

Estimation hydraulic conductivity via intelligent models using geophysical data

Saeid Yusefzadeh¹, Ata Allah Nadiri^{1*}

1- Department of Earth Sciences, Faculty of Natural Sciences, University of Tabriz, Iran

Keywords: Artificial neural network, Adaptive neuro-fuzzy inference system, Support vector machine, Artificial intelligence, Hydraulic conductivity

1-Introduction

Appropriate AI models should be less structurally complex and do not require more or more extensive information to provide the most optimal modeling using appropriate input data. Along with smart models, the similarity of the laws governing electric currents such as Ohm's law with the laws governing groundwater flow in porous environments such as Darcy's law, as well as the similarity of parameters affecting electric current and groundwater flow such as electrical conductivity and hydraulic conductivity, make this possible. Given this similarity, it is possible to use geophysical data to estimate hydraulic conductivity. Hydraulic conductivity estimation using classical methods such as pumping test is performed in different aquifers with different methods, such as in confined aquifers by Theis method (Theis, 1935), Jacop-Cooper method (Cooper and Jacob, 1946) and the Chow method (Chow, 1952) and in leaky aquifers by the Hantush method (Hantush and Jacob, 1956) and the Walton method (Walton, 1962) and also in the unconfined aquifers of the Bolton method (Bolton, 1963, 1954) and the Neuman method (Neuman, 1972, 1975, 1973). In the method presented by Monech in the flow to a well with limited diameter in the homogeneous and anisotropic unconfined aquifer, the obtained synthetic data from an aquifer with a hypothetical water table, the inverse (type curve analysis) and forward (sensitivity analysis) methods were investigated and the exact values of hydraulic parameters were obtained (Monech, 1997).

Tyfur et al. (2014) also used the combined SICM method to estimate the hydraulic conductivity in the Tasuj plain. In the present study, the efficiency of artificial neural network (ANN) models, adaptive neural fuzzy inference system (ANFIS), and support vector machine (SVM) have been compared using geophysical data and hydrogeological data in Maragheh-Bonab plain. It has not yet been used to predict hydraulic conductivity so that this research could yield new practical results. Based on the results, the support vector machine showed better performance than the other models with RMSE = 1.08 and $R^2 = 0.97$ in the test phase.

2- Material and methods

Three types of artificial intelligence methods, including ANN, ANFIS, and SVM, were used to estimate the hydraulic conductivity in the Maragheh-Bonab plain, and their results were compared. Based on the new generation of experimental models, these models are divided into the black box and gray box models and their black-box models, which are divided into artificial intelligence models and machine learning models. Therefore, one of the most widely used models in each of these categories was hydrogeological modeling, including the artificial neural network model as an artificial intelligence model, the Neuro-fuzzy model as a gray box model SVM model as a machine learning.

After running the models, hydraulic conductivity distribution maps obtained from each of these methods and scatter charts for each model were prepared and displayed. Eighty data were collected, including specific transverse resistance values, electrical conductivity, saturation thickness, and UTM (X) and UTM (Y) hydraulic conductivity points. Out of 80 data, 65 data for the training stage, and 15 data for the experimental stage were selected. Models were implemented by coding in MATLAB software environment (MATLAB, 2015).

*Corresponding author: nadiri.ata@gmail.com

DOI: 10.22055/AAG.2020.29223.1970

Received 2019-04-23

Accepted 2020-07-18

3- Results and discussion

3-1- ANN results

In this study, a multilayer perceptron neural network with MLP-LM algorithm was used to estimate the hydraulic conductivity. The ANN structure studied in this study has five input nodes and nine hidden nodes. The modeling results are shown in Table 1. The ANN model has also performed better in some areas (Fig. 1) in estimating hydraulic conductivity.

3-2- ANFIS results

In the ANFIS model implementation, each input is clustered in a different radius. In the next step, the number of fuzzy rules is determined for fuzzy fiction. The clustering radius values and the number of fuzzy rules must be proportional to the minimum error rate of the model. This model also shows better performance in some places and weaker performance in others (Fig. 2).

3-3- SVM results

The support vector machine used in this study is the least square support vector machine (LS-SVM). The performance of the model is presented in Table 1 that performs better in all test points than the other two models. However, in points 9 and 10, it shows poor performance compared to other points that can be due to lithological changes relative to other sites (Fig. 3).

The results show that the support vector machine model (of machine learning models) has performed better on test points than ANN and ANFIS models to learn the complicated relationship between input data and filter out possible errors. The results of the models are summarized based on the evaluation criteria presented in Table 1.

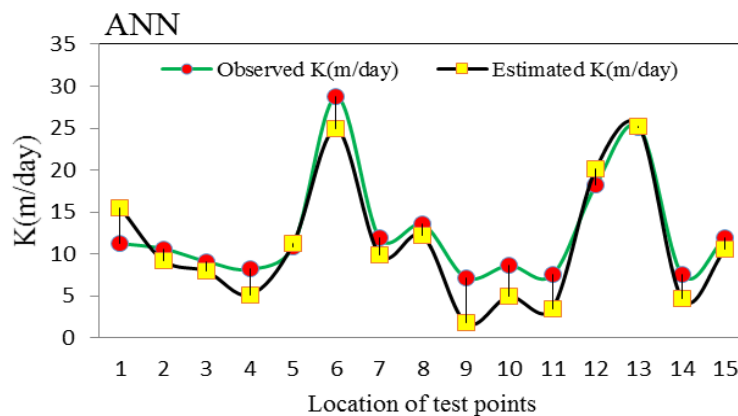


Fig. 1 .Comparison of observed and estimated values of hydraulic conductivity at test points by ANN model.

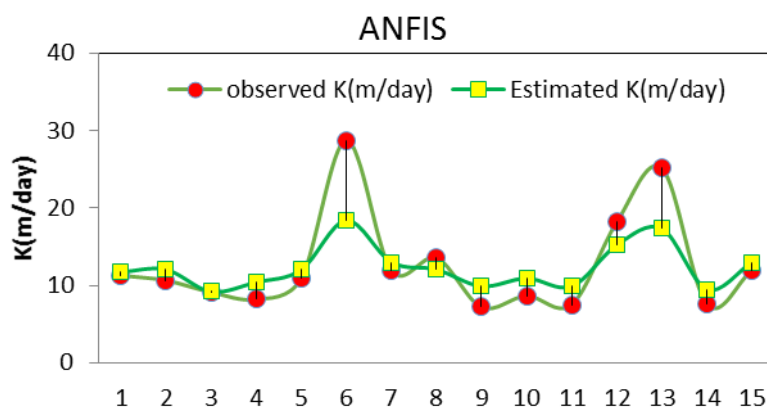


Fig. 2. Comparison of observed and estimated values of hydraulic conductivity at test points by ANFIS.

4- Conclusion

This study shows that by selecting the appropriate type and number of inputs and using proper and compatible artificial intelligence techniques, these techniques can be an excellent tool for estimating hydrogeological parameters such as hydraulic conductivity. The results of this study include the results of an artificial neural network model (ANN) with a three-layer perceptron structure with an LM algorithm, an adaptive neuro-fuzzy inference system (ANFIS), and a support vector machine (SVM).

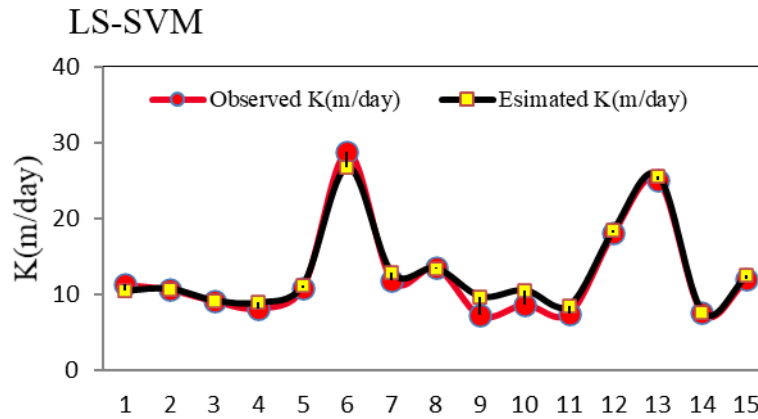


Fig. 3. Comparison of estimated and observed values of hydraulic conductivity at test points by LS-SVM model.

