



Development of Artificial Intelligence Committee Machine for Transmissivity Estimation, Case study: Tasuj Plain

A. Nadiri¹, A. Asghari Moghaddam^{2*},
H. Abghari³ and E. Fijani¹

Abstract

Hydrogeological parameters like transmissivity are among the important and money-consuming input parameters of ground water modeling. Fuzzy logic, Artificial Neural Networks, and Neurofuzzy has high capability in hydrogeological parameter estimation. In this research combination of these models applied to transmissivity estimation of Tasuj aquifer. Tasuj plain aquifer is one of the marginal plains of Lake Urmia which suffered more ground water declination in last decades and needs qualitative and quantitative management. To overcome the complexity of hydrogeologic systems, Hybrid Artificial Intelligence Modelis then presented as a committee machine. Based on the outputs, weights of each models optimized using particle swarm optimization which caused to form committee machine. Related geophysical and hydrogeological variables to transmissivity such as transverse resistivity (R_t), electric conductivity (EC), alluvium thickness (B), and geographic location were among inputs to this study. The obtained results from presented committee machine showed higher efficiency compared to the Fuzzy logic, Artificial Neural Network, and Neurofuzzy models, individually.

Keywords: Tasuj Plain, Fuzzy logic, Transmissivity, Artificial neural network, Committee machine, Neurofuzzy.

Received: May 28, 2012
Accepted: October 3, 2012

توسعه مدل‌های هوش مصنوعی مرکب در برآورد قابلیت انتقال آبخوان، مطالعه موردی: دشت تسوج

عطاالله ندیری^۱، اصغر اصغری مقدم^{۲*}،
هیراد عبقری^۳ و الهام فیجانی^۱

چکیده

پارامترهای هیدروژئولوژیکی از جمله قابلیت انتقال یکی از مهمترین پارامترهای ورودی در مدل‌سازی آبهای زیرزمینی است که عموماً تعیین آن برای نقاط مختلف آبخوان با هزینه‌های فراوانی انجام می‌گیرد. آبخوان دشت تسوج یکی از آبخوانهای حاشیه دریاچه ارومیه می‌باشد که در دهه اخیر با افت سطح آب زیرزمینی مواجه شده و نیازمند مدیریت کمی و کیفی است. بنابراین، در این تحقیق به عنوان مرحله اول، از مدل‌های منطق فازی، شبکه عصبی مصنوعی و نوروفازی برای برآورد قابلیت انتقال استفاده شد. سپس با توجه به پیچیدگی سیستم‌های هیدروژئولوژیکی، در این مطالعه روش ترکیبی از مدل‌های هوش مصنوعی پیشنهاد شده است که مدل هوش مصنوعی مرکب (Committee machine (CM)) خوانده می‌شود. با توجه به این که هر یک از مدل‌های فازی، شبکه عصبی مصنوعی و نوروفازی توانایی‌هایی در برآورد پارامترهای هیدروژئولوژیکی نشان داده‌اند، لذا در این روش ترکیبی از این مدل‌ها برای پیش‌بینی قابلیت انتقال استفاده شده است. به طوری که خروجی هر مدل با وزن بهینه شده بوسیله روش الگوریتم بهینه‌سازی جامعه ذرات، به خروجی مدل ترکیبی ارائه شده انجامید. در این مطالعه از متغیرهای ژئوفیزیکی و هیدروژئولوژیکی مرتبط با قابلیت انتقال مانند مقاومت عرضی (R_t)، هدایت الکتریکی (EC) و ضخامت آبخوان (B) و همچنین موقعیت جغرافیایی به عنوان ورودی برای برآورد قابلیت انتقال استفاده شد. بر اساس نتایج بدست آمده مدل ترکیبی پیشنهاد شده نسبت به هر یک از مدل‌های فازی، شبکه عصبی مصنوعی و نوروفازی نتایج بهتری نشان دادند.

کلمات کلیدی: آبخوان دشت تسوج، منطق فازی، قابلیت انتقال، شبکه عصبی مصنوعی، مدل هوش مصنوعی مرکب، نوروفازی.

تاریخ دریافت مقاله: ۸ خرداد ۱۳۹۱

تاریخ پذیرش مقاله: ۱۲ مهر ۱۳۹۱

1- PhD student, Department of Geology, University of Tabriz, Tabriz, Iran.
Email: Nadiri@tabrizu.ac.ir

2- Professor of Department of Geology, University of Tabriz, Tabriz, Iran.

3- Assistant professor of Department of Watershed Management, Urmia University, Urmia, Iran.

*- Corresponding Author

۱- دانشجوی دکتری هیدروژئولوژی، دانشگاه تبریز، تبریز، ایران.

۲- استاد دانشکده علوم طبیعی، دانشگاه تبریز، تبریز، ایران.

۳- استادیار دانشکده منابع طبیعی دانشگاه ارومیه، ارومیه، ایران.

*- نویسنده مسئول

جمله می توان به (Abbaspour et al., 2001) اشاره کرد که با استفاده از بهینه سازی با روش کلونی مورچه، هدایت هیدرولیکی را در محیط متخلخل با تخمینی مناسب به دست آوردند. پس از آنها (Li et al., 2006) با به کارگیری کلونی مورچه و کلونی مورچه ترکیبی با شبیه سازی آنیلینگ توانستند روش مناسبی برای تعیین پارامترهای هیدرولوژیکی آبخوان ارائه دهند. (Li and Liu 2005) از شبکه های عصبی مصنوعی برای تخمین هدایت هیدرولیکی بر اساس سطح آب زیرزمینی در چهار پیژومتر نزدیک به هم در محل سد بایشان (Baishan) در چین استفاده کردند و نتایج نسبتاً دقیقی به دست آوردند.

(Samani et al., 2007) از شبکه های عصبی مصنوعی (MLP-GDX) برای تحلیل داده های پمپاژ و به دست آوردن پارامترهای آبخوان استفاده کردند. (Mategaonkar and Eldho 2012) از الگوریتم بهینه سازی جامعه ذرات برای بهسازی آب زیرزمینی استفاده کردند. اخیراً تحقیقات فراوانی بر روی مقایسه کارایی روشهای هوش مصنوعی در برآورد و پیش بینی زمانی و مکانی پارامترها و یا پدیده های هیدرولوژیکی انجام گرفته است. از آن جمله می توان به اصغری مقدم و همکاران (۱۳۸۹) و (Shiri and Kişi 2011) اشاره کرد. (Shiri and Kişi 2011) نیز در مطالعه خود دو روش نوروفازی و برنامه نویسی ژنتیک برای پیش بینی تغییرات روزانه سطح آب زیرزمینی استفاده کردند. با توجه به اینکه هر یک از مدل های فوق توانایی های متفاوتی دارند، استفاده از روشهای ترکیبی و مدل های هوش مصنوعی مرکب برای مطالعه سیستم های پیچیده می تواند کارآمد باشد. به طوری که بیشتر مطالعات در حیطه هوش مصنوعی به این سمت سوق پیدا کرده اند. (Chen and Lin, 2006; Kadkhodaie-Ilkhchi, et al., 2009).

دشت تسوج یکی از دشتهای حوضه دریاچه ارومیه محسوب می شود که شدیداً با بحران کاهش سطح آب زیرزمینی مواجه است (ندیری و همکاران، ۱۳۸۹) و با وجود مطالعات فراوانی مانند مطالعات تفصیلی و ژئوفیزیک که در سالهای اخیر در این دشت صورت گرفته است هنوز نیاز مبرم به شناخت پارامترهای هیدروژئولوژیکی برای مدیریت منابع آب دارد. لذا در این تحقیق سعی گردید که با استفاده از داده های ژئوفیزیکی مرتبط با قابلیت انتقال، اقدام به برآورد این پارامتر با استفاده از مدل های هوش مصنوعی شود. هدف این تحقیق، مقایسه کارایی روشهای فازی، شبکه های عصبی مصنوعی و نوروفازی و استفاده از مدل های هوش مصنوعی مرکب برای برآورد مقدار قابلیت انتقال در دشت تسوج می باشد.

