

ارزیابی آکاییک و شوارتز به عنوان مدل منتخب تعیین گردید. در نهایت نیز مدل سازی با مدل ترکیبی ANN-ARIMA انجام گرفت که عملکرد بهتری نسبت به دو مدل شبکه عصبی و سری زمانی نشان داد. ($R^2=0.94$, $RMSE=0.05$)

کلید واژه‌ها: شبکه عصبی مصنوعی، سری زمانی، آزمون GAMI، SOI، قزوین.

مقدمه

خشکسالی به عنوان یکی از بلایای طبیعی تهدید کننده انسان و محیط زیست، هم از نظر فراوانی در رخداد و هم از نظر بزرگی زیان‌های وارد در صدر قرار گرفته است [۱۶]. به طوریکه در دراز مدت موجب خشکسالی آب‌شناسی و آب و زمین شناسی شده و کاهش منابع آب را از طریق خشکیدگی جریان‌های سطحی و زیرزمینی در پی دارد [۳۱]. بطوریکه خشکسالی آب زیرزمینی در اثر تغذیه ناکافی مخازن سفره‌های آب زیرزمینی بوجود آمده و به عبارتی زمان بروز آن هنگامی است که سطح آب زیرزمینی در یک دوره مشخص به زیر سطح نرمال منطقه رفته و منجر به ایجاد شرایط نامطلوب گردد. اگرچه با وجود همه تلاش‌ها و پیشرفت‌های علمی، تاکنون بشر نتوانسته است به علت پیچیدگی حاکم بر انواع خشکسالی، این پدیده را با دقت تمام پیش‌بینی نماید اما به هر حال با مطالعه رفتار بلند مدت هیدرولوژیکی یک منطقه و بکارگیری روش‌ها و مدل‌های آماری و مفهومی مختلف می‌توان تا اندازه‌های از وضعیت و قوع این پدیده در آینده اطمینان حاصل نمود. در این بین استفاده از تکنیک‌های هوش مصنوعی و سری‌های زمانی می‌تواند در مدل سازی آب زیرزمینی کمک زیادی داشته باشد [۳۰]. کاپولا و همکاران با مقایسه دو مدل شبکه عصبی مصنوعی و مدل‌های عددی در پیش‌بینی تراز سطح آب زیرزمینی نتیجه گرفتند که مدل شبکه عصبی در مقایسه با مدل‌های عددی نیازی به مشخصه‌های آشکار سیستم فیزیکی و داده‌های فیزیکی نداشته و همچنین دارای قابلیت بالای پیش‌بینی و آنالیز حساسیت می‌باشد که می‌تواند در استراتژی‌های مربوط به مدیریت منابع آب‌های زیرزمینی بسیار مناسب باشد [۵]. ملکی نژاد و شرعیاتی، جهت پیش‌بینی نوسانات سطح آب زیرزمینی در دشت مرودشت از مدل‌های سری زمانی و شبکه عصبی مصنوعی استفاده نمودند. نتایج ایشان نشان داد که مدل ARIMA(1,1,0)، دارای بهترین برآورد داده‌ها می‌باشد.

مقایسه کارایی مدل شبکه عصبی مصنوعی، سری زمانی و مدل ترکیبی ANN-ARIMA در مدل سازی و پیش‌بینی شاخص منع آب زیرزمینی (GRI) (مطالعه موردنی: جنوب استان قزوین)

فاطمه مقصود^۱، محمد رضا یزدانی^۲، محمد رحیمی^۳، آرش ملکیان^۴
و علی اصغر ذوق‌الفقاری^۵

تاریخ دریافت: ۱۳۹۳/۰۶/۳۰ تاریخ پذیرش: ۱۳۹۵/۰۲/۱۸

چکیده

خشکسالی آب زیرزمینی یکی از انواع خشکسالی است که در اثر تغذیه ناکافی مخازن سفره‌های آب زیرزمینی بوجود آمده و شاخص منع آب زیرزمینی (GRI) به عنوان روشنی برای بیان وضعیت سطح آب زیرزمینی محسوب می‌شود. تاکنون روش‌ها و مدل‌های مختلفی برای پیش‌بینی و مدل سازی این پدیده را شده است اما از آنجا که انتخاب یک مدل مناسب کار مشکلی می‌باشد می‌توان به جای استفاده از یک مدل؛ ترکیبی از مدل‌های منفرد قابل قبول را مورد استفاده قرار داد تا بتوان به پیش‌بینی مناسب‌تر و قابل اعتمادتری دست یافت. در این تحقیق پس از محاسبه مقادیر GRI طی دوره آماری (۱۳۹۰-۱۳۶۳) در جنوب استان قزوین و بررسی ارتباط آن با پارامترهای هواشناسی (بارندگی، دبی، تبخیر و تعرق پتانسیل، دما (میانگین، ماکزیمم، مینیمم)) و سیگنانلهای اقلیمی (SOI، AMM، AMO، MEI، PDO، SOI، AMM، AMO) با استفاده از آزمون گاما در سه ساختار ترکیب ورودی، اقدام به مدل سازی با شبکه عصبی مصنوعی گردید. نتایج نشان داد که سیگنانل اقلیمی SOI و پارامترهای دمایی دارای بیشترین همبستگی معنی دار با مقادیر GRI می‌باشند. استفاده از پارامترهای هواشناسی نیز سبب بهبود عملکرد شبکه عصبی گردید. همچنین مدل سری زمانی ARIMA(1,1,3)(2,0,1) با توجه به معیارهای

۱- نویسنده مسئول و دانشجوی دکتری علوم و مهندسی آبخیزداری، دانشکده منابع طبیعی و علوم دریایی، دانشگاه تربیت مدرس.
پست الکترونیک: F.maghsood@modares.ac.ir
۲- استادیار، دانشکده کویرشناسی، دانشگاه سمنان.
۳- استادیار، دانشکده کویرشناسی، دانشگاه سمنان.
۴- دانشیار، دانشکده منابع طبیعی، دانشگاه تهران.
۵- استادیار، دانشکده کویرشناسی، دانشگاه سمنان.

و کمترین تاثیر نیز به ترتیب مربوط به NAO، NOI، PDO، SOI و NP می‌باشد [۱۷]. با توجه به قرارگیری کشور ایران در کمریند خشک جغرافیایی و مطالعات انجام گرفته در زمینه بررسی انواع مختلف حشکسالی‌ها در ایران، در مجموع هیچ منطقه‌ای از کشور از این پدیده در امان نبوده و به نسبت موقعیت قرارگیری و شرایط آب و هوایی، به نوعی تحت تاثیر اثرات مخرب این پدیده قرار گرفته است، به طوریکه بخش‌های جنوبی، شرقی و مرکزی کشور به علت نوسانات بیشتر مقادیر بارندگی، از آسیب‌پذیری بیشتری برخودار هستند. دشت قزوین با وسعتی بیش از ۴۳۰ کیلومتر مربع از دشت‌های حاصلخیز و وسیع کشور به شمار می‌رود. در سال‌های اخیر، افزایش مدام مقاضای آب برای مصرف کنندگان بخش کشاورزی و صنعت و استفاده بی رویه از چاه‌ها که ناشی از برداشت بیش از حد از چاه‌های غیر مجاز و یا چاه‌های دارای مجوز می‌باشد، افت شدید سطح آب زیرزمینی در سطح آبخوان را به دنبال داشته است. در این تحقیق از شاخص منع آب زیرزمینی (GRI) به عنوان معرف وضعیت سطح آب زیرزمینی منطقه استفاده شده است. همچنین سعی شده است تا با در نظر گرفتن ساختارهای مختلف ورودی به شبکه عصبی، علاوه بر بررسی نقش پارامترهای هواشناسی و سیگنال‌های اقلیمی، اقدام به تعیین کارایی دو مدل منفرد شبکه عصبی و سری زمانی و همچنین مدل ترکیبی شبکه عصبی-سری زمانی (ANN-ARIMA) جهت پیش‌بینی مقادیر شاخص منع آب زیرزمینی در جنوب استان قزوین شود.

