



## پیش‌بینی هدایت هیدرولیکی از روی اطلاعات دانه‌بندی خاک با استفاده از مدل هوشمند SICM

محمد خلیلی ملکی<sup>۱</sup>، رامین وفايي پورسرخابی<sup>۲\*</sup>، عطاءاله ندیری<sup>۳</sup>، روزبه دبیری<sup>۴</sup>

۱- دانشجوی دکتری، گروه عمران، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

۲- استادیار، گروه عمران، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

۳- مرکز تحقیقات رباتیک و فناوری‌های نرم، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

۴- دانشیار، گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز، تبریز، ایران

۵- مرکز پژوهشی زمین پزشکی و زیست محیطی، دانشگاه تبریز، تبریز، ایران

\* نویسنده مسئول: [Raminvafaei@yahoo.com](mailto:Raminvafaei@yahoo.com)

تاریخ پذیرش مقاله: ۱۴۰۰/۰۹/۰۲

تاریخ دریافت مقاله: ۱۴۰۰/۰۲/۰۷

### چکیده

نفوذپذیری یکی از پارامترهای مؤثر بر جریان آب در محیط‌های متخلخل مانند توده سنگ و خاک می‌باشد که اهمیت ویژه‌ای در مطالعات ژئوتکنیکی مانند محل اجرای سازه‌های مهم و پراهمیتی مانند قطار شهری دارد و تعیین آن از اهداف اصلی در مطالعات ژئوتکنیک به شمار می‌رود. همچنین پارامتری مهم در حل مشکلات ژئوتکنیکی مانند نشت آب، محاسبه نشست، تحلیل پایداری و غیره می‌باشد. به دلیل گران، تخصصی، وقت‌گیر و غیرمطمئن بودن روش‌های اندازه‌گیری مستقیم (صحرایی و آزمایشگاهی) این پارامتر و همچنین به علت رفتار غیرخطی و شرایط ناهمگن و ناهمسان حاکم بر محیط‌های هیدروژئولوژیکی که موجب عدم قطعیت ذاتی روش‌های اندازه‌گیری مستقیم این پارامتر می‌شود، در سال‌های اخیر روش‌های مختلف هوش مصنوعی با دقت بیشتری نسبت به روش‌های فوق و برای جبران بخشی از این نقایص ارائه شده‌اند. در این مطالعه از دو روش هوش مصنوعی منفرد شامل مدل ماشین بردار پشتیبان کمینه مربعات (LSSVM) و مدل هیبرید موجکی عصبی (WANN) در خطوط ۱ و ۲ قطار شهری تبریز برای پیش‌بینی هدایت هیدرولیکی بر اساس اطلاعات دانه‌بندی استفاده شد؛ سپس نتایج این دو مدل انفرادی توسط مدل شبکه عصبی مصنوعی (ANN) ترکیب شده و با نام مدل هوشمند مرکب نظارت‌شده (SICM) موجب بهبودی نتایج گردید. مقایسه نتایج مرحله آزمایش سه مدل ارائه شده در این پژوهش نشان داد که هر سه مدل عملکرد نسبتاً مناسبی در پیش‌بینی هدایت هیدرولیکی داشتند؛ اما مدل ترکیبی SICM با داشتن  $RMSE = 0.00161$  cm/sec (ریشه میانگین مربعات خطا) و  $R^2 = 0.83$  (ضریب تبیین) نسبت به مدل‌های انفرادی نتایج بهتری را ارائه داده است.

**واژه‌های کلیدی:** قطار شهری تبریز، ماشین بردار پشتیبان، مدل هوشمند مرکب نظارت‌شده، هدایت هیدرولیکی، هیبرید موجکی عصبی.

### مقدمه

از درون مواد متخلخل می‌باشد. پارامتری که میزان نفوذپذیری خاک را بیان می‌کند، هدایت هیدرولیکی نامیده می‌شود. برای مدل‌سازی جریان آب در خاک بسیار مهم بوده و نقش اساسی در پیشبرد مطالعات ژئوتکنیکی دارد. بخصوص اهمیت تعیین دقیق این متغیر در پروژه‌های عظیم و مهم مهندسی مانند

نفوذپذیری یک مفهوم فیزیکی مهم بوده و به مفهوم قابلیت عبور مواد مایع از جمله آب از داخل مواد متخلخل مانند سنگ یا خاک می‌باشد. در واقع نفوذپذیری امکان جریان آب

اندازه‌گیری مستقیم باشند. برای نمونه می‌توان از شبکه‌ی عصبی مصنوعی (Nadiri et al., 2014; Tayfur Sihag, 2018) (et al., 2014; Nadiri et al., 2014; Sihag, 2018)؛ یوسف‌زاده و ندیری، (۱۳۹۶)، نرو فازی (Nadiri et al., 2014; Sezer et al., 2010)؛ ماشین بردار پشتیبان، یوسف‌زاده و ندیری (۱۴۰۰) و بالاخره هیبرید موجکی عصبی، یوسف‌زاده و ندیری (۱۳۹۶) نام برد که نتایج قابل قبولی از مدل‌سازی‌های متفاوت هوش مصنوعی داشته‌اند. روش‌های چندگانه و ترکیبی هوش مصنوعی نیز برای تخمین هدایت هیدرولیکی مورد توجه قرار گرفتند. نتایج این مدل‌ها نشان داد که این مدل‌ها به دلیل استفاده هم‌زمان از توانایی‌های منحصربه‌فرد تک‌تک مدل‌های انفرادی، عملکرد مناسب‌تری نسبت به مدل‌های انفرادی دارند (Nadiri et al., 2014; Tayfur et al., 2014)؛ یوسف‌زاده و ندیری، (۱۳۹۶). Ross et al. (2007) هدایت هیدرولیکی را از روی تحلیل فازی اطلاعات دانه‌بندی با دقت بالایی تخمین زدند. آن‌ها با بررسی لاگ‌های حفاری، نمونه‌هایی را ارائه دادند که این نمونه‌ها به صورت مخلوطی از چند خاک بودند و سپس برای هر کدام از خاک‌ها در داخل آن نمونه‌ها، درجه عضویت تعریف کردند و بدین ترتیب تحلیل فازی برای نمونه‌های خاک ارائه شد. پس از پیش‌بینی هدایت هیدرولیکی با استفاده از تحلیل فازی اطلاعات دانه‌بندی، در سال‌های اخیر این متغیر از روی اطلاعات دانه‌بندی و با استفاده از مدل‌های منفرد هوش مصنوعی نیز پیش‌بینی گردید (Erzin et al., 2009; Sedagha, 2016; Sihag, 2018)؛ هدایت هیدرولیکی از روی اطلاعات دانه‌بندی و با استفاده از هوش مصنوعی ترکیبی نیز پیش‌بینی شده است (Rogiers et al., 2012)؛ داداش‌بابا و همکاران، (۱۳۹۶). داداش‌بابا و همکاران، (۱۳۹۶) هدایت هیدرولیکی را در محدوده متروی شهر تبریز و با استفاده از مدل ترکیبی SOM-FL<sup>۱</sup> و از روی اطلاعات دانه‌بندی (توزیع اندازه ذرات) پیش‌بینی کردند. همچنین Rogiers et al. (2012) در آبخوان شمال بلژیک، هدایت هیدرولیکی را با استفاده از روش ترکیبی GLUE-ANN<sup>۲</sup> از روی داده‌های اندازه ذرات تخمین زدند.