Table 1. Comparison of model results based on evaluation criteria.

Stage	Criteria	Model
Train	R ²	ANN
	RMSE	
	MAE	
	I _{VF}	
Test	R ²	ANN
	RMSE	
	MAE	
	I _{VF}	
Train	R ²	ANFIS
	RMSE	
	MAE	
	I _{VF}	
Test	R ²	ANFIS
	RMSE	
	MAE	
	I _{VF}	
Train	R ²	LS-SVM
	RMSE	
	MAE	
	I _{VF}	
Test	R ²	LS-SVM
	RMSE	
	MAE	
	I _{VF}	

In addition, a comparison was made between the evaluation criteria to select the best type of model that can accurately estimate the hydraulic conductivity in the Maragheh-Bonab plain. Examining the values of R² and RMSE for each of the models used in this study, it was observed that the amount of RMSE for LS-SVM, ANN, ANFIS models are equal to 1.08, 2.81 and 1.12, respectively. These values indicate that the LS-SVM model is the most powerful model in estimating hydraulic conductivity in the Maragheh-Bonab plain aquifer. However,

ANN and ANFIS models are more sensitive to the structure of the model and the number of data than the LS-SVM. However, they show more unsatisfactory performance, indicating that the nature of the input data, the structure of the models, and the complexity of the hydrogeological conditions can affect the performance of models in different places. Therefore, it is suggested to use various types of artificial intelligence methods to better evaluate models' efficiency in estimating hydraulic conductivity in Maragheh-Bonab plain and other similar aquifers. Also, hybrid models with different linear combinations can be used to reduce measurement error further

References

- Chow, V.T., 1952. On the determination of transmissibility and storage coefficients from pumping test data. *Trans American Geophysical Union* 33, 397-404.
- Cooper, H.H., Jacob, C.E., 1946. A generalized graphical method for evaluating formation constants and summarizing well field history. *Trans American Geophysical Union* 27, 526-534.
- Moench, A.F., 1997. Flow to a well of finite diameter in a homogeneous, anisotropic water table aquifer. *Water Resource Research* 33(6), 1397-1407.
- Neuman, S.P., 1972. Theory of flow in unconfined aquifers considering delayed response of the water table. *Water Resources Research* 8, 1031-1045.
- Neuman, S.P., 1973. Supplementary comment on "Theory of flow in unconfined aquifers considering delayed response of the water table". *Water Resources Research* 9, 1102-1103.
- Neuman, S.P., 1975. Analysis of pumping test data from anisotropic unconfined aquifers considering delayed gravity response. *Water Resources Research* 11, 329-342.
- Tayfur, G., Nadiri, A.A., A.Moghaddam, A., 2014. Supervised Intelligent Committee Machine Method for Hydraulic Conductivity Estimation. *Water Resource Management* 28, 1173-1184.
- Theis, C.V., 1935. The relation between lowering of the piezometric surface and the rate and duration of discharge of the well using groundwater storage. *Trans American Geophysics Union* 2, 519-524.
- Walton, W.C. 1962. Selected analytical methods for well and aquifer evaluation. *Bull.* 49, Illinois State Water Survey, pp 18.

HOW TO CITE THIS ARTICLE:

Yusefzadeh, S., Nadiri, A.A., 2021. Estimation hydraulic conductivity via intelligent models using geophysical data. *Adv. Appl. Geol.* 11(2), 382- 404.

DOI: 10.22055/AAG.2020.29223.1970

url: https://aag.scu.ac.ir/article_15851.html

تخمین هدایت هیدرولیکی با استفاده از مدل‌های هوشمند با بکارگیری داده‌های ژئوفیزیکی

سعید یوسف زاده

گروه زمین‌شناسی، دانشکده علوم طبیعی، دانشگاه تبریز، تبریز، ایران

عطاالله ندیری*

گروه زمین‌شناسی، دانشکده علوم طبیعی، دانشگاه تبریز، تبریز، ایران

تاریخ دریافت: ۱۳۹۸/۰۲/۰۳ تاریخ پذیرش: ۱۳۹۹/۰۴/۲۸

*nadiri.ata@gmail.com

چکیده

در سالهای اخیر رشد جمعیت، توسعه یافتگی جوامع شهری و در نتیجه افزایش تقاضا برای مصارف مختلف آب مانند مصارف خانگی و کشاورزی، منابع آب زیرزمینی را بشدت مورد تهدید قرار داده است. این مسئله در کشور ما ایران به دلیل داشتن آب و هوای نیمه خشک از حساسیت بالایی برخوردار است. بنابراین شناخت شرایط هیدروژئولوژیکی حاکم بر آبخوان‌ها، شناخت جریان آب زیرزمینی و تخمین پارامترهای مؤثر بر جریان آب زیرزمینی مانند هدایت هیدرولیکی از اهمیت ویژه‌ای برخوردار بوده و در مدیریت، حفاظت، بازیابی و بهره برداری از آبهای زیرزمینی باید مورد توجه ویژه قرار بگیرد. در این مطالعه به منظور تخمین هدایت هیدرولیکی در آبخوان دشت مراغه - بناب از روش‌های هوش مصنوعی (شبکه عصبی مصنوعی؛ ANN)، سیستم استنتاج فازی - عصبی تطبیقی (ANFIS) و ماشین بردار پشتیبان (SVM) استفاده شد و نتایج مدل‌ها با همدیگر مقایسه شدند. برای این منظور، نتایج حاصل از مطالعات ژئوفیزیک (ژئوالکتریک) در دشت مراغه - بناب به عنوان ورودی مدل‌ها مورد تجزیه و تحلیل قرار گرفت. براساس نتایج بدست آمده ماشین بردار پشتیبان با داشتن مقدار $R^2 = 0.97$ و $RMSE=1.08$ در مرحله آزمایش کارایی بهتری را نسبت به مدل‌های دیگر نشان داد.

کلمات کلیدی: شبکه عصبی مصنوعی، سیستم استنتاج فازی - عصبی تطبیقی، ماشین بردار پشتیبان، هوش مصنوعی، هدایت هیدرولیکی

مقدمه

در آبخوان‌های آزاد از روش‌های Boulton (1954, 1963) و روش Neunan (1972, 1975, 1973) و روش Neunan (1972, 1975, 1973) در روشی که توسط Monech در جریان به چاه با قطر محدود در آبخوان آزاد هموزن و آنیزوتروپ ارائه شد، داده‌های سینتتیک حاصل از یک آبخوان با سطح ایستابی فرضی، با استفاده از روش معکوس (آنالیز منحنی تیپ) و پیشرو (آنالیز حساسیت) مورد بررسی قرار گرفت و مقادیر دقیق پارامترهای هیدرولیکی بدست آمد (Monech, 1997). همچنین برای تعیین این پارامتر در آزمایشگاه نیز تاکنون پنج روش مشهور شامل روشهای Higgen (Higgen, 1892)، Sheferd (Sheferd, 1989)، Fair and Hatch (Carman, 1956)، Sen و Alyamani (Hatch, 1933)، Sen و Alyamani (Sen, 1993) ارائه شده است. Sperry و Peirce (1995) پس از ارزیابی توانایی روش‌های آزمایشگاهی و فرمول‌های تجربی ارائه شده، چنین نتیجه گرفتند که به جز برای محیط‌های دارای ذراتی با اشکال بسیار نامنظم، بهترین روش، مربوط به فرمول تجربی Hazen (Hazen, 1892) است و در حالت کلی فرمول تجربی Sen و Alyamani (1993) به نتایج واقعی نزدیکتر می‌باشد. این روش‌ها با وجود اینکه از مزایای مختلفی مانند شناخت شرایط

