

علوم و تکنولوژی محیط زیست، دوره بیست و یکم، شماره یک، فروردین ماه ۹۸

ارزیابی مدل های هوشمند در تخمین هدایت الکتریکی آب های زیرزمینی

(مطالعه موردی: دشت مازندران)

عیسی حزباوی^{۱*}

habavi.i@lu.ac.ir

رضا دهقانی^۲

تاریخ پذیرش: ۹۵/۱۲/۲۵

تاریخ دریافت: ۹۵/۱۰/۳

چکیده

زمینه و هدف: منابع آب زیرزمینی در کنار آب های سطحی تأمین کننده نیاز بخش های شهری، صنعت و کشاورزی است که علاوه بر کمیت، کیفیت آن ها نیز باید بررسی شود. شوری یکی از مهم ترین پارامترهایی است که برای ارزیابی کیفیت آب های زیرزمینی در نظر گرفته می شود.

روش بررسی: در این پژوهش کاربرد مدل های شبکه عصبی مصنوعی و شبکه بیزین جهت پیش بینی هدایت الکتریکی ۸ چاه مشاهداتی دشت مازندران مورد بررسی قرار گرفت. که برای این منظور هیدروژن کرنات، کلرید، سولفات، کلسیم و منیزیم در مقیاس زمانی ماهانه طی دوره آماری (۱۳۹۳-۱۳۸۳) به عنوان ورودی و هدایت الکتریکی به عنوان پارامتر خروجی انتخاب شد. معیارهای ضریب همبستگی، میانگین قدر مطلق خطا و ضریب نش ساتکلیف برای ارزیابی و عملکرد مدل مورد استفاده قرار گرفت.

یافته ها: نتایج نشان داد مدل شبکه عصبی مصنوعی با ضریب همبستگی (۰/۹۸۹)، میانگین قدر مطلق خطا (۰/۰۱۹ ds/m) و نیز معیار نش ساتکلیف (۰/۹۷۰) در مرحله صحت سنجی در اولویت قرار گرفت

بحث و نتیجه گیری: در مجموع نتایج حاکی از توانمندی قابل قبول مدل شبکه عصبی مصنوعی در تخمین هدایت الکتریکی آب های زیرزمینی است.

واژه های کلیدی: آب زیرزمینی، دشت مازندران، شبکه بیزین، شبکه عصبی مصنوعی، هدایت الکتریکی.

۱- استادیار گروه مکانیک بیوسیستم، دانشگاه لرستان، خرم آباد، ایران* (مسوول مکاتبات).

۲- دانشجوی دکتری سازه های آبی، گروه مهندسی آب، دانشگاه لرستان، خرم آباد، ایران.

Assessment of Intelligent models for Estimating the Electrical Conductivity in Groundwater (Case study: Mazandaran plain)

Isa Hazbavi^{1*}
hazbavi.i@lu.ac.ir
Reza Dehghani²

Admission Date: March 15, 2017

Date Received: December 23, 2016

Abstract

Background and Objective: Groundwater resources along with surface water supply the needs for municipal, industrial and agriculture uses, and their quantity and quality should be investigated. Salinity is one of the most important parameters in assessing the quality of groundwater.

Method: In this study, application of artificial neural networks and Bayesian network in predicting the electrical conductivity in 8 observation wells in Mazandaran plain was investigated. For this purpose, hydrogen carbonate, chloride, sulfate, calcium and magnesium were selected as input and output parameters for electrical conductivity at monthly a scale during 2003-2013. The criteria of correlation coefficient, mean absolute error and Nash Sutcliff coefficient were used to evaluate the performance of the model.

Findings: The results showed that artificial neural network model has the highest correlation coefficient (0.989), the lowest mean absolute error (0.019 ds/m) and the highest standard of Nash Sutcliffe (0.970) ranked the first priority in the validation phase.

Discussion and Conclusion: The results indicate acceptable capability of artificial neural network models to estimate the electrical conductivity of groundwater.

Keywords: Groundwater, Mazandaran plain, Bayesian network, Artificial neural network, Electrical conductivity

1- Assistant Professor, Department of Biosystem Engineering, Lorestan University, Khorramabad, Iran
*(Corresponding Author)

2- Ph.D. Student of Water Structure, Faculty of Agric., Lorestan University, Khorramabad, Iran

مقدمه

آب همواره به عنوان یک رکن اصلی توسعه در تحولات اقتصادی و اجتماعی هر جامعه‌ای مطرح بوده است. افزایش روزافزون جمعیت، احداث کارخانجات صنعتی و بالا رفتن استانداردهای زندگی موجب افزایش نیاز به منابع آب باکیفیت مناسب جهت مصارف مختلف کشاورزی، صنعت و شرب شده است. یکی از مهم‌ترین منابع تأمین‌کننده آب، سفره‌های آب زیرزمینی می‌باشند که همواره تلاش شده است تا ضمن شناخت توانایی‌های این منابع، میزان مصرف آن‌ها نیز مشخص گردد. کیفیت آب زیرزمینی به اندازه‌ی کمیت آن برای قابل‌استفاده بودن آن در مصارف مختلف مهم و ضروری می‌باشد. از این رو پایش کیفی منابع آب از اهمیت زیادی برخوردار است. لذا در سال‌های اخیر بررسی تغییرات کیفیت آب‌های زیرزمینی به روش‌های کلاسیک آماری برای توسعه مدیریت منابع آب بکار گرفته شده است. امروزه سیستم‌های هوشمند به طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد، که مدل شبکه بیزین و شبکه عصبی مصنوعی از جمله این مدل‌ها است. طی سال‌های اخیر استفاده از روش شبکه‌های هوشمند در مطالعات کیفیت آب مورد توجه محققین قرار گرفته است، که از جمله می‌توان به موارد ذیل اشاره نمود:

زارع ایبانه و همکاران (۱) با استفاده از شبکه عصبی مصنوعی به تخمین نیترات موجود در آب زیرزمینی پرداختند. در این پژوهش از آمار و اطلاعات کمی و کیفی ۵۳ حلقه چاه آب زیرزمینی دشت همدان- بهار در دو گروه اطلاعات پرهزینه و کم‌هزینه، طی سال‌های ۱۳۸۲ تا ۱۳۸۷ بهره گرفتند و نشان دادند شبکه عصبی مصنوعی دقت بالایی در تخمین کیفیت آب زیرزمینی دارد. تمدنی کناری (۲) شبکه عصبی مصنوعی را جهت پیش‌بینی هوشمند شوری آب زیرزمینی بکار برد و نشان داد شبکه عصبی مصنوعی از کارایی مناسب و دقت قابل قبولی در تخمین شوری برخوردار است. درخشان و همکاران (۳) جهت شبیه‌سازی شوری آب‌های زیرزمینی دشت مازندران از شبکه عصبی مصنوعی استفاده نمودند و نشان دادند شبکه عصبی مصنوعی عملکرد قابل قبولی در شبیه‌سازی شوری آب

زیرزمینی دارد. کرد و همکاران (۴) در پژوهشی از مدل فازی برای بررسی کیفیت آبخوان‌های دشت اردبیل بهره گرفتند و نشان دادند که استفاده از منطق فازی برای مدل‌سازی توزیع مکانی روشی مناسب و به‌خصوص در مناطق با وسعت زیاد که فاصله بین نقاط نمونه‌برداری زیاد است، دارای عملکرد بهتری است. در پژوهشی دیگر عباسی و همکاران (۵) با استفاده از شبکه‌های عصبی مصنوعی، به تخمین میزان مواد جامد محلول در آبخوان‌های موجود در دشت تهران پرداختند و نتایج نشان داد که مدل‌های شبکه عصبی توانایی بالایی برای تخمین پارامترهای کیفی دارد. نصر و فاروک (۶) مدل شبکه عصبی را برای تخمین میزان شوری آب زیرزمینی جهت آبیاری مزارع آلکساندریا مصر توسعه دادند. نتایج حاصل از این تحقیق نشان داد، مدل شبکه عصبی مصنوعی تطبیق خوبی با مقادیر اندازه‌گیری شده و مورد انتظار شوری آب زیرزمینی دارد. خردپیشه و همکاران (۷) جهت ارزیابی کیفیت آب زیرزمینی دشت بهاباد یزد در طول دوره آماری (۲۰۱۳-۲۰۰۳) از مدل شبکه عصبی مصنوعی استفاده نمودند. نتایج نشان داد که مدل شبکه عصبی می‌تواند جایگزین مناسبی برای محاسبات طولانی شاخص کیفیت آب باشد. برزگر و اصغری مقدم (۸) پارامتر کیفی شوری ۹۳ آبخوان دشت تبریز را با شبکه عصبی مصنوعی در ساختارهای مختلف مورد بررسی قرار داده و به این نتیجه رسیدند که مدل شبکه عصبی مصنوعی RBFNN خطای پایینی در تخمین پارامترهای کیفی آب زیرزمینی دارد. در مجموع با توجه به پژوهش‌های انجام شده و همچنین اهمیت مدل‌سازی هدایت الکتریکی آب‌های زیرزمینی دشت مازندران در چاه‌های آغوزین، اله چال، پایین سرست، تیرکلا، چنگاز، پاشاکلا، اسپس کلا و اسکنده که مهم‌ترین چاه‌های شهرستان‌های بابل و امل می‌باشند و با توجه به این که کیفیت آب زیرزمینی این چاه‌ها کاهش یافته و مورد خطر جدی قرار گرفته‌اند بنابراین اقدامات مدیریتی جهت بهبود کیفیت آب آن بیش‌ازپیش ضروری است. لذا هدف از این تحقیق تخمین

