



## پیش‌بینی مدل مکانی سطح ایستابی با استفاده از تابع هایپر بولیک تانژانت

### شبکه‌ی عصبی مطالعه‌ی موردی: دشت سرخون

مسعود جلالی\*<sup>۱</sup>، محمد کمانگر<sup>۲</sup>، رباب رزمی<sup>۳</sup>

۱- استادیار، آب و هواشناسی، دانشگاه زنجان، زنجان، ایران

۲ و ۳- دانشجوی دکتری، آب و هواشناسی، دانشگاه زنجان، زنجان، ایران

تأیید نهایی مقاله: ۱۳۹۸/۰۹/۰۶

وصول مقاله: ۱۳۹۷/۰۹/۱۹

#### چکیده

در سال‌های اخیر سطح تراز آب‌های زیرزمینی در اثر تغییرات اقلیمی و همچنین شیوه و میزان بهره‌برداری از آن‌ها، روند نزولی داشته است. با توجه به افزایش تقاضای آب و افت شدید آب‌های زیرزمینی، مدیریت پایدار این منابع از اهمیت شایانی برخوردار است. پیش‌بینی سطح ایستابی با استفاده از مدل‌های ریاضی و آماری می‌تواند کمک قابل توجهی به برنامه‌ریزی و تصمیم‌گیری‌های مناسب جهت تأمین آب در درازمدت، داشته باشد. در این مطالعه تلاش شده است تا سطح آب‌های زیرزمینی با استفاده از شبکه‌ی عصبی گرادیان دیسکنت و تابع انتقال Hyperbolic Tangent پیش‌بینی شود. مدل تابع انتقال Tanh با تعداد ۴۰ نرون در لایه پنهان با ضریب همبستگی ۰/۹۹ و مجذور مربعات خطا ۰/۰۱ برای پیش‌بینی سطح ایستابی پیاده‌سازی شد. با تعمیم این مدل به ده چاه مشاهده‌ای و برون‌یابی در محیط سامانه‌ی اطلاعات جغرافیایی، مدل مکانی پیوسته سطح ایستابی در دشت سرخون برای سال ۱۴۰۰ تخمین زده شد. نتایج نشان داد که سطح ایستابی در قسمت‌های غربی دشت با مقدار ۷۲/۹۸ متر بیشترین و در بخش شرقی دشت با توجه به تراکم جمعیتی بیشتر مقدار با ۱۸/۷۲ متر کمترین سطح ایستابی را خواهند داشت. با توجه به میزان خطای پایین مدل، می‌توان نتیجه گرفت که با اجرای این مدل در دیگر حوزه‌ها می‌توان پیش‌بینی صحیحی از سطح آب‌های زیرزمینی به دست آورد و در برنامه‌ریزی و مدیریت پایدار آب‌های زیرزمینی از آن استفاده نمود.

**کلمات کلیدی:** سطح ایستابی، شبکه‌ی عصبی، تابع انتقال، دشت سرخون.

### ۱- مقدمه

آب‌های زیرزمینی منبع مهم و حیاتی از آب‌های شیرین هستند (وانچ<sup>۱</sup> و همکاران، ۲۰۱۸: ۷۴۵) که در محیط‌های شهری و روستایی جهت برطرف نمودن نیازهای آشامیدنی و کشاورزی محسوب می‌شوند (ماگش و همکاران<sup>۲</sup>، ۲۰۱۲: ۱۹۱). در سال‌های اخیر افزایش تقاضای آب و کاهش سرانه‌ی منابع تجدیدشونده، نگرانی‌های زیادی را ایجاد کرده است. محدودیت‌های منابع آب سطحی، افزایش تقاضای مصرف، همزمان با توسعه‌یافتگی جوامع و افزایش کشاورزی، محققان حوزه‌ی مطالعات آب‌های زیرزمینی را وادار به مدل‌سازی، تخمین و پیش‌بینی شرایط هیدروژئولوژیکی حاکم بر آبخوان‌ها ساخته است (ندیری و یوسفزاده، ۱۳۹۶: ۲۲). پیش‌بینی دقیق تراز آب زیرزمینی اهمیت زیادی در برنامه‌ریزی و مدیریت صحیح منابع آب دارد (رجایی و پوراصلان، ۱۳۹۴: ۱۶) چراکه مدیریت حوزه‌های آبخیز به‌نوبه خود در جهت پایداری منابع آب‌های سطحی و زیرزمینی (موهانتی و همکاران<sup>۳</sup>، ۲۰۱۰: ۱۸۴۶)، حفاظت و مدیریت صحیح و بررسی تغییرات سطح آن‌ها از اهمیت شایانی برخوردار است (ندیری و همکاران، ۱۳۹۵: ۱۱۶) بر اساس بررسی‌های انجام‌شده به‌وسیله‌ی سازمان ملل، ایران در زمره کشورهای مواجه با کمبود آب قلمداد می‌شود. با توجه به خشک‌سالی‌های دهه اخیر، برداشت بی‌رویه از آب‌های سطحی و زیرزمینی و کمبود آب در پهنه‌ی وسیعی از کشور، اهمیت و حساسیت مدیریت آب‌های زیرزمینی، نمود وسیعی می‌یابد. اعمال مدیریت صحیح جهت برنامه‌ریزی‌های کوتاه‌مدت، بلندمدت و استفاده‌ی بهینه‌ی پتانسیل آب‌های زیرزمینی، شناسایی و پیش‌بینی نوسانات سطح آب‌های زیرزمینی را می‌طلبد. تاکنون مدل‌های زیادی جهت پیش‌بینی سطح آب زیرزمینی به‌کاربرده شده است. ازجمله‌ی این مدل‌ها می‌توان به مدل‌های سری زمانی تجربی و مدل‌های فیزیکی اشاره کرد. (نایاک و همکاران<sup>۴</sup>، ۲۰۰۶: ۸۳). مطالعات مدل

