

مدل منطق فازی در تخمین قابلیت انتقال آبخوانها مطالعه موردی: دشت تسوج

عطا الله ندیری^{1*}، اصغر اصغری مقدم²، هیراد عبقری³، علی کلانتری اسکویی⁴،
عبدالله حسین پور⁴ و احد حبیب زاده⁴

تاریخ دریافت: 91/09/11 تاریخ پذیرش: 92/04/23

¹ استادیار، گروه زمین شناسی، دانشکده علوم طبیعی، دانشگاه تبریز

² استاد، گروه زمین شناسی، دانشکده علوم طبیعی، دانشگاه تبریز

³ استادیار گروه مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه ارومیه

⁴ کارشناس ارشد مرکز تحقیقات کشاورزی و منابع طبیعی آذربایجان شرقی

* مسئول مکاتبات، پست الکترونیکی: Nadiri@tabrizu.ac

چکیده

این مطالعه یک مدل منطق فازی مرکب نظارت شده (SCFL) برای تخمین قابلیت انتقال در آبخوان دشت تسوج ارائه می کند. تخمین قابلیت انتقال به ویژه در آبخوان ناهمگن بسیار پرهزینه و وقت گیر است. در این مطالعه، برای تخمین قابلیت انتقال با استفاده از داده های هیدروژئولوژیکی و ژئوفیزیکی از مدل های فازی مانند ممدانی (MFL)، لارسن (LFL) و ساگنو (SFL) استفاده شد. این مدل ها، نتایج مشابهی در تخمین قابلیت انتقال در دشت تسوج ارائه دادند. لذا به جای انتخاب مدل برتر از مدل SCFL برای ترکیب نتایج سه مدل منفرد فازی استفاده شد. برای استفاده همزمان از مزایای هر سه مدل مذکور، ترکیب غیر خطی از خروجی مدل های فازی برای ایجاد یک مدل منطق فازی مرکب نظارت شده به کار گرفته می شود. مدل مذکور از یک شبکه عصبی مصنوعی برای تخمین قابلیت انتقال بر اساس خروجی سه مدل فازی استفاده می کند. نتایج نشان داد مدل SCFL ارائه شده، توانست نسبت به روش های مدل منطق فازی مرکب ساده، که از روش ترکیب کننده خطی سود می بردند، بهتر عمل کند. همچنین نتایج نشانگر برتری نتایج مدل SCFL نسبت به هر یک از مدل های فازی بودند.

واژه های کلیدی: فازی ساگنو (SFL)، فازی لارسن (LFL)، فازی ممدانی (MFL)، منطق فازی مرکب نظارت شده (SCFL)

Fuzzy Logic Model for Estimation of Aquifers Transmissivity Case study: Tasuj Plain

AA Nadiri^{*1}, A Asghari Moghaddam², H Abghari³,
A Klantari⁴, A Hosseinpour⁴ and A habibzadeh⁴

Received: 1 September 2012 Accepted: 14 July 2013

¹-Assist. Prof., Dept. of Geology, Faculty of Sci., Univ. of Tabriz. Iran.

²-Prof., Dept. of Geology, Faculty of Sci., Univ. of Tabriz. Iran.

³-Assist. Prof., Dept. of Watershed Management, Faculty of Natural Resources, Urmia Univ. Iran.

⁴-Specialist in East Azerbaijan Agric. and Natural Resources Research Center. Tabriz. Iran.

* Corresponding Author Email: Nadiri@tabrizu.ac.ir

Abstract

This study presents a supervised committee fuzzy logic (SCFL) model to estimate transmissivity in the aquifer of the Tasuj Plain, Iran. The estimation of transmissivity especially in a heterogeneous aquifer is expensive and time consuming. In this study, fuzzy logic models such as Mamdani fuzzy logic (MFL), Larsen fuzzy logic (LSL) and Sugeno fuzzy logic (SFL) were applied to estimate transmissivity using hydrogeological and geophysical survey data. The results showed that all of these models have a similar fitting to the transmissivity data in the Tasuj Plain. The SCFL model was adopted to combine output of the three single fuzzy models instead of the selecting superior single model. To reap the advantage of considering single models, the SCFL proposes a nonlinear combination of individual FL model outputs through a committee fuzzy logic model. The SCFL method uses an artificial neural network (ANN) model to re-estimate transmissivity based on the output of the three FL models. The result showed improvement to the committee machine with a linear combination of FL models estimations. The results also showed significant fitting improvement to individual FL models.

Keywords: Larsen fuzzy logic, Mamdani fuzzy logic, Sugeno fuzzy logic, Supervised committee fuzzy logic, Transmissivity

آبخوان بدست می‌آید (تاد و میز، 2005) و با توجه به عدم قطعیت ذاتی این پارامتر، مدل‌های مختلفی برای پیش‌بینی دقیق آن قابل استفاده است (کدخدایی ایلیچی و امینی 2009). بدست آوردن مقادیر قابلیت انتقال با استفاده از آزمایشات صحرایی مانند روش آزمایش پمپاژ (تایس 1935، چاو 1952، کوپر و ژاکوب 1946).

مقدمه

قابلیت انتقال یکی از پارامترهای مهم در شناسایی خصوصیات آبخوان‌ها می‌باشد که بدست آوردن مقادیر و چگونگی توزیع آن در مدل‌سازی و مدیریت آبخوان‌ها ضروری به نظر می‌رسد. قابلیت انتقال از حاصل ضرب هدایت هیدرولیکی در ضخامت

روش‌ها برای رسیدن به یک نتیجه کلی و بهتر است. به این ترتیب، می‌توان از مزیت انفرادی هر یک از این مدل‌ها سود جست (لبنی و همکاران 2010). تا به حال دو روش برای تشکیل مدل‌های هوش مصنوعی مرکب ارائه شده است که عبارت است از روش متوسط‌گیری ساده (لیم 2005، چن و لین 2006) و متوسط‌گیری وزنی است (کدخدایی ایلخچی و همکاران 2009a). مطالعات اخیر که بر روی این دو روش ترکیب خطی برای مدل‌های هوش مصنوعی انجام شده، توانایی و کارایی بالاتر روش متوسط‌گیری وزنی را که وزن هر مدل با استفاده از روش‌های بهینه‌سازی الگوریتم ژنتیک³ (لبنی و همکاران 2010) تعیین می‌شود، نشان دادند. دشت تسوج یکی از دشت‌های حوضه دریاچه ارومیه محسوب می‌شود که شدیداً با بحران کاهش سطح آب زیرزمینی مواجه است (ندیری و همکاران 1389، ندیری و همکاران 2013) و با وجود مطالعات فراوانی مانند مطالعات تفصیلی و ژئوفیزیک که در سال‌های اخیر در این دشت صورت گرفته هنوز نیاز مبرم به شناخت پارامترهای هیدروژئولوژیکی برای مدیریت منابع آب دارد. لذا در این تحقیق سعی گردید که با استفاده از داده‌های ژئوفیزیک مرتبط با قابلیت انتقال اقدام به برآورد این پارامتر شود. در این مطالعه با توجه به خصوصیات قابلیت انتقال، از روش‌های فازی ممدانی⁴ (MFL)، لارسن⁵ (LFL)، و ساگنو⁶ (SFL)، برای پیش‌بینی و بررسی این پارامتر استفاده شد. همه مطالعات انجام شده روی هوش مصنوعی مرکب از جمله مدل‌های منطق فازی مرکب (CFL) از دو روش خطی متوسط‌گیری ساده و متوسط‌گیری وزنی برای ترکیب آنها استفاده کرده‌اند (لبنی و همکاران 2010، کدخدایی ایلخچی و همکاران 2009b، لیم 2005، چن و لین 2006). در این تحقیق به جای روش خطی از روش غیر خطی

