

جغرافیا و توسعه شماره ۴۳ تابستان ۱۳۹۵

وصول مقاله: ۱۳۹۴/۰۱/۱۸

تأیید نهایی: ۱۳۹۴/۱۲/۰۸

صفحات: ۱۷۰-۱۵۹

## مقایسه‌ی مدل استنتاج فازی و شبکه‌ی عصبی مصنوعی در برآورد عمق سنگ کف آبخوان مطالعه‌ی موردی: خراسان جنوبی - آبخوان بیرجند

دکتر عباس خاشعی سیوکی<sup>۱</sup>، حمید کاردان مقدم<sup>۲</sup>

### چکیده

آب زیرزمینی یکی از مهمترین منابع آب در مناطق خشک و نیمه‌خشک است. با توجه به کاهش سطح آب زیرزمینی بر اثر برداشت غیرمجاز در بیشتر دشت‌های ایران، دبی چاهها پس از مدت کوتاهی به میزان زیادی کاهش یافته و این مهم لزوم برنامه‌ریزی منابع آب را مورد توجه قرار می‌دهد. تعیین ضخامت آبرفت و نوع مصالح تشکیل‌دهنده‌ی آبخوان‌ها یکی از موارد ضروری جهت برنامه‌ریزی برای توسعه‌ی شهر و طراحی زیرساخت‌های آن می‌باشد. با توجه به اهمیت عمق برآورد سنگ کف آبخوان‌ها جهت برآورد حجم و برنامه‌ریزی منابع آب در این تحقیق کارایی مدل‌های شبکه‌ی عصبی مصنوعی و سیستم‌های استنتاج فازی عصبی در میزان عمق سنگ کف و پهنه‌بندی آن در بخش‌های مختلف آبخوان مورد بررسی قرار گرفت. در این تحقیق از پارامترهای طول و عرض جغرافیایی، شوری، تراز سطح آب و زمین به عنوان ورودی‌ها استفاده شد و تلاش شد تا مدل مناسب برای پیش‌بینی سنگ کف تعیین گردد. نتایج این مطالعه نشان داد که مدل شبکه‌ی عصبی مصنوعی با ضریب تبیین ۰/۸۳۵ و میانگین مجذور خطای ۴۹/۸۸ متر با ورودی‌های تراز آب زیرزمینی، طول و عرض جغرافیایی دقت بالاتری نسبت به مدل‌های نروفازی در برآورد عمق سنگ بستر دارد. کلیدواژه‌ها: ضخامت آبرفت، شبکه‌ی عصبی مصنوعی، عمق سنگ کف، استنتاج فازی عصبی، پیش‌بینی.

## مقدمه

همواره در حوضه‌های آبریز تعیین حد دقیق مرز آبخوان و ارزیابی پارامترهای هیدرودینامیکی آن بسیار پیچیده و هزینه بر بوده است. بی‌شک ضخامت رسوبات و عمق سنگ کف، یکی از پارامترهای تعیین کننده در رابطه با حل مسائل فوق خواهد بود لذا داشتن اطلاعات دقیق در رابطه با نوع و جنس رسوبات، ضخامت و تغییرات عمقی و جانبی آن‌ها امری لازم و ضروری است. یکی از چالش‌های فعلی دشت‌ها نوسانات سطح سفره‌ی آب زیرزمینی است که تحت تأثیر ضخامت آبرفت و عمق سنگ کف در چاه‌های مختلف شرایط متفاوتی خواهد داشت. هر گونه فعالیت در رابطه با خشک‌اندازی و تخلیه‌ی آب از سفره آب زیرزمینی باید متناسب با ضخامت رسوبات و عمق سنگ کف برنامه‌ریزی شود، تا از بروز مشکلات جدید جلوگیری شود. از طرف دیگر یکی از این پارامترها که حدود دقیق محدوده‌ی آبخوان را نشان می‌دهد لایه‌ی نفوذناپذیر یا سنگ کف است. برآورد دقیق عمق سنگ بستر به منظور استفاده مهندسی یکی از اهداف مهم در عملیات ژئوفیزیک می‌باشد. همچنین برآورد دقیق این پارامتر در تعیین محدوده‌ی حوزه‌های آبریز، حوزه‌های رسوبی، زمین لرزه و غیره حائز اهمیت است. کاربرد مطالعات ژئوفیزیک در آب‌های زیرزمینی جهت تخمین حجم و برآورد کیفیت و تهیه نقشه‌ها و سطح ایستابی انجام شده است.

شبکه‌های عصبی شاخه‌ای از هوش مصنوعی است که دارای الگوریتم‌های کامپیوتری در زمینه‌های متفاوت؛ طبقه‌بندی و تشخیص الگوها، تخمین پارامتر و غیره می‌باشند (مختاری، ۱۳۸۸: ۵۶۸). در سالیان اخیر، در پردازش اطلاعات برای مسائلی که برای آنها راه‌حل مشخصی موجود نیست، سیستم‌های هوشمند بطور فزاینده‌ای مورد توجه قرار گرفته‌اند که شبکه‌های عصبی مصنوعی و عصبی‌فازی از این مجموعه

می‌باشند. در مطالعات منابع آب، شبکه‌ی عصبی مصنوعی از سال ۱۹۹۲ توسط فرنچ مورد استفاده قرار گرفت و از آن پس بطور روزافزونی در این علوم به کار گرفته شد (French, 1992: 31).

