

کاربرد الگوریتم ژنتیک در بهینه‌سازی عملکرد سیستم استنتاج فازی-عصبی تطبیقی به منظور پیش‌بینی بیشترین دمای هوا (مطالعه موردی: شهر اصفهان)

مهران منوچهری نیا^۱، آرمین آزاد^۱، سعید فرزین^۲، حجت کرمی^{۲*}

۱. دانشجوی کارشناسی ارشد مهندسی و مدیریت منابع آب، دانشکده مهندسی عمران، دانشگاه سمنان

۲. استادیار گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان

(تاریخ دریافت ۱۳۹۶/۰۶/۲۶؛ تاریخ تصویب ۱۳۹۶/۱۰/۱۲)

چکیده

الگوریتم‌های موجود برای آموزش سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) با وجود کاربرد فراوان، نقایصی همچون به‌دام‌افتادن در بهینه محلی دارند. در پژوهش حاضر، کاربرد الگوریتم‌های بهینه‌سازی ژنتیک (GA)، ازدحام ذرات (PSO)، کلونی مورچگان برای محیط‌های پیوسته (ACOR) و تکامل تفاضلی (DE)، در توسعه و بهبود عملکرد ANFIS بررسی شد. به‌عنوان مطالعه موردی، بیشترین دمای ماهانه شهر اصفهان در بازه زمانی ۶۴ ساله (۱۳۳۰-۱۳۹۳)، شبیه‌سازی و تحلیل شد. به این منظور، ابتدا با استفاده از آنالیز حساسیت، مناسب‌ترین ورودی‌ها برای هر یک از افق‌های پیش‌بینی (یک ماه، یک تا سه سال) انتخاب شد. سپس، بیشترین دما به‌وسیله مدل‌های هیبریدی ANFIS-GA، ANFIS-PSO، ANFIS-DE، ANFIS-ACOR و مدل ANFIS پیش‌بینی شد. در ادامه، عملکرد هر یک از مدل‌ها با استفاده از شاخص‌های آماری R^2 ، RMSE و MAE ارزیابی شد. نتایج نشان داد مدل ANFIS-GA، به‌عنوان مناسب‌ترین مدل، دقت عملکرد ANFIS را در پیش‌بینی افق‌های یک ماه و یک تا سه سال آینده در R^2 به ترتیب به مقدار ۰/۰۶، ۰/۰۷، ۰/۰۸ و ۰/۱۲ و در RMSE به میزان ۰/۰۹، ۰/۰۹، ۰/۱۶ و ۰/۱ بهبود داده است. پس از آن، به ترتیب ANFIS-DE و ANFIS-PSO مناسب‌ترین دقت را داشتند. از سوی دیگر، ANFIS با بیشترین خطا و کمترین R^2 ، به‌عنوان ضعیف‌ترین مدل شناخته شد. نتایج نشان داد مدل‌های هیبریدی پیشنهادی، با استفاده از تکنیک جست‌وجوی سراسری و جلوگیری از به‌دام‌افتادن در بهینه محلی، عملکرد ANFIS را به‌طور مطلوبی بهبود داده‌اند. مدل‌های پیشنهادی پتانسیل زیادی به‌منظور استفاده در سایر مسائل مرتبط با هیدرولوژی و منابع آب دارند.

کلیدواژگان: الگوریتم‌های تکاملی هیبریدی، الگوریتم ژنتیک، جواب بهینه محلی، دمای هوا، سیستم استنتاج فازی-عصبی.

مقدمه

به‌طور حتم، از بزرگ‌ترین چالش‌های قرن ۲۱، تغییرات اقلیمی است. دمای محیط، یکی از پارامترهای بسیار مهم در تغییرات اقلیم است که از دیرباز مورد توجه اقلیم‌شناسان بوده است [۱]. پیش‌بینی دمای هوا اهمیت بسیاری در زمینه‌های مختلف مدیریت منابع آب از جمله کشاورزی، آبرسانی و چگونگی ذوب یخ‌ها دارد. از سوی دیگر، دمای هوا به‌عنوان یک ورودی اصلی در مدل‌های هیدرولوژیکی و اکولوژیکی است [۲]. تغییرات دمای هوا از سامانه‌های پیچیده غیرخطی است که برای شبیه‌سازی و تحلیل آن نمی‌توان از روش‌های کلاسیک خطی استفاده کرد. امروزه، پژوهشگران با ابداع علومی مانند روش‌های هوشمند، به دنبال راه‌هایی توانمندتر و دقیق‌تر نسبت به روش‌های معمول برای شناخت و پیش‌بینی پارامترهای هیدرولوژیکی هستند. در این میان، شبکه‌های عصبی مصنوعی و فازی عصبی، ابزارهایی مناسب برای تخمین و پیش‌بینی بسیاری از این پارامترها هستند [۳].

در شبکه‌های عصبی^۱ و فازی-عصبی^۲، تعیین ساختار مناسب شبکه و انتخاب پارامترهای آنها اهمیت خاصی دارد. همچنین، موفقیت این شبکه‌ها تا حد زیادی به دقت و کارایی الگوریتم‌های یادگیری آنها بستگی دارد. برای یادگیری شبکه‌های عصبی، از الگوریتم‌های مختلفی استفاده می‌شود که پرکاربردترین آنها، الگوریتم‌های مبتنی بر گرادیان، به‌ویژه پس‌انتشار و حداقل مربعات است. هرچند این الگوریتم‌ها توانمندی زیادی دارند، اما وجود چند ضعف عمده در آنها، مشکلاتی را در برخی موارد برای کاربران ایجاد می‌کند. الگوریتم‌های مبتنی بر گرادیان از تکنیک جست‌وجوی محلی استفاده می‌کنند و از این‌رو، همواره در معرض گیرافتادن در نقاط بهینه محلی هستند. همچنین، الگوریتم‌هایی همانند لوبنبرگ-مارکورت^۳ (LM) پیچیدگی محاسباتی زیادی دارند [۴]. بنابراین، به‌کارگیری روش‌هایی به‌منظور حل مشکلات الگوریتم‌های مبتنی بر گرادیان، همواره مورد توجه محققان بوده است. از مناسب‌ترین روش‌های یادشده، استفاده از الگوریتم‌های تکاملی^۴ (EA) به‌منظور آموزش شبکه است. الگوریتم‌های

تکاملی، توانایی زیادی در انجام جست‌وجوی سراسری و پرهیز از قرارگرفتن در بهینه محلی دارند [۵ و ۶].

