

EXTENDED ABSTRACT

Modeling of Groundwater Salinity Using Artificial Neural Network (ANN) and Geographic Information System (GIS) on the Caspian Southern Coasts

M. Sebghati^{1*} and V. Gholami²

- 1*-Corresponding Author, PhD Student of Watershed Management, Faculty of Natural Resources, University of Urmia (*sebghati.marhamat@gmail.com*)
2- Associate Professor, Department of Range and Watershed Management, Faculty of Natural Resources, University of Guilan.

Received: 1 August 2016

Revised: 23 April 2018

Accepted: 25 April 2018

Keywords: EC, Groundwater Salinity, Mazandaran Plain, MLP. **DOI:** 10.22055/jise.2018.18828.1359.

Introduction

Groundwater is one of the most important water resources on earth, and water salinity studies are very important for the protection and planning of water resources, especially in arid and semiarid areas such as Iran. Groundwater currently accounts for more than 90 percent of Iran's total drinking water consumption. This water resource is less susceptible to bacterial pollution and evaporation than surface water, and hence it is more important than surface water.

Materials and Methods

An ANN includes three layers, namely, input layer, hidden layer and output layer. A network can have more than one hidden layer. In this study, multi-layer perceptron (MLP) was applied to simulate groundwater salinity. MLP is generated through adding one or more hidden layers to one-layer perceptron and can solve complex problems. The feed-forward neural network was the first and simplest type of artificial neural network devised. In a feed-forward network, the information moves in only one direction, forward, from the input nodes, through the hidden nodes and to the output nodes. In the first stage of simulation, all data were normalized and divided into three classes: training data (65% of all data), test data (25% of all data) and cross validation data (10 % of all data). The different transfer functions such as hyperbolic tangent and sigmoid transfer functions were evaluated. Based on the results of this study (through trial-and-error method), the hyperbolic tangent transfer function was the best transfer function. Artificial neural network (ANN) is an efficient tool in hydrologic studies. In this study, an integration of ANN and GIS (the geographic information system) was applied to simulate groundwater salinity. ANN and GIS were, indeed, used for simulation purposes and as a pre-processing and post-processing system of the applied data, respectively. Thus, GIS was applied as an efficient tool to provide the base maps and to estimate the model's quantitative parameters. Different digital/base maps were provided in GIS environment including DEM, transmissivity of aquifer formations, water table depth, precipitation values and distance from Caspian Sea and water resources using topographic maps of the region and EC values using water salinity secondary data. Different piezometric wells were selected to simulate groundwater salinity (EC). In GIS pre-processing stage, raster layers of the input factors were provided and combined using overlay analysis with a pixel size 1×1 km. Therefore, the surface of study plain was separated to more than 10000 geo-referenced pixels (1×1km). These pixels had values of model inputs or groundwater salinity factors (transmissivity of aquifer formation, water table depth and the distance from water resource). We inserted the site coordinate for every pixel automatically in the GIS medium.

Pixels data (networks inputs and coordinate) were exported from GIS and then imported to NeuroSolutions software. In ANN medium, groundwater salinity (EC) was simulated using the validated optimum network for all of the 10000 pixels (the whole study plain).

Results and Discussion

Groundwater salinity was estimated for the studied plain based on the secondary data, observational wells and a validated MLP network. We estimated significant factors on water salinity including aquifer formations transmissivity, water table depth, site elevation, and distance from water resource. A number of the estimated significant factors on water salinity and EC are presented in Table (1). These data were imported in ANN medium for simulating the groundwater salinity. In the training stage, the changes in input data pattern and sensitivity analysis showed that three factors constituted the best inputs for simulating groundwater salinity. These three factors are transmissivity of aquifer formation, groundwater depth and distance from water resources (Gholami et al., 2010). Digital maps of these three factors were generated in GIS, shows the results of ANN simulation in the training stage for ground water salinity simulation, and as can be seen, $R_{sqr}=0.78$. The results of network evaluation are presented in Tables (2) and (3) showing error values in the training stage. Accordingly, acceptable results were observed in the training stage. The optimum network structure in groundwater salinity simulation included an MLP with three inputs, tangent hyperbolic transfer function, LM (Levenberg- Marquart) training technique and one neuron. Tangent hyperbolic transfer function and LM training technique are some of the best selections in modeling hydrologic parameters which were applied in different studies as a prior selection in the world. Finally, the optimized network was validated in the test stage ($R^2=0.78$). Moreover, the validated network and GIS were applied to simulate and map the groundwater salinity on the Caspian southern coasts.

Table 1- factors of groundwater salinity (EC) values and model inputs for a number of wells

Salinity (μ mho/cm)	Transmissivity (m ² /day)	Water table Depth (m)	Elevation (m)	Annual evaporation (Mm)	Annual evaporation (Mm)
6400	175	1.54	7227	1000	630
6200	100	2	3266	1000	650
5400	175	2.25	7159	1000	650
5200	100	3	2463	1000	650
5000	175	0.88	7651	1000	750
4800	175	2.25	9737	1000	650
4400	375	3	1271	1000	700
4200	100	1.73	1894	1000	620
4020	100	0.9	4276	1000	700
2900	175	2.24	6657	1000	700
3750	100	3	9567	1000	650
3600	100	2	1358	1000	670

Table 2-The results of network training for simulating EC

All runs	Training minimum	Training standard deviation	Cross validation minimum	Cross validation standard deviation
(Average of minimum MSEs)	0.02	0.0003	0.02	0.0006
(Average of final MSEs)	0.02	0.003	0.02	0.0006
The square of the mean squared error	0.009	0.009	0.16	0.16

Table 3- The results of network training and optimum network selection

(Best network)	validation	Training	Test
(Run)	1	2	-
(Epoch)	337	1000	-
(Average of minimum MSEs)	0.025	0.02	0.8
(Average of final MSEs)	0.025	0.02	0.9
The square of the mean squared error	0.16	0.09	0.112
R ²	-	-	0.78

Conclusions

Different model structures were developed to evaluate the probability impacts of enabling/disabling transmissivity of aquifer formation, water table depth, the distance from water resources as inputs. Results showed that three factors, namely, transmissivity of aquifer formation, water table depth, and the distance from water resources are the most important factors and the best inputs for groundwater salinity modeling (Gholami et al., 2010). Artificial neural network is an efficient tool in modeling, but it cannot preset its results in the forms of maps and geo-referenced data. We applied ANN to simulate the groundwater salinity and GIS as a pre-processing and post-processing tools in monitoring and mapping the results. Further, GIS resulted in an increasing modeling accuracy and modeling velocity. An MLP network with the tangent hyperbolic transfer function and LM training technique was the best network structure in the groundwater salinity simulation. Previous studies reported that an ANN with LM technique was an efficient structure in the hydrological parameters simulation (Chen and Adams, 2006).

Acknowledgements

Finally, the authors would like to acknowledge and thank the staff of Mazandaran Regional Water Company for providing the data required for the present study.

References

- 1- Chen, J. and Adams, B.J., 2006. Integration of artificial neural networks with conceptual models in rainfall-runoff modeling. *Journal of Hydrology*, 318(1), pp.232-249.
- 2- Gholami, V., Yousefi, Z. and Rostami, H.Z., 2010. Modeling of ground water salinity on the Caspian southern coasts. *Water resources management*, 24(7), pp.1415-1424.



© 2019 by the authors. Licensee SCU, Ahvaz, Iran. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0 license) (<http://creativecommons.org/licenses/by/4.0/>).