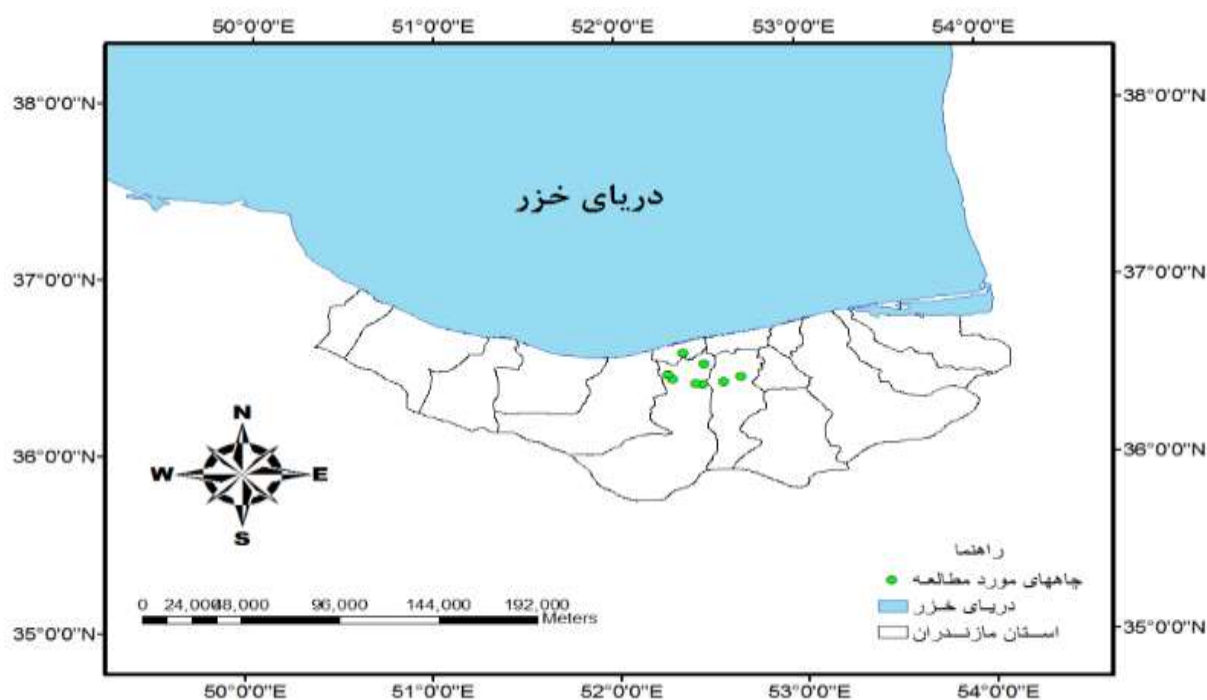
و سردی هوا گشته و گاهی موجب ریزش برف می‌گردد. میانگین بارندگی سالیانه در نوار ساحلی استان برابر با ۹۷۷ میلی‌متر است. در این پژوهش داده‌های پارامترهای کیفی در مقیاس زمانی ماهانه شامل هیدروژن کربنات (HCO_3)، کلرید (Cl)، سولفات (SO_4)، منیزیم (mg) و کلسیم (Ca) برحسب mg/l و نیز هدایت الکتریکی (Ec) برحسب ds/m مربوط به ۸ چاه مشاهداتی دشت مازندران در طی سال آماری (۱۳۸۳-۱۳۹۳) که از شرکت آب منطقه‌ای استان مازندران اخذ گردید، استفاده شد. در جدول ۱ موقعیت جغرافیایی چاه‌های مورد مطالعه نشان داده شده است. همچنین در شکل ۱ موقعیت چاه‌های مورد مطالعه نشان داده شده است. از این داده‌ها ۸۰ درصد (۷۶۸ رکورد)، به منظور آموزش مدل‌ها و ۲۰ درصد (۱۹۲ رکورد)، جهت صحت سنجی انتخاب گردید.

هدایت الکتریکی آب‌های زیرزمینی این دشت با استفاده از مدل‌های شبکه بیزین و شبکه عصبی مصنوعی باشد.

مواد و روش‌ها

منطقه مورد مطالعه


مازندران در شمال ایران در کرانه‌های جنوبی دریای خزر واقع است. این استان با مساحتی بالغ بر $۲۳۷۵۶/۴$ کیلومترمربع $۱/۴۶$ درصد مساحت کل کشور را شامل می‌شود. استان مذکور بین ۳۵ درجه و ۴۷ دقیقه تا ۳۸ درجه و ۵ دقیقه عرض شمالی ۵۰ درجه و ۳۲ دقیقه تا ۵۶ درجه و ۱۴ دقیقه طول شرقی از نصف‌النهار گرینویچ قرار گرفته است حد شمالی آن دریای مازندران (دریای خزر) و کشور ترکمنستان حد جنوبی آن استان تهران و استان سمنان حد غربی آن استان گیلان و حد شرقی آن استان خراسان می‌باشد. هوای مازندران معتدل و مرطوب است و بادهایی که از نواحی غربی می‌وزد باعث برودت



شکل ۱- موقعیت محدوده مطالعاتی

Figure 1. The location of the study area

زمینه‌های مختلف نظیر یادگیری ماشینی، کاوش متن، پردازش زبان طبیعی، شناسایی صدا، پردازش سیگنال، بیوانفورماتیک، کدهای کنترل خطا، تشخیص پزشکی، پیش‌بینی هوا و شبکه‌های سلولی پیدا کرده‌اند. بنابراین شبکه‌های بیزین^۱ مدل‌های گرافیکی هستند که برای استدلال در مواردی که پیچیدگی و عدم قطعیت وجود دارد به کار می‌روند و یا به عبارتی گرافی است که متغیرهای تصادفی و وابستگی آن‌ها را نمایش می‌دهد (۹). در این گراف گره‌ها نشان‌گر متغیرهای تصادفی گسسته یا پیوسته هستند و کمان‌های جهت‌داری که هر جفت از گره‌ها را به یکدیگر متصل می‌کنند وابستگی بین متغیرها را نمایش می‌دهد. در واقع این شبکه گراف جهت‌داری است که هیچ دوری در آن وجود ندارد (۱۰). نمونه‌ای از گراف ساده در شکل ۲ نشان داده شده است.