یکی دیگر از سیستم‌های شبیه‌سازی هوش مصنوعی، سیستم استنتاج تطبیقی عصبی- فازی می‌باشد. تفسیر و مدل‌سازی داده‌های ژئوفیزیکی در زمینه‌های مختلف، با استفاده از سیستم‌های نوین طی سال‌های اخیر انجام گرفته است. اسلام و همکاران با استفاده از شبکه‌ی عصبی پرسپترون چند لایه با الگوریتم آموزش پس انتشار خطا، عمق و شعاع حفره‌های زیرزمینی را از روی داده‌های میکروگرانی- سنجی تخمین زدند (Eslam, 2001: 5). سیستم استنتاج تطبیقی فازی- عصبی اولین بار در سال ۱۹۹۳ توسط ژانگ معرفی شد. این سیستم ابزاری جهانی جهت تخمین توابع پیوسته حقیقی در دامنه‌ای محدود می‌باشد که می‌تواند در سطوح اطمینان مختلف دقت مقبولی داشته باشد.

در پیش‌بینی نوسانات سطح ایستابی با استفاده از الگوریتم‌های فراکاوچی می‌توان به این تحقیقات اشاره کرد. ایزدی و همکاران و خاشعی‌سیوکی و همکاران با استفاده از شبکه‌ی عصبی مصنوعی به پیش‌بینی سطح آب زیرزمینی در دشت نیشابور پرداخت و بهترین مدل حاصله را ارائه داد (ایزدی و همکاران، ۱۳۸۶: ۸؛ خاشعی‌سیوکی و همکاران، ۱۳۹۲: ۱۲). تحقیقاتی نیز به توانایی شبکه‌های عصبی مصنوعی در پیش‌بینی پارامترهای آبخوان مانند ضریب انتقال و آبدی و ویژه اشاره دارد (Samani et al, 2007: 11). در این تحقیقات تنها از مدل شبکه‌های عصبی استفاده شد و شبکه‌های فازی مورد بررسی قرار نگرفته است در صورتی که تحقیقات نشان داد که در پیش‌بینی پدیده‌های طبیعی مانند برآورد عملکرد محصول و یا تبخیر-تعرق مدل‌های فازی عصبی در بسیاری از موارد کارایی بهتری نسبت

نایاک و همکاران (۲۰۰۶) در تحقیقی نشان دادند که مدل شبکه‌ی عصبی قابلیت پیش‌بینی سطح آب زیرزمینی را برای مدت ۴ ماه می‌تواند ارائه دهد. سریکنت و همکاران (۲۰۰۹) در تحقیقی نشان دادند که استفاده از شبکه‌ی عصبی با مدل شبکه پس انتشار استاندارد و با آموزش الگوریتم LM با ضریب تبیین ۰/۹۳ و میانگین مجذور خطای ۵/۴ برای پیش‌بینی سطح آب زیرزمینی مناسب‌ترین مدل است (Nayak et al, 2006: 15).

کولوما و همکاران در سال ۲۰۱۳ با استفاده از دو روش (ERT) اشعه الکتریکی مقاومتی در شرایط خشک و آنالیز امواج سطحی (SASW) عمق سنگ بستر را در آبخوان با نتایج ژئوفیزیک مورد تحلیل قرار دادند. به منظور واسنجی از ۱۳۱ نقطه در منطقه استفاده و در پایان با در نظر گرفتن کمترین میزان خطا بین مقدار مشاهده شده و مقدار شبیه‌سازی شده روش SASW جهت تحلیل انتخاب شد (Coulouma et al, 2013:7).

امروزه با توجه به اعتبارات ریالی شرکت‌های آب منطقه‌ای عملیات ژئوفیزیک در قسمت‌هایی از آبخوان‌ها صورت می‌پذیرد که همواره با توجه به توسعه‌های صورت پذیرفته در محدوده‌ی یک آبخوان این عملیات جوابگو نبوده و همیشه مشکلات عدم موجودیت داده‌های سنگ‌بستر وجود داشته است. همچنین جهت تعیین ضرایب هیدرودینامیکی و بهینه‌سازی این پارامترها در سفره‌های آب زیرزمینی نیاز مبرم به عمق سنگ بستر وجود دارد. لذا عدم برآورد دقیق از عمق سنگ بستر همیشه سبب عدم قطعیت در نتایج خروجی را در اختیار کاربران و مدیران قرار می‌دهد. استفاده از الگوریتم‌های فراکوشی مثل شبکه‌های عصبی و فازی می‌توانند با هزینه و زمان کمتر نتایج قابل قبولی را به دست آورند. همچنین با توجه به اینکه در سالیان اخیر تحقیقی روی تعیین عمق سنگ

به شبکه‌ی عصبی دارد (احمدی‌زاده و همکاران، ۱۳۸۸: ۱۱۵؛ خاشعی‌سیوکی و همکاران، ۱۳۹۲: ۱۲).

کورتولوس<sup>۱</sup> و رازاک<sup>۲</sup> (۲۰۱۰) با استفاده از مدل‌های فازی و عصبی به بررسی ارتباط بین بارندگی، سطح آب و میزان دبی استحصالی در روزهای قبل با میزان دبی خروجی از آبخوان‌های کارستی در فرانسه پرداختند. آنها این عمل را با استفاده از داده‌های آماری روزانه انجام دادند و به این نتیجه رسیدند که مدل‌های فازی بهتر از مدل‌های عصبی می‌تواند دبی استحصالی از آبخوان‌های کارستی را پیش‌بینی کند، هرچند که این تحقیق برای آبخوان‌های آبرفتی انجام نشد (Kurtulus & Razack, 2010:11).

