

مقایسه عملکرد رگرسیون خطی چندمتغیره و مدل‌های هوش مصنوعی در تخمین تابش کل خورشیدی

علی‌اکبر سبزی‌پرور* - استاد هواشناسی، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان
پویا عاقل‌پور - دانشجوی کارشناسی ارشد هواشناسی کشاورزی، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان
وحید ورشویان - استادیار، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان.

تاریخ دریافت: ۱۳۹۷/۵/۲۸ تاریخ پذیرش: ۱۳۹۸/۱/۱۷

چکیده

در این پژوهش، برای اولین بار در ایران، تابش کل خورشیدی (GSR) با به‌کارگیری داده‌های ساعتی رطوبت خاک و بدون استفاده از داده‌های ساعت آفتابی و مقدار ابرناکی برآورد شد. بدین منظور، از هشت متغیر روزانه شامل میانگین دمای هوا، بیشینه دما، کمینه دما، فشار هوا، رطوبت نسبی هوا، بارندگی، دمای میانگین خاک، و رطوبت خاک در کنار تابش کل روزانه در ایستگاه تحقیقاتی هواشناسی دانشگاه بوعلی سینا در یک دوره ۴۳۵ روزه (ثبت‌شده توسط واقعه‌نگاشت GEONICA) و مدل‌های رگرسیون خطی، سیستم استنتاج عصبی - فازی تطبیقی (ANFIS)، شبکه عصبی پرسپترون چندلایه (MLP)، و شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) استفاده شد. نمونه‌های ورودی - هدف به دو صورت تصادفی و غیرتصادفی وارد مدل‌ها شد که نتایج گواه بر دقت بهتر مدل‌ها در نمونه‌های تصادفی شده تحت شرایط استفاده از کل متغیرها به‌عنوان ورودی بود. بررسی‌ها حاکی از برتری مدل MLP با $RMSE=3.04$ مگاژول بر متر مربع در روز و $R^2=86.33\%$ بود. افزون‌براین، به‌کارگیری کمترین متغیرهای هواشناسی شامل سه متغیر دمای میانگین هوا، رطوبت نسبی هوا، و دمای خاک در مدل GRNN توانست با $RMSE=3.45$ مگاژول بر متر مربع در روز و $R^2=82.52\%$ عملکرد بسیار مطلوبی در تخمین GSR ارائه دهد. رگرسیون خطی چندمتغیره نیز فقط توانست یافتن ورودی‌ها را تسهیل کند.

واژگان کلیدی: دمای خاک، رطوبت خاک، GSR، MLP، ANFIS، GRNN

مقدمه

تابش خورشیدی منشأ همه انرژی‌های روی کره زمین و پارامتری مهم در مطالعات هیدرولوژی، مدیریت منابع آب، معادلات بیلان آبی، و مدل‌های شبیه‌سازی رشد گیاه به‌شمار می‌رود (سیدیان و همکاران، ۱۳۹۶: ۸۹). روش رایج ثبت داده‌های تابش خورشیدی استفاده از دستگاه پیرانومتر است و، به‌دلیل هزینه‌های زیاد، نصب و نگهداری این دستگاه در همه مناطق امکان‌پذیر نیست. از سوی دیگر، به‌رغم اینکه در مدل‌های مرسوم تخمین روزانه تابش کل (نظیر مدل انگستروم یا انگستروم - پریسکات) از داده‌های روزانه ساعات آفتابی و ابرناکی بهره گرفته می‌شود، این پارامترها متأسفانه به‌صورت دقیق و قابل اعتماد در ایستگاه‌ها اندازه‌گیری نمی‌شوند. همچنین، در برآوردها و پیش‌بینی‌های تابش کل خورشیدی (GSR)^۱ در مقیاس‌های زمانی کمتر از روزانه (ساعتی - دقیقه‌ای) امکان استفاده از پارامترهای فوق وجود ندارد. یکی از محدودیت‌های بسیار مهم برای محققان و پروژه‌های حیاتی تخمین تابش کل خورشیدی است (سیدیان و

E-mail: swsabzi@basu.ac.ir

* نویسنده مسئول، تلفن: ۰۹۱۲۱۸۵۹۹۷۰

1. Global Solar Radiation

همکاران، ۱۳۹۶: ۸۹). به استثنای پیرانومتر، که در عمل دقیق‌ترین روش اندازه‌گیری تابش خورشیدی است و برای صحت‌سنجی روش‌های دیگر نیز از آن استفاده می‌شود، از سه روش دیگر نیز برای این موضوع بهره گرفته می‌شود که عبارت‌اند از: مدل‌های فیزیکی و محاسباتی، اندازه‌گیری‌های ماهواره‌ای، و مدل‌های شبکه‌عصبی (هوشنگی و آل شیخ، ۱۳۹۳: ۱۸۸). مدل‌های فیزیکی و محاسباتی براساس عناصر و متغیرهای مختلف هواشناسی از جمله مدت تابش، ابرناکی، و دامنه روزانه دمای هوا می‌توانند مقدار تابش GSR را برآورد کنند. در مناطقی که در آن شبکه زمینی هواشناسی وجود ندارد، شدت تابش کل خورشیدی را می‌توان توسط داده‌های سنجش از دور ماهواره‌هایی همچون NOAA، INSAT، AVHRR، HIMAWARE، Meteosat، و GEOS اندازه‌گیری کرد. در مدل‌های پیش‌بینی شبکه‌عصبی، انواع پارامترهای هواشناسی مثل دمای هوا، رطوبت نسبی، و ساعت آفتابی به‌راحتی با یکدیگر ادغام می‌شوند تا تابش خورشیدی برآورد شود (هوشنگی و آل شیخ، ۱۳۹۳: ۱۸۸).

به‌رغم اینکه معادلات مبتنی بر ساعات آفتابی دارای قدرت تخمین بالاتری می‌باشند، به دلیل عدم اندازه‌گیری این متغیر در برخی ایستگاه‌ها، استفاده از معادلات مبتنی بر دما ارجحیت می‌یابد (قبایی سوق و همکاران، ۱۳۹۰: ۱۸۷). روش آنگستروم-پریسکات، به دلیل سادگی و نتایج قابل قبول، مدت زیادی است که برای برآورد محاسبه تابش کل خورشیدی به کار گرفته می‌شود که این رابطه بعدها توسط آکین‌اوغلو و اسویت (۱۹۹۰) و همچنین الاگیب و مانسل (۲۰۰۰) توسعه یافت و به شکل‌های نمایی و درجه دوم ارائه شد. از معادلات تجربی دیگر که برای تخمین تابش کل خورشیدی ارائه شد می‌توان به پژوهش‌های انجام‌گرفته توسط بریستو و کمپیل (۱۹۸۴)، عبدالله (۱۹۹۴)، و چن و همکاران (۲۰۰۴) نیز اشاره کرد. گذشته از این معادلات تجربی، در سال‌های اخیر مدل‌های غیرخطی هوش مصنوعی، نظیر شبکه‌عصبی پرسپترون چندلایه (سیواکریشنا رائو و همکاران، ۲۰۱۸؛ خسروی و همکاران، ۲۰۱۸؛ بیلدریم و همکاران، ۲۰۱۸)، ماشین بردار پشتیبان (ترابی و همکاران، ۲۰۱۸؛ فن و همکاران، ۲۰۱۸)، رگرسیون بردار پشتیبان (گوئرمویی و همکاران، ۲۰۱۸)، و دسته‌بندی گروهی داده‌ها^۱ (خسروی و همکاران، ۲۰۱۸) نیز توسط پژوهشگران برای برآورد مقادیر تابش به کار گرفته شده است. شبکه‌های عصبی مصنوعی با الهام از سلول‌های زیستی طراحی شده‌اند و قابلیت ایجاد نگاشت‌های غیرخطی میان متغیرهای ورودی و هدف را دارا می‌باشند (قبایی سوق و همکاران، ۱۳۹۰: ۱۸۷). از اولین تحقیقاتی که توسط مدل‌های هوش مصنوعی برای برآورد تابش خورشیدی انجام گرفت می‌توان به مطالعات مهندس و همکاران (۱۹۹۸) و لوپز و همکاران (۲۰۰۱) اشاره کرد که به ترتیب برای برآورد تابش کل خورشیدی و تابش فعال فتوسنتزی (PAR) از شبکه‌عصبی پرسپترون چندلایه بهره جستند. تیمویس و همکاران نیز توسط این مدل و مقایسه آن با مدل آنگستروم مطالعه‌ای انجام دادند (۲۰۰۵). در مناطق کوهستانی اسپانیا نیز بوش و همکاران (۲۰۰۸) تابش روزانه را به وسیله شبکه‌عصبی پرسپترون چندلایه برآورد و ارزیابی کردند. بهرنگ و همکاران (۲۰۱۰) در مطالعه‌ای برای برآورد تابش کل روزانه به وسیله متغیرهای هواشناسی، از مدل‌های شبکه‌عصبی پرسپترون چندلایه و شبکه‌عصبی شعاعی پایه استفاده کردند. ایشان با استفاده از پارامترهای شماره روز سال، میانگین دمای هوا، رطوبت نسبی، ساعت آفتابی، تبخیر، و سرعت باد ثبت شده در ایستگاه صفی‌آباد در دزفول توانستند دقت مطلوب این دو مدل را در برآورد تابش کل روزانه در این ایستگاه گزارش کنند. در تحقیقی توسط مرشد ورزنده و همکاران (۲۰۱۴) برای برآورد تابش در تهران از شبکه‌عصبی موجکی و مدل نروفازی استفاده شد که نتایج حاکی از دقت مطلوب این دو مدل در برآورد متغیر مورد بررسی بوده است. از مدل

1. Group Method of Data Handling
2. Photosynthetically Active Radiation

نروفازی برای پیش‌بینی سری زمانی روزانه تابش کل خورشیدی در طبس نیز استفاده شد و نتایج رضایت‌بخشی از این مدل برای پیش‌بینی این متغیر گزارش شد (محمدی و همکاران، ۲۰۱۵). از دیگر بررسی‌ها در زمینه تخمین تابش توسط شبکه عصبی پرسپترون می‌توان به تحقیقات گوئرمویی و همکاران (۲۰۱۶)، وکیلی و همکاران (۲۰۱۵)، و مینال و ایمانوئل سلواکومار (۲۰۱۸) و به‌وسیله مدل نروفازی به کاسم و همکاران (۲۰۱۶)، اولاتومیوا و همکاران (۲۰۱۵)، و سومیتیرا و نیرمال کومار (۲۰۱۲) اشاره کرد. در تحقیقی مشابه توسط لطفی‌نژاد و همکاران (۲۰۱۸) به همراه مدل نروفازی از شبکه‌های عصبی خفشی^۱ و همچنین شبکه عصبی رگرسیون تعمیم‌یافته استفاده شد و به مقایسه عملکرد آن‌ها پرداخته شد. برای تخمین تابش کل خورشیدی از ادغام مدل نروفازی با الگوریتم‌های قوی بهینه‌سازی نظیر ازدحام ذرات^۲ یا ژنتیک^۳ نیز استفاده می‌شود (هالابی و همکاران، ۲۰۱۸؛ خسروی و همکاران، ۲۰۱۸).