شکل ۲- گراف ساده شبکه بیزین

Figure 2. The graph is a simple Bayesian network در ساختار شبکه بیزین اگر مجموعه‌ای شامل n متغیر به صورت $\{X_1, X_2, X_3, \dots, X_n\}$ داشته باشیم که هر X_i یک متغیر تصادفی باشد و گره‌های والد این متغیر با $parent(X_i)$ نشان داده شوند، احتمال هر رویداد مانند $X=(X_1, X_2, X_3, \dots, X_n)$ به صورت زیر محاسبه می‌گردد.

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | parents(X_i)) \quad (1)$$

بعد از ایجاد شبکه، مقدار روابط بین گره‌های متصل به هم به دست می‌آید مقدار احتمال شرطی مربوط به هر متغیر در جدولی به نام جدول احتمال شرطی قرار می‌گیرد. هر گره یک جدول احتمال شرطی دارد که برای هر ترکیب از مقادیر والد هایش، احتمال شرطی هر کدام از این مقادیر را نگه می‌دارد و سپس توزیع‌های احتمال بعدی برای هر گره محاسبه می‌شود

جدول ۱- مشخصات چاه‌های مورد مطالعه

Table 1. View wells studied

UTM _y	UTM _x	چاه‌های مورد بررسی
۴۰۳۴۳۵۳	۶۱۶۱۳۳	آغوزین
۴۰۳۲۷۸۴	۶۴۰۸۴۸	اله چال
۴۰۳۶۱۹۳	۶۴۹۵۲۹	پایین سرست
۴۰۳۱۴۸۵	۶۳۱۰۸۹	تیرکلا
۴۰۳۷۴۰۰	۶۱۳۸۹۴	چنگاز
۴۰۳۱۹۶۷	۶۲۷۳۷۸	پاشاکلا
۴۰۴۴۲۳۰	۶۳۱۶۰۰	اسپی کلا
۴۰۵۰۷۱۷	۶۲۱۴۲۰	اسکنده

شبکه‌های بیزین

شبکه‌های بیزین که به نام شبکه‌های اعتقاد (باور) هم شناخته می‌شوند، متعلق به خانواده مدل‌های گرافیکی احتمالاتی هستند. این ساختارهای گرافیکی برای نشان دادن اطلاعات در یک حوزه دارای عدم قطعیت به کار می‌روند. به‌طور خاص هر گره در گراف نشان‌دهنده یک متغیر تصادفی است و شاخه‌ها (کمان) وابستگی‌های احتمالاتی بین متغیرها را نشان می‌دهند. این وابستگی‌های شرطی غالباً به وسیله روش‌های آماری و احتمالاتی مشخص ارزیابی می‌شوند. به‌طور کلی مدل‌های گرافیکی با شاخه‌های بدون جهت، میدان‌های تصادفی مارکوف یا شبکه‌های مارکوف نامیده می‌شوند. این شبکه‌ها یک تعریف ساده برای استقلال بین متغیرها بر مبنای مفهوم لایه مارکوف فراهم می‌کنند. شبکه‌های مارکوف در زمینه‌های فیزیک آماری و بینایی کامپیوتر بسیار مشهور هستند.


شبکه‌های بیزین متعلق به ساختار دیگری از مدل‌های گرافیکی به نام گراف‌های غیرمدور جهت‌دار هستند که در زمینه‌های آماری، یادگیری ماشینی و هوش مصنوعی بسیار مشهور هستند. شبکه‌های بیزین نمایش و محاسبات مؤثری از توزیع احتمالاتی مشترک روی یک سری متغیر تصادفی را فراهم می‌آورند. به‌علاوه شبکه‌های بیزین شدت ارتباط بین متغیرها را به‌صورت کمی مدل می‌کنند که اجازه می‌دهند با دسترسی به اطلاعات جدید، اعتقاد شرطی در مورد آن‌ها به‌صورت خودکار به‌روزرسانی شود. شبکه‌های بیزین مدل‌های بسیار معروفی در دهه اخیر شده‌اند. این شبکه‌ها کاربردهای بسیاری در

که این توزیع احتمال باور نامیده می‌شود.

شبکه عصبی مصنوعی

امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد (۱۱). ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است.

لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه میانی یا مخفی که از گره‌های پردازش‌گسترش‌یافته‌اند، محل پردازش داده‌ها است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه انجام گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس انتشار خطا^۲ با ساختار شبکه پیش‌خور و تعداد سه لایه به طور رضایت بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد (۱۲). از رایج‌ترین توابع محرک استفاده‌شده در شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد (۱۳). نمونه‌ای از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۳ نشان داده شده است.



شکل ۳- نمای کلی یک شبکه عصبی مصنوعی سه لایه

Figure 3. An artificial neural network three layers overview

معیارهای ارزیابی

در این تحقیق به منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب همبستگی (R)، قدر مطلق میانگین خطا

(RMSE) و ضریب نش ساتکلیف (NS) طبق روابط زیر استفاده گردید. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و یک می‌باشد.

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (2)$$

$$MAE = \frac{\sum_{i=1}^n |x_i - y_i|}{n} \quad (3)$$

$$NS = 1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad -\infty \leq NS \leq 1 \quad (4)$$

در روابط بالا، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ام، N تعداد گام‌های زمانی، \bar{x} و \bar{y} نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی - محاسباتی نسبت به زمان نیز جهت تحلیل بیش‌تر نتایج استفاده شده است.