بسیار پرهزینه و وقت‌گیر است. لذا به طور وسیعی مدل‌های عددی و فیزیکی مختلفی در پیش‌بینی و بررسی توزیع این پارامتر توسعه یافته‌اند (روز و همکاران 2007، سای و لی 2008). با توجه به برخی محدودیت‌های مدل‌های عددی و فیزیکی مانند وقت‌گیر بودن، پیچیده بودن، پرهزینه بودن و نیاز داشتن به داده‌های زیاد، روش‌های دیگری مانند روش‌های مختلف هوش مصنوعی برای پیش‌بینی قابلیت انتقال ارائه شده است.

مطالعات فراوانی بر روی پیش‌بینی پارامترهای هیدروژئولوژیکی با استفاده از مدل‌های هوش مصنوعی مانند فازی (اولتونجی و همکاران 2011) و شبکه‌های عصبی مصنوعی (چن و لین 2006، کدخدایی ایلخچی و همکاران 2009a) صورت گرفته است. مدل‌های فازی عموماً در مدل‌سازی مسائلی که با عدم قطعیت ذاتی همراه هستند، مناسب هستند (پالیدو-گوتیرز-ایترادا 2004) و مدل شبکه عصبی مصنوعی به عنوان یک تقریب‌گر جهانی می‌تواند در پیش‌بینی بررسی مسائل غیرخطی مفید باشد (اصغری مقدم و همکاران 1388). در پیش‌بینی پارامترهایی مانند قابلیت انتقال که با عدم قطعیت همراه است، عموماً بیش از یک مدل هوش مصنوعی قابل استفاده است و می‌توانند نتایج مشابهی حاصل کنند. که هر یک از این مدل‌ها به تنهایی دارای عدم قطعیت و مزایای مربوط به خود است. بنابراین مدل‌های چندگانه¹ که از مزایای همزمان هر یک از مدل‌ها به صورت ترکیبی استفاده می‌کنند، به عنوان مدل‌هایی با کارایی بالا معرفی شده‌اند. مدل‌های هوش مصنوعی مرکب² (AICM) از جمله این مدل‌ها هستند که برای پیش‌بینی چنین پارامترهایی توسعه یافته‌اند (ندیری و همکاران 2014، کدخدایی ایلخچی و همکاران 2009a,b، لیم 2005، نفتالی 1997). اساس تئوری این روش استفاده ترکیبی از نتایج هر یک از

³ Genetic Algorithm.

⁴ Mamdani fuzzy logic.

⁵ Larsen fuzzy logic.

⁶ Sugeno fuzzy logic.

¹ Multi-model.

² Artificial intelligence committee machine.

از مهمترین این گسل‌ها می‌توان گسل تسوج، قزلجه و انگشتجان را نام برد (قندی 1384).

تجزیه و تحلیل داده‌ها

در محدوده دشت تسوج 146 چاه بهره‌برداری مجاز وجود دارد که در بیشتر این چاه‌ها آزمایش پمپاژ پله‌ای توسط امور آب شهرستان تسوج و سازمان نظام مهندسی استان آذربایجان شرقی صورت گرفته و در پنج حلقه از این چاه‌ها آزمایش پمپاژ با دبی ثابت توسط سازمان آب منطقه‌ای آذربایجان شرقی انجام گرفته است. لذا داده‌های موجود از سازمان‌های مربوطه اخذ گردید (شکل 2). تعداد معدودی از داده‌های مقادیر قابلیت‌انتقال در این چاه‌ها که از دقت کمی برخوردار بود بر اساس لاگ چاه‌ها از روی مقادیر هدایت هیدرولیکی تجربی ارائه شده توسط تاد و میز (2005) برای خاک‌های مختلف و نتایج مطالعات ژئوفیزیک تصحیح یا حذف گردید. بر اساس مطالعات ژئوفیزیک انجام گرفته در این دشت داده‌های مقاومت الکتریکی ظاهری و نقشه هم ضخامت رسوبات آبرفتی در دسترس است (بی نام 1387). مقاومت الکتریکی ظاهری دارای دو مؤلفه اصلی مقاومت الکتریکی عرضی (R_t) و مقاومت الکتریکی طولی (R_L) می‌باشد که به ترتیب تغییرات پارامترهای هیدروژئولوژیکی (مانند نفوذ پذیری، کیفیت آب و غیره، ...) عمقی و جانبی را نشان می‌دهد. لذا مقاومت الکتریکی عرضی با مقادیر قابلیت-انتقال مرتبط است (میلت 1947، هارب و همکاران 2010) و همچنین مقادیر هدایت الکتریکی (EC) را نیز می‌توان از پارامترهای مرتبط با مقادیر قابلیت‌انتقال دانست (اورتگا و میراندا 2004). لذا بر این اساس ورودی مدل‌های به کار رفته عبارت از مقاومت الکتریکی عرضی (شکل 3)، ضخامت رسوبات آبرفتی (B) (شکل 1)، هدایت الکتریکی (EC) و موقعیت جغرافیایی داده‌های هدایت الکتریکی و قابلیت‌انتقال (شکل 2) بودند که از سازمان آب منطقه‌ای آذربایجان-شرقی، امور آب شهرستان تسوج و سازمان نظام

شبکه‌های عصبی برای ترکیب مدل‌های فازی استفاده شده است. مدل جدید ارائه شده، مدل منطق فازی مرکب نظارت شده¹ (SCFL) نام گرفت و توانایی و کارایی آن در پیش‌بینی قابلیت‌انتقال که عموماً با عدم قطعیت همراه است مورد بررسی قرار گرفت. همچنین برای بررسی توانایی مدل ارائه شده، این مدل با مدل منطق فازی مرکب CFL مقایسه شد و نتایج نشان داد که مدل منطق فازی مرکب نظارت شده است.