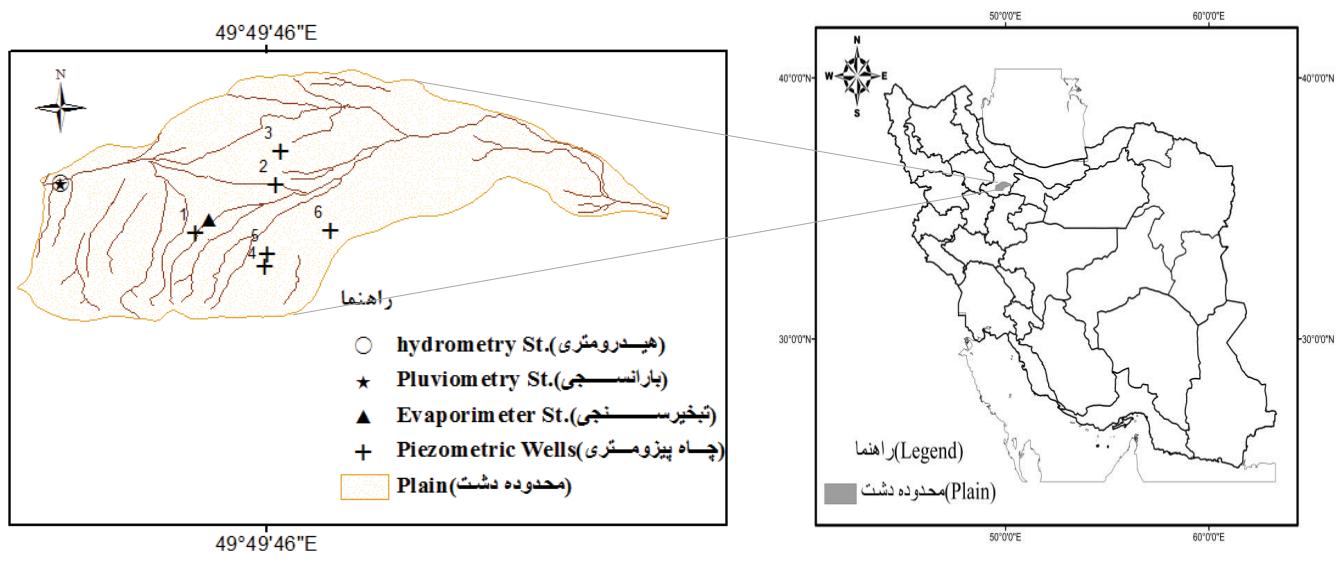
مواد و روش‌ها

منطقه مورد مطالعه

در این تحقیق به منظور انجام بهتر مدل‌سازی و در نظر نگرفتن اثر فاصله بر عملکرد مدل‌سازی با شبکه عصبی سعی شد محدوده دشتی از این استان مورد مطالعه قرار گیرد که حتی الامکان دارای پراکنش مناسبی از ایستگاه‌های بارانسنجی، هیدرومتری و تبخیرسنجی، با طول دوره آماری مشترک بلند مدت‌تری در اطراف چاه مورد مطالعه باشد. این دشت، واقع در جنوب استان قزوین می‌باشد که در محدوده طول جغرافیایی ۴۹ درجه و ۱۰ دقیقه تا ۵۰ درجه و ۲۹ دقیقه شرقی و عرض جغرافیایی ۳۵ درجه و ۲۰ دقیقه تا ۳۶ دقیقه و ۳۰ دقیقه شمالی قرار گرفته و شهرستان‌های بویین زهرا و قسمتی از تاکستان را در بر می‌گیرد. شکل ۱، موقعیت این دشت در استان قزوین و کشور و همچنین موقعیت ایستگاه‌ها و چاه‌های پیزومتری و جدول ۱ نیز مشخصات ایستگاه‌ها را نشان می‌دهد. لازم به ذکر است که برای مدل‌سازی مقادیر شاخص منع آب زیرزمینی (GRI) تنها یک چاه پیزومتری (طرزک) مورد بررسی قرار گرفت و از سایر چاه‌ها که در جدول ۱ آمده است، جهت بازسازی آمار ناقص چاه مورد نظر استفاده گردید. مقادیر دما و تبخیر و تعرق پتانسیل نیز با استفاده از آمار ایستگاه تبخیر سنجی بدست آمد.

همچنین با توجه به مقادیر معیارهای ارزیابی، مدل شبکه عصبی نسبت به سری زمانی تلفیقی دارای برتری جزئی می‌باشد [۲۲]. آداموسکی^۱ و همکاران طی تحقیقی به منظور پیش‌بینی سطح ایستابی در حوضه آبخیز کتیگای^۲ در شهر کبک^۳ کانادا، با استفاده از مقادیر بارندگی ماهانه، دمای متوسط و متوسط سطح ایستابی طی سال‌های ۲۰۰۲ تا ۲۰۰۹، به مقایسه سه روش شبکه عصبی (ANN)، مدل آریما (ARIMA) و شبکه عصبی-موجک (WA-ANN) پرداختند. نتایج نشان داد که مدل تلفیقی WA-ANN نوانایی خوبی در پیش‌بینی سطح ایستابی دارد [۱]. پورمحمدی و همکاران نیز در تحقیق خود با استفاده از داده‌های سطح ایستابی ۳۵ چاه در یکی از زیرحوزه‌های بختگان طی دوره آماری ۱۳۸۱-۸۹ به بررسی کارایی دو روش شبکه عصبی مصنوعی و سری‌های زمانی در پیش‌بینی سطح آب زیرزمینی پرداختند. نتایج نشان داد که هر دو روش مذکور دارای کارایی و دقت بالایی می‌باشند [۳۰]. مقایسه دو مدل شبکه عصبی و سری‌زمانی در دشت لار ایران نشان داد با وجودیکه پارامترهای مدل سری زمانی کمتر از مدل شبکه می‌باشد، اما شبکه عصبی از نوع RNN-BR بر اساس پارامترهای ورودی (دما، تبخیر تعرق پتانسیل، بارندگی و سطح آب زیرزمینی با تاخیر) دارای همبستگی ۹۵/۰ و خطای ۴/۹۹ بوده و دارای نتایج قابل قبولی برای پیش‌بینی سطح آب زیرزمینی در این منطقه می‌باشد [۲۸]. با وجودیکه تاثیر تغییر پذیری اقلیمی چند دهه‌ایست بر میزان تغذیه و مکانیسم‌ها و بعضی فرایندهای هیدرولوژیکی آب‌های سطحی بر کیفیت و کمیت منابع آب‌های زیرزمینی موثرند، هنوز در بعضی از مناطق جهان تا حد زیادی ناشناخته می‌باشد [۲۱، ۳۳، ۱۲]. نتایج پیش‌بینی جریان رودخانه کلمبیا با استفاده از پدیده‌های ENSO و PDO نشان داد که استفاده از شاخص‌های مذکور نتایج دقیق‌تری را در پی دارد [۶]. همچنین ارتباط تغییرات جریان رودخانه‌های دجله و فرات با شاخص NAO [۲۲] و ارتباط بارش اروپا - مدیترانه با پدیده ENSO نیز به اثبات رسیده است [۲]. در دریاچه ارومیه نیز وابستگی بالای شاخص‌های اقلیمی NAO و SOI به اثبات رسید [۱۵]. همچنین جهت پیش‌بینی موثرترین عوامل بر بارش با شبکه عصبی مصنوعی در ایرانشهر نیز، موثرترین درک میزان دما و رطوبت نسبی گزارش شد [۱۸]. از طرفی دیگر دریاچه ارومیه تاثیر تغییر پذیری اقلیمی و تغییر بر منابع آب‌های زیرزمینی بسیار پیچیده‌تر از منابع آب سطحی می‌باشد [۱۲]. بررسی تاثیر سیگنال‌های هواشناسی بر نوسان آب دریاچه ارومیه و دبی حوضه آبریز و استفاده از مدل پیش‌بینی شبکه عصبی مصنوعی در دریاچه ارومیه نیز نشان داد که در تمامی ایستگاه‌ها در حالت‌های زمانی مختلف اعم از همزمان، تاخیری سه ماهه و تاخیری شش ماهه موثرترین سیگنال‌ها به ترتیب NINO1+2، NINO3+1، NINO4 و NINO3 بوده

-
1. Adamowski
 2. Chateauguay
 3. Quebec



شکل ۱- (الف) نقشه موقعیت دشت در استان قزوین. (ب) موقعیت ایستگاه‌ها و چاه‌های پیزومتریک.