در چند سال گذشته، از الگوریتم‌های بهینه‌سازی برای بهبود عملکرد مدل‌های شبکه عصبی مصنوعی در پیش‌بینی پدیده‌های هیدرولوژیکی استفاده شده است. چنگ و همکارانش با استفاده از ترکیب الگوریتم هیبریدی ازدحام ذرات با رفتار کوانتومی و شبکه عصبی مصنوعی (ANN)، جریان ورودی روزانه سد هونگجیدو واقع در چین را پیش‌بینی کردند [۷]. جلال کمالی (۲۰۱۵) با استفاده از دو مدل ANFIS-PSO^۵ و ANFIS-GA^۶، به تخمین پارامترهای کیفی آب زیرزمینی دشت کرمان در جنوب شرقی اصفهان پرداخت. نتایج پژوهش ایشان بیان‌کننده عملکرد مناسب مدل‌های ارائه‌شده در مدل‌سازی کیفیت آب زیرزمینی بود [۸]. رضاپور تبری با استفاده از مدل هیبریدی فازی-عصبی و الگوریتم جست‌وجوی مستقیم به پیش‌بینی جریان در رودخانه طالقان در ایران پرداخت [۹]. نتایج پژوهش ایشان نشان داد الگوریتم مربوط به آن توانایی مناسبی در بهبود توانایی ANFIS برای مدل‌سازی جریان رودخانه داشت. بهمنش و محمدی با مدل عصبی بهبودیافته توسط الگوریتم رقابت استعماری، سری‌های زمانی آشوبناک را پیش‌بینی کردند. نتایج استفاده از این روش نشان‌دهنده کارایی مناسب سیستم استنتاج عصبی-فازی تطبیقی بهبودیافته در مقابله با مسائل پویا و همچنین توانایی آن در فرایند یادگیری پارامترها بود [۱۰]. در مطالعه‌ای دیگر، آزاد و همکارانش توانایی الگوریتم‌های تکامل تفاضلی به‌منظور بهبود توانایی ANFIS برای پیش‌بینی پارامترهای کیفی آب رودخانه را بررسی کردند. طبق گزارش آنها، الگوریتم یادشده توانایی مناسبی در بهبود توانایی ANFIS برای تخمین پارامترهای کیفی آب داشت [۱۱].

با توجه به اهمیت موضوع، در دهه اخیر در زمینه مدل‌سازی و پیش‌بینی دمای محیط نیز مطالعاتی با استفاده از هوش مصنوعی صورت گرفته است. صلاحی و همکارانش با استفاده از شبکه عصبی پرسپترون چندلایه (MLP) بیشترین دمای شهر اردبیل را پیش‌بینی کردند.

5. Adaptive neural fuzzy inference system-Genetic Algorithm
6. Adaptive neural fuzzy inference system-Particle swarm optimize

1. Neural Network
2. Neuro-Fuzzy Network
3. Levenberg-Markvt
4. Evolutionary Algorithms

به‌منظور انتخاب مناسب‌ترین ورودی به مدل‌ها؛ ۳. پیش‌بینی کوتاه‌مدت، میان‌مدت و بلندمدت بیشترین دمای ماهانه شهر اصفهان با استفاده از مدل‌های هیبریدی پیشنهادی؛ ۴. بررسی دقت و عملکرد مدل‌ها و معرفی مدل هیبریدی برتر.

مواد و روش‌ها

در تحقیق حاضر، از الگوریتم‌های تکاملی GA، ACO_R، PSO و DE برای آموزش ANFIS استفاده می‌شود. با این کار تلاش می‌شود برخی ضعف‌های الگوریتم‌های پیش‌فرض، همچون حجم محاسباتی زیاد و امکان به دام افتادن در بهینه محلی رفع شود. ابتدا، ساختارهای اولیه سیستم همچون تعیین درصد بخش‌های آموزش و واسنجی و تعیین برخی شاخص‌ها انجام می‌پذیرد. همچنین، برخی پارامترهای الگوریتم نظیر تعداد تکرار، تعداد جمعیت اولیه، میزان حد نهایی بهینه‌سازی، ضرایب الگوریتم‌ها نظیر آلفا و بتا، تابع هدف (در اینجا RMSE) و دیگر پارامترهای مربوط به الگوریتم تنظیم می‌شود. همچنین، در صورت نیاز داده‌ها نرمال‌سازی می‌شوند. در ادامه، الگوریتمی که به‌عنوان آموزش‌دهنده ANFIS انتخاب شده است، شروع به آموزش سیستم می‌کند. در واقع، این الگوریتم تلاش می‌کند تا مناسب‌ترین واریانس و میانگین را برای مدل‌سازی پیدا کند. به این صورت با استفاده از بهینه‌ترین مدل‌سازی انجام می‌شود. درخور یادآوری است که الگوریتم‌های موجود در ANFIS نیز دقیقاً همین کار را انجام می‌دهند، اما به برخی دلایل مطرح‌شده، این الگوریتم‌ها در برخی مسائل ضعیف‌تر عمل می‌کنند. پس از انجام آموزش، مراحل همانند ANFIS ساده ادامه می‌یابد تا مدل‌سازی سری زمانی بیشترین دمای شهر اصفهان به انتها برسد. سپس، دقت مدل‌های ارائه‌شده با استفاده از شاخص‌های آماری R^2 ، RMSE و MAE بررسی می‌شود.

منطقه مطالعه‌شده و پایگاه داده

شهر اصفهان در طول جغرافیایی ۵۱ درجه و ۳۹ دقیقه و ۴۰ ثانیه شرقی و عرض جغرافیایی ۳۲ درجه و ۳۸ دقیقه و ۳۰ ثانیه شمالی واقع شده است [۱۹]. این شهر با بیش از ۱۷۵۰ هزار نفر جمعیت و مساحتی حدود ۴۰۰ کیلومتر مربع، به‌عنوان مرکز استان اصفهان و یکی از

نتایج پژوهش آنها بیان‌کننده عملکرد مناسب مدل یادشده در پیش‌بینی بیشترین دمای هوا بود [۱۲]. تکتاز با استفاده از مدل‌های ANFIS و ARIMA^۱ بیشترین دمای ترکیه را پیش‌بینی کرد. نتایج پژوهش ایشان نشان‌دهنده عملکرد مناسب ANFIS بود [۱۳]. قربانی و همکارانش از سه مدل ANFIS، ANN و Genetic Programming (GP) برای پیش‌بینی بیشترین، کمترین و میانگین دمای هوای شهر تبریز استفاده کردند. نتایج تحقیقات آنها بیان‌کننده عملکرد مناسب و دقت زیاد مدل‌ها در پیش‌بینی دما بود [۱۴]. کیسی و همکارانش با استفاده از مدل‌های ANFIS، GRNN^۲ و KSOFM^۳، دمای نقطه شبنم را پیش‌بینی کردند. نتایج تحقیق آنها بیان‌کننده عملکرد مناسب‌تر ANFIS برای مدل‌سازی دما بود [۱۵]. دانشمند و همکارانش با استفاده از ANFIS دمای شهر مشهد را مدل‌سازی کردند. نتایج مطالعات آنها نشان داد سیستم عصبی-فازی در تحلیل حجم زیاد داده‌ها، عملکرد قابل قبولی دارد [۱۶]. محمدی و همکارانش با استفاده از ANFIS، دمای روزانه نقطه شبنم در دو شهر ایران را پیش‌بینی کردند. نتایج پژوهش آنها بیان‌کننده عملکرد مناسب ANFIS بود [۱۷]. کیسی و ثانی‌خانی با استفاده از داده‌های جغرافیایی، به پیش‌بینی بلندمدت ماهانه دمای ایران در ۵۰ ایستگاه با استفاده از مدل‌های هوش مصنوعی پرداختند. طبق گزارش ایشان، ANFIS عملکرد مناسبی در تخمین دمای هوا در دوره‌های بلندمدت داشت [۱۸].