در مطالعات داخلی از شبکه عصبی پرسپترون چندلایه برای برآورد مقادیر روزانه تابش کل خورشیدی در ایستگاه اهواز استفاده شد و نتایج حاصل از آن با اطلاعات سنجنده MODIS مقایسه گردید که عملکرد شبکه عصبی دقیق‌تر گزارش شد (امامی‌فر و علیزاده، ۱۳۹۳). از این مدل برای برآورد تابش کل در شهرهای اصفهان، ارومیه، شیراز، و کرمان (سبزی‌پرور و بیات ورکشی، ۱۳۸۹)، زاهدان (مقدم و چاری، ۱۳۹۵)، کرمانشاه (واثقیان، ۱۳۹۵)، و تبریز (سبزی‌پرور و علیایی، ۱۳۹۰) و نیز برای تخمین تابش خالص^۴ روزانه در همدان (سبزی‌پرور و ختار، ۱۳۹۴؛ ۱۳۹۵) استفاده شد. سبزی‌پرور و بیات ورکشی (۱۳۸۹) برای تخمین تابش کل خورشیدی از مدل نروفازی نیز استفاده کردند و دقت قابل قبول این مدل را گزارش نمودند. از مدل نروفازی برای برآورد تابش کل در ۶۳ ایستگاه کل کشور نیز استفاده شد و در مقایسه با شبکه عصبی نتایج حاصله از روش خوشه‌بندی فازی با سیستم سوگنو خطای کمتری را نسبت به شبکه عصبی نشان داد (هوشنگی و آل‌شیخ، ۱۳۹۳). در مطالعات پیری و همکاران (۱۳۹۲) از مدل نروفازی برای برآورد میزان تابش کل استفاده شده است. نتایج این بررسی، که در دو شهر زاهدان و بجنورد انجام شد و با خروجی‌های مدل آنگستروم و هارگریوز-سامانی مقایسه گردید، برتری مدل نروفازی را در این دو ایستگاه به نسبت مدل‌های تجربی اعلام نمود.

هدف اصلی، در مطالعه حاضر، مقایسه مدل‌های رگرسیون خطی چندمتغیره و سه مدل هوش مصنوعی نروفازی، شبکه عصبی پرسپترون چندلایه، و شبکه عصبی رگرسیون تعمیم‌یافته با یکدیگر در برآورد تابش کل خورشیدی روزانه در همدان و ارائه دقیق‌ترین مدل در تخمین این متغیر به کمک متغیرهای هواشناسی است.

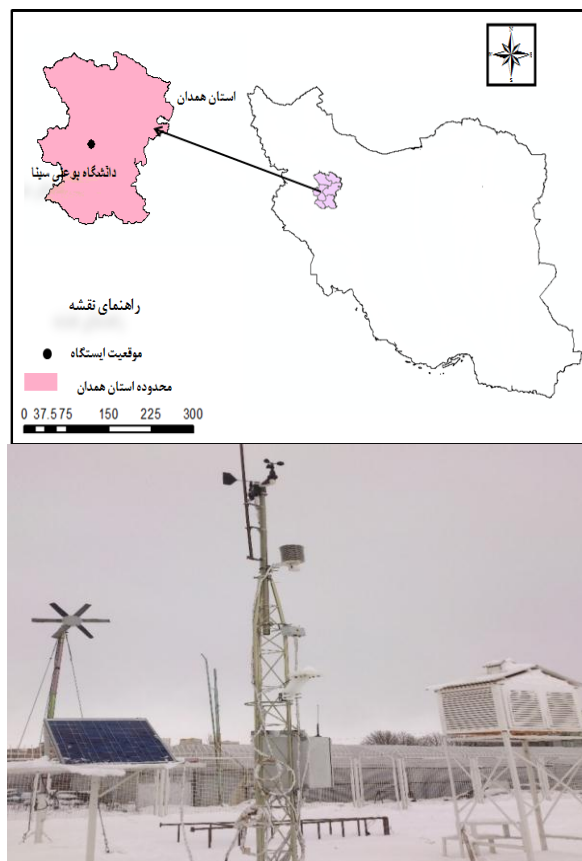
مواد و روش‌ها

داده‌ها

اقلیم همدان، با توجه به روش طبقه‌بندی دومارتن گسترش‌یافته، در کلاس نیمه‌خشک فراسرد واقع شده است (رحیمی و همکاران، ۲۰۱۳: ۴۱۷) و دارای متوسط ارتفاع ۱۸۰۰ متر از سطح دریاها^۵ آزاد است (سبزی‌پرور و ختار، ۱۳۹۵: ۲۰۸۸). در این مطالعه از تابش کل خورشیدی (GSR) ثبت‌شده توسط واقعه‌نگاشت اسپانیایی GEONICA، همراه برخی متغیرهای هواشناسی (مقادیر روزانه دمای بیشینه، میانگین و کمینه هوا، فشار هوا، رطوبت نسبی، دمای خاک، رطوبت خاک، و بارندگی) ثبت‌شده در ایستگاه تحقیقاتی هواشناسی دانشگاه بوعلی سینای همدان واقع در عرض جغرافیایی ۳۴

1. Bat Neural Network
2. Particle swarm optimization
3. Genetic Algorithm
4. Net Radiation

درجه و ۴۸ دقیقه و طول جغرافیایی ۴۸ درجه و ۲۸ دقیقه (سبزی‌پرور و ختار، ۱۳۹۴: ۴۰) و ارتفاع ۱۸۵۱ متر از سطح آب‌های آزاد استفاده شده است. شکل ۱ موقعیت جغرافیایی این ایستگاه را نشان می‌دهد. داده‌های مورد مطالعه به صورت روزانه وارد مدل شدند که این داده‌های روزانه از اندازه‌گیری‌های ده دقیقه‌ای واقعه‌نگاشت طی روزهای ۳۱ دسامبر ۲۰۱۶ تا ۱۰ مارس ۲۰۱۸ به دست آمده است.



شکل ۱. موقعیت جغرافیایی منطقه (سبزی‌پرور و ختار، ۱۳۹۴: ۴۱) و تصویر واقعه‌نگاشت GEONICA

مدل رگرسیون خطی چندمتغیره (MR)^۱

مدل رگرسیون خطی چندمتغیره مدلی است که میان سری متغیرهای مستقل (x_1, x_2, \dots, x_n) و وابسته (y) به شکل رابطه ۱ تعریف می‌شود:

$$y = b_1x_1 + b_2x_2 + \dots + b_nx_n + c \quad (1)$$

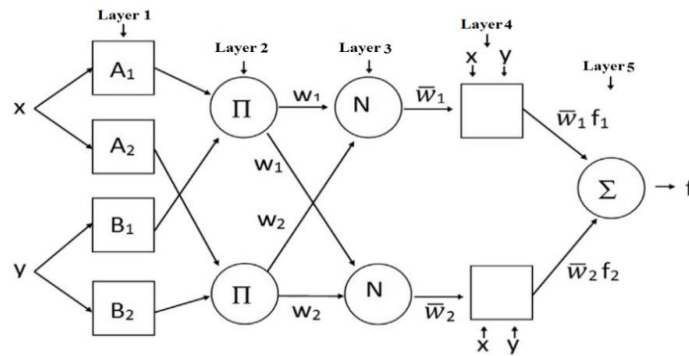
جایی که b_i ها ضرایب رگرسیونی و c ضریب ثابت مدل است (کشاورزی و همکاران، ۲۰۱۷: ۱۷۶). پس از انتخاب ورودی‌ها (متغیرهای هواشناسی) برای متغیر وابسته، که تابش است، ضرایب بهینه‌سازی شده و مدل استخراج می‌شود.

سیستم استنتاج عصبی- فازی تطبیقی (ANFIS)^۲

این مدل، که با نام مدل نروفازی نیز از آن یاد می‌شود، یک مدل شبکه‌ای چندلایه است که از الگوریتم‌های پیشرفته

1. Multilinear Regression
2. Adaptive Neuro-Fuzzy Inference System

یادگیری شبکه عصبی و منطق فازی برای توصیف روابط میان ورودی‌ها با خروجی استفاده می‌کند. این مدل قابلیت یادگیری شبکه‌های عصبی را برای تعریف و استفاده از روابط میان متغیرهای ورودی - خروجی با استفاده از قوانین فازی ارائه می‌دهد و سپس ساختار ورودی سیستم ایجاد می‌شود (کشاورزی و همکاران، ۲۰۱۷: ۱۷۷). شکل ۲ فرم شماتیک مدل ANFIS با پنج لایه را نشان می‌دهد.



شکل ۲. الگوی ساختار پایه ANFIS (کویچ و همکاران، ۲۰۱۷: ۶۴)

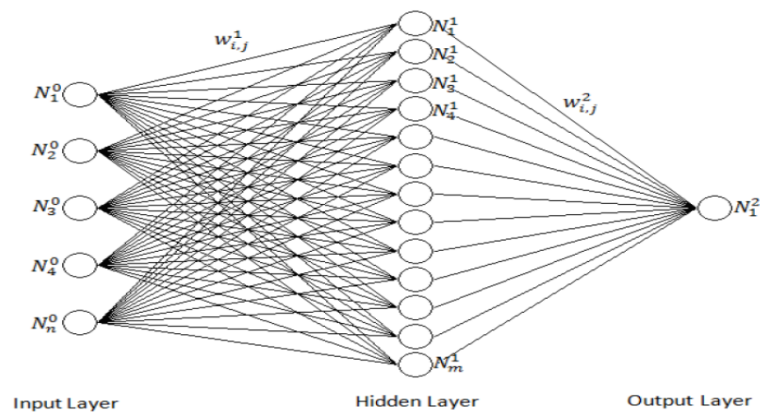
در لایه اول پارامترهای ورودی به مدل معرفی می‌شوند. این لایه دارای پارامترهایی است که موقعیت هر مجموعه فازی را کنترل می‌کند. خروجی لایه اول مقادیر پیشین توابع عضویت^۱ مطابق با ورودی سیستم فازی است (تابع عضویت منحنی است که به ازای هر نقطه در فضای ورودی یک مقدار عضویت بین ۰ و ۱ تعریف می‌نماید). گره‌ها در لایه دوم به محاسبه نتایج و میزان فعال‌سازی قوانین خاص نیاز دارند که توسط ورودی فازی تعیین می‌شود. در لایه سوم درجه فعالیت هریک از قانون‌های عضویت^۲ نرمال‌سازی می‌شود. در لایه چهارم گره‌ها چندمنظوره می‌شود و هر تابع یک مدل اولیه با پارامترهای مشتق شده ارائه می‌دهد و در نهایت لایه پنجم یا لایه خروجی خروجی‌های مدل را در اختیار می‌گذارد (کشاورزی و همکاران، ۲۰۱۷: ۱۷۷).

در مدل ANFIS روش خوشه‌بندی تفریقی^۳ فرض می‌شود که هر نقطه داده یک مرکز خوشه بالقوه است و احتمال اینکه هر نقطه داده بتواند مرکز خوشه را براساس چگالی نقاط اطراف خود تعریف کند محاسبه می‌شود. در این مطالعه از این روش برای خوشه‌بندی فازی داده‌ها بهره گرفته شده است (کشاورزی و همکاران، ۲۰۱۷: ۱۷۷).

شبکه عصبی پرسپترون چندلایه (MLP)^۴

این نوع شبکه یکی از مهم‌ترین انواع شبکه‌های عصبی مصنوعی است. این شبکه‌ها شامل مجموعه‌ای از واحدهای حسی یا نورون‌اند که متشکل از یک لایه ورودی، یک یا چند لایه پنهان، و یک لایه خروجی می‌باشند. سیگنال ورودی در خلال شبکه و در مسیری رو به جلو به صورت لایه به لایه منتشر می‌شود (هایکین، ۱۹۹۹). در این تحقیق برای مدل‌سازی تخمین تابش روزانه از این مدل، که به شبکه عصبی پیش‌خور^۵ نیز معروف است، استفاده شده است. شکل ۳ ساختار فیزیکی این مدل را نشان می‌دهد.

