



چشم‌انداز نوین مدل‌های مبتنی بر یادگیری گروهی به منظور شبیه‌سازی کیفیت و تراز سطح آب زیرزمینی

شیمای آزاده رنجبار^۱ | مجید خلقی^۲ | افشین اشرف‌زاده^۳

۱. گروه آبیاری و آبادانی، دانشکدگان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: Shima.azadeh.ran@ut.ac.ir shima.ranjbar20@gmail.com
۲. نویسنده مسئول، استاد گروه آبیاری و آبادانی، دانشکدگان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: mkholghi@gmail.com ، kholghi@ut.ac.ir
۳. استاد گروه آبیاری و آبادانی، دانشکدگان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: afshin.ashrafz@gmail.com

چکیده

برداشت بیش از حد از منابع آب زیرزمینی منجر به عدم تعادل کمی و کیفی قابل توجهی در اکثر آبخوان‌های ایران شده است. افزایش جمعیت، تغییرات اقلیمی و محدودیت منابع آب سطحی، نقش آب زیرزمینی را برای تأمین نیازهای شرب، کشاورزی و صنعت به مراتب پررنگ‌تر کرده است. لذا پایش و شبیه‌سازی تراز و کیفیت آب زیرزمینی برای مدیریت پایدار آبخوان‌ها ضروری است. دشت قزوین به عنوان یکی از قطب‌های کشاورزی کشور و همچنین وابستگی شدید به منابع آب زیرزمینی، به عنوان منطقه مورد مطالعه انتخاب گردید. مدل‌های هوش مصنوعی به دلیل توانایی یادگیری الگوهای غیرخطی پیچیده و عدم نیاز به شناخت کامل از فرآیندهای فیزیکی آبخوان، رویکردی کارآمد برای پیش‌بینی و شبیه‌سازی ارائه می‌دهند. هدف از این پژوهش، شبیه‌سازی کیفیت و تراز سطح آب زیرزمینی دشت قزوین با استفاده از سه مدل مبتنی بر یادگیری گروهی (RF، XGBoost و GBR) و یک مدل مبتنی بر نمونه (KNN) تعیین گردید. در این پژوهش از داده‌های ۲۰ ساله (۱۳۸۰-۱۴۰۰) شامل تراز ماهانه سطح آب زیرزمینی، پارامترهای کیفی آب و عوامل اقلیمی (بارش و دما) استفاده گردید. با مقایسه عملکرد مدل‌ها (معیارهای ارزیابی، نمودارهای پراکندگی، مقایسه مقادیر واقعی و پیش‌بینی شده، اهمیت ویژگی‌ها، تیلور، جعبه‌ای و رادار) نتایج نشان دادند که مدل‌های مبتنی بر یادگیری گروهی (RF، XGBoost و GBR) با NSE و R^2 حدود ۰/۹۹۶ و شناسایی دقیق رابطه محوری میان داده‌ها، بهترین عملکرد را در شبیه‌سازی کیفیت و تراز آب زیرزمینی در مقایسه با مدل KNN از خود نشان دادند.

کلمات کلیدی: دشت قزوین، شبیه‌سازی کیفیت و کمیت آب زیرزمینی، یادگیری گروهی، RF، GBR، XGBoost

۱- مقدمه

برداشت بی‌رویه از سفره‌های آب زیرزمینی همراه با مدیریت ناکارآمد منابع آب، منجر افت چشمگیر تراز سطح آب زیرزمینی و کسری شدید مخزن آب‌های زیرزمینی در اکثر دشت‌های کشور شده است. با توجه به وابستگی شدید به منابع آب زیرزمینی جهت تأمین آب شرب و کشاورزی کشور؛ مدیریت کارآمد و حفاظت از منابع آب‌های زیرزمینی در مناطق خشک و نیمه خشک مانند کشور ایران، امری ضروری و مهم می‌باشد. بنابراین، حفظ و نگهداری منابع آب زیرزمینی با کمیت و کیفیت مناسب، علاوه بر برنامه‌ریزی کوتاه‌مدت و بلندمدت، برای بهینه‌سازی بهره‌وری آنها ضروری است؛ که این مسئله نیازمند یک شبکه پایش دقیق می‌باشد (Fetter, 2001).



عدم وجود داده‌های کافی و دقیق سفره آب زیرزمینی برای توسعه مدل‌سازی بر مبنای فیزیک^۱ آبخوان، همچنین محدودیت‌های زمانی و هزینه‌ای جهت اجرای مکرر این مدل‌ها، کاربرد مدل‌های بر مبنای فیزیک آبخوان را با محدودیت مواجه می‌کند (Plumb et al., 2005). در این راستا، مدل‌های هوش مصنوعی^۲ (AI) و یادگیری ماشین^۳ (ML)، با قابلیت‌های خود در ارزیابی، شبیه‌سازی^۴ کیفیت آب زیرزمینی^۵ و تراز سطح آب زیرزمینی^۶ (GWL)، می‌توانند جایگزین‌های کارآمدی محسوب شوند (Adimalla and Taloor, 2020). مدل‌های هوش مصنوعی، با عدم نیاز به فرم پیچیده ریاضی در محاسبات، هزینه و نیروی انسانی کمتر و سرعت انجام بالا در مقایسه با روش مدل‌سازی بر مبنای فیزیک آبخوان، از قابلیت‌های ویژه‌ای برخوردار است (Chen and Zhang, 2020). مدل‌های هوش مصنوعی می‌توانند الگوهای غیرخطی و روابط پیچیده بین متغیرهای مختلف را به خوبی شناسایی و مدل کنند و با بهره‌گیری از قدرت محاسباتی و توانایی یادگیری از داده‌های تاریخی، امکان پیش‌بینی و تحلیل دقیق تر رفتار آب‌های زیرزمینی را فراهم می‌کنند (Poursaeid et al., 2020). به همین منظور در این پژوهش، روش‌های هوش مصنوعی که یکی از روش‌های مدل‌سازی بر مبنای داده می‌باشد، جهت شبیه‌سازی آب زیرزمینی مطرح می‌گردد.

در دهه‌های اخیر، محققان مختلفی از مدل‌های هوش مصنوعی و یادگیری ماشین برای شبیه‌سازی کیفیت و تراز سطح آب‌های زیرزمینی در تحقیقات آب‌های زیرزمینی استفاده کرده‌اند. Secci et al., (2023) عملکرد سه مدل مختلف هوش مصنوعی، خودبازگشت غیرخطی با ورودی برون‌زا^۷ (NARX)، حافظه کوتاه-مدت بلندمدت^۸ (LSTM) و شبکه عصبی کانولوشن^۹ (CNN) را در پیش‌بینی تاثیر تغییرات آب و هوا بر سطح آب‌های زیرزمینی در شمال توسکانی ایتالیا مورد بحث قرار می‌دهد. این مطالعه نشان داد که مدل LSTM بهترین عملکرد را در پیش‌بینی سطح آب‌های زیرزمینی با کاهش قابل توجه در سطح آب‌های زیرزمینی آینده نشان داد. Bahmani and Ouarda, (2021) پتانسیل دو مدل مختلف هوش مصنوعی، مدل برنامه‌ریزی بیان ژن^{۱۰} (GEP) و درخت مدل^{۱۱} (M5) برای شبیه‌سازی دقیق سطوح آب‌های زیرزمینی بررسی نمودند. مقادیر ماهانه سطح آب زیرزمینی سه حلقه چاه مشاهده‌ای و همچنین مقادیر بارندگی و دمای ماهانه یک ایستگاه هواشناسی از سال ۲۰۰۲ تا ۲۰۱۲ به عنوان ورودی مدل‌ها برای شبیه‌سازی سطح آب زیرزمینی برای یک ماه آینده استفاده کردند. نتایج نشان داد که مدل GEP دارای بهترین عملکرد برای شبیه‌سازی آب‌های زیرزمینی است، اما در حالی که M5 به دلیل عملکرد ضعیف آن توصیه نمی‌شود. Shiri et al., (2021) در پژوهشی با استفاده از داده‌های کیفی ۹۰ چاه آب زیرزمینی، توانایی مدل‌های هوش مصنوعی را برای شبیه‌سازی چهار پارامتر کیفی آب زیرزمینی شامل هدایت الکتریکی^{۱۲} (EC)، نسبت جذب سدیم^{۱۳} (SAR)، مواد جامد محلول^{۱۴} (TDS) و سولفات (SO₄) با استفاده از روش ارزیابی k-fold بررسی کردند. نتایج نشان داد که مدل ترکیبی ماشین بردار پشتیبان-الگوریتم کرم شبتاب^{۱۵} (SVM-FFA) نسبت به سایر مدل‌های هوش مصنوعی بهترین عملکرد پیش‌بینی، پایش و ارزیابی آب زیرزمینی در مناطق خشک و نیمه‌خشک که با محدودیت بارش و خشکسالی‌های مکرر مواجه هستند، معرفی کرده است. Nasr and Zahran, (2014) مدل شبکه عصبی مصنوعی^{۱۶} (ANN) را برای تخمین میزان شوری آب زیرزمینی جهت آبیاری مزارع اлександریا مصر توسعه دادند. نتایج نشان داد که مدل ANN تطبیق خوبی با مقادیر اندازه‌گیری شده و مورد انتظار شوری آب زیرزمینی دارد. El Bilali et al., (2021) نشان دادند که مدل شبکه عصبی مصنوعی (ANN) در پیش‌بینی کیفیت آب زیرزمینی نسبت به سایر مدل‌ها عملکرد بهتری دارد و هدایت الکتریکی (EC) مهم‌ترین عامل مؤثر است. Gong et al., (2016) دقت پیش‌بینی سیستم استنتاج فازی عصبی تطبیقی^{۱۷} (ANFIS)، شبکه‌های عصبی مصنوعی^{۱۸} (FNN) و ماشین‌های بردار پشتیبان^{۱۹} (SVM) را برای شبیه‌سازی ماهانه تراز سطح آب زیرزمینی بررسی نمودند. این سه مدل برای دو چاه در نزدیکی دریاچه Okeechobee در فلوریدا، ایالات متحده توسعه و اعمال شدند. برای ورودی مدل از داده‌های تراز سطح آب زیرزمینی قبلی، سطح دریاچه، بارش، و دما میانگین استفاده شده است. برای ارزیابی مدل از R، RMSE، NMSE و ضریب کارایی نش-ساتکلیف^{۲۰} (NSE) استفاده کردند. نتایج نشان دادند که مدل ANFIS نسبت به سایر الگوریتم‌ها برتری دارد.

Mateo et al., (2024) با استفاده از داده‌های غلظت بی‌کربنات، کلسیم، کلرید، منیزیم، نترات، پتاسیم، سدیم و سولفات و همچنین pH، و دما به پیش‌بینی شوری آب‌های زیرزمینی در اسپانیا پرداختند. پژوهشی در جنوب ترکیه با ۵۰ نقطه نمونه‌برداری، از مدل‌های ترکیبی مانند مدل رگرسیون بردار پشتیبان^{۲۱} (SVR) برای پیش‌بینی شاخص کیفیت آب زیرزمینی^{۲۲} (WQI) استفاده کردند. نتایج نشان داد که مدل SVR با R²



برابر با ۰/۹۶۸ بهترین همخوانی با داده‌های مشاهده‌ای دارد (Taşan, 2025). پژوهشی در جنوب غربی الجزایر به ارزیابی کیفیت آب برای مصارف کشاورزی پرداختند و نشان دادند که مدل تقویت گرادیان افراطی^{۲۴} (XGBoost) با R برابر با ۰/۹۸۳۴ دارای دقت خوبی جهت پیش‌بینی شاخص کیفیت آب کشاورزی^{۲۵} (IWQI) می‌باشد (Hussein et al., 2024). Wang and Lu, (2018) پیش‌بینی GWL کوتاه‌مدت را با استفاده از یک رویکرد رگرسیون جنگل تصادفی^{۲۶} (RF) بهبود یافته، با ترکیب ویژگی‌های تصادفی، ارزیابی کردند. آنها با ترکیب بارش، دما و سطح آب‌های زیرزمینی با تأخیرهای زمانی مشخص، به دقت پیش‌بینی بالایی دست یافتند و نتیجه گرفتند که مدل بهبود یافته، دقت بالاتری در پیش‌بینی تغییرات GWL دارد.

Feng et al., (2024) در مطالعه‌ای در استان خوزستان ایران، شش الگوریتم شامل CNN، شبکه عصبی بازگشتی (RNN)^{۲۷}، SVM، DT، RF و شبکه مولد متخاصم^{۲۸} (GAN) را مقایسه کردند و نشان دادند که CNN با RMSE برابر با ۰/۰۵۵۸ بهترین دقت را داشت، در این مطالعه از مجموعه داده بسیار بزرگی استفاده کردند. در مقابل، مطالعه Igwebuike et al., (2025) در آفریقای جنوبی نشان داد که مدل‌های RF و SVM در شرایط الگوهای سری زمانی ضعیف و داده محدود، عملکرد بهتری نسبت به LSTM در پیش‌بینی تراز آب زیرزمینی دارند. مطالعه‌ای در سال ۲۰۲۴ نشان داد که مدل تقویت گرادیان^{۲۹} (GBR) با R² برابر ۰/۹۹ عملکرد مشابه مدل‌های یادگیری عمیق را در پیش‌بینی تراز آب زیرزمینی ارائه کرد (Elmotawakkil et al., 2024). Khan and Ayaz, (2024) از شش مدل یادگیری ماشین استفاده نمودند و نتایج نشان داد که مدل ANN بهترین عملکرد را در پیش‌بینی کیفیت آب زیرزمینی دارد. Shende and Sahoo, (2024) با استفاده از ۸۹۳ نمونه آب زیرزمینی از ۶۸ موقعیت مکانی، به شبیه‌سازی شاخص کیفیت آب زیرزمینی با استفاده از مدل ANFIS پرداختند. نتایج نشان داد که مدل با ضریب همبستگی ۰/۹۲۱ و ۰/۸۳۷ به ترتیب برای مراحل آموزش^{۳۰} و آزمون^{۳۱}، بهترین عملکرد را داشته و به عنوان یک مدل قوی با دقت بالا برای پیش‌بینی شاخص کیفیت آب زیرزمینی پیشنهاد گردید. جدول ۱ خلاصه مطالعات پیشین در زمینه کاربرد مدل‌های هوش مصنوعی در شبیه‌سازی آب زیرزمینی را نشان می‌دهد.

جدول ۱- خلاصه مطالعات پیشین در زمینه کاربرد مدل‌های هوش مصنوعی در شبیه‌سازی آب زیرزمینی

Table 1- Summary of previous studies on the application of artificial intelligence models in groundwater simulation

Researcher and Year	Study Area	Statistical Period	Models Used	Target Parameter	Data Split	Best Model	Accuracy
Gong et al., (2016)	Florida, USA	2000-2009	ANN, SVM, ANFIS	GWL	70% training, 30% testing	ANFIS SVM	R ² =0.98
Bahmani and Ouarda, (2021)	Delfan, Iran	2002-2012	GEP, M5, EEMD, CEEMD, WT	GWL	75% training, 25% testing	CEEMD-GEP	R ² =0.82
El Bilali et al., (2021)	Berrechid, Morocco	2009-2019	RF, ANN, SVR	IWQI (TDS, SAR)	70% training, 30% testing	RF	R=0.99
Secci et al., (2023)	Tuscany, Italy	2005-2020	NARX, LSTM, CNN	GWL	90% training, 10% testing	LSTM	MSE=0.12
Hussein et al., (2024)	Naama, Algeria	Not specified 166 samples	XGBoost, SVR, KNN	IWQI	70% training, 30% testing	XGBoost SVR	R=0.9834 RMSE=2.82
Elmotawakkil et al., (2024)	Rabat-Kénitra, Morocco	2010-2022	GBR, SVR, RF	GWL	75% training, 25% testing	GBR	R ² =0.99, RMSE=2.98
Mateo et al., (2024)	Campo de Cartagena, Spain	2000-2023	ANN, MLR	EC (Salinity)	80% training, 20% testing	ANN	R ² =0.877, RMSE=0.747
Igwebuike et al., (2025)	West Coast, South Africa	2000-2010	RF, SVM, LSTM	GWL	80% training, 20% testing	SVM	MAE=0.356m MSE=0.37m



انتخاب رویکرد مدل‌سازی بین یادگیری گروهی^{۳۲}، یادگیری عمیق^{۳۳} و روش‌های عددی^{۳۴} (مانند MODFLOW)، تابعی از عوامل مختلف می‌باشد. مدل‌های عددی بر پایه فیزیک، نیازمند داده‌های تفصیلی هیدروژئولوژیکی شامل توزیع مکانی هدایت هیدرولیکی، ضخامت لایه‌های آبخوان، ضرایب ذخیره، شرایط مرزی دقیق و اطلاعات دقیق پمپاژ هستند که در بسیاری از آبخوان‌ها به طور کامل در دسترس نیستند (Langevin et al., 2017). مدل‌های یادگیری عمیق (مانند LSTM، CNN) نیازمند حجم بالای داده (معمولاً هزاران نمونه) هستند (Feng et al., 2024). مدل‌های یادگیری عمیق دقت پیش‌بینی یادگیری ماشین را در طیف گسترده‌ای از حوزه‌ها بهبود بخشیده‌اند، اما چالش اصلی در یادگیری عمیق این است که نیازمند تخصص و تجربه زیادی برای تنظیم پارامترهای بهینه است. استفاده از مدل‌های عمیق با ریسک بالای بیش برآزش مواجه هستند.

با توجه به محدودیت‌های ذکر شده در مدل‌های یادگیری عمیق و مدل‌های عددی، مدل‌های یادگیری گروهی به عنوان جایگزین مناسبی مطرح می‌شوند که تعادل بهینه‌ای بین دقت، کارایی محاسباتی و قابلیت تفسیر ارائه می‌دهند. این مدل‌ها نیازمند منابع محاسباتی و زمان آموزش کمتری نسبت به مدل‌های یادگیری عمیق هستند و در عین حال، برخلاف مدل‌های عددی، نیاز به داده‌های ورودی گسترده، پیچیده و بخصوص داده‌های هیدرودینامیکی مکانی ندارند.

مرور مطالعات پیشین نشان می‌دهد که مدل‌های یادگیری گروهی در سال‌های اخیر به عنوان چشم‌اندازی نوین در حوزه مدل‌سازی منابع آب زیرزمینی مطرح شده‌اند. این رویکرد از طریق ترکیب چندین مدل پایه، محدودیت‌های مدل‌های تک‌ساختاری را برطرف می‌نماید. مطالعات اخیر نشان داده‌اند که مدل‌های RF، XGBoost و GBR نه تنها از نظر دقت با مدل‌های یادگیری عمیق رقابت می‌کنند یا عملکردی برابر و بهتر از آن‌ها دارند (Feng et al., 2024; Igwebuike et al., 2025). علاوه بر این، مدل‌های یادگیری گروهی امکان تحلیل اهمیت ویژگی‌ها و درک فیزیکی فرآیندها را فراهم می‌کنند که برای مدیریت بهینه منابع آب ضروری است. بنابراین، در این پژوهش به دلیل سه عامل اساسی شامل حجم و نوع داده‌های در دسترس، پیچیدگی مسئله و منابع محاسباتی، با تمرکز بر چشم‌انداز نوین مدل‌های یادگیری گروهی، به ارزیابی جامع توانمندی این رویکرد در شبیه‌سازی کمی و کیفیت آب‌های زیرزمینی پرداخته می‌شود. مرور جامع پژوهش‌های پیشین، قابلیت و کارایی مدل‌های هوش مصنوعی در شبیه‌سازی و پیش‌بینی پارامترهای کیفی و کمی آب‌های زیرزمینی را تأیید می‌کند. با این حال، این بررسی چندین شکاف پژوهشی مهم در حوزه مدل‌سازی و شبیه‌سازی مدل‌سازی و شبیه‌سازی منابع آب زیرزمینی را نیز آشکار می‌سازد. نخست، اکثر پژوهش‌های انجام شده بر روی مدل‌های تک‌ساختاری مانند ANN، SVM و ANFIS متمرکز بوده‌اند، در حالی که مدل‌های مبتنی بر یادگیری گروهی، کمتر مورد توجه قرار گرفته‌اند. این در حالی است که مطالعات اخیر نشان می‌دهند رویکردهای گروهی پتانسیل قابل توجهی در افزایش دقت و پایداری مدل‌ها دارند. دوم، محدودیت در دامنه مقایسه مدل‌ها در مطالعات پیشین مشهود است. بسیاری از پژوهش‌ها تنها به مقایسه دو تا سه مدل اکتفا کرده‌اند و مقایسه جامعی بین رویکردهای مختلف یادگیری ماشین، به‌ویژه مقایسه بین مدل‌های مبتنی بر یادگیری گروهی و مدل‌های مبتنی بر نمونه^{۳۵} صورت نگرفته است. این محدودیت مانع از شناسایی جامع مدل برتر برای شرایط خاص هر منطقه می‌شود.

