

پیش‌بینی نوسانات عمق سطح آب زیرزمینی با استفاده از مدل‌های تلفیقی شبکه‌ی

عصبی - فازی تطبیقی - موجکی (WNF) (مطالعه موردی: دشت الشتر)

مسعود شاکرمی^{۱*}

تاریخ ارسال: ۱۴۰۰/۰۳/۰۴

تاریخ پذیرش: ۱۴۰۰/۰۵/۱۰

مقاله پژوهشی

چکیده:

هدف از تحقیق حاضر، تخمین سطح آب زیرزمینی دشت الشتر در زمان‌های $t+1$ ، $t+3$ و $t+6$ با استفاده از پارامترهای دما، بارش و سطح آب زیرزمینی در زمان‌های $t-1$ و $t-2$ با استفاده از مدل‌های شبکه عصبی (ANN)، سیستم استنتاج عصبی-فازی (ANFIS)، عصبی-موجکی (WNN) و تلفیق شبکه‌ی عصبی-فازی-موجکی (WNF) می‌باشد. جهت ارزیابی مدل‌ها از دو شاخص R^2 و RMSE استفاده گردید. نتایج حاصل از پیش‌بینی مدل‌های مختلف نشان داد که WNN، ANFIS و WNF نسبت به مدل ANN در پیش‌بینی عمق سطح آب زیرزمینی دارای دقت بالاتری می‌باشند. همچنین مقایسه نتایج حاصل از مدل‌هایی با پایه موجکی و دیگر مدل‌ها نشان می‌دهد، این مدل‌ها (WNN و WNF) دارای دقت بالاتری نسبت به دیگر مدل‌ها می‌باشند. به طوریکه استفاده از مدل WNF نسبت به ANN شاخص R^2 را از ۰/۹۴ به ۰/۹۸ (در پیش‌بینی یک ماه)، ۰/۸۴ به ۰/۹۳ (در پیش‌بینی سه ماهه) ۰/۷۶ به ۰/۸۵ (در پیش‌بینی شش ماهه) افزایش داده است. همچنین مدل WNF نسبت به ANN، شاخص RMSE را به ترتیب از ۰/۵۶ به ۰/۳۲ (در پیش‌بینی یک ماه)، ۰/۹۶ به ۰/۶۶ (در پیش‌بینی سه ماهه) و ۱/۱۸ به ۰/۹۷ (در پیش‌بینی شش ماهه) کاهش داده است. نتایج پیش‌بینی عمق سطح آب زیرزمینی با مدل‌های چهارگانه نشان داد که این مدل‌ها در پیش‌بینی گام‌های زمانی کوتاه‌تر، دارای نتایج دقیق‌تر بوده و استفاده از آنها در پیش‌بینی‌های با تأخیر زمانی بیشتر از سه ماهه، نه تنها تأثیر چندانی بر دقت مدل نداشته بلکه در مدل‌های با پایه موجکی، سبب کاهش دقت می‌شود.

واژه‌های کلیدی: آب‌های زیرزمینی، الشتر، تبدیل موجکی، سری زمانی، عصبی-فازی-موجکی

^۱ - * استادیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه لرستان، خرم‌آباد، ایران مسئول مکاتبات، ایمیل: shakarami.mas@lu.ac.ir



مقدمه

جهت برنامه‌ریزی تأمین آب قابل اعتماد و نیز مدیریت منابع آب، شناخت و بررسی دقیق نوسانات سطح آب زیرزمینی ضروری می‌باشد (عربی جوانمرد و جعفری، ۱۳۹۵، گنگ و همکاران، ۲۰۱۸). برنامه‌ریزی و مدیریت دقیق و قابل اطمینان از منابع آب، اطمینان از استفاده پایدار از منابع آبخیزداری بدون مدل‌های دقیق و قابل اطمینان حاصل نمی‌شود. علیرغم پیچیده‌گی و ماهیت تصادفی فرآیندهای هیدرولوژیکی در دهه‌های اخیر، پیشرفت‌های قابل توجه در توانایی و تولید مدل‌های دقیق هیدرولوژیکی حاصل شده است (نوری و همکاران، ۲۰۱۵).

پیش‌بینی نوسانات سطح آب زیرزمینی برای مدیریت صحیح این منابع با ارزش امری کاملاً ضروری است. روش‌های مختلفی برای پیش‌بینی سری‌های زمانی هیدرولوژیکی نظیر سطح آب زیرزمینی وجود دارد. عدم کارایی مدل‌های خطی در پیش‌بینی سری‌های زمانی نامانای و غیرخطی منجر به استفاده‌ی گسترده‌ی محققان از روش‌های هوش مصنوعی مانند شبکه‌های عصبی مصنوعی (ANN)، سیستم استنتاج فازی (FIS)، الگوریتم ژنتیک (GA) و نیز مدل‌های ترکیبی آن‌ها نظیر سیستم استنتاج عصبی-فازی (ANFIS) شده است. این مدل‌های هوشمند با استفاده از داده‌های اندک قادرند در مدت زمان کوتاه، سری‌های زمانی نامانای و غیرخطی را با دقت مناسب شبیه‌سازی کنند. با ظهور تبدیل موجک (WT) به عنوان ابزاری قدرتمند در تجزیه‌ی سری‌های زمانی نامانای و غیرخطی و اثبات توانایی‌های آن، تاکنون پدیده‌های هیدرولوژیکی زیادی با استفاده از آن بررسی شده‌اند. اما در زمینه‌ی آب‌های زیرزمینی و در تلفیق با دیگر مدل‌های هوشمند کمتر مورد استفاده قرار گرفته است (گنگ، ۲۰۱۸، سوریانارایانا و همکاران، ۲۰۱۴). تا کنون در سطح ملی و بین‌المللی پژوهش‌هایی در زمینه استفاده از مدل‌های هوشمند، جهت پیش‌بینی پدیده‌های هیدرولوژیکی انجام گرفته است.

دهقانی و همکاران (۱۳۸۹) در مقایسه سه روش شبکه عصبی مصنوعی، سیستم استنتاجی فازی-عصبی تطبیقی و زمین آمار در پیش‌بینی سطح آب زیرزمینی دشت قزوین

گزارش نمودند که روش سیستم استنتاجی فازی عصبی برای برآورد سطح آب در نقاط مجهول آبخوان داری دقت بیشتری نسبت به دو روش دیگر می‌باشد. زمانی و همکاران (۱۳۹۳) از تلفیق مدل شبکه عصبی مصنوعی بهینه شده با الگوریتم ژنتیک و روش زمین آمار برای تخمین تراز سطح ایستابی دشت‌های دزفول، زیدون و رامهرمز استفاده و گزارش نمودند که تلفیق این دو مدل قابلیت بسیار بالایی در تخمین سطح آب زیرزمینی این دشت‌ها دارد. همچنین نتایج بررسی کارآیی روش‌های شبکه عصبی مصنوعی و سری زمانی در پیش‌بینی سطح آب زیرزمینی در زیرحوضه بختگان استان فارس در دوره آماری ۸۹-۸۱ نشان داد که کارآیی و دقت هر دو تکنیک شبکه عصبی و سری زمانی در پیش‌بینی سطح ایستابی بالاست (پورمحمدی و همکاران، ۱۳۹۲).

نتایج تحقیق دیگر در بررسی عملکرد مدل شبکه عصبی موجک در تخمین دبی روزانه ایستگاه بادآور نورآباد واقع در استان لرستان نشان داد که مدل شبکه عصبی-موجک دارای عملکرد بهتری نسبت به مدل شبکه عصبی-مصنوعی دارد، به گونه‌ای که مدل شبکه عصبی موجک بالاترین ضریب تعیین (۰/۹۲)، جذر میانگین مربعات خطا (۰/۰۰۵) و نیز میانگین قدر مطلق خطا (۰/۰۰۳) در مرحله صحت سنجی در اولویت قرار دارد (باباعلی و دهقانی، ۱۳۹۸). همچنین در پژوهشی برای پیش‌بینی دبی اوج سیلاب حوضه مادرسو در استان گلستان از مدل شبکه عصبی و رگرسیون چند متغیره استفاده گردید. نتایج این تحقیق نشان داد مدل شبکه عصبی در مرحله آموزش به تعداد لایه میانه حساس نبوده و از عملکرد بهتری نسبت به روش رگرسیون چند متغیره برخوردار است (علیجانی و پناهی، ۱۳۹۲).

شاهی نژاد و دهقانی (۱۳۹۷) عملکرد مدل‌های شبکه عصبی موجک، ماشین بردار پشتیبان و برنامه‌ریزی بیان ژن به منظور تخمین اکسیژن محلول در آب رودخانه کامبرلند واقع در ایالت تنسی را بررسی و گزارش نمودند که به لحاظ توانایی بالای شبکه عصبی-موجک و حذف نویزهای سری‌های زمانی در تخمین پارامترهای کیفی آب رودخانه، این مدل می‌تواند راهکاری مناسب و سریع در مدیریت کیفیت منابع آب مطرح شود. پیش‌بینی نوسانات سطح آب

(MSE) و میانگین خطای مطلق (MAE) نشان داد که مدل ANN دقیق‌ترین نتایج را ارائه می‌دهد (معروف‌پور و همکاران، ۲۰۱۹). گرفت و همکاران (۲۰۱۹) از یک مدل ترکیبی موجک گسسته (WT) و شبکه‌های عصبی مصنوعی (ANN) برای پیش‌بینی دمای آب رودخانه وارتا در لهستان استفاده و گزارش نمودند که مدل‌های WT-ANN در شبیه‌سازی و پیش‌بینی سری زمانی دمای آب رودخانه از مدل‌های خطی، غیر خطی و سنتی ANN بهتر عمل می‌کنند.

در این راستا طی سالیان اخیر مدل‌های هوش مصنوعی نظیر شبکه‌های عصبی مصنوعی و شبکه‌های عصبی-فازی با ویژگی‌هایی چون غیرخطی بودن، استفاده از داده‌های محدود، سرعت بالای مدل‌سازی و از همه مهم‌تر دقت بالاتر آن‌ها در پیش‌بینی سری‌های زمانی نامانا، به صورت گسترده در زمینه‌های مختلف کاربرد یافته‌اند. اخیراً تبدیل موجک به عنوان ابزاری قدرتمند در تجزیه و تحلیل سری‌های زمانی نامانا کاربرد فراوانی در مدل‌سازی فرآیندهای هیدرولوژیکی یافته است. با استفاده از تبدیل موجک هر سری زمانی به مقادیر تقریبی و جزئیاتش تجزیه شده و پس از مدل‌سازی این مؤلفه‌ها، سری اصلی مجدداً از اجزایش بازسازی می‌شود. این تبدیل نسبت به تبدیل فوریه در تحلیل سری‌های نامانا، کارایی بیشتری دارد زیرا تبدیل موجک توانایی ارائه‌ی همزمان اطلاعات زمانی و فرکانسی یک سیگنال را دارد در حالی که تبدیل فوریه تنها قادر به ارائه‌ی اطلاعات فرکانسی سیگنال می‌باشد (حسن زاده، ۱۳۹۱).

