

شبیه‌سازی سطح ایستابی دشت ملایر براساس داده‌های هواشناسی با استفاده از شبکه‌ی

عصبی مصنوعی

حمید زارع‌ابیانه* - دانشیار گروه مهندسی آبیاری، دانشکده‌ی کشاورزی، دانشگاه بوعلی‌سینا، همدان
مریم بیات ورکشی - دانشجوی کارشناسی ارشد رشته‌ی آبیاری و زهکشی، دانشگاه بوعلی‌سینا، همدان
صفر معروفی - دانشیار گروه مهندسی آبیاری، دانشکده‌ی کشاورزی، دانشگاه بوعلی‌سینا، همدان
علیرضا ایلدرومی - استادیار گروه آبیاری دانشکده‌ی کشاورزی، دانشگاه ملایر

پذیرش مقاله: ۱۳۸۸/۱۲/۸ تأیید نهایی: ۱۳۹۰/۵/۹

چکیده

برای بررسی کارایی شبکه‌ی عصبی مصنوعی در شبیه‌سازی تغییرات سطح ایستابی سفره‌ی آب زیرزمینی دشت ملایر، از اطلاعات هواشناسی ایستگاه‌های تبخیرسنجی در سطح دشت، حجم آب برداشتی از سفره و مقادیر سطح ایستابی آن استفاده شد. از این اطلاعات، به‌عنوان ورودی شبکه‌ی عصبی مصنوعی نوع پرسپترون چندلایه در چارچوب چهار ساختار اطلاعاتی استفاده شد. ساختار اول، شامل میانگین اطلاعات دمای حداکثر هوا، دمای حداقل هوا، حداکثر رطوبت نسبی هوا، حداقل رطوبت نسبی هوا و میانگین تبخیر در مقیاس زمانی ماهانه و ارتفاع سطح ایستابی ماه پیش بود. در ساختار دوم از اطلاعات سطح ایستابی در یک، دو، سه و چهار ماه پیش استفاده شد. در ساختار سوم، افزون‌بر اطلاعات ساختار شماره‌ی دو، میانگین سطح ایستابی ماه مورد نظر و میانگین سطح ایستابی ماه پیش هم به‌کار گرفته شد. ساختار چهارم، براساس میانگین سطح ایستابی ماه مورد نظر، میانگین سطح ایستابی ماه پیش و اطلاعات هواشناسی ماهانه تعریف شد. ساختار سوم با آرایش ۱-۴-۴-۶، به‌عنوان ساختار مناسب با ۱/۹ درصد خطا در مقایسه با مقادیر واقعی پیشنهاد شد که نشان‌دهنده‌ی اهمیت به‌کارگیری عوامل سطح ایستابی سال‌های گذشته، در ورودی شبکه‌ی عصبی است. اجرای مدل بهینه‌ی شبکه‌ی عصبی، افت سطح ایستابی را ۱/۱۸ متر، به‌زای ۱/۹ درصد خطا برآورد کرد. جذر میانگین مربعات خطا در مدل بهینه‌ی شبکه‌ی عصبی با آرایش ۱-۴-۴-۶ بر مبنای قانون آموزش لوبنبرگ مارکوات و تابع محرک سیگموئید، در مقابل تغییرات واقعی سطح سفره ۰/۴۴ متر با ضریب تعیین ۰/۹۹ به‌دست آمد. با توجه به دقت مناسب مدل و روند کاهنده‌ی حاکم بر سفره، می‌توان استفاده از شبکه‌ی عصبی مصنوعی برای تصمیم‌گیری در مدیریت دشت را، به‌عنوان ابزاری با سرعت و دقت مناسب در شبیه‌سازی سطح آب زیرزمینی دشت ملایر، توصیه کرد.

کلیدواژه‌ها: مدل‌سازی، آب‌یرزمینی، شبیه‌سازی، شبکه‌ی عصبی مصنوعی پرسپترون چند لایه، دشت ملایر.

مقدمه

پیش‌بینی نوسان‌های سطح آب زیرزمینی برای مدیریت تأمین و بهره‌برداری از آبها، امری لازم است. نوسان‌های آب زیرزمینی، اثربافته از عوامل زیادی است که قطعی نبودن آنها، به دلیل تعدد متغیرهای مؤثر بر بیلان آبخوان و ماهیت نامتجانس محیطی، سبب پیچیدگی پیش‌بینی و تلاش پژوهشگران در بررسی تغییرات حجم مخزن شده است (نایاک و همکاران، ۲۰۰۶: ۹۷؛ اسمعیلی ورکی و همکاران، ۱۳۸۳: ۲). یکی از رویکردهای مناسب در مطالعه‌ی رفتار آبهای زیرزمینی، استفاده از مدل‌های رایانه‌ای است. بنابراین، شناخت سازوکار تغییرات سطح ایستابی در طول زمان و پیش‌بینی آن با استفاده از روند حاکم برای اطلاع از وضعیت سفره و میزان آب قابل دسترس، ضروری است. در این راستا، مدل‌های شبکه‌ی عصبی مصنوعی، به دلیل نبود درک فیزیکی از ماهیت مسئله، تنها براساس آموزش قادر به مدل‌سازی رفتار دینامیک یک فرایند غیرخطی هستند (دالی‌آکوپولس و همکاران، ۲۰۰۴: ۲۳۲). ویژگی پیش‌گفته سبب انعطاف‌پذیری شبکه‌ی عصبی مصنوعی در برابر خطاهای ناخواسته و بی‌تأثیر شدن آنها در روند کار است (دایهوف، ۱۹۹۰؛ طهماسبی و زمردیان، ۱۳۸۳: ۲). شبکه‌های عصبی مصنوعی با قابلیت اعتماد بیشتر زمانی و سازگاری با تغییرات پیش‌بینی نشده، جایگزین مناسب مدل‌های تجربی و رگرسیونی برای پیش‌بینی رفتار منابع آب به‌شمار می‌روند (بهروزی خزایی و همکاران، ۱۳۸۶: ۱۴۳؛ ایزدی و همکاران ۱۳۸۷: ۱۳۳). تسلطی در سال ۱۳۸۲ برای شبیه‌سازی سطح آب زیرزمینی دشت چمچال کرمانشاه، از یک مدل شبکه‌ی عصبی پرسپترون چندلایه استفاده کرد. نتایج وی بیانگر شبیه‌سازی مناسب و قابل قبول سطح ایستابی در چاهک‌های مشاهده‌ای بود. کارآموز و همکاران (۱۳۸۳: ۸) با اعمال راه‌کارهای مختلف بهره‌برداری از منابع آبهای سطحی و زیرزمینی منطقه‌ی جنوب شهر تهران، موفق به کنترل نوسان‌های سطح آب زیرزمینی بر پایه‌ی مدل‌های الگوریتم ژنتیک و شبکه‌های عصبی مصنوعی شدند. توانایی شبکه‌های عصبی مصنوعی با ساختار پرسپترون چندلایه، در مدل‌سازی آبخوان‌های آهکی در یک سازند کارستی در شمال فرانسه مطالعه شد (اصغری‌مقدم و همکاران، ۱۳۸۵: ۱). فروغی و همکاران (۱۳۸۵: ۱) یک مدل شبکه‌ی عصبی را برای پیش‌بینی نوسان‌های سطح ایستابی با استفاده از اطلاعات بارش، تبخیر، اختلاف دبی در طول رودخانه و میزان برداشت ماهانه از منابع آب زیرزمینی برای حوضه‌ی آبریز مارون در استان خوزستان ارائه کردند.