یافته‌ها

در این پژوهش به منظور مدل‌سازی کیفی هدایت الکتریکی ۸ چاه مشاهداتی دشت مازندران در طی سال آماری (۱۳۹۳-۱۳۸۳) از مدل‌های شبکه بیزین و شبکه عصبی مصنوعی استفاده شد. پارامترهای هیدروژن کربنات (HCO_3)، کلرید (Cl)، سولفات (SO_4)، کلسیم (Ca) و منیزیم (Mg) به عنوان ورودی و هدایت الکتریکی آب (EC) به عنوان پارامتر خروجی مدل بکار برده شد که در جدول ۲ خصوصیات آماری پارامترهای استفاده‌شده، مشاهده می‌شود. در ادامه نتایج مدل مورد استفاده ارائه می‌گردد. که در این میان ۸۰ درصد از داده‌ها (۷۶۸ رکورد)، به منظور آموزش و ۲۰ درصد مابقی (۱۹۲ رکورد)، برای صحت‌سنجی انتخاب گردید. یک نکته مهم در آموزش شبکه‌های عصبی نرمال‌سازی داده‌ها قبل از استفاده در مدل می‌باشد این عمل خصوصاً وقتی دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود (۱۴). برای نرمال‌سازی داده‌های تحقیق از رابطه زیر استفاده شده است:

$$X_n = 0.1 + 0.8 \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (5)$$

که در آن X_n مقدار نرمال شده ورودی X_i و X_{min} و X_{max} به ترتیب حداکثر و حداقل داده‌ها می‌باشد.

- 1- Multi-Layer Perceptron
- 2- Back Propagation (BP)
- 3- Feed Forward

جدول ۲- محدوده پارامترهای مورد استفاده جهت آموزش و صحت سنجیداده‌ها

Table 2. Parameters used for training and validation of data


صحت سنجی			آموزش				
ماکزیمم	میانگین	مینیمم	ماکزیمم	میانگین	مینیمم		
۹/۳۰۰	۲/۴۸۷	۰/۴۰۰	۱۰	۲/۳۳۳	۰/۳۰۰	So ₄ (mg/l)	پارامتر ورودی
۲۴/۷۰۰	۴/۲۷۷	۰/۴۰۰	۲۲	۲/۸۷۵	۰/۴۰۰	Cl(mg/l)	
۸/۵۰۰	۶/۲۹۱	۳/۶۰۰	۱۷/۵۰۰	۷/۰۳۵	۳/۲۰۰	Hco ₃ (mg/l)	
۹/۳۰۰	۳/۲۷۷	۱/۲۰۰	۶/۹۰۰	۳/۳۲۰	۱/۲۰۰	Mg(mg/l)	
۹/۲۰۰	۴/۶۷۷	۲/۲۰۰	۹/۳۰۰	۴/۶۷۵	۱/۲۰۰	Ca(mg/l)	
۳۴۰۰	۱۳۶۳/۲۵۰	۴۵۰	۳۵۰۰	۱۲۶۴/۳۲۶	۵۵۸	Ec(ds/m)	پارامتر خروجی

یک مجموعه داده‌ها با استفاده از دانش قبلی در مورد الگوها یا اطلاعات آماری داده‌ها، جداسازی می‌نماید همچنین یادگیری ماشینی با ترکیب قانون احتمالات بیز سبب می‌گردد با میزان خطای کم‌تری محتمل‌ترین الگوی رخداد یک پدیده را انتخاب و بررسی نماید (۱۰). جهت مقایسه نتایج شبکه بیزین از مدل شبکه عصبی مصنوعی استفاده شد که در این شبکه تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است، که در این تحقیق از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده گردید. آموزش شبکه‌های پرسپترون چندلایه با استفاده از الگوریتم آموزش پس انتشار خطا بنام الگوریتم لونیبرگ - مارکوارت به دلیل هم‌گرایی سریع‌تر در آموزش شبکه، استفاده شد. همچنین از ترکیبات مختلف توابع محرک در لایه (های) مخفی استفاده گردید. تعداد تکرارهای لازم در فرآیند یادگیری شبکه ۱۰۰۰ در نظر گرفته شده و عملکرد شبکه به کمک معیار میانگین مربعات خطا مورد ارزیابی قرار گرفته است. تعداد نرون های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسئله مورد بررسی مشخص شده، حال آنکه تعداد نرون های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار خطا مشخص گردید. روند کار با تعداد نرون های کم آغاز و افزودن نرون های اضافی تا زمانی ادامه می‌یابد که افزایش نرون های بیش‌تر تأثیری در بهبود خطا نداشته باشد، ادامه می‌یابد. که شبکه‌ای با ۸ نرون در لایه پنهان اول به‌عنوان بهترین شبکه در فرآیند مدل‌سازی حاصل شد. در جدول ۴ نتایج حاصل از مقایسه عملکرد ساختارهای مختلف به‌کاررفته به همراه پارامترهای آماریداده‌های بخش آموزش و