محدودیت منابع آب سطحی، افزایش تقاضای آب، افزایش فعالیت‌های کشاورزی همزمان با توسعه یافتگی جوامع، محققان حوزه مطالعات آبهای زیرزمینی را وادار ساخته است تا به مدلسازی، تخمین و پیش‌بینی شرایط هیدروژئولوژیکی حاکم بر آبخوان‌ها بپردازند. برای ارزیابی و شناخت شرایط هیدروژئولوژیکی آبخوان‌ها، حفاظت و مدیریت منابع آب زیرزمینی در حال و آینده، تخمین پارامترهای هیدروژئولوژیکی از اهمیت ویژه‌ای برخوردار است. یکی از این پارامترها هدایت هیدرولیکی اشباع آبخوان می‌باشد. روش‌های مختلف هیدروژئولوژیکی برای تخمین این پارامتر وجود دارند که هر کدام در زمینه‌های مختلفی مورد استفاده قرار گرفته و نشان داده‌اند که از کارایی نسبی برخوردار می‌باشند. تخمین هدایت هیدرولیکی با استفاده از روش‌های کلاسیک مانند آزمون پمپاژ، در آبخوان‌های مختلف با روش‌های مختلفی انجام می‌شود، به این صورت که در آبخوان‌های تحت فشار از روش‌های Theis (Theis, 1935)، روش Cooper-Jacob (Cooper and Jacob, 1946) و روش Chow (Chow, 1952) و در آبخوان‌های نشتی از روش‌های Hantush (Hantush, 1956) و روش Jacom-Hantush (Jacom-Hantush, 1955) و روش والتون (Walton, 1962) و همچنین

و هدایت هیدرولیکی، این امکان را به وجود آورده که با توجه به این شباهت، بتوان از داده‌های ژئوفیزیکی برای تخمین هدایت هیدرولیکی استفاده کرد. در یک مطالعه Nadiri و همکاران، قابلیت انتقال دشت تسوج را به روش SCFL^۲ (مدل فازی مرکب نظارت شده) تخمین زدند (Nadiri et al., 2014). آنها در این روش از داده‌های ژئوفیزیکی و هدایت الکتریکی به عنوان ورودی مدل‌های فازی استفاده کردند و چنین ابراز داشتند که استفاده از داده‌های ژئوفیزیکی می‌تواند هزینه‌ها را کاهش داده و نتایج نسبتاً دقیق‌تری هم در پی داشته باشند. در مطالعه پیش رو سعی شده است کارایی مدل‌های شبکه عصبی مصنوعی (ANN)، سیستم استنتاج فازی - عصبی تطبیقی (ANFIS) و ماشین‌بردار پشتیبان (SVM) با به کارگیری داده‌های ژئوفیزیکی و داده‌های هیدروژئولوژیکی در دشت مراغه - بناب باهم مقایسه شوند که تا به حال برای پیش بینی هدایت هیدرولیکی استفاده نشده است، لذا این تحقیق می‌تواند نتایج کاربردی و جدیدی را در بر داشته باشد.

مواد و روشها

منطقه مطالعاتی

دشت مراغه - بناب در جنوب استان آذربایجان شرقی واقع شده است. مهمترین شهرهای آن مراغه و بناب می‌باشد. شهرستان مراغه در فاصله حدود ۷۰ کیلومتری جنوب تبریز قرار دارد. وسعت کل محدوده بیش از ۱۰۰۰ کیلومتر مربع می‌باشد که حدود ۳۰۰ کیلومتر آن را دشت و پهنه‌های آبرفتی تشکیل می‌دهد و از نظر تقسیم بندی حوضه‌های آبریز کشوری، این محدوده در حوضه آبریز دریاچه ارومیه قرار گرفته است. صوفی چای مهمترین رودخانه این محدوده می‌باشد و از ارتفاعات جنوبی کوه‌های سهند سرچشمه می‌گیرد که تا میانه منطقه مطالعاتی جهتی تقریباً شمالی - جنوبی داشته و از آنجا تا دریاچه ارومیه دارای راستای عمومی شرقی - غربی می‌باشد پس از عبور از روستاهای مسیر خود وارد شهر مراغه شده و در جهت غرب تغییر مسیر داده و وارد دریاچه ارومیه می‌شود. شکل ۱ موقعیت منطقه مطالعاتی را نشان می‌دهد. میانگین بارندگی سالانه در منطقه مطالعاتی مراغه - بناب در ایستگاه سینوپتیک مراغه در حدود ۳۳۰ میلیمتر در سال برای یک دوره ۵۰ ساله (۱۹۶۰-۲۰۰۹) گزارش شده است.

زمین‌شناسی منطقه

پهنه اصلی دشت که با شیب ملایم گسترش دارد، غالباً تحت پوشش اراضی کشاورزی است. در حاشیه دریاچه ارومیه رسوبات دانه ریز و پهنه‌های نمکی، کفه‌های تبخیری را تشکیل داده‌اند. بستر رودخانه‌ها عمدتاً پوشیده از رسوبات آبرفتی دانه درشت بوده که به

زیرسطحی از طریق حفاری، برخوردار هستند اما وقت‌گیر و پرهزینه می‌باشند و به نیروی انسانی بیشتری نیاز دارند و همچنین به علت رفتار غیر خطی و شرایط ناهمگن و ناهمسان حاکم بر محیط‌های هیدروژئولوژیکی، پارامترهای اندازه‌گیری شده به وسیله این روش‌ها از عدم قطعیت ذاتی برخوردار می‌باشند. علاوه بر این تمام روش‌های اخیر حاصل حل معادلات حاکم بر جریان آب زیرزمینی با روش‌ها و با شرایط مرزی و قیود متفاوت و یا فرمول‌های تجربی می‌باشند. برای غلبه بر نواقص موجود در این روش‌ها، در چند سال اخیر مدل‌های هوش مصنوعی (AI)^۱ به طور گسترده‌ای در تخمین پارامترهای هیدروژئولوژیکی مورد استفاده قرار گرفته‌اند. این متدها برخلاف آزمون‌های صحرایی و آزمایشگاهی، دارای این قابلیت هستند که در زمانی کوتاه‌تر با صرف هزینه کمتر و با داده‌های در دسترس محدود، تخمین قابل قبولی از پارامترهای هیدروژئولوژیکی مانند هدایت هیدرولیکی ارائه دهند. بررسی مطالعات انجام گرفته در این زمینه، موفقیت متدهای هوش مصنوعی مانند منطق فازی (Bárdossy (1993) Hsieh et al. Batyrshin et al. (2005) and Disse Anifowose and Helmy et al. (2010) (2005) Nadiri (2011) Abdurraheem (2011) Nadiri et al. (2015) et al. (2013) Schaap and Leij, شبکه عصبی مصنوعی، Merdun et al. (2006) samani et al. (1998) Kurtulus and Razack Hu et al. (2008) (2007) Motaghian and Mohammadi (2011) (2010) Mokhtari et al. (2012) Khashei et al. (2013) نروفازی که ترکیبی از منطق فازی و شبکه عصبی مصنوعی می‌باشد Samani et al. (2005) Karam Beygi et al. (2009) Huang et al. (2001) Hong et al. (2009) Tutmez (2010) Nadiri et al. (2014) ماشین بردار پشتیبان Yoon et al. (2011) Zhao et al. (2011) Nadiri et al. (2012) Shahbazi and Pilpayehv (2012) Raghavendra (2014) (2013) را در تخمین پارامترهای مختلف هیدروژئولوژیکی هیدروژئولوژیکی را نشان می‌دهد. همچنین Tyfur و همکاران (۲۰۱۴) برای تخمین هدایت هیدرولیکی در دشت تسوج، از روش ترکیبی SICM^۲ استفاده کردند. مدل‌های هوش مصنوعی مناسب باید از پیچیدگی ساختاری کمتر برخوردار بوده و نیاز به اطلاعات گسترده و بیشتر نداشته باشند تا با استفاده از داده‌های ورودی مناسب بهینه‌ترین مدلسازی را ارائه دهند. در کنار مدل‌های هوشمند، شباهت قوانین حاکم بر جریان الکتریکی مانند قانون اهم با قوانین حاکم بر جریان آب زیرزمینی در محیط متخلخل مانند قانون دارسی و همچنین شباهت پارامترهای مؤثر بر جریان الکتریکی و جریان آب زیرزمینی مانند هدایت الکتریکی