Figure 1. (A) The Location of plain in Qazvin province. (B) The position of stations and piezometric wells.

جدول ۱- موقعیت جغرافیایی ایستگاه‌ها و چاه‌های منطقه مورد مطالعه.

Table 1. Geographical location of the studied stations and wells

نام ایستگاه	عرض جغرافیایی(درجه)	طول جغرافیایی(درجه)	نوع ایستگاه
Lat (deg)	Lon (deg)	Name of station	Type of station
35.87	49.54	(Rahimabad) رحیم آباد	Hydrometry
35.87	49.54	(Danesfahan) دانسفهان	Pluviometry
35.82	49.75	(Danesfahan) دانسفهان	تبخیر سنجی
35.80	49.73	(Danesfahan یک) دانسفهان یک	چاه‌های پیزومتری
35.87	49.84	(Tarzak) طرزک	Piezometric wells
35.91	49.85	(Kheirabad) خیر آباد	
35.75	49.83	(Chasekin) چاسکین	
35.77	49.83	(Tamirabad) تعمیر آباد	
35.80	49.92	(Ebrahimabad) ابراهیم آباد	

$$GRI_{y,m} = \frac{(D_{y,m} - \mu_{D,m})}{\sigma_{D,m}} \quad (1)$$

همچنین جهت تعیین طبقات مختلف خشکسالی در روش GRI می‌توان از طبقه‌بندی ارائه شدهی SPI نیز استفاده نمود [۲۴]. که در آن $D_{y,m}$ و $GRI_{y,m}$ به ترتیب مقدار نگه داشت آب زیرزمینی و مقدار این شاخص برای سال y و ماه m می‌باشد. $\mu_{D,m}$ و $\sigma_{D,m}$ میزان به ترتیب میانگین و انحراف معیار نگه داشت آب زیرزمینی برای ماه m از یک تعداد سال مشخص می‌باشد. از آنجا که بررسی آماری نشان داد که داده‌های سطح آب زیرزمینی نیز از توزیع گاما در سطح معنی داری ۵ درصد تبعیت می‌کنند، لذا در این روش مقادیر GRI

شاخص منبع آب زیرزمینی (GRI^I)، یکی از مهمترین شاخص‌های خشکسالی آب زیرزمینی می‌باشد که توسط مندسینو و همکاران (۲۰۰۸) به عنوان مقادیر استاندارد ماهانه ذخیره زیرزمینی بدون در نظرگرفتن انتقال آن، ارائه شده است. تحلیل خصوصیات این شاخص که از یک مدل بیلان آبی توزیعی ساده استخراج شده، بیانگر تغییرات مکانی زیاد این شاخص و حساسیت زیاد آن به خصوصیات لیتوژئوگرافی منطقه مورد مطالعه می‌باشد. فرمول کلی این شاخص به صورت رابطه ۱ است:

1. Groundwater Resources Index

شبکه‌های پرسپترون چند لایه (MLP³) می‌باشد [۲۵]. در شبکه‌های عصبی، تعداد نرون‌های لایه ورودی و خروجی باید برابر با تعداد پارامترهای ورودی و خروجی باشد ولی تعداد لایه‌های مخفی و تعداد نرون‌های آنها بصورت تجربی مشخص می‌شود [۱۰] بطوریکه قضیه تقریب ساز جهانی که توسط نیلسون در سال ۱۹۸۷ ثابت گردید بیان می‌کند که شبکه‌های عصبی با یک لایه مخفی با تابع سینکوئید در لایه میانی و تابع خطی در لایه خروجی قادر به تقریب تمامی توابع مورد نظر با هر درجه تقریب خواهد بود، به شرط آنکه تعداد نرون‌های لایه مخفی کافی باشد [۷]. در این تحقیق تعداد نرون لایه میانی از یک تا ۲۰ نرون مورد آزمون قرار گرفت. شاید مهمترین گام در مدل شبکه عصبی، انتخاب متغیرهای ورودی ضروری برای پیش‌بینی متغیرهای خروجی باشد [۱۱]. در این تحقیق ورودی‌های شبکه جهت پیش‌بینی مقادیر GRI ماهانه (به عنوان مقادیر خروجی شبکه) در سه نوع ساختار به طور مجزا مورد بررسی قرار گرفت. ورودی‌های ساختار اول علاوه بر GRI با تاخیرهای (۱، ۲، ۳، ۴، ۵، ۶، ۷، ۱۰ و ۱۱ ماهه)، شامل سیگنال‌های اقلیمی از قبیل، MEI⁴، AMO⁵، AMM⁶، AMO⁷ و PDO⁸ می‌باشند. لازم به ذکر است که داده‌های سیگنال‌های اقلیمی مذکور از وب سایت نوا^۹ استخراج گردید. ساختار دوم، تنها شامل GRI با تاخیرهای مذکور و ساختار سوم نیز شامل GRI با تاخیرهای مذکور و پارامترهای هواشناسی از جمله بارندگی، تبخیر و تعرق پتانسیل، معدل دما (حداقل، حداکثر و میانگین)، دمای مطلق (حداکثر و حداقل) طی دوره آماری ۲۷ ساله (۱۳۶۳-۱۳۹۰) می‌باشد. با توجه به توضیحاتی که در بخش پیش‌پردازش داده‌ها آمده است، ابتدا معنی‌داری همبستگی متقطع (بر اساس مقادیر P-Value) جهت تعیین گام تاخیر مورد نظر، بین پارامترهای هواشناسی و همچنین سیگنال‌های اقلیمی (به عنوان ورودی) با مقادیر GRI ماهانه (خروچی) تعیین گردید. پس از تعیین گام تاخیر مشخص برای هر پارامتر و سیگنال، تعیین ترکیب بهینه متغیرها با استفاده از آزمون گاما بدست آمد. همچنین در این تحقیق ۷۰ درصد از کل داده‌ها برای آموزش، ۱۵ درصد برای صحبت‌سنگی و ۱۵ درصد انتهایی (از سال ۱۳۸۷ تا ۱۳۹۰) برای داده تست استفاده گردید. در این مطالعه برای معماری شبکه عصبی از جعبه ابزار Artificial Neural Network در نرم‌افزار برنامه‌نویسی MATLAB استفاده شد. به منظور مقایسه عملکرد نتایج و تعیین بهترین ساختار مدل‌ها نیز از معیارهای جذر میانگین مربعات خطأ (RMSE)، میانگین قدر مطلق خطأ (MAE) و ضریب همبستگی (R^2)، استفاده گردید.

-
- 3. Multi Layer Perceptron
 - 4. Multivariate ENSO Index
 - 5. Southern Oscillation Index
 - 6. Atlantic Meridional Mode
 - 7. Atlantic Multi-decadal Oscillation
 - 8. Pacific Decadal Oscillation
 - 9. <http://www.esrl.noaa.gov>.