سوم، بررسی مطالعات پیشین نشان می‌دهد که هیچ‌یک از پژوهش‌های مذکور به‌طور همزمان به شبیه‌سازی کمی و کیفیت آب زیرزمینی نپرداخته‌اند. این در حالی است که مدیریت یکپارچه منابع آب مستلزم درک همزمان تغییرات کمی و کیفی آب زیرزمینی می‌باشد، زیرا این دو جنبه به شدت به یکدیگر وابسته هستند. چهارم، میانگین دوره آماری مورد استفاده در مطالعات پیشین بین ۸ تا ۱۲ سال بوده است که این دوره‌های کوتاه قادر به پوشش چرخه‌های بلندمدت خشکسالی و تغییرات اقلیمی نیستند. عدم در نظر گرفتن دوره‌های زمانی طولانی‌تر می‌تواند منجر به نادیده گرفتن الگوهای مهم هیدرولوژیکی و تغییرپذیری‌های دراز مدت شود. در پژوهش حاضر، از داده‌های ۲۰ ساله استفاده می‌شود که تقریباً دوبرابر میانگین دوره‌های آماری مطالعات قبلی است و امکان شناسایی بهتر روندهای بلندمدت را فراهم می‌نماید. پنجم، تحلیل اهمیت ویژگی‌ها^{۳۶} که برای شناخت مکانیسم عملکرد مدل و متغیرهای کلیدی تأثیرگذار ضروری است، در اکثر مطالعات پیشین نادیده گرفته شده است. این ضعف منجر به درک ناقص از نقش متغیرهای مختلف در پیش‌بینی و محدودیت در تفسیرپذیری نتایج می‌شود. پژوهش حاضر با ارائه تحلیل جامع اهمیت



ویژگی‌ها برای تمامی مدل‌ها، این خلأ را پر می‌کند. با این حال، مطالعات اخیر (۲۰۲۳-۲۰۲۵) توجه روزافزون به سمت به الگوریتم‌های پیشرفته‌تر مانند RF، XGBoost، GBR و نشان می‌دهند، که بیانگر تمایل جامعه علمی به بهره‌گیری از روش‌های قدرتمندتر یادگیری ماشین برای پیش‌بینی دقیق‌تر منابع آب است. بنابراین، پژوهش حاضر با هدف پر کردن خلأهای شناسایی شده، به مقایسه جامع مدل‌های یادگیری ماشین با تنوع ساختاری بالا برای پیش‌بینی همزمان کمیت و کیفیت آب زیرزمینی می‌پردازد.

با توجه به شکاف‌های شناسایی شده در مطالعات پیشین، این پژوهش پنج نوآوری اساسی را ارائه می‌دهد. نخست، این مطالعه به صورت جامع عملکرد رویکرد یادگیری گروهی (RF، GBR و XGBoost) را با رویکرد مبتنی بر نمونه (KNN) در یک چارچوب یکپارچه مقایسه می‌کند، در حالی که مطالعات پیشین تنها مدل‌های یک دسته را بررسی کرده‌اند. دوم، شبیه‌سازی همزمان هدایت الکتریکی (EC) و تراز سطح آب زیرزمینی (GWL) که امکان ارزیابی جامع عملکرد مدل‌ها در دو پارامتر کیفی و کمی، ارزیابی قابلیت تعمیم‌پذیری مدل‌ها در دو مسئله متفاوت و شناسایی مدل‌هایی که در هر دو زمینه عملکرد برتر دارند را فراهم می‌آورد. سوم، استفاده از ۲۰ سال داده مستمر (۱۳۸۰-۱۴۰۰) شامل خشکسالی، ترسالی و نرمال که تقریباً دوبرابر میانگین دوره‌های مورد استفاده در مطالعات پیشین است و پوشش کاملی از تغییرات اقلیمی و هیدرولوژیکی را فراهم می‌کند. چهارم، تحلیل جامع اهمیت ویژگی‌ها برای تمامی مدل‌ها که نشان می‌دهد مدل‌های گروهی توانسته‌اند روابط کلیدی را با دقت بالا شناسایی کنند. این تحلیل که در اکثر مطالعات پیشین نادیده گرفته شده، درک عمیق‌تری از مکانیسم عملکرد مدل‌ها ارائه می‌دهد. پنجم، ارزیابی چندبعدی با پنج معیار کمی (R^2 ، NSE، nRMSE و R، MAE) و شش نوع نمودار تحلیلی در مقایسه با مطالعات پیشین که به طور میانگین از سه معیار و دو نمودار استفاده می‌کنند. در مجموع، این پژوهش با ارائه چارچوبی جامع و چندبعدی، تحلیل دقیق و تنوع ساختاری مدل‌ها پیش‌بینی و مدیریت منابع آب زیرزمینی را ارائه می‌نماید.

دشت قزوین یکی از مهمترین قطب‌های کشاورزی و صنعتی در کشور می‌باشد که بدنبال آن تراکم جمعیتی را بوجود آورده است و علیرغم اینکه بخشی از نیازهای آبی منطقه توسط آب‌های سطحی تامین می‌شود، شدیداً به آب‌های زیرزمینی وابسته است، از این رو، منطقه مورد مطالعه در این پژوهش دشت قزوین تعیین گردید. این دشت در میان ۱۰ دشت حساس کشور قرار دارد و نتایج این پژوهش می‌تواند مستقیماً در برنامه‌ریزی منابع آب، سیستم هشدار زودهنگام و مدیریت تخصیص آب کشاورزی مورد استفاده قرار گیرد.

شناخت خصوصیات کمی و کیفی آب زیرزمینی و شبیه‌سازی دقیق این پارامترها برای مدیریت و بهره‌برداری بهینه از منابع آب امری لازم و ضروری است، در این راستا هدف از انجام این پژوهش مقایسه کارایی مدل‌های مبتنی بر یادگیری گروهی به منظور شبیه‌سازی کیفیت و تراز سطح آب زیرزمینی دشت قزوین می‌باشد. در این پژوهش، برای شبیه‌سازی تراز و کیفیت آب زیرزمینی، از چهار مدل یادگیری ماشین با رویکردهای متفاوت استفاده شد. سه مدل جنگل تصادفی (RF)، تقویت گرادیان افراطی (XGBoost) و تقویت گرادیان (GBR) به عنوان مدل‌های مبتنی بر یادگیری گروهی و مدل نزدیک‌ترین همسایه-K (KNN) به عنوان مدل مبتنی بر نمونه انتخاب شدند. این تنوع در انتخاب مدل‌ها امکان ارزیابی جامع و مقایسه عملکرد دو رویکرد متفاوت یادگیری ماشین را در شبیه‌سازی فراهم می‌آورد، تا ضمن بهره‌گیری از مزایای هر رویکرد، دقیق‌ترین مدل برای شرایط آبخوان دشت قزوین شناسایی شود.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

دشت قزوین در محدوده جغرافیایی ۴۹ درجه و ۱۰ دقیقه تا ۵۰ درجه و ۴۰ دقیقه طول شرقی و ۳۵ درجه و ۲۰ دقیقه تا ۳۶ درجه و ۳۱ دقیقه عرض شمالی واقع شده و در بخش شمالی و تقریباً غربی حوضه آبریز دریاچه نمک قرار دارد. مساحت ارتفاعات و دشت به ترتیب ۴۴۹۲/۳۷ و ۵۰۵۹/۳ کیلومتر مربع است. از لحاظ توپوگرافی، دامنه ارتفاعی منطقه بین ۱۱۳۱ تا ۲۹۰۲ متر با میانگین ۱۲۵۰ متر از سطح دریا متغیر است. دشت قزوین با اقلیم نیمه‌خشک دارای میانگین بارندگی سالانه ۳۱۷ میلی‌متر می‌باشد (Qazvin Regional Water Company, 2025).



دشت قزوین بر روی یک آبخوان آبرفتی به مساحت تقریبی ۴۰۰۰ کیلومتر مربع قرار گرفته است که حدود ۷۸ درصد از مساحت کل دشت را پوشش می‌دهد. از منظر زمین‌شناسی، این دشت که از طریق فرانشست تکنونیک شکل گرفته، به تدریج توسط رسوبات منتقل شده از ارتفاعات مجاور پر شده و مورفولوژی کاسه‌ای شکلی را ایجاد کرده است که در آن جریان‌های سطحی و زیرزمینی از اطراف به سمت مرکز دشت متمرکز می‌شوند (Fotamy et al., 2023). دشت قزوین با ۲۵۰ هزار هکتار اراضی کشاورزی، یکی از قطب‌های اصلی کشاورزی ایران است که نقش مهمی در تأمین امنیت غذایی کشور دارد. بیش از ۸۵ درصد از کل مصرف آب در این دشت را بخش کشاورزی به خود اختصاص می‌دهد. منابع آب سطحی دشت قزوین را رودخانه‌های شاهرود، خررود، ابهررود و چندین رودخانه فصلی تشکیل می‌دهند که به آن‌ها سهمیه‌ای از سد طالقان نیز افزوده می‌شود. به دلیل محدودیت و فصلی بودن منابع آب سطحی، عمده نیاز آبی برای مصارف کشاورزی از طریق برداشت از منابع آب زیرزمینی تأمین می‌شود (Azadeh Ranjbar et al., 2025).

تراز سطح آب زیرزمینی دشت قزوین به صورت ماهانه توسط چاه‌های مشاهده‌ای آمار برداری می‌شود و همچنین داده‌های کیفیت آب زیرزمینی، معمولاً دو مرتبه در سال (شش ماه اول و دوم) پارامترهایی نظیر سدیم (Na^+)، قلیائیت آب (pH)، کلراید (Cl^-)، سولفات (SO_4^{2-})، کلسیم (Ca^{2+})، منیزیم (Mg^{2+})، پتاسیم (K^+)، بی‌کربنات (HCO_3^-)، نسبت کل جامدات محلول (TDS) و هدایت الکتریکی (EC) توسط چاه‌های شبکه پایش آمار برداری می‌شود.

دشت قزوین با چالش‌های جدی در حوزه منابع آب زیرزمینی مواجه است. برداشت بی‌رویه از این منابع طی سال‌های اخیر، موجب افت متوسط سالانه ۱/۲۳ متر سطح آب زیرزمینی شده است (Azadeh Ranjbar, 2025). این وضعیت علاوه بر کاهش حجم ذخایر آبخوان، کیفیت آب را نیز تحت تأثیر قرار داده است. چالش‌های مدیریتی از جمله ضعف نظارت بر چاه‌های غیرمجاز و نبود سیستم یکپارچه پایش منابع آب زیرزمینی، بر شدت این مشکلات افزوده است. لذا، اجرای برنامه‌های حفاظتی مؤثر و به‌کارگیری مدیریت بهینه کیفیت و کمیت منابع آب برای جلوگیری از تخریب بیشتر آبخوان و بهبود شرایط موجود، امری ضروری و اجتناب‌ناپذیر است.

به طور کلی، آبخوان دشت قزوین به سه دلیل اساسی به عنوان منطقه مورد مطالعه انتخاب گردید. دلیل اول، محدود بودن منابع آب سطحی دائمی و وابستگی شدید منطقه به منابع آب زیرزمینی برای تأمین نیازهای شرب، کشاورزی و صنعت است. دلیل دوم، بحران کمی و کیفی حاکم بر آبخوان است که شامل روند افت تراز سطح آب زیرزمینی، کسری مخزن آبخوان و کاهش کیفیت آب می‌باشد. دلیل سوم، وجود تعداد و پراکنش مناسب چاه‌های مشاهده‌ای در سطح دشت است که امکان جمع‌آوری داده‌های کافی و معتبر برای توسعه و اعتبارسنجی مدل‌های یادگیری ماشین را فراهم می‌نماید.

داده‌های مورد استفاده در تحقیق حاضر شامل اطلاعات آب‌های زیرزمینی شامل تراز ماهانه سطح آب زیرزمینی چاه‌های مشاهده‌ای آبخوان قزوین، کیفیت آب زیرزمینی آبخوان قزوین از شرکت سهامی آب منطقه‌ای استان قزوین تهیه شده است. داده‌های هواشناسی شامل داده‌های بارش و دما، از داده‌های سنجش از دور به ترتیب از ماهواره IMERG و ERA5 با استفاده از Google Earth Engine استخراج گردید. موقعیت چاه‌های پایش کیفیت آب زیرزمینی و چاه‌های مشاهده‌ای آبخوان دشت قزوین در شکل ۱ نشان داده شده است. جدول ۱ و جدول ۲ به ترتیب مشخصات آماری پارامترهای کیفی آب زیرزمینی و تراز سطح آب زیرزمینی، بارش و دمای ماهانه آبخوان قزوین طی سال‌های ۱۴۰۰-۱۳۸۰ را نشان می‌دهد. جدول ۲ ویژگی‌های آماری پارامترهای کیفی آب زیرزمینی آبخوان قزوین را نشان می‌دهد که دامنه تغییرات گسترده‌ای در غلظت یون‌های محلول را نمایان می‌سازد. هدایت الکتریکی با دامنه ۳۱۳ تا ۹۰۸۰/۵ میکروزیمنس بر سانتی‌متر و ضریب تغییرات ۰/۶۰، بیشترین تنوع را نشان می‌دهد که بیانگر تفاوت قابل توجه در کیفیت آب در نقاط مختلف آبخوان است، در حالی که مقادیر بالای سدیم و کلر (با حداکثر به ترتیب ۵۹/۷۶ و ۵۸/۰۴ میلی‌گرم در لیتر) حاکی از وجود منابع شوری در برخی نواحی آبخوان می‌باشد.

جدول ۳ ویژگی‌های آماری تراز سطح آب زیرزمینی، بارش و دمای ماهانه در آبخوان قزوین را نشان می‌دهد. تراز آب زیرزمینی با میانگین ۱۱۹۲/۸۸ متر و ضریب تغییرات بسیار پایین (۰/۰۵) دارای پایداری قابل توجهی است، در حالی که بارش ماهانه با دامنه ۰ تا ۸۰/۹۹ میلی‌متر و



بالاترین ضریب تغییرات (۰/۸۷) نشان‌دهنده توزیع بسیار متغیر و بارش فصلی در منطقه می‌باشد. دمای ماهانه با دامنه ۳/۹۸- تا ۲۹/۰۴ درجه سلسیوس و ضریب تغییرات متوسط (۰/۶۶) دارای تغییرات فصلی منظم است، و این تفاوت در تغییرپذیری پارامترها تأییدی بر پاسخ کند آبخوان به تغییرات اقلیمی و بارش است. این تفاوت در تغییرپذیری پارامترها نشان می‌دهد که با وجود نوسانات شدید و فصلی بارش و دما، تراز آب زیرزمینی تغییرات بسیار ملایم و تدریجی دارد. این موضوع منعکس‌کننده پاسخ کند آبخوان به ورودی‌های اقلیمی است که عمدتاً ناشی از ضخامت زیاد ناحیه غیراشباع، ظرفیت ذخیره بالا و نفوذ عمقی آهسته است.

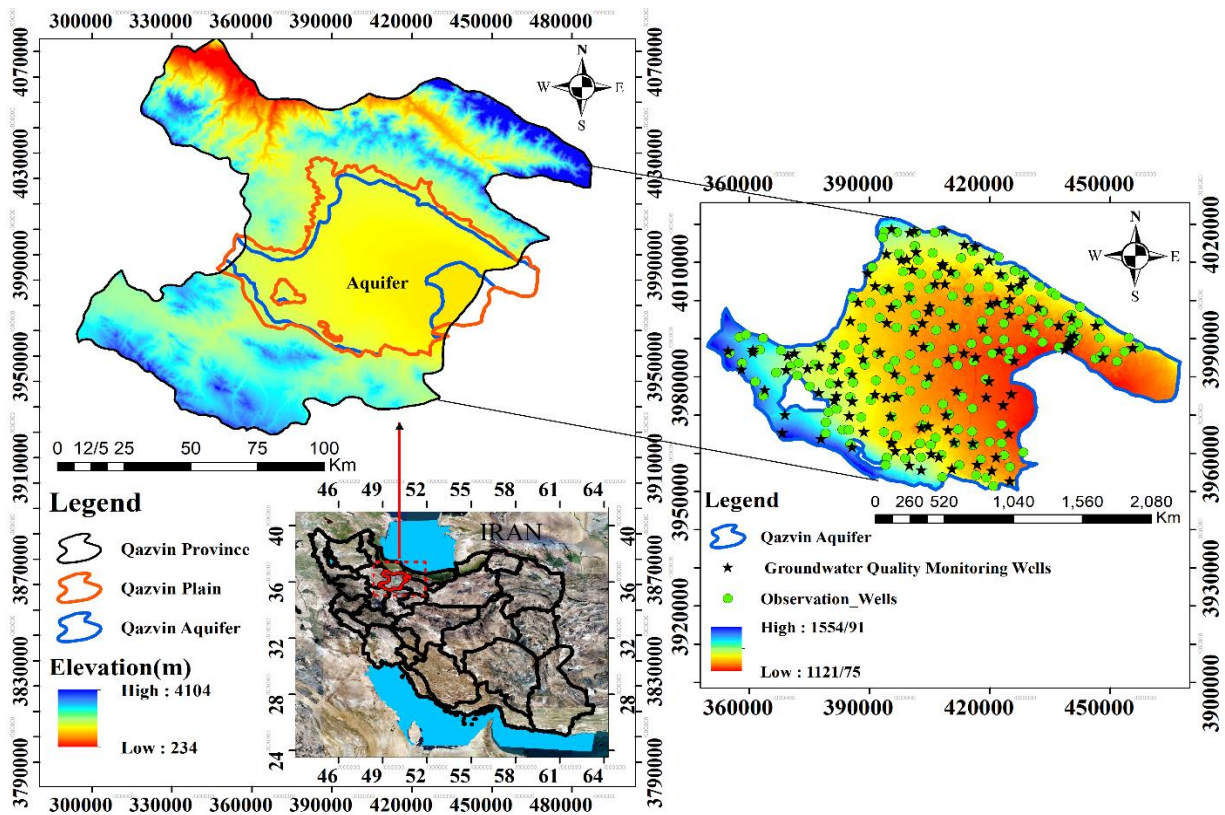


Fig. 1- Location of the study area and the spatial distribution of Groundwater quality monitoring wells and observation wells

شکل ۱- موقعیت منطقه مورد مطالعه و توزیع مکانی چاه‌های پایش کیفیت آب زیرزمینی و چاه‌های مشاهده‌ای

جدول ۲- مشخصات آماری پارامترهای کیفی آب زیرزمینی آبخوان قزوین (۱۴۰۰-۱۳۸۰)

Table 2- Statistical characteristics of groundwater quality parameters of Qazvin Aquifer (2001-2021)

Statistical characteristics	Water quality parameters									
	EC ($\mu\text{S}/\text{cm}$)	TDS	Ca	Mg	Na	K	HCO ₃	Cl	SO ₄	
Minimum	313.00	188.50	0.45	0.27	0.39	0.01	0.50	0.30	0.20	
Maximum	9080.50	5811.50	31.79	22.40	59.76	0.50	12.17	58.04	31.67	
Average	1740.73	1088.02	4.22	3.83	9.05	0.08	3.69	7.81	5.61	
Median	1452.50	911	3.52	3.43	6.92	0.06	3.65	4.9	5.11	
Standard deviation	1126.84	706.85	3.06	2.67	6.62	0.05	1.06	7.92	4.05	
CV (%)	0.60	0.65	0.73	0.70	0.73	0.73	0.29	1.01	0.72	



Mode	2640.00	379.00	2.49	4.62	3.50	0.05	3.70	0.70	7.92
Kurtosis	3.39	3.44	11.33	4.78	4.70	10.65	2.88	4.46	3.57
Skewness	1.40	1.41	2.43	1.63	1.63	2.36	0.54	1.76	1.47

جدول ۳- مشخصات آماری تراز سطح آب زیرزمینی، بارش و دمای ماهانه آبخوان قزوین (۱۴۰۰-۱۳۸۰)

Table 3- Statistical characteristics of groundwater level, Monthly precipitation and temperature of Qazvin Aquifer (2001-2021)

Statistical characteristics	parameters		
	Groundwater level	Monthly precipitation	Monthly temperature
	(m)	(mm)	(°C)
Minimum	1099.35	0.00	-3.98
Maximum	1411.15	80.99	29.04
Average	1192.88	15.22	13.68
Median	1172.23	11.87	14.13
Standard deviation	58.54	13.28	9.00
CV (%)	0.05	0.87	0.66
Mode	1265.79	0.00	18.86
Kurtosis	3.06	2.37	-1.38
Skewness	1.90	1.42	-0.05

۲-۲- روش تحقیق

در گام اول پژوهش، ابتدا داده‌های هواشناسی، کیفیت آب زیرزمینی و اطلاعات چاه‌های مشاهده‌ای آبخوان قزوین اخذ گردید و پیش‌برازش روی داده‌های آب زیرزمینی آبخوان دشت قزوین انجام گرفت. سپس به منظور شبیه‌سازی کیفیت آب زیرزمینی و تراز سطح آب زیرزمینی در بازه زمانی ۲۰ سال (۱۴۰۰-۱۳۸۰)، چهار مدل هوش مصنوعی (سه مدل مبتنی بر یادگیری گروهی و یک مدل مبتنی بر نمونه) انتخاب گردید. پس از انتخاب مدل و جمع‌آوری اطلاعات ورودی و خروجی مدل، ماتریس همبستگی رسم گردید و سپس داده‌ها به مجموعه‌های آموزش و آزمون (تست) تقسیم گردید. مدل‌سازی و شبیه‌سازی، با استفاده از نرم‌افزار پایتون انجام شد.