قطار شهری که مدیریت و کنترل صحیح آب‌های زیرزمینی در محل اجرای چنین سازه‌هایی ضرورت زیادی دارد، بیشتر نمایان می‌شود. پارامترهای زیادی در مقدار هدایت هیدرولیکی تأثیر می‌گذارند از جمله آنها اندازه خلل و فرج، اندازه دانه‌ها، شکل ذرات، تراکم ذرات و غیره. هدایت هیدرولیکی به توزیع اندازه دانه‌های توده متخلخل نیز وابسته است که این مطالعه براساس اطلاعات دانه‌بندی (توزیع اندازه ذرات) استوار است. تکنیک‌های متفاوتی برای تعیین مقدار هدایت هیدرولیکی پیشنهاد شده است که شامل روش‌های صحرایی (آزمایش پمپاژ چاه، تست اسلاگ<sup>۱</sup> و آزمایش ردیاب)، روش‌های آزمایشگاهی و محاسبات از روی فرمول‌های تجربی است (Todd and Mays, 2005). روش‌های فوق مزایایی مانند شناخت شرایط زیرسطحی از راه حفاری دارند، اما گران و وقت‌گیر می‌باشند. همچنین هدایت هیدرولیکی، یک متغیر تصادفی است که در حالت کلی توزیع آن در درون یک محیط متخلخل مبهم بوده و یا می‌توان گفت که با عدم قطعیت همراه است (Nowak and Cirpka, 2006).

برای رفع قسمتی از نقایص ذکرشده، مدل‌های هوش مصنوعی به کار گرفته شدند. در چند سال گذشته تحقیقات و مطالعات متعددی برای پیش‌بینی متغیرهای آب‌شناسی و آب‌زمین‌شناسی مانند بارش- رواناب، پیش‌بینی منابع آب زیرزمینی، تخمین نوسانات تراز آب زیرزمینی، مدل‌سازی کیفی آب زیرزمینی، ارزیابی آسیب‌پذیری آبخوان‌ها، جریان رودخانه‌ای، بار رسوب معلق و غیره. با استفاده از روش‌های هوش مصنوعی مانند ماشین بردار پشتیبان (Nourani and Nourani and Andalib, 2015; Andalib, 2019)؛ قره‌خانی و همکاران، (۱۳۹۴)؛ نورانی و عندلیب، (۱۳۹۶)؛ عندلیب و همکاران، (۱۳۹۸) و هیبرید موجکی عصبی (Nourani et al., 2019; Sharghi et al., 2009)؛ نورانی و عندلیب، (۱۳۹۶)؛ ترابی و همکاران، (۱۴۰۰)؛ عزیزی و همکاران، (۱۴۰۰)؛ رخ شاد و شهیدی، (۱۴۰۰) انجام گردیده است که موفقیت‌آمیز بوده‌اند. برای برآورد هدایت هیدرولیکی نیز از روش‌های مختلف هوش مصنوعی استفاده شده است. استفاده از این روش‌ها ثابت کرد که این روش‌ها می‌توانند جایگزین مناسبی برای روش‌های

<sup>۲</sup> Generalized likelihood uncertainty estimation artificial neural networks

<sup>۱</sup> Slug test

<sup>۲</sup> Self-organization map-fuzzy logic

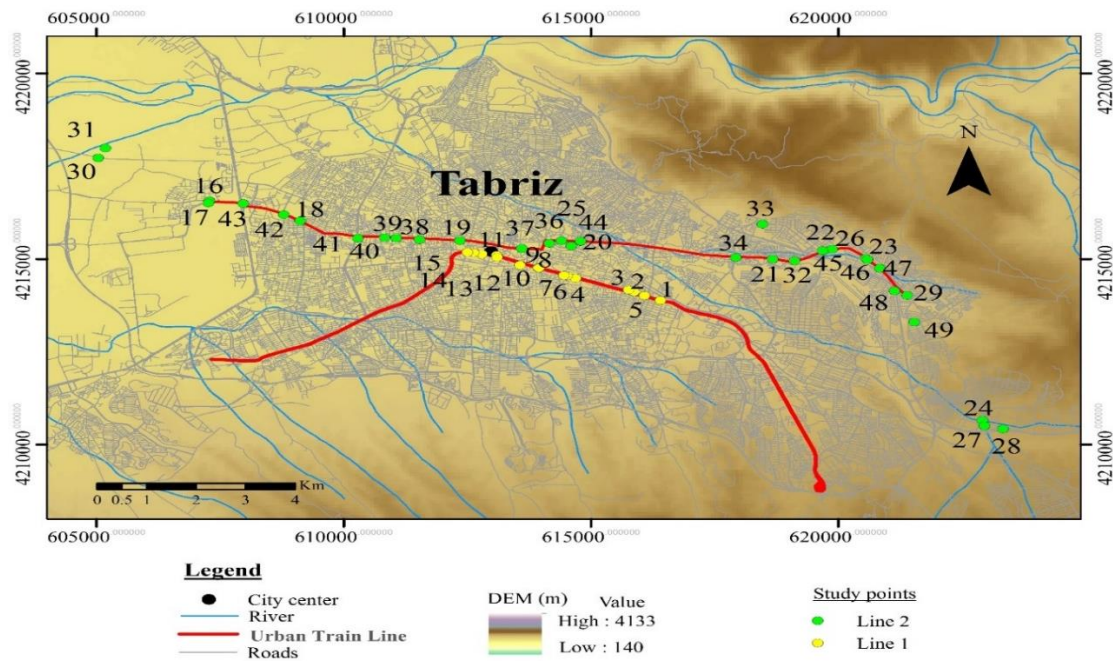
شمالی واقع شده است. قطار شهری تبریز از ۵ خط شامل ۴ خط اصلی و یک خط حومه تشکیل شده است و طول آن حدود ۱۰۰ کیلومتر می‌باشد. خط ۱ از جنوب شرق تبریز شروع شده و سپس از قسمت مرکزی شهر به جنوب غرب آن منتهی می‌شود. خط ۲ قطار شهری تبریز از منطقه قراملک شروع شده و پس از گذشتن از شهرک باغمیسه به سمت شرق امتداد یافته و پس از عبور از شهرک مرزداران در اطراف نمایشگاه بین‌المللی خاتمه می‌یابد. قسمتی از خط ۱ که مورد بحث این مطالعه بوده و شامل ۲۰ گمانه می‌باشد، در قسمت مرکزی شهر قرار دارد. طول محدوده مورد مطالعه خط ۲ حدود ۲۲ کیلومتر (تقریباً کل طول خط ۲) و شامل ۱۳۳ گمانه بود. پس از بررسی اطلاعات تمام گمانه‌ها، از اطلاعات ۱۵ گمانه خط ۱ و ۳۴ گمانه خط ۲ استفاده شد. از ۱۵ گمانه خط ۱ و ۳۴ گمانه خط ۲ به ترتیب ۵۱ و ۴۳ نمونه خاک در عمق‌های مختلف ۳ متری انتخاب شد؛ یعنی در مجموع ۹۴ نمونه خاک از ۴۹ گمانه مورد استفاده قرار گرفت (گزارش‌های مطالعات ژئوتکنیک خطوط ۱ و ۲ قطار شهری تبریز، ۱۳۸۳، ۱۳۸۴ و ۱۳۸۸). موقعیت گمانه‌ها در شکل ۱ نشان داده شده است.