به‌کارگیری شبکه‌های عصبی مصنوعی از سوی لالا هم و همکاران (۲۰۰۵: ۹۲) در ارزیابی سطح آب زیرزمینی آبخوان آهکی شمال فرانسه نشان داد، الگوریتم پرسپترون چندلایه با حداقل نرون میانی در کوتاه‌مدت، بهترین پیش‌بینی را دارد. نتایج پژوهش دهقانی و همکاران (۱۳۸۸: ۵۱۷) در مورد پیش‌بینی سطح آب زیرزمینی دشت قزوین با به‌کارگیری دو دسته داده‌های آموزش و آزمون نشان داد، دقت نتایج حاصل از روش‌های هوشمند عصبی، بیش از روش‌های زمین‌آمار بود. از جمله پژوهش‌های مرتبط با کاربرد شبکه‌های عصبی در پیش‌بینی نوسان‌های زمانی سطح آب زیرزمینی، مطالعات استریکانت و همکاران (۲۰۰۹: ۹۳۳) در حیدرآباد هندوستان است که مؤید قابلیت شبکه‌ی عصبی مصنوعی در پیش‌بینی سطح آب زیرزمینی با میانگین مجذور مربعات خطای ۴/۵ متر و ضریب تعیین ۰/۹۳ بود. محتشم و همکاران (۱۳۸۹: ۱) سطح ایستابی دشت بیرجند از استان خراسان رضوی را به‌کمک شبکه‌ی هوشمند عصبی برآورد کردند. نتایج

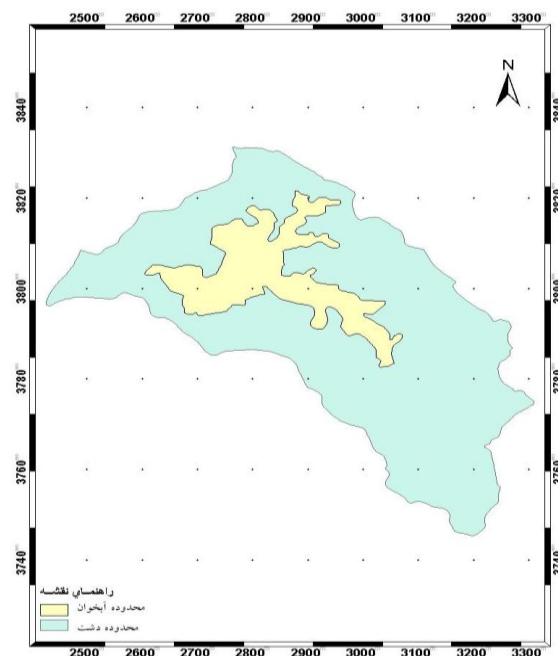
آنان گویای دقت بالای این روش، براساس کسب مقادیر کم میانگین مربعات خطا و مقادیر بالای ضریب تعیین نسبت به روش‌های دیگر بود.

مطالعات انجام گرفته در ایران نشان می‌دهد با وجود اهمیت پیش‌بینی رفتار یک سفره‌ی آب زیرزمینی و قابلیت شبکه‌های هوشمند عصبی، مطالعات محدودی در مورد شبیه‌سازی سطح ایستابی با استفاده از شبکه‌ی عصبی مصنوعی انجام گرفته است (دهقانی و همکاران، ۱۳۸۸: ۵۲۰).

با توجه به ضرورت‌های بیان شده، هدف این پژوهش، ایجاد ارتباط بین متغیرهای وابسته‌ی مؤثر در نوسان‌های سطح ایستابی در شرایط میدانی و یافتن شبکه‌ای با ساختار مناسب برای شبیه‌سازی و کمی‌کردن ارتباط نوسان‌های سطح ایستابی، به‌عنوان متغیر مستقل با عوامل مختلف هواشناسی و هیدروژئولوژی دشت ملایر است.

مواد و روش‌ها

دشت ملایر در بخش حوزه‌ی آبریز علیای رودخانه‌ی کرخه واقع شده و میان دو استان همدان (شهرستان ملایر) و استان مرکزی (شهرستان اراک) قرار دارد. این حوزه در مختصات جغرافیایی 30° ، 34° تا 30° ، 34° عرض شمالی و 30° ، 48° تا 1° ، 49° طول شرقی واقع است. وسعت کُلّ حوزه، 2965 کیلومترمربع، شامل 800 کیلومترمربع دشت و 2165 کیلومترمربع ارتفاعات حاشیه است. محدوده‌ی آبخوان و دشت ملایر در شکل شماره‌ی ۱ نشان داده شده است.



شکل ۱. محدوده‌ی دشت ملایر و آبخوان

آب‌وهوای دشت معتدل کوهستانی و گاهی سرد است. میزان بارندگی و تبخیر سالانه‌ی آن بین سال‌های ۱۳۵۴ تا ۱۳۸۵، به‌ترتیب 309 و 2294 میلی‌متر بوده است. در بررسی وضعیت کمی سفره‌ی آب زیرزمینی شکل‌های مختلف

برداشت و میزان برداشت از منابع آب زیرزمینی یک دشت ملاک عمل است. این اطلاعات برای سه دوره‌ی زمانی ۱۳۶۵، ۱۳۷۴ و ۱۳۸۲ در جدول شماره‌ی ۱ ارائه شده است.