1. Membership Function
2. Rules
3. Subtractive Clustering
4. Multilayer Perceptron
5. Feed Forward Neural Network



شکل ۳. ساختار پایه شبکه عصبی MLP (دمیرکایا و بالسیلار، ۲۰۱۲: ۶)

الگوریتم لونبرگ-مارکواردت (LM)^۱

لونبرگ-مارکواردت الگوریتمی در راستای همگرایی سریع در آموزش شبکه‌های عصبی است. این الگوریتم یک روش استاندارد برای حل مسائل حداقل مربعات غیرخطی است و به‌عنوان ترکیبی از روش‌های نیوتن گوسی و حداکثر شیب نزولی بیان می‌شود. در این مطالعه به‌منظور دوره یادگیری و واسنجی شبکه عصبی MLP از این الگوریتم استفاده شده است که از سرعت همگرایی بهتری در مقایسه با سایر روش‌های استاندارد برخوردار است و نیازمند محاسبات و حافظه کمتری است (موسوی، ۲۰۰۷: ۳۸۵).

شبکه عصبی رگرسیون تعمیم‌یافته (GRNN)^۲

این نوع شبکه عصبی یکی از انواع شبکه‌های عصبی شعاعی پایه و تقریب‌زننده‌ای همه‌منظوره برای توابع هموار است. این مدل توانایی تقریب‌زدن هرگونه تابع هموار با داده‌های کافی را دارد. GRNN یک شبکه عصبی سه‌لایه است که در آن تعداد نورون‌های موجود در لایه اول و آخر (همانند سایر شبکه‌های عصبی) به‌ترتیب برابر با ابعاد بردارهای ورودی و خروجی است، اما برخلاف سایر شبکه‌ها، تعداد نورون‌های لایه پنهان مدل GRNN برابر با تعداد داده‌های مشاهداتی است. در این نوع شبکه عصبی از تابع کارایی نرمال در هریک از نورون‌های لایه پنهان استفاده می‌شود و داده ورودی به این تابع برای هر نورون عبارت است از: فاصله اقلیدسی میان داده ورودی و مشاهداتی مربوط به آن نورون، که این تابع به شکل رابطه ۲ است (عراقی‌نژاد، ۲۰۱۴).

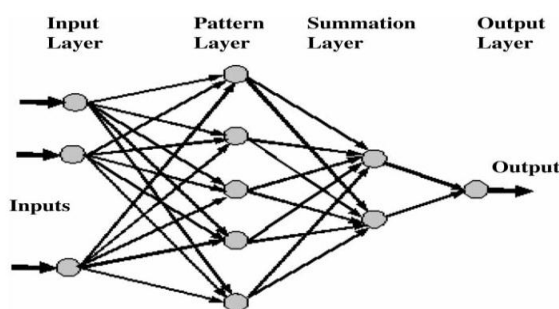
$$f(X_r, b) = e^{-I^2} \quad I = X_r - X_b \times 0.8326 / h \quad (2)$$

در این رابطه بردار ورودی به شبکه با خروجی نامشخص، X_b مقادیر ورودی مشاهداتی در زمان b ، و h پارامتر گستره شعاع است که با تغییر آن مقدار جمع و بازشدگی تابع تغییر خواهد کرد؛ به‌طوری‌که تابع بهترین برازش را بر روی داده‌ها پیدا کند. مقادیر خروجی این تابع در بازه صفر تا یک قرار دارد؛ به‌شکلی که هرچه قدر فاصله اقلیدسی دو بردار X_r و X_b به صفر نزدیک شود مقدار این تابع به یک نزدیک می‌شود و هرچه این فاصله بیشتر شود مقدار تابع به صفر نزدیک می‌شود. شبکه عصبی GRNN برای محاسبه خروجی از رابطه ۳ استفاده می‌کند (عراقی‌نژاد، ۲۰۱۴).

1. Levenberg-Marquardt
2. Generalized Regression Neural Network

$$Y_r = \frac{1}{\sum_{b=1}^n f(X_r, b)} \sum_{b=1}^n [f(X_r, b) \times T_b] \quad (3)$$

در این رابطه، T_b مقدار خروجی مشاهداتی متناظر با بردار ورودی b امین داده و n تعداد داده‌های مشاهداتی است. شکل ۴ ساختار شبکه عصبی GRNN را نشان می‌دهد.



شکل ۴. ساختار فیزیکی شبکه عصبی GRNN (هویچی و همکاران، ۲۰۱۳: ۱۵۱)

معیارهای صحت‌سنجی مدل‌ها

در این پژوهش، برای صحت‌سنجی مدل‌های ارائه‌شده و مقایسه مقادیر برآوردشده آن‌ها با مقادیر واقعی از دو معیار ریشه میانگین مربعات خطا (RMSE)^۱ و ضریب تبیین (R^۲) استفاده شده است (رابطه‌های ۴ و ۵).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - f_i)^2} \quad (4)$$

$$R^2 = \left[\frac{\sum_{i=1}^n (y_i - \bar{y})(f_i - \bar{f})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} * \sqrt{\sum_{i=1}^n (f_i - \bar{f})^2}} \right]^2 \quad (5)$$

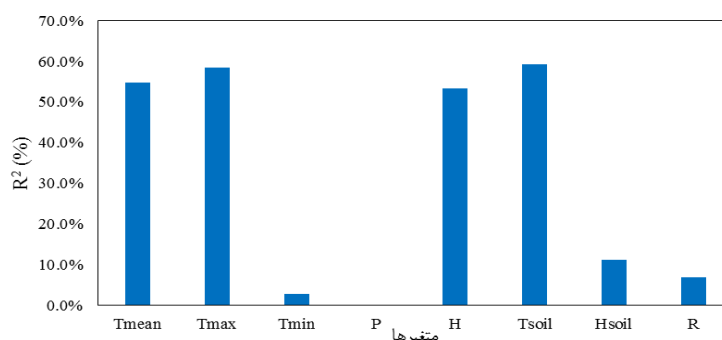
در رابطه‌های بالا y_i و \bar{y} به ترتیب داده‌های مشاهده‌ای و میانگین آن‌ها، f_i و \bar{f} داده‌های برآوردشده از مدل و میانگین آن‌ها، و n تعداد داده‌هاست. معیار RMSE هرچه قدر به صفر و R² به یک نزدیک‌تر باشند، به ترتیب دقت و همبستگی بالاتر خروجی‌های مدل را نشان می‌دهند.

در این مطالعه برای اجرای مدل‌های رگرسیونی از نرم‌افزار Minitab16 و برای مدل‌سازی مدل‌های هوش مصنوعی از کدنویسی در محیط نرم‌افزار MATLAB استفاده شده است.

یافته‌های تحقیق

در این پژوهش نخست ورودی‌ها از نظر میزان وابستگی با مقدار تابش روزانه ارزیابی شد و نتایج بر روی نمودار شکل ۵ به نمایش گذاشته شد.

1. Root Mean Square Error
2. Coefficient of Determination



شکل ۵. نمودار ستونی همبستگی‌های متغیرهای مستقل با GSR

در این نمودار، T_{mean} میانگین دمای هوا، T_{max} بیشینه دمای هوا، T_{min} کمینه دمای هوا، P فشار هوا، H رطوبت نسبی هوا، T_{soil} میانگین دمای خاک، H_{soil} رطوبت خاک، و R بارندگی در مقیاس روزانه است. همان‌گونه که مشخص است، بیشترین میزان همبستگی به ترتیب متعلق به متغیرهای دمای خاک، دمای بیشینه هوا، دمای میانگین هوا، و رطوبت نسبی هوا بوده است که به ترتیب دارای ضرایب تبیین ۵۹٫۳، ۵۸٫۴، ۵۴٫۸، و ۵۳٫۴ درصد با متغیر هدف بوده‌اند. این مسئله بیانگر این است که چنانچه در این منطقه در روزی تعداد متغیرهای ثبت شده کم باشد، با استفاده از این متغیرها می‌توان با دقت بهتری در مقایسه با سایر متغیرها مقدار تابش کل روزانه رسیده به زمین را تخمین زد. کمترین میزان همبستگی با تابش کل روزانه نیز متعلق به میانگین فشار هوای روزانه ایستگاه بوده است که مقدار ضریب تبیین آن برابر با ۰٫۲ درصد است. برای انتخاب متغیرهای بهینه، از ترکیب‌های دوتایی، سه‌تایی، و چهارتایی از این متغیرها به ۱۱ الگوی ماتریس‌های ورودی رسیده و با استفاده از آزمون همبستگی متغیرهای مستقل و وابسته نتیجه بر انتخاب ورودی‌های $P1 = \{H, T_{soil}\}$ و $P2 = \{T_{mean}, H, T_{soil}\}$ و $P3 = \{T_{mean}, H, T_{soil}\}$ به ترتیب از میان الگوهای ۲، ۳، و ۴ متغیره شد. بنا بر این یافته‌ها، به مدل‌سازی و برآورد میزان روزانه GSR با به کارگیری این سه الگوی ورودی با بهره‌گیری از مدل‌های مذکور اقدام شد. نسبت داده‌های آموزش و آزمون نیز برابر با ۷۵ درصد و ۲۵ درصد در نظر گرفته شده که به ترتیب برابر با متغیرهای ثبت شده در ۳۲۶ و ۱۰۹ روز است.

نخست از مدل خطی رگرسیون چندمتغیره استفاده شد که در دو حالت تصادفی و غیرتصادفی با یکدیگر مقایسه شدند (جدول ۱). نتایج ارزیابی مدل‌ها نشان داد که در همه ورودی‌ها مدل رگرسیون خطی چندمتغیره نمونه‌های تصادفی شده را با دقت بهتر و همبستگی بیشتری تخمین می‌زند. بالاترین خطا مربوط به نمونه‌های غیرتصادفی با ورودی‌های دمای میانگین خاک و رطوبت نسبی ($P1$) است که در دوره‌های آموزش، آزمون، و کل دوره به ترتیب دارای ریشه میانگین مربعات خطای $۵٫۰۳$ ، $۴٫۰۶$ ، و $۴٫۹۳$ $\frac{MJ}{m^2 \cdot day}$ و R^2 برابر با $۰٫۳۶$ ، $۰٫۱۸$ ، و $۰٫۶۴$ درصد بوده‌اند.