در تحقیق حاضر دو مدل انفرادی LSSVM<sup>۴</sup> و WANN<sup>۵</sup> و مدل ترکیبی SICM<sup>۶</sup> برای پیش‌بینی هدایت هیدرولیکی در قطار شهری تبریز (خطوط ۱ و ۲) مورد استفاده قرار می‌گیرند. بدین ترتیب که پس از اجرای مدل‌های انفرادی، برای استفاده هم‌زمان از مزایای تک‌تک این مدل‌ها، از نتایج آن‌ها که همان هدایت هیدرولیکی می‌باشد، به عنوان ورودی مدل ترکیبی استفاده می‌شود یعنی نتایج مدل‌های انفرادی توسط شبکه عصبی مصنوعی (ANN<sup>۷</sup>) که یک ترکیب‌کننده غیرخطی می‌باشد، بهینه شده و با نام مدل هوشمند مرکب نظارت شده ارائه می‌گردد؛ بنابراین در این تحقیق هدایت هیدرولیکی بر مبنای دانه‌بندی (توزیع اندازه ذرات) و با کمک مدل هوشمند مرکب نظارت شده (SICM) تخمین زده شده و پیش‌بینی می‌گردد.

## مواد و روش‌ها

### منطقه مورد مطالعه

شهر تبریز که در شکل ۱ نشان داده شده است؛ در استان آذربایجان شرقی در شمال غرب کشور ایران با مختصات جغرافیایی ۴۶ درجه و ۱۲ دقیقه تا ۴۶ درجه و ۲۳ دقیقه طول شرقی و ۳۸ درجه و ۱ دقیقه تا ۳۸ درجه و ۱۰ دقیقه عرض



<sup>۶</sup> Supervised intelligent committee machine

<sup>۷</sup> Artificial neural network

<sup>۴</sup> Least square support vector machine

<sup>۵</sup> Wavelet artificial neural network

شکل ۱- منطقه مورد مطالعه، موقعیت گمانه‌ها و نقاط اندازه‌گیری هدایت هیدرولیکی.

### تجزیه و تحلیل داده‌ها

گردید که دو شرط زیر رعایت گردد: اول اینکه ویژگی‌های آماری هر دودسته تقریباً مشابه باشد؛ دوم اینکه مقادیر کمینه و بیشینه داده‌ها در داخل داده‌های مرحله آموزش قرار داده شود. برای تعیین بهینه تعداد داده‌های مراحل آموزش و آزمایش به روش آزمون و خطا، حالت‌های مختلفی مورد بررسی قرار گرفت. حالت‌های بررسی شده عبارت‌اند از: ۸۰ درصد آموزش و ۲۰ درصد آزمایش، ۷۵ درصد آموزش و ۲۵ درصد آزمایش و ۷۰ درصد آموزش و ۳۰ درصد آزمایش. در بهترین حالت ۷۰ درصد داده‌ها برای مرحله آموزش و ۳۰ درصد بقیه نیز برای مرحله آزمایش اختصاص داده شد. مقادیر بیشینه، کمینه و میانگین داده‌های ورودی ( $D_{80}$  و  $D_{60}$ ,  $D_{30}$ ) و خروجی ( $K$ ) در جدول ۱ نشان داده شده است (گزارش‌های مطالعات ژئوتکنیک خطوط ۱ و ۲ قطار شهری تبریز، ۱۳۸۳، ۱۳۸۴ و ۱۳۸۸).

در تحقیق حاضر هدایت هیدرولیکی که بر اساس دانه‌بندی استوار است؛ با استفاده از مدل هوشمند مرکب نظارت‌شده، پیش‌بینی شد. با توجه به اینکه ورودی‌های این مدل همان خروجی‌های مدل‌های منفرد بودند، ابتدا مدل‌های منفرد اجرا گردیدند. برای اجرای مدل‌های منفرد از اطلاعات دانه‌بندی که از آزمایشات هیدرومتری و دانه‌بندی و بر طبق استاندارد AASHTOT27 به دست آمده بودند، استفاده گردید. بدین ترتیب اطلاعات دانه‌بندی ( $D_{80}$  و  $D_{60}$ ,  $D_{30}$ ) از روی منحنی‌های دانه‌بندی تعیین شدند. هدایت هیدرولیکی نیز از آزمایشات تعیین نفوذپذیری به روش لوفران با بار ثابت و افتان در گمانه‌ها، مشخص گردید. از ۹۴ مقدار هدایت هیدرولیکی افقی در این مطالعه استفاده شده است. روش انتخاب داده‌ها برای مراحل آموزش و آزمایش به صورت تصادفی بود ولی سعی

جدول ۱- مشخصات مهم آماری متغیرهای ورودی و خروجی.

متغیرها	کمینه	بیشینه	میانگین
$D_{30}$ (mm)	۰/۰۰۶	۰/۹۴	۰/۱۲۳
$D_{60}$ (mm)	۰/۰۷۶	۹/۳۸	۰/۸۴۵
$D_{80}$ (mm)	۰/۱۵۲	۲۷/۵	۳/۱۴۲
$K$ (cm/sec)	۰/۰۰۰۰۰۰۱۰۸	۰/۰۰۲۸۴	۰/۰۰۰۱۴۶

$$y = \text{sign} \left( \sum_{i=1}^n y_i a_i (x \cdot x_i) + b \right) \quad (1)$$

که در آن  $y$  خروجی معادله  $y_i$  ارزش طبقه نمونه آموزشی  $X_i$  و " $\cdot$ " نشان‌دهنده ضرب داخلی است. بردارهای  $X = [X_1, X_2, \dots, X_n]$  نشان‌دهنده یک داده ورودی و بردارهای  $X_i$  بردارهای پشتیبان هستند. مهم‌ترین کاربردهای ماشین بردار پشتیبان در طبقه‌بندی و خطی‌سازی داده‌هاست. ویژگی مهم ماشین بردار پشتیبان این است که برخلاف الگوریتم‌های کلاسیک و رگرسیون‌های خطی که به وسیله حداقل کردن قدر مطلق خطا یا توان دوم خطا عمل می‌کنند، آن‌ها ریسک عملیاتی را به حداقل می‌رسانند. SVM ریسک نبود طبقه‌بندی صحیح را به صورت یک سری عددی بیان می‌کند و بعد مقدار کمینه آن را حساب می‌کند، اما شبکه عصبی MLP<sup>۹</sup> هر موقع

### روش‌های هوش مصنوعی

#### ماشین بردار پشتیبان (SVM)

ماشین‌های بردار پشتیبان (SVM)<sup>۹</sup> در سال ۱۹۹۵ توسط واپنیک و کورتز معرفی شدند. ماشین بردار پشتیبان الگوریتمی است که نوع خاصی از مدل‌های خطی را می‌یابد که حداکثر حاشیه ابر صفحه را حاصل می‌کنند. حداکثر کردن حاشیه ابر صفحه منجر به حداکثر شدن تفکیک بین دسته‌ها می‌شود. به نزدیک‌ترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان اطلاق می‌گردد و تنها از این بردارها برای مشخص کردن مرز بین دسته‌ها استفاده می‌شود. قواعد تصمیم‌گیری که تعریف می‌شود و توسط یک صفحه بهینه که طبقات تصمیم‌گیری باینری را تفکیک می‌کند به صورت رابطه ۱ است (Vapnik and Cortez, 1995).