جدول ۱. تعداد و میزان تخلیه (میلیون مترمکعب) در دشت ملایر

بارش میلی‌متر	جمع		چشمه		قنات		چاه				سال
	تخلیه	تعداد	تخلیه	تعداد	تخلیه	تعداد	نیمه عمیق		عمیق		
							تخلیه	تعداد	تخلیه	تعداد	
۴۳۲	۱۸۹	۵۱۲	-	-	۱۵	۳۳	۶	۱۶۸	۱۶۸	۳۱۱	۱۳۶۵
۴۰۶	۴۹۵	۲۵۷۰	۶۸/۷	۷۵۵	۱۶۷/۵	۶۴۰	۱۵	۴۶۳	۲۴۴	۷۱۲	۱۳۷۴
۳۱۱	۲۵۲	۱۷۳۶	۱۴/۹	۷۳	۲۴	۲۳۴	۳۶/۵	۶۶۸	۱۷۶/۶	۷۶۱	۱۳۸۲

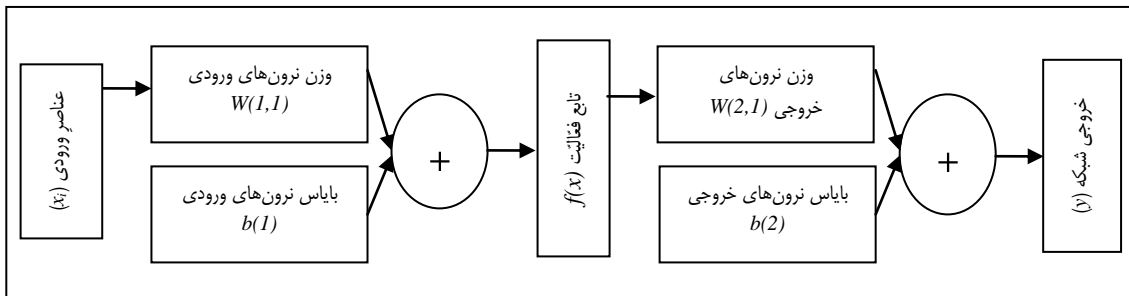
منبع: امور آب استان همدان، ۱۳۸۷: ۲۰

از آنجاکه داده‌های بلندمدت هواشناسی در تحلیل تغییرات سطح ایستابی اهمیت به‌سزایی دارد، بنابراین با استفاده از اطلاعات مربوط به سال‌های گذشته، اقدام به شبیه‌سازی روند تغییرات سطح آب زیرزمینی دشت ملایر در مقایسه با شرایط واقعی شد. برای این کار از اطلاعات هواشناسی و سطح ایستابی آب زیرزمینی استفاده شد. اطلاعات آب زیرزمینی از امور آب استان همدان و هواشناسی از ایستگاه‌های تبخیرسنجی دشت ملایر از آغاز تأسیس تا سال ۱۳۸۶ جمع‌آوری شد. این اطلاعات شامل، میانگین دمای حداکثر و میانگین دمای حداقل هوا، میانگین رطوبت نسبی حداکثر و میانگین رطوبت نسبی حداقل هوا و میانگین بارش ماهانه و میانگین تبخیر ماهانه بود. از آنجاکه در تمام روش‌های بازسازی داده‌ها امکان خطا وجود دارد، بنابراین از طول دوره‌ی آماری استفاده شد تا نیاز به بازسازی داده‌ها نباشد. ضمن آنکه بازسازی داده‌ها در نتایج شبکه‌ی عصبی مصنوعی تأثیرگذار است. مطالعات انجام‌شده نشان می‌دهد، در بیشتر موارد برای پیش‌بینی متغیرهای زمانی از مدل‌های سری‌های زمانی رگرسیون و اتورگرسیون استفاده می‌شود. این مدل‌ها از انواع مدل‌های خطی بوده که داده‌ها در آنها ثابت فرض شده و توانایی محدودی در برخورد با داده‌های غیرخطی و غیرآماري دارند (میشرا و همکاران، ۲۰۰۷). از آنجایی که نتایج زارع ایبانه و همکاران (۲۰۱۱) و طبری و همکاران (۲۰۱۰) نشان داده است که در صورت تبعیت و یا عدم تبعیت داده‌ها از توزیع نرمال، نتایج شبکه‌ی عصبی مصنوعی از اعتماد بالاتری برخوردار است، پژوهش پیش رو برای تحلیل نتایج، در چارچوب شبکه‌ی عصبی مصنوعی طراحی شده است.

برای بررسی نوسان‌های سطح ایستابی آبخوان دشت ملایر، از روش شبکه‌ی عصبی مصنوعی نوع پرسپترون چندلایه استفاده شد. این روش امکان بررسی تغییرات سفره‌ی آب زیرزمینی را در گام‌های مختلف زمانی با لحاظ اطلاعات گزینش‌شده در ورودی شبکه، فراهم می‌کند. طراحی ساختارهای مختلف شبکه‌ی عصبی با توجه به مطالعات انجام‌شده در این زمینه، از نوع پرسپترون چندلایه^۱ (MLP) با الگوریتم پس انتشارخطا^۲ (BP) مطابق شکل شماره‌ی ۲ بود.

1. Multi layer perceptron

2. Back Propagation



شکل ۲. شماتیک شبکه‌ی عصبی مورد استفاده

در شبکه‌ی عصبی چندلایه، براساس شکل شماره‌ی ۲، ارتباط بین عناصر ورودی در لایه‌ی اول (x_i) و خروجی در لایه‌ی آخر (y)، به کمک وزن‌های نرونی (W)، بایاس (b) و تابع فعالیت ($f(x)$) در لایه (های) میانی است. طراحی شبکه براساس ترکیبی از اطلاعات هواشناسی و مقادیر سطح ایستابی سفره در زمان‌های قبل، در قالب چهار ساختار متفاوت از اطلاعات در لایه‌ی ورودی انجام شده است. در هر یک از ساختارها، اطلاعات ورودی پس از پردازش، از راه خروجی نرون‌های لایه‌ی اول، به نرون‌های لایه (های) بعدی و در نهایت، در صورت قابل قبول بودن به خروجی شبکه منتقل می‌شود. در غیر این صورت با انتشار خطای محاسباتی به لایه‌های پیش، محاسبه‌ها دوباره تکرار می‌شوند. این روند تا کسب نتیجه‌ی قابل قبول ادامه می‌یابد. برای افزایش سرعت پردازش اطلاعات و عدم توقف شبکه در حداقل‌های محلی، از اطلاعات نرمال شده در بازه‌ی $[-1, +1]$ به‌عنوان ورودی شبکه استفاده شد. در ساختار اول، میانگین اطلاعات هواشناسی در طول دوره‌ی مطالعاتی و ارتفاع سطح ایستابی در یک ماه پیش به‌کارگرفته شد. در ساختار دوم و سوم، جنس نرون‌های ورودی و خروجی یکسان در نظر گرفته شد، به‌گونه‌ای که در ساختار دوم، متغیرهای ارتفاع سطح ایستابی در یک، دو، سه و چهار ماه پیش، به‌عنوان ورودی انتخاب شدند. با افزودن میانگین سطح ایستابی ماه مورد نظر و میانگین سطح ایستابی ماه پیش به اطلاعات ساختار دوم، ساختار سوم تشکیل شد. با در نظر گرفتن میانگین سطح ایستابی ماه مورد نظر، میانگین سطح ایستابی ماه پیش و اطلاعات هواشناسی، ساختار چهارم شکل گرفت. اجرای این ساختارها در نرم‌افزار تحت ویندوز Neuro Solution با قابلیت نرمال‌سازی داده‌ها انجام گرفت. از مزایای دیگر این نرم‌افزار، وجود توابع مختلف با الگوریتم‌های گوناگون در بانک نرم‌افزار است.