جدول ۱. مقایسه معیارهای ارزیابی مدل رگرسیون خطی چندمتغیره

ورودی		آموزش		آزمون		کل	
		(%) R^2	RMSE $(\frac{MJ}{m^2 \cdot day})$	(%) R^2	RMSE $(\frac{MJ}{m^2 \cdot day})$	(%) R^2	RMSE $(\frac{MJ}{m^2 \cdot day})$
تصادفی	P1	۶۶٫۵۰	۴٫۸۲	۵۸٫۹۰	۵٫۰۸	۶۴٫۳۰	۴٫۹۲
	P2	۶۸٫۳۰	۴٫۷۰	۵۹٫۵۰	۵٫۰۵	۶۵٫۷۰	۴٫۸۲
	P3	۶۸٫۸۰	۴٫۶۷	۵۹٫۹۰	۵٫۰۳	۶۶٫۳۰	۴٫۷۸
غیرتصادفی	P1	۶۰٫۳۰	۵٫۰۳	۱۸٫۳۰	۴٫۰۶	۶۴٫۲۰	۴٫۹۳
	P2	۶۰٫۸۰	۵٫۰۰	۲۷٫۳۰	۳٫۸۳	۶۵٫۶۰	۴٫۸۳
	P3	۶۱٫۳۰	۴٫۹۸	۲۹٫۳۰	۳٫۷۸	۶۶٫۲۰	۴٫۷۹

بیشترین دقت مربوط به مدل‌سازی با نمونه‌های تصادفی توسط هر چهار ورودی دمای بیشینه و میانگین هوا، دمای میانگین خاک، و رطوبت نسبی (گروه P3) است که به ترتیب در دوره‌های آموزش، آزمون، و کل دوره دارای ریشه میانگین مربعات خطای ۴٫۶۷، ۵٫۰۳، و ۴٫۷۸ $\frac{MJ}{m^2 \cdot day}$ و ضریب R^2 برابر با ۰٫۶۸، ۰٫۵۹، و ۰٫۶۳ درصد ارزیابی شدند. معادلات پیشنهادی مدل رگرسیونی با حداقل ورودی‌ها به شکل رابطه‌های ۶ الی ۸ است:

$$GSR = -0.39T_{Soil} - 0.14H + 19.67 \quad (6)$$

$$GSR = -0.52T_{mean} - 0.16H + 0.83T_{Soil} + 20.92 \quad (7)$$

$$GSR = 0.4 \cdot T_{max} - 0.83T_{mean} - 0.15H + 0.75T_{Soil} + 17.97 \quad (8)$$

جدول ۲. مقایسه معیارهای ارزیابی مدل ANFIS

ورودی	شعاع خوشه	آموزش		آزمون		کل		
		(%) R^2	RMSE $(\frac{MJ}{m^2 \cdot day})$	(%) R^2	RMSE $(\frac{MJ}{m^2 \cdot day})$	(%) R^2	RMSE $(\frac{MJ}{m^2 \cdot day})$	
تصادفی	P1	۰٫۲۱	۷۶٫۹۸	۳٫۹۸	۵۹٫۶۸	۵٫۳۵	۷۲٫۱۴	۴٫۳۷
	P2	۰٫۲۷	۸۰٫۸۳	۳٫۶۴	۶۴٫۵۸	۴٫۹۲	۷۶٫۶۰	۴٫۰۰
	P3	۰٫۳۶	۷۸٫۷۴	۳٫۸۳	۶۳٫۶۳	۴٫۹۳	۷۴٫۹۱	۴٫۱۳
غیرتصادفی	P1	۰٫۳۶	۶۵٫۵۵	۴٫۶۶	۱۵٫۵۷	۴٫۹۹	۶۷٫۰۶	۴٫۷۵
	P2	۰٫۴۸	۶۴٫۹۸	۴٫۷۰	۲۰٫۹۸	۴٫۷۷	۶۷٫۸۵	۴٫۷۲
	P3	۰٫۵۲	۶۶٫۱۳	۴٫۶۲	۲۲٫۰۱	۴٫۹۹	۶۸٫۱۵	۴٫۷۲

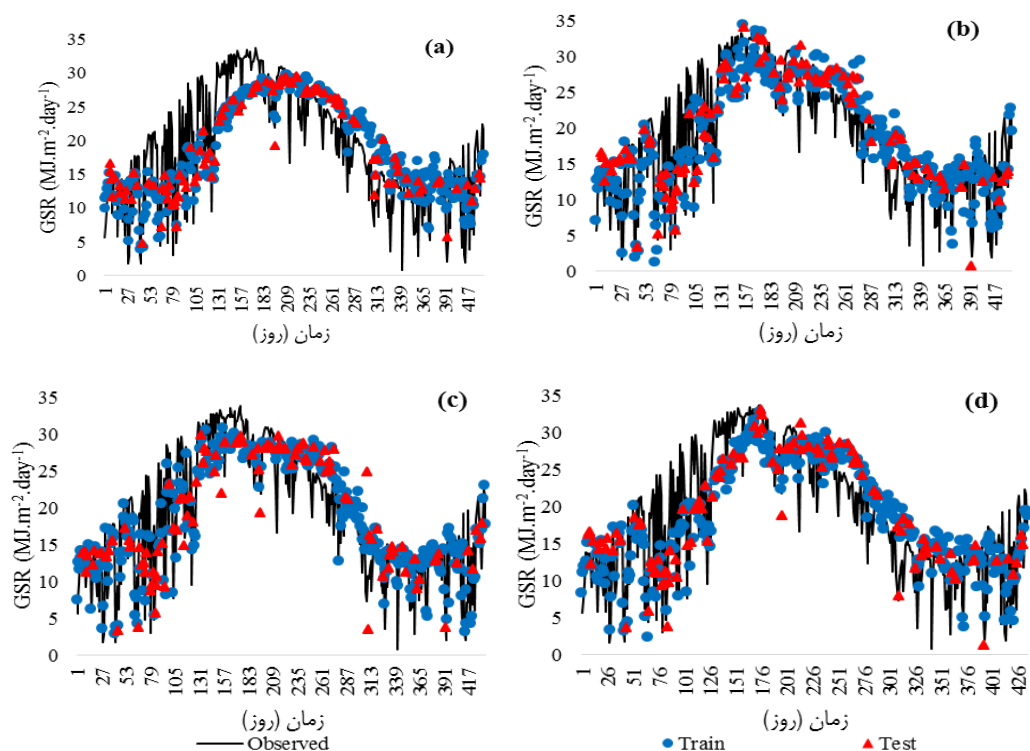
پس از رگرسیون، مدل‌سازی با شبیه‌سازهای هوش مصنوعی انجام شد. نخست مدل‌های برازش داده شده توسط مدل نروفازی ارزیابی شد (جدول ۲). نتیجه مشابه میان این مدل و رگرسیون خطی در این است که مدل‌سازی ANFIS نیز در نمونه‌های تصادفی شده دقت بهتری را از خود ارائه می‌دهد. وجه تمایز ANFIS با رگرسیون خطی چندمتغیره در بهترین ورودی بوده است که در این مدل بهترین ورودی‌ها دمای میانگین هوا، دمای میانگین خاک، و رطوبت نسبی هوا (گروه P2) بوده است. سرانجام، مدل ANFIS با نمونه‌های ورودی و هدف تصادفی شده و با استفاده از سه متغیر (گروه P2) و با شعاع خوشه ۰٫۲۷ توانست با ریشه میانگین مربعات خطای ۳٫۶۳، ۴٫۹۲، و ۳٫۹۹ $\frac{MJ}{m^2 \cdot day}$ و ضریب R^2 برابر با ۰٫۸۳، ۰٫۶۸، و ۰٫۶۳ درصد به ترتیب در دوره‌های آموزش، آزمون، و کل با متغیرهای ورودی کمتر عملکرد بهتر و خطای کمتری را نسبت به مدل رگرسیونی از خود نشان دهد.

جدول ۳. مقایسه معیارهای ارزیابی مدل GRNN

ورودی	گستره	آموزش		آزمون		کل		
		(%) R^2	RMSE $(\frac{MJ}{m^2 \cdot day})$	(%) R^2	RMSE $(\frac{MJ}{m^2 \cdot day})$	(%) R^2	RMSE $(\frac{MJ}{m^2 \cdot day})$	
تصادفی	P1	۱٫۵۷	۸۴٫۳۷	۳٫۳۰	۵۹٫۴۶	۵٫۳۶	۷۷٫۴۶	۳٫۹۰
	P2	۱٫۶۴	۸۹٫۶۹	۲٫۶۹	۶۳٫۰۴	۵٫۰۹	۸۲٫۵۲	۳٫۴۵
	P3	۲٫۳۳	۸۷٫۵۹	۲٫۹۵	۶۲٫۸۱	۵٫۰۸	۸۰٫۸۷	۳٫۶۱
غیرتصادفی	P1	۴٫۵۳	۶۴٫۵۳	۴٫۷۳	۲۸٫۸۷	۴٫۷۳	۶۸٫۰۹	۴٫۷۳
	P2	۵٫۴۵	۶۴٫۹۴	۴٫۷۱	۲۶٫۹۵	۴٫۷۷	۶۸٫۲۱	۴٫۷۲
	P3	۶٫۴۲	۶۴٫۹۱	۴٫۷۱	۲۴٫۹۲	۴٫۸۳	۶۸٫۰۲	۴٫۷۴

جدول ۴. مقایسه معیارهای ارزیابی مدل MLP

ورودی	تعداد نورون در لایه پنهان	تعداد نورون در لایه انتقال		آموزش		آزمون		کل		
		لایه اول	لایه دوم	R^2 (%)	RMSE ($\frac{MJ}{m^2 \cdot day}$)	R^2 (%)	RMSE ($\frac{MJ}{m^2 \cdot day}$)	R^2 (%)	RMSE ($\frac{MJ}{m^2 \cdot day}$)	
		اول	دوم							
تصادفی	P1	۱۵	-	Satlin	۷۴٫۷۱	۴٫۱۹	۵۹٫۱۲	۵٫۴۱	۷۰٫۴۳	۴٫۵۳
	P2	۱۸	۱۵	Tansig	۷۸٫۹۱	۳٫۸۳	۶۲٫۹۹	۵٫۰۴	۷۴٫۶۲	۴٫۱۷
	P3	۱۸	-	Tansig	۷۶٫۱۵	۴٫۰۶	۶۱٫۵۹	۵٫۱۱	۷۲٫۲۰	۴٫۳۵
غیرتصادفی	P1	۱۵	-	Tansig	۶۵٫۶۸	۴٫۶۵	۲۶٫۸۸	۴٫۷۱	۶۸٫۵۵	۴٫۶۷
	P2	۱۸	۱۲	Satlin	۶۷٫۱۹	۴٫۵۷	۲۱٫۶۴	۴٫۶۲	۶۹٫۰۵	۴٫۵۹
	P3	۱۸	۱۵	Satlin	۶۶٫۸۹	۴٫۵۸	۲۹٫۰۷	۴٫۶۸	۶۹٫۷۰	۶۰٫۴



شکل ۶. مقایسه خروجی مدل‌ها با مقادیر مشاهده‌ای GSR؛ رگرسیون خطی چندمتغیره (a)، ANFIS (b)، GRNN (c)، و MLP (d)

