



دانشگاه گوارزی و منابع طبیعی

نشریه پژوهش‌های حفاظت آب و خاک

جلد بیستم، شماره چهارم، ۱۳۹۲

<http://jwsc.gau.ac.ir>

توسعه و کاربرد مدل‌های عصبی، فازی، الگوریتم ژنتیک و زمین‌آمار در برآورد توزیع مکانی سطح ایستابی

*حمید زارع‌ابیانه^۱ و مریم بیات‌ورکشی^۲

^۱دانشیار گروه مهندسی آب، دانشگاه بوعلی‌سینا همدان، ایران،

^۲دانشجوی دکتری گروه مهندسی آب، دانشگاه بوعلی‌سینا همدان، ایران

تاریخ دریافت: ۹۰/۹/۱۳؛ تاریخ پذیرش: ۹۱/۸/۸

چکیده

در امر مدیریت پایدار منابع آب تجدیدپذیر در سطح یک آب‌خوار، تخمین سطح آب زیرزمینی از اهمیت زیادی برخوردار است. در این پژوهش از روش‌های هوشمند عصبی در قالب شبکه عصبی پرسپترون چندلایه، تابع پایه شعاعی، عصبی فازی و عصبی ژنتیک برای تخمین مقادیر نقطه‌ای سطح ایستابی در دشت همدان- بهار استفاده شد. به منظور برآورد سطح ایستابی در نقاط بدون اندازه‌گیری، مقادیر برآورد نقطه‌ای هر یک از روش‌های هوشمند عصبی در محیط زمین‌آمار کریجینگ پهنه‌بندی شد. در مجموع دقت روش‌های مورد استفاده بر حسب خطای کم‌تر مقادیر سطح ایستابی برآوردی به ترتیب به روش‌های عصبی ژنتیک، پرسپترون چندلایه، تابع پایه شعاعی و عصبی فازی تعلق داشت. به طوری که مجذور میانگین مربعات خطای روش عصبی ژنتیک در برآورد تغییرات مکانی سطح ایستابی برابر ۰/۴۳۱ متر با ضریب تبیین ۰/۹۹۶ بود. بیش‌ترین مقدار خطا به برآوردهای مدل شبکه عصبی فازی با خطای ۱/۲۷ متر و مدل شبکه تابع پایه شعاعی با خطای ۰/۸۱ متر تعلق داشت. هم‌چنین مقایسه تغییرات مکانی سطح ایستابی برآوردی از روش عصبی ژنتیک در محیط زمین‌آمار کریجینگ با مقادیر مشاهده‌ای نشان‌دهنده کاهش پراکنش نقاط و باریک‌تر بودن محدوده اطمینان ۹۰ درصد بود. از این رو با استفاده از طول و عرض جغرافیایی به‌عنوان بردار اطلاعات ورودی، می‌توان به دقت اطلاعات بالا در برآورد تغییرات مکانی و پهنه‌بندی مقادیر سطح ایستابی اطمینان به‌دست آورد.

واژه‌های کلیدی: سطح ایستابی، روش هوشمند عصبی، زمین‌آمار، دشت همدان- بهار

*مسئول مکاتبه: zareabyaneh@gmail.com

مقدمه

در مناطق خشک و نیمه‌خشک، آب‌های سطحی جواب‌گوی نیاز بخش‌های مختلف مصرف نبوده و این کمبود معمولاً از طریق آب‌های زیرزمینی جبران می‌گردد. گاهی تامین این منابع، زیان‌های زیست‌محیطی و کاهش سطح دسترسی به منابع آب زیرزمینی را به دنبال دارد. برای مثال، برداشت بی‌رویه از منابع آب زیرزمینی، باعث پدید آمدن فروچاله‌ها و یا تخریب برخی از زیست‌بوم‌های مناطق خشک و نیمه‌خشک می‌شود (رهنما و شکیبایی، ۲۰۰۵). برای حفظ پایداری در توسعه منابع تجدیدپذیر آب زیرزمینی یک منطقه، کمی نمودن تغییرات مکانی و زمانی این منابع از اهمیت زیادی برخوردار است. برآورد دقیق و قابل اطمینان از سطح ایستابی در آب‌خوان‌های مورد بهره‌برداری مهم بوده و در صورت اطلاع از نوسانات سطح ایستابی به‌آسانی و با هزینه پایین می‌توان به تغییرات ذخیره آب زیرزمینی دست یافت (گنجی‌خرم‌دل و همکاران، ۲۰۰۸). برآورد توزیع مکانی سطح ایستابی، در طیف گسترده‌ای از مسایل، مانند سدهای زیرزمینی، طرح‌های محیط زیست، طرح‌های آب‌خیزداری و بسیاری از بحث‌های منابع آب کاربرد دارد. تغییرات زیاد سطح ایستابی در نقاط مختلف سفره، کمبود چاه‌های مشاهداتی و پیچیدگی ارتباط سطح ایستابی با دیگر پارامترها، اهمیت توسعه روش‌های کارآمد را در برآورد توزیع مکانی سطح ایستابی دو چندان می‌نماید. روش‌های تخمین سطح ایستابی را می‌توان با دو رویکرد دنبال نمود. در رویکرد اول، هدف ایجاد مدل‌های ریاضی، تجربی و فیزیکی براساس مفاهیم انتقال جریان و حل معادلات هیدرولیک جریان در محیط‌های متخلخل است. نایاک و همکاران (۲۰۰۶) نیازمندی این روش‌ها به داده‌های متنوع، نداشتن تشابه نتایج به دست آمده از مناطق مختلف در شرایط مشابه و پیچیده و غیرخطی بودن رابطه‌های بین متغیرهای مؤثر بر سطح آب‌های زیرزمینی را سبب ناکارآمدی مدل‌های بالا دانسته‌اند. در رویکرد دوم با ابداع روش‌های هوشمند که ابزاری توانمند، انعطاف‌پذیر و مستقل از مدل‌های دینامیکی هستند، تغییرات سطح و حجم سفره قابل بررسی است. روش‌های هوشمند در پیش‌بینی سری‌های زمانی غیرماندگار و حل مسایل پیچیده مهندسی، ابزاری توانمند و مؤثر هستند (فقیه، ۲۰۱۰؛ چانگ و چانگ، ۲۰۰۶). این روش‌ها برای پیش‌بینی مکانی پدیده‌های هیدرولوژیکی به‌صورت ترکیبی با روش‌های زمین‌آماري نیز به‌کار گرفته شده‌اند. ریزو و دوگرتی (۱۹۹۴) با ترکیب شبکه‌های عصبی مصنوعی (ANN)^۱ در روش زمین‌آماري کریجینگ با عنوان عصبی- کریجینگ، در تخمین مشخصه‌های هیدرودینامیک آب‌خوانی واقع در

1- Artificial Neural Network

برلینگتون آمریکا استفاده کردند و نشان دادند روش توسعه یافته قادر به برآورد مناسب و دقیقی از مشخصات هیدرودینامیک در گستره مکانی آبخوان است. تسلطی (۲۰۰۳) برای شبیه سازی سطح آب زیرزمینی دشت چمچال کرمانشاه از یک مدل شبکه عصبی پرسپترون چندلایه (MLP)^۱ استفاده نمود. نتایج وی بیانگر شبیه سازی قابل قبول سطح ایستابی چاهک های مشاهده ای بود. پهنه بندی بارش در حوضه آبریز رودخانه مارون با روش های آمار کلاسیک و زمین آمار توسط میثاقی و محمدی (۲۰۰۶) انجام و با نتایج شبکه عصبی مصنوعی مقایسه شد. یافته های آن ها نشان داد دقت روش های زمین آمار در تخمین اطلاعات بارش برای نقاط بدون اندازه گیری بیش تر است. ولی به دلیل قابلیت و توانایی شبکه های عصبی مصنوعی در تحلیل روابط رگرسیونی، استفاده از روش های عصبی توصیه شد. گارسیا و شیجیدی (۲۰۰۶)، برای تخمین پارامترهای ضریب هدایت هیدرولیکی (K_s)^۲ و ضریب قابلیت انتقال (TD)^۳ سفره از مدل شبکه عصبی مصنوعی استفاده کردند. مطالعه آن ها نشان داد آموزش خوب شبکه های عصبی امری مهم در دستیابی به جواب های مطلوب است. در پژوهشی دیگر سه روش شبکه تطبیقی عصبی فازی (ANFIS)^۴، شبکه عصبی مصنوعی و مدل زمین آماری کریجینگ عمومی (OK)^۵ در تخمین ضریب قابلیت انتقال آبخوان دشت قزوین مورد ارزیابی قرار گرفت (خلقی و حسینی، ۲۰۰۶). نتایج به دست آمده بیانگر عملکرد مناسب شبکه تطبیقی عصبی - فازی در مقایسه با دو روش شبکه عصبی مصنوعی و زمین آمار کریجینگ بود. فروغی و همکاران (۲۰۰۶) یک مدل شبکه عصبی را برای پیش بینی نوسانات سطح ایستابی با استفاده از اطلاعات بارش، تبخیر، اختلاف دبی در طول رودخانه و میزان برداشت ماهانه از منابع آب زیرزمینی برای حوضه آبریز مارون در استان خوزستان توسعه دادند. اصغری مقدم و همکاران (۲۰۱۰) برای پیش بینی مکانی غلظت فلوراید از دو روش شبکه عصبی مصنوعی و زمین آمار در دشت های بازرگان و پلدشت در شمال غرب ایران استفاده کردند. نتایج بیانگر دقت بهتر برآوردهای شبکه عصبی مصنوعی در مقایسه با تخمین های زمین آمار کریجینگ و کوکریجینگ بود. توانمندی شبکه تطبیقی عصبی - فازی در برآورد مکانی سطح ایستابی نسبت به روش های شبکه عصبی مصنوعی و زمین آمار در آبخوان دشت قزوین توسط دهقانی و همکاران (۲۰۰۹) بررسی گردید. در این مطالعه با در نظر گرفتن مختصات هندسی

