

نشریه علمی- پژوهشی جغرافیا و برنامه‌ریزی، سال ۲۰، شماره ۵۸، زمستان ۱۳۹۵، صفحات ۲۸۱-۳۰۱

تاریخ دریافت: ۱۳۹۳/۰۳/۲۸

تاریخ پذیرش نهایی: ۱۳۹۳/۱۰/۱۸

پیش‌بینی زمانی و مکانی سطح آب زیرزمینی با استفاده از روش‌های هوش مصنوعی و زمین آمار (مطالعه موردی: آبخوان دشت دوزدوزان)

عطالله ندیری^۱

کیوان نادری^۲

اصغر اصغری مقدم^۳

محمدحسن حبیبی^۴

چکیده

نبود منابع آب سطحی دائمی در بسیاری از نقاط کشور باعث اضافه برداشت آب از منابع محدود زیرزمینی شده است. در دشت دوزدوزان که در حوضه آبریز دریاچه ارومیه قرار دارد، به دلیل عدم جریان سطحی دائمی برداشت بی‌رویه از منابع آب زیرزمینی باعث ایجاد متوسط افت ۷۶ سانتی‌متر در سال شده است. هدف از این تحقیق پیش‌بینی سطح آب زیرزمینی در این دشت با استفاده از روش‌های هوش مصنوعی و زمین آمار می‌باشد. در ابتدا با استفاده از روش خوشه‌بندی مرتبه‌ای (HCA) پیژومترها دسته‌بندی شدند. با انجام آنالیز حساسیت، داده‌های ماهانه سطح آب، بارش و تبخیر هرکدام با یک تأخیر زمانی طی دوره ۱۰ ساله (۹۱-۸۲) به‌عنوان ورودی‌های مدل انتخاب شدند. پس از نرمال‌سازی داده‌ها مدل‌سازی با شبکه‌های عصبی (ANNs) انجام شد. به منظور بررسی بیش‌تر شبیه‌سازی با مدل فازی ساگنو (SFL) نیز انجام شد. برای مقایسه نتایج دو مدل شاخص‌های آماری جذر میانگین مربعات خطا و ضریب تبیین به‌کار گرفته شدند. با توجه به برتری

Email:nadiri@tabrizu.ac.ir

۱- استادیار گروه علوم زمین، دانشگاه تبریز.

۲- دانشجوی کارشناسی ارشد هیدروژئولوژی.

۳- استاد گروه زمین‌شناسی، دانشگاه تبریز.

۴- دانشجوی کارشناسی ارشد هیدروژئولوژی.

مدل ANNs، مدل کریجینگ و کوکریجینگ عصبی برای پیش‌بینی مکانی سطح ایستابی انتخاب شدند و پیش‌بینی مکانی با هر دو مدل انجام شد. نتایج نشان داد که مدل کوکریجینگ با در نظر گرفتن پارامتر ثانویه توپوگرافی نسبت به مدل کریجینگ پیش‌بینی دقیق‌تری داشته است. براساس نتایج به‌دست آمده با افزایش بازه زمانی پیش‌بینی خطای مدل ترکیبی (کوکریجینگ عصبی) افزایش می‌یابد که بیش‌تر به دلیل افزایش خطای مدل شبکه عصبی مصنوعی با افزایش بازه زمانی پیش‌بینی می‌باشد و خطای مدل زمین‌آمار (کوکریجینگ) نامحسوس به‌نظر می‌رسد.

واژگان کلیدی: شبکه‌های عصبی مصنوعی (ANNs)، مدل فازی ساگنو (SFL)، نوسانات سطح ایستابی، کریجینگ، کوکریجینگ، دشت دوزدوزان.

مقدمه

مدل کردن سفره آب‌های زیرزمینی، به‌منظور پیش‌بینی سطح ایستابی از نظر مطالعات هیدروژئولوژی و مدیریتی، ایجاد سازه‌های مهندسی، مصارف کشاورزی و به‌دست آوردن آب‌های زیرزمینی با کیفیت بالا از اهمیت بالایی برخوردار است. انتخاب یک روش و رویکرد مناسب برای مدل‌سازی یک سیستم، کاملاً بستگی به میزان پیچیدگی آن سیستم داشته و پیچیدگی نیز ارتباط معکوس با میزان دانش و شناخت ما از آن سیستم دارد. پس در بسیاری از مواقع لزوماً باید دقت مورد انتظار از مدل را با میزان شناخت خود از سیستم منطبق نماییم. مزیت روش‌های هوش مصنوعی که عدم نیاز به فرم پیچیده ریاضی در محاسبات می‌باشد در دهه‌های اخیر باعث گردیده از این روش‌ها به‌عنوان یک ابزار مؤثر در مدل‌سازی استفاده شود. منطق فازی به‌عنوان یکی از روش‌های هوش مصنوعی در مطالعات هیدروژئولوژیکی کاربرد فراوانی دارد و تحقیقات بسیاری در این زمینه انجام شده است، از آن جمله می‌توان به (Yu et al, 2000 : 7) اشاره کرد که از روش‌های مختلف فازی برای پیش‌بینی سری‌های زمانی بارش استفاده کردند. (Ayvaz et al, 2007: 14) برای به‌دست آوردن پارامترهای آبخوان از روی سطح آب زیرزمینی از مدل فازی به‌عنوان یک روش حل معکوس بهره بردند. شبکه‌های عصبی مصنوعی به‌عنوان مدلی تجربی برای

مدل‌سازی سیستم غیر خطی پویا بسیار مناسب هستند. مبانی و کاربردهای متنوع شبکه‌های عصبی مصنوعی در هیدرولوژی و هیدروژئولوژی اخیراً طی مقالاتی ارائه شده است (اصغری مقدم و همکاران، ۱۳۸۷:۱۶؛ ندیری، ۱۳۸۶:۱۷۸؛ French et al, 2000: 22; ASCE, 2000: 22; al, 1992).

این مدل‌ها توانایی بالایی در کشف رابطه بین داده‌ها و شناخت الگوها دارند (Daliakopoulos et al, 2005: 12). تحقیقات قبلی نشان از توانایی بالای مدل شبکه‌های عصبی مصنوعی برای پیش‌بینی زمانی سطح آب‌های زیرزمینی دارند (Coulibaly et al, 2000:12; Lallahem et al, 2005:20).