به‌منظور مدل‌سازی هدایت الکتریکی آب زیرزمینی چاه‌های دشت مازندران از مدل شبکه بیزین استفاده شد. در این پژوهش ساختار شبکه بیزین از بین الگوریتم‌های K2 و BDeu، از الگوریتم K2 که مناسب‌ترین پارامتر الگوریتم یادگیری شبکه می‌باشد، برای ایجاد شبکه استفاده گردید. همچنین از میان متدهای موجود برای ساخت شبکه، از معمولی‌ترین متد Greedy Thick Thinning جهت الگوریتم یادگیری استفاده شد. برای استنتاج شبکه نیز الگوریتم Clustering برای نمایش میزان تأثیر هر کدام از پارامترها در نظر گرفته شد. در شکل ۴ میزان تأثیر هر کدام از عوامل تأثیرگذار بر روی هدایت الکتریکی نشان داده شده است. همان‌طور که در شکل ۴ مشاهده می‌شود تمامی پارامترها به‌طور مستقیم بر روی هدایت الکتریکی مؤثر است. همچنین در جدول ۳ نتایج ارزیابی مدل مشاهده می‌شود مدل شبکه بیزین با ضریب همبستگی ۰/۹۸۹ و میانگین قدر مطلق خطا ۰/۰۱۶ دسی زیمنس بر متر و ضریب نش ساتکلیف ۰/۹۷۸ در مرحله صحت سنجی عملکرد قابل قبولیاز خود نشان داده است. در شکل ۵ نمودار مدل مذکور برای داده‌های بخش صحت سنجی نشان داده شده است. در این شکل تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان قابل مشاهده می‌باشند، همان‌طور که مشاهده می‌شود مدل شبکه بیزین در تخمین اکثر مقادیر عملکرد قابل قبولی داشته است که این نتایج با نتایج صادقی حصار (۱۷) و قربانی و دهقانی (۴) هم‌خوانی دارد و در تبیین این نتایج می‌توان بیان نمود شبکه بیزین با استفاده از الگوریتم یادگیری K2 که به‌عنوان الگوریتم یادگیری ماشینی بوده، الگوهای مورد نظر را از

آماری ترسیم گردید (شکل ۷ و ۸). همان‌طور که در این شکل دیده می‌شود برای مدل‌های مذکور (شبکه بیزین، شبکه عصبی مصنوعی) بیش‌ترین خطا در محدوده ± 10 در صد قرار گرفته است. همان‌طور که از جدول اشکال ۶ و ۵ قابل‌مشاهده است نتایج حاکی از برتری مدل پیش‌بینی شبکه عصبی مصنوعی نسبت به مدل شبکه بیزین در پیش‌بینی هدایت الکتریکی می‌باشد که این نتایج با پژوهش‌های برزگر و همکاران (۹) و خرد پیشه و همکاران (۸) مطابقت دارد و این امر را می‌توان بدین صورت تبیین نمود مدل ANN به خاطر در اختیار داشتن کرنل غیرخطی توانایی مدل‌سازی رفتارهای غیر خطی را دارا است، و با توجه به ویژگی‌های نایستایی و غیرخطی بودن سری هدایت الکتریکی، به منظور پیش‌بینی و شبیه‌سازی دقیق ملزم به استفاده از شبکه عصبی می‌باشیم. چراکه شبکه بیزین به تنهایی قادر به غلبه بر نایستایی سیگنال نمی‌باشد.

صحت سنجی ارایه شده است. همان‌طور که در جدول ۴ مشاهده می‌شود ساختار شماره ۶ با بیش‌ترین ضریب همبستگی $0/989$ و کم‌ترین میانگین قدر مطلق خطا $0/019$ دسی زیمنس بر متر و ضریب نش ساتکلیف $0/970$ در مرحله صحت سنجی نسبت به سایر ساختارها جهت مدل‌سازی هدایت الکتریکی دشت مناسب‌تر خواهد بود. در شکل ۶ نمودار مقادیر مشاهداتی و محاسباتی نشان داده شده است همان‌طور که در شکل ۵ مشخص است تطابق مقادیر محاسباتی میزان هدایت الکتریکی مدل شبکه عصبی مصنوعی با مقادیر مشاهداتی در اکثر نقاط وجود دارد. به‌گونه‌ای که این مقادیر را نزدیک به مقدار واقعی شان تخمین زده است. در نهایت اختلاف مقادیر مشاهداتی هدایت الکتریکی و محاسباتی بهینه مدل شبکه بیزین و شبکه عصبی مصنوعی به‌صورت درصدی از میانگین مقادیر مشاهداتی (مقدار خطا)، محاسبه و نمودار آن نسبت به نمونه داده‌های ثبت شده دوره



شکل ۴- ساختار شبکه بیزین برای پیش‌بینی هدایت الکتریکی

Figure 4. Shows the structure of Bayesian networks for predicting EC

جدول ۳- نتایج حاصل از مدل بیزین

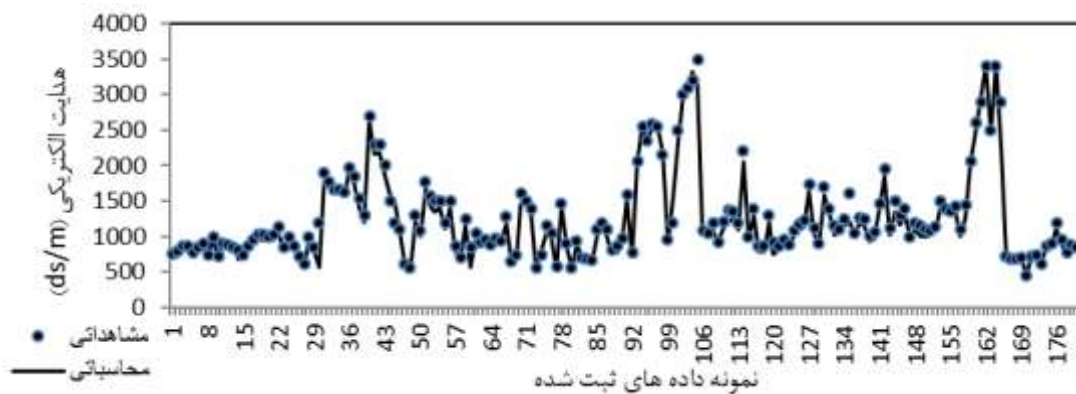
Table 3. Shows the results of Bayesian model