- 1- Multy Layer Perseptron
- 2- Hydraulic Conductivity
- 3- Transmissivite
- 4- Adaptive Neuro Fuzzy Inference System
- 5- Original Kriging

چاه‌ها به‌عنوان پارامترهای ورودی مشخص گردید که روش شبکه عصبی - فازی با توجه به ضریب همبستگی ۹۸ درصد و میانگین مربعات خطای کم‌تر، از دقت بالاتری برای تخمین تراز سطح آب زیرزمینی در نقاط مجهول آب‌خوان نسبت به روش‌های زمین‌آمار و شبکه‌های عصبی برخوردار بود. در پژوهش انجام شده به‌منظور پیش‌بینی سطح ایستابی آب‌خوان دشت بیرجند توسط محتشم و همکاران (۲۰۱۰) از روش شبکه عصبی مصنوعی استفاده شد. نتایج نشان داد شبکه عصبی آموزش یافته براساس اطلاعات ۱۶ پیزومتر، قادر به تخمین سطح آب زیرزمینی با دقت قابل قبول تا ۱۲ ماه بعد است. در پژوهشی دیگر توسط نیک‌منش و رخشنده‌رو (۲۰۱۱) توانایی شبکه‌های عصبی گوناگونی در محدوده سعادت‌شهر استان فارس مورد ارزیابی قرار گرفت. نتایج آن‌ها نشان داد شبکه عصبی مصنوعی پیش‌رو با الگوریتم لونیبرگ مارکوات در یک بازه زمانی ۲ ساله دارای متوسط خطایی معادل ۲/۰۴ و ۲/۲۷ متر برای مراحل آزمایش و آزمون بود.

مطالعات انجام گرفته در ایران نشان می‌دهد به‌رغم اهمیت پیش‌بینی تغییرات مکانی سفره آب زیرزمینی و قابلیت مدل‌های هوشمند عصبی، مطالعات محدودی انجام گرفته است (ایزدی و همکاران، ۲۰۰۸). از طرفی استفاده از حداقل پارامترهای ورودی زودیافت از جمله مختصات جغرافیایی کم‌تر مورد توجه بوده است. استفاده از طول و عرض جغرافیایی به‌عنوان دو متغیر مستقل از سوی طبری و همکاران (۲۰۱۰) در برآورد آب معادل برف، ژنگ و همکاران (۲۰۰۹) برای برآورد رطوبت و شوری در حوضه آبریز تاکلاماکان در شمال‌غربی چین و دهقانی و همکاران (۲۰۰۹) برای میان‌یابی سطح ایستابی دشت قزوین گزارش شده است. بنابراین با توجه به ضرورت‌های بیان شده، هدف این پژوهش ایجاد ارتباط بین متغیرهای وابسته مؤثر در نوسانات سطح ایستابی تحت شرایط میدانی و یافتن مدلی هوشمند با دقت مناسب به‌منظور پیش‌بینی رفتار مکانی و کمی کردن ارتباط نوسانات سطح ایستابی با عوامل جغرافیایی دشت همدان - بهار است.

مواد و روش‌ها

موقعیت منطقه مورد مطالعه: حوضه آبریز همدان - بهار با وسعت ۲۴۷۵ کیلومترمربع متشکل از ۸۸۰ کیلومترمربع دشت و ۵۲۰ کیلومترمربع آب‌خوان است. این حوضه در حد فاصل دو شهر همدان و بهار در مختصات طول جغرافیایی ۴۸ درجه و ۳۲ دقیقه شرقی، عرض جغرافیایی ۳۴ درجه و ۵۲ دقیقه

شمالی و ارتفاع ۱۷۳۰ متری از سطح دریا قرار دارد. حوضه مورد مطالعه بر حسب اهمیت موضوع یکی از مناطق بحرانی از نظر منابع آب زیرزمینی است که تقریباً در قسمت مرکزی استان همدان واقع است (روحانی و همکاران، ۲۰۰۷). دشت همدان- بهار دارای آب و هوای نیمه خشک سرد با میانگین دمای بیشینه و کمینه ۴۰ و ۳۴- درجه سانتی گراد، میانگین بارندگی بلندمدت سالانه ۳۱۲/۳ میلی متر و متوسط تعداد روزهای یخبندان ۱۴۲ روز می باشد (قاسمی و همکاران، ۲۰۰۷). کشاورزان این منطقه، به دلیل ارزش افزوده اقتصادی، تمایل شدیدی به کاشت سیب زمینی و یونجه دارند که در گروه محصولات با نیاز آبی بالا می باشند که در راستای بهره برداری بیش از حد از منابع آب زیرزمینی است. ضمن آن که بخش قابل توجهی از آب شرب شهر همدان نیز از این آبخوان تامین می گردد. شماتیک کلی محدوده مورد مطالعه در پهنه کشور و پراکنش چاه های انتخابی در شکل ۱ نمایش داده شده است.



شکل ۱- موقعیت محدوده مورد مطالعه و چاه های اندازه گیری در آبخوان دشت همدان- بهار.

وضعیت آب‌خوان نام برده به واسطه ارتباط هیدرولوژیکی آن در شمال‌شرق با آب‌خوان دشت کبودرآهنگ و دشت قهاوند، ریزش منابع آلاینده شهری و صنعتی شهرهای همدان، میانه، جوققان و شهرک‌های حاشیه‌ای آن به نسبت پیچیده است. پتانسیل فراوان آب‌خوان دشت همدان- بهار در تامین آب شرب و کشاورزی منطقه و استعداد فراوان اراضی کشاورزی دشت موجب شده است که وضعیت کمی و کیفی آن دست‌خوش تغییرات شدیدی باشد. به طوری که در بازه زمانی ۸۱-۱۳۶۲ سطح ایستابی آب‌خوان به میزان ۱۶/۴۵ افت داشته است (رحمانی و سدهی، ۲۰۰۴). از آنجا که توسعه مدل‌هایی با حداقل پارامترهای قابل دسترس مورد تاکید پژوهشگران در عرصه‌های مختلف است (کومار و همکاران، ۲۰۰۸)، بنابراین در این مطالعه سعی شد تا با به‌کارگیری مدل‌های نوین هوشمند و وارد کردن اطلاعات طول و عرض جغرافیایی نقاط برداشت (چاه‌ها)، به‌عنوان ورودی مدل‌ها، سطح ایستابی برآورد گردد. متغیرهای طول و عرض جغرافیایی به نوعی موقعیت جغرافیایی و مکانی چاه‌ها و به نوعی تغییرپذیری مکانی نقاط برداشت در آب‌خوان را نشان می‌دهند (دهقانی و همکاران، ۲۰۰۹). همچنین اطلاعات بالا به‌عنوان اطلاعات زودیافت و قابل دسترس می‌باشند. از طرفی باید توجه داشت که تعدد متغیرهای ورودی نیز می‌تواند سبب پیچیدگی ساختار شبکه و ناپایداری آن گردد و در بعضی موارد همبستگی بالای بین متغیرها هم به‌منزله استفاده از اطلاعات تکراری است (نوری و همکاران، ۲۰۰۹). به همین دلیل سعی شد تا با حداقل اطلاعات ورودی، به اطلاعات دقیقی از سطح ایستابی آب‌خوان دست یافت.

در این مطالعه از آمار و اطلاعات سطح ایستابی ۵۸ حلقه چاه عمیق و نیمه‌عمیق، به‌عنوان نقاط شاهد برای کنترل دقت اطلاعات پیش‌بینی استفاده شد. پایگاه داده‌ای، شامل مختصات طول و عرض جغرافیایی هر چاه در محیط Excel به‌صورت ستونی تنظیم و به‌عنوان داده‌های ورودی برای تمامی مدل‌ها تعریف گردید. همچنین میانگین حسابی داده‌های سطح ایستابی هر چاه مشاهداتی از ابتدای اندازه‌گیری تا سال ۱۳۸۸ به‌عنوان داده‌های خروجی شبکه در نظر گرفته شد. به این ترتیب برای هر چاه یک عدد به‌عنوان مقدار سطح ایستابی و دو عدد به‌عنوان طول و عرض جغرافیایی منظور شد. مشخصات جغرافیایی چاه‌های نمونه‌برداری در جدول ۱ ارائه شده است.

حمید زارع‌ایبانه و مریم بیات‌ورکشی

جدول ۱- موقعیت جغرافیایی محل‌های نمونه‌برداری.