1- Wunch et al.,  
 2- Magesh et al.,  
 3- Mohanty et al.,  
 4- Nayak et al.,

شبکه‌ی عصبی به‌عنوان یک تخمین‌گر در دهه‌های اخیر، بیانگر توانایی بالای این مدل در کشف رابطه بین داده‌ها و شناخت الگوها است (دیاکوپلس و همکاران<sup>۱</sup>، ۲۰۰۵: ۲۳۱). در سال‌های اخیر استفاده از شبکه‌های مختلف مصنوعی برای توصیف رفتار و پیش‌بینی سطوح آب زیرزمینی و مطالعه‌ی پویایی آن‌ها، توسعه چشم‌گیری داشته است. به‌عنوان مثال کاپولا و همکاران<sup>۱</sup> (۲۰۰۳) امکان پیش‌بینی سطح ۱۲ چاه مشاهده‌ای در حال پمپاژ را در موقعیت‌های مختلف آب و هوایی و با استفاده از شبکه‌های عصبی مصنوعی، در منطقه‌ای نزدیک خلیج تمبا فلوریدا مورد مطالعه قرار دادند. نتایج کار آن‌ها نشان داد که در مدل‌سازی سطح آب مناطق آهکی و کارستی، شبکه‌های عصبی با میانگین مطلق خطای ۰/۱۶ نسبت به مدل‌های عددی کالیبره شده با میانگین خطای مطلق ۰/۸۵ از جحیت دارد. دیاکوپلس و همکاران<sup>۲</sup> (۲۰۰۵) سطح آب زیرزمینی در دره مزایا<sup>۳</sup> در کرت یونان، را با استفاده از هفت مدل مختلف شبکه‌ی عصبی مصنوعی پیش‌بینی کردند نتایج ارزیابی آن‌ها شبکه‌ی عصبی با الگوریتم لونیگ را بهترین مدل جهت پیش‌بینی نشان داد. موهانتی و همکاران<sup>۴</sup> (۲۰۱۰) مطالعه‌ای در هند انجام دادند و مدل‌های مادفلو و شبکه‌ی عصبی در شبیه‌سازی سطح آب‌های زیرزمینی را مورد ارزیابی قرار دادند. نتایج نشان داد که مدل شبکه‌ی عصبی مصنوعی در کوتاه‌مدت پیش‌بینی بهتری داشته است. توآرمینو و همکاران<sup>۵</sup> (۲۰۱۲) جهت شبیه‌سازی‌های سطوح آب زیرزمینی از شبکه‌ی عصبی پیشرو استفاده نمودند. نتایج نشان داد که شبکه‌ی عصبی نسبت به مدل اتو رگرسیون موفق‌تر بوده است. چانگ<sup>۶</sup> و همکاران (۲۰۱۶) تحقیقی را جهت پیش‌بینی ماهیانه سطح آب‌های زیرزمینی در دشت ژائوشیو تایوان با استفاده از محاسبات نرم ترکیب روش‌های خودهمبستگی غیرخطی ایستگاه‌های باران‌سنجی، جریان آب سطحی و زیرزمینی و شبکه‌ی عصبی مصنوعی انجام دادند. نتایج آن‌ها نشان داد روش ابداعی ترکیبی آن‌ها با در دو حالت آموزش و پیش‌بینی ضریب

1- Coppola et al.,

2- Daliakopoulos et al.,

3- mezara et al.,

4- Mohanty et al.,

5- Taormina et al.,

6- Chang et al.,

همبستگی بالای ۰/۹ را از خود نشان می‌دهد. گازمن<sup>۱</sup> و همکاران (۲۰۱۷) جهت مدیریت بهینه آب‌های زیرزمینی مورداستفاده کشاورزان دره می‌سی‌سی‌پی آمریکا با استفاده از شبکه‌ی عصبی لونمبرگ و بیزی با تعداد نرون‌های ۲۵،۵۰، ۷۵ و ۱۰۰ عددی سطح آب‌های زیرزمینی را به صورت کوتاه مدت پیش‌بینی کردند. مقایسه‌ی روش‌ها با خطای متوسط مربعات و ضریب تعیین نشان داد بهترین روش شبکه‌ی عصبی با تعداد نرون ۱۰۰ و خطای ۰/۰۰۱۱۹ متر است. در مطالعات داخلی نیز رجایی و پوراصلان (۱۳۹۴) با استفاده از مدل‌های شبکه‌ی عصبی مصنوعی و کریجینگ و داده‌های هشت ساله پیش‌بینی زمانی و مکانی سطح ایستابی دشت داورزن را انجام دادند. نتایج آن‌ها نشان داد شبکه‌ی عصبی می‌تواند با میانگین ضریب انطباق ۰/۶۸ و ضریب همبستگی ۰/۶۵ می‌تواند نتایج قابل قبولی را در پیش‌بینی ارائه دهد. رجایی و همکاران (۱۳۹۵) پیش‌بینی تراز آب زیرزمینی حوزه‌ی آبریز شریف‌آباد قم را با استفاده از مدل‌های شبکه‌ی عصبی و موجک انجام دادند نتایج آن‌ها نشان داد مدل ترکیبی موجک عصبی پیش‌بینی دقیق‌تری برای تراز آب زیرزمینی ماهانه نسبت به مدل‌های تکی دارد به طوری که ضریب نش در مدل ترکیبی برای پیژومترهای مورد مطالعه بالای ۹۵ درصد حاصل شد. با بررسی تحقیقات انجام شده پیرامون پیش‌بینی سطح ارتفاع آب، نشان‌دهنده‌ی تخمین‌های با خطای‌های مختلف بوده است اما در این مطالعات شبکه‌های عصبی مصنوعی با ساختار یکسان اما لایه‌های پنهان متفاوت کم‌تر مورداستفاده قرار گرفته‌اند. همچنین بررسی سطح ایستابی به صورت نقطه‌ای در قالب توزیع زمانی انجام شده است و در آن توزیع مکانی در نظر گرفته نشده است. داوم خشک‌سالی‌های چندساله اخیر در استان هرمزگان و نیز ازدیاد مصرف بی‌رویه و خارج از توان مخازن آبی، منجر به تحمیل مشکلات عظیم و مخربی بر منابع آبی استان بالأخص مخازن زیرزمینی شده است. دشت سرخون یکی از حوزه‌های نزدیک به مرکز استان هرمزگان است که پیش‌بینی روند تغییرات و تراز سطح آب زیرزمینی آبخوان این دشت جهت اتخاذ تصمیمات بهینه حائز اهمیت است. هدف از این مقاله پیش‌بینی

