



## مقایسه عملکرد مدل‌های هوشمند در شبیه‌سازی پارامترهای کیفی آب سطحی و زیرزمینی (مطالعه موردی: دشت ساوه)

مریم بیات‌ورکشی<sup>۱</sup>، احمد باقری<sup>۲</sup>، مریم هاشمی<sup>۳</sup>

تاریخ ارسال: ۱۴۰۰/۰۱/۱۶

تاریخ پذیرش: ۱۴۰۰/۰۵/۳۱

مقاله پژوهشی

### چکیده

هدف از تحقیق حاضر شبیه‌سازی پارامترهای کیفیت منابع آب با استفاده از مدل‌های هوشمند و بررسی اثر منبع آب سطحی و زیرزمینی در دقت شبیه‌سازی پارامترهای کیفی آب می‌باشد. در این مطالعه کاربرد روش‌های شبکه عصبی مصنوعی (ANN) و عصبی-فازی (CANFIS) در شبیه‌سازی پارامترهای مهم کیفی آب سطحی و زیرزمینی دشت ساوه شامل TDS, SAR, EC, TH مورد ارزیابی قرار گرفت. بدین منظور پس از بررسی میزان همبستگی کاتیون‌ها و آنیون‌ها با پارامترهای هدف در هر دو منبع آبی، متغیرهای کیفی pH, Ca, Mg, Cl, SO<sub>4</sub> طی دوره ۵۰ ساله از ۱۳۴۵ لغایت ۱۳۹۵ به عنوان متغیرهای ورودی انتخاب گردیدند. نتایج شبیه‌سازی نشان داد که کمترین خطای برآورد شبکه عصبی مصنوعی برای منابع زیرزمینی و سطحی، به ترتیب مربوط به شبیه‌سازی TH و EC با خطای NRMSE معادل ۱/۲۹ و ۵/۳ درصد بود. بیشترین مقدار خطا در هر دو منبع مربوط به پارامتر SAR می‌باشد. به همین ترتیب، نتایج مشابه در شبیه‌سازی با روش فازی-عصبی بدست آمد. آزمون تی-تست نشان داد، که استفاده از روش‌های هوشمند عصبی و عصبی-فازی در برآورد پارامتر کیفی SAR در منابع آب زیرزمینی اختلاف معنی‌داری دارند، به طوری که مقدار NRMSE از ۳۲/۰۹ درصد در روش ANN به ۲۲/۸۲ درصد در روش CANFIS کاهش یافته است. در مورد سایر پارامترهای کیفی آب زیرزمینی، اختلاف معنی‌داری مشاهده نگردید. در مورد منابع آب سطحی، روش عصبی-فازی سبب بهبود معنی‌دار نتایج مدل‌سازی پارامترهای کیفی TDS, SAR شد، به طوری که مقدار NRMSE به ترتیب از ۶۰/۳۵ و ۲۹/۲۷ درصد در روش شبکه عصبی مصنوعی به ۲۸/۷۲ و ۱۶/۸۵ درصد در روش فازی-عصبی کاهش یافت. در مجموع می‌توان این‌گونه استنباط نمود که اثر نوع منبع آب در میزان خطای شبیه‌سازی هر یک از پارامترهای کیفی مشهود بود.

واژه‌های کلیدی: شبکه عصبی، عصبی-فازی، منبع آب سطحی، منبع آب زیرزمینی، پارامتر کیفی منابع آب

<sup>۱</sup> استادیار مهندسی منابع آب، گروه علوم و مهندسی خاکشناسی، دانشکده کشاورزی، دانشگاه ملایر، همدان، ایران. [m.bayat.v@malayeru.ac.ir](mailto:m.bayat.v@malayeru.ac.ir)

<sup>۲</sup> دانشجوی کارشناسی ارشد علوم و مهندسی آب-منابع آب، گروه علوم و مهندسی خاکشناسی، دانشکده کشاورزی، دانشگاه ملایر، همدان، ایران

[ahmad.bagheri@gmail.com](mailto:ahmad.bagheri@gmail.com)

<sup>۳</sup> دانش‌آموخته کارشناسی مهندسی آبیاری، گروه آب و خاک، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان، ایران

[ma.hashemi2008@yahoo.com](mailto:ma.hashemi2008@yahoo.com)



## مقدمه

شعاعی (RBF-ANN) و شبکه‌های عصبی پرسپترون چند لایه (MLP-ANN) پیش‌بینی نمودند. آن‌ها برای حذف نویزها و خطای ناشی از آن در پیش‌بینی پارامترهای کیفی، تکنیک استنتاج عصبی-فازی (WDT-ANFIS) استفاده نمودند. نتایج این مطالعات حاکی از نتایج رضایت بخش روش‌های هوش مصنوعی به کار برده شده در شبیه‌سازی پارامترهای کیفی است. آل مختار و آل یاسین (۲۰۱۹) توانایی استفاده تکنیک‌های هوش مصنوعی: سیستم استنتاج عصبی-فازی استنتاجی (ANFIS)، شبکه‌های عصبی مصنوعی (ANN) و مدل رگرسیون چندگانه (MLR) را برای پیش‌بینی و تخمین پارامترهای کیفی TDS و EC در تالاب ابوزریق در جنوب عراق مورد ارزیابی قرار دادند. مقایسه نتایج نشان داد که این سه مدل می‌توانند به طور رضایت‌بخشی کل مواد جامد محلول و رسانایی الکتریکی را تخمین بزنند، اما ANFIS به عنوان یک مدل پیش‌بینی کننده TDS و EC در باتلاق‌های عراق توصیه شده‌است. منتصری و همکاران (۲۰۱۸) عملکرد شبکه‌های عصبی مصنوعی (ANN)، سیستم (ANFIS)، (ANFIS-SC)، GP و (ANFIS-SC)، برنامه نویسی بیان ژن (GEP)، موجک-ANN، موجک-ANFIS و موجک-GEP را در پیش‌بینی TDS حوضه‌های نازلوچای (شمال غربی ایران)، تجن (شمال ایران)، زاینده رود (مرکز ایران) و هله (جنوب ایران) با شرایط مختلف آب و هوایی طی یک دوره ۲۰ ساله در دوازده ایستگاه هیدرومتریک مختلف مورد ارزیابی قرار دادند. معیارهای ارزیابی آماری نشان داد که عملکرد مدل‌های ترکیبی موجک-هوش مصنوعی عملکرد بهتری نسبت به مدل‌های منفرد دارد. سلطانی محمدی و همکاران (۲۰۱۷) پارامترهای کیفیت آب زیرزمینی دشت رامهرمز را شامل، نسبت جذب سدیم (SAR)، هدایت الکتریکی (EC) و کل جامدات محلول (TDS) را به کمک مدل‌های ANN و ANN+PSO شبیه‌سازی نمودند. نتایج نشان داد که مدل ANN+PSO بالاترین دقت پیش‌بینی برای SAR، EC و TDS را دارد.

اساساً مدل‌سازی نقش موثری در ارائه نتایج حاصل از تغییرات برخی متغیرهای کیفی ورودی در پارامترهای کیفی شبیه‌سازی شده دارد (محقق و همکاران، ۱۳۹۹). بررسی منابع نشان می‌دهد مطالعاتی بسیاری در خصوص

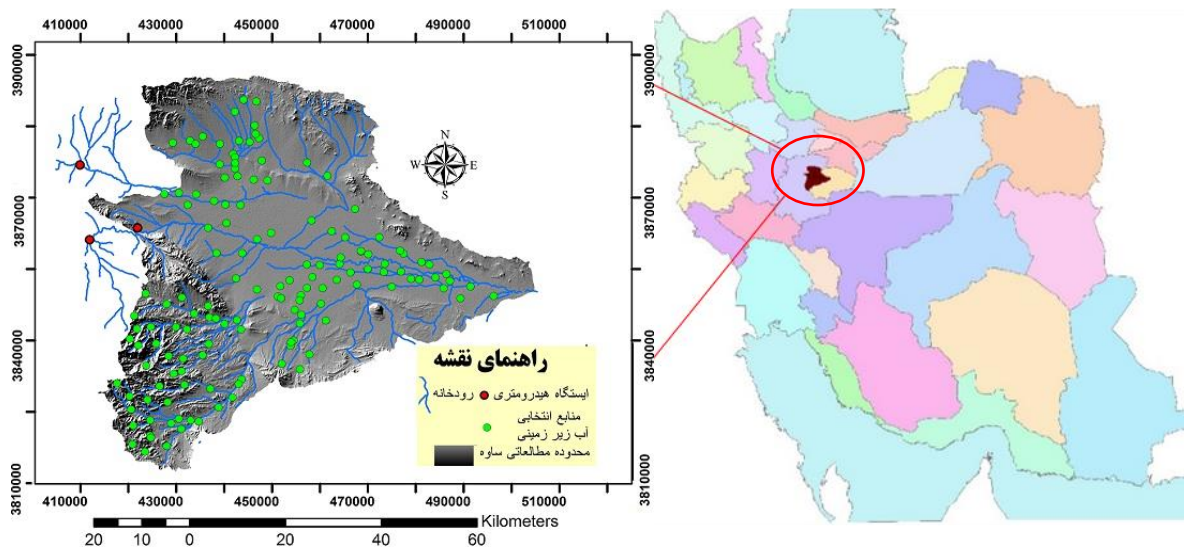
کیفیت آب یکی از مهمترین عوامل در مدیریت منابع آب و تامین آب مورد نیاز شرب، صنعت و کشاورزی است (محقق و همکاران، ۱۳۹۹). امروزه یکی از چالش‌های مهم در بیشتر مناطق بررسی کیفی منابع آب است. بشر برای دستیابی به این هدف، نیازمند انجام آزمایش‌های فراوان و صرف هزینه‌های سنگین است. در سنوات اخیر افزایش چشم‌گیر کاربرد روش‌های مدل‌سازی و شبیه‌سازی تا حد قابل توجهی سبب صرفه جویی در زمان و هزینه شده‌است (زمان‌زادقویدل و زینال‌زاده، ۱۳۹۴). استفاده از مدل‌سازی و گسترش کاربرد هوش مصنوعی و شبکه‌های عصبی هوشمند این امکان برای کارشناسان فراهم نموده تا در مدت زمان بسیار کوتاه و با به‌کارگیری تعداد معدودی از پارامترهای هیدروشیمیایی، کلاس کیفیت آب را مشخص نمایند (احمدپور و همکاران، ۱۳۹۸). در این میان شرایط متفاوت منابع آب زیرزمینی و آب سطحی از نظر برهمکنش با محیط اطراف، می‌تواند سبب تنوع ارتباط بین پارامترهای کیفی و نوع منبع باشد. بنابراین ارتباط بین پارامترهای کیفی به نوع منبع وابسته است (بیات‌ورکشی و همکاران، ۲۰۲۰). بدین جهت بررسی اثر نوع منبع آبی، زیرزمینی یا سطحی، بر مدل‌سازی امری ضروری به نظر می‌رسد. بررسی منابع حاکی از آن است که محققین در سال‌های اخیر با هدف کنترل و بررسی تاثیرات پارامترهای مختلف کیفی بر منابع آب سطحی و زیرزمینی، از روش‌های مختلف مدل‌سازی و شبیه‌سازی پارامترهای کیفی استفاده نمودند، که از جمله این موارد می‌توان به مطالعه بیات‌ورکشی و همکاران (۲۰۲۰) اشاره داشت که مقادیر هدایت الکتریکی، کل جامدات محلول، نسبت جذب سدیم و سختی کل را برای منابع آب سطحی و زیرزمینی همدان با روش داده‌کاوی تخمین زدند. آن‌ها برای این منظور از مدل درخت M5 و بهینه‌سازی آن با solver (ESP) استفاده نمودند. نتایج نشان داد که pH کمترین تاثیر را بر پارامترهای هدف دارد و در بین پارامترهای هدف TH بالاترین دقت شبیه‌سازی را داشت. نجاه احمد و همکاران (۲۰۱۹) نیتروژن آمونیاک (AN)، جامد معلق (TDS) و (pH) آب را با استفاده از سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)، شبکه‌های عصبی عملکرد