در پژوهش حاضر، بهبود کارایی و قابلیت مدل ANFIS، از طریق هیبرید آن با برخی الگوریتم‌های بهینه‌سازی بررسی و تحلیل می‌شود. به‌عنوان مطالعه موردی، دمای شهر اصفهان در یک دوره ۶۴ ساله، شبیه‌سازی و پیش‌بینی می‌شود. به این منظور، چهار هدف عمده ذیل دنبال می‌شود: ۱. استفاده از الگوریتم‌های ژنتیک (GA)، ازدحام ذرات (PSO)، کلونی مورچگان برای محیط‌های پیوسته^۴ (ACO_R) و تکامل تفاضلی^۵ (DE) به‌عنوان جایگزینی برای الگوریتم‌های آموزش مدل ANFIS؛ ۲. آنالیز حساسیت داده‌های ورودی مدل‌ها

1. Autoregressive integrated moving average
2. Generalized regression neural networks model
3. Kohonen self-organizing feature maps neural networks model
4. Ant colony for continuous domains
5. Differential evolution

در جدول ۱، اطلاعات آماری مربوط به دما و بارش در منطقه مطالعه شده در بازه زمانی ۱۳۳۰ تا ۱۳۹۳ آورده شده است. داده‌های هواشناسی استفاده شده در پژوهش حاضر، از سایت سازمان هواشناسی کشور به آدرس اینترنتی (WWW.irimo.ir) دریافت شده است.

کلان‌شهرهای ایران است. اصفهان اقلیمی کوهپایه‌ای دارد و تغییرات میانگین دمای آن بین پنج تا ۴۰ درجه سانتی‌گراد است. در چند سال گذشته به دلیل خشکسالی‌های اخیر و به دنبال آن خشک شدن رودخانه زاینده‌رود، اقلیم اصفهان در حال تغییر از کوهپایه‌ای به سمت خشک و بیابانی است.

جدول ۱. اطلاعات آماری دما و بارش در منطقه مطالعه شده

کمترین دمای ماهانه	متوسط دمای ماهانه	بیشترین دمای ماهانه	میانگین بارش سالانه	انحراف از معیار بیشترین دما	ضریب چولگی بیشترین دما
-۱۰	۷/۲	۴۱	۱۳۸	۹/۳۳	-۰/۲۳
-۱۳	۷/۹	۴۲	۹۳	۹/۱۷	-۰/۲۷
-۱۱	۸/۱	۴۳	۱۰۹	۱۰/۲۷	-۰/۳۶
-۱۲	۸/۲	۴۱	۱۳۷	۹/۶۷	-۰/۲۶
-۱۱	۸/۰۱	۴۲	۱۰۹	۹/۵۲	-۰/۱۸
-۱۳	۸/۲۹	۴۳	۱۳۹	۹/۱۶	-۰/۲۷

اساسی ارزش‌دهی، جهش، تقاطع یا بازترکیبی و در نهایت انتخاب گزینه بهینه است [۲۳]. فاکتورهای الگوریتم از جمله تعداد تکرارها، جمعیت اولیه، درصد Crossover و جهش به ترتیب ۱۰۰۰، ۱۰۰، ۰/۹ و ۰/۱ انتخاب شدند. اعداد گزارش شده ارقام با بهترین عملکرد هستند.

الگوریتم ژنتیک (GA)

اصول بنیادی الگوریتم ژنتیک نخستین بار توسط هالند در سال ۱۹۷۵ در دانشگاه میشیگان ابداع شد [۲۴]. مؤلفه اصلی الگوریتم، کروموزوم است که یک راه حل در فضای جست‌وجوی مسئله بهینه‌سازی را نشان می‌دهد. هر کروموزوم از ژن‌ها تشکیل یافته است که هر کدام یک پارامتر از مسئله را تشریح می‌کند [۲۵]. جست‌وجو با یک جمعیت اولیه از رشته‌ها شروع می‌شود و در هر تکرار رشته‌های منحصربه‌فرد مطابق با شرط کارایی ارزیابی می‌شوند و یک مقدار تناسب به آنها تخصیص داده می‌شود.

انتخاب، عملی است که در آن کروموزوم‌های نسل بعدی از جمعیت فعلی بر اساس قانون بقای نسل تعیین می‌شوند. این عمل مهم‌ترین مرحله در الگوریتم ژنتیک است و کارکرد بسیار مهمی در این فرایند دارد. روش عمومی انتخاب کروموزوم، تعیین احتمال انتخاب آنها بر اساس مقدار تابع هدف است. به این منظور، تعدادی عدد تصادفی تولید شده و با احتمال تجمعی آن مقایسه می‌شود. فاکتورهای الگوریتم از جمله تعداد تکرارها،

سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)

نظریه مجموعه فازی، توسط زاده در سال ۱۹۶۵ در دانشگاه برکلی آمریکا ارائه شد [۲۰]. این نظریه قادر است بسیاری از مفاهیم و متغیرها و سیستم‌هایی را که پیچیده و مبهم هستند، صورت‌بندی ریاضی بخشد و زمینه را برای استدلال، استنتاج، کنترل و تصمیم‌گیری در شرایط عدم اطمینان فراهم آورد. سیستم استنتاج فازی-عصبی تطبیقی از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند. این سیستم نخستین بار توسط جانگ در سال ۱۹۹۳ ارائه شد [۲۱].

الگوریتم تکامل تفاضلی (DE)

الگوریتم تکامل تفاضلی روشی در حوزه محاسبات تکاملی است که به یافتن پاسخ بهینه مسائل مختلف بهینه‌سازی می‌پردازد. این الگوریتم توسط استورن و پرایس در سال ۱۹۹۵ معرفی شد [۲۲]. الگوریتم مد نظر با استفاده از یک سری پاسخ پیشنهادی آغاز به کار می‌کند و طی یک سری تکرارهای متوالی سعی دارد که بهترین پاسخ را برای مسئله بهینه‌سازی پیدا کند. مهم‌ترین ویژگی الگوریتم DE، سرعت زیاد، سادگی و قدرتمند بودن آن است. این الگوریتم فقط با تنظیم سه پارامتر شامل NP اندازه جمعیت، F وزن جهش و CR احتمال انجام بازترکیبی یا تقاطع شروع به کار می‌کند. الگوریتم یادشده چهار مرحله

می‌تواند رسیدن به بیشینه تعداد نسل‌ها یا رسیدن به یک مقدار خاص شایستگی باشد.

$$V_i(t+1) = WV_i(t) + C_1 r_{v,i}(t)(p_i(t) - X_i(t)) \quad (4)$$

$$+ C_2 r_{v,i}(t)(p_g(t) - X_i(t))$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (5)$$

فاکتورهای الگوریتم شامل تکرارها، جمعیت اولیه، بهترین تجربه شخصی و گروهی به ترتیب ۱۰۰۰، ۱۰۰، ۲ و ۲ انتخاب شدند. اعداد گزارش شده ارقام با بهترین عملکرد هستند.

الگوریتم کلونی مورچگان پیوسته (ACO_R)

این الگوریتم برای نخستین بار توسط دوریگو در سال ۱۹۹۲ به‌عنوان ابزاری برای حل مسائل مشکل بهینه‌یابی مانند مسئله فروشنده دوره‌گرد ارائه شد [۲۸]. الگوریتم یادشده از رفتار جست‌وجوی غذای برخی گونه‌های مورچه در طبیعت الهام گرفته شده است [۲۹]. ایده اصلی روش کلونی مورچگان پیوسته استفاده از یک توزیع احتمال پیوسته با استفاده از یک تابع چگالی احتمال، به‌جای استفاده از یک توزیع احتمال گسسته است. به این منظور، الگوریتم، تابع گوسی را به کار می‌گیرد، اما یک تابع گوسی به‌تنهایی نمی‌تواند دو نقطه از فضا را، که نامزد بهینه بودن هستند، نشان دهد. بنابراین، دوریگو یک کرنل گوسی را که مجموع وزن‌دار از چندین تابع گوسی واحد است تعریف کرده و آن را با $G(x)$ نشان داد.

$$G_{(x)}^i = \sum_{l=1}^n W_l g_l^i(x) = \sum_{l=1}^n W_l \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu_l^i)^2}{2(\sigma_l^i)^2}} \quad (6)$$

تابع گوسی $G_{(x)}^i$ با سه بردار از پارامترهای W بردار وزن‌ها، μ^2 بردار میانگین و σ^2 بردار انحراف به ترتیب مطابق روابط ۷-۹ مشخص می‌شود.

$$\mu^i = \{ \mu_1^i, \dots, \mu_l^i \} = \{ S_1^i, \dots, S_l^i \} \quad (7)$$

$$W_L = \frac{1}{qn\sqrt{2\pi}} e^{-\frac{(l-1)^2}{2q^2n}} \quad (8)$$

$$\sigma_l^i = \xi \sum_{e=1}^n \frac{|S_e^i - S_l^i|}{n-1} \quad (9)$$

جمعیت اولیه، درصد Crossover و جهش به ترتیب ۵۰۰، ۶۰، ۰/۸ و ۰/۳ انتخاب شدند.