آفندی<sup>۳</sup> و واتنبر<sup>۴</sup> (۲۰۰۷) با استفاده از داده‌های روزانه سطح آب به کنترل افت آب زیرزمینی پرداختند. آنها با استفاده از مدل‌های ANFIS، RBF<sup>۵</sup> و LM<sup>۶</sup> سطح آب را بر اساس تأخیر زمانی از یک تا ۷ روز مورد بررسی قرار دادند (Affandi & wataniabe, 2007:10).

میرعربی و نخعی (۱۳۸۷) به بررسی دقت سیستم شبکه‌ی عصبی مصنوعی در پیش‌بینی نوسانات سطح آب زیرزمینی بر اساس اطلاعات پیژومتری در دشت بیرجند پرداختند و نتیجه گرفتند که با وارد کردن میزان بارندگی و برداشت با تأخیر زمانی ۲ ماهه دقت شبکه افزایش می‌یابد آنها از برداشت و بارندگی کل دشت، به عنوان ورودی مدل استفاده کردند در حالی که میزان بارندگی و تخلیه در قسمت‌های مختلف دشت با هم متفاوت است و تأثیر بسزایی بر نوسانات سطح آب دارد. تحقیقات متعددی از کاربرد مدل‌های شبکه‌ی عصبی در پیش‌بینی سطح آب زیرزمینی کم‌عمق با استفاده از پارامترهای هواشناسی و هیدروژئولوژی وجود دارد (میرعربی و نخعی، ۱۳۸۷: ۸).

1-Kurtulus  
2-Razack  
3-Affandi  
4-Watanabe  
5-Radial basis function  
6-Levenberg-marquardt

می‌شود. آبخوان اصلی بیرجند از نوع آزاد در بخش مرکزی و نیمه جنوبی محدوده تشکیل شده است. این گستره حدود ۳۵۴/۸ کیلومتر مربع از مجموع پهنه ۱۳۸۳ کیلومتر مربعی تحت پوشش رسوبات آبرفتی در محدوده‌ی بیرجند را شامل می‌گردد. سطح ایستابی در گستره‌ی آبخوان بین حداکثر ۱۳۹ متر در نواحی شمالی و شرقی تا حداقل ۷,۵ متر در جنوب غربی تغییر می‌کند. میانگین سطح ایستابی حدود ۷۳ متر برآورد می‌گردد. همچنین ضریب ذخیره‌ی متوسط آبخوان حدود ۵ درصد برآورد شده است. در فاصله سال‌های ۱۳۴۹ تا ۱۳۸۷، عملیات ژئوفیزیکی متعددی در دشت بیرجند انجام شده است که مشخصات مطابق با جدول (۱) (تعداد سونداژ و پروفیل و محدوده) و در شکل ۱ نیز موقعیت نقاط سونداژ و سنگ بسترارائه شده است.

بستر آبخوان صورت نگرفته و عمده تحقیقات در برآورد سطح آب زیرزمینی و حجم آبخوان بوده است لذا به منظور کاهش هزینه‌های اجرایی این مطالعه صورت گرفته است. نتایج بررسی منابع نشان داد که می‌توان با تحقیقی ۱- کارآیی الگوریتم‌های فراکاوشی را با داده‌های تجربی حاصل از عملیات ژئوفیزیک مقایسه نمود ۲- انواع الگوریتم‌های فراکاوشی را برای آبخوان بیرجند اجرا نموده و مدلی که کارآیی مناسب‌تری را دارد، پیشنهاد کرد.

### مواد و روش‌ها

#### - منطقه طرح

حوزه‌ی آبخیز بیرجند دارای وسعت ۳۱۵۵ کیلومتر مربع بوده، که ۱۰۴۵ کیلومترمربع دشت و بقیه را ارتفاعات تشکیل می‌دهد. دشت بیرجند طبق طبقه‌بندی‌های اقلیمی جزء مناطق خشک محسوب


جدول ۱: مشخصات عملیاتی ژئوفیزیکی دشت بیرجند

سال	تعداد سونداژ	تعداد پروفیل	محدوده‌ی بررسی
۱۳۵۰	۷۹	۱۱	بخشی از دشت بیرجند
۱۳۷۸	۲۹	۵	محدوده‌ی خوسف(شاهزیله) هدف تامین آب شرب شهر خوسف
۱۳۸۲	۷۱	۲۱	منطقه‌ی آبخیزداری جهاد (شرق بیرجند)
۱۳۷۷	۲۱	۴	دانشگاه آزاد
۱۳۸۰	۲۰	۴	قرارگاه
۱۳۸۷	۱۴۴	۱۵	کل دشت به منظور تکمیل پروفیل‌های قبلی

مأخذ: اداره مطالعات شرکت آب منطقه‌ای - ۱۳۸۵

آبخوان می‌رویم از این ضخامت کاسته می‌گردد، البته به استثناء منطقه‌ی شاهزیله که ضخامت مجدداً افزایش قابل توجهی پیدا می‌کند.

بر اساس نتایج عملیات ژئوفیزیک صورت گرفته نشانگر فاصله‌ی زیاد سنگ بستر تا سطح زمین در نواحی شرق آبخوان می‌باشد و هر چه به سمت غرب



شکل ۱: موقعیت نقاط سونداز و عمق سنگ کف تهیه شده از داده‌های ژئوفیزیک

تهیه و ترسیم: نگارندگان، ۱۳۹۴

قانون فازی "اگر- آنگاه" می‌باشد؛ می‌تواند به صورت زیر نشان داده شود: (Jang, 1997: 12).