شبیه سازی شوری آب زیرزمینی با تلفیق قابلیت های شبکه عصبی مصنوعی و سیستم اطلاعات جغرافیایی در سواحل جنوبی خزر

مرحمت سبقتی^{۱*} و وحید غلامی^۲

*-نویسنده مسئول، دانشجوی دکتری منابع طبیعی- آبخیزداری، دانشگاه ارومیه، Sebhathi.marhamat@gmail.com

۲- دانشیار دانشکده منابع طبیعی دانشگاه گیلان- گروه مرتع و آبخیزداری.

پذیرش: ۱۳۹۷/۲/۵

بازنگری: ۱۳۹۷/۲/۳

دریافت: ۱۳۹۵/۵/۱۱

چکیده

با توجه به شرایط کشور ایران به لحاظ کمبود منابع آب سطحی، استفاده از منابع آب زیرزمینی برای تأمین آب مورد توجه قرار گرفته است. انجام آزمایش های کیفی، زمان بر و پرهزینه است. بنابراین، استفاده از مدل ها برای شبیه سازی کیفیت آب متداول شده است. در تحقیق حاضر شبکه عصبی مصنوعی برای شبیه سازی شوری آب زیرزمینی و سیستم اطلاعات جغرافیایی (GIS) به عنوان پیش پردازنده و پس پردازنده در شبیه سازی در سطح دشت مازندران استفاده شد. شوری آب زیرزمینی با استفاده از شبکه پرسپترون چندلایه (MLP) و با در نظر گرفتن هدایت الکتریکی (EC) آب زیرزمینی و کمی نمودن عوامل مؤثر در شوری آب، شبیه سازی گردید. سپس، آزمون یا اعتباریابی مدل و تأیید کارایی مدل انجام پذیرفت. در محیط سیستم اطلاعات جغرافیایی، سطح دشت مطالعاتی به سلول های یک در یک کیلومتری به فرمت رستری جدا شد و از تلفیق لایه های ورودی مدل، لایه زمین مرجع عوامل شوری آب تهیه گردید. مقادیر کمی برای هر سلول به همراه مختصات به محیط شبکه عصبی وارد گشت و شبیه سازی شوری آب زیرزمینی برای مکان های فاقد آمار با شبکه بهینه اعتباریابی شده، انجام پذیرفت. سپس، نتایج با توجه به دست یابی مقادیر ضریب تعیین GIS وارد و نقشه یا لایه رستری شوری آب زیرزمینی براساس نتایج شبیه سازی شبکه عصبی تهیه شد. نتایج با توجه به دست یابی مقادیر ضریب تعیین $R^2 = 0.78$ و معیار میانگین مربعات خطای RMSE برابر با ۰/۱۲۲ در مرحله آزمون با ارزیابی کارایی شبکه عصبی و همچنین تحلیل هم پوشانی مقادیر برآوردی و مقادیر مشاهداتی در محیط GIS، دلالت بر دقت و کارایی تلفیق شبکه عصبی و GIS در مطالعات داشته است.

کلید واژه ها: شوری آب، هدایت الکتریکی، MLP، دشت مازندران.

مقدمه

با پیشرفت صنایع و افزایش جمعیت بشر و عدم رعایت استانداردهای زیست محیطی، منابع آبی به خصوص منابع آب زیرزمینی با خطرات زیادی از لحاظ آلودگی مواجه است. متأسفانه بیشتر بحث کمی منابع آب مورد مطالعه قرار گرفته و به مطالعه های کیفی آب کمتر پرداخته شده است.

این مسئله بیانگر اهمیت مطالعه های کیفیت آب، نظیر عوامل مؤثر در شوری آب و اتخاذ تدابیری برای جلوگیری از آن می باشد (Gholami, et al, 2010). در شمال ایران در سواحل جنوبی خزر، بالا بودن سطح سفره های آب زیرزمینی، تبخیر آب در آب بندها و نزارها و پیشروی آب شور دریای خزر، افزایش شوری آب های سطحی و زیرزمینی را منجر شده است. بنابراین عوامل مؤثر در شوری آب زیرزمینی شامل: عمق آب زیرزمینی، نوع تشکیلات آبخوان، میزان بارش و تبخیر در سطح منطقه، توپوگرافی و فاصله از دریا می باشند (Gholami and Darvari., 2013). در کشور هند سلامت ۲/۳ میلیون نفر به دلیل استفاده از آب های زیرزمینی با کیفیت نامطلوب به خطر افتاده است (Shah et al., 2003). اما در مورد ایران آمار دقیقی در دسترس نمی باشد. افزایش شوری آب زیرزمینی می تواند اثرات

مخری بر محیط طبیعی یک منطقه داشته باشد (Langford., et al., 2009). Mondal et al. (2010) با تعیین رابطه بین آب های زیر زمینی و آب های شور نظریه ای دادند که در یک دوره بارندگی های موسمی ارتباط مستقیم بین غلظت آب های زیرزمینی و کل مواد جامد محلول با کلرید، سدیم، منیزیم و سولفات وجود دارد و افزایش میزان سدیم و پتاسیم به علت پیشروی آب دریا می باشد. همچنین، شبکه عصبی مصنوعی (Artificial Neural Network) قابلیت ویژه ای در شبیه سازی های کمی دارد، اما توانایی ارائه نتایج به صورت نقشه یا گرافیک زمین مرجع را دارا نمی باشد. از طرفی بکارگیری اطلاعات به صورت زمین مرجع و تلفیق آن با سایر اطلاعات برای مدل سازی ها و برنامه ریزی های مدیریتی ضروری است. سیستم اطلاعات جغرافیایی (Geographic Information System) در زمینه ذخیره، پردازش و تحلیل داده ها بسیار توانمند است. Jang و Chen (2015) در رودخانه چوشویی تایوان با به کارگیری روش های زمین آمار به ارزیابی اثرات نیترات بر کیفیت آب زیرزمینی پرداختند و دریافتند روش کریجینگ نسبت به کریجینگ لجستیک نتایج بهتری را برای برآورد پارامتر مورد نظر و تهیه نقشه تغییرات آن ارائه می دهد. در زمینه به کارگیری شبکه عصبی در مطالعه های

ابزاری برای برنامه‌ریزی در جهت مدیریت و کاهش خطر شوری آب زیرزمینی و باشند.

مواد و روش‌ها

منطقه مورد مطالعه

منطقه مورد مطالعه در تحقیق حاضر، دشت مازندران (نیمه شمالی استان مازندران) در شکل (۱) ارائه شده است. این دشت از شمال به دریای خزر، از شرق به استان گلستان و از غرب به استان گیلان و از جنوب به ارتفاعات البرز مرکزی محدود می‌شود. محدوده مطالعاتی تحقیق حاضر در سواحل جنوبی دریای خزر در محدوده طول شرقی $34^{\circ} 50'$ تا $54^{\circ} 10'$ و عرض شمالی $35^{\circ} 37'$ واقع شده است. تغییرات شیب و ارتفاع در سواحل جنوبی خزر اندک بوده و عمدتاً مناطق مسطح دشتی شامل رسوبات آبرفتی کواترنری را شامل می‌شود، اما در جنوب، ارتفاعات البرز مرکزی گسترده می‌باشند. میزان بارش از غرب حدود 1300 میلی‌متر تا شرق استان حدود 600 میلی‌متر کاهش می‌یابد. اقلیم منطقه معتدل مرطوب است. دشت مازندران از منابع آب سطحی و زیرزمینی غنی برخوردار است و شکل رایج بهره‌برداری از آب زیرزمینی حفر چاه‌های کم عمق می‌باشد.

