

# برآورد هدایت هیدرولیکی با استفاده از روش SCMAI، مطالعه موردی: آبخوان دشت مراغه - بناب (آذربایجان شرقی)

سعید یوسفزاده<sup>۱</sup> و عطاءالله ندیری<sup>۲\*</sup>

<sup>۱</sup>دانشجوی کارشناسی ارشد، گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز، تبریز، ایران

<sup>۲</sup>دانشیار، گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز، تبریز، ایران

تاریخ دریافت: ۱۳۹۴/۱۰/۱۲ تاریخ پذیرش: ۱۳۹۵/۱۰/۰۴

## چکیده

امروزه آب زیرزمینی یکی از منابع اصلی آب آشامیدنی و کشاورزی و دیگر مصارف مختلف برای جوامع بشری است. با افزایش جمعیت و توسعه یافتگی جوامع، تقاضا برای این منبع طبیعی مهم و حیاتی و استراتژیک افزایش یافته است. این افزایش با کاهش منابع آبی با صدمه بر محیط آبخوانها همراه بوده است. بر این اساس برای رویارویی با بحران کم آبی و جلوگیری از تخریب آبخوانها، مدیریت آنها و در پی آن شناخت دقیق متغیرهای هیدروژئولوژیکی به شدت احساس می شود. یکی از مهم ترین این متغیرها، هدایت هیدرولیکی است. با وجود اینکه، سامانه آب زیرزمینی یک سامانه پیچیده است و برآورد متغیرهای هیدروژئولوژیکی که معمولاً با روش های کلاسیک مانند روش های آزمایشگاهی، اسلاگ تست، آزمایش ردیابی و آزمون های پمپاژ انجام می گیرد؛ با عدم قطعیت ذاتی همراه بوده و پرهزینه و وقت گیر است. بنابراین، استفاده از روش های هوش مصنوعی برای برآورد هدایت هیدرولیکی، می تواند از عدم قطعیت این متغیر کم کند و تا حدودی بر دقت آن بیافزاید؛ تا بتواند بر نواقص موجود در روش های کلاسیک چیره شود. در این پژوهش چهار روش هوش مصنوعی، روش سامانه استنتاج فازی ممدانی، سامانه استنتاج فازی ساجنو، شبکه عصبی موجکی، و ماشین بردار پشتیبان کمینه مربعات به عنوان مدل های منفرد برای برآورد هدایت هیدرولیکی آبخوان مراغه بناب با استفاده از داده های ژئوفیزیکی سطحی در منطقه به کار گرفته شد. با توجه به اینکه هر کدام از مدل ها بر پایه ویژگی های ذاتی خود در بخشی از این محدوده نتایج خوبی ارائه دادند. بنابراین برای استفاده همزمان از کارایی همه این مدل ها روش ترکیب غیرخطی با عنوان مدل هوش مصنوعی مرکب نظارت شده (SCMAI) برای برآورد هدایت هیدرولیکی در دشت مراغه - بناب استفاده و نتایج آن با استفاده از معیارهای ارزیابی مختلف نشان داده شد. مدل SCMAI با استفاده از ۱۵ داده مورد آزمایش قرار گرفت. مقادیر RMSE و  $R^2$  به ترتیب برابر ۰/۰۴۵ و ۰/۹۷ به دست آمد. با مقایسه این مقادیر با مقادیر محاسبه شده برای مدل های منفرد یاد شده، دیده شد که مدل SCMAI با داشتن RMSE کمتر و  $R^2$  بهتر از مدل های هوش مصنوعی منفرد است. این نتایج بیان می دارد که مدل SCMAI کارآیی بالایی در برآورد مقادیر هدایت هیدرولیکی در آبخوان آزاد و هتروژن دشت مراغه - بناب نشان می دهد.

**کلیدواژه ها:** شبکه موجکی - عصبی، ماشین بردار پشتیبان، منطق فازی، هدایت هیدرولیکی، هوش مصنوعی مرکب نظارت شده.

\*نویسنده مسئول: عطاءالله ندیری

E-mail: nadiri@tabrizu.ac.ir

## ۱- پیش نوشتار

راه حفاری دارند؛ اما وقت گیر و پرهزینه هستند و به نیروی انسانی بیشتری نیاز دارند و همچنین به علت رفتار غیرخطی و شرایط ناهمگن و ناهمسان حاکم بر محیط های هیدروژئولوژیکی، متغیرهای اندازه گیری شده به وسیله این روش ها عدم قطعیت ذاتی دارند. افزون بر این، همه روش های اخیر حاصل حل معادلات حاکم بر جریان آب زیرزمینی با روش ها و با شرایط مرزی و قیود متفاوت و یا فرمول های تجربی بود. با گسترش علوم و فناوری در حوزه مطالعات آب های زیرزمینی، مدل های هوش مصنوعی نیز برای تعیین متغیرهای آب زمین شناختی گسترش پیدا کرده اند. از میان روش های مختلف هوش مصنوعی می توان به روش های برآوردگری مانند منطق فازی (FL)، شبکه عصبی مصنوعی (ANN) و نرو- فازی (NF) اشاره کرد (Nadiri et al., 2013; Asadi et al., 2014). در چند سال گذشته مطالعات مختلفی برای برآورد متغیرهای آب زمین شناختی با استفاده از روش های منطق فازی (Bárdossy and Disse, 1993; Helmy et al., 2010; Tutmez and Hatipoglu, 2007; Chu and Chang, 2009; Anifowose and Abdulraheem, 2011; Tayfure, 2012; Morankar et al., 2013؛ ندیری و همکاران، ۱۳۹۳)، شبکه عصبی مصنوعی (Schaap and Leij, 1998; Merdun et al., 2006; Nayak et al., 2006; Samani et al., 2007; Tayfur et al., 2007; Mohanty et al., 2010; Motaghian and Mohammadi, 2011; Shirmohammadi et al., 2013; Chitsazan et al., 2015; Nadiri et al., 2015؛ مختاری و همکاران، ۱۳۹۱)، نرو- فازی (Tutmez, 2010; Huang et al., 2010; Moosavi et al., 2013; Safavi et al., 2013;) (Nadiri et al., 2014) برای برآورد متغیرهای آب زمین شناختی انجام گرفته است. همچنین بررسی مطالعات انجام گرفته در زمینه برآورد و پیش بینی متغیرهای

یکی از مهم ترین اهداف مدیریت و بهره برداری بهینه از آب زیرزمینی، پیش بینی شرایط آبخوانهاست که انجام این کار مستلزم شناخت دقیق متغیرهای آب زمین شناختی آنهاست. هدایت هیدرولیکی یکی از مهم ترین این متغیرهاست که بسیاری از ویژگی های جریان آب در محیط های متخلخل را می توان از راه این متغیر ارزیابی کرد؛ چرا که متغیرهای دیگری نیز وجود دارند که مقادیر آنها به هدایت هیدرولیکی وابسته است. به خاطر اهمیت بالای این متغیر در مطالعات آب های زیرزمینی و مدیریت یکپارچه و بهره برداری بهینه از منابع آب زیرزمینی، روش های آزمایشگاهی و صحرایی گوناگونی در طی سالیان گذشته گسترش پیدا کرده است. از جمله روش های صحرایی برآورد هدایت هیدرولیکی می توان به روش های پمپاژ، اسلاگ تست و آزمایش ردیابی اشاره کرد (اصغری مقدم و همکاران، ۱۳۸۷). تاکنون سه روش متفاوت برای تعیین این متغیر در صحرا برای روش اسلاگ تست (Bouwer, 1989; Hvorslev, 1951; Cooper et al., 1967) و چندین روش معمول برای آزمایش پمپاژ (Theis, 1935; Chow, 1952; Cooper and Jacob, 1946;) (Neuman, 1975) ارائه شده است. همچنین برای تعیین این متغیر در آزمایشگاه نیز تاکنون پنج روش مشهور شامل (Shepherd (1989)، Hezen (1892)، Alyamani and Sen (1993)، Fair and Hatch (1933)، Carman (1956) ارائه شده است. Sperry and Peirce (1995) پس از ارزیابی توانایی روش های آزمایشگاهی و فرمول های تجربی ارائه شده چنین نتیجه گرفتند که به جز محیط های دارای ذرات با اشکال بسیار نامنظم، بهترین روش در این زمینه فرمول تجربی (Hezen (1892) است و در حالت کلی فرمول تجربی (Alyamani and Sen (1993) به نتایج واقعی نزدیک تر است. این روش ها با وجود اینکه مزایای مختلفی مانند شناخت شرایط زیرسطحی از