تطبیقی به کارگیری گردیده است. پس از انجام شبیه سازی علاوه بر مقایسه کارایی عملکرد این دو روش در شبیه سازی هر یک از پارامترهای کیفی آب، بررسی اثر نوع منبع آبی (سطحی و زیرزمینی) در دقت مدل سازی نیز پرداخته شده است.

## مواد و روش

محدوده مطالعاتی ساوه به مساحت ۴۰۴۵/۳۵۵ کیلومتر مربع به عنوان جزئی از حوضه آبریز دریاچه نمک در بخش انتهایی زیر حوضه رودخانه قره چای، بصورت مشترک بین استان های مرکزی و قم واقع شده است (شکل ۱). همانطور که در شکل ۱ مشاهده می گردد، جهت رودخانه بطور قالب از شرق به غرب منطقه مورد مطالعه بوده و ایستگاه های هیدرومتری انتخاب شده بر اساس کفایت داده های موجود و سنوات مورد نیاز در ورودی دشت ساوه انتخاب شده است.

بررسی کارکرد مدل های هوشمند در شبیه سازی پارامترهای مختلف هیدرولوژی در حوزه منابع آب سطحی و یا آب زیرزمینی انجام گردیده است. به نظر می رسد مطالعات کمتری در شبیه سازی همزمان پارامترهای کیفیت آب در منابع آب سطحی و زیرزمینی و مقایسه نتایج با یکدیگر صورت گرفته است. از طرفی تفاوت در مسیر عبور منابع آب سطحی و زیرزمینی و نحوه اندرکنش این دو منبع با محیط میزبان می تواند، به عنوان یکی از عوامل موثر بر متغیرهای کیفیت آب و در نتیجه، تاثیرگذار بر کارایی مدل های هوشمند در شبیه سازی پارامترهای کیفی در این دو منبع مختلف، مورد توجه قرار گیرد. بنابراین در این مطالعه شبیه سازی و برآورد پارامترهای مهم کیفی آب شامل TDS, SAR, EC, TH که نقشی موثر بر تعیین کیفیت آب مورد نیاز شرب و کشاورزی دارند، برای منابع آب سطحی و زیرزمینی در دشت ساوه انجام شده است. بدین منظور دو روش شبکه عصبی مصنوعی و روش شبکه عصبی فازی




شکل (۱): نقشه محدوده مطالعاتی دشت ساوه و منابع انتخابی اندازه گیری پارامترهای کیفی

آماری بود. جدول ۱ خلاصه اطلاعات مورد استفاده به تفکیک منبع آبی را نشان می دهد. در مطالعه حاضر پارامترهای کیفی pH, Ca, Mg, SO<sub>4</sub>, Cl, به عنوان متغیرهای ورودی و پارامترهای کیفی مهم آب شامل TDS, TH, SAR, EC به عنوان متغیرهای خروجی مدل در نظر گرفته شده اند. پارامترهای TDS, EC به میزان نمک موجود در آب و به تبع آن تعیین کیفیت آب

در پژوهش حاضر پارامترهای مهم کیفی آب سطحی و زیرزمینی دشت ساوه طی دوره ۵۰ ساله از ۱۳۴۵ لغایت ۱۳۹۵ از شرکت مدیریت منابع آب ایران دریافت گردید. این اطلاعات برای هر دو منبع سطحی و زیرزمینی شامل هدایت الکتریکی (EC)، کل جامدات محلول (TDS)، نسبت جذب سدیم (SAR)، سختی کل (TH)، pH، کلر (Cl)، سولفات (SO<sub>4</sub>)، منیزیم (Mg) و کلسیم (Ca) می باشد. انتخاب دوره آماری مورد مطالعه براساس پوشش حداکثر تعداد داده ها و کمترین خلا

جدول (۱): خلاصه آمار پارامترهای کیفی اندازه گیری شده

SO <sub>4</sub>	Cl	Mg	Ca	pH	SAR	TDS	TH	EC	عنوان	منبع
					-	mg/L	mg/L	$\mu S/cm$		
۱۸/۶۵	۱۷/۰۸	۸/۸۸	۱۰/۲۳	۷/۸۷	۵/۹۶	۲۴۰۴/۲۰	۹۵۵/۹۱	۳۹۱۳/۵۱	میانگین	آب شرب
۱/۱۶	۰/۷۰	۱/۰۲	۱/۰۴	۶/۷۸	۰/۷۷	۹/۰۰	۱۳۶/۵۰	۵۰۴/۰۰	حداقل	
۶۵/۰۰	۱۲۴/۴۵	۴۴/۷۲	۵۵/۹۰	۸/۹۱	۲۲/۸۸	۱۲۱۴۰	۴۷۰۰	۱۷۴۳۰	حداکثر	
۱۳/۴۵	۱۹/۴۹	۷/۱۶	۸/۰۷	۰/۳۲	۳/۳۴	۲۰۵۵/۶۲	۴۷۶/۶۶	۳۰۵۱/۱۸	انحراف استاندارد	
۷۲/۱۳	۱۱۴/۵۱	۸۰/۶۲	۷۸/۹۰	۴/۰۳	۵۵/۹۶	۵۸/۴۹	۷۸/۱۱	۷۷/۹۸	ضریب پراکندگی	آب کشاورزی
۹/۴۹	۱۳/۵۱	۵/۳۱	۵/۲۳	۷/۹۲	۷/۱۹	۱۵۹۹/۲۱	۷۱۶/۲۶	۲۶۴۶/۰۶	میانگین	
۰/۱۰	۱/۳۲	۰/۳۵	۰/۹۰	۶/۷۰	۱/۶۳	۳۳۰	۲۲۵	۵۴۵/۰۰	حداقل	
۴۵/۰	۴۰	۱۷/۳	۱۸/۲۰	۹/۹۹	۱۹/۲۷	۵۴۵۰	۱۷۷۵	۷۱۹۰	حداکثر	
۵/۲۵	۷/۵۴	۳/۳۱	۳/۳۸	۰/۳۲	۳/۴۸	۷۲۷/۳۱	۲۷۱/۷	۱۱۸۷/۱۵	انحراف استاندارد	آب کشاورزی
۵۵/۳۲	۵۵/۸۰	۶۲/۳	۶۴/۵۲	۴/۰۳	۴۸/۳۱	۴۵/۴۸	۰/۳۸	۴۴/۸۶	ضریب پراکندگی	



شکل (۲): نمودار شمایک شبکه عصبی چند لایه با ورودی-ها و خروجی-های مدل در این پژوهش

و خروجی وزن-دهی و تعیین می-گردد. سپس مدل آموزش یافته برای شبیه-سازی پارامترهای مجهول به ازای مقادیر معلوم لایه ورودی مورد استفاده قرار می-گیرد. توسعه یک مدل شبکه عصبی مصنوعی با تعریف و تعیین تعداد لایه-های پنهان، تعداد نرون-ها در لایه-های ورودی، پنهان و خروجی، قانون آموزش و تابع انتقال انجام می-گردد (منتصری و زمانزادقویدل، ۱۳۹۵). در این مطالعه ساختار شبکه عصبی پرسپترون چند لایه (Multy layer perseptron) انتخاب گردید. این ساختار توانمندی نگاشت پیچیده غیر خطی و قانون یادگیری پس انتشار خطا (Back Propagation) را دارد. و توانایی تشخیص رابطه بین خروجی با لایه اطلاعات ورودی و مدل سازی از ویژگی-های مهم آن است (زارع ابیانه و بیات-ورکشی، ۱۳۹۰).

در این مطالعه داده-ها بصورت تصادفی و بر اساس متون علمی به دو گروه، ۷۰ درصد برای آموزش و ۳۰ درصد برای آزمون تقسیم شدند. تعداد نرون لایه میانی با استفاده از دو روش آزمون و خطا و روابط تجربی بدست آمد. روابط

برای مصارف شرب و کشاورزی بر می-گردد. پارامتر کیفی TH نقش مهمی در تعیین کیفیت آب شرب و املاح معدنی مفید آن دارد. اهمیت SAR نیز در برنامه تولید محصولات کشاورزی به اثبات رسیده است (بیات-ورکشی و همکاران، ۲۰۲۰). برای انتخاب پارامترهای ورودی معیارهایی شامل، تعداد داده-های اندازه-گیری موجود با کمترین خلاء آماری و میزان همبستگی آنیون-ها و کاتیون-های اندازه-گیری شده با متغیرهای خروجی ملاک عمل قرار گرفته است. میزان همبستگی پارامترهای ورودی با پارامترهای خروجی با استفاده از نرم افزار Spss16 انجام شد.