مواد و روش‌ها

منطقه مطالعاتی

دشت تسوج در فاصله حدود 100 کیلومتری شمال غرب شهر تبریز قرار گرفته است (شکل 1). حوضه مورد مطالعه مساحتی بالغ بر 559 کیلومتر مربع را دربرگرفته است که دشت تسوج تنها 256 کیلومتر مربع را شامل می‌شود و آبخوان آزاد موجود در این دشت به عنوان منبع اصلی آب جهت شرب و کشاورزی می‌باشد. منطقه از جنوب به دریاچه ارومیه از شمال به محدوده مرنند، ارتفاعات میشو و از شرق به شبستر و از غرب به سلماس محدود شده است. میزان متوسط سالانه ریزشهای جوی در ایستگاه تسوج 232/7 میلی‌متر در سال در طول بازه زمانی 1388-1379 می‌باشد. اقلیم منطقه نیمه خشک سرد می‌باشد و حداقل و حداکثر درجه حرارت هوا در ایستگاه تسوج به ترتیب برابر 11°C - و 33°C درجه سلسیوس می‌باشد. به طور کلی تنوع سازندها در منطقه بسیار زیاد و هر سه گروه سنگ‌های آذرین، دگرگونی و رسوبی به چشم می‌خورد و در این گستره سازندهای زمین‌شناسی از پرکامبرین تا عهد حاضر رخنمون دارند. گسل‌های بسیاری در منطقه وجود دارند که برخی از آنها حتی آبرفت‌های دوران چهارم را قطع می‌کنند. برخی از این گسل‌ها خیلی ژرف بوده و تا پی سنگ کشیده می‌شوند.

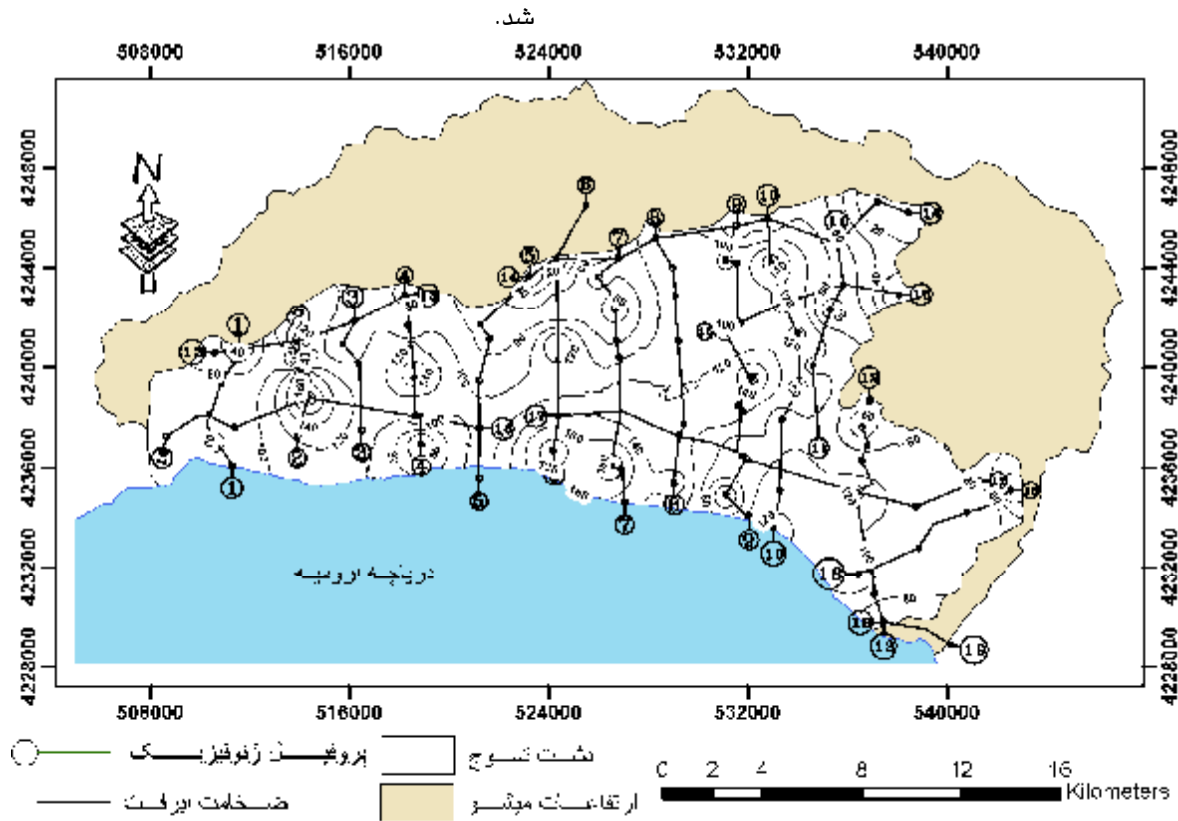
¹ Supervised committee fuzzy logic

عرض جغرافیایی به Y_{min} و X_{min} منطقه مطالعاتی انتقال و به صورت زیر تبدیل به برداری به نام O گردید.

$$O = \sqrt{(X - X_{min})^2 + (Y - Y_{min})^2} \quad [1]$$

در این تحقیق برای مدل‌های MFL، LFL و SFL داده‌های ورودی و هدف به دو دسته آموزش و آزمایش تقسیم گردید. به طوری که 109 داده برای مرحله آموزش و 25 داده برای مرحله آزمایش استفاده

مهندسی استان آذربایجان شرقی اخذ گردیده‌اند. جدول 1 نشانگر برخی از خصوصیات آماری پارامترهای ورودی است. با توجه به این که مدل‌های هوش مصنوعی عموماً به داده ورودی حساس بوده و کاهش ورودی‌های مدل باعث کاهش پیچیدگی این مدل‌ها می‌شود، لذا موقعیت جغرافیایی (UTM) با تغییراتی اعمال شد. به طوری که بر اساس رابطه 1 مبدأ طول و