در گام دوم پژوهش، با توجه به پنج معیار ارزیابی و سه نمودارهای (پراکندگی^{۳۷}، مقایسه مقادیر واقعی و پیش‌بینی شده و اهمیت ویژگی‌ها)، چهار مدل هوش مصنوعی به منظور شبیه‌سازی کیفیت آب زیرزمینی و تراز سطح آب زیرزمینی اعتبار سنجی گردید. در گام سوم پژوهش، با توجه به سه نمودارهای ارزیابی (تیلور^{۳۸}، جعبه‌ای^{۳۹} و رادار^{۴۰})، بهترین مدل به منظور شبیه‌سازی کیفیت آب زیرزمینی و تراز سطح آب زیرزمینی انتخاب گردید. فلوجارت پژوهش در شکل ۲ نشان داده شده است.

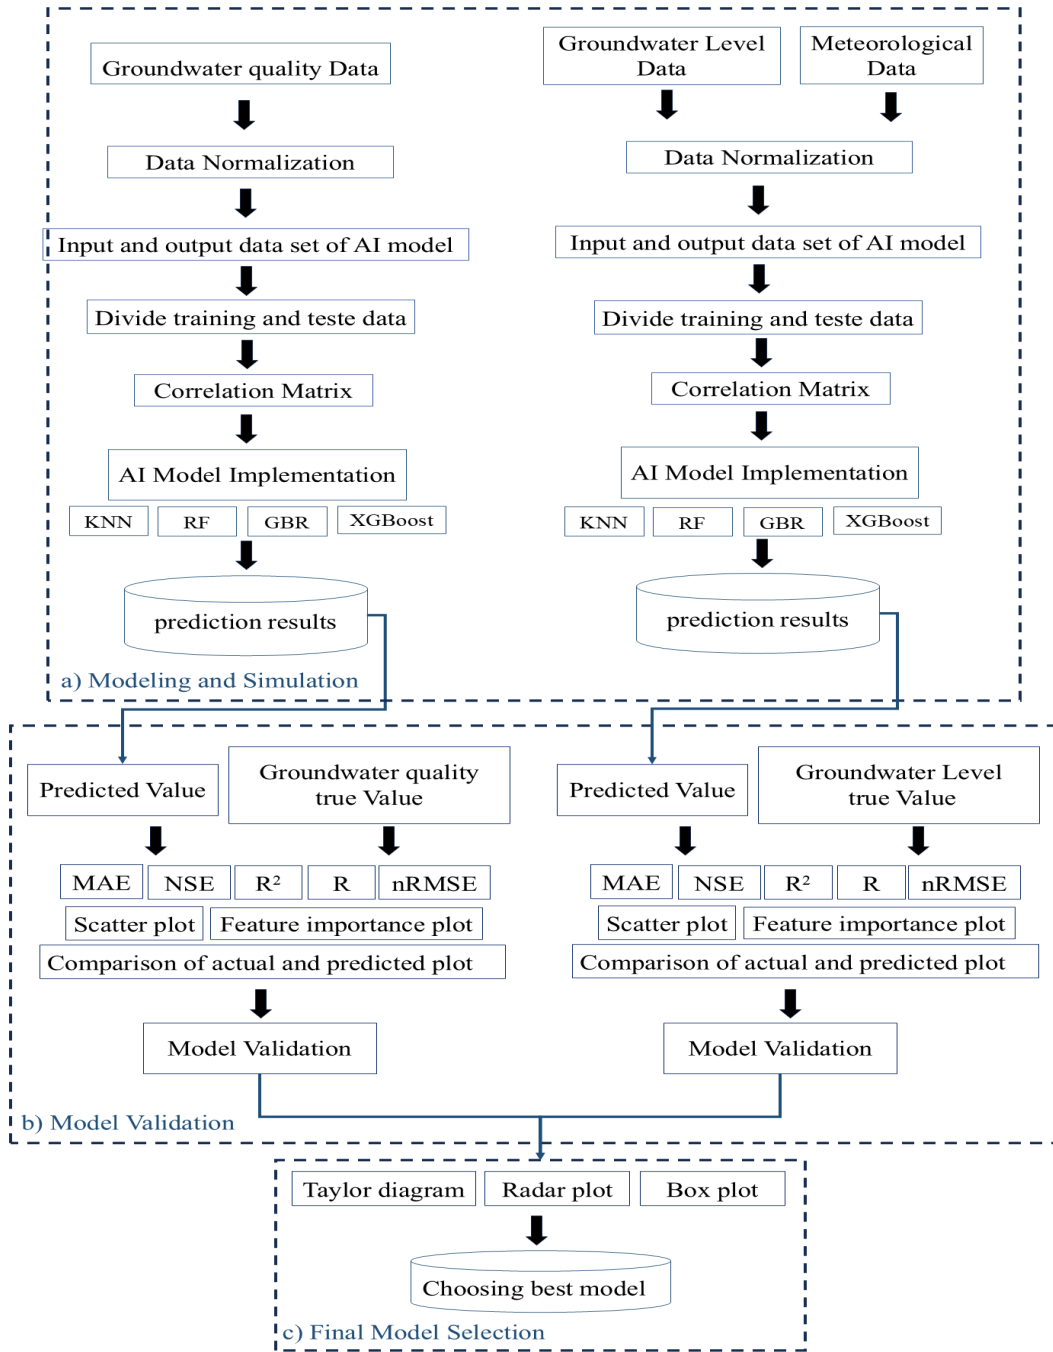


Fig. 2- Flowchart of the Methodology

شکل ۲- فلوجارت روش شناسی

۳-۲- مدل های هوش مصنوعی مورد استفاده در پژوهش

در این پژوهش، به منظور شبیه سازی تراز و کیفیت آبخوان از سه مدل مبتنی بر یادگیری گروهی، شامل جنگل تصادفی (RF)، تقویت گرادیان افراطی (XGBoost) و تقویت گرادیان (GBR) و یک مدل مبتنی بر نمونه، شامل مدل نزدیک ترین همسایه-K (KNN) بر اساس اصل تنوع ساختاری انتخاب شدند. این مدل ها دارای تفاوت های بنیادین در مکانیزم یادگیری هستند که به بهبود دقت پیش بینی کمک می کند.



مدل KNN به عنوان یک روش مبتنی بر نمونه، بر اساس فاصله در فضای ویژگی عمل می‌کند و پارامتری صریحی ایجاد نمی‌کند. این رویکرد غیرپارامتری با سه مدل دیگر که مبتنی بر یادگیری گروهی هستند، تفاوت اساسی دارد. در میان مدل‌های گروهی، مدل RF از استراتژی بگینگ^{۴۱} استفاده می‌کند که در آن درختان تصمیم به صورت موازی و مستقل آموزش داده می‌شوند. در مقابل، XGBoost و GBR از ایده تقویت^{۴۲} بهره می‌برند که یادگیرنده‌ها به صورت ترتیبی آموزش می‌بینند. تفاوت اساسی این دو در الگوریتم بهینه‌سازی است که مدل GBR بر پایه گرادین مرتبه اول عمل می‌کند، در حالی که XGBoost از بسط تیلور مرتبه دوم با منظم‌سازی L1 و L2 استفاده می‌کند.

بنابراین، مجموعه مدل‌های منتخب دارای تنوع ساختاری کافی در سه سطح، (۱) تفاوت بین رویکرد یادگیری مبتنی بر نمونه و مدل‌های مبتنی بر یادگیری گروهی، (۲) تفاوت در استراتژی ترکیب (بگینگ در برابر تقویت)، (۳) تفاوت در الگوریتم‌های بهینه‌سازی می‌باشند. این تنوع به افزایش توانایی مدل در شناسایی الگوهای پیچیده و غیر خطی کمک می‌کند و در نتیجه، دقت و قابلیت تعمیم‌پذیری پیش‌بینی‌ها را بهبود می‌بخشد. در ادامه به توضیح چهار مدل پرداخته می‌شود.

۲-۳-۱- نزدیک‌ترین همسایه-K

مدل KNN یا نزدیک‌ترین همسایه-K، یکی از روش‌های یادگیری نظارت‌شده است که کاربرد گسترده‌ای در حل مسائل طبقه‌بندی، رگرسیون و پیش‌بینی دارد. مدل KNN یک الگوریتم مبتنی بر نمونه است که به آن یادگیری مبتنی بر حافظه^{۴۳} نیز گفته می‌شود و از اصل تشابه همسایگی برای استنتاج بهره می‌برد. در این روش، برای تعیین برچسب یا تخمین مقدار یک نمونه جدید، از معیارهای فاصله گوناگون جهت بررسی نزدیک‌ترین همسایه‌های آن در داده‌های آموزشی استفاده می‌شود. با وجود مزایایی همچون سادگی پیاده‌سازی و انعطاف‌پذیری در مواجهه با انواع داده‌ها، مدل KNN با محدودیت‌هایی نیز همراه است که از آن جمله می‌توان به حساسیت عملکرد آن به انتخاب مقدار k (تعداد همسایه‌ها) و همچنین هزینه محاسباتی نسبتاً بالا، به ویژه در مجموعه‌داده‌های بزرگ، اشاره نمود (Peterson, 2009). مدل KNN با پارامتر تعداد همسایگان^{۴۴} برابر با پنج و معیار فاصله اقلیدسی (P) برابر با دو پیاده‌سازی می‌شود. از آنجا که این مدل به مقیاس ویژگی‌ها بسیار حساس است، داده‌های ورودی با روش استانداردساز^{۴۵} نرمال‌سازی می‌شوند که داده‌ها را به فضایی با میانگین صفر و واریانس یک تبدیل می‌کند. برای محاسبه اهمیت ویژگی‌ها، از روش اهمیت جایگشتی^{۴۶} با ۱۰ تکرار استفاده می‌شود که با جابجایی تصادفی مقادیر هر ویژگی و اندازه‌گیری میزان افت دقت مدل، اهمیت نسبی آن ویژگی را برآورد می‌کند.

۲-۳-۲- جنگل تصادفی

مدل RF یا جنگل تصادفی، به عنوان یکی از روش‌های قدرتمند یادگیری ماشین، برای طبقه‌بندی، دسته‌بندی و رگرسیون مورد استفاده قرار می‌گیرد که با بهره‌گیری از رویکردهای تصادفی و ترکیبی، قادر است به دقت پیش‌بینی بالایی دست یابد. این مدل یک روش یادگیری گروهی است که با ایجاد انبوهی از درختان تصمیم در طول آموزش کار می‌کند و با تجمع نتایج آن‌ها، صحت پیش‌بینی نهایی بهبود می‌یابد. هر درخت در ساختار مدل RF شامل گره‌هایی است که بر اساس ویژگی‌های مختلف داده‌ها تقسیم‌بندی می‌شوند (Breiman, 2001). عمق و تعداد این گره‌ها به پارامترهای تنظیمی مدل بستگی دارد. علاوه بر این، استفاده از زیرمجموعه‌های تصادفی از ویژگی‌ها در هر مرحله تقسیم گره، به افزایش تنوع در میان درختان و کاهش همبستگی بین آن‌ها کمک شایانی می‌نماید. این الگوریتم از طریق کاهش خطر بیش‌برازش، ارائه قابلیت تعمیم‌پذیری و توانایی شناسایی ویژگی‌های مؤثر، عملکردی قوی در تحلیل داده‌های پیچیده از خود نشان می‌دهد. مدل RF با ۱۰۰ درخت تصمیم^{۴۷} و پارامتر کنترل تصادفی^{۴۸} برابر با ۴۲ برای تضمین تکرارپذیری نتایج پیاده‌سازی می‌گردد. داده‌های ورودی با استانداردساز نرمال‌سازی می‌شوند تا یکنواختی در پیش‌پردازش داده‌ها حفظ شود. برای شناسایی تأثیر نسبی ویژگی‌ها، از معیار اهمیت جینی^{۴۹} استفاده می‌شود که بر اساس میزان کاهش ناخالصی در هر تقسیم درخت محاسبه می‌گردد.



۲-۳-۳- تقویت گرادیان افراطی

مدل XGBoost یک الگوریتم یادگیری ماشین قدرتمند است که عمدتاً برای وظایف یادگیری با نظارت، از جمله طبقه‌بندی و رگرسیون استفاده می‌شود (Lee et al., 2022). این الگوریتم توسط تیانکی چن، دانشمند علوم کامپیوتر و محقق یادگیری ماشین، معرفی شد (Chen and Guestrin, 2016).

مدل XGBoost یکی از پیشرفته‌ترین الگوریتم‌های یادگیری گروهی است که بر اساس تکنیک تقویت گرادیان^{۵۰} طراحی شده است. این مدل با ساخت متوالی از درخت‌های تصمیم ضعیف که هر کدام بر اصلاح خطاهای مدل قبلی تمرکز دارند، یک مدل پیش‌بینی قوی ایجاد می‌کند. فرآیند آموزش با یک پیش‌بینی اولیه (مانند میانگین متغیر هدف) شروع شده و سپس به‌طور تکراری درخت‌هایی را بر روی باقیمانده‌ها (تفاوت بین پیش‌بینی‌ها و مقادیر واقعی) برازش می‌دهد. مدل XGBoost از تنظیم‌کننده‌ها برای جلوگیری از بیش‌برازش، یادگیری با نرخ تطبیقی برای بهینه‌سازی و پردازش موازی برای افزایش سرعت محاسبات بهره می‌برد. این مدل به دلیل دقت بالا، سرعت مناسب و قابلیت مدیریت داده‌های پیچیده و غیرخطی، در مسائل مختلف کاربرد گسترده‌ای یافته است (Ibrahim et al., 2023). مدل XGBoost با ۱۰۰ درخت تصمیم، نرخ یادگیری^{۵۱} ۰/۱ و حداکثر عمق درخت برابر با شش پیاده‌سازی می‌شود. این تنظیمات برای ایجاد تعادل مناسب بین سرعت همگرایی و دقت پیش‌بینی انتخاب شده‌اند. پارامتر کنترل تضاد برابر با ۴۲ برای تکرارپذیری نتایج تنظیم می‌گردد. داده‌های ورودی با استانداردسازی نرمال‌سازی شده و اهمیت ویژگی‌ها با استفاده از معیار اهمیت جینی محاسبه می‌شود.

۲-۳-۴- تقویت گرادیان

مدل GBR یا تقویت گرادیان یکی از تکنیک‌های قدرتمند یادگیری ماشین است که به ویژه برای مسائل رگرسیون استفاده می‌شود. این مدل یک روش یادگیری گروهی یا ترکیبی است که در آن چندین مدل ضعیف‌تر را ترکیب می‌کند تا یک مدل قوی‌تر و دقیق‌تر ایجاد شود. به‌جای اتکا به یک مدل واحد، از چندین مدل استفاده می‌کند. در واقع از روش ایده‌ی تقویت^{۵۲} استفاده می‌کند و درخت‌ها به‌صورت تریبی ساخته می‌شوند، به‌طوری که هر درخت جدید تلاش می‌کند خطاهای درخت‌های قبلی را اصلاح کند تا یک مدل قوی‌تر تولید شود تا دقت پیش‌بینی بهبود یابد (Li et al., 2023). در مدل GBR، درختان تصمیم به عنوان مدل پایه استفاده می‌شوند که فرآیند یادگیری با یک پیش‌بینی اولیه (معمولاً میانگین داده‌ها) شروع شده و در هر مرحله، درخت جدیدی برای کاهش خطای پیش‌بینی‌های قبلی ایجاد می‌شود. این فرآیند با استفاده از یک نرخ یادگیری برای کنترل تأثیر هر درخت و تابع هزینه برای محاسبه گرادیان، تا رسیدن به معیار توقف ادامه می‌یابد و در نهایت مدلی با دقت بالا که قادر به شناسایی روابط پیچیده است و می‌تواند با داده‌های گسسته و پیوسته کار کند، ایجاد می‌شود. مدل GBR با ۱۰۰ درخت تصمیم و حداکثر عمق درخت سه پیاده‌سازی می‌گردد. محدودیت عمق درخت به منظور کنترل بیش‌برازش و افزایش قابلیت تعمیم‌پذیری مدل اعمال شده است. پارامتر کنترل تضاد برابر با ۴۲ برای تکرارپذیری نتایج تنظیم می‌شود. داده‌های ورودی نرمال‌سازی شده و اهمیت ویژگی‌ها از طریق معیار اهمیت جینی استخراج می‌گردد.

۲-۴- پیاده‌سازی مدل‌های هوش مصنوعی

در این پژوهش به منظور شبیه‌سازی کیفیت آب زیرزمینی، داده‌های ورودی مدل‌های هوش مصنوعی شامل موارد (K, Na, Mg, Ca, SO₄, Cl, HCO₃, pH و TDS) و پارامتر خروجی کیفیت آب زیرزمینی (EC) می‌باشد. به منظور شبیه‌سازی تراز سطح آب زیرزمینی، داده‌های ورودی مدل‌های هوش مصنوعی شامل ۳۶ مجموعه داده ماهانه می‌باشد که شامل سطح آب زیرزمینی ماهانه چاه‌های مشاهده‌ای، داده‌های بارش ماهانه و دمای ماهانه (۱۲ ماه گذشته) در آبخوان قزوین می‌باشد و پارامتر خروجی سطح آب زیرزمینی با تأخیر ۱۲ ماهه می‌باشد. انتخاب این تأخیر زمانی بر اساس تحلیل تأخیرهای هیدرولوژیک آبخوان و نتایج همبستگی زمانی داده‌ها صورت گرفت؛ به‌طوری که واکنش آبخوان قزوین نسبت



به بارش و تغییرات سطح آب در بازه‌های میان مدت (۶ تا ۱۲ ماهه) بیشترین همبستگی را نشان می‌دهد. علاوه بر این، افق زمانی ۱۲ ماهه متناسب با نیازهای مدیریتی و برنامه‌ریزی سالانه منابع آب زیرزمینی است و امکان پیش‌بینی روندهای آینده را فراهم می‌کند. دوره زمانی مورد استفاده ۱۳۸۰-۱۴۰۰ می‌باشد.

در این پژوهش، داده‌ها قبل از ورود به مدل‌های یادگیری ماشین تحت فرآیند آماده‌سازی قرار گرفتند. پس از بارگذاری داده‌ها و جداسازی ویژگی‌های ورودی از متغیر هدف، تمامی ویژگی‌ها با استفاده از روش مقیاس‌بندی استاندارد ساز نرمال‌سازی شدند، این امر برای الگوریتم‌هایی مانند مدل KNN که به مقیاس داده‌ها حساس هستند، ضروری است. سپس به صورت تصادفی، ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد داده‌ها برای آزمون استفاده می‌گردد. بعد از آماده‌سازی پارامترهای ورودی و خروجی، اقدام به شبیه‌سازی و پیش‌بینی مقادیر تراز و کیفیت آب زیرزمینی، با استفاده از مدل‌های هوش مصنوعی گردید. به منظور تهیه چهار مدل هوش مصنوعی KNN، RF، XGBoost و GBR از محیط برنامه‌نویسی پایتون استفاده گردید.