الگوریتم ازدحام ذرات (PSO)

الگوریتم بهینه‌سازی ازدحام ذرات توسط ابره‌ارت و کندی در سال ۱۹۹۵ پیشنهاد شد [۲۶]. این الگوریتم تا کنون به‌طور موفقیت‌آمیزی در بسیاری از علوم استفاده شده است. الگوریتم ازدحام ذرات تکاملی با تقلید از پرواز پرندگان یا حرکات ماهیان و تبادل اطلاعات میان آنها ابداع شده است. در این الگوریتم هر راه‌حل فقط یک ذره در فضای جست‌وجوست. همه ذره‌ها یک مقدار شایستگی دارند که توسط تابع شایستگی که باید بهینه شود، ارزیابی می‌شود. افزون بر این، هر ذره t یک موقعیت X در فضای d بعدی مسئله دارد که در تکرار t ام، با رابطه ۱ نمایش داده می‌شود. این ذره سرعت V دارد که حرکت آن را هدایت می‌کند و در تکرار t ام با رابطه ۲ نشان داده می‌شود. سپس، ذره برای تثبیت بهترین موقعیت پیشین خود در هر تکرار از حافظه‌ای با عنوان بردار P در رابطه ۳ استفاده می‌کند.

$$X_i^t = (x_{i1}^t, x_{i2}^t, \dots, x_{id}^t) \quad (1)$$

$$V_i^t = (v_{i1}^t, v_{i2}^t, \dots, v_{id}^t) \quad (2)$$

$$P_i^t = (p_{i1}^t, p_{i2}^t, \dots, p_{id}^t) \quad (3)$$

در هر تکرار جست‌وجو، هر ذره با در نظر داشتن دو مقدار بهترین به‌روزرسانی می‌شود. نخستین مقدار مربوط به بهترین راه‌حلی است که ذره تا کنون آن را تجربه کرده است. این مقدار را به‌اصطلاح بهترین می‌نامند. دومین بهترین که توسط الگوریتم بهینه‌سازی ازدحام ذرات دنبال می‌شود، بهترین موقعیتی است که تا کنون در جمعیت به‌دست آمده است [۲۷]. این مقدار بهینه عمومی است که به‌اصطلاح مناسب‌ترین g نامیده می‌شود. پس از اینکه این دو مقدار پیدا شد، سرعت و موقعیت هر ذره توسط روابط ۴ و ۵ به‌روزرسانی می‌شود. در روابط ۴ و ۵، t بیان‌کننده شماره تکرار، و متغیرهای $C1$ و $C2$ عامل‌های یادگیری است. اغلب $C1 = C2 = 2$ است که میزان جابه‌جایی یک‌ذره را در یک‌بار تکرار کنترل می‌کند. $r1$ و $r2$ دو عدد تصادفی یکنواخت در بازه یک و صفر است. پارامتر w نشان‌دهنده وزن اینرسی است که در بازه یک و صفر مقدار اولیه می‌گیرد. شرط خاتمه

تکرارها، جمعیت اولیه، آلفا و بتا به ترتیب ۳۰۰، ۰.۴۵، ۲ و ۱ انتخاب شدند. این اعداد بهترین عملکرد را داشته‌اند.

معیارهای ارزیابی دقت و خطای مدل سازی

عملکرد هر یک از مدل‌های ارائه شده با استفاده از شاخص‌های آماری R^2 ، RMSE و MAE مطابق روابط ۱۰-۱۲ ارزیابی می‌شود.

$$R^2 = \left[\frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \right]^2 \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (11)$$

$$MAE = \left(\frac{\sum_{i=1}^n |x_i - y_i|}{n} \right) \quad (12)$$

چشم‌اندازهای مختلف انتخاب شد (جدول ۲). به منظور تعیین برترین ورودی برای پیش‌بینی بیشترین دمای اصفهان در چشم‌اندازهای یک ماه و یک، دو و سه سال، داده‌ها به ترتیب در چهار گروه اصلی (A, B, C و D) قرار گرفتند. همچنین، هر گروه به شش زیرگروه تقسیم شد. به طور مثال، برای پیش‌بینی در چشم‌انداز یک سال (B)، در زیرگروه نخست (B1)، دما با تأخیر ۱۲ و ۱۳ ماه قرار داده شد. سپس، با بالا رفتن عدد زیرگروه (B2, B3, B4, ...)، هر بار دما با یک ماه تأخیر بیشتر، به زیرگروه قبلی اضافه می‌شود، به صورتی که A6 تأخیری بین ۱۲ تا ۱۸ دارد. در ادامه، با استفاده از گروه‌های موجود، بیشترین دمای هریک از چشم‌اندازها پیش‌بینی شد. درخور یادآوری است که دلیل استفاده کردن از شش زیرگروه این موضوع بوده که گروه‌های با بیش از هفت ماه تأخیر نتایجی مشابه و یا ضعیف‌تر از گروه‌های قبلی داشتند که نتایج آنها در مقاله حاضر آورده نشده است.

با توجه به نتایج، در چشم‌انداز پیش‌بینی یک ماه و یک سال، به ترتیب A3 و B2 به عنوان بهترین ورودی برای مدل‌سازی افق‌های یاد شده انتخاب شدند. در ادامه، برای افق‌های دو و سه سال نیز، C2 و D3 با بهترین عملکرد، به عنوان ورودی‌های برتر برای پیش‌بینی چشم‌اندازهای دو و سه سال معرفی شدند.