در این مطالعه، داده‌ها به‌صورت تصادفی و براساس تجربه‌های پژوهشگران دیگر، به دو گروه داده‌ی آموزش (۸۰ درصد) و آزمون (۲۰ درصد) دسته‌بندی شدند (کسکین و همکاران، ۲۰۰۹: ۸۵؛ کیسی و همکاران، ۲۰۰۹: ۴۴۰؛ دهقانی و همکاران، ۱۳۸۸: ۵۱۷). انتخاب تعداد نرون‌های لایه‌ی میانی، به‌صورت آزمون و خطا و استفاده از روابط تجربی است. در این مطالعه برای به‌دست‌آوردن تقریب بهتر شبکه‌ی عصبی، تعداد نرون‌های لایه‌ی میانی با استفاده از رابطه‌ی تجربی زیر تعیین شد.

$$(n_i + 1)n_m + (n_m + 1)n_0 \leq 0.1n \quad \text{رابطه‌ی (۱)}$$

در این رابطه؛ n_i : تعداد نرون در لایه‌ی ورودی؛ n_m : تعداد نرون در لایه‌ی میانی؛ n_0 : تعداد نرون در لایه‌ی خروجی و n : تعداد متغیرهای آموزشی هستند (نورانی و همکاران، ۱۳۸۶: ۴).

در اجرای شبکه‌ی عصبی مصنوعی، توابع محرک سیگموئید، تانژانت، سیگموئید خطی و تانژانت خطی استفاده شد. همچنین برای هر تابع محرک، از قوانین مختلف آموزشی همچون، لونیگ مارکوات، مومنتوم و گرادیان مزدوج استفاده شده است. برای دستیابی به ساختار بهینه، تلاش شد تا تمامی قوانین آموزشی و توابع محرک تعریف شده در محیط نرم‌افزار فوق، به شکل سعی و خطا مورد آزمون قرار گیرد. برای تعیین مقدار بهینه‌ی تعداد تکرار محاسباتی شبکه^۱ از روش سعی و خطا استفاده و خطای پیش‌بینی آن با مقادیر مختلفی از تکرارهای محاسباتی برای شبکه‌ی بهینه، محاسبه شد. گفتنی است که توابع محرک نرون‌های ورودی، میانی و خروجی یکسان در نظر گرفته شدند. در این راستا، مطالعه‌ی آدینه و همکاران (۲۰۰۹) نیز نشان داد که یکسان در نظر گرفتن توابع محرک نسبت به متفاوت بودن توابع محرک لایه‌های مختلف، منجر به نتایج بهتری می‌شود.

الگوریتم لونیگ - مارکوات، از جمله الگوریتم‌های سریع در آموزش شبکه‌ی عصبی مصنوعی است که برای بهینه‌سازی غیرخطی بر مبنای قانون حداقل مربعات عمل می‌کند (خوش تقاضا و همکاران، ۱۳۸۶). به همین ترتیب، تابع محرک سیگموئید، نوعی تابع نمایی است که رابطه بین مجموع ورودی‌های وزن دار (X_j) هر یک از نرون‌های لایه زام و

$$\text{خروجی نرون } Y_j \text{ را به کمک معادله } Y_j = \frac{1}{1 + \exp(-X_j)} \text{ برقرار می‌کند.}$$

معیارهای پذیرش نتایج پیش‌بینی شده در هر یک از ساختارهای شبکه‌ی عصبی، بر مبنای کمتر بودن خطای کمی حاصل از مقادیر محاسباتی و مقادیر مشاهداتی شامل، بیشینه‌ی ضریب تعیین (R^2)^۲، کمینه‌ی ریشه‌ی میانگین مربعات خطا^۳ (RMSE)، میانگین قدر مطلق خطا^۴ (MAE) و خطای نسبی^۵ (RE) از روابط ۲ تا ۵ بود (زارع ایبانه و همکاران، ۱۳۸۹).

$$R^2 = \frac{(\sum_{i=1}^n (y_{actual} - y_{actual}) \times (y_{forecast} - y_{forecast}))^2}{\sum_{i=1}^n (y_{actual} - y_{actual})^2 \times (y_{forecast} - y_{forecast})^2} \quad \text{رابطه‌ی ۲}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{actual_i} - y_{forecast_i}| \quad \text{رابطه‌ی ۳}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{actual_i} - y_{forecast_i})^2} \quad \text{رابطه‌ی ۴}$$

$$RE = \frac{(y_{actual} - y_{forecast})}{y_{actual}} \times 100 \quad \text{رابطه‌ی ۵}$$

که در آن: y_{actual_i} ، مقدار مشاهده شده متغیر، $y_{forecast_i}$ ، مقدار محاسبه شده متغیر و n ، تعداد داده‌ها است.

1. Epoch
2. Determination Coefficient
3. Root Mean Square Error
4. Mean absolute error
5. Relative Error

یافته‌های تحقیق

همان‌گونه که در جدول شماره‌ی ۱ نشان داده شد، تعداد چاه‌های عمیق و نیمه‌عمیق در سال ۱۳۸۲ نسبت به سال‌های پیش افزایش داشته، درحالی‌که، دشت از سال ۱۳۷۹ از نظر حفر چاه‌های جدید ممنوعه بوده است. از سویی حجم آب برداشتی از چاه‌های عمیق در سال ۱۳۸۲ نسبت به سال ۱۳۷۴، افزایشی نداشته است. این امر می‌تواند به دلایل مختلفی از جمله، افزایش تعداد چاه‌های نیمه‌عمیق و حجم آب برداشتی از آنها باشد که سبب جلوگیری از تغذیه‌ی عمقی سفره شده است. تأثیر این عامل در کاهش آب‌دهی قنات، چشمه‌ها و چاه‌های عمیق به‌واسطه‌ی افت سطح ایستابی و خشک شدن آنها مشهود است. هرچند کاهش بارندگی‌ها، بروز خشکسالی‌های پیوسته و برداشت‌های غیرمجاز از سفره نیز، در کاهش آب‌دهی سفره اثرگذار بوده است. در مجموع جدول شماره‌ی ۱ نشان می‌دهد که حجم آب زیرزمینی به جز سال ۱۳۷۴ کاهش یافته است. در بررسی دقیق‌تر، روند تغییرات سفره‌ی آب زیرزمینی دشت ملایر از سال آبی ۱۳۷۴ تا ۱۳۸۵ در جدول شماره‌ی ۲ آمده است.