از برآزش توزیع گاما بر مقادیر سطح آب زیرزمینی بدست آمد و در واقع به عنوان شاخص منبع آب زیرزمینی استاندارد شده معروفی و در این تحقیق مورد استفاده قرار گرفت. در این تحقیق با استفاده از داده‌های سطح آب چاه پیزومتری مورد نظر، طی سال‌های ۱۳۶۳ تا ۱۳۹۱ اقدام به تعیین این شاخص در مقیاس ماهانه گردید.

پیش‌پردازش و تعیین ترکیب بهینه متغیرهای ورودی به مدل شبکه عصبی مصنوعی

به طور کلی انجام هر گونه عملیات بر روی داده‌های خام که باعث افزایش کارایی شبکه در مدل‌سازی داده‌های ورودی و خروجی می‌شود را پیش‌پردازش گویند. که به علت تاثیر متفاوت داده‌های ورودی بر روی نرون‌ها در ابتدا لازم است داده‌های ورودی به شبکه معیارسازی شوند [۱۰]. بدین منظور پس از حذف روند نزولی از سری داده‌ها، با استفاده از رابطه ۲ مقادیر GRI در دامنه عددی ۰,۱ تا ۰,۹ قرار گرفت.

$$y = .8 * \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} + .1 \quad (2)$$

سپس با استفاده از روش همبستگی متقطع^۱ در محیط افزاری MINITAB پارامترهای موثر بر مقادیر GRI در گام زمانی مشخص، تعیین شد و سپس با استفاده از آزمون گاما^۲ و در محیط نرم‌افزاری Winngamma اقدام به تعیین ترکیب بهینه متغیرهای ورودی موثر به شبکه گردید. آزمون گاما را می‌توان به عنوان ابزاری مناسب برای یافتن بهترین ساختار از متغیرهای ورودی به مدل غیر خطی در نظر گرفت [۳۲] که با استفاده از آن، مقدار میانگین مربعات خطای مدل پیش از استفاده محاسبه و ترکیب بهینه متغیرهای ورودی شناسایی می‌شود. چنانچه با حذف یک پارامتر ورودی، مقدار گاما افزایش یابد، یعنی آن پارامتر اثر مثبتی در مدل‌سازی داشته و بهتر است در ترکیب ورودی از آن استفاده شود و بر عکس. همچنین افزایش در زیاد و یا کم شدن مقدار گاما نیز می‌تواند نشان دهنده میزان اثر مثبت و یا منفی پارامتر مورد نظر در عملکرد مدل‌سازی باشد [۲۷].

شبکه عصبی مصنوعی و ساختارهای ورودی

ایده اصلی شبکه‌های عصبی مصنوعی بر مبنای شبیه‌سازی شبکه عصبی انسان است. از مهمترین مزایای شبکه عصبی مصنوعی نسبت به سیستم‌های هوشمند دیگر قدرت یادگیری شبکه از محیط پیرامون است، این یادگیری بدین معناست که شبکه با کمک فرایند آموزش مقادیر وزن‌ها را طوری تغییر دهد که عملکرد مدل به سمت حالت مورد انتظار ما پیش رود [۲۰]. بر اساس ترکیب مختلف نرون‌ها و قوانین مختلف یادگیری، شبکه‌های مختلفی تشکیل می‌شود که یکی از کاربردی‌ترین آنها در علوم مهندسی برای نگاشت غیر خطی،

-
- 1. Cross Correlation Function
 - 2. Winngamma

می‌توان مدل‌های مختلف که در حالت منفرد نیز نتایج نسبتاً قابل قبولی ارائه داده اند را با یکدیگر ترکیب کرده تا بتوان به پیش‌بینی مناسب‌تر و قابل اعتمادتری دست یافت.

در این تحقیق از مدل ترکیبی شبکه عصبی-سرو زمانی استفاده شد. این مدل اولین بار توسط وانگ در سال ۲۰۰۵، با ترکیب مدل‌های ARMA و ANN و PARMA با PANN انجام شد [۳۴]. از آنجا که در هر یک از مدل‌های سرو زمانی و هوش مصنوعی ممکن است مقادیر خروجی را باشد کمتر یا بیشتر پیش‌بینی نماید، خروجی نهایی در این روش ترکیبی از خروجی‌های وزن‌دار شده‌ی هر یک از مدل‌های تکی بوده که به صورت رابطه (۶) می‌باشد.

$$y_{t+1} = \sum_{j=1}^k a_j f_{t,j} + \varepsilon_{t+1} \quad (6)$$

در این رابطه f_j مقادیر پیش‌بینی شده در یک گام زمانی آینده از توسط روش \bar{a} در زمان t و a_j مقادیر وزن‌ها و ε_{t+1} نیز مقادیر باقی مانده می‌باشد.

نتایج:

پس از محاسبه میزان آسیب‌پذیری سطح آب زیرزمینی در چاه مورد مطالعه در برابر خشکسالی هیدروژئولوژیک، به کمک شاخص منبع آب زیرزمینی GRI و حذف روند نزولی اقدام به بررسی ارتباط آن با سیگنال‌های اقلیمی و پارامترهای هواشناسی مورد نظر گردید. ارتباط بین مقادیر شاخص منبع آب زیرزمینی با سیگنال‌های اقلیمی و پارامترهای هواشناسی با استفاده ازتابع همبستگی متقاطع در محیط نرم‌افزاری MINITAB محاسبه و به صورت جدول ۲ آورده شده است. مطابق با جدول، پارامترهای هواشناسی دمایی و تبخیر و تعرق با توجه به مقادیر P-value، دارای بیشترین همبستگی و به صورت مستقیم بوده و بارندگی با همبستگی ۱۱/۰-۰/۱ دارای کمترین همبستگی با مقادیر GRI می‌باشد. همچنین ارتباط معنی داری نیز برای مقادیر دبی در هیچ تاخیر زمانی مشاهده نشد. در مورد سیگنال‌های اقلیمی نیز بیشترین همبستگی به ترتیب با SOI به صورت مستقیم و MEI به صورت معکوس می‌باشد. این بدان معناست که به عنوان مثال هر زمان شاخص MEI اتفاق بیافتد تاثیر آن بر GRI، یک ماه بعد و به صورت معکوس پیدیدار خواهد شد (شکل ۲). همچنین شاخص AMO نیز در هیچ تاخیر زمانی دارای همبستگی معنی دار نبود. با توجه به مقادیر GRI بدست آمده از سطح آب زیرزمینی، بیشترین میزان و تداوم افت سطح آب و در نتیجه کاهش در مقادیر GRI به ترتیب در سال‌های ۱۳۸۴ و ۱۳۸۵ مشاهده گردید (شکل ۲). جدول ۳، مقادیر آزمون گاما به منظور بررسی اثر پارامترهای موثر و تعیین ترکیب بهینه متغیرها را نشان می‌دهد. همانطور که اشاره شد چنانچه با حذف یک متغیر مقدار گاما نسبت به حالتی که تمام متغیرها حضور دارند، افزایش یابد نشان دهنده‌ی تاثیر مثبت آن متغیر در مدل‌سازی می‌باشد. بدین ترتیب مطابق با جدول، در ساختار اول شبکه عصبی، AMM و PDO به ترتیب با سه و پنج

