

شبیه‌سازی تراز سطح آب زیرزمینی با استفاده از مدل حداقل مربعات ماشین بردار پشتیبان و مقایسه آن با شبکه عصبی مصنوعی و رگرسیون خطی چند متغیره

سامی قوردویی میلان^۱، ناصر آریا آذر^۲، سامان جوادی^{۳*}، بابک رازدار^۴

۱- کارشناس ارشد مهندسی منابع آب، گروه مهندسی آبیاری و زهکشی، پردیس ابوریحان، دانشگاه تهران، تهران

۲- کارشناس ارشد آبیاری و زهکشی، گروه مهندسی آبیاری و زهکشی، دانشگاه تبریز، تبریز

۳- استادیار، گروه مهندسی آبیاری و زهکشی، پردیس ابوریحان، دانشگاه تهران، تهران

۴- استادیار، گروه پایش منابع آب، پژوهشکده محیط زیست جهاد دانشگاهی، گیلان، رشت

نویسنده مسئول: javadis@ut.ac.ir

تاریخ پذیرش مقاله: ۱۳۹۸/۰۷/۲۱

تاریخ دریافت مقاله: ۱۳۹۸/۱۰/۱۶

چکیده

امروزه برای اجرای سناریوهای مدیریتی، انتخاب راهکارهای عملی مناسب در جهت مدیریت منابع آب زیرزمینی و همچنین تعیین نرخ برداشت از آب زیرزمینی نیازمند ساخت مدل ساده‌شده‌ای از آبخوان و شبیه‌سازی آن می‌باشد. نخستین اقدام در جهت مدیریت آب زیرزمینی، شبیه‌سازی تراز سطح آب زیرزمینی و سپس پیش‌بینی آن با توجه به عوامل مؤثر بر تراز سطح آب زیرزمینی است. از این‌رو در تحقیق حاضر، سعی شده است از سه مدل مختلف داده مینا جهت شبیه‌سازی تراز سطح آب زیرزمینی استفاده گردد، تا کارایی مدل حداقل مربعات بردار پشتیبان نسبت به مدل رگرسیونی خطی چند متغیره و شبکه عصبی مقایسه گردد. رویکرد حاضر در آبخوان امامزاده جعفر در استان کهگیلویه و بویراحمد انجام شد. بدین منظور الگوهای مختلفی با ترکیب داده‌های ورودی تراز سطح آب زیرزمینی در ماه قبل، بارش، دما، برداشت از آبخوان و تبخیر در ماه حاضر برای برآورد مقدار تراز سطح آب زیرزمینی در انتهای ماه بررسی تدوین گردید. طول دوره موردنظر ۲۰ ساله شامل ۲۴۰ داده و در گام ماهانه از سال ۱۳۷۶ تا ۱۳۹۵ در نظر گرفته شد. از حدود ۷۵ درصد داده‌ها برای آموزش مدل و ۲۵ درصد جهت آزمون مدل‌ها و انتخاب الگوی برتر از بین الگوهای مختلف استفاده گردید. نتایج نشان داد که هر سه مدل بکار رفته با دقت قابل قبولی قادر به شبیه‌سازی تراز سطح آب زیرزمینی هستند. از بین مدل‌ها، مدل حداقل مربعات ماشین بردار پشتیبان با معیارهای ارزیابی RMSE، MAPE و ضریب تبیین برای بخش صحت سنجی به ترتیب برابر ۰/۶۱ متر، ۰/۰۶۹ و ۰/۹۹ برای الگوی با ترکیب پارامترهای تراز سطح آب زیرزمینی در انتهای ماه قبل، برداشت از آبخوان و بارندگی ماه موجود به‌عنوان مدل برتر انتخاب گردید در نهایت از مدل‌های مذکور می‌توان به‌عنوان جایگزین مدل‌های عددی در جهت مدیریت و پیش‌بینی تراز سطح آب زیرزمینی استفاده کرد. واژه‌های کلیدی: آب زیرزمینی، آبخوان امامزاده جعفر، شبیه‌سازی آب زیرزمینی، LS-SVM، MLR.

۱- مقدمه

تعیین نرخ مناسب برداشت از آب زیرزمینی، طراحی مدل ساده‌شده‌ای از آبخوان و شبیه‌سازی آن نیاز است. از سوی دیگر مدل کردن سفره‌های آب زیرزمینی به‌منظور شبیه‌سازی و

امروزه برای اجرای سناریوهای مدیریتی، انتخاب راهکارهای عملی مناسب در جهت مدیریت منابع آب زیرزمینی و همچنین

پیش‌بینی سطح ایستابی از منظر تصمیم‌گیری‌های مدیریتی، مصارف بهینه کشاورزی و تعیین پتانسیل آب‌های زیرزمینی باکیفیت از اهمیت بالایی برخوردار است. اگرچه مدل‌های فیزیکی و ریاضی ابزار اساسی و دقیقی جهت تعیین متغیرهای هیدروژئولوژیکی و درک فرآیندهای صورت گرفته در یک سیستم می‌باشند، اما دارای محدودیت‌های هزینه‌ای و زمانی هستند (رجائی و همکاران، ۲۰۱۹). جدا از این دو مورد، این مدل‌ها نیازمند اطلاعات دقیق و متنوع ورودی هستند که نیازمند حجم زیاد محاسبات و زمان طولانی برای ساخت و اجرای مدل می‌باشد. از سوی دیگر، در اغلب موارد ضروری است مدل شبیه‌سازی با مدل‌هایی چون بهینه‌سازی به جهت مدیریت بهینه از منابع آب زیرزمینی ترکیب شوند که تلفیق مدل‌های فیزیکی و عددی این تبادل را دشوار و گاهی ناممکن می‌کند. با توجه به توضیحات و مشکلات موجود در استفاده از مدل‌های مذکور در برخی موارد لازم است از مدل‌های هوشمند و غیرخطی به جای مدل‌های عددی و فیزیکی استفاده کرد (رجائی و همکاران، ۲۰۱۹).

در چند سال اخیر استفاده از مدل‌هایی که بدون نیاز به اطلاعات زیادی قادر به شبیه‌سازی رفتار یک سیستم هستند؛ رواج بیشتری پیدا کرده است (عینی و همکاران، ۱۳۹۷). ارزش این مدل‌ها زمانی نمایان می‌شود که برای به دست آوردن برخی اطاعات یک سیستم نیاز به هزینه و زمان زیادی است. بنابراین برای چنین سیستم‌هایی استفاده از مدل‌های غیر مفهومی و غیر آزمایشگاهی توصیه می‌شود. از انواع مدل‌های مذکور می‌توان به مدل‌های شبکه‌های عصبی، سیستم استنتاج فازی، برنامه‌ریزی بیان ژن، شبکه بیزین و... اشاره کرد که در مدیریت آب اعم از آب سطحی، آب زیرزمینی، سیستم آب شهری، ریسک و شکست‌پذیری سامانه‌های منابع آبی، بررسی و ارزیابی کیفی منابع آبی و بهره‌برداری تلفیقی استفاده شده است (اکامپو دوگو و همکاران، ۲۰۰۶؛ نورانی و همکاران، ۲۰۰۸؛ زیود و همکاران، ۲۰۱۶؛ بنی حبیب و همکاران، ۲۰۱۸؛ قوردویی میلان و

همکاران، ۲۰۱۸؛ روزبهنی و همکاران، ۲۰۱۸؛ ندیری و همکاران، ۲۰۱۹). سعیدی رضوی و عرب (۱۳۹۷) با استفاده از مدل‌های منطق فازی، شبکه عصبی و سری زمانی به پیش‌بینی سطح آب زیرزمینی دشت عجب‌شیر پرداختند نتایج حاصل نشان داد که مدل منطق فازی می‌تواند تراز سطح ایستابی را با دقت قابل قبولی پیش‌بینی نماید. باباعلی و دهقانی (۱۳۹۶) در پژوهشی با مقایسه مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی در پیش‌بینی سطح آب زیرزمینی نورآباد به نتیجه رسیدند که دو مدل مورد استفاده با دقت قابل قبولی توانسته به تخمین تراز سطح ایستابی بپردازد، در مجموع نتایج نشان داد که مدل شبکه عصبی موجک توانایی بالایی در تخمین مقادیر کمینه و بیشینه تراز سطح ایستابی دارد.