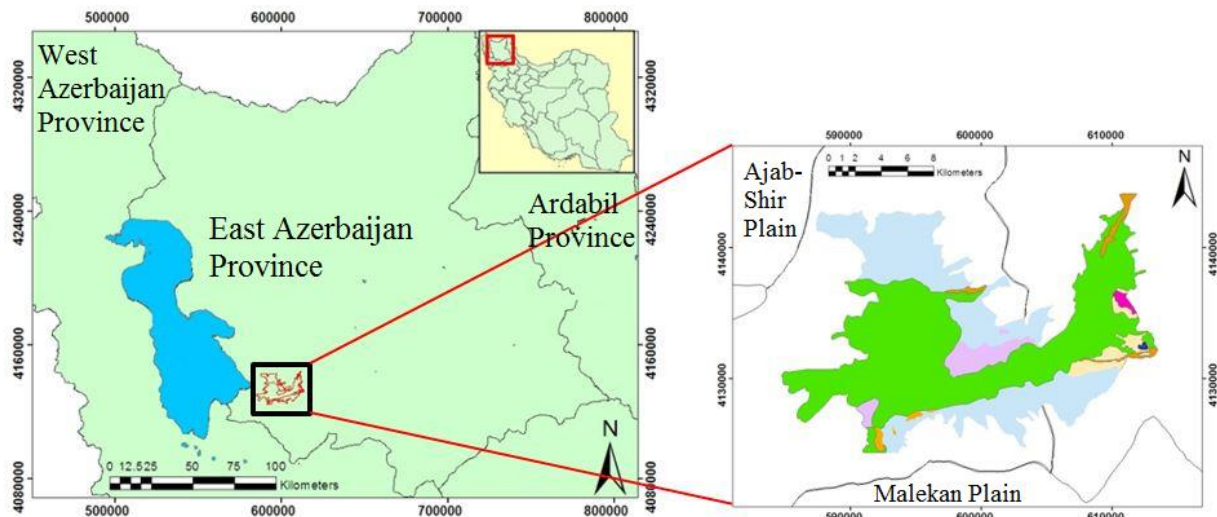
1-Artificial Intelligence.

2-Supervised Intelligent Committee Machine

3-Supervised Committee Fuzzy Model

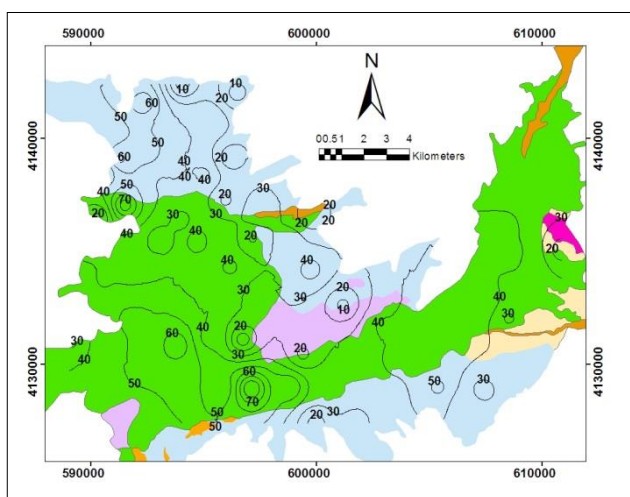
مقداری آب نفوذ کرده که بوسیله تعدادی چشمه با آبدهی ناچیز مشخص می‌گردد. نهشته های آبرفتی دوران چهارم مهمترین سنگ مخزن آب زیرزمینی منطقه‌اند. آبخوان پیوسته‌ای که در آبرفت‌های دشت مراغه - بناب تشکیل شده است و از جنوب شهر مراغه شروع شده تا شوره‌زارهای دریاچه ارومیه ادامه دارد به عنوان آبخوان اصلی دشت مراغه - بناب نامگذاری شده است. در شکل ۲ نقشه زمین-شناسی محدوده‌ی مطالعاتی نشان داده شده است.

سمت غرب دانه ریزتر می‌شوند. ارتفاع بلندترین نقطه سفره ۱۶۰۷ متر از سطح دریا و پست‌ترین نقطه با ارتفاع ۱۲۶۲ متر از سطح دریا در شوره زارهای حاشیه دریاچه ارومیه واقع شده است (Fijani 2013). آبخوان دشت مراغه - بناب را رسوبات آبرفتی کواترنری تشکیل داده است. پاره‌ای از سازندهای سنگی منطقه دارای تراوایی درز و شکاف‌اند. در سازندهای درز و شکافدار منطقه که به طور عموم از جنس ولکانیک‌های سهند و آهک‌های شیل‌دار می‌باشند



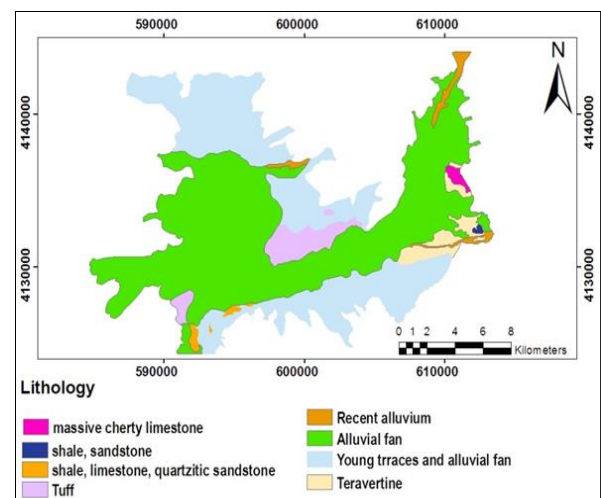
شکل ۱- موقعیت محدوده مطالعاتی.

Fig. 1. Location of study area.



شکل ۳- نقشه هم ضخامت آبرفت.

Fig. 3. Iso thickness of alluvium.



شکل ۲- نقشه زمین شناسی محدوده‌ی مطالعاتی.

Fig. 2. Geological map of study area.