در روابط یاد شده، بردار واریانس $\sigma_n^i = q_n$ است. برای این بردار فرض می‌شود یک مورچه، یکی از راه‌حل‌های موجود در آرشیو را بر اساس یک فرایند احتمالی مانند چرخه رولت انتخاب می‌کند [۳۰]. بنابراین، راه‌حلی که رتبه بالاتری دارد، شانس بیشتری برای انتخاب شدن توسط مورچه‌ها را خواهد داشت. ضرایب الگوریتم شامل تعداد

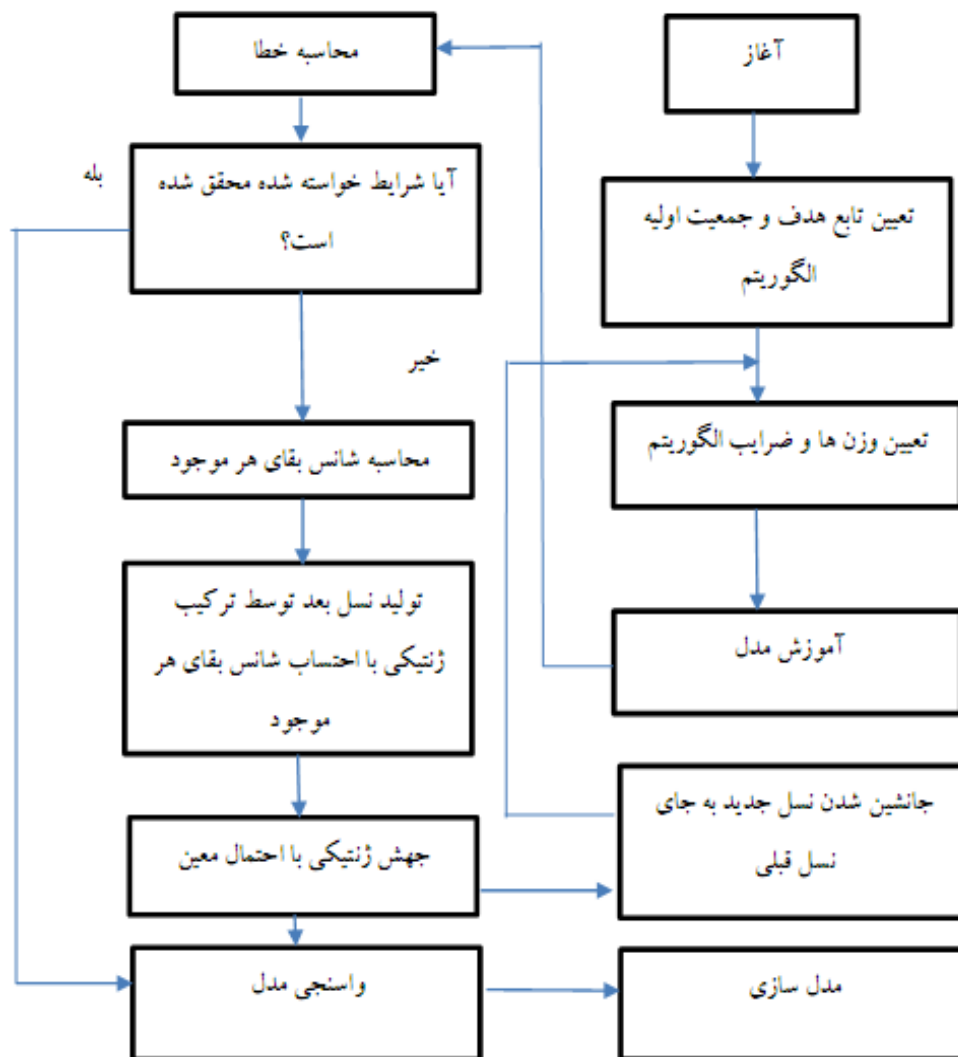
در روابط ۱۰ تا ۱۲، \bar{x} و \bar{y} مقادیر مشاهده شده و میانگین آنها و X و Y مقادیر پیش‌بینی شده و میانگین آنها توسط مدل‌هاست.

نتایج و بحث

از میان الگوریتم‌های هیبریدی ارائه شده در تحقیق حاضر، به عنوان نمونه مراحل عملکرد الگوریتم ANFIS-GA در شکل ۱ آورده شده است. در این پژوهش از داده‌های موجود، ۷۰ درصد برای آموزش و ۳۰ درصد برای تست استفاده شد. تعداد اپوچ ANFIS ساده و تعداد تکرار الگوریتم‌های ارائه شده نیز ۵۰۰ بوده است. درخور یادآوری است که ۵۰۰، تعداد بهینه تکرار برای همه مدل‌ها است و با بالاتر بردن تعداد تکرارها عملکرد مدل‌ها تأثیر شایان توجهی نداشته‌اند. همچنین، درباره ضرایب مربوط به الگوریتم‌ها، میزان بهینه آنها به صورت سعی و خطا به دست آمده و مناسب‌ترین آنها استفاده شده است. شایان یادآوری است برای نتایج ANFIS ساده، مدل‌سازی با استفاده از سیستم‌های مختلف انجام شده و نتایج ارائه شده، مربوط به مناسب‌ترین عملکردهاست.

آنالیز حساسیت

در تحقیق حاضر، با استفاده از آنالیز حساسیت، بهترین داده‌های ورودی برای پیش‌بینی بیشترین دما در



شکل ۱. مراحل پیش‌بینی بیشترین دمای اصفهان به وسیله مدل ANFIS-GA

جدول ۲. آنالیز حساسیت پیش‌بینی بیشترین دما

گروه‌ها	زیرگروه‌ها	شاخص‌های ارزیابی			گروه‌ها	زیرگروه‌ها	شاخص‌های ارزیابی		
		R ²	RMSE	MAE			R ²	RMSE	MAE
A1	T _{t-1} , T _{t-2}	۰/۹۲	۱/۲۴	۱/۹۴	C1	T _{t-24} , T _{t-25}	۰/۸۲	۱/۵۱	۲/۷۷
A 2	F1+ T _{t-3}	۰/۹۴	۱/۵۶	۱/۵۹	C 2	H1+ T _{t-26}	۰/۸۴	۱/۴۷	۲/۶۴
A 3	F2+ T _{t-4}	۰/۹۴	۱/۰۹	۱/۴۵	C 3	H2+ T _{t-27}	۰/۸۴	۱/۴۵	۲/۷۹
A 4	F3+ T _{t-5}	۰/۹۳	۱/۱۹	۱/۶۶	C 4	H3+ T _{t-28}	۰/۸۰	۱/۵۱	۲/۷۳
A 5	F4+ T _{t-6}	۰/۹۵	۱/۱۱	۱/۴۶	C 5	H4+ T _{t-29}	۰/۸۲	۱/۴۹	۲/۶۹
A 6	F5+ T _{t-7}	۰/۸۹	۱/۳۹	۲/۲۸	C 6	H5+ T _{t-30}	۰/۷۴	۱/۵۸	۳/۰۹
B1	T _{t-12} , T _{t-13}	۰/۸۹	۱/۳۹	۲/۲۸	D1	T _{t-36} , T _{t-37}	۰/۷۳	۱/۷۸	۳/۴۲
B 2	G1+ T _{t-14}	۰/۹۲	۱/۲۵	۲/۰۸	D 2	I1+ T _{t-38}	۰/۸۰	۱/۶۹	۳/۳۴
B 3	G2+ T _{t-15}	۰/۹۱	۱/۲۹	۲/۰۴	D 3	I2+ T _{t-39}	۰/۷۹	۱/۶۱	۳/۱۱
B 4	G3+ T _{t-16}	۰/۹۰	۱/۲۸	۲/۰۰	D 4	I3+ T _{t-40}	۰/۷۷	۱/۶۵	۳/۲۶
B 5	G4+ T _{t-17}	۰/۹۱	۱/۶۵	۲/۱۲	D 5	I4+ T _{t-41}	۰/۷۵	۱/۶۷	۳/۳۱
B 6	G5+ T _{t-18}	۰/۸۹	۱/۳۳	۲/۱۳	D 6	I5+ T _{t-42}	۰/۷۶	۱/۶۶	۳/۳۳