کفه‌های تبخیری را تشکیل داده‌اند. بستر رودخانه‌های جاری در دشت بیشتر پوشیده از رسوبات آبرفتی دانه‌درشت است که به سوی باختر دانه‌ریزتر می‌شوند. ارتفاع بلندترین نقطه سفره ۱۶۰۷ متر از سطح دریا و ارتفاع پست‌ترین نقطه ۱۲۶۲ متر از سطح دریا در شوره‌زارهای حاشیه دریاچه ارومیه است (فیجانی، ۱۳۹۲). آبخوان دشت مراغه- بناب را رسوبات آبرفتی کواترنری تشکیل داده است. پاره‌ای از سازندهای سنگی منطقه دارای تراوایی درز و شکاف هستند. در سازندهای درز و شکاف‌دار منطقه که به‌طور عموم از جنس آتشفشانی‌های سهند و آهک‌های شیل‌دار هستند؛ مقداری آب نفوذ می‌کند که به وسیله تعدادی چشمه با آبدهی ناچیز مشخص می‌شود. نهشته‌های آبرفتی دوران چهارم مهم‌ترین سنگ مخزن آب زیرزمینی منطقه هستند. آبخوان پیوسته‌ای که در آبرفت‌های دشت مراغه- بناب تشکیل شده است؛ از جنوب شهر مراغه شروع می‌شود و تا شوره‌زارهای دریاچه ارومیه ادامه دارد که به عنوان آبخوان اصلی دشت مراغه- بناب نام‌گذاری شده است. بر پایه اطلاعات حاصل از بررسی‌های ژئوفیزیکی و نتایج حفاری چاه‌های اکتشافی و مشاهده‌ای، آبخوان دشت مراغه- بناب از نوع آزاد و تک‌لایه است. گستره محدوده آبخوان در حدود ۱۹۰ کیلومتر مربع برآورد شده است. بهره‌برداری از آبخوان اصلی دشت به کمک شماری چاه ژرف و نیمه‌ژرف و تعدادی قنات و چشمه صورت می‌گیرد (مهندسین مشاور یکم، ۱۳۹۲). به علت برداشت زیاد از آب زیرزمینی در دشت مراغه- بناب برای کشاورزی و در نتیجه روبه‌رو بودن با کمبود منابع آب و همچنین به علت فعالیت شهرک‌های صنعتی که منابع آب‌های زیرزمینی را در معرض آلودگی به آلاینده‌های شیمیایی قرار داده‌اند؛ به نظر می‌رسد که محافظت و بازیابی چاه‌های آب، مدیریت آبخوان و بهره‌برداری بهینه از آب زیرزمینی در دشت مراغه- بناب باید بیش از پیش مورد توجه قرار گیرد. برای مدیریت و بهره‌برداری بهینه از آب زیرزمینی، شناخت شرایط آب‌زمین‌شناختی آبخوان امری ضروری است. برای شناخت بهتر این شرایط باید متغیرهای مؤثر بر رفتار آبخوان با دقت بیشتری پیش‌بینی و برآورد شوند که یکی از مهم‌ترین این متغیرها هدایت هیدرولیکی است. برای تشخیص ویژگی‌های آب‌زمین‌شناختی منطقه، مطالعات ژئوفیزیک و حفاری‌های اکتشافی به‌صورت مجزا مورد توجه قرار گرفته‌اند. مطالعات ژئوفیزیک انجام گرفته در دشت مراغه- بناب به روش ژئوالکتریک بوده (Sadeghfam et al., 2016) و طی آن ۶۸ سونداژ در راستای ۱۲ نیم‌رخ ژئوالکتریک برداشت شده است (شکل ۲). ستبرای اشباع رسوبات از جمله متغیرهای مؤثر در برآورد هدایت هیدرولیکی است که برای به دست آوردن آن با توجه به مطالعات ژئوفیزیک انجام شده، نقشه هم‌ستبرای آبرفت رسم شد (شکل ۳). برای رسم نقشه‌های هم‌ستبرای اشباع (شکل ۳) از روش درون‌یابی IDW در محیط نرم‌افزار ArcGIS استفاده شد. روش IDW از جمله روش‌های قطعی است. بنابراین برای خطوط هم‌ستبرای آبرفت که دارای داده‌های مشاهداتی و قطعیت بالایی هستند؛ از این روش استفاده شد.

در دشت مراغه- بناب ۶ حلقه چاه اکتشافی و ۶ حلقه چاه پمپاژ حفاری شده است. ژرف‌ترین چاه اکتشافی با ۷۲ متر ژرفا در روستای قلعه خالصه قرار دارد. همچنین روی ۶ حلقه از چاه‌های اکتشافی که پیزومتر نیز داشتند؛ آزمایش پمپاژ انجام گرفته است (مهندسین مشاور یکم، ۱۳۹۲). با در نظر گرفتن اطلاعات و داده‌های یاد شده، در این مطالعه از مدل‌های فازی ممدانی، فازی ساگنو، ماشین بردار پشتیبان و هیبرید موجکی-عصبی برای برآورد هدایت هیدرولیکی در دشت مراغه- بناب استفاده شد. سپس بر پایه مدل SCMAI خروجی هر یک از مدل‌های منفرد یاد شده با استفاده از مدل شبکه عصبی مصنوعی پرسپترون چندلایه ترکیب شد. به این صورت که خروجی هر یک از مدل‌های منفرد به عنوان ورودی، وارد شبکه عصبی پرسپترون چندلایه شد. همان‌گونه که اشاره شد؛ در این مطالعه از مدل‌های فازی ممدانی و ساگنو نیز استفاده شد. اولین مرحله در اجرای این مدل‌ها دسته‌بندی داده‌ها و تعیین توابع عضویت است. در این پژوهش از روش کاهشی برای مدل ساگنو استفاده شد که روشی کارا و مفید در دسته‌بندی داده‌ها و تعیین قوانین فازی در پژوهش‌های اخیر بوده است (Nadiri et al., 2014).

آب‌شناسی و آب‌زمین‌شناسی مانند میزان رواناب، تغییرات سطح آب، ضریب ذخیره، تخلخل، قابلیت انتقال، کیفیت آب‌های سطحی و زیرزمینی و غیره، موفقیت روش‌های هوش مصنوعی مانند ماشین بردار پشتیبان (Nadiri et al., 2013) و Nadiri et al., 2017 a and c؛ ندیری و همکاران، (۱۳۹۵ الف) و هیبرید موجکی-عصبی (Nourani et al., 2014)؛ ندیری و یوسف‌زاده، (۱۳۹۶) به اثبات رسیده است. متغیرهای آب‌زمین‌شناختی مانند هدایت هیدرولیکی مقادیر قطعی و ثابتی ندارند و در بیشتر مواقع با عدم قطعیت همراه هستند (Tayfur et al., 2014). با این حال، برای برآورد هدایت هیدرولیکی از روش‌های منطق فازی (Ross et al., 2007; Olatunji et al., 2011; Inan and Tayfur, 2012; Colín et al., 2011; Tamari et al., 1996; Garcia and Shigidi, 2006; Sun et al., 2011; Malki and Baldwin, 2002; Hurtado et al., 2009; Gaur et al., 2013) و نرو-فازی (Zezar et al., 2010; Dhar and Patil, 2012; Tayfur et al., 2014; Nadiri, 2015) استفاده شده است. با توجه به توانایی ذاتی و متفاوت هر کدام از این مدل‌ها، Nadiri et al. (2013) روش ترکیبی SCMAI را برای برآورد متغیرهای هیدروژئوشیمیایی ارائه داده‌اند و به دنبال آن، Tayfur et al. (2014) مطالعه‌ای مبنی بر برآورد هدایت هیدرولیکی با استفاده از مدل SCMAI انجام دادند. این پژوهشگران با استفاده از هدایت الکتریکی و ستبرای اشباع به برآورد هدایت هیدرولیکی و قابلیت انتقال دشت تسوج به کمک روش‌های فازی ممدانی، فازی ساگنو، شبکه عصبی مصنوعی و نرو-فازی پرداختند و سپس مقادیر خروجی هر یک از این مدل‌ها را با استفاده از شبکه عصبی بهینه کردند. در این پژوهش برای برآورد هدایت هیدرولیکی در دشت مراغه- بناب از روش SCMAI استفاده شد. با توجه به اینکه در مدل ترکیبی SCMAI به کار رفته در این مطالعه، از خروجی مدل‌های انفرادی هوش مصنوعی مانند ماشین بردار پشتیبان حداقل مربعات (LS-SVM)، سامانه استنتاج فازی (FIS) و سامانه موجکی-عصبی (Wavelet-ANN) استفاده می‌شود؛ از مزایای تک‌تک این روش‌ها استفاده و متغیر مورد نظر برآورد می‌شود که این کار توسط یک ترکیب کننده غیرخطی انجام می‌گیرد. بنابراین، این روش تجمیعی از مزایای روش‌های دیگر است که به‌صورت انفرادی اجرا می‌شوند. در این صورت، مقادیر برآورد شده به وسیله تک‌تک روش‌ها که در مدل SCMAI ترکیب می‌شوند، بار دیگر بهینه و به مقدار مشاهداتی نزدیک‌تر می‌شوند. در نتیجه می‌تواند نتایج بهتری نسبت به مدل‌های انفرادی داشته باشد. بنابراین، در این پژوهش سعی شده است که با استفاده از داده‌های ژئوفیزیکی مرتبط با هدایت هیدرولیکی، این متغیر به کمک مدل هوش مصنوعی مرکب نظارت شده (SCMAI) در دشت مراغه- بناب برآورد شود.

## ۲- مواد و روش‌ها

دشت مراغه- بناب در جنوب استان آذربایجان شرقی جای دارد (شکل ۱). مهم‌ترین شهرهای آن مراغه و بناب است. شهرستان مراغه در فاصله حدود ۷۰ کیلومتری جنوب تبریز قرار دارد. گستردگی کل محدوده بیش از ۱۰۰۰ کیلومتر مربع است که حدود ۳۰۰ کیلومتر آن را دشت و پهنه‌های آبرفتی تشکیل می‌دهد و از دید تقسیم‌بندی حوضه‌های آبریز کشوری، این محدوده در حوضه آبریز دریاچه ارومیه جای گرفته است. این منطقه از شمال به ارتفاعات سهند، از باختر به دریاچه ارومیه، از شمال باختری به محدوده عجب‌شیر و از خاور و جنوب به محدوده دشت ملکان می‌رسد. میانگین بارندگی سالانه در منطقه مطالعاتی مراغه- بناب در ایستگاه سینوپتیک مراغه در حدود ۳۳۰ میلی‌متر در سال برای یک دوره ۵۰ ساله (۱۳۳۹ تا ۱۳۸۸) گزارش شده است. صوفی‌چای مهم‌ترین رودخانه جاری در منطقه مورد مطالعه است که منبع اصلی تأمین آب آن از دامنه‌های جنوبی سهند سرچشمه می‌گیرد. این رودخانه در سوی جنوب باختری جریان می‌یابد و پس از عبور از روستاهای مسیر خود وارد شهر مراغه می‌شود و در سوی باختر تغییر مسیر می‌دهد و وارد دریاچه ارومیه می‌شود (فیجانی، ۱۳۹۲). پهنه اصلی دشت که با شیب ملایم گسترش دارد؛ بیشتر تحت پوشش زمین‌های کشاورزی است. در حاشیه دریاچه ارومیه رسوبات دانه‌ریز و پهنه‌های نمکی،