۲-۵- ارزیابی مدل‌های هوش مصنوعی

برای ارزیابی عملکرد مدل‌های هوش مصنوعی و انتخاب بهترین مدل، در این پژوهش از پنج معیارهای ارزیابی میانگین خطای مطلق (MAE)^{۵۳}، ضریب همبستگی پیرسون^{۵۴} (R)، ضریب تعیین^{۵۵} (R²)، ضریب نش-ساتکلیف (NSE) و ریشه دوم میانگین مربعات خطا نرمال شده (nRMSE)^{۵۶} استفاده شده است. این معیارها به صورت ۱ تا ۵ تعریف می‌شوند.

$$MAE = \frac{\sum |C_i - M_i|}{n} \quad (m), \quad 0 \leq MAE \quad (1)$$

$$R = 1 - \frac{\sum_{i=1}^n (C_i - \bar{C})(M_i - \bar{M})}{\sqrt{\sum_{i=1}^n (C_i - \bar{C})^2 (M_i - \bar{M})^2}}, \quad -1 < R < 1 \quad (2)$$

$$R^2 = \frac{\sum_{i=1}^n M_i C_i}{\sqrt{\sum_{i=1}^n M_i^2 \sum_{i=1}^n C_i^2}}, \quad 0 < R < 1 \quad (3)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (C_i - M_i)^2}{\sum_{i=1}^n (C_i - \bar{C})^2}, \quad -\infty < NSE < 1 \quad (4)$$

$$nRMSE = \frac{\sqrt{\frac{\sum (C_i - M_i)^2}{n}}}{\bar{M}}, \quad 0 < nRMSE < 1 \quad (5)$$

که در این روابط، C_i و M_i به ترتیب داده‌های برآورد شده و داده‌های مشاهده شده، \bar{C} و \bar{M} به ترتیب میانگین داده‌های برآورد شده و میانگین داده‌های مشاهده شده و n تعداد داده‌ها می‌باشند. ضریب تعیین، ضریب همبستگی و ضریب نش-ساتکلیف هرچه به یک نزدیک‌تر باشد و میانگین خطای مطلق و ریشه دوم میانگین مربعات خطا نرمال شده هر چه به صفر نزدیک‌تر باشد، بیانگر آن است که مدل برآورد بهتری داشته است.

انتخاب این معیارها بر اساس توانایی آن‌ها در تحلیل چندبعدی و پوشش جامع جنبه‌های مختلف خطا و دقت صورت گرفته است. معیار MAE به دلیل داشتن واحد اصلی داده، قابلیت تفسیر مستقیم دارد و برای درک کلی میزان انحراف کارایی دارد. در حالی که nRMSE به خطاهای بزرگ‌تر حساس‌تر بوده و امکان مقایسه بین مجموعه داده‌های با مقیاس‌های متفاوت را فراهم می‌کند و برای تشخیص نقاط پرت و خطاهای شدید کارایی دارد. ضریب همبستگی پیرسون (R) قدرت و جهت رابطه خطی را اندازه‌گیری می‌کند، در حالی که ضریب تعیین (R²) نسبت واریانس قابل تبیین توسط مدل را نشان می‌دهد. معیار NSE به عنوان استاندارد رایج در مطالعات هیدرولوژی و منابع آب، کارایی مدل را در مقایسه با یک مدل ساده مبتنی بر میانگین ارزیابی می‌کند. استفاده همزمان از این پنج معیار تضمین می‌کند که مدل برتر از تمام جنبه‌های دقت، همبستگی، کنترل



خطاهای شدید و قابلیت تعمیم‌پذیری ارزیابی شده و انتخاب نهایی بر اساس تحلیل جامع عملکرد صورت می‌گیرد. (Krause et al., 2005; Moriasi et al., 2007)

سپس برای ارزیابی عملکرد مدل‌های مختلف و انتخاب بهترین مدل هوش مصنوعی در مرحله آزمون مدلسازی، در این مقاله از سه نمودار استفاده می‌شود. نمودار پراکنندگی و نمودار مقایسه مقادیر واقعی و پیش‌بینی شده که نشان می‌دهد چقدر پیش‌بینی‌ها به مقادیر واقعی نزدیک هستند. نمودار اهمیت ویژگی‌ها مشخص می‌کند که کدام پارامترهای ورودی بیشترین تأثیر را در پیش‌بینی دارند. سرانجام، از سه نمودار تیلور، جعبه‌ای و رادار برای اطمینان از انتخاب صحیح مدل برتر استفاده می‌شود. نمودار تیلور بهترین مدل را با کمترین خطای شبیه‌سازی بر اساس سه شاخص از جمله انحراف معیار، ضریب همبستگی و ریشه دوم میانگین مربعات خطا معرفی می‌کند. نمودار رادار برای نمایش چندبعدی داده‌ها از محورهای شعاعی استفاده می‌کند که از یک نقطه مرکزی مشترک آغاز می‌شوند و هر محور نشان‌دهنده یک متغیر یا ویژگی است، به طوری که مقادیر هر متغیر روی محور مربوطه قرار گرفته و اتصال این نقاط یک چندضلعی را تشکیل می‌دهد که الگوی کلی و مقایسه نسبی متغیرها را به صورت بصری نمایان می‌سازد. جهت مقایسه میانگین‌ها و آزمون نرمال بودن داده‌ها و تعیین داده‌های پرت از نمودار جعبه‌ای استفاده گردید. نمودار جعبه‌ای معیاری برای شناسایی شکل توزیع و شناسایی داده‌های پرت است.

۳- نتایج و بحث

۳-۱- همبستگی داده‌های کیفیت آب زیرزمینی

شکل ۳ ماتریس همبستگی پارامترهای کیفی آب زیرزمینی دشت قزوین، روابط معناداری بین متغیرهای کیفیت آب زیرزمینی را نشان می‌دهد. همبستگی کامل (۱/۰۰) بین TDS و EC، همبستگی بسیار قوی (۰/۹۵ - ۰/۹۳) بین Na, Cl, TDS و EC بیانگر آن است که سدیم و کلر عوامل اصلی شوری آب بوده و از منشأ مشترکی نظیر انحلال سازندهای نمکی یا نفوذ آب‌های شور تأمین می‌شوند. همبستگی‌های قابل توجه (۰/۸۴ - ۰/۶۸) بین Ca, Mg و SO₄ نشان‌دهنده عبور آب از سازندهای کربناته و تبخیری است که منجر به افزایش سختی و املاح محلول می‌شود. همبستگی منفی pH با اکثر پارامترها به‌ویژه Ca و Mg نشان می‌دهد که با افزایش انحلال املاح و سختی، pH کاهش می‌یابد. در مقابل، HCO₃ استقلال نسبی از سایر پارامترها را نشان می‌دهد که بیانگر عملکرد سیستم بافری کربنات است. این الگوهای همبستگی نشان می‌دهد که کیفیت آب زیرزمینی دشت قزوین تحت کنترل یک مکانیسم غالب شامل انحلال سازندهای تبخیری-کربناته و اختلاط با آب‌های شورتر قرار دارد. رفتار هم‌زمان و هماهنگ پارامترهای شوری، بیانگر وجود منشأ مشترک و تقویت تدریجی فرآیندهای افزایش شوری است. همچنین این الگوها نشان‌دهنده سامانه‌ای با زمان ماند بالا و پاسخ کند هستند؛ به طوری که تغییرات کیفی عمدتاً به صورت تدریجی و انباشتی رخ می‌دهد و اثرپذیری زیادی از نوسانات کوتاه‌مدت ندارد. کاهش تراز سطح آب می‌تواند گرادیان هیدرولیکی را به سمت ورود آب‌های شورتر افزایش دهد و فرآیندهای انحلال و اختلاط را تشدید نماید. بنابراین، نظارت مستمر و با فرکانس مناسب بر کیفیت آب زیرزمینی برای شناسایی روندهای تدریجی و جلوگیری از تشدید شوری و نفوذ آب‌های شورتر ضروری است.

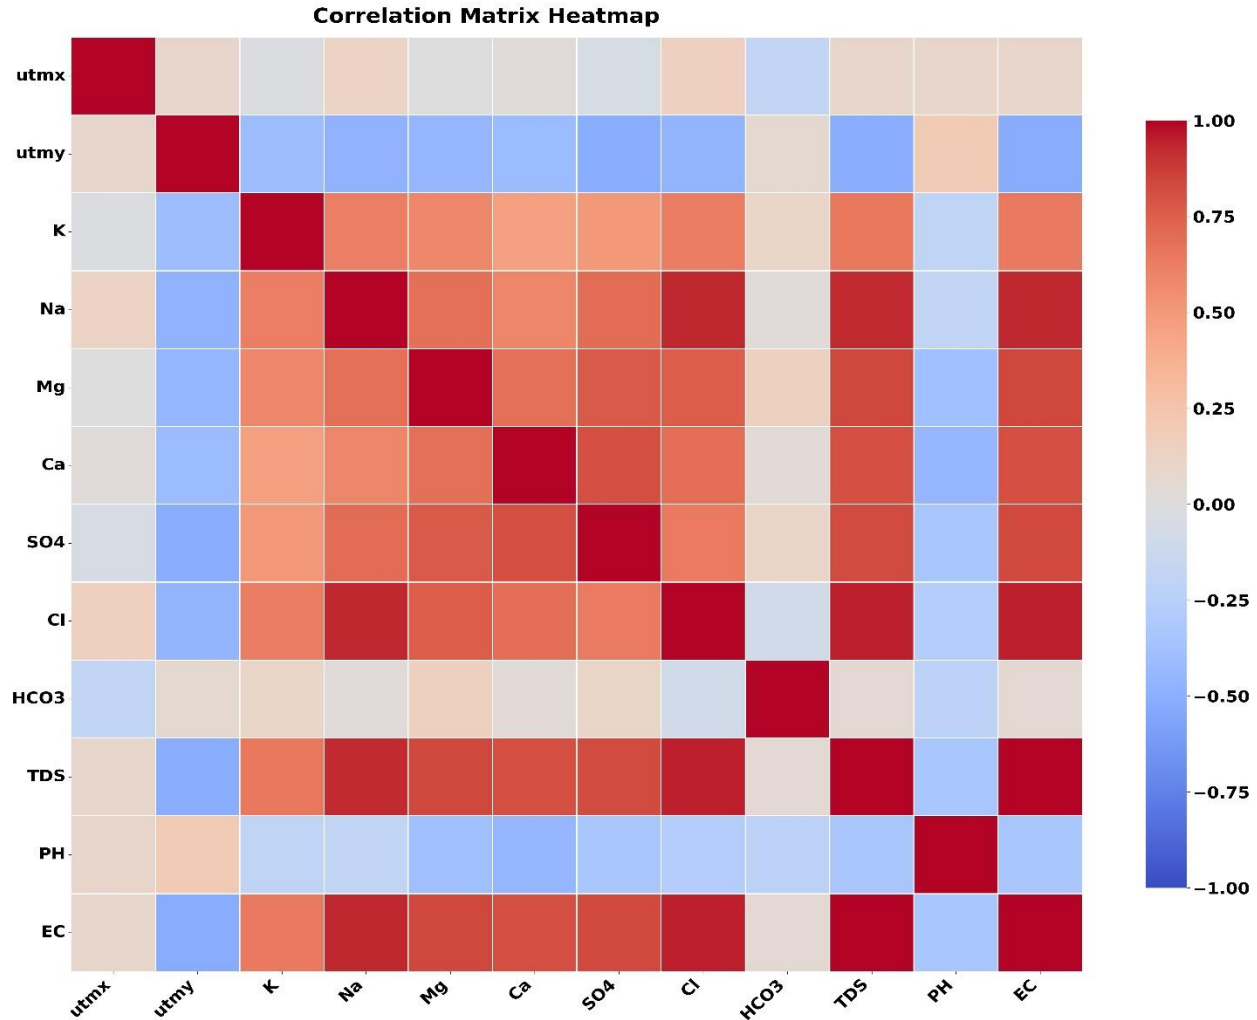


Fig. 3- Correlation Matrix of Groundwater Quality Parameters

شکل ۳- ماتریس همبستگی پارامترهای کیفیت آب زیرزمینی

۳-۲- همبستگی تراز سطح آب زیرزمینی با عوامل اقلیمی

شکل ۴ ماتریس همبستگی رابطه بین تراز سطح آب زیرزمینی (L_1-L_{12})، بارش ماهانه (p_1-p_{12}) و دمای ماهانه (t_1-t_{12}) را نشان می‌دهد. همبستگی کامل (۱/۰۰) بین تمام ماه‌های تراز آب زیرزمینی نشان می‌دهد که سطح آب در طول سال روند یکنواخت و پایداری دارد و تغییرات فصلی محسوسی را تجربه نمی‌کند، که این موضوع می‌تواند ناشی از ضخامت زیاد ناحیه غیراشباع و عمق زیاد سطح ایستابی، ظرفیت ذخیره بالا، یا برداشت مداوم و یکنواخت باشد. همبستگی‌های بسیار ضعیف و متغیر بین بارش ماهانه و تراز آب (معمولاً کمتر از ۰/۴) بیانگر این است که تغذیه آبخوان به صورت مستقیم و فوری از بارش صورت نمی‌گیرد، بلکه احتمالاً با تأخیر زمانی قابل توجه، نفوذ کند از طریق لایه‌های غیراشباع، یا تحت تأثیر عوامل دیگری مانند رواناب سطحی و تبخیر-تعرق انجام می‌شود. همبستگی‌های منفی بین دما و تراز آب (حدود ۰/۱۴- تا ۰/۲۳-) نشان می‌دهد که در ماه‌های گرم‌تر، سطح آب کاهش می‌یابد که می‌تواند ناشی از افزایش تبخیر-تعرق، افزایش برداشت برای مصارف کشاورزی در فصل گرم، یا کاهش تغذیه باشد. همبستگی‌های منفی قوی بین بارش و دما در برخی ماه‌ها (مانند ۰/۲۹- در $p_{12}-t_{12}$) منطبق با الگوی آب و هوایی است که در آن ماه‌های سرد معمولاً بارندگی بیشتری دارند. در مجموع، این الگوها نشان می‌دهد که آبخوان مورد مطالعه یک سیستم با



اینرسی بالا و پاسخ کند به تغییرات محیطی است که در آن رابطه مستقیم و فوری بین بارش و سطح آب وجود ندارد، و این موضوع بر اهمیت مدیریت بلندمدت و پایش مستمر برای حفظ پایداری منابع آب زیرزمینی تأکید می‌کند.

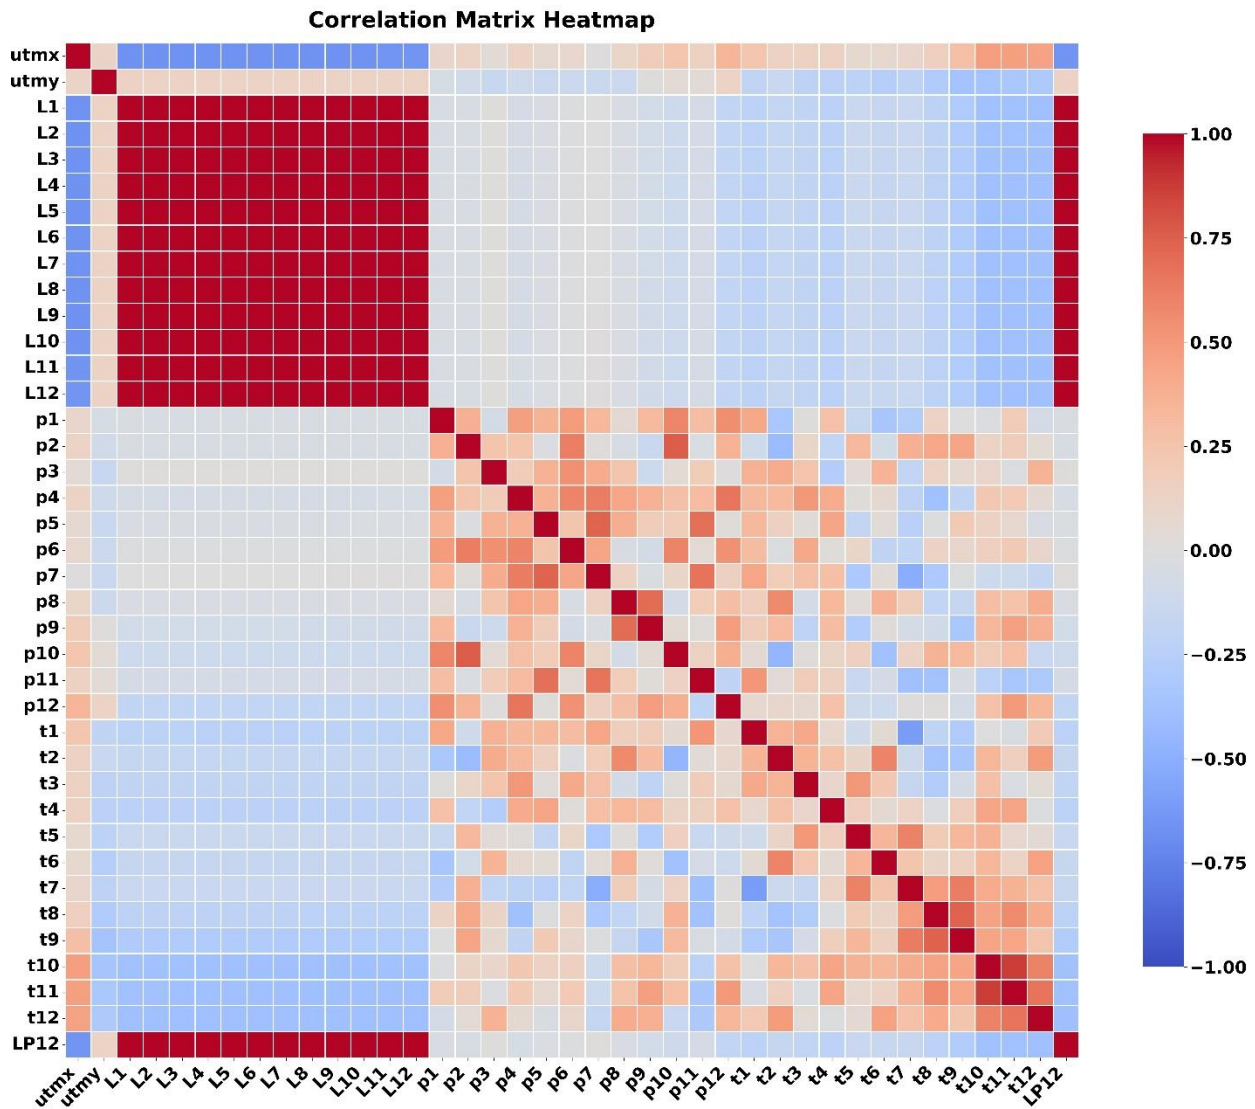


Fig. 4- Correlation Matrix of groundwater level, Monthly precipitation and temperature

شکل ۴ - ماتریس همبستگی تراز سطح آب زیرزمینی، بارش و دما ماهانه

۳-۳- نتایج شبیه سازی کیفیت آب زیرزمینی (EC)

با توجه به جدول ۴ معیارهای ارزیابی، شکل ۵ نمودارهای پراکندگی و شکل ۶ نمودارهای مقایسه مقادیر واقعی و پیش‌بینی شده تحلیل جامع عملکرد چهار مدل در پیش‌بینی پارامتر EC آب زیرزمینی به شرح زیر می‌باشد.