محدوده‌ی آبخوان در حدود ۱۹۰ کیلومتر مربع برآورد شده است. بهره‌برداری از آبخوان اصلی دشت به کمک تعدادی چاه عمیق و نیمه عمیق و تعدادی قنات و چشمه صورت می‌گیرد. تعداد نقاط برداشت از آبخوان محدوده‌ی مطالعاتی ۶۸۴۱ حلقه چاه می‌باشد که از این

هیدروژئولوژی منطقه

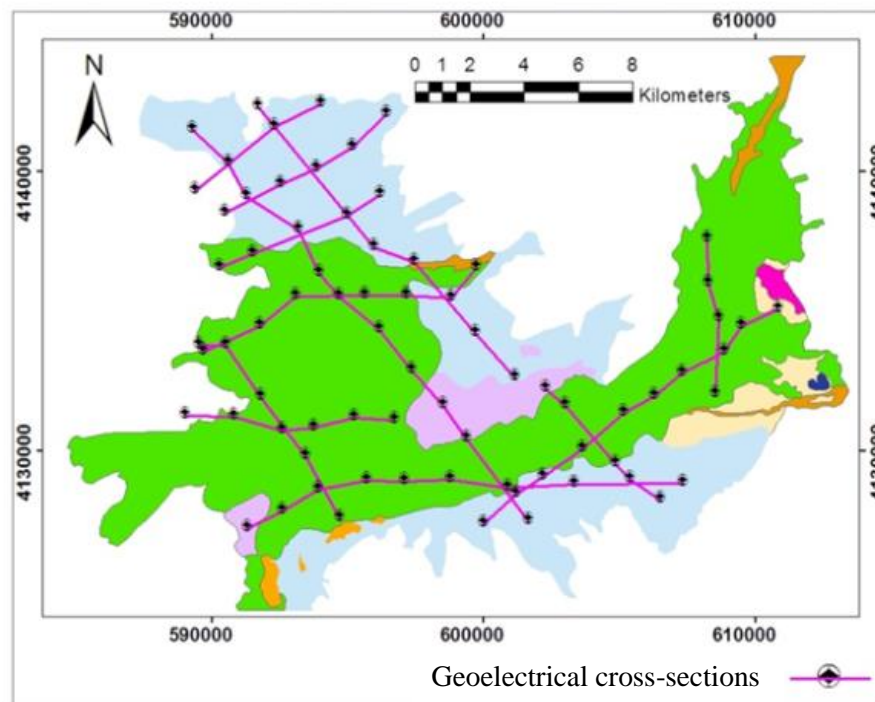
براساس اطلاعات حاصل از بررسی‌های ژئوفیزیکی و نتایج حفاری چاه‌های اکتشافی و مشاهده‌ای، آبخوان دشت مراغه - بناب از نوع آزاد و تک لایه می‌باشد (Sadegfam et al., 2016). گستره‌ی

شده است با بکارگیری داده‌های ژئوفیزیکی و هیدروژئولوژیکی، توسط مدل‌های هوشمند تخمین زده شود. برای تشخیص خصوصیات هیدروژئولوژی و ژئوفیزیکی مؤثر بر هدایت هیدرولیکی، مطالعات ژئوفیزیک و حفاری‌های اکتشافی بصورت مجزا مورد توجه قرار گرفته‌اند.

مطالعات ژئوفیزیک

مطالعات ژئوفیزیک انجام گرفته در دشت مراغه - بناب به روش ژئوالکتریک بوده که توسط شرکت مهندسی مشاور آب و خاک (۱۹۷۵) انجام گرفته است و طی آن ۶۸ سونداژ در راستای ۱۲ پروفیل ژئوالکتریک برداشت شده است. با استفاده از نتایج مطالعات ژئوفیزیکی می‌توان پارامترهای مؤثر بر هدایت هیدرولیکی مانند ضخامت آبرفت و مقاومت ویژه عرضی را بدست آورد. با توجه به اینکه در این مطالعه به تخمین و پیش‌بینی هدایت هیدرولیکی بخش اشباع آبخوان دشت مراغه - بناب پرداخته شده است، با استفاده از مطالعات ژئوفیزیک انجام شده نقشه هم ضخامت آبرفت تهیه گردید و ضخامت اشباع آبخوان از طریق ضخامت آبرفت بدست آمد. براساس این مطالعات، ضخامت آبرفت بیش از ۸۰ متر می‌باشد که شامل نهشته‌های کنگلومرای با چورشدگی ضعیف و سیمان رسی - ماسه - ای هستند. شکل‌های ۳ و ۴ نقشه هم ضخامت آبرفت و نقشه مقاطع ژئوالکتریکی را نشان می‌دهند.

تعداد ۵۹۱ حلقه غیر فعال است. از مجموع ۶۲۵۰ حلقه چاه فعال، تعداد ۶۰ حلقه چاه عمیق و ۶۱۹۰ حلقه چاه نیمه عمیق است. علاوه بر این، ۱۰۸ رشته قنات وجود دارد که ۶۰ رشته از آنها خشک شده است. تعداد چشمه‌های منطقه نیز ۶۶ دهنه بوده که ۱۵ دهنه از آنها خشک شده است. آبدهی چاه‌های عمیق به طور متوسط ۹،۵ لیتر بر ثانیه و میزان برداشت سالانه از آنها در حدود ۴،۸۳ میلیون متر مکعب برآورد شده است. آبدهی متوسط چاه‌های نیمه عمیق ۲،۳ مترمکعب بر ثانیه بوده و مجموع برداشت سالانه از آنها به ۳۳،۱۴ میلیون متر مکعب رسیده است (Engineers, 2013). همچنین بر اساس گزارشات سازمان آب منطقه‌ای استان آذربایجان شرقی، تخلیه سالانه از چشمه‌های موجود در منطقه حدود ۰،۶۵ میلیون مترمکعب در سال است که این مقدار در قنات‌های موجود برابر با ۱،۷۶ میلیون مترمکعب می‌باشد. با توجه به اطلاعات فوق و همچنین با توجه به برداشت زیاد از آب زیرزمینی به جهت وجود کشاورزی و فعالیت شهرک‌های صنعتی، منابع آب‌های زیرزمینی در دشت مراغه - بناب در معرض کم آبی و آلودگی به آلاینده‌های شیمیایی قرار گرفته‌اند، در نتیجه محافظت و بازیابی چاه‌های آب، مدیریت آبخوان و بهره برداری بهینه از آب زیرزمینی در این دشت باید بیش از پیش مورد توجه قرار گیرد. برای دستیابی به این مهم، شناخت شرایط هیدروژئولوژیکی آبخوان امری ضروری است. به همین منظور باید پارامترهای مؤثر بر رفتار آبخوان با دقت بیشتری پیش‌بینی و تخمین زده شوند. یکی از مهمترین پارامترهای هیدروژئولوژیکی، هدایت هیدرولیکی می‌باشد که در این تحقیق سعی



شکل ۴- نقشه مقاطع ژئوالکتریک.

Fig. 4. Geoelectrical cross-sections.

حفاریهای اکتشافی

در دشت مراغه - بناب تعداد ۶ حلقه چاه اکتشافی و ۶ حلقه چاه پمپاژ حفاری شده است. عمیق‌ترین چاه اکتشافی با ۷۲ متر عمق در روستای قلعه خالصه قرار دارد. همچنین بر روی ۶ حلقه از چاههای اکتشافی که دارای پیرومتر نیز بودند، آزمایش پمپاژ انجام گرفته است (Yekom Consulting Engineers, 2013).

