

پیش‌بینی سطح آب زیرزمینی با استفاده از مدل منطق فازی مرکب نظارت شده
(مطالعه‌ی موردی: دشت مشگین‌شهر)

عطاالله ندیری^{۱*}

فاطمه واحدی^۲

اصغر اصغری مقدم^۳

چکیده

دشت مشگین‌شهر که در شمال غرب ایران در استان اردبیل قرار گرفته است از جمله مناطقی می‌باشد که عمده تقاضا برای آب شرب و کشاورزی از طریق آب زیرزمینی این محدوده تأمین می‌شود. بنابراین به منظور مدیریت صحیح و مؤثر این منابع، مطالعه و بررسی تغییرات سطح آب زیرزمینی در این دشت ضروری می‌باشد. بدین منظور برای بررسی این منابع از روش‌های مدل‌سازی بهره گرفته شده است که در این میان مدل‌های هوش مصنوعی به دلیل توانایی بالا، کم هزینه بودن، استفاده از اطلاعات کمتر و همچنین اجرای سریع آنها از توجه خاصی برخوردارند. در این مطالعه یک مدل منطق فازی مرکب نظارت شده (SCFL) برای پیش‌بینی سطح آب زیرزمینی در سه پیژومتر دشت ارایه شده است. برای اجرای مدل SCFL ابتدا سطح آب زیرزمینی با استفاده از داده‌های بارش، دما، تخلیه از چاه‌های بهره‌برداری و سطح آب زیرزمینی در یک زمان قبل توسط مدل‌های فازی ممدانی (MFL)، لارسن (LFL)، و ساگنو (SFL) پیش‌بینی شد. سپس برای استفاده همزمان از مزایای هر سه مدل مذکور، ترکیب غیرخطی از خروجی مدل‌های فازی منفرد برای ایجاد یک مدل منطق فازی مرکب نظارت شده بکار برده شد. به منظور ارزیابی کارایی و دقت مدل‌ها در پیش‌بینی، از سه معیار مختلف RMSE، MAE و R^2 استفاده شد. نتایج نشان داد که مدل SCFL با مقادیر MAE برابر ۰/۱۲، ۰/۰۴ و ۰/۰۳ به ترتیب برای پیژومترهای شماره ۱، ۲ و ۳ در مرحله‌ی آموزش بهترین پیش‌بینی را نسبت به هر سه مدل منفرد فازی ارایه کرده است. همچنین مدل SCFL توانست RMSE پیش‌بینی را تا ۶٪ درصد برای پیژومتر شماره یک و ۸٪، ۱۴٪ درصد به ترتیب برای پیژومترهای شماره دو و سه کاهش دهد.

واژه‌های کلیدی: سطح آب زیرزمینی، فازی ساگنو، فازی ممدانی، فازی لارسن، منطق فازی مرکب نظارت شده، دشت مشگین‌شهر.

مقدمه

Email: nadiri@tabrizu.ac.ir

۱- استادیار آشناسی، دانشگاه تبریز، تبریز، ایران (نویسنده مسئول).

۲- دانشجوی کارشناسی ارشد آب‌شناسی، دانشگاه تبریز، تبریز، ایران.

۳- استاد آب‌شناسی، دانشگاه تبریز، تبریز، ایران.

محدودیت منابع آب سطحی، افزایش تقاضای مصرف آب همزمان با توسعه‌ی صنعتی و اقتصادی جوامع و افزایش کشاورزی، آب‌های زیرزمینی را به یک منبع طبیعی ارزشمند در جهت تأمین نیازهای مربوطه تبدیل کرده است. از طرفی استخراج بی‌رویه‌ی آب‌های زیرزمینی به یک مسأله‌ی جدی جهانی خصوصاً در کشورهای در حال توسعه گردیده است (کونیکو و کندی^۱، ۲۰۰۵: ۳۱۸). بنابراین به منظور حفاظت و مدیریت صحیح و مؤثر این منابع ارزشمند، مطالعه و بررسی تغییرات سطح آب زیرزمینی از اهمیت ویژه‌ای برخوردار می‌باشد. با توجه به شرایط پیچیده و غیرقابل مشاهده‌ی محیط زیرسطحی، مدل‌سازی آب‌های زیرزمینی به عنوان ابزاری قدرتمند برای توسعه‌ی برنامه‌ریزی‌های مدیریتی قابل اجرا در مورد آب‌های زیرزمینی و محافظت از این منبع حیاتی می‌باشد. با توجه به برخی محدودیت‌های مدل‌های عددی و فیزیکی مانند وقت‌گیر بودن، پیچیده بودن، پرهزینه بودن و نیاز داشتن به داده‌های زیاد، مدل‌های تجربی از جمله روش‌های هوش مصنوعی می‌توانند در زمانی کوتاه‌تر با صرف هزینه‌ی کمتر و با داده‌های در دسترس محدود، نتایج ارزشمندی را ارائه دهند (کوپولا^۲ و همکاران، ۲۰۰۳: ۳۴۸؛ نیکلاس^۳ و همکاران، ۲۰۰۸: ۳۳۳۸؛ جا و ساهو^۴، ۲۰۱۵: ۶۷۲).

در دهه‌های اخیر محققان بسیاری از مدل‌های هوش مصنوعی از جمله مدل فازی به عنوان مدلی مؤثر و توانا در پیش‌بینی سیستم‌های پیشرفته هیدرولوژی بهره‌جسته‌اند، که می‌توان به مواردی در زمینه‌های مختلف اشاره کرد به عنوان مثال: (۱) طبقه‌بندی کیفی آب (باربیری^۵ و همکاران، ۲۰۰۱؛ گتولر^۶ و همکاران، ۲۰۰۲؛ گتولر و تینه^۷، ۲۰۰۴؛ کرد و اصغری مقدم، ۲۰۱۴)، (۲) پیش‌بینی مکانی کیفی آب زیرزمینی (کومار^۸ و همکاران، ۲۰۱۰؛ سمسون^۹ و همکاران، ۲۰۱۰؛ رحیمی و مکرم، ۲۰۱۲)، (۳) توزیع آلودگی آب زیرزمینی (موحمت اوغلی و یاردیمسی^{۱۰}، ۲۰۰۶؛ توتمز و هتیب اوغلی^{۱۱}، ۲۰۱۰؛ کیورسکی-میلوسویک^{۱۲} و همکاران، ۲۰۱۵-، ۴) آسیب‌پذیری آب زیرزمینی (اوزبک و پیندر^{۱۳}، ۱۹۹۸؛ دیکسون^{۱۴}، ۲۰۰۴ و ۲۰۰۵؛ یوریکو^{۱۵} و همکاران، ۲۰۰۴؛ گمیتزی^{۱۶} و همکاران، ۲۰۰۶؛ رضایی و همکاران، ۲۰۱۳؛ فیجانی و همکاران،

-
- 1- Konikow and Kendy
 - 2- Coppola et al.,
 - 3- Nikolos et al.,
 - 4- Jha and Sahoo
 - 5- Barbieri et al.,
 - 6- Guler et al.,
 - 7- Guler and Thyne
 - 8- Kumar et al.,
 - 9- Samson et al.,
 - 10- Muhammetoglu and Yardimci,
 - 11- Tutmez and Hatipoglu
 - 12- Kiurski-Milošević et al.,
 - 13- Ozbek and Pinder
 - 14- Dixon
 - 15- Uricchio
 - 16- Gemitzi et al.,

۲۰۱۳)، و ۵) پیش‌بینی کمی آب زیرزمینی (کوپولا و همکاران، ۲۰۰۲؛ تیفور^۱ و همکاران، ۲۰۰۳؛ آلوپسی^۲ و همکاران، ۲۰۰۶؛ ندیری و همکاران، ۱۳۹۳).