با توجه به جدول ۴ معیارهای ارزیابی، مدل‌های RF و GBR عملکرد برتر و بسیار نزدیک به هم را نشان داده‌اند. در مرحله تست، مدل RF با R^2 برابر با ۰/۹۹، NSE برابر با ۰/۹۹، MAE برابر با ۵۸/۹۱ و nRMSE برابر با ۰/۱۴۲ و مدل GBR با R^2 برابر با ۰/۹۹، NSE برابر با ۰/۹۹، MAE برابر با ۵۸/۶۱ از دقت بسیار بالایی برخوردار هستند. مدل XGBoost نیز با R^2 و NSE برابر با ۰/۹۹۱۰، MAE برابر با ۶۲/۰۰۵



و nRMSE برابر با ۰/۰۱۶۰ عملکرد بسیار مناسبی را نشان داده است. با توجه به شکل ۵، نمودارهای پراکندگی هر سه مدل (XGBoost, RF) و GBR) نشان می‌دهند که نقاط به شدت نزدیک به خط یک به یک قرار گرفته‌اند و کم‌ترین انحراف را دارند، به‌ویژه مدل‌های RF و GBR که تقریباً تمامی نقاط روی خط ایده‌آل واقع شده‌اند. با توجه به شکل ۶، نمودارهای مقایسه مقادیر واقعی و پیش‌بینی شده نیز تأیید می‌کنند که خطوط واقعی و پیش‌بینی شده تقریباً کاملاً بر هم منطبق هستند و این مدل‌ها توانسته‌اند تمام نوسانات، از مقادیر کمینه تا نقاط بیشینه، را با دقت بالایی پیش‌بینی کنند و حتی در شرایط نوسانات شدید و ناگهانی نیز همخوانی مناسبی بین مقادیر واقعی و پیش‌بینی شده مشاهده می‌شود. با توجه به جدول ۴ معیارهای ارزیابی، مدل KNN با R^2 برابر با ۰/۹۷، NSE برابر با ۰/۹۷، MAE برابر با ۱۱۵/۳۷ و nRMSE برابر با ۰/۰۲۵۵ عملکرد ضعیف‌تری را در مقایسه با سه مدل دیگر نشان داده است. با توجه به شکل ۵، نمودار پراکندگی این مدل پراکندگی و انحراف قابل توجهی را در نقاط، به‌ویژه در محدوده مقادیر متوسط و بالاتر نمایان می‌سازد، به طوری که نقاط به صورت پراکنده‌تری پیرامون خط یک به یک توزیع یافته‌اند. با توجه به شکل ۶، مقایسه مقادیر واقعی و پیش‌بینی شده نیز انحرافات را در پیش‌بینی نوسانات شدید و نقاط بیشینه آشکار می‌کند و نشان می‌دهد که مدل KNN نتوانسته دامنه نوسانات را به درستی شبیه‌سازی کند.

جدول ۴- ارزیابی عملکرد مدل‌های KNN, RF, XGBoost و GBR در پیش‌بینی کیفیت آب زیرزمینی (EC) بر اساس

شاخص‌های آماری در مراحل آموزش و آزمون

Table 4- Performance evaluation of KNN, RF, XGBoost and GBR models in predicting Groundwater quality (EC) based on statistical indices in the train and test stages

Model	Train					Test				
	MAE	R	R ²	NSE	nRMSE	MAE	R	R ²	NSE	nRMSE
KNN	84.4720	0.9938	0.9865	0.9865	0.0151	115.377	0.9890	0.9772	0.9772	0.0255
RF	21.6462	0.9994	0.9988	0.9988	0.0046	58.9195	0.9965	0.9929	0.9929	0.0142
XGBoost	18.3538	0.9997	0.9995	0.9995	0.0028	62.0052	0.995	0.9910	0.991	0.0160
GBR	36.3105	0.9990	0.9980	0.9980	0.0058	58.6144	0.9963	0.9927	0.9927	0.0144

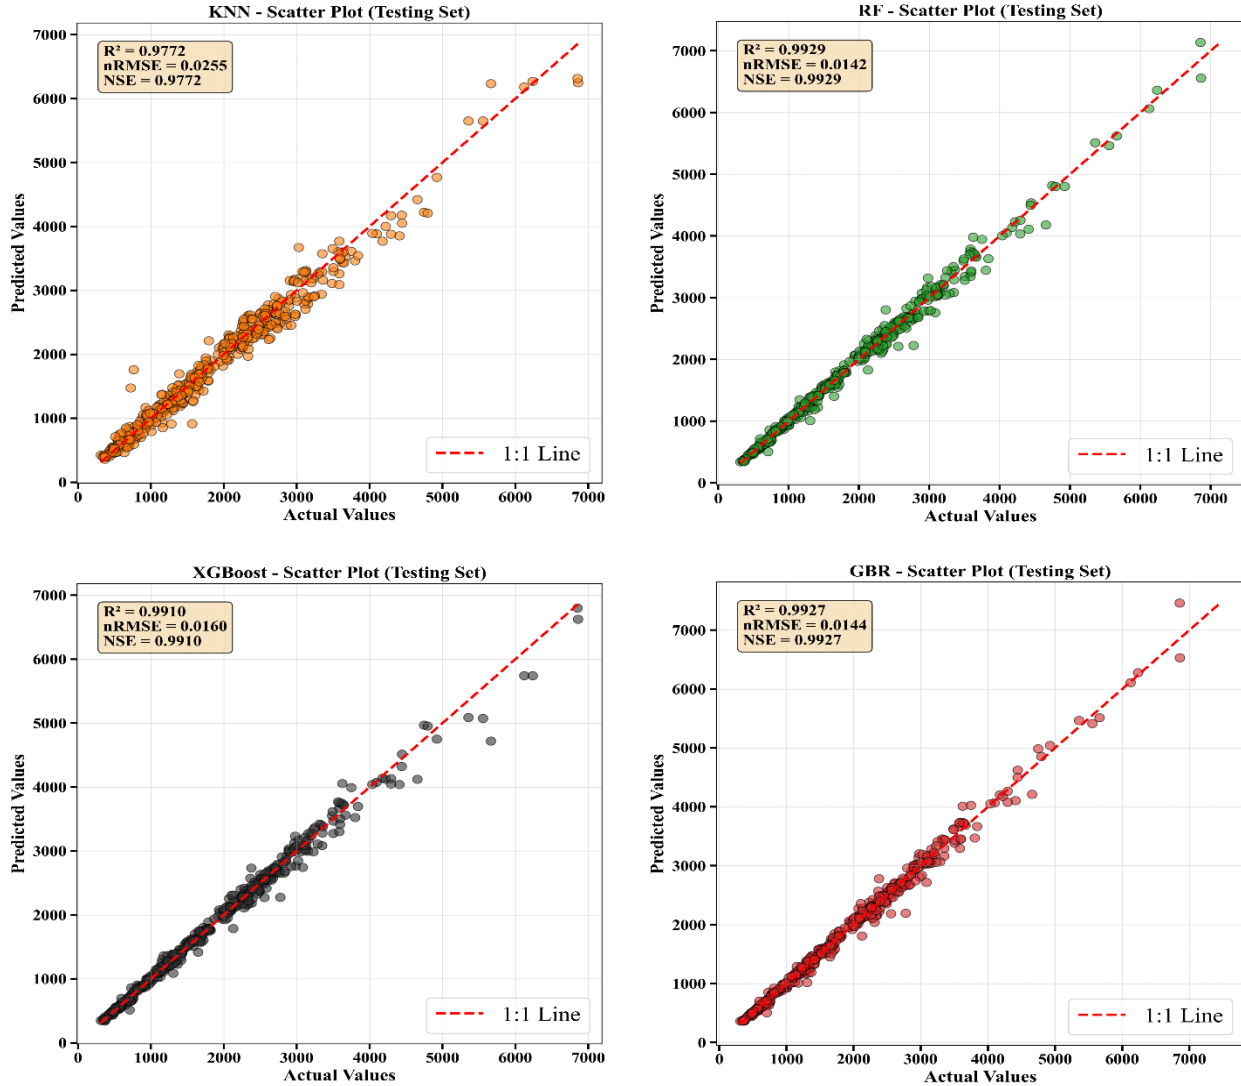


Fig. 5- Scatter plots of observed and predicted EC in the test stage

شکل ۵- نمودارهای پراکندگی EC مشاهده شده و پیش‌بینی شده در مرحله آزمون

اسناد

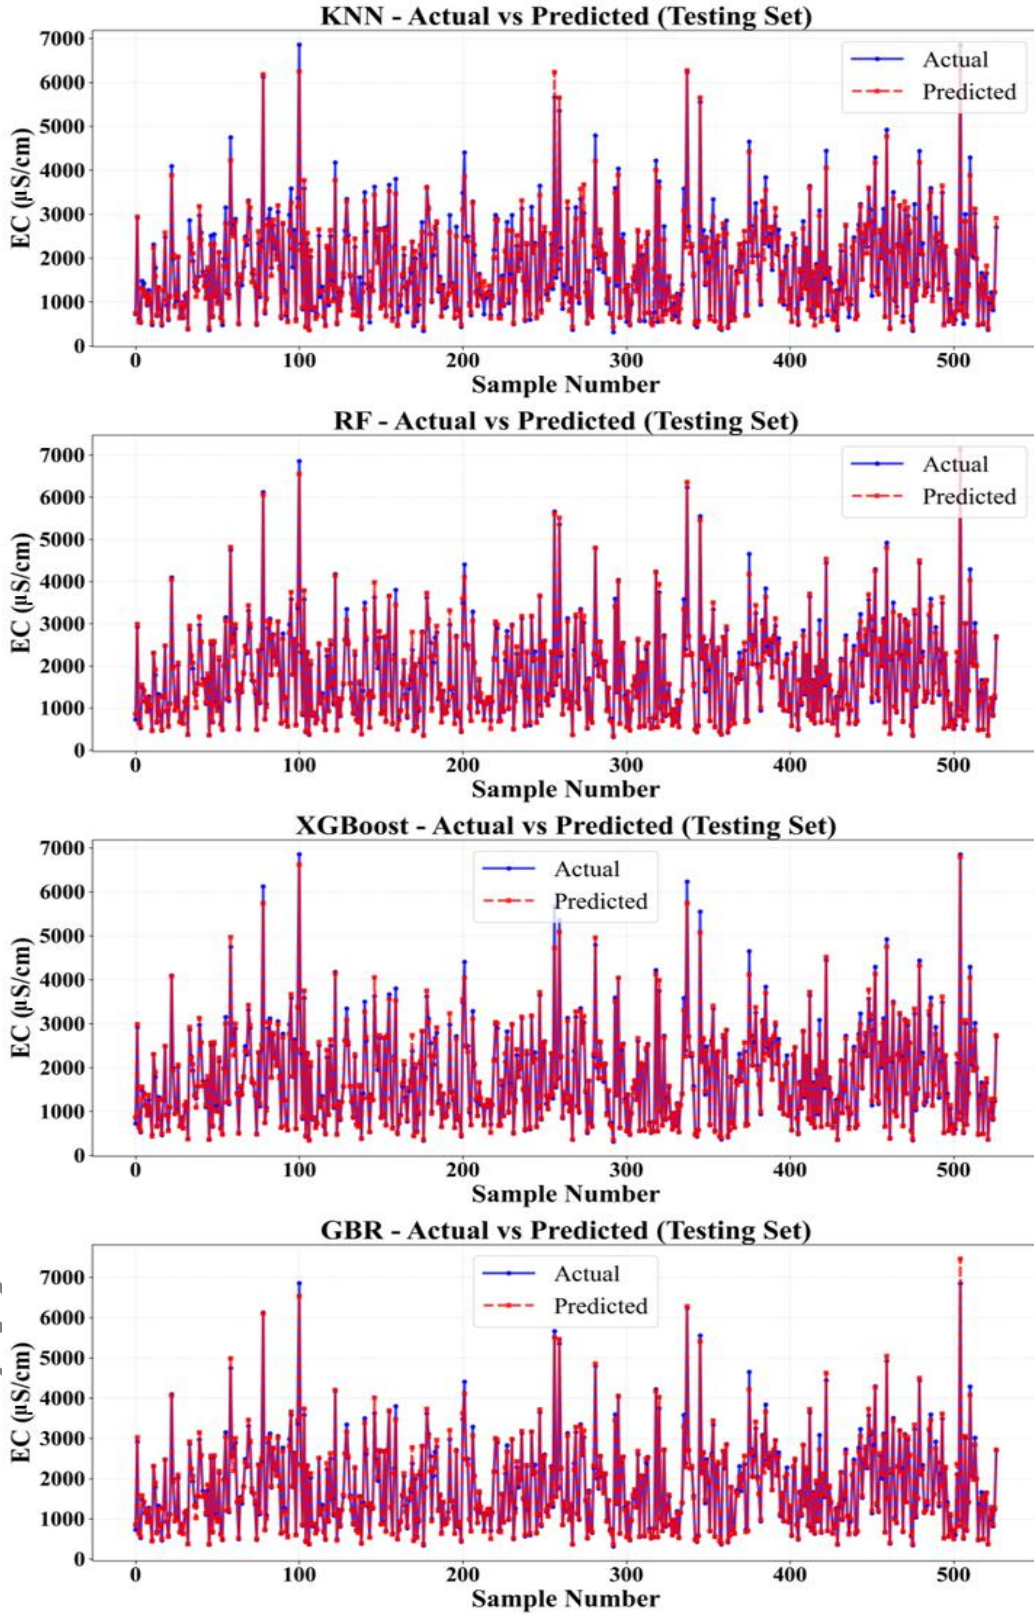


Fig. 6- Comparison of actual and predicted EC in the test stage

شکل ۶- مقایسه مقادیر واقعی و پیش‌بینی شده EC در مرحله آزمون



با تحلیل شکل ۷ نمودار اهمیت ویژگی‌ها، تفاوت اساسی مدل KNN با سه مدل دیگر مشخص شده است. در مدل KNN، توزیع اهمیت ویژگی‌ها نسبتاً متعادل و گسترده است و پارامترهای Na، Cl، TDS، SO₄، Ca و Mg به ترتیب مهم‌ترین نقش را دارند، به طوری که اهمیت آن‌ها به صورت تدریجی از حدود ۰/۰۷ تا ۰/۰۳ کاهش می‌یابد و سایر پارامترها نیز اهمیت‌های کوچک‌تر اما قابل توجهی دارند. این الگو نشان می‌دهد که مدل KNN به طور یکنواخت به ویژگی‌های مختلف توجه کرده و نتوانسته ساختار اصلی و مهم‌ترین رابطه بین متغیرها را به درستی شناسایی کند. در مقابل، مدل‌های RF، XGBoost و GBR الگوی کاملاً متفاوت و متمرکزی نشان می‌دهند. در هر سه مدل، پارامتر TDS با اهمیت نزدیک به ۱/۰ (تقریباً ۱۰۰ درصد) به عنوان تنها و مهم‌ترین ویژگی و قوی‌ترین پیش‌بینی‌کننده EC شناسایی شده است و تمامی پارامترهای دیگر شامل Na، Cl، SO₄، Ca، Mg و سایر ویژگی‌ها اهمیت بسیار ناچیز و تقریباً صفر دارند. این تمرکز شدید بر پارامتر TDS در مدل‌های RF، XGBoost و GBR نشان‌دهنده شناسایی دقیق رابطه بنیادین و مستقیم بین TDS و EC است که از نظر علمی نیز قابل توجیه است، چراکه هدایت الکتریکی (EC) به طور مستقیم و قوی به مجموع جامدات محلول (TDS) وابسته است. این تفاوت بنیادین در شناسایی ساختار اهمیت ویژگی‌ها توضیح می‌دهد که چرا مدل‌های RF، XGBoost و GBR عملکرد بهتری نسبت به KNN داشتند. این مدل‌ها با تمرکز بر مهم‌ترین ویژگی و شناسایی صحیح رابطه غالب بین EC و TDS، پیش‌بینی دقیق‌تری ارائه کرده‌اند و توانسته‌اند نویز ناشی از سایر متغیرها را به حداقل برسانند. در واقع مدل‌های گروهی برای مسائل با تعداد ویژگی زیاد، سری‌های زمانی پیچیده و وجود نوسانات برتری دارند. مدل KNN تنها بر اساس فاصله اقلیدسی عمل می‌کند و توانایی شناسایی روابط را ندارد، در حالی که مدل‌های گروهی با ساختارهای درختی قادر به کشف الگوها هستند. مدل KNN با توجه پراکنده و یکنواخت به ویژگی‌های مختلف، نتوانسته ساختار اصلی داده‌ها را درک کند و احتمالاً نویز و اطلاعات غیرمرتبط بیشتری را وارد مدل کرده است که منجر به کاهش دقت پیش‌بینی شده است. در مجموع، با توجه به معیارهای کمی جدول، نمودارهای پراکندگی و الگوهای زمانی به وضوح نشان می‌دهند که مدل‌های مبتنی بر یادگیری گروهی (RF، XGBoost و GBR) با توانایی شناسایی مهم‌ترین رابطه بین متغیرها (رابطه EC-TD)، به دلیل قدرت برتر در کاهش واریانس، مدیریت داده‌ها، شناسایی دقیق الگوهای و نوسانات زمانی، فیلترسازی نویز و قابلیت تعمیم‌دهی عالی، انتخاب مناسب‌تری برای پیش‌بینی کیفیت آب زیرزمینی (EC) در این مطالعه هستند. مدل RF با کم‌ترین MAE در مرحله تست، اندکی از دو مدل دیگر برتر بوده و در تمامی جنبه‌های ارزیابی برتری خود را اثبات کرده است.

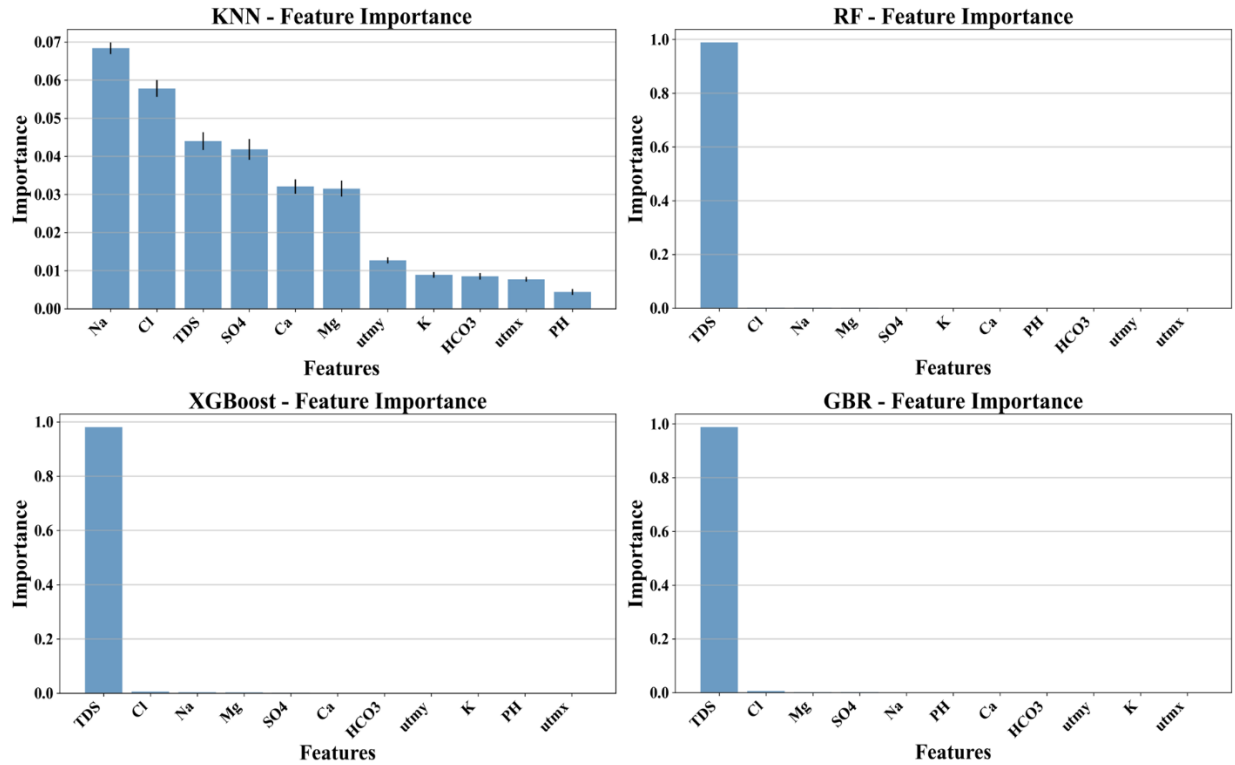


Fig. 7- Feature importance plots of predicted EC

شکل ۷- نمودارهای اهمیت ویژگی‌ها در پیش‌بینی EC

۳-۴- نتایج شبیه سازی تراز سطح آب زیرزمینی

با توجه به جدول ۵ معیارهای ارزیابی، شکل ۸ نمودارهای پراکندگی و شکل ۹ نمودارهای مقایسه مقادیر واقعی و پیش‌بینی شده تحلیل جامع عملکرد چهار مدل در پیش‌بینی تراز سطح آب زیرزمینی به شرح زیر می‌باشد.