1- Guzman et al.,

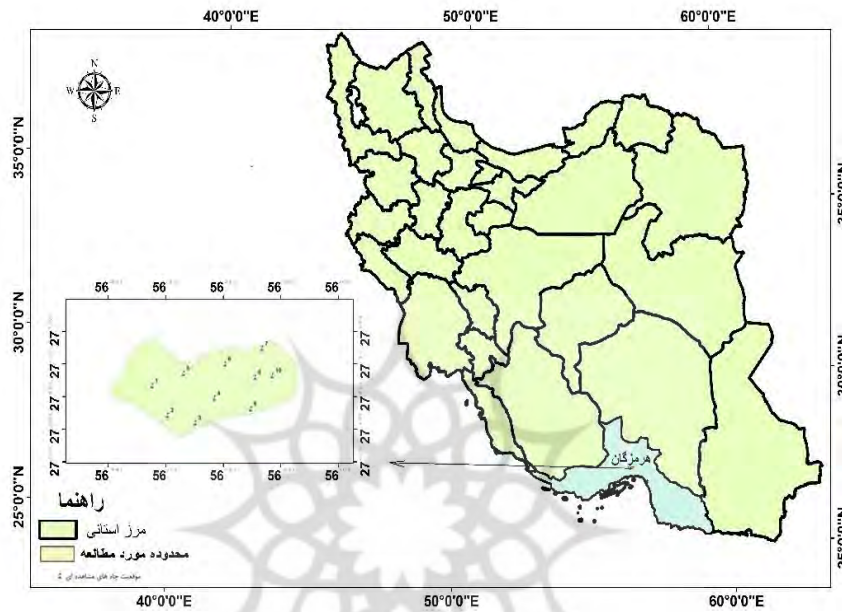
مدل مکانی تراز سطح ایستایی دشت سرخون با استفاده از روش شبکه‌ی عصبی مصنوعی و قاعده Hyperbolic tangent و بررسی سطح خطای این مدل است. در واقع به ارزیابی توانایی این مدل در پیش‌بینی سطح ایستایی جهت تولید اطلاعات مکان محور برای مدیریت بهینه‌ی حوزه‌ی مورد بررسی خواهد بود.

## ۲- مواد و روش

### - محدوده‌ی مورد مطالعه

آبخوان سرخون به فاصله‌ی تقریبی ۲۵ کیلومتری از بندرعباس با مساحتی حدود ۱۰۴۶ کیلومترمربع و در حدود عرض‌های شمالی ۲۷ و ۹ دقیقه تا ۳۵ و ۲۷ دقیقه و طول‌های شرقی ۵۶°، ۷ دقیقه تا ۳۳°، ۵۶ و ۳۳ دقیقه شکل (۱) در حوضه‌ی آبریز سرخون واقع شده است. بلندترین نواحی دشت سرخون دامنه‌ی کوه گنو در غرب دشت و پست‌ترین نواحی آن حاشیه‌ی رودخانه شور در شرق دشت است. روستای سرخون و اراضی زراعی و باغات مربوط به آن و نیز عمده چاه‌های بهره‌برداری در بخش شرقی دشت و در پائین‌دست مسیل‌های دم<sup>۱</sup> و قادهار<sup>۲</sup> قرار داشته و این موضوع باعث افت سطح آب زیرزمینی به علت تمرکز چاه‌ها شده است. محدوده مورد مطالعه از نظر زمین‌شناسی ساختاری، در زون زاگرس چین‌خورده واقع شده است. در این محدوده سازندهایی از پرکامبرین تا کواترنر وجود دارد. جنس آبرفت در بخش غربی و ورودی دشت و همچنین مرکزی دشت دانه‌درشت و با پیشروی به سمت شمال شرق و جنوب و بالاخص شرق و جنوب شرقی (خروجی دشت) از قطر دانه‌بندی آبرفت کاسته شده و آبرفت حالت دانه‌ریز پیدا می‌کند. میزان بارندگی بلندمدت سالانه این حوضه ۲۲۵ میلی‌متر، دمای متوسط ۲۲/۸ درجه‌ی سانتی‌گراد و تبخیر از سطح دشت ۳۵۰۸ میلی‌متر است.


1- Dam  
2- Ghadhar



شکل (۱) محدوده ی مورد مطالعه در ایران و هرمزگان

Fig (1) Study Area in Iran and Hormozgan

به منظور نشان دادن تغییرات عمق سطح آب زیرزمینی در سال های مختلف از هیدروگراف معرف آبخوان استفاده شده است. هیدروگراف معرف یک آبخوان، عکس العمل آبخوان را در طول یک دوره ی مشخص نسبت به عوامل تغذیه و تخلیه کننده نشان می دهد. از روی هیدروگراف مذکور می توان تغییر ارتفاع میانگین سطح آب را برای یک دوره ی مشخص تعیین نمود. با توجه به نمودار (۲) میزان تغییرات سطح آب زیرزمینی دشت سرخون در طی دوره ی ۲۵ ساله ی آبی ۶۹-۶۸ لغایت ۹۲-۹۱ سالانه به طور متوسط حدود ۰/۵ متر افت داشته است.