(Samani et al, 2007: 11) از شبکه‌های عصبی مصنوعی (MLP-GDX) برای تحلیل داده‌های پمپاژ و به‌دست آوردن پارامترهای آبخوان استفاده کردند. مدل زمین آمار به عنوان روشی کارا، کاربرد وسیعی در پیش‌بینی مکانی پدیده‌های هیدرولوژیکی از جمله سطح آب‌های زیرزمینی داشته است (Dunlap and Spinazola, 1984:19).

تحقیقاتی در زمینه استفاده از روش‌های کریجینگ و کوکریجینگ برای ارزیابی و تخمین نوسانات سطح ایستابی انجام شده و نتایج قابل قبولی حاصل شده است (Desbarats et al, 2002:14 ; Hoeksema et al, 1989:10).

با توجه به این‌که هر یک از مدل‌های فوق توانایی‌های متفاوتی دارند، استفاده از روش‌های ترکیبی و مدل‌های هوش مصنوعی مرکب برای مطالعه سیستم‌های پیچیده می‌تواند کارآمد باشد. به‌طوری‌که بیش‌تر مطالعات در حیطه هوش مصنوعی به این سمت سوق پیدا کرده‌اند (Kadkhodaie et al, 2009: 10; Tayfur et al, 2014: 12). کریجینگ عصبی برای اولین بار توسط (Rizzo and Dougherty, 1994: 59) برای بررسی هدایت هیدرولیکی آبخوان معرفی شد. مدل ارائه شده توسط آن‌ها که در اصل ترکیب مدل سه لایه‌شبکه‌های عصبی مصنوعی و مدل زمین آمار بود، نتایج قابل قبولی ارائه داد (اصغری مقدم و همکاران، ۱۳۸۸:۱۱). از روش کریجینگ عصبی برای پیش‌بینی زمانی و مکانی تغییرات سطح آب‌های زیرزمینی در آبخوان محدوده شهر تبریز بهره جستند.

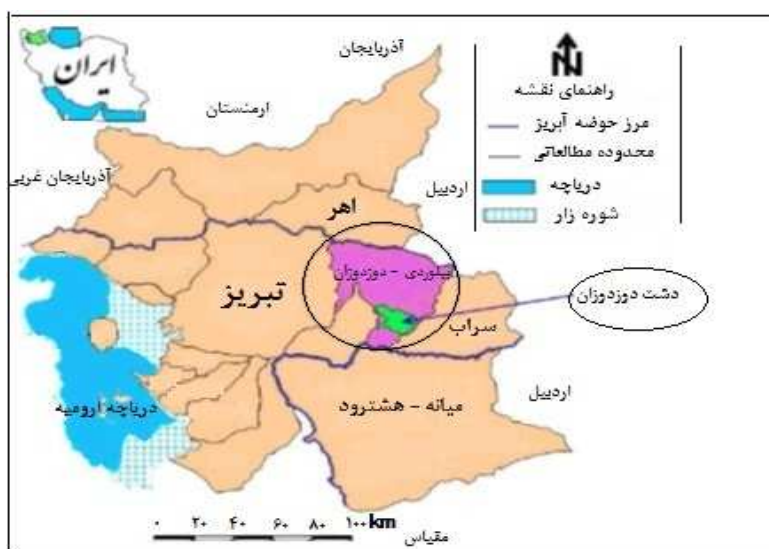
دشت دوزدوزان در حوضه آبریز دریاچه ارومیه قرارداد که به دلیل خشکسالی‌های اخیر و نیز استفاده بی‌رویه از منابع آب زیرزمینی با بحران کاهش سطح آب و نیز کاهش کیفیت آب مواجه است. با توجه به عدم جریان سطحی دائمی و نقش منابع آب زیرزمینی در تأمین نیاز آبی منطقه مدیریت این منابع حیاتی، امری ضروری و اجتناب‌ناپذیر است. هدف از این تحقیق پیش‌بینی زمانی و مکانی سطح آب زیرزمینی در آبخوان دشت دوزدوزان با استفاده از مدل ترکیبی زمین آمار و هوش مصنوعی می‌باشد.

منطقه مورد مطالعه

محدوده مطالعاتی دوزدوزان در حوضه آبریز دریاچه ارومیه و در ۷۵ کیلومتری جنوب شرق تبریز واقع شده است، شکل (۱) موقعیت منطقه مطالعاتی را نشان می‌دهد. حوضه مورد مطالعه مساحتی بالغ بر ۲۱۷ کیلومتر مربع را دارد که دشت دوزدوزان حدود ۸۸/۵ کیلومتر آن را شامل می‌شود. حداکثر ارتفاع در داخل منطقه در قسمت جنوب غربی به ارتفاع ۱۹۰۰ متر و حداقل آن در دشت برابر ۱۶۴۵ متر در قسمت شمال غرب می‌باشد. اقلیم منطقه براساس اقلیم نمای آمبرژه از نوع نیمه‌خشک سرد می‌باشد و براساس آمار ایستگاه برازین از سال ۷۰ الی ۹۲ متوسط درجه حرارت $۸/۷^{\circ}\text{C}$ می‌باشد. میزان متوسط سالانه ریزش‌های جوی براساس آمار ایستگاه باران‌سنجی دشت دوزدوزان ۲۹۶/۵ میلی‌متر در سال طی دوره ده ساله (۱۳۹۱-۱۳۸۲) می‌باشد. برونزد و رخنمون سازندهای زمین‌شناسی، منطقه بیلوردی - دوزدوزان را به چند ناحیه مجزا و جدا از هم تقسیم کرده است که دشت دوزدوزان در جنوب این محدوده قرار دارد. در محدوده مطالعاتی دوزدوزان گسترش اصلی رخنمون‌های زمین‌شناسی را سازندهای میوسن تشکیل می‌دهد. نهشته‌های آبرفتی وسیع که شیب متوسط به سوی غرب و جنوب غرب دارند دشت دوزدوزان را می‌پوشانند. رواناب این دشت از سمت جنوب غرب از حوضه خارج می‌شود که پس از عبور از روی مارن‌های گچ‌دار به آجی چای می‌پیوندد و این می‌تواند یکی از عوامل شوری آجی چای باشد.