موقعیت جغرافیایی (UTM)		شماره	موقعیت جغرافیایی (UTM)		شماره
عرض	طول		عرض	طول	
۳۸۶۷۱۴۰	۲۷۱۲۰۳	۳۰	۳۸۶۸۵۵۰	۲۷۲۳۵۵	۱
۳۸۶۴۶۸۰	۲۶۹۹۷۰	۳۱	۳۸۶۸۳۷۰	۲۷۲۴۵۹	۲
۳۸۶۶۹۳۰	۲۷۰۸۳۶	۳۲	۳۸۶۸۱۷۰	۲۷۲۵۳۳	۳
۳۸۶۶۰۳۰	۲۷۰۵۵۶	۳۳	۳۸۶۷۹۶۰	۲۷۲۶۱۴	۴
۳۸۶۷۵۶۰	۲۷۰۶۹۲	۳۴	۳۸۶۷۸۶۰	۲۷۲۴۶۶	۵
۳۸۶۷۴۳۰	۲۷۰۵۰۷	۳۵	۳۸۶۷۷۹۰	۲۷۲۲۶۷	۶
۳۸۶۶۵۳۰	۲۶۹۶۸۹	۳۶	۳۸۶۷۷۰۰	۲۷۲۰۶۷	۷
۳۸۶۶۴۹۰	۲۶۹۳۹۲	۳۷	۳۸۶۷۶۴۰	۲۷۱۷۱۳	۸
۳۸۶۷۰۰۰	۲۶۹۴۰۸	۳۸	۳۸۶۷۸۸۰	۲۷۱۶۱۷	۹
۳۸۶۴۵۲۰	۲۷۴۰۴۶	۳۹	۳۸۶۸۰۳۰	۲۷۱۵۵۸	۱۰
۳۸۶۴۸۴۰	۲۷۳۹۷۳	۴۰	۳۸۶۸۲۲۰	۲۷۱۶۲۴	۱۱
۳۸۶۵۱۱۰	۲۷۳۳۵۶	۴۱	۳۸۶۸۳۴۰	۲۷۱۷۰۵	۱۲
۳۸۶۵۲۷۰	۲۷۳۳۳۱	۴۲	۳۸۶۸۴۱۰	۲۷۱۹۴۲	۱۳
۳۸۶۵۴۷۰	۲۷۳۴۳۶	۴۳	۳۸۶۸۴۸۰	۲۷۲۱۵۶	۱۴
۳۸۶۵۷۰۰	۲۷۳۵۴۰	۴۴	۳۸۶۸۲۱۳	۲۷۲۱۴۷	۱۵
۳۸۶۵۹۳۰	۲۷۳۶۲۸	۴۵	۳۸۶۵۶۰۰	۲۷۱۲۱۰	۱۶
۳۸۶۴۸۸۰	۲۷۳۶۲۸	۴۶	۳۸۶۵۵۵۷۰	۲۷۱۹۱۹	۱۷
۳۸۶۴۵۰۹	۲۷۴۶۳۸	۴۷	۳۸۶۶۲۰۰	۲۷۱۲۹۹	۱۸
۳۸۶۴۱۴۰	۲۷۱۱۴۷	۴۸	۳۸۶۶۶۶۰	۲۷۱۴۹۸	۱۹
۳۸۶۴۶۷۰	۲۷۱۴۵۱	۴۹	۳۸۶۵۶۳۰	۲۷۰۶۴۹	۲۰
۳۸۶۴۲۳۰	۲۷۱۴۳۴	۵۰	۳۸۶۵۷۶۰	۲۷۰۲۵۰	۲۱
۳۸۶۳۳۷۰	۲۷۱۳۰۳	۵۱	۳۸۶۵۳۶۰	۲۷۰۳۳۱	۲۲
۳۸۶۲۸۶۰	۲۷۱۳۲۱	۵۲	۳۸۶۵۴۹۰	۲۶۹۹۰۳	۲۳
۳۸۶۲۲۶۰	۲۷۰۵۲۲	۵۳	۳۸۶۶۳۲۰	۲۷۰۷۸۲	۲۴
۳۸۶۳۳۹۰	۲۷۰۶۸۷	۵۴	۳۸۶۶۵۳۰	۲۷۰۳۹۰	۲۵
۳۸۶۳۱۵۰	۲۷۰۶۶۱	۵۵	۳۸۶۷۰۶۰	۲۷۰۲۰۶	۲۶
۳۸۶۲۱۵۰	۲۷۱۰۸۷	۵۶	۳۸۶۶۷۴۰	۲۶۹۸۲۹	۲۷
۳۸۶۳۱۴۰	۲۷۰۹۷۴	۵۷	۳۸۶۶۲۵۰	۲۶۹۹۹۹	۲۸
۳۸۶۳۴۸۰	۲۷۰۸۵۲	۵۸	۳۸۶۷۰۷۰	۲۷۱۶۶۸	۲۹

روش‌های محاسباتی: مقادیر سطح ایستابی از روش‌های شبکه عصبی پرسپترون چندلایه (MLP)، شبکه تابع پایه شعاعی (RBF)^۱ و دو روش ترکیبی سیستم استنتاج تطبیقی عصبی فازی (CANFIS)^۲ و الگوریتم عصبی ژنتیک (ANNGA)^۳ به‌عنوان روش‌های هوشمند، برآورد و با مقادیر واقعی مورد آزمون قرار گرفت. در نهایت همبستگی مکانی مقادیر سطح ایستابی برآورد شده از همه روش‌ها به‌صورت منطقه‌ای و براساس معیارهای خطاسنجی و ضریب تعیین مورد ارزیابی و در محیط کریجینگ پهنه‌بندی شد.

شبکه عصبی مصنوعی: شبکه‌های عصبی مصنوعی با الهام از سیستم مغز انسان و براساس مدل ریاضی سلول عصبی^۴ عمل می‌نمایند. شبکه‌های عصبی متشکل از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه میانی با تعدادی نرون در هر یک از لایه‌ها هستند (فقیه، ۲۰۱۰؛ یآوری و مهدوی، ۲۰۰۶). منطق شبکه‌های عصبی به‌کارگیری تعدادی داده طی فرآیند آموزش شبکه و تغییر پیاپی مقدار وزن‌ها، به‌منظور محاسبه خروجی‌هایی با کم‌ترین مقدار خطا می‌باشد (بیات‌ورکشی و همکاران، ۲۰۱۰).

شبکه عصبی مورد استفاده در این پژوهش از نوع پرسپترون سه‌لایه شامل یک لایه ورودی، یک لایه میانی و یک لایه خروجی است. این نوع شبکه، پس از دریافت ورودی مسئله و پردازش آن در لایه میانی، خروجی مسئله را نتیجه می‌دهد. در هر بار اجرا، داده‌های مشاهده‌ای با مقدار برآوردی مقایسه (رابطه ۱) و در صورت دست نیافتن به جواب مطلوب، وزن‌های شبکه به‌گونه‌ای تنظیم می‌شوند که پاسخ واقعی در گام زمانی بعدی به پاسخ مطلوب، نزدیک شود.

$$j_i(n) = t_i(n) - a_i(n) \quad (1)$$

که در آن، $j_i(n)$: خطای لحظه‌ای شبکه، t_i : خروجی عنصر i ام شبکه در n امین تکرار، a : خروجی واقعی شبکه در هر تکرار است.


تصحیح وزن‌ها با استفاده از تئوری کاهش شیب^۵ از رابطه ۲ انجام می‌شود که با برآورد خطای خروجی و انتشار آن به عقب (به داخل سیستم)، وزن انتخابی در مدل اصلاح می‌گردد (عبدی و همکاران، ۱۹۹۶؛ رضایی و همکاران، ۲۰۰۷):

- 1- Radial Basis Function
- 2- Co-Active Neuro-Fuzzy Inference System
- 3- Adaptive Neural Network based Genetic Algorithm
- 4- Perceptron
- 5- Gradient

$$W_{ij}(n+1) = w_{ij}(n) + \eta \delta(n) x_i(n) \quad (2)$$

که در آن، $W_{ij}(n+1)$: وزن اتصال عنصر i به عنصر j در $n+1$ امین تکرار، $w_{ij}(n)$: مقدار این وزن در n امین تکرار است، $\delta_i(n)$: خطای موضعی که به طور مستقیم از $j_i(n)$ در n امین تکرار محاسبه شده است و η : اندازه قدم محاسباتی^۱ است.

شکل ۲ تصویر ساده‌ای از ساختار شبکه عصبی مصنوعی پرسپترون استفاده شده در این پژوهش را نشان می‌دهد.

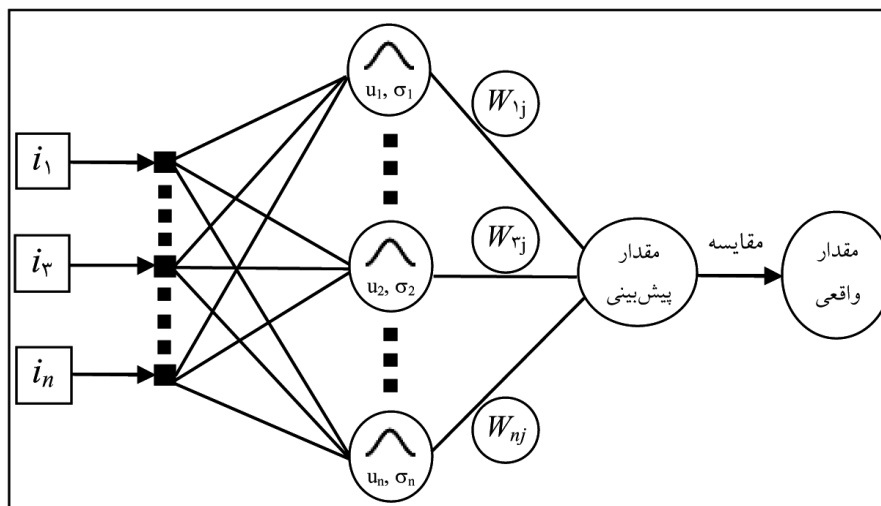


شکل ۲- ساختار شبکه‌های عصبی پرسپترون.