## ۲-۱. تجزیه و تحلیل داده‌ها

تلفات درجه دوم بدون هیچ قانونی استفاده می‌کند که سبب برآورد ضعیف‌تری می‌شود. از این رو به منظور جلوگیری از این، LS-SVM وزن‌دار برگرفته می‌شود و در مواردی که وزن‌های کوچک به داده‌ها اختصاص داده شود؛ روش آموزشی دو مرحله‌ای ارائه می‌شود. این مدل به دلیل استفاده از معادلات خطی در حل مسائل، دقت محاسباتی بالاتری نسبت به ماشین بردار پشتیبان کلاسیک دارد (ندیری و همکاران، ۱۳۹۵ ب). یک مجموعه آموزشی از  $N$  داده  $\{x_i, y_i\}_{i=1}^N$  در نظر گرفته می‌شود که  $x_i \in R^d$ ،  $y_i \in R$  داده ورودی و  $R$  داده خروجی است. فرمول‌بندی ریاضیاتی مدل‌های رگرسیون LS-SVM در کارهای (Nadiri et al. (2017a) ارائه شده است.  $\sigma$  (متغیر تابع کرنل) و  $\gamma$  (متغیر تنظیم‌کننده خطا) دو متغیر اصلی در مدل ماشین بردار پشتیبان هستند که میزان خطا و دقت برآورد به میزان زیادی به مقادیر این دو متغیر بستگی دارد. در مدل‌سازی با کمینه مربعات ماشین بردار پشتیبان، انتخاب مقادیر مناسب دو متغیر  $\gamma$  و  $\sigma$  اهمیت بسیار زیادی دارد. مقادیر این دو متغیر هم می‌تواند با روش آزمون و خطا یا با بهینه‌سازی تعیین شود. در این مطالعه از روش دوم برای تعیین مقادیر بهینه بهره گرفته شد. افزون بر این دو متغیر، انواع توابع کرنل می‌تواند با توجه به نوع مطالعات مورد استفاده قرار گیرند. انواع مختلفی تابع کرنل مانند خطی، سیگموئیدی، پایه شعاعی (RBF) و چند جمله‌ای وجود دارد که در این مطالعه از تابع نوع RBF استفاده شده است.

**– مدل موجکی – عصبی (Wavelet-ANN):** واژه Wavelet از دو جزو Wave به معنی موج و Let به معنی کوچک و گذرا بودن تشکیل یافته و مفهوم آن موجک گذرا یا موج کوچک است. واژه مادر به این مسئله اشاره می‌کند که توابع ساخته شده با طول متفاوت برای پیمایش سیگنال و محاسبه ضرایب موجک، از تابع اصلی یا موجک مادر منشعب شده‌اند. به‌طور کلی روش موجکی – عصبی در شبیه‌سازی و پیش‌بینی سیگنال‌ها به کار می‌رود. بدین صورت که ابتدا با استفاده از تجزیه موجکی، سیگنال به چند زیرسری تبدیل می‌شود که یکی از آنها برآورد یا زمینه سری اصلی است و بقیه زیرسری‌ها نیز جزئیات هستند. سپس با در نظر گرفتن این زیرسری‌ها به عنوان ورودی شبکه عصبی، به پیش‌بینی و تحلیل سیگنال‌ها پرداخته می‌شود. در این مطالعه داده‌ها بر پایه آزمون و خطا و همچنین با توجه به تعدادشان به دو سطح تجزیه شدند. بر این اساس، هر یک از سیگنال‌های ورودی با استفاده از انتقال موجک ناپیوسته، به دو زیرسیگنال تجزیه شد. این روش به‌ویژه در سیگنال‌هایی که دارای تناوب هستند؛ نتایج شبکه عصبی مصنوعی را بهبود می‌بخشد (اعلمی و همکاران، ۱۳۹۲). توابع موجکی توابعی هستند که دو ویژگی مهم دارند: نوسانی بودن و کوتاه‌مدت بودن. در تحلیل سیگنال از فرم دیگری از انتقال موجک با نام انتقال موجک غیر پیوسته نیز استفاده می‌شود. در این نوع انتقال موجک متغیرهای انتقال و مقیاس به‌طور غیر پیوسته انتخاب می‌شوند. با توجه به رابطه مشخص‌کننده یک تابع موجک، می‌توان دریافت که توابع بسیاری وجود دارند که دارای این ویژگی باشند (کماسی، ۱۳۸۶). در چند سال گذشته، پژوهشگران بسیاری در زمینه توابع موجک، کاوش‌های بسیاری انجام داده‌اند و قابلیت‌های هر یک از این توابع نشان داده شده است؛ مانند، تابع موجک دابچیز، تابع موجک گوسین، تابع موجک هار، تابع موجک مورلت و غیره. در این مطالعه از تابع موجک db4 برای تحلیل سیگنال‌ها استفاده شد. انواع مختلف این توابع در جعبه ابزار نرم‌افزار MATLAB نیز شرح داده شده است. روابط ریاضیاتی مربوط به مدل شبکه‌های موجکی – عصبی به‌طور مفصل در کارهای پژوهشی (Nourani et al. (2014) توضیح داده شده است.

**– منطق فازی (FL):** اساس تئوری فازی برای اولین بار توسط Zadeh (1965) معرفی شد که در سال‌های اخیر توانایی بالایی در کاهش خطای برآوردی نسبت به روش احتمالاتی نشان داده است. روش فازی روشی مناسب برای کاهش خطای برآوردی و انسانی نسبت به تئوری‌های دیگر ارائه کرده است (Nadiri, 2015). داده‌های آب‌زمین‌شناختی عموماً دارای خطای برآوردی ذاتی هستند و داده‌های صحیح بدون خطا به شمار نمی‌آیند. برای نمونه به دست آوردن هدایت هیدرولیکی و قابلیت انتقال از راه آزمون پمپاژ خطایی غیر قابل چشم‌پوشی دارد. بنابراین روش

داده‌های ورودی برای هر یک از مدل‌های هوش مصنوعی در دشت مراغه – بناب، داده‌های ژئوفیزیکی و هیدروژئولوژی شامل مقاومت ویژه عرضی ( $R_v$ )، هدایت الکتریکی (EC)، ستبرای اشباع (B) و مختصات جغرافیایی شامل  $UTM(X)$  و  $UTM(Y)$  نقاط برداشت هدایت هیدرولیکی و تنها خروجی مدل نیز هدایت هیدرولیکی است. این داده‌ها از شرکت سهامی آب منطقه‌ای استان آذربایجان شرقی تهیه و مورد تجزیه و تحلیل قرار گرفتند. در دشت مراغه – بناب ۸۰ هدایت هیدرولیکی از راه آزمون پمپاژ با دبی ثابت و متغیر اندازه‌گیری شده است که موقعیت نقاط اندازه‌گیری در شکل ۴ نشان داده شده است. مقدار بیشینه هدایت هیدرولیکی برابر با  $39/26$  متر بر روز و مقدار کمینه آن برابر  $0/27$  متر بر روز برآورد شده است. برای برآورد هدایت هیدرولیکی در مدل‌های هوش مصنوعی ۸۰ درصد داده‌ها برای مراحل آموزش و باقی داده‌ها برای مرحله آزمایش اختصاص داده شدند که روش انتخاب داده‌ها برای هر دسته داده به‌صورت تصادفی بود؛ به‌طوری که ویژگی‌های آماری این دو دسته یکسان باشد. با توجه به اینکه هدایت هیدرولیکی در سفره‌های آزاد با مقادیر ستبرای اشباع سفره، مقاومت ویژه عرضی و هدایت الکتریکی رابطه دارد؛ لازم است این متغیرها در محدوده مطالعاتی تعیین شود. با تلفیق داده‌های نتایج چاه‌پیمایی و مطالعات ژئوفیزیک مشخص شد که ستبرای اشباع آبخوان بیشینه تا کمی بیش از ۴۰ متر می‌رسد. همچنین بر پایه مطالعات ژئوفیزیک انجام گرفته در این دشت، داده‌های مقاومت ویژه عرضی و نقشه هم‌ستبرای رسوبات رسم شد (شکل‌های ۲ و ۳). مقاومت الکتریکی ظاهری دارای دو مؤلفه اصلی مقاومت طولی (RL) و مقاومت عرضی (RT) است که به ترتیب تغییرات متغیرهای آب‌زمین‌شناختی جانبی و ژرفی را نشان می‌دهند. بنابراین می‌توان مقاومت الکتریکی عرضی را با مقادیر هدایت هیدرولیکی مرتبط دانست. با توجه به اینکه مقادیر هدایت الکتریکی ممکن است تحت تأثیر فعالیت‌های کشاورزی و صنعتی در منطقه قرار گیرد؛ به همین دلیل سعی شد از آخرین اطلاعات در دسترس استفاده شود تا مقادیر برآورد شده به واقعیت نزدیک‌تر باشد. بر این اساس، مقادیر هدایت الکتریکی (EC) مورد استفاده در این پژوهش از نتایج آزمایشات هیدروشیمی حاصل از اندازه‌گیری ۳۷ نمونه در سال ۱۳۹۰ به دست آمد.

## ۲-۲. روش‌های هوش مصنوعی

**– ماشین بردار پشتیبان:** ماشین بردار پشتیبان یک سامانه یادگیری کارآمد است که از اصل استقرایی کمینه‌سازی خطای ساختاری بهره می‌جوید و سبب یک جواب بهینه کلی می‌شود (قره‌خانی و همکاران، ۱۳۹۴). مهم‌ترین کاربرد ماشین بردار پشتیبان در رده‌بندی و خطی‌سازی داده‌هاست. بر خلاف الگوریتم‌های کلاسیک و رگرسیون‌های خطی که به وسیله کمینه کردن قدر مطلق خطا یا توان دوم خطا رفتار می‌کنند، ماشین بردار پشتیبان ریسک عملیاتی را کمینه می‌کنند. SVM ریسک عدم رده‌بندی صحیح را به‌صورت یک سری عددی بیان و سپس مقدار کمینه این را حساب می‌کند؛ بر خلاف شبکه عصبی مصنوعی پرسپترون چندلایه که هر موقع خطای تقسیم‌بندی (تفکیک) کم باشد آن را به عنوان یک راه‌حل ارائه می‌دهد. همچنین ماشین بردار پشتیبان برخلاف شبکه‌های عصبی با مشکل گیر افتادن در کمینه‌های محلی تابع خطا روبه‌رو نمی‌شود (Huang et al., 2010). 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 عبارتند 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. کمینه مربعات ماشین بردار پشتیبان (LS-SVM) یک مدل SVM اصلاح شده است که توسط (Suykens et al. (2002) ارائه شده و یک روش یادگیری ماشین قابل اجرا برای رده‌بندی و رگرسیون است (Nadiri et al. 2017a and b). روش LS-SVM به جای مسئله درجه دوم SVM از معادلات KKT (Karush–Kuhn–Tucker) خطی استفاده می‌کند. SVM از یک تابع