با توجه به جدول ۵ معیارهای ارزیابی، مدل‌های RF، XGBoost و GBR عملکرد برتر و بسیار نزدیک به هم را نشان داده‌اند. در مرحله تست، مدل RF با R^2 برابر با ۰/۹۹۹۳، NSE برابر با ۰/۹۹۸، MAE برابر با ۱/۴۱ و nRMSE برابر با ۰/۰۰۶۸، مدل GBR با R^2 برابر با ۰/۹۹۹۳، NSE برابر با ۰/۹۹۸۸، MAE برابر با ۱/۳۳ و مدل XGBoost با R^2 برابر با ۰/۹۹۸۲، NSE برابر با ۰/۹۹۸، MAE برابر با ۱/۵۰ و nRMSE برابر با ۰/۰۰۷۸ از دقت بسیار بالایی برخوردار هستند. با توجه به شکل ۸، نمودارهای پراکندگی هر سه مدل نشان می‌دهند که نقاط به شدت نزدیک به خط یک به یک قرار گرفته‌اند و کم‌ترین انحراف را دارند، به طوری که تقریباً تمامی نقاط روی خط ایده‌آل واقع شده‌اند. با توجه به شکل ۹، نمودارهای مقایسه مقادیر واقعی و پیش‌بینی شده نیز تأیید می‌کنند که خطوط واقعی و پیش‌بینی شده تقریباً کاملاً بر هم منطبق هستند و این مدل‌ها توانسته‌اند تمام نوسانات، از مقادیر کمینه تا نقاط بیشینه، را با دقت بالایی پیش‌بینی کنند و حتی در نوسانات شدید و ناگهانی نیز عملکرد پایداری داشته‌اند.

با توجه به جدول ۵ معیارهای ارزیابی، مدل KNN با MAE برابر با ۸/۰۷ عملکرد ضعیف‌تری را در مقایسه با سه مدل دیگر نشان داده است. با توجه به شکل ۸، نمودار پراکندگی این مدل پراکندگی و انحراف قابل توجهی را در نقاط، به ویژه در محدوده مقادیر متوسط و بالاتر نمایان می‌سازد، به طوری که نقاط به صورت ابری پیرامون خط یک به یک توزیع یافته‌اند و فاصله آن‌ها از خط ایده‌آل به وضوح مشهود است. با توجه به شکل ۹، نمودار مقایسه مقادیر واقعی و پیش‌بینی شده نیز انحرافات قابل ملاحظه‌ای را در پیش‌بینی نوسانات شدید و نقاط بیشینه آشکار می‌کند، به گونه‌ای که در بسیاری از نقاط، خط پیش‌بینی با خط واقعی فاصله محسوسی دارد و مدل نتوانسته دامنه نوسانات را به درستی شبیه‌سازی کند.

جدول ۵- ارزیابی عملکرد مدل‌های KNN، RF، XGBoost و GBR در پیش‌بینی تراز سطح آب زیرزمینی بر اساس شاخص‌های آماری در مراحل آموزش و آزمون

Table 5- Performance evaluation of KNN, RF, XGBoost and GBR models in predicting Groundwater level based on statistical indices in the train and test stages

Model	Train					Test				
	MAE	R	R ²	NSE	nRMSE	MAE	R	R ²	NSE	nRMSE
KNN	6.4242	0.9880	0.9746	0.9747	0.0306	8.0717	0.9799	0.9592	0.9593	0.0376
RF	0.5448	0.9999	0.9998	0.9998	0.0026	1.4175	0.9993	0.9993	0.9987	0.0068
XGBoost	0.4223	0.9999	0.9999	0.9999	0.0019	1.5086	0.999	0.998	0.998	0.0078
GBR	0.8226	0.9998	0.9996	0.9996	0.0037	1.3310	0.9993	0.9993	0.9988	0.0066

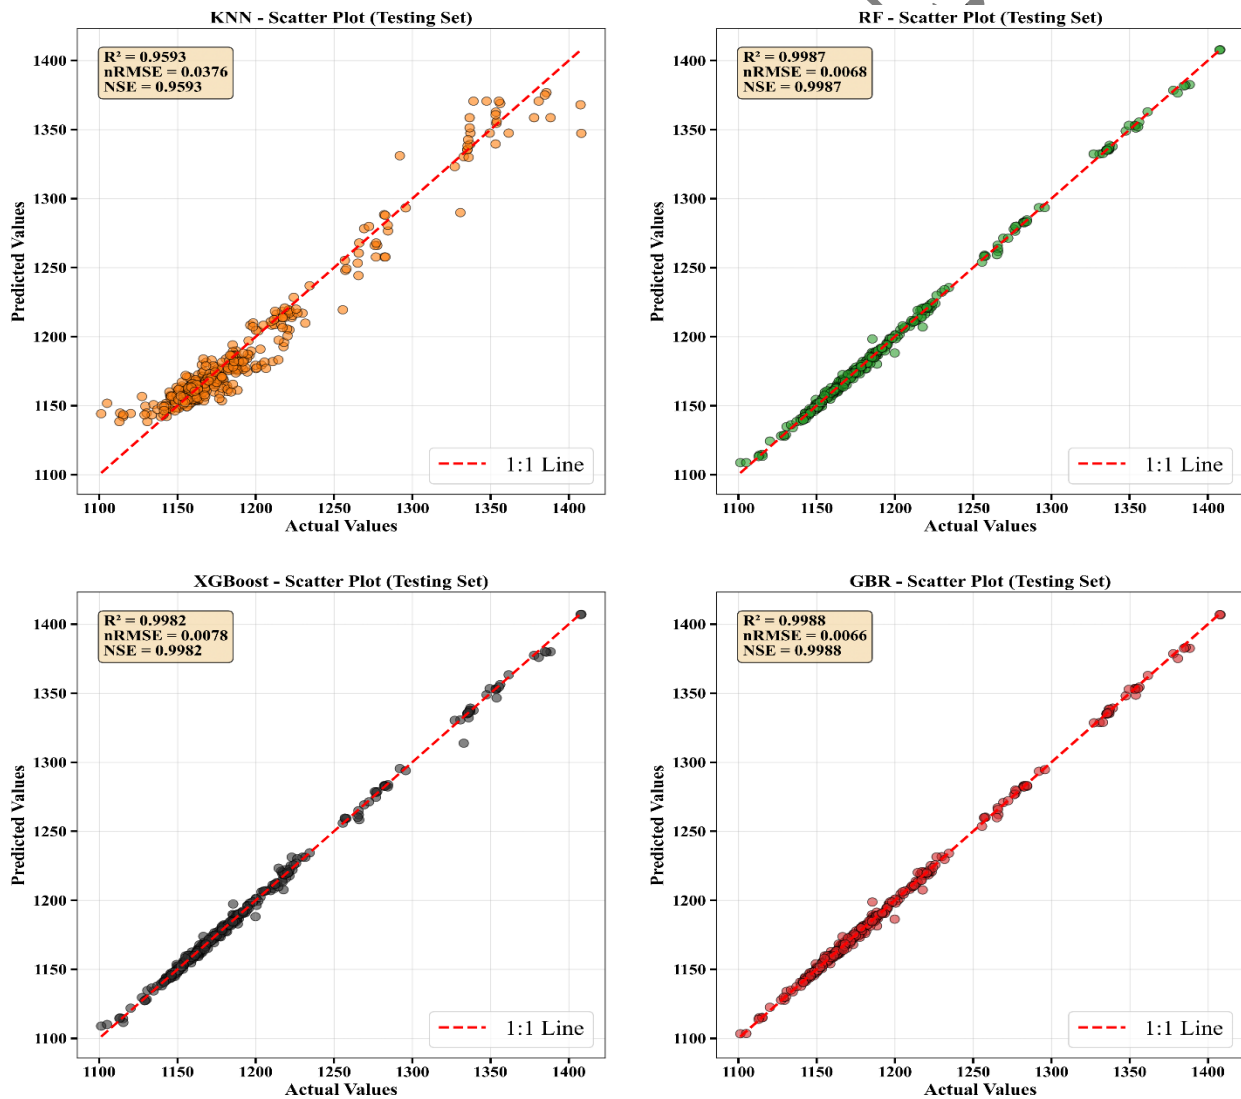


Fig. 8- Scatter plots of observed and predicted GWL in the test stage

شکل ۸- نمودارهای پراکندگی تراز سطح آب زیرزمینی مشاهده شده و پیش‌بینی شده در مرحله آزمون

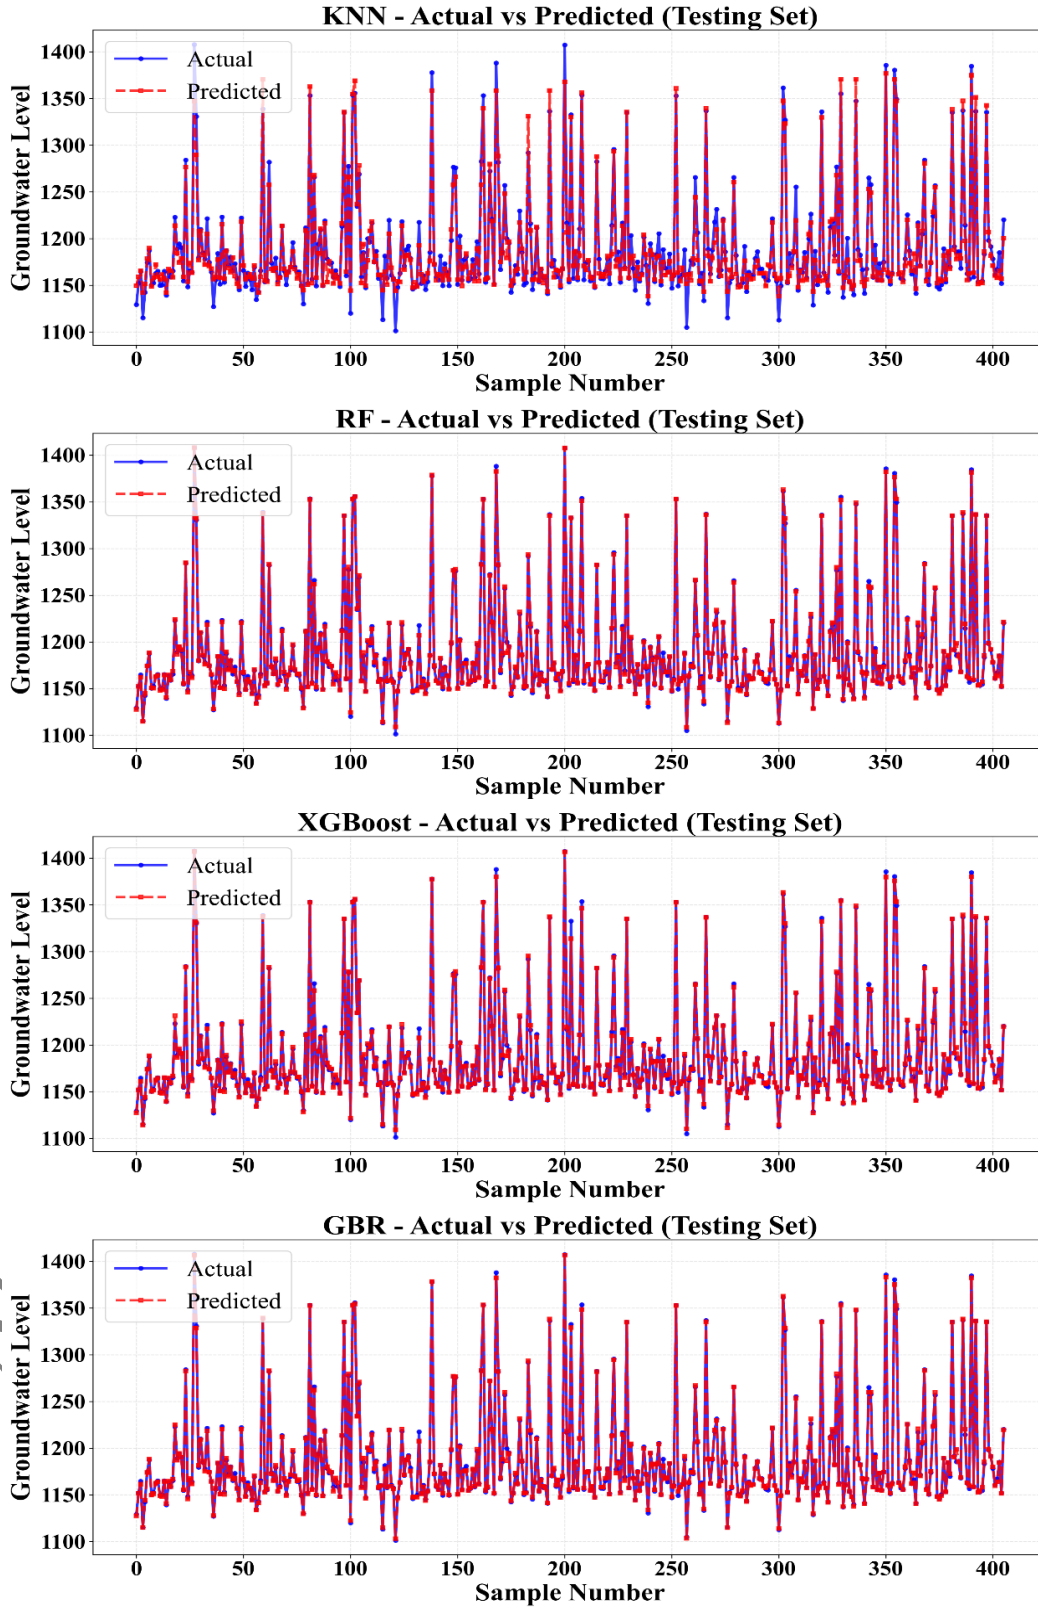


Fig. 9- Comparison of actual and predicted GWL in the test stage

شکل ۹- مقایسه مقادیر واقعی و پیش‌بینی شده تراز سطح آب زیرزمینی در مرحله آزمون



با تحلیل شکل ۱۰ نمودار اهمیت ویژگی‌ها، تفاوت اساسی مدل KNN با سه مدل دیگر مشخص شده است. در مدل KNN، توزیع اهمیت ویژگی‌ها نسبتاً یکنواخت و متعادل است و تمامی داده‌های تراز سطح آب زیرزمینی (L_1 تا L_{12}) دارای اهمیت مشابه و تقریباً برابری هستند، درحالی‌که پارامترهای دما (T) و بارش (P) اهمیت منفی یا بسیار ناچیزی دارند. این الگو نشان می‌دهد که مدل KNN نتوانسته ساختار زمانی و وابستگی‌های غیرخطی بین متغیرها را به درستی شناسایی کند و به جای تمرکز بر مهم‌ترین ویژگی‌ها، به طور یکسان به تمام متغیرها توجه کرده است.

در مقابل، مدل‌های RF، XGBoost و GBR الگوی کاملاً متفاوت و سلسله مراتبی مشخصی نشان می‌دهند. در مدل RF، تراز آب زیرزمینی ماه‌های نزدیک‌تر (L_1 ، L_2 ، L_3) با اهمیت بالای حدود ۰/۲۷، ۰/۱۲ و ۰/۱۱ به ترتیب به عنوان مهم‌ترین پیش‌بینی‌کننده‌ها شناسایی شده‌اند و با افزایش تأخیر زمانی، اهمیت ویژگی‌ها به تدریج کاهش می‌یابد. در مدل XGBoost، این الگو بسیار برجسته‌تر است و تراز ماه اول (L_1) با اهمیت حدود ۰/۵۵ به عنوان غالب‌ترین ویژگی مطرح است و تراز ماه دوم (L_2) با اهمیت حدود ۰/۱۸ در رتبه دوم قرار دارد، و سایر ویژگی‌ها اهمیت بسیار کم‌تری دارند. مدل GBR نیز روند مشابهی را نشان می‌دهد، به طوری که L_1 با اهمیت حدود ۰/۴، L_2 با حدود ۰/۲۴ و L_3 با حدود ۰/۱۶ بیش‌ترین نقش را دارند و اهمیت سایر متغیرها به سرعت کاهش می‌یابد. در هر سه مدل، پارامترهای بارش و دما نیز اهمیت ناچیزی دارند.

این تفاوت بنیادین در شناسایی ساختار اهمیت ویژگی‌ها توضیح می‌دهد که چرا مدل‌های RF، XGBoost و GBR عملکرد بهتری نسبت به مدل KNN داشتند. این مدل‌ها با تمرکز هوشمندانه بر تأثیرگذارترین ویژگی‌ها (به ویژه تراز ماه‌های نزدیک) و شناسایی صحیح وابستگی زمانی و الگوهای غیرخطی در داده‌ها، پیش‌بینی دقیق‌تری ارائه کرده‌اند. در حالی که مدل KNN با توجه یکنواخت و پراکنده به تمامی ویژگی‌ها، نتوانسته ساختار زمانی داده‌ها را درک کند و احتمالاً نویز و اطلاعات غیرمرتبط بیش‌تری را وارد مدل کرده است.

در مجموع، با توجه به معیارهای کمی جدول و نمودارهای پراکنده‌گی به وضوح نشان می‌دهند که مدل‌های مبتنی بر یادگیری گروهی (RF، XGBoost و GBR) با توانایی شناسایی دقیق ساختار سلسله مراتبی اهمیت ویژگی‌ها و روابط پیچیده زمانی بین متغیرها، به دلیل قدرت برتر در کاهش واریانس، مدیریت داده‌های پیچیده، شناسایی دقیق الگوهای غیرخطی و وابستگی‌های زمانی و قابلیت تعمیم‌دهی عالی، انتخاب مناسب‌تری برای پیش‌بینی تراز سطح آب زیرزمینی در این مطالعه هستند. مدل GBR با کم‌ترین MAE و nRMSE در مرحله تست، با اختلاف خیلی کم از دو مدل دیگر برتر بوده و در تمامی جنبه‌های ارزیابی برتری خود را اثبات کرده است.

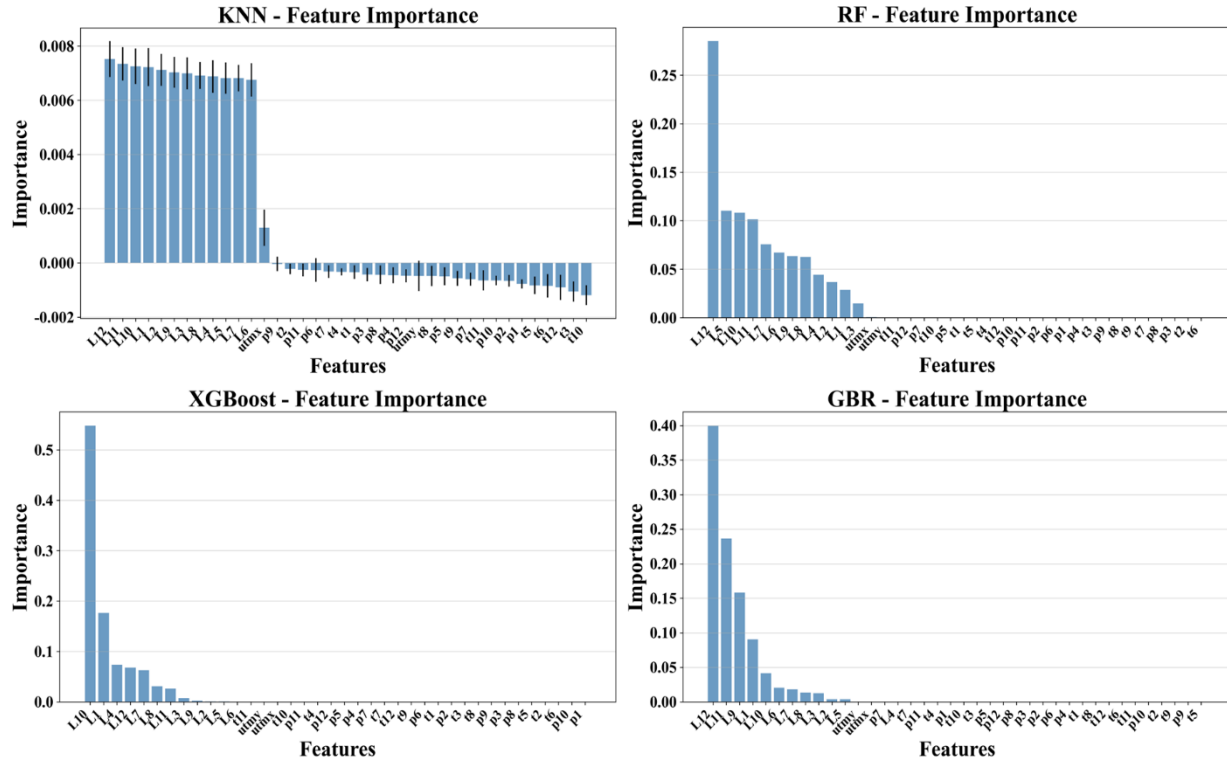


Fig. 10- Feature importance plots of predicted GWL
 شکل ۱۰- نمودارهای اهمیت ویژگی‌ها در پیش‌بینی تراز سطح آب زیرزمینی

۳-۵- ارزیابی مدل‌های هوش مصنوعی

با توجه به شکل ۱۱ نمودارهای رادار، شکل ۱۲ نمودارهای جعبه‌ای و شکل ۱۳ نمودارهای تیلور، برای کیفیت آب زیرزمینی و تراز سطح آب زیرزمینی، تحلیل جامع عملکرد مدل‌ها به شرح زیر می‌باشد.