جدول ۲. متوسط سالانه‌ی ارتفاع سطح آب زیرزمینی دشت ملایر

سال آبی	متوسط ارتفاع (متر)	سال آبی	متوسط ارتفاع (متر)
۱۳۷۴-۷۵	۱۶۸۸/۸۹۳	۱۳۸۰-۸۱	۱۶۷۸/۸۸۹
۱۳۷۵-۷۶	۱۶۸۸/۷۱۱	۱۳۸۱-۸۲	۱۶۷۷/۵۵
۱۳۷۶-۷۷	۱۶۸۷/۴۹۲	۱۳۸۲-۸۳	۱۶۷۶/۵۷۷
۱۳۷۷-۷۸	۱۶۸۴/۹۵۲	۱۳۸۳-۸۴	۱۶۷۵/۱۷۶
۱۳۷۸-۷۹	۱۶۸۲/۳۰۴	۱۳۸۴-۸۵	۱۶۷۴/۴۹۵
۱۳۷۹-۸۰	۱۶۸۰/۷۷۵	۱۳۸۵-۸۶	۱۶۷۴/۳۳۶
مجموع افت آب زیرزمینی		۱۴/۵۶ متر	

منبع: امور آب استان همدان، ۱۳۸۷

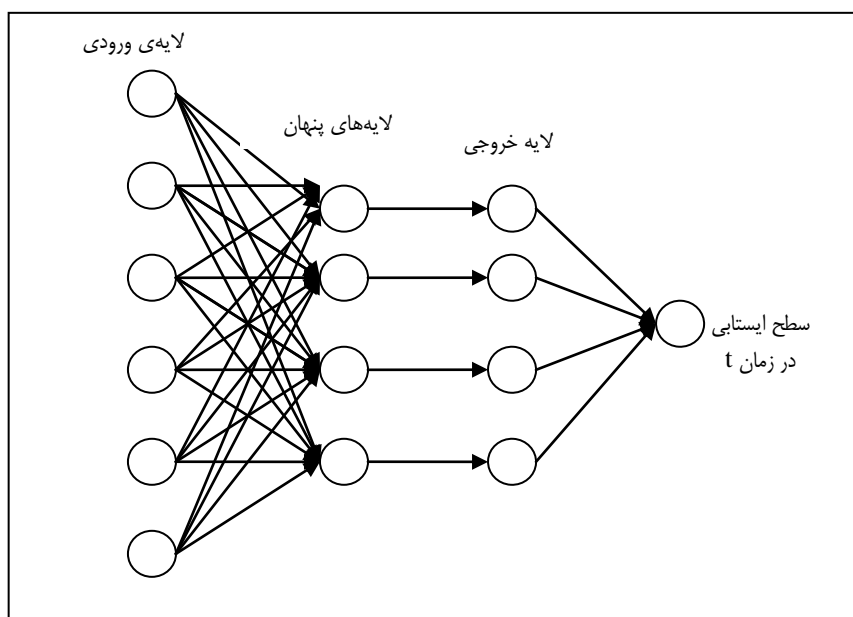
اطلاعات جدول شماره‌ی ۲ نشان‌دهنده‌ی تغییرات سطح آب زیرزمینی دشت و افت پی‌درپی آن در محدوده‌ی زمانی ۱۳۷۴ تا ۱۳۸۵، در حدود ۱۴/۶ متر برابر ۳۱۸ میلیون مترمکعب کاهش ذخایر سفره‌ی آب زیرزمینی است. بدین ترتیب سفره‌ی آب زیرزمینی طی یک دوره‌ی ۱۲ ساله، به‌طور متوسط، ۱/۲ متر در هر سال افت داشته است. در سال‌های گذشته میزان افت افزایش داشته، به‌گونه‌ای که حداکثر آن در سال آبی ۱۳۷۷-۷۸، در حدود ۳/۷۲ متر بوده است. با توجه به بروز خشکسالی و برداشت زیاد از منابع آب زیرزمینی، چنین افت ناگهانی می‌تواند نشان‌دهنده‌ی آسیب‌پذیری آبخوان در سال‌های خشک باشد. این امر لزوم پیش‌بینی دقیق‌تر سطح ایستابی دشت برای مدیریت تغذیه و تخلیه از سفره را نشان می‌دهد.

نتایج به‌کارگیری ساختارهای عصبی معرفی شده در پیش‌بینی سطح ایستابی با استفاده از شاخص‌های آماری، براساس روابط ۲ تا ۵ محاسبه و با یکدیگر مقایسه شدند. در جدول شماره‌ی ۳، بهترین نتایج به‌دست‌آمده از پیش‌بینی با استفاده از مدل شبکه‌ی عصبی چندلایه در حالات مختلف توابع محرک و تعداد نرون‌ها در لایه‌ی اول و میانی ارائه شده است.

جدول ۳. نتایج شاخص‌های آماری پیش‌بینی سطح آب زیرزمینی از شبکه‌ی عصبی مصنوعی

RE %	MAE (m)	RMSE (m)	R ²	نرون لایه‌ی میانی	تعداد لایه‌ی پنهان	تابع محرک	قانون آموزش	تعداد نرون ورودی	ساختار
۰/۰۰۵	۰/۳۴	۰/۴۴	۰/۹۸۶	۴	۲	سیگموئید	مونتوم	۷	۱
۰/۰۲۳	۰/۵۸	۰/۷۱	۰/۹۸	۴	۲	سیگموئید	لونبرگ مارکوات	۴	۲
۰/۰۰۴	۰/۲۰	۰/۴۴	۰/۹۹۲	۴	۲	سیگموئید	لونبرگ مارکوات	۶	۳
۰/۰۰۳	۰/۴۶	۰/۶۱	۰/۹۷۱	۴	۱	سیگموئید	لونبرگ مارکوات	۸	۴

بر اساس جدول شماره‌ی ۳، مدل منتخبی که کمترین میزان خطا و بیشترین ضریب تعیین را دارد، ساختار سوم بوده که دارای آرایش ۶-۴-۴-۱ است و تابع محرک آن سیگموئید با قانون آموزش لونبرگ مارکوات است. این نتیجه مؤید آموزش خوب شبکه و دقت پیش‌بینی‌هاست؛ زیرا در صورتی که شبکه در مرحله‌ی آموزش به هر دلیلی دچار فرآیند حفظ کردن شود، در ارائه‌ی نتایج با توجه به تعداد آماره‌های خطاسنجی، دقت لازم را نخواهد داشت. شکل شماره‌ی ۳، تصویر ساده‌ای از ساختار MLP شماره‌ی ۳ را به‌عنوان شبکه با ساختار بهینه نشان می‌دهد.