بر این اساس، داده‌ها به ۸ دسته تقسیم و ۸ قانون اگر-آنگاه تعیین شد. شکل ۷ نمونه‌ای از توابع عضویت متغیرهای ورودی را نشان می‌دهد. توابع عضویت استفاده شده برای مدل‌سازی فازی مقادیر هدایت هیدرولیکی، تابع گوسی است که به داده‌های دسته‌بندی شده برازش داده شد. تابع عضویت خروجی مدل ساگنو تابعی خطی است که بر پایه ورودی‌ها ساخته می‌شود. برای نمونه در این مطالعه خروجی اولین تابع عضویت از پنج ورودی ایجاد می‌شود.

$$output MFL = c_1 \times utmx + c_2 \times utmy + c_3 \times R_1 + c_4 \times b + c_5 \times EC + c_6 \quad (4)$$

در رابطه بالا متغیرهای  $c_1, c_2, c_3, c_4, c_5, c_6$  ضرایب ورودی‌های  $EC, R_1, b$  در UTM X, UTM Y هستند.  $c_6$  نیز متغیر ثابت معادله است. این متغیرها با برآورد کمینه مربعات به دست می‌آیند. بر این اساس هر تابع عضویت خروجی ۶ متغیر خواهد داشت. در مدل ممدانی از روش دسته‌بندی FCM استفاده شد. بر پایه این روش، تعداد دسته‌ها توسط کاربر به صورت دستی و با روش آزمون و خطا تعیین شد. تعداد بهینه دسته‌ها در کمترین مقدار RMSE که برای مراحل آموزش و آزمایش به ترتیب برابر ۴/۰۸ و ۴/۱۴ متر بر روز هستند، ۲۶ دسته تعیین شد (شکل ۸). در این روش تابع عضویت ورودی و خروجی تابع گوسی بود. مقادیر ضریب تعیین نیز برای مدل ممدانی در مرحله آموزش برابر ۰/۷۵ و در مرحله آزمایش برابر ۰/۷۲ به دست آمد. بر پایه نتایج به دست آمده از اجرای مدل‌های فازی، مدل ساگنو نتایج به نسبت بهتری در مقایسه با مدل ممدانی نشان داد (جدول ۱). بنابراین به دلیل اینکه هر یک از مدل‌ها برتری‌های خاص خود را دارند؛ برای استفاده از برتری‌های هر دو آنها در یک زمان از مدل مرکب نظارت شده استفاده شد. کارآیی مدل موجکی-عصبی نیز به متغیرهایی مانند سطح تجزیه، نوع تابع موجکی و تعداد نودهای میانی بستگی دارد. برای تعیین نوع تابع موجکی برای تجزیه سیگنال‌های ورودی، از روش آزمون و خطا استفاده شد و دیده شد که تابع موجکی db4 به عنوان موجک مادر دقت بیشتری نسبت به توابع دیگر مانند sym و gaussian دارد. در مرحله بعد، داده‌های تجزیه شده وارد شبکه عصبی پیشخور پرسپترون چندلایه شدند. برای انتخاب تعداد نودهای میانی نیز از روش آزمون و خطا استفاده شد و بر این اساس، وقتی تعداد نرون‌های میانی ۳ در نظر گرفته شد، بهترین نتایج در این حالت به دست آمد.

هنگامی که زیرسری‌ها به عنوان ورودی به شبکه عصبی وارد می‌شوند؛ شبکه عصبی به هر یک از زیرسری‌های تجزیه‌ای وزن خاصی می‌دهد. برای نمونه در سطح تجزیه ۲، شبکه عصبی وزن بالاتر را به d2 اختصاص می‌دهد. چرا که d2 نسبت به زیرسیگنال‌های دیگر بیشترین وابستگی را به سیگنال اصلی هدایت هیدرولیکی و نقش معناداری در برآورد هدایت هیدرولیکی دارد. در اجرای مدل ماشین بردار پشتیبان، ابتدا نوع ماشین بردار پشتیبان تعیین (LS-SVM) و سپس مقادیر متغیر تنظیم کننده ( $\gamma$ ) و متغیر کرنل یا هسته ( $\sigma$ ) مشخص شد. مقدار این دو متغیر از راه بهینه‌سازی تعیین شد و از میان انواع توابع کرنل (Kernel) مانند تابع پایه شعاعی (RBF)، چندجمله‌ای (Poly)، خطی (Lin)، پرسپترون چندلایه (MLP) و سینک (Sinc) در این مطالعه کرنل نوع RBF انتخاب شد. مقادیر متغیرهای  $\sigma$  و  $\gamma$  به ترتیب ۲/۵۴ و ۲/۸۸ است. پس از اجرای مدل‌ها، کارآیی هر یک از آنها با استفاده از معیارهای ارزیابی، بررسی و در جدول ۱ ارائه شد.

به منظور مقایسه بصری مقادیر مشاهداتی و محاسباتی برای داده‌های دست، منحنی آن برای مدل‌های SCMAI، LS-SVM، Wavelet-ANN، فازی ساگنو و فازی ممدانی در شکل ۹ آورده شد. همان‌گونه که از این شکل پیداست؛ پس از اجرای مدل SCMAI میزان نزدیکی مقادیر مشاهداتی و محاسباتی هدایت هیدرولیکی افزایش و در نتیجه میزان خطای اندازه‌گیری کاهش پیدا می‌کند. این نتیجه مهم به ماهیت و کارکرد این مدل بستگی دارد که می‌تواند مقادیر محاسباتی حاصل از مدل‌های منفرد را به میزان قابل توجهی بهینه کند.

در نتیجه می‌توان در مطالعات مربوط به برآورد متغیرهای آب‌زمین‌شناختی، به جای استفاده از یک روش، چندین روش را به صورت همزمان استفاده کرد و از ترکیب آنها نتایج بهتری به دست آورد. با توجه به جدول ۴ و شکل ۹، در میان مدل‌های

مدل‌های فازی می‌تواند به عنوان روشی کارادر کاهش خطا و برآورد دقیق متغیرهای آب‌زمین‌شناختی به شمار رود (ندیری و همکاران، ۱۳۹۳). فرایندهای کلی مدل‌سازی توسط سامانه‌های فازی شامل سه بخش اصلی است: ۱) فازی کردن داده‌ها. این کار با تعریف تابع عضویت انجام می‌شود؛ ۲) ایجاد ارتباط میان داده‌های ورودی و داده‌های خروجی. این کار با ایجاد یک سری قوانین فازی مانند قانون «اگر-آنگاه» ایجا می‌شود؛ ۳) تجمیع نتایج سامانه و نافازی‌سازی. این کار به وسیله عملگرهای فازی انجام می‌گیرد که شامل and و or و not هستند. عملگر AND به دو صورت کمینه‌سازی (min) و وزن‌دهی (prod) و عملگر or نیز به صورت بیشینه‌سازی رفتار می‌کنند. مدل فازی به روش‌های مختلفی قابل اجرا است؛ که از آن جمله می‌توان به روش‌های (MFL) (Mamadani and Assilian (1975) و (Sugeno (1985) اشاره کرد. تفاوت مدل فازی ساگنو و ممدانی در توابع خروجی آنهاست؛ به این معنی که تابع عضویت خروجی سامانه فازی ساگنو به صورت رابطه خطی است که توسط روش دسته‌بندی به دست می‌آید. تابع عضویت خروجی ممدانی نیز باتوجه به نوع و ماهیت داده‌ها و مطالعه، می‌تواند متفاوت باشد؛ مانند تابع عضویت گوسین. اولین مرحله در ایجاد یک مدل فازی، دسته‌بندی داده‌هاست که بستگی به نوع مدل فازی مورد استفاده دارد و می‌توان از روش‌های دسته‌بندی مختلف استفاده کرد که از آن جمله می‌توان به روش subtractive برای مدل ساگنو و روش fuzzy C-means برای مدل ممدانی اشاره کرد (ندیری و همکاران، ۱۳۹۳). متغیر اصلی در روش دسته‌بندی کاهشی برای تعیین دسته‌ها و قوانین اگر-آنگاه، شعاع دسته‌بندی است. مقادیر این متغیر میان ۰ و ۱ متغیر است. کاهش این متغیر سبب افزایش دسته‌ها و قوانین و افزایش آن سبب کاهش دسته‌ها و قوانین می‌شود (Nadiri et al., 2015).

**– مدل هوش مصنوعی مرکب نظارت شده (SCMAI):** برای اجرای این مدل از روش‌های ماشین بردار پشتیبان کمینه مربعات (LS-SVM)، هیبرید موجکی عصبی (Wavelet-ANN) و سامانه استنتاج فازی شامل فازی ممدانی (MFL) و فازی ساگنو (SFL) استفاده شد. به این صورت که هر یک از این مدل‌ها ابتدا به صورت انفرادی اجرا و خروجی آنها با استفاده از شبکه عصبی مصنوعی بهینه شد. برای اجرای هر یک از این مدل‌ها از مقاومت ویژه عرضی، هدایت الکتریکی و ستبری اشباع آبخوان، که عوامل مؤثر در مقدار هدایت هیدرولیکی به شمار می‌روند و موقعیت نقاط برداشت هدایت هیدرولیکی به عنوان ورودی مدل‌ها استفاده شد. در این مطالعه مدل هوش مصنوعی مرکب نظارت شده ارائه شده است که از یک شبکه مصنوعی به عنوان ترکیب کننده غیر خطی به جای روش‌های میانگین‌گیری ساده و میانگین‌گیری وزنی استفاده می‌کند. از دید ریاضیاتی، این مدل را می‌توان به صورت روابط ۱ تا ۳ نشان داد:

$$\hat{K}_1 = AI_i (UTMX, UTM Y, R_1, B, EC) \quad (1)$$

$$O_j = f_1(b_j + \sum_i W_{ji} \hat{K}_i) \quad (2)$$

$$O_k = \hat{K}_{SCMAI} = f_2(b_k + \sum_j W_{kj} O_j) \quad (3)$$

در معادلات بالا  $\hat{K}_1$  خروجی مدل‌های هوش مصنوعی است که به عنوان تأمین ورودی برای شبکه عصبی مصنوعی به شمار می‌رود و  $f_1$  و  $f_2$  به ترتیب توابع فعال‌سازی برای لایه مخفی و لایه خروجی هستند.  $O_j$  خروجی  $j$ ام گره در لایه میانی است.  $W_{ji}, W_{kj}, b_j, b_k$  وزن‌ها و بایاس‌های لایه مخفی و لایه خروجی هستند.  $O_k$  خروجی پایانی مدل هوش مصنوعی مرکب است. وزن‌ها و بایاس‌ها با الگوریتم آموزشی LM بهینه می‌شوند. شکل ۵ چهارچوب کلی مدل SCMAI را نشان می‌دهد.