توانایی مدل‌های تلفیقی شبکه‌های عصبی-موجکی (WNN) و عصبی-فازی (ANFIS) در مدل‌سازی فرآیندهای مختلف هیدرولوژیکی به اثبات رسیده است (شیری و کیسی، ۲۰۱۲، جوان و همکاران، ۲۰۱۵، اتر و همکاران، ۲۰۱۷) حال با تحقیقات انجام گرفته توسط نویسندگان، تاکنون مدل تلفیقی شبکه‌ی عصبی-فازی-موجکی (WNF) در سطح کشور در زمینه پیش‌بینی سطح آب زیر زمینی بکار نرفته است. بنابراین لازم است کارایی این مدل در زمینه‌ی آب‌های زیرزمینی به منظور مدیریت بهتر این منابع حیاتی مورد بررسی و ارزیابی قرار گیرد. لذا هدف از تحقیق حاضر استفاده از روش تلفیقی شبکه‌ی عصبی-فازی تطبیقی-موجکی (WNF) برای پیش‌بینی

زیرزمینی در حوضه آبریز می‌شی وارم حیدرآباد هند با استفاده از شبکه عصبی استاندارد FFN که با الگوریتم لوبنرگ-مارکورت (LM) آموزش دیده شده نشان داد که مدل مذکور بهترین انطباق و روند پیش‌بینی را با داده‌های مشاهداتی دارد (رکانت، ۲۰۰۹).

شیری و کیسی (۲۰۱۱) توانایی سیستم‌های استنتاج عصبی-فازی تطبیقی (ANFIS) و برنامه نویسی ژنتیکی (GP) را برای پیش‌بینی نوسانات عمق سطح آب مورد بررسی قرار دادند. نتایج این محققان نشان داد که مدل‌های ANFIS و GP را می‌توان با موفقیت در پیش‌بینی عمق آب‌های زیرزمینی به کار برد.

عملکردهای دو روش هوشمند شبکه عصبی مصنوعی (ANN) و سیستم استنتاج عصبی-فازی (ANFIS) برای پیش‌بینی هدایت الکتریکی آب (EC) ۱۲۰ چاه مشاهده‌ای در دشت تبریز با استفاده از مختصات جغرافیایی (پارامتر ورودی) مورد بررسی قرار گرفت. نتایج نشان داد که مدل ANFIS با خطای جذر میانگین مربعات $1/69 \text{ dS.m}^{-1}$ و ضریب همبستگی (R^2) ۰/۸۴، بهترین دقت را در بین مدل‌ها نشان داد (جیهونی و همکاران، ۲۰۱۵).

در مطالعه‌ی برای پیش‌بینی نوسانات سطح آب زیرزمینی از ترکیبی از تجزیه حالت تجربی گروه (EEMD) و مدل‌های داده محور (مانند شبکه‌های عصبی مصنوعی (ANN)، ماشین‌های بردار پشتیبانی (SVM) و سیستم استنتاج عصبی-فازی (ANFIS)) استفاده گردید. نتایج نشان داد که مدل‌های ترکیبی EEMD-ANN، EEMD-SVM و EEMD-ANFIS دارای مقدار R بالاتر و میانگین RMSE کمتری از ANN، SVM و ANFIS بودند. نتایج حاصل از این مطالعه نشان داد که مدل‌های ترکیبی پیشنهادی می‌توانند قابلیت پیش‌بینی نوسانات سطح آب زیرزمینی را بهبود و به عنوان دستورالعملی مفید و سودمند برای مدیریت منابع آب پایدار به کار گرفته شوند (گنگ و همکاران، ۲۰۱۸).

در مطالعه‌ای از روش‌های مبتنی بر زمین آمار و شبکه عصبی مصنوعی (ANN) و مدل ANFIS برای پیش‌بینی توزیع مکانی هدایت الکتریکی آب‌های زیرزمینی (EC) در دشت‌های کشتیت، نرماشیر بم و رحمت آباد کرمان استفاده شد. مقادیر شاخص‌های ریشه میانگین مربعات خطا



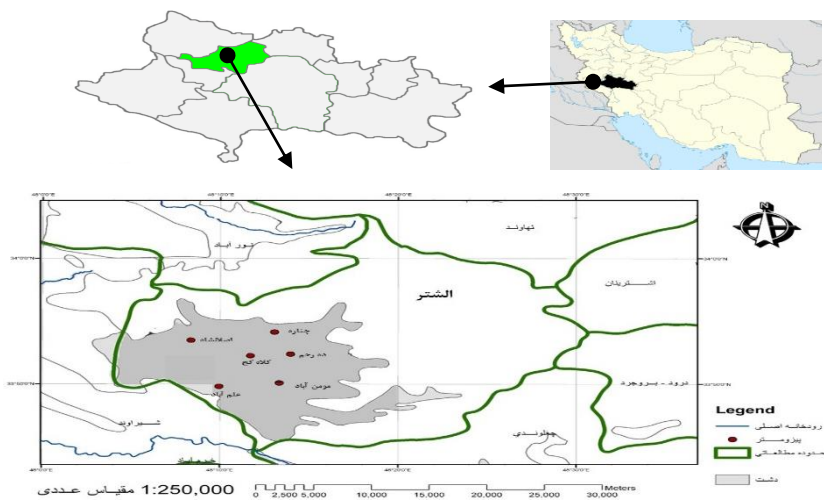
رودخانه کشکان است که خود یکی از شاخه‌های رودخانه کرخه به شمار می‌رود. حداکثر و حداقل ارتفاع حوضه به ترتیب با ۳۶۳۹ و ۱۴۷۰ متر در قله کوه‌های گرین و خروجی حوضه رودخانه هررود می‌باشد. متوسط ارتفاع محدوده مطالعاتی ۲۰۹۹ متر از سطح دریا محاسبه شده است. این شهرستان از نظر اقلیمی، دارای اقلیم مدیترانه‌ای و نیمه‌مرطوب با زیراقلیم سرد و فراسرد (یا ارتفاعی) می‌باشد. میزان بارندگی از ۴۵۰ میلیمتر در نواحی مرکزی تا بیش از ۱۰۰۰ میلی‌متر در سال در ارتفاعات شمال غربی متغیر و متوسط آن ۵۵۴ میلی‌متر تعیین گردیده است (کالیبراد و همکاران، ۱۳۹۲). به علت قرارگرفتن اکثر اراضی محدوده مطالعاتی در رقوم‌های بالاتر از ۱۶۰۰ متر از سطح دریا، سهم قابل‌توجهی از ریزش‌ها در فاصله ماه‌های آبان لغایت اردیبهشت بصورت برف پایدار و نیمه‌پایدار می‌باشد، از این نظر رژیم رودخانه از نظر منشاء جریان "بارانی - برفی" می‌باشد. جهت جریان آب زیرزمینی حوضه از نواحی شمال، شمال غرب و شمال شرق به سمت جنوب و به سمت رودخانه است. آبخوان الشتر از نوع سفره آزاد است (سلیمانی مطلق و همکاران، ۱۳۹۵).

سطح آب زیرزمینی در یک $[h(t+1)]$ ، دو $[h(t+3)]$ و سه $[h(t+6)]$ ماه آینده دشت الشتر و مقایسه آن با نتایج بدست آمده از مدل‌های ANN، WNN و ANFIS می‌باشد.

مواد و روش‌ها

موقعیت منطقه مورد مطالعه:

با توجه به اهمیت آبخوان الشتر در تأمین آب کشاورزی، بررسی نوسانات سطح ایستایی برای مدیریت منابع آب در این ناحیه لازم می‌باشد. هدف از پژوهش حاضر پیش‌بینی نوسانات سطح آب زیرزمینی در آبخوان الشتر می‌باشد. به طور کلی در این پژوهش از پارامترهای داده‌های دما (T)، بارش (P) و سطح آب زیرزمینی (G) در زمان‌های $t-2$ ، $t-1$ ، t ، $t+1$ ، $t+3$ و $t+6$ استفاده شده است. حوضه آبریز الشتر با وسعت ۸۱۱ کیلومتر مربع در ناحیه غربی کشور و در دامنه‌های جنوب غربی رشته کوه زاگرس واقع گردیده است و از نظر جغرافیائی در مختصات $۳۴^{\circ}-۰۵'$ تا $۴۸^{\circ}-۳۱'$ طول شرقی و $۴۳^{\circ}-۳۳'$ تا $۳۴^{\circ}-۰۵'$ عرض شمالی قرار دارد. این حوضه از زیر حوضه‌های فرعی



شکل (۱): موقعیت دشت الشتر بر روی نقشه کشور ایران و همچنین نقشه پراکندگی پیژومترها در دشت الشتر

شدند. موقعیت محدودی مطالعاتی در کشور و همچنین مشخصات جغرافیایی چاه‌های نمونه برداری به ترتیب در شکل (۱) و جدول (۱) ارائه شده است. در این پژوهش از آمار دما و بارش ماهیانه ایستگاه‌های خرم‌آباد و سراب صیدعلی به ترتیب به عنوان ایستگاه معرف حوضه استفاده شده است.


شبکه عصبی مصنوعی پرسپترون چند لایه (ANN):

شبکه‌های عصبی مصنوعی (ANN) در حقیقت مدل ساده شده‌ای از سیستم عصبی مرکزی می‌باشند و کارکردی شبیه به مغز انسان دارند. معماری معمول ANNs متشکل از سه لایه است: لایه ورودی که داده‌ها را در شبکه توزیع می‌کند، لایه پنهان که داده‌ها را پردازش می‌کند و لایه خروجی که نتایج را به ازای ورودی‌های مشخص، استخراج می‌کند. شکل (۲) ساختار یک شبکه‌ی عصبی مصنوعی و نحوه‌ی عملکرد یک نرون را نشان می‌دهد.

جمع‌آوری داده‌ها، تجزیه و تحلیل آنها:

در این پژوهش، از داده‌های درازمدت ماهیانه‌ی موجود حوضه الشتر شامل داده‌های دما، بارش و سطح آب زیرزمینی که از سازمان آب منطقه‌ی لرستان گردآوری شده بود، به منظور پیش‌بینی سطح آب زیرزمینی توسط مدل‌های شبکه‌ی عصبی مصنوعی (ANN)، مدل‌های عصبی-فازی (ANFIS)، عصبی-موجک (WNN) و عصبی-فازی-موجکی (WNF) استفاده شد.