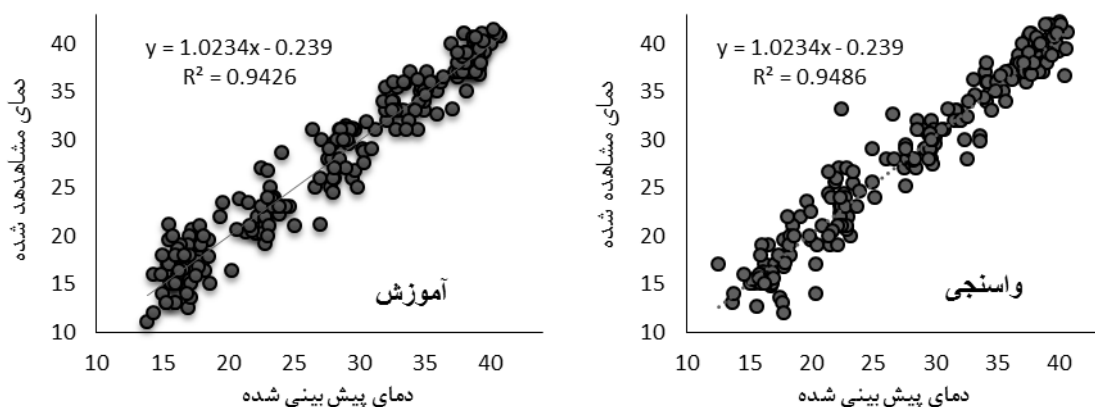
درخور یادآوری است که در قسمت آموزش، شرایط تقریباً به صورت معکوس بود. در این قسمت، ANFIS با مناسب‌ترین R^2 و کمترین RMSE و MAE در رتبه نخست قرار گرفت. این موضوع در حالی است که نتایج مدل‌های ترکیبی ارائه شده، در هر دو بخش آموزش و صحت‌سنجی بسیار به یکدیگر نزدیک است. بنابراین، مدل ANFIS آموزشی ضعیف‌تر نسبت به مدل‌های ترکیبی دارد. این موضوع با نتایج باقی مطالعات درباره بهبود عملکرد مدل‌های هوشمند به وسیله الگوریتم‌های فراابتکاری مطابقت دارد. به طور نمونه، جلال کمالی [۸] و رضایور تبری [۹] گزارش دادند که مدل‌های ترکیبی ارائه شده، عملکردی بهتر از مدل‌های معمولی قبلی داشتند. عملکرد مقایسه‌ای مناسب‌ترین مدل (ANFIS-GA) در دو بخش آموزش و صحت‌سنجی در شکل ۲ آورده شده است.

پیش‌بینی بیشترین دمای اصفهان در افق‌های زمانی مختلف افق پیش‌بینی یک ماه

برای پیش‌بینی بیشترین دمای شهر اصفهان در افق یک ماه، پس از انجام آنالیز حساسیت و یافتن مناسب‌ترین داده برای ورودی مدل‌ها، پیش‌بینی با پنج مدل (ANFIS-PSO، ANFIS-GA، ANFIS-ACO_R، ANFIS-DE و ANFIS) انجام شد. نتایج مدل‌ها در افق پیش‌بینی یک ماه در جدول ۳ آورده شده است. در این افق پیش‌بینی، در مرحله صحت‌سنجی مدل ANFIS-GA با R^2 ، RMSE و MAE به ترتیب برابر ۰/۹۴ و ۱/۱۱ و ۱/۵۲ با وجود R^2 برابر با ANFIS-DE اما به دلیل خطای کمتر در رتبه نخست قرار گرفت. سپس، ANFIS-ACO_R و ANFIS-PSO با اختلاف اندک به نسبت به باقی مدل‌ها، در رتبه‌های سوم و چهارم قرار گرفتند. در انتها، نیز ANFIS با کمترین R^2 و بیشترین میزان خطا در رتبه آخر قرار گرفت.

جدول ۳. مقایسه عملکرد مدل‌ها در پیش‌بینی افق یک ماه

مدل‌ها	شاخص‌های ارزیابی					
	R^2		RMSE		MAE	
	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی
ANFIS	۰/۹۷	۰/۸۸	۱/۰۶	۱/۲۰	۱/۳۸	۱/۷۲
ANFIS-ACO _R	۰/۹۳	۰/۹۳	۱/۱۰	۱/۱۸	۱/۴۷	۱/۷۲
ANFIS-GA	۰/۹۴	۰/۹۴	۱/۱۵	۱/۱۱	۱/۵۶	۱/۵۲
ANFIS-DE	۰/۹۳	۰/۹۴	۱/۱۰	۱/۱۲	۱/۵۶	۱/۵۴
ANFIS-PSO	۰/۹۴	۰/۹۳	۱/۰۹	۱/۱۷	۱/۴۴	۱/۷۰



شکل ۲. ضریب تبیین مناسب‌ترین مدل (ANFIS-GA) در پیش‌بینی دمای یک ماه آینده



بازه زمانی یک سال، نشان‌دهنده قابلیت مناسب این مدل‌ها در تخمین نقاط حداقل و حداکثر سری زمانی است. از سوی دیگر، در بخش آموزش نیز همانند افق پیش‌بینی یک ماه، ANFIS با R^2 ، RMSE و MAE به ترتیب ۰/۹۵، ۱/۱۸ و ۲/۰۹ در رتبه نخست قرار دارد. نزدیک‌ترین نتایج به ANFIS مربوط به ANFIS-PSO با اختلاف به ترتیب ۰/۹۱، ۱/۲۳ و ۲/۱۱ برای R^2 ، RMSE و MAE است. درخور یادآوری است که اختلاف زیاد نتایج ANFIS در دو بخش آموزش و صحت‌سنجی، می‌تواند نشان‌دهنده نبود آموزش صحیح در این مدل باشد.

افق پیش‌بینی یک سال

مقایسه عملکرد مدل‌های ارائه‌شده در پیش‌بینی دما در یک سال آینده در جدول ۴ نشان داده شده است. در افق پیش‌بینی یک‌ساله نیز همه مدل‌ها توانستند عملکرد ANFIS را بهبود دهند. در این بازه زمانی نیز ANFIS-GA با R^2 ، RMSE و MAE به ترتیب ۰/۹۰، ۱/۳۲ و ۲/۰۷ در رتبه نخست قرار گرفت. سپس ANFIS-DE، ANFIS-ACO_R و ANFIS-PSO به ترتیب در رتبه‌های بعدی قرار گرفتند. در شکل ۳ اسکاتر مدل برتر (ANFIS-GA) آورده شده است. درخور یادآوری است که R^2 مناسب نمونه‌های ارائه‌شده در

جدول ۴. عملکرد مدل‌های ارائه‌شده در پیش‌بینی دما در یک سال

مدل‌ها	شاخص‌های ارزیابی					
	R^2		RMSE		MAE	
	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی
ANFIS	۰/۹۵	۰/۸۴	۱/۱۸	۱/۴۱	۲/۰۹	۲/۴۹
ANFIS-ACO _R	۰/۸۹	۰/۸۹	۱/۳۲	۱/۳۲	۲/۷۶	۲/۰۹
ANFIS-GA	۰/۹۰	۰/۹۰	۱/۳۰	۱/۳۲	۲/۱۳	۲/۰۷
ANFIS-DE	۰/۸۹	۰/۸۹	۱/۳۶	۱/۲۹	۲/۵۰	۲/۱
ANFIS-PSO	۰/۹۱	۰/۸۸	۱/۲۳	۱/۳۸	۲/۱۱	۲/۲