تجزیه و تحلیل داده ها

استفاده از داده‌های حاصل از مطالعات ژئوفیزیکی جهت تخمین هدایت هیدرولیکی به طور قابل توجهی می‌تواند بر عدم قطعیت ذاتی موجود در داده‌های حاصل از آزمایشات پمپاژ را کاهش دهد. بنابراین، در این تحقیق از داده‌های حاصل از اندازه‌گیری‌های ژئوفیزیکی که با هدایت هیدرولیکی در ارتباط می‌باشند به عنوان ورودی مدل‌ها استفاده شد. این داده‌ها شامل: مقاومت ویژه عرضی (R_t)، هدایت الکتریکی (EC)، ضخامت اشباع (B) و علاوه بر آنها $UTM(X)$ و $UTM(Y)$ نقاط برداشت هدایت هیدرولیکی می‌باشند. با تلفیق داده‌های نتایج حاصل از لاگ‌های چاههای مشاهده‌ای (و مطالعات ژئوفیزیک)، مشخص شد ضخامت اشباع آبخوان حداکثر تا کمی بیش از ۴۰ متر می‌رسد. برای شناسایی ویژگیهای آبرفت‌های دشت مراغه - بناب مانند ضخامت آبرفت، بررسی‌های اکتشافی در دو بخش مطالعات ژئوفیزیکی و حفاریهای اکتشافی در این منطقه انجام گرفته است. بررسی‌های ژئوفیزیکی که با روش ژئوالکتریک انجام یافته، در سال ۱۳۵۴ در قالب مطالعات آبهای زیرزمینی، با عنوان بررسی‌های ژئوالکتریک منطقه میان‌دوآب - مراغه توسط مهندسین مشاور آب و خاک انجام گرفته است. در بررسی‌های اکتشافی نیز، تعداد ۳۹ حلقه چاه مشاهده‌ای حفر گردیده که براساس آن، به اطلاعاتی مانند عمق سطح آب زیرزمینی، دست یافتیم. با تلفیق داده‌های حاصل از بررسی‌های ژئوفیزیکی و حفاری‌های اکتشافی و با استفاده از نرم افزار ArcGis (با درونیابی بروش کریجینگ) ضخامت آبرفت و ضخامت اشباع در نقاط مختلف محاسبه گردید. مقاومت ویژه الکتریکی (R) بر حسب اهم‌متر یک پارامتر فیزیکی مهم در هیدروژئولوژی است. مقاومت الکتریکی ظاهری دارای دو مؤلفه اصلی مقاومت طولی (R_L) و مقاومت عرضی (R_T) می‌باشد که به ترتیب تغییرات پارامترهای هیدروژئولوژیکی جانبی و عمقی را نشان می‌دهند لذا مقاومت الکتریکی عرضی با مقادیر هدایت هیدرولیکی مرتبط می‌باشد. با وجود اینکه اساس محاسبات هدایت هیدرولیکی، برپایه مقاومت ویژه واقعی است، ولی در تحقیق پیش رو با توجه به نارسایی داده‌ها در مطالعات ژئوالکتریک، از مقاومت ویژه ظاهری استفاده شده است. همچنین مقاومت ویژه الکتریکی عمدتاً به کیفیت کترولیت، کمیت کترولیت در واحد حجم سنگ و نحوه توزیع کترولیت در منافذ بستگی دارد. از طرفی با افزایش میزان کترولیتها، مقدار هدایت الکتریکی نیز افزایش می‌یابد، بنابراین توزیع هدایت الکتریکی (EC) را نیز می‌توان از پارامترهای مرتبط با هدایت هیدرولیکی دانست

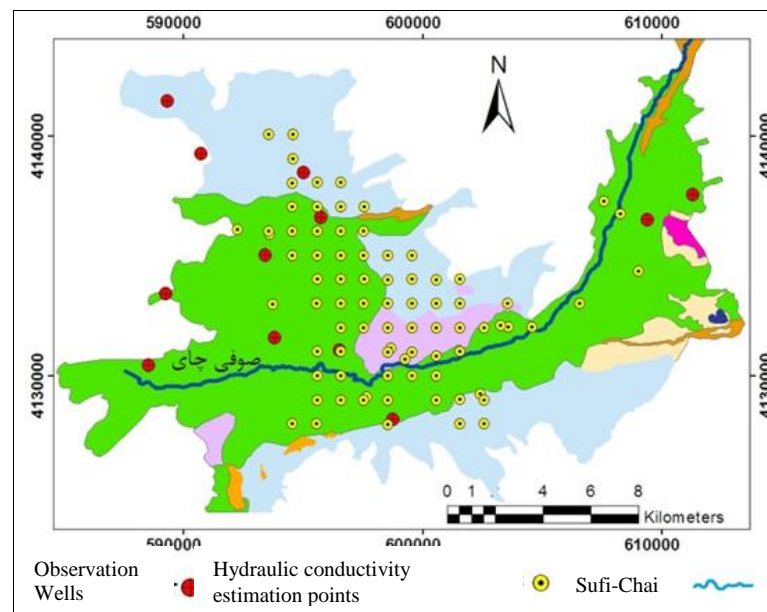
(Ortega and Mirand, 2004). هدایت الکتریکی مورد استفاده در این تحقیق از نتایج آزمایشات هیدروشیمی حاصل از اندازه‌گیری ۳۷ نمونه در سال ۲۰۱۱ بدست آمد. این داده‌ها از سازمان آب منطقه‌ای استان آذربایجان شرقی تهیه و مورد تجزیه و تحلیل قرار گرفتند. در دشت مراغه - بناب تعداد ۸۰ هدایت هیدرولیکی از طریق آزمون پمپاژ با دبی ثابت و متغیر اندازه‌گیری شده است که موقعیت نقاط اندازه‌گیری در شکل ۵ نشان داده شده است. همانطوری که قبلاً ذکر شد، آبخوان دشت مراغه - بناب، آزاد و تک لایه می‌باشد. در این آبخوان ابتدا مقدار قابلیت انتقال محاسبه شده، سپس با در نظر گرفتن ضخامت، مقدار هدایت هیدرولیکی در آن نقاط محاسبه گردید. مقدار حداکثر هدایت هیدرولیکی برابر با ۳۹٫۲۶ متر بر روز و مقدار حداقل آن برابر ۰٫۲۷ متر بر روز تخمین زده شده اند. تقسیم‌بندی داده‌ها در مدل‌های هوش مصنوعی برای تخمین هدایت هیدرولیکی به این صورت انجام شد که ۸۰٪ داده‌ها برای مراحل آموزش و ۲۰٪ داده‌ها برای آزمون استفاده از داده‌های ژئوفیزیکی در مطالعات هیدروژئولوژی، شباهت قوانین حاکم بر جریان الکتریکی و جریان آب زیرزمینی می‌باشد. قانون اهم ($I = -\sigma \frac{dv}{dl}$) جریان الکتریکی را در یک محیط هادی توصیف می‌کند. این قانون از نظر ساختار ریاضی و مفهوم فیزیکی با قانون دارسی ($v = -K \frac{dh}{dl}$) هم تراز است. این هم تراز از آن جهت است که v ، σ ، I به ترتیب با نرخ جریان آب در سطح واحد، سرعت دارسی v ، هدایت هیدرولیکی K ، بارهیدرولیکی h و شیب هیدرولیکی $\frac{dh}{dl}$ ، هم سنگ هستند. همانطور که مشاهده می‌شود، عامل هدایت الکتریکی هم سنگ هدایت هیدرولیکی می‌باشد، بنابراین هدایت الکتریکی عامل موثر بر هدایت هیدرولیکی می‌تواند باشد و از طرفی، هدایت الکتریکی رابطه غیرمستقیم با مقاومت الکتریکی دارد ($EC = \frac{1}{R}$). بنابراین عامل دیگری که بر هدایت هیدرولیکی تاثیر می‌گذارد، مقاومت می‌باشد. همانطور که قبلاً ذکر شد، مقاومت مورد استفاده در مطالعات آبهای زیرزمینی در خصوص تخمین هدایت هیدرولیکی با استفاده از داده‌های ژئوفیزیکی، مقاومت ویژه واقعی می‌باشد. برای این منظور، محققین از نتایج کاوشهای ژئوفیزیکی و برخی فرمولهای تجربی بهره می‌برند. به عنوان مثال؛ (Taheri Tizro et al., 2012)، برای تخمین تخلخل و آبدی ویژه با استفاده از روش ژئوالکتریک، از هدایت الکتریکی برای محاسبه مقاومت ویژه آب استفاده کردند.

$$\rho_w = \frac{10^4}{\sigma_w} \quad (\text{رابطه ۱})$$

ρ_w : مقاومت ویژه آب
 σ_w : هدایت الکتریکی آب

بودند، بنابراین مستقیماً و بدون نیاز به روابط تبدیلیگر، مورد استفاده قرار گرفتند.

در تحقیق پیش‌رو، داده‌های مورد استفاده (مقاومت ویژه آبخوان و هدایت الکتریکی)، از نتایج حاصل از مطالعات ژئوفیزیک در دسترس



شکل ۵- موقعیت چاههای مشاهده‌ای و نقاط اندازه‌گیری هدایت هیدرولیکی.

Fig. 5. Location of observation wells and hydraulic conductivity estimation points.