با استفاده از اطلاعات ۶ پیزومتر، از سال ۱۳۷۶ تا ۱۳۹۸ تراز سطح آب حوضه الشتر مورد بررسی قرار گرفت. مهم‌ترین معیار انتخاب پیزومترها در این پژوهش، برخورداری از آمار سطح آب زیرزمینی در ماه‌هایی مشابه بوده است. بر این اساس از بین چاه‌های دشت، ۶ پیزومتری مومن‌آباد، کلاه‌کج، ده‌رحم، چناره، علم‌آباد و اصلانشاه به منظور پیش‌بینی نوسانات سطح آب زیرزمینی انتخاب



شکل (۲): ساختار شماتیک یک شبکه‌ی عصبی مصنوعی سه لایه و نحوه‌ی پردازش اطلاعات در یک نرون

جدول (۱): موقعیت جغرافیایی پیزومترهای مورد مطالعه

نام پیزومتر	عرض	طول	ارتفاع
مؤمن‌آباد	۲۴۲۹۴۳	۳۷۴۷۳۴۲	۱۵۶۷/۷۲
کلاه‌کج	۲۴۱۵۳۴	۳۷۴۸۶۵۸	۱۵۷۶/۰۲
ده‌رحم	۲۴۱۸۲۵	۳۷۵۱۵۶۹	۱۵۸۶/۳۴
چناره	۲۴۲۷۳۰	۳۷۵۴۸۴۴	۱۶۱۲/۶۰
علم‌آباد	۲۳۹۴۴۵	۳۷۴۸۸۸۴	۱۵۷۲/۲۳
اصلانشاه	۲۳۹۵۶۷	۳۷۴۶۸۹۷	۱۵۶۲/۷۱

$$\text{if } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } z_2 \\ = p_2x + q_2y + r_2$$

در شکل‌های (۳ و ۴) به ترتیب ساختار یک سیستم فازی و یک سیستم عصبی-فازی سوگنو ارائه شده است. این سیستم برای فرآیند آموزش از ترکیبی از روش‌های آموزش پی انتشار خطا و کمیته مربعات و کمیته مربعات خطا بهره‌گیری می‌کند (کرباسی، ۱۳۹۵). در ANFIS لازم است که در لایه اول نوع تابع عضویت و تعداد آن مشخص شود. برای این منظور در لایه اول، دو روش تفکیک شبکه‌ای و تفکیک خوشه‌ای جهت کلاسه‌بندی داده‌ها وجود دارد. انواع توابع موجود در این شبکه شامل مثلثی، گوسی، گوسی نوع دو و دوزنقه‌ای می‌باشد. مدل فازی عصبی تطبیقی بر اساس تغییر در میزان مقادیر مرکز و دامنه توابع تعلق در تکرارهای مختلف جهت رسیدن به شبکه مناسب بر اساس حداقل خطای موجود عمل می‌کند. یک مدل ANFIS به طور کلی از پنج لایه تشکیل شده است:

لایه‌ی اول - گره‌های ورودی: هر گره این لایه، یک مجموعه‌ی فازی است. یعنی داده‌ها قبل از ورود به گره‌های این لایه توسط فازی‌سازها، فازی شده‌اند. خروجی هر گره لایه‌ی اول، درجه‌ی عضویت متغیر ورودی به مجموعه‌ی فازی یعنی $\mu_{A_i}(x)$ و $\mu_{B_j}(y)$ است که پارامترهای هر گره، تعیین‌کننده‌ی شکل تابع عضویت مجموعه‌ی فازی آن گره می‌باشند. تابع عضویت مناسب از بین توابع عضویت مثلثی، دوزنقه‌ای، گوسی، زنگوله‌ای و حلقوی با روش سعی و خطا، توسط کاربر تعیین می‌شود.

لایه‌ی دوم - گره‌های قاعده: در این لایه، مقادیر ورودی به هر گره توسط عملگرهای فازی با هم ترکیب شده و وزن هر قاعده به عنوان خروجی تعیین می‌شود. به عنوان مثال با ضرب دو مقدار ورودی به این گره‌ها، مقدار وزن هر گره از رابطه‌ی (۳) بدست می‌آید.

$$w_k = \mu_{A_i}(x) \times \mu_{B_j}(y) \quad (3)$$

لایه‌ی سوم - گره‌های متوسط: گره‌های این لایه، عمل محاسبه‌ی وزن نسبی قوانین را مطابق رابطه‌ی (۴) انجام می‌دهند. در اینجا n تعداد گره‌های این لایه است.

$$\bar{w}_k = \frac{w_k}{\sum_{k=1}^n w_k} \quad (4)$$

در یک شبکه‌ی عصبی مصنوعی، نرون m ام اطلاعات ورودی خود را از طریق گره‌های ورودی I_i دریافت و اطلاعات قبل از ورود به هسته‌ی اصلی نرون وزن دار می‌شوند. مقدار کل ورودی به نرون از رابطه‌ی (۱) محاسبه می‌شود. در مرحله‌ی بعد، یک تابع موسوم به تابع محرک که معمولاً تابعی غیرخطی است، روی این مقدار حاصل جمع عمل کرده و مقدار خروجی نرون از رابطه‌ی (۲) تعیین می‌گردد. در این تحقیق از مدل شبکه‌های عصبی پرسپترون چندلایه (MLP) و الگوریتم آموزش پس انتشار خطا (BP)، استفاده شد. جهت اطلاعات بیشتر در زمینه شبکه عصبی به پژوهش باباعلی و دهقانی (۱۳۹۸) رجوع گردد.

$$U_m = \sum_{i=1}^n I_i W_{i,m} + b_m \quad (1)$$

$$O_m = f\left(\sum_{i=1}^n I_i W_{i,m} + b_m\right) \quad (2)$$

سیستم استنتاج فازی - عصبی مصنوعی (ANFIS):

یک مجموعه‌ی فازی برخلاف یک مجموعه‌ی کلاسیک (مجموعه‌ی قطعی) دارای مرزهای مشخصی نیست. هر گزاره در منطق کلاسیک یا بولی، یا ارزش صفر دارد یا ارزش یک. یعنی در منطق کلاسیک، یا عضو x به مجموعه‌ی A تعلق دارد (معادل ارزش ۱) یا ندارد (معادل ارزش ۰). اما در منطق فازی، برای هر عضو درجه‌ای از عضویت بین ۰ و ۱ اختصاص می‌یابد. مشکل اصلی منطق فازی این است که فاقد روند سینماتیکی برای طراحی یک کنترل‌کننده‌ی فازی است. اما شبکه‌ی عصبی این توانایی را دارد که از محیط آموزش ببیند، ساختارش را خود مرتب کند و با شیوه‌ای، تعامل خود را تطبیق دهد. به همین سبب با ترکیب قابلیت سیستم فازی و قابلیت آموزش شبکه‌ی عصبی، مدل ANFIS به وجود آمده است. این مدل همانند مدل فازی از دانش تجربی بهره گرفته و نیز همانند مدل شبکه‌ی عصبی می‌تواند آموزش ببیند. مجموعه‌ی قوانین فازی با دو قاعده‌ی if-then برای مدل ANFIS به روش سوگنوی درجه‌ی اول و با دو ورودی x و y و یک خروجی z به صورت زیر تعریف می‌شوند.

$$\text{if } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } z_1 \\ = p_1x + q_1y + r_1$$

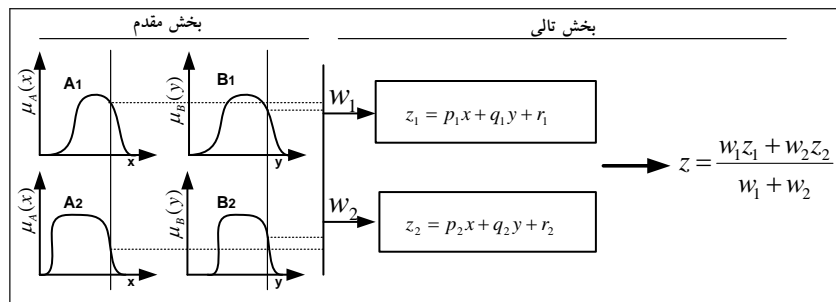
لایه‌ی پنجم - گرہ‌های خروجی: این لایه آخرین لایه‌ی شبکه بوده و دارای یک گرہ است. این تنها گرہ، تمامی ورودی‌هایش را مطابق رابطه‌ی (۶) جمع‌بندی کرده و به عنوان خروجی نهایی ارائه می‌دهد.

$$z = \sum_{k=1}^n z_k \quad (6)$$

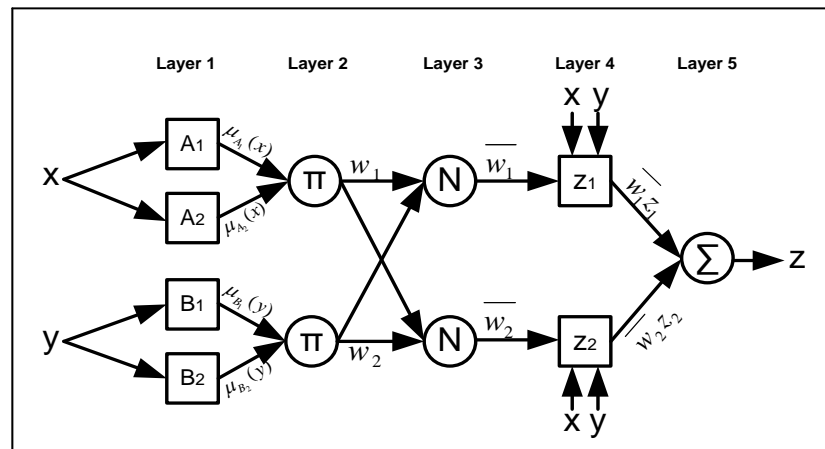
لایه‌ی چهارم - گرہ‌های نتیجه: این لایه، لایه‌ی قوانین نامیده می‌شود که در آن، قوانین وزن‌دار بخش تالی مدل، بر اساس ورودی‌های مدل شکل می‌گیرند. خروجی هر یک از گرہ‌های این لایه از رابطه‌ی (۵) بدست می‌آید.

$$z_k = \bar{w}_k(p_k x + q_k y + r_k) \quad (5)$$

که p_k ، q_k و r_k پارامترهای متعاقب یا نتیجه‌ی اولیه نامیده می‌شوند.



شکل (۳): ساختار یک سیستم استنتاجی فازی با تابع عضویت مثلثی و با دو قاعده



شکل (۴): ساختار سیستم استنتاج فازی - عصبی سوگنو با دو قاعده



موجک (WNN):

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \psi\left(\frac{t-\tau}{s}\right) \quad (8)$$

رابطه‌ی (۷) یک رابطه با دو متغیر s و τ است که s پارامتر مقیاس (عکس فرکانس) و τ پارامتر انتقال می‌باشند. علامت * نیز نشان دهنده‌ی مزدوج مختلط است. ψ تابع پنجره یا موجک مادر و $\frac{1}{\sqrt{|s|}} \psi\left(\frac{t-\tau}{s}\right)$ موجک‌های حاصل از انتقال و تغییر مقیاس موجک مادر هستند. واژه‌ی مادر به این سبب به کار می‌رود که تمامی نسخه‌های انتقال یافته و مقیاس شده (موجک‌های دختر)، همگی از این تابع به دست می‌آیند. یعنی موجک مادر یک الگو برای سایر پنجره‌هاست. علامت (...) نیز نشان دهنده‌ی ضرب برداری دو تابع در فضای سیگنال است.

با اعمال تبدیل گسسته، داده‌های اولیه موجکی شده و به دو دسته تقریب و جزئیات تقسیم می‌شوند. دسته تقریب دارای فرکانس کم بوده و نشان دهنده روند کلی داده‌های موجود می‌باشد و در محاسبات نقش بسیار مهمی را ایفا می‌نمایند. دسته جزئیات دارای فرکانس بالاست و بیانگر تغییرات محدوده در داده‌هاست. فرایند تجزیه سیگنال شامل یک یا چند مرحله است که در تجزیه چند مرحله‌ای، موج پس از اولین مرحله تفکیک با تجزیه مجدد قسمت تقریبی، تجزیه موج ادامه می‌یابد. در علوم منابع آب، بیشتر از موجک‌های هار (Haar)، دابچی (Db) و سیملت (Sym) استفاده شده است (کاناس و همکاران ۲۰۰۶).