به دلیل تنوع و پیچیدگی شرایط زیرسطحی و استفاده از داده‌های صحرایی محدود، عدم قطعیت بالایی در رابطه با ورودی‌ها و خروجی‌های مدل وجود دارد (کوپولا و همکاران، ۲۰۰۳: ۳۴۸). مجموعه‌های فازی به دلیل دارا بودن مرزهای مبهم و تدریجی بین مجموعه‌های تعریف شده، دارای قابلیت غلبه بر عدم قطعیت ذاتی سیستم و کنترل خطای انسانی می‌باشند (کالو و استرادا^۳، ۲۰۰۹: ۲۰۳؛ کدخدایی ایلخچی و امینی، ۲۰۰۹: ۶۸). با توجه به اینکه پیش‌بینی‌های نوسانات آب زیرزمینی نیز با عدم قطعیت همراه می‌باشد، منطق فازی به عنوان ابزاری مناسب برای مقابله با عدم قطعیت‌های موجود از اهمیت خاصی برخوردار است. شبکه‌ی عصبی مصنوعی نیز به عنوان یک تقریبگر جهانی می‌تواند در پیش‌بینی و بررسی مسایل غیرخطی مفید باشد (اصغری مقدم و همکاران، ۱۳۸۸: ۱۳۰). برای پیش‌بینی سطح آب زیرزمینی شبکه‌ی عصبی مصنوعی به صورت مقایسه‌ای با منطق فازی (میلواقانان و نایدو^۴، ۲۰۱۱: ۲۵۲۳؛ بیشت^۵ و همکاران، ۲۰۱۳: ۱۰۷) و نروفازی (افندی و واتاناب^۶، ۲۰۰۷: ۱؛ امامقلی‌زاده و همکاران، ۲۰۱۴: ۵۴۳۳؛ رشیدی و همکاران، ۲۰۱۵: ۷۷) (۷۷) به کار رفته است. آیواز^۷ و همکاران (۲۰۰۷: ۲۴۰)، مدل فازی را برای به دست آوردن پارامترهای آبخوان آبخوان از روی سطح آب زیرزمینی به عنوان یک روش حل معکوس به کار بردند، آنها از مدل FCM^۸ برای زون‌بندی آبخوان بهره گرفتند. بیشت و همکاران (۲۰۰۹: ۱۶)، مدل‌های منطق فازی و نروفازی را برای پیش‌بینی سطح آب زیرزمینی به کار بردند. آنها تغذیه و تخلیه‌ی آب زیرزمینی، سطح آب زیرزمینی در زمان گذشته و حال را به عنوان ورودی‌های مدل‌ها مورد استفاده قرار دادند. در این مطالعه مدل نروفازی نتایج بهتری نسبت به منطق فازی ارائه داد. در تحقیقی دیگر از روش نروفازی برای پیش‌بینی نوسانات سطح آب زیرزمینی در حوضه‌ی رودخانه آماراواتی^۹ در جنوب هند استفاده کردند. مدل به کار رفته توانست نوسانات سطح آب زیرزمینی را با دقت خوبی پیش‌بینی کند (یوماماهسواری و کالامانی^{۱۰}، ۲۰۱۴: ۵۲۳). جلال کمالی و همکاران (۲۰۱۱: ۸۶۷) توانایی روش‌های نروفازی و شبکه عصبی مصنوعی را در پیش‌بینی سطح آب

1- Tayfur et al.,

2- Alvisi et al.,

3- Calvo and Estrada

4- Mayilvaganan and Naidu

5- Bisht et al.,

6- Affandi and Watanabe

7- Ayvaz et al.,

8- Fuzzy C-Means

9- Amaravathi River

10- Umamaheswari and Kalamani

زیرزمینی بررسی کردند. هر دو مدل خوبی ارائه دادند اما روش نروفازی در مقایسه با شبکه‌ی عصبی مصنوعی عملکرد بهتری در منطقه‌ی مطالعاتی دشت کرمانشاه در ایران داشت.

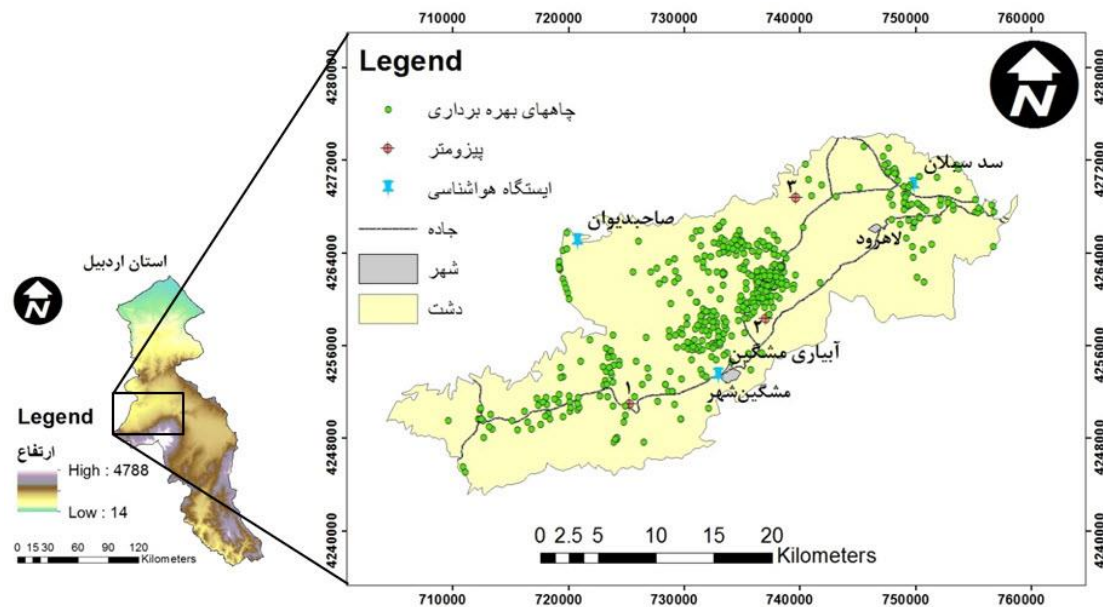
در پیش‌بینی مسایلی که با عدم قطعیت همراه هستند، معمولاً بیش از یک مدل هوش مصنوعی قابل استفاده است که هر یک از مدل‌ها دارای عدم قطعیت و مزایای خاص خود هستند. برای استفاده‌ی همزمان از مزایای همه‌ی مدل‌ها می‌توان از مدل‌های چندگانه استفاده کرد که چند مدل منفرد را به صورت ترکیبی بکار می‌گیرد (ندیری و همکاران، ۱۳۹۳). ندیری و همکاران (۱۳۹۳) مدل‌های فازی ممدانی، لارسن و ساگنو برای تخمین قابلیت انتقال در آبخوان دشت تسوج مورد استفاده قرار گرفت. سپس از ترکیب غیرخطی مدل‌های مذکور برای ایجاد مدل منطق فازی مرکب نظارت شده به منظور بهره‌گیری از مزایای هر سه مدل استفاده شد. نتایج نشانگر برتری مدل مرکب نسبت به هر یک از مدل‌های فازی بودند. در تحقیقی دیگر از ندیری و همکاران (۱۳۹۴)، مدل منطق فازی مرکب را برای پیش‌بینی و بررسی مقادیر غلظت آرسنیک کل در محدوده‌ی مطالعاتی سد سهند به کار بردند. آنها در این روش از ترکیب سه مدل فازی ممدانی، لارسن و ساگنو به صورت خطی و وزنی استفاده کردند. نتایج نشان داد که مدل جدید ارائه شده توانایی و کارایی بالایی در ترکیب مدل‌های فازی دارد. همچنین مدل منطق فازی مرکب وزنی توانست مقدار RMSE را نسبت به نوع خطی ۲۵٪ کاهش دهد.

در دشت مشگین شهر کشاورزی از فعالیت‌های مهم اقتصادی به شمار می‌رود و همچنین عمده تقاضا برای آب شرب و کشاورزی از طریق آب‌های زیرزمینی تأمین می‌شود. بنابراین به منظور مدیریت هر چه مؤثرتر این منابع، مطالعه و بررسی سطح آب زیرزمینی در این دشت ضروری می‌باشد. دوانقی (۱۳۸۸)، آبخوان دشت مشگین شهر را با استفاده از مدل‌های ریاضی - عددی شبیه‌سازی کرده است. متوسط خطای به دست آمده از این تحقیق برای حالت ماندگار و غیرماندگار بیشتر از ۲ متر به دست آمد. از طرفی با توجه به داده‌های محدود در دسترس از منطقه به نظر می‌رسد که روش‌های جدید هوش مصنوعی برای مدل‌سازی این آبخوان بسیار مناسب هستند. لذا در این تحقیق، سعی شده تا با استفاده از پارامترهای مؤثر بر نوسانات سطح آب زیرزمینی اقدام به پیش‌بینی سطح آب زیرزمینی شود. در این مطالعه روش‌های فازی ممدانی (MFL)، لارسن (LFL)، و ساگنو (SFL) برای پیش‌بینی سطح آب زیرزمینی به کار رفته سپس از یک شبکه عصبی مصنوعی برای ترکیب غیر خطی مدل‌های فازی استفاده شد. مدل ارائه شده در این تحقیق، مدل منطق فازی

مرکب نظارت شده (SCFL) نام گرفته که توانایی و کارایی آن در پیش‌بینی سطح آب زیرزمینی مورد بررسی قرار گرفته است. مدل جدید فازی مرکب نظارت شده در این تحقیق برای پیش‌بینی سطح آب زیرزمینی با تحقیقات قبلی متفاوت بوده و تا به حال به کار گرفته نشده است.