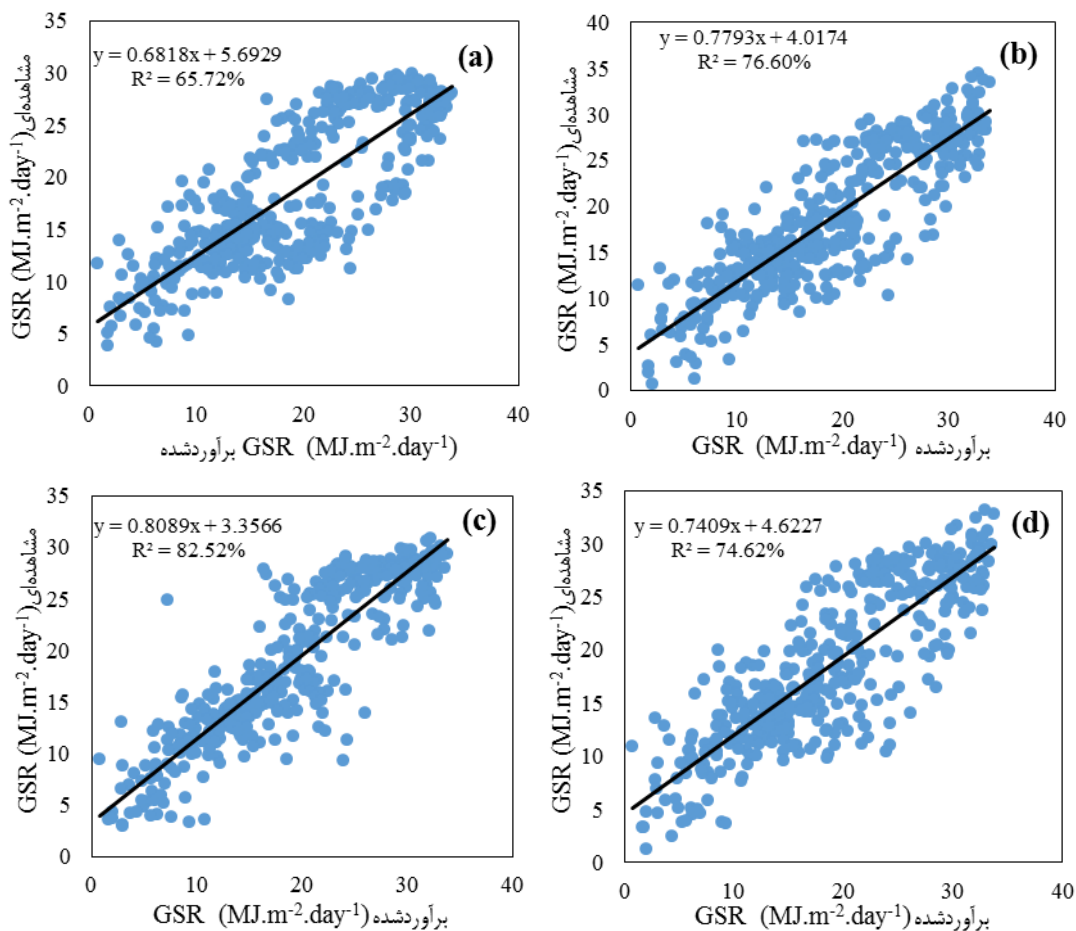
در ادامه از دو شبکه عصبی MLP و GRNN برای تخمین تابش کل روزانه استفاده شد. نتایج حاصل از مدل GRNN (جدول ۳) نیز نشان داد که در نمونه‌های تصادفی شده دقت مدل‌سازی بیشتر از نمونه‌های تصادفی نشده بوده و همچون مدل ANFIS ورودی P2 بهترین عملکرد را دارا بوده است. در آخر با گستره شعاع ۱٫۶۴ و نمونه‌های ورودی و هدف تصادفی‌شده، شبکه عصبی GRNN توانست با ریشه میانگین مربعات خطای ۲٫۶۹، ۵٫۰۸، و ۳٫۴۵ $\frac{MJ}{m^2 \cdot day}$ و ضریب R^2 برابر با ۸۹٫۶۹، ۳٫۰۴، و ۸۲٫۵۲ درصد به ترتیب در دوره‌های آموزش، آزمون، و کل با متغیرهای ورودی کمتر عملکرد دقیق‌تری را به نسبت مدل رگرسیون خطی و همین‌طور ANFIS ارائه کند.

در جدول ارزیابی مربوط به شبکه عصبی MLP (جدول ۴) نیز بهترین ورودی مشابه با سایر مدل‌های هوش مصنوعی بوده است (ورودی P2) که توسط معیارهای ارزیابی مذکور انتخاب شد. در این شبکه، توابع انتقال مختلف و همچنین تعداد لایه‌ها و نورون‌های مختلف و بهترین آرایش شبکه، بنا بر سعی و خطا، انتخاب شد. بررسی‌ها نشان داد که بهترین عملکردها متعلق به یک و دو لایه پنهان و همچنین تابع انتقال تانژانت سیگموئیدی (tansig) و تابع انتقال خطی اشباع (satlin) است و همانند سایر مدل‌ها نمونه‌های ورودی و هدف تصادفی خطای کمتری را در مدل‌سازی حاصل می‌نمایند. بهترین آرایش شبکه شامل دو لایه پنهان، ۱۸ نورون در لایه اول، و ۱۵ نورون در لایه دوم، و تابع انتقال تانژانت سیگموئیدی بوده است. ضرایب تبیین ۰/۷۸۹۱، ۰/۶۲۹۹ و ۰/۷۴۶۲ درصد و همچنین RMSE برابر با ۰/۳۸۳، ۰/۵۱۰۴ و ۰/۴۱۷ $\frac{MJ}{m^2.day}$ به ترتیب در روزهای منتخب برای آموزش، آزمون، و کل بیانگر دقت خوب این مدل برای برآورد میزان GSR بوده است. این مدل به نسبت مدل رگرسیونی دارای دقت بیشتری است و به نسبت مدل‌های ANFIS و GRNN از دقت کمتری برخوردار است.

بر اساس جدول‌های ارزیابی مدل‌ها، این نتیجه را می‌توان گرفت که اگر داده‌ها تصادفی نشوند، خطای آن‌ها در دوره تست کمتر می‌شود. دلیل بر آن است که طی این روزهای مشخص (۲۲ نوامبر ۲۰۱۷ تا ۱۰ مارس ۲۰۱۸) همبستگی روزانه متغیرهای مستقل با متغیر وابسته (GSR) به نسبت روزهای تصادفی شده بیشتر است. این امر نشان می‌دهد که در طی این روزهای سال متغیرهایی از جمله دمای خاک، دمای میانگین، بیشینه هوا، و رطوبت نسبی هوا، به نسبت سایر روزهای سال، تغییرات همگن‌تر و ملایم‌تری در راستای تغییرات روزانه GSR دارند. اما، در مجموع، دوره‌های آموزش و آزمون برای مدل‌سازی روزهای تصادفی شده با خطای کمتر می‌توانند عملکرد مطلوب‌تری به نسبت روزهای مرتب‌شده برحسب زمان از خود ارائه دهند.

در شکل ۶ بخش a، که مربوط به خروجی‌های رگرسیون خطی چندمتغیره و مقادیر مشاهده‌ای تابش است، مشخص است که خروجی‌های این مدل در ابتدا به مقادیر واقعی نزدیک است، اما با گذشت زمان و رسیدن به روزهایی که تابش در حال افزایش است (اواخر فوریه تا اواخر جولای ۲۰۱۷) رفته‌رفته از مقادیر واقعی فاصله می‌گیرد و کم‌برآورد می‌شود و همین‌طور طی ماههایی که تابش خورشیدی در حال کاهش است (اواخر آگوست تا اواسط دسامبر ۲۰۱۷) در تخمین مقادیر آن بیش‌برآورد بوده است. در واقع، مقادیر GSR را با تأخیر برآورد می‌نماید و با رسیدن به ماه‌های ژانویه و فوریه ۲۰۱۸ دوباره به خطای حداقل خود بازمی‌گردد. این بیش‌برآوردی‌ها و کم‌برآوردی‌ها در سه مدل هوش مصنوعی (شکل ۶ بخش‌های b و c و d) به حداقل مقادیر خود می‌رسد و کمترین فاصله‌ها از مقادیر واقعی در مدل GRNN و سپس ANFIS مشاهده می‌شود. شبکه عصبی MLP نیز تا حدودی در برآورد مقادیر GSR طی دوره‌ای که طول روز در حال افزایش است کم‌برآورد عمل کرده است، اما بیش‌برآوردی MLP در دوره‌ای که طول روز در حال کاهش است به اندازه خروجی‌های مدل رگرسیونی قابل ملاحظه نیست. کم‌برآوردی مدل طی روزهای اواخر فوریه تا اواخر جولای ۲۰۱۷ در دو مدل ANFIS و GRNN بسیار کمتر از دو مدل دیگر است و به‌ویژه در مدل GRNN به حداقل میزان خطای خود می‌رسد. همچنین، بیش‌برآوردی این دو مدل در روزهای اواخر آگوست تا اواسط دسامبر ۲۰۱۷ بسیار ضعیف است و دقت هر دو مدل به‌ویژه GRNN خوب ارزیابی می‌شود. قابل ذکر است که کاهش‌های چشم‌گیر رخ داده در ثبت مجموع تابش روزانه تا حدود بسیار زیادی وابسته به ابرناکی و ساعت آفتابی است و، به‌رغم موجود نبودن این داده‌ها، می‌توان ملاحظه کرد که مدل‌ها تا حدود زیادی توانسته‌اند در چنین روزهایی مقادیر GSR را حتی بدون در دست داشتن این دو پارامتر با دقت بسیار خوبی تخمین بزنند.

خروجی‌های هر چهار مدل در شکل ۷ با مقادیر واقعی در نمودار همبستگی به‌نمایش گذاشته شده‌اند. با استناد به فاصله مقادیر برآوردی از خط رگرسیونی و همچنین میزان ضریب R^2 ، که مربوط به کل دوره است، نیز می‌توان مشاهده کرد مقادیر برآوردی هر سه مدل از مدل‌های هوش مصنوعی به نسبت مدل رگرسیونی دارای همبستگی بالاتری با مقادیر مشاهده‌ای بوده‌اند. ناکام‌بودن رگرسیون خطی چندمتغیره در این مدل‌سازی نشان‌دهنده وجود همبستگی غیرخطی میان متغیرهای هواشناسی روزانه مورد استفاده با مقدار تابش کل روزانه رسیده به زمین است. همبستگی خروجی‌ها با مقادیر مشاهده‌ای از بیشترین به کمترین متعلق به مدل‌های GRNN، ANFIS، MLP، و رگرسیون خطی چندمتغیره بوده است که به ترتیب مقادیر R^2 برابر با ۸۲/۵۲، ۷۶/۶۰، ۷۴/۶۲، و ۶۵/۷۲ درصد را شامل می‌شوند.



شکل ۷. مقایسه همبستگی خروجی مدل‌ها با مقادیر مشاهده‌ای GSR: رگرسیون خطی چندمتغیره (a)، ANFIS (b)، GRNN (c)، و MLP (d)

در بخش دیگر از این مطالعه، مدل بین همه ورودی‌های در اختیار (۸ متغیر) با مقادیر GSR ارائه شده است که در ادامه به ارزیابی نتایج آن پرداخته می‌شود.

در ارزیابی مدل‌های اجرا شده با کل ورودی‌ها (جدول ۵) نتایج حاصله گواه بالارفتن دقت مدل‌هاست. دقت کل در مدل رگرسیونی حدود ۰/۷، ANFIS ۰/۸، GRNN ۰/۰۵، و MLP ۱/۱ $\frac{MJ}{m^2.day}$ بهبود یافته است. همانند مدل‌سازی با ورودی‌های کمتر، با این ورودی‌ها نیز نمونه‌های ورودی و هدف تصادفی شده بهتر از نمونه‌های مرتب‌شده بر حسب زمان