توسعه‌ی مدل تلفیقی فازی - عصبی - موجکی (WNF): در این فاز، ابتدا هر یک از سری‌های زمانی دما، بارش و سطح آب زیرزمینی در زمان t و ماقبل آن، با استفاده از تبدیل موجک به مؤلفه‌های خود تجزیه و در مرحله‌ی بعد، این مؤلفه‌ها با استفاده از مدل‌های عصبی - فازی پیش‌بینی شدند. سپس مؤلفه‌های خروجی مدل با استفاده از فیلترهای بالاگذر و پایین‌گذر مناسب به منظور بازسازی سری زمانی پیش‌بینی شده، با هم ترکیب شدند. در نهایت مدل‌های با توابع عضویت، حدود و تعداد دسته‌های فازی مختلف و نیز الگوهای مختلف با استفاده از ضرایب R^2 و RMSE به منظور انتخاب مدل برتر در هر گام زمانی پیش‌بینی، مورد مقایسه و ارزیابی قرار گرفتند.

تبدیل موجک به عنوان روشی جایگزین برای تبدیل فوری‌ی زمان کوتاه ارائه شده است و هدف از ارائه‌ی آن، غلبه بر مشکلات مربوط به قدرت تفکیک‌پذیری فرکانس در تبدیل فوری‌ی زمان کوتاه است. در تبدیل موجک همانند تبدیل فوری‌ی زمان کوتاه، سیگنال مورد نظر به پنجره‌هایی تقسیم شده و تبدیل موجک بر روی هر کدام از این پنجره‌ها به صورت جداگانه انجام می‌گیرد. در تبدیل موجک علاوه بر تغییرپذیری قدرت تفکیک فرکانس‌های یک سیگنال یا طول پنجره، متناسب با نوع فرکانس، هم‌زمان عرض پنجره یا مقیاس فرکانس نیز متناسب با نوع فرکانس تغییر می‌کند. به عبارت دیگر، در تبدیل موجک به جای فرکانس، مقیاس وجود دارد. یعنی تبدیل موجک، نوعی تبدیل زمان - مقیاس است. بر همین اساس با استفاده از تبدیل موجک، در مقیاس‌های بالا سیگنال منبسط شده و جزئیات سیگنال قابل تجزیه و تحلیل است و در مقیاس‌های پایین سیگنال منقبض شده و کلیات سیگنال قابل بررسی می‌باشد. به این ترتیب، تبدیل موجک نسبت به تبدیل فوری‌ی زمان کوتاه، جزئیات بیشتری از سیگنال‌های نا ایستا ارائه داده و در پردازش آن‌ها به مراتب بهتر عمل می‌کند (حسن زاده، ۱۳۹۱). در تبدیل فوری‌ی زمان کوتاه به دلیل ثابت بودن اندازه‌ی پنجره، در سراسر صفحه‌ی زمان - فرکانس، رزولوشن ثابت است. در حالی که در تبدیل موجک، طول و عرض مستطیل‌ها که در واقع المان‌های رزولوشن هستند، تغییر می‌کنند. جهت اطلاعات بیشتر در زمینه سیستم موجک (WT) به پژوهش معروفی و همکاران (۱۳۹۲) رجوع گردد.

تبدیل موجک به دو صورت پیوسته و گسسته تعریف می‌شود.

تبدیل موجک پیوسته (CWT): تبدیل موجک پیوسته‌ی تابع $f(t)$ به صورت روابط (۷) و (۸) تعریف می‌شود.

$$\begin{aligned} CWT_f^\psi(s, \tau) &= \Psi_f^\psi(s, \tau) \\ &= \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (9) \\ &= \langle f(t), \psi_{s,\tau}(t) \rangle \end{aligned}$$

معیارهای آماری برای مقایسه مدل‌ها

به منظور مقایسه مدل‌های مختلف، از معیارهای آماری زیر استفاده گردیده است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - p_i)^2}$$

$$R^2 = \frac{(\sum_{i=1}^n (O_i - \bar{O}_i)(P_i - \bar{P}_i))^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \sum_{i=1}^n (P_i - \bar{P}_i)^2}$$

O_i : سطح آب مشاهداتی در پیزومترها، P_i : سطح آب پیش‌بینی شده توسط مدل، \bar{O}_i : میانگین سطح آب مشاهداتی در پیزومترها \bar{P}_i : میانگین سطح آب پیش‌بینی شده توسط مدل

به طور کلی در این پژوهش از پارامترهای دما، بارش و سطح آب زیرزمینی در زمان‌های $t-1$ و $t-2$ برای ایجاد الگوهای ورودی و به منظور پیش‌بینی سطح آب زیرزمینی در زمان‌های $t+1$ ، $t+3$ و $t+6$ استفاده شده است. بر این اساس ۶۳ الگوی ورودی ممکن در نظر گرفته شده است. با استفاده از مدل‌های شبکه‌ی عصبی، الگوهای ورودی برتر از بین الگوهای ورودی مورد نظر به روش سعی و خطا انتخاب شده و به عنوان الگوهای ورودی سایر مدل‌های غیرخطی نیز به کار رفته‌اند. برخی از الگوهای در نظر گرفته شده، در جدول (۲) آورده شده است. در این گام با استفاده از مدل انتخاب شده‌ی نهایی، سطح آب زیرزمینی در گام‌های زمانی ۱، ۳ و ۶ ماهه برای هر پیزومتر پیش‌بینی شده است.

جدول (۲): برخی از الگوهای ورودی برای مدل‌های غیرخطی

الگوی ورودی*	پارامترهای الگوی ورودی	الگوی ورودی	پارامترهای الگوی ورودی
I_1	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	I_4	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}$
I_2	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}$	I_5	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, G_t, G_{t-1}, G_{t-2}$
I_3	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t$	I_6	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, G_t, G_{t-1}$
I_{17}	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	I_{49}	$T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$
I_{18}	$P_t, P_{t-1}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}$	I_{50}	$T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}$
I_{19}	$P_t, P_{t-1}, T_t, T_{t-1}, T_{t-2}, G_t$	I_{51}	$T_t, T_{t-1}, T_{t-2}, G_t$
I_{20}	$P_t, P_{t-1}, T_t, T_{t-1}, T_{t-2}$	I_{52}	T_t, T_{t-1}, T_{t-2}
I_{29}	$P_t, P_{t-1}, G_t, G_{t-1}, G_{t-2}$	I_{61}	G_t, G_{t-1}, G_{t-2}
I_{30}	$P_t, P_{t-1}, G_t, G_{t-1}$	I_{62}	G_t, G_{t-1}
I_{31}	P_t, P_{t-1}, G_t	I_{63}	G_t
I_{49}	$P_t, P_{t-1}, G_t, G_{t-1}, G_{t-2}$	I_{64}	G_t, G_{t-1}, G_{t-2}

*: دلیل محدودیت در تعداد صفحات فقط برخی از الگوهای ورودی در جدول (۲) ذکر گردیده است.

موجکی (WNN) از نرم‌افزار MATLAB R2015a، استفاده شد.

برای آموزش مدل از ۸۰ درصد داده‌ها استفاده شده است. برای بررسی کارایی مدل، از ۲۰ درصد باقیمانده‌ی داده‌ها استفاده شده است. برای ارزیابی نتایج مدل‌سازی از ضرایب R^2 و $RMSE$ استفاده شده است. مدل‌های مختلف با معماری‌های گوناگون بر اساس ضرایب R^2 و $RMSE$ با هم مقایسه شده و مدل برتر به ازای هر الگوی ورودی انتخاب می‌شوند. در این تحقیق برای اجرای مدل‌های شبکه‌ی عصبی مصنوعی (ANN)، مدل‌های عصبی-فازی (ANFIS)، عصبی-موجک (WNN) و عصبی-فازی-

نتایج و بحث:

نتایج پیش‌بینی‌های ۱، ۳ و ۶ ماهه توسط هر یک از مدل‌های مورد نظر برای هر پیزومتر، در جداول ۳ تا ۵ ارائه گردیده است. در این جداول، نوع الگوی ورودی، تعداد گره‌ها و تعداد دوره‌ها یا تکرار فرآیند آموزش شبکه و در نهایت مقادیر معیارهای تعیین کارایی مدل (R^2 و $RMSE$)

مقادیر طبیعی‌تر بوده و دارای چولگی کمتری هستند. برعکس داده‌هایی که به صورت ناگهانی از میانگین یا مقدار قطعی فاصله گرفته‌اند، مدل‌های مورد نظر در این ماه‌ها دارای خطاهای بیشتری می‌باشد. نتایج ارائه شده در جداول ۳ تا ۶ نشان می‌دهد که کاربرد مدل‌های ANFIS، WNN و WNF نسبت به مدل ANN در تمامی پیرومترها نتایج بهتری را دارند. نتایج این تحقیق با نتایج زارع ایبانه و بیات ورکشی (۱۳۹۰)، اسمعیلی گیساوندانی و همکاران (۱۳۹۴) و کرباسی (۱۳۹۵) مطابقت دارد. این محققان بترتیب با کاربرد مدل تلفیقی ANFIS در پیش‌بینی رواناب، خشکسالی و تبخیر و تعرق گزارش نمودند که کاربرد مدل ANFIS نسبت به مدل ANN سبب بهبود نتایج می‌گردد. همچنین مدل‌های پیش‌بینی با پایه موجک سبب بهبود نتایج خواهد گردید

برای هر یک از مدل‌ها ارائه شده است. نمودار سری‌های زمانی مشاهده شده و پیش‌بینی شده‌ی سطح آب زیرزمینی در گام‌های زمانی ۱، ۳ و ۶ ماهه مربوط به پیرومترهای چناره و مومن‌آباد بعنوان نمونه (بعلت محدودیت در تعداد صفحات) در شکل‌های ۵ تا ۱۲ آورده شده است. همچنین در شکل ۱۳ به طور نمونه، مقادیر RMSE و R^2 مربوط به مدل‌های مختلف در پیرومتر چناره ارائه گردیده است. با دقت در نمودار مربوط به میزان خطای پیش‌بینی مدل‌های مختلف (شکل ۱۳) مشاهده می‌شود که این خطاها در ماه‌های مختلف پیش‌بینی، تقریباً روند تغییر مشابهی دارند. به عبارت دیگر خطای مدل‌های چهارگانه در ماه‌های پیش‌بینی مختلف، تقریباً روند تغییر یکسانی دارد و با هم کم و زیاد می‌شوند. دلیل این پدیده به ماهیت و مقدار داده‌ی مورد نظر بر می‌گردد. یعنی خطای مدل در داده‌های نزدیک به میانگین سری کمتر است زیرا این

جدول (۳): نتایج پیش‌بینی ۱ ماهه‌ی سطح آب زیرزمینی توسط مدل‌های مختلف در پی‌زومترهای مختلف