یکی از مهمترین اهداف مدل سازی جریان آب زیرزمینی پیش بینی رفتار آبخوان می باشد که انجام این مدل سازی مستلزم شناخت دقیق پارامترهای هیدروژئولوژیکی آبخوان است. قابلیت انتقال (T) که از حاصل ضرب هدایت هیدرولیکی (K) در ضخامت آبخوان بدست می آید یکی از این پارامترهای آبخوان است که بسیاری از خصوصیات جریان آب در محیط های متخلخل به مقادیر این پارامتر بستگی دارد. به علاوه، اندازه گیری این پارامتر در آزمایشگاه و صحرا بسیار پرهزینه و وقت گیر است. این پارامتر در آزمایشگاه به طور غیرمستقیم و با تعیین هدایت هیدرولیکی و با در دست داشتن ضخامت آبخوان و در صحرا به طور مستقیم به دست می آید. با توجه به اهمیت این پارامتر روشهای بسیار متنوعی برای بدست آوردن این پارامتر در صحرا و آزمایشگاه توسعه پیدا کرده است. روشهای صحرائی تعیین قابلیت انتقال و یا هدایت هیدرولیکی شامل آزمایشهای پمپاژ، اسلاگ تست^۱ و آزمایش ردیابی می باشد. تاکنون سه روش متفاوت برای تعیین این پارامتر توسط اسلاگ تست (Bouwer and Rice, 1976; Bouwer, 1989; Hvorslev, 1951; Cooper et al., 1967) و چندین روش معمول برای آزمایشهای پمپاژ (Theis, 1935; Chow, 1952; Cooper and Jacob, 1946; Neuman, 1972) ارائه شده است.

برای تعیین این پارامتر در آزمایشگاه نیز تاکنون پنج روش مشهور شامل (Hazen (1892), Shepherd (1989), Fair and Hatch (1933), Alyamani and Sen (1993) شده است. (Sperry and Peirce (1995) پس از ارزیابی توانایی این روشهای آزمایشگاهی و فرمول های تجربی ارائه شده، چنین نتیجه گرفتند که به جز برای محیطهای دارای ذراتی با اشکال بسیار نامنظم، بهترین روش مربوط به فرمول تجربی (Hazen (1892) است و در حالت کلی فرمول تجربی (Alyamani and Sen (1993) به نتایج واقعی نزدیکتر می باشد. تمام روشهای اخیر حاصل حل معادلات حاکم بر جریان آب زیرزمینی با روشها و با شرایط مرزی و قیود متفاوت یا فرمول های تجربی هستند. با توسعه مدل های هوش مصنوعی در علوم هیدرولوژی، روشهای متنوعی برای تعیین پارامترهای هیدروژئولوژیکی توسعه پیدا کرده است. از جمله این روشها می توان به روشهای متنوع بهینه سازی (الگوریتم ژنتیک، الگوریتم بهینه سازی جامعه ذرات، کلونی مورچه و کلونی مورچه ترکیبی با شبیه سازی آنیلینگ^۲) و روشهای تخمین گری مانند فازی، شبکه های عصبی مصنوعی و نوروفازی اشاره کرد. اخیراً مطالعات فراوانی بر روی مقایسه کارایی روشهای هوش مصنوعی در برآورد پارامترها یا پیش بینی پدیده های هیدرولیکی انجام گرفته است. از آن

۲- مواد و روشها

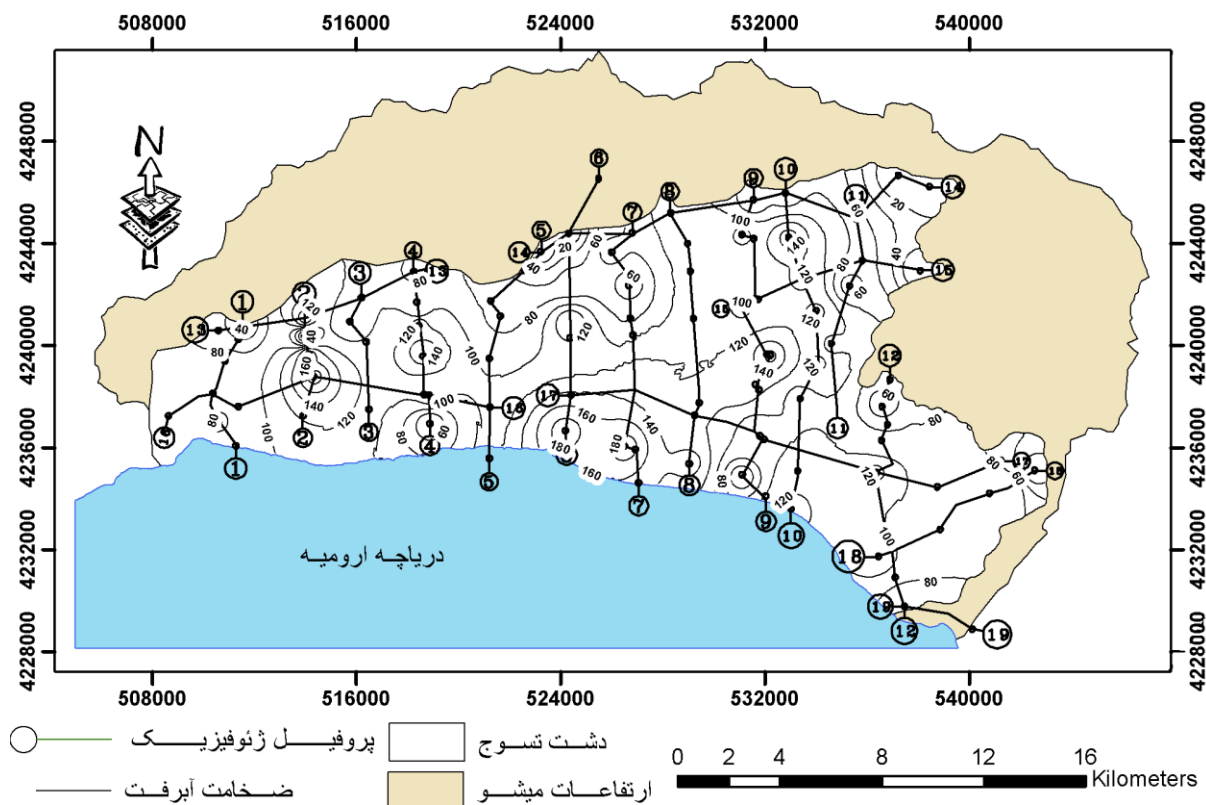
۲-۱- منطقه مورد مطالعه

آذرین، دگرگونی و رسوبی به چشم می‌خورد و در این گستره سازندهای زمین شناسی 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. از مهمترین این گسلها می‌توان گسل تسوج، قزلبه و انگشتجان را نام برد.

۲-۲- تجزیه و تحلیل داده

در محدوده دشت تسوج ۱۴۶ چاه بهره برداری مجاز وجود دارد که در بیشتر این چاهها آزمایش پمپاژ پله‌ای توسط امور آب شهرستان تسوج و سازمان نظام مهندسی استان آذربایجان شرقی و در پنج حلقه از این چاهها آزمایش پمپاژ با دبی ثابت توسط سازمان آب منطقه‌ای آذربایجان شرقی انجام گرفته است. تعداد معدودی از این چاهها که مقادیر قابلیت انتقال در آنها از دقت کمی برخوردار بود براساس لاگ چاهها و داده‌بندی آنها از روی مقادیر هدایت هیدرولیکی تجربی ارائه شده توسط Todd and Mays (2005) برای خاک های مختلف و نتایج مطالعات ژئوفیزیک تصحیح یا حذف گردید.

