

بررسی تأثیر سنج‌های اقلیمی بر تخمین دمای خاک توسط الگوریتم هیبریدی شبیه‌سازی تبرید

بابک محمدی^{۱*}، باقر حیدرپور^۲

۱- دانشجوی دکتری هواشناسی کشاورزی، گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

۲- استادیار گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد رودسر و املش، رودسر، ایران

(تاریخ دریافت: ۹۶/۰۷/۱۰، تاریخ پذیرش: ۹۶/۱۲/۲۸)

چکیده

مطالعات جغرافیایی که به منظور برنامه‌ریزی شهری، اقلیم‌شناسی، ساخت و ساز عمرانی و همچنین کشاورزی یک منطقه صورت می‌گیرد به تخمین دمای خاک آن منطقه وابسته است. در این پژوهش دمای ۵۰ سانتی‌متری عمق خاک با استفاده از مدل الگوریتم هیبریدی شبیه‌سازی تبرید و مدل منفرد ماشین بردار پشتیبان در ایستگاه هواشناسی شهر آدنا واقع در کشور ترکیه شبیه‌سازی شده است. الگوریتم شبیه‌سازی تبرید (SA) یک الگوریتم بهینه‌سازی است که وقتی با ماشین بردار پشتیبان (SVM) تلفیق شود باعث کمینه شدن خطای تخمین و در نهایت بهبود نتایج تخمین می‌شود و در این پژوهش برای اولین بار از الگوریتم هیبریدی شبیه‌سازی تبرید بر پایه ماشین بردار (SVM-SA) در تخمین دمای خاک استفاده شده است تا دقت این الگوریتم در این زمینه مورد بررسی قرار گیرد. نتایج نشان داد که مدل هیبریدی شبیه‌سازی تبرید بر پایه ماشین بردار پشتیبان را با معیار نش - ساتکلیف حدود ۰/۹۹۴ و جذر میانگین مربعات خطا را برابر با ۰/۳۳۱ درجه سلسیوس به خوبی برآورد می‌کند. همچنین برای مدل منفرد ماشین بردار پشتیبان میزان معیار نش - ساتکلیف حدود ۰/۹۷۳ و جذر میانگین مربعات خطا برابر با ۱/۲ درجه سلسیوس به دست آمده است. بهترین ترکیب ورودی از بین ترکیب‌های تعیین شده برای تخمین دمای خاک ترکیب متشکل از ورودی‌های میانگین دمای هوا، بارش، تابش خورشیدی و فشار هوا انتخاب شد. نتایج نشان داد که الگوریتم هیبریدی شبیه‌سازی تبرید می‌تواند به عنوان ابزاری کارآمد در مدل‌سازی دمای اعماق خاک استفاده شود.

کلمات کلیدی: اقلیم‌شناسی، الگوریتم هیبریدی، دمای خاک، شبیه‌سازی، ماشین بردار پشتیبان

مقدمه

فرآیندهای پویای خاک را تحت تأثیر قرار می‌دهد (آرشداد و آروز ۲۰۰۳). دمای خاک همچنین با عمق خاک تغییر پیدا می‌کند و خاک عمیق‌تر دمای ثابت‌تری خواهد داشت. به همین دلیل در هنگام اشاره به دمای خاک باید به عمقی که اندازه‌گیری در آن عمق صورت گرفته نیز اشاره کرد. برای نمونه دمای خاک در عمق ۴ اینچی (۱۰/۱۶ سانتی‌متری) توسط وزارت کشاورزی آمریکا در نظر گرفته شده است (میلیکان ۱۹۴۲) و بورینگ (۱۹۸۴)، برای مطالعه دمای خاک، عمق ۱۰ سانتی‌متری را به دلیل اینکه بیشترین فرآیندهای اکوسیستمی در لایه‌های بالایی خاک صورت می‌پذیرد مورد بررسی قرار داد. دمای خاک در اعماق بالایی ممکن است یا مستقیماً اندازه‌گیری یا به وسیله مدل‌سازی از دمای هوا تخمین زده شود. بنابراین ارائه روش‌های مدل‌سازی که قادر به ارائه نتایج قابل قبول در برآورد دمای

دمای خاک و چگونگی تغییرات آن نسبت به زمان و مکان یکی از مهم‌ترین عواملی است که نه تنها تبادل ماده و انرژی را در خاک تحت تأثیر قرار می‌دهد، بلکه مقدار و جهت کلیه فرآیندهای فیزیکی خاک به طور مستقیم وابسته به آن است. به علاوه تبخیر و تعرق، جوانه‌زنی، تهویه خاک، رشد گیاه، فعالیت ریشه و میکروارگانیسم‌های خاک تابع دمای خاک هستند. پیش‌بینی دمای خاک با توجه به کمبود اندازه‌گیری‌های مستقیم در مزرعه و تأثیر آن در مدیریت و برنامه‌ریزی آبیاری حائز اهمیت است. از این رو در روش‌های محاسباتی و تجربی موجود، از شرایط مرزی و خصوصیات گرمایی خاک به عنوان روشی برای پیش‌بینی دمای خاک استفاده می‌شود. دمای خاک رشد و جوانه‌زنی بذر، ریشه و ساقه، تبخیر، ذخیره و حرکت آب و فرآیندهای میکروبی، چرخه عناصر غذایی و بسیاری دیگر از