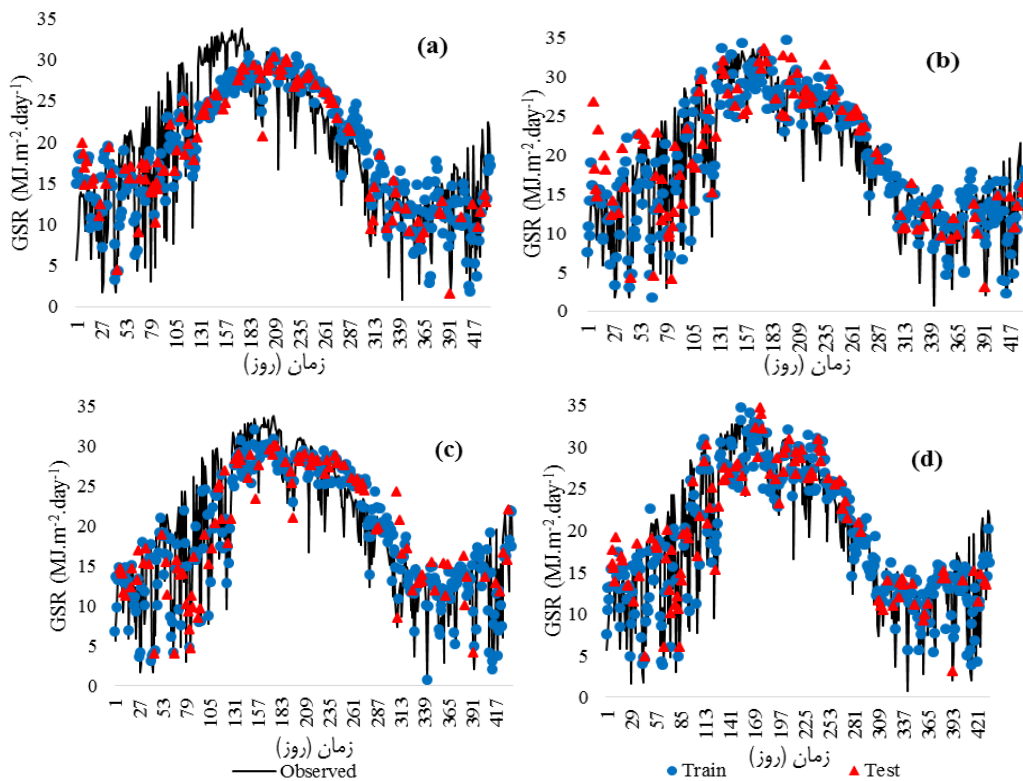
مدل‌سازی شده‌اند. البته، با نمونه‌های مرتب برحسب زمان نیز ورودی‌های جدید (کل ورودی‌ها) عملکرد بهتری ارائه می‌نمایند. این مسئله بیانگر این است که، به‌رغم همبستگی خطی پایین برخی متغیرهای مستقل با متغیر GSR به‌صورت تکی، استفاده توأم از همین متغیرها در مدل‌سازی موجب ایجاد همبستگی بیشتر میان آنها با تابش کل رسیده به زمین می‌شود و اثرهای مثبت قابل ملاحظه‌ای را در مدل‌سازی‌های رگرسیونی و همچنین هوش مصنوعی نمایان می‌کند. معادله برآورد تابش کل با استفاده از این ورودی‌ها طبق رابطه ۹ است:

جدول ۵. مقایسه آماری نتایج مدل‌ها با در نظر گرفتن همه ورودی‌ها

ورودی	مدل	آموزش		آزمون		کل	
		(%)R ²	RMSE ($\frac{MJ}{m^2 \cdot day}$)	(%)R ²	RMSE ($\frac{MJ}{m^2 \cdot day}$)	(%)R ²	RMSE ($\frac{MJ}{m^2 \cdot day}$)
تصادفی	MR	۷۵٫۹۰	۴٫۰۸	۷۲٫۷۰	۴٫۱۴	۷۵٫۲۰	۴٫۱۱
	ANFIS	۸۸٫۳۵	۲٫۸۳	۷۳٫۳۰	۴٫۳۰	۸۴٫۴۳	۳٫۲۶
	GRNN	۹۱٫۳۹	۲٫۴۷	۵۸٫۴۲	۵٫۳۱	۸۲٫۸۶	۳٫۴۱
	MLP	۸۸٫۳۲	۲٫۸۵	۷۹٫۸۴	۳٫۵۶	۸۶٫۳۳	۳٫۰۴
غیرتصادفی	MR	۷۲٫۴۰	۴٫۱۹	۴۷٫۳	۳٫۲۶	۷۴٫۶۰	۴٫۱۵
	ANFIS	۸۲٫۲۸	۳٫۳۴	۴۴٫۲۰	۳٫۵۳	۸۳٫۱۶	۳٫۳۶
	GRNN	۷۷٫۶۰	۳٫۷۹	۲۰٫۶۵	۵٫۰۷	۷۶٫۰۴	۴٫۱۵
	MLP	۸۴٫۸۲	۳٫۱۰	۴۱٫۰۹	۳٫۹۹	۸۴٫۰۹	۳٫۳۴

$$GSR = -1.24T_{mean} + 0.59T_{max} + 0.07T_{min} - 0.08P - 0.21H + 0.97T_{Soil} + 59.28H_{Soil} - 0.15R + 82.02 \quad (9)$$

نکته بسیار متفاوت در تخمین تابش با این ورودی‌ها، در نتایج ارزیابی مدل‌های هوش مصنوعی بوده، که ترتیب آنها در دقت برعکس شده است. به عبارتی، به ترتیب دقت، مدل‌های MLP، ANFIS، GRNN، و رگرسیون خطی چندمتغیره قرار دارند با میزان RMSE کل برابر با ۳٫۰۴، ۳٫۲۶، ۳٫۴۱ و ۴٫۱۱ $\frac{MJ}{m^2 \cdot day}$ و همچنین ضریب R² برابر با ۸۶٫۳۳، ۸۴٫۴۳، ۸۲٫۸۶ و ۷۵٫۲۴ درصد. همان‌گونه که مشخص است، به نسبت مدل‌سازی با ورودی‌های قبلی، در این ترتیب جای دو مدل MLP و GRNN با یکدیگر تغییر کرده است. دلیل این مسئله را می‌توان در دو امر خلاصه کرد: شبکه عصبی MLP به نسبت GRNN پارامترهای زیادتری را برای بهینه‌سازی مدل در اختیار دارد؛ از جمله توابع انتقال، تعداد لایه‌های پنهان، و تعداد نورون‌ها در هر لایه؛ حال آنکه مدل GRNN فقط از یک پارامتر (گستره شعاع) برای این امر استفاده می‌کند و همچنین GRNN با هر تنظیم گستره شعاع یک جواب مشخص می‌دهد، اما MLP در هر تنظیم آرایش و با هر بار آموزش شبکه جوابی متفاوت می‌دهد و خروجی‌های مدل را به نسبت دفعات ماقبل بهینه می‌گرداند. این مسئله باعث می‌شود تا در استفاده از ورودی‌های بیشتر، قدرت مانور بیشتری برای تخمین دقیق‌تر متغیر وابسته توسط شبکه عصبی MLP وجود داشته باشد. در آخر مدل MLP توانست با داده‌های تصادفی شده دو لایه پنهان و ۱۸ و ۱۲ نورون به ترتیب در لایه‌های پنهان اول و دوم و تابع انتقال خطی اشباع (satlin) دقت بسیار خوبی را نسبت به سایر مدل‌ها از خود به‌نمایش گذارد. نمودار خروجی‌های این چهار مدل با ورودی‌های جدید در شکل ۸ نشان داده شده است.

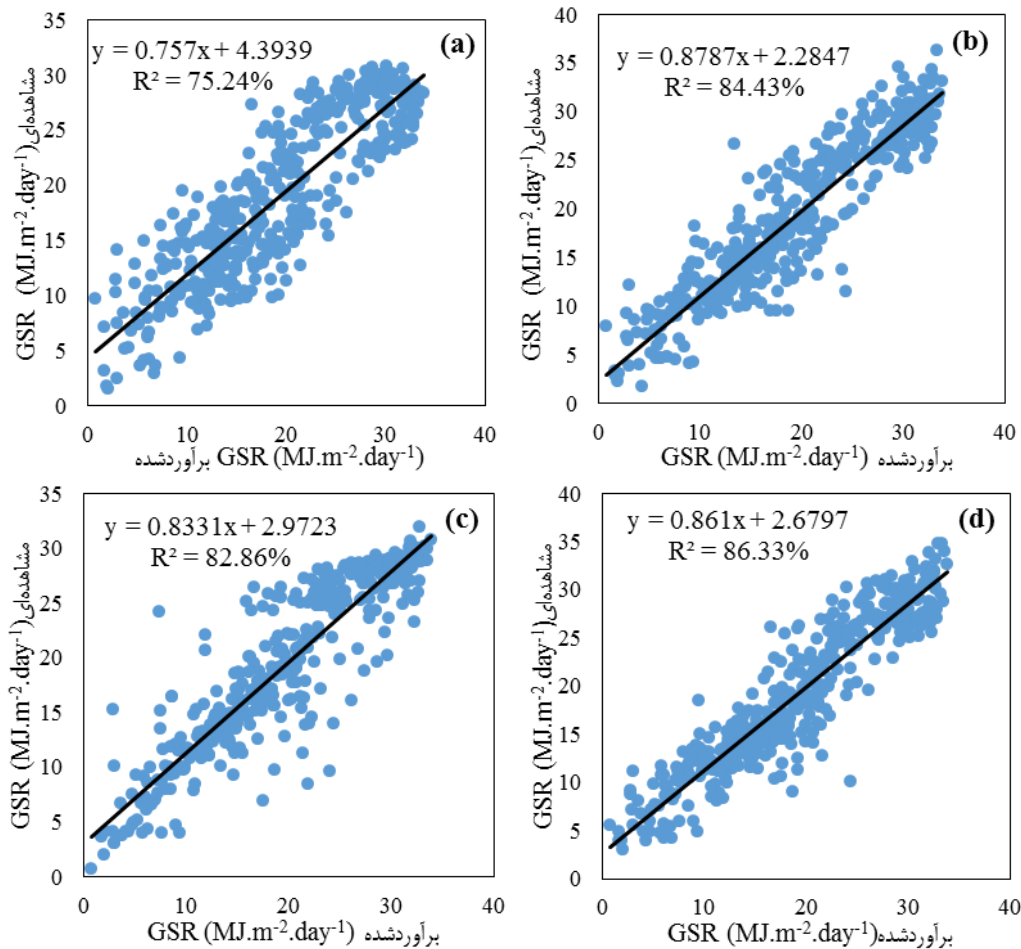


شکل ۸. مقایسه خروجی مدل‌ها با مقادیر مشاهده‌ای GSR با لحاظ نمودن همهٔ و روی‌ها: رگرسیون خطی چندمتغیره (a)، ANFIS (b)، GRNN (c)، و MLP (d)

همان‌گونه که در شکل ۸ مشخص است، خروجی‌های رگرسیون چندمتغیره به مقادیر واقعی نزدیک‌تر شده و همچنین از کم‌برآوردی‌ها و بیش‌برآوردی‌های آن به‌ترتیب در طی دوره‌های افزایش و کاهش طول روز کاسته شده است. مدل ANFIS نیز در برآورد تابش طی روزهایی از ژانویه و فوریه و همین‌طور چند روز از روزهای اوج تابش (حدود ۵ روز در طول ژوئن تا جولای) قدری بیش‌برآورد بوده است. اما در سایر روزهای این دوره بسیار خوب عمل کرده و خروجی‌های آن همپوشانی بسیار خوبی با مقادیر اندازه‌گیری‌شده داشته است. مدل GRNN در تعدادی از روزهایی که طول روز در حال افزایش بوده و همین‌طور در روزهای محدودهٔ انقلاب تابستانی (مارس تا اواخر ژوئن) قدری کم‌برآوردی داشته و در چند روز از روزهایی که طول روز در حال کاهش است مقداری بیش‌برآوردی داشته است. اما این مدل به‌ویژه در روزهایی که طول روز متوسط بوده، توانسته بیشتر کاهش‌های شدید و ناگهانی تابش رسیده به زمین را، که به‌موجب ابرناکی شدید کم شده‌اند، با دقتی بسیار عالی تخمین بزند.