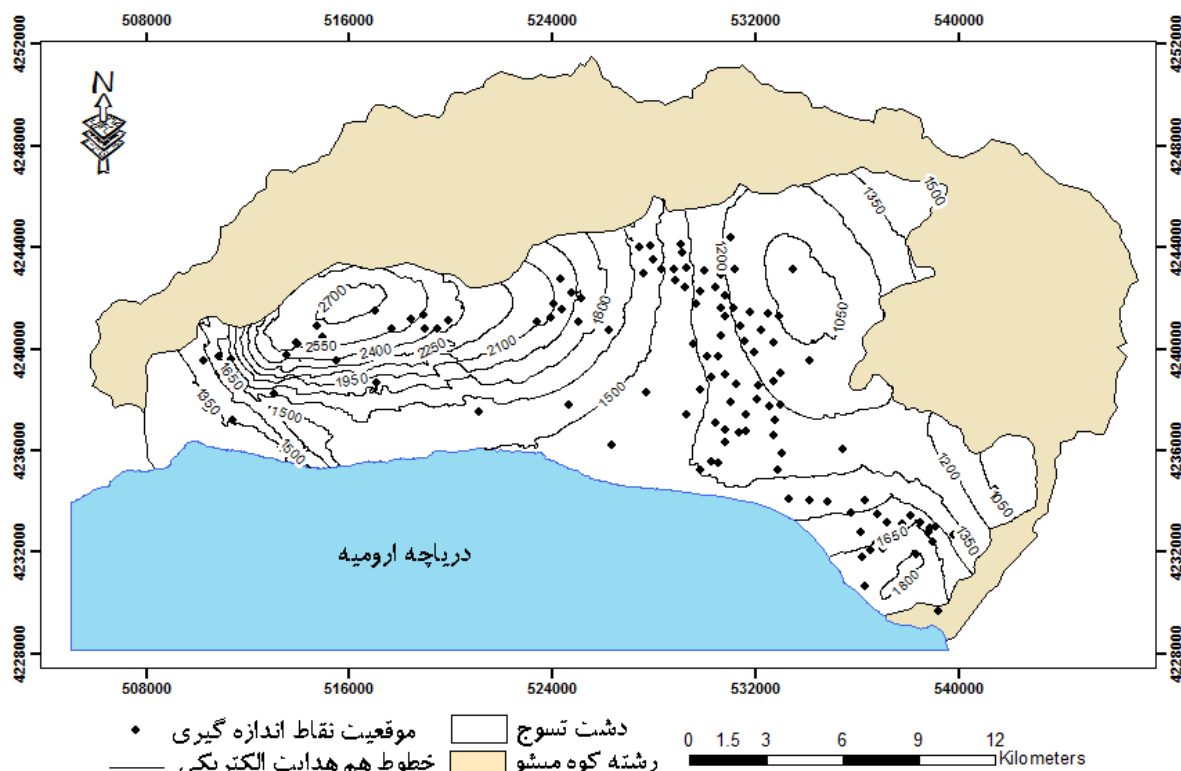


شکل 1- موقعیت منطقه مطالعاتی و پروفیل ژئوفیزیکی و هم تراز های ضخامت آبرفت (متر).

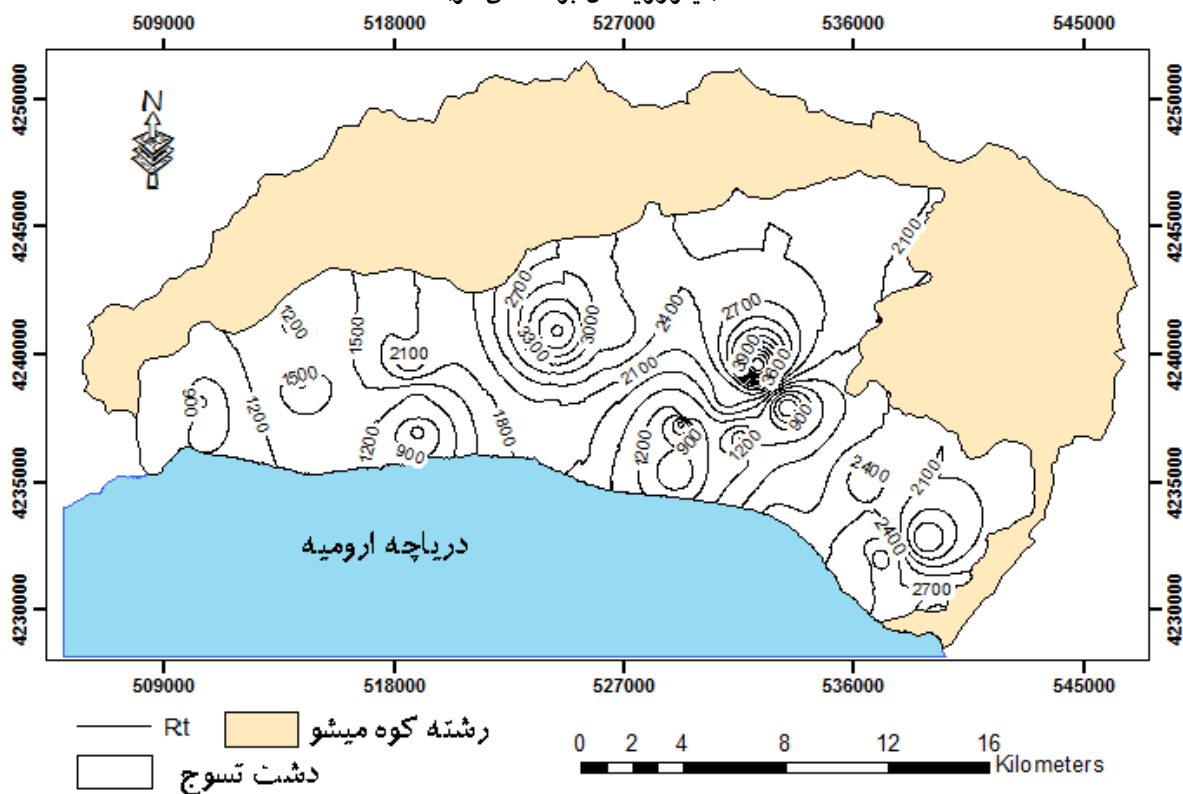
جدول 1- برخی از خصوصیات آماری پارامترهای ورودی در مدل‌های LFL، MFL و SFL.

پارامتر	کمینه	بیشینه	متوسط	انحراف از معیار	واریانس
O (m)	11072/19	36991/08	26029/2	6408/50	41068994
EC(μ S/cm)	700	3153/67	1603/42	487/30	237470/3
$R_t(\Omega\text{-m})$	625/08	5070/54	2551/20	1299/46	1688602
B (m)	44/29	182/39	107/36	19/73	389/64
T(m^2/d)	13/1	215	84/97	43/29	1874/2

توجه: در این جدول (O) موقعیت داده ها، (B) ضخامت رسوبات آبرفتی، (EC)، هدایت الکتریکی، (R_t) مقاومت الکتریکی عرضی می‌باشد



شکل 2- توزیع مقادیر هدایت الکتریکی و موقعیت مکانهای اندازه گیری قابلیت انتقال (متر مربع بر روز) و هدایت الکتریکی (میکروزیمنس بر سانتی متر).



شکل 3- توزیع مقادیر مقاومت عرضی (اهم-متر) در منطقه مطالعاتی.

منطق فازی (FL)

(FCM) Fuzzy C-Means برای روش ممدانی و لارسن اشاره کرد.

