

مقایسه کارایی مدل‌های تلفیقی NN-ARX و ANFIS با GA-GT جهت تخمین تبخیر روزانه از تشت در شرایط اقلیمی خشک و گرم بلوچستان

جابر سلطانی^{*۱} - علیرضا مقدم نیا^۲ - جمشید پیری^۳ - جواد میرمراذهی^۴

تاریخ دریافت: ۱۳۹۱/۷/۸

تاریخ پذیرش: ۱۳۹۱/۱۰/۱۹

چکیده

امروزه تخمین صحیح تبخیر به عنوان یکی از عناصر مهم چرخه هیدرولوژی، نقش مهمی را در توسعه پایدار و مدیریت بهینه منابع آب کشورهای مواجه با بحران آب می‌تواند ایفاء کند. تاکنون روش‌ها و فرمول‌های تجربی فراوانی در زمینه برآورد فرایند غیر خطی و پیچیده تبخیر روزانه از تشت ارائه شده که با عدم قطعیت می‌باشد و از دقت بالایی برخوردار نبوده و همچنین دسترسی به تمام پارامترهای ورودی آنها مشکل و یا اندازه‌گیری آنها محتاج صرف هزینه و زمان زیادی می‌باشند. در این تحقیق کارایی دو مدل غیر خطی NN-ARX و ANFIS جهت برآورد تبخیر روزانه از تشت در شرایط اقلیمی خشک و گرم (ایران‌شهر)، خشک و گرم ساحلی (چابهار) و اقلیم نیمه خشک و معتدل گرم (سراوان) مورد ارزیابی قرار گرفته است. از بین پنج پارامتر ورودی شامل سرعت باد، درجه حرارت، رطوبت نسبی، فشار و ساعات آفتابی در دوره ۵ ساله از ابتدای مهر ۱۳۸۴ تا انتهای اسفند ۱۳۸۹، بهترین ترکیب ورودی مدل با استفاده از الگوریتم ژنتیک آزمون گاما (GA-GT) برای هر یک از ایستگاه‌های سینوپتیک واقع در این مناطق انتخاب گردید. سپس با استفاده از مدل‌های NN-ARX و ANFIS، تبخیر روزانه از تشت برآورد شد. با بکارگیری معیارهای آماری شامل R2، RMSE و MAE، کارایی مدل ANFIS با ۳ تابع عضویت نوع گوسی و مدل NN-ARX برای هر یک از ایستگاه‌های سینوپتیک منتخب ارزیابی گردید. نتایج حاصله نشان می‌دهد که دقت مدل ANFIS نسبت به مدل NN-ARX در برآورد تبخیر روزانه از تشت در شرایط اقلیمی خشک و گرم بلوچستان مورد بررسی بیشتر است.

واژه‌های کلیدی: تبخیر از تشت، شبکه‌های عصبی مصنوعی، شبکه‌های عصبی فازی، الگوریتم ژنتیک، آزمون گاما، اقلیم خشک و گرم

مقدمه

میلیون‌ها مترمکعب آب جمع‌آوری شده با هزینه زیاد در سال از مخازن سدها بصورت تبخیر باعث تجمع املاح و نمک‌ها در مخازن و کاهش کیفیت آب مخازن آب شیرین می‌شود (۴). براساس آمارهای موجود، از حجم حدود ۴۰ میلیارد مترمکعبی مخازن آبی کشورمان، سالانه یک میلیارد متر مکعب تبخیر می‌شود (۲۹). لذا با توجه به محدودیت منابع آب در برخی از مناطق خشک و نیمه خشک کشور ایران تخمین درست پارامتر تبخیر به عنوان یکی از عناصر مهم چرخه هیدرولوژی، می‌تواند نقش مهمی در برنامه‌ریزی دست‌اندرکاران برای جلوگیری از هدر رفت آب از طریق تبخیر، کیفیت آب موجود، توسعه پایدار و مدیریت بهینه منابع آب ایفاء کند. در این راستا، اهمیت پارامتر تبخیر در مناطقی همچون استان سیستان و بلوچستان در ایران که دارای اقلیم خشک و نیمه خشک بوده و مشکل کم آبی نیز وجود دارد، دو چندان می‌گردد. بررسی اقلیمی این ناحیه نشان می‌دهد که

یکی از عوامل محیطی بسیار مهم در هر منطقه تلفات سالانه میلیون‌ها مترمکعب آب به صورت تبخیر از خاک و سطح مخازن آب بوده، که می‌تواند تأثیر بسزایی بر درآمد کشاورزان داشته باشد. در مناطقی با تابش خورشیدی و کمبود فشار بخار اشباع بالا، مقدار قابل توجهی از کل آب ذخیره شده، به صورت تبخیر از دست می‌رود که منجر به تقلیل بازده مصرف آب می‌شود (۱۰ و ۱۱). از سویی ائتلاف

۱- استادیار گروه مهندسی آبیاری و زهکشی، پردیس ابوریحان، دانشگاه تهران
(*) نویسنده مسئول: (Email: jsoltani@ut.ac.ir)

۲- دانشیار گروه احیای مناطق خشک و کوهستانی، دانشکده منابع طبیعی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران

۳ و ۴- مربی و دانش‌آموخته کارشناسی ارشد گروه مهندسی آب، دانشکده آب و خاک، دانشگاه زابل

رطوبت نسبی و سرعت باد در این مطالعه استفاده شده است. ترکیب های مختلفی از پارامترها به عنوان ورودی اعمال می شود و به ازای آن عملکرد پس انتشار پیشرو^۱ در ANN با بازگشت خطی بر اساس پارامترهای عملکرد (RMSE و R^2) مقایسه می نمود. مقایسه نتایج نشان می دهد که وقتی برای ساخت و آزمایش مدل، پارامترهای ورودی بیشتر در نظر گرفته می شوند، در مقایسه با حالت تک پارامتری هم خوانی بهتری مشاهده می شود. این مطالعه نشان می دهد که مدل سازی پس انتشار پیشرو بر پایه ANN می تواند به عنوان یک رویکرد جایگزین و کارآ برای تخمین تبخیر روزانه از مخازن اعمال گردد. سانگ وان و هونگ کی (۲۸) شبکه عصبی مصنوعی را برای تخمین میزان تبخیر از تشت در مناطق روستایی کره جنوبی شامل داده های روزانه ماکزیمم، میانگین و مینیمم دما، رطوبت نسبی مینیمم و میانگین، دمای نقطه شبنم، سرعت باد ماکزیمم و میانگین، ساعات آفتابی و تبخیر از تشت در یک بازه آماری ۳ ساله در مناطق مختلف استفاده کردند. نتایج تحقیق بیانگر توانایی بالای شبکه های عصبی مصنوعی در پیش بینی میزان تبخیر از تشت دارد. کیسی (۱۲) دو روش شبکه های عصبی مصنوعی و منطق فازی را برای تخمین میزان تبخیر روزانه از تشت بکار گرفت. داده های مورد استفاده شامل درجه حرارت، تشعشعات خورشیدی، رطوبت نسبی، سرعت باد و فشار هوا جهت ورودی و میزان تبخیر روزانه از تشت خروجی مدل ها بوده است. بررسی فوق نشان داد که روش منطق فازی نسبت به شبکه های عصبی مصنوعی نتایج بهتری ارائه می دهند. گرچه نتایج استخراجی از شبکه های عصبی مصنوعی نیز رضایت بخش بوده و خطایی برابر ۰/۱۷ میلی متر در روز داشته است. کسکین و تریزی (۱۱) شبکه های عصبی مصنوعی را برای محاسبه میزان تبخیر روزانه از تشت در دریاچه اجیردیر ترکیه بکار بردند. متغیرهای مورد استفاده در مدل شامل دمای هوا، دمای آب، رطوبت نسبی، تابش خورشیدی، سرعت باد و فشار هوا می باشند. نتایج پژوهش نشان داد که در منطقه مورد مطالعه اثر سرعت باد و رطوبت نسبی قابل صرف نظر کردن است. سودهیر و همکاران (۲۲) با استفاده از مدل شبکه های عصبی مصنوعی به پیش بینی و تخمین میزان تبخیر از تشت در کشور هند اقدام نمودند. در این پژوهش از داده های ورودی شامل دمای هوا، رطوبت نسبی، سرعت باد و ساعات آفتابی در بازه آماری (۱۹۹۴-۱۹۹۰) استفاده گردید. نتایج حاصل نشان داد که مدل شبکه عصبی مصنوعی در مقایسه با مدل های تجربی توانمندتر است. بر اساس این تحقیق لحاظ کردن کلیه پارامترها در ورودی مدل عملکرد بهتری دارد. برتن و همکاران (۸) شبکه های عصبی مصنوعی برای پیش بینی میزان تبخیر روزانه از تشت استفاده کردند. در این پژوهش داده های ورودی مدل شامل درجه حرارت، بارندگی، رطوبت نسبی، تشعشعات

بطور طبیعی استعداد زیادی برای تبخیر در این منطقه وجود دارد. بالا بودن درجه حرارت و وزش باد، به همراه پایین بودن رطوبت نسبی، تبخیر آب را نسبت به سایر مناطق افزایش می دهد. متوسط سالیانه تبخیر در ایران تقریباً ۱۸۰۰ میلی متر معادل ۷۱ درصد بارندگی متوسط سالیانه برآورد گردیده است. مقادیر ارائه شده شاهد براین ادعاست که تبخیر پارامتر مؤثری در مدیریت کمی و کیفی و بیابان های منابع آب منطقه ای در ایران است (۱۷ و ۲۹).

