌دهد. نتایج نشان می‌دهد مدل MLR عملکردی خوب در مدل‌سازی دمای خاک در تمام عمق‌ها بویژه لایه سطحی (۳۰-۰ سانتی‌متر) داشته است. برای

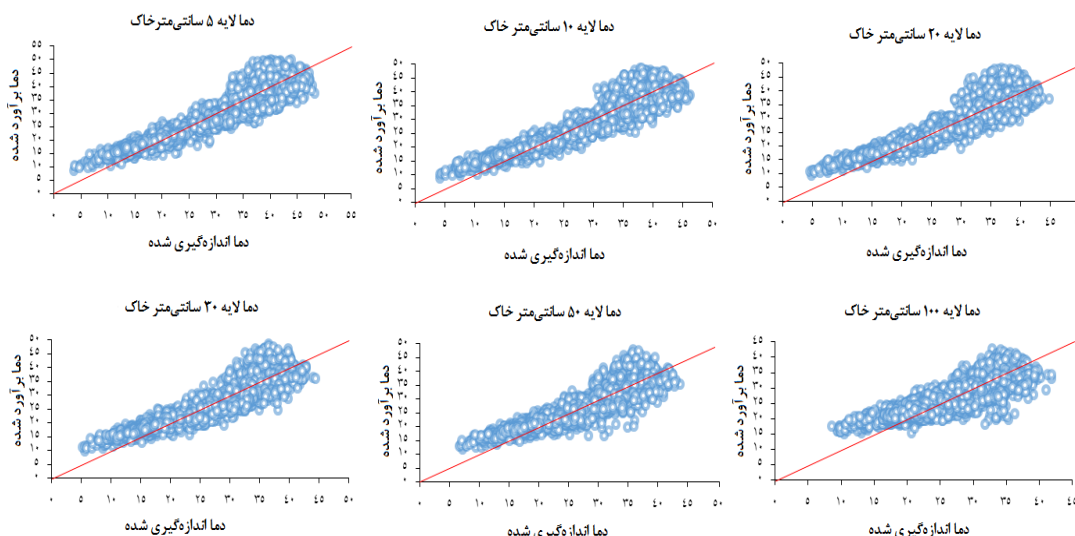
بین دمای خاک و دمای هوا مربوط به اعماق سطحی خاک و کم‌ترین آن مربوط به عمق یک متری است.

داد که دمای هوا، تبخیر تعرق و تبخیر به ترتیب بیشترین ضرایب همبستگی را با دمای خاک در عمق ۵ سانتی‌متر دارند. مطالعه Mazidi et al. (2018) نشان داد که بالاترین ضریب همبستگی

جدول ۲- روابط رگرسیون خطی چندگانه بین دمای خاک در عمق‌های مختلف و پارامترهای هواشناسی در استان خوزستان

R	R ²	MAE	RMSE	روابط رگرسیونی چندگانه	عمق خاک (cm)
۰/۹۲۹	۰/۸۶۴	۱/۳۹۸	۲/۷۵۷	$T_s = 9.365 + 0.055evt + 0.470ew - 0.482ff - 0.014rr$	۵
۰/۹۲۸	۰/۸۶۲	۱/۴۳۱	۲/۵۸۴	$T_s = 9.364 + 0.051evt + 0.496ew - 0.460ff - 0.015rr$	۱۰
۰/۹۲۳	۰/۸۵۱	۱/۴۴۴	۲/۶۰۲	$T_s = 9.613 + 0.046evt + 0.509ew - 0.425ff - 0.013rr$	۲۰
۰/۹۱۴	۰/۸۳۶	۱/۴۵۰	۲/۶۲۱	$T_s = 10.192 + 0.043evt + 0.513ew - 0.416ff - 0.013rr$	۳۰
۰/۸۹۸	۰/۸۰۷	۱/۵۲۸	۲/۷۱۱	$T_s = 11.866 + 0.039evt + 0.528ew - 0.403ff - 0.012rr$	۵۰
۰/۸۳۷	۰/۷۰۰	۱/۵۲۹	۲/۸۷۳	$T_s = 14.558 + 0.028evt + 0.533ew - 0.384ff - 0.010rr$	۱۰۰