امروزه در مطالعات بسیاری مدل-های هوشمند عصبی در مباحث مختلف مهندسی آب مورد توجه قرار گرفته است. درک رفتار غیر خطی پدیده-ها و فرایندهایی که تعریف دقیق و درک خاصی از رفتار آن-ها وجود ندارد از مشخصه-های اساسی این قبیل مدل-های هوشمند به حساب می-آید، که این امر سبب شده تا شبکه-های عصبی مصنوعی و عصبی-فازی برای پیش-بینی پدیده-های مختلف هیدرولوژیکی از جمله پارامترهای کیفیت آب به کار گرفته شوند. ساختمان مدل شبکه عصبی مصنوعی مطابق شکل ۲ از سه لایه ورودی، پنهان و خروجی تشکیل یافته است.

در لایه ورودی داده-های پایه اندازه-گیری یا آزمایش شده برای مدل تعریف می-شود. به همین ترتیب داده مورد نظر برای شبیه-سازی به عنوان لایه خروجی معرفی می-گردد. مقادیر لایه یا لایه-های پنهان در مرحله یادگیری یا آموزش به-ازای مقادیر معلوم لایه-های ورودی



فازی - عصبی به روش سعی و خطا توابع عضویت زنگوله‌ای (bell) و گوسین (Gaussian) و مدل‌های فازی TSK و Tsukamoto مورد بررسی قرار گرفتند. همچنین برای تعیین ویژگی‌های قسمت عصبی ساختارهای بهینه مشخص شده در مدل‌سازی به روش شبکه عصبی مصنوعی مورد استفاده قرار گرفت.

مدل‌سازی پارامترهای کیفی خروجی به روش‌های شبکه عصبی مصنوعی و سیستم تطبیق مشترک عصبی-فازی با استفاده از نرم‌افزار Neurosolution 5.0 انجام گردید. نرم‌افزار فوق از قابلیت نرمال‌سازی داده‌ها برخوردار است و با ابزار امکان اعتبار سنجی متقابل توانایی بررسی خوبی آرایش را دارد (زارع-ابیان و همکاران، ۱۳۸۸).

مقایسه عملکرد هر یک از روش‌ها با استفاده از ضریب همبستگی  $r$  که از نمودار گرافیکی داده‌های واقعی و مدل‌سازی شده بدست آمده است و آماره ریشه میانگین مربعات خطای نرمال شده NRMSE استفاده شده است.

$$RMSE = \left[ \frac{1}{n} \sum_{i=1}^n (E_i - \hat{E}_i)^2 \right]^{0.5} \quad (1)$$

$$NRMSE = \frac{1}{\bar{E}} \left[ \frac{1}{n} \sum_{i=1}^n (E_i - \hat{E}_i)^2 \right]^{0.5} \quad (2)$$

$E_i$  مقدار داده اندازه‌گیری شده،  $\hat{E}_i$  مقدار داده مدل‌سازی شده،  $\bar{E}$  متوسط داده اندازه‌گیری شده و  $n$  تعداد کل داده‌هاست (جوادی و همکاران، ۱۳۹۶).

### نتایج و بحث

به‌منظور درک بهتر از وضعیت اطلاعات مورد استفاده، نمودار توزیع فراوانی هر یک از پارامترهای کیفی هدف در دو منبع آبی مورد مطالعه در شکل ۳ ارائه گردید. محور نمودار افقی بیان‌گر دامنه تغییرات هر یک از پارامترها و محور عمودی فراوانی هر یک از مقادیر را نشان می‌دهد. ترسیم نمودار نرمال هر یک از پارامترها موید وضعیت نرمال یا عدم نرمال بودن توزیع داده‌ها است. براساس نتایج شکل ۳، توزیع آماری کلیه پارامترهای هدف نرمال می‌باشد. مقدار آزمون آماری کولموگروف-اسمیرونوف در جدول ۳ نیز موید مطلب فوق می‌باشد. همان‌گونه که از جدول ۳ استنباط می‌گردد، مقدار آماره کولموگروف-اسمیرونوف کلیه پارامترهای مورد مطالعه بیان‌گر توزیع نرمال داده‌ها می‌باشد.

مورد استفاده در جدول شماره ۲ ارائه شده است. در روش سعی و خطا تعداد نرون لایه پنهان از ۶ تا ۲۰ و ۳۱ و ۳۶ برای توابع مختلف انتقال و قوانین آموزش متفاوت مورد بررسی قرار گرفت.

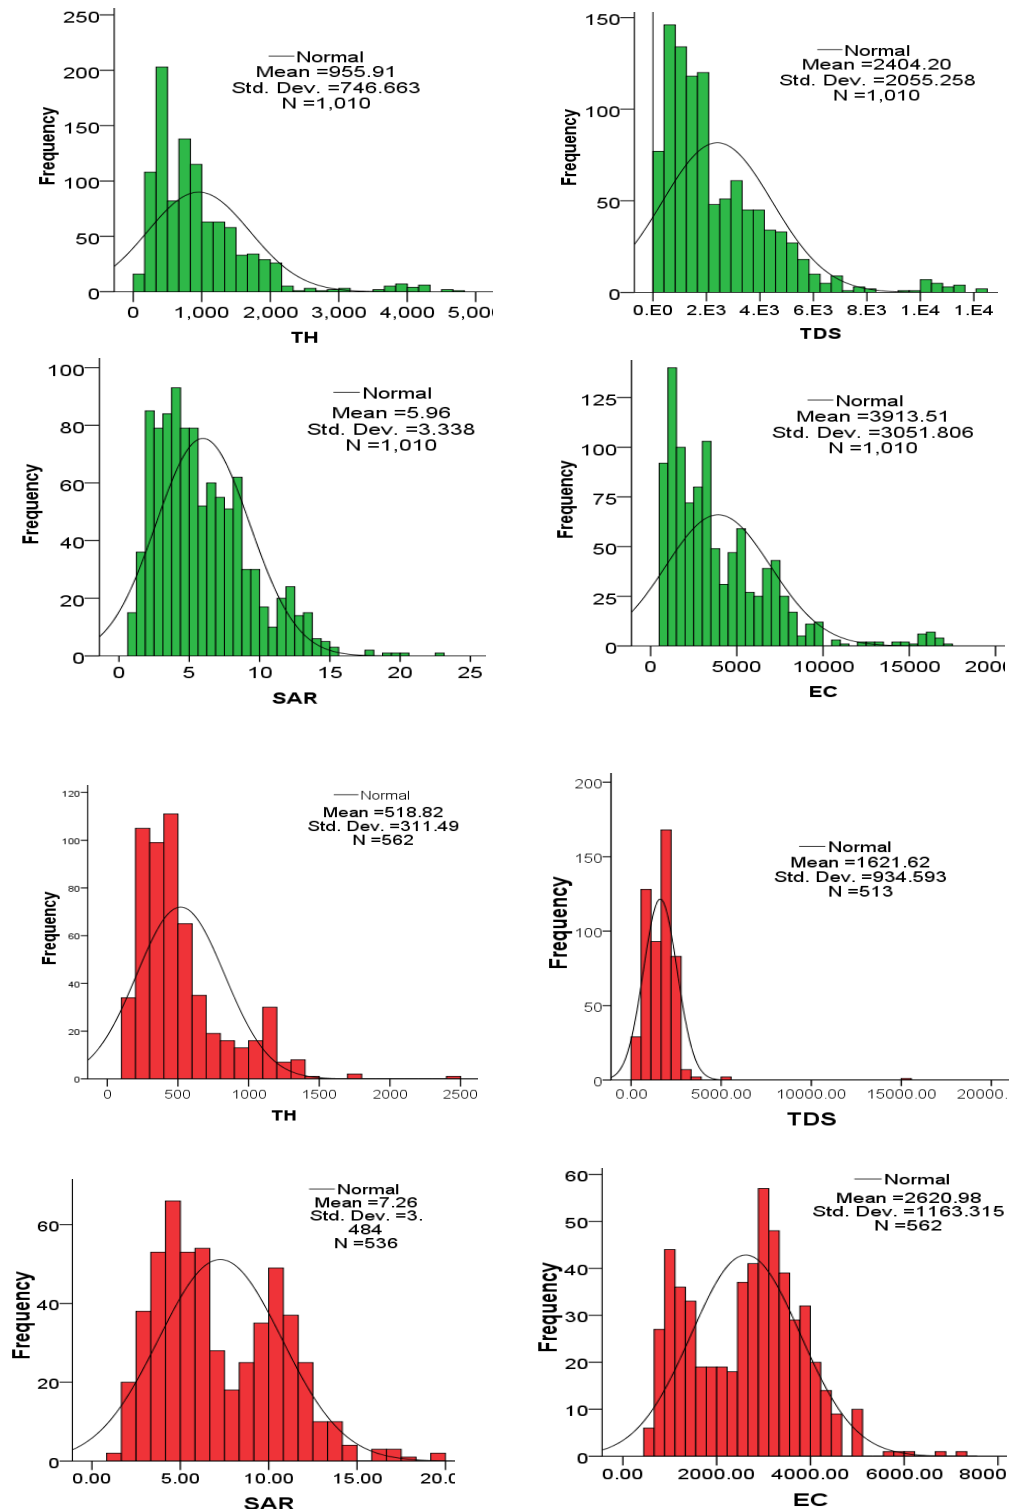
جدول (۲): روابط تجربی محاسبه تعداد نرون لایه میانی گاناشیلا و دیپا، (۲۰۱۳)