بطور کلی مدل های هیدرولوژیکی از جمله مدل های تبخیر موجود نیازمند پارامترهای ورودی فراوان هستند که دسترسی به آنها مشکل است و با اندازه گیری آنها زمان بر و محتاج صرف هزینه زیادی می باشد، و از سویی واسنجی شان نیز بسیار وقت گیر بوده که کمتر مورد توجه قرار می گیرند. در دهه های اخیر برای حل مشکلات مربوط به کاربرد مدل های هیدرولوژیکی و هیدرولوژیکی، مدل های هوش مصنوعی نظیر شبکه عصبی مصنوعی که یک مدل محاسباتی بوده و بر اساس سیستم عصبی مغز انسان در فرآیند یادگیری طراحی شده در مطالعات منابع آب و برای پیش بینی ها توسط محققین مختلف مورد استفاده قرار گرفته است. امروزه این مدل ها بطور فزاینده ای مورد توجه قرار گرفته اند. علت این استقبال از هوش مصنوعی را می توان قدرت شبیه سازی این نوع مدل در فرآیندهای که تعریف دقیق و درک خاصی از آنها وجود ندارد و حساسیت کمتر آن نسبت به وجود خطا در ورودی ها دانست. به بیان دیگر، این مدل ها می توانند با حداقل پارامترهای اندازه گیری شده و با دقت قابل قبولی تغییرات متغیر مورد نظر را پیش بینی نمایند. جذابیت مدل های هوش مصنوعی بخاطر توانایی آنها در حل مسائل غیرخطی، حجیم و دارای خطا می باشد. همچنین این مدل ها توانایی یادگیری حل مسائل فازی و تشخیص الگوها را نیز دارا می باشند (۱، ۳، ۴، ۶، ۷، ۱۴، ۱۷، ۱۸، ۱۹، ۲۱، ۲۲، ۲۳، ۲۵، ۲۷ و ۲۹).

در زمینه کاربرد هوش مصنوعی برای تخمین تبخیر از تشت تحقیقات فراوانی انجام شده است که به تعدادی از آنها اشاره می شود. شیرسات و سینگه (۲۱) مدل های کاربرد شبکه عصبی مصنوعی، رگرسیون آماری و چند مدل اقلیمی را جهت پیش بینی تبخیر روزانه از تشت با آب و هوای نیمه خشک در دهلی نو هند با استفاده از داده های روزانه شامل متغیر دمای ماکزیمم هوا، دمای مینیمم هوا، رطوبت نسبی، ساعات آفتابی و سرعت باد در یک دوره چهار ساله (۲۰۰۴-۲۰۰۷) بررسی کردند. نتایج حاصل نشان داد که مدل ANN در مقایسه با سایر روش ها عملکرد بهتری برای تخمین مقدار تبخیر روزانه از تشت داشته است. ژئول (۹) تحقیقی برای نشان دادن امکان و قابلیت های مدل سازی بر پایه ANN به منظور پیش بینی تبخیر از یک مخزن در حالتی که معادلات کلاسیک و تجربی نتوانسته اند تبخیر را به طور دقیق پیش بینی کنند، انجام داد. یک دسته داده های هواشناسی شامل تبخیر سطحی روزانه، دما، تشعشع خورشیدی،

1- Feed Forward

کانسکر در سال (۱۹۹۷) روش GT را به عنوان ابزاری برای تجزیه و تحلیل مدل‌سازی غیرخطی معرفی کرد. همچنین در سال‌های اخیر برای کاهش مراحل سعی و خطا^۳ در مدل‌سازی‌های هوشمند و غیر خطی و انتخاب ترکیب بهینه و مناسبی از انواع پارامترهای ورودی و خروجی به مدل‌های هوش مصنوعی و غیر خطی بکار می‌رود. همچنین یک ابزار توسعه یافته برای تخمین میانگین مربعات خطای حاصل از مدل‌سازی پدیده‌های مختلف با استفاده از مجموعه داده‌های مشاهداتی از آن پدیده است (۲۰). مقدمه و همکاران (۱۵) روش GT جهت پیش پردازش پارامترهای ورودی موثر بر تایش خورشیدی بکار بردند. آن‌ها ارزیابی شبکه‌های مختلف عصبی مصنوعی نظیر LLR، ELMAN، MLP و NNAR و ANFIS با بکارگیری نتایج حاصل از شیوه GT و معیارهای مختلف آماری انجام دادند. قبائی سوق و همکاران (۲) مدل‌سازی هوشمند تایش خورشیدی با استفاده از آزمون گاما و مقایسه با معادلات تجربی و اسنجی شده در کرمانشاه طی دوره آماری ۱۹۹۲ الی ۲۰۰۱ انجام دادند. آن‌ها ارزیابی شبکه‌های مختلف عصبی مصنوعی نظیر ANN(LM)، ANN(SCG) و LLR نسبت به معادلات تجربی و اسنجی شده با بکارگیری نتایج حاصل از GT و معیارهای مختلف آماری انجام دادند. نتایج حاصل برتری مدل‌سازی هوشمند را نشان داد.

در تحقیق حاضر، دو مدل شبکه عصبی خودرگرسیون با ورودی برنزا^۴ (NNARX) و عصبی-فازی که با گزینه بهینه‌سازی مدل گاما تست در محیط نرم افزار MATLAB تلفیق شده، جهت برآورد تبخیر روزانه از تست در شرایط اقلیمی خشک و گرم توسعه داده شده است. هدف اصلی این مقاله، استفاده از تکنیک گاما تست (GT) مبتنی بر الگوریتم ژنتیک^۵ (GA) و انتخاب بهترین ترکیب ورودی به مدل‌های NNARX و ANFIS جهت پیش‌بینی تغییرات پارامترهای دما، سرعت باد، رطوبت نسبی، فشار، ساعات آفتابی و همچنین ارزیابی کارایی مدل‌های فوق در سه ایستگاه سینوپتیک ایران‌شهر، چابهار و سراوان که با اقلیم‌های خشک و گرم (ایران‌شهر)، اقلیم خشک و گرم ساحلی (چابهار) و اقلیم نیمه خشک و معتدل گرم (سراوان) می‌باشد، مورد بررسی قرار گرفته است. تا بتوان از آن به منظور آنالیز سریع تبخیر در این سه ایستگاه استفاده نمود.