تبخیر، ew فشار بخار، ff سرعت باد، rr بارندگی و Ts دما خاک



شکل ۲- همبستگی دمای خاک (درجه سلسیوس) برآورد شده با دمای خاک اندازه‌گیری شده (درجه سلسیوس) رگرسیون خطی چندگانه در عمق‌های مختلف

نتایج شبکه عصبی نیز نشان‌دهنده این است که با افزایش عمق ضرایب همبستگی (R) و تعیین (R²) کاهش و مقدار آماره‌های RMSE و MAE افزایش یافته‌اند، یعنی با افزایش عمق خاک همبستگی بین پارامترهای هواشناسی با دمای خاک کاهش یافته است. همچنین نتایج نشان‌دهنده نزدیک بودن ضرایب همبستگی و آماره‌های خطا لایه‌های ۵ تا ۳۰ سانتی‌متری است؛ یعنی پارامترهای هواشناسی بیشترین تأثیر را بر دمای سطح خاک تا عمق ۳۰ سانتی‌متری زیر سطح خاک دارند و با افزایش عمق این تأثیر کاهش می‌یابد. شایان ذکر است که از عمق ۵ تا ۳۰ سانتی‌متری دقت مدل در برآورد دمای خاک به مقدار ناچیزی کمتر شده است اما از عمق ۵۰ سانتی‌متری به بعد مقدار کاهش دقت مدل بیشتر بوده است. در شکل (۳) با توجه به نمودارهای همبستگی ۱:۱ بین دمای خاک اندازه‌گیری شده با

شبکه عصبی مصنوعی MLPNN

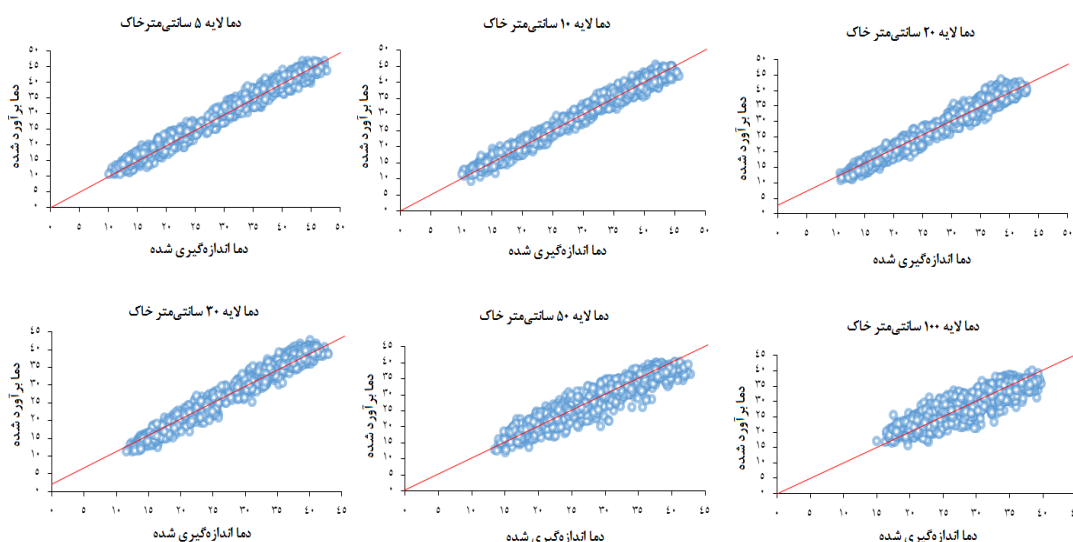
جدول (۳) ساختار شبکه عصبی ایجاد شده به همراه ضرایب همبستگی و آماره‌های خطا حاصل از برآورد دمای عمق‌های مختلف خاک را نشان می‌دهد. ساختار شبکه عصبی مورد استفاده در این پژوهش شامل یک لایه ورودی، دو لایه میانی (پنهان) به ترتیب با تعداد ۱۵ و ۴ نرون و تابع فعالیت تانژانت سیگموئید و یک لایه خروجی با تابع فعالیت خطی است. با توجه به نتایج این جدول مشاهده می‌شود که شبکه عصبی پرسپترون چندلایه استفاده شده به منظور برآورد دمای خاک، در تمامی عمق‌های خاک از دقت بسیار خوبی برخوردار بوده است. به طوری که برای این مدل‌های مقادیر R² از ۰/۹۶۷-۰/۹۹۷، مقادیر R از ۰/۹۸۸-۰/۹۸۳، مقادیر RMSE از ۰/۰۷۲-۰/۰۳۴، درجه سلسیوس و مقادیر MAE از ۰/۰۶۳-۰/۰۲۳، درجه سلسیوس می‌باشد.