آبخوان دشت دوزدوزان از نوع نامحصور و ناهمگن است که به‌عنوان منبع اصلی آب جهت مصارف شرب، کشاورزی و صنعت بشمار می‌رود. آبخوان درون نهشته‌های آبرفتی

دوران چهارم جای گرفته است. جنس سنگ کف آبخوان از نوع رسوبات مارنی/رسی میوسن بوده و شیب عمومی آن به سمت شمال غرب است. ضخامت رسوبات آبخوان در قسمت شمال غرب آبخوان به ۱۳۰ متر می‌رسد و به سمت شرق و شمال شرق ضخامت کاهش می‌یابد. با استفاده از روش بیلان جز به جز ضریب ذخیره آبخوان ۳/۵ درصد به دست آمده است.

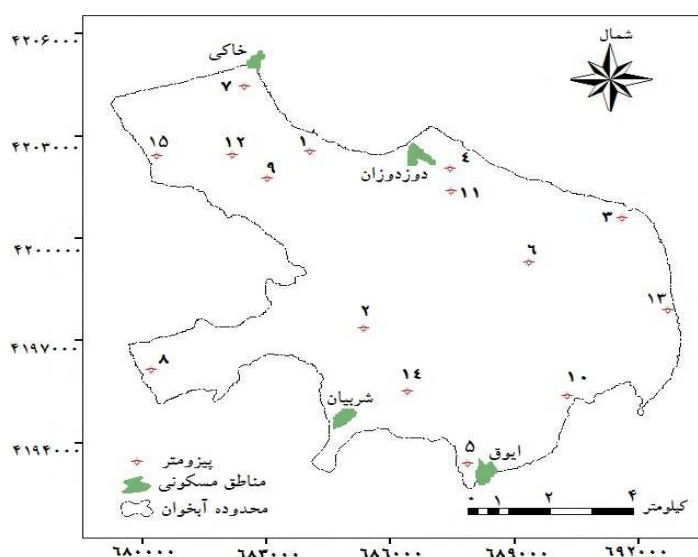


شکل (۱) موقعیت منطقه مطالعاتی

مواد و روش‌ها

در دشت دوزدوزان ۱۵ حلقه چاه پیزومتر برای پایش سطح آب حفر شده است. پس از بررسی طول داده‌های در دسترس برای پیزومترهای موجود در منطقه، ۸ پیزومتر (۱ تا ۸) برای انجام مدل‌سازی انتخاب شدند (شکل ۲). براساس آنالیز حساسیت انجام شده ورودی‌های انتخاب شده برای مدل‌ها جهت پیش‌بینی سطح آب زیرزمینی عبارتند از: ۱- سطح آب زیرزمینی در یک زمان قبل در پیزومترهای مربوطه (1- t₀) ۲- بارش در یک زمان قبل

(t0-1) ۳- تبخیر در یک زمان قبل (t0-1). در این تحقیق از داده‌های بارش ایستگاه دوزدوزان، همچنین داده‌های تبخیر ایستگاه برازین استفاده شده است. برای مدل‌سازی، داده‌های ورودی و هدف به دو دسته آموزش و آزمایش تقسیم شدند. به طوری که ۸۰٪ داده‌ها (۸۰-۸۹) برای مرحله آموزش و ۲۰٪ داده‌ها (۹۰-۹۱) برای مرحله تست انتخاب شد.



شکل (۲) موقعیت پیزومترهای آبخوان دشت دوزدوزان

منطق فازی (FL)

منطق فازی روشی مناسب جهت کاهش خطای تخمینی و انسانی نسبت به تئوری‌های دیگر ارائه کرده است (نیک‌روش و امین‌زاده، ۲۰۰۳: ۷۴۴). سیستم فازی سه بخش اصلی را شامل می‌شود: (۱) تعریف تابع عضویت یا به عبارت دیگر فازی کردن داده‌ها، (۲) ایجاد ارتباط بین ورودی و خروجی با استفاده از یک سری قوانین مثل اگر- آنگاه، (۳) مرحله جمع کردن نتایج سیستم یا غیرفازی‌سازی. روش ساگنو (SFL) برای اجرای مدل‌های فازی در این تحقیق استفاده شده است. در روش ساگنو تابع عضویت خروجی سیستم فازی یک رابطه

خطی و ثابت است که توسط روش دسته‌بندی به‌دست می‌آید. گام نخست در ایجاد یک مدل فازی دسته‌بندی داده‌هاست که انتخاب روش دسته‌بندی بستگی به نوع روش مدل فازی دارد. در این تحقیق روش Subtractive برای دسته‌بندی داده‌ها در مدل فازی ساگنو استفاده شده است.

شبکه عصبی مصنوعی (ANNs)

برای انتخاب بهترین ساختار شبکه‌های عصبی مصنوعی از شبکه‌های عصبی پیشرو (FNN) و ۳ الگوریتم (BR5, GDX6, LM7) استفاده شد. این ساختارها براساس نتایج به‌دست آمده از آن‌ها در مطالعات قبلی انجام گرفته از بین ساختارهای مختلف انتخاب شده است (Daliakopoulos et al, 2005:12 ; Coulibaly et al, 2000:12).

چندین نوع از طراحی شبکه‌های عصبی به‌منظور پیش‌بینی متغیرهای مرتبط با هیدرولوژی بیان شده است (Maier and Dandy, 1998:24). تعداد بهینه گره‌های لایه میانی از طریق آزمون و خطا به‌دست آمد، به طوری که حالت بیضی شکل و تخم‌مرغی شکل شبکه حفظ شود (ندیری و همکاران، ۱۳۹۱ب: ۱۴). تابع سیگموئید تانژانتی هیپربولیک یکی از توابعی است که براساس تحقیقات قبلی (اصغری‌مقدم و همکاران، ۱۳۸۸: ۱۱) برای مدل‌سازی سیستم‌های طبیعی غیرخطی کارایی بالایی دارد. این تابع به‌عنوان تابع تبدیلگر گره‌های پردازشگر لایه مخفی مورد استفاده قرار گرفت. معمولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. (Alvisi et al, 2005:18). در این تحقیق کلیه داده‌های ورودی قبل از اعمال به شبکه از طریق رابطه زیر نرمال شدند (فربودنام و همکاران، ۱۳۸۸: ۱۷):

$$x_{normal} = 0.1 + 0.8 \times \left(\frac{X_0 - X_{min}}{X_{max} - X_{min}} \right) \quad [1]$$

- 1- Bayesian Regularization
- 2- Gradient Descent back propagation
- 3- Levenberg-Marquardt

در این رابطه X_{normal} مقدار نرمال شده، X_0 مقدار واقعی، X_{max} و X_{min} به ترتیب مقادیر ماکزیمم و منیمم داده‌ها می‌باشند.