### ۳- بحث

همان‌گونه که پیش‌تر اشاره شد؛ بازده مدل فازی ساگنو بستگی به شعاع دسته‌بندی دارد که مقدار بهینه آن در این مطالعه بر پایه کمترین مقدار RMSE و با استفاده از روش آزمون و خطا، ۰/۴ تعیین شد (شکل ۶).

ساگنو، ماشین بردار پشتیبان و شبکه موجکی- عصبی وارد شبکه عصبی مصنوعی می‌شوند و دوباره هدایت هیدرولیکی جدیدی توسط شبکه عصبی مصنوعی برآورد می‌شود. نتایج کلی زیر از این مطالعه حاصل می‌شود:

- با توجه به مقادیر معیارهای ارزیابی ( $R^2, RMSE, MAE, I_{VP}$ ) می‌توان نتیجه گرفت که مدل ماشین بردار پشتیبان دقت بیشتری نسبت به روش‌های منفرد دیگر دارد که این مسئله می‌تواند ناشی از توانایی‌های ماشین بردار پشتیبان مانند خوشه‌بندی و استفاده از توابع کرنل باشد. مقدار RMSE مربوط به مدل LS-SVM برابر با  $1/0.8$  دست آمد. اما با مقایسه آن با مدل ترکیبی، دیده می‌شود که در نقاطی که مدل ماشین بردار پشتیبان عملکرد ضعیفی نشان داده است؛ مدل ترکیبی در این نقاط برآورد بهتری از هدایت هیدرولیکی ارائه می‌دهد. برای نمونه در نقاط ۲، ۳، ۵، ۸ و ۱۴ مدل ترکیبی نسبت به مدل ماشین بردار پشتیبان عملکرد بهتری نشان می‌دهد. بنابراین می‌توان نتیجه گرفت که مدل ترکیبی SCMAI با داشتن  $RMSE=0.045$  نسبت به مدل ماشین بردار پشتیبان دقت بالاتری نشان می‌دهد. بررسی تغییرات  $R^2$  برای مدل SCMAI در مراحل آموزش و آزمایش به ترتیب از مقدار  $0.999$  به  $0.97$  نشان می‌دهد که این مدل نسبت به مدل‌های دیگر قابلیت آموزش بالاتری دارد.

- همانطور که در شکل ۹ نشان داده شد؛ با وجود اینکه مدل LS-SVM نتایج بهتری نشان می‌دهد؛ مدل SCMAI به سبب استفاده از مزایای همه مدل‌ها این امکان را فراهم می‌کند که با ترکیب نتایج مدل‌های منفرد، میزان مقادیر مشاهداتی و محاسباتی هر چه بیشتر به همدیگر نزدیک شود. به عبارتی دیگر، میزان خطا را کاهش و همبستگی میان داده‌های مشاهداتی و محاسباتی را افزایش می‌دهد. بنابراین می‌تواند برای برآورد مقادیر هدایت هیدرولیکی، نسبت به دیگر مدل‌هایی که به صورت انفرادی برای برآورد هدایت هیدرولیکی به کار رفته‌اند؛ مفید تر واقع شود.

- این مطالعه نشان داد که مدل‌های MFL و Wavelet-ANNs به ترتیب با داشتن  $RMSE=4.81$  و  $RMSE=2.85$  در مرحله آزمایش، نتایج ضعیف‌تری در برآورد هدایت هیدرولیکی در دشت مراغه بناب نشان دادند.

- به دلیل اینکه در طبیعت، آبخوان‌ها هتروژنیته و پیچیدگی زیادی دارند؛ این مطالعه نشان داد که مدل SCMAI با داشتن توانایی استفاده از قابلیت‌ها و ترکیب نتایج مدل‌های مختلف؛ می‌تواند برای برآورد دیگر متغیرهای آب‌زمین‌شناختی مانند قابلیت انتقال، تخلخل، درصد رطوبت و غیره در آبخوان‌های ناهمگن و آزاد به کار گرفته شود.

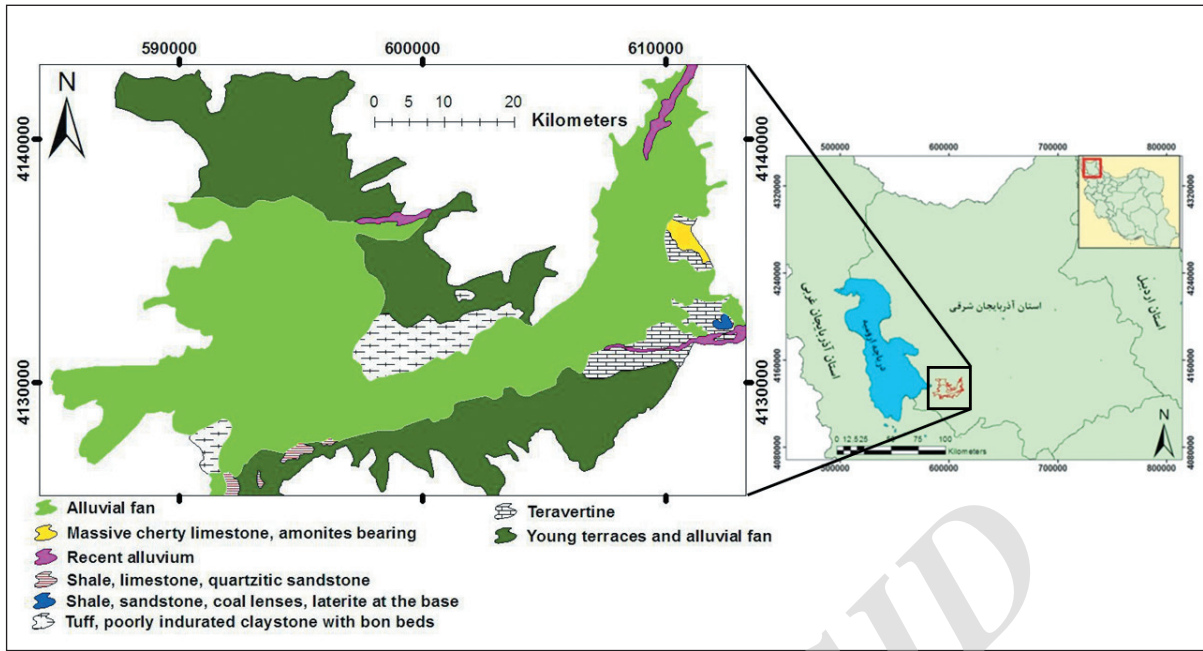
#### سیاسگزاری

این پژوهش با حمایت مالی مرکز مطالعات و همکاری‌های علمی بین‌المللی (CISSC) در قالب طرح ICARD به شماره قرارداد ۱۴۷۹ انجام شده است. نگارندگان مراتب سپاس خود را از این مرکز اعلام می‌دارند.

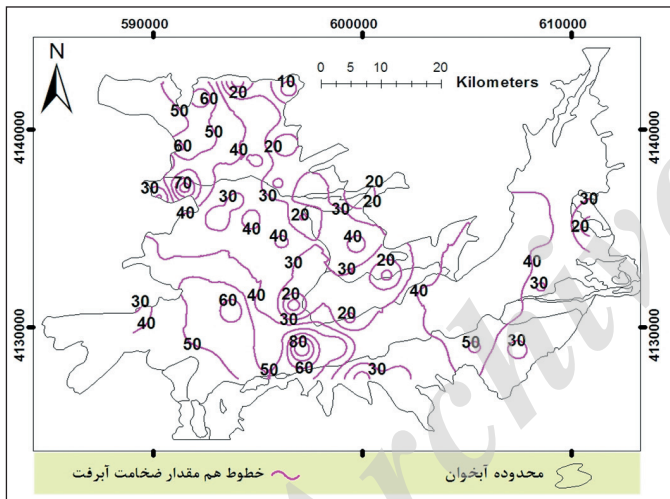
منفرد، مدل LS-SVM با داشتن مقدار  $RMSE=1.08$  در مرحله آزمایش، برآورد بهتری از هدایت هیدرولیکی نسبت به مدل‌های دیگر نشان می‌دهد. اما در مقایسه با مدل SCMAI که در آن مقدار  $RMSE=0.045$  است؛ خطای بیشتری دارد. به منظور مشاهده توزیع مقادیر هدایت هیدرولیکی در محدوده آبخوان دشت مراغه- بناب، نقشه توزیع هدایت هیدرولیکی تهیه و در شکل ۱۰ آورده شد. با توجه به عدم قطعیت در مقادیر متغیر هدایت هیدرولیکی، برای رسم نقشه هم‌ارزش هدایت هیدرولیکی (شکل ۱۰) از روش درون‌یابی کریجینگ در محیط نرم‌افزار ArcGIS استفاده شد. همان‌گونه که انتظار می‌رفت، بیشترین مقدار هدایت هیدرولیکی در مراکز دشت و در پادگان‌های آبرفتی است. این نتیجه نشان‌دهنده انطباق منطقی محاسبات حاصل از مدل‌سازی مدل SCMAI با واقعیت‌های موجود در منطقه است. (Nadiri et al. (2013) با استفاده از مدل SCMAI میزان تجمع فلوراید آب زیرزمینی را در دشت ماکو پیش‌بینی کردند. آنها برای این کار از مدل‌های هوش مصنوعی SFL، MFL، NF و ANN استفاده کردند و از ANN به عنوان ترکیب کننده غیرخطی بهره گرفتند. نتایج کار این پژوهشگران نشان داد که در میان مدل‌های منفرد، مدل MFL نسبت به مدل‌های دیگر دقت پایین‌تری دارد و در برابر آن، مدل ANN کارایی دارای بالاتری است. این نتایج به وسیله مدل SCMAI بهینه شد و نتایج بهتری نسبت به تک‌تک مدل‌ها به دست آمد. در مطالعه پیش رو نیز مدل MFL نسبت به مدل‌های منفرد دیگر دقت پایینی دارد. تفاوت این مطالعه با مطالعه پیشین در این است که در اینجا افزون بر مدل‌های MFL و SFL از مدل‌های Wavelet-ANN و LS-SVM به عنوان جدیدترین روش در برآورد هدایت هیدرولیکی استفاده و مدل ANN به عنوان ترکیب کننده غیرخطی به کار گرفته شد. در پایان مقادیر برآورد شده به وسیله این مدل‌ها توسط مدل SCMAI بهینه شد و نتایج به نسبت بهتری به دست آمد. در یک مطالعه دیگر توسط Tayfur et al. (2014)، مدل SICM برای برآورد هدایت هیدرولیکی در دشت تسوج اجرا شد. در این مطالعه نیز از مدل‌های SFL، MFL، NF و ANN استفاده و از ANN به عنوان ترکیب کننده غیرخطی بهره گرفته شد. مقایسه این مطالعه با مقاله پیش رو نشان داد که مدل LS-SVM نسبت به مدل‌های NF و ANN مورد استفاده در مقاله Tayfur et al. (2014)، کارایی بالاتری دارد. افزون بر این، مقایسه نتایج مراحل آزمایش مدل‌ها نشان می‌دهد که مدل ترکیبی SCMAI نسبت به مدل SICM نیز نتایج بهتری ارائه می‌کند.