تعیین شاخص برای ارزیابی شوری آب زیرزمینی

در تحقیق حاضر از شاخص هدایت الکتریکی (EC) آب زیرزمینی به عنوان معیار شوری آب استفاده گردید. شاخص هدایت الکتریکی آب زیرزمینی نشان دهنده میزان مجموع نمک‌های محلول است. به عبارت دیگر، درجه شوری آب را از روی هدایت الکتریکی آن برحسب میلی‌موس بر سانتی‌متر محاسبه می‌کنند. طبقات مختلف شوری آبیاری از نظر شاخص عبارتند از (Ghosh and Sharma, 2006).

الف- هدایت الکتریکی < 250 میکروموس بر سانتی‌متر = شوری خیلی کم ب- هدایت الکتریکی $250-750$ میکروموس بر سانتی‌متر = شوری کم ج- هدایت الکتریکی $750-2250$ میکروموس بر سانتی‌متر = شوری متوسط د- هدایت الکتریکی $2250-4000$ میکروموس بر سانتی‌متر = شور و- هدایت الکتریکی > 4000 میکروموس بر سانتی‌متر = خیلی شور می‌باشد (Mahdavi, 1999). در این مطالعه ابتدا تعداد 146 حلقه چاه آب مشاهداتی شرکت آب منطقه‌ای مازندران انتخاب گردید. چاه‌های انتخابی دارای تعداد بالایی نمونه‌برداری و آزمایش‌های کیفی منظم در طی دهه گذشته می‌باشند. موقعیت چاه‌های مورد مطالعه دشت مازندران در شکل (۱) ارائه شده است. شوری آب زیرزمینی در طی زمان متغیر است. که تابع عوامل مختلف خواهد بود. نمونه‌برداری و آزمایش‌های کیفی آب زیرزمینی در چاه‌های مشاهداتی هر ماه یک‌بار انجام می‌پذیرد. در پژوهش حاضر متوسط شوری آب با دوره متوسط دو ساله به‌عنوان شوری آب چاه مورد مطالعه در نظر گرفته شد.

هیدرولوژی، تحقیقات متعددی انجام گرفته است از جمله آن‌ها می‌توان به Li et al. (2012)؛ Mohanty et al. (2013) و Ducci و Sellerino (2013) اشاره نمود که نتایج آن‌ها دلالت بر کارایی شبکه عصبی در مدل‌سازی‌ها داشته است. در زمینه به‌کارگیری تلفیقی قابلیت‌های این دو سامانه Gangopadhyay et al. (1999) با استفاده تلفیقی از قابلیت‌های شبکه عصبی و سیستم اطلاعات جغرافیایی به مدل‌سازی آب زیرزمینی در تایلند اقدام نمودند و دریافتند که روش به‌کارگیری تلفیقی شبکه عصبی و سیستم اطلاعات جغرافیایی ابزاری کارآمد برای شبیه‌سازی ژئومتری و پارامترهای هیدرودینامیکی آبخوان می‌باشد.

Lallahem et al. (2005) با استفاده از شبکه عصبی به ارزیابی تغییرات سطح آب زیرزمینی پرداختند و به این نتیجه رسیدند که شبکه عصبی کارایی مطلوبی در برآورد سطح آب زیرزمینی دارد. Daliakopoulos et al. (2005) برای برآورد سطح آب زیرزمینی از شبکه عصبی با روش پس انتشار خطا و الگوریتم لونیبرگ-مارکواردت (Levenberg-Marquardt) استفاده کردند و به این نتیجه رسیدند که این مدل قادر است با استفاده از داده‌های محدود، برآورد قابل قبولی را برای سطح آب زیرزمینی در آینده ارائه دهد.

Krishna et al. (2008) با استفاده از شبکه عصبی به مدل‌سازی آب زیرزمینی در شهر ساحلی کاکینادا در هند پرداخت و به این نتیجه دست یافت که این مدل با روش پس انتشار خطا و الگوریتم بهترین پیش‌بینی را ارائه می‌دهد.

Singh et al. (2011) با مطالعه‌ای دریافتند که سیستم اطلاعات جغرافیایی می‌تواند ابزاری کارآمد برای مطالعات آب‌های زیرزمینی و طبقه‌بندی کیفیت آب باشد. تحقیقات ایشان نشان داد که توسعه شهری و مناطق مسکونی تأثیر مهمی در کاهش کیفیت آب داشته است. گام نخست ارزیابی کیفیت آب، تعیین شاخص کیفیت آب مناسب با توجه به داده‌های موجود می‌باشد. Stigter et al. (2006) از شاخص کیفیت آب زیرزمینی برای ارزیابی تأثیر فعالیت‌های کشاورزی روی کیفیت آب و پارامترهای کیفی آب استفاده کردند. با در نظر گرفتن مطالب بیان شده می‌توان چنین استنباط کرد که به‌دلیل اهمیت به‌سزای منابع آب زیرزمینی، بررسی مطالعات کیفی این منابع می‌تواند کمک مؤثری در مدیریت و برنامه‌ریزی استفاده از این منابع آبی داشته باشد. هدف از این مطالعه بررسی وضعیت شوری آب زیرزمینی دشت مازندران با استفاده از GIS (رقومی‌سازی داده‌ها) و شبکه عصبی مصنوعی (با استفاده از داده‌های رقومی اعتبارسنجی) می‌باشد تا بتوان بر اساس مطالعه‌های کیفیت آب‌های زیرزمینی به نقشه‌های پهنه‌بندی شوری آب زیرزمینی دست یافت که این نتایج می‌تواند