زمین آمار (Geostatistic)

روش کریجینگ بر اساس میانگین متحرک وزن‌دار بوده و می‌توان آن را بهترین تخمین‌گر خطی نارایب خواند. در روش کریجینگ مدل ریاضی‌ای که برای درون‌یابی استفاده می‌شود به صورت زیر می‌باشد (حسینی پاک، ۱۳۷۷: ۳۱۴):

$$Z^*(x) = \sum_{i=1}^n \lambda_i Z(x_i) \quad [2]$$

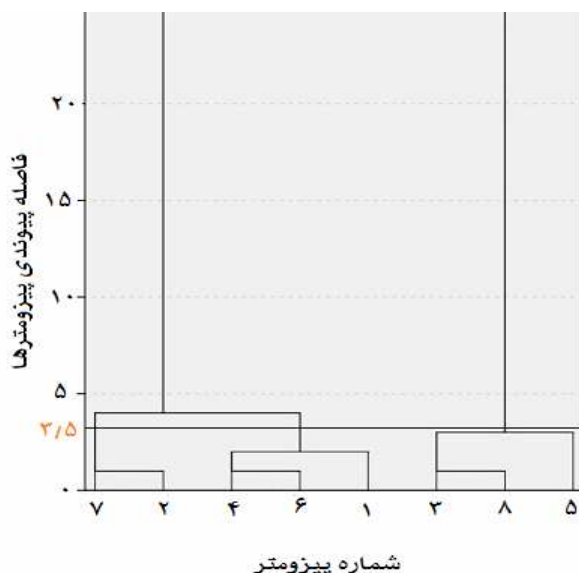
در این رابطه $Z^*(x)$ ، مقدار اندازه‌گیری شده (مقدار معلوم) در موقعیت i ام می‌باشد. λ_i ، مقدار وزن نقاط معلوم در موقعیت i ام به منظور تخمین مقادیر مجهول x و موقعیت مجهول است، n نیز تعداد نقاط معلوم می‌باشد.

این نوع کریجینگ را کریجینگ خطی می‌نامند. زیرا ترکیب خطی n داده می‌باشد. شرط استفاده از این تخمین‌گر این است که متغیر Z دارای توزیع نرمال باشد. در غیر این صورت یا باید از کریجینگ غیر خطی استفاده کرد و یا این که به نحوی توزیع متغیرها را به نرمال تبدیل کرد (Coope and Istok, 1998:17). همان‌طور که در آمار کلاسیک نیز روش‌های چندمتغیره وجود دارد در زمین آمار نیز می‌توان با استفاده از روش کوکریجینگ که بر اساس همبستگی بین متغیرهای مختلف استوار است به تخمین متغیرها پرداخت. البته شرط استفاده از این روش وجود همبستگی بین دو متغیر بیش از ۶۰٪ می‌باشد (Coope and Istok, 1998: 17).

یافته‌ها و بحث

برای پیش‌بینی سطح آب توسط مدل‌های هوش مصنوعی پیژومترها براساس سطح تراز و عمق آب زیرزمینی، موقعیت هر پیژومتر و ارتفاع از سطح آب‌های آزاد، UTM و هدایت

هیدرولیکی در محل هر پیزومتر با استفاده از روش خوشه‌بندی مرتبه‌ای (HCA) دسته‌بندی شدند. در خوشه‌بندی مرتبه‌ای از روش sWard method و برای اندازه‌گیری تفاوت بین گروه‌ها از روش Euclidean distance استفاده شد. مقدار آستانه در این تحقیق $3/5$ در نظر گرفته شد. یعنی پیزومترهایی با فاصله پیوندی کمتر از $3/5$ در یک گروه قرار می‌گیرند. بر این اساس سه دسته پیزومتر خواهیم داشت (شکل ۳).



شکل (۳) خوشه‌بندی پیزومترها با استفاده خوشه‌بندی مرتبه‌ای

مدل شبکه‌های عصبی مصنوعی

مدل‌سازی با کدنویسی در نرم‌افزار MATLAB 2012b انجام شد. به‌منظور انتخاب الگوریتم مناسب جهت مدل‌سازی، با توجه به خصوصیات هیدروژئولوژیکی آبخوان، پیزومتر شماره ۲ به‌عنوان پیزومتر مرکزی ۸ دشت انتخاب شد. از روش آزمون و خطا تعداد بهینه

1- UTMx= 685350 , UTM_y= 4197350

نودهای لایه میانی ۲ نود به دست آمد بنابراین با توجه به ورودی‌ها و خروجی‌ها، شبکه به دست آمده دارای ساختار $3 \times 2 \times 1$ می‌باشد. نتایج مدل برای الگوریتم‌های مختلف آموزش شبکه، براساس شاخص‌های آماری ارزیابی مدل در جدول (۱) آورده شده است. نتایج نشان می‌دهد که بهترین الگوریتم برای مدل‌سازی شبکه‌های عصبی مصنوعی لونیبرگ-مارکوارت می‌باشد.

جدول (۱) نتایج الگوریتم‌های مختلف برای پیرومتر مرکزی دشت با شبکه عصبی مصنوعی پیشرو

الگوریتم GDx		الگوریتم BR		الگوریتم LM		
R2	RMSE	R2	RMSE	R2	RMSE	
۰/۸۳	۰/۶۹	۰/۹۲	۰/۱۸	۰/۹۶	۰/۲۱	آموزش
۰/۷۷	۰/۷۴	۰/۸۵	۰/۲۳	۰/۸۷	۰/۲۵	آزمایش

با توجه به نتایج شبکه پیشرو با الگوریتم لونیبرگ-مارکوارت (FNN-LM) برای شبیه‌سازی انتخاب شد. در ادامه برای هر دسته از پیرومترها مدل‌سازی انجام شد. با استفاده از روش آزمون و خطا برای دسته‌های سه تایی پیرومترها ۴ نود برای لایه میانی انتخاب شد، همچنین در دسته دوتایی ۳ نود برای لایه میانی با توجه به کم‌ترین مقدار خطای بازده مدل به دست آمد.