<sup>۹</sup> Multi-layer perceptron

<sup>۹</sup> Support vector machine

### مدل موجگی عصبی (WANN)

#### تابع موجگ

تابع موجگ، تابعی است که دو ویژگی مهم را دارا باشد: نوسانی بودن و کوتاه مدت بودن.  $\psi(x)$ ، تابع موجگ است اگر و فقط اگر تبدیل فوریه آن  $\psi(\omega)$ ، شرط زیر را ارضا کند (Mallat, 1998):

$$\int_{-\infty}^{+\infty} \frac{|\psi(\omega)|}{|\omega|^2} d\omega < +\infty \quad (2)$$

این شرط با عنوان شرط پذیرفتگی برای موجگ  $\psi(x)$  شناخته می‌شود. رابطه فوق را می‌توان معادل با فرمول زیر دانست:

$$\psi(0) = \int_{-\infty}^{+\infty} \psi(x) dx = 0 \quad (3)$$

این ویژگی تابع با میانگین صفر، چندان محدودکننده نبوده و توابع بسیاری را می‌توان بر اساس آن تابع موجگ نامید.  $\psi(x)$  تابع موجگ مادر است که توابع مورد استفاده در تحلیل، با دو عمل ریاضی انتقال و مقیاس در طول سیگنال مورد تحلیل، تغییر اندازه و تغییر محل می‌یابند (Mallat, 1998).

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (4)$$

در نهایت ضرایب موجگ در هر نقطه از سیگنال (b) و برای هر مقدار از مقیاس (a) با رابطه  $\delta$  قابل محاسبه است (Mallat, 1998):

$$\begin{aligned} \text{CWT}(a,b) &= W f(a,b) \\ &= \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(x) \psi\left(\frac{x-b}{a}\right) dx \\ &= \int_{-\infty}^{+\infty} f(x) \psi_{a,b}(x) dx \end{aligned} \quad (5)$$

توابع موجگ‌ها دارای انواع بسیاری هستند که مهم‌ترین و پرکاربردترین آنها شامل تابع موج Daubechies, Haar, Mexican hat, Morlet, Symlet و Meyer می‌باشند (Mallat, 1998).

انواع مختلف این توابع در جعبه ابزار نرم‌افزار MATLAB شرح داده شده است.

#### شبکه عصبی مصنوعی

شبکه‌های عصبی توانایی شناخت یک سیستم غیرخطی دینامیکی بدون داشتن هیچ‌گونه پیش‌فرض در فرآیند

که خطای تفکیک کم باشد آن را به‌عنوان یک راه‌حل ارائه می‌دهد. ماشین بردار پشتیبان برخلاف شبکه‌های عصبی با مشکل گیر افتادن در مینیمم‌های محلی تابع خطا مواجه نیست (Hong, 2011; Yin, 2011). مراحل حل مسئله در الگوریتم ماشین‌های بردار پشتیبان همانند الگوریتم شبکه‌های عصبی به دو مرحله آموزش و آزمایش تقسیم می‌شود. انواع مدل‌های ماشین بردار پشتیبان عبارت‌اند از رده‌بندی بردار پشتیبان، رگرسیون بردار پشتیبان، کمینه مربعات ماشین بردار پشتیبان، برنامه‌ریزی خطی ماشین بردار پشتیبان و ماشین‌های بردار پشتیبان Nu. در این پژوهش از ماشین بردار پشتیبان کمینه مربعات استفاده شد. ماشین بردار پشتیبان کمینه مربعات (LSSVM) یک مدل SVM اصلاح‌شده است و یک روش یادگیری ماشین قابل اجرا برای رده‌بندی و رگرسیون است (Suykens et al., 2002). روش LSSVM به‌جای مسئله درجه دوم SVM از معادلات KKT<sup>۱۰</sup> خطی استفاده می‌کند. SVM از یک تابع تلفات درجه دوم بدون هیچ قانونی استفاده می‌کند که سبب برآورد ضعیف‌تری می‌شود از این‌رو به‌منظور جلوگیری از این، LSSVM وزن‌دار برگرفته می‌شود و در مواردی که وزن‌های کوچک به داده‌ها اختصاص داده شود، روش آموزشی دو مرحله‌ای ارائه می‌شود. این مدل به‌دلیل استفاده از معادلات خطی در حل مسائل، دقت بیشتری نسبت به ماشین بردار پشتیبان کلاسیک دارد (Seifi, 2010; Shabri, 2012; and Suhartono, 2012).

یک مجموعه آموزشی از N داده  $\{x_i, y_i\}_{i=1}^N$  در نظر گرفته می‌شود که  $x_i \in R^d$  داده ورودی و  $y_i \in R$  داده خروجی است. فرمول‌بندی یا جزئیات ریاضیاتی مدل‌های رگرسیون LSSVM در کارهای (Nadiri et al., 2017a) ارائه شده است. انواع توابع کرنل می‌توانند با توجه به نوع مطالعات مورد استفاده قرار گیرند. انواع مختلف تابع کرنل مانند خطی، سیگموئیدی، پایه شعاعی و چندجمله‌ای وجود دارد که در این مطالعه از کرنل RBF<sup>۱۱</sup> استفاده شده است. علت انتخاب کرنل RBF این بود که این نوع کرنل بالاترین میزان کارایی را در مدل‌های هیدرولوژیکی داشته است (Suykens and Vandewalle, 1999).

<sup>11</sup> Radial basis function

<sup>۱۰</sup> Karush-Kuhn-tucker



## معیارهای ارزیابی

به منظور سنجش دقت مدل‌ها در انجام پیش‌بینی، صحت سنجی مدل‌ها انجام می‌شود. برای این منظور معیارهای مختلفی مورد استفاده قرار می‌گیرند که در این تحقیق دو مورد از پرکاربردترین آنها به کار گرفته شد.  $R^2$  یا  $DC^{12}$  (ضریب تبیین) مطابق رابطه ۹ و  $RMSE^{13}$  (ریشه میانگین مربعات خطا) مطابق رابطه ۱۰ (Legates and Cabe, 1999):

$$DC = R^2 = 1 - \frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2} \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_i - \hat{Q}_i)^2} \quad (10)$$

که در این روابط  $Q_i$  داده‌های محاسباتی،  $\hat{Q}_i$  داده‌های مشاهداتی،  $\bar{Q}$  میانگین داده‌های مشاهداتی و  $n$  تعداد داده‌ها می‌باشد. بهترین جواب زمانی حاصل می‌گردد که مقدار رابطه ۹ به عدد یک و مقدار رابطه ۱۰ به عدد صفر نزدیک شود.