شکل ۳. ضریب تبیین مناسب‌ترین مدل (ANFIS-GA) در پیش‌بینی دمای یک سال آینده

($R^2=0.84$, $RMSE=1.46$, and $MAE=2.57$) در رتبه دوم قرار گرفت. در ادامه، دو مدل ANFIS-PSO و ANFIS-DE در رتبه‌های چهارم و پنجم قرار گرفتند. در انتها، نیز همانند بازه‌های زمانی قبلی، ANFIS با ضعیف‌ترین نتایج در رتبه آخر قرار گرفت. اسکاتر مدل برتر در شکل ۴ آورده شده است. درخور یادآوری است که R^2 پایین ANFIS می‌تواند به دلیل به دام افتادن در بهینه محلی باشد. از سوی دیگر، در بخش

افق پیش‌بینی دو سال

مدل‌های ترکیبی در این حالت از پیش‌بینی نیز عملکرد به نسبت خوبی داشتند، به صورتی که متوسط R^2 ، RMSE و MAE به ترتیب ۰/۸۳، ۱/۵۰ و ۲/۷۳ بود. در بخش صحت‌سنجی این افق پیش‌بینی، ANFIS-GA با R^2 ، RMSE و MAE به ترتیب ۰/۸۴، ۱/۴۴ و ۲/۵۷ مناسب‌ترین مدل در این قسمت بود. سپس، ANFIS-ACO_R با کمی اختلاف

صورتی که پس از ANFIS-DE، ANFIS-GA، ANFIS-ACO_R و MAE و R² برابر با ANFIS-ACO_R، اما به دلیل R² و MAE مناسب‌تر، در جایگاه دوم قرار گرفت. پس از آنها نیز ANFIS-PSO و ANFIS در رتبه‌های چهارم و پنجم قرار گرفتند. در شکل ۵ تغییرات ضریب تبیین بهترین مدل آورده شده است. از سوی دیگر، در بخش آموزش، ANFIS با بیشترین R² و کمترین میزان خطا، همانند افق‌های پیش‌بینی قبلی در رتبه اول قرار گرفت. این تفاوت عملکرد دو بخش آموزش و صحت‌سنجی، مطابق دلایل مطرح‌شده در قسمت‌های قبل، می‌تواند نشان‌دهنده ضعف ANFIS در مدل‌سازی مناسب سری زمانی باشد. درخور توجه آنکه عملکرد مدل‌های پیشنهادی تا افق سه سال، دارای نتایج قابل قبول بود و قابلیت آنها با افزایش افق پیش‌بینی به بیشتر از سه سال، کاهش می‌یابد.



آموزش، ANFIS و ANFIS-PSO با اختلاف بسیار اندکی در رتبه‌های اول و دوم قرار گرفتند. سپس، ANFIS-GA و ANFIS-DE با عملکردی کاملاً یکسان، به طور مشترک در رتبه سوم قرار گرفتند. ANFIS-ACO_R نیز با ضعیف‌ترین عملکرد در رتبه آخر قرار گرفت (جدول ۵).

افق پیش‌بینی سه سال

در پیش‌بینی بیشترین دمای شهر اصفهان با افق سه سال، عملکرد مدل‌های استفاده‌شده ضعیف‌تر از بازه‌های زمانی قبلی بود (جدول ۶). به صورتی که در این افق پیش‌بینی، میانگین R² در بخش صحت‌سنجی از ۰/۹۴ در افق یک ماه، به ۰/۷۵ و RMSE و MAE نیز به ۱/۷۹ و ۳/۷ رسیده بود. در این قسمت، مدل ANFIS-GA، با R²، RMSE و MAE به ترتیب ۰/۸۲، ۱/۵۸ و ۲/۹۶ در رتبه نخست قرار گرفت. درخور یادآوری است که تفاوت عملکرد بهترین مدل و میانگین مدل‌ها در این قسمت بسیار اندک بود، به

جدول ۵. عملکرد مدل‌های ارائه‌شده در پیش‌بینی دما در دو سال



مدل‌ها	شاخص‌های ارزیابی					
	R ²		RMSE		MAE	
	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی
ANFIS	۰/۸۵	۰/۷۶	۱/۳۹	۱/۶۰	۱/۴۲	۳/۱۶
ANFIS-ACO _R	۰/۸۳	۰/۸۴	۱/۵۲	۱/۴۶	۱/۵۲	۲/۶۸
ANFIS-GA	۰/۸۳	۰/۸۴	۱/۴۴	۱/۴۴	۱/۴۴	۲/۵۷
ANFIS-DE	۰/۸۴	۰/۸۱	۱/۴۴	۱/۵۹	۱/۴۴	۳/۰۶
ANFIS-PSO	۰/۸۵	۰/۸۲	۱/۴۳	۱/۴۹	۱/۴۳	۲/۷۴



شکل ۴. ضریب تبیین مناسب‌ترین مدل (ANFIS-GA) در پیش‌بینی دمای دو سال آینده

جدول ۶. عملکرد مدل‌های ارائه‌شده در پیش‌بینی دما در سه سال

مدل‌ها	شاخص‌های ارزیابی					
	R^2		RMSE		MAE	
	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی
ANFIS	۰/۸۴	۰/۷۰	۱/۵	۱/۶۸	۲/۵۸	۳/۲۹
ANFIS-ACOR	۰/۷۷	۰/۷۸	۱/۶۸	۱/۶۱	۳/۱۵	۳/۱۶
ANFIS-GA	۰/۷۷	۰/۸۲	۱/۶۶	۱/۵۸	۳/۲۱	۲/۹۶
ANFIS-DE	۰/۷۷	۰/۷۹	۱/۶۴	۱/۶۱	۳/۱۷	۳/۱۴
ANFIS-PSO	۰/۷۷	۰/۷۵	۱/۶۱	۱/۶۱	۲/۷۹	۳/۱۶



شکل ۵. ضریب تبیین مناسب‌ترین مدل (ANFIS-GA) در پیش‌بینی دمای سه سال آینده

نتیجه‌گیری

در سال‌های اخیر، رویکرد هیبرید شبکه‌های عصبی و فازی-عصبی با الگوریتم‌های تکاملی بهینه‌یاب، توجه بسیاری به خود جلب کرده است. الگوریتم‌های هیبریدی، توانایی زیادی در انجام جست‌وجوی سراسری و پرهیز از قرار گرفتن در بهینه‌ی محلی دارند. در این پژوهش از پنج مدل ANFIS-DE, ANFIS-GA, ANFIS-ACOR, ANFIS-PSO و ANFIS برای پیش‌بینی بلندمدت بیشترین دمای ماهانه شهر اصفهان در یک دوره آماری ۶۳ ساله (۱۳۳۰-۱۳۹۳) استفاده شده است. ابتدا با توجه به آنالیز حساسیت، ورودی‌های مناسب برای هریک از چشم‌اندازها (یک ماه، یک، دو و سه سال) انتخاب شدند. سپس، با استفاده از مدل‌های یادشده، پیش‌بینی برای هریک از چشم‌اندازها صورت گرفت. مهم‌ترین نتایج به‌دست‌آمده در پژوهش حاضر عبارت‌اند از:

۱. مدل‌های هیبریدی ارائه‌شده (ANFIS-PSO, ANFIS-ACOR, ANFIS-GA و ANFIS-DE)، عملکرد مناسبی در بهبود نتایج ANFIS برای پیش‌بینی دما داشتند.

۲. در بین مدل‌های هیبریدی پیشنهادی، مدل ANFIS-GA به‌صورت متوسط R^2 و RMSE مدل ANFIS را به ترتیب ۸/۳۰ و ۱۱ درصد بهبود بخشید و به عنوان مدل برتر شناخته شد.