اولین دسته سه تایی از پیرومترها شامل پیرومترهای (۱، ۴، ۶) می‌باشد. در این دسته شبکه ۵ ورودی و ۳ خروجی خواهد داشت. پس از ۲۰ دوره آموزشی با خطایی برابر 2.18×10^{-9} Mean square error با کمینه خطا ممکن آموزش پایان یافت. بعد از این مرحله داده‌های مرحله آزمایش به مدل داده شد و نتایج مدل در مرحله آزمایش نیز به دست آمد. دسته سه تایی دیگر از پیرومترها شامل پیرومترهای ۳، ۵ و ۸ می‌باشد. پس از ۳۵ دوره آموزشی با خطای برابر 2.37×10^{-9} Mean square error به کمینه خطای ممکن رسید و آموزش پایان یافت. سپس داده‌های مرحله آزمایش به مدل داده شد. دسته آخر از پیرومترها شامل دو پیرومتر ۲ و ۷ می‌باشد، با توجه به دوتایی بودن این پیرومترها شبکه مورد نظر ۲ خروجی خواهد داشت. پس از ۲۲ دوره آموزشی با خطای برابر 2.12×10^{-9} square error

Mean 9 به کمینه خطای ممکن رسید و آموزش پایان یافت. سپس شبیه‌سازی برای داده‌های آزمایش نیز انجام شد. نتایج مدل شبکه عصبی مصنوعی در جدول (۲) آمده است.


جدول (۲) نتایج مدل شبکه‌های عصبی مصنوعی (ANNs) در مرحله آموزش و تست

شماره پیزومتر								معیار ارزیابی مدل	
۸	۷	۶	۵	۴	۳	۲	۱		
۰/۲۱	۰/۲۳	۰/۱۳	۰/۰۶	۰/۱۱	۰/۱۹	۰/۱۸	۰/۱	RMSE	مرحله
۰/۸۹	۰/۸۵	۰/۹۶	۰/۹۵	۰/۹۵	۰/۹۱	۰/۸۹	۰/۹۲	R _۲	آموزش
۰/۵۴	۰/۳۶	۰/۲۱	۰/۱۴	۰/۱۸	۰/۳۵	۰/۲۳	۰/۲۷	RMSE	مرحله
۰/۷۳	۰/۷۹	۰/۶۷	۰/۸۵	۰/۷۴	۰/۶۲	۰/۸۵	۰/۷۸	R _۲	تست


مدل فازی

در این قسمت از مدل فازی ساگنو برای پیش‌بینی سطح آب زیرزمینی استفاده شده است. برای مدل‌سازی فازی نیز از نرم‌افزار MATLAB 2012b استفاده شد. اولین مرحله در این روش دسته‌بندی داده‌ها و تعیین توابع عضویت است که در این تحقیق از روش کاهشی (Subtractive) برای مدل ساگنو استفاده شد که روشی کارا و مفید در دسته‌بندی داده‌ها و تعداد قوانین در تحقیقات اخیر بوده است (جراح و هالوانی، ۲۰۰۱: ۲۲؛ چپو، ۱۹۹۴: ۱۱). پارامتر اصلی در این روش دسته‌بندی برای تعیین دسته‌ها و قوانین اگر-آنگاه شعاع دسته‌بندی است. مقادیر این پارامتر بین صفر و یک می‌باشد. کاهش این پارامتر باعث افزایش دسته‌ها و قوانین و افزایش آن به سمت یک باعث کاهش دسته‌ها و قوانین خواهد بود (چپو، ۱۹۹۴: ۱۱). بازده مدل فازی بستگی به تعیین شعاع بهینه دسته‌بندی دارد. شکل (۴) نشان می‌دهد که بهینه‌ترین شعاع خوشه‌بندی برای دسته‌های سه تایی پیزومترها ۰/۷ و برای دسته دوتایی ۰/۶ می‌باشد که به ترتیب متوسط کمینه مقدار RMSE را برابر ۰/۱۲ و ۰/۱۸ متر ایجاد می‌کند. بر این اساس برای دسته‌های سه‌تایی از پیزومترها ۱۰ قانون و ۱۰ دسته فازی برای داده‌ها و در دسته دوتایی از پیزومترها ۸ قانون و ۸ دسته فازی برای داده‌ها به دست آمد. توابع عضویت استفاده شده برای مدل‌سازی تابع گوسی بود که به داده‌های دسته‌بندی

شده برازش داده شد. تابع گوسی نشانگر توزیع نرمال داده‌ها است. شکل (۵) نمونه‌ای از توابع عضویت داده‌های ورودی را برای دسته دوتایی پیژومترها نشان می‌دهد.

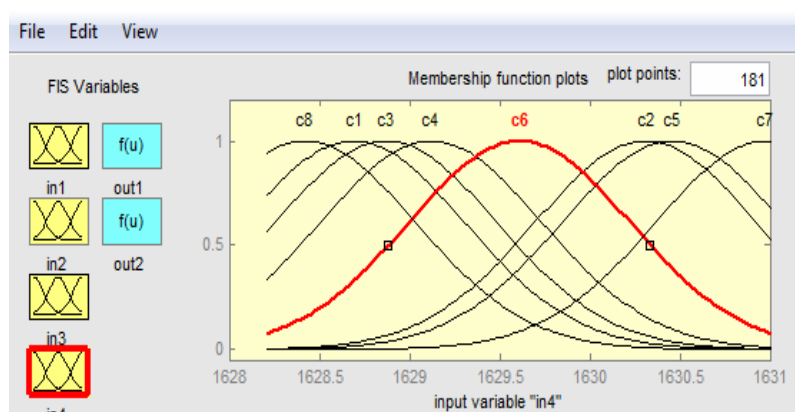


(الف)



(ب)

شکل (۴) شعاع خوشه‌بندی و تعداد قوانین براساس کمینه RMSE (الف) برای دسته سه تایی (ب) برای دسته دوتایی.



شکل (۵) نمونه‌ای از توابع عضویت متغیرها در دسته دوتایی پیرومترها برای ورودی ۴

نتایج مدل فازی ساگنو برای مرحله آموزش و تست در هرکدام از پیرومترها در جدول (۳) آورده شده است. مقایسه نتایج دو مدل نشان می‌دهد که اگرچه در مرحله آموزش نتایج بسیار نزدیک به هم هستند. ولی شبکه‌های عصبی مصنوعی در مرحله تست پیش‌بینی دقیق‌تری داشته است.