هواشناسی بر دمای خاک در عمق‌های پایین‌تر است.

جدول ۳- آماره‌های خطا و ضرایب همبستگی و تعیین مدل شبکه عصبی (MLPNN) با آرایش نرون‌های (۱-۴-۱۵)

عمق خاک (cm)	تعداد تکرار	RMSE	MAE	R ²	R
۵	۴۵۱	۰/۰۳۳۸	۰/۰۲۲۹	۰/۹۹۶۷	۰/۹۹۸۳
۱۰	۵۹۶	۰/۰۳۶۹	۰/۰۲۴۱	۰/۹۹۵۵	۰/۹۹۷۷
۲۰	۲۸۰	۰/۰۳۸۹	۰/۰۲۷۸	۰/۹۹۴۱	۰/۹۹۷۰
۳۰	۲۵۰	۰/۰۵۰۷	۰/۰۴۰۵	۰/۹۹۱۴	۰/۹۹۳۴
۵۰	۱۷۳	۰/۰۶۳۷	۰/۰۵۴۲	۰/۹۶۸۴	۰/۹۸۴۱
۱۰۰	۲۰۰	۰/۰۷۲۱	۰/۰۶۳۵	۰/۹۶۷۰	۰/۹۸۳۳

برآورد شده مشخص شد که از عمق ۵ تا ۳۰ سانتی‌متری مدل شبکه عصبی MLPNN بیشترین دقت، بهترین پراکنش و برآورد را در تخمین دمای خاک داشته است که نشان‌دهنده بیشترین تأثیر پارامترهای هواشناسی بر دمای خاک در عمق ۵ تا ۳۰ سانتی‌متری است؛ اما در عمق‌های ۵۰ تا ۱۰۰ سانتی‌متری نمودار همبستگی پراکندگی بیشتری پیدا کرده است که بیانگر کم شدن تأثیر پارامترهای هواشناسی بر دمای خاک در لایه‌های عمقی و کاهش دقت مدل شبکه عصبی در تخمین دمای خاک در لایه‌های زیرین است. همچنین مشاهده می‌شود که با افزایش عمق به‌ویژه از عمق ۵۰ سانتی‌متری به بعد دامنه نوسانات دمای خاک کمتر شده است که این امر نیز دلیل بر کاهش اثر پارامترهای



شکل ۳- همبستگی دمای خاک (درجه سلسیوس) برآورد شده با دمای خاک (درجه سلسیوس) اندازه‌گیری شده شبکه عصبی مصنوعی MLPNN در عمق‌های مختلف

تیبین کاهش یافته‌اند؛ یعنی با افزایش عمق خاک همبستگی بین پارامترهای هواشناسی با دمای خاک کمتر شده است و همچنین با افزایش عمق آماره‌های RMSE و MAE نیز افزایش یافته‌اند که نشان‌دهنده کاهش اثر پارامترهای هواشناسی به‌عنوان متغیر مستقل بر دمای خاک به‌عنوان متغیر وابسته با افزایش عمق خاک است.