اوج این کار در روز ۷ دسامبر ۲۰۱۷ است که حداقل تابش روزانه در کل دورهٔ مورد مطالعه است و مدل GRNN توانسته میزان GSR در این روز را با دقتی بسیار عالی و دقیق‌تر از همهٔ مدل‌ها برآورد کند. شبکهٔ عصبی MLP، همان‌طور که مشهود است، به غیر از چند روز معدودی که اندکی بیش‌برآوردی داشته، توانسته است با متغیرهای جدید مقادیر GSR را با خطایی بسیار کم تخمین بزند و همپوشانی قابل ملاحظه‌ای با مقادیر مشاهده‌ای تابش در بیشتر روزها ایجاد کند که عملکرد آن در مقایسه با همهٔ مدل‌ها بسیار دقیق‌تر ارزیابی می‌شود. مقایسهٔ نمودارهای همبستگی مدل‌ها با ورودی جدید (شکل ۹) و ورودی‌های قبلی (شکل ۷) نیز گواهی دیگر بر عملکرد قوی‌تر کل ورودی‌ها به نسبت

ورودی‌های کمتر است. خروجی‌های مدل‌ها به خط رگرسیونی نزدیک‌تر است و با مقادیر ضریب R^2 بالاتر نشان‌دهنده همبستگی قوی‌تر این خروجی‌ها با مقادیر مشاهده‌ای تابش در همه مدل‌ها به‌خصوص شبکه عصبی ANFIS و MLP در کل دوره است. عملکرد مدل‌ها با در نظر گرفتن میزان R^2 بزرگ‌تر از ۷۵ درصد بسیار خوب ارزیابی می‌شود.



شکل ۹. نمودار همبستگی خروجی‌های مدل‌ها با مقادیر مشاهده‌ای GSR؛ رگرسیون خطی چندمتغیره (a)، ANFIS (b)، GRNN (c)، و MLP (d)

نتیجه‌گیری

دیدبانی دقیق مقدار ابرناکی و ساعات آفتابی یکی از چالش‌های برآورد تابش کل خورشیدی با پارامترهای مذکور در ایران است. نتایج تحقیق حاضر نشان داد که، به‌رغم در دست نداشتن دو متغیر ابرناکی و ساعات آفتابی، که دو متغیر بسیار مؤثر در تابش رسیده به زمین‌اند، مدل‌های هوش مصنوعی نظیر ANFIS، GRNN، و MLP در اقلیم نیمه‌خشک فراسرد همدان عملکرد مطلوبی در برآورد تابش کل خورشیدی روزانه ارائه می‌کنند. در صورت در دست داشتن متغیرهای کمتر، می‌توان به‌وسیله مدل GRNN و سه متغیر میانگین دمای هوا، میانگین دمای خاک، و رطوبت نسبی هوا مقدار تابش کل را برآورد کرد. در صورت داشتن همه متغیرهای مورد استفاده در این پژوهش، از خطای همه مدل‌ها به نسبت کاسته می‌شود و به‌ترتیب دقت، مدل‌های MLP، ANFIS، و GRNN عملکرد مطلوبی به‌نمایش می‌گذارند. با توجه به

معیارهای RMSE و R^2 ، مدل رگرسیونی در مقایسه با مدل‌های هوش مصنوعی عملکرد نسبتاً ضعیفی دارد و فقط در یافتن ورودی‌های مناسب می‌توان از آن استفاده کرد.

در مطالعات که‌خا مقدم و چاری (۱۳۹۵) و بیات و میرلطیفی (۱۳۸۸) نیز عملکرد مدل‌های هوش مصنوعی به نسبت مدل‌های رگرسیونی مطلوب‌تر ارزیابی شده است. از جهت نتایج مدل MLP، تحقیق جاری همسو با پژوهش‌های وکیلی و همکاران (۲۰۱۵) بر روی اقلیم خشک سرد تهران، گوئرمویی و همکاران (۲۰۱۶)، و بنکاسیالی و همکاران (۲۰۱۶) در اقلیم مشابه نیمه‌خشک در جنوب الجزایر و به‌رنگ و همکاران (۲۰۱۰) در اقلیم نیمه‌خشک گرم دزفول است که از نظر کلاس رطوبتی در منطقه مشابه با همدان قرار دارد (رحیمی و همکاران، ۲۰۱۳). همچنین، سبزی‌پرور و علیایی (۱۳۹۰) در اقلیم نیمه‌خشک سرد تبریز با استفاده از مدل MLP به RMSE حدود با ۳/۳ ژول بر سانتی‌متر مربع در روز دست یافتند که نشان می‌دهد یافته‌های تحقیق حاضر مدل‌های پیشنهادی دقیق‌تری ارائه می‌کند. نتایج مدل ANFIS در این مطالعه با نتایج کاسم و همکاران (۲۰۱۶) بر روی تابش ساعتی در اسکندریه واقع در شمال غربی مصر، کویج و همکاران (۲۰۱۷) بر روی تابش روزانه در اقلیم نیمه‌مرطوب گرم شبه‌جزیره یوتاکان در مکزیک، و سبزی‌پرور و بیات ورکشی (۱۳۸۹)، که براساس طبقه‌بندی اقلیمی دمارتن گسترش یافته (رحیمی و همکاران، ۲۰۱۳)، در کلاس‌های رطوبتی نیمه‌خشک (ارومیه و شیراز)، خشک (کرمان)، و فراخشک (اصفهان) ایران انجام شد، از نظر عملکرد هم‌جهت بوده است. طبق جست‌وجوهای انجام‌گرفته، از مدل GRNN فقط در یک مطالعه برای تخمین GSR استفاده شده است. لطفی‌نژاد و همکاران (۲۰۱۸) از مدل GRNN برای تخمین تابش روزانه در تهران استفاده کردند که واقع در اقلیم خشک سرد است. طبقه‌بندی اقلیمی همدان متفاوت با تهران است. بنابراین، تخمین تابش کل خورشیدی به‌وسیله مدل GRNN در اقلیم نیمه‌خشک فراسرد برای اولین بار در تحقیق حاضر انجام شد. این پژوهشگران (لطفی‌نژاد و همکاران، ۲۰۱۸) نتایج حاصل از GRNN را با ANFIS مقایسه کردند و دقت مدل ANFIS را برتر دانستند که در بخش مدل‌سازی با استفاده از کل ورودی‌ها در پژوهش حاضر نتایج مشابه بوده است. مقایسه مدل‌های ANFIS و MLP در این تحقیق با بهره‌گیری از کل متغیرها به‌عنوان ورودی همسو با نتایج تحقیقات کویج و همکاران (۲۰۱۷) است که مدل MLP را دقیق‌تر معرفی کرده‌اند. اما در مطالعه هوشنگی و آل‌شیخ (۱۳۹۳)، که بر روی ۶۳ ایستگاه در کل کشور انجام گرفت، دقت ANFIS برای تخمین GSR بهتر از MLP ارزیابی شد. حاصل تحقیق ایشان مخالف با نتایج تحقیق جاری است که علت آن ممکن است تأثیرات نوع اقلیم در نتایج مدل‌ها باشد.

برطبق مطالعات انجام‌شده تا کنون، مقایسه این سه مدل هوش مصنوعی و بدون استفاده از داده‌های ساعات آفتابی و مقدار ابرناکی برای تخمین تابش کل روزانه در تحقیقی مشاهده نشده است. این نکته شایان ذکر است که در تحقیقات فوق‌الذکر حداقل از یکی از متغیرهای ساعت آفتابی یا ابرناکی استفاده شده است؛ حال آنکه این پارامترها در پژوهش حاضر مورد استفاده قرار نگرفت. پیشنهاد می‌شود در یکی از ایستگاه‌هایی با اقلیم مشابه مدل‌سازی هوش مصنوعی با استفاده از این متغیرها نیز انجام گیرد تا تأثیر به‌کارگیری متغیرهای ساعت آفتابی یا مقدار ابرناکی با نتایج این پژوهش مقایسه شود. شبیه‌سازی مقدار تابش GSR با روش حاضر در دیگر اقلیم‌ها نیز برای ادامه کار ارزش تحقیقاتی دارد.

منابع

- امامی‌فر، س. و علیزاده، ا. (۱۳۹۳). برآورد میزان تابش خورشیدی با استفاده از محصولات دمای سطح زمین سنجنده MODIS مدل شبکه عصبی، آب و خاک (علوم و صنایع کشاورزی)، ۳۷(۳): ۶۱۷-۶۲۵.
- بیات، ک. و میرلطیفی، س.م. (۱۳۸۸). تخمین تابش کل خورشیدی روزانه با استفاده از مدل‌های رگرسیونی و شبکه‌های عصبی مصنوعی، علوم کشاورزی و منابع طبیعی، ۱۶(۳): ۲۷۰-۲۸۰.
- پیری، ج.؛ انصاری، ح. و فرید حسینی، ع. (۱۳۹۲). مدل‌سازی تابش خورشید رسیده به زمین با استفاده از ANFIS و مدل‌های تجربی (مطالعه موردی: ایستگاه‌های زاهدان و بجنورد)، انرژی ایران، ۱۶(۳): ۳۷-۵۸.
- سبزی‌پرور، ع.ا. و علیایی، ا. (۱۳۹۰). ارزیابی عملکرد شبکه عصبی مصنوعی در پیش‌بینی تابش خورشیدی کل روزانه و مقایسه آن با نتایج مدل آنگستروم (مطالعه موردی: ایستگاه همدیدی تبریز)، ژئوفیزیک ایران، ۵(۳): ۳۰-۴۱.
- سبزی‌پرور، ع.ا. و بیات ورکشی، م. (۱۳۸۹). ارزیابی دقت روش‌های شبکه عصبی مصنوعی و عصبی-فازی در شبیه‌سازی تابش کل خورشیدی، پژوهش فیزیک ایران، ۱۰(۴): ۳۴۷-۳۵۷.
- سبزی‌پرور، ع.ا. و ختار، ب. (۱۳۹۴). ارزیابی شبکه عصبی مصنوعی و مدل تجربی ایرماک در تخمین تابش خالص خورشیدی روزانه در اقلیم سرد و نیمه‌خشک (مطالعه موردی: همدان)، دانش آب و خاک، ۲۵(۲): ۳۷-۵۰.
- سبزی‌پرور، ع.ا. و ختار، ب. (۱۳۹۵). اعتبارسنجی مدل‌های تجربی و نیمه‌تجربی برآورد تابش خالص روزانه با استفاده از مقادیر اندازه‌گیری‌شده در اقلیم سرد و نیمه‌خشک، آب و خاک (علوم و صنایع کشاورزی)، ۳۰(۶): ۲۰۸۷-۲۱۰۰.
- سیّدیان، س.م.؛ فراستی، م.؛ روحانی، ح. و حشمت‌پور، ع. (۱۳۹۶). تخمین تابش خورشیدی با استفاده از پارامترهای هواشناسی، تحقیقات منابع آب ایران، ۱۳(۱): ۸۸-۱۰۰.
- قبایی سوق، م.؛ مساعدی، ا. و دهقانی، ا.ا. (۱۳۹۰). مدل‌سازی هوشمند تابش خورشیدی با استفاده از آزمون گاما و مقایسه با معادلات تجربی واسنجی‌شده در کرمانشاه، پژوهش‌های حفاظت آب و خاک، ۱۰(۴): ۱۸۵-۲۰۸.
- کهنخا مقدم، پ. و چاری، م.م. (۱۳۹۵). مقایسه مدل‌های تجربی، رگرسیونی، و شبکه عصبی مصنوعی در برآورد تابش خالص دریافتی (R_s) در ایستگاه سینوپتیک زاهدان، جغرافیای طبیعی، ۹(۳۴): ۱۳۷-۱۵۰.
- واتقیان، ی. (۱۳۹۵). تخمین تابش کلی خورشید در استان کرمانشاه با استفاده از شبکه‌های عصبی مصنوعی، انرژی ایران، ۱۹(۱): ۴۴-۱۵.
- هوشنگی، ن. و آل‌شیخ، ع.ا. (۱۳۹۳). ارزیابی روش‌های فازی، عصبی، و فازی-عصبی در تخمین تابش خورشیدی کشور، علوم و فنون نقشه‌برداری، ۴(۳): ۱۸۷-۲۰۰.
- Abdallah, Y.A.G. (1994). New correlation of global solar radiation with meteorological parameters for Bahrain, *Solar Energy*, 16: 111-120.
- Akinoglu, B.G. and Ecevit, A.A. (1990). Further comparison and discussion of sunshine based models to estimate global solar radiation, *Energy*, 15: 865-72.
- Araghinejad, S. (2014). *Data-Deriven Modeling: Using MATLAB in Water Resources and Environmental Engineering*, New York, Springer.
- Bayat, K.; Mirlatifi, S.M. (2009). Estimating global solar radiation using regression and artificial neural network models, *Agricultural and Natural Resources Science*, 16(3): 270-280.