جدول (۳) نتایج مدل فازی ساگنو (SFL) در مرحله آموزش و تست

شماره پیرومتر								معیار ارزیابی مدل	
۸	۷	۶	۵	۴	۳	۲	۱		
۰/۱۱	۰/۱	۰/۱۵	۰/۱	۰/۱۱	۰/۱۶	۰/۰۸	۰/۰۹	RMSE	مرحله
۰/۸۶	۰/۹۸	۰/۹۶	۰/۹۴	۰/۹۶	۰/۹۲	۰/۹۷	۰/۹۷	R ^۲	آموزش
۰/۶۴	۰/۳۸	۰/۲۸	۰/۵۵	۰/۶۳	۰/۵۵	۰/۶۱	۰/۴۱	ERMS	مرحله
۰/۶۵	۰/۷۲	۰/۶۸	۰/۶۷	۰/۷۲	۰/۷۹	۰/۷۵	۰/۷۸	R ^۲	تست

پس از حصول نتایج پیش‌بینی زمانی برای سطح تراز آب‌های زیرزمینی با استفاده از مدل شبکه‌های عصبی مصنوعی و مدل فازی ساگنو، مرحله بعدی به‌دست آوردن بهترین مدل ژئواستاتستیکی برای پیش‌بینی مکانی سطح تراز آب‌های زیرزمینی در محدوده مطالعاتی می‌باشد. در این مرحله نتایج مدل شبکه‌های عصبی مصنوعی شامل داده‌های پیش‌بینی

ماهانه سطح آب زیرزمینی برای بازه دو ساله، به‌عنوان ورودی مدل زمین آمار برای پیش‌بینی مکانی سطح آب‌های زیرزمینی در محدوده مطالعاتی به‌کار گرفته شد. در این تحقیق از روش‌های کریجینگ و کوکریجینگ معمولی استفاده گردید. در هر مدل زمین آمار اولین مرحله رسم سیمواریوگرام (که عموماً واریوگرام نیز نامیده می‌شود) می‌باشد. برای رسم واریوگرام ابتدا نیاز به تعیین نوع توزیع داده‌ها داریم. از آزمون کولمو لگروف و اسمیرنوف ۹ برای بررسی آماره‌های (مثل متوسط، واریانس و چولگی و...) داده‌های سطح آب استفاده شد. نتایج نشان داد که داده‌ها از توزیع نرمال و لوگ نرمال تبعیت نمی‌کنند. بنابراین از تبدیل ریشه مربعات ۱۰ برای حذف روند از داده‌ها استفاده شد رسم واریوگرام در چهار جهت اصلی نشان داد که داده‌ها همسانگرد بوده و ناهمسانگردی محسوسی را نشان نمی‌دهند. بنابراین واریوگرام داده‌ها برای حالت همسانگرد رسم شد. سپس مدل‌های تجربی مختلف (کروی، نمائی، خطی و گوسین) بر آن برازش داده شدند تا بهترین مدل برای مدل سازی نهایی به‌دست آید. نتایج نشان داد که بهترین برازش مربوط به مدل کروی می‌باشد.

با توجه به این‌که سطح آب زیرزمینی همبستگی بالایی با توپوگرافی دارد بنابراین از مدل کوکریجینگ نیز برای پیش‌بینی مکانی سطح آب زیرزمینی استفاده شد. این مدل با وجود اینکه از نظر تئوریک توانایی تحلیل چندین متغیر را همزمان دارد ولی در عمل تنها برای دو متغیر می‌تواند جواب مناسبی بدهد (ایساک و استریواستاوا، ۱۹۸۹: ۵۶۱). در این تحقیق علاوه بر مقادیر سطح آب زیرزمینی در هر پیزومتر از توپوگرافی (نقشه DEM) به عنوان متغیر ثانویه استفاده شده است. با توجه به هم واحد بودن متغیرها نیازی به یکسان سازی واحدها نبود. برای انجام این مدل‌سازی با توجه به بررسی اولیه از نظر حذف روند و ناهمسانگردی، از نتایج به‌دست آمده از مرحله مدل‌سازی کریجینگ استفاده شد و تنها به

1- Kolmogrov-Sminov


2- Root squer transformation

بررسی همسانگردی واریوگرام مقادیر توپوگرافی و واریوگرام متقابل اکتفا شد. پس از حذف روند داده‌های توپوگرافی (نقشه DEM) با بررسی واریوگرام در چهار جهت اصلی معلوم شد که واریوگرام متقابل و واریوگرام نقشه ارتفاعی هم حالت ایزوتروپ دارند. در روش کوکریجینگ علاوه بر واریوگرام رسم شده برای هر متغیر بایستی واریوگرام متقابل نیز از روی واریوگرام‌های دو متغیر رسم گردد و از روی این واریوگرام پیش‌بینی مکانی صورت گیرد. روش رسم واریوگرام متقابل در بسیاری از منابع آمده است (حسنی‌پاک، ۱۳۷۷: ۳۱۴). واریوگرام مدل کوکریجینگ و واریوگرام متقابل برازش شده در مدل کوکریجینگ در شکل (۷) نشان داده شده‌اند.


خطای مدل‌های ژئواستاتستیکی (تفاوت مقادیر محاسباتی و مشاهداتی نقاط معلوم) به دست آمد (جدول ۴). لازم به ذکر است که خطای نشان داده شده در این جدول ترکیبی از خطای دو مدل شبکه عصبی مصنوعی و زمین‌آمار می‌باشد.