دشت تسوج در فاصله حدود ۱۰۰ کیلومتری شمال غرب شهر تبریز قرار گرفته است (شکل ۱). حوضه مورد مطالعه مساحتی بالغ بر ۵۵۹ کیلومتر مربع را در بر گرفته است که دشت تسوج تنها ۲۵۶ 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، از شرق به شبستر و از غرب به سلماس محدود شده است. بلندترین نقطه منطقه در کوه علمدار دارای ارتفاع ۳۱۱۳ متر از سطح دریا است و ارتفاع منطقه در ساحل دریاچه ۱۲۷۴ متر می‌باشد. میزان متوسط سالانه ریزشهای جوی در ایستگاه تسوج ۲۳۲/۷ میلی‌متر در سال در طول بازه زمانی ۱۳۷۹-۱۳۸۸ گزارش شده است. اقلیم منطقه نیمه خشک سرد می‌باشد و درجه حرارت حوضه در ایستگاه تسوج بین 11°C - و 33°C درجه سانتی‌گراد متغیر می‌باشد. براساس زون‌بندیهای زمین‌ساختی در ایران، محدوده مطالعاتی تسوج در ادامه شمال باختری زون زمین‌ساختی ایران مرکزی و زون تکتونیکی سندج - سیرجان و جنوب واحد زمین‌ساختی البرز - آذربایجان قرار دارد. به طور کلی تنوع سازندها در منطقه بسیار زیاد و هر سه گروه سنگهای



شکل ۱- موقعیت منطقه مطالعاتی و پروفیل ژئوفیزیکی و خطوط هم ضخامت آبرفت

بر اساس مطالعات ژئوفیزیک انجام گرفته در این دشت، داده‌های مقاومت ظاهری، نقشه هم ضخامت رسوبات آبرفتی در دسترس است (مهندسين مشاور صحراکاو، ۱۳۸۷). مقاومت ظاهری دارای دو مؤلفه اصلی مقاومت عرضی (R_T) و مقاومت طولی (R_L) می‌باشد که به ترتیب تغییرات هیدروژئولوژیکی عمقی و جانبی را نشان می‌دهد. بنابراین مقاومت عرضی با مقادیر قابلیت انتقال مرتبط است (Maillet, 1947; Harb et al, 2010) و از طرفی با توجه به ارتباط مقادیر مقاومت عرضی با هدایت الکتریکی (EC) می‌توان EC را نیز از پارامترهای مرتبط با مقادیر قابلیت انتقال دانست (Valcarce and Rodríguez, 2004). لذا بر این اساس، ورودی مدل‌های به کار رفته عبارت از مقاومت عرضی، ضخامت رسوبات آبرفتی (B)، موقعیت جغرافیایی و هدایت الکتریکی (EC) بودند. جدول ۱ نشانگر خصوصیات آماری پارامترهای ورودی است. با توجه به این که مدل‌های هوش مصنوعی عموماً به داده‌های 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 (۱) مبدأ طول و عرض جغرافیایی به X_{min} و Y_{min} منطقه مطالعاتی انتقال و تبدیل به پارامتری به نام O گردید.

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

در این تحقیق برای مدل‌های فازی، نوروفازی، و شبکه‌های عصبی مصنوعی داده‌های ورودی و هدف به دو دسته آموزش و آزمایش تقسیم گردید. به طوری که برای ۱۰۹ داده مرحله آموزش و ۲۵ داده برای مرحله آزمایش استفاده شد.

۳-۲- مدل‌های هوش مصنوعی مرکب

در این تحقیق برای استفاده همزمان از کارایی مدل‌های هوش مصنوعی مختلف مدل‌های هوش مصنوعی مرکب استفاده شده است. به طوری که روشهای فازی، شبکه‌های عصبی مصنوعی و نوروفازی برای برآورد قابلیت انتقال در دشت تسوج استفاده شدند و الگوریتم بهینه‌سازی جامعه ذرات برای ترکیب نتایج این مدل‌ها

بوسیله وزن‌دهی برای ایجاد مدل هوش مصنوعی مرکب (CM) برای برآورد قابلیت انتقال به کار گرفته شده است که در زیر به توصیف کلی این روشها پرداخته می‌شود:

۲-۳-۱- منطق فازی^r (FL)

اساس تئوری فازی برای اولین بار توسط زاده در سال ۱۹۶۵ معرفی گردید و در سالهای اخیر توانایی بالایی در کاهش خطای برآوردی نسبت به روش احتمالاتی نشان داده است. روش فازی روشی مناسب جهت کاهش خطای برآوردی و انسانی نسبت به تئوری‌های قابل اعتماد دیگر ارائه کرده است (Nikravesh and Aminzadeh, 2003). داده‌های هیدروژئولوژیکی عموماً دارای خطای برآوردی ذاتی است و داده‌هایی صریح و بدون خطا به حساب نمی‌آید. برای مثال، به دست آوردن قابلیت انتقال از آزمایش پمپاژ دارای خطایی غیر قابل اغماض است. لذا این روش می‌تواند به عنوان روشی کارا در کاهش این خطا و برآورد دقیق پارامترهای هیدروژئولوژیکی محسوب شود.

هر سیستم فازی شامل سه بخش اصلی است: الف) فازی کردن داده‌ها که این عمل با تعریف تابع عضویت انجام می‌شود، ب) ایجاد ارتباط بین ورودی و خروجی که این کار نیز با یک سری قوانینی مانند اگر آنگاه (if-then) انجام می‌شود، ج) مرحله آخر، بررسی سیستم است که به دو روش ممدانی یا ساگنو قابل اجراست. تفاوت این دو روش در خروجی آنهاست که در روش ساگنو بر خلاف روش ممدانی تابع عضویت خروجی سیستم فازی به صورت ثابت یا رابطه خطی است که توسط روش دسته بندی به دست می‌آید.

۲-۳-۲- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی یک سیستم پردازشگر اطلاعات توده‌ای هستند که به صورت موازی قرار گرفته‌اند و عملکردی شبیه شبکه عصبی مغز انسان دارند (Hopfield, 1982). اصول زیر نشانگر اساس شبکه‌های عصبی مصنوعی می‌باشند:

جدول ۱- خصوصیات آماری پارامترهای ورودی

پارامتر	واریانس	انحراف از معیار	متوسط	بیشینه	کمینه
O (m)	۴۱۰۶۸۹۹۴	۶۴۰۸/۵۰	۲۶۰۲۹/۲	۳۶۹۹۱/۰۸	۱۱۰۷۲/۱۹
EC ($\mu\text{moh/cm}$)	۲۳۷۴۷۰/۳	۴۸۷/۳۰	۱۶۰۳/۴۲	۳۱۵۳/۶۷	۷۰۰
R_t (Ohm-m)	۱۶۸۸۶۰۲	۱۲۹۹/۴۶	۲۵۵۱/۲۰	۵۰۷۰/۵۴	۶۲۵/۰۸
B (m)	۳۸۹/۶۴	۱۹/۷۳	۱۰۷/۳۶	۱۸۲/۳۹	۴۴/۲۹
T (m^2/d)	۱۸۷۴/۲	۴۳/۲۹	۸۴/۹۷	۲۱۵	۱۳/۱

۲-۳-۳- روش نوروفازی^۹ (NF)

این روش در حقیقت ترکیبی از روش فازی و شبکه عصبی مصنوعی می‌باشد و از مزایای هر دو روش استفاده می‌کند. به طوری که از شبکه عصبی مصنوعی برای تعیین قوانین و از فازی برای تعیین توابع عضویت استفاده می‌شود. در این روش شبکه عصبی مصنوعی به جای بهینه کردن وزنها، قوانین فازی را بهینه می‌کند. در روش نوروفازی تنها می‌توان از روش فازی ساگو که خروجی آن ثابت یا خطی است، سود جست.

۲-۳-۴- الگوریتم بهینه‌سازی جامعه ذرات^{۱۰} (PSO)

بهینه‌سازی جامعه ذرات از روشهای بهینه‌سازی فراکوشی است که اخیراً در مسائل علوم مهندسی آب به طور وسیعی استفاده شده است. روش بهینه‌سازی PSO اولین بار توسط Kennedy and Eberhart (1995) معرفی گردید. اساس PSO شبیه‌سازی یک رفتار دسته جمعی است که از آن برای نشان دادن حرکت گروه پرندگان و ماهیان استفاده می‌شود. اساس کار PSO بر این موضوع استوار است که در هر لحظه، ذره مکان خود را در فضای جستجو با توجه به بهترین مکانی که تاکنون در آن قرار گرفته و بهترین مکانی که در کل همسایگی وجود دارد، تنظیم می‌کند.