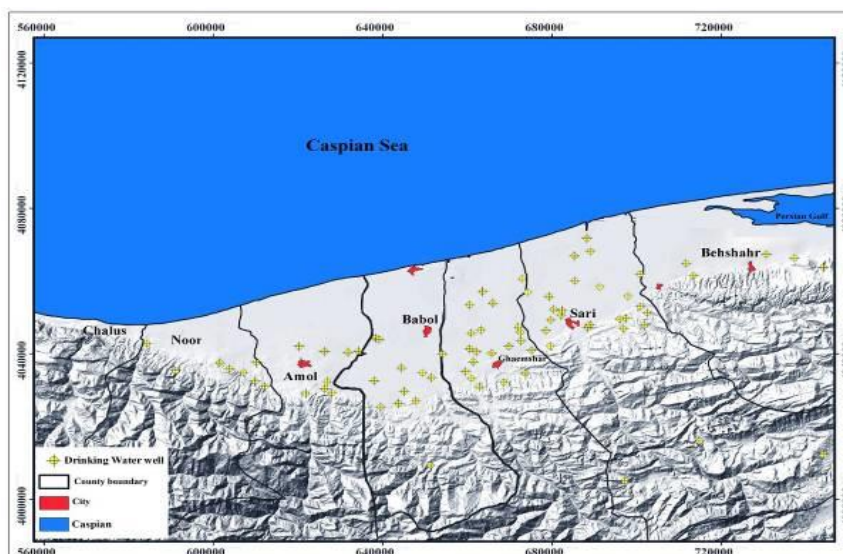


Fig 1- Location of Mazandaran Plain and Study Wells in Mazandaran Province

شکل ۱- موقعیت دشت مازندران و چاه‌های مطالعاتی در سطح استان مازندران

مرحله صحت‌سنجی (Cross Validation) و حدود ۲۵ درصد برای مرحله آزمون یا اعتباریابی تفکیک شدند. در این تحقیق، از تابع غیرخطی مشتق‌پذیر سیگموئید و تابع انتقال تانژانت هیپربولیک استفاده شده است. مقایسه نتایج در مرحله آموزش (آزمون و خطا)، استفاده از تابع انتقال تانژانت هیپربولیک را به‌عنوان گزینه مناسب تعیین نمود. هم‌چنین، با آزمون و خطا و ارزیابی کارایی هر یک از روش‌ها، روش یادگیری (LM) به‌عنوان تکنیک یادگیری بهینه انتخاب گردید. آموزش شبکه یکی از گام‌های مهم در مدل‌سازی با شبکه عصبی تلقی می‌گردد که در واقع همان فرآیند بروزرسانی ضرایب وزنی در لایه (های) میانی و خروجی است. نرون‌ها باید از اشتباهات خود درس گرفته و در جهت بهبود نتیجه حرکت کنند. روند آموزش شبکه به‌طور معمول به دو گونه متفاوت الگو به الگو (حالت متوالی) و گروهی (حالت دسته‌ای) انجام می‌شود. تجربه نشان داده که روش دوم به نتایج بهتری می‌رسد (Rajurkar et al., 2004). اما، بهتر است این مقادیر به گونه‌ای گزینش شوند که موجب سرعت بیشتر آموزش و هم‌گرایی بهتر مسأله مورد نظر گردد. مبنای تصمیم‌گیری برای انتخاب بهترین شبکه در هر بار اجرای برنامه، ضریب همبستگی (R) و متوسط قدر مطلق خطا (MSE) بوده است. برای تعیین معماری بهینه شبکه از روش سعی و خطا و با انجام آزمون‌های مختلف، شبکه‌ای که کمترین میزان خطا و بیشترین کارایی را دارد، انتخاب گردید. در تعیین معماری بهینه سعی گشته از ساختارهای ساده با تعداد ورودی‌های مؤثر استفاده شود.

معرفی شبکه عصبی (ANN)

معماری معمول شبکه‌های عصبی مصنوعی متشکل از سه لایه است. لایه ورودی که داده‌ها را در شبکه توزیع می‌کند، لایه پنهان که داده‌ها را پردازش می‌نماید و لایه خروجی که نتایج را براساس ورودی‌های مشخص، استخراج می‌نماید. یک شبکه می‌تواند چندین لایه پنهان داشته باشد. در تحقیق حاضر شبکه پرسپترون چندلایه (Multi-Layer Perceptron) یا برای شبیه‌سازی شوری آب زیرزمینی استفاده شد که در شکل (۲) ارائه شده است. شبکه پرسپترون چند لایه با افزودن یک یا چند لایه پنهان به شبکه پرسپترون تک‌لایه ساخته می‌شود و این توپولوژی توانایی حل مسائل پیچیده را دارد (Tokar and Markus, 2000).

مدل عمومی شبکه پرسپترون چندلایه، شبکه جلو رونده (Forward Feed) با روال تعلیم انتشار به عقب (Propagation Training) می‌باشد. شبکه جلورونده شبکه‌ای است که ورودی‌های لایه اول نرون‌های آن به لایه بعدی متصل است و در هر سطح این امر صدق می‌کند تا به لایه خروجی برسد. انتشار به عقب به این معنی است که پس از رسیدن به خروجی شبکه، ابتدا وزن‌های لایه آخر تصحیح شده و بعد به ترتیب وزن‌های لایه‌های قبلی تصحیح می‌گردند. شبکه مورد استفاده در تحقیق حاضر، پرسپترون چند لایه با الگوریتم پس انتشار و تابع انتقال تانژانت هیپربولیک در لایه مخفی و تابع خطی در لایه خروجی می‌باشد. برای ارائه ساختار بهینه شبکه عصبی و اعتباریابی آن داده‌ها به سه دسته تقسیم شدند. ۶۵ درصد داده‌ها برای آموزش، ۱۰ درصد برای




Fig. 1- Structure of Multilayer Neural Network

شکل ۲- ساختار شبکه عصبی چندلایه

$$EC = f(T, G_w, P) \quad (۶)$$

$$EC = f(T, E, P) \quad (۷)$$

$$EC = f(T, P) \quad (۸)$$

$$EC = f(T, E) \quad (۹)$$

در روابط فوق EC : شوری یا هدایت الکتریکی آب زیرزمینی بر حسب میکروموس بر سانتیمتر، f : عوامل موثر ورودیها T : قابلیت انتقال متوسط تشکیلات آبخوان بر حسب متر مربع در روز، G_w : عمق متوسط سفره آب زیرزمینی به متر، LS : فاصله از دریا بر حسب متر، E : تبخیر متوسط سالانه به میلی‌متر و P : بارش متوسط سالانه به میلی‌متر می‌باشد. این نه الگوی ورودی با ساختار شبکه عصبی ثابت برای شبیه‌سازی شوری آب زیرزمینی بکار گرفته شدند و با به‌کارگیری روش آزمون و خطا و انجام تحلیل حساسیت مشخص شد که ساختار بهینه ورودی‌های شبکه شامل سه ورودی قابلیت انتقال تشکیلات آبخوان، بارش سالانه و فاصله از دریای خزر می‌باشد. در نهایت ساختار بهینه شبکه با مشخص شدن ورودی‌های بهینه، تابع انتقال و تکنیک یادگیری مناسب و تکرار آموزش شبکه تعیین گشت. پس از آموزش، ارزیابی کارایی شبکه یا مرحله آزمون با داده‌های دیگر انجام پذیرفت.

تلفیق قابلیت‌های شبکه عصبی (ANN) و سیستم اطلاعات جغرافیایی (GIS)

شبکه عصبی قابلیت نسبتاً بالایی در شبیه‌سازی مقادیر کمی پارامترهای هیدرولوژیک دارد، اما در ارائه نتایج به شکل گرافیکی و به‌خصوص گرافیکی زمین مرجع دارای محدودیت است. در تحقیق حاضر از تلفیق قابلیت‌های شبکه عصبی و سیستم اطلاعات جغرافیایی برای مدل‌سازی شوری آب زیر زمینی استفاده گردید. شبکه عصبی به‌عنوان سامانه‌ای برای شبیه‌سازی و سیستم اطلاعات جغرافیایی به‌عنوان سامانه پیش پردازنده و پس پردازنده داده‌ها به‌کار گرفته شد. ابتدا عوامل کمی پارامترهای مدل شامل قابلیت انتقال تشکیلات آبخوان، عمق متوسط سفره، فاصله از دریا، تبخیر و بارش سالانه با استفاده از داده‌ها، نقشه‌ها و لایه‌های رقومی موجود در محیط سیستم اطلاعات جغرافیایی برای ۱۴۶ حلقه چاه آب مطالعاتی برآورد گشت. پس از کمی نمودن داده‌ها،

مشخصات ورودی شبکه

هدف از آموزش شبکه دست‌یابی به شبکه‌ای است که بتواند روابط بین ورودی و خروجی مدل را به‌یود بخشد. به‌علت اینکه قوانین خاصی جهت طراحی شبکه‌های عصبی مصنوعی (ANN)، موجود نیست، ساختارهای مختلفی مورد بررسی قرار گرفت. در این تحقیق ابتدا اطلاعات گسترده‌ای شامل آزمایش‌های شوری آب زیرزمینی، نوع تشکیلات آبخوان و قابلیت انتقال آنها، عمق متوسط سفره آب زیرزمینی، فاصله از منابع آب (دریا)، تبخیر و بارش سالانه تهیه شدند. برای مدل‌سازی شوری آب زیرزمینی، ۱۴۶ حلقه چاه مشاهداتی شرکت آب منطقه‌ای مازندران در سطح دشت مازندران در نظر گرفته شد و برای چاه‌های مطالعاتی شاخص هدایت الکتریکی آب زیرزمینی به‌عنوان معیاری جهت ارزیابی و طبقه‌بندی شوری آب براساس آزمایش‌های کیفی آب در دوره دو ساله برآورد گشت. هدف شبیه‌سازی شوری آب با استفاده از شبکه عصبی مصنوعی می‌باشد.