#### ۴- نتیجه‌گیری

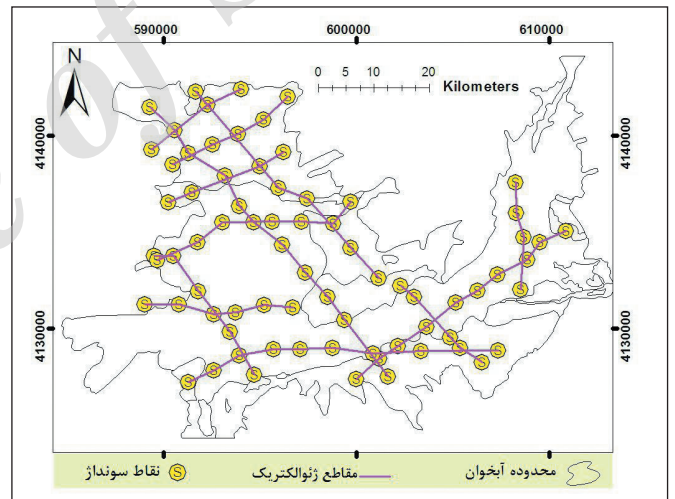
در این پژوهش، از مدل هوش مصنوعی مرکب نظارت شده (SCMAI) استفاده شد که خروجی مدل‌های هوش مصنوعی را برای برآورد هدایت هیدرولیکی در دشت مراغه- بناب ترکیب می‌کند. در این مدل، خروجی مدل‌های فازی ممدانی، فازی



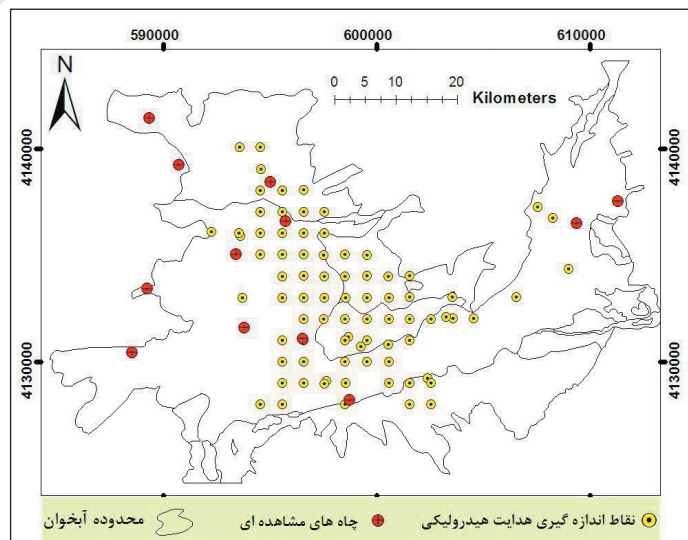
شکل ۱- موقعیت جغرافیایی محدوده آبخوان دشت مراغه- بناب و نقشه سنگ‌شناسی محدوده آبخوان دشت مراغه- بناب.




شکل ۳- نقشه هم‌ستبرای رسوبات آبرفتی.




شکل ۲- نقشه مقاطع ژئوالکتریکی (تغییر یافته از مهندسین مشاور یکم، ۱۳۹۲).



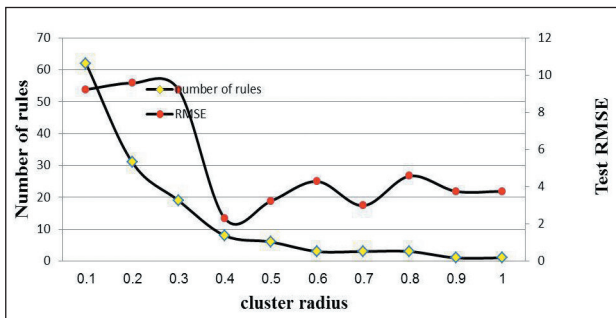
شکل ۴- موقعیت چاه‌های مشاهده‌ای و نقاط اندازه‌گیری هدایت هیدرولیکی.



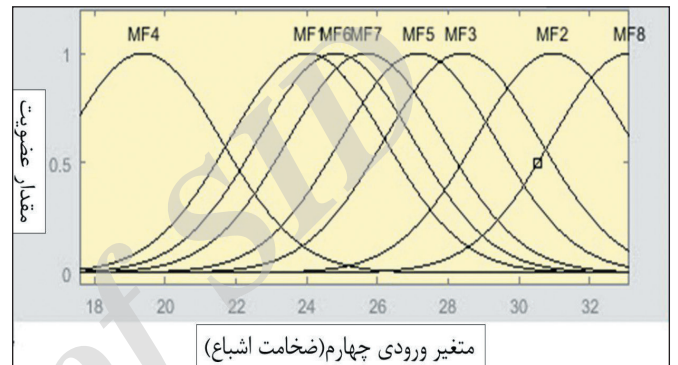
شکل ۶- تغییرات تعداد قانون‌ها و RMSE در برابر تغییر مقدار شعاع دسته‌بندی برای تعیین بهترین شعاع دسته‌بندی.



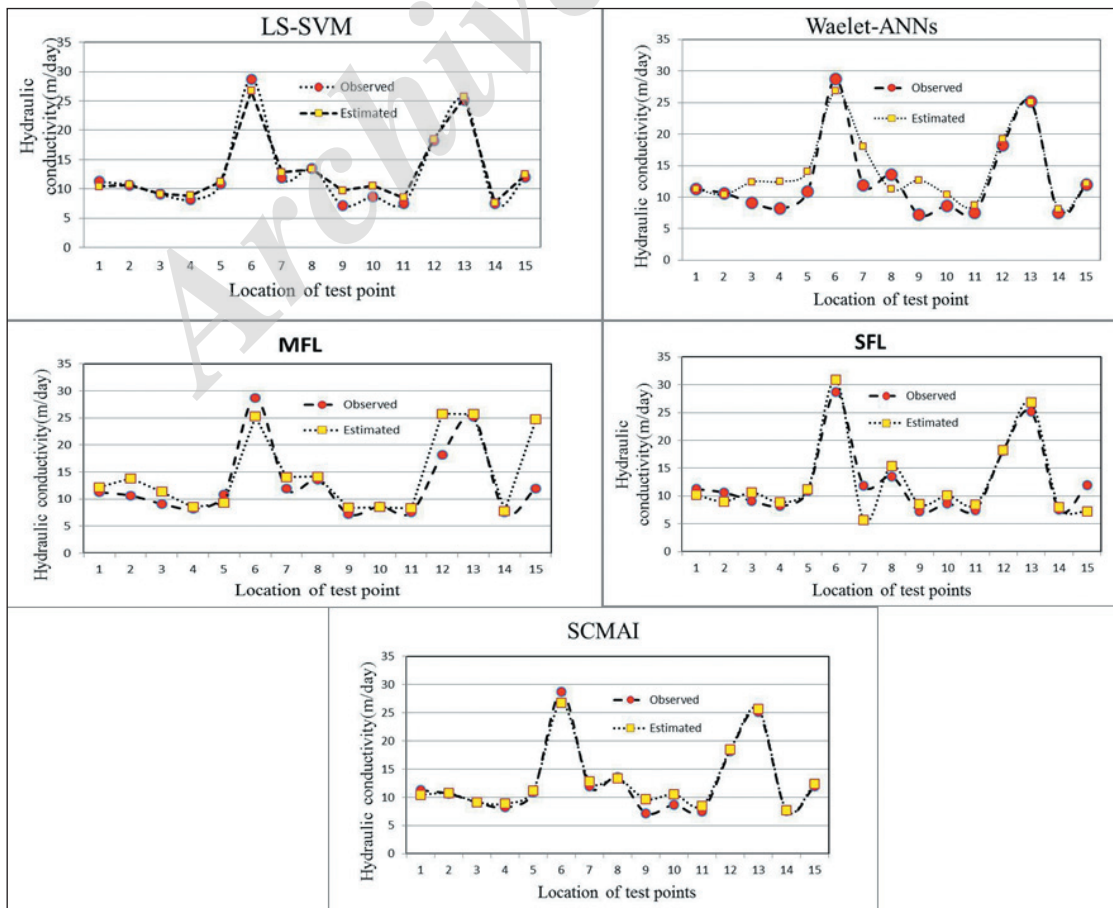
شکل ۵- ساختار کلی مدل SCMAI به کار رفته.