معرفی منطقه‌ی مورد مطالعه

محدوده‌ی مطالعاتی دشت مشگین‌شهر می‌باشد که در شمال غرب ایران، در استان اردبیل قرار دارد. کوه سبلان با قله‌ای به ارتفاع ۴۸۱۴ متر از سطح دریا مرتفع‌ترین نقطه‌ی منطقه می‌باشد که در قسمت جنوب شرقی مشگین‌شهر واقع شده است و پست‌ترین نقطه مربوط به خروجی دشت که در روستای صاحب‌دیوان قرار دارد و ارتفاع آن ۷۱۴ متر از سطح دریا می‌باشد. سراسر شمال این شهرستان را دنباله کوه‌های ارسباران که از غرب به شرق کشیده شده، پوشانده است. در فاصله‌ی بین اهر و مشگین‌شهر کوه‌های دوسرداغ و ایلان‌داغ قرار دارند. علاوه بر اینها، ارتفاعات دیگری با جهت شمال‌شرقی - جنوب‌غربی به نام صلوات‌داغ در شمال مشگین‌شهر وجود دارد. این دشت در حد فاصل بین طول‌های جغرافیایی $47^{\circ} 20'$ و $47^{\circ} 58'$ و عرض‌های جغرافیایی $38^{\circ} 18'$ تا $38^{\circ} 35'$ واقع شده است و دارای وسعتی در حدود ۷۰۵ کیلومتر مربع است (شکل ۱). آبخوان دشت مشگین‌شهر از نوع آزاد است. اقلیم منطقه بر اساس اقلیم‌نمای آمبرژه^۲ (۱۹۳۰: ۶۵۱) از نوع نیمه‌خشک سرد می‌باشد. متوسط دمای سالیانه ۱۱/۶۶ درجه‌ی سانتی‌گراد (بر اساس داده‌های ایستگاه‌های آبیاری مشگین، صاحب‌دیوان و سد سبلان، ۱۳۸۸-۱۳۹۱) و میزان متوسط سالانه‌ی بارش ۲۹۲ میلی‌متر (بر اساس داده‌های ایستگاه آبیاری مشگین، ۱۳۸۰-۱۳۹۱) در سال می‌باشد.



شکل (۱) موقعیت منطقه‌ی مورد مطالعه

مواد و روش‌ها

پس از بررسی تغییرات سطح آب زیرزمینی و ارتفاع سطح زمین در محل پیزومترهای موجود در دشت، پیزومترهای شماره ۱، ۲ و ۳ به عنوان نماینده‌ی پیزومترهای دشت انتخاب شدند که تغییرات سطح آب در آنها شبیه بیشتر پیزومترها بود و هر کدام از آنها نمایانگر بخشی از دشت می‌باشد که از نظر ارتفاعی با بخش‌های دیگر متفاوت هستند و همین‌طور از نظر توزیع در بخش شرقی مرکزی و بخش غربی دشت قرار گرفته‌اند. در این تحقیق از داده‌های سطح آب زیرزمینی ماهانه در زمان t_0-1 (GWL^*) در پیزومترهای مربوطه، میزان متوسط بارندگی در هر ماه (P)، متوسط دمای ماهانه (T) و میزان تخلیه از چاه‌های بهره‌برداری در هر ماه (D) که طی دوره‌ی ۹ ساله (۱۳۸۳ تا ۱۳۹۱) در دسترس بودند به عنوان ورودی و سطح آب زیرزمینی در زمان t_0 به عنوان خروجی در هر دو مدل انتخاب شدند. قابل ذکر است که پیزومترهای منتخب دارای داده‌های آماری کاملی بوده و برای تصحیح داده‌های پرت از روش curve fitting استفاده شد. تعداد داده‌های مورد استفاده برای هر پارامتر ۱۰۴ عدد بود که ۸۰ درصد آنها برای مرحله‌ی آموزش و ۲۰ درصد بقیه برای مرحله تست مدل‌ها استفاده شدند. در منطقه‌ی مطالعاتی داده‌های سطح آب زیرزمینی و میزان تخلیه از چاه‌های بهره‌برداری برای پیزومترهای مذکور به ترتیب دارای روند نزولی و صعودی می‌باشند. داده‌های دما و بارش روند تقریباً ثابتی را در دوره‌ی ۹ ساله نشان دادند. همچنین نوسانات سطح آب زیرزمینی در هر سه پیزومتر در

طول دوره‌ی آماری ذکر شده مورد بررسی قرار گرفت. بررسی‌ها تغییرات ۱/۲، ۰/۵ و ۰/۴۵ متری را به ترتیب برای پیژومترهای شماره ۱، ۲ و ۳ نشان دادند.

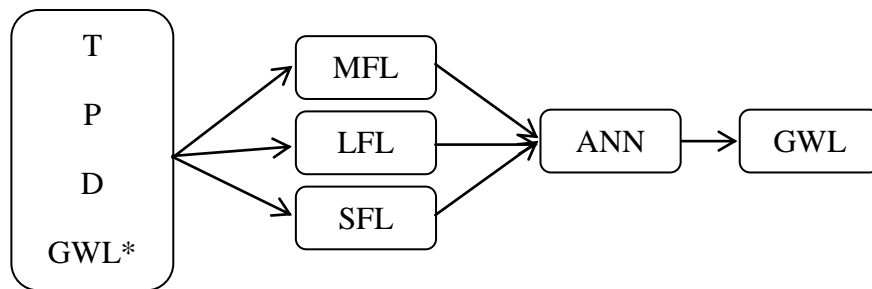
منطق فازی (FL)

مجموعه‌های فازی مرزهای مبهم و تدریجی بین مرزهای تعریف شده دارند، که برای مقابله با ماهیت عدم قطعیت در سیستم و خطاهای انسانی مناسب هستند (کالو و استرادا، ۲۰۰۹: ۲۰۳؛ تیفور و همکاران، ۲۰۱۴: ۱۱۷۴). سیستم فازی شامل سه بخش اصلی است: ۱. تعریف تابع عضویت یا فازی‌سازی داده‌ها، ۲. ایجاد ارتباط بین ورودی و خروجی که با استفاده از یک سری قوانین مثل اگر-آنگاه^۱ انجام می‌شود، ۳. غیر فازی سازی که توسط عملگرهای فازی and، or و not انجام می‌گیرد. عملگر and به دو صورت کمینه‌سازی (min) و وزن‌دهی (prod) و عملگر or به صورت بیشینه‌سازی عمل می‌کند. مدل فازی معمولاً به سه روش مختلف ممدانی^۲ (ممدانی و آسیلیان، ۱۹۷۵: ۱)، لارسن^۳ (لارسن، ۱۹۸۰: ۳) و ساگنو^۴ (تاکاگی و ساگنو، ۱۹۸۵: ۱۱۶) قابل اجرا می‌باشد. تفاوت اصلی بین روش‌های مختلف فازی در نوع تابع عضویت خروجی و عملگر به کار رفته می‌باشد. تفاوت روش ساگنو با دو روش دیگر در خروجی آن‌ها است که برخلاف دو روش دیگر که خروجی به صورت فازی می‌باشد، تابع عضویت خروجی سیستم فازی در روش ساگنو به صورت ثابت یا رابطه خطی است که توسط روش دسته‌بندی به دست می‌آید. اولین مرحله در ایجاد یک مدل فازی دسته‌بندی داده‌ها می‌باشد که روش دسته‌بندی داده‌ها بستگی به نوع مدل فازی استفاده شده دارد. از جمله روش‌های دسته‌بندی داده‌ها می‌توان به روش کاهشی^۵ برای روش ساگنو و روش FCM برای روش ممدانی و لارسن اشاره کرد که برتری این روش‌ها نسبت به روش دسته‌بندی k-means این است که در این روش‌ها نوع خوشه‌بندی داده‌ها در یک محیط فازی است تا یک محیط قطعی، بنابراین می‌تواند دارای دقت خوبی در حل مسایل نسبت به روش k-means باشد (بزدک^۶ و همکاران، ۱۹۸۱). روش‌های ممدانی و لارسن از جهاتی مثل مثل تابع عضویت خروجی که به صورت فازی است و نیاز به غیر فازی‌سازی دارد، شبیه هم هستند. تفاوت این دو روش در نوع عملگر فازی به کار رفته می‌باشد که روش ممدانی عملگر min (ممدانی و آسیلیان^۷، ۱۹۹۹: ۱۳۸؛ ممدانی، ۱۹۷۶: ۶۷۱ و ۱۹۷۷: ۱۱۸۳) و روش لارسن عملگر prod (لارسن، ۱۹۸۰: ۵) را به عنوان عملگر فازی به کار می‌گیرد.