قانون اول: اگر  $X$  برابر  $A_1$  و  $Y$  برابر  $B_1$  باشد آنگاه:

$$f_1 = p_1x + q_1y + r_1 \quad 1$$

قانون دوم: اگر  $X$  برابر  $A_2$  و  $Y$  برابر  $B_2$  باشد آنگاه:

$$f_2 = p_2x + q_2y + r_2 \quad 2$$

مقادیر  $p_1, p_2, q_1, q_2$  و وزن‌های اختصاص داده شده و  $r_1$  و  $r_2$  اختلاف امیدریاضی تابع  $f$  می‌باشند.

مدل فازی- عصبی اجازه می‌دهد که سیستم‌های فازی در مباحث آموزش پارامترها از الگوریتم آموزش برگشتی تطابقی<sup>۳</sup> استفاده نمایند. در این روش با استفاده از الگوریتم شیب نزولی خطا، مقدار خطا به سمت ورودی‌ها پخش شده و پارامترها تصحیح می‌شوند. این روش آموزش دقیقاً همانند روش پس انتشار خطای مورد استفاده در شبکه‌های عصبی مصنوعی است. طبق ساختار شبکه‌ی فازی- عصبی می‌توان خروجی کل ( $f$ ) را به صورت ترکیب خطی پارامترهای نتیجه به صورت زیر نوشت: (Jang, 1997: 12)

### سیستم استنتاج فازی- عصبی

سیستم استنتاج فازی- عصبی تطبیقی شامل شبکه‌های عصبی چندلایه‌ای می‌باشند و از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی<sup>۱</sup> بین فضای ورودی و خروجی استفاده می‌کنند. این سیستم با توجه به توانایی در ترکیب قدرت زبانی یک سیستم فازی با قدرت عددی یک شبکه‌ی عصبی، موفقیت‌های بسیاری را در مدل‌سازی و کنترل سیستم‌های پیچیده داشته است. این سیستم از نظر عملکرد مشابه سیستم‌های استنتاج فازی می‌باشد (Jang-1997PP:12).

سامانه‌ی استنتاج عصبی- فازی تطبیقی به کار گرفته شده در تحقیق حاضر، معادل مدل فازی از مرتبه سوگنو<sup>۲</sup> می‌باشد (Jang, 1997 PP:12).

الگوریتم هیبرید آموزشی که شامل کاهش شیب و روش حداقل مربعات می‌باشد؛ به صورت زیر قابل بیان خواهد بود. یک سیستم استنتاج فازی با دو متغیر ورودی  $X$  و  $Y$  با یک متغیر خروجی  $f$  در نظر گرفته می‌شود. مدل فازی مرتبه اول سوگنو، که شامل دو

$$f = \bar{w}_1 f_1 + \bar{w}_2 f_2 = (\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + (\bar{w}_2 x) p_2 + (\bar{w}_2 y) q_2 + (\bar{w}_1) r_1 + (\bar{w}_2) r_2 \quad (3)$$

(W با پاس تابع می‌باشد.)

که اگر تغییر کوچکی در شرایط محیطی شبکه رخ داد، شبکه بتواند با آموزش مختصر برای شرایط جدید نیز کارآمد باشد. در یک شبکه‌ی عصبی هر نرون بطور مستقل عمل می‌کند و رفتار کلی شبکه، برآیند رفتار نرونهاست. به عبارت دیگر نرون‌ها در یک روندهمکاری یکدیگر را تصحیح می‌کنند. این خصوصیت باعث افزایش تحمل‌پذیری خطا در سیستم می‌گردد. از رایج‌ترین الگوریتم‌های آموزش شبکه‌های عصبی مصنوعی می‌توان الگوریتم پس انتشار خطا را نام برد. پارامترهای مؤثر در مدل‌سازی شبکه‌های عصبی نقش اساسی دارند شامل تعداد دفعات آموزش شبکه، تعداد لایه‌های شبکه و تعداد نرون‌های لایه میانی می‌باشند. در حالت کلی در مدل‌سازی شبکه‌های عصبی، تکرار دفعات آموزش سبب بهبود نتایج شبیه‌سازی می‌شود و هر چه تعداد تکرار در آموزش شبکه بیشتر شود، خطای شبیه‌سازی (پیش‌بینی) در شبکه کمتر می‌شود. اما هنگامی که تعداد تکرارها از یک مقدار تجاوز کند، خطای آموزش شبکه نیز افزایش پیدا می‌کند بهترین تعداد تکرار آموزشی مقداری است که خطای هر دو دسته آزمایشی و آموزشی تا حد ممکن کمینه گردند (حمدزاده، ۱۳۸۱: ۱۱۵).

### مدل‌سازی سیستم استنتاج فازی - عصبی

به منظور برآورد عمق سنگ کف نخست به صورت آماری داده‌های حاصل از مطالعات ژئوفیزیک مورد تحلیل و داده‌های پرت با استفاده از توزیع نرمال و ترسیم از مجموعه داده‌ها حذف و سپس همگنی داده‌ها با استفاده از آزمون ساده ران تست<sup>۱</sup>، تأیید شد. برای استفاده از داده‌های مذکور در مدل‌های عصبی و فازی

به این ترتیب پیاده‌سازی یک سیستم فازی به گونه‌ای انجام می‌شود که قابلیت یادگیری داشته باشد. بنابراین مقادیر پارامترهای نتیجه شده با استفاده از روش کم‌ترین مجموع مربعات خطا به دست می‌آیند. با ترکیب این روش و روش پس انتشار خطا یک روش آموزشی ترکیبی ایجاد می‌شود که به صورت زیر عمل می‌کند: در هر دو آموزش هنگام حرکت رو به جلو خروجی‌های گره‌ها به صورت عادی تا لایه‌ی چهارم محاسبه می‌شوند و سپس پارامترهای نتیجه توسط روش‌های محاسبه خطا نظیر کم‌ترین مجموع مربعات خطا محاسبه می‌شوند.