مدل	الگوی ورودی	نوع موجک	سطح تجزیه	تعداد گره میانی	تعداد تکرار	R ²	RMSE
اصلانشاه							
ANN	P _t , T _t , G _t , G _{t-1} , G _{t-2}	-	-	۲	۱۱	۰/۹۷۰۷	۱/۱۷۲۴
ANFIS	P _t , T _t , G _t , G _{t-1} , G _{t-2}	-	-	۴۴	۴۳	۰/۹۷۱۳	۱/۱۶۱۷
WNN	G _t , G _{t-1} , G _{t-2}	db _۲	۱	۲	۱۳	۰/۹۷۶۴	۱/۰۵۳۵
WANFIS	P _t , T _t , G _t , G _{t-1} , G _{t-2}	db _۲	۱	۴۴	۲۵	۰/۸۷۷۴	۰/۷۷۰۲
پی‌زومتر چناره							
ANN	T _t , G _{t-1} , G _t , G _{t-2}	-	-	۲	۳۲	۰/۸۹۸۲	۰/۴۰۹
ANFIS	T _t , G _{t-1} , G _t , G _{t-2}	-	-	۳۰	۶۶	۰/۹۲۵۶	۰/۳۴۲۴
WNN	P _t , T _t , G _t , G _{t-1} , G _{t-2}	db _۵	۲	۳	۲۳	۰/۹۷۷۷	۰/۱۸۷۰
WANFIS	G _t , G _{t-1} , G _{t-2}	db _۲	۲	۳۰	۱۷	۰/۹۸۴۴	۰/۱۵۶۷
ده رحم							
ANN	G _t , G _{t-1} , G _{t-2}	-	-	۴	۲۶	۰/۹۴۰۷	۰/۴۶۸۹
ANFIS	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	-	-	۷۲	۷۵	۰/۹۴۴۵	۰/۴۵۳۶
WNN	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	db _۲	۲	۲	۱۶	۰/۹۷۵۸	۰/۲۹۹۴
WANFIS	G _t , G _{t-1} , G _{t-2}	db _۲	۱	۳۰	۲۳	۰/۹۸۲۱	۰/۲۵۷۳
کلاه کج							
ANN	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	-	-	۴	۳۳	۰/۹۳۰۷	۰/۴۲۳۵
ANFIS	P _t , T _t , G _t , G _{t-1} , G _{t-2}	-	-	۴۴	۴۳	۰/۹۳۲۰	۰/۴۱۶۹
WNN	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	db _۵	۱	۲	۲۵	۰/۹۶۳۸	۰/۳۰۵۹
WANFIS	P _t , T _t , G _t , G _{t-1} , G _{t-2}	db _۵	۱	۴۴	۱۰۰	۰/۹۷۳۹	۰/۲۵۹۹
علم آباد							
ANN	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	-	-	۲	۱۴	۰/۹۵۱۱	۰/۴۷۶۷
ANFIS	P _t , T _t , G _t , G _{t-1} , G _{t-2}	-	-	۴۴	۴۱	۰/۶۴۰۶	۰/۵۲۶۳
WNN	P _t , P _{t-1} , T _t , T _{t-1} , G _t , G _{t-1} , G _{t-2}	db _۲	۱	۲	۸۰	۰/۹۶۸۹	۰/۳۸۰۱
WANFIS	G _t , G _{t-1} , G _{t-2}	db _۵	۱	۳۰	۲۲	۰/۹۸۴۷	۰/۲۶۷۱
مومن آباد							
ANN	P _t , P _{t-1} , T _t , T _{t-1} , G _t , G _{t-1} , G _{t-2}	-	-	۳	۲۷	۰/۳۱۱۲	۰/۴۱۰۲
ANFIS	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	-	-	۷۲	۷۲	۰/۹۲۹۵	۰/۳۶۵۷
WNN	P _t , P _{t-1} , T _t , T _{t-1} , G _t , G _{t-1} , G _{t-2}	db _۲	۱	۳	۱۶	۰/۹۶۷۹	۰/۲۴۷۱
WANFIS	G _t , G _{t-1} , G _{t-2}	db _۴	۱	۳۰	۱۸	۰/۹۷۸۹	۰/۲۰۰۲

ANFIS سبب بهبود قابل ملاحظه‌ای در نتایج پیش‌بینی‌های ۱، ۳ و ۶ ماهه شده است. موجک‌های db2، db3، db4، db5 و har در مدل‌های پیش‌بینی یک ماهه

بر اساس نتایج ارائه شده در جداول ۳ تا ۵ مشاهده می‌شود که استفاده از تبدیلات موجک در تجزیه‌ی سری‌های زمانی ورودی نسبت به مدل‌های ANN و

هر کدام به ترتیب ۳، ۱، ۴ و ۰ بار، در پیش بینی ۳ ماهه ۴ و ۱ بار برای تجزیه‌ی سری‌های زمانی ورودی به این مدل‌ها مورد استفاده قرار گرفته‌اند.

جدول (۴): نتایج پیش‌بینی ۳ ماهه‌ی سطح آب زیرزمینی توسط مدل‌های مختلف در پیزومترهای مختلف

مدل	الگوی ورودی	نوع موجک	سطح تجزیه	تعداد گره میانی	تعداد تکرار	R ²	RMSE
اصلا نشاء							
ANN	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	-	-	۲	۸	۰/۸۷۲۰	۲/۴۲۷۴
ANFIS	P _t , P _{t-1} , T _t , T _{t-1} , G _t , G _{t-1} , G _{t-2}	-	-	۵۸	۱۰۰	۰/۸۸۷۶	۲/۲۷۲۸
WNN	P _t , P _{t-1} , T _t , T _{t-1} , G _t , G _{t-1} , G _{t-2}	db _۲	۱	۲	۱۴	۰/۸۸۶۲	۲/۴۸۵۶
WANFIS	P _t , T _t , G _t , G _{t-1} , G _{t-2}	db _۲	۴	۴۴	۵۵	۰/۹۳۲۵	۱/۷۶۱۴
پیزومتر چناره							
ANN	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	-	-	۱	۲۱	۰/۷۷۵۴	۰/۶۰۰۷
ANFIS	G _t , G _{t-1} , G _{t-2}	-	-	۳۰	۶۳	۰/۷۸۸۸	۰/۵۸۲۰
WNN	P _t , T _t , G _t , G _{t-1} , G _{t-2}	db _۲	۲	۶	۳۶	۰/۹۰۹۱	۰/۳۸۱۵
WANFIS	P _t , T _t , G _t , G _{t-1} , G _{t-2}	db _۴	۲	۴۴	۳۷	۰/۹۳۰۹	۰/۳۳۲۴
ده رحم							
ANN	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	-	-	۲	۱۷	۰/۸۲۰۸	۰/۸۱۴۱
ANFIS	G _t , G _{t-1} , G _{t-2}	-	-	۳۰	۳۵	۰/۸۲۴۶	۰/۸۰۵۵
WNN	P _t , T _t , G _t , G _{t-1} , G _{t-2}	db _۲	۲	۵	۳۳	۰/۹۲۵۱	۰/۵۲۵۷
WANFIS	G _t , G _{t-1} , G _{t-2}	db _۴	۲	۳۰	۲۳	۰/۹۳۳۹	۰/۴۹۳۴
کلاه کچ							
ANN	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	-	-	۵	۱۷	۰/۸۴۳۴	۰/۶۳۴۰
ANFIS	P _t , T _t , G _t , G _{t-1} , G _{t-2}	-	-	۴۴	۴۲	۰/۸۳۲۴	۰/۶۷۲۹
WNN	P _t , P _{t-1} , T _t , T _{t-1} , G _t , G _{t-1} , G _{t-2}	db _۴	۲	۳	۱۹	۰/۹۱۴۴	۰/۴۶۸۳
WANFIS	P _t , T _t , G _t , G _{t-1} , G _{t-2}	db _۵	۳	۴۴	۸۰	۰/۹۲۵۴	۰/۴۳۶۹
علم آباد							
ANN	G _t , G _{t-1} , G _{t-2}	-	-	۲	۹	۰/۸۸۹۴	۰/۷۱۵۳
ANFIS	P _t , T _t , G _t , G _{t-1} , G _{t-2}	-	-	۴۴	۴۲	۰/۸۵۰۹	۰/۸۳۳۴
WNN	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	db _۲	۱	۲	۲۰	۰/۹۰۳۷	۰/۶۶۷۷
WANFIS	P _t , P _{t-1} , P _{t-2} , T _t , T _{t-1} , T _{t-2} , G _t , G _{t-1} , G _{t-2}	db _۲	۲	۷۲	۴۶	۰/۹۳۹۲	۰/۵۳۱۳

ادامه جدول (۴): نتایج پیش‌بینی ۳ ماهه‌ی سطح آب زیرزمینی توسط مدل‌های مختلف در پیرومترهای مختلف

مومن آباد							
ANN	$P_t, P_{t-1}, T_t, T_{t-1}, G_t, G_{t-1}, G_{t-2}$	-	-	۳	۲۷	۰/۹۱۱۲	۰/۴۱۰۲
ANFIS	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	-	-	۷۲	۷۲	۰/۹۲۹۵	۰/۳۶۵۷
WNN	$P_t, P_{t-1}, T_t, T_{t-1}, G_t, G_{t-1}, G_{t-2}$	db_r	۱	۳	۱۶	۰/۹۶۷۹	۰/۲۴۷۱
WANFIS	G_t, G_{t-1}, G_{t-2}	db_f	۱	۳۰	۱۸	۰/۹۷۸۹	۰/۲۰۰۲

با دقت در نمودارهای مربوط به مقایسه‌ی مقادیر مشاهده شده و مقادیر پیش‌بینی شده توسط مدل‌های مختلف پیش‌بینی، مشاهده می‌شود که در مدل‌هایی که از تبدیل موجک به منظور تجزیه‌ی سری‌های زمانی ورودی استفاده نشده است (ANN و ANFIS)، نمودار مربوط به مقادیر پیش‌بینی شده نسبت به نمودار مربوط به مقادیر مشاهده شده دارای تأخیر می‌باشد. علت بروز این پدیده می‌تواند به ساختار مدل مورد نظر و اختصاص وزن و یا تأثیر بیشتر داده‌های نزدیک به گام پیش‌بینی توسط مدل مربوط باشد. در نتیجه داده‌ی پیش‌بینی شده به آخرین داده یا داده‌های ورودی نزدیک‌تر می‌باشد. اما باید توجه نمود که همین مقدار پیش‌بینی شده نیز با واقعیت هم‌خوانی قابل قبولی دارد. همان‌گونه که در این نمودارها مشاهده می‌شود در مدل‌هایی که از تبدیل موجک به منظور تجزیه‌ی سری‌های زمانی ورودی به مدل استفاده شده است تقریباً این پدیده وجود ندارد و این موضوع به تأثیر مثبت تبدیل موجک در تجزیه‌ی سری‌های زمانی به مقادیر تقریبی و جزئیات آن و در نتیجه توریع میزان تأثیر پذیری این مؤلفه‌ها بر مقادیر خروجی بر می‌گردد.