در یک فضای جستجوی D بعدی، سرعت و موقعیت هر ذره با روابط (۳ و ۲) تعیین می‌شود (Shi and Eberhart, 1999):

$$V_{i,d}^{n+1} = w.V_{i,d}^n + c_1 r_{1,i,d}^n (pbest_{i,d}^n - x_{i,d}^n) + c_2 r_{2,i,d}^n (gbest_{i,d}^n - x_{i,d}^n) \quad (2)$$

$$X_{i,d}^{n+1} = X_{i,d}^n + V_{i,d}^{n+1} \quad (3)$$

که در آن $V_{i,d}^n$ سرعت ذره i در تکرار فعلی، $V_{i,d}^{n+1}$ سرعت ذره i در تکرار جدید، $x_{i,d}^n$ موقعیت کنونی ذره، $x_{i,d}^{n+1}$ موقعیت ذره در تکرار جدید، $pbest$ بهترین موقعیتی که ذره i تاکنون اختیار کرده است، $gbest$ بهترین موقعیت بهترین ذره (بهترین موقعیتی که تمام ذرات تاکنون اختیار کرده‌اند)، $d=1,2,\dots,D$ ، که d اندازه ابعاد فضای جستجو می‌باشد؛ w ، اینرسی وزنی^{۱۱} نامیده می‌شود؛ n شماره تکرار می‌باشد، $r_{1,i,d}$ و $r_{2,i,d}$ اعداد تصادفی در محدوده (۰،۱) با توزیع یکنواخت هستند که برای حفظ تنوع و گوناگونی گروه به کار می‌روند. c_1 و c_2 دو ضریب ثابت و مثبت می‌باشند که به ترتیب پارامترهای شناختی و اجتماعی خوانده می‌شوند.

۱- پردازش داده‌ها در واحدهای منفردی به نام نرون صورت می‌گیرد. ۲- سیگنال‌های بین نرون‌ها از طریق خطوط ارتباطی انتقال می‌یابند. ۳- وزن نسبت داده شده به هر خط ارتباطی نشانگر قدرت ارتباطی آن خط است. ۴- هر نرون به طور معمول دارای توابع فعال‌سازی^۴ و تبدیل‌گر برای تعیین سیگنال‌های خروجی از داده‌های ورودی شبکه می‌باشد.

ساختار شبکه‌های عصبی مصنوعی بوسیله الگوی ارتباط بین نرون‌ها، روش تعیین وزنه‌های ارتباطی و تابع انتقال، معرفی می‌شود. ساختار عادی یک شبکه عصبی مصنوعی، معمولاً از لایه ورودی، لایه‌های میانی (مخفی) و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. آخرین لایه یا لایه خروجی شامل مقادیر پیش‌بینی شده بوسیله شبکه می‌باشد و بنابراین خروجی مدل را معرفی می‌کند.

لایه‌های میانی یا مخفی که از نرون‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌هاست. تعداد لایه‌های مخفی و نرون‌ها در هر لایه مخفی به طور معمول بوسیله روش آزمون و خطا مشخص می‌شود. نرون‌های لایه‌های مجاور در شبکه به طور کامل با هم در ارتباط هستند. شبکه‌های عصبی مصنوعی به روشهای مختلفی مانند چگونگی ارتباط نرون‌ها و حرکت داده‌ها در شبکه دسته‌بندی می‌شوند (اصغری مقدم و همکاران، ۱۳۸۷). در این تحقیق، از شبکه پرسپترون چند لایه که یکی از شبکه‌های پیشرو^۵ (FFN) می‌باشد، استفاده شد که در این شبکه‌ها اطلاعات از ورودی به طرف خروجی حرکت می‌کنند. نرون‌های موجود در یک لایه به هم مرتبط نمی‌شوند بلکه نرون‌ها در یک لایه به لایه بعدی ارتباط می‌یابند. بنابراین خروجی یک نرون در یک لایه به سیگنالی که از لایه قبلی دریافت می‌کند، وزن تعیین شده برای آن و نوع تابع تبدیل‌گر بستگی دارد.

مراحل انجام شده در یک شبکه توسط الگوریتم‌های ریاضی متفاوت صورت می‌گیرد که مهمترین آنها عبارتند از: ۱- الگوریتم انتشار خطا به عقب^۶ (BP)، ۲- الگوریتم گرادیان مزدوج^۷ (CG)، ۳- الگوریتم لوبنرگ-مارکوارت^۸ (LM)، که از این میان الگوریتم LM کاراترین الگوریتم محسوب می‌شود (ASCE, 2000). اطلاعات بیشتری در مورد روش شبکه‌های عصبی مصنوعی را می‌توان در تحقیقات اخیر افرادی چون Maier and Dandy (2000) و Maier et al. (2010) یافت.

Haykin, 1991; Geman et al., 1992; Naftaly et al., 1997; Huang et al., 2001; Lim, 2005 and Chen and Lin, 2006; Kadkhodaie-Ilkhchi et al., 2009; Karimpouli et al., 2010) می‌توان اصول کلی آن را می‌توان به صورت زیر توضیح داد:

$$e[e_i^2] = E_i = e[(\hat{T}_i - T)^2] \quad (5)$$

با فرض وجود i سیستم پیش بینی $T_i, i=1, \dots, K$ بردار هدف و \hat{T}_1 خروجی هر سیستم و در نتیجه e_i برابر مقادیر مشاهداتی منهای محاسباتی خواهد بود و در رابطه فوق $e[\cdot]$ امیدریاضی است و متوسط خطا برای هریک از سیستم‌های هوش مصنوعی به صورت رابطه (۶) حساب می‌شود:

$$E_{avg} = 1/k \sum_{i=1}^k E_i = (1/k) \sum_{i=1}^k [e_i^2] \quad (6)$$

که در رابطه فوق k تعداد سیستم‌های استفاده شده، E_i خطای هر سیستم و E_{avg} متوسط خطای هر سیستم می‌باشد. لذا با اعمال روش متوسط‌گیری از بردار خروجی هر یک از سیستم پیش بینی \hat{T}_1 خروجی مدل هوش مصنوعی مرکب \hat{T}_{CM} به صورت رابطه ۷ خواهد بود:

$$\hat{T}_{CM} = 1/k \sum_{i=1}^k \hat{T}_i \quad (7)$$

بنابراین برای مربع خطای مدل هوش مصنوعی مرکب خواهیم داشت:

$$E_{CM} = e[(\hat{T}_{CM} - T)^2] = e[(1/k \sum_{i=1}^k \hat{T}_i - T)^2] = e[(1/k \sum_{i=1}^k e_i)^2] \quad (8)$$

با در نظر گرفتن نا معادله کاجی^{۱۲} در رابطه (۹) می‌توان نشان داد بر اساس رابطه (۱۰) مدل هوش مصنوعی مرکب کمترین خطا را نسبت به هر یک از مدل‌های استفاده شده خواهد شد.

$$(a_1 b_1 + a_2 b_2 + \dots + a_n b_n)^2 \leq (a_1^2 + a_2^2 + \dots + a_n^2) \times (b_1^2 + b_2^2 + \dots + b_n^2) \quad (9)$$

$$E_{CM} = e[(1/k \sum_{i=1}^k \hat{T}_i - T)^2] \leq (1/k) \sum_{i=1}^k [e_i^2] = E_{avg} \quad (10)$$