مدل منطق فازی مرکب نظارت شده¹ (SCFL)

در سال‌های اخیر روش‌های هوش مصنوعی توسعه فراوانی در علوم مختلف پیدا کرده است و می‌تواند بر حسب نوع سیستم مورد بررسی در مدل‌سازی به کار گرفته شود. با توجه به اینکه هر یک از روش‌های هوش مصنوعی مانند فازی، نروفازی و یا شبکه‌های عصبی مصنوعی مزایای منحصر به فردی دارند لذا در تحقیقات اخیر برای استفاده همزمان از مزایای روش‌های مختلف از روش‌های متوسط‌گیری خطی مانند متوسط‌گیری ساده و متوسط‌گیری وزنی برای ایجاد هوش مصنوعی مرکب² (AICM) و از آن جمله مدل منطق فازی مرکب (CFL) استفاده شده است (لیم 2005، چن و لین 2006، کدخدایی ایلیچی و همکاران 2009b). در این تحقیق برای استفاده همزمان از کارایی مدل‌های منطق فازی مختلف، مدل منطق فازی مرکب نظارت شده استفاده شده است. به طوری که روش‌های MFL، LFL و SFL برای تخمین قابلیت انتقال در دشت تسوج استفاده شدند. برای ترکیب نتایج این مدل‌ها از شبکه‌های عصبی مصنوعی استفاده شد (شکل 4). نتایج مدل SCFL با مدل منطق فازی مرکب ساده CFL فازی برای تخمین قابلیت انتقال مقایسه شد. شبکه‌های عصبی مصنوعی به روش‌های مختلفی مانند چگونگی ارتباط گره‌ها و حرکت داده‌ها در شبکه، دسته‌بندی می‌شوند (اصغری مقدم و همکاران 1388). در این تحقیق از شبکه چند لایه پرسپترون³ MLP که یکی از شبکه‌های پیشرو⁴ (FFN)، استفاده شد که در این شبکه‌ها اطلاعات از ورودی به طرف خروجی حرکت می‌کنند. گره‌های موجود در یک لایه بهم مرتبط نمی‌شوند، بلکه گره‌ها در

اساس تئوری فازی برای اولین بار توسط لطفی‌زاده در سال 1965 معرفی گردید و در سال‌های اخیر توانایی بالایی در کاهش خطای تخمینی نسبت به روش احتمالاتی نشان داده است. روش فازی روشی مناسب جهت کاهش خطای تخمینی و انسانی نسبت به تئوری‌های دیگر ارائه کرده است (نیک روش و امین زاده 2003). داده‌های هیدروژئولوژیک عموماً دارای خطای تخمینی ذاتی است و داده‌هایی صریح و بدون خطا به حساب نمی‌آید. برای مثال، بدست آوردن قابلیت انتقال از آزمایش پمپاژ دارای خطایی غیرقابل اغماض است. لذا این روش می‌تواند به عنوان روشی کارا در کاهش این خطا و تخمین دقیق پارامترهای هیدروژئولوژیکی محسوب شود.


هر سیستم فازی شامل سه بخش اصلی است: الف) فازی کردن داده‌ها که این با تعریف تابع عضویت انجام می‌شود، ب) ایجاد ارتباط بین ورودی و خروجی که این کار نیز با یک سری قوانین مانند اگر آنگاه (if-then) انجام می‌شود، ج) مرحله آخر، مرحله تجمیع نتایج سیستم و غیرفازی‌سازی است که بوسیله عملگرهای فازی که شامل and، or، و not می‌شود. عملگر and به دو صورت کمینه‌سازی (min) و وزن‌دهی (prod) و عملگر or نیز به صورت بیشینه‌سازی عمل می‌کند. مدل فازی به سه روش فازی مختلف ممدانی (MFL) (ممدانی 1975، 1976، 1977)، لارسن (LFL) (لارسن 1980)، و ساگنو (ساگنو 1985) (SFL) قابل اجراست. تفاوت روش ساگنو با دو روش دیگر در خروجی آنها است که بر خلاف دو روش دیگر تابع عضویت خروجی سیستم فازی به صورت ثابت یا رابطه خطی است که توسط روش دسته‌بندی به دست می‌آید. اولین مرحله در ایجاد یک مدل فازی دسته‌بندی داده‌ها است که بسته به نوع مدل فازی استفاده شده دارد و می‌توان از روش‌های دسته‌بندی مختلف استفاده کرد، که از آن جمله می‌توان به روش Subtractive برای روش ساگنو و روش

¹ Supervised committee fuzzy model.

² Artificial intelligence committee machine

³ Multilayer perceptron.

⁴ Feedforward Network



شکل 4- ساختار شماتیکی از مدل SCFL.

نتایج و بحث

مدل فازی

همان‌گونه که در قسمت روش‌شناسی اشاره شد در این تحقیق از سه روش فازی مختلف ممدانی (MFL)، لارسن (LFL)، و ساگو (SFL)، برای پیش‌بینی قابلیت‌انتقال در آبخوان تسوج استفاده شد. اولین مرحله در این روش دسته‌بندی داده‌ها و تعیین توابع عضویت است که در این تحقیق از روش کاهشی¹ برای مدل ساگو استفاده شد که روشی کارا و مفید در دسته‌بندی داده‌ها و تعداد قوانین در تحقیقات اخیر بوده است (ندیری و همکاران 2014، جراح و هالاوانی 2001، چپو 1994). پارامتر اصلی در این روش دسته‌بندی برای تعیین دسته‌ها و قوانین اگر- آنگاه شعاع دسته‌بندی است. مقادیر این پارامتر بین صفر و یک می‌باشد. کاهش این پارامتر باعث افزایش دسته‌ها و قوانین و افزایش آن به سمت یک باعث کاهش دسته‌ها و قوانین خواهد بود (چپو 1994). بازده مدل فازی بستگی به تعیین شعاع بهینه دسته‌بندی دارد که مقدار بهینه آن 0/4 تعیین شد. بر این اساس داده‌ها به هفت دسته تقسیم و هفت قانون اگر- آنگاه تعیین شد. شکل 5 نمونه‌ای از توابع عضویت داده‌های ورودی را نشان می‌دهد. توابع عضویت استفاده شده برای مدل‌سازی فازی مقادیر قابلیت‌انتقال تابع گوسی بود که به داده‌های دسته‌بندی شده برآزش