در مدل ELM نیز ضرایب همبستگی و آماره‌های خطا لایه‌های ۵ تا ۳۰ سانتی‌متری بسیار نزدیک و مشابه هم و با دقت زیاد است که این امر نشان‌دهنده تأثیرپذیرتر بودن لایه‌های سطح خاک از شرایط جوی حاکم نسبت به لایه‌های عمیق‌تر است و از عمق ۵۰ تا ۱۰۰ سانتی‌متری دقت مدل ELM نیز در تخمین دمای خاک کاهش بیشتری داشته است که نشان‌دهنده پایین آمدن اثر شرایط آب و هوایی بر دمای خاک در لایه‌های زیرین است. پراکنش داده‌ها در اطراف نمودار خط همبستگی ۱:۱ بین

ماشین یادگیری سریع (ELM)

در جدول (۴) ساختار ماشین یادگیری سریع مورد استفاده به-همراه ضرایب همبستگی و آماره‌های خطا حاصل از مدل ELM در برآورد دمای خاک عمق‌های مختلف نشان داده شده است. ساختار ماشین یادگیری سریع به‌دست آمده در این پژوهش شامل یک لایه ورودی، یک لایه میانی (پنهان) با تعداد ۱۲۰۰ نرون و تابع فعالیت تانژانت سیگموئید و یک لایه خروجی است. همچنین نتایج جدول (۴) نشان می‌دهد مدل ELM عملکردی بسیار خوبی در مدل‌سازی دمای خاک در تمام عمق‌ها داشته است. برای مدل ELM به‌ترتیب مقادیر R² از ۰/۹۹۶-۰/۹۶۷، مقادیر R از ۰/۹۹۸-۰/۹۴۸، مقادیر RMSE از ۰/۰۷۸-۰/۰۲۸، درجه سلسیوس و مقادیر MAE از ۰/۰۶۵-۰/۰۲۳، درجه سلسیوس می‌باشد.

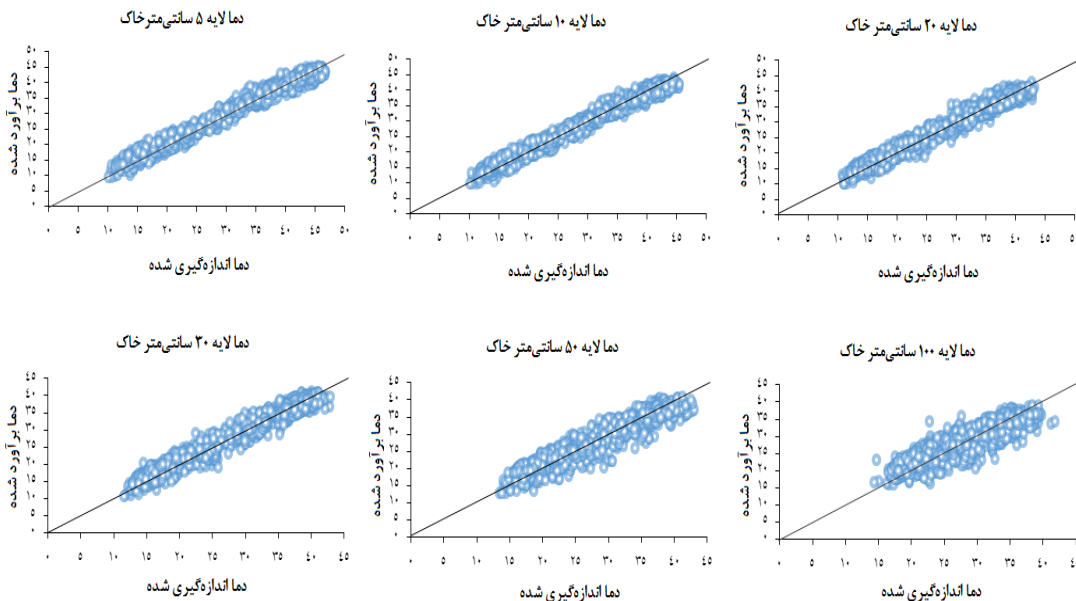
نتایج مدل ELM نیز همانند رگرسیون و شبکه عصبی نشان‌دهنده این است که با افزایش عمق، ضرایب همبستگی و

عمق ۵۰ سانتی‌متری به بعد دامنه نوسانات دمای خاک کمتر شده است که این امر نیز دلیل بر کاهش اثر پارامترهای هواشناسی بر دمای خاک در عمق‌های پایین‌تر است.