جدول (۴) نتایج مدل‌های کوکریجینگ عصبی و کوکریجینگ عصبی برای داده‌های ماه دوازدهم و بیست و چهارم پیش‌بینی

تفاوت مقادیر محاسباتی و مشاهداتی (متر)				H(m)	Y(m)	X(m)
مدل کوکریجینگ عصبی		مدل کوکریجینگ عصبی				
ماه دوازدهم	ماه بیست و چهارم	ماه دوازدهم	ماه بیست و چهارم			
-۰/۲۹۹۲	-۰/۲۹۸۱	-۰/۴۰۵	-۰/۳۹۳	۱۶۵۲/۱۴	۴۲۰۲۵۵۰	۶۸۴۰۵۰
۰/۲۴۷	۰/۲۴۶۶	-۰/۳۵۸	-۰/۳۲۱	۱۷۱۹	۴۱۹۷۳۵۰	۶۸۵۳۵۰
-۰/۳۷۲۱	-۰/۳۶۳	-۰/۴۶	-۰/۳۸۵	۱۷۵۲/۷۴	۴۲۰۰۵۷۵	۶۹۱۶۰۰
-۱/۱۹۸۴	-۰/۱۹۵	-۰/۳۹۹	-۰/۳۹۷	۱۶۷۳/۴	۴۲۰۲۰۵۰	۶۸۷۴۵۰
۰/۱۶۳	۰/۱۶۲۴	۰/۵۸۵	۰/۵۴	۱۷۸۰/۲۹	۴۱۹۳۴۰۰	۶۸۷۸۵۰
۰/۲۲۶۱	۰/۲۲۴	۰/۴۸۹۲	۰/۵۲۹	۱۶۷۸/۱۶	۴۱۹۹۳۰۰	۶۸۹۳۵۰
۰/۲۸۰۲	۰/۲۷۹۴	۰/۴۲۷	۰/۴۱۶	۱۶۴۲/۳۱	۴۲۰۴۴۴۸	۶۸۲۴۶۸
-۰/۵۶۲۱	-۰/۵۵۱۲	-۰/۵۸۲۶	-۰/۵۸۲۳	۱۷۷۷	۴۱۹۶۱۳۳	۶۸۰۲۱۱



(الف)

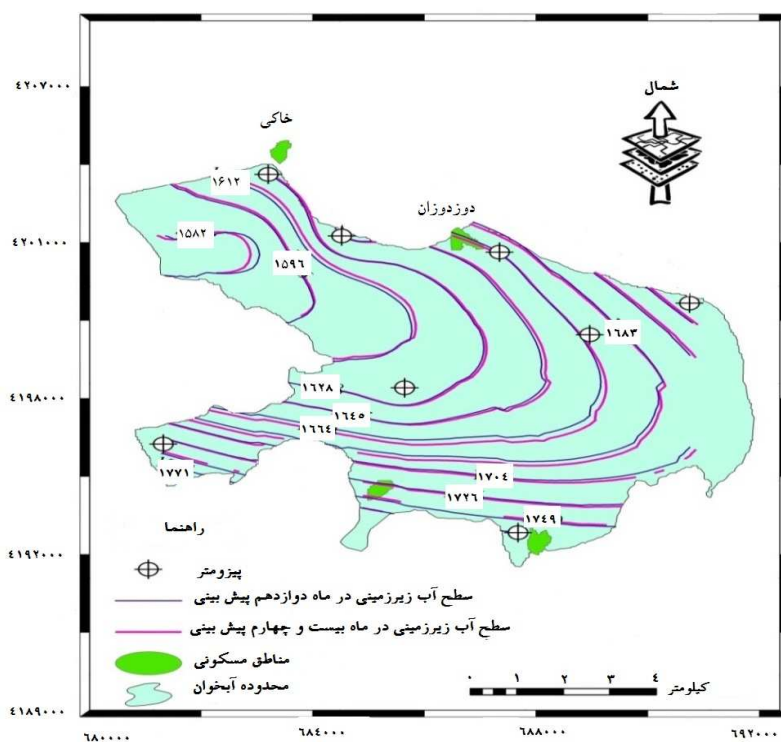


(ب)

شکل (۷) الف) واریوگرام حاصل از برازش مدل کروی در روش کریجینگ (ب) واریوگرام متقابل برازش داده شده در روش کوکریجینگ

براساس نتایج به دست آمده مدل کوکریجینگ نسبت به مدل کریجینگ عملکرد بهتری داشته است. با توجه به تعداد و توزیع غیریکنواخت پیزومترها نتیجه منطقی به نظر می‌رسد و استفاده از داده ثانویه در کوکریجینگ باعث بهبود پیش‌بینی مکانی شده است. شکل (۸)

نتایج نهایی مدل کوکریجینگ برای ماه‌های دوازدهم و بیست و چهارم پیش‌بینی را نشان می‌دهد.



شکل (۸) نتایج مدل کوکریجینگ عصبی برای ماه دوازدهم و ماه بیست و چهارم پیش‌بینی

نتیجه‌گیری

پیش‌بینی زمانی و مکانی تغییرات سطح آب زیرزمینی یکی از مسائل مهم در مطالعات هیدروژئولوژیکی می‌باشد. در این تحقیق از دو مدل فازی و شبکه‌های عصبی مصنوعی برای پیش‌بینی زمانی سطح آب زیرزمینی استفاده شد. با توجه به شاخص‌های آماری اعتبارسنجی مدل نتایج حاصل از هر دو مدل قابل قبول به نظر می‌رسد. نتایج نشان می‌دهد

که مدل شبکه‌های عصبی مصنوعی کارایی بهتری داشته است. ترکیب دو مدل شبکه‌های عصبی مصنوعی و زمین آمار می‌تواند راه‌حل مناسبی برای رفع نواقص هر کدام از مدل‌ها باشد. در این تحقیق از ترکیب این دو مدل استفاده شده است (کوکرینجینگ عصبی) و نتایج قابل قبولی برای پیش‌بینی زمانی و مکانی سطح آب زیرزمینی حاصل شده است. خطای مدل کوکرینجینگ عصبی، ترکیبی از خطای دو مدل شبکه عصبی مصنوعی و کوکرینجینگ می‌باشد، براساس نتایج حاصله با افزایش دوره پیش‌بینی بازده مدل ترکیبی کاهش می‌یابد که حاصل افزایش خطا با افزایش دوره پیش‌بینی در مدل شبکه‌های عصبی مصنوعی می‌باشد و خطای مدل ژئواستاتیسیتیک نامحسوس است. روش ارائه شده در این تحقیق می‌تواند برای مکان‌های فاقد پیژومتر بسیار مفید باشد به طوری که با در دسترس بودن داده‌های تعدادی پیژومتر می‌توان سطح آب را در منطقه وسیعی پیش‌بینی کرد و از صرف زمان و هزینه‌های بالا برای حفر پیژومترهای بیش‌تر صرفه‌جویی کرد. باتوجه به خطی بودن مدل زمین آمار (کوکرینجینگ) و عدم امکان استفاده عملی از بیش از دو پارامتر به‌نظر می‌رسد استفاده از روش‌های هوش مصنوعی در پیش‌بینی مکانی، خطای نهایی مدل را به‌طور چشمگیری کاهش دهد.