در ادامه پس از محاسبه‌ی خطا در بازگشت رو به عقب نسبت خطا بر روی پارامترهای شرط پخش شده و با استفاده از روش شیب نزولی خطا مقدار آن‌ها تصحیح می‌شوند (مختاری، ۱۳۸۱: ۵۶۸). با توجه به توانمندی‌های زیاد مدل‌های شبکه عصبی در علوم مختلف از جمله علوم آب، این مدل‌ها در سالیان اخیر در گستره‌ی وسیعی به کار گرفته شده‌اند. همچنین این مدل‌ها به خوبی و با دقت بسیار بالایی ویژگی‌های هیدرولوژیک خاک را پیش‌بینی می‌کنند.

مدل شبکه‌ی عصبی قادرند رابطه‌ی میان ورودی‌ها و خروجی‌های یک سیستم فیزیکی را توسط شبکه‌ای از گره‌ها که همگی با هم متصل هستند، تعیین نمایند که در آن میزان فعالیت هر یک از این اتصالات توسط اطلاعات تاریخی تنظیم می‌شود (فرایند آموزش) و در نهایت مدل قادر خواهد بود قوانین مرتبط میان ورودی‌ها و خروجی‌ها را کشف نماید، هر چند قوانین غیر خطی و پیچیده باشند (Russell, 2003: 946)

قابلیت یادگیری در شبکه‌های عصبی، با استفاده از تنظیم پارامترهای شبکه انجام می‌گیرد. با این هدف

در این رابطه:  $X_i$ : مقدار استاندارد شده،  $X$ : مقدار واقعی و  $X_{min}, X_{max}$ : به ترتیب مقادیر حداقل و حداکثر داده‌ها می‌باشند. شش سناریوی ورودی برای داده‌ها تعریف و برای آموزش شبکه‌های عصبی و فازی آماده شدند (جدول ۲). این سناریوها جهت تعیین حداقل داده‌های ممکن جهت شبیه‌سازی عمق سنگ بستر انتخاب شدند و با توجه به همبستگی موجود بین داده‌های ورودی و عمق سنگ بستر این انتخاب صورت گرفت.

عصبی ابتدا داده‌ها به صورت تصادفی به سه قسمت تقسیم شدند. ۵۰ درصد از داده‌ها که ۳۲ داده برای آموزش، ۲۵ درصد معادل ۱۵ داده برای اعتبارسنجی<sup>۱</sup> و ۲۵ درصد باقیمانده معادل ۱۵ داده برای آزمایش مدل‌ها استفاده شد. به منظور افزایش کارایی مدل‌های عصبی و عصبی فازی، همه‌ی داده‌ها ابتدا به شکل نرمال بین دو عدد ۰/۱ و ۰/۹ استاندارد شدند سپس آنها به مقادیر اولیه بعد از استفاده در شبیه‌سازی برگشتند (Rahimi Khoob, 2008:5).

$$X_i = 0.8 \left( \frac{X - X_{min}}{X_{max} - X_{min}} \right) + 0.1 \quad :4$$

جدول ۲: سناریوهای مختلف برای پارامترهای ورودی به شبکه عصبی، عصبی فازی

پارامترها			سناریوهای مدل		
EC	ارتفاع سطح ایستابی	ارتفاع سطح زمین	UTM Y	UTM X	
			*	*	<b>A</b>
		*	*	*	<b>B</b>
*			*	*	<b>C</b>
	*		*	*	<b>D</b>
*	*	*			<b>E</b>
*		*			<b>F</b>

مأخذ: نتایج مطالعات، ۱۳۹۴

استفاده از شبکه عصبی- فازی دو روش منقطع‌سازی شبکه‌ای و خوشه‌بندی جزئی وجود دارد که تفاوت عمده‌ی آنها در انتخاب تابع عضویت ورودی می‌باشد (مختاری، ۱۳۸۱: ۵۶۸). در طراحی شبکه‌های ANFIS نتایج حاصل از توابع عضویت مختلف مانند: مثلثی، گوسی و زنگوله‌ای و نیز تعداد دو تا پنج تابع عضویت برای هر پارامتر بررسی شد. در این مطالعه از روش خوشه‌بندی انتخابی<sup>۴</sup> نیز استفاده شد. از آنجا که در این روش قبل از اعمال توابع فازی، ورودی‌ها دسته‌بندی می‌شود در بعضی از ورودی‌ها می‌تواند باعث بهبود کارایی شود (مختاری، ۱۳۸۱: ۵۶۸). از داده‌های استفاده شده در مرحله‌ی آزمایش برای

در این تحقیق برای اجرای مدل‌های شبکه عصبی و فازی از جعبه ابزار استاندارد شبکه عصبی و نروفازی در نرم‌افزار<sup>۱</sup> MATLAB<sup>۲</sup> استفاده شد. به منظور آموزش شبکه‌ی عصبی بایاس‌ها<sup>۳</sup> از مقادیر پیش‌فرض نرم‌افزار استفاده گردید. در مدل شبکه‌ی عصبی از مدل شبکه‌های عصبی پرسپترون چندلایه با الگوریتم آموزش پس انتشار خطا استفاده شد. همچنین از تابع سیگموئیدی Logsig به عنوان تابع انتقال در لایه‌ی میانی و خروجی استفاده شد. با استفاده از روش سعی و خطا تعداد نرون‌های لایه‌های مخفی به دست آمد. در محیط AnfisEdit نرم‌افزار MATLAB جهت