داده‌های واقعی و داده‌های تخمین زده‌شده با مدل ELM (شکل ۴) نشان‌دهنده این موضوع است که از عمق ۵ تا ۳۰ سانتی‌متری بسیار متراکم و نزدیک به هم است و از عمق ۵۰ سانتی‌متری پراکندگی آن‌ها بیشتر شده است. با افزایش عمق مخصوصاً از

جدول ۴- آماره‌های خطا و ضرایب همبستگی و تعیین در مدل ماشین یادگیری سریع (ELM) با تعداد نرون‌های ۱۲۰۰ و یک تکرار

عمق خاک (cm)	RMSE	MAE	R ²	R
۵	۰/۰۲۸۵	۰/۰۲۳۰	۰/۹۹۶۵	۰/۹۹۸۲
۱۰	۰/۰۳۶۱	۰/۰۲۶۱	۰/۹۹۳۲	۰/۹۹۶۶
۲۰	۰/۰۳۸۵	۰/۰۳۱۱	۰/۹۹۱۱	۰/۹۹۴۹
۳۰	۰/۰۵۴۶	۰/۰۴۳۳	۰/۹۹۰۱	۰/۹۹۳۸
۵۰	۰/۰۶۳۷	۰/۰۵۵۶	۰/۹۷۱۷	۰/۹۸۵۷
۱۰۰	۰/۰۷۸۲	۰/۰۶۵۱	۰/۹۶۸۶	۰/۹۸۴۲



شکل ۴- همبستگی دمای خاک (درجه سلسیوس) برآورد شده با دمای خاک (درجه سلسیوس) اندازه‌گیری شده ماشین یادگیری سریع ELM در عمق‌های مختلف

بحث و نتیجه‌گیری

عمق خاک کمتر متأثر از افت‌وخیزهای پارامترهای هواشناسی مانند دمای هوا است، به عبارت دیگر، پاسخ لایه‌های زیرین به تغییر دمای هوا بسیار کند است، در صورتی که این پاسخ در سطح خاک از سرعت چشمگیری برخوردار است (Jaffari Golestan 2008). همچنین دقت روابط در لایه‌های سطحی خاک به واسطه تأثیرپذیری بیشتر دمای خاک از عوامل جوی و تأخیر زمانی کمتر جهت انتقال حرارت از سطح به این لایه‌ها است (Parsafar et al., 2011). همچنین نتایج بررسی همبستگی بین دمای اندازه‌گیری شده و برآورد شده نشان داد در هر سه نوع مدل پراکنش داده‌ها در اطراف خط ۱:۱ (دمای خاک اندازه‌گیری شده و برآورد شده) در عمق‌های ۵ تا ۳۰ سانتی‌متری متراکم و در عمق‌های

نتایج به‌دست‌آمده از هر سه مدل رگرسیون خطی چندگانه MLR، شبکه عصبی MLPNN و ماشین یادگیری سریع ELM به‌خوبی نشان می‌دهد با افزایش عمق خاک همبستگی بین دمای خاک و پارامترهای هواشناسی کاهش یافت؛ یا به عبارت دیگر اثر پارامترهای هواشناسی بر دمای خاک با افزایش عمق کاهش یافت که با نتایج تحقیق (Abyaneh et al 2016)، janbaz Ghobadi et al. (2017) و Asadi et al (2014) مطابقت دارد. در هر سه مدل ارائه‌شده بیشترین همبستگی بین دمای خاک با پارامترهای هواشناسی مربوط به لایه‌های ۵ تا ۳۰ سانتی‌متری است. به دلیل عایق‌بندی لایه‌های عمقی خاک توسط لایه‌های بالایی، دمای

خطا (RMSE) از عمق ۵ تا ۲۰ سانتی‌متری مدل ELM دقت بهتری داشته و در عمق ۳۰ و ۱۰۰ سانتی‌متری مدل MLPNN عملکرد بهتری داشته است و در عمق ۵۰ سانتی‌متری هر دو مدل دقت یکسانی داشته‌اند. همچنین پراکنش داده‌ها در اطراف خط ۱:۱ در نمودار همبستگی (دمای خاک اندازه‌گیری شده و برآورد شده) به‌دست‌آمده با استفاده هر دو مدل شبکه عصبی MLPNN و ماشین یادگیری سریع ELM ب بسیار مشابه یکدیگر است و دارای دقت بالای هستند.