در ساختار شبکه عصبی طرح شده در این پژوهش، از روش پس‌انتشار خطا با تابع آموزشی لونیبرگ مارکوات^۲ به‌عنوان روشی سیستماتیک در آموزش شبکه‌های عصبی چندلایه استفاده شد. هدف از آموزش شبکه، حداقل نمودن خطای بین مقادیر محاسباتی و مشاهداتی، از طریق تنظیم مقادیر وزن‌ها می‌باشد (رحیمی‌خوب و همکاران، ۲۰۰۹). الگوریتم لونیبرگ مارکوات تغییر یافته الگوریتم کلاسیک نیوتن است که به‌علت سرعت بالای آن کاربرد زیادی دارد (نیک‌منش و رخشنده‌رو، ۲۰۱۱). شبکه تابع پایه شعاعی: یکی دیگر از مدل‌های مورد استفاده در این پژوهش شبکه تابع پایه شعاعی (RBF) است که از نوع شبکه‌های پیش‌رو بوده و بر خلاف شبکه‌های عصبی به‌طور ثابت دارای ۳ لایه می‌باشد. در شبکه RBF نیز مشابه شبکه MLP، اطلاعات ورودی پس از پردازش در لایه میانی به مقدار خروجی در پایان مدل‌سازی منتهی می‌گردد. در شکل ۳ ساختمان شماتیک یک شبکه RBF آورده شده است.

1- Step Size

2- Levenberg Marquette



شکل ۳- ساختار مدل شبکه عصبی RBF

مطابق شکل ۳، لایه ورودی محل تزریق اطلاعات، لایه میانی یا طبقه RBF معادل تابع محرک در شبکه عصبی و لایه خروجی ترکیبی خطی از تمامی خروجی‌های طبقه RBF می‌باشد. تابع محرک در بیش‌تر موارد از نوع گوسین غیرخطی شعاعی است که با دو مشخصه مرکز گوسی (c_i) و واریانس یا میزان فشردگی گوسی (σ) شناسایی می‌گردد (محمدی، ۲۰۰۶). این دو مشخصه به ترتیب خروجی نرون‌های لایه میانی و لایه خروجی را در قالب رابطه ۳، محاسبه می‌نمایند.

$$\hat{Y}_i = \sum_{i=1}^n W_i \exp\left(-\frac{1}{\sigma_i} u_i\right) \quad (3)$$

که در آن، Y_i : خروجی شبکه i ام، W_{ij} : اتصال سیناپسی میان خروجی گره RBF j ام به‌ازای بردار ورودی X_j و u_i : فاصله بردار ورودی $X_j = [x_1 \ x_2 \ \dots \ x_p]$ از بردار مرکز $c_i = [c_{i1} \ c_{i2} \ \dots \ c_{ip}]$ با ماتریس نرم \sum_i بوده و به‌صورت رابطه زیر تعریف می‌شود.

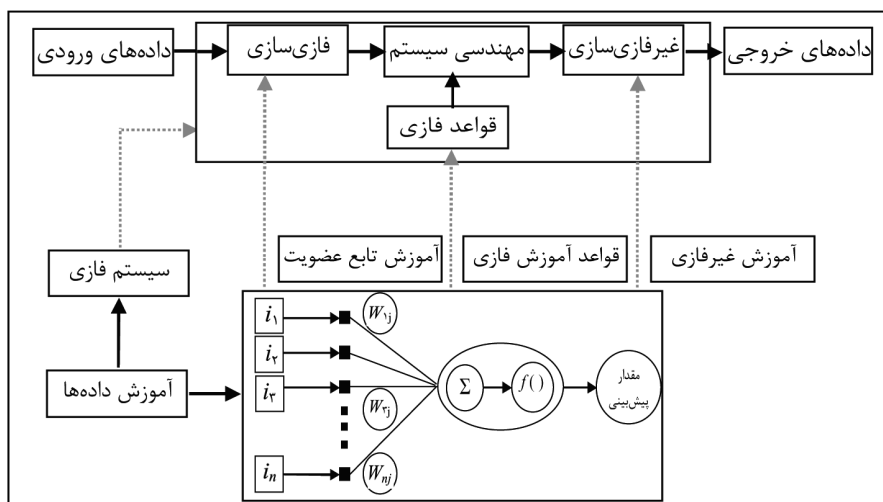
$$u_i = \|X_j - C_i\|_{\sum_i} = \sqrt{\sum_{j=1}^p \left(\frac{x_j - c_{ij}}{\sigma_{ij}}\right)^2} = \sqrt{\left(\frac{x_1 - c_{i1}}{\sigma_{i1}}\right)^2 + \dots + \left(\frac{x_p - c_{ip}}{\sigma_{ip}}\right)^2} \quad (4)$$

ماتریس نرم با مقادیر ثابت $[c_{i1} c_{i2} \dots c_{ip}]$ به‌عنوان پارامتر لایه مخفی i امین نرون RBF می‌باشد که در آن ثابت‌ها قطرهای ماتریس نرم می‌باشند. برای یافتن پاسخ‌های مطلوب لازم است تا شبکه RBF نیز مشابه شبکه MLP به هدف یافتن مقادیر مناسب برای مرکز گوسی و تعیین وزن‌های لایه آخر آموزش یابد. برای آموزش RBF از روش‌های ترکیبی بدون ناظر و با ناظر استفاده شد. بخش بدون ناظر برای تنظیم پارامترهای RBF و بخش دارای ناظر برای تنظیم وزن‌های طبقه RBF بود. باید توجه داشت که تعداد گره‌های لایه RBF نیز مشابه شبکه MLP به‌صورت آزمون و خطا انتخاب و پیشنهاد می‌گردد.

روش ترکیبی عصبی فازی: با توجه به فرض موفقیت روش شبکه عصبی مصنوعی در مدل‌سازی و برآورد فرآیندهای پیچیده غیرخطی و عملکرد مناسب منطق فازی در حل مسایل مختلف مهندسی، در اینجا این فرضیه مطرح شد که منطق فازی تا چه حد در بهینه‌یابی و انتخاب پارامترهای متغیر شبکه عصبی که به روش آزمون و خطا تعیین می‌شود، موفق است؟ برای پاسخ به این فرضیه مدل سطح ایستایی براساس روش تلفیقی عصبی فازی تدوین گردید. در ساختار عصبی فازی ترکیبی از شبکه عصبی با منطق فازی (CANFIS) به‌صورت ساختار شبکه‌ای پیش‌رونده استفاده شد. مدل CANFIS از ویژگی‌های شبکه عصبی (ANN) به‌همراه سیستم استنتاج فازی (FIS)^۱ در قالب یک محیط عصبی فازی بهره می‌گیرد (آیتک، ۲۰۰۸). در منطق فازی روند سیستماتیک برای طراحی یک کنترل‌کننده فازی وجود ندارد در حالی که شبکه عصبی با توجه به ویژگی آموزش از محیط، توانایی تطبیق با شرایط جدید را دارد. سیستم فازی، سیستمی منطبق بر قواعد منطقی شرط-نتیجه است و نقطه شروع ساخت آن به‌دست آوردن مجموعه‌ای از قواعد بالا تحت عنوان اگر-آن‌گاه^۲ فازی با استفاده از دانش فرد خبره یا دانش حوزه موردنظر است (زاده، ۱۹۶۵). در مدل‌سازی CANFIS، کاربر قادر است تا مشخصات شبکه عصبی مصنوعی و مدل فازی را بر خلاف ساختار ANFIS به تفکیک انتخاب و به ساختار بهینه آن به روش آزمون و خطا دست یابد. برای آموزش شبکه ANFIS ابتدا تمامی داده‌های ورودی به بازه‌های فازی تقسیم و وزن نسبی قوانین براساس مقادیر ورودی به هر گره به‌دست آمد (زارع‌ایبانه و همکاران، ۲۰۱۱). تکرار مراحل بالا تا به‌دست آوردن حداقل خطا و نبود بهبودی آن در تکرارهای بعدی، ادامه می‌یابد. شکل ۴ ساختار ترکیب شده شبکه‌های عصبی فازی توسعه‌یافته در این پژوهش را نشان می‌دهد.

1- Fuzzy Inference System

2- If-Then




شکل ۴- ساختار شبکه عصبی فازی مورد استفاده در مطالعه.

در ساختار CANFIS، بخش عصبی با ساختار MLP، مشخصه‌های مربوط به توابع عضویت بخش فازی را تعیین می‌نمایند. ساختار فازی به کار گرفته شده هم مشابه ساختار عصبی، دارای ۳ بخش اصلی فازی‌ساز ورودی^۱، موتور استنتاج^۲ و غیرفازی‌ساز خروجی^۳ می‌باشد. فازی‌ساز ورودی مقادیر قطعی متغیرهای ورودی را به مجموعه‌های فازی تبدیل می‌نماید و غیرفازی‌ساز خروجی مقادیر به دست آمده از موتور استنتاج فازی را به مقادیر قطعی تبدیل می‌نماید. سیستم کنترل فازی مورد استفاده در این پژوهش از نوع گوسی^۴ بود که توانایی کاهش اغتشاشات احتمالی در داده‌های ورودی را دارد (منعم و کیاپاشا، ۲۰۰۹). موتور استنتاج فازی از نوع سوگنو^۵ و یکی از موتورهای پرکاربرد در سیستم‌های فازی است (بیات‌ورکشی و همکاران، ۲۰۱۰).