شکل (2) هیدروگراف واحد آبخوان آبرفتی دشت سرخون

Fig (۲) Hydrograph of alluvial aquifer unit of Sarakhoon plain

از آنجایی که هدایت الکتریکی نمایانگر میزان املاح در آب است می‌توان از آن به‌عنوان شاخص کیفی آب استفاده کرد در این پژوهش برای تهیه‌ی لایه‌ی هدایت الکتریکی محدوده‌ی دشت سرخون از اطلاعات کیفی چاه‌های مشاهده‌ای با میانگین آمار ۱۰ ساله استفاده شد. به‌این‌ترتیب که اطلاعات ثبت‌شده پارامتر EC چاه‌های مشاهده‌ای به‌صورت لایه‌ای وارد نرم‌افزار Arc GIS گردید و سپس توسط میانبایی به روش کریجینگ معمولی نقشه‌ی پراکنش هدایت الکتریکی دشت بدست آمد. محدوده‌ی پارامتر هدایت الکتریکی بین ۶۸۲ تا ۶۲۵۰ میکروموس بر سانتی‌متر می‌باشد. به‌طورکلی آب‌های زیرزمینی در بخش غربی و ورودی دشت و همچنین مرکزی دشت دارای میزان املاح کمتر بوده که می‌توان آن را ناشی از تغذیه‌ی آبرفت دانه‌درشت از جریان‌ات ارتفاعات غربی دانست، همچنین در جهت شمال شرق و جنوب و بالاخص شرق و جنوب شرقی (خروجی دشت) در حوالی روستای فتح‌الجلیل به دلیل کاسته شدن از قطر دانه‌بندی آبرفت و طول مسیر

جریان آب زیرزمینی و تغذیه‌ی ناشی از رودخانه شور (به دلیل وجود مناطق بهره‌برداری از آب‌های زیرزمینی در حاشیه‌ی شرقی دشت سرخون و ایجاد شیب هیدرولیکی)، در فصول کمینه سطح آب هدایت الکتریکی افزایش یافته و به مرز ۷۰۰۰ میکروموس بر سانتی‌متر می‌رسد.

## ۲-۲ گردآوری داده‌ها و روش تحلیل

در این تحقیق از اطلاعات ده چاه مشاهده‌ای طی دوره‌ی ۲۵ ساله‌ی آبی ۱۳۶۹-۱۳۶۸ لغایت ۱۳۹۳-۱۳۹۲ برگرفته از سازمان آب منطقه‌ای استان هرمزگان استفاده گردید که مشخصات آن در جدول یک آمده است.

جدول (۱) مشخصات چاه‌های مشاهده‌ای در محدوده مورد مطالعه

مأخذ: اداره آب منطقه‌ای هرمزگان، ۱۳۹۵

Table (1) Characteristics of observation wells in the study area  
Reference: Hormozgan Regional Water Authority, 2016

شماره چاه	نوع آبخوان	نوع سازند	سال حفر	عمق (متر)	تراز	X	Y
۱	آزاد	آبرفت	۱۳۶۸	۸۱	۱۸۰/۱۱	۴۳۳۰۳۱	۳۰۳۱۲۵۸
۲	آزاد	آبرفت	۱۳۶۸	۶۳	۱۶۵/۵۵	۴۳۴۷۵۵	۳۰۲۸۱۰۷
۳	آزاد	آبرفت	۱۳۶۸	۳۷/۲۷	۱۴۴/۸۳	۴۳۷۱۴۸	۳۰۲۷۴۴۵
۴	آزاد	آبرفت	۱۳۶۸	۴۴/۵	۹۴/۴۷	۴۳۸۸۲۴	۳۰۲۹۵۵۵
۵	آزاد	آبرفت	۱۳۶۸	۶۱	۱۳۲/۰۳	۴۳۶۱۳۹	۳۰۳۱۶۷۶
۶	آزاد	آبرفت	۱۳۶۸	۵۰	۹۱/۸۵	۴۴۲۹۷۱	۳۰۳۳۷۹۳
۷	آزاد	آبرفت	۱۳۶۸	۴۱	۸۶/۶۹	۴۴۲۹۷۱	۳۰۳۳۷۹۳
۸	آزاد	آبرفت	۱۳۶۸	۳۰/۵	۷۴/۰۴	۴۴۲۳۶۹	۳۰۳۱۳۵۳
۹	آزاد	آبرفت	۱۳۶۸	۴۷	۸۶/۵۴	۴۴۱۹۷۵	۳۰۲۸۶۴۱
۱۰	آزاد	آبرفت	۱۳۶۸	۳۰/۵	۷۱/۴۱	۴۴۳۸۸۱	۳۰۳۱۵۰۱

شبکه‌های عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند



یادگیری<sup>۱</sup> و با استفاده از پردازشگرهایی بنام نرون تلاش می‌کند با تنظیم وزن‌ها، مدلی را با استفاده از نمونه‌های ورودی-خروجی که در دسترس هستند بدست آورد. وزن نرون‌های لایه‌ی پنهان و لایه‌ی خروجی به‌گونه‌ای تغییر می‌کنند که میزان خطا مینیمم باشد. این خطا به‌صورت زیر نشان داده می‌شود.

$$E = \frac{1}{2}(y - O)^2 \quad (1)$$

شبکه‌ی عصبی استفاده‌شده در این مقاله بردار خروجی  $Y = [y]$  است. که در رابطه‌ی (۱)،  $y$  خروجی نمونه در دسترس و  $O$  خروجی تولید شده توسط شبکه برای همان نمونه می‌باشد.  $X = [x_1, \dots, x_n]$  بردار ورودی است و  $n$  تعداد مؤلفه‌های بردار ورودی است.  $K$  تعداد نمونه‌هایی است که در طول فرایند یادگیری از آن‌ها استفاده می‌شود. برای هر بردار  $X$  ورودی داده‌شده،  $O$  بردار خروجی تولیدشده توسط شبکه است.