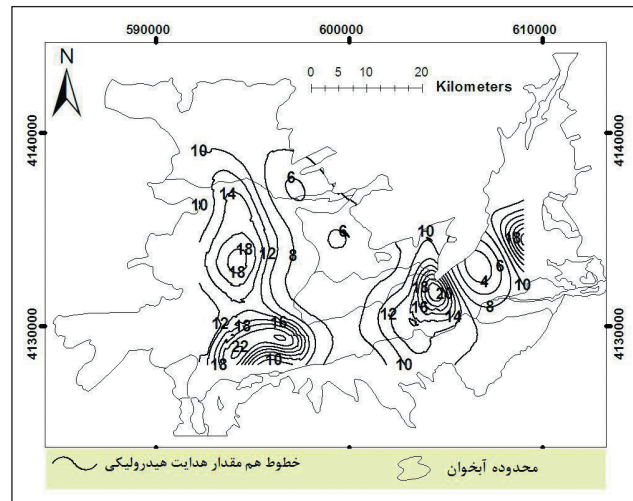
شکل ۸- تغییرات تعداد قانون‌ها و RMSE در برابر تغییر تعداد دسته‌ها برای تعیین تعداد بهینه دسته‌ها.



شکل ۷- نمونه ای توابع عضویت متغیر ورودی B (ستبرای اشباع).



شکل ۹- منحنی مقادیر مشاهداتی و محاسباتی هدایت هیدرولیکی برای انواع مدل‌ها.



شکل ۱۰- نقشه توزیع مقادیر هدایت هیدرولیکی حاصل از مدل SCMAI.

جدول ۱- نتایج مدل‌های هوش مصنوعی.

	SFL		MFL		LS-SVM		Wavelet-ANN		SCMAI	
	آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش
$R^2$	0.99	<u>0.93</u>	0.75	<u>0.72</u>	0.99	<u>0.96</u>	0.93	<u>0.79</u>	0.999	<u>0.979</u>
RMSE	0.23	<u>2.3</u>	3.77	<u>4.81</u>	0.79	<u>1.08</u>	1.59	<u>2.85</u>	0.004	<u>0.045</u>
MAE	0.02	0.6	0.46	1.24	0.003	0.28	0.19	0.73	0.003	0.28
$I_{VF}$	1	0.99	1.11	1.13	1	1.03	0.95	1.11	1	1.02

## کتابنگاری

- اصغری مقدم، ا.، ندیری، ع.، فیجانی، ا.، ۱۳۸۷- پیش‌بینی مکانی هدایت هیدرولیکی در محدوده متروی شهر تبریز، کنفرانس مشترک سازمان زمین‌شناسی و انجمن زمین‌شناسی ایران، ۲ ص. علمی، م.، صادق‌فام، س.، فاضلی‌فرد، م. و نقی‌پور، ل.، ۱۳۹۲- مدل‌سازی سری داده‌ها، دانشگاه تبریز، تبریز، ۲۹۹ ص..
- فیجانی، ا.، ۱۳۹۲- هیدروژئولوژی و هیدروژئوشیمی آبخوان دشت مراغه- بناب با استفاده از مدل‌سازی آب زیرزمینی، رساله دکترای هیدروژئولوژی، گروه علوم زمین دانشگاه تبریز، ۲۰۰ ص.
- قره‌خانی، م.، ندیری، ع.، اصغری مقدم، ا. و صادقی‌اقدم، ص.، ۱۳۹۴- بهینه‌سازی مدل دراستیک با استفاده از ماشین بردار پشتیبان و شبکه عصبی مصنوعی به منظور ارزیابی آسیب پذیری ذاتی آبخوان دشت اردبیل. اکوهیدروژئولوژی، ۳، صص. ۳۱۱ تا ۳۲۴.
- کماسی، م.، ۱۳۸۶- مدل‌سازی بارش- رواناب با استفاده از مدل ترکیبی موجک- شبکه عصبی مصنوعی، پایان‌نامه کارشناسی ارشد هیدروژئولوژی گروه عمران، دانشگاه تبریز، ۱۳۵ ص.
- مختاری، ز.، ناظمی، ا. و ندیری، ع.، ۱۳۹۱- پیش‌بینی تراز آب زیرزمینی با استفاده از مدل شبکه‌های عصبی مصنوعی (مطالعه موردی: دشت شبستر)، فصلنامه زمین‌شناسی کاربردی، ۴، صص. ۳۴۵ تا ۳۵۳.
- مهندسین مشاور یکم، ۱۳۹۲- گزارش مطالعات آب زیرزمینی دشت مراغه- بناب، سازمان آب منطقه ای تبریز، ۱۸۲ ص.
- ندیری، ع. و یوسف‌زاده، س.، ۱۳۹۶- مقایسه کارایی مدل‌های شبکه‌های عصبی مصنوعی، منطق فازی و سیستم استنتاج نرو- فازی تطبیقی در تخمین هدایت هیدرولیکی آبخوان دشت مراغه- بناب هیدروژئومورفولوژی، ۱۰، صص. ۲۱ تا ۴۰.
- ندیری، ع.، اصغری مقدم، ا.، عبقری، ه.، کلاتری اسکویی، ع.، حسین‌پور، ع. و حبیب‌زاده، ا.، ۱۳۹۳- مدل منطق فازی در تخمین قابلیت انتقال آبخوان، مطالعه موردی: دشت تسوج، نشریه دانش آب و خاک، ۱، ۲۴، صص. ۲۰۹ تا ۲۲۳.
- ندیری، ع.، واحدی، ف. و اصغری مقدم، ا.، ۱۳۹۵ الف- پیش‌بینی سطح آب زیرزمینی با استفاده از مدل منطق فازی مرکب نظارت شده (مطالعه موردی: دشت مشگین‌شهر). هیدروژئومورفولوژی، ۱۰(۶)، صص. ۱۱۵ تا ۱۳۴.
- ندیری، ع.، واحدی، ف.، اصغری مقدم، ا. و کدخدایی، ع.، ۱۳۹۵ ب- استفاده از مدل هوش مصنوعی مرکب نظارت شده برای پیش‌بینی سطح آب زیرزمینی. مهندسی عمران و محیط زیست، ۴۶، ۳، صص. ۸۴ تا ۱۰۴.



## References

- Alyamani, M. and Sen, Z., 1993- Determination of hydraulic conductivity from complete grain size distribution curves. *Ground Water*, 31, 551-555.
- Anifowose, F. and Abdulraheem, A., 2011- Fuzzy logic-driven and SVM-driven hybrid computational intelligence models applied to oil and gas reservoir characterization. *J Nat Gas Sci Eng*, 3(3):505–517.
- Asadi, S., Hassan, M., Nadiri, A. A. and Dylla, H., 2014- Artificial intelligence modeling to evaluate field performance of photocatalytic asphalt pavement for ambient air purification. *Environmental Science and Pollution Research*, 21 (14): 8847-8857
- Bárdossy, A. and Disse, M., 1993- Fuzzy rule-based models for infiltration. *Water Resour Res*, 29(2):373–382.
- Bouwer, H., 1989- The Bouwer and Rice slug test- An update. *Ground Water*, 27: 304-309.
- Carman, P. C., 1956- *Flow of Gases Through Porous Media*. Butterworths, London, Great Britain, 182 p.
- Chitsazan, N., Nadiri, A. A. and Tsai, F. F. C., 2015- Prediction and structural uncertainty analyses of artificial neural networks using hierarchical Bayesian model averaging, *Journal of Hydrology*, 528: 52-62.
- Chow, V. T., 1952- On the determination of transmissibility and storage coefficients from pumping test data. *Transactions, American Geophysical Union*, 33, 397-404.
- Chu, H. J. and Chang, L. C., 2009- Application of optimal control and fuzzy theory for dynamic groundwater remediation design. *Water Resour Manag*, 23(4):647–660.
- Colin, F., Guillaume, S. and Tisseyre, B., 2011- Small catchment agricultural management using decision variables defined at catchment scale and a fuzzy rule-based system: a Mediterranean vineyard case study. *Water Resour Manag* 25(11):2649–2668.
- Cooper, H. H. and Jacob, C. E., 1946- A generalized graphical method for evaluating formation constants and summarizing well field history. *Trans. Amer. Geophysical union*, 27: 526-534.
- Cooper, H. H., Bredehoeft, J. D. and Papadopoulos, I. S., 1967- Response of a finite diameter well to an instantaneous charge of water. *Water Resource Research*, 3: 263-269.
- Dhar, A. and Patil, R. S., 2012- Multiobjective design of groundwater monitoring network under epistemic uncertainty. *Water Resour Manag*, 26(7):1809–1825.
- Fair, G. M. and Hatch, L. P., 1933- Fundamental factors governing the stream line flow of water through sand. *Journal of American Water Work Association*. 25: 1551-1565.
- Garcia, L. A. and Shigidi, A., 2006- Using neural networks for parameter estimation in groundwater. *J Hydrol* 318(1–4): 215–231.
- Gaur, S., Sudheer, Ch., Graillot, D., Chahar, B. R., and Kumar, D. N., 2013- Application of artificial neural networks and particle swarm optimization for the management of groundwater resources. *Water Resour Manag* 27(3):927–941.
- Hazen, A., 1892- Some physical properties of sands and gravels. *Massachusetts state board of health 24th Annual Report*, 539-556.
- Helmy, T., Fatai, A. and Faisal, K., 2010- Hybrid computational models for the characterization of oil and gas reservoirs. *Expert Syst Appl*, 37(7):5353–5363.
- Huang, Y., Gedeon, T. D. and Wong, P. M., 2010- An integrated neural-fuzzy-genetic-algorithm using hyper-surface membership functions to predict permeability in petroleum reservoirs. *Eng Appl Artif Intell* 14(1):15–21.
- Hurtado, N., Aldana, M. and Torres, J., 2009- Comparison between neuro-fuzzy and fractal models for permeability prediction. *Comput Geosci*, 13:181–186.
- Hvorslev, M. G., 1951- Time lag and soil permeability in groundwater observations. *Bulletin No. 36, US Army Corps of Engineering, Waterways Experiments Stations, Vicksburg, Mississippi*. 49pp. Isaaks EH and Srivastava RM, 1989. *Applied Geostatistics*. Oxford University press, London. 561p.
- Inan, T. and Tayfur, G., 2012- A prediction model for the level of well water. *Sci Res Essays* 7(50):4242–4252.
- Malki, H. A. and Baldwin, J., 2002- A neuro-fuzzy based oil/gas producibility estimation method. *IEEE Int Jt Conf Neural Netw*, 1:896–901.
- Mamdani, E. H. and Assilian, S., 1975- An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7: 1-13.
- Merdun, H., Inar, O. C., Meral, R., Apan, M., 2006- Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity, *Soil Tillage Res* 90:108–116.
- Mohanty, S., Jha, M. K., Kumar, A. and Sudheer, K. P., 2010- Artificial neural network modeling for groundwater level forecasting in a River Island of Eastern India. *Water Resour Manag*, 24(9):1845–1865.
- Moosavi, V., Vafakhah, M., Shirmohammadi, B., Behnia, N., 2013- AWavelet-ANFIS hybrid model for groundwater level forecasting for different prediction periods. *Water Resour Manag* 27(5):1301–1321.
- Morankar, D. V., Raju, K. S. and Kumar, D. N., 2013- Integrated sustainable irrigation planning with multiobjective fuzzy optimization approach, *Water Resour Manag*, 27(11):3981–4004.
- Motaghian, H. R. and Mohammadi, J., 2011- Spatial estimation of saturated hydraulic conductivity from terrain attributes using regression, kriging, and artificial neural networks. *Pedosphere*, 21(2):170–177.
- Nadiri, A. A., 2015- *Application of Artificial Intelligence methods in Geosciences and Hydrology*. OMICS Publication. 124p.
- Nadiri, A. A., Fijani, E., Tsai, F. T. C. and Asghari Moghaddam, A., 2013- Supervised committee machine with artificial intelligence for prediction of fluoride concentration, *Journal of Hydroinformatics*, 15: 1474-1490.