عوامل مؤثر در شوری آب شامل نوع تشکیلات آبخوان و قابلیت انتقال آنها، عمق متوسط سفره آب زیرزمینی، فاصله از منابع آب (دریا)، تبخیر سالانه و بارش سالانه بر اساس نقشه‌ها و لایه‌های رقومی سازمان تحقیقات منابع آب ایران و نقشه‌های توپوگرافی ۱:۲۵۰۰۰ و همچنین مطالعات اطلس منابع آب استان برآورد گشت. به‌عبارتی، برای ۱۴۶ حلقه چاه مطالعاتی شاخص EC به‌عنوان متغیر وابسته یا خروجی شبکه و عوامل مؤثر در شوری آب به‌عنوان متغیرهای مستقل یا ورودی‌های شبکه برآورد شده و به محیط نرم‌افزار NeuroSolutions برای مدل‌سازی وارد شدند. برای آموزش و سپس آزمون کارایی یک شبکه عصبی، انتخاب تعداد و نوع پارامترهای ورودی به مدل از اهمیت بسیاری برخوردار است (Gholami and Darvari, 2013). به همین دلیل براساس روش آزمون و خطا نه الگوی ورودی طراحی، شامل موارد زیر ارزیابی شده است:

$$EC = f(T, G_w, LS, E, P) \quad (۱)$$

$$EC = f(T, G_w, E, P) \quad (۲)$$

$$EC = f(T, G_w, E) \quad (۳)$$

$$EC = f(T, G_w, E, LS) \quad (۴)$$

$$EC = f(T, P, LS) \quad (۵)$$

مدل سازی در محیط شبکه عصبی با هدف شبیه سازی شوری آب زیرزمینی انجام پذیرفت. در این مرحله، آموزش داده ها و سپس آزمون یا اعتباریابی شبکه انجام پذیرفت و در نهایت شبکه عصبی بهینه اعتباریابی شده ارائه گشت. در گام بعدی، سیستم اطلاعات جغرافیایی نقش پیش پردازنده را ایفا خواهد نمود. هدف از تحقیق، استفاده از شبکه عصبی برای شبیه سازی شوری آب زیرزمینی برای مکان های فاقد آمار آن هم به صورت گرافیکی زمین مرجع می باشد. براساس نتایج، ساختار بهینه شبکه عصبی برای شبیه سازی شوری آب زیرزمینی نیاز به سه ورودی قابلیت انتقال متوسط تشکیلات آبخوان، بارش سالانه و فاصله از دریا دارد. در این مرحله، لایه های رستری سه عامل مذکور تهیه شدند و با تحلیل هم پوشانی با اندازه سلولی یک در یک کیلومتر با یکدیگر تلفیق شدند. بنابراین، سطح دشت مازندران در محیط سیستم اطلاعات جغرافیایی به بیش از ده هزار سلول زمین مرجع دارای رقوم عوامل شوری آب (سه عامل مذکور) تفکیک شد. آنچه مسلم هست اندازه شبکه سلولی را می توان کوچک تر در نظر گرفت که موجب نتایج دقیق تر در مورد ورودی یا عامل فاصله از دریا خواهد شد، اما تعداد خیلی زیاد سلول ها، محدودیت اجرای شبیه سازی در محیط نرم افزار شبکه عصبی را همراه داشته است. داده های این سلول ها (ورودی های مدل) و مختصات که به طور خودکار برای هر

سلول درج شده بود از محیط GIS خروجی گرفته شد و به محیط شبکه عصبی وارد گشت. در محیط شبکه عصبی با به کارگیری شبکه بهینه اعتباریابی شده، شوری آب (EC) برای تمامی ده هزار سلول برآورد شد. سپس، مقادیر شوری آب برآوردی به همراه مختصات از محیط شبکه عصبی به محیط سیستم اطلاعات جغرافیایی وارد گشت. در این مرحله سیستم اطلاعات جغرافیایی نقش پس پردازنده را ایفا می نماید. مقادیر شوری آب به واسطه مختصات (عامل کمکی برای تشخیص موقعیت جغرافیایی) همراه با آن و قابلیت های سیستم اطلاعات جغرافیایی به صورت لایه رستری شوری آب زیرزمینی دشت مازندران ارائه شد. مقادیر شاخص شوری آب زیرزمینی چاه مطالعاتی بر روی لایه رستری کیفیت آب شبیه سازی شده هم پوشانی شد تا صحت و دقت نتایج از طریق مقایسه اعداد مقادیر شبیه سازی شده و مقادیر واقعی ارزیابی و تایید گردد. در نهایت، لایه شوری آب زیرزمینی پس از طبقه بندی به صورت نقشه پهنه بندی خطر شوری آب زیرزمینی ارائه گشت. در تحقیق حاضر با استفاده از تلفیق قابلیت های شبکه عصبی و GIS، شبیه سازی با دقت و سرعت عمل بالا در سطحی وسیع انجام شد و نتایج به صورت زمین مرجع گرافیکی (نقشه) ارائه گشت. روش انجام پژوهش در شکل (۳) بیان شده است.