مواد و روش‌ها

مبانی نظری تحقیق

همانطوری که اشاره شد، فرآیند تبخیر از جمله پارامترهای مهم در

خورشیدی و سرعت باد بوده و داده خروجی مدل میزان تبخیر از تست می‌باشد. نتایج حاصل از تحقیق فوق نشان داد که روش شبکه عصبی مصنوعی در مقایسه با روش‌های دیگر دارای کمترین خطا که برابر ۱/۱۱ میلی متر در روز بوده است. پیری و همکاران (۱۷) از مدل شبکه عصبی مصنوعی برای تخمین میزان تبخیر از مخازن آب چاه نیمه-های سیستان با اقلیم گرم و خشک واقع در جنوب شرق ایران استفاده کردند. داده‌های روزانه ورودی به مدل شامل دمای هوا، سرعت باد، کمبود فشار بخار اشباع و رطوبت نسبی و داده خروجی مدل میزان تبخیر روزانه از تست در بازه آماری (۲۰۰۶-۱۹۹۵) مورد استفاده قرار گرفت. بر اساس نتایج این تحقیق روش شبکه‌های عصبی مصنوعی نسبت به مدل‌های تجربی عملکرد بهتری داشته است. همچنین داده‌های سرعت باد، کمبود فشار بخار اشباع و رطوبت نسبی به عنوان داده‌های ورودی به مدل بر میزان تبخیر روزانه از تست موثرتر می‌باشند. رحیمی خوب (۱۸) از شبکه‌های عصبی مصنوعی برای پیش‌بینی میزان تبخیر روزانه از تست در منطقه نیمه خشک صافی آباد دزفول در دشت خوزستان واقع در جنوب غرب ایران در بازه زمانی (۲۰۰۳-۱۹۹۶) استفاده کردند. بر اساس این تحقیق نتایج حاصل نشان دهنده عملکرد رضایت بخش مدل شبکه‌های عصبی مصنوعی بوده است. مقدم نیا و همکاران (۱۴) با استفاده از شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی-عصبی جهت برآورد تبخیر روزانه از مخازن چاه نیمه‌های سیستان اقدام کردند. در تحقیق فوق برای انتخاب ترکیب مناسب ورودی مدل‌ها از تکنیک آزمون گاما^۱ (GT) استفاده شده بطوری که پارامترهای کمبود فشار بخار، رطوبت نسبی و سرعت باد به عنوان ورودی‌های بهینه برای مدل‌های ANN و ANFIS معرفی شده‌اند. همچنین نتایج نشان داد که خروجی مدل‌های ANN در مقایسه با ANFIS جهت پیش‌بینی تبخیر دقیق‌تر است. پیری و همکاران (۱) با استفاده از شبکه عصبی مصنوعی به تخمین تبخیر روزانه از تست تبخیر در ایستگاه گنبد اقدام نمودند. در تحقیق فوق با استفاده از آمار روزانه هواشناسی ایستگاه گنبد به آموزش مدل‌های ANN با ساختار پرسپترون چند لایه و الگوریتم پس انتشار^۲ (BP) خطا پرداخته می‌شود. پارامترهای درجه حرارت هوا، رطوبت نسبی، سرعت باد و ساعات آفتابی به عنوان ورودی‌های شبکه و تبخیر روزانه از تست تبخیر بعنوان خروجی شبکه در نظر گرفته می‌شود. بمنظور بررسی تأثیر پارامترهای ورودی در تخمین تبخیر از آنالیز حساسیت استفاده شد. نتایج نشان داد که پارامترهای دما و سرعت باد بترتیب بیشترین و کمترین تأثیر را در تخمین مقدار تبخیر از تست دارا می‌باشد. همچنین از ANN می‌توان با دقت مناسبی در تخمین میزان تبخیر روزانه از تست تبخیر استفاده نمود.

3- Try & Error

4- Neural Network-Auto Regressive Extra (NN-ARX)

5-Genetic Algorithm

1-Gamma Test

2-Back propagation

ساختار مدل در این مقاله، ساختار مدل ARX است و مرتبه مدل با کنترل تمام حالات ممکن با فرض دسترسی به حداکثر مقدار ممکن طراحی می‌شود، به نحوی که تخمین، برازش^۵ بهتری (رابطه ۲) را در فاز آزمایش ارائه دهد.

$$Fit = 100 \left(1 - \frac{norm(\hat{y} - y)}{norm(y - mean(y))} \right) \quad (2)$$

که در این فرمول \hat{y} = مقادیر پیش‌بینی شده و y = مقادیر مشاهده شده است.

همچنین کم بودن خطای $\mathcal{E} = y - \hat{y}$ و ماتریس کوواریانس آن و عدم همبستگی لحظات مختلف آن در فاز آزمایش در مرحله ارزیابی و اعتبار مدل مهم است.

$$\hat{y}(t | \theta) = g(\varphi(t)) \quad (3)$$

φ = بردار رگرسیون و θ = بردار پارامترهای مدل است.

در حالت کلی تخمین از خروجی به صورت تابعی از مشاهدات می‌باشد. در مدل خطی ARX این رابطه به صورت خطی نسبت به پارامتر (Linear Regression) مطرح است.

$$\hat{y}(t | \theta) = \varphi^T(t) \hat{\theta} \quad (4)$$

$\hat{\theta}$ = تخمین بردار پارامترهای مدل است.

با استفاده از شبکه عصبی به جای استفاده از یک جمع‌کننده ساده از ساختار غیرخطی شبکه عصبی استفاده می‌شود، که در شکل ۱ این موضوع نشان داده شده است (۱ و ۱۵).

به این ترتیب شبکه عصبی MLP، دینامیک داده‌ها را فرا گرفته و بعنوان مدل تخمین‌گر برای فرم ARX (NN-ARX) عمل می‌کند. برای تعیین تعداد نرون‌های لایه میانی نیز از بین چندین حالت مختلف، حالتی را که مدل برازش بهتری در فاز آزمایش ارائه کند، انتخاب می‌شود. از آنجایی که محدوده اعداد در متغیرهای مختلف متفاوت است لذا نرمالیزه کردن داده‌ها نقش مهمی در بهبود عملکرد مدل دارد. برای این منظور، اگر r یک سری زمانی و $m = \min_t \{r(t)\}$ ، $M = \max_t \{r(t)\}$ باشد، $r_N(t)$ سیگنال نرمالیزه خواهد بود که به صورت زیر بیان می‌شود (۱، ۱۶ و ۱۷).

$$r_N(t) = \frac{r(t) - m}{M - m} \quad (5)$$

چرخه هیدرولوژی و مهندسی منابع آب است. پدیده تبخیر را می‌توان به صورت یک فرآیند اتفاقی غیر خطی و پیچیده و غیر ساکن^۱ (پویا) در نظر گرفت. به دلیل تاثیر متقابل پارامترهای مختلف هواشناسی در محاسبه تبخیر، روابطی غیرخطی برای تخمین مقدار آن وجود دارد که معمولاً از دقت بالایی برخوردار نیستند. لذا در دهه‌های اخیر کاربرد شیوه‌های هوش مصنوعی از جمله شبکه‌های عصبی مصنوعی و سیستم عصبی-فازی برای تخمین و پیش‌بینی پارامترها با استفاده از ارتباط ذاتی بین داده‌ها مورد توجه محققان قرار گرفته و در حال توسعه می‌باشد. از آنجا که ساختارهایی نظیر شبکه عصبی مصنوعی از قدرت نگاشت غیرخطی برخوردارند و همچنین دارای خصوصیت یادگیری هستند، بنابراین با استفاده از این ساختارها می‌توان از آنها برای مدل‌سازی استفاده کرد. بنابراین در تحقیق حاضر، ابتدا دو مدل شبکه عصبی مصنوعی پویا و عصبی-فازی که با گزینه بهینه‌سازی الگوریتم ژنتیک مدل گاما تست تلفیق گردید. سپس این مدل به منظور انتخاب ورودی‌های بهینه و مناسب جهت برآورد تبخیر روزانه از تست در شرایط اقلیمی خشک و گرم توسعه داده شده و در نهایت نتایج حاصل مورد مقایسه قرار گرفته است. ساختار هر یک از این مدل‌ها در ادامه تشریح شده است.

مدل شبکه عصبی - خودرگرسیونی با ورودی برونزا (NN-ARX)


در بحث شناسایی سیستم، مدل‌های آماری قوی برای مدل‌سازی فرآیندهای اتفاقی و سری‌های زمانی وجود دارد. به طور کلی مدل‌های پویا در بررسی‌های کوتاه مدت، دقیق‌تر از مدل‌های ساکن^۲ پاسخ می‌دهد (۱۱). شبکه‌های پویا دارای یک بخش خطی خودرگرسیونی (ARX) و یک بخش غیرخطی شبکه عصبی پیشخور انتشار برگشتی (ANN) است. مدل ARX یکی از ساختارهایی است که در بحث شناسایی سیستم کاربرد زیادی دارد (۱).

در این مطالعه، درجه حرارت (T)، سرعت باد (W)، کمبود فشار بخار اشباع (Ed) و درصد رطوبت نسبی (RH) به عنوان ورودی به مدل وارد می‌شود و تبخیر به عنوان خروجی است. بدین صورت فضای مشاهدات Z^N جهت مدل‌سازی آماده می‌شود. داده‌ها به دو دسته داده‌های یادگیری^۳ و داده‌های آزمایش^۴ تقسیم میشوند (۲۳).

(۱) $Z^N = \{ [u(t), y(t)] | t = 1, 2, \dots, N \}$ $u(t) = [u_1(t) \ u_2(t) \ \dots \ u_s(t)]$
در این رابطه t : زمان در حوزه گسسته، N : تعداد کل داده‌ها، $u(t)$: داده‌های مناسب از ورودی و $y(t)$: داده خروجی سیستم است.

- 1-Dynamic
- 2-Static
- 3- Training Data
- 4- Testing Data

5- Fitness



شکل ۱- بلوک دیاگرام مدل NN-ARX

عضویت A_i و B_i بوده و این درجه‌ای است که کفایت x را برای A_i و B_i تعیین می‌کند. معمولاً $\mu_{A_i}(x)$ را به شکل تابع زنگوله‌ای با حداکثر یک و حداقل صفر توسط رابطه ذیل تعیین می‌شود:

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\frac{(x - c_i)^2}{a_i} \right]^{b_i}} \quad (8)$$

که در آن $\{a_i, b_i, c_i\}$ مجموعه پارامترها هستند. پارامترهای این لایه به پارامترهای اولیه^۲ معروف هستند.