منابع

- اصغری مقدم، اصغر؛ نورانی، وحید و عطالله ندیری (۱۳۸۷)، «مدل‌سازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی»، *مجله دانش کشاورزی دانشگاه تبریز*، شماره ۱، سال ۱۳۸۷، صص ۱-۱۵.
- اصغری مقدم، اصغر؛ نورانی، وحید و عطالله ندیری (۱۳۸۸)، «پیش‌بینی زمانی و مکانی سطح آب‌های زیرزمینی در محدوده متروی شهر تبریز با استفاده از مدل کریجینگ عصبی»، *مجله تحقیقات منابع آب ایران*، شماره ۱، سال ۱۳۸۹، صص ۱۴-۲۴.
- فربودنام، نیما؛ قربانی، محمدعلی و محمدتقی اعلمی (۱۳۸۸)، «پیش‌بینی جریان رودخانه با استفاده از برنامه‌ریزی ژنتیک»، *مجله دانش آب و خاک*، شماره ۱، سال ۱۳۸۹، صص ۱۰۷-۱۲۳.
- ندیری، عطالله؛ اصغری مقدم، اصغر؛ عبقری، هیراد و الهام فیجانی (۱۳۹۱b)، «استفاده از مدل‌های هوش مصنوعی مرکب در پیش‌بینی قابلیت انتقال، مطالعه موردی دشت تسوج»، *مجله تحقیقات منابع آب ایران*، شماره ۳، سال ۱۳۹۲، صص ۶۱-۷۴.
- ندیری، عطالله (1386)، «پیش‌بینی سطح آب‌های زیرزمینی توسط مدل ANNs در محدوده متروی شهر تبریز»، پایان‌نامه کارشناسی ارشد، دانشکده علوم طبیعی، دانشگاه تبریز.
- Alvisi, S., Mascellani, G., Franchini, M., Bardossy, A., (2006), "Water level forecasting through Fuzzy logic and artificial neural network approaches", *Hydrology and Earth System Science*, 10, 1-17.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, (2000), "Artificial neural network in hydrology, part I and II", *Journal of Hydrological Engineering*. ASCE, 5, 115-137.
- Ayvaz, M.T., Karahan, H., Aral, M.M., (2007), "Aquifer parameter and zone structure estimation using kernel-based fuzzy c-means clustering and genetic", *Journal of Hydrology*, 343, 240 – 253.
- Chiu, S., (1994), "Fuzzy model identification based on cluster estimation", *Journal of Intelligent and Fuzzy Systems*, 2, 267-278.

- Coope, R.M., Istok, J.D., (1998), "Geostatistics applied to ground water contamination I: Mthodology", *Journal of Enviroment*, 114, 270-286.
- Coulibaly, P., Anctil, F., Bobée, B., (2000), "Daily reservoir inflow forecasting using artificial neural networks with stopped training approach", *Journal of Hydrology*, 230, 244-257.
- Daliakopoulos, N.I., Coulibaly, P., Tsanis, I.k., (2005), "Ground water level forecasting using artificial neural networks", *Journal of Hydrology*, 309, 229-240.
- Desbarats, A.J., Logan, C.E., Hinton, M.J., Sharp, D.R., (2002), "On the kriging of water table elevation using collateral information from a digital elevation model", *Journal of Hydrology*, 255, 25-38.
- Dunlap, L.E., Spinazola, J.M., (1984), "Interpolation water-table altitudes in west-central kanses using kriging techniques", US Geological Survey Water-supply Paper, 2238, 19.
- French, M.N., Krajewski, W.F., Cuykendal, R.R., (1992), "Rainfall forecasting in space and time using a neural network", *Journal of Hydrology*, 137, 1-37.
- Hoeksema, R.J., Clapp, R.B., Thomas, A.L., Hunley, A.E., Farrow, N.D., Dearstone, K.C., (1989), "Cokriging model for estimation of water table elevation", *Journal of Water Resource Research*, 25, 429-438.
- Isaaks, E.H., Srivastava, R.M., (1989), "*Applied Geostatistics*", Oxford University press, 561.
- Jarrah, O.A., Halawani, A., (2001), "Recognition of gestures in Arabic sign language using neuro-fuzzy systems", *Artificial Intelligence*, 133, 117-138.
- Kadkhodaie-Ilkhchi, A., Rezaee, M.R., Rahimpour-Bonab, H. (2009), "Committee neural network for prediction of normalized oil content from well log data: An example from South Pars GasField PersianGulf", *Journal of Petroleum Science and Engineerin*, 65, 23-32.

- Lallahem, S., Mania, J., Hani, A., Najjar, Y., (2005), "On the use of neural networks to evaluate ground water levels in fractured media", *Journal of Hydrology*, 307, 92-111.
- Maier H.R., Dandy G.C., (2000), "Neural network for the prediction and forecasting water resources variables: a review of modeling issues and applications", *Environmental Modeling Software*, 15, 101-124.
- Nikraves, M., Aminzadeh, F., (2003), "Soft Computing and Intelligent Data Analysis in Oil Exploration Part1: Introduction: Fundamentals of Soft Computing", Elsevier, Berkeley, USA, 744.
- Samani, N., Gohari-Moghadam, M., Safavi, A.A., (2007), "A simple neural network model for the determination of aquifer parameters", *Journal of Hydrology*, 340, 1-11.
- Tayfur, G., Nadiri, A.A., Moghaddam, A.A., (2014), "Supervised Intelligent Committee Machine Method for Hydraulic Conductivity Estimation", *Water Resources Management*, 28, 1173-1184.
- Rizzo, D.M., Dougherty, D.E., (1994), "Characterization of aquifer properties using artificial neural network: neural kriging", *Water Resource Research*, 30, 438-497.
- Yu, P.S., Chen, C.J., Chen, S.J., (2000), "[Application of gray and fuzzy method for rainfall forecasting]", *Journal of Hydrological Engineering*, ASCE, 5, 339-345.