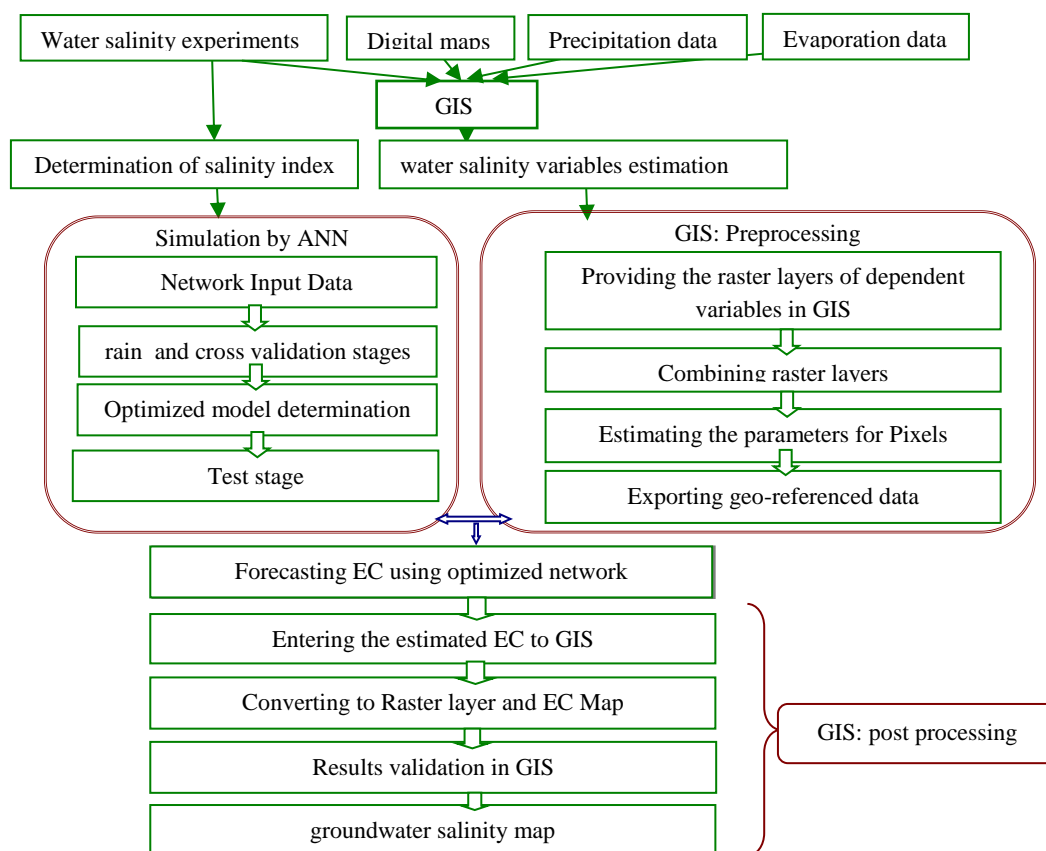


Fig. 2- The flow chart showing the methodology stages used in this study

شکل ۳- نمایش مراحل روش جریان مورد استفاده در این مطالعه

نتایج

براساس نتایج، شبکه عصبی دقت قابل قبولی در برآورد شوری آب زیرزمینی دارد ($R^2=0.78$). چنین نتیجه‌ای با نتایج محققان دیگر هم‌خوانی دارد (Anctil and Rat, 2005). هدف از تحقیق حاضر برآورد شوری آب زیرزمینی در مکان‌های فاقد آمار و ارائه نتایج به گونه قابل استفاده برای عموم است. بدین منظور لایه‌های رستری عوامل شوری آب یا ورودی‌های شبکه با اندازه سلولی یک در یک کیلومتری در محیط GIS تهیه و سپس، این سه لایه رستری با یکدیگر تلفیق گردید. در نهایت در محیط GIS، یک لایه زمین مرجع حاوی سه پارامتر ورودی شبکه بهینه خواهیم داشت. اطلاعات هر سلول به همراه مختصات از محیط GIS به محیط شبکه عصبی (نرم افزار NeuroSolutions) وارد شد. سپس، از شبکه عصبی بهینه اعتباریابی شده برای برآورد شوری آب در مکان‌های فاقد آمار استفاده گشت.

شبکه عصبی، شاخص شوری آب را برای هر سلول برآورد نموده و مقادیر برآورد شده با مختصات (X,Y) دوباره به محیط Arc GIS به‌عنوان پس‌پردازنده وارد گشت. از قابلیت‌های GIS برای پایش نتایج شبکه عصبی به‌صورت لایه رستری شاخص شوری آب استفاده شده است که نتایج، در شکل (۸) مشاهده می‌گردد. همچنین پهنه‌بندی شوری آب زیرزمینی در دشت مطالعاتی در این شکل ارائه شده است. همان‌طور که در این اشکال مشاهده می‌گردد به‌منظور ارزیابی مجدد نتایج و صحت مراحل انجام کار، موقعیت چاه‌های مطالعاتی با رقم شوری آب (EC) بر روی لایه یا نقشه شوری آب برآوردی درج شده است. مقایسه ارقام واقعی با پهنه‌های شوری آب برآوردی، حاکی از کارایی شبکه عصبی و کارایی روش تلفیق شبکه عصبی و سیستم اطلاعات جغرافیایی دارد (Gangopadhyay., 1999). همان‌طوری که در نقشه حاصله شکل (۸) مشاهده می‌شود روش ارائه شده در تحقیق حاضر توانسته است شبیه‌سازی قابل قبولی برای طبقه‌بندی شوری آب زیرزمینی ارائه نماید و میزان خطای موجود، در صحت طبقه‌بندی شوری آب در سطح وسیع یک دشت یا یک حوضه آبخیز خدشه‌ای وارد نمی‌کند.

شوری آب زیرزمینی برای آب چاه‌های مطالعاتی براساس نمونه برداری‌های یک دوره ۲۴ ماهه برآورد شد. مقادیر کمی عوامل موثر در شوری آب براساس داده‌ها و نقشه‌های رقمی برآورد شده و نمونه‌هایی از مقادیر برآوردی برای چاه‌های مطالعاتی در جدول (۱) ارائه شده است. پس از برآورد کمی شوری آب زیرزمینی و عوامل موثر در آن برای ۱۴۶ حلقه چاه مطالعاتی، ورود داده‌ها و به‌کارگیری آن‌ها در محیط شبکه عصبی انجام شد. آموزش شبکه با ۶۵ درصد داده‌ها و صحت‌سنجی یا Cross validation با ۱۰ درصد داده‌ها انجام پذیرفت و در نهایت ۲۵ درصد داده‌ها برای اعتباریابی یا آزمون به‌کار گرفته شدند. در مرحله آموزش تغییر الگوی‌های داده‌های ورودی و تحلیل حساسیت شبکه به داده‌های ورودی نشان داد که سه پارامتر قابلیت انتقال تشکیلات آبخوان، بارش منطقه و فاصله دریا بهترین ورودی‌ها یا عوامل اصلی تأثیر گذار در شوری آب زیرزمینی می‌باشند. نقشه‌های رقمی این سه عامل در محیط سیستم اطلاعات جغرافیایی تهیه شدند که در شکل‌های (۴) تا (۶) ارائه شده است. نتایج ارزیابی کارایی شبکه در شبیه‌سازی شوری آب زیرزمینی در مرحله آموزش در جداول (۲) و (۳) ارائه شده است. جداول (۲) و (۳) که منعکس‌کننده میزان خطا در مرحله آموزش می‌باشند که بر اساس آن‌ها، نتایج مناسبی در مرحله آموزش حاصل آمد. ساختار بهینه شبکه شامل شبکه پرسپترون چند لایه با سه ورودی، تابع انتقال تانژانت هیپربولیک، روش یادگیری لوبنرگ-مارکوارت و یک نرون جهت شبیه‌سازی شوری آب زیرزمینی می‌باشد. روش یادگیری LM برای شبیه‌سازی مسائل هیدرولوژیک مناسب می‌باشند و در تحقیقات متعدد به‌عنوان گزینه برتر استفاده شده‌اند (Samani et al., 2007). در مرحله بعد، آزمون یا ارزیابی کارایی شبکه بهینه انجام شد. نتایج ارزیابی مرحله آزمون از طریق مقایسه مقادیر شبیه‌سازی شده و مقادیر واقعی ارزیابی در شکل (۷) ارائه شده است.