رابطه ریاضی	نام روش
$N_h = (\sqrt{1 + 8n} - 1)/2$	Li et al.
$N_h = n - 1$	Tamura and Tateishi
$N_h = \frac{2^n}{n} + 1$	Zhang et al.
$N_h = (n + \sqrt{N_p})/L$	Jinchuan and Xinzhe
$N_h = \sqrt{nN_o}$	Shibata and Ikeda
$N_h = 2^n - 1$	Hunter et al.
$N_h = (4n^2 + 3)/(n^2 - 8)$	Proposed approach

$N_h$  = تعداد نرون لایه میانی،  $n$  = تعداد نرون لایه ورودی،

$N_p$  = تعداد نرون لایه خروجی و  $L$  = تعداد لایه پنهان

در این مطالعه بهترین تابع انتقال و تابع آموزش شبکه نیز با آزمون و خطا بدست آمد. که برای این منظور کلیه توابع انتقال و تابع آموزش موجود در نرم‌افزار Neurosolution مورد سنجش قرار گرفت. در نهایت حدود ۵۲۰ ساختار مختلف مورد بررسی قرار گرفت و بهترین ساختار با کمترین خطا و بیشترین ضریب همبستگی برای شبیه‌سازی داده‌های کیفیت آب تعیین و به‌کار گرفته شد. در گام بعدی، برای شبیه‌سازی و بازسازی داده‌های کیفیت آب از روش ترکیبی عصبی-فازی استفاده شد. مدل CANFIS از ویژگی‌های شبکه عصبی مصنوعی ANN به همراه سیستم استنتاجی فازی (Fuzzy Inference System) FIS در قالب یک محیط عصبی-فازی بهره‌می‌گیرد. سیستم فازی بر مبنای قاعده‌های منطقی شرط-نتیجه شکل می‌گیرد و نقطه آغاز ساخت آن بر اساس اگر-آنگاه است. در مدل‌سازی CANFIS امکان تفکیک و جداسازی ویژگی‌های ساختار شبکه عصبی مصنوعی و ساختار فازی وجود دارد و کاربر می‌تواند ساختار بهینه را به روش آزمون و خطا به دست آورد (زارع-ابیان و بیات‌ورکشی، ۱۳۹۰). برای تعیین بهترین ساختار شبکه



شکل (۳): هیستوگرام توزیع پارامترهای کیفی هدف (رنگ سبز مربوط به منابع آب زیرزمینی و رنگ قرمز مربوط به منابع آب سطحی است)

جدول (۳) آزمون کولموگروف-اسمیرنوف

ضریب	EC	TH	SAR	TDS
آب	۴/۳۳۴	۴/۴۸۸	۲/۹۰۱	۴/۵۹۵
زیرزمینی	Sig.	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰
آب	۳/۴۹۵	۱/۹۲۷	۳/۰۲۷	۲/۶۶۲
سطحی	Sig.	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰

مشهود می‌باشد. در یک نگاه کلی، مقدار ضرایب همبستگی بین پارامترهای کیفی آب زیرزمینی به مراتب بیش از آب سطحی است. دلیل این امر را می‌توان، اثرگذاری عوامل محیطی بر تغییرات کیفیت آب سطحی دانست، درحالی که آب زیرزمینی از این تاثیرپذیری مستثنا می‌باشد. همان‌گونه که بیات‌ورکشی و همکاران (۲۰۲۰) اذعان داشتند، افزایش عوامل موثر بر یک متغیر منجر به پیچیدگی و کاهش همبستگی آن با سایر عوامل می‌باشد. نتایج مطالعه محمدی و ابراهیمی (۱۳۹۸) و صیادی-شهرکی و صیادی‌شهرکی (۱۳۹۸) نیز با نتایج فوق هم‌خوانی دارد. پس از تعیین پارامترهای ورودی، اجرای ساختارهای مختلف مدل‌های هوشمند عصبی در تخمین هر یک از پارامترهای کیفی مورد مطالعه مورد بررسی قرار گرفت. جدول ۴ نتایج اجرای شبکه عصبی مصنوعی در برآورد پارامترهای کیفی آب سطحی و زیرزمینی را نشان می‌دهد. همان‌گونه که در مواد و روش‌ها بیان گردید، ارزیابی نتایج با شاخص NRMSE و ضریب همبستگی صورت گرفت.

به‌منظور بررسی ارتباط بین پارامترهای کیفی در هر یک از منابع آبی، اقدام به محاسبه ضریب همبستگی گردید. جدول ۴ مقدار ضریب همبستگی پیرسون بین هر یک از پارامترهای کیفی به تفکیک منابع آب سطحی و زیرزمینی را نشان می‌دهد. نتایج جدول ۴ بیان‌گر تفاوت مقادیر ضریب همبستگی بین پارامترهای کیفی در هر یک از منابع است. به‌عبارت دیگر اثر نوع منبع آب بر تاثیرپذیری هر یک از پارامترهای کیفی مشهود می‌باشد. همان‌گونه که در جدول ۴ مشاهده می‌گردد، پارامتر pH با کلیه پارامترهای کیفی مورد مطالعه در آب زیرزمینی همبستگی معنی‌داری دارد، درحالی که عدم همبستگی پارامتر فوق با سایر پارامترهای کیفی مورد بررسی در آب سطحی، در جدول ۴

جدول (۴): ضریب همبستگی آزمون پیرسون برای پارامترهای کیفی منابع آب زیرزمینی

منبع آبی	EC	TH	TDS	SAR	pH	Ca	Mg	Cl	SO <sub>4</sub>
زیرزمینی	۰/۸۹**	۰/۸۲**	۰/۸۸**	۰/۸۵**	-۰/۲۵**	۰/۸۲**	۰/۷۷**	۰/۷۱**	۱/۰۰
سطحی	۰/۸۶۱**	۰/۷۷۹**	۰/۷۵۳**	-۰/۳۵۰*	-۰/۰۶۸	۰/۶۰۱**	۰/۷۱۳**	۰/۶۵۲**	۱/۰۰
زیرزمینی	۰/۹۵**	۰/۹۵**	۰/۹۵**	۰/۶۷**	-۰/۲۴**	۰/۹۲**	۰/۹۴**	۱/۰۰	
سطحی	۰/۹۳۵**	۰/۶۷۲**	۰/۹۱۹**	-۰/۲۶۹	-۰/۱۵۱	۰/۶۹۰**	۰/۴۴۴*	۱/۰۰	
زیرزمینی	۰/۹۴**	۰/۹۸**	۰/۹۳**	۰/۶۲**	-۰/۳۰**	۰/۹۲**	۱/۰۰		
سطحی	۰/۶۰۹**	۰/۸۲۶**	۰/۵۶۶**	-۰/۳۴۳*	۰/۰۲۳	۰/۳۵۲*	۱/۰۰		
زیرزمینی	۰/۹۵**	۰/۹۸**	۰/۹۳**	۰/۶۲**	-۰/۳۱**	۱/۰۰			
سطحی	۰/۷۳۲**	۰/۷۹۸**	۰/۶۸۶**	-۰/۶۱۳**	-۰/۱۶۴	۱/۰۰			
زیرزمینی	-۰/۲۷**	-۰/۳۱**	-۰/۲۵**	۰/۱۵**	۱/۰۰				
سطحی	-۰/۰۸۸	-۰/۱۱۵	-۰/۱۳۹	-۰/۱۱۵	۱/۰۰				
زیرزمینی	۰/۸۱**	۰/۶۳**	۰/۸۱**	۱/۰۰					
سطحی	۱/۳۵۴*	-۰/۵۷۰**	-۰/۳۵۶*	۱/۰۰					
زیرزمینی	۰/۹۹**	۰/۹۵**	۱/۰۰						
سطحی	۰/۹۴۴**	۰/۷۴۴**	۱/۰۰						
زیرزمینی	۰/۹۶**	۱/۰۰							
سطحی	۰/۷۹۵**	۱/۰۰							
زیرزمینی	۱/۰۰								
سطحی	۱/۰۰								

آموزش لونیبرگ-مارکوات و تابع فعالیت سیگموئید و تانژانت می‌باشد. همان‌گونه که از نتایج جدول شماره ۵ استنباط

بررسی ویژگی ساختار بهینه شبکه عصبی مصنوعی در برآورد هر یک از پارامترهای کیفی بیانگر برتری قانون



می‌باشد. در مطالعه معاشری و همکاران (۲۰۱۳) نیز به برتری قانون آموزش لونیگ-مارکوات و تابع محرک سیگموئید در مدل‌سازی کیفیت آب اشاره شده است که همسو با نتایج جدول ۵ می‌باشد.

می‌گردد، برای بیشتر ساختارهای بهینه قانون آموزش لونیگ-مارکوات و تابع محرک سیگموئید و تانژانت نتایج بهتری نسبت به سایر ساختارها داشته است. نتایج فوق همسو با گزارشات وهابی-مشهور و رحیمی-خوب (۱۳۹۴)

جدول (۵): نتایج عملکرد شبکه عصبی مصنوعی در شبیه‌سازی پارامترهای کیفی آب سطحی و زیرزمینی

منبع آب	پارامتر	ساختار	تابع انتقال	تابع آموزش	آزمون	آموزش
					NRMSE%	RMSE
زیرزمینی	SAR	۵-۲۰-۱	سیگموئید	لونیگ-مارکوات	۳۲/۰۹	۱/۹۶
سطحی		۵-۷-۱	سیگموئید	لونیگ-مارکوات	۶۰/۳۵	۵/۱۶
زیرزمینی	EC	۵-۱۶-۱	سیگموئید	لونیگ-مارکوات	۳/۴۵۵	۱۳۴/۳۳۰
سطحی		۵-۶-۱	تانژانت	لونیگ-مارکوات	۵/۳	۱۷۱/۷۶۴
زیرزمینی	TDS	۵-۳۱-۱	تانژانت	لونیگ-مارکوات	۱۲/۲۷	۲۹۳
سطحی		۵-۱۶-۱	تانژانت	لونیگ-مارکوات	۲۹/۷۷	۴۷۲
زیرزمینی	TH	۵-۳۱-۱	سیگموئید	لونیگ-مارکوات	۱/۲۹	۱۲/۳۸
سطحی		۵-۹-۱	سیگموئید	لونیگ-مارکوات	۸/۹۱	۵۰/۸

می‌باشد، همین امر منجر به افزایش خطا در پیش‌بینی مقدار آن می‌گردد. نتایج ضریب همبستگی پارامترهای کیفی آب زیرزمینی در جدول ۴ نیز موید نتیجه فوق می‌باشد. همان‌گونه که از جدول ۴ مشاهده می‌گردد، مقدار ضریب همبستگی TH با سایر پارامترها به مراتب بیش از مقدار ضریب همبستگی SAR است.