شبکه‌های عصبی یکی از پرکاربردترین و رایج‌ترین مدل‌های هوش مصنوعی است که کارایی مناسب آن در شبیه‌سازی‌های مختلف اثبات شده است. به عنوان نمونه در زمینه شبیه‌سازی تراز سطح آب زیرزمینی می‌توان به تحقیقات محققان داخلی مختلفی پرداخت که نتایج تحقیقات آن‌ها حاکی از عملکرد مناسب شبکه عصبی مصنوعی است (گویی و همکاران، ۱۳۹۷، نیکبخت، ۱۳۹۵). در سطح بین‌المللی نیز تحقیقات زیادی در جهت ارزیابی شبکه عصبی مصنوعی بر روی تراز سطح آب زیرزمینی انجام گردیده که نتایج آن‌ها حاکی از توانایی این مدل شبیه‌سازی آب زیرزمینی بود است (چن و همکاران، ۲۰۰۹؛ چانگ و همکاران، ۲۰۱۵؛ امامقلی زاده و همکاران، ۲۰۱۴؛ نورانی و همکاران، ۲۰۱۱). در تحقیقی میرازی و ناظمی (۱۳۹۰)، کارکرد شبکه عصبی مصنوعی را با سامانه‌های هوشمند استنتاج فازی عصبی و برنامه‌ریزی ژنتیک برای تخمین تراز سطح آب زیرزمینی دشت شبستر را مورد ارزیابی قرار داد. نتایج تحقیق نشان داد که هر سه مدل توانایی بالایی در تخمین مقدار تراز سطح آب زیرزمینی را دارا هستند. در تحقیق دیگری به مقایسه مدل شبکه عصبی مصنوعی و مدل رگرسیونی چند متغیره برای پیش‌بینی تراز سطح آب زیرزمینی پرداخته‌اند.

یکی از مباحث مهم در استفاده از مدل‌های هوش مصنوعی در شبیه‌سازی انتخاب پارامترهای ورودی مؤثر جهت تخمین مناسب مقدار خروجی مطلوب است. لذا در جدول ۱ در محققان زیادی پارامترهای مختلف ورودی جهت تخمین مناسب رفتار تراز سطح آب زیرزمینی با مدل‌های مختلفی در جهت شبیه‌سازی تراز سطح آب زیرزمینی بکار برده‌اند. به‌علاوه با توجه به جدول مذکور مدل‌های مختلفی جهت شبیه‌سازی مناسب مورد استفاده قرار گرفته است. در اکثر تحقیقات معمولاً چند مدل هوش مصنوعی بکار رفته‌اند و مورد ارزیابی قرار گرفته‌اند که در هیچ‌یک از تحقیقات از مدل حداقل مربعات بردار ماشین پشتیبان استفاده نشده است. در اکثر آن‌ها گام زمانی در نظر گرفته شده عمدتاً به صورت ماهانه بود. بنابراین با توجه به وضعیت آمار و اطلاعات در ایران و برای کاهش عدم قطعیت مناسب به نظر می‌رسد از داده‌های ماهانه برای شبیه‌سازی در نظر گرفته شود.

ایشان ورودی‌های مختلفی از جمله تبادل آبخوان و رودخانه، دمای محیط و بارش را به عنوان پارامترهای تأثیرگذار در خروجی مدل در نظر گرفتند. در نهایت نیز نتایج نشان داد که مدل شبکه عصبی دقت قابل قبولی نسبت به مدل رگرسیونی چند متغیره دارد (ساهو و جها، ۲۰۱۳). مدل حداقل مربعات ماشین بردار پشتیبان که در سال ۱۹۹۵ مطرح گردید (کورتس و واپنیک، ۱۹۹۵)، با وجود اینکه در زمینه‌های زیادی کارایی آن مورد ارزیابی قرار گرفته است؛ اما در مطالعات آب‌های زیرزمینی کمتر مورد استفاده قرار گرفته است. رضایی و همکاران (۱۳۹۳) از مدل LS-SVM در جهت تعیین شبکه پایش کمی آب زیرزمینی استفاده کردند. در نهایت با توجه به تابع تقریب بهینه، از بین ۶۳ چاه مشاهداتی وجود ۴۲ چاه مشاهداتی به منظور پایش مکانی مناسب در منطقه دشت رامهرمز مشخص شد. با این وجود مدل مذکور جهت شبیه‌سازی تراز سطح آب زیرزمینی مورد استفاده قرار نگرفته است.

جدول ۱- برخی تحقیقات انجام شده در زمینه شبیه‌سازی تراز سطح آب زیرزمینی با پارامترهای ورودی مختلف.

محقق	محدوده مطالعاتی	متغیرهای ورودی*	مدل مورد استفاده	گام زمانی
Coulibaly et al. (2001)	Gondo aquifer, Burkina Faso	GWL- P- T	ANN	ماهانه
Krishna et al. (2008)	Andhra Pradesh state, India	GWL, R, ET	ANN	ماهانه
Jalalkamali et al. (2011)	Kerman, Iran	GWL, T, R	ANFIS, ANN	ماهانه
Sreekanth et al. (2011)	Maheshwaram watershed, India	GWL, R, E, T, H	ANN, ANFIS	ماهانه
Juan et al. (2015)	Qinghai-Tibet Plateau, China	GWL, T, P	ANN	روزانه
Khaki et al. (2015)	Langat basin, Malaysia	R, H, E, min and max T	ANFIS, ANN	ماهانه
Yoon et al. (2016)	South Korea	GWL, P	SVM, ANN	روزانه
Nie et al. (2017)	Jilin Province, China	P, E, T	SVM, ANN	ماهانه
Wen et al. (2017)	Northwestern China	GWL, P, E, T	Wavelet-ANN, ANN	ماهانه
Yu et al. (2018)	Northwest China	GWL, ET, Q	Wavelet-ANN, Wavelet-SVR	ماهانه
Guzman et al. (2018)	Mississippi delta region, USA	GWL, P, ET	SVR, ANN	روزانه
Kardan moghaddam et al (2019)	Birjand, Iran	GWL, P, E, T, Q	ANN, BN	ماهانه
پژوهش حاضر (۲۰۲۰)	Imam-Zadeh Jafar aquifer	GWL, P, T, Q, E	LS-SVM, ANN, MLR	ماهانه


*عبارات اختصاری بکار رفته، GWL: تراز سطح آب زیرزمینی، T: دما، P: بارندگی، Q: مقدار تخلیه، E: مقدار تبخیر، ET: مقدار تبخیر - تعرق، H: رطوبت

۲- مواد و روش‌ها

۲-۲. محدوده مطالعاتی و داده‌های مورد استفاده

محدود مطالعاتی امامزاده جعفر در جنوب غربی ایران و در استان کهگیلویه و بویر احمد قرار گرفته است. این محدوده بین طول جغرافیایی ۵۰° - ۵۱° تا ۲۱° - ۲۱° شرقی و عرض جغرافیایی ۳۰° - ۳۰° تا ۲۷° - ۲۷° شمالی گسترده شده است. به دلیل ارتفاعات فراوانی که در منطقه مطالعاتی وجود دارند، میانگین سالانه بارندگی حدود ۶۰۰ میلی‌متر است. موقعیت آبخوان امامزاده جعفر در شکل ۱ قابل مشاهده است. این آبخوان دارای مساحت کم در حدود $۵۴/۱$ کیلومترمربع است. باوجود مساحت کم و علیرغم بارش زیاد در منطقه قسمت عمده

نیازهای آبی توسط آب زیرزمینی تأمین می‌گردد بنابراین به دلیل برداشت زیاد و بارندگی کمتر در سال‌های اخیر موجب افت آب زیرزمینی شده است (گزارش‌ها بیلان آب زیرزمینی محدوده مطالعاتی امامزاده جعفر، ۱۳۹۳). با توجه به فیزیک منطقه شمال و شمال شرق آبخوان را ارتفاعات تشکیل داده است. جهت جریان آب زیرزمینی از قسمت شمال آبخوان به سمت جنوب آبخوان می‌باشد. حدود ۲۱ چاه مشاهداتی در جهت قرائت سطح آب زیرزمینی در نقاط مختلف آبخوان حفر شده‌اند. از این تعداد حدود ۱۸ چاه مشاهداتی که اطلاعات کامل‌تری داشتند در به دست آوردن هیدرو گراف آبخوان مورد استفاده قرار گرفت



شکل ۱- محدوده مطالعاتی آبخوان امامزاده جعفر.