یک لایه به لایه بعدی ارتباط می‌یابند. بنابراین، خروجی یک گره در یک لایه به سیگنالی که از لایه قبلی دریافت می‌کند، وزن تعیین شده برای آن و نوع تابع تبدیل‌گر بستگی دارد. مدل SCFL ارائه شده را می‌توان به صورت زیر نوشت (ندیری و همکاران 2013; 2014):

$$\hat{T}_i = FL_i(O, EC, R_1, B) \quad [2]$$

$$O_j = f_1 \left(b_j + \sum_i W_{ji} \hat{T}_i \right) \quad [3]$$

$$O_k = \hat{T}_{SCFL} = f_2 \left(b_k + \sum_j W_{kj} O_j \right) \quad [4]$$

در فرمول فوق \hat{T}_i خروجی مدل‌های فازی که به عنوان i^{th} ورودی استفاده شده است و f_1 و f_2 به ترتیب تابع فعال‌سازی برای لایه مخفی و لایه خروجی است. O_j نیز j^{th} خروجی گره‌ها در لایه مخفی است. W_{ji} و W_{kj} به ترتیب وزن بین لایه اول، دوم و سوم است و همینطور b_j و b_k به ترتیب بایاس برای لایه‌های مذکور است. توابع فعال‌سازی، توابعی پیوسته هستند مانند سیگموئید، هایپربولیک و غیره که در این مطالعه از تابع هایپربولیک برای گره‌های لایه میانی یا مخفی و از تابع خطی برای گره‌های لایه خروجی استفاده شد. O_k نیز خروجی مدل SCFL می‌باشد. برای آموزش مدل شبکه عصبی مصنوعی نیز از روش آموزش نظارت شده استفاده شد، به طوری که از بین الگوریتم‌های موجود به این منظور، کارا ترین آنها یعنی الگوریتم لوبنبرگ - مارکوت برای بدست آوردن وزن و بایاس بهینه به کارگرفته شد (هایکین 1991، انجمن مهندسیین عمران آمریکا 2000).


¹ Subtractive

18/3 متر مربع بر روز، 12 دسته تعیین شد. در این دو روش نیز توابع عضویت ورودی و خروجی تابع گوسی بود. مقادیر ضریب تعیینی نیز برای مدل‌های ممدانی و لارسن در مرحله آموزش برابر با 0/82 و 0/84 بود. نتایج این دو مدل در مرحله آزمایش نیز به ترتیب در شکل های 7 و 8 ارائه شده است. بر اساس نتایج مدل‌های فازی که در جدول 2 ارائه شده است با وجود اینکه هر سه مدل فازی نتایج قابل قبول دارند ولی مدل ساگنو نتایج نسبتاً بهتری نسبت به دو مدل دیگر دارد. لذا چون هر یک از این سه مدل مزیت‌های خاص خود را دارد لذا برای استفاده از مزیت‌های هر سه مدل در یک زمان از مدل مرکب نظارت شده استفاده شد.


داده شد. تابع عضویت خروجی مدل ساگنو، تابعی است خطی که بر اساس ورودی‌ها ساخته می‌شود. برای مثال خروجی اولین تابع عضویت از چهار ورودی ایجاد می‌شود:

$$Output\ MF1 = C_1 \times O + C_2 \times EC + C_3 \times R_t + C_4 \times R_f + C_5 \quad [5]$$


در رابطه فوق پارامترهای به ترتیب C_1, C_2, C_3, C_4 و C_5 ضریب ورودی های O, EC, R_t و R_f می‌باشند. C_5 نیز پارامتر ثابت هر معادله است. این پارامترها با برآورد خطی حداقل مربعات بدست می‌آید. با این توصیف هر تابع عضویت خروجی پنج پارامتر خواهد داشت. شکل 6 نتایج مدل فازی ساگنو را نشان می‌دهد. در مدل ممدانی و لارسن از روش دسته بندی FCM استفاده شد. در این روش نیز تعداد دسته‌های بهینه بر اساس کمترین مقدار RMSE که به ترتیب برابر بود با 17/37،




شکل 5- نمونه ای از توابع عضویت متغیرها $(R_t) \cdot (\Omega - m)$.



شکل 6- مقایسه نتایج مشاهداتی و محاسباتی توسط مدل ساگنو (SFL) برای پیش‌بینی قابلیت انتقال. مرحله آموزش (الف)، مرحله آزمایش (ب).



شکل 7- مقایسه نتایج مشاهداتی و محاسباتی توسط مدل ممدانی (MFL) برای پیش‌بینی قابلیت انتقال، مرحله آموزش (الف)، مرحله آزمایش (ب).



شکل 8- مقایسه نتایج مشاهداتی و محاسباتی توسط مدل لارسن (LFL) برای پیش‌بینی قابلیت انتقال، مرحله آموزش (الف)، مرحله آزمایش (ب).


جدول 2- نتایج مدل های فازی در مراحل آموزش و آزمایش.

مدل			معیار ارزیابی	مراحل
SFL	MFL	LFL		
۱۳/۲۴	۱۷/۳۷	۱۸/۳	RMSE(m ² /d)	آموزش
۰/۹۱	۰/۸۴	۰/۸۲	R ²	
۱۷/۴۷	۱۷/۰۱	۲۱/۶۷	RMSE(m ² /d)	آزمایش
۰/۷۹	۰/۷۹	۰/۷۱	R ²	


در طی آموزش با الگوریتم LM پس از 73 دوره آموزش بهینه شد. مقادیر RMSE و R^2 در جدول 3 ارائه شده است. مقایسه داده‌های مشاهداتی و محاسباتی نیز در شکل 9 و توزیع مقادیر قابلیت انتقال حاصله از مدل SCFL در شکل 10 نشان داده شده است. بر اساس نتایج مدل‌های فازی و SCFL که در جداول 2 و 3 ارائه شده، مدل جدید ارائه شده نتایج بهتری نسبت به هر یک از مدل‌های فازی به تنهایی نشان می‌دهند. برای تأیید نتایج مدل SCFL، کارایی این مدل با کاراترین مدل منطق فازی مرکب که روش میانگین‌گیری وزنی است (بنی و همکاران 2010) مقایسه شد.

تخمین قابلیت انتقال با استفاده از مدل منطق فازی مرکب نظارت شده (SCFL)

مدل منطق فازی مرکب نظارت شده ارائه شده در شکل 4 برای ترکیب نتایج سه مدل فازی ممدانی (MFL)، لارسن (LFL)، و ساگنو (SFL) به کار گرفته شد. به طوری که خروجی مدل‌های فازی پس از نرمالیزه شدن به عنوان ورودی وارد مدل MLP-LM شدند و بر اساس معادلات 3 و 4 فرایند آموزش با استفاده از 109 داده مرحله آموزش انجام شد. شبکه ایجاد شده دارای ساختار 1-2-3 بود، یعنی شامل سه گره در لایه ورودی، دو گره در لایه میانی، و یک گره در لایه خروجی است. تابع فعال‌سازی در لایه دوم هایپربولیک و در لایه سوم خطی بود. مقادیر وزن و بایاس شبکه



شکل 9- مقایسه نتایج مشاهداتی و محاسباتی توسط مدل SCFL برای پیش‌بینی قابلیت انتقال، مرحله آموزش (الف)، مرحله آزمایش (ب).