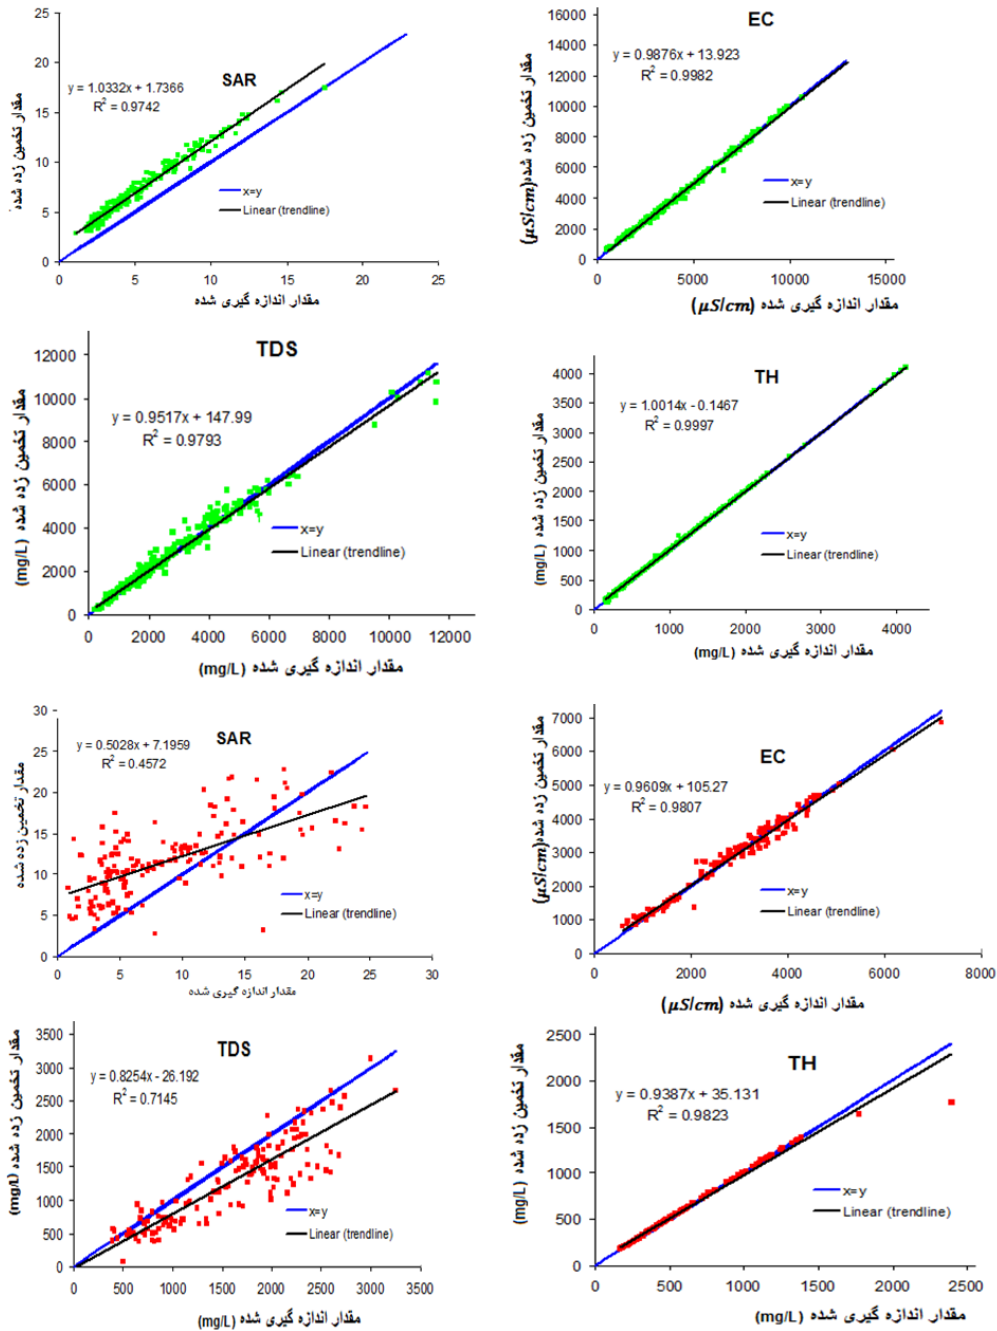
ارزیابی عملکرد شبکه عصبی مصنوعی در برآورد پارامترهای کیفی آب سطحی نشان می‌دهد که میانگین مقدار خطا برای کلیه پارامترها بیش از آب زیرزمینی می‌باشد. این اختلاف در برخی پارامترها مانند SAR چشمگیر می‌باشد (۶۰/۳۵ درصد در مقابل ۵/۳ درصد). دلیل این امر را می‌توان به مقدار ضریب همبستگی بین پارامترهای کیفی آب سطحی در مقایسه با آب زیرزمینی نسبت داد (جدول ۴). بیات و ورکشی و همکاران (۲۰۲۰) نیز در مطالعه خود به پیچیدگی روابط حاکم بر تغییرات کیفیت

مقایسه نتایج بهینه شبکه عصبی مصنوعی در برآورد هر یک از پارامترهای کیفی در آب زیرزمینی نشان می‌دهد که کمترین خطای برآورد شبکه عصبی مصنوعی به شبیه‌سازی TH تعلق دارد که معادل ۱/۲۹ درصد می‌باشد. مقدار ضریب همبستگی ساختار فوق نیز برابر ۰/۹۹۸ است. که موید عملکرد مناسب مدل در برآورد پارامتر مذکور می‌باشد. در مقابل، بیشترین خطای برآورد شبکه عصبی در مدل‌سازی پارامترهای کیفی آب زیرزمینی متعلق به SAR می‌باشد. براساس نتایج جدول ۵، مقدار خطای NRMSE پارامتر فوق برابر ۳۲/۰۹ درصد می‌باشد که نسبت به سایر پارامترها اختلاف قابل توجهی دارد. مطالعه میرسنجری و همکاران (۱۳۹۶) نیز نشان داد که شبکه عصبی مصنوعی توانایی بالایی در شبیه‌سازی پارامترهای کیفی آب زیرزمینی دارد. پیری و بامری (۱۳۹۳) نیز بر این باورند که از آنجا که مقدار پارامتر SAR وابسته به پارامترهای زیاد



آب زیرزمینی، به پارامتر SAR تعلق دارد. نتایج اجرای ساختار بهینه شبکه عصبی مصنوعی در برآورد هر یک از پارامترهای کیفی آب زیرزمینی و سطحی در مقابل مقادیر مشاهداتی در شکل ۴ قابل مشاهده است.

آب سطحی اشاره داشته‌اند که همسو با نتایج فوق می‌باشد. مقایسه نتایج شبیه‌سازی هر یک از پارامترها در آب سطحی نشان می‌دهد که کمترین خطای NRMSE به پارامتر EC مربوط می‌باشد که برابر ۵/۳ درصد خطا و ۰/۹۹۰ همبستگی می‌باشد. در مقابل، بیشترین خطا، مشابه نتایج



شکل ۴: نمودار نقطه‌ای داده‌های مشاهده شده و شبیه‌سازی شده با ANN (نقاط سبز، منابع زیرزمینی و نقاط قرمز، منابع سطحی)

بررسی قرار گرفت. همان‌گونه که در مواد و روش بیان گردید، برتری مدل CANFIS نسبت به ANFIS، در انتخابی بودن ساختار شبکه عصبی مصنوعی در این مدل تلفیقی است. در حالی که در مدل‌های ANFIS، امکان انتخاب ساختار شبکه عصبی مصنوعی به صورت جداگانه میسر نمی‌باشد (زارع‌ابیانه و بیات‌ورکشی، ۱۳۹۰).

همان‌گونه از شکل دریافت می‌گردد، تغییرات هر یک از پارامترها همسو با مقادیر مشاهداتی است که این امر بیانگر دقت بالای شبکه عصبی مصنوعی در شبیه‌سازی می‌باشد. به‌منظور بررسی اثر منطق فازی در عملکرد شبکه عصبی مصنوعی در برآورد پارامترهای کیفی، ساختارهای مختلف مدل تلفیقی عصبی-فازی در شبیه‌سازی هر یک از پارامترهای کیفی در دو منبع آب سطحی و زیرزمینی مورد

جدول (۶): نتایج عملکرد روش CANFIS در شبیه‌سازی پارامترهای کیفی دشت ساوه

ردیف	پارامتر	ساختار	تابع			آموزش		
			عضویت	انتقال	تابع	R	RMSE	NRMSE%
زیرزمینی	SAR	۲-۲-۲-۲-۲	زنگوله‌ای	سیگموئید	لونیبرگ مارکوات	۰/۹۱	۱/۳۸	۲۲/۸۲
سطحی		۲-۲-۲-۲-۲	زنگوله‌ای	سیگموئید	لونیبرگ مارکوات	۰/۹۲	۱/۹	۲۸/۷۲
زیرزمینی	EC	۲-۲-۲-۲-۲	گوسین	تانزانانت	لونیبرگ مارکوات	۰/۹۹	۳۳۲	۸/۳
سطحی		۲-۲-۲-۲-۲	گوسین	تانزانانت	لونیبرگ مارکوات	۰/۹۸	۲۶۶	۹/۶
زیرزمینی	TDS	۲-۲-۲-۲-۲	زنگوله‌ای	تانزانانت	لونیبرگ مارکوات	۰/۹۹	۳۲۹	۱۳/۷۸
سطحی		۲-۲-۲-۲-۲	گوسین	تانزانانت	لونیبرگ مارکوات	۰/۹۳	۷۶۵	۱۶/۸۵
زیرزمینی	TH	۲-۲-۲-۲-۲	گوسین	سیگموئید	لونیبرگ مارکوات	۰/۹۹	۶۸/۲۵	۶/۹
سطحی		۲-۲-۲-۲-۲	زنگوله‌ای	سیگموئید	لونیبرگ مارکوات	۰/۹۹۶	۵۶/۷۳	۱۵/۰۷