با توجه به شکل ۱۱ نمودارهای رادار که چهار معیار ارزیابی شامل ضریب همبستگی پیرسون، R^2 ، MAE و MSE را به صورت هم‌زمان نمایش می‌دهند، الگوی واضحی از عملکرد مدل‌ها ارائه می‌کنند. در نمودارهای رادار، هر محور نشان‌دهنده یک معیار نرمال شده (تا ۱) است. مساحت بزرگ‌تر چندضلعی نشان‌دهنده عملکرد بهتر است. همپوشانی RF، XGBoost و GBR نشان‌دهنده عملکرد یکسان این سه مدل است. برای مقایسه دقیق‌تر معیارهای خطا در نمودارهای رادار، می‌توان به محورهای MAE و MSE توجه ویژه کرد. در این نمودارها، مقادیر خطا به صورت معکوس نرمال‌سازی شده‌اند، به این معنی که مقدار بالاتر در نمودار رادار (نزدیک‌تر به مرز بیرونی) نشان‌دهنده خطای پایین‌تر و عملکرد بهتر است. در هر دو پارامتر کیفیت و تراز آب زیرزمینی، مدل‌های RF، XGBoost و GBR چندضلعی‌های بسیار بزرگ و منبسطی را تشکیل داده‌اند که تقریباً به مرزهای بیرونی نمودار رادار نزدیک‌اند و تقریباً بر یکدیگر منطبق هستند. این همپوشانی نشان می‌دهد که هر سه مدل در تمامی معیارهای ارزیابی عملکرد بسیار نزدیک و برتری دارند و مقادیر بالای ضریب همبستگی و R^2 (نزدیک به ۰/۹۹ تا ۱) و مقادیر پایین MAE و MSE را کسب کرده‌اند. در مقابل، مدل KNN چندضلعی کوچک‌تر و منقبض‌تری را تشکیل می‌دهد که به‌وضوح از سه مدل دیگر فاصله دارد، به‌ویژه در محورهای MAE و MSE که نشان‌دهنده خطای بالاتر این مدل است. این تفاوت در هر دو پارامتر کیفیت و تراز سطح آب زیرزمینی به‌طور سازگار مشاهده می‌شود.

با توجه به شکل ۱۲ نمودارهای جعبه‌ای، توزیع خطاها و مقادیر پیش‌بینی شده برای کیفیت آب زیرزمینی (EC) و تراز سطح آب زیرزمینی (GWL) در چهار مدل ارائه می‌دهند و به وضوح برتری مدل‌های مبتنی بر یادگیری گروهی را نشان می‌دهند. در شبیه‌سازی کیفیت و تراز سطح



آب زیرزمینی، مدل‌های RF، XGBoost و GBR جعبه‌های بسیار فشرده و متقارنی با میانه نزدیک به صفر دارند که بیانگر توزیع نرمال و متمرکز خطاها حول صفر و پایداری بالا در پیش‌بینی است، در حالی که مدل KNN جعبه بزرگ‌تر و پراکندگی قابل توجهی در خطاها با تعداد بیشتری نقاط پرت نشان می‌دهد، به‌ویژه در پیش‌بینی GWL که خطاهای منفی تا ۶۰- متر مشاهده می‌شود. در بخش توزیع مقادیر واقعی در مقابل پیش‌بینی شده، تمام مدل‌ها توزیع مشابهی با میانه حدود ۱۷۰۰-۲۰۰۰ میکروزیمنس بر سانتی‌متر برای EC و ۱۱۸۰-۱۱۹۰ متر برای GWL دارند، اما مدل KNN دارای پراکندگی و دامنه بین‌چارکی متفاوتی است که نشان‌دهنده عدم قطعیت بیشتر در پیش‌بینی‌های آن می‌باشد. این نمودارها تأیید می‌کنند که مدل‌های گروهی نه تنها از نظر معیارهای آماری بلکه از نظر توزیع خطاها و کنترل نقاط پرت نیز عملکرد برتر و پایدارتری دارند، در حالی که مدل KNN دچار خطاهای سیستماتیک بزرگ‌تر و ضعف در قابلیت تعمیم‌پذیری است. این نمودارها به وضوح تأیید می‌کنند که مدل‌های مبتنی بر یادگیری گروهی (RF، XGBoost و GBR) نه تنها از نظر معیارهای آماری بلکه از نظر توزیع خطاها نیز عملکرد برتر و پایدارتری دارند، در حالی که مدل KNN دچار خطا، پراکندگی بیشتر و نقاط پرت بیشتری می‌شود که همگی نشانه ضعف در قابلیت تعمیم‌پذیری و عدم توانایی در شناسایی دقیق الگوهای پیچیده داده‌ها است.

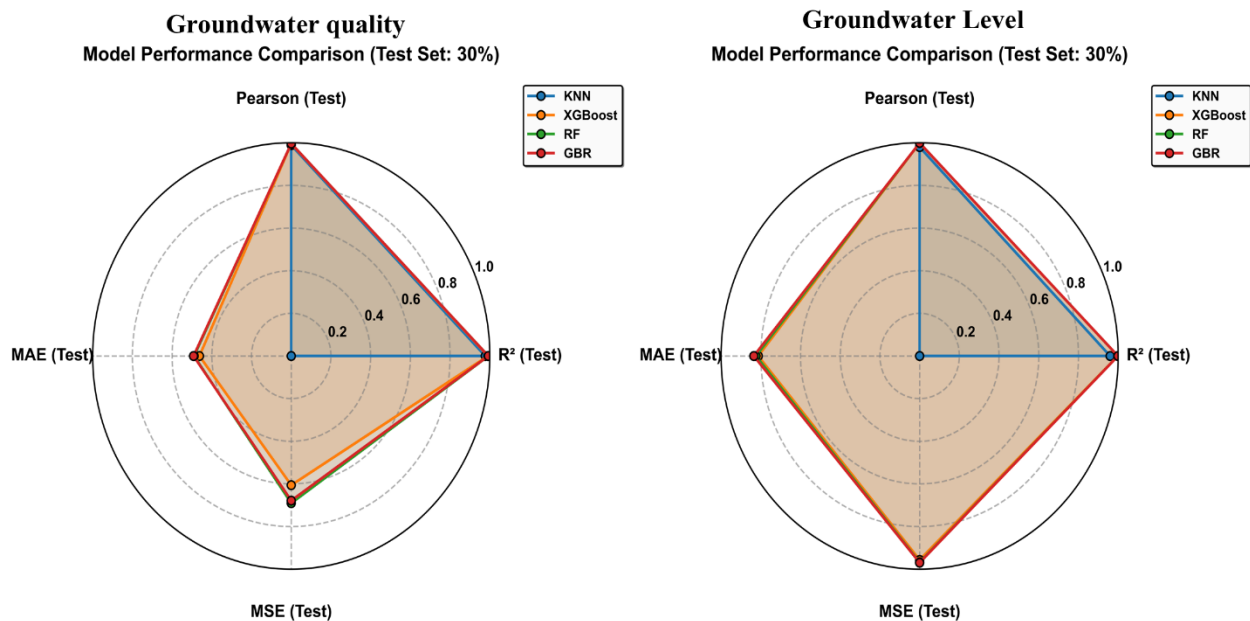
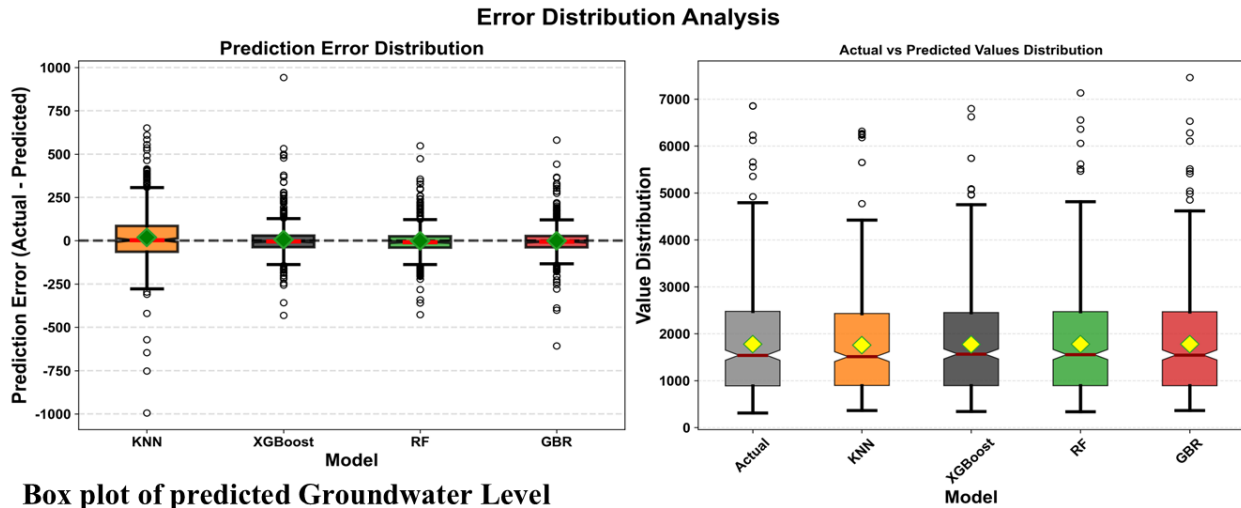


Fig. 11- Radar charts of predicted Groundwater Level, Groundwater quality

شکل ۱۱- نمودارهای رادار تراز سطح آب زیرزمینی و کیفیت آب زیرزمینی پیش‌بینی شده

Box plot of predicted Groundwater quality



Box plot of predicted Groundwater Level

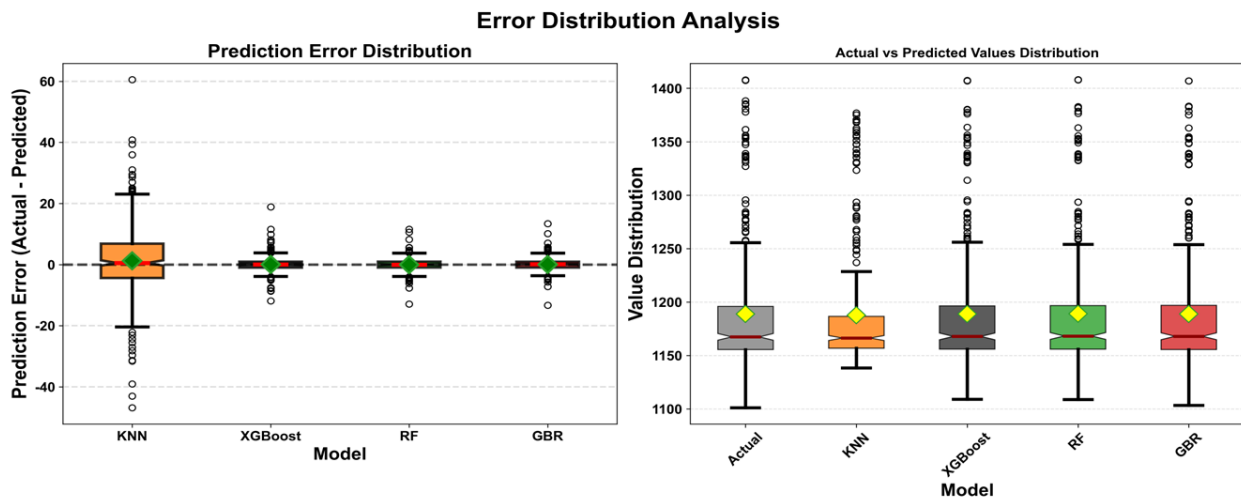


Fig. 12- Box plots of predicted Groundwater Level, Groundwater quality

شکل ۱۲- نمودارهای جعبه‌ای تراز سطح آب زیرزمینی و کیفیت آب زیرزمینی پیش‌بینی شده

با توجه به شکل ۱۳ نمودارهای تیلور نیز همین الگو را تأیید می‌کنند. نمودارهای تیلور همبستگی، انحراف معیار و RMSE را به صورت یکپارچه نمایش می‌دهند. در نمودار تیلور، نقطه مرجع (ستاره مشکی) نشان‌دهنده مقادیر مشاهده‌ای واقعی است. هرچه نقاط مدل‌ها به این نقطه نزدیک‌تر باشند، عملکرد آن‌ها بهتر است. در هر دو نمودار (تراز و کیفیت آب زیرزمینی)، نقطه مرجع (ستاره مشکی) نشان‌دهنده مقادیر واقعی است. مدل‌های RF و XGBoost و GBR با نقاط بسیار نزدیک به یکدیگر و به نقطه مرجع قرار گرفته‌اند، به طوری که تقریباً روی هم منطبق هستند. این قرارگیری نشان می‌دهد که این مدل‌ها همبستگی بسیار بالا (نزدیک به ۱)، انحراف معیار مشابه با مقادیر واقعی و RMSE بسیار پایین دارند. در شکل ۱۳- الف نمودار تیلور مربوط به تراز آب زیرزمینی، تطابق این سه مدل با نقطه مرجع حتی برجسته‌تر است و به سختی می‌توان نقاط آن‌ها را از یکدیگر تفکیک کرد. در مقابل، مدل KNN در هر دو نمودار تیلور با فاصله قابل ملاحظه‌ای از نقطه مرجع قرار گرفته است، که نشان‌دهنده همبستگی اندکی پایین‌تر و RMSE بالاتر است. در شکل ۱۳- ب در نمودار تیلور کیفیت آب زیرزمینی، فاصله مدل KNN از نقطه مرجع بیشتر از نمودار تراز آب زیرزمینی است، که بیانگر عملکرد نسبتاً ضعیف‌تر این مدل در پیش‌بینی کیفیت آب زیرزمینی می‌باشد.



با توجه به نمودارهای جعبه‌ای، رادار و نمودارهای تیلور، ترتیب عملکرد مدل‌های هوش مصنوعی در پیش‌بینی هر دو پارامتر کیفیت و تراز آب زیرزمینی به شرح زیر می‌باشد. مدل‌های RF، XGBoost و GBR دارای بهترین عملکرد و تقریباً یکسان هستند، در حالی که مدل KNN عملکرد قابل قبول اما ضعیف‌تر دارد. تفاوت بین RF، XGBoost و GBR بسیار ناچیز است و هر سه عملکرد تقریباً یکسانی دارند، به طوری که در نمودارهای رادار و دیاگرام‌های تیلور به سختی قابل تفکیک هستند. دلیل برتری این سه مدل، توانایی آن‌ها در شناسایی دقیق الگوها و روابط بین متغیرها است؛ در مورد کیفیت آب زیرزمینی، تمرکز بر رابطه قوی EC-TDS و در مورد تراز آب زیرزمینی، شناسایی صحیح وابستگی‌های زمانی و اهمیت تراز ماه‌های نزدیک می‌باشد. در حالی که مدل KNN با رویکرد پراکنده و یکنواخت به ویژگی‌های مختلف، نتوانسته این روابط کلیدی و ساختار اصلی داده‌ها را به‌طور مؤثر شناسایی کند.

در نتیجه، مدل‌های مبتنی بر یادگیری گروهی شامل RF، XGBoost و GBR برای پیش‌بینی هر دو پارامتر کیفیت آب زیرزمینی و تراز سطح آب زیرزمینی برتر هستند و این برتری در هر دو پارامتر به‌صورت سازگار، پایدار و قابل اعتماد در تمامی معیارهای ارزیابی شامل همبستگی، دقت، خطا و انحراف معیار مشاهده شده است. این نمودارها به‌وضوح نشان می‌دهند که انتخاب هر یک از این سه مدل برای کاربردهای عملی پیش‌بینی منابع آب زیرزمینی، تضمین‌کننده دقت و قابلیت اعتماد بالا خواهد بود.

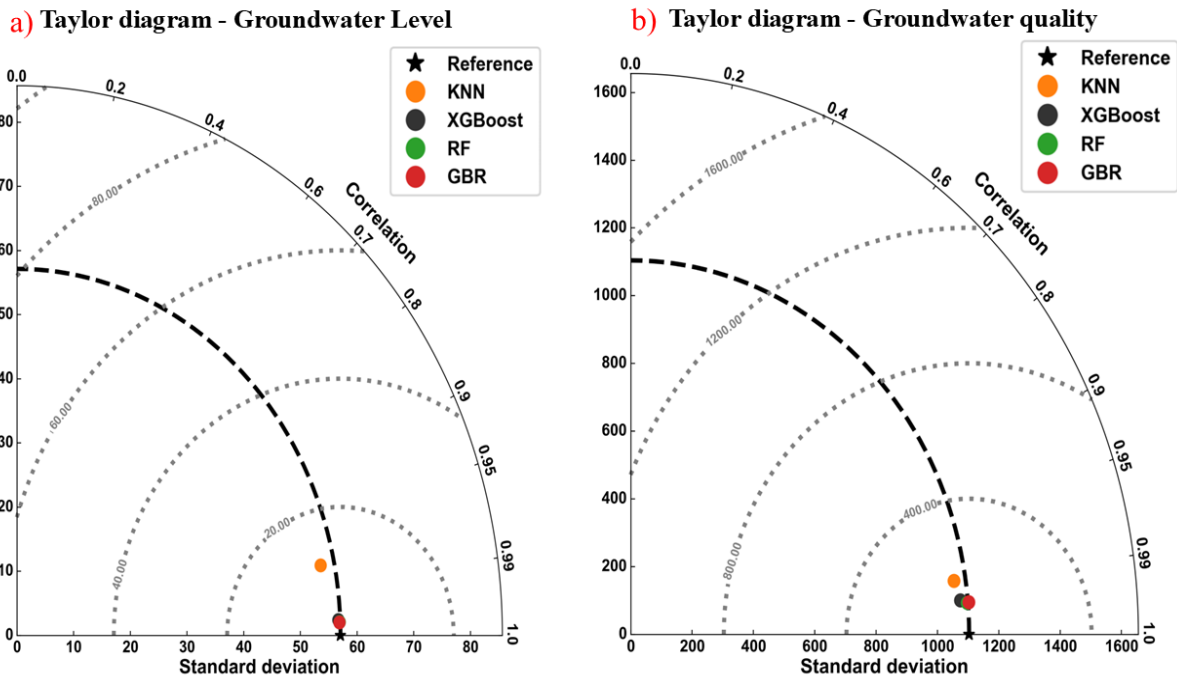


Fig. 13- Taylor diagram for choosing the best AI models in the test stage a)GWL, b)EC

شکل ۱۳- نمودار تیلور برای انتخاب بهترین مدل‌های هوش مصنوعی در مرحله آزمون الف) تراز سطح آب زیرزمینی، ب) EC

۴- نتیجه‌گیری

برداشت بی‌رویه از منابع آب زیرزمینی در اکثر دشت‌های کشور باعث افت شدید تراز سطح آب زیرزمینی و همچنین کاهش کیفیت آن شده است. با توجه به ضرورت شناخت خصوصیات کمی و کیفی آب زیرزمینی، بنابراین هدف از انجام این پژوهش، مقایسه کارایی مدل‌های مبتنی بر یادگیری گروهی (RF، XGBoost و GBR) و مدل مبتنی بر نمونه (KNN)، در شبیه‌سازی کیفیت آب زیرزمینی و شبیه‌سازی تراز سطح آب زیرزمینی



تعیین گردید. نتایج به دست آمده از پنج معیارهای ارزیابی، نمودارهای پراکندگی، مقایسه مقادیر واقعی و پیش‌بینی شده، تحلیل اهمیت ویژگی‌ها، نمودارهای تیلور، جعبه‌ای و رادار، الگوی سازگار و قابل اعتمادی از عملکرد مدل‌ها را نشان دادند.

از آنجایی که دشت قزوین یکی از دشت‌های مهم کشاورزی و وابستگی شدید به آب‌های زیرزمینی، تعداد و پراکنش مناسب چاه‌های مشاهده‌ای پایش کیفیت آب زیرزمینی و مشکلات کیفیت آب زیرزمینی، منطقه مورد مطالعه در این پژوهش دشت قزوین تعیین گردید. تحلیل ماتریس همبستگی کیفیت آب زیرزمینی نشان داد که همبستگی کامل بین کل جامدات محلول و هدایت الکتریکی و همبستگی‌های قوی بین یون‌های اصلی شوری بیانگر نقش غالب انحلال املاح در کیفیت آب زیرزمینی است. تحلیل ماتریس همبستگی تراز سطح آب زیرزمینی، همبستگی بالا بین ماه‌های متوالی بیانگر تغییرات تدریجی و قابل پیش‌بینی است.