بنابراین با توجه به نتایج به‌دست‌آمده می‌توان نتیجه گرفت که دو مدل شبکه عصبی MLPNN و ماشین یادگیری سریع ELM توانایی بالایی در برآورد دمای خاک با استفاده از پارامترهای هواشناسی نسبت به رگرسیون خطی چندگانه MLR داشته‌اند؛ اما در مقایسه نحوه ایجاد دو مدل MLPNN و ELM، مدل ELM بسیار سریع‌تر و در زمان کوتاه‌تری به‌دست‌آمد زیرا برخلاف مدل MLPNN که در آن تعداد نرون‌های لایه‌های میانی به‌صورت سعی و خطا تعیین می‌شود که فرآیندی زمان‌بر است و همچنین فرآیند آموزش در آن با چندین تکرار صورت گرفت تا مدل آموزش ببیند و بر اساس این آموزش خروجی مناسب تهیه شود، در مدل ELM لایه مخفی نیاز به تنظیم ندارد و فرایند یادگیری آن تنها نیازمند یک تکرار است؛ بنابراین در مقایسه با شبکه‌های عصبی MLPNN سرعت آموزش بسیار بالاتری داشته و همچنین می‌توان گفت تا حدودی عملکرد کلی بهتری در برآورد دمای خاک داشته است. Nahvi et al. (2016) و Feng et al. (2019) به‌طور مشابه مشاهده کردند که عملکرد مدل ELM در برآورد دمای خاک در مقایسه با سایر مدل‌هایی که به کار بردند بهتر بوده است. به‌طور کلی با توجه به نتایج این پژوهش می‌توان نتیجه گرفت مدل ماشین یادگیری سریع ELM به‌عنوان روشی دقیق، سریع و کم‌هزینه، در برآورد و مدل‌سازی دمای خاک در کوتاه‌ترین زمان، بالاترین دقت و با کم‌ترین هزینه مؤثر و مفید است و استفاده از آن به‌منظور برآورد دمای خاک در سایر مناطق توصیه می‌شود.

سپاسگزاری

نویسندگان این مقاله از سازمان هواشناسی کشور به سبب در اختیار قرار دادن داده‌های هواشناسی کمال تشکر و قدردانی را دارند.

REFERENCES

Abyaneh, H.Z. Varkeshi, M.B., Golmohammadi, G., and Mohammadi, K. (2016). Soil temperature estimation using an artificial neural network and co-active neuro-fuzzy inference system in two different climates, *Arabian Journal of Geosciences*, 9(5), 377.