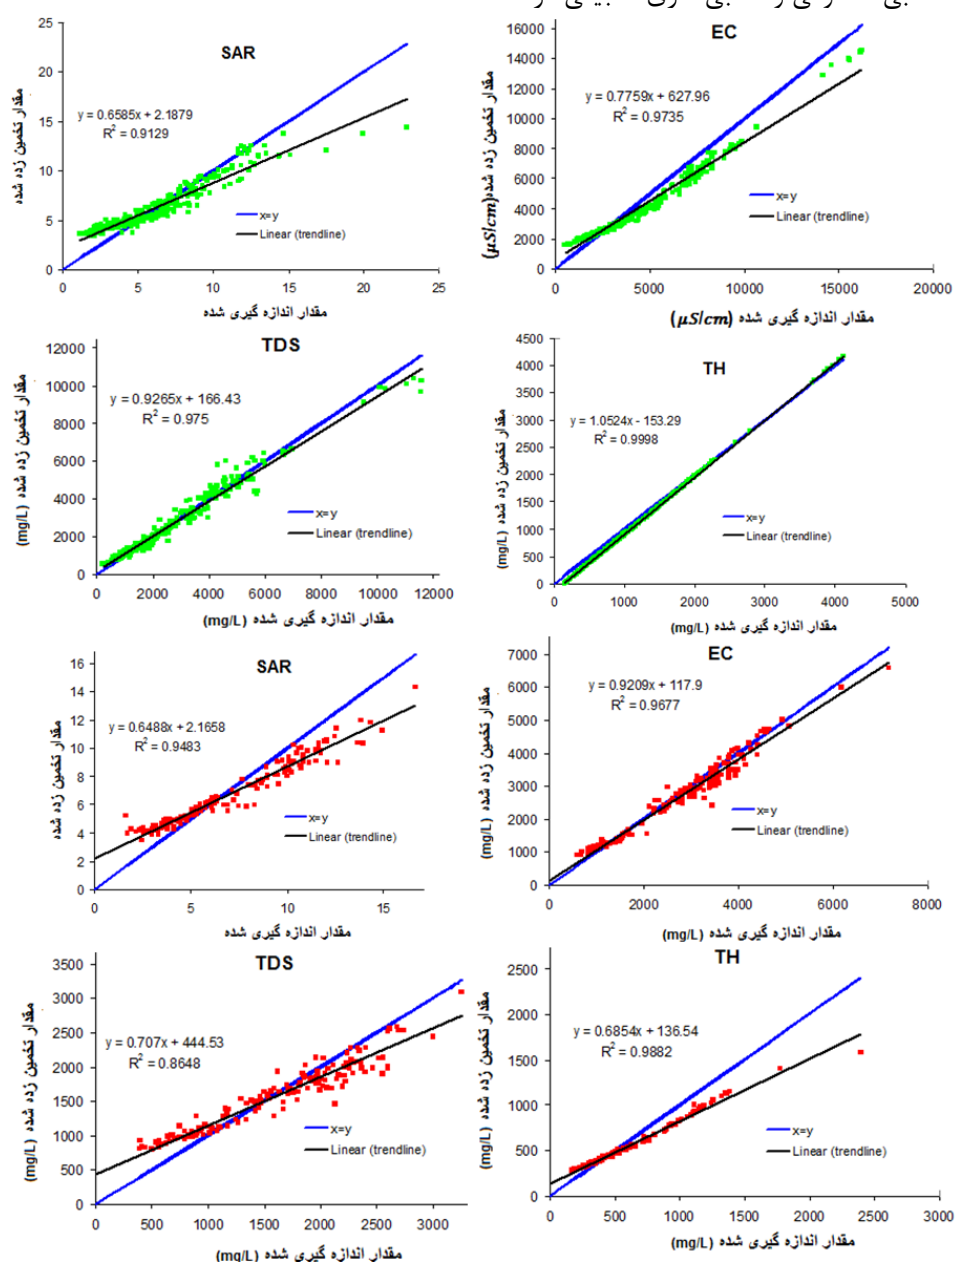
جدول ۶ نتایج اجرای ساختار بهینه هر یک از پارامترهای کیفی به تفکیک منبع آب را نشان می‌دهد. از نتایج جدول ۶ اینگونه استنباط می‌گردد که تعداد دو دسته فازی با تابع عضویت گوسین نتایج بهتری نسبت به سایر ساختارها در مدل CANFIS داشته است. نتیجه مشابه در مطالعه برآورد رواناب سالانه توسط زارع‌ابیانه و بیات‌ورکشی (۱۳۹۰) نیز گزارش شده است که همسو با نتایج فوق می‌باشد. مقایسه مقدار آماره‌های خطاسنجی NRMSE پارامترهای کیفی آب زیرزمینی نشان می‌دهد که کمترین مقدار خطا مربوط به TH می‌باشد که برابر ۶/۹ درصد است و همبستگی مربوطه نیز معادل ۰/۹۹ می‌باشد. در مقابل، شبیه‌سازی پارامتر SAR بیشترین مقدار خطای

۲۲/۸۲ NRMSE را به خود اختصاص داده است که برابر ۲۲/۸۲ درصد با ۰/۹۱۰ همبستگی می‌باشد. که نسبت به سایر پارامترها اختلاف قابل توجهی دارد. ارزیابی عملکرد مدل عصبی-فازی تطبیقی در برآورد پارامترهای کیفی آب سطحی، حاکی از آن است که همانند نتایج شبکه عصبی مصنوعی، میانگین مقدار خطا برای هر چهار پارامتر کیفی هدف بیش از آب زیرزمینی می‌باشد. با مقایسه نتایج دلیل این امر را می‌توان به مقدار ضریب همبستگی بین پارامترهای کیفی آب سطحی در مقایسه با آب زیرزمینی نسبت داد (جدول ۴). مقایسه نتایج شبیه‌سازی هر یک از پارامترها در آب سطحی نشان می‌دهد که کمترین خطای NRMSE به پارامتر EC مربوط می‌باشد که برابر ۹/۶ درصد خطا و ۰/۹۸ همبستگی می‌باشد. در مقابل بیشترین خطا، مشابه نتایج آب زیرزمینی، به پارامتر SAR تعلق دارد، که

برآورد هر یک از پارامترها از روش آزمون تی (T-Test) در نرم افزار spss16 اجرا و نتایج در جدول ۷ ارائه گردیده است. همانطور که در جدول ۷ مشاهده می شود استفاده از روش های هوشمند عصبی و عصبی-فازی در برآورد پارامتر کیفی SAR در منابع آب زیرزمینی دشت ساوه اختلاف معنی داری دارند، به گونه ای که مقدار NRMSE از ۳۲/۰۹ درصد در روش شبکه عصبی مصنوعی به ۲۲/۸۲ در روش عصبی-فازی تطبیقی کاهش یافته است.

آماره های NRMSE و R به ترتیب برابر ۲۸/۷۲ درصد و ۰/۹۲ برآورد شده است.

نتایج اجرای مدل عصبی-فازی تطبیقی در برآورد هر یک از پارامترهای کیفی آب زیرزمینی و سطحی در مقابل مقادیر مشاهداتی در شکل ۵ قابل مشاهده است. همان گونه از شکل ۵ دریافت می گردد، ارتباط تنگاتنگی بین تغییرات هر یک از پارامترها با مقادیر مشاهداتی وجود دارد که موید دقت بالای مدل در شبیه سازی است. برای مقایسه عملکرد دو روش شبکه عصبی مصنوعی و عصبی-فازی تطبیقی در



شکل (۵): نمودار نقطه-ای داده های مشاهده شده و شبیه سازی شده با CANFIS نقاط سبز، منابع زیرزمینی و نقاط قرمز، منابع سطحی



بهبود معنی‌دار نتایج مدل‌سازی پارامترهای کیفی TDS, SAR شده است و مقدار NRMSE به ترتیب از ۶۰/۳۵ و ۲۹/۲۷ درصد در روش شبکه عصبی مصنوعی به ۲۸/۷۲ و ۱۶/۸۵ درصد در روش فازی-عصبی کاهش یافته است. در مقابل، اختلاف معنی‌داری بین عملکرد هر دو روش عصبی و عصبی-فازی در برآورد پارامتر EC, TH مشاهده نگردید.