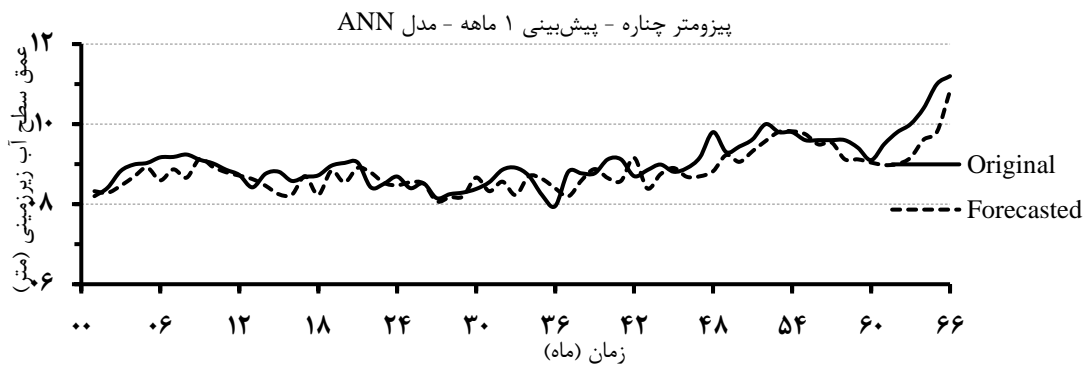
نتایج ارائه شده در جداول ۳ تا ۵ نشان می‌دهد که استفاده از مدل تلفیقی WNN به جای مدل ANN در پیش‌بینی‌های ۱ ماهه و ۳ ماهه‌ی سطح آب زیرزمینی در تمامی پیرومترها به میزان قابل توجهی مقدار R^2 را افزایش و مقدار RMSE را کاهش داده است. به عبارت دیگر این مدل نتایج پیش‌بینی را به میزان چشمگیری بهبود داده است. همچنین استفاده از مدل تلفیقی WNF به جای مدل ANFIS در پیش‌بینی‌های ۱، ۳ و ۶ ماهه‌ی مربوط به تمامی پیرومترها بجز پیش‌بینی ۳ ماهه‌ی مربوط به پیرومتر اصلان‌شاه سبب بهبود قابل ملاحظه‌ی در نتایج پیش‌بینی شده است.

جدول (۵): نتایج پیش‌بینی ۶ ماهه‌ی سطح آب زیرزمینی توسط مدل‌های مختلف در پیرومترهای مختلف


مدل	الگوی ورودی	نوع سطح تجزیه موجک	تعداد گره میانی	تعداد تکرار	R^2	RMSE	
اصلان‌شاه							
ANN	$P_t, P_{t-1}, T_t, T_{t-1}, G_t, G_{t-1}, G_{t-2}$	-	-	۲	۱۳	۰/۷۹۴۱	۳/۰۴۰۸
ANFIS	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	-	-	۷۲	۶۶	۰/۸۱۱۲	۲/۹۰۷۲
WNN	$P_t, P_{t-1}, T_t, T_{t-1}, G_t, G_{t-1}, G_{t-2}$	db_r	۱	۲	۱۳	۰/۸۲۸۹	۲/۷۶۱۶
WANFIS	G_t, G_{t-1}, G_{t-2}	db_r	۱	۳۰	۱۴	۰/۸۳۷۵	۲/۶۹۱۷
پیرومتر چناره							
ANN	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	-	-	۶	۳۰	۰/۷۰۵۱	۰/۶۹۳۵
ANFIS	$P_t, T_t, G_t, G_{t-1}, G_{t-2}$	-	-	۴۴	۴۴	۰/۶۹۴۴	۰/۷۰۶۰
WNN	$P_t, T_t, G_t, G_{t-1}, G_{t-2}$	db_r	۱	۲	۱۳	۰/۷۹۱۹	۰/۵۸۱۳
WANFIS	G_t, G_{t-1}, G_{t-2}	haar	۱	۳۰	۳۶	۰/۷۹۵۵	۰/۵۷۶۳

ادامه جدول (۵): نتایج پیش‌بینی ۶ ماهه‌ی سطح آب زیرزمینی توسط مدل‌های مختلف در پیژومترهای مختلف


ANN	G_t, G_{t-1}, G_{t-2}	-	-	۳	۲۲	۰/۶۴۷۰	۱/۱۴۱۲
ANFIS	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	-	-	۷۲	۹۳	۰/۶۲۲۴	۱/۱۸۲۳
WNN	$P_t, T_t, G_t, G_{t-1}, G_{t-2}$	db_r	۲	۲	۳۷	۰/۸۱۷۷	۰/۸۱۹۵
WANFIS	$P_t, T_t, G_t, G_{t-1}, G_{t-2}$	db_Δ	۱	۴۴	۷۲	۰/۸۲۶۹	۰/۷۹۸۶
کلاه کج							
ANN	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	-	-	۲	۲۴	۰/۸۳۳۱	۰/۶۵۱۱
ANFIS	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	-	-	۷۲	۷۷	۰/۸۳۴۱	۰/۶۴۹۳
WNN	$P_t, P_{t-1}, T_t, T_{t-1}, G_t, G_{t-1}, G_{t-2}$	db_r	۱	۳	۲۸	۰/۸۵۳۴	۰/۶۰۹۴
WANFIS	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	db_f	۱	۶۵	۲۹	۰/۸۸۰۴	۰/۵۵۰۶
علم آباد							
ANN	$P_t, T_t, G_t, G_{t-1}, G_{t-2}$	-	-	۱۰	۱۰	۰/۸۲۵۲	۰/۸۹۶۲
ANFIS	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	-	-	۷۲	۷۷	۰/۸۴۴۳	۰/۸۴۸۵
WNN	$P_t, P_{t-1}, T_t, T_{t-1}, G_t, G_{t-1}, G_{t-2}$	db_Δ	۱	۴	۱۲	۰/۸۵۳۹	۰/۸۲۰۸
WANFIS	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	db_Δ	۲	۷۲	۹۳	۰/۹۱۶۴	۰/۶۵۶۶
مومن آباد							
ANN	$P_t, T_t, G_t, G_{t-1}, G_{t-2}$	-	-	۲	۳۱	۰/۷۵۵۱	۰/۶۷۴۳
ANFIS	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	-	-	۷۲	۷۱	۰/۷۸۷۳	۰/۶۲۷۲
WNN	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	db_r	۱	۵	۲۳	۰/۸۰۵۳	۰/۶۰۰۱
WANFIS	$P_t, P_{t-1}, P_{t-2}, T_t, T_{t-1}, T_{t-2}, G_t, G_{t-1}, G_{t-2}$	db_Δ	۱	۷۲	۳۲	۰/۸۲۲۶	۰/۵۷۲۶




شکل (۵): نمودار عمق سطح آب زیرزمینی واقعی و پیش‌بینی شده با مدل ANN در پیژومتر چناره




شکل (۶): نمودار عمق سطح آب زیرزمینی واقعی و پیش‌بینی شده با مدل ANFIS در پیژومتر چناره




شکل (۷): نمودار عمق سطح آب زیرزمینی واقعی و پیش‌بینی شده با مدل WNN در پیزومتر چناره




شکل (۸): نمودار عمق سطح آب زیرزمینی واقعی و پیش‌بینی شده با مدل WNF در پیزومتر چناره




شکل (۹): نمودار عمق سطح آب زیرزمینی واقعی و پیش‌بینی شده با مدل ANN در پیزومتر مومن آباد



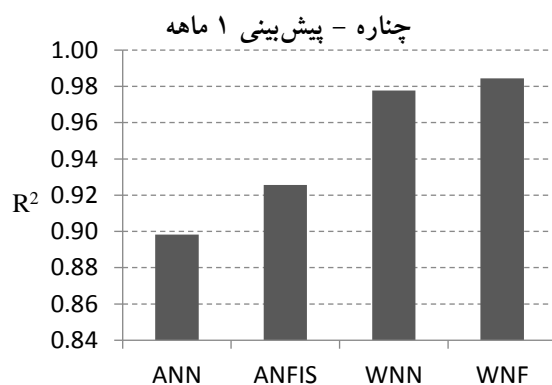

شکل (۱۰): نمودار عمق سطح آب زیرزمینی واقعی و پیش‌بینی شده با مدل ANFIS در پیزومتر مومن آباد





شکل (۱۱): نمودار عمق سطح آب زیرزمینی واقعی و پیش‌بینی شده با مدل WNN در پیزومتر مومن آباد




شکل (۱۲): نمودار عمق سطح آب زیرزمینی واقعی و پیش‌بینی شده با مدل WNF در پیزومتر مومن آباد



شکل (۱۳): مقایسه‌ی مقادیر $RMSE$ و R^2 مربوط به مدل‌های مختلف در پیزومتر چناره





ادامه شکل (۱۳): مقایسه‌ی مقادیر $RMSE$ و R^2 مربوط به مدل‌های مختلف در پی‌زومتر چناره

پیش‌بینی‌های ۶ ماهه، همچنان این مدل‌ها نتایج مناسبی در این گام پیش‌بینی ارائه داده‌اند.

در نهایت با توجه به نتایج ارائه شده در جداول ۳ تا ۵ می‌توان گزارش نمود که که مدل تلفیقی WNF در مقایسه با WNN دارای نتایج بهتری می‌باشد. به طوری که مدل تلفیقی WNF در پیش‌بینی‌های ۱ و ۳ ماهه‌ی سطح آب زیرزمینی مربوط به تمامی پی‌زومترها، به میزان قابل ملاحظه‌ای سبب افزایش مقدار R^2 و کاهش نسبت به مدل تلفیقی WNN شده است. همچنین این مدل در پیش‌بینی‌های ۶ ماهه‌ی مربوط به تمامی پی‌زومترها نسبت به مدل WNN کارایی بهتری داشته است.

بهبود نتایج پیش‌بینی‌ها توسط مدل تلفیقی WNF نسبت به مدل WNN در گام‌های پیش‌بینی کوتاه‌تر، چشمگیرتر است. به طوری که در پیش‌بینی‌های ۱ ماهه و حتی ۳ ماهه، نتایج مدل WNF مناسب‌تر بوده و در پیش‌بینی ۶ ماهه نتایج دو مدل تلفیقی به هم نزدیک‌تر است. نتایج این تحقیق با نتایج نیرومند فرد و همکاران (۱۳۹۸)، همخوانی دارد. نتایج این محققان در پیش‌بینی جریان رودخانه با دو مدل نروفازی و هیبرید موجکی-عصبی حاکی از برتری مدل موجکی-عصبی می‌باشد.

همچنین نتایج کرباسی (۱۳۹۵) در تخمین تبخیر و تفرق مرجع با مدل‌های هیبریدی نشان داد که کاربرد مدل ترکیبی موجکی ANFIS - نسبت به مدل ANFIS به سبب پیش‌پردازش داده‌های ورودی موجب افزایش دقت برآورد پارامترها شده است. در تبیین این نتایج می‌توان بیان نمود

مقایسه مدل فازی-عصبی و مدل عصبی-فازی-موجکی نشان می‌دهد که پیش‌پردازش داده‌ها با استفاده از تبدیل موجکی و استفاده از آن به عنوان ورودی مدل فازی-عصبی به مقدار قابل توجهی دقت مدل را در پیش‌بینی سطح آب زیرزمینی افزایش داده است. نتیجه فوق توسط بسیاری از محققان که مدل‌های هیبریدی بر پایه موجکی را با مدل‌های بدون استفاده از موجکی مقایسه کرده‌اند، گزارش شده است (کرباسی، ۱۳۹۵، کیسی و شیری، ۲۰۱۲، باچور و همکاران، ۲۰۱۵)

مدل تلفیقی شبکه‌ی عصبی-فازی-موجکی نسبت به شبکه عصبی R^2 را بترتیب از ۰/۹۴ به ۰/۹۸ (در پیش‌بینی یک ماه)، ۰/۸۴ به ۰/۹۳ (در پیش‌بینی سه ماهه) ۰/۷۶ به ۰/۸۵ (در پیش‌بینی شش ماهه) افزایش داده است. همچنین مدل تلفیقی شبکه‌ی عصبی-فازی-موجکی نسبت به شبکه عصبی $RMSE$ را بترتیب از ۰/۵۶ به ۰/۳۲ (در پیش‌بینی یک ماه)، ۰/۹۶ به ۰/۶۶ (در پیش‌بینی سه ماهه) و ۱/۱۸ به ۰/۹۷ (در پیش‌بینی شش ماهه) کاهش داده است.