خطی چند متغیره نیز ۷۵ درصد داده‌ها از ابتدای دوره به‌عنوان داده‌های بخش آموزش انتخاب گردید. در ادامه به بررسی برخی خصوصیات پارامترهای ورودی پرداخته شده است که در جدول ۲ قابل مشاهده است. با توجه به جدول مذکور برای هر متغیر ۲۴۰ گام زمانی در نظر گرفته شده است. مقدار تراز سطح آب زیرزمینی در آبخوان مذکور از ۶۶۹ متر تا ۶۲۹ متر متغیر است. بیشترین برداشت ماهانه از آبخوان حدود ۴/۵ میلیون مترمکعب در ماه برآورد شده است. این آبخوان از وضعیت بارندگی مناسبی برخوردار نیست (با اینکه در ارتفاعات بارش مناسبی رخ می دهد) به‌طوری که بیشترین بارندگی در طول دوره موردنظر ۴۳۹ میلی‌متر در ماه بوده است و به‌طور متوسط ماهانه ۳۲ میلی‌متر بارندگی مشاهده می‌گردد. متوسط دمای ماهانه در طول دوره موردنظر ۲۳/۴ درجه سانتی‌گراد است.

جدول ۲- خصوصیات آماری پارامترها ورودی.

پارامتر	تعداد رکورد	کمترین	میانگین	بیشترین	انحراف معیار	ضریب تغییرات	چولگی
تراز سطح آب زیرزمینی (m)	۲۴۰	۶۲۹	۶۵۳	۶۶۹/۴	۱۰	۰/۰۱۵	-۰/۲۶
چاه بهره‌برداری (MM3)	۲۴۰	۰/۶۸	۲/۲۶	۴/۳۲	۰/۹	۰/۴	۰/۳۳
بارش (mm)	۲۴۰	۰	۳۲	۴۳۹	۵۹	۱/۸۳	۳/۱
دما (C)	۲۴۰	۸/۱	۲۳/۴	۳۶/۸	۸/۵	۰/۳۶	-۰/۰۸
تبخیر	۲۴۰	۴۲	۴۷۹	۸۹۵۳	۹۵۵/۶	۲	۷/۶

متغیر خروجی دارند. پارامترهای تراز سطح آب زیرزمینی و بارندگی همبستگی مثبتی با متغیر خروجی دارد اما بقیه پارامترهای ورودی همبستگی منفی با متغیر مستقل دارند. با این وجود انتظار می‌رود در الگویی که متغیرهای تراز آب زیرزمینی، برداشت آب زیرزمینی و بارش باشد از بیشترین دقت برخوردار گردد.

جدول ۳- مقایسه همبستگی بین پارامتر ورودی و خروجی.

پارامتر	GWL(n-1)	W(n)	R(n)	T(n)	E(n)
GWL(n)	۰/۹۲	-۰/۴۰	۰/۳۰	-۰/۰۹	-۰/۰۷

انتخاب بهترین ترکیب از بین متغیرهای ورودی نیازمند تدوین الگوهای مختلف ورودی و سپس اعمال هر یک از آن‌ها و

برای شبیه‌سازی تراز سطح آب زیرزمینی با مدل‌های مذکور نیاز به اطلاعات مشاهداتی مستقل بود که مقدار تراز سطح آب زیرزمینی در انتهای ماه را تخمین بزند. بنابراین با توجه به تحقیقات گذشته از متغیرهای تراز سطح آب زیرزمینی ماه قبل $(GWL_{(n-1)})$ ، بارش $(R_{(n)})$ ، برداشت از آب زیرزمینی $(W_{(n)})$ ، دما $(T_{(n)})$ و تبخیر $(E_{(n)})$ به‌صورت ماهانه به‌عنوان ورودی انتخاب گردید. با مشخص بودن پارامترهای ورودی و گام زمانی ماهانه، آمار و اطلاعات داده‌های مشاهداتی استخراج گردید. از مهر سال ۱۳۷۶ تا شهریور سال ۱۳۹۵ دوره شبیه‌سازی استفاده گردید. حدود ۷۵ درصد داده‌ها برای آموزش و مابقی برای صحت سنجی مدل در نظر گرفته شد. با توجه به ماهیت مدل شبکه عصبی و حداقل مربعات ماشین بردار پشتیبان داده‌های آموزش و آزمون به‌صورت تصادفی انتخاب گردید. در مدل رگرسیون

قبل از هرگونه مدل‌سازی، ضریب همبستگی بین داده‌های مستقل و وابسته محاسبه گردید (جدول ۳). مقدار ضریب همبستگی بین ۱ تا -۱ متغیر است. هر چقدر ضریب همبستگی به یک نزدیک باشد نشان دهنده همبستگی قوی مثبت و هر چقدر این مقدار به -۱ نزدیک باشد دارای همبستگی قوی اما منفی بین متغیر مستقل و وابسته است. برای تراز سطح آب زیرزمینی ماه قبل و تراز سطح آب زیرزمینی این ماه است. این همبستگی نشان می‌دهد که مقدار خروجی بیشترین تأثیر را از تراز سطح آب زیرزمینی در ماه قبلش می‌گیرد؛ پس انتظار می‌رود در هر الگویی که تراز سطح آب زیرزمینی در ماه قبل وجود داشته باشد از دقت قابل قبولی جهت تخمین مقدار خروجی برخوردار باشد. پارامترهای دما و تبخیر کمترین همبستگی را با

در نهایت ارزیابی خروجی هریک از الگوها است. این ارزیابی به کمک معیارهای ارزیابی صورت می‌گیرد که در ادامه شرح داده شده است. از این رو با توجه به ورودی‌های مختلف حدود ۱۵ الگوی مختلف که ورودی‌های دومتغیره، سه، چهار و پنج متغیره دارند؛ در نظر گرفته شده است که در جدول ۴ قابل مشاهده است. الگوها از A تا P با توجه به تعداد ورودی‌ها از کمترین به بیشترین نام‌گذاری شده‌اند و نتایج نیز با توجه به نام‌گذاری هر الگو در قسمت نتایج آورده شده است.

جدول ۴- الگوهای مختلف ورودی برای تخمین تراز سطح آب زیرزمینی در انتهای ماه موجود.

الگو	متغیرهای ورودی					تعداد متغیر ورودی	متغیر خروجی
	E(n)	T(n)	R(n)	W(n)	GWL(n-1)		
A	x	x	x	✓	✓	✓✓	
B	x	✓	x	x	✓	✓✓	
C	✓	x	x	x	✓	✓✓	
D	x	x	✓	x	✓	✓✓	
E	x	x	✓	✓	x	✓✓	
F	x	✓	x	✓	✓	✓✓✓	
G	x	x	✓	✓	✓	✓✓✓	
H	x	✓	✓	x	✓	✓✓✓	GWL(n)
J	x	✓	✓	✓	x	✓✓✓	
K	✓	✓	x	✓	x	✓✓✓	
L	x	✓	✓	✓	✓	✓✓✓✓	
M	✓	✓	✓	x	✓	✓✓✓✓	
N	✓	✓	✓	✓	x	✓✓✓✓	
O	✓	✓	x	✓	✓	✓✓✓✓	
P	✓	✓	✓	✓	✓	✓✓✓✓✓	

با اعمال و استفاده از روش حداقل مربعات (LST) رابطه (۱) به صورت رابطه (۲) درمی‌آید.

$$Y_i = b_0 + b_1 X_{1,i} + b_2 X_{2,i} + \dots + b_k X_{k,i} + e_i$$

که در آن b_0 ، b_1 و... مقادیر ضرایب رگرسیونی هستند. e_i مقدار باقیمانده خطای رگرسیونی است که قابل صرف نظر کردن است؛ بنابراین رابطه رگرسیونی چند متغیره به صورت رابطه (۳) قابل تعریف کردن است.

$$\hat{Y} = b_0 + b_1 X_{1,i} + b_2 X_{2,i} + \dots + b_k X_{k,i}$$

مدل MLR یکی از ساده‌ترین مدل‌های پیش‌بینی متغیرهای هیدرولوژیکی است که در این تحقیق برای شبیه‌سازی تراز سطح آب زیرزمینی به کاررفته است لذا متغیرهای تراز سطح آب زیرزمینی در انتهای ماه قبل، بارش، دما، تبخیر و برداشت از چاه‌ها در این ماه به عنوان متغیر مستقل و تراز سطح آب زیرزمینی در انتهای این ماه نیز به عنوان پارامتر مستقل در مدل MLR است.