بنابراین به نظر می‌رسد روش فازی-عصبی تطبیقی برای شبیه‌سازی داده کیفی SAR در منابع آب زیرزمینی دشت ساوه عملکرد بهتری دارد. در مورد سایر پارامترهای کیفی هدف در منابع آب زیرزمینی اختلاف معنی‌داری مشاهده نمی‌گردد. لیکن با توجه به خطای کمتر و سرعت بالاتر در روش شبکه عصبی مصنوعی این روش قابل توصیه می‌باشد. در منابع آب سطحی اختلاف معنی‌داری در شبیه‌سازی پارامترهای کیفی SAR, TDS, با دو روش بالا مشاهده می‌گردد. روش عصبی-فازی تطبیقی سبب

جدول (۷): نتایج آزمون تی (T-Test)

Sig.	T	پارامتر	منبع	Sig.	T	پارامتر	منبع
۰/۸۳۳	۰/۰۴۳	EC		۰/۶۱۴	۰/۲۵۴	EC	
.	۶۹/۷۳۷	SAR	آب سطحی	۰/۰۰۰	۴۸/۲۹۳	SAR	آب زیرزمینی
۰/۰۰۷	۷/۲۸۹	TDS		۰/۷۲	۰/۸۴	TDS	
۰/۱۲۵	۲/۳۷۰	TH		۰/۵۲۱	۰/۴۱۲	TH	

در هر دو منبع مربوط به پارامتر SAR می‌باشد. به همین ترتیب نتایج مشابه در شبیه‌سازی با روش فازی-عصبی نیز بدست آمد. آزمون تی-تست نشان داد، که استفاده از روش‌های هوشمند عصبی و عصبی-فازی در برآورد پارامتر کیفی SAR در منابع آب زیرزمینی اختلاف معنی‌داری دارند، به طوری که مقدار NRMSE از ۳۲/۰۹ درصد در روش ANN به ۲۲/۸۲ درصد در روش CANFIS کاهش یافته است. در مورد سایر پارامترهای کیفی آب زیرزمینی، اختلاف معنی‌داری مشاهده نگردید. در مورد منابع آب سطحی روش عصبی-فازی سبب بهبود معنی‌دار نتایج مدل‌سازی پارامترهای کیفی SAR, TDS, شد، به طوری که مقدار NRMSE به ترتیب از ۶۰/۳۵ و ۲۹/۲۷ درصد در روش شبکه عصبی مصنوعی به ۲۸/۷۲ و ۱۶/۸۵ درصد در روش فازی-عصبی کاهش یافت. در مجموع می‌توان این‌گونه استنباط نمود که اثر نوع منبع آب در میزان خطای شبیه‌سازی هر یک از پارامترهای کیفی مشهود بود.

## نتیجه‌گیری

در پژوهش حاضر عملکرد مدل‌های هوشمند عصبی و فازی-عصبی در شبیه‌سازی پارامترهای کیفی آب سطحی و زیرزمینی مورد ارزیابی قرار گرفت. بنابراین متغیرهای SO<sub>4</sub>, Cl, Mg, Ca, Ph به عنوان ورودی و پارامترهای مهم کیفی شامل TDS, SAR, EC, TH به عنوان خروجی در نظر گرفته شدند. شبیه‌سازی با دو روش شبکه عصبی مصنوعی و عصبی-فازی تطبیقی در قالب نرم‌افزار Neurosolution 5.0 صورت گرفت. در این مطالعه ساختار شبکه و مشخصات آن بر اساس نتایج مطالعات قبلی، روش سعی و خطا و روابط تجربی تعیین گردیدند. مقایسه میانگین نتایج بدست آمده با روش T-TEST انجام شد. نتایج شبیه‌سازی نشان داد که کمترین خطای برآورد شبکه عصبی مصنوعی به ترتیب برای منابع زیرزمینی و سطحی مربوط به شبیه‌سازی TH و EC با خطای NRMSE معادل ۱/۲۹ و ۵/۳ درصد تعلق دارد. بیشترین مقدار خطا

## منابع

احمدپور، س. ز.، احمدیان فر، ا.، اصغری‌پری، س. ا. ۱۳۹۸. تخمین پارامترهای کیفی آب با استفاده از ترکیب روش ماشین یادگیری قدرتمند و تئوری موجک، اکو هیدرولوژی، دوره ۶، شماره ۲، تابستان ۱۳۹۸، ص ۳۶۹-۳۸۳.

- پیری، ح.، بامری، ا. ۱۳۹۳. برآورد نسبت جذبی سدیم (SAR) در آبهای زیرزمینی با استفاده از وایازی خطی چند متغیره و شبکه‌ی عصبی مصنوعی (مطالعه‌ی موردی دشت بجنستان)، مجله مهندسی منابع آب، سال هفتم، شماره ۲۱، ص ۸۰-۶۷.
- جوادی، ع.، مصطفی‌زاده‌فرد، ب.، شایان‌نژاد، م.، مصدقی، م. ۱۳۹۶. ارزیابی معادلات نفوذ آب به خاک در شرایط تلفیق کیفیت آب و آبیاری، رطوبت اولیه خاک و بار آبی ثابت، نشریه پژوهش آب در کشاورزی، جلد ۳۱، شماره ۳، ص ۴۷۰-۴۸۲.
- زارع‌ایبانه، ح.، بیات‌ورکشی، م. ۱۳۹۰. ارزیابی مدل‌های هوشمند عصبی و تجربی در تخمین رواناب سالانه، نشریه آب و خاک (علوم و صنایع کشاورزی)، ۲۵ (۲)، ص ۳۷۹-۳۶۵.
- زارع‌ایبانه، ح.، قاسمی، ع.، بیات‌ورکشی، م.، محمدی، ک.، سبزی‌پرور، ع. الف. ۱۳۸۸. ارزیابی کارایی دو نرم‌افزار شبکه عصبی مصنوعی در پیش‌بینی تبخیر-تعرق گیاه مرجع، مجله دانش آب و خاک، جلد ۱، شماره ۱۹، ص ۱۶۳-۱۵۰.
- صیادی‌شهرکی، ف.، صیادی‌شهرکی، ع. ۱۳۹۸. شبیه‌سازی هدایت الکتریکی دشت بهبهان با استفاده از مدل‌های ANN و ANN-PSO، علوم و مهندسی آب و فاضلاب، سال چهارم، شماره ۱، ص ۳۴-۴۱.
- زمان‌زادقویدل، س.، زینال‌زاده، ک. ۱۳۹۴. برآورد مقدار جامدات محلول رودخانه با استفاده از محاسبات نرم (مطالعه موردی: بالادست سد بوکان)، نشریه آب و خاک (علوم و صنایع کشاورزی)، جلد ۲۹، شماره ۵، آذر ۱۳۹۲، ص ۱۲۷۷-۱۲۶۲.
- محقق، ع.، ولیخان‌انارکی، م.، فرزین، س. ۱۳۹۹. مدل سازی پارامترهای کیفی (هدایت الکتریکی و کل مواد جامد محلول) رودخانه کارون در ایستگاه‌های ملاثانی، اهواز و فارسیات با بهره‌گیری از روشهای مبتنی بر داده‌کاوی، مجله سلامت و محیط زیست، دوره سیزدهم شماره اول، بهار ۱۳۹۹، ص ۱۲۲-۱۰۳.
- محمدی، پ.، ابراهیمی، ک. ۱۳۹۸. ارتقا الکتریکی رودخانه با کاربرد مدل‌های شبکه عصبی مصنوعی (ANN) و استنتاج فازی عصبی تطبیقی (ANFIS-SC) بر اساس روش تجزیه به مولفه‌های اصلی (مطالعه موردی نکارود)، نشریه علوم و مهندسی آبخیزداری ایران، سال سیزدهم، شماره ۴۷، زمستان ۱۳۹۸، ص ۳۰-۳۹.
- منتصری، م.، زمان‌زادقویدل، س. ۱۳۹۵. مقایسه عملکرد مدل‌های هوش مصنوعی در تخمین پارامترهای کیفی رودخانه در دوره‌های کم آبی و پر آبی، نشریه آب و خاک (علوم و صنایع کشاورزی)، جلد ۳۰، شماره ۶، بهمن-اسفند ۱۳۹۵، ص ۱۷۴۷-۱۷۳۳.
- میرسنجری، م. م.، محمدیاری، ف.، بصیری، ر.، حمیدی پور، ف. ۱۳۹۶. مدل سازی پارامترهای کیفی SAR، EC و TDS در آب زیرزمینی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی دشت مهران و دهلران)، فصلنامه انسان و محیط زیست، شماره ۴۲، پاییز ۱۳۹۶، ص ۱۱-۱.
- وهابی‌مشهور، م.، رحیمی‌خوب، ع. ۱۳۹۴. مقایسه عملکرد مدل‌های درختی و شبکه عصبی به منظور یافتن داده‌های گمشده تبخیر از تشت در استان خوزستان، نشریه پژوهش‌های حفاظت آب و خاک، جلد بیست و دوم، شماره چهارم، ص ۲۰۲-۱۸۷.
- Al-Mukhtar, M., Al-Yaseen, F. 2019. Modeling Water Quality Parameters Using Data-Driven Models, a Case Study Abu-Ziriq Marsh in South of Iraq, Article in Hydrology. March 2019, 6, 24; doi:10.3390/hydrology6010024.
- Bayatvarkeshi, M., Alam Imteaz, M., Kisi, O., Zarei, M., Mundher Yaseen, Z. 2020. Application of M5 model tree optimized with Excel Solver Platform for water quality parameter estimation, Environmental Science and Pollution Research <https://doi.org/10.1007/s11356-020-11047-w>.
- Gnana Sheela, K., Deepa, S. N. 2013. Review on Methods to Fix Number of Hidden Neurons in Neural Networks, Hindawi Publishing Corporation Mathematical Problems in Engineering Volume 2013, Article ID 425740, 11 pages.
- Moasheri, S. A., Rezapour, O.M., Beyranvand, Z., Poornoori, Z. 2013. Estimating the spatial distribution of groundwater quality parameters of Kashan plain with integration method of Geostatistics-Artificial Neural Network Optimized by Genetic-Algorithm. International Journal of Agriculture and Crop Science, Vol. 5 (20), pp. 2434-2442.



Montaseri, M., Zaman Zad Ghavidel, S., Sanikhani, H. 2018. Water quality variations in different climates of Iran: toward modeling total dissolved solid using soft computing techniques, *Stochastic Environmental Research and Risk Assessment*, [\(0123456789\)..-volV](https://doi.org/10.1007/s00477-018-1554-9(0123456789)..-volV)(0123456789)..-volV).

Najah Ahmed, A., Binti Othman, F., Afan, H. A., Khaleel Ibrahim, R., Chow Ming, F., Shabbir Hossain, M., Ehteram, M., Elshafie, A. 2019. Machine learning methods for better water quality prediction, *Journal of Hydrology* 578 (2019) 124084, P 1-18.

Soltani Mohammadi, A., Sayadi Shahraki, A., Naseri, A.A. 2017. Simulation of groundwater quality parameters using ANN and ANN+PSO models (Case study: Ramhormoz Plain), *Pollution*, spring 2017 3(2): 191-200.