کارایی مدل‌های WNN و WNF در بهبود نتایج، از گام‌های پیش‌بینی ۱ ماهه به ۳ ماهه و از ۳ ماهه به ۶ ماهه کاهش یافته است. علت کاهش دقت پیش‌بینی‌ها با افزایش گام پیش‌بینی، افزایش دامنه‌ی تغییرات مقادیر ورودی و به تبع آن افزایش مقدار خطای پیش‌بینی می‌یابد. باید توجه داشت که علی‌رغم کاهش میزان بهبود نتایج در

عملکرد چهار مدل مدل‌های ANN، WNN، ANFIS و WNN در پیش‌بینی نوسات سطح آب زیرزمینی دشت الشتر مورد ارزیابی قرار گرفت. به منظور پیش‌بینی نوسات سطح آب زیرزمینی در گام‌های زمانی ۱، ۳ و ۶ ماه بعد $(t + 1, t + 3, t + 6)$ از پارامترهای دما، بارش و سطح آب زیرزمینی در گام‌های زمانی ۰، ۱ و ۲ ماهه قبل $(t, t - 1, t - 2)$ استفاده شده است. نتایج این تحقیق نشان داد که نتایج حاصل از مدل‌های ANFIS، WNN و WNF نسبت به مدل ANN در پیش‌بینی سطح آب زیرزمینی دارای دقت بالاتری است. همچنین بعلت نا ایستایی سطح آب زیرزمینی، برای مدل‌سازی دقیق‌تر، سطح آب زیرزمینی، نیاز به پیش پردازش داده‌های ورودی به مدل است. لذا استفاده از مدل‌های با پایه تبدیل موجک بعلت جدا نمودن سیگنال به فرکانس‌های بالا و پایین، دقت مدل را تا حد قابل توجهی افزایش خواهد داد. نتایج این تحقیق نشان داد که استفاده از تأخیرهای زمانی بیشتر از سه ماهه تأثیر چندانی بر دقت مدل‌های پیشنهادی ندارد و حتی در مدل‌های شامل موجک، سبب کاهش دقت خواهد شد. نتایج حاصل از تأخیرهای زمانی بر دقت مدل نشان داد که بهبود نتایج پیش‌بینی‌ها توسط مدل تلفیقی WNF نسبت به مدل WNN در گام‌های پیش‌بینی کوتاه‌تر، چشمگیرتر است. به طوری که در پیش‌بینی‌های ۱ ماهه و حتی ۳ ماهه، نتایج مدل WNF مناسب‌تر بوده و در پیش‌بینی ۶ ماهه نتایج دو مدل تلفیقی به هم نزدیک بوده و تفاوت زیادی با هم ندارد.

تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پایین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی افزایش می‌دهد. از آنجا که سیگنال‌های بالا گذر و پایین گذر حاصل از تجزیه موجک، برآزش بسیار خوبی با معادلات مجموع سینوسی دارند، لذا هر چه تعداد مراتب این معادلات بیشتر باشد دقت کار افزایش خواهد یافت.

در مورد توجیه برتری مدل‌های بر پایه موجک می‌توان این گونه بیان کرد که سری زمانی هیدرولوژیکی پیچیده با استفاده از تبدیل موجک گسسته به چند سری زمانی ساده تجزیه می‌گردد، بنابراین برخی از ویژگی‌های سری زمانی اصلی نظیر دوره‌های روزانه، هفتگی، ماهانه و سالانه به وضوح بیشتری قابل مشاهده است. این برتری را می‌توان حتی در مدل‌های رگرسیونی موجک نیز مشاهده نمود.

نتیجه‌گیری

رزیابی دقیق سطح آب‌های زیرزمینی به مدیران، مهندسان و ذینفعان آب اجازه می‌دهد که درک بهتر از پویایی و عوامل اساسی تاثیرگذار بر سطح آب‌های زیرزمینی داشته باشند و برای جلوگیری یا کاهش عوارض جانبی از برداشت آب زیرزمینی استراتژی‌های بهتری را طراحی کنند. به طوریکه مدل‌های دقیق و قابل اعتماد برای پیش‌بینی سطح آب زیرزمینی، می‌تواند به اطمینان از استفاده پایدار سفره‌های آب زیرزمینی برای تأمین آب شهری و روستایی و بهبود بهره‌وری در مصرف آب کمک کند. در تحقیق حاضر

منابع

- اسمعیلی گیساوندانی، ح.، ع.م. آخوندعلی، ح. زارعی و م. تقیان. ۱۳۹۶. ارزیابی قابلیت مدل‌های سیستم استنتاج فازی-عصبی تطبیقی، شبکه عصبی مصنوعی و رگرسیونی در تحلیل منطقه ای سیلاب. پژوهش‌های حفاظت آب و خاک (علوم کشاورزی و منابع طبیعی)، سال بیست و چهارم، شماره ۳، ص ۱۶۶-۱۴۹.
- باباعلی، ح. و ر. دهقانی. ۱۳۹۸. بررسی عملکرد مدل شبکه عصبی موجک در تخمین دبی روزانه. علوم و مهندسی آبیاری، سال چهل و دوم، شماره ۳، ص ۱۱۶-۱۰۵.
- پورمحمدی، س.، ح. ملکی‌نژاد و ر. پورشرعیاتی. ۱۳۹۲. مقایسه کارایی روش‌های شبکه عصبی و سری‌های زمانی در پیش‌بینی سطح آب زیرزمینی (مطالعه موردی: زیرحوزه بختگان استان فارس). نشریه پژوهش‌های حفاظت آب و خاک (علوم کشاورزی و منابع طبیعی)، سال بیستم، شماره ۴، ص ۲۶۲-۲۵۱.
- حسن زاده، ی.، ع. کردانی و ا. فاخری فرد. ۱۳۹۱. پیش‌بینی خشکسالی با استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی-موجکی. فصلنامه علمی-پژوهشی آب و فاضلاب، سال بیست و سه، شماره ۸۳، ص ۵۹-۴۸.

دهقانی، ا.، م. عسگری و ا. مساعدی. ۱۳۸۹. مقایسه سه روش شبکه عصبی مصنوعی، سیستم استنتاجی فازی، عصبی تطبیقی و زمین آمار در میان یابی سطح آب زیرزمینی (مطالعه موردی دشت قزوین). علوم کشاورزی و منابع طبیعی، سال شانزدهم، شماره ۱، ص ۵۲۸-۵۱۷.

زارع ابیانه، ح.ر. و م. بیات ورکشی. ۱۳۹۰. ارزیابی مدل‌های هوشمند عصبی و تجربی در تخمین رواناب سالانه. مجله آب و خاک (علوم و صنایع کشاورزی)، سال بیست و پنجم، شماره ۲، ص ۳۶۵-۳۷۹.

زمانی، ر.، ا. محمودی، ع.م. آخوندعلی، ح. زارعی و ف. رادمنش. ۱۳۹۳. تخمین سطح ایستابی با استفاده از یک روش ترکیبی بهینه شده با الگوریتم ژنتیک در دشت رامهرمز. نشریه آبیاری و آب ایران، سال چهارم، شماره ۳، ص ۳۸-۲۶.

سلیمانی مطلق، م.، ه. قاسمیه و ع. مطالبی. ۱۳۹۵. تغییر ضرایب ذخیره و قابلیت انتقال آبخوان دشت الشتر به علت خشکسالی و افزایش بهره‌برداری منابع آب زیرزمینی. مجله علمی پژوهشی مهندسی آکوسیستم بیابان، سال پنجم، شماره ۱۱، ص ۱۰۴-۹۳.

شاهی نژاد، ب.، ر. دهقانی. ۱۳۹۷. مقایسه مدل‌های شبکه عصبی موجک، ماشین بردار پشتیبان و برنامه ریزی بیان ژن در تخمین میزان اکسیژن محلول در آب رودخانه‌ها. نشریه تحقیقات منابع آب ایران، سال چهاردهم، شماره ۳، ص ۲۷۷-۲۶۵.

عربی جوانمرد، ز. و ه. جعفری. ۱۳۹۵. بررسی نوسانات سطح ایستابی در آبخوان الشتر، مجموعه مقالات بیستمین همایش انجمن زمین شناسی ایران ۱۶ تا ۱۸ شهریور ماه ۱۳۹۵، دانشگاه .

علیچانی، ع. و ب. پناهی. ۱۳۹۲. پیش‌بینی دبی اوج سیلابی با استفاده از مدل شبکه عصبی مصنوعی و رگرسیون چند متغیره (مطالعه موردی حوضه آبریز مادرسو استان گلستان). نشریه جغرافیا، سال یازدهم، شماره ۳۸، ص ۱۱۳-۱۳۲.

کالیزاد، ز.، آ. ملکیان و ب. معتمد. ۱۳۹۲. تعیین الگوی توزیع منابع آب زیرزمینی (مطالعه موردی: حوزه آبخیز الشتر، استان لرستان). پژوهشنامه مدیریت حوزه آبخیز، سال چهارم، شماره ۷، ص ۶۹-۵۷.

کریاسی، م. ۱۳۹۵. پیش‌بینی تبخیر- تفرق مرجع هفتگی با استفاده از مدل ترکیبی موجک- فازی عصبی تطبیقی. نشریه پژوهش آب در کشاورزی (علوم خاک و آب)، سال سی، شماره یک، ص ۸۷-۷۳.

معروفی، ص.، ک. امیرمرادی و ن. پارسافر. ۱۳۹۲. پیش‌بینی جریان روزانه با استفاده از شبکه‌های عصبی مصنوعی و عصبی- موجکی (مطالعه موردی: رودخانه باراندوزچای). دانش آب و خاک. سال بیست و سوم، شماره ۳، ص ۹۳-۱۰۳.

نیرومند فرد، ف.، ع. خاشعی سیوکی و ع. شهیدی. ۱۳۹۸. ارزیابی کارایی دو مدل نروفازی و هیبرید موجکی- عصبی در پیش‌بینی جریان رودخانه (مطالعه موردی: حوضه محمد آباد). نشریه پژوهشنامه مدیریت حوزه آبخیز، سال دهم، شماره ۱۹، ص ۲۲۱-۲۱۱.

Bachour, R., I. Maslova, A. Ticlavlilca, W. Walker and M. McKee. 2015. Wavelet-multivariate relevance vector machine hybrid model for forecasting daily evapotranspiration. *Stochastic Environmental Research and Risk Assessment*, 29(2):1-15.

Cannas B., A. Fanni, L. See, and G. Sias. 2006. Data preprocessing for river flow forecasting using neural networks, Wavelet transforms and data partitioning. *Physics and Chemistry of the Earth, Parts A/B/C*, 31(18): 1164-1171.