$$O_k = f(-net_k) \quad (2)$$

$f$  تابع انتقال است و  $net_k$  برای نرون‌های لایه‌ی خروجی با نمونه  $k$  ام به‌صورت زیر است (یونابا و همکاران، ۲۰۱۰: ۲۷۷):

$$net_k = W_k^T \cdot H_k = \sum_{l=1}^L W_{kl} H_{kl} \quad (3)$$

$L$  تعداد نرون‌های موجود در لایه‌ی پنهان می‌باشد،  $H_{kl}$  خروجی نرون  $l$  ام لایه‌ی پنهان و  $W_{kl}$  وزن آن است. بردار  $W_k = [W_{k1}, \dots, W_{kL}]$  می‌باشد.

هر کدام از نرون‌های لایه‌ی پنهان در هر لحظه با توجه به ورودی‌ها و وزن‌های هر یک از آنها، خروجی تولید می‌کنند. خروجی  $H_{kl}$  به صورت زیر است (آن ۳ و تانیگچی ۴، ۲۰۱۸: ۶):

1- Learning  
2- Yonaba  
3- Anh  
4- Taniguchi

$$H_{kl} = f(-net_{kl}) \quad (۴)$$

که مقدار برای نرون‌های لایه‌ی پنهان به صورت زیر می‌باشد:

$$net_{kl} = w_{kl}^T \cdot X_k = \sum_{i=1}^I w_{kli} x_{ki} \quad (۵)$$

$x_i$  ورودی  $i$  ام از بردار ورودی  $X_k$  برای نرون  $l$  ام لایه‌ی پنهان و  $w_{kli}$  وزن این ورودی است. بردار وزن برای هر نرون لایه‌ی پنهان به صورت  $w_{kl} = [w_{kl1}, \dots, w_{kln}]$  می‌باشد. در کل شبکه‌ی عصبی هر نمونه از ورودی‌ها را به یک خروجی نگاشت می‌کند.

$$O_k = f(-W_k^T \cdot f(w_{kl}^T \cdot X_k)) \quad (۶)$$

به منظور ارزیابی کارایی مدل به دست آمده از MAE و RMSE و  $R^2$  استفاده می‌شود.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_i - \hat{Q}_i| \quad (۷)$$

$$RMSE = MSE^{0.5} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_i - \hat{Q}_i)^2} \quad (۸)$$

MAE و RMSE مقادیری از صفر تا بی نهایت را دریافت می‌کنند که هر چه مقدارشان کمتر باشد بهتر است.  $R^2$  هر چه به یک نزدیک تر باشد مناسب‌تر است (آداموسکی<sup>۱</sup> و چان<sup>۲</sup>، ۲۰۱۰: ۳۲).

$$R^2 = 1 - \frac{\sum (Q_i - \hat{Q}_i)^2}{\sum Q_i^2 - \frac{\sum \hat{Q}_i^2}{n}} \quad (۹)$$

## ۳- بحث و نتایج

ابتدا ۷۰ درصد داده‌ها (از ۱۳۶۸ تا سال ۱۳۸۹) به‌عنوان داده‌های آموزشی به مدل معرفی گردید منظور از آموزش یک شبکه‌ی انتخابی بر مبنای اطلاعات موجود، تنظیم مقادیر وزن‌ها یا مقادیر ثابت اولیه به‌گونه‌ای است که خطای بین مقادیر خروجی محاسبه‌شده و مشاهده‌شده حداقل گردد. ۲۰ درصد داده‌ها تا سال ۱۳۹۳ به‌عنوان تست برای اعتبار سنجی به کار برده شد.

در گام اول:  $\eta > 0$  و  $E_{max} > 0$  انتخاب می‌شوند.

گام دوم: وزن‌های  $w$  با مقادیر کوچک مقداردهی می‌شوند،  $k := 1$  و  $E$  با صفر مقداردهی می‌شوند.

گام سوم: آموزش شروع می‌شود. ورودی  $x^k$  موجود است.

$x := x^k, y := y^k$  و خروجی  $O$  محاسبه می‌شود.

$$O = \frac{1}{1 + \exp(-W^T \cdot o)} \quad (10)$$

$O$  بردار خروجی لایه‌ی پنهان است که هر عنصر به صورت زیر محاسبه می‌شود:

$$O_l = \frac{1}{1 + \exp(-w_l^T \cdot x)} \quad (11)$$

گام چهارم: وزن‌های واحد خروجی به روز می‌شوند.

$$W = W + \eta \delta o \quad (12)$$

گام پنجم: وزن‌های واحدهای لایه‌ی پنهان به هنگام می‌شود.

$$w_1 = w_1 + \eta \delta w_1 f'(-w_1^T \cdot x) \quad x_l, l = 1, \dots, L \quad (13)$$

گام ششم: مقدار خطای تکرار فعلی محاسبه و به خطای موجود  $E$  اضافه می‌شود.

$$E = E + \frac{1}{2} (Y - O)^2 \quad (14)$$

گام هفتم: اگر  $k < K$  آنگاه  $k := k+1$  و آموزش ادامه می‌یابد و به گام سوم می‌رود در غیر این صورت به گام هشت می‌رود.

گام هشتم: اگر  $E < E_{\max}$  آموزش کامل است. در غیر این صورت  $E := 0$  و  $k := 1$  و چرخه آموزش جدیدی با رفتن به گام سوم آغاز می‌شود.