مدل در لایه خروجی معرفی می‌شود. شکل ۶ نمونه‌ای از یک شبکه عصبی مصنوعی را نشان می‌دهد که لایه‌های ورودی، میانی و خروجی در آن مشخص هستند. در این شکل، متغیرهای ورودی شامل: W_{ij} , B , R_T , $UTMY$, $UTMX$ ؛ بردار وزن میان نود W_{jk} ؛ بردار وزن میان نود میانی و نود خروجی، I_i ؛ ورودی نام را نشان می‌دهد که بر این اساس $I_i = \{UTMX, UTMY, R_T, B, EC\}$ می‌باشد. O_j خروجی نام از لایه میانی را نشان می‌دهد. b_j و b_k به ترتیب بایاس تنظیم کننده لایه ورودی و لایه میانی را نشان می‌دهند. ورودی‌های هر گره ممکن است از متغیرهای ورودی یا خروجی گره‌های دیگر حاصل شود. هر گره دارای یک تابع عملگر است که به آن تابع تبدیلیگر گفته می‌شود.

$$f = (x \cdot w + b) \quad (\text{رابطه ۲})$$

در این رابطه؛ x ورودی، w بردار وزن و b بایاس یا مقدار آستانه می‌باشند. یکی از مهمترین و پرکاربردترین توابع تبدیلیگر، تابع سیگموئید می‌باشد، که به صورت رابطه زیر بیان می‌شود:

$$f(t) = \frac{1}{1 + \exp(-nt)} \quad (\text{رابطه ۳})$$

$f(t)$ تابع تبدیلیگر، n ورودی خالص نرون، t تقریبی است که بیانگر طول قسمت خطی نمودار تابع تبدیلیگر می‌باشد، بطوریکه اگر t بزرگ باشد قسمت خطی تابع بصورت عمودی درآمده و در واقع تابع به شکل یک تابع حدی دو مقداره در می‌آید و اگر t کوچک باشد، تابع

روش‌های هوش مصنوعی


شبکه‌های عصبی مصنوعی (ANNs)

یک شبکه عصبی مصنوعی، یک روش محاسباتی نرم است که عملکرد آن از مغز انسان الهام گرفته شده است. در یک شبکه نمونه معمولاً پردازش داده‌ها از طریق ارتباطات درونی شبکه که بوسیله نرون‌ها ایجاد می‌شود، انجام می‌گیرد. در این تحقیق از یک شبکه عصبی پرسپترون چند لایه که کارایی آن در تحقیق‌های قبلی به اثبات رسیده (Schaap and Leij, 1998؛ Merdum et al., 2006؛ Samani et al., 2007؛ Hu et al., 2008؛ Kurtulus؛ Razack, 2010؛ Motaghian and Mohammadi, 2011؛ Mokhtari et al., 2012؛ Khashei et al., 2013) استفاده شده است. به طور کلی یک شبکه عصبی مصنوعی پرسپترون دارای سه لایه می‌باشد که این لایه‌ها از طریق نودها به همدیگر متصل می‌شوند. این لایه‌ها شامل: لایه ورودی^۴ که ورودی‌های مدل را شامل می‌شود. لایه میانی یا لایه مخفی^۵ محل انجام پردازش بر روی داده‌های ورودی می‌باشد. لایه خروجی^۶ که خروجی مدل را معرفی می‌کند. تعداد ورودی‌ها در لایه اول و همچنین تعداد لایه‌های میانی می‌توانند متغیر باشند. در لایه میانی چندین گره پردازشگر وجود دارد که هر یک از نودهای ورودی به تک تک نودهای میانی متصل می‌شوند و بعد از پردازش بر روی ورودی‌ها در لایه میانی، خروجی

- 4-Input layer
- 5-Hidden layer
- 6- Output layer

غیرکاهنده است و به علت سادگی و کارایی بالای آن، در فرایند آموزش مورد استفاده قرار می‌گیرد (Mokhtari et al., 2012).

به شکل S کشیده شده در امتداد محور افقی در خواهد آمد. شکل تابع $f(t)$ تعیین کننده جواب یک گره به سیگنال ورودی کلی است که آن را دریافت می‌کند. این تابع یک تابع کران دار، یکنواخت و



شکل ۶- نمونه ای از شبکه عصبی مصنوعی سه لایه با پنج ورودی و یک خروجی.

Fig. 6. Example of three layer artificial neural network with 5 inputs.

کلی هرچه تعداد تکرارها در آموزش شبکه بیشتر باشد خطای پیش بینی در شبکه کمتر می‌شود. اما هنگامی که تعداد تکرارها از یک مقدار تجاوز کند، خطای دسته آزمایشی نیز افزایش می‌یابد (Mokhtari et al., 2012). براساس روش آزمون و خطا، تعداد بهینه تکرارهای آموزش در این تحقیق ۵۰۰ تعیین شد و در این مقدار، شبکه بهترین عملکرد را از خود نشان داد.

سیستم استنتاج نرو - فازی تطبیقی (ANFIS)

هر یک از مدل‌های ANNs و FIS^y به تنهایی دارای مزایا و معایبی هستند. مدل شبکه عصبی مصنوعی (ANNs) زمانی کارایی بهتری از خود نشان می‌دهد که اطلاعات و داده‌های کافی وجود داشته باشد. این مدل از داده‌های مشاهداتی قبلی برای آموزش شبکه استفاده می‌کند، بنابراین کمبود اطلاعات و داده‌ها، کارایی سیستم را کاهش می‌دهد. همچنین به دلیل اینکه شبکه عصبی مصنوعی مقادیر وزن خود را به صورت تصادفی در نظر می‌گیرد، ممکن است در طی فرایند آموزش در حداقل محلی (Local-minimal) گرفتار شود که در نهایت باعث می‌شود شبکه خوب آموزش ندیده و کارایی لازم را نداشته باشد (Samani et al., 2009). در حالیکه سیستم استنتاج فازی (FIS) برای مدل‌سازی به قوانین زبانی به عنوان اطلاعات اولیه نیاز دارد. علاوه بر این، متغیرهای ورودی و خروجی در این مدل به صورت زبانی توصیف می‌شوند. بنابراین اگر اطلاعات ناقص و متناقض باشند، سیستم فازی باید با این شرایط وفق داده

آموزش شبکه

در این پژوهش، از کدنویسی در محیط نرم افزار متلب به جای استفاده از جعبه ابزار استفاده شد و به این ترتیب مدل مورد نظر و تعداد لایه های میانی که قابل تغییر می‌باشد ایجاد شد و بر این اساس، با تغییر تعداد نرون‌های لایه میانی و تعداد تکرارهای آموزش، ساختار بهینه شبکه بدست آمد. بهینه سازی تعداد گره‌های لایه میانی نیز به این معناست که دقت مدل افزایش و خطای مدل کاهش یابد. همچنین در این مطالعه تابع TANSIG مورد استفاده قرار گرفته است. این تابع با استفاده از روش آزمون و خطا، بهترین تابع برای مدل‌سازی سیستم‌های طبیعی غیرخطی تشخیص داده شده است (Nourani et al., 2008a; Nadiri et al., 2013; Chitsazan et al., 2015). در شبکه‌های عصبی مصنوعی با توجه به اینکه وارد کردن داده‌ها به صورت خام قابل پردازش نیست، لذا در آموزش شبکه، نرمالیزه کردن داده‌ها قبل از اجرای شبکه بسیار مهم است. برای پیشگیری از چنین شرایطی و همچنین به لحاظ یکسان سازی ارزش داده‌ها برای شبکه عمل نرمال‌سازی داده‌ها مطابق رابطه 4 انجام شد.