صحت سنجی			آموزش			مدل
NS	MAE(ds/m)	R	NS	MAE (ds/m)	R	
0/978	0/016	0/989	0/975	0/013	0/987	شبکه بیزین

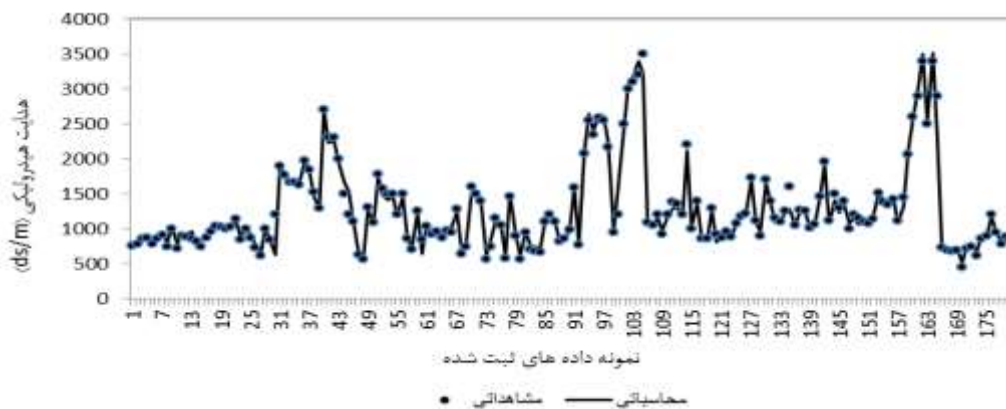
جدول ۴- ساختار و توابع محرک بهینه در مدل سازی شبکه های عصبی مصنوعی و شاخص های آماری در مراحل آموزش و صحت سنجی

Table 4. Shows the structure and functions for optimum driving in artificial neural network modeling and statistical indicators in the training and validation

صحت سنجی			آموزش			تابع محرک	ساختار	شماره
NS	MAE (ds/m)	R	NS	MAE (ds/m)	R			
۰/۹۴۰	۰/۰۴۵	۰/۹۷۱	۰/۹۳۰	۰/۰۴۸	۰/۹۶۴	تانزانته هیپربولیک	۱-۳-۵	۱
۰/۹۴۷	۰/۰۳۷	۰/۹۷۶	۰/۹۴۲	۰/۰۳۸	۰/۹۷۱	تانزانته هیپربولیک	۱-۴-۵	۲
۰/۹۵۳	۰/۰۳۰	۰/۹۸۰	۰/۹۵۱	۰/۰۳۱	۰/۹۷۸	تانزانته هیپربولیک	۱-۵-۵	۳
۰/۹۶۰	۰/۰۲۵	۰/۹۸۳	۰/۹۵۸	۰/۰۲۹	۰/۹۸۱	تانزانته هیپربولیک	۱-۶-۵	۴
۰/۹۶۸	۰/۰۲۱	۰/۹۸۷	۰/۹۶۰	۰/۰۲۳	۰/۹۸۵	تانزانته هیپربولیک	۱-۷-۵	۵
۰/۹۷۰	۰/۰۱۹	۰/۹۸۹	۰/۹۶۲	۰/۰۲۰	۰/۹۸۷	تانزانته هیپربولیک	۱-۸-۵	۶
۰/۹۶۳	۰/۰۲۴	۰/۹۸۶	۰/۹۵۵	۰/۰۲۶	۰/۹۷۶	تانزانته هیپربولیک	۱-۱۰-۵	۷
۰/۹۵۸	۰/۰۲۶	۰/۹۸۱	۰/۹۵۳	۰/۰۲۸	۰/۹۷۵	تانزانته هیپربولیک	۱-۱۲-۵	۸
۰/۹۵۱	۰/۰۳۱	۰/۹۷۴	۰/۹۴۸	۰/۰۳۳	۰/۹۷۰	تانزانته هیپربولیک	۱-۱۳-۵	۹




شکل ۵- نمودار حاصل از مقادیر محاسباتی و مشاهداتی مدل شبکه بیزین برای داده های ثبت شده در مرحله صحت سنجی
Figure 5. Shows the diagram of the observed and computed values Bayesian network model to data recorded in the validation phase




شکل ۶- نمودار حاصل از مقادیر محاسباتی و مشاهداتی مدل شبکه عصبی مصنوعی برای داده های ثبت شده در مرحله صحت سنجی

Figure 6. Diagram of the values observed and artificial neural network model to data recorded in the validation phase



شکل ۷- نمودار خطای بهینه مدل شبکه بیزین به صورت درصدی از میانگین مقادیر مشاهداتی

Figure 7. Errors charts optimal Bayesian network model as a percentage of average values observed



شکل ۸- نمودار خطای بهینه مدل شبکه عصبی مصنوعی به صورت درصدی از میانگین مقادیر مشاهداتی

Figure 8. Graph artificial neural network model optimization error as a percentage of average values observed

نتیجه‌گیری

آزمایشگاهی آن‌ها پرهزینه و زمان‌بر هستند، می‌باشد. در مجموع این تحقیق نشان می‌دهد استفاده از مدل شبکه عصبی مصنوعی می‌تواند در زمینه تخمین هدایت الکتریکی و کیفیت آب‌های زیر زمینی مؤثر باشد. و همچنین این مدل می‌تواند در نوبه خود برای تسهیل توسعه و پیاده سازی استراتژی‌های کیفیت آب‌های زیر زمینی مفید باشد و گامی در اتخاذ تصمیمات مدیریتی در جهت بهبود آب زیرزمینی حوضه‌های آبخیز می‌باشد.