## نتایج

### ماشین بردار پشتیبان کمینه مربعات (LSSVM)

برای اجرای ماشین بردار پشتیبان، از میان انواع مدل‌های ماشین بردار پشتیبان که در قسمت مدل‌های هوش مصنوعی توضیح داده شده است، مدل ماشین بردار پشتیبان کمینه مربعات (LSSVM) انتخاب شد. پس از آن، برای تعیین مقادیر مناسب تنظیم‌کننده  $\gamma$  و متغیر کرنل  $\sigma$ ، ابتدا در برنامه MATLAB کد نویسی شده و سپس این مقادیر به روش آزمایش و خطا بهینه شدند. تعیین مناسب مقادیر  $\gamma$  و  $\sigma$  تأثیر زیادی در نتایج مدل داشت. این مطالعه نشان داد که با انتخاب مناسب این مقادیر می‌توان به نتایج بهتری دست یافت. این مقادیر بهینه برای  $\gamma$  برابر  $2/80$  و برای  $\sigma$  برابر  $7/90$  بود. از میان انواع توابع کرنل، تابع پایه شعاعی (RBF) برای این مطالعه انتخاب گردید. پس از اجرای مدل، مقادیر به دست آمده برای  $R^2$  و RMSE مرحله آموزش به ترتیب  $0/88$  و  $0/000129 \text{ cm/sec}$  و برای مرحله آزمایش به ترتیب  $0/64$  و  $0/000238 \text{ cm/sec}$  تعیین شد جدول (۲).

جدول ۲- نتایج مدل‌های هوش مصنوعی در مراحل آموزش و آزمایش.

مدل‌ها	معیار ارزیابی		مراحل	
	SICM	WANN		LSSVM
	$0/000109$	$0/000128$	$0/000129$	مرحله آموزش
	$0/91$	$0/88$	$0/88$	
	$0/000161$	$0/000222$	$0/000238$	مرحله آزمایش
	$0/83$	$0/69$	$0/64$	

### هیبرید موجکی عصبی (WANN)

به بقیه توابع، دقت بیشتری دارد و به عنوان تابع موجک مادر انتخاب گردید. برای انتخاب مناسب تعداد سطح تجزیه، داده‌ها در ۲ و ۳ سطح تجزیه شدند. نتایج به دست آمده در این مطالعه نشان داد که سطح تجزیه ۲ مناسب‌تر از ۳ می‌باشد که علتش تعداد داده‌هاست. داده‌های تجزیه شده به عنوان ورودی، وارد شبکه عصبی پرسپترون چندلایه شدند. در این مرحله نوبت انتخاب تعداد نرون‌های میانی با روش آزمون و خطا بود که با توجه به نتایج به دست آمده، ۳ نرون میانی برای این مطالعه در نظر گرفته شد. در شکل‌های ۳ و ۴ مقادیر  $R^2$  و RMSE


در این مدل، ابتدا توسط تبدیل موجک، پیش‌پردازش داده‌ها انجام می‌گیرد. نتایج این پردازش به عنوان ورودی در مدل شبکه عصبی مورد استفاده قرار می‌گیرد. متغیرهای مهمی که در نتایج مدل مؤثر هستند، عبارت‌اند از: نوع تابع موجکی، سطح تجزیه و تعداد نرون‌های میانی. ابتدا نوع تابع موجک مادر انتخاب شد. روش انتخاب، آزمون و خطا بود. توابع موجک مادر بررسی شده در این تحقیق عبارت بودند از:  $db_4$ ،  $db_3$ ،  $db_2$  و  $db_5$ . پس از اجرا ملاحظه گردید که تابع موجک  $db_4$  نسبت

<sup>12</sup> Root mean squared error

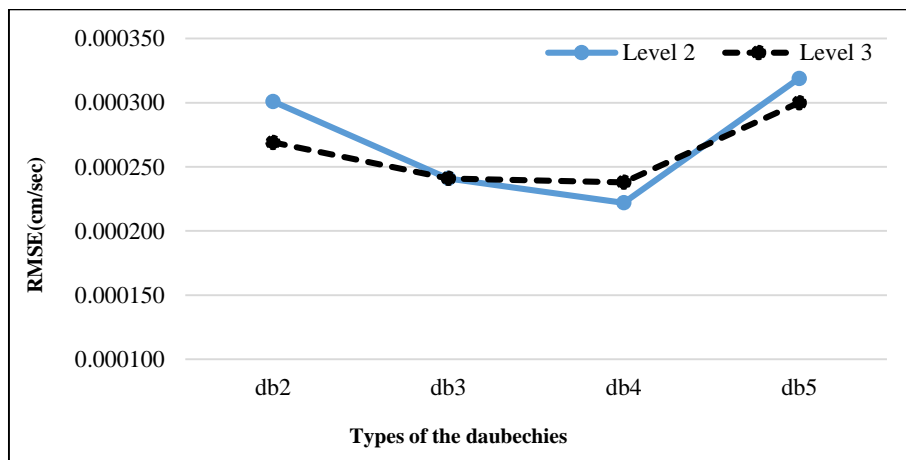
<sup>13</sup> Determination coefficient

پس از اجرای مدل، مقادیر  $R^2$  و RMSE برای مراحل آموزش و آزمایش مشخص شد. این مقادیر برای مرحله آموزش به ترتیب ۰/۸۸ و ۰/۰۰۰۱۲۸ cm/sec و برای مرحله آزمایش به ترتیب ۰/۶۹ و ۰/۰۰۰۲۲۲ cm/sec تعیین گردید جدول (۲).

مرحله‌ی آزمایش که نتیجه استفاده از توابع مختلف موجک مادر دابچیز، با سطوح تجزیه ۲ و ۳ و سه نرون میانی می‌باشند، نشان داده شده است. همچنان که مشهود است با استفاده از db4 و سطح تجزیه ۲ بهینه‌ترین مقادیر یعنی بیشترین مقدار برای  $R^2$  و کمترین مقدار برای RMSE به دست آمده است.



شکل ۳- نتایج  $R^2$  با انواع مختلف توابع موجک مادر دابچیز با سطوح تجزیه ۲ و ۳ در مرحله آزمایش.



شکل ۴- نتایج RMSE با انواع مختلف توابع موجک مادر دابچیز با سطوح تجزیه ۲ و ۳ در مرحله آزمایش.

TANSIG و PURELINE به عنوان توابع فعال سازی به ترتیب برای لایه‌های میانی (مخفی) و خروجی استفاده شد. برای روند آموزش نیز نوع الگو به الگو (EPOCH) در نظر گرفته شد. در این مدل  $R^2$  و RMSE در مرحله آموزش به ترتیب ۰/۹۱ و ۰/۰۰۰۱۰۹ cm/sec و در مرحله آزمایش به ترتیب ۰/۸۳ و ۰/۰۰۰۱۶۱ cm/sec تعیین گردید جدول (۲).