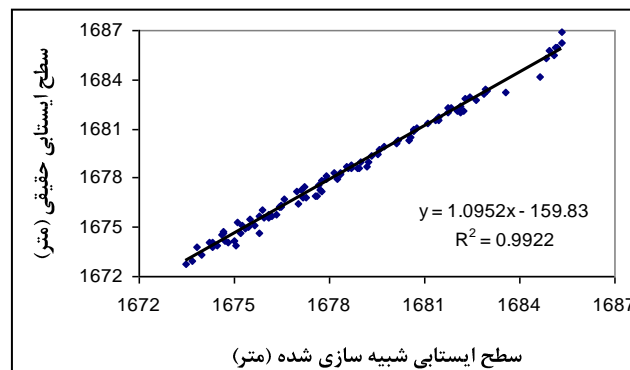


شکل ۳. ساختار پرسپترون چند لایه مورد استفاده در این مطالعه

با توجه به ساختار شبکه در شکل شماره‌ی ۳، جنس اطلاعات استفاده شده در لایه‌ی اول مشابه تابع هدف است؛ ضمن آنکه از نظر زمانی، تعداد بردارهای اطلاعات ماه‌های پیش نسبت به بردار سال‌های پیش در ورودی مدل بیشتر بود و گویای اهمیت اطلاعات جدید در پیش‌بینی نتایج است.

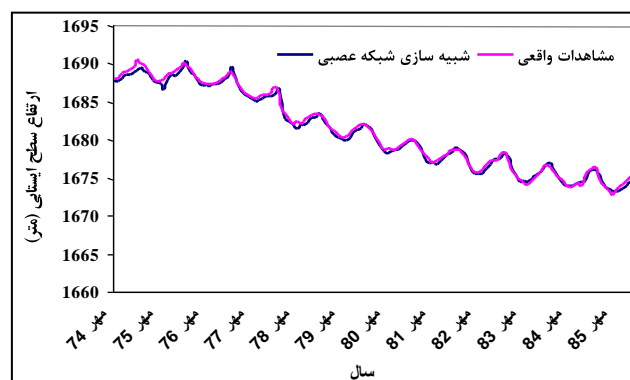
نمودار پراکندگی داده‌های پیش‌بینی‌شده و داده‌های مشاهده‌ای نسبت به خط، یک‌به‌یک در شکل شماره‌ی ۴ آورده شده است. شکل شماره‌ی ۴، ارتباط بین خروجی شبکه‌ی عصبی با مقادیر واقعی سطح آب زیرزمینی را به‌شکل معادله‌ی

درجه اول و میزان انحراف از خط نیمساز ربع اول نشان می‌دهد. گفتنی است که هرچه داده‌ها به نمودار یک‌به‌یک نزدیک‌تر باشند، نشان‌دهنده‌ی توانایی بیشتر مدل، در برآورد ارتفاع سطح ایستابی است. در این شکل نیز مشاهده می‌شود که نتایج شبکه‌ی عصبی مصنوعی پراکندگی کمی دارد.



شکل ۴. ارتباط بین مقادیر خروجی شبکه‌ی عصبی با مقادیر واقعی ارتفاع آب زیرزمینی

در شکل شماره‌ی ۵، هیدروگراف واحد آبخوان دشت و مقادیر پیش‌بینی‌شده از ساختار شماره‌ی سه شبکه‌ی عصبی نشان داده شده است. نتایج نموداری این شکل نشان می‌دهد که تفاوت چندانی بین سطح آب زیرزمینی شبیه‌سازی‌شده و مشاهدات واقعی، طی دوره‌ی مورد مطالعه وجود ندارد. این نتیجه پیش از این براساس معیارهای خطاسنجی نیز تأیید شده بود (جدول شماره‌ی ۳). براساس شکل شماره‌ی ۵، بیشتر اختلافات در فاصله‌ی زمانی مهر ۷۴ تا مهر ۷۸ بوده است که می‌تواند ناشی از خطای دستگاهی باشد. همان‌گونه که مشاهده می‌شود در اواخر دوره‌ی زمانی مورد مطالعه، از میزان خطا کاسته شده است که آن نیز می‌تواند ناشی از افزایش کیفیت دستگاه‌های رقومی نسبت به دستگاه‌های خودکار باشد.



شکل ۵. هیدروگراف مشاهدات واقعی و شبیه‌سازی شده با شبکه‌ی عصبی مصنوعی دشت ملایر

با توجه به شکل شماره‌ی ۵ درمی‌یابیم که مجموع برداشت از سفره با چاه‌های بهره‌برداری در سال‌های گذشته به‌گونه‌ی چشم‌گیری از میزان تغذیه‌ی سفره فراتر رفته است. بنابراین روزبه‌روز از ذخیره‌ی سفره کاسته می‌شود و این درحالی است که روند بهره‌برداری از چاه‌ها همان‌گونه که در جدول شماره‌ی ۱ نیز بیان شد، سال‌به‌سال روبه‌افزایش

است. میزان متوسط آب برداشتی از مهر ۷۴ تا مهر ۸۵ برابر ۳۱۹ میلیون مترمکعب، در مقابل ۳۱۳ میلیون مترمکعب برداشت شبیه‌سازی شده از شبکه‌ی عصبی است. مقایسه‌ی حجم آب برداشتی شبیه‌سازی شده با مقدار واقعی برداشت شده، نشان‌دهنده‌ی ۱/۹ درصد خطای شبکه‌ی عصبی است که در مقابل وسعت سطح مورد مطالعه، رقمی ناچیز بوده و می‌توان آن را نادیده گرفت. بنابراین نتایج شبیه‌سازی قابل اعتماد بوده و با توجه به وجود مشکلات در ثبت ارتفاع آب زیرزمینی، مدل پیشنهادی، قابلیت تکمیل آمار را در صورت وجود نقص در آنها داشته و محاسبه‌ها را نیز به صورت خودکار انجام می‌دهد.

نتیجه‌گیری

در این مطالعه پس از تعیین متغیرهای ورودی مؤثر در مدل‌سازی سطح آب زیرزمینی، روند افت سطح ایستابی دشت ملایر با استفاده از شبکه‌ی عصبی مصنوعی، نوع پرسپترون چندلایه شبیه‌سازی شد. مدل‌سازی صورت گرفته در این مطالعه، بر مبنای استفاده از حداقل اطلاعات ورودی برای شبیه‌سازی بود. در ساختار پیشنهادی، نوع اطلاعات استفاده شده در ورودی شبکه‌ی عصبی مشابه خروجی، شامل ارتفاع سطح ایستابی در زمان‌های پیش است. ضمن آنکه تابع محرک آن سیگموئید با قانون آموزش لونیگ مارکوات بود. تابع محرک مذکور در مطالعه‌ی ایزدی و همکاران (۱۳۸۶: ۶۹) نیز، به عنوان بهترین ساختار شبکه‌ی عصبی مصنوعی در پیش‌بینی سطح آب زیرزمینی گزارش شد. مقدار ۱/۹ درصد خطای کلی مربوط به شبکه‌ی عصبی مصنوعی، نشان‌دهنده‌ی قابلیت استفاده مدل در شبیه‌سازی سطح ایستابی است. به نظر می‌رسد که متغیرهای وارد شده به مدل، توانسته‌اند با دقت زیاد، الگوی نوسان‌های سطح ایستابی در سال‌های مورد مطالعه را توجیه کنند و استفاده از شبکه‌های گفته شده در شبیه‌سازی سطح ایستابی دشت ملایر، به دلیل خطای کم، موفق بوده است. مقایسه‌ی نتایج ساختار بهینه‌ی شبکه‌ی عصبی این پژوهش با مطالعه‌ی ایزدی و همکاران (۱۳۸۶: ۵۹) و اسمعیلی ورکی و همکاران (۱: ۱۳۸۳) در پیش‌بینی سطح آب زیرزمینی، مؤید عملکرد خوب شبکه در این مطالعه با ۶ متغیر ورودی نسبت به ۱۵ متغیر در گزارش ایزدی و همکاران (۱۳۸۶: ۵۹) ($R^2 = 0/937$) و ۱۰ متغیر در مطالعه‌ی اسمعیلی ورکی و همکاران (۱: ۱۳۸۳) ($R^2 = 0/90$) است. ضمن آنکه تعداد نرون‌های کمتر در ورودی شبکه‌ی عصبی مصنوعی نیز، از دید سرعت و دقت محاسبه برتر است (زارع ایبانه و همکاران، ۱۳۸۹). همچنین با توجه به انعطاف‌پذیری مدل شبکه‌ی عصبی مصنوعی، می‌توان از نتایج این پژوهش در مدیریت بهره‌برداری بهینه‌ی آبخوان دشت و پایش مداوم الگوی برداشت آبهای زیرزمینی برای تأمین آب استفاده کرد.