لایه دوم یا گره‌های قاعده، که در آن مقادیر ورودی به هر گره در هم ضرب شده و حاصل که وزن قانون‌ها می‌باشد بدست می‌آید. در لایه دوم عملگر "AND" (و) بکار برده شده تا خروجی که نمایانگر بخش مقدم آن قانون بوده بدست آید.

$$O_{2,i} = w_i = \mu_{A_i}(x) * \mu_{B_i}(y), \quad i = 1, 2 \quad (9)$$

لایه سوم، هر گره‌ی این لایه، دایره‌ای با علامت N است. گره‌های این لایه وزن قانون‌ها را نرمال‌سازی می‌کنند.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (10)$$

لایه چهارم، گره‌های نتیجه که لایه قوانین نامیده می‌شود و در این لایه قانون‌ها بدست می‌آیند.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (11)$$

که در آن؛ \bar{w}_i خروجی چهارمین گره از لایه قبلی و p_i ، q_i و r_i ضرایب این ترکیب خطی است.

سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)

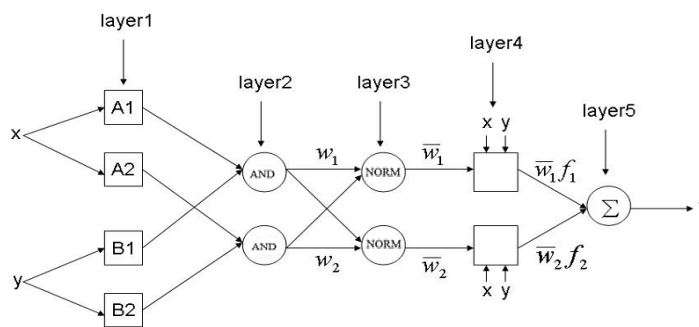
اولین بار نظریه مجموعه‌های فازی در سال ۱۹۶۵ توسط پروفسور لطفی عسکرزاده دانشمند ایرانی تبار و استاد دانشگاه برکلی، عرضه شد. امروزه، این نظریه ضمن گسترش در زمینه‌های مختلف کاربردهای گوناگونی نیز پیدا کرده است (۲۳). در سال ۱۹۹۳ جانگ با مدنظر قرار دادن توانایی‌های سیستم‌های استدلال فازی و شبکه‌های عصبی تطبیقی، مدل استنتاج فازی-عصبی تطبیقی را ارائه کرد (۲۳) و (۲۴). مدل ANFIS توانایی و قابلیت دو مدل فوق را دارد بطوری‌که این مدل همانند مدل فازی از دانش تجربی بهره گرفته و نیز همانند مدل شبکه عصبی می‌تواند آموزش ببیند. نقص مدل ANFIS زمان‌بر بودن آموزش ساختار و تعیین پارامترها می‌باشد. در سیستم فازی-عصبی روش متداول آموزش، سیستم استنتاج فازی نوع ساجینو می‌باشد که از الگوریتم یادگیری پیوندی برای تعیین پارامترهای سیستم فازی به منظور آموزش مدل استفاده می‌کند (۲۵). مدل ترکیبی استنتاج فازی-عصبی (ANFIS) دارای ساختار پنج لایه‌ای است و هر کدام از این لایه‌ها نقش خاصی را ایفا می‌کنند (شکل ۲).

لایه اول یا لایه ورودی‌ها، در این لایه ورودی‌ها از توابع عضویت عبور کرده و درجه عضویت گره‌های ورودی به بازه‌های مختلف فازی با استفاده از توابع عضویت مشخص می‌گردد. توابع عضویت انواع متفاوتی دارد که از جمله آن می‌توان به توابع دوزنقه‌ای، مثلثی، سیگموئید، گوسی و تابع زنگوله‌ای شکل، که حالت کلی‌تری از آنها را شامل می‌شود، اشاره کرد.

$$O_{1,i} = \mu_{A_i}(x), \quad \text{for } i = 1, 2 \quad (6)$$

$$O_{1,i} = \mu_{B_i}(x), \quad \text{for } i = 3, 4 \quad (7)$$

که در این‌جا؛ x ورودی گره‌ی i ، A_i و B_i عبارت زبانی (کوچک، بزرگ و غیره) است که در این تابع گره مشارکت دارد. همچنین، $O_{1,i}$ تابع



شکل ۲- ساختار یک شبکه ANFIS

تحقیق به منظور رعایت اختصار از شرح کامل روش آزمون گاما، معادل اتوابات آنها خودداری میشود. به عنوان مثال مجموعه‌ی زیر را در نظر بگیرید:

$$\{(x_i, y_i), 1 \leq i \leq M\} \quad (13)$$

که در آن بردار $x \in R^m$ به عنوان ورودی و مطابق آن عدد $y \in R$ به عنوان خروجی در نظر گرفته می‌شود و فرض می‌کنیم که بردارهای x قابلیت پیشگویی فاکتورهای مورد استفاده موثر در خروجی y را داشته باشند.

فرض کنید $\{i, k\}, x_n, k$ امین نزدیکترین همسایه در یک عبارت فاصله اقلیدسی برای $(1 \leq i \leq M), (1 \leq k \leq p)$ می‌باشد، لذا در این روش با تعیین مقدار نزدیک‌ترین همسایگی برای نقاط $p, \gamma_M(k), \delta_M(k)$ ایجاد کرد:

$$\gamma = A\delta + \Gamma \quad (14)$$

عرض از مبدأ خط رگرسیون فوق برابر مقدار آزمون گاما و شیب^۲ بیشتر آن بیانگر پیچیدگی بیشتر مدل میباشد. همچنین مقدار خطای استاندارد^۳ (SE) آن هرچه به عدد صفر نزدیکتر باشد با اطمینان بیشتری میتوان مقدار گاما را نشاندهنده‌ی اغتشاش موجود در داده‌ها دانست. از طرفی، شیب رگرسیون خطی است که برای محاسبه آماره‌ی گاما مورد استفاده قرار می‌گیرد. در واقع شیب یک مقدار بی-بعد است که بیان کننده‌ی پیچیدگی تابع می‌باشد به نظر می‌رسد این مقدار ثابت می‌باشد. برای اطمینان از مقدار شیب، باید داده‌ها نرمالیزه شوند. اما در واقع زمانی که مقدار گاما مثبت باشد نتیجه‌ی کار درست است، که در این حالت، از نقاطی که دارای مقادیر کمتر در مقایسه با دیگر متغیرها هستند مورد استفاده قرار می‌گیرند. برای این منظور می‌توان استاندارد بودن نتایج را با شاخص V_{ratio} که بصورت ذیل تعریف می‌شود ملاحظه کرد:

لایه پنجم، آخرین لایه شبکه است شامل یک تک گره با علامت \sum بوده که با جمع کردن همه مقادیر ورودی به آن، خروجی کلی سیستم را محاسبه می‌کند. این لایه نتایج هر قانون فازی را طی فرایند غیرفازی‌سازی به خروجی غیرفازی تغییر شکل می‌دهد.

$$O_{s,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (12)$$

پارامترهای مربوط به توابع عضویت طی فرایند یادگیری تغییر می‌کنند. محاسبه این پارامترها (و یا تنظیم آن‌ها) از طریق یک بردار گرادین بوده، بطوری که این بردار گرادین یک معیار اندازه‌گیری برای مطلوبیت مدل‌سازی پارامترهای سیستم استنتاج فازی فراهم می‌آورد. پس از فراهم آمدن بردار گرادین از روال‌های بهینه‌سازی دیگر برای بهینه‌سازی پارامترها و کاهش خطا استفاده نمود. در پایان تجزیه و تحلیل‌های حاصل از هریک از مدل‌ها که با معماری‌ها و الگوریتم‌های مختلف به دست آمده‌اند را با یکدیگر مقایسه و بهترین نتیجه استخراج و ارائه شده‌است (۳، ۱۵، ۱۶، ۲۳ و ۲۳).