جدول ۱- نمونه‌ای از مقادیر شوری آب زیرزمینی (EC) و ورودی‌های مدل برای تعدادی از چاه‌های مطالعاتی
Table 1- Factors of groundwater salinity (EC) values and model inputs for a number of wells

Salinity (μ mho/cm)	Transmissivity (m ² /day)	Water table Depth (m)	Elevation (m)	Annual evaporation (Mm)	Annual evaporation (Mm)
6400	175	1.54	7227	1000	630
6200	100	2.00	3266	1000	650
5400	175	2.25	7159	1000	650
5200	100	3.00	2463	1000	650
5000	175	0.88	7651	1000	750
4800	175	2.25	9737	1000	650
4400	375	3.00	1271	1000	700
4200	100	1.73	1894	1000	620
4020	100	0.9	4276	1000	700
2900	175	2.24	6657	1000	700
3750	100	3.00	9567	1000	650
3600	100	2.00	1358	1000	670

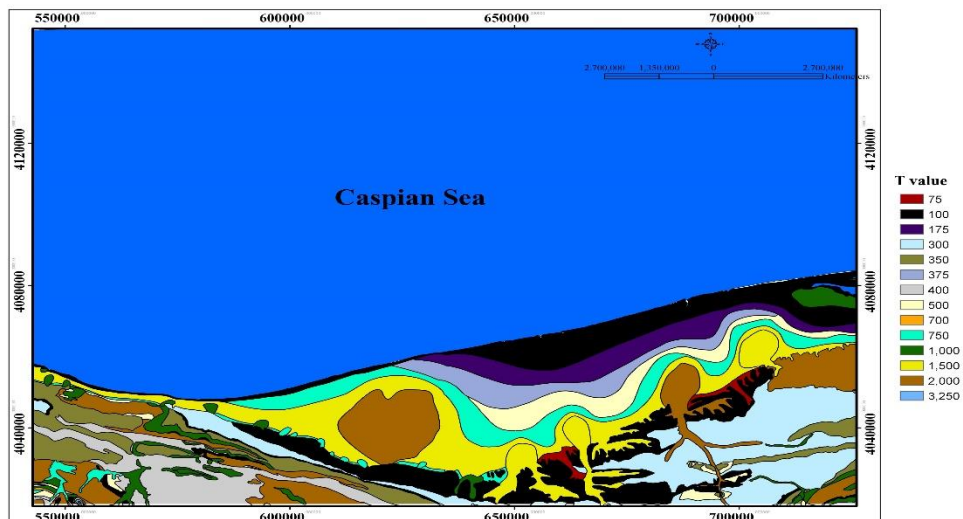


Fig. 4- The map of average transmissivity of aquifer formation in the study area (m^2/day)
 شکل ۴- نقشه قابلیت انتقال متوسط تشکیلات آبخوان دشت مطالعاتی (m^2/s)




Fig. 5- Map or raster layer of annual mean precipitation obtained from interpolation of statistics of meteorological stations in the region

شکل ۵- نقشه یا لایه رستری بارش متوسط سالانه حاصل از درون یابی آمار ایستگاه های هواشناسی منطقه

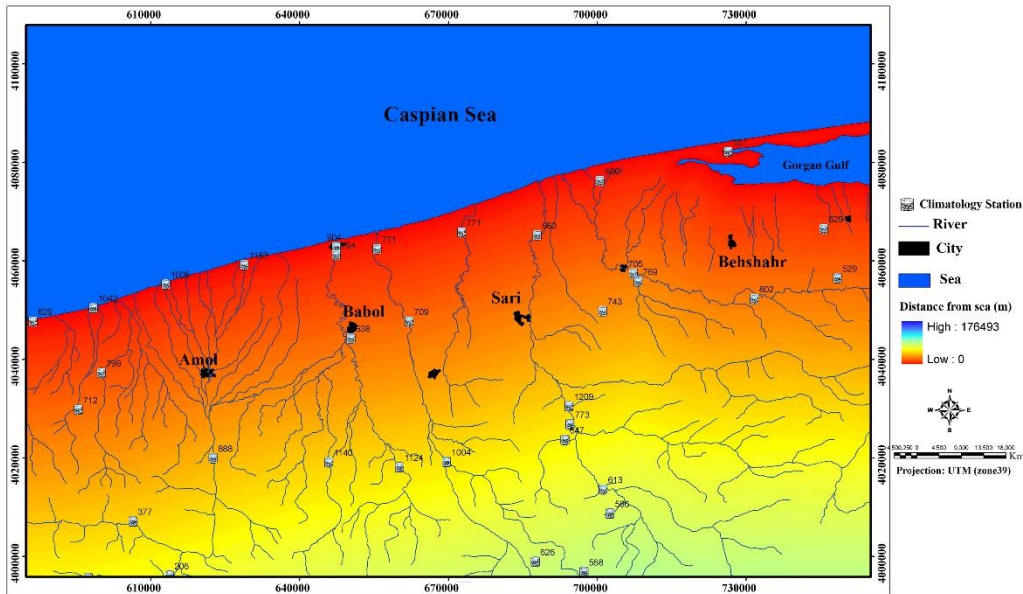


Fig. 6- The map of distance from sea at the level of the study area (m)

شکل ۶- نقشه یا لایه رستری فاصله از دریا در سطح دشت مطالعاتی بر حسب متر

جدول ۲- نتایج آموزش شبکه عصبی برای شبیه سازی شوری آب زیرزمینی

Table 2-The results of network training for simulating EC

All runs	Training minimum	Training standard deviation	Cross validation minimum	Cross validation standard deviation
(Average of minimum MSEs)	0.02	0.0003	0.02	0.0006
(Average of final MSEs)	0.02	0.003	0.02	0.0006
The square of the mean squared error	0.009	0.009	0.16	0.16

جدول ۳- نتایج آموزش شبکه عصبی و انتخاب شبکه عصبی بهینه

Table 3- The results of network training and optimum network selection

(Best network)	validation	Training	Test
(Run)	1	2	-
(Epoch)	337	1000	-
(Average of minimum MSEs)	0.025	0.02	0.8
(Average of final MSEs)	0.025	0.02	0.9
The square of the mean squared error	0.16	0.09	0.112
R ²	-	-	0.78




Fig. 7- Evaluation of ANN efficiency in groundwater salinity simulation. Comparison between estimated and actual EC values in the validation or test mumos /cm stage (R²=0.78)

شکل ۷- ارزیابی کارایی شبکه عصبی در شبیه سازی شوری آب زیرزمینی در مرحله آزمون یا اعتباریابی از طریق مقایسه

مقادیر واقعی و مقادیر شبیه سازی شده (R²=۰/۷۸)



Fig. 8- The map of groundwater salinity (EC) is resulted ANN and GIS capabilities
شکل ۸- نقشه شوری آب زیرزمینی (EC) حاصل از تلفیق قابلیت های GIS و ANN

داشته باشند. سیستم اطلاعات جغرافیایی حجم بالایی از ورودی های مدل را در زمان کوتاه مهیا نمود و شبکه عصبی بهینه اعتباریابی شده با سرعت مشابهی برای مکان های فاقد آزمایشهای کیفی، شوری آب زیرزمینی را برآورد نمود. در نهایت برآوردهای شبکه در محیط سیستم اطلاعات جغرافیایی به صورت لایه رقومی زمین مرجع ارائه شدند. نکته اصلی دقت ورودی ها و خروجی شبکه می باشد. آنچه مسلم است توانایی ایجاد اندازه سلولی کوچکتر وجود داشته و محققین می توانند اندازه سلولی داده های ورودی را در حد ۱۰ در ۱۰ متر در نظر بگیرند، اما در این مطالعه، دقت داده های رقومی موجود در مورد ورودی های شبکه در این حد نمی باشد. از طرفی با کوچکتر در نظر گرفتن اندازه سلولی، تعداد نمونه ها بسیار افزایش خواهد یافت و مشکل حجم بالای محاسبات به وجود می آید. براساس نتایج حاصله، بخش قابل توجهی از نیمه شرقی دشت مطالعاتی دارای منابع آب زیرزمینی شور و نسبتاً شور می باشند و با توجه به افزایش شوری آب در دهه های اخیر لزوم انجام مطالعات آتی و اخذ تدابیر لازمه برای حفاظت منابع آب گوشزد می شود. خوشبختانه، اطلاعات زیادی در مورد قابلیت انتقال تشکیلات آبخوان، بارش و فاصله از دریا در سطح دشت مازندران موجود است و برای به کارگیری مدل ارائه شده در سطح دشت مازندران مشکلی نخواهد داشت.