شکل 10- توزیع مقادیر قابلیت انتقال حاصله از مدل SCFL.

جامعه ذرات به عنوان پیش فرض، پارامترهای شتاب برابر مقادیر $c_1 = c_2 = 2$ استفاده شد، اما نتایج تجربی نشان می‌دهد که مقادیر $c_1 = c_2 = 0/5$ ممکن است نتایج بهتری را حاصل نماید. تحقیقات نشان می‌دهد که ممکن است انتخاب پارامتر شناختی، c_1 ، بزرگتر از پارامتر اجتماعی، c_2 ، با این شرط که $c_1 + c_2 \leq 4$ باشد، منجر به نتایج بهتری شود. پارامترهای r_1 و r_2 برای حفظ تنوع و گوناگونی گروه بکار می‌روند و آنها اعداد تصادفی در محدوده (0/1) با توزیع یکنواخت هستند. پس از مشخص شدن محدودیت‌های مسئله و تابع پنالتی به منظور انجام آنالیز حساسیت مدل الگوریتم جامعه ذرات ترکیب‌های مختلف از هر پارامتر در نظر گرفته شد (بانکس و همکاران، 2008). در این آنالیز با در نظر گرفتن مقادیر مختلف برای c_1 و c_2 (پارامترهای شناختی و اجتماعی)، W_{max} و W_{min} و بعد از 10 بار اجرای مدل، بهترین مقادیر این پارامترها با توجه به کمترین مقدار تابع هدف به ترتیب 1/5، 2، 0/1 و 0/5 بدست آمد. پس از شناخت پارامترهای مدل اقدام به بهینه‌سازی و بدست آوردن وزن‌ها شد، بهترین جمعیت اولیه نیز 200 انتخاب شد و در بهینه‌ترین حالت

مقایسه نتایج مدل منطق فازی مرکب نظارت شده (SCFL) با مدل منطق فازی مرکب (CFL)

هدف این مرحله مقایسه نتایج مدل SCFL ارائه شده با مدل CFL است، که با اعمال ضریب وزنی برای هر یک از مدل‌های فازی ایجاد می‌شود. در این مرحله از روش الگوریتم بهینه‌سازی جامعه ذرات برای بهینه‌سازی و وزن‌دهی برای این سه مدل استفاده شد. مبانی و مفاهیم این روش توسط بانکس و همکاران (2007، 2008) ارائه شده است. بدین منظور تابع برازش به صورت رابطه زیر تعریف می‌شود:

$$MSE_{CFL} = \sum_{i=1}^k 1/k (w_1 \hat{T}_{1i} + w_2 \hat{T}_{2i} + w_3 \hat{T}_{3i} + w_4 \hat{T}_{4i})^2 \quad [6]$$

این تابع مقدار خطای MSE^1 مدل مرکب را برای پیش‌بینی مرحله آموزش نشان می‌دهد، به طوری که w_1 ، w_2 و w_3 به ترتیب وزن مدل‌های فازی ممدانی (MFL)، لارسن (LFL) و ساگنو (SFL) و T_i مقادیر مشاهداتی و n تعداد داده‌های آموزشی (109 نمونه) را نشان می‌دهد. الگوریتم جامعه ذرات همانند روش‌های بهینه‌سازی ابتکاری و هوش مصنوعی بهینه‌سازی نیاز به تعیین پارامترهای مناسب مدل دارد. در اولین نسخه الگوریتم


¹ Mean Square Error

بینی شده برای مدل منطق فازی مرکب بدست آمد (شکل 11، جدول 3). بر اساس نتایج ارائه شده در جدولهای 2 و 3 بهترین نتایج مربوط به مدل SCFL می‌باشد و این مدل از مدل‌های فازی به تنهایی و مدل CFL نتایج بهتری ارائه دادند.

مقدار RMSE برای داده‌های آموزش برابر با 8/38 مترمربع بر روز بدست آمد (جدول 3). وزن‌های مدل‌های مختلف از این مدل بصورت رابطه زیر بدست آمد:

$$\hat{T}_{CFL} = 0.34 \times \hat{T}_{MFL} + 0.27 \times \hat{T}_{LFL} + 0.39 \times \hat{T}_{SFL} \quad [7]$$

با به کارگرفتن وزن های بدست آمده به صورت فرمول فوق برای داده‌های مرحله آزمایش، مقادیر پیش-



شکل 11- مقایسه نتایج مشاهداتی و محاسباتی توسط مدل CFL برای پیش‌بینی قابلیت انتقال، مرحله آموزش (الف)، مرحله آزمایش (ب).

جدول 3- ارزیابی عملکرد نتایج AICM با مدل SCFL.

مدل		معیار ارزیابی	مراحل
SCFL	CFL		
5/82	8/38	RMSE(m ² /d)	آموزش
0/98	0/95	R ²	
6/8	10/74	RMSE(m ² /d)	آزمایش
0/96	0/93	R ²	

نتایج بدست آمده توسط هر یک از این مدل‌ها به تنهایی دارد. علاوه بر این، مقایسه نتایج به دست آمده از مدل SCFL و CFL نیز نشان داد که مدل جدید ارائه شده توانایی و کارایی بالایی در ترکیب مدل‌های فازی دارد. دلیل این موضوع را می‌توان در تفاوت روش ترکیب

نتیجه گیری کلی

نتایج مدل منطق فازی مرکب ارائه شده، که از ترکیب نتایج مدل‌های فازی ممدانی (MFL)، لارسن (LFL)، و ساگو (SFL) توسط شبکه عصبی مصنوعی حاصل شد، نشان از برتری مدل ارائه شده نسبت به

فازی مرکب ارائه شده و با استفاده از داده‌های ژئوفیزیکی و هدایت الکتریکی برای کاهش هزینه‌ها سود جست، که می‌تواند نتایج نسبتاً دقیقی هم در پی داشته باشد. خطای موجود در مدل نهایی به عوامل مختلفی بستگی دارد. از آن جمله می‌توان به تعداد محدود داده‌ها، ناهمگنی آبخوان، و خطای ذاتی موجود در داده‌های ورودی و حتی داده‌های خروجی اشاره کرد. افزایش دقت داده‌های ژئوفیزیکی و آزمایش پمپاژ در آبخوان‌ها می‌تواند در کاهش خطای موجود در مدل ارائه شده مؤثر باشد.