آزمون گاما (GT)

آزمون گاما یک ابزار مدل بهینه‌سازی غیرخطی است که به کمک آن می‌توان ترکیب مناسب از بین پارامترهای ورودی مختلف برای مدل‌سازی داده‌های خروجی و ایجاد یک مدل هموار را بررسی نمود. همچنین این آزمون می‌تواند تا اندازه‌ای برای تخمین آن بخش از واریانس داده‌های خروجی که از روی داده‌های ورودی با ایجاد یک مدل هموار نمی‌توانند حساب شوند بکار رود. بطور کلی در مدل‌سازی‌های غیرخطی نظیر شبکه‌های عصبی مصنوعی مشکلاتی نظیر: فوق برازش^۱، انتخاب ساختار شبکه بر اساس سعی و خطا، لزوم ارزیابی مجموعه داده‌ها و انتخاب ورودی‌های بهینه وجود دارند که تمام موارد فوق بر روی یک مدل خوب تاثیر گذار است. در این

2-Gradient
3-Standard Error

1- Overtraining

مربعات خطا (RMSE) و ضریب رگرسیون همبستگی (R^2) مطابق روابط زیر استفاده گردید (۱، ۲، ۳، ۱۱، ۱۵، ۱۹ و ۲۳).

$$MAE = \frac{\sum_{i=1}^N |\hat{y}_i - y_i|}{N} \quad (16)$$

$$RMSE = \left[\frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{N} \right]^{\frac{1}{2}} \quad (17)$$

$$R^2 = \frac{\left[\sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})(y_i - \bar{y}) \right]^2}{\sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2 \sum_{i=1}^N (y_i - \bar{y})^2} \quad (18)$$

در این رابطه‌ها؛ y_i = مقادیر مشاهده شده، \hat{y}_i = مقادیر شبیه‌سازی شده، \bar{y}_i = میانگین مقادیر مشاهده شده، $\bar{\hat{y}}_i$ = میانگین مقادیر شبیه‌سازی شده و N = تعداد نمونه‌ها می‌باشد.

مقدار RMSE بیانگر این است که مقادیر پیش‌بینی شده چقدر از مقادیر مشاهده شده انحراف دارد و حد پایین RMSE صفر می‌باشد. R نیز بیانگر عملکرد مدل بوده و مقدار آن بین صفر و یک می‌باشد که هر چه به یک نزدیک‌تر باشد بهتر است. معیار MAE بیانگر دقت روش و مقدار متوسط خطا بوده، و هر چه به صفر نزدیک‌تر باشد، بهتر بوده و نشان‌دهنده دقت بیشتر است.

منطقه مورد مطالعه

منطقه بلوچستان از خشک‌ترین مناطق ایران محسوب می‌شود. مقدار بارندگی در این ناحیه نه تنها بسیار کم، بلکه توزیع زمانی و مکانی آن نیز نامنظم است. تبخیر به علت خشکی هوا، درجه حرارت زیاد و جریان‌های بادها شدید بوده، و میزان آن به ۲۰ تا ۹۰ برابر باران سالیانه می‌رسد.

$$V = \frac{\Gamma}{\sigma^2(y)} \quad (15)$$

که در اینجا $\sigma^2(y)$ ، واریانس خروجی y است. این نسبت بررسی شکلی را که وابسته به دامنه خروجی است مسیر می‌سازد و خروجی مناسب را می‌تواند برای توابع ساده مدل‌سازی کند. نسبت V به شاخص صفر نزدیک می‌شود تا بتواند پیشگویی خروجی y را انجام دهد. هرگاه این متغیر به یک نزدیک شود نمایانگر یک خطای تصادفی بسیار بزرگ است و مدل موردنظر نامناسب است (۱۵، ۱۷ و ۱۸).

بنابراین، با استفاده از روش آزمون گاما برای پیش‌پردازش پارامترها می‌توان ترتیب میزان اهمیت پارامترهای ورودی، بهترین ترکیب از میان ترکیب‌های ممکن و تعداد داده‌های مورد نیاز برای ایجاد یک مدل هموار جهت ورود به ANNs و ANFIS را بدست آورد. اگر فرض شود N پارامتر ورودی بر وقوع پدیده‌ای موثر باشند تعداد 2N-1 ترکیب معنی‌دار از پارامترهای ورودی بوجود می‌آید که برای مدل‌سازی این پدیده با استفاده از ANNs و ANFIS بررسی تک‌تک ترکیبات ایجاد شده برای یافتن بهترین ترکیب کاری بسیار وقت‌گیر و خسته‌کننده است. بنابراین هنگامی که عوامل موثر بر پدیده‌ای بطور قابل ملاحظه‌ای زیاد باشد با استفاده از تکنیک پیش‌پردازش آزمون گاما می‌توان ترتیب میزان اهمیت پارامترهای ورودی و بهترین ترکیب از میان تمام ترکیب‌های ممکن و تعداد داده‌های لازم برای آموزش مدل‌های نظیر ANNs و ANFIS را بدست آورد (۱۵ و ۱۹).

اعتبار سنجی ساختار مدل تلفیقی پیشنهادی

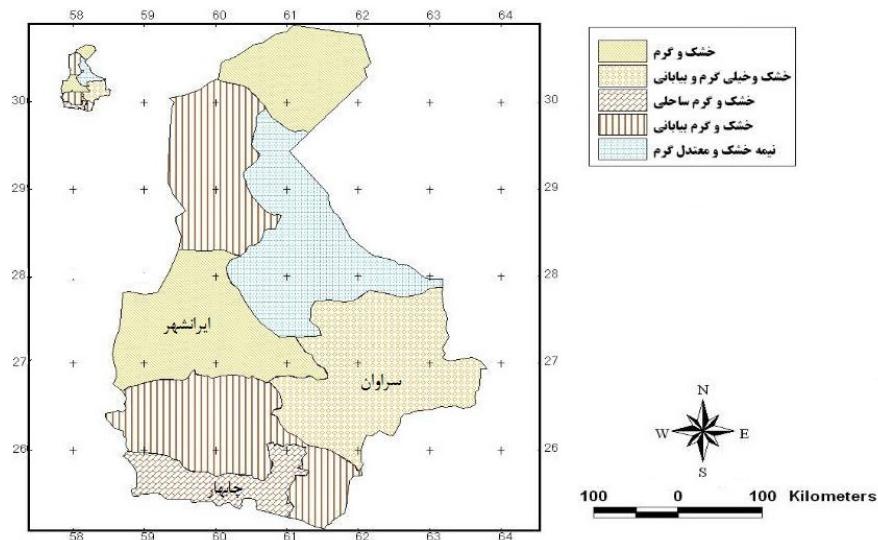
اعتبار مدل با مقایسه تبخیر پیش‌بینی شده توسط مدل‌ها و مقادیر اندازه‌گیری شده برای تعدادی از سال‌های آماری که در آموزش شبکه از آنها استفاده نشده مورد بررسی قرار گرفت. برای این منظور از ویژگی‌های آماری میانگین قدرمطلق خطا (MAE)، جذر میانگین

جدول ۱- موقعیت جغرافیایی ایستگاه‌های منطقه مورد مطالعه (سازمان هواشناسی و آب منطقه‌ای استان سیستان و بلوچستان)

ارتفاع از سطح دریا (m)	مقادیر میانگین سالیانه					مساحت			عرض جغرافیایی (دقیقه - درجه)	طول جغرافیایی (دقیقه - درجه)	ایستگاه
	ساعات آفتابی	سرعت باد (KNOTS)	رطوبت نسبی (%)	تبخیر از تشتت (mm)	بارندگی (mm)	دما (°C)	پوشش هر ایستگاه (km ²)	سال تاسیس (میلادی)			
۱۱۹۵	۳۴۱۶/۱	۶	۳۱	۳۷۳۷	۱۰۶/۳	۲۲/۱	۲۳۸۷۹	۱۹۸۶	۲۷°۲۰'	۶۳° ۲۰'	سراوان
۵۹۱/۱	۳۲۷۹/۸	۳/۹	۳۱	۳۱۸۹/۴	۱۱۶/۸	۲۶/۹	۳۰۲۳۰	۱۹۶۴	۲۷° ۱۳'	۶۰° ۴۳'	ایرانشهر
۸	۳۱۴۴/۷	۶	۶۱	۲۷۰۰/۵	۱۱۰/۵	۲۶/۳	۲۴۷۲۹	۱۹۶۳	۲۵° ۱۷'	۶۰° ۳۷'	چابهار

جدول ۲- ناحیه‌بندی اقلیمی ایستگاه‌های منطقه مورد مطالعه

شهر	طول جغرافیایی (دقیقه - درجه)	عرض جغرافیایی (دقیقه - درجه)	روش آمبرژه	روش کوپن	روش چند متغیره آماری
سراوان	۶۳° ۲۰'	۲۷° ۲۰'	بیابانی گرم خفیف	مدیترانه‌ای گرم	نیمه خشک و معتدل گرم
ایرانشهر	۶۰° ۴۲'	۲۷° ۱۲'	بیابانی گرم خفیف	گرم و خشک	خشک و گرم
چابهار	۶۰° ۳۷'	۲۵° ۱۷'	بیابانی گرم شدید	گرم و خشک	خشک و گرم ساحلی