نتایج مدل‌سازی نشان داد که مدل‌های یادگیری گروهی عملکرد برتری نسبت به مدل مبتنی بر نمونه دارند. در پیش‌بینی کیفیت آب زیرزمینی، مدل‌های GBR و RF بهترین عملکرد را داشتند و مدل XGBoost نیز نتایج بسیار نزدیک به دو مدل ارائه کرد. مدل KNN با افت در عملکرد از مرحله آموزش به آزمون نشان داد که بیانگر ضعف در تعمیم‌پذیری است. در شبیه‌سازی تراز آب زیرزمینی، مدل‌های یادگیری گروهی عملکرد استثنایی داشتند و مدل GBR با کمترین خطا برترین نتایج را کسب کرد. نمودارهای پراکندگی نشان دادند که پیش‌بینی‌های این مدل‌ها تقریباً کاملاً بر خط یک به یک منطبق بوده و نمودارهای مقایسه مقادیر واقعی و پیش‌بینی شده تأیید کردند که آن‌ها توانسته‌اند تمامی نوسانات، از مقادیر کمینه تا بیشینه، را با دقت بالایی شبیه‌سازی کنند.

تحلیل اهمیت ویژگی‌ها نقش کلیدی در درک برتری این مدل‌ها ایفا کرد و نتایج نشان داد که مدل‌های گروهی توانسته‌اند ساختار داده‌ها را به درستی شناسایی کنند، در حالی که مدل مبتنی بر نمونه با توزیع یکنواخت اهمیت، این ساختار را نادیده گرفته است. در پیش‌بینی کیفیت آب زیرزمینی، مدل‌های RF، XGBoost و GBR با شناسایی دقیق رابطه بنیادین بین EC و TDS، تمرکز خود را بر این رابطه محوری قرار دادند و پارامتر TDS را با اهمیت نزدیک به ۱۰۰ درصد به‌عنوان قوی‌ترین پیش‌بینی‌کننده شناسایی کردند. در پیش‌بینی تراز سطح آب زیرزمینی، این مدل‌ها با شناسایی صحیح ساختار سلسله‌مراتبی وابستگی‌های زمانی، اهمیت بالایی به تراز ماه‌های نزدیک‌تر به ویژه (L_1 و L_2) اختصاص دادند، که منعکس‌کننده درک عمیق آن‌ها از دینامیک زمانی سیستم آب زیرزمینی است. نمودارهای تیلور و رادار نیز نشان دادند که این سه مدل در تمامی معیارهای ارزیابی شامل همبستگی، انحراف معیار و خطای ریشه میانگین مربعات، عملکردی تقریباً یکسان و بسیار نزدیک به مقادیر ایده‌آل دارند. نمودارهای جعبه‌ای نشان دادند که سه مدل مبتنی بر یادگیری گروهی، جعبه‌های بسیار فشرده دارند که بیانگر توزیع نرمال و متمرکز خطاها حول صفر و پایداری بالا در پیش‌بینی است، در حالی که مدل KNN جعبه بزرگ‌تر و پراکندگی قابل توجهی در خطاها با تعداد بیشتری نقاط پرت نشان می‌دهد.

یافته‌های این پژوهش به‌وضوح نشان می‌دهند که مدل‌های یادگیری گروهی ابزارهای قدرتمندی برای شبیه‌سازی کیفیت و تراز آب زیرزمینی هستند. این مدل‌ها با توانایی برتر در شناسایی الگوها، مدیریت داده‌های چندبعدی، کاهش واریانس، فیلترسازی نویز و قابلیت تعمیم‌دهی عالی، گزینه‌های مناسب و قابل اعتمادی برای پیش‌بینی پارامترهای کمی و کیفی آب زیرزمینی هستند. سازگاری نتایج در هر دو کاربرد پیش‌بینی کیفیت و تراز آب، استحکام و پایداری این مدل‌ها را تأیید می‌کند و استفاده از آن‌ها را برای مدیریت پایدار منابع آب زیرزمینی و برنامه‌ریزی بهینه بهره‌برداری توصیه می‌نماید. عملکرد برتر مدل‌های مبتنی بر یادگیری گروهی RF، XGBoost و GBR در شبیه‌سازی همزمان پارامترهای کمی و کیفی آب زیرزمینی دشت قزوین و توانایی آن‌ها در شناسایی دقیق روابط بنیادین بین پارامترها و ساختار وابستگی‌های زمانی، چشم‌انداز امیدوارکننده‌ای برای مدیریت پایدار منابع آب زیرزمینی و برنامه‌ریزی بهینه بهره‌برداری ارائه می‌دهد.

نتایج این پژوهش بر اساس تحلیل‌های آماری، ماتریس‌های همبستگی، پنج معیار ارزیابی، نمودارهای پراکندگی، مقایسه مقادیر واقعی و پیش‌بینی شده، تحلیل اهمیت ویژگی‌ها و نمودارهای تیلور، جعبه‌ای و رادار، الگوی سازگار و قابل اعتماد از عملکرد مدل‌ها را نشان دادند و نکات کلیدی زیر را آشکار ساختند:



- برتری مدل‌های یادگیری گروهی: مدل‌های RF، XGBoost و GBR عملکرد برتری نسبت به مدل KNN در هر دو کاربرد پیش‌بینی کیفیت و تراز آب زیرزمینی نشان دادند.
- شناسایی دقیق روابط بنیادین: مدل‌های گروهی رابطه محوری بین EC و TDS و ساختار سلسله‌مراتبی وابستگی‌های زمانی (اهمیت بالای L1 و L2) را به‌درستی تشخیص دادند.
- دقت و پایداری بالا: نمودارهای پراکندگی، تیپور، رادار و جعبه‌ای تأیید کردند که مدل‌های گروهی توانسته‌اند تمامی نوسانات را با دقت بالا شبیه‌سازی کنند و خطاهای آن‌ها توزیع نرمال و متمرکز حول صفر دارند.
- ضعف تعمیم‌پذیری KNN: مدل KNN با افت عملکرد از مرحله آموزش به آزمون و توزیع یکنواخت اهمیت ویژگی‌ها، ناتوانی در شناسایی ساختار واقعی داده‌ها را نشان داد.
- چشم‌انداز کاربردی: این مدل‌ها ابزارهای قدرتمندی برای مدیریت پایدار، پایش مستمر، هشدار زودهنگام و برنامه‌ریزی بهینه بهره‌برداری از منابع آب زیرزمینی هستند.

با توجه به چالش‌های فزاینده کمی و کیفی منابع آب زیرزمینی در مناطق خشک و نیمه‌خشک ایران، دشت قزوین نیازمند توجه ویژه و اتخاذ راهبردهای مدیریتی مبتنی بر شواهد علمی برای جلوگیری از تشدید بحران و تضمین پایداری منابع آب برای نسل‌های آینده است. این مدل‌های منتخب می‌توانند به‌عنوان ابزارهای تصمیم‌گیری قدرتمند برای مدیریت پایدار منابع آب زیرزمینی، پایش مستمر کیفیت آب، هشدار زودهنگام تغییرات، برنامه‌ریزی بهینه بهره‌برداری و پایش بین‌رفتار آینده سیستم‌های آب زیرزمینی مورد استفاده قرار گیرند و چشم‌اندازی روشن برای بهبود راهبردهای مدیریتی و حفظ پایداری این منابع حیاتی فراهم آورند.

بر اساس یافته‌های این پژوهش، پیشنهادهای زیر برای بهره‌برداری عملی از مدل‌های یادگیری گروهی در مدیریت منابع آب زیرزمینی دشت قزوین ارائه می‌شود: (۱) استفاده از مدل‌های برتر به‌عنوان ابزار پایش برای هشدار زودهنگام کاهش تراز آب یا افزایش شوری در بازه زمانی ماهانه، (۲) تدوین برنامه‌های برداشت مرحله‌ای بر اساس آستانه‌های پیش‌بینی‌شده تراز سطح آب توسط مدل‌های یادگیری گروهی، (۳) اولویت‌بندی مناطق مستعد خطر کیفی با استفاده از خروجی‌های مدل، به‌ویژه در بخش‌هایی که احتمال تشدید شوری وجود دارد، (۴) طراحی شبکه پایش بهینه و کم‌هزینه با تکیه بر مدل‌های منتخب و بازسازی داده‌های گمشده، و (۵) ادغام مدل‌های یادگیری گروهی با سامانه‌های اطلاعات جغرافیایی و پهنه‌بندی خطر برای شناسایی نقاط بحرانی و تعیین مناطق با اولویت مداخله مدیریتی.

- 1- Physical Based
- 2- Artificial intelligence (AI)
- 3- Machine learning (ML)
- 4- Simulation
- 5- Groundwater quality
- 6- Groundwater level (GWL)
- 7- Nonlinear autoregressive exogenous (NRAX)
- 8- Long-Short Term Memory (LSTM)
- 9- Convolutional Neural Network (CNN)
- 10- Gene expression programming (GEP)
- 11- Model tree M5
- 12- Electrical Conductivity (EC)
- 13- Sodium Adsorption Ratio (SAR)
- 14- Total Dissolved Solids (TDS)
- 15- Firefly Algorithm (FFA)
- 16- Artificial Neural Networks (ANN)
- 17- Adaptive network-based fuzzy inference system (ANFIS)
- 18- Feedforward Neural Network (FNN)
- 19- Support Vector Machine (SVM)
- 20- Nash-Sutcliffe Efficiency (NSE)
- 21- Decision Tree (DT)
- 22- Support vector regression (SVR)
- 23- Water Quality Index (WQI)
- 24- Extreme Gradient Boosting (XGBoost)
- 25- Irrigation Water Quality Index (IWQI)
- 26- Random Forest (RF)
- 27- Recurrent Neural Network (RNN)
- 28- Generative Adversarial Network (GAN)
- 29- Gradient Boosting Regression (GBR)
- 30- Train
- 31- Test
- 32- Ensemble Learning
- 33- Deep Learning
- 34- Numerical Model
- 35- Instance-Based
- 36- Feature importance
- 37- Scatter plot
- 38- Taylor diagram
- 39- Box plot
- 40- Radar chart
- 41- Bagging
- 42- Boosting
- 43- Memory-Based
- 44- Neighbors
- 45- StandardScaler
- 46- Permutation Importance
- 47- n_estimators
- 48- random_state
- 49- Gini Importance
- 50- Gradient Boosting
- 51- learning_rate
- 52- Boosting
- 53- Mean absolute error (MAE)
- 54- Pearson Correlation (R)
- 55- R-squared (R^2)
- 56- Normalized Root Mean Square Error (nRMSE)

Adimalla N and Taloor AK (2020) Hydrogeochemical investigation of groundwater quality in the hard rock terrain of South India using Geographic Information System (GIS) and groundwater quality index (GWQI) techniques. *Groundwater for Sustainable Development*. Elsevier B.V. 10:100288. Available at: <https://doi.org/10.1016/j.gsd.2019.100288>

Azadeh Ranjbar S (2025) Groundwater Management Framework Based on Artificial Intelligence. M.Sc. Thesis, University of Tehran (In Persian)

Azadeh Ranjbar S, Kholghi M and Abdeh Kolahchi A (2025) Assessment and Validation of GRACE Satellite Data with Groundwater Resources Index (GRI) at Qazvin Aquifer Plain. *Iranian Journal of Soil and Water Research* 56(4):1103–1117 (In Persian)

Bahmani R and Ouarda TBMJ (2021) Groundwater level modeling with hybrid artificial intelligence techniques. *Journal of Hydrology*. Elsevier B.V. 595(September):125659. Available at: <https://doi.org/10.1016/j.jhydrol.2020.125659>

Breiman L (2001) Random forests. *Machine learning* 45(5):32

Chen T and Guestrin C (2016) XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794

Chen Y and Zhang D (2020) Physics-Constrained Deep Learning of Geomechanical Logs. *IEEE Transactions on*



- Geoscience and Remote Sensing. IEEE 58(8):5932–5943
- El Bilali A, Taleb A and Brouziyne Y (2021) Groundwater quality forecasting using machine learning algorithms for irrigation purposes. *Agricultural Water Management* 245(July)
- Elmotawakkil A, Sadiki A and Enneya N (2024) Predicting groundwater level based on remote sensing and machine learning: a case study in the Rabat-Kénitra region. *Journal of Hydroinformatics* 26(10):2639–2667
- Feng F, Ghorbani H and Radwan AE (2024) Predicting groundwater level using traditional and deep machine learning algorithms. *Frontiers in Environmental Science* 12:1291327
- Fetter CW (2001) *Applied Hydrogeology*. Upper Saddle River, New Jersey: Prentice-Hall, Inc.
- Fotamy MJ, Kholghi M, Abdeh A and Roostaei M (2023) The Performance of the Evidence Weighting in GIS for Determining the Effective Factors on the Land Subsidence in Qazvin Plain. *Iran-Water Resources Research* 19(3) (In Persian)
- Gong Y, Zhang Y, Lan S and Wang H (2016) A Comparative Study of Artificial Neural Networks, Support Vector Machines and Adaptive Neuro Fuzzy Inference System for Forecasting Groundwater Levels near Lake Okeechobee, Florida. *Water Resources Management* 30(1):375–391
- Hussein EE, Derdour A, Zerouali B, Almaliki A, Wong YJ, Ballesta-de los Santos M, Minh Ngoc P, Hashim MA and Elbeltagi A (2024) Groundwater Quality Assessment and Irrigation Water Quality Index Prediction Using Machine Learning Algorithms. *Water (Switzerland)* 16(2)
- Ibrahim H, Yaseen ZM, Scholz M, Ali M, Gad M, Elsayed S, Khadr M, Hussein H, Ibrahim HH, Eid MH, ... Khalifa MM (2023) Evaluation and Prediction of Groundwater Quality for Irrigation Using an Integrated Water Quality Indices, Machine Learning Models and GIS Approaches: A Representative Case Study. *Water (Switzerland)* 15(4)
- Igwebuike N, Ajayi M, Okolie C, Kanyerere T and Halihan T (2025) Application of machine learning and deep learning for predicting groundwater levels in the West Coast Aquifer System, South Africa. *Earth Science Informatics* 18(1):6
- Khan I and Ayaz M (2024) Sensitivity analysis-driven machine learning approach for groundwater quality prediction: Insights from integrating ENTROPY and CRITIC methods. *Groundwater for Sustainable Development* 26:101309
- Krause P, Boyle DP and Båse F (2005) Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*, 89–97
- Langevin C., Hughes J., Banta E., Niswonger R., Panday S and Provost AM (2017) Documentation for the MODFLOW 6. U.S. Geological Survey. Available at: https://water.usgs.gov/water-resources/software/MODFLOW-6/mf6io_6.0.4.pdf <https://doi.org/10.3133/tm6A55>
- Lee JH, Lee JY, Lee MH, Lee MY, Kim YW, Hyung JS, Kim KB, Cha YK and Koo JY (2022) Development of a short-term water quality prediction model for urban rivers using real-time water quality data. *Water Supply* 22(4):4082–4097
- Li W, Finsa MM, Laskey KB, Houser P and Douglas-Bate R (2023) Groundwater Level Prediction with Machine Learning to Support Sustainable Irrigation in Water Scarcity Regions. *Water (Switzerland)* 15(19)
- Mateo LF, Más-López MI, García-del-Toro EM, García-Salgado S and Quijano MÁ (2024) Artificial Neural Networks to Predict Electrical Conductivity of Groundwater for Irrigation Management: Case of Campo de Cartagena (Murcia, Spain). *Agronomy* 14(3)
- Moriasi DN, Arnold JG, Van Liew MW, Bingner RL, Harmel RD and Veith TL (2007) Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 885–900
- Nasr M and Zahran HF (2014) Using of pH as a tool to predict salinity of groundwater for irrigation purpose using artificial neural network. *Egyptian Journal of Aquatic Research*. National Institute of Oceanography and Fisheries 40(2):111–115. Available at: <http://dx.doi.org/10.1016/j.ejar.2014.06.005>
- Peterson LE (2009) K-nearest neighbor. *Scholarpedia* 4(2):1883
- Plumb AP, Rowe RC, York P and Brown M (2005) Optimisation of the predictive ability of artificial neural network (ANN) models: A comparison of three ANN programs and four classes of training algorithm. *European Journal of Pharmaceutical Sciences* 25(4–5):395–405
- Poursaeid M, Mastouri R, Shabanlou S and Najarchi M (2020) Estimation of total dissolved solids, electrical conductivity, salinity and groundwater levels using novel learning machines. *Environmental Earth Sciences*. Springer Berlin Heidelberg 79(19):1–25. Available at: <https://doi.org/10.1007/s12665-020-09190-1>
- Qazvin Regional Water Company (2025) Monthly Report on Precipitation and Surface Water Resources of Qazvin Province (in Two Watersheds: Central Plateau and Sefidrud). Qazvin, Iran, 30p (In Persian)
- Secci D, Giovanna Tanda M, D’Oria M and Todaro V (2023) Artificial intelligence models to evaluate the impact of climate change on groundwater resources. *Journal of Hydrology*. Elsevier B.V. 627(PB):130359. Available at: <https://doi.org/10.1016/j.jhydrol.2023.130359>
- Shende AD and Sahoo MM (2024) Real time simulation of groundwater quality index using adaptive neuro-fuzzy



inference. Spatial Information Research 32(1):1-12

Shiri N, Shiri J, Yaseen ZM, Kim S, Chung IM, Nourani V and Zounemat-Kermani M (2021) Development of artificial intelligence models for well groundwater quality simulation: Different modeling scenarios. PLoS ONE 16(5 May). Available at: <http://dx.doi.org/10.1371/journal.pone.0251510>

Taşan M (2025) Improved Prediction of Groundwater Quality Index by Hybrid Machine Learning Models in a Coastal Region: A Case Study From Southern Turkey. International Journal of Environmental Research 19(4):147

Wang W and Lu Y (2018) Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model. IOP Conference Series: Materials Science and Engineering

ویراستاری نشده، غیر قابل استناد

A Novel Perspective on Ensemble Learning Models for Groundwater Level and Quality Simulation

Shima Azadeh Ranjbar¹  | Majid Kholghi²  | Afshin Ashrafzadeh³ 

1. Department of Irrigation & Reclamation Eng, College of Agriculture & Natural Resources, University of Tehran, Karaj, Iran. E-mail: : Shima.azadeh.ran@ut.ac.ir, shima.ranjbar20@gmail.com
2. Corresponding Author, Department of Irrigation & Reclamation Eng, College of Agriculture & Natural Resources, University of Tehran, Karaj, Iran. E-mail: kholghi@ut.ac.ir, mkholfghi@gmail.com
3. Department of Irrigation & Reclamation Eng, College of Agriculture & Natural Resources, University of Tehran, Karaj, Iran. E-mail: afshin.ashrafz@gmail.com

Abstract

Excessive withdrawal of groundwater resources has led to significant quantitative and qualitative issues in most aquifers in Iran. Population growth, climate change and limited surface water resources have intensified pressure on groundwater reserves to meet drinking, agricultural, and industrial demands. Therefore, monitoring and simulation of groundwater level and quality are essential for sustainable aquifer management. The Qazvin Plain, as one of the country's important agricultural regions with high dependence on groundwater resources, was selected as the study area. Artificial intelligence models offer an efficient approach for prediction and simulation due to their ability to learn complex nonlinear patterns without requiring complete understanding of aquifer physical processes. The objective of this research was to simulate groundwater quality and level in Qazvin Plain using three ensemble learning models (RF, XGBoost, and GBR) and one instance-based model (KNN). In this study, 20 years of data (2001-2021) including monthly groundwater level, water quality parameters, and climatic factors (precipitation and temperature) were used. Comparison of model performance (Performance evaluation, scatter plots, comparison of actual and predicted values, feature importance, Taylor diagrams, box plots and radar charts) revealed that ensemble learning models (RF, XGBoost, and GBR) with NSE and R^2 values of approximately 0.996 and precise identification of pivotal relationships among data, demonstrated superior performance in simulating groundwater quality and level compared to the KNN model.

Keywords: Ensemble learning, GBR, Groundwater quality and quantity simulation, Qazvin Plain, RF, XGBoost.

فایلی استناد