این مدل ۷۷/۸۴ متر می‌باشد. علت آن به تأثیری که شوری آب زیرزمینی در ایجاد خطا در تعیین سنگ کف در مطالعات ژئوالکتریک ایجاد می‌کند. غلظت املاح سبب انتقال جریان در آب می‌شود. در مطالعات ژئوفیزیک صورت گرفته در سطح آبخوان، شوری آب سبب تغییر مسیر جریان شده و دقت تعیین عمق سنگ کف پایین می‌آورد. بررسی‌ها نشان داد که بعد از سناریوی d سناریوی b یعنی ورودی طول و عرض جغرافیایی و ارتفاع سطح زمین از دقت مناسب‌تری در برآورد تراز سنگ کف برخوردار است. میزان دقت در برآورد سنگ کف به ترتیب برای سناریوهای f و c و a کاسته می‌شود. این نتایج با نتایج مطالعات خاشعی سیوکی و سربازی (۲۰۱۳) مطابقت دارند. آنها در تحقیقشان طول، عرض جغرافیایی و غلظت کلر را به عنوان مناسب‌ترین ورودی به مدل جهت نتیجه مناسب اعلام داشتند و بیان داشتند که بین پارامترهای شوری و کلر همبستگی بالایی وجود دارد این در حالی است که در این تحقیق نیز سطح آب زیرزمینی، طول و عرض جغرافیایی ارائه شده که دارای همبستگی مناسبی با عمق سنگ کف است. تغییرات عمق سنگ کف دشت بیرجند مانند یک فلوم که گودی آن در وسط دشت و شیب آن از غرب به شرق امتداد دارد سطح آب در کنارها بالا و سنگ کف نیز به تناسب آن بالاتر از مرکز آبخوان می‌باشد و این تناسب در تمامی بخش‌های آبخوان رعایت شده است و نتایج مدل نیز حاکی از این مهم است.

مقایسه نتایج ANN, ANFIS با داده‌های مشاهده‌ای به کار گرفته شدند. این مقایسه توسط استفاده از شاخص آماری از قبیل: ضریب تبیین ( $R^2$ ) و ریشه متوسط خطای مربعات (RMSE) صورت گرفت.

$$R^2 = \frac{[\sum_{i=1}^n (P_i - P^-)(O_i - O^-)]^2}{\sum_{i=1}^n (P_i - P^-)^2 (O_i - O^-)^2} \quad : 5$$


$$RMSE = [N^{-1} \sum_{i=1}^N (P_i - O_i)^2]^{0.5} \quad : 6$$

N: برابر با تعداد کل داده‌ها،  $P_i$ : عمق سنگ کف تخمین زده شده (با استفاده از مدل ANN و ANFIS)،  $O_i$ : داده مشاهده‌ای  $P^-$  و  $O^-$  به ترتیب برابر با متوسط مقادیر  $P_i$  و  $O_i$  هستند. برای اینکه بهترین نتیجه انتخاب شود، ابتدا پارامترهای ( $RMSE, R^2$ ) درجه بندی شدند سپس توسط نزولی کردن داده‌های در نرم‌افزار آماری Excel، بهترین رتبه انتخاب گردید. ورودی مدل‌ها در جدول ۲ ارائه شده است.


## نتایج و بحث

بر اساس نتایج به دست آمده از تحلیل در مورد ۶ سناریوی مختلف ورودی به شبکه عصبی مصنوعی مطابق شکل (۵) نشان داد که استفاده از ۳ ورودی مختصات نقاط به همراه ارتفاع سطح ایستابی با ضریب تبیین ۰/۸۳ با میانگین مجذور خطا ۶۲/۵ متر جهت پیش‌بینی انتخاب شد. در این میان کمترین دقت مربوط به ورودی‌های طول و عرض جغرافیایی و شوری آب زیرزمینی می‌باشد چرا که میانگین مجذور خطای






b (ورودی: مختصات نقاط و ارتفاع)



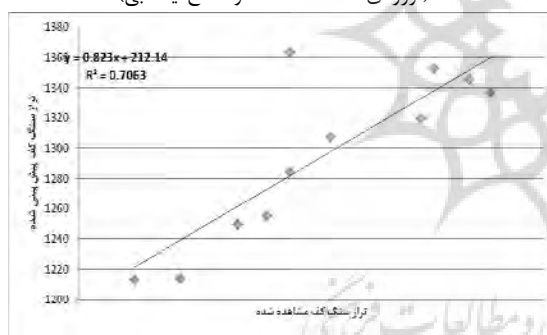
a (ورودی: مختصات نقاط)




d (ورودی: مختصات نقاط و سطح ایستایی)



c (ورودی: مختصات نقاط و EC)



f (ارتفاع و EC)



e (ورودی: سطح ایستایی، ارتفاع، EC)

شکل ۵: نمودارهای مربوط به داده‌های مشاهده شده و پیش‌بینی شده در انواع سناریوهای ورودی به ANN

تهیه و ترسیم: نگارندگان، ۱۳۹۴

و ارتفاع آنها به عنوان سناریو مناسب‌تر انتخاب شد. براساس نتایج به دست آمده از تحلیل در مورد ۶ سناریوی مختلف ورودی به روش‌های فازی مطابق شکل (۶) نشان داد که سناریوی b استفاده از ۳ ورودی مختصات نقاط به همراه ارتفاع نقاط با ضریب همبستگی ۰/۴۵۸ و میانگین مجذور خطای ۳۳ متر به عنوان بهترین مدل جهت پیش‌بینی سنگ کف انتخاب شد.