همکاران (۱۹۹۳) با استفاده از دمای هوا و به کارگیری رگرسیون خطی، دمای خاک را در عمق ۱۰ سانتی‌متری در ۶ اقلیم متفاوت در آمریکا برآورد کردند. پلابورگ (۲۰۰۲) برای برآورد دمای خاک در عمق ۱۰ سانتی‌متری در دانمارک روابط ساده و تجربی ارائه داد. نتایج کار او نشان داد مدل تجربی با ضریب همبستگی ۰/۹۸ قادر به پیش‌بینی دمای خاک است. سبزی پرور و همکاران (۱۳۸۴-الف) با استفاده از دمای هوا، رطوبت هوا، فشار بخار اشباع و تابش خورشیدی، با استفاده از رگرسیون‌های چند متغیره اقدام به برآورد دمای اعماق مختلف خاک در اقلیم گرم و نیمه خشک کردند. نتایج نامبردگان بیانگر تغییرات R^2 بین ۰/۹۴ (عمق ۵ سانتی‌متر) تا ۰/۷۳ (عمق ۱۰۰ سانتی‌متر) و تغییرات RMSE نیز بین ۲/۷۵ تا ۲/۰۶۲ درجه سلسیوس است. سبزی پرور و همکاران (۱۳۸۴-ب) با مطالعه‌ای دیگر که روی برآورد دمای خاک با استفاده از رگرسیون چند متغیره انجام دادند، با احتساب فراسنج‌های دمای کمینه، دمای بیشینه، میانگین دمای هوا، رطوبت نسبی، سرعت باد و ساعات آفتابی به عنوان فراسنج‌های ورودی مدل، به ترتیب در بهترین و بدترین حالت به ضریب همبستگی ۰/۹۴ در اعماق ۵ و ۲۰ سانتی‌متری ایستگاه زاهدان و ۰/۶۴ در عمق ۵ سانتی‌متری ایستگاه رامسر دست یافتند. بلترامی (۲۰۰۱) گزارش کرد که دمای خاک در فصل‌های بهار، تابستان و پاییز که خاک یخ‌زده نیست، با پسماند زمانی (تأخیر فاز) مشخصی از دمای هوای سطح خاک پیروی می‌کند، در صورتی که در فصل زمستان به دلیل پوشش برف و گرمای نهان ذوب برف رها شده از سطح خاک، چنین همبستگی وجود ندارد. بیلگیلی (۲۰۱۰) با استفاده از شبکه عصبی مصنوعی و داده‌های هواشناسی هر ماه، به پیش‌بینی دمای خاک در ماه بعدی پرداخت. نتایج او نشان داد که استفاده از شبکه عصبی یک روش قابل اطمینان و موثق برای پیش‌بینی دمای خاک است. بیلگیلی (۲۰۱۰) در پیش‌بینی دمای خاک از مدل‌های رگرسیونی و مدل هوشمند شبکه عصبی مصنوعی استفاده کرد و مقایسه نتایج نشان داد که شبکه عصبی با دقت ۰/۹۹۸۱ درجه سلسیوس عملکرد بهتری نسبت به رگرسیون خطی و رگرسیون غیرخطی دارد.

خاک باشد، می‌تواند راه حل مناسبی برای برآورد این متغیر در نقاط فاقد اندازه‌گیری و همچنین پیش‌بینی آن برای ماه‌های بعدی باشد. استفاده از مدل‌های شبکه‌های عصبی مصنوعی به طور گسترده‌ای طی سال‌های اخیر مورد توجه واقع شده است (چنگک و ایسلام، ۲۰۰۰ و طبری و همکاران، ۲۰۱۱).

در سال‌های اخیر شبکه عصبی و ماشین بردار پشتیبان، در مدل‌سازی فرایندهای هیدرولوژیکی متعدد مثل رواناب (گویال، ۲۰۱۴) بارش (حمیدی و همکاران، ۲۰۱۴) مدل‌سازی بارش و رواناب (مدرس، ۲۰۰۹) تبخیر و تعرق (ترزی، ۲۰۱۳). سامویی و دیکسون، ۲۰۱۲. کیسی، ۲۰۱۳. کیم و همکاران، ۲۰۱۴) دمای هوا (ارتاک و همکاران، ۲۰۱۴) جریان رودخانه (کیسی و کیم، ۲۰۱۱) سطح آب (کیسی و کیم، ۲۰۱۱) و رسوبات معلق (کیسی، ۲۰۱۲). به طور گسترده‌ای استفاده شده‌اند. محققین زیادی به توسعه‌ی مدل‌های ساده برای پیش‌بینی و محاسبه‌ی دمای خاک در عمق‌های مختلف در شرایط متفاوت پوشیده از چمن و گیاهان مختلف و همچنین خاک بدون پوشش پرداختند (هانکس و همکاران (۱۹۷۱) و بیلگیلی (۲۰۱۰)). میهالاکاکو (۲۰۰۱) به منظور مدل‌سازی و برآورد تغییرات روزانه و سالانه دمای سطح زمین از روش‌های مدل تجربی و نظریه شبکه عصبی استفاده نمود. میهالاکاکو (۲۰۰۱) در مطالعه‌ای دو روش بیلان انرژی و شبکه عصبی مصنوعی را به منظور برآورد دمای خاک سطحی مورد مقایسه قرار داد. نتایج نشان داد که تکنیک هوش مصنوعی پیشنهاد شده قادر به برآورد دقیق‌تری از توزیع دمای سطحی خاک است. به طور کلی عامل‌هایی که به مدل شبکه عصبی وارد شدند، شامل دما و رطوبت نسبی هوا، مقدار تابش خورشیدی رسیده به سطح زمین و خروجی آن مقادیر دمای سطح خاک بدون پوشش در مقیاس ساعتی بود.

تاکنون مطالعات زیادی در زمینه برآورد دمای خاک صورت گرفته است؛ مانند هانکس و همکاران (۱۹۷۱) که با کاربست روش عددی موفق به برآورد دمای خاک به عنوان تابعی از زمان و عمق شدند. در این مطالعه دمای محاسبه شده ۱/۵ درجه سلسیوس با دمای واقعی اختلاف داشت. ژنگک و