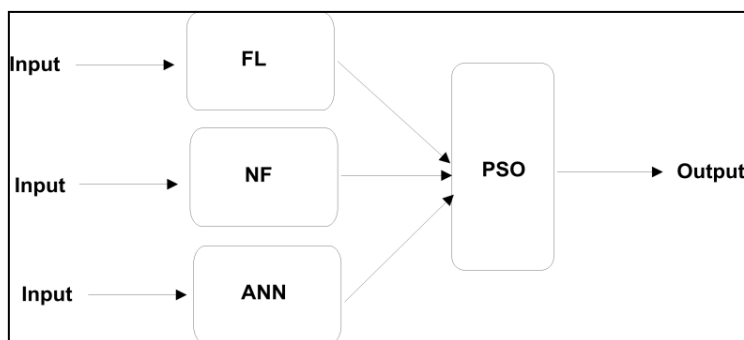
همانطور که گفته شد اینرسی وزنی، جهت کنترل تأثیر سوابق سرعت‌های پیشین بر روی سرعت کنونی مورد استفاده قرار می‌گیرد. بنابراین پارامتر w ، قابلیت گروه را در اکتشاف مناطق بهینه فراگیر و محلی، و استخراج جواب بهینه، تنظیم می‌کند. نتایج تجربی نشان داده که بهتر است در ابتدا، جهت بهبود اکتشاف فراگیر، مقدار زیادتری برای اینرسی وزنی w در نظر گرفته شود و به تدریج بهبود در استخراج راه حل بهینه، از مقدار آن کاسته شود (Shi and Eberhart, 1998, 1999). بنابراین می‌توان برای تعیین اینرسی وزنی از رابطه (۴) استفاده نمود:

$$w = w_{Max} \frac{(w_{Max} - w_{Min}) \times n}{iTer_{Max}} \quad (4)$$

که در آن w_{Max} میزان اولیه اینرسی وزنی، w_{Min} میزان نهایی اینرسی وزنی، $iTer_{Max}$ حداکثر تعداد تکرارها و n نیز شماره تکرار جاری می‌باشد. میزان مناسب پارامترهای c_1 و c_2 در رابطه (۲)، می‌تواند افزایش سرعت همگرایی و بهبود جواب محلی را نتیجه دهد.

۲-۳-۵- مدل هوش مصنوعی مرکب (CM)

یک مدل هوش مصنوعی مرکب از گروهی از مدل‌های هوش مصنوعی تشکیل می‌شود که خروجی‌های مدل‌ها را ترکیب کرده و نتایج بهتری نسبت به هر یک از مدل‌ها ارائه می‌دهد. شکل ۲ دیاگرام شماتیکی از مدل هوش مصنوعی مرکب ارائه شده در این تحقیق را نشان می‌دهد. روشهای مختلفی برای ترکیب مدل‌های هوش مصنوعی وجود دارد که روش متوسط‌گیری تجمعی ساده از مشهورترین آنها به حساب می‌آید (Naftaly et al., 1997, Chen and Lin, 2006). در این تحقیق برای ترکیب وزنی روشهای مختلف از روش الگوریتم بهینه سازی جامعه ذرات استفاده شده است. براساس مطالعات انجام گرفته در زمینه مدل‌های هوش مصنوعی مرکب (Bates and Granger, 1969;



شکل ۲- دیاگرام شماتیکی از مدل هوش مصنوعی مرکب ارائه شده

۳- نتایج و بحث

۳-۱- مدل فازی

همانگونه که در قسمت روش‌شناسی گفته شد از بین روشهای فازی به دلیل اینکه قابل مقایسه با روش نوروفازی باشد از روش ساگنو استفاده شد. اولین مرحله در این روش دسته‌بندی داده‌ها و تعیین توابع عضویت است که در این تحقیق از روش کاهش (subtractive) برای مدل‌سازی فازی استفاده شد که روشی کارا و مفید در دسته‌بندی داده‌ها و تعیین توابع عضویت و قوانین در تحقیقات اخیر بوده است (Chiu, 1994; Jarrah and Halawani, 2001). پارامتر اصلی در این روش دسته‌بندی برای تعیین دسته‌ها و قوانین اگر-آنگاه شعاع دسته بندی 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 (Chiu, 1994). بازده مدل فازی بستگی به تعیین شعاع بهینه دسته‌بندی دارد که بر اساس شکل ۳ مقدار بهینه آن ۰/۴ تعیین شد. بر این اساس ۷ قانون اگر-آنگاه و تابع عضویت تعیین شد. شکل ۴ نمونه‌ای از توابع عضویت داده‌های ورودی و قوانین را نشان می‌دهد.

به طوریکه σ و μ پارامترهای توزیع نرمال هستند و به ترتیب نشانگر متوسط و انحراف از معیار داده‌ها می‌باشند. تابع عضویت گوسی بر اساس متوسط و انحراف از معیار دسته‌ها ساخته می‌شوند. تابع عضویت خروجی مدل ساگنو تابعی است خطی که براساس ورودی‌ها ساخته می‌شود. برای مثال خروجی اولین تابع عضویت از چهار ورودی ایجاد می‌شود:

$$\text{Output MF1} = C_1 \times O + C_2 \times EC + C_3 \times R_t + C_4 \times R_t + C_5 \quad (12)$$

در رابطه فوق پارامترهای به ترتیب C_1, C_2, C_3, C_4 ضریب ورودی‌های O, EC, R_t, B 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.

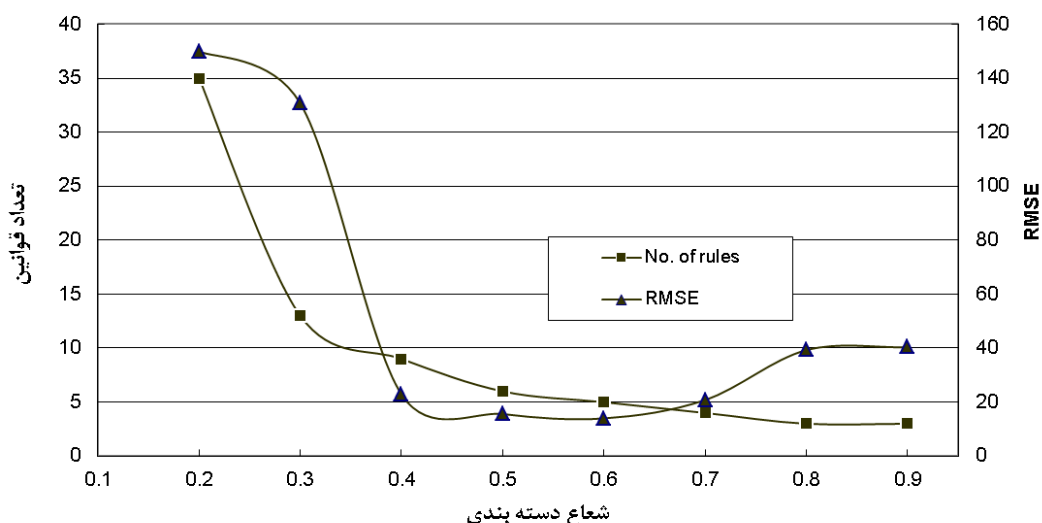
شکل ۴ به صورت گرافیکی نمونه‌ای از توابع عضویت را برای ورودی‌ها و خروجی را نشان می‌دهد و شکل ۵ نتایج مدل فازی را نشان می‌دهد.

۳-۲- نتایج مدل‌سازی توسط شبکه‌های عصبی مصنوعی

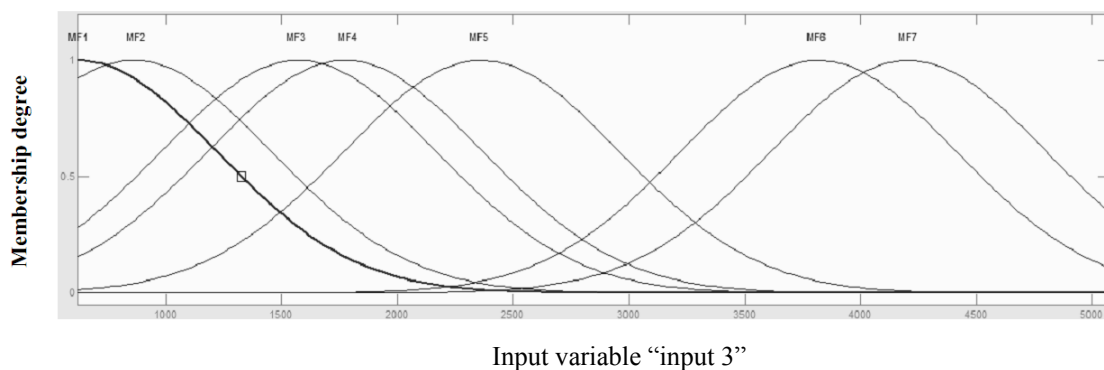
مدل بعدی استفاده شده برای پیش‌بینی هدایت هیدرولیکی، روش شبکه‌های عصبی مصنوعی است. به این منظور از شبکه چند لایه پرسپترون با الگوریتم LM استفاده شد. در این روش نیز شبیه روش فازی چهار ورودی شامل مقاومت عرضی (R_t), ضخامت رسوبات آبرفتی (B), موقعیت جغرافیایی (O) و هدایت الکتریکی (EC) به عنوان لایه ورودی استفاده شد.