هر یک از این الگوها به صورت مجزا بر روی هر مدل اعمال می‌گردد و در نهایت توسط معیارهای ارزیابی در نظر گرفته شده مورد ارزیابی قرار گرفتند در ادامه به توضیح مدل‌های مورد استفاده در این پژوهش پرداخته شده است.

۲-۲- رگرسیون خطی چند متغیره (MLR)

این روش ارتباط دو یا چند متغیر مستقل (پیش‌بینی کننده) با یک متغیره وابسته (متغیر پیش‌بینی شونده) برای یک سری داده‌های زمانی مشاهداتی بیان می‌کند که شکل کلی آن به مانند رابطه (۱) است (یو و همکاران، ۲۰۱۸)


$$Y_i = \beta_0 + \beta_1 X_{1,i} + \beta_2 X_{2,i} + \dots + \beta_k X_{k,i} + \varepsilon_i$$

که در آن Y_i مقدار متغیر وابسته در مشاهده i است. $X_{1,i}$ ، $X_{2,i}$ و... مقادیر متغیرهای مستقل در مشاهدات i است. ε_i یک متغیر تصادفی که به صورت توزیع نرمال انتخاب می‌گردد.

۳-۲- شبکه عصبی مصنوعی (ANN)

می‌گردد و در نهایت توسط تابعی در لایه میانی به لایه خروجی منتقل می‌گردد. لایه خروجی بعد از اعمال و وزن و بایاس در نهایت نیز توسط تابع دیگر به مقدار خروجی منتقل می‌گردد. مدل شبکه عصبی نیز توسط الگوریتم‌های مختلفی آموزش می‌بینید تا مقادیر خطای بین مشاهداتی و خروجی را به حداقل برسانند. در قسمت نتایج تعداد نرون مطلوب برای لایه میانی و الگوریتم مناسب جهت آموزش شبکه عصبی آورده شده است. در نهایت نیز همه الگوهای تدوین شده توسط شبکه عصبی شبیه‌سازی می‌شوند و با معیارهای مختلف مورد ارزیابی قرار می‌گیرند.

مدل‌های شبکه عصبی مصنوعی، سال‌های زیادی به امید رسیدن به عملکردی مشابه کارایی انسان در زمینه سرعت و شناخت تصویر مورد مطالعه قرار گرفته است. این مدل‌ها یک سیستم پردازش اطلاعات با توزیع موازی هستند که عملکردی مشابه شبکه‌های عصبی زیستی مانند مغز انسان دارند (لیپمن، ۱۹۸۷). شکل ۲ تصویر شماتیکی از یک شبکه عصبی مصنوعی را برای پژوهش حاضر نشان می‌دهد. این شبکه دارای چهار ورودی مختلف، یک لایه میانی و یک لایه خروجی تشکیل شده است. هر ورودی وزنی به خود می‌گیرد و سپس با بایاس جمع



شکل ۲- نمونه شبکه عصبی طراحی شده برای تحقیق حاضر.

که در آن T, b, W به ترتیب بیانگر وزن‌ها، بایاس تابع رگرسیون و نشان‌دهنده ترانزاده هستند. $\varphi(x)$ ترسیم غیرخطی ورودی ها در فضای ویژگی با ابعاد بالا است. رگرسیونی غیرخطی مذکور توسط رابطه بهینه‌سازی (۵) قابل حل است.

$$\min j(w, e) = \frac{1}{2} W^T W + \frac{1}{2} \gamma \sum_{k=1}^N e_k^2$$

با توجه به محدودیت‌ها داریم:

$$y_k = W^T \varphi(x) + b + e_k, \quad k = 1, 2, \dots, N$$

γ پارامتر تنظیم‌کننده بخش خطا است و e میزان خطا را نشان می‌دهد. مقدار γ همواره تابع تقریب را کنترل می‌کنند بنابراین مقدار آن اگر بزرگ باشد خطای بیشتری ایجاد می‌کند. حل با استفاده از شکل لاگرانژی از تابع هدف اصلی:

$$L(w, b, e, \alpha) = j(w, e) - \sum_{i=1}^N \alpha_i \{W^T \varphi(x) + b + e_k - y_k\}$$

۴-۲- حداقل مربعات ماشین بردار پشتیبان (LS-SVM)

این روش ابتدا تحت عنوان ماشین بردار پشتیبان مطرح گردید (سویکنس و همکاران، ۱۹۹۵). مدل ماشین بردار پشتیبان روش مناسبی به منظور طبقه‌بندی و پیش‌بینی در علوم مختلف استفاده گردید. اما در سال ۱۹۹۹ مدل حداقل مربعات ماشین بردار پشتیبان را معرفی کردند [۱۶]. این مدل محدودیت‌های یکسانی با روش SVM کلاسیک دارد؛ اما نسبت به این روش پیچیدگی محاسبات کمتر اما دقت و سرعت بالاتری دارد. چارچوب مدل LS-SVM به صورت زیر است. مجموعه داده‌های آموزشی مانند $\{x_k, y_k\}_{k=1}^N$ که داده ورودی آن شامل $x_k \in R^N$ و داده‌های خروجی $y_k \in R$ معرفی می‌گردد. بنابراین تابع رگرسیون غیرخطی در فضای وزنی اولیه به صورت رابطه (۴) خواهد شد [۳۴]:

$$y(x) = W^T \varphi(x) + b \quad (4)$$

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{x_o - x_p}{x_o} \right|}{n} \times 100 \quad (13)$$

که در آن X_o و X_p به ترتیب مقدار داده‌های واقعی و شبیه‌سازی شده هستند.

۳- نتایج و بحث

در این پژوهش از سه مدل مختلف MLR، ANN و LS-SVM در جهت شبیه‌سازی تراز سطح آب زیرزمینی استفاده گردید. پژوهش مذکور بر روی داده‌های آبخوان امامزاده جعفر گچساران انجام گردید. از ۲۱ چاه مشاهداتی موجود در آبخوان حدود ۱۸ چاه پس از بازسازی برخی از آن‌ها، به کمک تیسن بندی هیدرو گراف واحد آبخوان استخراج گردید سپس مورد شبیه‌سازی قرار گرفت. از داده‌های سال‌های ۱۳۷۶ تا ۱۳۹۵ در گام ماهانه استفاده شد که در ادامه به تفکیک به نتایج خروجی هر یک از مدل‌ها پرداخته شده است.

۳-۱- مدل رگرسیونی چند متغیره

با توجه به توضیحات داد شده در مورد مدل رگرسیون خطی چند متغیره، هر یک از الگوهای تدوین شده با استفاده از نرم‌افزار SPSS انجام گردید. بنابراین بهترین رابطه رگرسیونی بین پارامترهای مستقل و وابسته برای هر الگو استخراج گردید. جدول ۵، نتایج معیارهای ارزیابی را برای هر یک از الگوهای مختلف را نشان می‌دهد. با استفاده از داده‌های قسمت آموزش مدل رگرسیونی خطی چند متغیره استخراج گردید و در ادامه با داده‌های بخش آزمون، مدل طراحی شده مورد آزمون قرار گرفت. از بین الگوهای مختلف، الگوی M با ورودی‌های تراز سطح آب زیرزمینی ماه قبل، باش، دما و تبخیر این ماه بهترین دقت را برای بخش آزمون داشته است لذا به‌عنوان الگوی برتر در مدل رگرسیونی خطی چند متغیره انتخاب گردید. از بین الگوهای تدوین شده بدترین الگو نیز، الگوی N بود که در آن از پارامتر مستقل تراز سطح آب زیرزمینی ماه قبل استفاده نشده است.

که در آن α_i ضریب لاگرانژ است. بر اساس شرایط کان - تاکر (Karush - Kuhn- Tucker) مدل LS-SVM به‌منظور تابع تقریب به‌صورت رابطه (۸) نوشته می‌شود (گسنل و همکاران، ۲۰۰۲).

$$y(\chi) = \sum_{k=1}^N \alpha_k K(\chi, \chi_k) + b \quad (8)$$

$K(\chi, \chi_k)$ تابع کرنل نامیده می‌شود و مقدار آن طبق رابطه (۹) محاسبه می‌گردد (بوزردوم و همکاران، ۲۰۱۳)

$$K(\chi, \chi_k) = \exp\left(-\frac{\|\chi - \chi_k\|^2}{\sigma^2}\right) \quad (9)$$

در این تحقیق از تابع کرنل پایه شعاعی برای حل استفاده شده است.