مدل سرو زمانی

مدل سرو زمانی یا استوکاستیک در علوم مختلفی از جمله شبیه‌سازی و پیش‌بینی رفتار سیستم‌های هیدرولیکی به کار می‌روند که با در نظر گرفتن همبستگی پیاپی میان مشاهدات سرو، رفتار سرو زمانی را پیش‌بینی می‌کنند. برای توسعه مدل‌های سرو زمانی یک الگوریتم سه مرحله‌ای توسط باکس و جنیکس ارائه شد [۳]. این الگوریتم دارای سه مرحله‌ای تشخیص، تخمین و برآورده مدل می‌باشد. در مرحله تشخیص با ترسیم داده‌ها و تعیین مقادیر خودهمبستگی^۱ و خود همبستگی جزئی سرو زمانی، خواصی از قبیل داده‌های پرت، وجود روند در سرو زمانی و ایستا بودن سرو زمانی مورد بررسی قرار گرفته و سپس اقدام به حذف روند از مقادیر شاخص منبع آب زیرزمینی گردید. همچنین نوع مدل و مرتبه‌های میانگین متحرک و اتورگرسیو نیز تعیین گردید. در مرحله برآورده با استفاده از روش‌هایی همچون حداکثر درست نمایی و مومنتم پارامترهای مدل تخمین زده شد. در مرحله صحت سنجی نیز مستقل و نرمال بودن باقیمانده‌ها بررسی گردید. که برای تعیین استقلال باقیمانده‌ها از مقادیر خودهمبستگی و خودهمبستگی جزئی و همچنین آماره باکس پیرسون طبق رابطه ۳ استفاده شد [۹].

$$Q = n(n+2) \sum_{k=1}^k \frac{r_k^2}{n-k} \quad (3)$$

$$AIC(M) = n \ln \sigma_a^2 + 2M \quad (4)$$

$$SBC(M) = n \ln \sigma_a^2 + M \ln n \quad (5)$$

در نهایت برای انجام آزمون درستی مدل از دو معیار آکائیک و شوارتز استفاده گردید (روابط (۴) و (۵)). در این روابط مقدار n واریانس تخمینی خطأ با استفاده از روش حداکثر درست نمایی، n تعداد داده‌ها و M نیز تعداد پارامترهای مدل می‌باشد که مدلی که مقدار کمتری از این دو معیار را به خود اختصاص دهد به عنوان مدل برتر انتخاب می‌گردد. سپس اقدام به پیش‌بینی مقادیر تست با استفاده از مدل انتخابی گردید. در این مرحله مقادیر خشکسالی در یک گام زمانی به جلو پیش‌بینی می‌گردد. بدین صورت که پس از هر بار پیش‌بینی یگ گام بعد، مقدار به دست آمده به عنوان جزیی از مقادیر مشاهداتی به سرو اضافه شده و جهت تعیین گام زمانی بعد، مدل مجدد اجرا می‌شود. یعنی برای هر تعداد از داده‌های تست یکبار مدل اجرا شده و به اصطلاح پیش‌بینی‌ها به هنگام می‌شوند.

ANN-ARIMA مدل

گاهای "انتخاب یک مدل مناسب کار مشکلی می‌باشد، زیرا از یک سو مدلی که نسبت به سایر مدل‌ها در تمام حوزه‌ها شرایط برتر و قطعیت بیشتری داشته باشد وجود نداشته و از سویی دیگر تمام مدل‌ها به نوعی دارای یک مقدار عدم قطعیت در پارامتر و ساختارها می‌باشند [۱۰] [۳۴]. به همین دلیل به جای استفاده از یک مدل

1. Autocorrelation function(ACF)

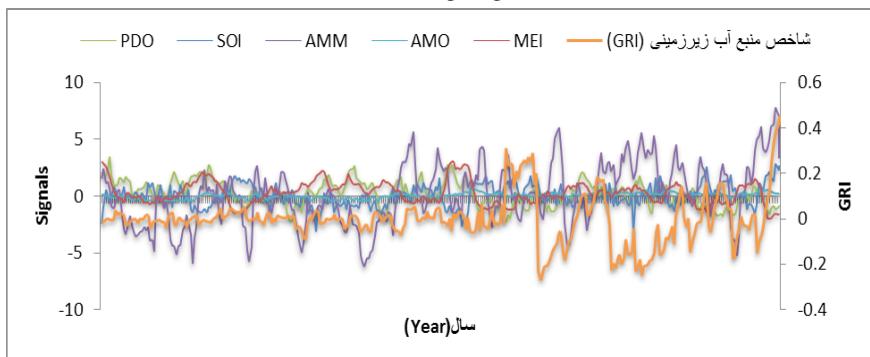
2. Partial autocorrelation function(PACF)

جدول ۲- تابع همبستگی متقاطع بین سری زمانی مقادیر GRI با سیگنال‌های اقلیمی و پارامترهای هواشناسی.

Table 2. Cross Correlation Function of GRI values with climate signals and meteorological parameters.

پارامتر هواشناسی و سیگنال اقلیمی climate signals and meteorological parameters									
تبخیر تعرق پتانسیل (میلی متر)	بارندگی (میلی متر)	دبه (مترمکعب بر ثانیه)	حداکثر دما مطلق (درجه سانتی گراد)	حداقل دما مطلق (درجه سانتی گراد)	میانگین دما (درجه سانتی گراد)	حداکثر دما (درجه سانتی گراد)	حداقل دما (درجه سانتی گراد)	فاکتور Factor	
Evapotranspiration (mm)	Precipitation (mm)	Discharge (m³/s)	Abs Max Temperature (°C)	Abs Min Temperature (°C)	Mean Temperature (°C)	Max Temperature (°C)	Min Temperature (°C)		
0.26	-0.11	-	0.24	0.29	0.28	0.28	0.28	CCF Lag	
5	6	-	5	5	5	5	5		
0.05>	0.05>	NS	0.05> PDO -0.19 3	0.05> SOI 0.25 1	0.05> AMM -0.12 5	0.05> AMO -	0.05> MEI -0.23 1	P-Value	
			0.05>	0.05>	0.05>	NS	0.05>	CCF Lag P-Value	

NS همبستگی معنی داری وجود ندارد.



شکل ۲- ارتباط سیگنال‌های اقلیمی با شاخص منبع آب زیرزمینی (GRI)

Figure 2. The relation of climate signals and Groundwater Resources Index(GRI).

نتایج نهایی ترکیب بهینه ورودی‌های شبکه عصبی در جدول ۴ آورده شده است. در پیش‌بینی مقادیر تست با استفاده از مدل سری زمانی ۸۵ درصد داده‌ها برای آموزش و ۱۵ درصد باقی مانده برای تست در نظر گرفته شد و در واقع از ۱۵ درصد داده‌های اعتبار سنجی در مدل شبکه عصبی نیز به عنوان داده آموزش در مدل سری زمانی استفاده گردید. نتایج مدل‌سازی با بهترین ساختار مدل سری زمانی در جدول ۵ نشان می‌دهد که مدل ARIMA(1,1,3) (2,0,1) نسبت به سایر مدل‌ها دارای خطای کمتری بر اساس معیارهای آکاییک و

گام زمانی تاخیر، موثرترین سیگنال‌های اقلیمی جهت مدل‌سازی با شبکه عصبی مصنوعی می‌باشد و شاخص SOI به دلیل دارا بودن مقدار گاما کمتر از حالتی که تمامی متغیرها حضور دارند، از ترکیب متغیرها حذف گردید. در ساختار دوم، به سبب اینکه مقدار گاما در تاخیرهای ۱۰ و ۵ شاخص منبع آب زیرزمینی، کاهش یافت در ترکیب ورودی در نظر گرفته نشد. در ساختار سوم نیز، حذف تمامی پارامترهای هواشناسی بجز تبخیر و تعرق سبب افزایش مقدار گاما شده و بدین ترتیب تبخیر و تعرق از ترکیب ورودی حذف شد.

جدول ۳- نتایج آزمون گاما برای مقادیر GRI در سه ساختار مورد بررسی.

Table 3. The results of GRI3's Gamma Test in three structures.