در گام پنجم الگوریتم بالا،  $\Delta W = [\Delta W_1, \dots, \Delta W_L]$  است و داریم:

$$\Delta W_l = -\eta \frac{\partial E}{\partial W_l} \quad (15)$$


در این تحقیق تابع Hyperbolic tangent با ۵، ۱۰، ۲۰، ۴۰ و ۱۵۰ نرون مورد آزمایش قرار گرفت. تابع hyperbolic tangent عبارت است از:

$$f(\text{net}) = \frac{1 - e^{-\text{net}}}{1 + e^{-\text{net}}} \quad (16)$$

پس از پیاده‌سازی الگوریتم‌های شبکه‌ی عصبی با تعداد نرون‌های مختلف در نرم‌افزار متلب نتایج پیش‌بینی ارتفاع آب دشت سرخون با توابع انتقال Hyperbolic tangent به دست آمد. پس از آموزش شبکه در نظر گرفته‌شده، معیارهای ارزیابی برای هر تابع انتقال با تعداد نرون‌های متفاوت بر روی داده‌های تست آزمایش‌شده و میزان خطای هر مدل با نرون‌های مختلف، برای انتخاب مناسب‌ترین مدل برای پیش‌بینی ارتفاع آب، بررسی گردید و با استفاده از این الگوریتم برای داده‌های ده چاه مشاهده‌ای ارتفاع آب برای دوازده ماه سال ۲۰۲۱ پیش‌بینی شدتنظیم مقادیر روزها یا مقادیر ثابت اولیه به گونه‌ای است که خطای بین مقادیر خروجی محاسبه شده و مشاهده شده حداقل گردد. نتایج پیش‌بینی ارتفاع آب دشت سرخون با استفاده از تابع مذکور حاصل از پیاده‌سازی الگوریتم شبکه‌ی عصبی با تعداد نرون‌های مختلف در شکل (۳)، لحاظ گردیده است. جدول (۳) نیز نتایج ارزیابی میزان خطا برای هر تابع انتقال با تعداد نرون‌های مختلف را نشان می‌دهد.

جدول (۳) میزان خطای‌های متفاوت با تعداد نرون‌های مختلف  
Table (3) shows the error rates with different number of neurons

تعداد نرون		۵	۱۰	۱۵	۲۰	۴۰
Tanh	MAE	۰/۰۳۴۰	۰/۰۱۸۸	۰/۰۱۵۵	۰/۰۱۵۴	۰/۰۱۲۵
	RMSE	۰/۰۳۴۳	۰/۰۱۹۳	۰/۰۱۶۲	۰/۰۱۵۹	۰/۰۱۳۲
	$R^2$	۰/۹۹۷۹	۰/۹۹۹۳	۰/۹۹۹۵	۰/۹۹۹۶	۰/۹۹۹۷



شکل (۳) نتایج پیش‌بینی سطح متوسط ایستابی با تابع انتقال تانژانت و نرون‌های متفاوت

Fig (3) shows the results of the prediction of the mean water level with the tangent transfer function and different neurons

همان‌گونه که مشهود است با افزایش تعداد نرون میزان MAE و RMSE کاهش یافته است و میزان  $R^2$  افزایش یافته و به یک نزدیک‌تر شده است که همه این موارد بیانگر کاهش میزان خطا با افزایش تعداد نرون می‌باشند. با اینکه MAE و RMSE مقادیری نزدیک به یکدیگر را نشان می‌دهند، در مقایسه، میزان MAE کم‌تر است. پس از بررسی میزان خطاهای هر مدل با نرون‌های مختلف تابع انتقال تانژانت هایپربولیک با چهل نرون در لایه‌ی پنهان مناسب‌ترین مدل تشخیص داده شد. با استفاده از این الگوریتم برای داده‌های ده چاه مشاهده ای ارتفاع آب برای دوازده ماه سال ۱۴۰۰ پیش‌بینی شد. میانگین سالیانه ارتفاع آب هر چاه در جدول (۴) آورده شده است. میزان معیارهای بررسی کارایی

مدل برای هر چاه نیز در جدول (۴) ارائه گردیده است. میزان هر سه معیار به موازات یکدیگر از چاه اول به چاه دهم، افزایش و کاهش داشته است. بطوریکه افزایش و کاهش میزان خطا از چاه اول تا دهم، دارای روند تقریباً منظمی بوده است. میزان خطا در چاه نهم با توجه به هر سه معیار، کمترین میزان و در چاه اول بیشترین میزان را به خود اختصاص داده است.

جدول (۴) سطح ایستابی پیش بینی شده برای سال ۱۴۰۰ و میزان خطاهای برآورد شده هر چاه

Table (4) Predicted water level for 1400 and estimated error rates per well


اره چاه	ارتفاع ایستابی	MAE	RMSE	R <sup>2</sup>
چاه ۱	۷۲/۹۹	۰/۱۱۵۷	۰/۱۱۸۶	۰/۹۷۷۱
چاه ۲	۴۸/۵۲	۰/۰۱۲۲	۰/۰۱۳۷	۰/۹۹۹۱
چاه ۳	۲۱/۷۵	۰/۰۱۰۱	۰/۰۱۰۷	۰/۹۹۷۵
چاه ۴	۴۵/۶۶	۰/۰۳۷۰	۰/۰۳۸۶	۰/۹۸۷۱
چاه ۵	۵۸/۰۶	۰/۰۰۸۸	۰/۰۱۰۹	۰/۹۹۹۶
چاه ۶	۵۲/۲۴	۰/۰۳۰۳	۰/۰۳۲۰	۰/۹۹۳۶
چاه ۷	۳۲/۷۲	۰/۰۰۷۱	۰/۰۰۷۷	۰/۹۹۹۳
چاه ۸	۲۹/۹۶	۰/۰۲۱۵	۰/۰۲۴۴	۰/۹۸۸۳
چاه ۹	۳۷/۳۴	۰/۰۰۳۶	۰/۰۰۴۴	۰/۹۹۹۸
چاه ۱۰	۱۸/۲۷	۰/۰۰۹۸	۰/۰۱۰۴	۰/۹۹۵۶

برای تعیین بهترین مدل مکانی پراکنش سطوح مختلف عمق آب زیرزمینی از مدل‌های زمین‌آماری استفاده شد. جهت انتخاب بهترین روش برون‌یابی در این تحقیق هشت روش استفاده گردید که جدول (۵) در زیر به اختصار ذکر شده است.