روش ترکیبی عصبی ژنتیک: یکی دیگر از روش‌های ترکیبی روش تلفیق یافته شبکه عصبی مصنوعی با الگوریتم ژنتیک به عنوان یک ابزار ریاضی مناسب برای برآورد سطح ایستایی بود. الگوریتم ژنتیک، یک الگوریتم جستجوی موازی برای انتخاب طبیعی اصلح، بر پایه نظریه داروین برای یافتن بهترین راه

- 1- Fuzzifier Input
- 2- Inference Engine
- 3- Defuzzifier Output
- 4- Gaussian
- 5- Sugeno

حل (کروموزوم) است. هدف از به کارگیری الگوریتم ژنتیک، بهینه سازی پارامتر وزن شبکه عصبی مصنوعی بود. بنابراین تابع هدف الگوریتم ژنتیک، تابعی از نتایج آماری شبکه عصبی مصنوعی است. ساختار کلی یک شبکه عصبی ژنتیک در شکل ۵ نمایش داده شده است.



شکل ۵- ساختار شبکه عصبی ژنتیک مورد استفاده در مطالعه.

الگوریتم ژنتیک با تلفیق عملگرهای به گزینی و تولیدمثل^۱، تلاقی^۲ و جهش^۳، با هدف یافتن بهترین راه حل، جمعیتی از کروموزوم های اولیه را ایجاد می نماید. سپس بخشی از جمعیت هر نسل برای آموزش توسط شبکه عصبی به طور تصادفی مقداردهی اولیه می شود و میزان خطا با استفاده از داده های آموزش محاسبه می گردد. سپس به روزرسانی پارامترهای شبکه با توجه به مقادیر تابع هدف و نرخ های جهش و تلاقی انجام می شود. هر کروموزوم مجموعه ژن هایی است که سعی در بهینه سازی پارامترهای شبکه عصبی و برآورد مقادیر سطح ایستابی دارد. تمرکز این روش بر جمعیتی از نقاط به عنوان مجموعه جواب موجب جلوگیری از افتادن الگوریتم ژنتیک در حداقل های محلی می شود. در مرحله

- 1- Reproduction
- 2- Cross Over
- 3- Mutation

بعدی توابع هدف کروموزم‌های نسل اولیه محاسبه می‌شود. در این مرحله پارامترهای الگوریتم ژنتیک از طریق آموزش کروموزوم‌ها به کمک شبکه عصبی و ارزیابی توده‌های تولیدی در مرحله تولیدمثل، تکامل می‌یابند. با پیدایش نسل‌های جدید شبکه عصبی آموزش داده شده با داده‌های نسل اولیه می‌تواند دچار خطا گردد، بنابراین آموزش کروموزوم‌ها به‌طور دوره‌ای تکرار می‌گردد.

تمرکز روش جستجوگر عصبی ژنتیک بر جمعیتی از نقاط به‌عنوان مجموعه جواب موجب جلوگیری از افتادن الگوریتم ژنتیک در حداقل‌های محلی می‌شود. همچنین به‌کارگیری شبکه عصبی منجر به کاهش پیچیدگی‌های زمان‌بر محاسباتی و بهره‌گیری از قواعد آماری به‌جای قواعد صریح می‌گردد. شبکه عصبی مورد استفاده در این روش نیز مشابه مشابه الگوریتم‌های قبلی متشکل از یک لایه ورودی، یک لایه میانی و یک لایه خروجی بود.

این پژوهش مشتمل بر ۵۸ جفت الگوی ورودی و خروجی است که هر خروجی تابعی نامعلوم از بردار دوبعدی ورودی است. ورودی‌ها به‌صورت یک ماتریس 58×2 شامل مختصات طول و عرض جغرافیایی ۵۸ چاه می‌باشد. خروجی‌های هر یک از مدل‌ها به‌صورت یک ماتریس 58×1 است که مربوط به مقدار سطح ایستابی برآورد شده برای هر چاه‌ها می‌باشد.

با توجه به این‌که در این پژوهش هدف، بررسی دقت روش‌های شبکه پرسپترون چندلایه، شبکه تابع پایه شعاعی، سیستم تطبیقی عصبی فازی و عصبی ژنتیک است، بنابراین در مرحله اول مطابق عرف روش‌های هوشمند عصبی، ۸۰ درصد داده‌ها به‌عنوان داده‌های آموزش به‌صورت تصادفی از مجموعه داده‌ها کنار گذاشته شد (بیات‌ورکشی و همکاران، ۲۰۰۹). در مرحله دوم، تمامی تحلیل‌ها بر روی باقی‌مانده داده‌ها صورت گرفت و مقادیر سطح ایستابی برآورد شده با مقادیر واقعی مقایسه گردید. از آنجایی‌که یکی از مراحل پردازش داده‌ها برای شبکه‌های هوش مصنوعی هم‌ارزش کردن داده‌های ورودی به‌منظور حذف پراکندگی داده‌ها می‌باشد، بنابراین از قابلیت استانداردسازی نسخه پنجم نرم‌افزار Neuro Solution در محدوده [۱ و ۰] استفاده شد (زارع‌ایبانه و همکاران، ۲۰۱۱). همه عملیات مدل‌سازی روش‌های هوشمند عصبی نیز در جعبه ابزار نرم‌افزار بالا انجام گرفت. این نرم‌افزار دارای قابلیت بالا در پردازش و تحلیل اطلاعات ورودی، دقت مطلوب و تسهیل در نمایش خروجی‌ها برای تهیه مدل‌های هوشمند می‌باشند.

در نهایت به منظور تحلیل ساختار مکانی مقادیر سطح ایستابی به دست آمده از روش های هوشمند، روش زمین آمار کریجینگ استفاده شد. روش کریجینگ نوعی روش پارامتری است که به دلیل در نظر گرفتن همبستگی مکانی داده ها از اهمیت خاصی در بررسی داده های زمینی برخوردار است. به این منظور با استفاده از مدل رایانه ای ArcGIS وابسته به سیستم اطلاعات جغرافیایی (GIS)^۱، نقشه های پهنه بندی سطح ایستابی منطقه مورد مطالعه تهیه گردید.

برای ارزیابی میزان توانایی مدل های تدوین یافته در عکس العمل نسبت به متغیرهای ورودی، از آماره های مجذور میانگین مربعات خطا (RMSE)^۲ و میانگین خطای مطلق (MAE)^۳ استفاده شد. آماره RMSE دقت مدل را براساس تفاضل بین مقادیر واقعی و برآوردی و آماره MAE انحراف سطح ایستابی محاسباتی از مقادیر هدف (واقعی) را ارزیابی می کند.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad (5)$$

$$MAE = \frac{\sum_{i=1}^n |X_i - Y_i|}{n} \quad (6)$$

همچنین از شاخص ضریب تبیین (R^2)^۴ که تعیین کننده تناسب برازش مدل رگرسیون خطی به جفت داده های تخمینی و مشاهداتی است، نیز استفاده گردید. مقدار این ضریب همواره بین صفر و ۱ بوده و نزدیک بودن آن به یک نشان دهنده عملکرد بهتر مدل است.

$$R^2 = \frac{(\sum (X_i - \bar{X})(Y_i - \bar{Y}))^2}{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2} \quad (7)$$

که در آن ها، X_i و Y_i به ترتیب i امین داده سطح ایستابی برآوردی و اندازه گیری، \bar{X} و \bar{Y} به ترتیب متوسط داده های X_i و Y_i ، و n تعداد نمونه های مورد ارزیابی می باشند.

-
- 1- Geographic Information System
 - 2- Root Mean Square Error
 - 3- Mean Absolute Error
 - 4- Coefficient of Determination

در نهایت برای ارزیابی بهتر نتایج، مقادیر محاسبه شده با استفاده از هر یک از روش‌ها در مقابل مقادیر واقعی با در نظر گرفتن محدوده اطمینان ۹۰ درصد در قالب دو خط موازی با خط نیم‌ساز ترسیم شد. در صورتی که خروجی هر یک از مدل‌ها پهنه‌بندی شده در محیط کریجینگ با مقادیر واقعی سطح ایستابی برابر باشد، همه نقاط بر روی خط نیم‌ساز با معادله $y=x$ قرار می‌گیرد. میزان انحراف نقاط نسبت به خط نیم‌ساز بیانگر میزان تفاوت میان خروجی‌های پهنه‌بندی شده هر مدل با مقادیر واقعی است. فراوانی داده‌های درون باند نشان می‌دهد که هر مدل با چه دقت و احتمالی قادر به پیش‌بینی سطح ایستابی است. انحراف نقاط از خطوط اطمینان بیانگر توانایی کم‌تر مدل در پیش‌بینی نقاط بدون اندازه‌گیری است.