داده و روش‌ها

منطقه مورد مطالعه

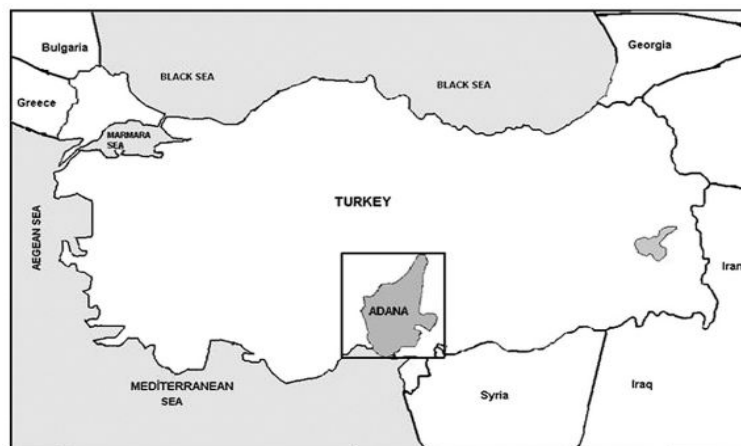
در این پژوهش از اطلاعات هواشناسی ایستگاه همدید آدنا در کشور ترکیه با دوره آماری ۸ ساله (۹۶ ماهه) استفاده شد. این ایستگاه دارای طول جغرافیایی 35° و عرض جغرافیایی 37° است. شهر آدنا با وسعت ۱۹۴۵ کیلومترمربع، از شهرهای ساحلی جنوب کشور ترکیه و اقلیم معتدل و مرطوبی دارد. ارتفاع تقریبی آن از سطح دریا ۲۳ متر است. شکل (۱) نمایی از منطقه و شکل‌های (۲) و (۳) به ترتیب دمای عمق ۵۰ سانتیمتری خاک و مشخصات اقلیمی منطقه مورد مطالعه را نشان می‌دهد.

مدل ماشین بردار پشتیبان (SVM)


اولین کاربرد این روش در مسائل جغرافیایی توسط دیباک و همکاران (۲۰۰۱) با شبیه‌سازی بارش-رواناب ارائه شد. ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای نظریه بهینه‌سازی مفید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده می‌کند و منجر به یک جواب بهینه کلی می‌شود. شکل (۳) ساختار ماشین بردار پشتیبان را نشان می‌دهد.

طبری و همکاران (۲۰۱۱) به مقایسه عملکرد شبکه عصبی مصنوعی از نوع پرسپترون چند لایه با روش رگرسیون خطی چند متغیره برای برآورد دمای روزانه خاک در عمق‌های ۵، ۱۰، ۳۰، ۵۰ و ۱۰۰ سانتی‌متری در منطقه خشک ایران پرداختند. برای ورودی دو مدل شبکه عصبی و رگرسیون خطی چندگانه از میانگین روزانه متغیرهای هواشناسی که شامل دما، تابش خورشیدی و رطوبت نسبی بود، استفاده شد. نتایج مقایسه بین این دو مدل نشان داد که شبکه عصبی مصنوعی دقت بیشتری در برآورد دمای روزانه خاک در منطقه مورد مطالعه داراست.

هدف از مطالعه حاضر ارزیابی قابلیت الگوریتم هیبریدی شبیه‌سازی تبرید بر پایه ماشین بردار پشتیبان (SVM-SA) و ماشین بردار پشتیبان (SVM) در شبیه‌سازی دمای خاک در عمق ۵۰ سانتی‌متری خاک با استفاده سایر فراسنج‌های هواشناسی در شهر آدنا در کشور ترکیه با دوره آماری ۸ ساله (۹۶ ماه) است. نوآوری این پژوهش تلفیق الگوریتم شبیه‌سازی تبرید (SA) با ماشین بردار پشتیبان (SVM) است و در ادامه بررسی خواهد شد که این تلفیق در برآورد دمای خاک چه قدر موفقیت‌آمیز است.



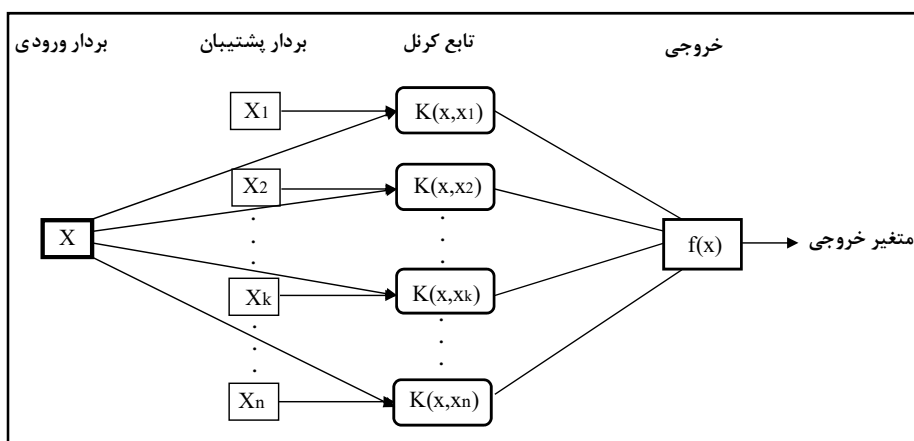
شکل ۱- نمایی از منطقه مورد مطالعه (آدنا- ترکیه)



شکل ۲- دمای عمق ۵۰ سانتی متری خاک در طول دوره آماری (آدنا-ترکیه)

جدول ۱- فراسنج‌های اقلیمی مورد استفاده در این تحقیق برای ایستگاه آدنا

فراسنج‌های اقلیمی	واحد (ماهانه)	میانگین	کمینه	بیشینه	انحراف معیار	همبستگی با دمای عمق ۵۰ سانتی متری خاک
میانگین دمای هوا	درجه سلسیوس	۱۹/۲۴	۶/۸	۲۹/۷	۷/۲۶	۰/۹۷۵
تابش خورشیدی	کیلو کالری بر سانتی متر مربع	۰/۳۷	۰/۱۲	۰/۶۵	۰/۱۳	۰/۷۵۳
سرعت باد	متر بر ثانیه	۱/۱۲	۰/۳	۱/۶	۰/۳۰۸	-۰/۰۴۵
رطوبت نسبی هوا	درصد	۶۸/۳۶	۵۶/۱	۷۹/۳	۵/۴۸۳	۰/۱۳۹
فشار هوا	اتمسفر	۱/۰۰۹	۱/۰۰۱	۱/۰۲۱	۰/۰۰۴	-۰/۵۵۹
بارش	میلی متر	۷/۲۵۴	۲/۲	۱۱/۳	۲/۳۳۶	۰/۸۴۲
دمای عمق ۵۰ سانتی متری خاک	درجه سلسیوس	۲۱/۳۹	۱۰/۴	۳۲/۸	۷/۴۴	۱



شکل ۳- ساختار ماشین بردار پشتیبان

ماشین بردار پشتیبان معمولاً از تابع کرنل پایه شعاعی استفاده می‌شود، در این تحقیق نیز از این تابع استفاده شده است. فرمول کرنل پایه شعاعی در زیر آورده شده است (محمدی و امامقلی زاده ۱۳۹۵):

$$k(x, x_i) = \exp(-\|x - x_i\|^2 / \sigma^2) \quad (۶)$$

لازم به ذکر است فرآیند محاسبات ماشین بردار پشتیبان، بر اساس کدنویسی در محیط متلب انجام و فراسنج‌های تابع کرنل از طریق سعی و خطا بهینه می‌شوند. همچنین در این تحقیق از هسته تابع پایه شعاعی به دلیل پرکاربرد بودن استفاده شده است (محمدی و امامقلی زاده ۱۳۹۵).