با توجه پراکندگی‌های چاه‌های مشاهده‌ای و RMSE در نهایت Radial Basis Function بهترین مدل برازش جهت برون‌یابی در منطقه تشخیص داده شد. سپس با این روش مدل مکانی پیش‌بینی‌شده از ارتفاع متوسط سالیانه آب‌های زیرزمینی در دشت سرخون به دست آمد.

جدول (۵) میزان RMSE روش‌های درون‌یابی  
Table (5) RMSE Interpolation Methods

روش درون‌یابی	RMSE
Inverse distance weighting with powe1	۱۵/۶۴
Inverse distance weighting with powe3	۱۳/۳۶
Inverse distance weighting with powe4	۱۴/۹۳
Local Polynomial Interpolation	۱۱/۱۵
Radial Basis Function	۹/۱۴
Simple Kiriging	۱۴/۷۸
Universal Kiriging	۱۱/۷۱
Ordinary Kiriging	۱۰/۶۳



شکل (۴) مدل مکانی پیش‌بینی شده از سطح ایستابی در دشت سرخون سال ۱۴۰۰

Fig (4) The predicted spatial model of the water level in the Sarakhoon plain of 1400

#### ۴- نتیجه‌گیری

مدل‌های شبکه‌ی عصبی در سال‌های اخیر به‌طور فزاینده جهت پیش‌بینی متغیرهای هیدرولوژی از سطح ارتفاع آب‌های زیرزمینی، مورد استفاده قرار گرفته‌اند. در این پژوهش مدل شبکه‌ی عصبی تانژانتی با تعداد نرون‌های متفاوت جهت پیش‌بینی سطح ارتفاع آب‌های زیرزمینی پیاده‌سازی شدند. پس از بررسی معیارهای ارزیابی، مدل شبکه‌ی عصبی هایپربولیک تانژانت با چهل نرون در لایه پنهان به‌عنوان مدل برتر انتخاب گردید و با تعمیم آن برای چاه‌های مشاهده‌ای، مدل پیش‌بینی مکانی از ارتفاع سطح آب‌های زیرزمینی به دست آمد. کمترین مقادیر سطح ایستایی مربوط به قسمت شرقی دشت است که می‌تواند ناشی از تمرکز کشت در این ناحیه و برداشت زیاد از طریق چاه‌های عمیق و نیمه‌عمیق، باشد و بیش‌ترین مقدار مربوط به قسمت غربی آبخوان است که وجود کوهستان در بالادست و تغذیه مستمر از آن را می‌توان دلیل موجهی برای توجیه این امر دانست. میزان بسیار پایین خطا و همبستگی بالای این مدل، حاصل از نتایج داده‌های تست، مبین کارایی آن در پیش‌بینی سطح ارتفاع آب زیرزمینی است. نتایج این تحقیق همسو با نتایج کاپولا<sup>۱</sup> و همکاران (۲۰۰۳) برتری شبکه‌های عصبی را نسبت به مدل‌های عددی اثبات نموده است؛ اما در این تحقیق با توجه به استفاده از شبکه‌های عصبی متفاوت و نرون‌های متعدد، میانگین مطلق خطا کم‌تر برآورد گردیده است و امکان پیش‌بینی بلند مدت‌تری وجود دارد. همچنین نتایج دیاکوپلس<sup>۲</sup> و همکاران (۲۰۰۵) حاکی از برتری شبکه‌ی عصبی لونمبرگ نسبت به مدل‌های دیگر بوده است که وجود سه لایه‌ی پنهان را کافی دانسته است؛ در حالی که به نظر می‌رسد استفاده از لایه‌های پنهان مختلف با نرون‌های متعدد در مدل‌های مختلف منجر به کاهش خطا و متفاوت بودن انتخاب مدل برتر، می‌گردد. تأکید توآرمینو، چاو و سیتچی (۲۰۱۲) بیشتر بر پیش‌بینی‌های کوتاه‌مدت نوسانات آب زیرزمینی بوده است. آن‌ها در کار خود از پارامترهای بارش، تبخیر- تعرق و سطح آب در مدل شبکه‌ی عصبی خود استفاده نموده‌اند. باوجود دارا بودن پارامترهای