نتایج پیش‌بینی سنگ بستر با استفاده از مدل سیستم‌های استنتاج فازی عصبی در شکل (۶) ارائه شده است. جهت تحلیل و انتخاب روش مناسب در پیش‌بینی سنگ بستر با استفاده از روش‌های استنتاج فازی عصبی از توابع عضویت مختلف در سناریوهای مختلف استفاده گردید که بر این اساس از روش‌های مختلف نیز جهت تکمیل و بهینه‌سازی استفاده گردید. بر این اساس استفاده از سناریو ورودی مختصات نقاط


جدول ۳: پارامترهای بهترین مدل روش ANFIS

سناریو	پارامترهای روش خوشه‌بندی فازی				خصوصیات روش ANFIS		
	محدوده تأثیر	فاکتور Squash	نسبت قابل قبول	نسبت بازگشتی	تعداد تابع عضویت	نوع تابع عضویت	مدل بهینه‌سازی
e	۰/۵	۱/۲۵	۰/۵	۰/۱۵	-	-	hybrid
f	-	-	-	-	۴۴	psigmf	hybrid
d	۰/۵	۱/۲۵	۰/۵	۰/۱۵	-	-	hybrid
c	-	-	-	-	۴۴۴	trapmf	hybrid
b	۰/۵	۱/۲۵	۰/۵	۰/۱۵	-	-	hybrid
a	-	-	-	-	۳۳	pimf	hybrid


مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۴

تقسیم‌شده و با استفاده از روش Subtractive clustering بر روی هر کلاس، تابع عضویت با تعداد تابع مجزا اعمال می‌نماید. این عمل باعث می‌شود که FISهایی با حداقل تعداد قواعد مورد نیاز برای هر کلاس تشکیل شود (خاشعی‌سیوکی و همکاران، ۱۳۹۲: ۱۲). نتایج جدول (۳) نشان می‌دهد که سناریوهای b، d و e با استفاده از روش خوشه‌بندی فازی از دقت مناسبی برخوردار است.

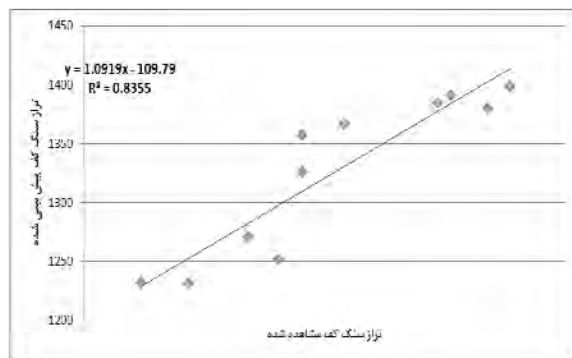
نکته‌ی قابل توجه این است که در مدل‌های فازی هیچ کدام از توابع عضویت نتوانسته است دقت قابل توجه‌ای را در برآورد سنگ کف ارائه دهند بطوری که استفاده از روش خوشه‌بندی، کارایی مناسب‌تری را نشان داده است. این روش توسط بزدک ارائه شد (Bezdec, 1981: 239) ایشان یک روشی را که در آن داده‌ها در یک فضای چند بعدی به تعدادی کلاس متفاوت تبدیل می‌شود را ارائه داد. در این روش قبل از اعمال مدل فازی و تعیین FISها، داده به طبقات و کلاس‌هایی




b (ورودی: مختصات نقاط و ارتفاع)




a (ورودی: مختصات نقاط)




d ( ورودی: مختصات نقاط و سطح ایستایی)



c ( ورودی: مختصات نقاط و EC)



f ( ارتفاع و EC)



e ( ورودی: سطح ایستایی، ارتفاع، EC)

شکل ۶: نمودارهای داده‌های مشاهده شده و پیش‌بینی شده در انواع سناریوهای ورودی به روش‌های فازی

تهیه و ترسیم: نگارندگان، ۱۳۹۴

توجه به اهمیت تعیین عمق سنگ کف آبخوان‌ها جهت برآورد حجم و برنامه‌ریزی منابع آب در این تحقیق کارایی مدل‌های شبکه‌ی عصبی مصنوعی و سیستم‌های استنتاج فازی عصبی در برآورد سنگ کف و پهنه‌بندی آن در بخش‌های مختلف آبخوان مورد بررسی قرار گرفت در این تحقیق از پارامترهای طول و عرض جغرافیایی، شوری، تراز سطح آب و زمین به عنوان ورودی‌ها استفاده شد نتایج نشان داد که مدل شبکه‌ی عصبی ANN، ۲۷ درصد دقت بیشتری نسبت به مدل ANFIS دارد. همچنین متغیرهای ورودی تراز آب زیرزمینی، طول و عرض جغرافیایی با ضریب تبیین ۰/۸۳۵ و میانگین مجذور خطای ۶۲/۴۸ متغیرهای ورودی منتخب می‌باشند.

مقایسه‌ی نتایج دو سیستم هوشمند و خبره شبکه‌ی عصبی مصنوعی و سیستم استنتاج فازی نشان داد که شبکه‌ی عصبی ANN دقت ۲۷ درصد بیشتری نسبت به مدل ANFIS دارد که با نتایج خاشعی‌سیوکی و سربازی (۲۰۱۳) مطابقت دارد. تفاوت دو مدل در این بود که مدل ANN سناریوی طول و عرض جغرافیایی با سطح آب را مناسب‌ترین مدل ورودی انتخاب نمود، ولی مدل ANFIS سناریوی طول و عرض و ارتفاع سطح زمین را به عنوان مدل مناسب انتخاب کرد.