تقدیر و تشکر

در پایان نویسندگان بر خود لازم می دانند از همکاری و زحمات پرسنل شرکت آب منطقه ای مازندران به جهت تامین داده های مورد نیاز تحقیق حاضر و همچنین سایر حمایت های آن شرکت ها تقدیر و تشکر نمایند.

نتایج و بحث

براساس تحقیقات مختلف انجام شده در خصوص کارایی شبکه های عصبی مصنوعی، در مدل سازی پارامترهای هیدرولوژیک، واضح است که توانایی های این روش با توجه به ساختارهای مختلف آن و نیز طبیعت مسئله ای که باید حل شود، متفاوت می باشد. با انتخاب نوع و تعداد مناسب عوامل ورودی و نیز استفاده از نوع مناسب و سازگار شبکه عصبی مصنوعی و نیز واسنجی کردن مناسب آن می توان گفت که این روش ابزاری بسیار کارا و مناسب برای برآورد پارامترهای کیفیت آب می باشد. نتایج حاصل از تحقیق حاضر دلالت بر توانایی نسبتاً قابل قبول شبکه عصبی در شبیه سازی شوری آب زیرزمینی دارد. با توجه به نتایج عملکرد شبکه برای آرایش های مختلف و نیز مقایسه نتایج حاصله با داده های واقعی می توان گفت که عوامل قابلیت انتقال تشکیلات آبخوان، میزان بارش منطقه و فاصله از دریا مهم ترین عوامل تاثیرگذار در شوری آب زیرزمینی در دشت مطالعاتی می باشند (Gholami and Darvari., 2013). شبکه عصبی ابزاری کارآمد در مدل سازی می باشد، اما نکته حایز اهمیت، بکارگیری نتایج آن است. در تحقیق حاضر شبکه عصبی شبیه سازی شوری آب زیرزمینی و سیستم اطلاعات جغرافیایی به عنوان پیش پردازنده و پس پردازنده برای افزایش دقت و سرعت مدل سازی و پایش نتایج شبکه عصبی در سطح وسیع به کار گرفته شد. نتایج تحقیقات گذشته نیز حاکی از کارایی بالای شبکه عصبی در برآورد و شبیه سازی های هیدرولوژیک می باشد (Chen and Adams, 2006). محور اصلی تحقیق حاضر، ارتباط خودکار شبکه عصبی با سیستم اطلاعات جغرافیایی است تا نتایج قابل استفاده برای عموم کاربران باشد. همچنین، نتایج شبکه عصبی قابلیت تحلیل های هم پوشانی با سایر داده های محیطی را

References

- 1- Anctil, F. and Rat, A., 2005. Evaluation of neural network streamflow forecasting on 47 watersheds. *Journal of Hydrologic Engineering*, 10(1), pp.85-88.
- 2- Chen, J. and Adams, B.J., 2006. Integration of artificial neural networks with conceptual models in rainfall-runoff modeling. *Journal of Hydrology*, 318(1), pp.232-249.
- 3- Daliakopoulos, I.N., Coulibaly, P. and Tsanis, I.K., 2005. Groundwater level forecasting using artificial neural networks. *Journal of Hydrology*, 309(1), pp.229-240.
- 4- Ducci, D. and Sellerino, M., 2013. Vulnerability mapping of groundwater contamination based on 3D lithostratigraphical models of porous aquifers. *Science of the Total Environment*, 447, pp.315-322.
- 5- Gangopadhyay, S., Gautam, T.R. and Gupta, A.D., 1999. Subsurface characterization using artificial neural network and GIS. *Journal of Computing in Civil Engineering*, 13(3), pp.153-161.
- 6- Gholami, V. and Darvari, Z. 2013., Comparison of Performance of Multiple Regression and Artificial Neural Network (ANN) in Simulation of Groundwater Salinity on Mazandaran Provinces. *Journal of Water Research in Agriculture*. 26(1): 356-355. (In Persian).
- 7- Gholami, V., Yousefi, Z. and Rostami, H.Z., 2010. Modeling of ground water salinity on the Caspian southern coasts. *Water Resources Management*, 24(7), pp.1415-1424.
- 8- Ghosh, N.G. and Sharma, K.D. 2006. Groundwater Modeling and Management, Capital Publishing Company. Inter-basin of Odisha, India, *Journal of Hydrology* 495:38-51.
- 9- Jang, C.S. and Chen, S.K., 2015. Integrating indicator-based geostatistical estimation and aquifer vulnerability of nitrate-N for establishing groundwater protection zones. *Journal of Hydrology*, 523, pp.441-451.
- 10- Krishna, B., Satyaji Rao, Y.R. and Vijaya, T., 2008. Modelling groundwater levels in an urban coastal aquifer using artificial neural networks. *Hydrological Processes*, 22(8), pp.1180-1188.
- 11- Lallahem, S., Mania, J., Hani, A. and Najjar, Y., 2005. On the use of neural networks to evaluate groundwater levels in fractured media. *Journal of Hydrology*, 307(1), pp. 92-111.
- 12- Langford, R.P., Rose, J.M. and White, D.E., 2009. Groundwater salinity as a control on development of eolian landscape: An example from the White Sands of New Mexico. *Geomorphology*, 105(1), pp.39-49.
- 13- Li, X., Shu, L., Liu, L., Yin, D. and Wen, J., 2012. Sensitivity analysis of groundwater level in Jinci Spring Basin (China) based on artificial neural network modeling. *Hydrogeology Journal*, 20(4), pp.727-738.
- 14- Mahdavi, M. 1999. Applied Hydrology, Tehran University Press. 324, pp. (In Persian).
- 15- Mohanty, S., Jha, M.K., Kumar, A. and Panda, D.K., 2013. Comparative evaluation of numerical model and artificial neural network for simulating groundwater flow in Kathajodi-Surua Inter-basin of Odisha, India. *Journal of Hydrology*, 495, pp.38-51.
- 16- Mondal, N.C., Singh, V.P., Singh, V.S. and Saxena, V.K., 2010. Determining the interaction between groundwater and saline water through groundwater major ions chemistry. *Journal of Hydrology*, 388(1), pp.100-111.
- 17- Rajurkar, M.P., Kothyari, U.C. and Chaube, U.C., 2004. Modeling of the daily rainfall-runoff relationship with artificial neural network. *Journal of Hydrology*, 285(1), pp.96-113.
- 18- 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), pp.1-11.

- 19- Shah, T., Roy, A.D., Qureshi, A.S. and Wang, J., 2003, May. Sustaining Asia's groundwater boom: an overview of issues and evidence. In *Natural Resources Forum* (Vol. 27, No. 2, pp. 130-141). Blackwell Publishing Ltd.
- 20-Singh, C.K., Shashtri, S., Mukherjee, S., Kumari, R., Avatar, R., Singh, A. and Singh, R.P., 2011. Application of GWQI to assess effect of land use change on groundwater quality in lower Shiwaliks of Punjab: remote sensing and GIS based approach. *Water Resources Management*, 25(7), pp.1881-1898.
- 21-Stigter, T.Y., Ribeiro, L. and Dill, A.C., 2006. Application of a groundwater quality index as an assessment and communication tool in agro-environmental policies—Two Portuguese case studies. *Journal of Hydrology*, 327(3), pp.578-591.
- 22-Tokar, A.S. and Markus, M., 2000. Precipitation-runoff modeling using artificial neural networks and conceptual models. *Journal of Hydrologic Engineering*, 5(2), pp.156-161.