توابع عضویت استفاده شده برای مدل‌سازی فازی مقادیر هدایت هیدرولیکی تابع گوسی بود که به داده‌های دسته بندی شده برازش داده شد. تابع گوسی $f(x)$ نشانگر توزیع نرمال داده‌ها است:

$$f(x) = \frac{e^{-\frac{(x-\mu)^2}{\sigma^2}}}{\sigma\sqrt{2\pi}} \quad (11)$$




شکل ۳- تغییرات تعداد قانونها و RMSE در مقابل تغییر مقدار شعاع دسته‌بندی




Input variable "input 3"

شکل ۴- نمونه ای از توابع عضویت متغیرها (R_t)



الف




ب

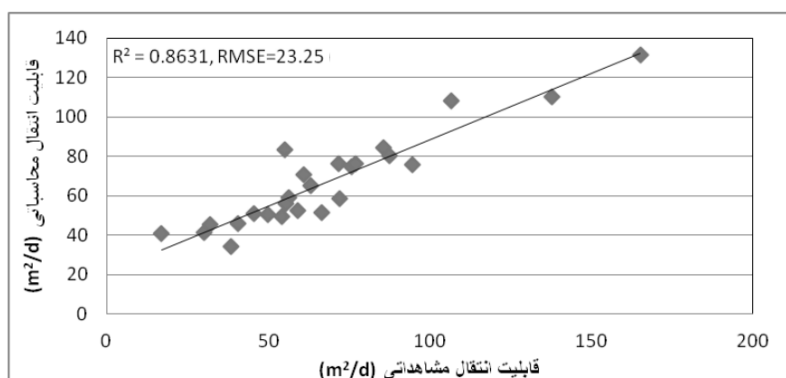
شکل ۵- نتایج مدل فازی، الف) مرحله آموزش، ب) مرحله آزمایش

تعداد نرون‌ها در لایه میانی و خروجی به ترتیب سه و یک می‌باشد. برای آموزش شبکه از الگوریتم LM استفاده شد که جزئیات آموزش و فرایند محاسبه آن توسط Boadu (1997;1998) و انجمن مهندسين عمران آمریکا ارائه شده است (ASCE, 2000). تابع تبدیل‌گر در لایه دوم سیگموئید تانژانتی (Tansig) و در لایه سوم خطی (Purlin) می‌باشد. تعداد دوره‌های آموزش ۵۱ بوده و مقادیر ضریب همبستگی و RMSE برای مرحله آموزش و آزمایش (صحت‌سنجی) در شکل ۶ ارائه شده است.

تعداد نرون‌ها در لایه میانی و خروجی به ترتیب سه و یک می‌باشد. برای آموزش شبکه از الگوریتم LM استفاده شد که جزئیات آموزش و فرایند محاسبه آن توسط Boadu (1997;1998) و انجمن مهندسين عمران آمریکا ارائه شده است (ASCE, 2000). تابع تبدیل‌گر در لایه دوم سیگموئید تانژانتی (Tansig) و در لایه سوم خطی (Purlin) می‌باشد. تعداد دوره‌های آموزش ۵۱ بوده و مقادیر ضریب همبستگی و RMSE برای مرحله آموزش و آزمایش (صحت‌سنجی) در شکل ۶ ارائه شده است.



الف



ب

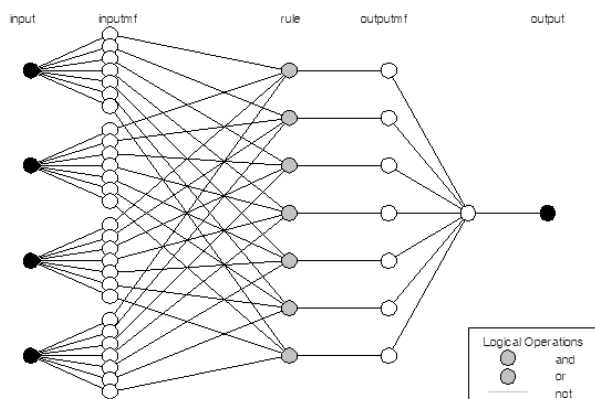
شکل ۶- نتایج مدل شبکه عصبی برای دو مرحله آموزش، آزمایش

۳-۳- نتایج مدل نوروفازی

مدل دیگری که در این تحقیق مورد استفاده قرار گرفت ترکیب مدل فازی و شبکه عصبی بود که نوروفازی نامیده می‌شود. در این مدل از شبکه‌های عصبی مصنوعی برای بهینه‌سازی مدل فازی استفاده می‌شود. در این روش نیز همانند روش فازی از روش دسته‌بندی کاهشی استفاده شد و برای بهینه کردن پارامترهای مدل از الگوریتم هیبرید استفاده شد.

۴-۳- نتایج مدل هوش مصنوعی مرکب

در این مرحله هدف ایجاد مدل مرکب با ضریب وزنی برای هر یک از مدل‌های به کار رفته می‌باشد که می‌تواند نتایج بهتری در پی داشته باشد. در این مرحله از روش الگوریتم بهینه‌سازی جامعه ذرات برای بهینه‌سازی و وزن دهی برای این سه مدل استفاده شد.




شکل ۷- ساختار شماتیک از سیستم فازی.

این الگوریتم ترکیبی از الگوریتم‌های حداقل مربعات (Least square) و گرادیان نزولی انتشار به عقب (Backpropagation gradient descent) می‌باشد. مدل ساگنوی بهینه شده با الگوریتم هیبرید پس از دو دوره آموزشی به مقدار بهینه رسید. شکل ۷ ساختار شماتیک سیستم نوروفازی را نشان می‌دهد. براساس نتایج بدست آمده از مدل نوروفازی (شکل ۸) و مقایسه نتایج مدل‌های دیگر مشخص می‌شود که مدل شبکه‌های عصبی مصنوعی کارایی بالاتری نسبت به دو مدل قبلی دارد.


Kennedy (1998) پارامترهای شتاب را برای اولین نسخه الگوریتم جامعه ذرات به عنوان پیش فرض، مقادیر $c_1 = c_2 = 2$ پیشنهاد کرده است، 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 (۰،۱) با توزیع یکنواخت هستند.

پس از مشخص شدن محدودیت‌های مسئله و تابع پناستی، به منظور انجام آنالیز حساسیت مدل الگوریتم جامعه ذرات ترکیب‌های مختلف از هر پارامتر در نظر گرفته شد. در این آنالیز با در نظر گرفتن مقادیر مختلف برای C_1 و C_2 (پارامترهای شناختی و اجتماعی)، W_{min} و W_{max} و بعد از ۱۰ بار اجرای مدل، بهترین مقادیر این پارامترها با توجه به کمترین مقدار تابع هدف به ترتیب ۱/۵ و ۲، ۰/۱ و ۰/۵ بدست آمد. البته پارامتر اینرسی وزنی حساسیت چندانی از خود نشان نداد. شکل ۹ آنالیز حساسیت پارامترهای شناختی و اجتماعی را نشان می‌دهد.