الگوریتم شبیه‌سازی تبرید (SA)

الگوریتم شبیه‌سازی تبریدی (تبرید شبیه‌سازی شده) یا سرد کردن تدریجی یکی از الگوریتم‌های فرا ابتکاری بوده که علیرغم ساختاری ساده، اثربخشی بالایی در حل بسیاری از مسائل بهینه‌سازی ترکیبی دارد. این الگوریتم یک روش جستجوی محلی^۱ است که سعی در به دست آوردن جواب بهینه سراسری^۲ دارد. شبیه‌سازی تبریدی یک روش فراابتکاری احتمالی^۳ بر مبنای مدل مونت کارلو است که توسط متروپولیس و همکارانش در سال ۱۹۵۳ ارائه شد و به طور گسترده در عرصه‌های گوناگون مسائل بهینه‌سازی ترکیبی مورد استفاده قرار می‌گیرد (گونزالز و همکاران ۲۰۰۱، تران و همکاران، ۲۰۰۷).

اساس این الگوریتم بر مبنای رابطه بین ساختار اتمی، آنتروپی و دما در طول تبرید یک ماده و شباهت آن با پدیده آیلینگ (Annealing) است. این الگوریتم در دهه هشتاد میلادی توسط کرکپاتریک و همکاران^۴ معرفی شد و تاکنون به دلیل سادگی و همچنین کارایی، تأثیر شگرفی در زمینه حل مسائل بهینه‌سازی ترکیباتی گذاشته است. از آن به بعد روش تبرید شبیه‌سازی شده برای حل مسائل بهینه‌سازی مختلفی که شامل متغیرهای مستقل بسیاری هستند به کار گرفته شده است (فایان، ۱۹۹۷؛ تران و همکاران، ۲۰۰۷). برخلاف روش‌های بهینه‌سازی موضعی که

در مدل رگرسیون، بردار پشتیبان، تابعی مرتبط با متغیر وابسته y که خود تابعی از چند متغیر مستقل x است، برآورد می‌شود (یعنی تابعی از متغیرهای مستقل است). مشابه سایر مسائل رگرسیونی فرض می‌شود رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند $f(x)$ به علاوه مقداری اغتشاش (خطای مجاز ε) مشخص شود.

$$f(x) = W^T \cdot \phi(x) + b \quad (۱)$$

$$Y = f(x) \pm \text{noise} \quad (۲)$$

چنانچه W بردار ضرایب، b ثابت مشخصه‌های تابع رگرسیونی و $\Phi(x)$ تابع کرنل باشد، آنگاه هدف پیدا کردن فرم تابعی برای $f(x)$ است. این مهم با واسنجی مدل ماشین بردار پشتیبان توسط مجموعه‌ای از نمونه‌ها (مجموعه واسنجی) محقق می‌شود. برای محاسبه W و b لازم است:

$$W^T \cdot \phi(x_i) + b - y_i \leq \varepsilon + \varepsilon_i^* \quad (۳)$$

$$\frac{1}{2} W^T w + C \sum_{i=1}^N \varepsilon_i + C \sum_{i=1}^N \varepsilon_i^* y_i - W^T \cdot \phi(x_i) - b \leq \varepsilon + \varepsilon_i \quad (۴)$$

$$\varepsilon_i, \varepsilon_i^* \geq 0, i = 1, 2, \dots, N$$

در معادلات بالا C عددی صحیح و مثبت است که عامل تعیین جریمه در هنگام رخ دادن خطای واسنجی مدل است، $\phi(x)$ تابع کرنل، N تعداد نمونه‌ها و دو مشخصه ε_i و ε_i^* متغیرهای کمبود هستند (اسکندری و همکاران ۱۳۹۰). در نهایت تابع رگرسیون بردار پشتیبان را می‌توان به فرم زیر بازنویسی کرد:

$$f(x) = \sum_{i=1}^N \bar{\alpha}_i \phi(x_i)^T \cdot \phi(x) + b \quad (۵)$$

در معادله (۵)، $\bar{\alpha}_i$ میانگین ضرایب لاگرانژ است. محاسبه $\phi(x)$ در فضای مشخصه آن ممکن است بسیار پیچیده باشد. برای حل این مشکل روند معمول در مدل رگرسیون بردار پشتیبان انتخاب یک تابع کرنل است. با توجه به این که در

3- Probabilistic met heuristic
4- Kirkpatrick, Gellat and Vecchi

1- Local search
2- Global Optimization

در غیر این صورت (احتمال P_{t-1}) پاسخ x_{t+1} پذیرفته می‌شود. که در رابطه فوق P_t به صورت زیر تعریف می‌شود:

$$P = \exp(-[f(x) - f(x_t)] / \theta t)$$

در رابطه فوق θt بیان کننده دما در تکرار t می‌باشد و قانونی که برای تعیین θt را به کار گرفته می‌شود، برنامه خنک کننده (Cooling schedule) نامیده می‌شود. در ابتدا θt را برابر با یک مقدار مثبت $\theta_1 > 0$ می‌گیرند که بعد از هر T تکرار در یک ضریب a که $0 < a < 1$ در هر مرحله از الگوریتم SA یک حالت جدیدی از سیستم از حالت فعلی ساخته می‌شود که اگر انرژی مربوط به این حالت جدید پایین‌تر از حالت فعلی باشد، عمل جایگزینی صورت می‌گیرد و حالت جدید به عنوان حالت فعلی پذیرفته می‌شود. اگر حالت جدید به میزان d ذول انرژی بیشتری از حالت فعلی داشته باشد آنگاه احتمال تغییر حالت فعلی به حالت جدید برابر رابطه زیر است:

$$p = \exp(-d/KT)$$

در این رابطه k ثابت بولتزمن و T دمای مطلق حالت فعلی است. این اقدام به طور مشابه تکرار می‌شود که تحت عنوان مرحله متروپلیس شناخته می‌شود و این رویه را چرخه متروپلیس می‌نامند. با توجه به توضیحات فوق در خصوص الگوریتم SA پایه می‌توان مزیت‌های این الگوریتم را به صورت زیر فهرست کرد:

الف- الگوریتم SA می‌تواند با هر سیستم اختیاری و تابع هزینه ارتباط پیدا کند.