۲-۵- تجزیه، تحلیل و ارزیابی داده‌ها

استفاده از داده‌های خام برای ورودی به مدل‌هایی چون شبکه عصبی مصنوعی و LS-SVM موجب کاهش دقت و کارایی آن می‌شود؛ بنابراین داده‌ها قبل ورود به مدل توسط رابطه (۱۰) ابتدا نرمال‌سازی می‌شوند و سپس اعداد نرمال‌شده در خروجی به حالت قبل برمی‌گردند.

$$x_i = 0.8 \left[\frac{x - x_{min}}{x_{max} - x_{min}} \right] + 0.1 \quad (10)$$

که در آن x_i ، x_{min} و x_{max} به ترتیب مقدار نرمال شده، مقدار واقعی، کمترین داده و بیشترین داده در طور دوره موردنظر است. برای ارزیابی الگوها معیارهای ارزیابی برای سنجش الگوها از ضریب تبیین (R^2)، خطای جذر میانگین مربعات نرمال شده (RMSE) و درصد میانگین مطلق خطا (MAPE) استفاده شده است. هرچقدر مقدار ضریب تبیین به عدد یک نزدیک‌تر باشد، RMSE و MAPE به صفر نزدیک‌تر باشند، کارایی مدل موردنظر نیز بهتر است.

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_p - x_o)^2}{\sum_{i=1}^n (x_o - \bar{x}_o)^2} \quad (11)$$


$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_p - x_o)^2}{n}} \quad (12)$$

جدول ۵- نتایج ارزیابی الگوهای مختلف برای مدل MLR

الگو	R ²		MAPE		RMSE	
	Test	Train	Test	Train	Test	Train
A	۰/۹۶	۰/۹۹	۰/۱۰	۰/۰۷۴	۱/۰۵	۰/۷۵
B	۰/۹۵	۰/۹۹	۰/۱۱	۰/۰۸۵	۱/۱۰	۰/۷۸
C	۰/۹۹	۰/۹۹	۰/۱۱	۰/۰۸۹	۱/۰۰	۰/۷۹
D	۰/۹۹	۰/۹۹	۶/۹۳	۰/۰۶۰	۴۴/۰	۰/۶۳
E	۰/۱۰۶	۰/۹۹	۲/۴۰	۰/۰۶۷	۱۷/۳	۰/۶۳
F	۰/۹۵	۰/۹۹	۰/۲۳	۰/۰۷۹	۱/۷۷	۰/۷۹
G	۰/۹۷	۰/۹۹	۰/۷۸۹	۰/۰۶۵	۵/۱۴	۰/۶۲
H	۰/۹۷	۰/۹۹	۰/۱۱۷	۰/۰۶۵	۱/۰۱	۰/۶۲
J	۰/۲۳	۰/۹۹	۱/۹۲	۰/۰۶۴	۱۳/۸	۰/۶۲
K	۰/۱۸	۰/۱۲	۱/۹۳	۰/۸۶	۱۳/۸	۶/۸۷
L	۰/۹۷	۰/۹۹	۰/۰۹۹	۰/۰۶۵	۱/۰۱	۰/۶۲
M	۰/۹۷	۰/۹۹	۰/۰۹۶	۰/۰۶۶	۰/۹۵	۰/۶۳
N	۰/۱۲	۰/۲۵	۱/۹۱	۰/۸۶	۱۳/۷	۶/۸۷
O	۰/۸۱	۰/۹۹	۰/۳۲	۰/۰۶۸	۳/۴۰	۰/۶۲

در نهایت نیز رابطه رگرسیونی برای الگوی منتخب به‌مانند رابطه
(۱۴) است.
مقادیر شبه سازی شده و مشاهداتی الگوی منتخب در شکل ۳
قابل مشاهده است. مشاهده می‌گردد که مدل رگرسیونی منتخب
به‌خوبی توانسته مقدار رفتار تراز سطح آب زیرزمینی در انتهای
ماه موجود را تخمین بزند.


$$GWL(n) = 0.997 \times (GWL_{(n-1)}) + 0.007 \times (R_n) - 0.005 \times (T_n) - 0.00001 \times (E_n) + 1.431 \quad (14)$$



شکل ۳- مقادیر شبیه‌سازی شده و مشاهده شده بخش آزمون برای الگوی برتر (M) (در مدل MLR).

شبیه‌سازی توسط مدل MLR با الگوی مناسب انتخاب شده برای
کل دوره مورد نظر مورد شبیه‌سازی قرار گرفت که نمودار سری
زمانی بین مقادیر شبیه‌سازی شده و مشاهداتی در شکل ۴ آمده
است.

در نتیجه می توان با استفاده از الگوی منتخب در مدل MLR تا توجه به اطلاعات تراز سطح آب زیرزمینی ماه قبل، بارش، دما حدودی تراز سطح آب زیرزمینی در انتهای ماه موردنظر را با و تبخیر این ماه تا حدودی تخمین زد.



شکل ۴- سری زمانی مقادیر شبیه سازی شده و واقعی برای دوره موردنظر (۱۳۷۵-۱۳۹۵).

۳-۳- مدل شبکه عصبی مصنوعی

شبکه عصبی مصنوعی دیگر مدل بکار رفته در پژوهش حاضر بود که قبل ارائه نتایج هر یک از الگوها نیاز به مشخص کردن معماری بکار رفته است. برخی خصوصیات به کار رفته در معماری شبکه عصبی در جدول ۶ آمده است. برای همه الگوهای موردنظر معماری های مختلفی در نظر گرفته شد در نهایت معماری مناسب برای همه ورودی ها مطابق جدول مذکور به دست آمد.

جدول ۶- خصوصیات معماری در نظر گرفته شده برای مدل ANN.

معماری شبکه عصبی مصنوعی	بازه در نظر گرفته شده برای هر یک از خصوصیات	موارد انتخاب شده بر اساس معیارهای ارزیابی
داده های آموزش (درصد)	۷۵-۷۰ (به صورت تصادفی)	۷۵
تعداد لایه های در نظر گرفته شده	۴-۲	۲
تعداد نرون های لایه های میانی	۲۰-۵	۱۲-۱۰
تابع انتقال لایه میانی	تابع سیگموئید - تابع هایپربولیک	تابع سیگموئید
تابع انتقالی لایه خروجی	تابع سیگموئید- تابع همانی	تابع همانی
الگوریتم آموزش شبکه	LM- BN	LM
تعداد تکرار در هر اجرا	۱۰۰۰	۱۰۰۰

جدول ۷ نتایج ارزیابی هر یک از الگوهای به کار رفته در مدل ANN را نشان می دهد. در الگوهای که تراز سطح آب زیرزمینی ماه قبل به عنوان ورودی وجود داشت مدل با دقت بهتری شبیه سازی نموده است. اما در الگوهای که فاقد ورودی تراز سطح آب زیرزمینی ماه قبل بود مدل با دقت کمتری قادر به تخمین رفتار آب زیرزمینی بوده است به عنوان نمونه می توان به


الگوهای E و N اشاره کرد که به ترتیب دارای پارامترهای ورودی W, R, T, E و W, R, T بود. الگوی برتر انتخاب شده با توجه به تخمین مقدار خروجی دخیل بودند بنابراین الگوی P با RMSE، MAPE و R^2 به ترتیب برابر با ۰/۶، ۰/۰۶۸، ۰/۹۹۶ و ۰/۹۹۶. بهترین الگو برای مدل شبکه عصبی انتخاب گردید.

جدول ۷- نتایج ارزیابی الگوهای مختلف برای مدل ANN.