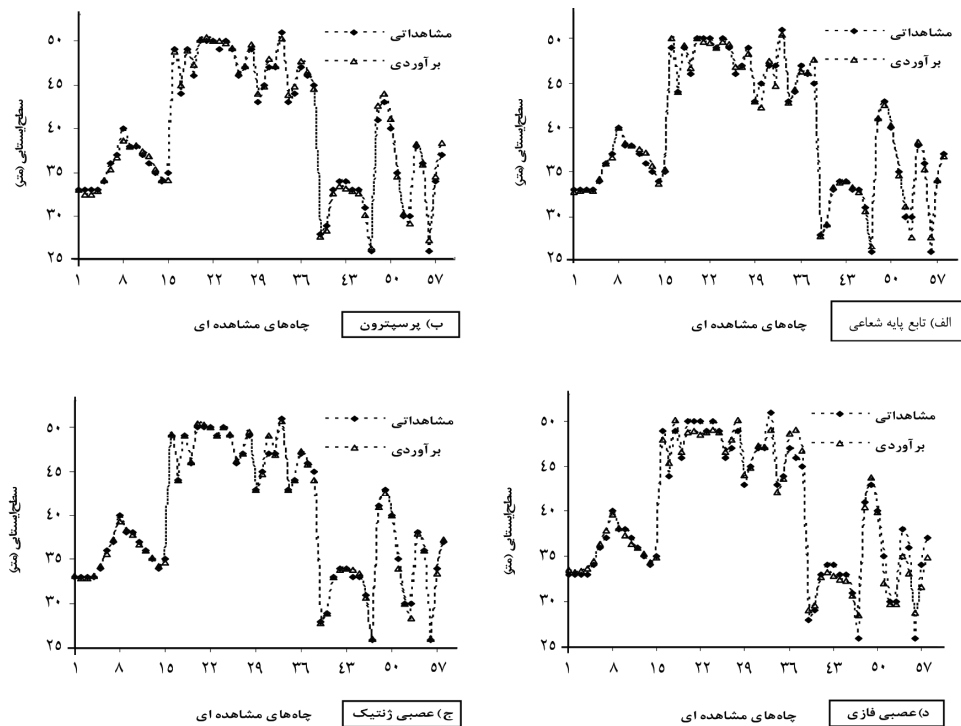
نتایج و بحث

در این مطالعه پیش‌بینی تراز سطح ایستابی با استفاده از ۴ ساختار شبکه هوشمند عصبی شامل شبکه پرسپترون چندلایه، شبکه تابع پایه شعاعی، شبکه عصبی فازی و شبکه عصبی ژنتیک صورت گرفت. نتایج کلی نشان داد، پس از ساخت مدل‌های تشریح شده در بخش مواد و روش، بهترین ساختار عصبی برای تمامی شبکه‌های هوشمند شامل ساختاری سه‌لایه با ۴ نرون در لایه پنهان بود که در راستای نتایج زارع‌ایبانه و همکاران (۲۰۱۱) مبنی بر کاهش توان یادگیری شبکه و خطر بیش‌برازش، به‌واسطه افزایش تعداد نرون در لایه میانی است.

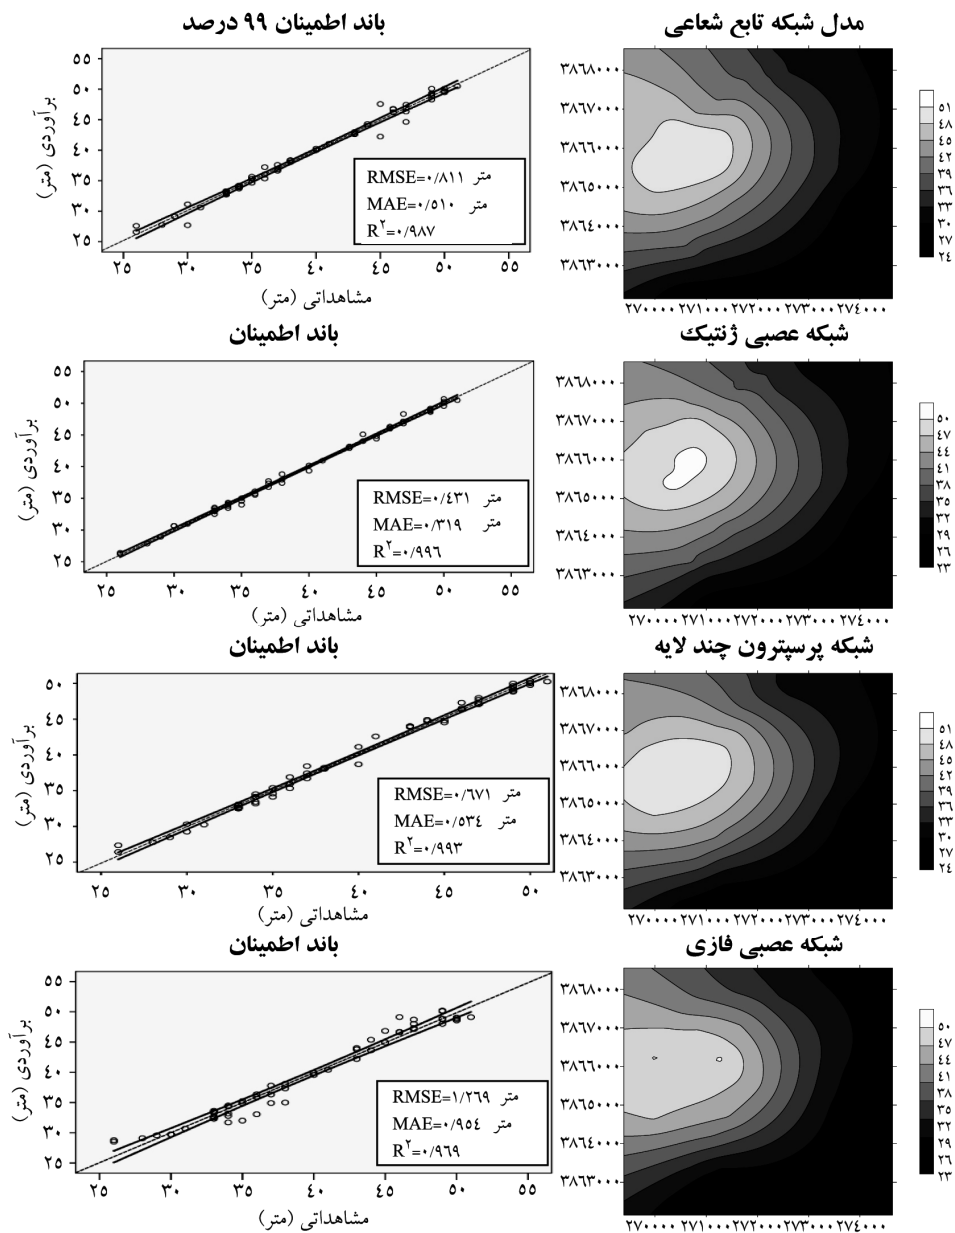
جزئیات مقادیر پیش‌بینی شده از هر ساختار و مقادیر مشاهداتی متناظر آن برای مقایسه در شکل ۶ آورده شد. همان‌گونه که از قبل اشاره شد نرم‌افزار مورد استفاده قابلیت اجرای اتوماتیک داده‌ها در شرایط استاندارد را دارا است. ولی خروجی‌های ارزیابی شده در شکل ۶، به‌صورت داده‌های واقعی (غیراستاندارد) می‌باشند.

شکل ۶ براساس داده‌های ورودی یکسان در تمام ساختارها، برای برآورد متغیر مجهول سطح ایستابی است که در آن سطح آب زیرزمینی بر مبنای سیستم مختصات نقشه‌ای قائم الزاویه چاه‌ها به‌عنوان ورودی و میانگین تراز سطح آب به‌عنوان خروجی برآورد می‌گردد. شکل ۶ نشان می‌دهد مقادیر سطح ایستابی برآورد شده از روش‌های مختلف در مقایسه با مقادیر واقعی دارای پراکنش زیادی نیست. تفاوت‌های جزئی در نتایج هر یک از روش‌های می‌تواند به‌دلیل ماهیت متفاوت هر یک

از مدل‌های تخمین‌گر در پاسخ به ورودی‌های یکسان باشد. با این وجود استفاده از آماره‌های ارزیابی مشخص می‌نماید که میزان خطای هر کدام از روش‌ها چه مقدار است، تا با تهیه مدل رقومی منطقه، نقشه پهنه‌بندی سطح ایستابی در محیط زمین‌آمار کریجینگ ایجاد گردد. بر این اساس خطای مربوط به روش‌های مختلف در محدوده مطالعاتی در قالب معیارهای $RMSE$ ، MAE و R^2 محاسبه و در شکل ۷ ارائه گردید. بنابراین نتایج مربوط به پهنه‌بندی سطح ایستابی به‌دست آمده از برآوردهای نقطه‌ای روش‌های هوشمند عصبی تلفیقی و غیرتلفیقی نیز به‌همراه محدوده اطمینان ۹۰ درصد در مقابل مقادیر مشاهداتی برای هر یک از روش‌ها در شکل ۷ نمایش داده شد.



شکل ۶- مقایسه مقادیر سطح ایستابی مشاهداتی در مقابل مقادیر برآوردی.




شکل ۷- نمودار مقادیر پهنه‌بندی شده و برآوردی از روش‌های مختلف.

نتایج اولیه به دست آمده از شکل ۷ نشان می‌دهد کم‌ترین مقدار خطای برآوردی معادل $0/43$ متر به روش تلفیقی عصبی ژنتیک تعلق دارد و بیش‌ترین مقدار خطا به اندازه $1/27$ متر مربوط به روش عصبی فازی است. همچنین مقایسه نتایج به دست آمده از روش‌های هوشمند عصبی در تخمین سطح ایستابی در مقایسه با مقادیر مشاهده شده نشان می‌دهد که روش شبکه عصبی پرسپترون با مقدار خطای $0/67$ متر عملکرد مناسب‌تری نسبت به روش عصبی فازی و شبکه تابع پایه شعاعی داشته است. مقایسه نتایج به دست آمده از این مطالعه با نتایج نیک‌منش و رخشنده‌رو (۲۰۱۱) نشان داد استفاده از طول و عرض جغرافیایی نسبت به داده‌های دما، بارندگی، رواناب سطحی و رودی، رواناب سطحی خروجی و هیدروگراف واحد آب نتایج مطلوب‌تری را به دنبال داشت. به طوری که خطای برآورد سطح ایستابی به مقدار ۸۱ درصد کم‌تر از خطای گزارش شده از سوی نیک‌منش و رخشنده‌رو (۲۰۱۱) برای آب‌خوان سعادت‌شهر فارس بود. از نظر تئوری تمرکز روش ژنتیک بر مجموعه‌ای از کروموزم‌ها و آموزش دوره‌ای کروموزم‌های تولیدمثلی می‌تواند به نتایج بهتر در مقابل روش‌های عصبی منجر شود. این نتایج در راستای گزارش فقیه (۲۰۱۰) مبنی بر توانمندی روش ژنتیک در مسایل مرتبط با هیدرولوژی است. هم‌چنین محمدی (۲۰۰۶) توانمندی الگوریتم عصبی ژنتیک در نیاز نداشتن به مشتقات تابع جواب به واسطه ارتباط مستقیم با تابع اصلی و استفاده از قواعد آماری به جای قواعد صریح و گلدبرگ (۱۹۸۹) آموزش‌پذیری مناسب الگوریتم عصبی ژنتیک را با توجه به گستردگی فضای جستجو، انتخاب جمعیت اولیه و تعداد نسل‌های مناسب در افزایش دقت مؤثر می‌دانند.