Etter, S., N. Addor, M. Huss and F. David. 2017. Climate change impacts on future snow ice and rain runoff in a swiss mountain catchment using multi-dataset calibration. *J. Hydrology: Regional Studies*. 13:222-239.

Gong, Y., Zh. Wang, G. Xu, Z. Zhang. 2018. A Comparative Study of Groundwater Level Forecasting Using Data-Driven Models Based on Ensemble Empirical Mode Decomposition. *Water*, 10 (6), 730.

Javan, K., M.R. Fallah Haghgo Lialestani and M. Nejadhossein. 2015. A comparison of ANN and HSPF models for runoff simulation in Gharehsoo River watershed, Iran. *J. Modeling Earth Systems and Environment*. 1(41):1-13.



Jeihouni, M., R., Delirhasannia, S.K., Alavipanah, M., Shahabi, S. Samadianfard, .2015. Spatial analysis of groundwater electrical conductivity using ordinary kriging and artificial intelligence methods (Case study: Tabriz plain, Iran). Original scientific paper, GEOFIZIKA, 32(2): 191–208.

Kisi, O. and J. Shiri. 2012. Wavelet and neuro-fuzzy conjunction model for predicting water table depth fluctuations. Hydrology Research, 43(3):286-300.

Kisi, O. and J. Shiri. 2012. Wavelet and neuro-fuzzy conjunction model for predicting water table depth fluctuations. Hydrology Research. 43(3):286-300.

Maroufpoor, S., A.Fakheri-Fard, and J. Shiri. 2018. Study of the spatial distribution of groundwater quality using soft computing and geostatistical models, ISH Journal of Hydraulic Engineering, 2017. <https://doi.org/10.1080/09715010.2017.1408036>

Nourani, V., M.T. Alami, F.D.Vousoughi. 2015. Wavelet-entropy data pre-processing approach for ANN-based groundwater level modeling. J. Hydrol. 524: 255–269.

Shiri, J., Ö. Kisi. 2011. Comparison of genetic programming with neuro-fuzzy systems for predicting short-term water table depth fluctuations. Comput. Geosci. 37: 1692–1701.

Suryanarayana, C., C. Sudheer, V. Mahammood, B.K. Panigrahi.2014. An integrated wavelet-support vector machine for groundwater level prediction in visakhapatnam, india. Neurocomputing. 145: 324–335.



Forecasting Groundwater table depth fluctuations using conjunction models of Wavelet – Neural - Fuzzy Network (WNF) (case study: Aleshtar Plain)

Masoud Shakarami^{1*}

Abstract

The aim of this study was to estimate the groundwater level of Aleshtar plain at times $t + 1$, $t + 3$ and $t + 6$ using the parameters of temperature, precipitation and groundwater level at times t , $t-1$ and $t-2$ using models: neural network (ANN), a neural fuzzy inference system (ANFIS), a neural-wavelet (WNN), and an integrated neural-fuzzy-wavelet (WNF) network. Two indices R^2 and RMSE were used to evaluate the models. The results of predicting different models showed that ANFIS, WNN and WNF have higher accuracy in predicting groundwater level than ANN model. Also, the comparison of the results obtained from wavelet-based models and other models showed that these models (WNN and WNF) have higher accuracy than other models due to pre-processing and data analysis. The use of WNF model compared to ANN has increased the R^2 index from 0.94 to 0.98 (in one-month forecast), 0.84 to 0.93 (in three-month forecast) 0.76 to 0.85 (In the six-month forecast). Also, WNF compared to ANN model, has decreased RMSE index from 0.56 to 0.32 (in one-month forecast), 0.96 to 0.66 (in three-month forecast) and 1.18 to 0.97 (in the six-month forecast). The results of groundwater depth prediction with four models showed that these models have more accurate in predicting shorter time steps. Also, using of models in predictions with a time delay of more than three months, not only does not have much effect on the accuracy of the model, but in models with wavelet basis reduces the accuracy.

Keywords: Aleshtar, Groundwater, Neuro-fuzzy-Wavelet, Time series, Wavelet transform.

¹ *Assistant Professor, Department of Water Engineering, Faculty of Agriculture, University of Lorestan, Khorramabad, Iran
Corresponding author: E-mail: Shakarami.mas@lu.ac



groundwater level fluctuations forecasting using conjunction models of Wavelet - Neural-Fuzzy Network (WNF) (WNN) (case study: Aleshtar Plain)

Masoud Shakarami¹*

Introduction

Groundwater has always been considered as one of the important and major sources of drinking water and agriculture, especially in arid and semi-arid regions. Today, the improper use of groundwater, which is usually more than the amount of nutrients, has led to the drying of wells, aqueducts and springs, degraded water quality, increased pumping costs, the advancement of saline water and subsidence. In this regard, predicting groundwater level fluctuations can be of great help in planning and subsequent decisions to provide long-term drinking water, agriculture and industry. Thus, accurate and reliable planning and management of water resources cannot be achieved without accurate and reliable models. Despite the complexity and random nature of hydrological processes in recent decades, significant advances have been made in the ability to produce accurate hydrological models. Therefore, predicting groundwater level fluctuations is absolutely necessary for the proper management of these valuable resources. There are several methods for predicting hydrological time series such as groundwater level. The inefficiency of linear models in predicting anonymous and nonlinear time series leads to the widespread use of artificial intelligence methods such as artificial neural networks (ANN), fuzzy inference system (FIS), genetic algorithm (GA) as well as hybrid models of systems such as syntheses. Fuzzy (ANFIS). Using small data, these smart models are able to simulate anonymous and nonlinear time series with appropriate accuracy in a short period of time. With the advent of wavelet transform (WT) as a powerful tool in analyzing anonymous and nonlinear time series and proving its capabilities, many hydrological phenomena have been investigated using it. But it has been less used in the field of groundwater and in combination with other intelligent models.

Methodology

The purpose of this study is to estimate the groundwater level of Aleshtar basin at times $t + 1$, $t + 3$ and $t + 6$ using the parameters of temperature, precipitation and groundwater level at times t , $t-1$ and $t-2$. In order to estimate the groundwater level of Aleshtar basin, neural network (ANN), neural-fuzzy system (ANFIS), neural-wavelet (WNN) and integrated neural-fuzzy-wavelet (WNF) models were used. To predict groundwater level in 6 piezometers of Momenabad, Kolahkaj, Dehrahm, Chenareh, Alamabad and Aslanshah using WNN and WNF models, first using wavelet transform, unknown series of groundwater level, temperature and precipitation into approximate components and details. These subsets were used as input to neural network models (ANN) and neural-fuzzy inference system (ANFIS) for network training and finally groundwater level prediction. Then these components were combined again using wavelet transform to reconstruct the main series and finally using the results, ANN, WNN, ANFIS and WNF models were evaluated and compared. In this study, groundwater level, temperature and precipitation at times $(t-2, t-1, t)$ were considered as the input of neural network models (ANN) and neural-fuzzy inference system (ANFIS) and groundwater level in 1, 3 and 6 month scales of prediction and results were evaluated using two indices R^2 and RMSE. Eighty percent of the data were used randomly for training and twenty percent of the data were used for testing and validation. Finally, the output of the models was compared with the values measured in the observation wells.

¹ *Assistant Professor, Department of Water Engineering, Faculty of Agriculture, University of Lorestan



Discussion and conclusion

The results of this study showed that the results of ANFIS, WNN and WNF models have a higher accuracy in predicting groundwater level than ANN model. Also, due to the instability of the groundwater level, for more accurate modeling of the groundwater level, it is necessary to pre-process the input data to the model. Therefore, the use of wavelet transform base models (WNN and WNF) due to the separation of the signal into high and low frequencies, the model accuracy will be significantly increased. Using the integrated model of neural-fuzzy-wavelet network (WNF) COMPARES to the neural network (ANN), R2 index increased from 0.94 to 0.98 (in a one-month forecast), 0.84 to 0.93 (in 3-month forecast) and 0.76 to 0.85 (in the 6-month forecast). Also, the integrated model of neural-fuzzy-wave network compared to the neural network has decreased the RMSE index from 0.56 to 0.32 (in one-month forecast), 0.96 to 0.66 (in 3-month forecast) and 1.18. TO 0.97 (in the six-month forecast). Comparison of real-time series diagrams and values predicted by different models showed that in models that did not use wavelet transform to parse the input time series (ANN and ANFIS), the graph of predicted values compared to the graph of observed values has There is a delay.

The most important references

- Bachour, R., I. Maslova, A. Ticlavilca, W. Walker and M. McKee. 2015. Wavelet-multivariate relevance vector machine hybrid model for forecasting daily evapotranspiration. *Stochastic Environmental Research and Risk Assessment*, 29(2):1-15.
- Cannas B., A. Fanni, L. See, and G. Sias. 2006. Data preprocessing for river flow forecasting using neural networks, Wavelet transforms and data partitioning. *Physics and Chemistry of the Earth, Parts A/B/C*, 31(18): 1164-1171.
- Etter, S., N. Addor, M. Huss and F. David. 2017. Climate change impacts on future snow ice and rain runoff in a swiss mountain catchment using multi-dataset calibration. *J. Hydrology: Regional Studies*. 13:222-239.
- Gong, Y., Zh. Wang, G. Xu, Z. Zhang. 2018. A Comparative Study of Groundwater Level Forecasting Using Data-Driven Models Based on Ensemble Empirical Mode Decomposition. *Water*, 10 (6), 730.
- Javan, K., M.R. Fallah Haghgoo Lialestani and M. Nejadhossein. 2015. A comparison of ANN and HSPF models for runoff simulation in Gharehsoo River watershed, Iran. *J. Modeling Earth Systems and Environment*. 1(41):1-13.
- Jeihouni, M., R., Delirhasannia, S.K., Alavipanah, M., Shahabi, S. Samadianfard, .2015. Spatial analysis of groundwater electrical conductivity using ordinary kriging and artificial intelligence methods (Case study: Tabriz plain, Iran). Original scientific paper, *GEOFIZIKA*,. 32(2): 191–208.
- Kisi, O. and J. Shiri. 2012. Wavelet and neuro-fuzzy conjunction model for predicting water table depth fluctuations. *Hydrology Research*, 43(3):286-300.
- Kisi, O. and J. Shiri. 2012. Wavelet and neuro-fuzzy conjunction model for predicting water table depth fluctuations. *Hydrology Research*. 43(3):286-300.
- Maroufpoor, S., A.Fakheri-Fard, and J. Shiri. 2018. Study of the spatial distribution of groundwater quality using soft computing and geostatistical models, *ISH Journal of Hydraulic Engineering*, 2017. <https://doi.org/10.1080/09715010.2017.1408036>
- Nourani, V., M.T. Alami, F.D.Vousoughi. 2015. Wavelet-entropy data pre-processing approach for ANN-based groundwater level modeling. *J. Hydrol.* 524: 255–269.
- Shiri, J., Ö. Kisi. 2011. Comparison of genetic programming with neuro-fuzzy systems for predicting short-term water table depth fluctuations. *Comput. Geosci.* 37: 1692–1701.
- Suryanarayana, C., C. Sudheer, V. Mahmood, B.K. Panigrahi.2014. An integrated wavelet-support vector machine for groundwater level prediction in visakhapatnam, india. *Neurocomputing*. 145: 324–335