الگو	NRMSE		MAPE		R^2	
	Test	Train	Test	Train	Test	Train
A	۰/۸۶	۰/۸	۰/۰۸۳	۰/۰۸۸	۰/۹۹	۰/۹۹
B	۰/۸۵	۰/۷۸	۰/۰۷	۰/۰۸۴	۰/۹۹	۰/۹۹
C	۰/۹۲	۰/۸۸	۰/۰۸۸	۰/۰۸۹	۰/۹۸	۰/۹۹
D	۰/۷۳	۰/۶۹	۰/۰۷۴	۰/۰۸۲	۰/۹۹	۰/۹۹
E	۹/۶۵	۸/۴۳	۰/۹۷	۰/۹۸	۰/۶۲	۰/۶۸
F	۱/۲	۰/۸۵	۰/۰۸۵	۰/۱۳۰	۰/۹۹	۰/۹۹
G	۰/۶۲	۰/۶۸	۰/۰۷۶	۰/۰۷۶۹	۰/۹۹	۰/۹۹
H	۱/۷۵	۰/۷۱	۰/۰۷۳	۰/۰۷۵	۰/۹۸	۰/۹۹
J	۰/۷۹	۰/۷۸	۰/۰۷۴	۰/۰۷۶	۰/۹۹	۰/۹۹
K	۰/۷۰	۰/۷۵	۰/۰۷۷	۰/۰۷۵	۰/۹۹	۰/۹۹
L	۰/۹۸	۰/۸۳	۰/۰۸۴	۰/۰۹۲	۰/۹۹	۰/۹۹
M	۰/۷۸	۰/۶۷	۰/۰۸۹	۰/۰۷۵	۰/۹۹	۰/۹۹
N	۶/۳	۱۲/۵۶	۳/۴۵	۱/۸۱	۰/۶۸	۰/۸۸
O	۰/۸۳	۰/۸۶	۰/۰۷۵	۰/۰۷۸	۰/۹۸	۰/۹۹
P	۰/۶۰	۰/۵۸	۰/۰۶۴	۰/۰۶۸	۰/۹۹	۰/۹۹

به خط ۴۵ همخوانی مناسبی دارند. در نهایت کل داده‌های موردنظر به وسیله شبکه عصبی انتخاب شده مورد شبیه‌سازی قرار گرفت تا سری زمانی شبیه‌سازی شده و واقعی برای کل دوره موردنظر به دست آید نتیجه این عمل در شکل ۶ قابل مشاهده است. مشاهده می‌گردد که ANN توانسته تخمین مناسبی از تراز سطح آب زیرزمینی برای انتهای همراه در طول دوره داشته باشد.

نمودار سری زمانی داده‌های مشاهداتی و شبیه‌سازی شده برای قسمت آزمون در ادامه و در شکل ۵ آمده است. با توجه به اینکه داده‌های آموزش و آزمون به صورت تصادفی انتخاب شده‌اند مقادیر شبیه‌سازی شده به درستی تخمین زده شده‌اند. به صورت بصری مشخص است که مدل ANN به خوبی توانسته مقدار تراز سطح آب زیرزمینی در انتهای ماه را تخمین بزند. همچنین با توجه به شکل مذکور مقادیر مشاهداتی و شبیه‌سازی شده نسبت



شکل ۵- مقادیر شبیه‌سازی شده و مشاهده شده بخش آزمون برای الگوی برتر P (در مدل ANN).



شکل ۶- سری زمانی مقادیر شبیه‌سازی شده و واقعی مدل ANN برای دوره موردنظر (۱۳۷۶-۱۳۹۵).

برداشت آب زیرزمینی و بارندگی ماه موجود قادر به تخمین تراز سطح آب زیرزمینی انتهای ماه موجود شد. در حالت واقعی نیز وجود عوامل تخلیه و تغذیه بر تراز سطح آب زیرزمینی تأثیر بسزایی دارد. دو پارامتر برداشت از آب زیرزمینی و بارش تأثیر مستقیم بر تراز سطح آب زیرزمینی دارند ضمن اینکه یکی از مهم‌ترین منبع تخلیه آبخوان چاه برداشت است و مهم‌ترین منبع تغذیه نیز مقدار بارندگی است، تأثیر بسزایی بر تراز انتهای ماه داشتند که در این مدل به‌خوبی مشخص گردید. دو پارامتر دما و تبخیر تأثیر مستقیمی بر منابع آب زیرزمینی ندارند اما

۳-۴- مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM)
در بخش دوم این پژوهش مقدمه‌ای در مورد LS-SVM ارائه شد و در جدول ۸ مقادیر پارامترهای بهینه استفاده شده در این مدل شرح داده شده است. مناسب‌ترین الگو از بین الگوهای موجود در این مدل الگوی G است که دارای بیشترین دقت نسبت به سایر الگوها با RMSE برابر ۰/۶۱ متر، MAPE برابر ۰/۰۶۹ درصد و ضریب تبیین ۰/۹۹۵ برای قسمت آزمون است (جدول ۹). مدل LS-SVM برخلاف دو مدل دیگر الگوی با سه پارامتر ورودی که شامل تراز سطح آب زیرزمینی ماه قبل،

وجود دما و تبخیر باعث کاهش بارندگی‌ها و یا افزایش نیاز آبی می‌گردد که این خود موجب کاهش تغذیه به آبخوان و افزایش برداشت از آبخوان می‌شود که تأثیر غیرمستقیمی دارد. البته به‌مانند دو مدل دیگر در الگوهای که تراز سطح آب زیرزمینی ماه قبل به‌عنوان ورودی موجود نیست مدل کمترین دقت را داشته است.

جدول ۸- پارامترهای بهینه مدل برتر LS-SVM


مدل	نحوه انتخاب داده‌ها برای آموزش	تابع کرنل	σ^2	γ
LS-SVM	۷۵ درصد (تصادفی)	RBF	۷۳۲۷	۴۱۶۱۷

جدول ۹- نتایج ارزیابی الگوهای مختلف برای مدل LS-SVM

الگو	RMSE		MAPE		R^2	
	Test	Train	Test	Train	Test	Train
A	۰/۷۸	۰/۷۵	۰/۰۷۹	۰/۰۸	۰/۹۹	۰/۹۹
B	۰/۶۷	۰/۸۱	۰/۰۷	۰/۰۸۴	۰/۹۹	۰/۹۹
C	۰/۷۹	۰/۷۸	۰/۰۸۲	۰/۰۸۳	۰/۹۹	۰/۹۹
D	۰/۶۸۴	۰/۶۸	۰/۰۶۹	۰/۰۷۴	۰/۹۹	۰/۹۹
E	۶/۲۹	۶	۰/۷۴	۰/۷۶۶	۰/۶۴	۰/۶۱
F	۰/۸	۱/۴۸	۰/۰۷۹	۰/۱۰۰	۰/۹۹	۰/۹۹
G	۰/۶۶	۰/۶۱	۰/۰۶۶	۰/۰۶۹	۰/۹۹	۰/۹۹
H	۰/۶۳	۱/۸۳	۰/۰۶۷	۰/۰۸۱	۰/۹۷	۰/۹۹
J	۰/۷۱	۰/۷۲	۰/۰۷۴	۰/۰۷۵	۰/۹۹	۰/۹۹
K	۰/۷۸	۰/۷۳	۰/۰۷۶	۰/۰۸۰	۰/۹۹	۰/۹۹
L	۰/۶۴	۰/۹	۰/۰۸	۰/۰۹۵	۰/۹۹	۰/۹۹
M	۰/۶۹	۰/۷۶	۰/۰۸۴	۰/۰۷	۰/۹۹	۰/۹۹
N	۱۵/۱۶	۷/۲	۰/۴۵	۰/۷۶	۰/۵۲	۰/۸۵
O	۰/۷۹	۰/۷۳	۰/۰۷۹	۰/۰۷۸	۰/۹۹	۰/۹۹
P	۰/۶۹	۰/۸۱	۰/۰۷۰	۰/۰۸۴	۰/۹۹	۰/۹۹

شکل (۷) مقادیر شبیه‌سازی شده و واقعی بخش آزمون را برای الگوی منتخب نشان می‌دهد. مشخص است که اختلاف بین مقادیر شبیه‌سازی شده و مشاهداتی بسیار ناچیز و در حد چند سانتی‌متر است که این نکته توانایی بالای مدل LS-SVM در شبیه‌سازی تراز سطح آب زیرزمینی در انتهای ماه را نشان می‌دهد. به‌علاوه توزیع داده‌های مشاهداتی در مقابل شبیه‌سازی نشان می‌دهد که نسبت به خط ۴۵ درجه در نظر گرفته‌شده هم‌راستا هستند و مقادیر مشاهداتی و شبیه‌سازی شده بسیار نزدیک به هم هستند. درنهایت نیز به مشابه دو مدل دیگر الگوی برتر انتخاب‌شده در این مدل شبیه‌سازی برای کل داده‌ها انجام گرفت که در شکل (۸) قابل مشاهده است. مشخص است که سری زمانی برای دو سری داده مشاهداتی و شبیه‌سازی شده بسیار ناچیز و مدل LS-SVM به‌خوبی توانسته مقدار تراز سطح آب زیرزمینی در انتهای ماه موردنظر را تخمین بزند. درنهایت با توجه به جدول قبلی و نمودار سری زمانی مشخص است که مدل مذکور قادر به شبیه‌سازی تراز سطح آب زیرزمینی با الگوهای مختلف را دارا است. با توجه به وضعیت آبخوان مذکور که در طول دوره موردنظر کاهش زیادی داشته است می‌توان

سناریوهای مدیریتی در جهت بهبود وضع آبخوان اعمال کرد. با توجه به اینکه دقت آن‌ها کمتر از تابع شعاعی بود از آوردن در این تحقیق همچنین از دیگر توابع کرنل نیز استفاده شد اما نتایج آن‌ها چشم‌پوشی شد.