منابع

- Ahmadi Naddoshan, M., Soffianian, A. and Khajedin S.J., 2009, **Land Cover Mapping of Arak City Using Artificial Neural Network and Maximum Likelihood Classifiers**, Physical Geography Research Quarterly, No. 69, PP. 83-89.
- Asghari Moghaddam, A., Nadiri, A. and Fijani, E. 2006, **Ability to Study Different Models of Artificial Neural Networks to Evaluate Groundwater Water Level in the Hard Formation**, Tenth Conference of Geological Society, Tehran.
- Behroozi Khazaei, N., Amiri Chayjan, R., Tavakoli Hashjin, T. and Khoshtaghaza, M.H., 2007,

- Investigation on Important Drying Indices of Grape in Hot Air Flow by Using Artificial Neural Networks**, Agricultural Research Water, Soil & Plant in Agriculture, Vol. 7, No. 3, PP. 141-154.
- Biswas, A., 2005, **An Assessment of Future Global Water Issues**, Water Resources Development Journal, Vol. 21, No. 2, PP. 229-237.
- Coppola, E., Szidarovszky, F., Poulton, M. and Charles, E., 2003, **Artificial Neural Network Approach for Predicting Transient Water Levels in a Multi Layered Groundwater System under Variable State, Pumping, and Climate Conditions**, Hydrologic Engineering, Vol. 8, No. 6, PP. 348-360.
- Coulibaly, P., Anctil, F., Aravena, R. and Bobée, B., 2001, **Artificial Neural Network Modeling of Water Table Depth Fluctuations**, Water Resources Research, Vol. 37, No. 4, PP. 885-896.
- Daliakopoulos, I., Coulibaly, P. and Tsanis, I., 2004, **Groundwater Level Forecasting Using Artificial Neural Networks**, Journal of Hydrology, Vol. 309, No. 4, PP. 229-240.
- Dayhoff, J., 1990, **Neural Networks Principles**, Prentice Hall International, U.S.A.
- 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)**, Journal of Agriculture Science Natural Resource, Vol. 16, No. 1-b, PP. 517-528.
- Esmaili Varaki, M., Khayat khalaghi, M. and Shafiei, M., 2004, **Provide a Model for Intelligent Water Level Fluctuations Estimated Alluvial Groundwater Aquifer Using an Artificial Neural Network**, Articles First Annual Conference of Iran Water Resources Management, P. 1-11.
- Foroghi, H., Moazed, H., Kashefipour, M. and Karami, M., 2006, **Management Level Maron River Basin Aystaby Using Artificial Neural Networks**, Seventh Seminar on International River Engineering, Ahvaz.
- Hosaini, M.T., Siosemarde, A. Fathi, P. and Siosemarde, M., 2007, **Application of Artificial Neural Networks (ANN) and Multiple Regressions for Estimating Assessing the Performance of Dry Farming Wheat Yield in Ghorveh Region, Kurdistan Province**, Agricultural Research: Water and Soil and Plant, Vol. 7, No. 1, PP. 41-54.
- Izadi, A., Davari, K., Alizadeh, A. and Ghahreman, B., 2008, **Application of Panel Data Model in Predicting Groundwater Level**, Journal of Irrigation and Drainage Engineering, No. 2, PP. 133-144.
- Izadi, A., Davari, K., Alizadeh, A., Ghahreman, B. and Haghayeghi Moghaddam, S.A., 2007, **Water Table Forecasting Using Artificial Neural Network**, Journal of Irrigation and Drainage Engineering, No. 2, PP. 71-59.
- Karamuz, M., Mohammadrezapur Tabari, M. and Kerachian, R., 2004, **Integrated Exploitation of Groundwater and Surface Water Resources in Southern Tehran: Application of Genetic Algorithm Models and Artificial Neural Networks**, the First Annual Conference of Water Resources, Tehran University.
- Khalili, S.R., Davari, K. and Mousavi Baygi, M., 2008, **Monthly Precipitation Forecasting Using Artificial Neural Networks: A Case Study For Synoptic Station of Mashad**, Journal Water and Soil, Agricultural Science & Technology Ferdowsi University of Mashhad, Vol. 22, No. 1, PP. 39-99.
- Keskin, M.E., Terzi, Ö. and Taylan, D., 2009, **Estimating Daily Pan Evaporation Using**