۵۰ تا ۱۰۰ سانتی‌متری پراکندگی آن‌ها بیشتر شد که نشان‌دهنده کاهش دقت هر سه مدل در برآورد دمای خاک با استفاده از پارامترهای هواشناسی در عمق‌های پایین‌تر است. نتایج ارزیابی دقت پیش‌بینی مدل‌های به‌دست‌آمده جهت برآورد دمای خاک نشان داد مدل‌های ELM، MLPNN و MLR عملکردی مطلوب در مدل‌سازی دمای خاک در تمام عمق‌ها داشتند برای مدل‌های ELM، MLPNN، MLR به‌ترتیب مقادیر R^2 از ۰/۸۶۴-۰/۷۰۰، ۰/۹۹۷-۰/۹۶۷ و ۰/۹۹۶-۰/۹۶۷، مقادیر R از ۰/۹۲۹-۰/۸۲۳، ۰/۹۸۸-۰/۹۸۳ و ۰/۹۹۸-۰/۹۴۸، مقادیر RMSE از ۲/۸۲۳-۲/۵۵۷، ۰/۰۷۲-۰/۰۳۴ و ۰/۰۷۸-۰/۰۲۸، درجه سلسیوس و مقادیر MAE از ۱/۵۲۹-۱/۳۹۸، ۰/۰۶۳-۰/۰۲۳ و ۰/۰۶۵-۰/۰۲۳ درجه سلسیوس بود. با توجه به مقادیر آماره‌های ضریب همبستگی (R)، ضریب تعیین (R^2)، میانگین خطای مطلق (MAE) و جذر میانگین مربع خطا (RMSE) مربوط به هر سه مدل می‌توان نتیجه گرفت که دقت مدل رگرسیون خطی چندگانه بسیار پایین‌تر از شبکه عصبی و ماشین یادگیری سریع است و همچنین در نمودار همبستگی به‌دست‌آمده با استفاده از رگرسیون چندگانه پراکنش داده‌ها در اطراف خط ۱:۱ (دمای خاک اندازه‌گیری شده و برآورد شده) نسبت به مدل‌های شبکه عصبی و ماشین یادگیری سریع بسیار بیشتر و نامنظم‌تر است که نشان‌دهنده دقت کم‌تر مدل رگرسیون خطی چندگانه در برآورد دمای خاک نسبت به دو مدل دیگر است؛ که با نتایج Sabziparvar and Khoshhal (2018) مطابقت دارد که آن‌ها دریافتند که دقت شبکه عصبی نسبت به رگرسیون در برآورد دمای خاک بهتر است. مقایسه نتایج به‌دست‌آمده با استفاده از دو مدل شبکه عصبی MLPNN و ماشین یادگیری سریع ELM نشان می‌دهد که هر دو مدل دقت بالایی در برآورد دمای خاک داشته‌اند و مقادیر ضرایب همبستگی و آماره‌های خطا مربوط به هر دو مدل بسیار نزدیک به یکدیگر است و تفاوت آن‌ها با یکدیگر بسیار جزئی بوده است. در عمق ۵ تا ۲۰ سانتی‌متری خاک مقدار دقت ضریب همبستگی (R) و ضریب تعیین (R^2) به‌دست‌آمده از مدل MLPNN به‌صورت بسیار جزئی از مدل ELM بهتر است اما از عمق ۳۰ تا ۱۰۰ سانتی‌متری دقت مدل ELM به‌صورت جزئی بهتر بوده است. در مورد مقدار میانگین خطای مطلق (MAE)، مدل MLPNN در تمام عمق‌های خاک به‌صورت بسیار جزئی دقت بهتری داشته است؛ اما در مورد جذر میانگین مربع

Alavipanah, S. K. (2006). Thermal remote sensing and its application in the earth sciences. Universality of Tehran Press, 523.

Alizadeh, A. (2014). Soil Physics (7th ed). Publishing Ferdowsi University of Mashhad.

Asadi, L., Hezarjaribi, A., Ghorbani, Kh., Zakernia, M.