ب- الگوریتم SA می‌تواند به طور احتمالی یافتن جواب بهینه را تضمین کند.

ج- الگوریتم SA می‌تواند به راحتی برای هر مسئله پیچیده کد شود.

د- الگوریتم SA معمولاً جواب خوبی را تولید می‌کند (زارع مهرجردی و همکاران، ۱۳۹۰).

فقط می‌توانند یک مقدار کمینه نزدیک به حدس اولیه را پیدا کنند، روش تبرید شبیه‌سازی شده، مقدار کمینه مطلق را پیدا می‌کند (تران و همکاران، ۲۰۰۳). مفهوم اصلی روش تبرید شبیه‌سازی شده از فرآیند فیزیکی تبرید فلزات مذاب سرچشمه می‌گیرد. در فرآیند تبرید، یک فلز مذاب با دمای بسیار زیاد به تدریج خنک می‌شود. در دماهای زیاد، اتم‌های سازنده فلز به صورت تصادفی قرار گرفته‌اند و می‌توانند به آسانی نسبت به یکدیگر جابه‌جا شوند. با کاهش تدریجی دما، حرکت اتم‌ها محدود می‌شود به طوری که اتم‌ها شروع به مرتب شدن می‌کنند و تشکیل کریستال می‌دهند. سطح انرژی کریستال تشکیل شده به سرعت سرد کردن فلز بستگی دارد. اگر کاهش دما خیلی سریع صورت بگیرد، ممکن است ساختار کریستالی تشکیل نشده و به جای آن ساختاری غیر کریستالی با سطح انرژی بالا تشکیل شود. بنابراین برای رسیدن به کمترین میزان سطح انرژی، فرآیند سرد کردن باید به آرامی صورت پذیرد (تران و همکاران، ۲۰۰۷؛ اونسان و همکاران، ۱۹۹۴؛ واسان و همکاران، ۲۰۰۹؛ فایان، ۱۹۹۷؛ دوران و همکاران، ۲۰۰۰).

روش SA مبتنی بر سازوکارهای آماری است که در آن فرآیند خنک کاری به صورت گرمادهی و سردسازی آهسته یک ماده به منظور دستیابی به یک ساختار کریستالی سخت و محکم انجام می‌شود. وقتی یک جسم را حرارت می‌دهیم کم کم منبسط می‌شود و در اثر این انبساط و گرما از نظر فیزیکی در سطح انرژی بالایی قرار می‌گیرد که در این حالت در واقع اتم‌ها به نظر خیلی بی‌نظم می‌رسند. ولی وقتی جسم را کم کم سرد می‌کنیم آرایش اتم‌ها به نظر منظم‌تر می‌شود و اصطلاحاً گفته می‌شود که سیستم از نظر فیزیکی در سطح انرژی پایینی قرار دارد. الگوریتم SA در هر تکرار t ، یک جواب x به صورت تصادفی از همسایگی $N(x_t)$ انتخاب می‌کند. همسایه‌های یک حالت (جواب)، حالت‌های جدیدی از مسئله هستند که با تغییر در حالت کنونی و با توجه به روشی از پیش تعیین شده ایجاد می‌شوند. چنانچه پاسخ جدید مناسب‌تر باشد، x_{t+1} را برابر x قرار می‌دهیم در غیر این صورت با احتمال P_t پاسخ x پذیرفته شده و

نش- ساتکلیف (NS) است که به ترتیب در روابط ۷ و ۸ آورده شده‌اند. دقیق‌ترین مدل با توجه به این معیارها، مدلی خواهد بود که مقدار این دو معیار برای آن به ترتیب نزدیک به یک، صفر و یک باشد (محمدی ۱۳۹۶):

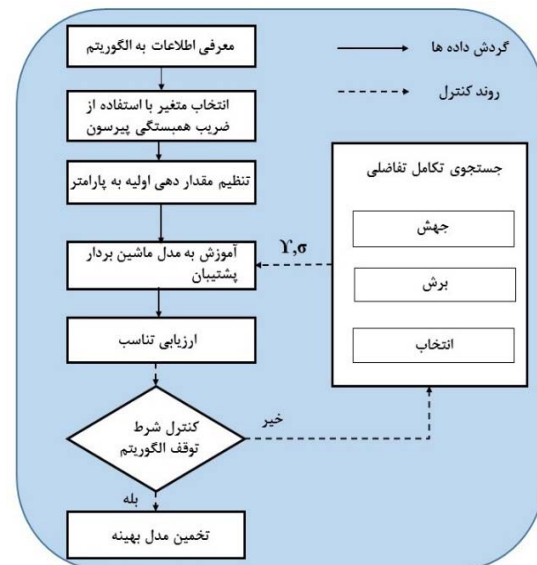
$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (7)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (8)$$

در روابط بالا x_i و \bar{x} به ترتیب مقادیر مشاهداتی جریان و میانگین مقادیر مشاهداتی، y_i مقادیر محاسباتی دمای خاک، \bar{y} میانگین مقادیر محاسباتی و N تعداد داده‌هاست.

بحث و بررسی

با توجه به همبستگی فراسنج‌های هواشناسی، این فراسنج‌ها تحت ساختارهای متفاوتی به عنوان ورودی‌های دو مدل شبیه‌ساز ماشین بردار پشتیبان و الگوریتم هیبریدی شبیه‌سازی تبرید تعریف شدند که ساختارهای ورودی تعریف شده در جدول ۲ ارائه شده است.