شکل ۴- نمایی از بلوچستان و شرایط آب و هوایی آن

است. فایل بردارهای ورودی و خروجی مدل‌ها در محیط نرم افزار Excel تهیه شده است. بدین صورت که داده‌های تهیه شده از ایستگاه تخیرسنجی در هر دوره آماری از ابتدای دوره آماری به ترتیب تا انتهای آن (به عنوان مثال در دوره ۵ ساله از ابتدای مهر ۱۳۸۴ تا انتهای اسفند ۱۳۸۹)، هر یک بطور جداگانه در یک ستون مرتب شده‌اند. سپس از طریق آزمون گاما تعداد داده‌های مورد نیاز برای آموزش به آن اختصاص می‌یابد. در این تحقیق داده‌های در دسترس تنها به دو زیرمجموعه آموزشی و آزمون تقسیم شدند. بردارهای ورودی و خروجی که برای آموزش و آزمون شبکه استفاده می‌شدند هر کدام به یک صفحه کاری در محیط نرم افزار Excel انتقال داده شد. بنابراین فایل بردارهای ورودی و خروجی مدل شبکه عصبی یک فایل Excel متشکل از پنج صفحه کاری می‌باشد، که هر صفحه کاری یک بردار ورودی یا خروجی از داده‌های مرحله آموزشی و آزمون را در بر می‌گیرد. شبکه عصبی مصنوعی مورد استفاده در این تحقیق دارای ساختار پیشخور چند لایه‌ای یا پرسپترون چند لایه‌ای بدلیل کارایی بهتر در امر پیش‌بینی تخیر می‌باشد. برای تعیین تعداد مناسب نرون‌ها در لایه پنهانی از ۱ تا ۹ نرون افزایش داده شد و با توجه به نتایج بدست آمده بهترین ساختار نرونی انتخاب شد. توابع محرک بکار برده شده در این تحقیق از نوع لوگ

میزان رطوبت نسبی بویژه در فصل گرم بجز در سواحل جنوبی بسیار پایین است و درجه حرارت بسیار بالا می‌باشد. اطلاعات و داده‌های مربوط به ایستگاه‌های مورد نظر از سازمان هواشناسی و آب منطقه‌ای استان سیستان و بلوچستان تهیه گردیده است. در جدول ۱ برخی از خصوصیات جغرافیایی سه شهرستان تحت مطالعه ایرانشهر، چابهار و سراوان ارائه شده است (۵). در جدول ۲ براساس چند شاخص مختلف اقلیمی، اقلیم شهرستان‌های مورد مطالعه مشخص گردیده است. در شکل ۴ نمایی از بلوچستان و نمایی کلی از وضعیت اقلیمی آن مشاهده می‌گردد (۵).

طراحی مدل با استفاده از NN-ARX و ANFIS

به منظور مدل کردن تخیر روزانه از تشت با استفاده از شبکه عصبی مصنوعی و سیستم استنتاج عصبی فازی، کد نویسی در محیط نرم‌افزار جامع MATLAB صورت گرفت. در این تحقیق برای مدل کردن تخیر روزانه از تشت پنج پارامتر ورودی شامل سرعت باد، درجه حرارت، رطوبت نسبی، کمبود فشار اشباع و ساعات آفتابی بوده، ساختار مدل ANFIS از تابع عضویت نوع گوسی با سه عدد تابع عضویت و در مورد نوع شبکه عصبی یک شبکه دینامیک شامل یک لایه مخفی و یک لایه خروجی تخیر روزانه تشت طراحی گردیده

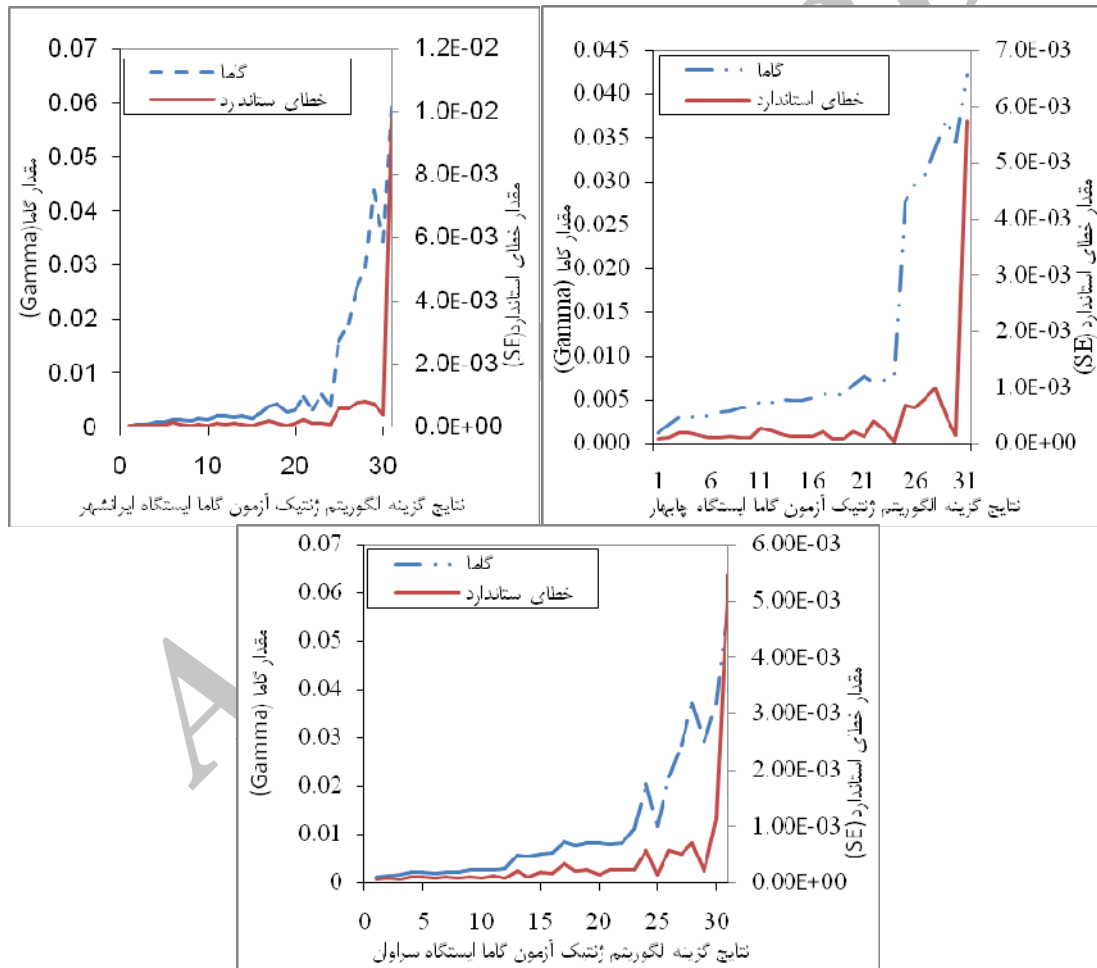
نتایج و بحث

فرآیند غیر خطی تبخیر روزانه از تشتت به عنوان یکی از عناصر مهم چرخه هیدرولوژی می‌تواند نقش بسیار مهمی را در توسعه پایدار و مدیریت بهینه منابع آب منطقه بلوچستان واقع در کمربند خشک کشور ایفاء کند.

سیگموئیدی، تانژانت هایپربولیک و خطی بوده و الگوریتم آموزشی از نوع لونبرگ - مارکوارت^۱ است. در مرحله انتهای با توجه به معیارهای آماری که در بخش قبلی گفته شد برای هر دو مرحله آموزش و آزمون محاسبه نموده و نتایج باهم مورد مقایسه قرار می‌گیرد.

جدول ۳ - نتایج الگوریتم ژنتیک آزمون گاما در سه ایستگاه

ایستگاه	Gamma	SE	Gradient	V _{Ratio}
ایرانشهر	۰/۰۰۰۲۹	۰/۰۰۰۰۴۴۷	۰/۰۹۳	۰/۰۰۴۸
چابهار	۰/۰۰۰۱۲	۰/۰۰۰۰۸۵۳	۰/۰۸۷	۰/۰۳
سراوان	۰/۰۰۰۱۳	۰/۰۰۰۰۰۶۱	۰/۰۸۱	۰/۰۲



شکل ۵- نتایج گزینه الگوریتم ژنتیک آزمون گاما ایستگاه های (الف)ایرانشهر (ب)چابهار و (ج)سراوان

1 - Levenberg- Marquardt Algorithm

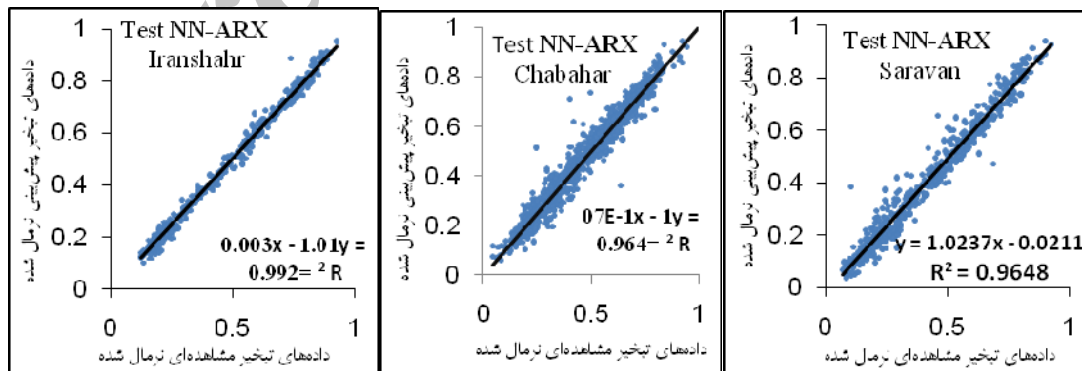
استاندارد را داشته باشد که در این تحقیق ترکیب مطلوب شامل همه پارامترها می‌باشد.