- Nadiri, A. A., Gharekhani, M., Khatibi, R. and Moghaddam, A. A., 2017a- Assessment of groundwater vulnerability using supervised committee to combine fuzzy logic models. *Environmental Science and Pollution Research*, 24 (9): 8562-8577.
- Nadiri, A. A., Gharekhani, M., Khatibi, R., Sadeghfam, S. and Moghaddam, A. A., 2017b- Groundwater vulnerability indices conditioned by supervised intelligence committee machine (SICM). *Science of the Total Environment*, 574: 691-706.
- Nadiri, A. A., Hassan, M. M. and Asadi, S., 2015- Supervised intelligence committee machine to evaluate field performance of photocatalytic asphalt pavement for ambient air purification. *Transportation Research Record: Transportation Research Record: Journal of the Transportation Research Board*. 2528, 96-105.
- Nadiri, A. A., Sedghi, Z., Khatibi, R. and Gharekhani, M., 2017c- Mapping vulnerability of multiple aquifers using multiple models and fuzzy logic to objectively derive model structures. *Science of The Total Environment*, 593: 75-90
- Nadiri, A., Chitsazan, N., Tsai, F. and Moghaddam, A., 2014- Bayesian Artificial Intelligence Model Averaging for Hydraulic Conductivity Estimation, *J. Hydrol. Eng.*, 10.1061/(ASCE)HE.1943-5584.0000824, 520-532.
- Nayak, P. C., Rao, Y. R. S. and Sudheer, K. P., 2006- Groundwater level forecasting in a shallow aquifer using artificial neural network approach, *Water Resour Manag*, 20(1):77–90. (<http://link.springer.com/article/10.1007/s11269-006-4007-z>).
- Neuman, S. P., 1975- Analysis of pumping test data from anisotropic unconfined aquifers considering delayed gravity response, *water resources research*, 11: 329-342.
- Nourani, V., Hosseini Baghanam, A., Adamowski, J. and Kisi, O., 2014- Applications of hybrid wavelet–Artificial Intelligence models in hydrology: A review. *Journal of Hydrology*, 514: 358-377.
- Olatunji, S. O., Selamat, A. and Abdulraheem, A., 2011- Modeling the permeability of carbonate reservoir using type-2 fuzzy logic systems. *Comput Ind*, 62:147–163.
- Ross, J., Ozbek, M. and Pinder, G. F., 2007- Hydraulic conductivity estimation via fuzzy. *Math Geol* 39(8):765–780.
- Sadeghfam, S., Hassanzadeh, Y., Nadiri, A. A. and Zarghami, M., 2016- Localization of groundwater vulnerability assessment using catastrophe theory. *Water resources management*, 30(13): 4585-4601.
- Safavi, H. R., Chakraei, I., Samani, A. K., Golmohammadi, M. H., 2013- Optimal reservoir operation based on conjunctive use of surface water and groundwater using neuro-fuzzy systems. *Water Resour Manag*, 27(12):4259–4275.
- Samani, N., Gohari-Moghadam, M. and Safavi, A. A., 2007- A simple neural network model for the determination of aquifer parameters. *J Hydrol*, 340:1–11.
- Schaap, M. G. and Leij, F. J., 1998- Using neural networks to predict soil water retention and soil hydraulic conductivity, *Soil Tillage Res* 47:37–42.
- Sezer, A., Göktepe, A. B. and Altun, S., 2010- Adaptive neuro-fuzzy approach for sand permeability estimation. *EnvironEng Manag J*, 9(2):231–238.
- Shepherd, R. G., 1989- Correlations of permeability and grain size. *Ground Water*, 27, 633-638.
- Shirmohammadi, B., Vafakhah, M., Moosavi, V. and Moghaddamia, A., 2013- Application of several data-drive techniques for predicting groundwater level. *Water Resour Manag* 27(2):419–432.
- Sperry, M. S. and Peirce, J. J., 1995- A model for estimating the hydraulic conductivity of granular material based on grain shape, grain size and porosity. *Ground Water*, 33: 892-898.
- Sugeno, M., 1985- An introductory survey of fuzzy control. *Inf. Sci. (NY)*, 36: 59–83.
- Sun, J., Zhao, Z. and Zhang, Y., 2011- Determination of three dimensional hydraulic conductivities using a combined analytical/neural network model. *Tunn Undergr Space Technol* 26:310–319.
- Suykens, J. A. K., Van, G. T., Brabanter, J. D., De, M. B. and Vandewalle, J., 2002- *Least Squares Support Vector Machines*, World Scientific Publishing, Singapore.
- Tamari, S., Wosten, J. H. M. and Ruiz-Suarez, J. C., 1996- Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Sci Soc Am J* 60(6):1732–1741.
- Tayfur, G., 2012- *Soft computing in water resources engineering*. WIT Press, Southampton.
- Tayfur, G., Moramarco, T. and Singh, V. P., 2007- Predicting and forecasting flow discharge at sites receiving significant Lateral inflow. *Hydrol Process*, 21(14):1848–1859.
- Tayfur, G., Nadiri, A. A. and Asghari Moghaddam, A., 2014- Supervised Intelligent Committee Machine Method for Hydraulic Conductivity Estimation. *Water Resour Manage*, 28:1173–1184.
- Theis, C. V., 1935- the relation between lowering of the piezometric surface and the rate and duration of discharge of the well using groundwater storage. *Trans. Amer. Geop. Union*, 2:519-524.
- Tutmez, B., 2010- Assessment of porosity using spatial correlation-based radial basis function and neuro-fuzzy inference system. *Neural Comput Appl*, 19:499–505.
- Tutmez, B. and Hatipoglu, Z., 2007- Spatial estimation model of porosity. *Comput Geosci* 33:465–475.
- Zadeh, L. A., 1965- Fuzzy sets. *Information and Control*, 8(3): 338-353.

# Estimation of hydraulic conductivity by using of SCMAI model Maraghe-Bonab aquifer as a case study

S. Yusefzadeh<sup>1</sup> and A. A. Nadiri<sup>2\*</sup>

<sup>1</sup>M.Sc. Student, Department of Earth Sciences, Faculty of Natural Sciences, University of Tabriz, Tabriz, Iran

<sup>2</sup>Associate Professor, Department of Earth Sciences, Faculty of Natural Sciences, University of Tabriz, Tabriz, Iran

Received: 2016 January 02

Accepted: 2016 December 24

## Abstract

Nowadays ground water is the main source of drinking, agriculture and other uses in arid and semi-arid areas. The demand for this critical and strategic natural resource has increased with population growth and society developments. This process decreases water resources and damages aquifers environment. Therefore, we need to manage aquifers and understand the hydrogeological parameters to deal with water crisis and prevent distraction of the aquifers. Hydraulic conductivity is one of the most important parameters for aquifer management. The ground water system is complex and estimation of hydrogeological parameters is associated with inherent uncertainty and also is costly and time consuming that is usually done with classical methods such as laboratory tests, slug test, tracing test and pumping tests. Therefore recently estimation of hydraulic conductivity by artificial intelligence methods has reduced the uncertainty of this parameter and add up some accuracy, so that it can overcome the shortcoming of classical methods. In this study, four artificial intelligence methods including Mamdani fuzzy logic (MFL) system, Sugeno fuzzy logic (SFL) system, Wavelet-neural network method and Least square support vector machine (LS-SVM) method were used as individual models to estimate the hydraulic conductivity using surface geophysical data in Maragheh-Bonab aquifer. Given that each of these models based on their inherent properties presented good results in some parts of area, therefore, for parallel use of the four models the nonlinear combination method as a supervised committee machine artificial intelligence (SCMAI) model was used to estimate the hydraulic conductivity in the Maragheh-Bonab aquifer. The result of this model showed that this new combinational model has higher performance than other single models presented by using different evaluation criteria. The SCMAI model was tested against 15 data. The RMSE and  $R^2$  for SCMAI prediction were computed as 0.045 and 0.97, respectively. A comparison between the values estimated by this model with those by individual mentioned models indicated that SCMAI model performs better than individual AI models supported by lower RMSE and higher  $R^2$ . This result implies that SCMAI model shows high performance for estimating the hydraulic conductivity values in the heterogeneous unconfined aquifer in the Maragheh-Boanb plain.

**Key words:** Wavelet-neural network, Support vector machine, Fuzzy logic, Hydraulic conductivity, Supervised compound artificial intelligence. For Persian Version see pages 183 to 192

\*Corresponding author: A. A. Nadiri; E-mail: nadiri@tabrizu.ac.ir