Reference

1. Zare Abiane, H., Bayat varkeshi, M., Akhavan, S., Mohamadi, M. 2011. Estimation of groundwater nitrate in hamedan-bahar plain using neural network synthesis and the effect of data separation on prediction accuracy.

در پژوهش حاضر عملکرد مدل‌های هوشمند شبکه بیزین و شبکه عصبی مصنوعی جهت شبیه‌سازی هدایت الکتریکی آب زیرزمینی دشت مازندران را با استفاده از پارامترهای هیدروژن کربنات، کلرید، سولفات، کلسیم و منیزیم مورد ارزیابی قرار گرفت. مقادیر هدایت الکتریکی مشاهداتی با هدایت الکتریکی تخمین زده شده این مدل با استفاده معیارهای ارزیابی بررسی گردید. نتایج شبکه بیزین نشان داد پارامترهای مورد بررسی تأثیری مستقیم بر روی هدایت الکتریکی دارند و همچنین نتایج این پژوهش با توجه به معیار ارزیابی نشان داد که مدل شبکه عصبی مصنوعی دقت بالا و خطای ناچیز در تخمین هدایت الکتریکی و قابلیت بسیار بالایی در تخمین برخی مقادیر کمینه، بیشینه و میانی دارد. در تبیین این نتایج می‌توان بیان نمود که شبکه عصبی مصنوعی قادر به پیش‌بینی هدایت الکتریکی در حجم بالا، احتیاج به اندازه‌گیری و کارهای

8. Kheradpisheh Z, Talebi A, Rafati L, Ghaneian MT, Ehrampoush MH. 2015. Groundwater quality assessment using artificial neural network: A case study of Bahabad plain, Yazd, Iran. *Desert*; 20(1):65-71.
9. Barzegar R, Asghari Moghadam A. 2016. Combining the advantages of neural networks using the concept of committee machine in the groundwater salinity prediction. *Modeling Earth Systems and Environment*; 26(2):1-13.
10. Heckerman, D. 1997. Bayesian Networks for data Mining "data mining and knowledge Discovery 1, 79-119, Kluwer Academic Publishers. Manufactured in the Netherlands.
11. Nguyen RT. 1998. Prentiss and j. E. shively.. Rainfall interpolation for santa Barbara county. UCSB, Department Geography, USA.
12. Nourani, V., Alami, M.T., Aminfar, M.H. 2009. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*. 22(2): 466-472.
13. Nourani, V., Kisi, Ö., Komasi, M. 2011. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*. 402 (1-2): 41-59.
14. Sadeghi Hesar A. Tabatabaee, Hamid. Jalali, Mehrdad.. Monthly Rainfall Forecasting Using Bayesian Belief Networks. 2012.
15. Tokar, A., Johnson, P. 1999. Rainfall-Runoff Modeling Using Artificial Neural Networks. *J Hydrol. Eng.* 4(3):232-239.
16. Zhu, YM., Lu, XX., Zhou, Y., 2007. Suspended sediment flux modeling with artificial neural network: An *Environmental Studies*, Vol. 37(58), pp. 129-140. (In Persian)
2. Tamadoni Konari, S., 2012. Intelligent prediction of groundwater salinity using artificial neural network. Second Conference on Environmental Planning and Management. Tehran. Iran. (In Persian)
3. Derakhshan, Sh., Gholami, V., Darvari, Z., 2013. Simulation of groundwater salinity using artificial neural network (ANN) on the coast of Mazandaran province. *Irrigation Science and Engineering*. Vol. 36(2), pp. 61-70. (In Persian)
4. Mohammad Ali Ghorbani, M.A., Dehghani, R., 2017. Comparison of Bayesian Neural Networks and Artificial Neural Network to Estimate Suspended Sediments in the Rivers (Case Study: Simineh Road). *Environmental Science and Technology*. Vol. 19(2), pp. 1-13. (In Persian)
5. Kord, M., Asghari Moghadam, A., Nakhaei, M., 2015. Quantitative modeling of nitrate distribution in Ardabil plain aquifer using fuzzy logic. *Environmental Studies*, Vol. 41(1), pp. 67-89. (In Persian)
6. Abbasi P, Mehrdadi N, Nabi R, Zare Abyaneh H. 2013. Application of Artificial Neural Network to Predict Total Dissolved Solids Variations in Groundwater of Tehran Plain, Iran. *International Journal of Environment and Sustainability*; 2(1):10-20.
7. Nasr M, Farouk Zahran H. 2014. Using of pH as a tool to predict salinity of groundwater for irrigation purpose using artificial neural network. *The Egyptian Journal of Aquatic Research*; 40(2):111-115.

17. Sadeghi Hesar, A. Tabatabaee, H. Jalali, M. 2012. Monthly Rainfall Forecasting Using Bayesian Belief Networks.

example of the Longchuanjian River in the Upper Yangtze Catchment. Geomorphology,84(1),111-125.