### نتیجه

تعیین ضخامت آبرفت و نوع مصالح تشکیل‌دهنده‌ی آبخوان‌ها یکی از موارد ضروری جهت برنامه‌ریزی برای توسعه‌ی شهر و طراحی زیرساخت‌های آن می‌باشد با

- Eslam, E., Salem, A., and Ushijima., K (2001). Detection of cavities and tunnels from gravity data using a neural network: *Explor. Geophys.*, 32, 204-208.
- French, M. N., Krajewski, W. F. and Cuendall, P. P (1992). Rainfall forecasting in space and time using artificial neural network. *Journal of Hydrology*, 13(7), 1-31.
- Jang JSR, Sun CT and Mizutani E (1997). *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall, Upper Saddle River, New Jersey, USA.
- Khashei-Siuki, A., Kouchakzadeh, M and Ghahraman B (2011). Predicting dryland wheat yield from meteorological data using expert system in Khorasan province, I.R. Iran. *Journal of Agricultural Science and Technology* (Accepted).
- Kurtulus, B. and Razack M (2010). Modeling daily discharge responses of a large karstic aquifer using soft computing methods: Artificial neural network and neuro-fuzzy. *Journal of Hydrology* 381:101- 111
- Nayak, P.C., Sudheer K.P., Rangan D.M. and Ramasastri K. S (2006). A Neuro- Fuzzy Computing Technique for Modeling Hydrological Time Series. *Journal of Hydrology*, 291(1): 52-66.
- Osman, O., Albora, A. M., and Ucan, O. N (2007). Forward modeling with forced neural networks for gravity anomaly profile: *Math Geol*, 39, 593-605.
- Rahimi Khoob, A (2008). Artificial Neural Network Estimation of Reference Evapotranspiration from Pan Evaporation in a Semi-Arid Environment. *Irrigation Science*, Available in [www.Springer.com](http://www.Springer.com).
- Russell, Stuart & Norvig, Peter (2003). *Artificial Intelligence: A Modern Approach*. Prentice Hall, New Jersey.
- Samani, N. Gohari-Moghadam M., Safavi A.A. (2007). A simple neural network model for the determination of aquifer parameters. *Journal of Hydrology* 340, 1-11.
- Sreekanth, P. D., Geethanjali, N. D., Sreedevi, P. D., Shakeel Ahmed, Steyl G (2009). Application of Artificial Neural Networks in the Field of hydrology. Institute of Groundwater Studies Faculty of Natural and Agricultural Sciences. University of the Free State.
- Telford, W. M., Geldart, L. P., Sheriff, R. E., and Keys., D. A (1988). *Applied geophysics*: Cambridge University Press.
- Thompson, D (1982). EULDPH -A new technique for making computer-assisted depth estimates from magnetic data: *Geophysics*, 47, 31-37.
- Zadeh, L. A (1965). Fuzzy sets. *Information Control*, 8(3), 338-353.
- منابع**
- احمدی زاده، کاوه (۱۳۸۸). مدل سازی تبخیر-تعرق مرجع روزانه با استفاده از سیستم استنتاج عصبی- فازی، پایان نامه کارشناسی ارشد. آبیاری و زهکشی. دانشکده کشاورزی دانشگاه تربیت مدرس. تهران.
- ایزدی، عزیزالله؛ کامران داوری؛ امین علیزاده، امین؛ بیژن قهرمان (۱۳۸۶). کاربرد مدل شبکه عصبی در پیش بینی پارامترهای منابع آب زیرزمینی، نهمین کنفرانس کاهش تبخیر. کرمان صفحه ۸.
- خاشعی سیوکی، عباس؛ بیژن قهرمان؛ مهدی کوچک زاده (۱۳۹۲). مقایسه مدل های شبکه عصبی مصنوعی، ANFIS و رگرسیونی در برآورد سطح ایستابی آبخوان دشت نیشابور مجله آبیاری و زهکشی. شماره ۱. جلد ۷. بهار ۱۳۹۲. صفحات ۲۲-۱۰.
- مختاری، موهند (۱۳۸۸). کاربرد MATLAB و SIMULINK در مهندسی، چاپ اول. ترجمه صمدی بخارایی. مرکز انتشارات خراسان.
- میرعربی، علی؛ محمد نخعی (۱۳۸۷). پیش بینی نوسانات سطح آب زیرزمینی دشت بیرجند با استفاده از شبکه عصبی مصنوعی، مجموعه مقالات دوازدهمین همایش انجمن زمین شناسی ایران. اهواز شرکت ملی مناطق نفت خیز جنوب. صفحات ۸-۱.
- Affandi, A and Watanabe, K (2007). Daily groundwater level fluctuation forecasting using soft computing technique. *Nature & Science*, 5(2).
- Albora, A. M., Ozmen, A., and Ucan, O. N (2001). Residual separation of magnetic field using a cellular neural network approach: *Pure and Appl Geophys*, 158, 1797-1818.
- Bezdec, J. C (1981). *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York.
- Blakely, R (1995). *Potential theory in gravity and magnetic applications*: Cambridge University Press.
- Coulouma, G. Lagacherie, P. Samyn, K. Grandjean, G (2013). Comparisons of dry ERT, diachronic ERT and the spectral analysis of surface waves for estimating bedrock depth in various Mediterranean landscapes. *Geoderma* 199 (2013) 128-134.
- Chang, F. J. and Chang, Y. T (2006). Adaptive Neuro-Fuzzy Inference System for Prediction of Water level in Reservoir. *Advances in Water Resources*, 29(1): 1-10.