پس از شناخت پارامترهای مدل، اقدام به بهینه سازی و بدست آوردن وزن‌ها شد. بهترین جمعیت اولیه نیز ۲۰۰ انتخاب شد که در بهینه‌ترین حالت مقدار RMSE برای داده‌های آموزش برابر با ۱۰/۴۷ مترمربع بر روز بود. همانگونه که در رابطه (۱۴) نشان داده شده است، وزنهای خروجی مدل‌های فازی \hat{T}_{FL} ، نوروفازی \hat{T}_{NF} ، و شبکه عصبی \hat{T}_{ANN} به ترتیب ۰/۲۹۷، ۰/۲۹۲، و ۰/۴۱۹ به دست آمد.



الف




ب

شکل ۸- نتایج مدل نوروفازی، (الف) مرحله آموزش، (ب) مرحله آزمایش

بدین منظور تابع برازش به صورت رابطه (۱۳) تعریف می‌شود:

$$MSE_{CM} = \sum_{i=1}^k 1/k (w_1 \hat{T}_{1i} + w_2 \hat{T}_{2i} + w_3 \hat{T}_{3i} - T_i)^2 \quad (13)$$

این تابع مقدار خطای مدل مرکب را برای پیش بینی مرحله آموزش نشان می‌دهد، به طوری که w_1 ، w_2 و w_3 به ترتیب وزن مدل‌های فازی، نوروفازی، و شبکه عصبی مصنوعی و T_i مقادیر مشاهده‌ای و n تعداد داده‌های آموزشی (۱۰۹ نمونه) را نشان می‌دهد. الگوریتم جامعه ذرات همانند روش‌های بهینه سازی ابتکاری و هوش مصنوعی بهینه سازی نیاز به تعیین پارامترهای مناسب مدل دارد.



شکل ۹- آنالیز حساسیت پارامترهای اجتماعی و شناختی

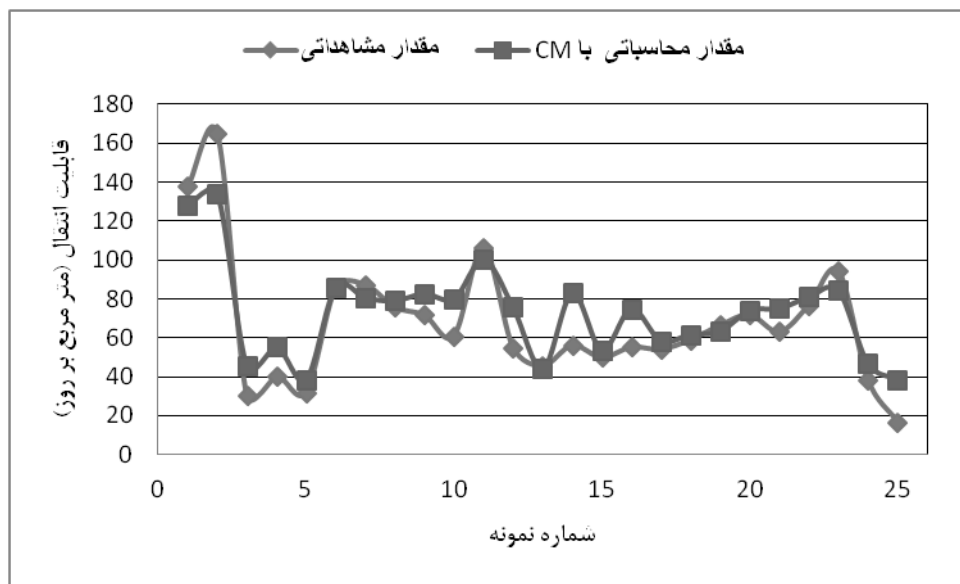
$$\hat{T}_{CM} = 0.297 \times \hat{T}_{FL} + 0.292 \times \hat{T}_{NF} + 0.419 \hat{T}_{ANN} \quad (14)$$

با به کارگرفتن وزنه‌های به دست آمده به صورت فرمول فوق برای داده‌های مرحله آزمایش، مقادیر پیش‌بینی شده برای مدل هوش مصنوعی مرکب ارائه شده بدست آمد، به طوری که مقدار RMSE و R^2 مدل برابر ۱۵/۲ و ۰/۹ می‌باشد. شکل ۱۰ نتایج نهایی را برای مدل فوق نشان می‌دهد. مقایسه نتایج مدل‌های مختلف با مدل CM در جدول ۲ ارائه شده است.

۴- نتیجه گیری

نتایج مدل هوش مصنوعی مرکب ارائه شده، شامل مدل‌های فازی، نوروفازی، و شبکه عصبی مصنوعی که توسط مدل الگوریتم جامعه ذرات همبستگی بین مقادیر مشاهداتی و محاسباتی قابلیت انتقال برقرار می‌شود، قابلیت بالایی در پیش‌بینی مقادیر قابلیت انتقال در آبخوانها دارد. نتایج مدل‌های فازی، نوروفازی، و شبکه عصبی مصنوعی بدست آمده نشان می‌دهد که نتایج دقیق‌تری در مرحله

آزمایش با استفاده از مدل شبکه‌های عصبی مصنوعی حاصل شد. به کمک وزنه‌های بهینه به دست آمده از الگوریتم جامعه ذرات برای سه مدل فوق (به ترتیب ۰/۲۹۷، ۰/۲۹۲، و ۰/۴۱۹) باعث افزایش کارایی مدل‌ها از $RMSE=23/25$ و $R^2=0/86$ به $RMSE=15/2$ و $R^2=0/9$ شد و با وجود داده‌های محدود به خصوص برای مدل شبکه‌های عصبی مصنوعی، مدل‌های مرکب می‌توانند روشی مناسب برای پیش‌بینی و برآورد پارامترهای هیدروژئولوژیکی باشند. لذا با توجه به هزینه‌های بالای آزمایشهای صحرایی پیش‌بینی قابلیت انتقال در آبخوانها می‌توان از مدل مرکب ارائه شده و با استفاده از داده‌های ژئوفیزیکی و هدایت الکتریکی 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، هتروژنیتهی 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 موثر باشد.



شکل ۱۰- نتایج مدل مرکب ارائه شده برای داده‌های مرحله آموزش

جدول ۲- مقایسه نتایج مدل‌های مختلف با مدل CM

مدل				معیار ارزیابی	مرحله
۰/۹۰۶۷	۰/۹۱۸	۰/۹۱۸۱	-	R^2	آموزش
۱۴/۰۱	۱۳/۴۸	۱۲/۵۳	-	RMSE	
۰/۷۶۲۴	۰/۸۶۳۱	۰/۷۴۲۴	۰/۹	R^2	آزمایش
۲۳/۵۳	۲۳/۲۵	۲۴/۹	۱۵/۲	RMSE	

- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology (2000). Artificial neural network in hydrology, part I and II. *J. Hydrol. Eng.* 5(2), pp. 115-137.
- Bates, J.M. and Granger, C.W.J. (1969). The combination of forecast. *Operations Research Quarterly* 20(4), pp. 451-468.
- Boadu, F.K. (1997). Rock properties and seismic attenuation: neural network analysis. *Pure and Applied Geophysics* 149(3), pp. 507-524.
- Boadu, F.K. (1998). Inversion of fracture density from field seismic velocities using artificial neural networks. *Geophysics* 63(2), pp. 534-545.
- Bouwer, H. (1989). The Bouwer and Rice slug test- An update. *Ground Water*, 27(3), pp. 304-309.
- Bouwer, H. and Rice, R. C. (1976). A slug test for determining hydraulic conductivity of unconfined aquifer with completely or partial penetrating wells. *Water Resource Research*, 12(3), pp. 423-438.
- Chen, C.H. and Lin, Z.S. (2006). A committee machine with empirical formulas for permeability prediction. *Computers and Geosciences* 32(4), pp. 485-496.
- Chiu, S. (1994). Fuzzy model identification based on cluster estimation. *Journal of Intelligent and Fuzzy Systems* 2(4), pp. 267-278.
- Chow, V. T. (1952). On the determination of transmissibility and storage coefficient from pumping test data. *Transactions, American Geophysical Union*, 33(3), pp. 397-404.
- 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(1), pp. 263-269.
- Cooper, H. H. and Jacob, C. E. (1946). A generalized graphical method for evaluation formation constants and summarizing well field history. *Transactions, American Geophysical Union*, 27(4), pp. 526-534.
- Fair, G. M. and Hatch, L. P. (1933). Fundamental factors governing the stream line flow of water through sand. *Journal of American Water Works Association*. 25(11), pp. 1551-1565.
- Geman, S., Bienenstock, E. and Doursat, R. (1992). Neural networks and the bias/variance dilemma. *Neural Computation*, 4(1), pp. 1-58.
- 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), pp. 105-115.