همان‌گونه که اشاره شد برای ارزیابی بهتر نتایج، مقادیر محاسبه شده با استفاده از هر یک از روش‌ها در مقابل مقادیر واقعی با در نظر گرفتن محدوده اطمینان ۹۰ درصد ترسیم شد (شکل ۷). لازم به ذکر است وجود نقاط بیش‌تر در مرزها و نقاط همسایگی، بیانگر دقت بیش‌تر مدل می‌باشد (دهقانی و همکاران، ۲۰۰۹). بنابراین می‌توان بیان نمود کاهش پراکنش نقاط و باریک‌تر بودن محدوده اطمینان ۹۰ درصد، بیانگر برتری مدل می‌باشد که در مدل عصبی ژنتیک نسبت به سایر مدل‌ها مشهود است. در مجموع با توجه به شکل ۷ چنین استنباط می‌گردد که دقت مدل‌ها بر حسب خطای کم‌تر در تخمین سطح ایستابی در نقاط بدون اندازه‌گیری به ترتیب اولویت شامل عصبی ژنتیک، پرسپترون چندلایه، تابع پایه شعاعی و عصبی فازی است. میناچی و محمدی (۲۰۰۶) علت خطای روش‌های هوشمند را نیازمندی این روش‌ها به مجموعه الگوهای ورودی و خروجی دانسته‌اند. به علاوه به نظر می‌رسد خطاهای انسانی در قرائت و ثبت اطلاعات و حجم اندازه‌گیری‌ها نیز در مقدار خطای میان‌یابی

نقش دارند. ترتیب برتری روش‌های بالا در زمینه‌های گوناگون مطالعه شده از سوی پژوهشگران مختلف گزارش شده است (دهقانی و همکاران، ۲۰۰۹؛ میثاقی و محمدی، ۲۰۰۶). با بررسی نتایج این پژوهش و نیز پژوهش‌های قبلی هم‌چون دهقانی و همکاران (۲۰۰۹)، میثاقی و محمدی (۲۰۰۶) و خلیقی و حسینی (۲۰۰۶) می‌توان چنین نتیجه‌گیری نمود که مناسب‌ترین روش تحلیل مکانی، به نوع متغیر هیدرولوژیکی و عوامل مؤثر منطقه‌ای بر آن بستگی دارد. از سوی دیگر تراکم شبکه نقاط اندازه‌گیری نیز یک عامل تعیین‌کننده در ارتباط با روش منتخب است.

آب‌خوان مورد مطالعه با استفاده از مدل رایانه‌ای ArcGIS در درون مرز بسته محدوده آب‌خوان به‌صورت رقمی شامل مرزهای سیستم (شکل ۸ سمت چپ) و پهنه‌بندی آن در ۵ کلاس (شکل ۸ سمت راست) آمده است.



شکل ۸- نقشه پهنه‌بندی تغییرات سطح ایستابی در منطقه مورد مطالعه.

با توجه به همبستگی بالای سطح ایستابی نسبت به مکان، به دلیل تفاوت‌های مکانی قسمت‌های مختلف آب‌خوان، تهیه نقشه سطح ایستابی با دقت مناسب براساس نتایج به‌دست آمده از روش کریجینگ انجام شد. همان‌گونه که شکل ۸ نشان می‌دهد قسمت غربی دشت که به‌صورت برآمده است بیانگر ضخامت بیشتر آب‌خوان می‌باشد و با دور شدن از آن به‌سمت حواشی از ضخامت آب‌خوان کاسته می‌شود. به‌عبارت دیگر هرچه از قسمت مرکزی آب‌خوان به‌سمت شمال، جنوب و شرق آب‌خوان فاصله می‌گیریم، ضخامت لایه آب‌دار و به پیروی از آن حجم آب ذخیره شده کاهش می‌یابد.

شکل ۸ (سمت راست) نقشه پهنه‌بندی سطح ایستابی را در ۵ کلاس نشان می‌دهد. بیش‌ترین ضخامت به اندازه ۴۱-۵۱ متر مربوط به بخش غربی دشت است و کم‌ترین ضخامت به مقدار ۲۴-۳۰ متر در شرق و جنوب دشت قرار دارد. با توجه به شکل ۸ پراکنش چاه‌ها در بخش غربی دشت به‌علت دسترسی به منابع پایدار آب زیرزمینی و جریان‌های سطحی به‌دست آمده از ذوب تدریجی برف در دامنه‌های کوه الوند یکنواخت‌تر می‌باشند. در حالی‌که در حاشیه‌های دشت به‌علت کم‌تر بودن ضخامت سفره، پراکنش چاه‌ها نامنظم است. با توجه به تغذیه غالب سفره آب زیرزمینی از ریزش‌های جوی و آبراهه‌های متعدد منشعب از دامنه‌های الوند کوه در بخش غربی دشت (امور آب استان، ۲۰۰۸) و با توجه به ضخامت بیش‌تر سفره در این بخش صحت پهنه‌بندی قابل توجیه است. همچنین لزوم ایجاد مکان‌های تغذیه مصنوعی برای جلوگیری از کاهش ممتد سطح ایستابی به‌ویژه در حاشیه‌های دشت ضروری به‌نظر می‌رسد که مکان‌یابی تغذیه مصنوعی تاسران در حاشیه شمالی دشت و تغذیه مصنوعی هارون‌آباد در شمال‌شرقی دشت در این راستا بوده و بیانگر نتایج این مطالعه است.

نتیجه‌گیری

هدف از انجام این پژوهش بسط و توسعه نتایج روش‌های نوین با پایه عصبی در محیط زمین‌آمار بود تا آن‌جایی‌که روش پیشنهادی با دقت کافی قادر به تخمین مقادیر سطح ایستابی در نقاط بدون اندازه‌گیری باشد. نتایج به‌دست آمده از این پژوهش در قالب موارد زیر خلاصه می‌شود:

- ۱- استفاده از داده‌هایی با آسانی اندازه‌گیری، منجر به کاهش هزینه‌های اولیه می‌شود. داده‌های جمع‌آوری شده از سطح آب‌خوان مورد مطالعه طول و عرض جغرافیایی بود. که امکان تعیین دقیق آن با ابزار نقشه‌برداری میسر می‌باشد.
- ۲- آزمون و ارزیابی روش‌های نوین عصبی در آب‌خوان دشت همدان- بهار و معیارهای خطای به‌دست آمده نشانگر عملکرد مناسب این روش‌ها در برآوردهای نقطه‌ای می‌باشد. بنابراین نتایج روش‌های پیشنهادی را می‌توان در سایر آب‌خوان‌های منطقه و آب‌خوان‌های مشابه کنترل و ارزیابی نمود.
- ۳- این پژوهش نشان داد برآوردهای روش ترکیبی عصبی ژنتیک در محیط کریجینگ، روشی مناسب برای پیش‌بینی و پهنه‌بندی سطح ایستابی است. این روش قابلیت برآورد سطح ایستابی در نقاط بدون اندازه‌گیری را براساس مقادیر به‌دست آمده از پیش‌بینی با ورودی‌های طول و عرض جغرافیایی نقاط برداشت دارد.

۴- به‌طورکلی دقت و اعتبار هر تخمینی، بستگی به کیفیت و کمیت پارامتر مورد سنجش دارد. پارامتر سطح ایستابی تنها پارامتر قابل اندازه‌گیری است که دقت آن بستگی به دقت اندازه‌گیری‌ها دارد. از طرف دیگر اندازه‌گیری‌های زیاد می‌تواند باعث اتلاف وقت و هزینه برای اندازه‌گیری‌های میدانی و تراکم اندازه‌گیری‌های کم باعث کمبود اطلاعات کافی گردد. از این‌رو استفاده از تئوری زمین‌آمار به‌واسطه استفاده از نقاط همسایگی، میزان اثر خطا در داده‌های جمع‌آوری شده را کاهش می‌دهد. از آن‌جا که سطح ایستابی متغیری است پیوسته که به موقعیت جغرافیایی نقاط ایستگاهی وابسته است، بنابراین دارای پراکنش مکانی است و این موضوع اهمیت مدیریت مکانی سطح ایستابی را تأیید می‌کند.