شماره ترکیب	ساختار اول		ساختار دوم		ساختار سوم	
	First structure	مقدار گاما	Second structure	مقدار گاما	Third structure	مقدار گاما
متغیر حذفی	متغیر حذفی	متغیر حذفی	متغیر حذفی	متغیر حذفی	متغیر حذفی	متغیر حذفی
Number of combination	Mask Variable	Gamma Value	Mask Variable	Gamma Value	Mask Variable	Gamma Value
1	—	0.001605	—	0.002982	—	—
2	PDO _(t-3)	0.002442	GRI _(t-12)	0.003122	Evapotranspiration _(t-5)	0.000432
3	SOI _(t-1)	0.001388	GRI _(t-11)	0.003155	Precipitation _(t-6)	0.001658
4	AMM _(t-5)	0.00301	GRI _(t-10)	0.002674	Abs_Max_Temp _(t-5)	0.00071
5	MEI _(t-1)	0.001658	GRI _(t-6)	0.003457	Abs_Min_Temp _(t-5)	0.001039
6	GRI _(t-12)	0.002202	GRI _(t-5)	0.003049	Mean_Temp _(t-5)	0.000702
7	GRI _(t-11)	0.00154	GRI _(t-4)	0.003473	Max_Temp _(t-5)	0.000726
8	GRI _(t-10)	0.001741	GRI _(t-3)	0.003	Min_Temp _(t-5)	0.000746
9	GRI _(t-6)	0.002168	GRI _(t-2)	0.00291	GRI _(t-12)	0.000655
10	GRI _(t-5)	0.001464	GRI _(t-1)	0.003965	GRI _(t-11)	0.000847
11	GRI _(t-4)	0.001664			GRI _(t-10)	0.000824
12	GRI _(t-3)	0.00171			GRI _(t-6)	0.00114
13	GRI _(t-2)	0.002076			GRI _(t-5)	0.001266
14	GRI _(t-1)	0.002177			GRI _(t-4)	0.001089
15					GRI _(t-3)	0.001228
16					GRI _(t-2)	0.000228
17					GRI _(t-1)	0.002569

جدول ۴- نتایج نهایی ترکیب بهینه ورودی‌ها.

Table 4. Final results of optimum combination inputs.

ترکیب ورودی	ساختار
Input combination	structure
.PDO _(t-3) , AMM _(t-5) , MEI _(t-1) , GRI _(t-12) , GRI _(t-10) , GRI _(t-6) , GRI _(t-4) , GRI _(t-3) , GRI _(t-2) , GRI _(t-1)	First
.GRI _(t-12) , GRI _(t-11) , GRI _(t-6) , GRI _(t-5) , GRI _(t-4) , GRI _(t-3) , GRI _(t-1)	Second
GRI _(t-12) , GRI _(t-11) , GRI _(t-10) , Pre _(t-6) , Abs_Max _(t-5) , Abs_Min _(t-5) , Mean _(t-5) , Max _(t-5) , Min _(t-5) , .GRI _(t-6) , GRI _(t-5) , GRI _(t-4) , GRI _(t-3) , GRI _(t-1)	Third

تست داشته‌اند. به طوریکه ساختارهای اول و سوم نسبت به مدل منفرد آریما نیز نتایج بهتری داشته‌اند. همانطور که در قبل اشاره شد مدل ترکیبی (ANN-ARIMA)، از خروجی‌های وزن‌دار شده‌ی مدل‌های منفرد بوده که در این تحقیق شامل شبکه عصبی پرسپترون چندلایه و مدل سری زمانی آریما می‌باشد. این اقدام در محیط نرم‌افزاری

شوارتز بوده و لذا از این مدل جهت پیش‌بینی مقادیر تست استفاده گردید. نتایج بهترین ساختار هریک از مدل‌های منفرد و مدل ترکیبی شبکه عصبی - آریما(ANN-ARIMA) در جدول ۶ آورده شده است. مطابق با جدول ساختار سوم، اول و دوم شبکه عصبی بر اساس معیارهای ارزیابی به ترتیب بیشترین کارایی را در پیش‌بینی مقادیر

جدول ۵- پارامترهای مدل منتخب و معیارهای ارزیابی برای مدل سری‌های زمانی GRI.

Table 7. Parameters and evaluation measures of selected model for GRI.

Model	Parameters	Coef	SE Coef	T ratio	P value	AIC	SBC
مدل	پارامترها	مقدار پارامتر	معیار خطای استاندارد	نسبت T	مقدار P	معیار آکاایک	معیار شوارتز
ARIMA(1,1,3)(2,0,1)	ϕ_1	0.7808	1.5788	0.49	0.621		
	Φ_1	1.1482	0.0704	16.31	0		
	Φ_2	-0.1392	0.071	-1.96	0.051	14.60057	
	θ_1	0.8462	1.5744	0.54	0.591		
	θ_2	-0.2738	0.1213	-2.26	0.025		
	θ_3	0.1788	0.3316	0.54	0.59		
	Θ_1	0.8913	0.0405	22.02	0		

جدول ۶- نتایج معیارهای ارزیابی شبکه عصبی، سری زمانی و مدل ترکیبی ANN-ARIMA به منظور پیش‌بینی مقادیر GRI.

Table 5. The results of evaluation measures for Artificial Neural network, Time series and ANN-ARIMA models in order to GRI forecasting.

R ²		RMSE		MAE		ساختار بهینه	مدل
آموزش	تست	آموزش	تست	آموزش	تست	Optimum structure	Model
Train	Test	Train	Test	Train	Test		
0.91	0.86	0.04	0.09	0.02	0.07	10-14-1	First ANN St. شبکه اول
0.92	0.84	0.03	0.08	0.02	0.06	7-18-1	Second ANN St. شبکه دوم
0.94	0.90	0.03	0.06	0.02	0.05	14-10-1	Third ANN St. شبکه سوم
0.90	0.85	0.05	0.08	0.05	0.08	(1,1,3)(2,0,1)	سری زمانی ARIMA
0.91	0.94	0.03	0.05	0.04	0.04	ANN-ARIMA	ترکیبی ANN-ARIMA

بحث و نتیجه گیری:

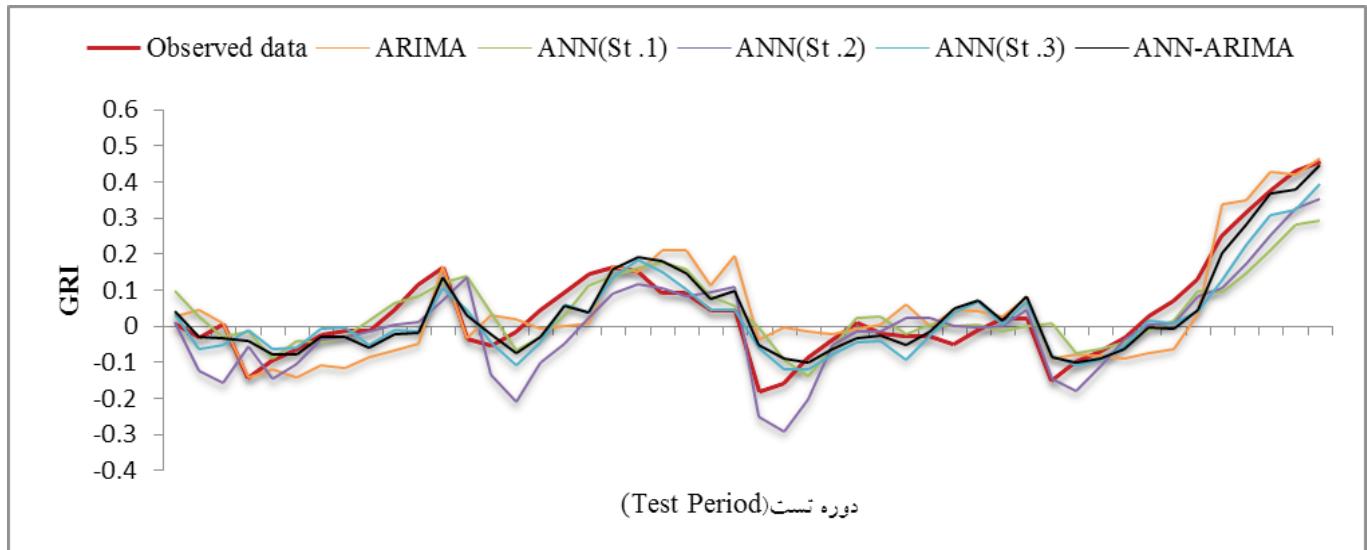
در سال‌های اخیر، عوامل بسیاری سبب افت شدید سطح آب زیرزمینی در سطح آبخوان‌های واقع در استان قزوین گردیده است که به تبع ادامه این روند سبب بروز شرایط بحرانی در آن‌ها خواهد شد. لذا پیش‌بینی و مدل‌سازی خشکسالی در این منطقه بر راهکارهای مهم و اولیه در مدیریت سیستم‌های منابع آب نقش داشته و کاهش خسارات ناشی از خشکسالی را در پی دارد.