- Adaptive Neural-based Fuzzy Inference System**, Theoretical and Applied Climatology, Vol. 98, No. 1-2, PP. 79-87.
- Kisi, O., Haktanir, T., Ardicioglu, M., Ozturk, O., Yalcin, E. and Uludag, S., 2009., **Adaptive Neuro-fuzzy Computing Technique for Suspended Sediment Estimation**, Advances in Engineering Software, Vol. 40, PP. 438-444.
- Kumar, M., Raghuwanshi, N., Singh, R., Wallender, W. and Pruitt, W., 2002, **Estimating Evapotranspiration Using Artificial Neural Networks**, Journal of Irrigation and Drainage Engineering, ASCE, Vol. 128, No. 4, PP. 224-233.
- Lallahema, S., Maniaa, J., Hania, A. and Najjarb, Y., 2005, **On the Use of Neural Networks to Evaluate Groundwater Levels in Fractured Media**, Journal of Hydrology, Vol. 307, PP. 92-111.
- Marofi, S., Tabari, H., Zare Abyaneh, H., 2010, **Predicting Spatial Distribution of Snow Water Equivalent Using Multivariate Non-linear Regression and Computational Intelligence Methods**, Water Resource Manage, Vol. 25, No. 5, PP. 1417-1435.
- Mirabbasi Najafabadi, R. and Rahnama, M.B., 2007, **Sirjan Plain Aquifer Simulation Using MODFLOW Model and Its Effects Tangoieh Dam**, Iran Water Research, No. 1, PP. 1-9.
- Mishra, A.K., Desai, V.R. and Singh, V.P., 2007, **Drought Forecasting Using a Hybrid Stochastic and Neural Network Model**, Journal of Hydrologic Engineering, Vol. 12, No. 6, PP. 626-638.
- 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, Vol. 2, No. 1, PP. 77-99.
- Norani, V., Asghari Moghaddam, A. and Nadiri, A., 2007, **Evaluation of Groundwater in the Aquifer Water Level Within the City of Tabriz with Artificial Neural Networks**, the Third National Conference of Civil Engineering, University of Tabriz.
- Sreekanth, P.D., Geethanjali, N., Sreedevi, P.D., Shakeel Ahmed, Ravi Kumar, N. and Kamala Jayanthi, P.D., 2009, **Forecasting Groundwater Level Using Artificial Neural Networks**, Current Science, Vol. 96, No. 7, PP. 933- 939.
- Tahmasebi, A.R. and Zomorrodian, S.M.A., 2004, **Estimation of Soil Liquefaction Potential Using Artificial Neural Network**, Second National Student Conference on Water and Soil Resources.
- Tasaloti, B., 2003. **The Estimated Groundwater Levels Using Artificial Neural Networks and Mudflow**, MS. Thesis, Faculty of Agriculture, Tarbiat Modares University.
- Water Affairs of Hamedan Province, 2008, **Groundwater Resources Report Hamedan Province**.
- Zare Abyaneh, H., Bayat Varkeshi, M., Marofi, S. and Amiri Chayjan, R., 2010, **Evaluation of Artificial Neural Network and Adaptive Neuro Fuzzy Inference System in Decreasing of Reference Evapotranspiration Parameters**, Journal of Water and Soil. Vol. 24, No. 2, pp. 297-305.
- Zare Abyaneh, H., Bayat Varkeshi, M., and Daneshkare Arasteh, P., 2011, **Forecasting Nitrate Concentration in Groundwater using Artificial Neural Network and Linear Regression Models**, International Agrophysics, Vol. 25, No. 2, PP. 187-192.
- Zare abyaneh, H., Yazdani, V. and Azhdari, KH., 2009, **Comparative Study of Four Meteorological Drought Index Based on Relative Yield of Rain Fed Wheat in Hamedan Province**, Physical Geography Research Quarterly, No. 69, PP. 35-49.

Simulation of Malayer Plain Groundwater Level Based on Weather Data Using Artificial Neural Network

Zare Abyaneh H. *

Associate Prof., Dep. of Irrigation Engineering, Agricultural Faculty of BU Ali Sina University,
Hamedan

Bayat Varkeshi M.

M.A. Student, Department of Irrigation Engineering, BU Ali Sina University, Hamedan

Marofi S.

Associate Prof., Dep. of Irrigation Engineering, Agricultural Faculty of BU Ali Sina University,
Hamedan

Ildromi A.R.

Assistant Prof. Dep. of Irrigation Engineering, Agricultural Faculty of Malayer University

Received: 27/02/2010 Accepted: 31/07/2011

Extended Abstract

Introduction

Prediction of groundwater level is necessary for supply management and utilization of water. Groundwater Fluctuations is influenced by many variables. One of the most appropriate methods, the study of groundwater, is using computer models. Thus, understanding of ground water variation mechanism and its prediction is necessary for awareness of available groundwater. In this regard, artificial neural network models, due to lack of understanding of the physical nature of the problem in modeling a nonlinear system are capable. Studies in Iran show that, in spite of the importance of groundwater level prediction and intelligent neural network capabilities, few studies regarding water table simulations using artificial neural networks has been done so far.

According to the necessities expressed purpose of this study is establish the relation between of groundwater level fluctuations associated with effective artificial neural network, in order to simulate and quantify associated water table fluctuations as an independent variable with various meteorological factors and hydro geology of Malayer plain.

Methodology

Malayer plain groundwater table located in Hamedan province was selected to evaluate the efficiency of artificial neural network for predicting water table changes. The collected data were based on similar studies and the effects of data on water table. They were used as inputs for artificial neural network on four structures. First data structure was including average maximum air temperature, minimum air temperature, maximum relative humidity, minimum relative humidity and evaporation monthly scale and height of water table of last month. In the second structure, water table data for every month from 1, 2, 3 and 4 previous months were used as inputs. Average of water table of month and average of monthly water table plus the input of second structure were used as input for third structure. The inputs of fourth structure were mean of water table, data of last month and monthly meteorological data. Different patterns of artificial neural network were used on the basis of the four structure using Neurosolution

* E-mail: zareabyaneh@gmail.com

software to estimate the water table.

Results and Discussion

The results showed that using water table parameters of previous years had the higher precision than other parameters on the prediction of water table. In other words, the results of the second and third data structures in which the input data kind was the same as output one better than two other structures were evaluated. In total, third structure topology 1-4-4-6 shows 6 neurons in the network input and middle layer 4 neurons is a suitable structure with 1.9 percent error compared with the actual values. The research showed that hydrograph of the plain during 1995 to 2006 was descending with the average of 1.2 meter annual loss and in total study period 14.5 m loss has experienced. Implementation of optimal neural network model consists of 6 neurons in the first layer of information; 1.18 m loss water table can be estimated. In other words, neural network with 1.9 percent average error rate was able to estimate withdraw from the table during studies 313 million m^3 versus 319 million m^3 of the actual harvested. Root Mean Square Error (RMSE) in the neural network optimal model 1-4-4-6 pattern based on Levenberg Marquet rule learning and the sigmoid function against table level actual changes was obtained 0.44 m with coefficient of determination 0.99 respectively. Error values resulting from the implementation of the proposed neural network model compared to other structures and similar studies have been done a very good accuracy.

Conclusion

Totally, it could be inferred that such variables entered the model structure based on structure of the number 3, the model and prediction water table changes is successful.

Comparison of the optimum structure of neural network study with Izadi et al (2007) and Esmail verki et al (2004) in predicting groundwater levels, confirming the good performance of the network in this study with six input parameters to 15 parameters in the report and Izadi et al (2007) ($R^2 = 0.937$) and 10 parameters in the study of sciatic Ismail et al (2004) ($R^2 = 0.90$) is. Meanwhile the number of input neurons in neural network under the terms of the speed and accuracy is more preferable (Abyaneh Zare et al, 2010).

The suitable model and carefully downtrend governing table, using artificial neural networks for decision and management plain, as appropriate tool with speed and accuracy in predicting groundwater level in Malayer plain is recommended.

Keywords: Groundwater Modeling, Simulation, Artificial Neural Network, MLP, Malayer Plain.