1- if→then
 2- Mamdani
 3- Larsen
 4- Sugeno
 5- Subtractive
 6- Bezdec
 7- Mamdani and Assilian

مدل منطق فازی مرکب نظارت شده (SCFL)

یک مدل هوش مصنوعی مرکب نتایج چند مدل هوش مصنوعی منفرد را ترکیب می‌کند تا از مزایای همه‌ی مدل‌های منفرد برای تولید خروجی نهایی استفاده کند (ندیری و همکاران، ۲۰۱۳: ۱۴۷۵). در این تحقیق، برای استفاده‌ی همزمان از کارایی مدل‌های مختلف منطق فازی از مدل منطق فازی مرکب نظارت شده استفاده شده است. شکل (۲) تصویر شماتیکی از این مدل را نشان می‌دهد. در این مدل، از روش‌های MFL، LFL و SFL برای پیش‌بینی سطح آب زیرزمینی در سه پیزومتر دشت مشگین شهر استفاده شده است. روش‌های مختلفی برای ترکیب مدل‌های هوش مصنوعی وجود دارد که روش متوسط‌گیری تجمعی ساده^۱ و متوسط‌گیری وزنی از معروف‌ترین آنها می‌باشند (نفتالی^۲ و همکاران، ۱۹۹۷: ۲۸۵؛ چن و لین^۳، ۲۰۰۶: ۴۸۶؛ لبنی و همکاران، ۲۰۱۰: ۱۷۶). در این مطالعه، به جای روش متوسط‌گیری ساده و وزنی از یک شبکه-ی عصبی مصنوعی به عنوان یک ترکیب‌کننده‌ی نظارت شده استفاده شده است (تیغور و همکاران، ۲۰۱۴: ۱۱۷۴).



شکل (۲) تصویر شماتیکی از مدل SCFL

بر اساس مطالعات انجام گرفته در زمینه‌ی مدل‌های هوش مصنوعی مرکب (لیم^۴، ۲۰۰۵: ۱۸۵؛ چن و لین، ۲۰۰۶: ۴۸۷؛ کدخدایی و همکاران، ۲۰۰۹: ۴۶۲؛ کریم‌پولی و همکاران، ۲۰۱۰: ۲۲۸) می‌توان اصول کلی آن را به صورت زیر توضیح داد:

$$E_i = \varrho \left[\left(T_i^{\wedge} - T \right)^2 \right] = \varrho \left[e_i^2 \right] \quad \text{رابطه‌ی (۱)}$$

1- simple ensemble averaging method
2- Naftaly
3- Chen and Lin
4- Lim

با فرض وجود i سیستم پیش بینی $T, i=1, \dots, N$ بردار هدف و T_i^{\wedge} خروجی هر سیستم خواهد بود و در رابطه‌ی فوق [۱] امید ریاضی است و متوسط خطا برای هریک از سیستم‌های هوش مصنوعی به صورت رابطه‌ی ۲ محاسبه می‌شود:

$$E_{avg} = \frac{1}{k} \sum_{i=1}^k E_i = \left(\frac{1}{k} \right) \sum_{i=1}^k [e_i^2] \quad \text{رابطه‌ی (۲)}$$

لذا با اعمال روش متوسط گیری بردار خروجی به صورت رابطه‌ی (۳) خواهد بود:

$$T_{CM}^{\wedge} = \frac{1}{k} \sum_{i=1}^k T_i^{\wedge} \quad \text{رابطه‌ی (۳)}$$

بنابراین، برای مربع خطای مدل هوش مصنوعی مرکب خواهیم داشت:

$$E_{CM} = \varrho \left[\left(T_{CM}^{\wedge} - T \right)^2 \right] = \varrho \left[\left(\frac{1}{k} \sum_{i=1}^k T_i^{\wedge} - T \right)^2 \right] = \varrho \left[\left(\frac{1}{k} \sum_{i=1}^k e_i \right)^2 \right] \quad \text{رابطه‌ی (۴)}$$

با در نظر گرفتن معادله‌ی کاجی در رابطه‌ی (۵) می‌توان نشان داد بر اساس رابطه‌ی (۴) مدل هوش مصنوعی مرکب کمترین خطا را نسبت به هر یک از مدل‌های استفاده شده خواهد شد.

$$(a_1 b_1 + a_2 b_2 + \dots + a_n b_n)^2 \leq (a_1^2 + a_2^2 + \dots + a_n^2) \times (b_1^2 + b_2^2 + \dots + b_n^2) \quad \text{رابطه‌ی (۵)}$$

$$E_{CM} = \varrho \left[\left(\frac{1}{k} \sum_{i=1}^k T_i^{\wedge} - T \right)^2 \right] \leq \left(\frac{1}{k} \right) \sum_{i=1}^k [e_i^2] = E_{avg} \quad \text{رابطه‌ی (۶)}$$

بنابراین با توجه به روابط بالا روش‌های مرکب هوش مصنوعی از جمله مدل مرکب منطق فازی ارایه شده در این تحقیق از کارایی مدل‌های مختلف بهره گرفته و یک روش توسعه یافته در پیش‌بینی سطح آب زیرزمینی می‌باشد که نتایج بهتری نسبت به مدل‌های منفرد به کار رفته در این مطالعه به دست می‌دهد.

ارزیابی دقت مدل‌ها

در این تحقیق به منظور ارزیابی کارایی مدل‌ها و توانایی آنها در پیش‌بینی دقیق از معیار جذر میانگین مربع خطا (RMSE^۱)، میانگین خطای مطلق (MAE^۲) و ضریب تبیین (R^۲) استفاده شده است. از سه معیار مختلف برای ارزیابی دقت مدل‌ها استفاده شده است که به صورت زیر تعریف می‌شوند:

1- Root Mean Square Error

2- Mean Absolute Error

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \hat{X}_i)^2} \quad \text{رابطه‌ی (۷)}$$

$$MAE = \frac{\sum_{i=1}^n |X_i - \hat{X}_i|}{n} \quad \text{رابطه‌ی (۸)}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - \hat{X}_i)^2}{\sum_{i=1}^n (X_i - \bar{X}_i)^2} \quad \text{رابطه‌ی (۹)}$$

در روابط فوق X_i و \hat{X}_i به ترتیب مقادیر مشاهداتی و محاسباتی، \bar{X}_i میانگین مقادیر مشاهداتی و n تعداد کل داده‌ها می‌باشد. RMSE و MAE میزان خطای بین مقادیر مشاهداتی و محاسباتی را نشان می‌دهد و R^2 نشانگر میزان بازده مدل است. هر چقدر RMSE و MAE به سمت صفر و R^2 به یک میل کنند بهترین جواب برای مدل ایجاد خواهد شد.