#### مدل هوشمند مرکب نظارت شده (SICM)

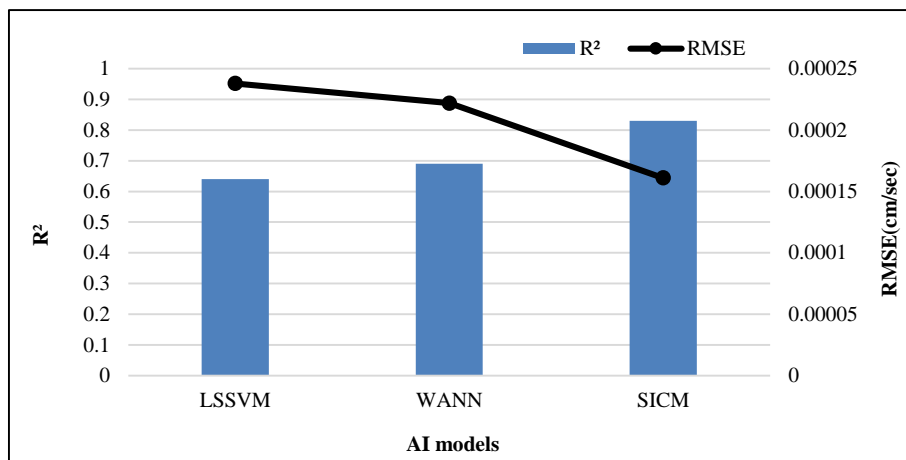
برای اجرای مدل هوشمند مرکب نظارت شده، ابتدا دو مدل انفرادی LSSVM و WANN اجرا گردیدند؛ سپس خروجی آن‌ها که همان هدایت هیدرولیکی می‌باشد به عنوان ورودی در شبکه عصبی مصنوعی (ANN) استفاده گردید. در اجرای شبکه عصبی مصنوعی (ANN)، به عنوان ترکیب کننده غیرخطی خروجی‌های مدل‌های انفرادی، از تابع آموزشی الگوریتم لونیبرگ- مارکوات (LM) بهره گرفته شد. از



**بحث**

نسبت به دو مدل انفرادی می‌باشد شکل (۵). در مقایسه دو مدل انفرادی LSSVM و WANN نیز مدل WANN با داشتن  $R^2 = 0/69$  و  $RMSE = 0/000222$  cm/sec در مرحله آزمایش نسبت به مدل LSSVM که دارای  $R^2 = 0/64$  و  $RMSE = 0/000238$  بود، مدل دقیق‌تر بوده و پیش‌بینی بهتری از هدایت هیدرولیکی داشته است و علت آن احتمالاً تجزیه داده‌ها به زیر سری‌ها قبل از وارد کردن آنها به شبکه عصبی مصنوعی می‌باشد شکل (۵).

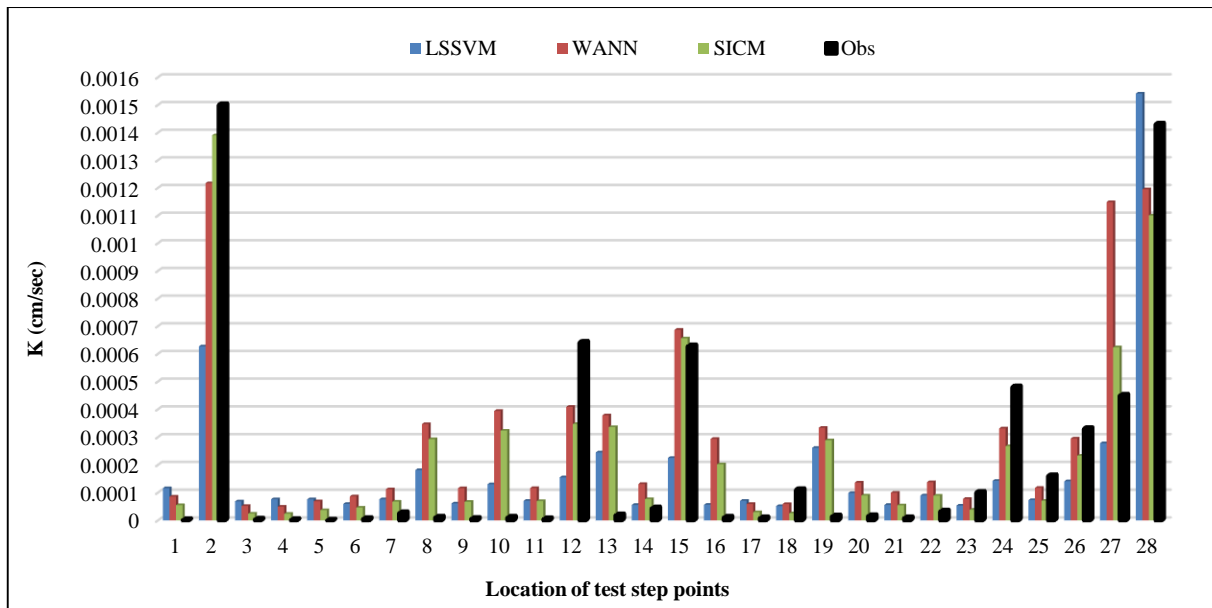
با مقایسه نتایج مدل SICM با دو مدل انفرادی، مشاهده گردید که مدل SICM نسبت به دو مدل انفرادی پیش‌بینی بهتری از هدایت هیدرولیکی داشته و این پیش‌بینی با دقت بیشتری همراه بوده است به طوری که با داشتن  $R^2 = 0/83$  و  $RMSE = 0/000161$  cm/sec در مرحله آزمایش نسبت به مدل انفرادی دقیق‌تر یعنی WANN که دارای  $R^2 = 0/69$  و  $RMSE = 0/000222$  cm/sec می‌باشد، ارتقای نتایج این مدل مشهود بوده و نشان‌دهنده تخمین دقیق‌تر هدایت هیدرولیکی



شکل ۵- نمودار مقایسه‌ای مقادیر  $R^2$  و RMSE مدل‌های هوش مصنوعی در مرحله آزمایش.

در نقاطی مانند ۱۲، ۱۴ و ۲۷ مدل ترکیبی SICM توانسته است نسبت به یک مدل انفرادی، مقادیر محاسباتی را ارتقاء داده و به مقادیر مشاهداتی نزدیک‌تر نماید، به مفهومی دیگر مدل SICM توانسته است مقادیری بین مقادیر دو مدل انفرادی به خود اختصاص دهد که این نیز نشان‌دهنده ارتقای نسبی نتایج در این نقاط می‌باشد. همچنین با بررسی نقطه به نقطه این شکل مشاهده گردید که نقاطی مانند ۱۸ و ۲۸ نیز وجود دارند که در آن نقاط مقادیر محاسباتی مدل‌های انفرادی به مقادیر مشاهداتی نزدیک‌تر است یعنی در این نقاط مدل‌های انفرادی بهتر عمل کرده‌اند و این نیز به دلیل نقاط قوت خاص و مزیت منحصر به فرد مدل‌های انفرادی می‌باشد شکل (۶).

به‌غیر از  $R^2$  و RMSE که معیارهای بسیار مهمی برای ارزیابی نتایج مدل‌ها می‌باشند با ارائه روشی دیگر نیز می‌توان دقت پیش‌بینی مدل‌ها را بررسی کرد. برای این منظور مطابق شکل ۶ در یک نمودار اندازه نزدیکی مقادیر محاسباتی هر سه مدل با مقادیر مشاهداتی مرحله آزمایش نشان داده شد. پس از رسم نمودار مشخص گردید که مدل ترکیبی SICM توانسته است نزدیکی مقادیر محاسباتی و مشاهداتی را به میزان قابل توجهی افزایش دهد. این نزدیکی در ۱۳ نقطه از ۲۸ نقطه کاملاً نمایان است. مثلاً با دقت در نقاط ۲، ۷ و ۱۵ مشاهده گردید که مقادیر محاسباتی در این نقاط در مدل SICM نسبت به هر دو مدل انفرادی، به مقادیر مشاهداتی نزدیک‌تر است یعنی تأثیر کاملاً مستقیمی روی نتایج داشته است. همچنین مشاهده گردید که



شکل ۶- نمودار مقایسه‌ای مقادیر محاسباتی مدل‌های هوش مصنوعی با مقادیر مشاهداتی مرحله آزمایش.