۳. استفاده از آنالیز حساسیت روی داده‌ها به انتخاب مناسب‌ترین ورودی به مدل‌ها منجر شد. به گونه‌ای که در برخی از گام‌های پیش‌بینی، مقدار R^2 را تا ۳۰ درصد، RMSE را تا ۲۵ درصد و MAE را تا ۳۵ درصد بهبود بخشید.

۴. در افق یک‌ماهه، محدوده ضرایب تبیین سیستم‌های عصبی در بازه ۰/۹۳ تا ۰/۹۷ قرار گرفت. این در حالی است که در افق پیش‌بینی سه‌ساله، بیشترین و کمترین مقدار به‌دست‌آمده برای R^2 به ترتیب برابر با ۰/۸۴ و ۰/۷۷ است.

۵. میزان دقت مدل‌های هیبریدی، با افزایش افق پیش‌بینی کاهش یافته است. مدل ANFIS-GA که به عنوان مناسب‌ترین مدل در چشم‌انداز یک‌ماهه انتخاب شد، دارای RMSE و MAE به ترتیب برابر با ۱/۱۱ و ۱/۵۲ بود. در حالی که شاخص‌های یادشده در افق پیش‌بینی سه‌ساله، به ترتیب برابر با ۲/۹۶ و ۱/۵۸ شد.

منابع

- [1]. Asakareh H. ARIMA modeling of annual mean temperature of Tabriz city. *Geographical Research*. 2009; 47: 123-131.
- [2]. Benavides R, Montes F, Rubio A , Osoro K. Geostatistical modeling of air temperature in a mountainous region of northern Spain. *Agricultural and Forest Meteorology*. 2007; 146(3-4): 173-188.
- [3]. Jain AK. Mao J, Mohiuddin KM.. Artificial neural networks: A tutorial. *Computer, IEEE*. 1996: 31-44.
- [4]. Peyghami MR, Khanduzi R. Novel MLP neural network with hybrid tabu search algorithm. *Neural Network World*. 2013; 3(13): 255-270.
- [5]. Pousinho HMI, Mendes VMF, Catalão JPS. Hybrid PSO-ANFIS Approach for Short-Term Electricity Prices Prediction. In *Proceedings of the 2010 PES general meeting, Michigan*. 2010: 1-6.
- [6]. Sheikhan M, Mohammadi N. Time series prediction using PSO-optimized neural network and hybrid feature selection algorithm for IEEE load data. *Neural computing and applications*. 2013; 23(3-4): 1185-1194.
- [7]. Cheng CHT, Niu WJ, Feng ZK, Shen J, Chau KW. Daily Reservoir Runoff Forecasting Method Using Artificial Neural Network Based on Quantum-behaved Particle Swarm Optimization. *Water*. 2015; 7: 4232- 4246.
- [8]. Jalalkamali A. Using of hybrid fuzzy models to predict spatiotemporal groundwater quality parameters. *Earth Science Informatics*. 2015; 8(4): 885-894.
- [9]. Rezapour Tabari M M. Prediction of River Runoff Using Fuzzy Theory and Direct Search Optimization Algorithm Coupled Model. *Arabian Journal for Science and Engineering*. 2016; 41(10): 4039-4051.
- [10]. Behmanesh M, Mohammadi M. Adaptive Neuro-Fuzzy Inference System with Self-Feedback and Imperialist Competitive Learning Algorithm for Chaotic Time Series Prediction. *Journal of Computational Intelligence in Electrical Engineering*. 2016; 4(7): 13-30.
- [11]. Azad A, Karami H, Farzin S, Saeedian A, Kashi H, Sayyahi H. Prediction of water quality parameters using ANFIS optimized by intelligence algorithms (Case study: Gorganrood River). *KSCE Civil engineering Journal*. 2017; 1-8. DOI 10.1007/s12205-017-1703-6. [Persian]
- [12]. Salahi B, Hoseini SA, Shayeghi H, Sobhani B. Prediction of maximum temperatures using artificial neural network model. *Geographic research*. 2010; 25(3): 57-78. [Persian]
- [13]. Tektas M. Weather Forecasting Using ANFIS and ARIMA Models, A Case Study for Istanbul. *Environmental Research, Engineering and Management*. 2010; 51:5-10.
- [14]. Ghorbani MA, Kazemi H, Farsadizadeh D, Yousefi P. Prediction of Air Temperature Using Artificial Intelligent Methods. *Journal of Engineering and Applied Sciences*. 2012; 7(2): 134-142.
- [15]. Kisi O, Kim S, Shiri J. Estimation of dew point temperature using neuro-fuzzy and neural network techniques. *Theoretical and Applied Climatology*. 2013; 114(3-4): 365-373.
- [16]. Daneshmand H, Tavousi T, Khosravi M, Tavakkoli S. Modeling minimum temperature via adaptive 4 neuro-fuzzy inference system method based 5 on spectral analysis of climate indices. *Journal of the Saudi Society of Agricultural Sciences*. 2015; 14(1): 33-40.
- [17]. Mohammadi K, Shamsirband Sh, Tong CW, Arif M, Petkovic Ch. A new hybrid support vector machine-wavelet transform approach for estimation of horizontal global solar radiation. *Energy Conversion and Management*. 2015; 92: 162-171.
- [18]. Kisi O, Sanikhani H. Modelling long-term monthly temperatures by several data-driven methods using geographical inputs. *International Journal of Climatology*. 2015; DOI: 10.1002/joc.4249.
- [19]. Shafaghi S. *Geography of Isfahan*. 2nd ed. University of Esfahan. Esfahan. 2003. [Persian]
- [20]. Zadeh LA. Fuzzy sets. *Information and Control*. 1965; 8(3): 338-353.
- [21]. Jang JSR. ANFIS: Adaptive-network-based fuzzy inference system. *Systems, Man and Cybernetics, IEEE Transactions*. 1993; 23(3), 665-685.
- [22]. Storn R, Price K. *Differential Evolution-A Simple and Efficient Adaptive Scheme for Global Optimization over Continuous Spaces*. Technical report, International Computer Science, Berkeley. 1995.
- [23]. Dashti R, Sattari M T, Nourani V. Performance evaluation of differential evolution algorithm in optimum operating of Eleviyan single-reservoir dam system. *Journal of Protection of water and soil resources*. 2017; 6(3): 61-76.
- [24]. Holland JH. *Adaption in natural and artificial system*. The University of Michigan Press. 1975.

- [25]. Jaramillo J, Bhadury J, Batta R. On the use of genetic algorithms to solve location problems. *Computers & Operations Research*. 2002; 29: 761-779.
- [26]. Eberhart R, Kennedy J. A New Optimizer Using Particle Swarm Theory. *Sixth International Symposium on Micro Machine and Human Science*, IEEE. 1995.
- [27]. Golmakani H, Fazel M. Constrained Portfolio Selection using Particle Swarm Optimization. *Expert Systems with Applications*. 2011; 38: 8327-8335.
- [28]. Dorigo M. Optimization, Learning and Natural Algorithms. Ph.D Thesis. Dipartimento di Elettronica, Politecnico di Milano, Italy. 1992.
- [29]. Socha K, Dorigo M. Ant colony optimization for continuous domains. *European Journal of Operational Research*. 2008; 185: 1155-1173.
- [30]. Deb K A P, Agarwal S, Meyarivan T. A Fast Elitist Multi-Objective Genetic Algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*. 2000; 6: 182-197.