بحث و نتایج

نتایج حاصل از مدل‌های فازی

همانگونه که در بخش روش‌شناسی اشاره شد در این تحقیق از سه روش مختلف فازی ممدانی، لارسن، و ساگنو برای پیش‌بینی سطح آب زیرزمینی استفاده شده است. اولین مرحله در این روش دسته‌بندی داده‌ها و تعیین توابع عضویت می‌باشد که در این پژوهش از روش خوشه‌بندی کاهشی برای مدل ساگنو استفاده شد که روشی کارا و مفید در دسته‌بندی داده‌ها و تعداد قوانین در تحقیقات اخیر بوده است (چیو^۱، ۱۹۹۴: ۲۷۱؛ جراح و هالوانی^۲، ۲۰۰۱: ۱۲۲؛ ندیری و همکاران، ۲۰۱۴: ۵۲۱). اصول شعاع دسته‌بندی در این روش بر اساس کمینه خطای ایجاد شده می‌باشد. شعاع دسته، پارامتر مهمی در خوشه‌بندی کاهشی می‌باشد که کنترل‌کننده‌ی تعداد دسته‌ها و تعداد قوانین اگر آنگاه است که مقدار این پارامتر بین صفر و یک می‌باشد. کاهش این پارامتر باعث افزایش دسته‌ها و تعداد قوانین و افزایش آن به سمت یک باعث کاهش دسته‌ها و قوانین خواهد بود (چیو، ۱۹۹۴: ۲۷۱). بنابراین بازده مدل فازی بستگی به تعیین شعاع بهینه‌ی دسته‌بندی دارد. در این مطالعه بر اساس کمترین خطای ایجاد شده برای دو پیژومتر شماره ۱ و ۳ بهینه‌ترین شعاع دسته‌بندی ۰/۸ تعیین شد که این شعاع دسته‌بندی ۳ دسته‌ی فازی و ۳ قانون اگر - آنگاه را برای داده‌های ورودی و خروجی ایجاد می‌کند. این مقدار برای پیژومتر شماره دو ۰/۶ به دست آمد که بر این اساس داده‌ها به ۷ دسته تقسیم و ۷ قانون اگر - آنگاه تعیین شد. شکل (۳)، نمونه‌ای از توابع عضویت استفاده شده برای


1- Chiu

2- Jarrah and Halawani

یکی از داده‌های ورودی پیژومتر شماره‌ی (۲)، را نشان می‌دهد. تابع عضویت استفاده شده برای مدل‌سازی فازی سطح آب زیرزمینی برای تابع گوسی بود و تابع عضویت خروجی مدل از نوع خطی می‌باشد که بر اساس داده‌های ورودی ساخته می‌شود. برای مثال خروجی اولین تابع عضویت از چهار ورودی ایجاد می‌شود:

$$\text{Output MF1} = C_1.T + C_2.P + C_3.D + C_4.GWL^* + C_5 \quad (10)$$

در رابطه فوق پارامترهای C_1, C_2, C_3, C_4 و C_5 به ترتیب ضریب ورودی‌های T, P, D و GWL^* می‌باشند. C_5 یک پارامتر ثابت معادله است. این پارامترها با برآورد خطی حداقل مربعات به دست می‌آید (ندیری و همکاران، ۱۳۹۳).



پارامتر ورودی چهارم (سطح آب زیرزمینی)

شکل (۳) نمونه‌ای از توابع عضویت متغیرها

در مدل ممدانی و لارسن از روش دسته‌بندی FCM استفاده شد. در این روش‌ها نیز تعداد دسته‌های بهینه بر اساس کمترین RMSE که مقادیر آنها در جدول (۱) آمده، به ترتیب ۲۱، ۲۸ و ۱۶ دسته برای پیژومترهای شماره یک، دو و سه تعیین شد. در این دو روش تابع عضویت ورودی و خروجی تابع گوسی می‌باشد. مقادیر RMSE، MAE و R^2 مربوط به مراحل آموزش و آزمایش پیژومترها با استفاده از هر سه روش فازی در جدول (۱) ارائه شده است.

بر اساس این نتایج مدل ساگنو عملکرد بهتری نسبت به دو مدل ممدانی و لارسن نشان داده است که می‌تواند به دلیل خروجی مدل ساگنو باشد که به صورت خطی می‌باشد و یا به دلیل نوع روش دسته‌بندی و عملکرد به کار رفته در این مدل باشد. با مقایسه‌ی MAE حاصل از مدل‌ها برای پیژومترها مشخص شد که کمترین خطا مربوط به پیژومتر شماره‌ی ۳ با مقدار ۰/۰۴ برای مرحله‌ی آموزش و ۰/۰۷ برای مرحله‌ی آزمایش مدل می‌باشد. دلیل این امر می‌تواند نوسانات کمتر سطح آب زیرزمینی (۰/۴۵ متر) در این پیژومتر نسبت به دو پیژومتر دیگر باشد. از طرفی پیژومتر شماره‌ی (۱) با نوسانات سطح آب زیاد (۱/۲ متر) دارای بیشترین میانگین خطای مطلق است. با توجه به این مسأله که همه‌ی مدل‌ها خطای قابل قبولی را ارائه

داده‌اند اما چون هر یک از مدل‌ها مزیت‌های خاص خود را دارد، لذا برای استفاده همزمان از مزیت‌های هر سه مدل فازی از مدل مرکب نظارت شده استفاده شد.


جدول (۱) نتایج حاصل از مدل‌های فازی و SCFL برای پیرومترها در مراحل آموزش و آزمایش

پیرومترها	مراحل	معیار ارزیابی	نوع مدل			
			SCFL	SFL	MFL	LFL
شماره‌ی (۱)	آموزش	RMSE	۰/۱۶	۰/۱۷	۰/۲۶	۰/۲۶
		MAE	۰/۱۲	۰/۱۳	۰/۲۰	۰/۲۰
		R ²	۰/۸۳	۰/۸۱	۰/۵۷	۰/۵۹
آزمایش	آموزش	RMSE	۰/۱۸	۰/۱۹	۰/۲۷	۰/۳۲
		MAE	۰/۱۴	۰/۱۵	۰/۲۱	۰/۲۳
		R ²	۰/۷۹	۰/۷۷	۰/۵۵	۰/۳۷
شماره‌ی (۲)	آموزش	RMSE	۰/۰۶	۰/۰۷	۰/۲۳	۰/۲۱
		MAE	۰/۰۴	۰/۰۵	۰/۲۰	۰/۱۸
		R ²	۰/۹۷	۰/۹۵	۰/۵۳	۰/۶۰
آزمایش	آموزش	RMSE	۰/۱۷	۰/۱۸	۰/۲۷	۰/۲۵
		MAE	۰/۰۹	۰/۱۱	۰/۲۲	۰/۲۰
		R ²	۰/۸۰	۰/۷۸	۰/۵۱	۰/۵۸
شماره‌ی (۳)	آموزش	RMSE	۰/۰۴	۰/۰۵	۰/۰۸	۰/۰۸
		MAE	۰/۰۳	۰/۰۴	۰/۰۶	۰/۰۶
		R ²	۰/۸۶	۰/۸۴	۰/۶۲	۰/۶۳
آزمایش	آموزش	RMSE	۰/۰۸	۰/۰۹	۰/۱۳	۰/۱۲
		MAE	۰/۰۶	۰/۰۷	۰/۰۹	۰/۰۹
		R ²	۰/۷۴	۰/۷۱	۰/۴۳	۰/۴۷

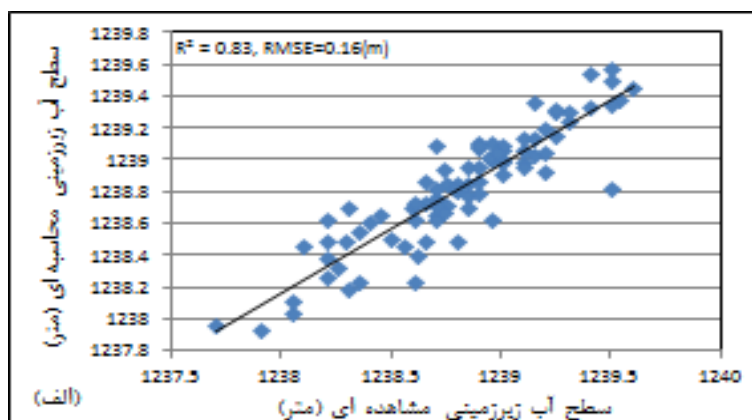
نتایج حاصل از مدل منطق فازی مرکب نظارت شده (SCFL)

مدل منطق فازی مرکب نظارت شده (شکل ۲) برای ترکیب نتایج سه مدل ممدانی، لارسن، و ساگنو به کار گرفته شد. برای اجرای مدل منطق فازی مرکب نظارت شده خروجی مدل‌های فازی پس از نرمالیزه شدن به عنوان ورودی یک شبکه‌ی عصبی مصنوعی استفاده شدند. در این مطالعه، شبکه‌ی عصبی مصنوعی به کار رفته به عنوان یک ترکیب کننده‌ی غیرخطی نظارت شده برای ترکیب مدل‌های فازی عمل می‌کند. این شبکه دارای ساختار ۱-۲-۳ بود. بدین معنی که شبکه شامل سه گره در لایه‌ی ورودی، دو گره در لایه‌ی میانی و یک گره در لایه‌ی خروجی می‌باشد که همان سطح آب پیش‌بینی شده توسط مدل است. تابع تبدیل‌گر در لایه‌ی میانی از نوع سیگموئید تانژانتی و در لایه‌ی خروجی خطی می‌باشد. برای آموزش این شبکه‌ی عصبی، الگوریتم لونیبرگ - مارکوارت به عنوان یک الگوریتم یادگیری برای تخمین بهینه وزن‌ها و بایاس‌ها انتخاب شد.