کردن دانست، لذا می‌توان چنین نتیجه گرفت که روش غیرخطی شبکه‌های عصبی مصنوعی در ترکیب مدل-های فازی کارایی بالاتری دارد و نتایج دقیق‌تری را ارائه می‌دهد. به طوری که مدل SCFL نسبت به مدل CFL توانست مقدار RMSE را تا 37 درصد کاهش دهد. با توجه به عدم قطعیت موجود در پارامترهای هیدروژئولوژیک به خصوص قابلیت انتقال، مدل منطق فازی مرکب ارائه شده می‌تواند روشی مناسب برای پیش‌بینی و برآورد این پارامترها باشند. همینطور با توجه به هزینه‌های بالای آزمایش‌های صحرایی پیش-بینی قابلیت انتقال در آبخوان‌ها می‌توان از مدل منطق

منابع مورد استفاده

- اصغری مقدم الف، ندیری ع، و فیجانی الف، 1388. استفاده از مدل های شبکه‌های عصبی مصنوعی و زمین‌آمار برای پیش بینی مکانی غلظت فلئوئورید. مجله دانش آب-خاک. شماره 2، 19/1، صفحه های 129 تا 145.
- بی نام، 1387. مطالعات ژئوفیزیک دشتهای تبریز، تسوج، و هادیشهر. مهندسين مشاور صحراکاو.
- ندیری، ع، اصغری مقدم، الف، 1389. استفاده از روش های آماری چند متغیره در مطالعه فرآیندهای هیدروشمیایی آبخوانها، مطالعه موردی: دشت تسوج، چهاردهمین همایش انجمن زمین ایران و بیست وهشتمین گردهمایی علوم زمین، 25 تا 27 شهریور، دانشگاه ارومیه.
- قندی، الف، 1384. بررسی هیدروژئولوژی و هیدروژئوشیمی آبخوان دشت تسوج و تأثیرات طرح تغذیه مصنوعی بر منابع آبهای زیرزمینی منطقه. پایاننامه کارشناسی ارشد، گروه زمین‌شناسی، دانشکده علوم طبیعی، دانشگاه تبریز.
- Anonymous, 2000. ASCE task committee on application of artificial neural networks in hydrology, part I and II. *Journal Hydrologic Engineering* 5: 115-137.
- Banks, A, Vincent, J, and Anyakoha, C, 2007. A review of particle swarm optimization. Part I: background and development. *Natural Computing* 6: 467-484.
- Banks, A, Vincent, J, and Anyakoha, C, 2008. A review of particle swarm optimization. Part II: hybridisation, combinatorial, multicriteria and constrained optimization, and indicative applications. *Natural Computing* 7: 109-124.
- Chen CH, and Lin ZS, 2006. A committee machine with empirical formulas for permeability prediction. *Computers and Geosciences* 32: 485-496.
- Chiu S, 1994. Fuzzy model identification based on cluster estimation. *Journal of Intelligent and Fuzzy Systems* 2: 267-278.
- Chow VT, 1952. On the determination of transmissibility and storage coefficient from pumping test data. *Transactions, American Geophysical Union* 33: 397-404.
- Cooper HH and Jacob CE, 1946. A generalized graphical method for evaluation formation constants and summarizing well field history. *Transactions, American Geophysical Union* 27: 526-534.
- Harb N, Haddad K and Farkh S, 2010. Calculation of transverse resistance to correct aquifer resistivity of groundwater saturated zones : implications for estimating its hydrogeological properties. *Lebanese Science Journal* 11(1): 105-115.
- Haykin S, 1991. *Neural Networks: A Comprehensive Foundation*. Englewood Cliffs, NJ, 842pp.
- Jarrah OA and Halawani A, 2001. Recognition of gestures in Arabic sign language using neuro-fuzzy systems. *Artificial Intelligence* 133: 117-138.

- 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* 32(1): 67-78.
- Kadkhodaie-Ilkhchi A, Rezaee MR and Rahimpour-Bonab H, 2009a. 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* 65: 23-32.
- Kadkhodaie-Ilkhchi A, Rezaee MR, Rahimpour-Bonab H, and Chehrizi, A, 2009b. Petrophysical data prediction from seismic attributes using committee inference system. *Computers & Geosciences* 35, 2314–2330.
- Labani MM, Kadkhodaie-Ilkhchi A, and 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* 72: 175-185.
- Larsen PM, 1980. Industrial applications of fuzzy logic control. *International Journal of Man-Machine Studies* 12: 3–10.
- Lim JS, 2005. Reservoir properties determination using fuzzy logic and neural networks from well data in offshore Korea. *Journal of Petroleum Science and Engineering* 49: 182–192.
- Maillet R, 1947. The fundamental equations of electrical prospecting. *Geophysics* 12: 529-556.
- Mamdani EH and Assilian S, 1975. An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies* 7: 1-13.
- Mamdani EH, 1976. Advances in the linguistic synthesis of fuzzy controllers. *International Journal of Man-Machine Studies* 8(6): 669-678.
- Mamdani EH, 1977. Application of fuzzy logic to approximate reasoning using linguistic synthesis computers, *IEEE Transactions C-26*(12): 1182–1191.
- Nadiri, AA, Asghari Moghaddam, A, Tsai, F T-C, and Fijani, E, 2013. Hydrogeochemical analysis for Tasuj plain aquifer, Iran. *Journal of Earth System Science*. 122(4): 1091-1105.
- Nadiri, AA, Chitsazan, N, Tsai, F, and Asghari Moghaddam, A, 2014. Bayesian artificial intelligence model averaging for hydraulic conductivity estimation. *Journal Hydrological Engineerin* 19(3): 520-523.
- Naftaly U, Intrator N and Horn D, 1997. Optimal ensemble averaging of neural networks. *Computation in Neural Systems* 8: 283–296.
- Nikravesh M and Aminzadeh F, 2003. *Soft Computing and Intelligent Data Analysis in Oil Exploration. Part1: Introduction: Fundamentals of Soft Computing.* Elsevier, Berkeley, USA.
- Olatunji SO, Selamat A and Abdulraheem A., 2011. Modeling the permeability of carbonate reservoir using type-2 fuzzy logic systems. *Computers in Industry* 62: 147–163.
- Ortega RMV and Miranda WR, 2004. Resolution power of well log geophysics in karst aquifers. *Journal of Environmental Hydrology* 12: 1-7.
- Pulido Calvo I and Gutiérrez Estrada JC, 2009. Improved irrigation water demand forecasting using a soft-computing hybrid model. *Biosystems Engineering* 102(2): 202-218.
- Ross J, Ozbek M and Pinder GF, 2007. Hydraulic conductivity estimation via fuzzy. *Mathematical Geology* 39(8): 765-780.
- Sugeno M, 1985. *Industrial Application of Fuzzy Control.* Elsevier Science Pub. Co., New York, USA.
- Theis CV, 1935. The relationship between the lowering of piezometric surface and the rate and duration of discharge of a well using groundwater storage. *Transactions, American Geophysical Union* 16: 519-524.
- Todd DK and Mays LW, 2005. *Groundwater Hydrology.* 3rd ed. Wiley, New York, USA,.
- Tsai FTC and Li X, 2008. Multiple parameterizations for hydraulic conductivity identification. *Ground Water* 46(6): 851- 864.