منابع

1. Abdi, H., Valentin, D., Edelman, B., and O'Toole, A.J. 1996. A Widrowe Hoff learning rule for a generalization of the linear auto-associator. *J. Mathemat. Psych.* 40: 2. 175-182. (In Persian)
2. Asghari Moghaddam, A., Nadiri, A., and Fijani, A. 2010. Spatial prediction of fluoride concentration using artificial neural networks and geostatic models. *Water and Soil Sci. (Agricultural Science)*. 19: 2. 129-145. (In Persian)
3. Aytok, A. 2008. Co-active neuro fuzzy inference system for evapotranspiration modeling. *Soft Computing-A Fusion of Foundations, Method. Appli.* 13: 7. 691-700.
4. Bayat Varkeshi, M., Zare Abyaneh, H., Marofi, S., Sabziparvar, A.A., and Soltani, F. 2009. Simulation of reference evapotranspiration using Artificial Neural Method and Empirical Methods and comparison with experimental Lysimeter data in cold semi-arid climate of Hamedan. *J. Water and Soil Cons.* 16: 4. 79-100. (In Persian)
5. Chang, F., and Chang, Y. 2006. Adaptive neuro-fuzzy inference system for prediction of water level in reservoir. *Advanc. Water Resour.* 29: 1-10.
6. Dehghani, A.A., Asgari, M., and Mosaedi, A. 2009. Comparison of Geostatistics, Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference System Approaches in Groundwater Level Interpolation (Case study: Ghazvin aquifer). *J. Agric. Sci. Natur. Resour.* 16: 1. 517-528. (In Persian)
7. Faghieh, H. 2010. Evaluating Artificial Neural Network and its Optimization Using Genetic Algorithm in Estimation of Monthly Precipitation Data (Case Study: Kurdistan Region). *J. Agric. Tech. Sci. Natur. Resour.* 14: 51. 27-44. (In Persian)
8. Foroghi, H., Moazed, H., Kashefipour, M., and Karami, M. 2006. Maroon river basin water table levels management using artificial neural networks. In: *River Engineering Seventh International Seminar*. (In Persian)

9. Ganji Khorramdel, N., Mohammadi, K., and Monem, M.J. 2008. Optimization of observation well network for the estimation of groundwater balance using double water table fluctuation method. *J. Water Soil.* 22: 2. 358-370. (In Persian)
10. Garcia, L.A., and Shigidi, A. 2006. Using Neural Networks for Parameter Estimation in Ground Water. *J. Hydr.* 318: 1. 215-231.
11. Ghasemi, A., Zareabyaneh, H., Amiri Chayjan, R., Mohamadi, K., Marofi, S., and Ahmadi, M. 2007. Comparing evapotranspiration (ET₀) estimates from the experimental methods and artificial neural networks, with lysimeter data. *J. Agric. Res.* 7: 3. 245-258. (In Persian)
12. Goldberg, D.E. 1989. Genetic algorithm in search, optimization and machine learning. Addison-Wesley, Reading, MA, 412p.
13. Izadi, A., Davari, K., Alizadeh, A., and Ghahreman. 2008. Application of panel data model in predicting groundwater level. *Iran. J. Irrig. Drain.* 2: 2. 133-145. (In Persian)
14. Kholgi, M., and Hosseini, S.M. 2006. Estimation of aquifer transmissivity using kriging, artificial neural network. *J. Spat. Hydr.* 6: 2. 68-81. (In Persian)
15. Kumar, M., Bandyopadhyay, A., Raghuwanshi, N.S., and Singh, R. 2008. Comparative study of conventional and artificial neural network-based ET₀ estimation models. *J. Irrig. Sci.* 26: 6. 531-545.
16. Misaghi, F., and Mohammadi, K. 2007. Estimating spatial distribution of rainfall using statistical and geostatistical methods and comparison with artificial networks. *J. Agric. Sci.* 29: 4. 1-13. (In Persian)
17. Mohamadi, M.S. 2006. Learning without supervision of RBF neural network by using genetic algorithm. P 1-6, In: Ninth Conference on IRAN Electrical Engineering student. (In Persian)
18. Mohtasham, M., Dehghani, A.A., Akbarpour, A., Meftah Halaghi, M., and Etebari, B. 2010. Groundwater level determination by using artificial neural network (case study: Birjand Aquifer). *J. Iran. Irrig. Drain.* 4: 1. 1-10. (In Persian)
19. Monem, M.J., and Kiapasha, M.S. 2009. Development and evaluation of an upstream fuzzy control system model for irrigation canals. *J. Iran. Water Res.* 3: 4. 41-50.
20. Nayak, P., Satyaji Rao, Y.R., and Sudheer, K.P. 2006. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water Resour. Manage.* 2: 1. 77-99.
21. Nikmanesh, M.R., and Rakhshandehroo, G.R. 2011. Evaluate the ability of artificial neural networks in prediction of groundwater levels in Saadat Shahre Fars. *Iranian Water Resour. Research.* 7: 1. 82-86. (In Persian)
22. Nouri, R., Farokhnia, A., Morid, S., and Riahi Modvar, H. 2009. Effect of input variables preprocessing in artificial neural network on monthly flow prediction by PCA and wavelet transformation. *Water and Wastewater.* 20: 1. 13-22. (In Persian)

23. Rahimi Khob, A., Behbahani, M., and Jamshidi, M. 2009. Evaluation of Two Empirical Methods and Artificial Neural Network Models Used for Estimation of Solar Radiation Intercepted at the Earth's Surface: A Case Study in Southeast of Tehran. *J. Agric. Sci. Tech. Natur. Resour.* 13: 50. 53-63. (In Persian)
24. Rahmani, A.R., and Sedehi, M. 2004. Prediction of Hamadan - Bahar plain groundwater levels with time series model. *Water and Wastewater.* 15: 3. 42-49. (In Persian)
25. Rahnama, M., and Shakibae, A. 2005. Modeling of the Earth Summit in the drop in groundwater level (Case Study of Rafsanjan plain). In: Fifth the Iranian Hydraulic Conference. (In Persian)
26. Rezaei, A., Mahdavi, M., Luxe, K., Feiznia, S., and Mahdian, M.H. 2007. Regional Peak Flows Modelling of Sefid rood Dam's Sub Basins Using Artificial Neural Network. *J. Agric. Sci. Tech. Natur. Resour.* 11: 1. 25-40.
27. Rizzo, D.M., and Dogherty, D.E. 1994. Characterization of aquifer properties using Artificial Neural Networks: Neural Kriging. *Water Resour. Res.* 30: 2. 483-497.
28. Rohani, S., Peykan, Gh., and Taghdiri, B. 2007. Determination of optimum cropping pattern with the emphasis on sustainability of water resources: A case study in Bahar plain-Hamedan. *J. Agric. Res. Water, Soil and Plant in Agric.* 7: 1. 85-96. (In Persian)
29. Tabari, H., Maroufi, S., Zareabyaneh, H., and Sharifi, M.R. 2010. Comparison of artificial neural network and combined models in estimating spatial distribution of snow depth and snow water equivalent in samsami basin of Iran. *Neural Comp. Appl.* 19: 4. 625-635.
30. Tasaloti, B. 2003. Estimation of groundwater table using Modflow and artificial neural networks. A thesis, Master of Science. Agriculture faculty. Tarbiat Modares University, 105p. (In Persian)
31. Water Affairs of Hamedan Province. 2008. Report of groundwater resources Hamedan Province. (In Persian)
32. Yavari, M., and Mahdavi, S. 2006. Predict the penetration rate of cars using Neural Networks. *J. Neur. Engin. Faculty of Tehran University (Special Mining Engineering).* 40: 1. 1-12. (In Persian)
33. Zade, L.A. 1965. Fuzzy sets. *Information contro.* 8: 3. 338-353.
34. Zareabyaneh, H., Bayatvarkeshi, M., and Marofi, S. 2011. Forecasting of garlic (*Allium sativum L.*) evapotranspiration by using multiple modeling. *J. Agric. Sci. Natur. Resour.* 18: 2. 89-107. (In Persian)
35. Zheng, Z., Zhang, F., Chai, X., Zhu, Z., and Ma, F. 2009. Estimation of Soil Moisture and Salinity with Neural Kriging. In IFIP International Federation for Information Processing, *Computer and Computing Technologies in Agriculture II*, 2: 1227-1237.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 20(4), 2013
<http://jwsc.gau.ac.ir>

Development and application of statistical and neural, Fuzzy, Genetic Algorithm models in estimation of spatial distribution of water table level

***H. Zare Abyaneh¹ and M. Bayat Varkeshi²**

¹Associate Prof., Dept. of Water Engineering, Bu-Ali Sina University, Hamedan, Iran,

²Ph.D. Student, Dept. of Water Engineering, Bu-Ali Sina University, Hamedan, Iran

Received: 12/04/2011; Accepted: 10/29/2012

Abstract

Estimation of groundwater in the aquifer water resources management is important. In this study for estimation of the spatial distribution of water table level in Hamadan-Bahar plain neural intelligent methods including Multy Layer Perseptron (MLP), Radial Basis Function (RBF), Co-Active Neuro-Fuzzy Inference System (CANFIS) and Adaptive Neural Network based Genetic Algorithm (ANNGA) were used. To estimate water table in locations without measurements values, point values were estimated from each neural intelligent methods zoned in geographic information system. Overall, accuracy of used method based minimum errors were related to ANNGS, MLP, RBF and CANFIS, respectively. So that in ANNGA model, Root Mean Square Error (RMSE) was 0.431 m and correlation coefficient (r) value was 0.996. Maximum errors were related to CANFIS and RBF models with RMSE=1.27 m and RMSE=0.81 m, respectively. Also, comparison of the spatial variation of water table estimated by ANNGA model with observational data showed that points distribution in 90% confidence limits were little. Therefore, with using the latitude and longitude as input data water table spatial changes and its zoning can be estimated.

Keywords: Water table, Neural intelligent method, Geostatistical, Hamadan-Bahar plain

* Corresponding Author; Email: zareabyaneh@gmail.com