(ASCE, ۲۰۰۰). ضریب تبیینی برای پیزومترهای شماره ۱، ۲، و ۳ در مرحله آموزش به ترتیب برابر ۰/۸۳، ۰/۹۷ و ۰/۸۶ و برای مرحله‌ی آزمایش به ترتیب برابر ۰/۷۹، ۰/۸۰ و ۰/۷۴ به دست آمد. مقادیر RMSE، MAE و R^2 حاصل از این مدل برای مراحل آموزش و آزمایش پیزومترها در جدول (۱) ارایه شده است. نتایج حاصل از مدل منطق فازی مرکب نظارت شده در اشکال (۴، ۵ و ۶)، آمده است. بر اساس این نتایج، مدل SCFL نتایج بهتری نسبت به هر یک از مدل‌های منفرد فازی نشان می‌دهد.



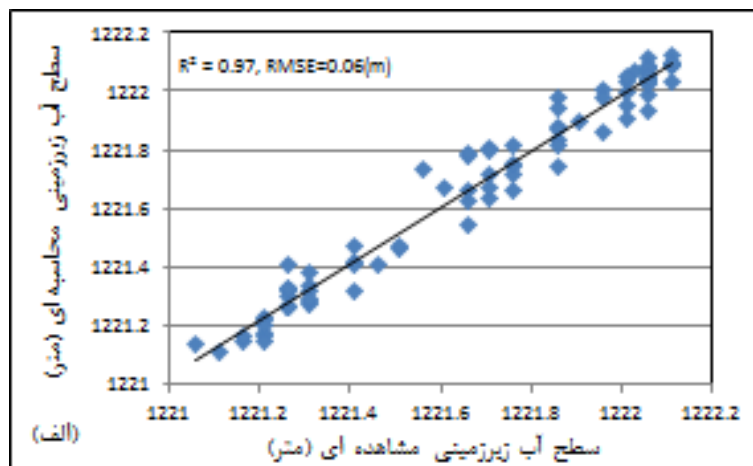
شکل (۴) نتایج مدل برای پیزومتر شماره‌ی (۱)، الف) مرحله‌ی آموزش




شکل (۴) نتایج مدل برای پیزومتر شماره‌ی (۱) ب) مرحله‌ی آزمایش



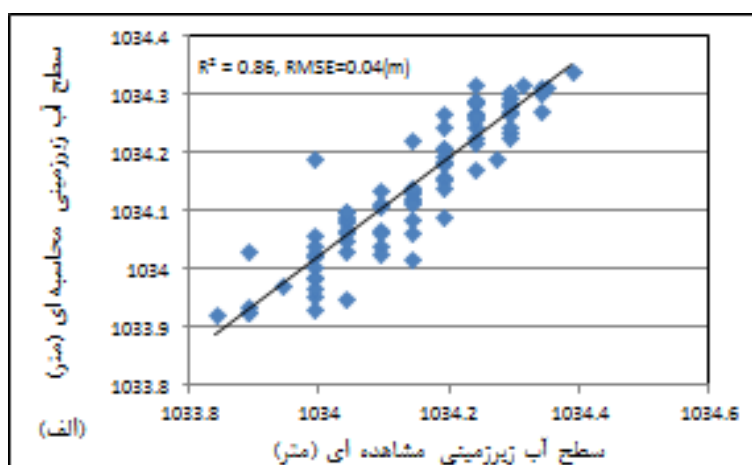
شکل (۵) نتایج مدل برای پیزومتر شماره‌ی (۲) الف) مرحله‌ی آموزش



شکل (۵) نتایج مدل برای پیزومتر شماره‌ی (۲) ب) مرحله‌ی آزمایش



شکل (۶) نتایج مدل برای پیزومتر شماره‌ی ۳، الف) مرحله‌ی آموزش



شکل (۶) نتایج مدل برای پیژومتر شماره‌ی (۳) (ب) مرحله‌ی آزمایش

نتایج حاصل از این تحقیق در مقایسه با مدل عددی انجام شده در این منطقه (دوانقی، ۱۳۸۸) نشان داد که همه مدل‌های ارائه شده در این مطالعه خطای مدل را به‌طور چشمگیری کاهش دادند. از طرفی مدل منطق فازی مرکب نظارت شده نتایج بهتری را نسبت به مدل‌های منفرد فازی نشان داد که قابلیت بالای این مدل را در به کارگیری توانایی مدل‌ها به صورت همزمان در پیش‌بینی نشان می‌دهد. همچنین، مقایسه‌ی MAE حاصل از مدل ترکیبی نیز برای پیژومترها نشان داد که پیژومترهایی شماره‌ی (۲ و ۳) که دارای نوسانات سطح آب کمتری بودند نتایج بهتری نسبت به پیژومتر شماره‌ی (۱) با نوسانات سطح آب زیاد نشان دادند.

در این مطالعه نیز مدل SCFL همانند مطالعات انجام شده با مدل مشابه توسط ندیری و همکاران (۱۳۹۳، ۱۳۹۴)، نتایج بهتری را نسبت به مدل‌های منفرد ارائه کرد. همچنین، نتایج حاصل از این تحقیق در مقایسه با مدل عددی انجام شده در منطقه نشان می‌دهد که خطای مدل‌سازی از RMSE بالای ۲ متر به طور متوسط به ۰/۱۶ متر کاهش یافته است که توانایی مدل‌های هوش مصنوعی را در مسایل پیش‌بینی در شرایط پیچیده‌ی زیرسطحی با داده‌های محدود در دسترس نشان می‌دهد.

نتیجه‌گیری

در این تحقیق سطح آب زیرزمینی با استفاده از مدل‌های مختلف فازی ممدانی، لارسن و ساگنو با داده‌های بارش، میزان حجم برداشتی از آب زیرزمینی، دما و سطح آب زیرزمینی در یک زمان قبل پیش‌بینی شد. نتایج نشان داد که هر یک از مدل‌های فازی به تنهایی قابلیت مدل‌سازی و پیش‌بینی سطح آب زیرزمینی را دارا می‌باشند. هر یک از مدل‌های فازی مزیت خاص خود را دارد. لذا، برای به کارگیری از توانایی ذاتی و متفاوت هر کدام از مدل‌های فازی و متعاقباً برای دستیابی به نتایج بهتر در زمینه‌ی پیش‌بینی سطح آب

زیرزمینی اقدام به ترکیب غیرخطی این مدل‌ها گردید. مدل منطق فازی مرکب ارایه شده در این تحقیق، نتایج مدل‌های فازی ممدانی، لارسن و ساگنو را توسط یک شبکه‌ی عصبی مصنوعی ترکیب کرده و سطح آب زیرزمینی دوباره پیش‌بینی شد. نتایج حاصل از مدل SCFL نشان داد که این مدل از کارایی و دقت بالایی نسبت به مدل‌های منفرد فازی داشته و نتایج بهتری را مراحل آموزش و آزمایش نسبت به دیگر مدل‌ها ارایه داد که دلیل آن بهره‌گیری این مدل از مزایای همه‌ی مدل‌ها به طور همزمان می‌باشد. مدل SCFL توانست RMSE پیش‌بینی را تا ۶٪ درصد برای پیژومتر شماره یک و ۸٪، ۱۴٪ درصد به ترتیب برای پیژومترهای شماره‌ی دو و سه کاهش دهد. همچنین مقادیر MAE برای پیژومترها نشان داد که پیژومترهایی که دارای نوسانات سطح آب کمتری هستند، نتایج بهتری را در پیش‌بینی ارایه می‌دهند. با توجه به عدم قطعیت موجود در پارامترهایی مثل سطح آب زیرزمینی مدل مرکب منطق فازی ارایه شده می‌تواند روشی مناسب برای پیش‌بینی و تخمین این پارامتر باشد که نتایج این تحقیق نیز به روشنی بیانگر این امر می‌باشد.