طبق نتایج تحقیق، نوسانات شاخص منبع آب زیرزمینی با یک گام تاخیر، واپسگی بالاتری را با شاخص‌های اقلیمی SOI و MEI از خود نشان داده است که با توجه به ارتباط بسیار نزدیک متقابل میان سطوح آب زیرزمینی و سطحی، با نتایج مطالعه انجام گرفته در

MINITAB انجام گرفت که معادله مدل ترکیبی به صورت رابطه (۵) می‌باشد که در آن A، B و C به ترتیب مقادیر پیش‌بینی شده GRI بدست آمده با مدل سری زمانی، شبکه عصبی و مدل ترکیبی می‌باشد.

$$C = 0.00792 + (0.227 \times A) + (0.791 \times B) \quad (5)$$

در نهایت مدل ترکیبی شبکه عصبی-آریما(ANN-ARIMA) مقادیر تست را با همبستگی بیشتر و خطای کمتری پیش‌بینی نموده و می‌تواند نسبت به سایر مدل‌های مورد مطالعه در این تحقیق کارایی قابل قبولی داشته باشد. بطوریکه طبق شکل ۳، ساختار دوم بخصوص در پیش‌بینی مقادیر حداقل توانایی خوبی از خود نشان نداده است.



شکل ۳- مقادیر GRI مشاهداتی و پیش‌بینی شده با استفاده از مدل شبکه عصبی مصنوعی، سری زمانی و مدل ترکیبی.

Figure 3. Observed and predicted GRI values using ANN, ARIMA and ANN-ARIMA models

در آینده مورد بررسی قرار گیرد. در مجموع انتخاب مدل مناسب جهت پیش‌بینی هرچه دقیق‌تر مقادیر GRI از یک طرف نیاز به بررسی کلیه مدل‌های پیش‌بینی داشته و از طرف دیگر باید متناسب با نوع نیاز، هدف و امکانات باشد، لذا به طور قطعی نمی‌توان تنها یک مدل مناسب را برای کل منطقه ارائه و تعمیم داد. چرا که هر مدل دارای مزایا و محدودیت‌هایی است که با توجه به ویژگی‌های نواحی مختلف، نوع داده و... ممکن است نتایج مختلفی از آن بدست آید [۲۲، ۳۴]. لذا نیاز است تعیین مدل مناسب با خطا‌برآورد کمتر در هر منطقه به صورت جداگانه مورد بررسی قرار گیرد و با توجه به هدف و نیاز، از مدل معروفی شده جهت انجام پیش‌بینی‌های آینده به منظور مدیریت بهتر استفاده گردد.

منابع

- Adamowski, J. and Fung Chan, Hiu. 2011. A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*. 407:28-40.
- Astañeda, C. Herrero, J. and Auxiliadora, M. 2005. Landsat monitoring of playa lakes.
- Box, G.E.P. and Jenkins, G.M. 1976. *Time Series Analysis Forecasting and Control*. San Francisco: Holden-Day.
- Chitsazan, M. Rahmani, Gh. and Neyamadpour, A. 2013. Groundwater level simulation using artificial neural network: a case study from Aghili plain, urban area of Gotvand, south-west Iran, *JGeope*. 3(1): 35-46.

دریاچه ارومیه در ایران مطابقت داشته است [۱۵] و [۸]. در نمونه مطالعه انجام گرفته در خارج از کشور نیز ارتباط معنی‌داری بین SOI و تراز آب در آرژانتین مشاهده است [۲۹]. همچنین شاخص PDO نیز برخلاف AMO تاثیر معنی‌داری بر تراز آب داشت که با نتایج محققین همخوانی دارد [۲۱]. مقایسه عملکرد دو مدل منفرد شبکه عصبی و سری زمانی نشان داد که با تعیین ترکیب بهینه ورودی، مدل شبکه عصبی مصنوعی نسبت به مدل سری زمانی دارای عملکرد بهتری بوده که با نتایج محققین همخوانی دارد [۲۰، ۲۸، ۳۴، ۳۵]. در مجموع نیز مقایسه مقادیر پیش‌بینی شده در سه روش مذکور نشان داد که مدل ترکیبی ANN-ARIMA با میزان همبستگی ۰,۹۴ (RMSE= 0.05)، دارای نتایج قابل قبولی نسبت به دو روش دیگر می‌باشد که با مطالعات مشابه در این زمینه مطابقت دارد [۲۶] و [۹]. همچنین نتایج ساختارهای اول، دوم و سوم ورودی به شبکه عصبی نشان داد که در مجموع استفاده از پارامترهای هواشناسی سبب بهبود عملکرد شبکه گردیده است که با مطالعه انجام شده توسط محققین همخوانی دارد [۳۰] و [۴]. چراکه در ساختار سوم شبکه عصبی علاوه بر بیشتر بودن تعداد پارامترهای ورودی نسبت به دو ساختار دیگر، تعداد پارامترهای ورودی با همبستگی بالا نیز در افزایش عملکرد این ساختار موثر بوده است که با نتایج محققین همخوانی دارد [۱۴]. از آنجا که افزایش تعداد پارامترهای ورودی ممکن است سبب افزایش خطای پیش‌بینی با استفاده از شبکه عصبی شود، لذا در ساختار اول شبکه عصبی در این تحقیق تنها پنج سیگنال اقلیمی مورد بررسی قرار گرفت که با توجه به ناشناخته بودن برخی ارتباطات و اثرات رفتارهای اقلیم بر آب‌های زیرزمینی نیاز به اطلاعات و تحقیقات گسترده‌ای می‌باشد [۱۲] که در این راستا پیشنهاد می‌شود اثر سایر سیگنال‌ها و عوامل نیز در افزایش یا کاهش دقت پیش‌بینی