- 1- Slug test.
- 2- Annealing simulation.
- 3- Fuzzy logic
- 4- Activation Function
- 5- Feedforward Network
- 6- Back Propagation Algorithm
- 7- Conjugate Gradient Algorithm
- 8- Levenberg-Marquardt
- 9- Neurofuzzy
- 10- Particle Swarm optimization
- 11- Inertia Weight
- 12- Cauchy's inequality

۵- مراجع

- اصغری مقدم، الف، ندیری، ع. و نورانی، و (۱۳۸۷). "مدل سازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی". مجله دانش کشاورزی. جلد ۱۸ شماره ۱.
- اصغری مقدم، الف، ندیری، ع. و فیجانی، الف. (۱۳۸۹). "استفاده از مدل‌های شبکه‌های عصبی مصنوعی و زمین‌آمار برای پیش‌بینی مکانی غلظت فلئورید". مجله دانش آب-خاک. سال ۱۹/۱ شماره ۲ ص ۱۴۵-۱۲۹.
- مهندسین مشاور صحراکاو، (۱۳۸۷). "مطالعات ژئوفیزیک دشتهای تبریز، تسوج و هادیشهر". سازمان آب منطقه‌ای آذربایجان شرقی.
- ندیری، ع، اصغری مقدم، الف. و فیجانی، الف. (۱۳۸۷). "پیش‌بینی مکانی هدایت هیدرولیکی در محدوده متروی شهر تبریز". دوازدهمین همایش انجمن زمین شناسی ایران، اهواز ۳۰ بهمن تا ۲ اسفند.
- ندیری، ع. و اصغری مقدم، الف. (۱۳۸۹). "استفاده از روشهای آماری چند متغیره در مطالعه فرآیندهای هیدروشمیایی آبخوانها، مطالعه موردی: دشت تسوج". چهاردهمین همایش انجمن زمین ایران و بیست و هشتمین گردهمایی علوم زمین، دانشگاه ارومیه ۲۵ تا ۲۷ شهریور.
- Abbaspour, K.C., Schulin, R. and Van Genuchten, M. (2001). Estimating unsaturated soil hydraulic parameters using ant colony optimization. *Advances in Water Resources*, 24(8), pp. 827-841.
- Alyamani, M. and Sen, Z. (1993). Determination of hydraulic conductivity from complete grain size distribution curves. *Ground Water*, 31(4), pp. 551-555.

- Li, Sh., Liu, Y. and Yu, H. (2006). Parameter Estimation Approach in Groundwater Hydrology Using Hybrid Ant Colony System. Lecture Notes in Computer Science, Springer Berlin.
- 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*, 49(3-4), pp.182–192.
- Maier H. R. , Jain, A., Dandy, G. C. and Sudheer, K.P. (2010). Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions. *Environmental Modelling & Software*, 25(8), pp. 891-909.
- Maier, H.R. and Dandy, G.C. (2000). Neural network for the prediction and forecasting water resources variables: a review of modeling issues and applications. *Environmental Modeling & Software*, 15(3), pp. 101-124.
- Maillet, R. (1947). The fundamental equations of electrical prospecting. *Geophysics*, 12(4), pp. 529-556.
- Mategaonkar, M. and Eldho, T.I. (2012). Groundwater remediation optimization using a point collocation method and particle swarm optimization. *Environmental Modelling & Software*, 32, pp. 37-48.
- Myers, D. E. (1991). Pseudocross-variograms, positive- definiteness and cokriging. *Mathematical Geology*, 23(6), pp. 805-816.
- Naftaly, U., Intrator, N. and Horn, D. (1997). Optimal ensemble averaging of neural networks. *Computation in Neural Systems*, 8(3), pp. 283–296.
- Neuman, S. P. (1972). Theory of flow in unconfined aquifers considering delayed response of water table, *Water Resources Research*, 8(4), pp. 1031-1045.
- Nikraves, M. and Aminzadeh, F. (2003). Soft Computing and Intelligent Data Analysis in Oil Exploration. Part1: Introduction: Fundamentals of Soft Computing. Elsevier, Berkeley, USA, 744 p.
- Samani, N., Gohari-Moghadam, M. and Safavi, A. A. (2007). A simple neural network model for the determination of aquifer parameters. *Journal of Hydrology*, 340(1-2), pp. 1-11.
- Shepherd, R. G. (1989). Correlations of permeability and grain size. *Ground Water*, 27(5), pp. 633-638.
- Shi Y. and Eberhart R. (1999). Empirical study of particle swarm optimization, *Proceeding IEEE International Congress Evolutionary Computation*, Washington, DC., USA, pp. 1945-1950.
- Haykin, S. (1991). Neural Networks: A Comprehensive Foundation. *Englewood Cliffs, NJ*, 842p.
- Hazen, A. (1892). Some physical properties of sands and gravels. *Massachusetts State Board of Health 24th Annual Report*. pp. 539-556.
- Hopfield, J. J. (1982). Neural network and physical systems with emergent collective computational abilities. *Proc. Nat. Academy of Scientists*, 79, pp.2554-2558.
- Huang, Y., Gedeon, T.D. and Wong, P.M. (2001). An integrated neural-fuzzy- genetic-algorithm using hyper-surface membership functions to predict permeability in petroleum reservoirs. *Engineering Applications of Artificial Intelligence* 14(1), pp.15–21.
- Huang, Z. and Williamson, M.A. (1996). Artificial neural network modeling as an aid to source rock characterization. *Marine and Petroleum Geology*, 13(2), pp. 227–290.
- 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*. 49p.
- Jarrah, O.A. and Halawani, A. (2001). Recognition of gestures in Arabic sign language using neuro-fuzzy systems. *Artificial Intelligence* 133(1-2), pp. 117–138.
- Kadkhodaie-Ilkhchi, A., Rezaee, M. R. and Rahimpour-Bonab, H. (2009). A committee neural network for prediction of normalized oil content from well log data: An example from South Pars GasField, Persian Gulf. *Journal of Petroleum Science and Engineering*, 65(1-2), pp. 23-32.
- Karimpouli, S., Fathianpour, N. and 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*, 73(3-4), pp. 227–232.
- Kennedy, J. (1998). The behavior of particles. In: Porto VW, Saravanan N, Waagen D and Eiben AE (eds) *Evolutionary Programming VII*, Springer, pp. 581-590.
- Kennedy, J., and Eberhart R. (1995). Particle Swarm Optimization. In: *Proceedings of the International Conference on Neural Networks, Perth, Australia, IEEE, Piscataway*.
- Li, Sh. and Liu, Y. (2005). Parameter Identification Procedure in Groundwater Hydrology with Artificial Neural Network. *Advances in Intelligent Computing*, Springer Berlin, 971p.

- Theis, C. V. (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(2), pp. 519-524.
- Todd, D. K. and Mays, L. W. (2005). *Groundwater Hydrology*. Wiley, 3 edition. 656 p.
- Valcarce, R. M. O. and Rodríguez, W. M. (2004). Resolution power of well log geophysics in karst aquifers. *Journal of Environmental Hydrology*. 12, pp. 1-7.
- Shi, Y. and Eberhart R. (1998). A modified Particle Swarm Optimizer, *Proceeding of the 1998 IEEE Conference on Evolutionary Computation*. AK, Anchorage.
- Shiri, J. and Kişi, Ö. (2011). Comparison of genetic programming with neuro-fuzzy systems for predicting short-term water table depth fluctuations. *Computers & Geosciences*, 37(10), pp. 1692-1701
- 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(2), pp. 892-898.