شکل ۴- فلوچارت تبرید بر مبنای ماشین بردار پشتیبان

معیارهای ارزیابی

با استفاده از روش‌های مختلفی می‌توان عملکرد مدل‌ها را مورد ارزیابی و مقایسه قرار داد و یکی از این روش‌ها استفاده از معیارهای ارزیابی است. از جمله معیارهای ارزیابی پرکاربرد در علوم مهندسی ریشه میانگین مربعات خطا (RMSE) و معیار

جدول ۲- ساختارهای متفاوت ترکیب فراسنج‌های مؤثر در برآورد دمای خاک به عنوان ورودی مدل‌های شبیه‌ساز

شماره ساختار	تعداد ورودی	فراسنج‌های ورودی	فراسنج خروجی
۱	۱	میانگین دمای هوا	دمای عمق ۵۰ سانتی متری خاک
۲	۲	میانگین دمای هوا، بارش	دمای عمق ۵۰ سانتی متری خاک
۳	۳	میانگین دمای هوا، بارش، تابش خورشیدی	دمای عمق ۵۰ سانتی متری خاک
۴	۴	میانگین دمای هوا، بارش، تابش خورشیدی، فشار هوا	دمای عمق ۵۰ سانتی متری خاک
۵	۵	میانگین دمای هوا، بارش، تابش خورشیدی، فشار هوا، رطوبت نسبی هوا	دمای عمق ۵۰ سانتی متری خاک
۶	۶	میانگین دمای هوا، بارش، تابش خورشیدی، فشار هوا، رطوبت نسبی هوا، سرعت باد	دمای عمق ۵۰ سانتی متری خاک

بودن دامنه کاهش خطا از یک ساختار به ساختار دیگر، بیشتر مشهود است. از دلایل این موضوع می‌توان به فاصله زیاد مقدار خطای اولیه (خطا در ساختار ۱ مدل ماشین بردار منفرد) اشاره نمود. همان‌طور که انتظار می‌رفت از آنجا که مدل‌های آموزش داده شده برای مجموعه داده‌های مستقلی مورد آزمون قرار گرفتند، نتایج هر دو مدل ماشین بردار پشتیبان منفرد و الگوریتم هیبریدی شبیه‌سازی تبرید در مرحله آموزش و در تمامی ساختارهای تعریف شده کمی بهتر از نتایج متناظر در مرحله آزمون بوده است. بر اساس نتایج به دست آمده در مدل الگوریتم هیبریدی شبیه‌سازی تبرید بر پایه ماشین بردار پشتیبان، بهترین مقادیر خطا از نقطه نظر تعداد ورودی‌ها و کمترین اختلاف خطا برای حالت آموزش و آزمون ساختار شماره چهارم بوده است و همچنین بهترین مدل برای ماشین بردار پشتیبان منفرد ساختار ششم بوده است.



نتایج مربوط به شبیه‌سازی مقادیر ماهانه دمای خاک در دوره آموزش (۷۵ درصد داده‌ها معادل ۷۲ داده) و آزمون (۲۵ درصد داده‌ها معادل ۲۴ داده) در ایستگاه مورد مطالعه بر اساس مدل ماشین بردار پشتیبان منفرد و مدل الگوریتم هیبریدی شبیه‌سازی تبرید در جداول ۳ و ۴ ارائه شده است. آنچنان که نتایج این جداول نشان می‌دهد ترکیب چهارم با ورودی‌های میانگین دمای هوا، بارش، تابش خورشیدی و فشار هوا در هر دو مدل ماشین بردار منفرد و مدل الگوریتم هیبریدی شبیه‌سازی تبرید بر پایه ماشین بردار با بهترین نتایج همراه بوده است. نکته مهم در رابطه با نتایج جدول ۳ و ۴ آن است که اگرچه مقادیر خطای برآورد دمای خاک در هر ۶ ساختار ورودی و در هر دو حالت آموزش و آزمون ماشین بردار پشتیبان منفرد از مقادیر متناظر آنها در مدل الگوریتم شبیه‌سازی تبرید بیشتر است، با این حال نقش افزوده شدن ورودی‌ها در مدل ماشین بردار پشتیبان منفرد در قیاس با مدل الگوریتم شبیه‌سازی تبرید به واسطه بیشتر

جدول ۳- نتایج ارزیابی عملکرد مدل ماشین بردار پشتیبان در برآورد دمای خاک

آزمون		آموزش		فراسنج شبکه		شماره ساختار	مدل
RMSE (°C)	NS	RMSE (°C)	NS	γ	σ^2		
۱/۶۱۰	۰/۹۴۲	۱/۵۵۳	۰/۹۵۲	۷۴/۲۵	۶۶/۵۲	۱	ماشین بردار پشتیبان
۱/۴۲۹	۰/۹۶۱	۱/۳۳۷	۰/۹۷۲	۹۰/۶۲	۱۷/۵۰	۲	
۱/۱۹۸	۰/۹۷۷	۰/۹۱۱	۰/۹۸۳	۵۱/۳۸	۳۲/۱۰	۳	
۱/۱۲۲	۰/۹۷۷	۰/۸۷۵	۰/۹۸۴	۸۳/۱۸	۲۵/۱۹	۴	
۱/۱۸۳	۰/۹۷۸	۰/۸۷۰	۰/۹۹۰	۳۶/۷۷	۱۴/۵۵	۵	
۱/۲۰۰	۰/۹۷۳	۰/۸۷۷	۰/۹۸۴	۸۲/۵۷	۳۴/۱۵	۶	

جدول ۴- نتایج ارزیابی عملکرد مدل شبیه‌سازی تبرید در برآورد دمای خاک

مدل	شماره ساختار	فراسنج شبکه			آموزش		آزمون		
		β	c	ϵ	n	NS	RMSE(°C)	NS	RMSE(°C)
الگوریتم هیبریدی شبیه‌سازی تبرید بر پایه ماشین بردار پشتیبان	۱	۲/۵	۰/۷	۰/۰۰۵	۳۰۰	۰/۹۹۶	۰/۲۹۲	۰/۹۹۲	۰/۴۵۶
	۲	۲/۲	۰/۲	۰/۰۰۵	۳۵۰	۰/۹۹۶	۰/۲۷۰	۰/۹۹۳	۰/۴۰۳
	۳	۳/۱	۰/۵	۰/۰۰۵	۳۰۰	۰/۹۹۷	۰/۲۵۲	۰/۹۹۴	۰/۳۴۲
	۴	۲/۷	۰/۶	۰/۰۰۵	۲۰۰	۰/۹۹۸	۰/۲۶۶	۰/۹۹۴	۰/۳۳۱
	۵	۲	۰/۳	۰/۰۰۵	۲۵۰	۰/۹۹۸	۰/۲۴۸	۰/۹۹۴	۰/۳۳۹
	۶	۲/۲	۰/۵	۰/۰۰۵	۳۰۰	۰/۹۹۹	۰/۲۱۳	۰/۹۹۵	۰/۳۴۱