شبکه عصبی مصنوعی به کار گرفته شده در این تحقیق از نوع NN-ARX با سه عدد لایه و تعداد ۵ نرون در لایه ورودی و از ۱ تا ۹ نرون متغیر در لایه پنهان و یک نرون در لایه خروجی، و الگوریتم آموزشی لونبرگ مارکواردت، نوشته شده در نرم‌افزار MATLAB می‌باشد که از نظر معیارهای ارزیابی همچون RMSE، MAE و R^2 از عملکرد خوبی در هر سه ایستگاه برخوردار بود. می‌توان گفت که مدل NN-ARX روند خوبی در آموزش داده‌ها داشته‌اند و در مرحله پیش‌بینی بخوبی داده‌ها را پیش‌بینی نموده‌اند. اما یکی از دلایلی که این پیش‌بینی در این مدل بخوبی انجام گرفته الگوریتم یادگیری بکار رفته در این شبکه‌ها به روش لونبرگ - مارکواردت می‌باشد زیرا این الگوریتم قدرت یادگیری و سرعت بیشتری نسبت به دیگر الگوریتم‌های بکار رفته دارد. شبکه عصبی - فازی استفاده شده با ۳ عدد تابع عضویت نوع گوسی نیز در مقابل سایر تعداد تابع عضویت و دیگر انواع توابع عضویت از قبیل مثلثی و ذوزنقه‌ای و... از برتری محسوسی از نظر معیارهای ارزیابی همچون RMSE، MAE و R^2 برای هر سه ایستگاه برخوردار بود.

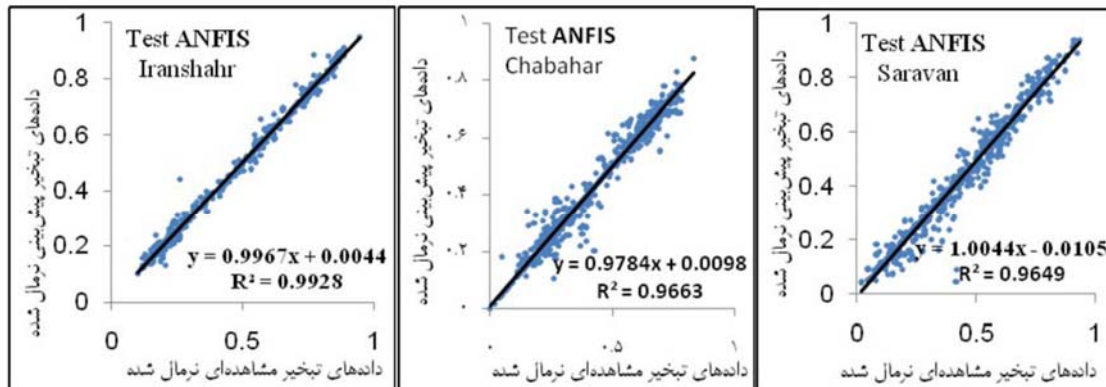
لذا، در این تحقیق کارایی دو مدل تلفیقی NN-ARX و GA-GT با ANFIS در شبیه‌سازی پارامتر غیرخطی و قطعی تبخیر روزانه از تشت در سه ایستگاه سینوپتیک ایران شهر، چابهار و سراوان در شرایط اقلیمی خشک و گرم بلوچستان مورد ارزیابی قرار گرفت. برای تعیین پارامترهای ورودی موثر بر عملکرد شبکه عصبی مصنوعی و شبکه عصبی فازی از گزینه الگوریتم ژنتیک موجود در آزمون گاما (GA-GT) استفاده گردید. بهترین ترکیب ورودی به مدل‌ها میانگین دما، میانگین رطوبت نسبی، سرعت باد، ساعات آفتابی و کمبود فشار اشباع انتخاب شد. با کاربرد روش آزمون گاما برای پیش‌پردازش پارامترها، ترتیب میزان اهمیت پارامترهای ورودی، بهترین ترکیب از میان تمام ترکیب‌های ممکن و تعداد داده‌های مورد نیاز برای ایجاد یک مدل هموار جهت ورود به ANN و ANFIS را بدست می‌آید. همانطور که قبلاً هم اشاره شد، در روش‌های هوش مصنوعی برای طراحی ساختار اگر فرض شود N پارامتر ورودی بر وقوع پدیده‌ای موثر باشند 2N-1 ترکیب معنی‌دار از پارامترهای ورودی بوجود می‌آید، که کاری بسیار وقت‌گیر و خسته کننده است. اما با استفاده از GA-GT با بررسی ۳۱ ترکیب ایجاد شده از ۵ پارامتر اقدام گردید. طبق نتایج آورده شده در جدول ۳ و شکل ۵، ترکیبی بهتر است که کمترین مقدار گاما و درعین حال کمترین مقدار خطای

جدول ۴- نتایج مدل های تلفیقی NN-ARX و ANFIS در هر ایستگاه‌های مورد مطالعه

نام روش	پارامترهای ورودی	عضویت/تابع محرک	ایران‌شهر			چابهار			سراوان		
			MAE	RMSE	R^2	MAE	RMSE	R^2	MAE	RMSE	R^2
NN-ARX	$T_{ave}, RH_{ave}, W, H, P$	Logsig-Logsig	0.167	4.07	0.993	0.193	3.6	0.97	5.8	0.484	
ANFIS	$T_{ave}, RH_{ave}, W, H, P$	Gauss	0.131	3.08	0.996	0.126	2.55	0.985	4.6	0.34	



شکل ۶- نمودار بین مقادیر مشاهده شده و برآورد شده در ایستگاه‌های سینوپتیک سه گانه با مدل تلفیقی GAGT-NN-ARX و ضرایب همبستگی آنها



شکل ۷- نمودار بین مقادیر مشاهده شده و برآورد شده در ایستگاه‌های سینوپتیک سه‌گانه با مدل تلفیقی GAGT-ANFIS و ضرایب همبستگی آنها
 الف) نمودار پراکندگی ایستگاه سینوپتیک ایرانشهر (ب) نمودار پراکندگی ایستگاه سینوپتیک چابهار (ج) نمودار پراکندگی ایستگاه سینوپتیک سراوان
 الف) نمودار پراکندگی ایستگاه سینوپتیک ایرانشهر (ب) نمودار پراکندگی ایستگاه سینوپتیک چابهار (ج) نمودار پراکندگی ایستگاه سینوپتیک سراوان

در این تحقیق کارایی دو مدل تلفیق غیر خطی GAGT-NN و ARX و GAGT-ANFIS جهت برآورد تبخیر روزانه از تست در بعضی از شرایط اقلیمی شامل اقلیم خشک و گرم (ایران‌شهر)، اقلیم خشک و گرم ساحلی (چابهار) و اقلیم نیمه خشک و معتدل گرم (سراوان) بر اساس روش اقلیم بندی چند متغیره آماری مورد بررسی قرار گرفته است. مطابق جدول ۴، نتایج حاصله از بکارگیری معیارهای ارزیابی (R^2 ، RMSE و MAE) نشان دهنده توانایی مطلوب دو مدل فوق در ایستگاه ایرانشهر تحت شرایط اقلیمی خشک و گرم نسبت به دو ایستگاه چابهار تحت شرایط اقلیمی خشک و گرم ساحلی و سراوان تحت شرایط اقلیمی نیمه خشک و معتدل گرم می‌باشد. همچنین هر دو از دقت و سرعت خوبی در برآورد تبخیر روزانه از تست برخوردار هستند. جواب متفاوت مدل‌ها در هر یک از آب و هوای فوق‌الذکر بیانگر کارایی مطلوب آن‌ها متناسب با شرایط اقلیمی و داده‌های ورودی است.

گرچه مطابق نتایج جدول ۴ و بر اساس معیارهای ارزیابی RMSE، MAE و R^2 دقت و ارجحیت مدل GAGT-ANFIS در مقابل GAGT-NN-ARX بیشتر می‌باشد.