منابع

- اصغری مقدم، اصغر؛ ندیری، عطاالله و الهام فیجانی (۱۳۸۸). «استفاده از مدل‌های شبکه‌های عصبی مصنوعی و زمین‌آمار برای پیش‌بینی مکانی غلظت فلئورید»، مجله دانش آب- خاک، شماره‌ی ۲، صص ۱۲۹-۱۴۵.
- ندیری، عطاالله؛ اصغری مقدم، اصغر؛ عبقری، هیرداد؛ کلانتری اسکویی، علی؛ حسین‌پور، عبدالله و احد حبیب‌زاده (۱۳۹۳)، «منطق فازی در تخمین قابلیت انتقال آبخوان‌ها مطالعه موردی: دشت تسوج»، نشریه دانش آب و خاک، جلد ۲۴، شماره‌ی ۱، صص ۲۰۹-۲۲۳.
- ندیری، عطاالله؛ صادقی اقدم، فریبا و اصغر اصغری مقدم (۱۳۹۴)، «استفاده از مدل منطق فازی مرکب در برآورد آرسنیک منابع آبی در حوضه آبریز سد سهند»، علوم زمین، سال ۲۵، شماره‌ی ۹۷، صص ۳۹۷-۴۰۶.
- دوانقی، مارال (۱۳۸۸)، «ارزیابی پتانسیل منابع آب زیرزمینی مشگین‌شهر و شبیه‌سازی آبخوان مربوطه با استفاده از مدل‌های ریاضی-عددی»، پایان‌نامه کارشناسی ارشد، دانشگاه تبریز.
- Affandi, A.K., and Watanabe, K., (2007), “**Daily Groundwater Level Fluctuation Forecasting Using Soft Computing Technique**”, Nature and Science, Vol. 5, No. 2, PP: 1-10.
- Alvisi, S., Mascellani, G., Franchini, M., Bardossy, A., (2006), “**Water Level Forecasting through Fuzzy Logic and Artificial Neural Network Approaches**”, Hydrology and Earth Sydtem Science, Vol. 10, PP: 1-17.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, (2000), “**Artificial Neural Network in Hydrology, Part I and II**”, Journal of Hydrologic Engineering, Vol. 5, No. 2, PP: 115-137.
- Ayvaz, M.T., Karahan, H., Aral, M., (2007), **Aquifer Parameter and Zone Structure Estimation Using Kernel-based Fuzzy C-means Clustering and Genetic**, Journal of Hydrology, Vol. 343, PP: 240– 253.
- Barbieri, P., Adami, G., Favretto, A., Lutman, A., Avoscan, W., Reisenhofer, E., (2001), “**Robust Cluster Analysis for Detecting Physico-chemical Typologies of Freshwater from Wells of the Plain of Friuli (Northeastern Italy)**”, Analytica Chimica Acta, Vol. 440, PP: 161– 170.
- Bezdec, J. C., (1981), “**Pattern Recognition with Fuzzy Objective Function Algorithms**”, Plenum Press, New York.
- Bisht, D.C.S., Raju, M.M., and Joshi, M.C., (2009), “**Simulation of Water Table Elevation Fluctuation Using Fuzzy-logic and ANFIS**”, Computer Modelling and New Technologies, Vol. 13, No. 2, PP: 16–23.
- Bisht, D., Jain, Sh., and Raju, M.M., (2013), “**Prediction of Water Table Elevation Fluctuation through Fuzzy Logic and Artificial Neural Networks**”, International Journal of Advanced Science and Technology, Vol. 51, PP: 107-120.

- Calvo, P.I., and Estrada, G.J.C., (2009), “**Improved Irrigation Water Demand Forecasting Using a Soft-computing Hybrid Model**”, Biosystems Engineering, Vol. 102, No. 2, PP: 202–218.
- Chen, C.H., Lin, Z.S., (2006), “**A Committee Machine with Empirical Formulas for - Permeability Prediction, Computers and Geoscience**”, Vol. 32, PP: 485–496.
- Chiu, S.L., (1994), “**Fuzzy Model Identification Based on Cluster Estimation**”, Journal of Intelligent and Fuzzy Systems, Vol. 2, No. 3, PP: 267–278.
- Coppola, E., A., Duckstein, L., and Davis, D., (2002), “**Fuzzy Rule-based Methodology for Estimating Monthly Groundwater Recharge in a Temperate Watershed**”, Journal of Hydrologic Engineering, Vol. 4, PP: 326-335.
- Coppola, E., Szidarovszky, F., Poulton, M., and Charles, E., (2003), “**Artificial Neural Network Approach for Predicting Transient Water Levels in a Multilayered Groundwater System under Variable State, Pumping, and Climate Conditions**”, Journal of Hydrologic Engineering, Vol. 6, PP: 348–360.
- Dixon, B., (2004), “**Prediction of Groundwater Vulnerability Using an Integrated GIS Based Neuro-fuzzy Techniques**”, Journal of Spatial Hydrology, Vol. 4, No. 2, PP: 1-38.
- Dixon, B., (2005), “**Groundwater Vulnerability Mapping: A GIS and Fuzzy Rule Based Integrated Tool**”, Applied geography, Vol. 25, PP: 327–347.
- Emamgholizadeh, S., Moslemi, K., Karami, G., (2014), “**Prediction the Groundwater Level of Bastam Plain (Iran) by Artificial Neural Network (ANN) and Adaptive Neuro-Fuzzy Inference System (ANFIS)**”, Water Resources Management, Vol. 28, PP: 5433–5446.
- Emberger, L. (1930), “**La Vegetation De La Region Mediterraneenne, Essai D’une Classification Des Groupements Vegetaux**”, Revue générale de Botanique, Vol. 42, PP: 641-662.
- Fijani, E., Nadiri, A.A., Asghari Moghaddam, A., Tsai, F.T.C., Dixon, B., (2013), “**Optimization of DRASTIC Method by Supervised Committee Machine Artificial Intelligence to Assess Groundwater Vulnerability for Maragheh–Bonab Plain Aquifer, Iran**”, Journal of Hydrology, Vol. 503, PP: 89–100.
- Gemitzi A., Petalas C., Tsihrintzis V.A., Pisinaras V., (2006), “**Assessment of Groundwater Vulnerability to Pollution: A Combination of GIS, fuzzy logic and Decision Making Techniques**”, Environmental Geology, Vol. 49, No. 5, PP: 653–673.
- Guler, C., Thyne, G.D., (2004), “**Delineation of Hydrochemical Facies Distribution in a Regional Groundwater System by Means of Fuzzy C-means Clustering**”, Water Resources Research, Vol. 40, PP: 1–11.