- and AghaShariatmadari, Z. (2014). Estimating Soil Temperature Using Modern Methods of Data Analysis. *Iranian Journal of Irrigation and Drainage*, 8(1), 145-152
- Bachmann, J., Horton, R., Grant, S. A., and van der ploeg R. R. (2002). Temperature dependence of water retention curves for wettable and water repellent soils. *Soil Science Society of America Journal*, 66(1), 44-52.
- Chow, T. T., Long, H., Mok, H. Y., and Li, K. W. (2011). Estimation of soil temperature profile in Hong Kong from climatic variables. *Energy and Buildings*, 43(12), 3568-3575.
- Citakoglu, H. (2017). Comparison of artificial intelligence techniques for prediction of soil temperatures in Turkey. *Theoretical and Applied Climatology*, 130 (1-2), 545-556.
- Deng, W. Y., Zheng, Q. H., Chen, L., and Xu, X. B. (2010). Research on extreme learning of neural networks. *Chinese Journal of Computers*, 33(2), 279-287.
- Ding, S., Zhao, H., Zhang, Y., Xu, X., and Nie, R. (2015). Extreme learning machine: algorithm, theory and applications. *Artificial Intelligence Review*, 44(1), 103-115.
- Feng, Y., Cui, N., Hao, W., Gao, L., and Gong, D. (2019). Estimation of soil temperature from meteorological data using different machine learning models. *Geoderma*, 338, 67-77.
- Gill, J., and Singh, S. (2015). An efficient neural networks based genetic algorithm model for soil temperature prediction. *International Journal of Emerging Technologies in Engineering Research (IJETER)*, 3, 1-5.
- Ismail Beekey, F. Zare haggi, D. Ghorbani, M. and Neyshabouri, M. (2017). Soil Temperature Estimation Based on Climatic Parameters Using Artificial Neural Network Models and Hybrid Firefly Algorithm (Case Study, East Azarbaijan Province). *Fourth International Conference on Environmental Planning and Management*, Tehran, Faculty of Environment, University of Tehran.
- Jacobs, A. F., Heusinkveld, B. G., and Holtslag, A.A. (2011). Long-term record and analysis of soil temperatures and soil heat fluxes in a grassland area, The Netherlands. *Agricultural and Forest Meteorology*, 151(7), 774-780.
- Jaffari Golestan, M., Raeini-Sarjaz, M. and Ahmadi, M.Z. (2008). Estimation of soil depth temperatures using curve analysis and regression models for City of Sari (Iran). *Journal of Agricultural Sciences and Natural Resources*, 14(5), 112-123. (In Farsi)
- Janbaz Ghobadi, GH., Yaghoubi, M., and Gholi Zade, B. (2017). Investigation of the Relationship between Meteorological Shelter Temperature with The temperature of different soil depths in air Humidity conditions. (Case Study: Sari City). *Earth Science Research*, 8(30), 80-94. (In Farsi)
- Kim, S. and Singh, V.P. (2014). Modeling daily soil temperature using data-driven models and spatial distribution. *Theoretical and Applied Climatology*, 118 (3), 465-479.
- Kisi, O., Tombul, M. and Kermani, M.Z. (2015). Modeling soil temperatures at different depths by using three different neural computing techniques. *Theoretical and applied climatology*, 121(1-2), 377-387.
- Mazidi, A. and Fallah Zadeh F. (2011). Study the process of annual soil temperature in Yazd station. *Geography and Development*, 9(24), 39-50.
- Mazidi, A., Mozafari, G.A., and Jahani, F. (2018). Determination of the Relationship between Temperature and Depth of Soil at Abade Station. *The Second National Iranian Meteorological Conference*, May 28, 2018, Ferdusi University, Mashhad, Iran, pp. 1-6.
- Momeni, M., and Faal Qayyumi, A. (2010). Statistical analysis using SPSS. University of Tehran Press.
- Nahvi, B., Habibi, J., Mohammadi, K., Shamsirband, S. and Razgan, O.S.A. (2016). Using selfadaptive evolutionary algorithm to improve the performance of an extreme learning machine for estimating soil temperature. *Computers and Electronics in Agriculture*, 124, 150-160.
- Parsafar, N., and Marofi, S. (2011). Estimation of Soil Temperature from Air Temperature Using Regression Models, Artificial Neural Network and Adaptive Neuro-Fuzzy Inference System (Case Study: Kermanshah Region). *Soil and Water Science*, 3(21), 139-152. (In Farsi)
- Plauborg, F. (2002). Simple model for 10 cm soil temperature in different soils with short grass. *European Journal of Agronomy*, 17, 173-179.
- Sabziparvar, A. A., and Khoshhal, J. F. (2018). Comparison of Multi-Layer Perceptron artificial neural network and Linacre regression model performance for predicting daily minimum temperature (Case study: Kerman, Shiraz, Rasht and Hamedan). *Iranian Journal of Geophysics*, 12(3), 107-121. (In Farsi)
- Samadianfard, S., Asadi, E., Jarhan, S., Kazemi, H., Kheshtgar, S., Kisi, O., and Manaf, A.A. (2018). Wavelet neural networks and gene expression programming models to predict short-term soil temperature at different depths. *Soil and Tillage Research*, 175, 37-50.
- Tabari, H., Hosseinzadeh Talae, P., and Willems, P. (2015). Short-term forecasting of soil temperature using artificial neural network. *Meteorological Applications*, 22(3), 576-585.
- Yazdani, V., Ghahreman, B., Farhadi, G., and Nori, H. (2012). Modeling soil depth temperature by using methrological parameters. *Journal of Water and Soil Conservation*. 19(4) 1-15, (In Farsi)
- Yusefi, A., Farrokhian Firouzi, A., and Aminzadeh, M. (2020). Effect of mulch on soil moisture, temperature and heat flux variation in the presence of shallow groundwater. *Iranian Journal of Soil and Water Research*, 50(9), 2213-2225. (In Farsi)