شمال بلژیک در نحوه ترکیب مدل‌ها می‌باشد. در آبخوان شمال بلژیک ابتدا مدل شبکه عصبی مصنوعی (ANN) اجرا گردیده و سپس با استفاده از GLUE نتایج بهینه شدند؛ در صورتی که در تحقیق حاضر ابتدا مدل‌های انفرادی اجرا شدند، سپس نتایج این مدل‌ها توسط شبکه عصبی مصنوعی (ANN) ترکیب شده و موجب بهبودی نتایج گردید. تفاوت تحقیق حاضر با دو تحقیق آبخوان دشت تسوج و آبخوان دشت مراغه-بناب در این است که در هر دو تحقیق یادشده، از داده‌های ژئوفیزیکی و هیدروژئولوژی مانند هدایت الکتریکی، مقاومت ویژه عرضی و ضخامت اشباع برای پیش‌بینی هدایت هیدرولیکی استفاده شده است در صورتی که در تحقیق حاضر از اطلاعات دانه‌بندی (توزیع اندازه ذرات) که یکی از پارامترهای بسیار مهم در نفوذپذیری می‌باشد، استفاده گردیده است. تفاوت دیگر این تحقیق با تحقیق آبخوان دشت تسوج در نوع استفاده از مدل‌های هوش مصنوعی منفرد می‌باشد به طوری که در این تحقیق از مدل‌های انفرادی WANN و LSSVM که در پیش‌بینی هدایت هیدرولیکی کمتر استفاده شده‌اند، بهره گرفته شده است ولی در مطالعه آبخوان دشت تسوج مدل‌های منفرد منطق فازی، شبکه عصبی مصنوعی و نروفازی مورد استفاده قرار گرفته‌اند.

Rogiers et al. (2012) هدایت هیدرولیکی را با روش ترکیبی GLUE-ANN در آبخوان نئوزن شمال بلژیک تخمین زدند. آن‌ها در این تحقیق داده‌های دانه‌بندی را به‌عنوان ورودی برای پیش‌بینی هدایت هیدرولیکی مورد استفاده قرار دادند و به این نتیجه رسیدند که این مدل ترکیبی عملکرد مناسب‌تری در تخمین هدایت هیدرولیکی داشته است. (Tayfur et al. (2014 با استفاده از مدل ترکیبی SICM، هدایت هیدرولیکی را در دشت تسوج پیش‌بینی کردند. آن‌ها در این تحقیق از مدل‌های انفرادی منطق فازی ممدانی و ساگنو، شبکه عصبی مصنوعی و نروفازی استفاده کردند. نتایج تحقیق نشان داد که مدل ترکیبی SICM نسبت به مدل‌های انفرادی در پیش‌بینی هدایت هیدرولیکی موفق‌تر عمل کرده است. در مطالعه دیگری یوسف‌زاده و ندیری (۱۳۹۶) از روش SCMAI<sup>۱۴</sup> که ترکیبی از نتایج مدل‌های منفرد هوش مصنوعی بود، استفاده کرده و هدایت هیدرولیکی را در آبخوان دشت مراغه-بناب تخمین زدند. مدل‌های منفرد هوش مصنوعی استفاده شده در این تحقیق شامل منطق فازی ساگنو و ممدانی، ماشین بردار پشتیبان و هیبرید موجکی عصبی بودند. بررسی نتایج مدل‌ها نشان داد که مدل ترکیبی SCMAI تخمین مناسب‌تری از هدایت هیدرولیکی نسبت به مدل‌های انفرادی داشته است. تفاوت تحقیق حاضر با تحقیق انجام‌گرفته در آبخوان نئوزن

<sup>۱۴</sup> Supervised committee machine artificial intelligent

## نتیجه گیری

رخ شاد، ا. م.، شهیدی، ع.، ۱۴۰۰. عملکرد شش روش ترکیبی هوشمند در مدل سازی کیفی آب زیرزمینی مطالعه موردی: دشت بافق. هیدروژئولوژی، ۶(۱)، ۱۳۹-۱۲۶.

سازمان قطار شهری تبریز، ۱۳۸۳، ۱۳۸۴ و ۱۳۸۸. گزارش های مطالعات ژئوتکنیک خطوط ۱ و ۲ قطار شهری تبریز.

عزیزی، ا.، رجبی، ا.، یعقوبی، ب.، شعبانلو، س.، ۱۴۰۰. تخمین نوسانات تراز آب زیرزمینی توسط مدل بهینه موجک-برنامه نویسی بیان ژن. هیدروژئولوژی، ۶(۱)، ۸۳-۶۸.

عندلیب، غ.، نورانی، و.، منیری، فرح، ح.، شرقی، ا.، ۱۳۹۸. توسعه روش ترکیبی موجک-شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای مدلسازی چند ایستگاه های بارش-رواناب با استفاده از ابزارهای خوشه بندی و اطلاعات مشترک. رویکردهای نوین در مهندسی عمران، ۳(۲)، ۴۹-۶۲.

قره خانی، م.، ندیری، ع.، ا.، اصغری مقدم، ا.، صادقی اقدم، ف.، ۱۳۹۴. بهینه سازی مدل دراستیک با استفاده از ماشین بردار پشتیبان و شبکه عصبی مصنوعی به منظور ارزیابی آسیب پذیری ذاتی آبخوان دشت اردبیل. اکوهیدرولوژی، ۲(۳)، ۳۱۱-۳۲۴.

نورانی، و.، عندلیب، غ.، ۱۳۹۶. به کارگیری مدل های ترکیبی موجک-شبکه عصبی مصنوعی و ماشین بردار پشتیبان در پیش بینی بار رسوب معلق آجی چای. رویکردهای نوین در مهندسی عمران، ۱(۲)، ۵۵-۴۶.

یوسفزاده، س.، ندیری، ع.، ا.، ۱۳۹۶. برآورد هدایت هیدرولیکی با استفاده از روش SCMAI، مطالعه موردی: آبخوان دشت مراغه- بناب (آذربایجان شرقی). فصلنامه علمی-پژوهشی علوم زمین، ۲۷(۱۰۵)، ۱۹۲-۱۸۳.

یوسفزاده، س.، ندیری، ع.، ا.، ۱۴۰۰. تخمین هدایت هیدرولیکی با استفاده از مدل های هوشمند با به کارگیری داده های ژئوفیزیکی. زمین شناسی کاربردی پیشرفته، ۱۱(۲)، ۳۸۲-۴۰۴.