شکل ۷- مقادیر شبیه‌سازی‌شده و مشاهده‌شده بخش آزمون برای الگوی برتر (در مدل LS-SVM).



شکل ۸- سری زمانی مقادیر شبیه‌سازی‌شده و واقعی مدل LS-SVM برای دوره موردنظر (۱۳۷۶-۱۳۹۵).

باشد باید تعداد ورودی‌های بیشتر در نظر گرفته شود. البته در تحقیقات گذشته نیز به‌صورت تجربی اثبات‌شده است مدل ANN ورودی‌هایی بیشتر دو متغیر را بهتر شبیه‌سازی می‌کند و چه‌بسا ورودی‌های تأثیرگذار بیشتری وجود داشته باشد و در نتیجه تخمین بهتری ایجاد می‌شود. مدل LS-SVM الگوی با سه پارامتر ورودی شامل تراز ماه قبل، برداشت و بارش این ماه را به‌عنوان مناسب‌ترین الگوی ورودی در جهت تخمین مقدار خروجی تشخیص داد. ذکر این نکته ضروری است که مهم‌ترین پارامتر ورودی تراز سطح آب زیرزمینی ماه قبل بود که تأثیر

الگوهای به‌کاررفته در هر سه مدل نتایج متفاوتی داشتند. در مدل MLR بهترین الگو، چهار پارامتر ورودی داشت که نشان داد هر چه پارامترهای ورودی بیشتر باشد؛ دقت تخمین مقدار خروجی بیشتر می‌شود. در این مدل نکته جالب، نبود مقدار برداشت به‌عنوان پارامتر ورودی بود که یکی از مؤثرترین عوامل تأثیرگذار بر تراز سطح آب زیرزمینی محسوب می‌شود که می‌توان این نکته را به‌عنوان نقطه‌ضعف مدل رگرسیونی دانست. اما در مدل ANN الگویی که پنج ورودی داشت دقت مناسب‌تری داشت و نشان داد برای آنکه مدل از دقت مناسبی برخوردار

بسیاری در خروجی مدل داشت و چنانچه در الگوهایی که از آن به عنوان ورودی استفاده نمی شد دقت مدل به طور قابل توجهی کاهش پیدا می کرد. این الگو این نشان می دهد که تراز هر ماه تا چه حد به تراز ماه قبل وابسته است برخلاف جریان رودخانه ها که همبستگی قوی بین جریان رودخانه این ماه با ماه قبل وجود ندارد. در نهایت نیز مدل برتر را می توان مدل LS-SVM انتخاب کرد که دارای بیشترین دقت نسبت به دو مدل قبلی بود به طوری که علاوه بر برتری دقت در الگوی G، دقت قابل قبول تری در الگوی M نسبت به نتایج MLR داشت طوری که مقدار RMSE برابر ۰/۷۶، MAPE برابر ۰/۰۷ و ضریب تبیین ۰/۹۳ به دست آمد در حالی که این مقادیر برای MLR به ترتیب برابر ۰/۹۵، ۰/۰۹۶ و ۰/۹۷ بود.

۴- نتیجه گیری

با توجه به اهمیت و نقش تراز آب زیرزمینی در ارزیابی وضعیت کمی آبخوان جهت تصمیم گیری از دیدگاه مدیران منابع آب، لذا پیش بینی این پارامتر جهت ارزیابی وضعیت منابع آب زیرزمینی یک منطقه حائز اهمیت است. بدین منظور در این تحقیق از سه مدل رگرسیون خطی چند متغیره، شبکه عصبی مصنوعی و روش حداقل مربعات ماشین بردار پشتیبان جهت شبیه سازی تراز آب زیرزمینی استفاده گردید. با توجه به نقش پارامترهای مختلف به عنوان پیش بینی کننده بر تراز آب زیرزمینی، لذا پارامترهای مختلف در آبخوان ارزیابی و بر اساس مطالعات مختلف انجام شده پارامترهای تراز آب زیرزمینی، بارش، دما، تبخیر و برداشت ماهانه انتخاب گردید. به منظور تعیین بهترین الگوی جهت ورود پارامترهای پیش بینی تراز آب زیرزمینی، الگوهای مختلف پیش بینی کننده ها در هر سه مدل مورد ارزیابی قرار گرفت. بر این اساس در مدل رگرسیونی خطی چند متغیره، الگوی تراز سطح آب زیرزمینی ماه قبل، بارش، دما

و تبخیر این ماه بهترین دقت را برای بخش آزمون نشان داد. در مدل شبکه عصبی مصنوعی ترکیب تمام پارامترهای ورودی بیشترین دقت نشان داد تا این موضوع که این مدل در سامانه هایی با ترکیبات مختلف و پیچیده نتایج بهتری را شبیه سازی می نماید تأیید شود. مدل LS-SVM که به عنوان یک مدل جدید، برای شبیه سازی تراز آب زیرزمینی در این پژوهش پیشنهاد شده بود بر خلاف دو مدل قبلی، تعداد پارامتر کمتری را جهت شبیه سازی تراز آب زیرزمینی استفاده گردید. سه پارامتر تراز آب زیرزمینی ماه قبل، برداشت آب زیرزمینی و بارندگی ماه موجود به عنوان پارامترهای منتخب جهت شبیه سازی انتخاب گردید. نتایج این تحقیق نشان داد که در مدل های مختلف، الگوهای ورودی متفاوتی از نظر پارامترهای ورودی جهت شبیه سازی تراز آب زیرزمینی با دقت مناسب انتخاب می گردد. همچنین نتایج نشان داد که هر سه مدل مورد استفاده، رویکرد متفاوتی برای شبیه سازی ارائه دادند. در نهایت نیز بیشترین دقت از بین این مدل ها در مدل LS-SVM است که دارای میانگین مجذور خطای ۰/۶۶ متر در حالت آموزش و ۰/۶۱ متر در حالت آزمون است. همچنین میزان ضریب تبیین در این مدل نیز ۹۹ درصد است. با توجه به دقت مناسب روش LS-SVM در شبیه سازی تراز آب زیرزمینی نتایج حاکی از تابع کرنل RBF، با واریانس ۷۳۲۷ و گامای ۴۱۶۱۷ برای حالت بهینه است. نتایج این مطالعه نشان داد که استفاده از رویکرد LS-SVM جهت شبیه سازی تراز آب زیرزمینی و ارزیابی پارامترهای ورودی جهت شبیه سازی می تواند علاوه بر کاهش تعداد پارامترهای ورودی دقت مناسبی را جهت شبیه سازی نشان دهد. این موضوع این امکان را به تصمیم گیران بخش آب می دهد تا با استفاده از این مدل شبیه سازی تراز آبخوان را جهت بهبود وضعیت فعلی انجام دهند.