شکل ۵- نتایج شبیه‌سازی دمای خاک (درجه سلسیوس) برای بهترین ترکیب ورودی یعنی ترکیب چهارم برای هر دو مدل، مدل منفرد ماشین بردار پشتیبان و مدل الگوریتم هیبریدی شبیه‌سازی تبرید، برای بخش آزمون.

نتیجه‌گیری

با توجه به نتایج به دست آمده از دقت بالای الگوریتم هیبریدی شبیه‌سازی تبرید دو نتیجه‌گیری مهم می‌توان انجام داد. اولاً موفقیت‌آمیز بودن روش پیشرو در انتخاب فراسنج‌های مؤثر که باعث نشان دادن اضافه شدن خطای تک تک ورودی‌ها شد و همچنین مناسب‌ترین ورودی‌های میانگین دمای هوا، بارش، تابش خورشیدی و فشارهوا را به شبکه پیشنهاد داده است. دوم دقت زیاد الگوریتم هیبریدی شبیه‌سازی تبرید که از ماشین بردار پشتیبان منفرد هم دقیق‌تر است و این نتیجه‌گیری با نتیجه‌گیری سلیمی و همکاران (۲۰۱۱) تطابق دارد و به عنوان الگوریتم هیبریدی جدید در حوزه علوم مهندسی می‌توان معرفی کرد. همچنین در مقایسه نتایج این پژوهش با نتایج تحقیقات دیگر پژوهشگران، از جمله بیلگیلی (۲۰۱۰) که در پیش‌بینی دمای خاک با استفاده از مدل‌های رگرسیونی و مدل هوشمند شبکه عصبی مصنوعی نشان داد که شبکه عصبی با دقت $0/9981$ عملکرد بهتری نسبت به رگرسیون خطی و رگرسیون غیرخطی دارد، در پژوهش حاضر الگوریتم هیبریدی شبیه‌سازی تبرید نتایجی بهتر با خطایی کمتر داشته است ($RMSE = 0/331$).

منابع

۴- سبزی‌پرور. ع. ا.، ح. زارع ایبانه و م. بیات ورکیشی، ۱۳۸۴- ب، مقایسه مدل بین پیش‌بینی درجه حرارت خاک با استفاده از مدل ANFIS و روش‌های رگرسیونی در سه اقلیم مختلف، نشریه آب و خاک، جلد ۲۴، شماره ۲، صص. ۲۷۴ تا ۲۸۵.

۵- محمدی، ب. و ص. امامقلی‌زاده، ۱۳۹۵، استفاده از تحلیل مؤلفه اصلی برای تعیین ورودی‌های مؤثر بر تخمین بارش به کمک شبکه عصبی مصنوعی و ماشین بردار پشتیبان، سامانه‌های سطوح آبگیر باران، ۴ (۴)، صص. ۶۷ تا ۷۵.

۶- محمدی، ب. ۱۳۹۶، تخمین تبخیر روزانه بر اساس مدل هیبریدی شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی کرم شب‌تاب، پایان‌نامه کارشناسی ارشد، دانشکده کشاورزی، دانشگاه تبریز.

7- Arshad, M. A. & R. H. Azooz, 2003, In-row residue management effects on seed-zone temperature, moisture and early growth of barley and canola in a cold semi-arid region in northwestern Canada, American Journal of Alternative Agriculture, 18: 129-136.

8- Beltrami, H., 2001, On the relationship between ground temperature histories and meteorological records, Global and Planetary Change, 29: 327-348.

9- Bilgili, M., 2010, the use of artificial neural networks for forecasting the monthly mean soil temperatures in Adana, Turkey, Turk Journal Agriculture, 35: 83-93.

10- Bilgili, M., 2010, Prediction of soil temperature using regression and artificial neural network models, Meteorology Atmospheric Physics, 110: 59-70.

11- Buring, P., 1984, The role of terrestrial vegetation in the global carbon cycle measurement by remote sensing, John Wiley and Sons edition, Massachusetts, USA, pp: 91-109.

12- Chang, D. H. & S. Islam, 2000, Estimation of Soil Physical Properties Using Remote Sensing and Artificial neural network, Remote Sensing of Environment, 74: 534-544.

13- Dibike, Y., S. Velickov, D. Solomatine & M. Abbott, 2001, Model induction with of support vector machines: Introduction and applications, Journal of Computing in Civil Engineering, 15: 208- 216.

۱- اسکندر، ع.، ر. نوری، ح. معراجی و الف. کیاقدادی، ۱۳۹۰، توسعه مدلی مناسب بر مبنای شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای پیش‌بینی بهنگام اکسیژن خواهی بیوشیمیایی ۵ روزه، محیط‌شناسی، سال ۳۸، ش ۶۱، بهار ۹۱، صص. ۷۱ تا ۸۲.

۲- زارع مهرجردی، ی.، ش. برقی و ح. مومنی، ۱۳۹۰، به کارگیری روش فوق ابتکاری - شبیه‌سازی تبرید تدریجی برای حل مسایل زنجیره تأمین، مجله تحقیق در عملیات و کاربردهای آن، سال هشتم، شماره ۳، صص. ۱ تا ۲۴.

۳- سبزی‌پرور. ع. ا.، ح. طبری و ا. آئینی، ۱۳۸۴، برآورد میانگین روزانه دمای خاک در چند نمونه اقلیمی ایران با استفاده از داده‌های هواشناسی، دوره ۱۴، شماره ۵۲، صص. ۱۲۵ تا ۱۳۷.