آنچه از جدول ۴ قابل استنباط است توانایی بالای مدل NN-ARX با الگوریتم لونبرگ - مارکوارت در محاسبه تبخیر روزانه از سطح آزاد است. بطوری که روند خوبی در آموزش داده‌ها داشته و در مرحله پیش‌بینی بخوبی داده‌ها را پیش‌بینی نموده‌است. شبکه عصبی-فازی استفاده شده با تابع عضویت نوع گوسی از برتری محسوسی از نظر معیارهای ارزیابی همچون RMSE، MAE و R^2 برای هر سه ایستگاه برخوردار بود. اشکال ۶ و ۷ نتایج مقایسه داده‌های واقعی با داده‌های پیش‌بینی شده و نمودار پراکندگی تبخیرهای مشاهده‌ای و پیش‌بینی شده را نشان می‌دهد.

نتیجه‌گیری

در زمینه برآورد تبخیر روزانه از تست که یک فرایند غیر خطی و پیچیده و متأثر از پارامترهای مختلف هواشناسی با عدم قطعیت می‌باشد، روش‌ها و فرمول‌های تجربی غیرخطی زیادی ارائه شده که اولاً از دقت بالایی برخوردار نبوده و ثانیاً دسترسی به تمام پارامترهای ورودی آنها مشکل و یا اندازه‌گیری آنها محتاج صرف هزینه و زمان زیادی می‌باشند.

منابع

- ۱- پیری م، دهقانی ا.ا، حسام م. و ظهیری ع.ر. ۱۳۸۷. استفاده از شبکه‌های عصبی مصنوعی در تخمین تبخیر روزانه از تست تبخیر. دومین همایش ملی مدیریت شبکه‌های آبیاری و زهکشی.
- ۲- قبائی س.م، مساعدی ا.، دهقانی ا.ا. ۱۳۹۰. مدل‌سازی هوشمند تابش خورشیدی با استفاده از آزمون گاما و مقایسه با معادلات تجربی واسنجی شده در کرمانشاه. مجله پژوهش‌های حفاظت آب و خاک، جلد ۱۸، شماره ۴.
- ۳- مفتاح هلقی م، پیری م، دهقانی ا.ا، حسام م. و ظهیری ع.ر. ۱۳۸۸. استفاده از سیستم استنتاج فازی-عصبی در تخمین تبخیر روزانه از تست تبخیر. پنجمین همایش ملی علوم و مهندسی آب‌خیزداری ایران.
- ۴- کارآموز م. و عراقی نژاد ش. ۱۳۸۴. هیدرولوژی پیشرفته. مرکز نشر دانشگاه صنعتی امیرکبیر. تهران.

- ۵- مرکز تحقیقات هواشناسی کاربردی سیستان و بلوچستان. ۱۳۸۹.
- ۶- منہاج م.ب. ۱۳۸۱. مبانی شبکه های عصبی. مرکز نشر دانشگاه صنعتی امیرکبیر. تهران.
- 7- Bruton J.M., McClendon R.W., and Hoogenboom G. 2000. Estimating daily pan evaporation with artificial neural network. *Trans. Of the ASCE*, 43(2):492-496.
- 8- French M.N., Krajewski W.F., and Cuykendall R.R. 1992. Rainfall forecasting in space and time using neural network. *J. Hydrol.*, 137:1-31.
- 9- Goel A. 2009. Annbased modeling for prediction of evaporation in reservoirs (research note). *Transaction A:Basics*, 22-4:351-358 .
- 10- Hudson N.W. 1987. Soil and water conservation in semi-arid areas. Food and Agriculture Organization (FAO). *Soil Bulletin*, 57:109-122.
- 11- <http://www.wnn.ir>
- 12- Jang J.S.R., Sun C.T. and Mizutani E. 1997. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intellogence*. Prentice-Hall International. New Jersey.
- 13- Keskin M.E., Terzi O., and Kucukille E.U. 2009. Data mining process for integrated Evaporation model. *Journal of Irrigation and Drainage Engineering*, 135: 39-43.
- 14- Kisi O. 2006. Daily pan evaporation modeling using a neuro-fuzzy computing technique. *J. Hydrol.* 329: 636-646.
- 15- Maier H.R., Jain A., Dandy G.C., and Sudheer K.P. 2010. Methods used for development of neural networks for the prediction of water resource variables in rivers systems: Current status and future directions. *Environmental Modeling & Software*, 1-19.
- 16- Mayer W.S. 1999. Standard reference evaporation calculation for Inland, South Eastern Australia. CSIRO Land and Water, Adelaide Laboratory, Technical Report 35/98, September.
- 17- Moghaddamnia A., Ghafari Gousheh M., Piri J., Amin S., and Han D. 2008. Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources*, 32: 88-97.
- 18- Moghaddamnia A., Remesan R., Hassanpour Kashani M., Mohammadi M., Han D., and Piri J. 2009. Comparison of LLR, MLP, Elman, NNARX and ANFIS Models with a case study in solar radiation estimation. *Journal of Atmospheric and Solar-Terrestrial Physics*, 71: 975-982.
- 19- Monte R.A. 1999. A random walk for dummies. *Mit undergraduate journal of mathematics*, 1:143-148.
- 20- Piri J., Amin S., Moghaddamnia A., Keshavarz A., Han D. and Remesan R. 2009. Daily Pan evaporation modeling in a hot and dry Climate. *Journal of Hydrologic Engineering*, 14(8): 803-811.
- 21- Rahimikhoob A. 2009. "Estimation daily pan evaporation using artificial neural network in a Semi-Arid environmental. *Theoretical and Applied Climatology*, 98:101-105.
- 22- Rosenberry D.O., Winter T.C., Buso D.C. and Likens G.E. 2007. Comparison of 15 evaporation methods applied to a small mountain lake in the northeastern USA. *Journal of Hydrology*, 340: 149-166.
- 23- Remesan R., Shamim M.A., and Han D. 2008. Model data selection using gamma test for daily solar radiation estimation. *Hydrological Processes*, 22:4301-4309.
- 24- Shirsath P.B., and Singh A.K. 2010. A comparative study of daily pan evaporation estimation using ANN, regression and climate based models. *Water Resource Management*, 24:1571-1581.
- 25- Sudheer K.P., Gosain A.K., Mohana R.D. and Saheb S.M. 2002. Modeling evaporation using an artificial neural network algorithm. *Hydrological Processes*, 16:3189-3202.
- 26- Sungwon K., Hongkee J. 2006. "An Expansion of the Ungaged Pan Evaporation Using Neural Networks Model in Rural Regions, South Korea" *World Environmental and Water Resources Congress*.
- 27- Tabesh M., Soltani J., Farmani R. and Savic D. 2009. Assessing pipe failure rate and mechanical reliability of water distribution networks using data-driven modeling. *Journal of Hydroinformatics*, 11(1): 1-17.
- 28- Terzi O., and Keskin M.E. 2005. Modeling of daily pan evaporation. *Journal of Applied Sciences*, 5(2):368-372.
- 29- Willmott C.J. 1982. Some comments on the evaluation of model performance. *Bulletin of American Meteorological Society*, 63:1309-1313.



Performance Comparison of Integrated Models of NN-ARX and ANFIS with GA-GT to Daily Pan Evaporation Estimation Under Arid and Hot Climate of Baluchistan

J. Soltani^{1*}- A. Moghaddamnia²- J. Piri³- J. Mirmoradzehi⁴

Received:29-09-2012

Accepted:08-01-2013

Abstract

Nowadays, accurate estimation of evaporation as one of the important elements of hydrological cycle can play an important role in sustainable development and optimal water resources management of the countries facing water crisis. Up to now, empirical methods and formulas on estimation of non-linear and complex process of daily pan evaporation have been developed that is of uncertainty. These methods and formulas do not have high accuracy and also access to their input parameters is difficult or their measurement requires high cost and time. In this study, performances of two non-linear models of NN-ARX and ANFIS have been evaluated to estimate daily pan evaporation under arid and hot climate conditions including dry and warm climate (Iranshahr), dry and coastal warm (Chahbahar), and semi-arid and warm temperate (Saravan). For this purpose, the best combination of model inputs was selected by using Genetic Algorithm embedded in Gama Test software for each of Synoptic stations located in these regions for the 5years period(2005-2010), then daily pan evaporation was estimated by using NN-ARX and ANFIS models. By employing the statistical criteria including R2 .RMSE and MAE, performances of ANFIS model with three Gaussian membership functions and NN-ARX model were evaluated for each of the selective Synoptic stations. The obtained results indicate the accuracy of ANFIS model is higher than the one of NN-ARX model in estimating daily pan evaporation in different climatic conditions.

Keywords: Pan evaporation, ANNs, ANFIS, Genetic Algorithm, Gama Test, Arid and hot climate, Baluchistan

1- Assistant Professor of Irrigation and Drianage Engineering Department, Aboureyhan Compus, University of Tehran (*-Corresponding Author Email: Jsoltani@ut.ac.ir)

2- Associate Professor of Mountain and Arid Regions Reclamation Department, Faculty of Natural Resources, University of Tehran

3,4- Lecture and Former MSc Student of Water Engineering Department, Faculty of Water and Soil, University of Zabol