- Chang, J., Wang, G. and Mao, T., 2015. Simulation and prediction of suprapermafrost groundwater level variation in response to climate change using a neural network model. *Journal of Hydrology*, 529, pp.1211-1220.
- Chang, J., Wang, G. and Mao, T., 2015. Simulation and prediction of suprapermafrost groundwater level variation in response to climate change using a neural network model. *Journal of Hydrology*, 529, pp.1211-1220.
- Chen, L. H., Chen, C. T., & Pan, Y. G. 2009. Groundwater level prediction using SOM-RBFN multisite model. *Journal of Hydrologic Engineering*, 15(8), 624-631.
- Cortes, C. and Vapnik, V., 1995. Support-vector networks. *Machine learning*, 20(3), pp.273-297.
- Coulibaly, P., Anctil, F., Aravena, R. and Bobée, B., 2001. Artificial neural network modeling of water table depth fluctuations. *Water resources research*, 37(4), pp.885-896.
- Emamgholizadeh, S., Moslemi, K. and Karami, G., 2014. Prediction the groundwater level of bastam plain (Iran) by artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS). *Water resources management*, 28(15), pp.5433-5446.
- Gestel, T.V., Suykens, J.A., Lanckriet, G., Lambrechts, A., Moor, B.D. and Vandewalle, J., 2002. Bayesian framework for least-squares support vector machine classifiers, Gaussian processes, and kernel Fisher discriminant analysis. *Neural computation*, 14(5), pp.1115-1147.
- Guzman, S.M., Paz, J.O., Tagert, M.L.M. and Mercer, A.E., 2019. Evaluation of Seasonally Classified Inputs for the Prediction of Daily Groundwater Levels: NARX Networks Vs Support Vector Machines. *Environmental Modeling & Assessment*, 24(2), pp.223-234.
- Haykin, S., 1994. *Neural networks: a comprehensive foundation*. Prentice Hall PTR.
- Jalalkamali, A., Sedghi, H. and Manshouri, M., 2010. Monthly groundwater level prediction using ANN and neuro-fuzzy models: a case study on Kerman plain, Iran. *Journal of hydroinformatics*, 13(4), pp.867-876.
- Khaki, M., Yusoff, I. and Islami, N., 2015. Simulation of groundwater level through artificial
- منابع
باباعلی، ح ر، دهقانی، ر. ۱۳۹۶. مقایسه مدل های شبکه عصبی موجک و شبکه عصبی مصنوعی در پیش بینی سطح آب زیرزمینی، مجله هیدروژئولوژی، ۲ (۲)، ۹۶-۱۰۸.
- رضای، ا، خاشعی سیوکی، ع، و، شهیدی، ع. ۱۳۹۳. طراحی شبکه پایش سطح آب زیرزمینی با استفاده از مدل حداقل مربعات ماشین بردار پشتیبان (LS)، (SVM) تحقیقات آب و خاک ایران، ۴۵(۴)، ۳۸۹-۳۹۶.
- سعیدی رضوی، ب، عرب، ع ر. ۱۳۹۷. پیش بینی سطح آب زیرزمینی با استفاده از مدل های منطق فازی، شبکه عصبی و سری زمانی، مجله هیدروژئولوژی، ۲ (۲)، ۶۱-۸۳.
- گویلی، س، جوادی، س، بنی حبیب، م، ا، و، ثانی خانی، ه. ۱۳۹۷. مقایسه مدل های هوشمند در پیش بینی نوسانات تراز سطح آب دریاچه زریوار با در نظر گیری تراز آب زیرزمینی. مجله تحقیقات منابع آب ایران، ۴(۳)، ۲۶۸-۲۷۷.
- عینی، م ر، جوادی، س، دلاور، م، دارند، م. ۱۳۹۷. شناخت دقت پایگاه داده ماهواره ای بارش PERSIANN-CDR در شبیه سازی رواناب مدل SWAT بر روی پهنه حوضه دریاچه مهارلو. پژوهشهای جغرافیای طبیعی ۵۰ (۳)، ۵۶۳-۵۷۶.
- ندیری، عطاالله، طاهرخانی، ز، و، صادقی، ف. ۱۳۹۶. پیش بینی سطح آب زیرزمینی دشت بستان آباد با استفاده از ترکیب نظارت شده مدل های هوش مصنوعی. مجله تحقیقات منابع آب ایران، ۱۳(۳)، ۴۳-۵۵.
- نیکبخت، ج، و، نوری، س، ۱۳۹۵. پیش بینی تراز سطح آب زیرزمینی با کمک شبکه های موجک-عصبی (مطالعه موردی: دشت مراغه-آذربایجان شرقی)، مجله هیدروژئولوژی، ۱(۱)، ۲۹-۴۳.
- Banihabib ME, Mousavi-Mirkalaei P. Extended linear and non-linear auto-regressive models for forecasting the urban water consumption of a fast-growing city in an arid region. *Sustainable Cities and Society*. 2019 Jul 1; 48:101585.
- Bouzerdoum, M., Mellit, A. and Pavan, A.M., 2013. A hybrid model (SARIMA-SVM) for short-term power forecasting of a small-scale grid-connected photovoltaic plant. *Solar Energy*, 98, pp.226-235.
- Cawley, G.C. and Talbot, N.L., 2002. Improved sparse least-squares support vector machines. *Neurocomputing*, 48(1-4), pp.1025-1031.

- Rajaei, T., Ebrahimi, H., & Nourani, V. (2019). A review of the artificial intelligence methods in groundwater level modeling. *Journal of hydrology*.
- Roobahani, A., Ebrahimi, E., & Banihabib, M. E. 2018. A framework for ground water management based on bayesian network and MCDM techniques. *Water resources management*, 32(15), 4985-5005.
- Sahoo S, Jha MK. Groundwater-level prediction using multiple linear regression and artificial neural network techniques: a comparative assessment. *Hydrogeology Journal*. 2013 Dec 1;21(8):1865-87.
- Sreekanth, P.D., Sreedevi, P.D., Ahmed, S. and Geethanjali, N., 2011. Comparison of FFNN and ANFIS models for estimating groundwater level. *Environmental Earth Sciences*, 62(6), pp.1301-1310.
- Suykens, J.A. and Vandewalle, J., 1999. Least squares support vector machine classifiers. *Neural processing letters*, 9(3), pp.293-300.
- Wen, X., Feng, Q., Deo, R.C., Wu, M. and Si, J., 2016. Wavelet analysis-artificial neural network conjunction models for multi-scale monthly groundwater level predicting in an arid inland river basin, northwestern China. *Hydrology Research*, 48(6), pp.1710-1729.
- Yoon, H., Hyun, Y., Ha, K., Lee, K.K. and Kim, G.B., 2016. A method to improve the stability and accuracy of ANN-and SVM-based time series models for long-term groundwater level predictions. *Computers & geosciences*, 90, pp.144-155.
- Yu, H., Wen, X., Feng, Q., Deo, R.C., Si, J. and Wu, M., 2018. Comparative study of hybrid-wavelet artificial intelligence models for monthly groundwater depth forecasting in extreme arid regions, Northwest China. *Water resources management*, 32(1), pp.301-323.
- Zyoud, S. H., Kaufmann, L. G., Shaheen, H., Samhan, S., & Fuchs-Hanusch, D. 2016. A framework for water loss management in developing countries under fuzzy environment: Integration of Fuzzy AHP with Fuzzy TOPSIS. *Expert Systems with Applications*, 61, 86-105.
- intelligence system. *Environmental earth sciences*, 73(12), pp.8357-8367.
- Krishna, B., Satyaji Rao, Y.R. and Vijaya, T., 2008. Modelling groundwater levels in an urban coastal aquifer using artificial neural networks. *Hydrological Processes: An International Journal*, 22(8), pp.1180-1188.
- Lippman, R.P., 1987. An introduction to computing with neural nets. *IEEE ASSP Magazine. DeTienne et al./NEURAL NETWORKS AS STATISTICAL TOOLS*, 263, pp.4-22.
- Moghaddam, H.K., Moghaddam, H.K., Kivi, Z.R., Bahreinimotlagh, M. and Alizadeh, M.J., 2019. Developing comparative mathematic models, BN and ANN for forecasting of groundwater levels. *Groundwater for Sustainable Development*, 9, p.100237.
- Milan, S. G., Roobahani, A., & Banihabib, M. E. 2018. Fuzzy optimization model and fuzzy inference system for conjunctive use of surface and groundwater resources. *Journal of hydrology*, 566, 421-434.
- Nadiri, A. A., Naderi, K., Khatibi, R., & Gharekhani, M., 2019. Modelling groundwater level variations by learning from multiple models using fuzzy logic. *Hydrological sciences journal*, 64(2), 210-226.
- Nie, S., Bian, J., Wan, H., Sun, X. and Zhang, B., 2016. Simulation and uncertainty analysis for groundwater levels using radial basis function neural network and support vector machine models. *Journal of Water Supply: Research and Technology—AQUA*, 66(1), pp.15-24.
- Nourani, Vahid, Asghar Asghari Mogaddam, and Ata Ollah Nadiri., 2008 An ANN-based model for spatiotemporal groundwater level forecasting. *Hydrological Processes: An International Journal* 22.26 5054-5066.
- Nourani, V., Ejlali, R.G. and Alami, M.T., 2011. Spatiotemporal groundwater level forecasting in coastal aquifers by hybrid artificial neural network-geostatistics model: a case study. *Environmental Engineering Science*, 28(3), pp.217-228.
- Ocampo-Duque, W., Ferre-Huguet, N., Domingo, J. L., & Schuhmacher, M. 2006. Assessing water quality in rivers with fuzzy inference systems: A case study. *Environment International*, 32(6), 733-742.