- Guler, C., Thyne, G.D., McCray, J.E., Turner, A.K., (2002), “**Evaluation of Graphical and Multivariate Statistical Methods for Classification of Water Chemistry Data**”, Hydrogeology Journal, Vol. 10, PP: 455–474.
- Jalalkamali, A., Sedghi, H., and Manshouri, M., (2011), “**Monthly Groundwater level Prediction Using ANN and Neuro-fuzzy Models: A Case Study on Kerman Plain, Iran**”, Journal of Hydroinformatics, Vol. 13.4, PP: 867-876.
- Jarrah, O.A., Halawani, A., (2001), “**Recognition of Gestures in Arabic Sign Language Using Neuro-fuzzy Systems**“, Artificial Intelligence, Vol. 133, PP: 117-138.
- Jha, M.K., and Sahoo, S., (2015), “**Efficacy of Neural Network and Genetic Algorithm Techniques in Simulating Spatio-temporal Fluctuations of Groundwater**, Hydrological Processes, Vol. 29, PP: 671-691.
- Kadkhodaie-Ilkhchi A., Rezaee M.R., Rahimpour-Bonab H. (2009), “**A Committee Neural Network for Prediction of Normalized Oil Content from Well Log Data :An Example from South Pars Gas Field ,Persian Gulf**, Journal of Petroleum Science and Engineering, Vol. 65, PP: 23-32.
- Kadkhodaie-Ilkhchi A., and Amini A. (2009), “**A Fuzzy Logic Approach to Estimating Hydraulic Flow Units from Well Log Data: A Case Study from the Ahwaz Oilfield, South Iran**, Journal of Petroleum Geology, Vol. 32, No. 1, PP: 67-78.
- Kadkhodaie-Ilkhchi A., Rahimpour-Bonab H., and Rezaee M. (2009), “**A Committee Machine with Intelligent Systems for Estimation of Total Organic Carbon Content from Petrophysical Data: An Example from Kangan and Dalan Reservoirs in South Pars Gas Field, Iran**, Computers and Geosciences, Vol. 35, PP: 459– 474.
- Karimpouli S., Fathianpour N., Roohi J. (2010), “**A New Approach to Improve Neural Networks' Algorithm in Permeability Prediction of Petroleum Reservoirs Using Supervised Committee Machine Neural Network (SCMNN)**, Journal of Petroleum Science and Engineering, Vol. 73, PP: 227–232.
- Kiurski-Milošević, J.Ž., Miloradov, M.B.V., Ralević, N.M., (2015), “**Fuzzy Model for Determination and Assessment of Groundwater Quality in the City of Zrenjanin, Serbia**, Hem. ind., Vol. 69, No. 1, PP: 17–28.
- Konikow, L.F., Kendy, E., (2005), “**Groundwater Depletion: A Global Problem**”, Hydrogeology Journal, Vol. 13, No. 1, PP: 317–320.
- Kord, M., Asghari-Moghaddam, A., (2014), “**Spatial Analysis of Ardabil Plain Aquifer Potable Groundwater Using Fuzzy Logic**”, Journal of King Saud University-Science, Vol. 26, PP: 129–140.
- Kumar, N.V., Mathew, S., Swaminathan, G., (2010), “**Multifactorial Fuzzy Approach for the Assessment of Groundwater Quality**”, Journal of Water Resource and Protection, Vol. 2, PP: 597-608.

- Labani, M.M., Kadkhodaie-Ilkhchi, A., Salahshoor, K., (2010), “**Estimation of NMR Log Parameters from Conventional Well Log Data Using a Committee Machine with Intelligent Systems: A Case Study from the Iranian Part of the South Pars Gas Field, Persian Gulf Basin**”, Journal of Petroleum Science and Engineering, Vol. 72, PP: 175–185.
- Larsen PM, (1980), “**Industrial Applications of Fuzzy Logic Control**”, International Journal of Man-Machine Studies, Vol. 12, PP: 3–10.
- Lim, J.S., (2005), “**Reservoir Properties Determination Using Fuzzy Logic and Neural Networks from Well Data in Offshore Korea**”, Journal of Petroleum Science and Engineering, Vol. 49, PP: 182–192.
- Mamdani, E.H., and Assilian, S., (1999), “**An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller**”, International Journal of Man-Machine Studies, Vol. 51, PP: 135–147.
- Mamdani, E.H., (1976), “**Advances in the Linguistic Synthesis of Fuzzy Controllers**”, International Journal of Man-Machine Studies, Vol. 8, No. 6, PP: 669–678.
- Mamdani, E.H., (1977), “**Application of Fuzzy Logic to Approximate Reasoning Using Linguistic Synthesis**”, IEEE Transactions on Computers, Vol. 26, No. 12, PP: 1182–1191.
- Mayilvaganan, M.K., and Naidu, K.B., (2011), “**ANN and Fuzzy Logic Models for the Prediction of groundwater level of a watershed**”, International Journal on Computer Science and Engineering, Vol. 3, No. 6, PP: 2523- 2530.
- Muhammetoglu, A., Yardimci, A., (2006), “**A Fuzzy Logic Approach to Assess Groundwater Pollution Levels Below Agricultural Fields**”, Environmental Monitoring and Assessment, Vol. 118, PP: 337– 354.
- Nadiri, A.A., Chitsazan, N., Tsai, F.T-C., and Moghaddam, A.A., (2014), “**Bayesian Artificial Intelligence Model Averaging for Hydraulic Conductivity Estimation**”, Journal of Hydrologic Engineering, Vol. 19, PP. 520-532.
- Nadiri, A.A., Fijani, E., Tsai, F.T-C., and Moghaddam, A.A., (2013a), “**Supervised Committee Machine with Artificial Intelligence for Prediction of Fluoride Concentration**”, Journal of Hydroinformatics, Vol. 15, PP: 1474–1490.
- Naftaly, U., Intrator, N., Horn, D., (1997), “**Optimal Ensemble Averaging of Neural Networks**, Computation in Neural System, Vol. 8, PP: 283–296.
- Nikolos IK, Stergiadi M, Papadopoulou MP, Karatzas GP. (2008), “**Artificial Neural Networks as an Alternative Approach to Groundwater Numerical Modelling and Environmental Design**”, Hydrological Processes, Vol. 22, PP: 3337–48.
- Ozbek M.M., Pinder, G.F., (1998), “**A Fuzzy Logic Approach to Health Risk Based Design of Groundwater Remediation**”, Computer Methods and Water Resources, Vol. 12, No. 1, PP: 115–122.

- Rahimi, D., Mokarram, M., (2012), “**Assessing the Groundwater Quality by Applying Fuzzy Logic in GIS Environment- A Case Study in Southwest Iran**”, International Journal of Environmental Sciences, Vol. 2, No. 3, PP: 1798- 1806.
- Rashidi, S., Mohammadan, M., and Azizi, K., (2015), “**Predicting of Groundwater Level Fluctuation Using ANN and ANFIS in Lailakh Plain**”, Journal of Renewable Natural Resources Bhutan, Vol. 3, No, 1, PP: 77-84.
- Rezaei, F., Safavi, H. R., Ahmadi, A., (2013), “**Groundwater Vulnerability Assessment Using Fuzzy Logic: A Case Study in the Zayandehrood Aquifers, Iran**”, Environmental Management, Vol. 51, PP: 267–277.
- Samson, M., Swaminathan, G., Kumar, N.V., (2010), “**Assessing Groundwater Quality for Potability Using a Fuzzy Logic and GIS – A Case Study of Tiruchirappalli City– India**”, Computer Modelling, Vol. 14, No. 2, PP: 58–68.
- Takagi, T. & Sugeno, M. (1985), “**Fuzzy Identification of Systems and Its Application to Modeling and Control**”, IEEE Transactions on Human–Machine Systems, Vol. 15, No. 1, PP: 116–132.
- Tayfur, G., Nadiri, A.A., and Moghaddam, A.A., (2014), “**Supervised Intelligent Committee Machine Method for Hydraulic Conductivity Estimation**”, Water Resources Management, Vol. 28, PP: 1173-1184.
- Tayfur, G., Ozdemir, S. and Singh, V.P. (2003), “**Fuzzy Logic Algorithms for Ruoff-induced Sediment Transport from Bare Soil Surfaces**”, Advances in Water Resources, Vol. 26, PP: 1249-1256.
- Tutmez, B., Hatipoglu, Z., (2010), “**Comparing Two Data Driven Interpolation Methods for Modeling Nitrate Distribution in Aquifer**”, Ecological Informatics, Vol. 5, PP: 311–315.
- Umamaheswari, G. R., and Kalamani, D., (2014), “**Adaptive Neuro Fuzzy Inference System for Monthly Froundwater Level Prediction in Amaravathi River Minor Basin**”, Journal of Theoretical and Applied Information Technology, Vol. 68, No. 3, PP: 523-530.
- Uricchio, V.F., Giordano, R., Lopez, N., (2004), “**A Fuzzy Knowledge-based Decision Support Wystem for Groundwater Pollution Risk Evaluation**”, Journal of Environmental Management, Vol. 73, PP: 189–197.
- Zadeh, L.A., (1965), “**Fuzzy Sets**”, Information and Control, Vol. 8, No. 3, PP: 338–353.