- Behrang, M.A.; Assareh, E.; Ghanbarzadeh, A. and Noghrehabadi, A.R. (2010). The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data, *Solar Energy*, 84(8): 1468-1480.
- Benkaciali, S.; Haddadi, M.; Khellaf, A.; Gairra, K. and Guermoui, A. (2016). Evaluation of the global solar irradiation from the artificial neural network technique, *Revue des Energies Renouvelables*, 19(4): 617-631.
- Bosch, J.L.; Lopez, G. and Batlles, F.J. (2008). Daily solar irradiation estimation over a mountainous area using artificial neural networks, *Renewable Energy*, 33: 1622-1628.
- Bristow, K.L., Campbell, G.S., (1984). On the relationship between incoming solar radiation and daily maximum and minimum temperature, *Agric. Forest Meteorol*, Vol. 31, PP. 159-166.
- Chen, R.S.; Ersi, K.; Yang, J.P.; Lu, S.H. and Zhao, W.Z. (2004). Validation of five global radiation models with measured daily data in China, *Energy Convers. Manage*, 45: 1759-1769.
- Demirkaya, S. and Balcilar, M. (2012). The contribution of soft computing techniques for the interpretation of dam deformation, In *FIG Working Week 2012 - Knowing to manage the territory, protect the environment, evaluate the cultural heritage*, 6-10 May, Rome, Italy.
- Elagib, N. and Mansell, M.G. (2000). New approaches for estimating global solar radiation across Sudan, *Energy Convers Manage*, 41: 419-34.
- Emamifar, S. and Alizadeh, A. (2014). Estimation of Solar Radiation Using Land Surface Temperature MODIS Sensor Data and Neural Network Model, *Journal of Water and Soil*, 28(3): 617-625.
- Fan, J.; Wang, X.; Wu, L.; Zhou, H.; Zhang, F.; Yu, X.; Lu, X. and Xiang, Y. (2018). Comparison of Support Vector Machine and Extreme Gradient Boosting for predicting daily global solar radiation using temperature and precipitation in humid subtropical climates: A case study in China, *Energy conversion and management*, 164: 102-111.
- Ghabaei-Sough, M.; Mosaedi, A. and Dehghani, A.A. (2011). Solar radiation data and their intelligent modeling based on gamma test with evaluation of calibrated empirical equations, *Journal of Water and Soil Conservation*, 18(4): 185-208.
- Guermoui, M.; Rahebi, A.; Benkaciali, S. and Dejelloul, D. (2016). Daily global solar radiation modelling using multi-layer perceptron neural networks in semi-arid region, *Leonardo Electronic Journal of Practices and Technologies*, 15(28): 35-46.
- Guermoui, M.; Rahebi, A.; Gairra, K. and Benkaciali, S. (2018). Support vector regression methodology for estimating global solar radiation in Algeria, *The European Physical Journal Plus*, 133(1): 22.
- Halabi, L.M.; Mekhilef, S. and Hossain, M. (2018). Performance evaluation of hybrid adaptive neuro-fuzzy inference system models for predicting monthly global solar radiation, *Applied energy*, 213: 247-261.
- Haykin, S. (1999). *Neural Networks: a comprehensive foundation*, MacMillan, New York.
- Hooshangi, N. and Alesheikh, A.A. (2015). Evaluation of ANN, ANFIS and fuzzy systems in estimation of solar radiation in Iran, *Journal of Geomatics Science and Technology*, 4(3): 187-200.
- Houichi, L.; Dechemi, N.; Heddami, S. and Achour, B. (2013). An evaluation of ANN methods for estimating the lengths of hydraulic jumps in U-shaped channel, *Journal of Hydroinformatics*, 15(1): 147-154.
- Kakhkh-Moghaddam, P. and Chari, M.M. (2017). Comparing empirical, regression and artificial neural network models, in estimating received net radiation of Zahedan synoptic station, *Natural Geography*, 9(34): 137-150.

- Kassem, A.S.; Aboukarima, A.M.; El Ashmawy, N.M. and Zayed, M.F. (2016). Comparison of Empirical Models and an Adaptive Neuro Fuzzy Inference System for Estimating Hourly Total Solar Radiation on Horizontal Surface at Alexandria City, Egypt, *Advances in Research*, 7(5): 1-17.
- Keshavarzi, A.; Sarmadian, F.; Shiri, J.; Iqbal, M.; Tirado-Corbala, R. and Evis Omran, E.S. (2017). Application of ANFIS-Based Subtractive Clustering Algorithm in Soil Cation Exchange Capacity Estimation Using Soil and Remotely Sensed Data, *Measurement*, 95: 173-180.
- Khosravi, A.; Nunes, R.O.; Assad, M.E.H. and Machado, L. (2018). Comparison of artificial intelligence methods in estimation of daily global solar radiation, *Journal of cleaner production*, 194: 342-358.
- Lopez, G.; Rubio, M.A.; Martinez, M. and Batlles, F.J. (2001). Estimation of hourly global photosynthetically active radiation using artificial neural network models, *Agri Forest Meteorol*, 107: 279-291.
- Lotfinejad, M.M.; Hafezi, R.; Khanali, M.; Hosseini, S.S.; Mehrpooya, M. and Shamsirband, S. (2018). A Comparative Assessment of Predicting Daily Solar Radiation Using Bat Neural Network (BNN), Generalized Regression Neural Network (GRNN), and Neuro-Fuzzy (NF) System: A Case Study, *Energies*, 11(5): 1-15.
- Meenal, R. and Immanue Selvakumar, A. (2018). Assessment of SVM, empirical and ANN based solar radiation prediction models with most influencing input parameters, *Renewable Energy*, 121: 324-343.
- Mohammadi, K.; Shamsirband, S.; Tong, C.V.; Amjad Alam, K. and Petkovic, D. (2015). Potential of adaptive neuro-fuzzy system for prediction of daily global solar radiation by day of the year, *Energy Conversion and Management*, 93: 406-413.
- Mohandes, M.; Rehman, S. and Halawani, T.O. (1998). Estimation of global solar radiation using artificial neural networks, *RenewEnergy*, 14: 179-184.
- Morshed Varzandeh, M.H.; Rahbari, O.; Vafaeipour, M.; Raahemifar, K. and Heidarzadeh, F. (2014). Performance of Wavelet Neural Network and ANFIS Algorithms for Short-Term Prediction of Solar Radiation and Wind Velocities, *The 4th World Sustainability Forum*, 1-30 Nov. 2014.
- Mosavi, M.R. (2007). GPS Receivers Timing Data Processing using Neural Networks: Optimal Estimation and Errors Modeling, *International Journal of Neural Systems*, 17(5): 383-393.
- Olatomiwa, L.; Mekhilef, S.; Shamsirband, S. and Petkovic, D. (2015). Adaptive Neuro-fuzzy approach for solar radiation prediction in Nigeria, *Renewable and Sustainable Energy Reviews*, 51: 1784-1791.
- Piri, J.; Ansari, H. and Farid-Hosseini, A. (2013). Modeling ground-reached solar radiation using ANFIS and empirical models (Case of study: Zahedan and Bojnourd stations), *Iranian Journal of Energy*, 16(3): 37-58.
- Quej, V.H.; Almorox, J.; Arnaldo, J.A. and Saito, L. (2017). ANFIS, SVM and ANN soft-computing techniques to estimate daily global solar radiation in a warm sub-humid environment, *Journal of Atmospheric and Solar–Terrestrial Physics*, 155: 62-70.
- Rahimi, J.; Ebrahimpour, M. and Khalili, A. (2013). Spatial changes of Extended De Martonne climatic zones affected by climate change in Iran, *Theoretical and Applied Climatology*, 112(3-4): 409-418.
- Sabziparvar, A.A. and Bayat-Varkeshi, M. (2011). Evaluation accuracy of artificial neural networks and neuro-fuzzy methods in simulating global solar radiation, *Iranian Physics Research*, 10(4): 347-357.

- Sabziparvar, A.A. and Khataar, B. (2014). Evaluation of Artificial Neural Network (ANN) and Irmak Experimental Models to Predict Daily Solar Net Radiation (Rn) in Cold Semi-arid Climate (Case study: Hamedan), *Water and Soil Science*, 25(2): 37-50.
- Sabziparvar, A.A. and Khataar, B. (2017). Validation of Empirical and Semi-empirical Net Radiation Models versus Observed Data for Cold Semi-arid Climate Condition, *Journal of Water and Soil*, 30(6): 2087-2100.
- Sabziparvar, A.A. and Olyaie, E. (2012). Evaluation of the performance of artificial neural networks (ANN) in predicting the daily global solar radiation and comparison with results from the Angström model (case study: Tabriz synoptic station), *Iranian Journal of Geophysics*, 5(3): 30-41.
- Seyedian, S.M.; Farasati, M.; Rouhani, H. and Heshmatpour, A. (2017). Solar Radiation Prediction Using Metrological Parameters, *Iran-Water Resources Research*, 13(1): 88-100.
- Siva Krishna Rao K.D.V.; Premalatha, M. and Naveen, C. (2018). Analysis of different combinations of meteorological parameters in predicting the horizontal global solar radiation with ANN approach: A case study, *Renewable and Sustainable Energy Reviews*, 91: 248-258.
- Sumithira, T.R. and Nirmal Kumar, A. (2012). Prediction of monthly global solar radiation using adaptive neuro fuzzy inference system (ANFIS) technique over the State of Tamilnadu (India): a comparative study, *Applied Solar Energy*, 48(2): 140-145.
- Torabi, M.; Mosavi, A.; Ozturk, P.; Varkonyi-Koczy, A. and Istvan, V. (2018). September, A hybrid machine learning approach for daily prediction of solar radiation, In *International Conference on Global Research and Education* (PP. 266-274), Springer, Cham.
- Tymvios, F.S.; Jacovides, C.P.; Michaelides, S.C. and Scouteli, C. (2005). Comparative study of Angstroms and artificial neural networks methodologies in estimating global solar radiation, *Solar Energy*, 78: 752-762.
- Vakili, M.; Sabbagh-Yazdi, S.R.; Kalhor, K. and Khosrojerdi, S. (201). Using Artificial Neural Networks for Prediction of Global Solar Radiation in Tehran Considering Particulate Matter Air Pollution, *Energy Procedia*, 74: 1205-1212.
- Vaseghian, Y. (2016). Estimating global solar radiation in Kermanshah province using artificial neural networks, *Iranian Journal of Energy*, 19(1): 15-44.
- Yıldırım, H.B.; Çelik, Ö.; Teke, A. and Barutçu, B. (2018). Estimating daily Global solar radiation with graphical user interface in Eastern Mediterranean region of Turkey, *Renewable and Sustainable Energy Reviews*, 82: 1528-1537.