در این تحقیق از دو روش هوش مصنوعی منفرد LSSVM و WANN و یک مدل ترکیبی با نام SICM که از نتایج دو مدل انفرادی برای پیش بینی هدایت هیدرولیکی بر اساس اطلاعات دانه بندی در قطار شهری تبریز، بهره جسته استفاده گردید. بررسی نتایج نشان داد که با وجود این که هر سه مدل هوش مصنوعی ارائه شده در این تحقیق در پیش بینی هدایت هیدرولیکی عملکرد نسبتاً مناسبی داشتند، اما مدل ترکیبی SICM به دلیل استفاده هم زمان از مزایای هر دو مدل انفرادی، نسبت به آن دو مدل، پیش بینی بهتری داشته است. مقایسه نتایج پیش بینی این مدل با دو مدل منفرد در مرحله آزمایش، نشان از افزایش به ترتیب ۳۰ و ۲۰ درصدی  $R^2$  این مدل و کاهش به ترتیب ۳۲ و ۲۷ درصدی RMSE این مدل نسبت به دو مدل انفرادی به ترتیب LSSVM و WANN داشت. مقایسه نتایج نشان داد که در میان دو مدل انفرادی LSSVM و WANN، مدل WANN عملکرد مناسب تری در برآورد هدایت هیدرولیکی داشته است؛ همچنین هر کدام از مدل های انفرادی به علت نقاط قوت خاص خود، در نقاطی عملکرد بهتری داشته اند. پیشنهاد می شود در تحقیقی دیگر به غیر از این دو مدل هوش مصنوعی منفرد از یک یا دو مدل هوش مصنوعی منفرد دیگر در کنار این دو مدل منفرد استفاده کرده و بررسی نمود که آیا استفاده هم زمان از نتایج این مدل ها به صورت ترکیبی می تواند اندک نقاط ضعف مدل ترکیبی SICM را برطرف نموده و در تدقیق پیش بینی هدایت هیدرولیکی تأثیر مثبتی داشته باشد.

## منابع

ترابی، ح.، نصرالهی، ع.، ح.، دهقانی، ر.، ۱۴۰۰. ارزیابی مدل شبکه عصبی موجک در پیش بینی منابع آب زیرزمینی استان لرستان. هیدروژئولوژی، ۶(۱)، ۱-۱۲.

داداش بابا، م.، ندیری، ع.، ا.، اصغری مقدم، ا.، برزگری، ق.، ۱۳۹۶. ارزیابی توانایی مدل ترکیبی SOM-FL برای پیش بینی هدایت هیدرولیکی در محدوده متروی شهر تبریز. اکوهیدرولوژی، ۴(۱)، ۷۵-۸۷.

- networks. *Mathematical Geosciences*, 44(6), 739-763.
- Ross, J., Ozbek, M., Pinder, G. F. 2007. Hydraulic conductivity estimation via fuzzy analysis of grain size data. *Mathematical geology*, 39(8), 765-780.
- Sedaghat, A., Bayat, H., Safari Sinegani, A. A. 2016. Estimation of soil saturated hydraulic conductivity by artificial neural networks ensemble in smectitic soils. *Eurasian Soil Science*, 49(3), 347-357.
- Seifi, A., 2010. Developing of expert system to prediction of daily evapotranspiration by support vector machine and compare results to ANN, ANFIS and experimental method. M.Sc. Thesis, Department of Water Engineering, Tarbiat Modarres University, Tehran, Iran (In Persian).
- Sezer, A., Göktepe, A. B., Altun, S. 2010. Adaptive neuro-fuzzy approach for sand permeability estimation. *Environmental Engineering & Management Journal (EEMJ)*, 9(2), 231-238.
- Shabri, A., Suhartono. 2012. Streamflow forecasting using least-squares support vector machines. *Hydrological Sciences Journal*, 57(7), 1275-1293.
- Sharghi, E., Nourani, V., Najafi, H., Gokcekus, H. 2019. Conjunction of a newly proposed emotional ANN (EANN) and wavelet transform for suspended sediment load modeling. *Water Supply*, 19(6), 1726-1734.
- Sihag, P. 2018. Prediction of unsaturated hydraulic conductivity using fuzzy logic and artificial neural network. *Modeling Earth Systems and Environment*, 4(1), 189-198.
- Suykens, J. A. K., Vandewalle, J. 1999. Least squares support vector machine classifiers. *Neural processing letters*, 9(3), 293-300.
- Suykens, J. A. K., Van, G. T., Brabanter, J. D., De, M. B., Vandewalle, J. P. 2002. Least squares support vector machines. World scientific Publishing, Singapore.
- Tayfur, G., Nadiri, A. A., Asghari Moghaddam, A. 2014. Supervised intelligent committee machine method for hydraulic conductivity estimation. *Water resources management*, 28(4), 1173-1184.
- Todd, D. K., Mays, L. W., 2005. *Groundwater Hydrology*. (Third Edition): John Wiley and Sons. New York, 636 p.
- Vapnik, V., Cortes, C. 1995. Support Vector Networks. *Machine Learning*, 20, 1-25.
- Yin, J. 2011. LogP prediction for blocked tripeptides with amino acids descriptors (HMLP) by multiple linear regression and support vector regression. *Procedia Environmental Sciences*, 8, 173-178.
- Andalib, G., Nourani, V. 2019. Application of Wavelet Denoising and Artificial Intelligence Models for Stream Flow Forecasting. *Advance Researches in Civil Engineering*, 1(1), 1-8.
- Erzin, Y., Gumaste, S. D., Gupta, A. K., Singh, D. N. 2009. Artificial neural network (ANN) models for determining hydraulic conductivity of compacted fine-grained soils. *Canadian Geotechnical Journal*, 46(8), 955-968.
- Hong, W. C. 2011. Traffic flow forecasting by seasonal SVR with chaotic simulated annealing algorithm. *Neurocomputing*, 74(12-13), 2096-2107.
- Kim, T. W., Valdés, J. B. 2003. Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering*, 8(6), 319-328.
- Legates, D. R., McCabe, Jr. G. J. 1999. Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation. *Water resources research*, 35(1), 233-241.
- Mallat, S. G., 1998. A wavelet tour of signal processing. Academic press. San Diego, 557p.
- Nadiri, A. A., Chitsazan, N., Tsai, F. T. C., Asghari Moghaddam, A. 2014. Bayesian artificial intelligence model averaging for hydraulic conductivity estimation. *Journal of Hydrologic Engineering*, 19(3), 520-532.
- Nadiri, A. A., Gharekhani, M., Khatibi, R., Asghari Moghaddam, A. 2017a. Assessment of groundwater vulnerability using supervised committee to combine fuzzy logic models. *Environmental Science and Pollution Research*, 24(9), 8562-8577.
- Nourani, V., Andalib, G. 2015. Daily and monthly suspended sediment load predictions using wavelet based artificial intelligence approaches. *Journal of Mountain Science*, 12(1), 85-100.
- Nourani, V., Hosseini Baghanam, A., Adamowski, J., Kisi, O. 2014. Applications of hybrid wavelet-artificial intelligence models in hydrology: a review. *Journal of Hydrology*, 514, 358-377.
- Nourani, V., Komasi, M., Mano, A. 2009. A multivariate ANN-wavelet approach for rainfall-runoff modeling. *Water resources management*, 23(14), 2877-2894.
- Nowak, W., Cirpka, O. A. 2006. Geostatistical inference of hydraulic conductivity and dispersivities from hydraulic heads and tracer data. *Water Resources Research*, 42(8), W08416, doi: 10.1029/2005 WR004832.
- Rogiers, B., Mallants, D., Batelaan, O., Gedeon, M., Huysmans, M., Dassargues, A. 2012. Estimation of hydraulic conductivity and its uncertainty from grain-size data using GLUE and artificial neural