## Assessment of the Impact of the Iype of Water Resource (surface and ground) on the Performance of Intelligent Models in Simulation of Water Quality Parameters

Maryam Bayatvarkeshi<sup>2</sup>, Ahmad Bagheri<sup>2</sup>, Maryam Hashemi<sup>3</sup>

### Abstract

The main purpose of this study is to evaluate the effect of type of water resource in simulating water quality parameters in Savel plain by the intelligent models. In this investigation, the performance of ANN and CANFIS models in simulation of TDS, SAR, EC, and TH were compared with each other. For this aim, considering the correlation of the parameters, the Ph, Ca, Mg, Cl, and SO<sub>4</sub> from 1966 to 2016 were selected as the input variables. The results indicated that the minimum error by the ANN in groundwater and surface water resources were related to the TH and the EC with 1.29 and 5.3 % respectively. The maximum error in both resources corresponded to the SAR. The same results were obtained by the CANFIS. The consequences of the T-Test showed that there was a significant difference between the ANN and the CANFIS in estimation of the SAR in the groundwater. So that the value of NRMSE decreased from 32.9% in the ANN to 22.82% in the CANFIS. Concerning the other parameters, there was not any significant distinction. In case of the surface water, the CANFIS led to increase of proficiency of simulation of the SAR and the TDS. So thar, the value of the NRMSE declined from 60.35 and 29.27% in the ANN to 28.72 and 16.85 % in the CANFIS. In general, the impact of the type of the water resource in the accuracy of intelligent models in simulation of water quality parameters was approved.

**Keywords:** Word, Intelligent models, ANN, CANFIS, Water quality, Water resource

---

<sup>2</sup> Assistant Professor of Water Engineering, Department of Soil Science, Faculty of Agriculture, University of Malayer, Malayer, Iran. [M.bayat.v@malayeru.ac.ir](mailto:M.bayat.v@malayeru.ac.ir)

<sup>2</sup> MSc student of Water Engineering, Department of Soil Science, Faculty of Agriculture, University of Malayer, Malayer, Iran. [ahmad.bagheri@gmail.com](mailto:ahmad.bagheri@gmail.com)

<sup>3</sup> Graduated of Irrigation Engineering, Shahid Bahonar University of Kerman, Kerman, Iran. [ma.hashemi2008@yahoo.com](mailto:ma.hashemi2008@yahoo.com)

## Research Paper

## Assessment of the impact of the type of water resource (surface and ground) on the performance of intelligent models in simulation of water quality parameters

Maryam Bayatvarkeshi<sup>1</sup>, Ahmad Bagheri<sup>2\*</sup>, Maryam Hashemi<sup>3</sup>

<sup>1</sup> Assistant Professor of Water Engineering, Department of Soil Science, Faculty of Agriculture, University of Malayer, Malayer, Iran.

<sup>2</sup> MSc student of Water Engineering, Department of Soil Science, Faculty of Agriculture, University of Malayer, Malayer, Iran.

<sup>3</sup> Graduated of Irrigation Engineering, Shahid Bahonar University of Kerman, Kerman, Iran



10.22125/IWE.2021.279626.1495

Received:  
**April.05.2021**  
Accepted:  
**August.22.2021**  
Available online:  
**March.13.2022**

**Keywords:**  
Word, Intelligent  
models, ANN,  
CANFIS, Water  
quality, Water  
resource

### Abstract

The main purpose of this study is to evaluate the effect of type of water resource in simulating water quality parameters in Savel plain by the intelligent models. In this investigation, the performance of ANN and CANFIS models in simulation of TDS, SAR, EC, and TH were compared with each other. For this aim, considering the correlation of the parameters, the Ph, Ca, Mg, Cl, and SO<sub>4</sub> from 1966 to 2016 were selected as the input variables. The results indicated that the minimum error by the ANN in groundwater and surface water resources were related to the TH and the EC with 1.29 and 5.3 % respectively. The maximum error in both resources corresponded to the SAR. The same results were obtained by the CANFIS. The consequences of the T-Test showed that there was a significant difference between the ANN and the CANFIS in estimation of the SAR in the groundwater. So that the value of NRMSE decreased from 32.9% in the ANN to 22.82% in the CANFIS. Concerning the other parameters, there was not any significant distinction. In case of the surface water, the CANFIS led to increase of proficiency of simulation of the SAR and the TDS. So that, the value of the NRMSE declined from 60.35 and 29.27% in the ANN to 28.72 and 16.85 % in the CANFIS. In general, the impact of the type of the water resource in the accuracy of intelligent models in simulation of water quality parameters was approved.

### 1. Introduction

Water quality is one of critical factor in water resource management and providing water requirement for drink, industry and agriculture sectors. Measuring water quality parameters can be done by specials analysis at laboratories, which needs more time and cost. These grounds compel experts to find alternative methods with high accuracy in prediction of the relevant parameters (Montaseri et al., 2018).

\* **Corresponding Author:** Maryam Bayatvarkeshi

**Address:** Soil science, Agriculture faculty, Malayer  
University, Iran.

**Email:** m.bayat.v@malayeru.ac.ir

**Tel:** +98 81 3333 9841



Among them, application of intelligent models has been reported as the suitable methods to address the issues. In the other hand, water quality parameter strongly depends on the type of the water resource including surface and groundwater. In other words, interaction of environment can cause changes of water quality parameters, thus the relationship among water quality parameters depends on the kind of the resource (Bayatvarkehsi et al., 2020). The main purpose of this study is to simulate water quality parameters by intelligent models and evaluate the effect of type of water resource in simulating them in Saveh plain by the intelligent models.

## 2. Materials and Methods

In this investigation, the performance of ANN and CANFIS models in simulation of TDS, SAR, EC, and TH were compared with each other. For this aim, considering the correlation of the parameters, the pH, Ca, Mg, Cl, and SO<sub>4</sub> from 1966 to 2016 were selected as the input variables. Running the ANN was carried out on Nonresolution software. For this purpose, variety of learning rules and active function were tested. The number of neurons of the hidden layer was calculated considering the below table.

**Table 1- Different equations for calculating the neuron in the hidden layer**

equation	Method
$N_h = (\sqrt{1 + 8n} - 1)/2$	Li et al.
$N_h = n - 1$	Tamura and Tateishi
$N_h = \frac{2^n}{n} + 1$	Zhang et al.
$N_h = (n + \sqrt{N_p})/L$	Jinchuan and Xinzhe
$N_h = \sqrt{nN_o}$	Shibata and Ikeda
$N_h = 2^n - 1$	Hunter et al.
$N_h = (4n^2 + 3)/(n^2 - 8)$	Proposed approach

Performing the CANFIS was done considering different membership functions on the software. The evaluation of the methods was done by the Normal Root Mean Square Error (RMSE) and Correlation coefficient (r) as following:

$$NRMSE = \frac{1}{E} \left[ \frac{1}{n} \sum_{i=1}^n (E_i - \hat{E}_i)^2 \right]^{0.5} \quad (1)$$

## 3. Results

The findings of the correlation coefficients showed that there was a strong link among water quality parameters in groundwater in compared to the surface water. Affecting environmental measures on surface water resource can be one of reasons of this result, whereas, this affect cannot be observed in groundwater. The same results were reported in the study of Mohammadi and Ebrahimi (2019) and Sayadi Shahraki and Sayadi Shahraki (2019). The results indicated that the minimum error by the ANN in groundwater and surface water resources were related to the TH and the EC with NRMSE=1.29 and 5.3 % respectively. The maximum error in both resources corresponded to the SAR. The same results were obtained by the CANFIS. The consequences of the T-Test showed that there was a significant difference between the ANN and the CANFIS in estimation of the SAR in the groundwater. So that the value of NRMSE decreased from 32.9% in the ANN to 22.82% in the CANFIS.

## 4. Discussion and Conclusion

Concerning the other parameters, there was not any significant distinction. In case of the surface water, the CANFIS led to increase the proficiency of simulation of the SAR and the TDS. So that, the value of the NRMSE declined from 60.35 and 29.27% in the ANN to 28.72 and 16.85 % in the CANFIS. In general, the impact of the type of the water resource in the accuracy of intelligent models in simulation of water quality parameters was approved.

## 5. Six important references

1. Bayatvarkeshi, M., Alam Imteaz, M., Kisi, O., Zarei, M., Mundher Yaseen, Z. 2020. Application of M5 model tree optimized with Excel Solver Platform for water quality parameter estimation, *Environmental Science and Pollution Research*
2. Gnana Sheela, K., Deepa, S. N. 2013. Review on Methods to Fix Number of Hidden Neurons in Neural Networks, Hindawi Publishing Corporation *Mathematical Problems in Engineering* Volume 2013, Article ID 425740, 11 pages.
3. Moasheri, S. A., Rezapour, O.M., Beyranvand, Z., Poornoori, Z. 2013. Estimating the spatial distribution of groundwater quality parameters of Kashan plain with integration method of Geostatistics-Artificial Neural Network Optimized by Genetic-Algorithm. *International Journal of Agriculture and Crop Science*, Vol. 5 (20), pp. 2434-2442
4. Mohammadi, P., Ebrahimi, K. 2019. An Improvement on the Estimation of River ECs Using ANN Models and ANFIS Involving PCA Analysis, Case Study; Nekarood River, IRAN, *Iran-Watershed Management Science & Engineering*, Vol. 13, No. 47, pp. 29-39, Winter 2020.
5. Montaseri, M., Zaman Zad Ghavidel, S., Sanikhani, H. 2018. Water quality variations in different climates of Iran: toward modeling total dissolved solid using soft computing techniques, *Stochastic Environmental Research and Risk Assessment*, [https://doi.org/10.1007/s00477-018-1554-9\(0123456789\(\),-volV\)\(0123456789\(\),-volV\)](https://doi.org/10.1007/s00477-018-1554-9(0123456789(),-volV)(0123456789(),-volV)).
6. Sayadi Shahraki, F., Sayadi Shahraki, A. 2019. Simulation of Electrical Conductivity of Behbahan Plain Using ANN and ANN-PSO Models, *Journal of Water & Wastewater Science & Engineering (jwwse)* Vol. 4, No. 1, PP. 34-41, Spring 2019, DOI: 10.22112/jwwse.2019.160050.1126.

## Conflict of Interest

There is no conflict interest in this paper.