15. Jalili, S. Morid, S. Banakar, A. and Namdar Ghanbari, R. 2011. Assessing the effect of SOI and NAO indices on lake Urmia Water level variations, application of spectral analysis. *Journal of Water and Soil*. 25(1): 140-149. (In Persian)
16. Kenneth, H. F. 2003. Climate variation drought and desertification. W. M. Annual Report Jevenva.
17. Khaledi, M.B and Fatahi, E. 2013. Analysis of lake water level between the climatic signals. *Quarterly Geographical Journal of Territory (Sarzamin)*,10(37), 91-107. (In Persian)
18. Khosravi, M. and Shakiba, H. 2010. Precipitation forecasting using artifitial neural Network for flood management (Case Study: Iranshahr region (South East of Iran)). 4th International Congress of The Islamic World Geographers (ICIWG), 1-21. (In Persian)
19. Khosravi, M. Nasiri, M. Safavi, A.A. and Poorjafarian, N. 2012. Drought forecasting using Artificial Neural Network.(Shiraz station). *Journal of Arid Regions Geographic Studies*. 2(8): 103-119. (In Persian)
20. Khuriyatia, M. Okayamab, H. and Suyantohadia, A. 2011. Application of artificial neural networks in underground water resources management, *Aula Orientalis*. 1: 1-10.
21. Kuss, A.J.M. and Gurdak, J.J. 2014. Groundwater level response in U.S. principal aquifers to ENSO, NAO, PDO, and AMO. *Journal of Hydrology*. 519: 1939-1952.
22. Malekinezhad, H. and Poorshareyati, R. 2012. Application and comparison of time series and artificial neural network in prediction of ground water table (Case Study: Mavast Plain). *Irrigation Science and Engineering*. 23(2): 81-82. (In Persian)
23. Mariotti, A. Zeng, N. Lau, K. M. 2002. Euro-Mediterranean rainfall and ENSO seasonally varying relationship, *Geophysical Research Letters*, 29(12): 59-1-59-4.
24. Mendicino, G. Senatore, A. and Versace, P. 2008. A Groundwater Resource Index (GRI) for drought monitoring and forecasting in a Mediterranean climate. *Journal of Hydrology*, 357: 282- 302.
5. Coppola, E. Rana, A.J. Poulton, M. Szidarovszky, F. and Uhi, V.W. 2005. Aneural networks model for predicting aquifer water level elevation. *Ground Water*. 43: 231-241.
6. Cullen, H. N. and Demenocal, P. B. 2000. North Atlantic Influence on Tigris-Euphrates Stream Flow, *International journal of Climatology*, 20: 853-863.
7. Dini, M. 2005. Short-term prediction of Tehran urban water demanding using fuzzy and neuro-fuzzy method. Master Thesis. technical college. Tehran University. (In Persian)
8. Fatehi Maraj, A. Borhani Darian, A. and Mahdian, M. (2006). Forecasting seasonal rainfall using teleconnection pattern (Case study: Orumiyah Lake Basin), *Journal of Sciennce and Technology of Agriculture and Natural Resources, Water and Soil Science*, 10(3): 45-58.(In Persian)
9. Fathabadi , A. mahdavi, and M.M. Salajegheh, A. 2008. Streamflow forecasting using Neuro-fuzzy and time series methods . *Iranian Journal of Watershed Management Science and Engineering*. 2(5), 21-30. (In Persian)
10. Fathabadi, A.H. 2008. Streamflow forcasting using neuro-fuzzy methods and analysis time series. Master Thesis. Natural resource college. Tehran University. (In Persian)
11. Feng, Sh. Kang, Sh. Huo, Z. Chen, Sh. and Mao, X. 2008. Neural networks to simulate regional ground water levels affected by human activities, *Ground Water*, 46(1): 80-90.
12. Green, T. Taniguchi, M. Kooi, H. Gurdak, J.J. Hiscock, K. Allen, D. Treidel, H. and Aurelia, A. 2011. Beneath the surface of global change: impacts of climate change on groundwater. *Journal of Hydrology*. 405: 532-560.
13. Holman, I.P. 2006. Climate change impacts on ground-water recharge-Uncertainty, short comings, and the way forward, *Hydrogeology Journal*, 14(5):637-647.
14. Jain, A. and Kumar, A.M. 2007. Hybrid neural network models for hydrologic time series forecasting, *Applied Soft Computing Journal*. 7 (2): 585-592.

32. Sharifi, A.R. Dinpajouh, Y. Fakherifard, A. and Moghaddamnia, A.R. 2013. Optimum combination variables for runoff modelling using Gamma test (Case study: Amame watershed), Journal of Water and Soil, 23(4): 59-72. (In Persian)
33. Treidel, H. Martin-Bordes, J.L. and Gurdak, J.J. 2011. Climate change effects on groundwater resources: A global synthesis of findings and recommendations, International Association of Hydrogeologists-(IAH) – International Contributions to Hydrogeology. Taylor & Francis Publishing, Boca Raton, FL, 17-29.
34. Wang, W. Gelder, P. and Virijling. J.K. 2005. Improving daily stream flow forecasting by combining ARMA and ANN models. International conference on innovation advances and implementation of flood forecasting technology, 1:1-13.
35. Yang, Z.P. Lu, W.X. Long, Y. Q. and Li, P. 2009. Application and comparison of two prediction models for groundwater levels: A case study in Western Jilin province, China, Journal of Arid Environments, 73: 487- 492.
25. Menhaj, M.b. 2008. Fundamentals of neural networks , Sharif University of Technology press. Vol1. (In Persian)
26. Mishra, A.K. Desai V.R. and Singh, P. 2007. Drought forecasting using a hybrid stochastic and neural network model, Journal of Hydrologic Engineering, 12(6): 638-626 .
27. 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.
28. Mohammadi, M.R. and fereydooni, M. 2014. Evaluation of artificial neural network and time series models to simulate groundwater levels, International Journal of Engineering Science Invention, 3(3): 43-46.
29. Pasquini, A.I. Lecomte, K.L. and Depetris, P.J. 2008. Climate change and recent water level variability in Patagonian proglacial lakes, Argentina, Global and Planetary Change, 63: 290-298.
30. Poormohammadi, H. Malekinezhad, H. and Poorshareyati, R. 2013. Comparison of ANN and time series appropriately in prediction of ground water table (Case Study: Bakhtegan basin). Journal of water and Soil Conservation. 20(4): 251-262. (In Persian)
31. Seif, M. Mohammadzadeh, H and Mosaedi, A. 2012. Evaluating the impacts of drought on groundwater resources in Fasa aquifer using SPI, GRI and SECI. Water Engineering. 5(13): 45-59. (In Persian)

Abstract

**Performance Comparison of Artificial Neural Network, Time Series and ANN-ARIMA
for Groundwater Resources Index (GRI) Forecasting
(Case Study: South of Qazvin Province)**

F. Maghsoud^{*1}, M. R. Yazdani², M. Rahimi³, A. Malekian⁴ and A. A. Zolfaghari⁵

Received: 2014/09/21 Accepted: 2016/05/07

Groundwater drought is one of the drought types that caused by lack of sufficient groundwater recharge. Groundwater Resources Index (GRI) is a method to express the state of this type of drought using ground water level data. Various methods and models have been presented in order to forecast and model, but selecting a reliable model is a difficult task. So, it would be better to use a combination of acceptable models instead of using just one model. In this study, the GRI values over 1984-2011 period were calculated in south of Qazvin province and its relationship with meteorological parameters such as precipitation, discharge, evapotranspiration, temperature (Mean, Max, Min) and large scale climate signals (MEI, SOI, AMM, AMO, PDO) was modeled by artificial neural network based on the Gamma test and in three structures. The results show that SOI and temperature have higher significant correlation with GRI values and also using the meteorological parameters as input parameters lead to improving the artificial neural network performance. Moreover, the ARIMA (1, 1, 3) (2, 0, 1) was selected for forecasting of GRI based on evaluation measures such as AIC and SBC. Finally, ANN-ARIMA modeling revealed better performance compared with the ANN and ARIMA ($R^2=0.94$, RMSE= 0.05).

Keywords: Artificial neural network, Time series, Gamma test, GRI, SOI, Qazvin.

*1. Ph.D., Student of Watershed Management Sciences and Engineering, Faculty of Natural Resources & Marine Sciences, Tarbiat Modares University. Corresponding Author, Email: F.maghsoud@modares.ac.ir

2. Assistant Professor, Faculty of Desert, University of Semnan. Email: m_yazdani@semnan.ac.ir

3. Assistant Professor, Faculty of Desert, University of Semnan. Email: mrahimi@sun.semnan.ac.ir

4. Associate Professor, Faculty of Natural Resources, University of Tehran. Email: malekian@ut.ac.ir

5. Assistant Professor, Faculty of Desert, University of Semnan. Email: azolfaghari@semnan.ac.ir