1- Coppola

2- Daliakopoulos



بیش‌تر، میانگین مطلق خطای مدل برتر آن‌ها بیشتر از میانگین خطای مدل برتر تحقیق حاضر، بوده است. که احتمالاً علت، اندک بودن نرون های لایه‌ی پنهان و همچنین بازه‌ی زمانی کوتاه انتخابی آن‌ها بوده است. همچنین نتایج تحقیق پیش‌رو، با یافته‌های موهانتی<sup>۱</sup>، کومار<sup>۲</sup>، سودهیر<sup>۳</sup> (۲۰۱۰) که شبکه‌های عصبی را برتر از مدل‌های عددی در پیش‌بینی سطح آب های زیرزمینی در کوتاه‌مدت دانسته‌اند، هم جهت است. اما پیشنهاد آن‌ها جهت پیش‌بینی بلندمدت، مدل‌های عددی است؛ برخلاف نتایج حاصله مطالعه‌ی حاضر که کارایی بالای تغییر الگوریتم‌های شبکه‌ی عصبی در پیش‌بینی‌ها، در بلندمدت را نیز به اثبات رساند. نتایج مطالعه حاکی از آن است که استفاده از یک الگوریتم شبکه‌ی عصبی با تعداد نرون های ثابت نمی‌تواند معیار بررسی کارایی یک مدل باشد و با استفاده از یک الگوریتم اما نرون‌های متعدد می‌توان به نتایج متفاوتی دست یافت. همچنین، علی‌رغم بالا رفتن زمان پردازش عملیات، با افزایش تعداد نرون‌ها، خطای مدل پیش‌بینی کاهش خواهد یافت. در این تحقیق با تست تابع انتقال تانژانتی و نرون‌های متعدد، مدل دارای کم‌ترین خطا انتخاب گردید و با تعمیم این مدل به ده چاه موجود و برون‌یابی مدل مکانی، ارتفاع آب‌های زیرزمینی در کل دشت بدست آمد. مدلسازی متغیرهای آب‌های زیرزمینی بستگی زیادی به کیفیت داده‌ها دارد. از طرفی، بازه‌ی زمانی انتخاب شده، می‌تواند نتایج را تحت تأثیر قرار دهد. بدلیل عدم وجود متغیرهای مهم دیگر از جمله داده‌های منظم بارش و تبخیر و تعرق، در بازه‌ی زمانی مورد مطالعه، امکان بالاتر بردن دقت مدل وجود نداشت. اما امکان ارتقاء دقت مدل، با بکار بردن متغیرهای مهم تأثیرگذار در ارتفاع سطح آب‌های زیرزمینی، محتمل است. این مدل مکانی می‌تواند، به منظور کنترل میزان برداشت آب در مکان‌های مختلف جهت مدیریت پایدار منابع آب، تعیین ساختار پارامترهای ورودی شبکه‌ی عصبی تأثیر دوره‌های خشکسالی و ترسالی و همچنین تأثیر پارامترهایی نظیر بارندگی، دما و تبخیر و تعرق در پیش‌بینی سطح آب زیرزمینی، به کار برده شود.

1- Mohanty

2- Kumar

3- Sudheer

## ۵- منابع

### -Reference

- Adamowski, J., & Chan, H.F. (2011). A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*, 407(1-4), 28-40.
- Anh. Quan Tran, Taniguchi. Kenji. (2018). Coupling dynamical and statistical downscaling for high-resolution rainfall forecasting: case study of the Red River Delta. Vietnam, <https://doi.org/10.1186/s40645-018-0185-6>.
- Chang, F., Chang, L., Huangm C. (2016). Prediction of monthly regional groundwater levels through hybrid soft-computing techniques. *Journal of Hydrology*. Volume541, Part B, October 2016, 976-965.
- Coppola, E., Szidarovszky, F., Poulton, M., & Charles, E. (2003). Artificial Neural Network Approach for Predicting Transient Water Levels in a Multilayered Groundwater System under Variable State, Pumping, and Climate Conditions. *Journal of Hydrologic Engineering*. 8(6), 348-360. doi:10.1061/(ASCE)1084-0699(2003)8:6(348).
- Daliakopoulos, I.N., Coulibaly, P., & Tsanis, I.K. (2005). Groundwater level forecasting using artificial neural networks. *Journal of Hydrology*. 309(1-4), 229-240. doi: <http://dx.doi.org/10.1016/j.jhydrol.2004.12.001>.
- Magesh, N.S., Chandrasekar, N., & Soundranayagam, J.P. (2012). Delineation of groundwater potential zones in Theni district, Tamil Nadu, using remote sensing, GIS and MIF techniques. *Geoscience Frontiers*. 3(2), 189-196. doi: <http://dx.doi.org/10.1016/j.gsf.2011.10.007>.
- Gazman, S., Paz, J., Target, M., (2017). The Use of NARX Neural Networks to Forecast Daily Groundwater Levels. *Water Resources Management*, 31(5), 1591-1603.
- Mohanty, S., Jha, M, Kumar, A. and Sudheer, K,P. (2010). Artificial Neural Network Modeling for Groundwater Level Forecasting in a River Island of Eastern India. *Water Resources Management*. 24(9), 1845-1865. From: doi: 10.1007/s11269-009-9527-x.

- Nadiri, A., Vahedi, F., & Moghadam, A. (2016). Groundwater level prediction using a supervised composite fuzzy logic model. *Hydrogeomorphology*, 6, 115-134.
- Nadiri, A., Yosefadi, Sayyed. (2017). Comparison of Artificial Neural Network Models, Fuzzy Logic and Adaptive Neuro Fuzzy Inference for Estimation of Hydraulic Conductivity of Maragheh-Bonab Plain Aquifer. *Hydrogeomorphology*, 10, 21-40.
- Nayak, P., Satyaji Rao, Y.R., and Sudheer, K.P., (2006). Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water Resources Management*, 2(1), 77-99.
- Rajay, T., Poraslan, F. (2015). Temporal and spatial prediction of groundwater level in the referee plain. *Hydrogeomorphology*, 4,1-19.
- Rajay, T., Zinivand, A., & Jafari, H. (2016). Groundwater level prediction of Sharifabad catchment of Qom using neural wavelet models. *Journal of Applied Geographical Research*, 16(42), 7-26.
- Sethi, R.R., Kumar, A., Sharma, S.P., & Verma, H.C. (2010). Prediction of water table depth in a hard rock basin by using artificial neural network. *International Journal of Water Resources and Environmental Engineering*, 2(4), 95-102.
- Taormina, R., Chau, K.w., & Sethi, R. (2012). Artificial neural network simulation of hourly groundwater levels in a coastal aquifer system of the Venice lagoon. *Engineering Applications of Artificial Intelligence*, Vol.25, No.8, 1670-1676. doi:  
<http://dx.doi.org/10.1016/j.engappai.2012.02.009>.