- 25- Kisi, O., 2012, Modeling discharge-suspended sediment relationship using least square support vector machine, *J. Hydrol.*, 456: 110–120.
- 26- Kisi, O., 2013, Least squares support vector machine for modeling daily reference evapotranspiration, *Irrig. Sci.*, 31(4): 611–619.
- 27- Kisi, O. & M. Cimen, 2011, A wavelet-support vector machine conjunction model for monthly streamflow forecasting, *J. Hydrol.*, 399(1–2): 132–140.
- 28- Kisi, O., J. Shiri, S. Karimi, Sh. Shamshirband, Sh. Motamedi, D. Petkovic & R. Hashim, 2015, A survey of water level fluctuation predicting in Urmia Lake using support vector machine with firefly algorithm, *Applied Mathematics and Computation*, 270: 731–743.
- 29- Mihalakakou, G., 2001, On estimating soil surface temperature profiles, *Energy & Building*. Vol. 34.
- 30- Millikan, C. R., 1942, Studies on soil conditions in relation to root-rot of cereals, *Proceeding of the Royal Society of Victoria*, 54, 145.
- 31- Modarres, R., 2009, Multi-criteria validation of artificial neural network rainfall-runoff modeling, *Hydrol. Earth Syst. Sci.*, 13: 411–421.
- 32- Muller, G. & J. Doring, 1989, Berechnungsverfahren für die temperature in unbewachsenem boden. *Archiv für Acker- und Pflanzenbau und Bodenkunde*, Berlin, 33, 385–391.
- 33- Ouenesan, A., B. Srinivasa, P. H. Bunge and B. J. Travis, 1994, Application of simulated annealing and other global optimization methods to reservoir description: myths and realities, SPE 28415, 69th Annual Technical Conference and Exhibition, New Orleans, LA, U.S.A., pp. 25–28.
- 34- Plauborg, F., 2002, Simple model for 10 cm soil temperature in different soils with short grass, *European Journal of Agronomy*, 17: 173–179.
- 35- Roodenburg, J., 1985, Estimating 10-cm soil temperatures under grass, *Agricultural and Forest Meteorology*, 34: 41–52.
- 36- Salimi Sartakhti, J., M. H. Zangoeei & K. Mozafari, 2012, Hepatitis disease diagnosis using a novel hybrid method based on support vector machine and simulated annealing (SVM-SA), *Computer methods and programs in biomedicine* 108: 570–579.
- 14- Demirel, M., 2007, Performing k-means analysis to drought principal components of Turkish rivers, Rosenstiel School of Marine and Atmospheric Sciences, Division of Meteorology and Physical Oceanography, Miami Florida.
- 15- Durand, M. D. & S. R. White, 2000, Trading accuracy for speed in parallel simulated annealing with simultaneous moves, *Elsevier Parallel Computing*, Vol. 26: 135–150.
- 16- Ertac, M., E. Firuzan & S. Solum, 2014, Forecasting Istanbul monthly temperature by multivariate partial least square, *Theor. Appl. Climatol.*, 117:1–13.
- 17- Fabian, V., 1997, Simulated annealing simulated computers & mathematics with applications, Vol. 33, No. 1/2, pp. 81–94.
- 18- Ghorbani M. A., H. Ahmadzadeh, M. Isazadeh & O. Terzi, 2016, A comparative study of artificial neural network (MLP, RBF) and support vector machine models for river flow prediction, *Environmental Earth Science*, 75: 476–490.
- 19- Gonzalez, R. C. & V. S. Perez, Two procedures for stochastic simulation of vuggy formations, 2001, SPE 69663, Latin American and Caribbean Petroleum Engineering Conference, Buenos Aires, Argentina, pp. 25–28.
- 20- Goyal, M. K., 2014, Monthly rainfall prediction using wavelet regression and neural network: an analysis of 1901–2002 data, Assam, India, *Theor. Appl. Climatol.*, 118: 25–34.
- 21- Hamidi, O. H., J. Poorolajal, M. Sadeghifar, H. Abbasi, Z. Maryanaji, H. R. Faridi & L. Tapak, 2014, a comparative study of support vector machines and artificial neural networks for predicting precipitation in Iran, *Theor. Appl. Climate.*, Doi: 10.1007/s00704-014-1141-z
- 22- Hanks, R. J., D. D. Austin & W. T. Ondrechen, 1971, Soil temperature estimation by a numerical method, *Soil Science Society of America Journal*, 35: 665–667.
- 23- Hasfurther, V. R. & R. D. Burman, 1974, Soil temperature modeling using air temperature as a driving mechanism, *Transactions of ASAE*, 78–81.
- 24- Ilin, A. & T. Raiko, 2010, Practical approaches to principal component analysis in the presence of missing values, *Journal of Machine Learning Research*, 11: 1957–2000.

- 41- Tran N. H., Z. Chen and S. S. Rahman, 2003, Characterizing and Modeling of Naturally Fractured Reservoirs with the use of Object-Based Global Optimization, Petroleum Society's Canadian International Petroleum Conference, Calgary, Alberta, Canada, pp. 10 – 12.
- 42- Vasan A. & K. S. Raju, 2009, Comparative analysis of simulated annealing, Simulated Quenching and Genetic Algorithms for optimal reservoir operation Elsevier, Applied Soft Computing, Vol. 9, pp. 274–281.
- 43- Zheng, D., Hunt Jr. Raymond & S. W. Running, 1993, A daily soil temperature model based on air temperature and precipitation for continental applications, Climate Research Journal, 2: 183-191.
- 37- Samui, P. & B. Dixon, 2012, Application of support vector machine and relevance vector machine to determine evaporative losses in reservoirs, Hydrol. Process 26: 1361–1369.
- 38- Tabari, H, A. A. Sabziparvar & M. Ahmadi, 2011, Comparison of artificial neural network and multivariate linear regression methods for estimation of daily soil temperature in an arid region, Meteorology Atmospheric Physics, 110: 135–142.
- 39- Terzi, O., 2013, Daily pan evaporation estimation using gene expression programming and adaptive neural-based fuzzy inference system, Neural Comput. Appl., 23: 1035–1044.
- 40- Tran, N. H. & K. Tran, 2007, Combination of fuzzy ranking and simulated annealing to improve discrete fracture inversion Elsevier, Mathematical and Computer Modeling, Vol. 45, pp. 1010–1020.