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (\text{رابطه ۴})$$

تعداد دوره‌ها یا تکرارهای آموزش شبکه

یکی از معیارهای مهم در آموزش شبکه، تعداد دوره‌ها یا تکرارهایی است که شبکه در حین آموزش انجام می‌دهد. تعیین تعداد صحیح این تکرارها در آموزش شبکه بسیار مهم است. به طور

از تابع گوسی به عنوان تابع عضویت استفاده شد که بصورت زیر بیان می شود:

$$\mu_{Ai}(x) = e^{-(x-c_i)^2/2\sigma_i^2} \quad (\text{رابطه ۸})$$

C_i مرکز تابع گوسی و σ_i پهن شدگی تابع عضویت را نشان می دهد. لایه دوم: هدف این لایه، محاسبه درجه فعالیت (قدرت آتش) قوانین فازی می باشد (Gorzalczany, 2001):

$$w_i = Q_i^2 = \mu_{1i}(X) \times \mu_{2i}(X) \times \mu_{3i}(X) \times \mu_{4i}(X) \times \mu_{5i}(X) \quad (\text{رابطه ۹})$$

W_i : وزن قانون A_m و μ_j مجموعه های فازی تعریف شده برای متغیرهای X هستند.

لایه سوم: هر گره در این لایه درجه فعالیت قانون A_m را با استفاده از محاسبه وزن قانون A_m به درجه فعالیت کل قوانین، نرمال سازی می کند.

$$Q_i^3 = w_i^* = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (\text{رابطه ۱۰})$$

لایه چهارم: هر گره در این لایه یک گره تطبیقی با تابع گره است که مدل درجه اول ساگنو را با استفاده از پارامترهای متأخر (تالی) بیان می کند. بنابراین خروجی این لایه بصورت زیر معرفی می شود:

$$O_i^4 = w_i^* f_i = w_i^* (p_i x + q_i y + r_i) \quad (\text{رابطه ۱۱})$$

لایه پنجم: این لایه به عنوان لایه خروجی می باشد. مجموع خروجی لایه های قبلی را به عنوان ورودی محاسبه می کند و با استفاده از معادله زیر به عنوان خروجی نهایی مدل معرفی می کند:

$$O_i^5 = \sum_i w_i^* f_i = \frac{\sum_i w_i^* f_i}{w_i} \quad (\text{رابطه ۱۲})$$

بهینه سازی مقادیر پارامترهای تطبیقی در سیستم فازی - عصبی از اهمیت حیاتی برخوردار می باشد. این پارامترها شامل تابع عضویت در لایه اول و پارامترهای لایه چهارم و معادله ۱۰ می باشند (Jang, 1993) برای تعیین پارامترهای یک سیستم ANFIS الگوریتم آموزشی ترکیبی را ارائه کرد. این الگوریتم برای بهینه کردن پارامترهای شبکه از تکنیکهای گرادیان نزولی و حداقل مربعات استفاده می کند. خروجی سیستم نیز بصورت زیر بیان می شود:

$$f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 = w_1^* f_1 + w_2^* f_2 \quad (\text{رابطه ۱۳})$$

شود ولی از آنجایی که روش رسمی برای این کار وجود ندارد، بنابراین با روش های ابتکاری این کار را انجام می دهد. این کار معمولاً وقت گیر و دارای خطا می باشد. مزایا و معایب ANNs و FIS توسط Nauck و Kruse (1999) (Nauck and Kruse, 1999) توصیف شده است. سیستم استنتاج فازی - عصبی تطبیقی که در سال ۱۹۹۲ توسط Jung مطرح شد از ترکیب قابلیت تولید قوانین فازی مدل FIS و قابلیت آموزش شبکه در مدل ANNs ایجاد می کند و به این ترتیب می تواند بر معایب هر یک از این مدل ها غلبه کند. ANFIS با محدودیت های کمتری نسبت به مدل های FIS و ANNs در زمینه های مختلفی از جمله در مطالعات آبهای زیرزمینی مانند تخمین پارامترهای هیدرولیکی، می تواند نتایج بهتری ارائه دهد.

ساختار ANFIS

برای شناخت ساختار و طرز کار ANFIS آشنایی با سیستم منطق فازی و شبکه های عصبی مصنوعی ضروری است. با توجه به شکل ۷ اگر سیستم ANFIS دارای ۲ ورودی x و y و یک خروجی f باشد برای مدل فازی ساگنو درجه اول، مجموعه قوانین معمولی سیستم فازی به صورت ۲ قانون اگر - آنگاه به شکل زیر در می آید:

Rule1 = if(x belongs to A1) (رابطه ۵)

and(y belongs to B1)
then(f1 = p1x + q1y + r1)

Rule2 = if(x belongs to A2) (رابطه ۶)

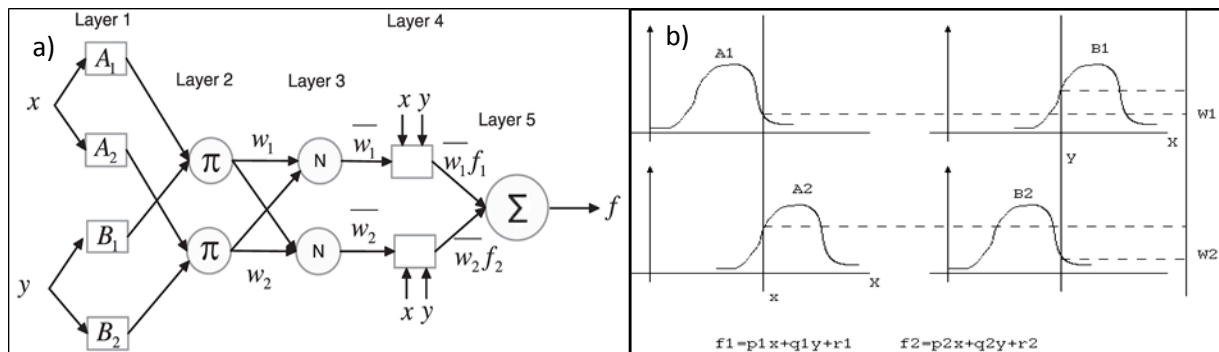
and(y belongs to B2)
then(f2 = p2x + q2y + r2)

P_i و Q_i پارامترهای متأخر نامیده می شوند که در طول فرایند آموزش تعیین می شوند. F_i نیز به عنوان خروجی محیط فازی می باشد که توسط قوانین فازی مشخص می شود. شکل ۷ مکانیزم استدلال را برای مدل ساگنو و b_7 مدل ANFIS متناظر با این سیستم فازی را نشان می دهد.

لایه اول: گره های موجود در این لایه، تابع عضویت داده های ورودی را ایجاد می کند. خروجی نرون ۱ بوسیله معادله زیر تعریف می شود:

$$Q_i^1 = \mu_{ji}(x) \quad i = 1, 2, 3, 4, 5 \quad (\text{رابطه ۷})$$

Z : تعداد ورودی، A_i : شاخص تابع عضویت، $X = \{R_i, B, EC, UTMX, UTM Y\}$ مجموعه داده های ورودی و $\mu_j(X)$ مجموعه فازی همراه با نرون i و تابع عضویت را نشان می دهد. برای تابع عضویت A می توان یکی از توابع عضویت مثلثی، دوزنقه ای، زنگوله ای یا گوسی را انتخاب کرد. در این تحقیق بر اساس خصوصیات داده ها



شکل ۷- (a) مکانیزم استدلال برای مدل ساگنو و (b) ساختار ANFIS متناظر.

Fig. 7. (a) Reasoning mechanism in sugeno model and (b) Corresponding ANFIS structure.

مینیمم‌های محلی تابع خطا مواجه نمی‌شود (Hong, 2011). مراحل حل مسئله در الگوریتم ماشین‌های بردار پشتیبان همانند الگوریتم شبکه‌های عصبی به دو مرحله آموزش و آزمایش تقسیم می‌شود. انواع مدل‌های ماشین بردار پشتیبان عبارتند از طبقه‌بندی بردار پشتیبان^۹، رگرسیون بردار پشتیبان^{۱۰}، حداقل مربعات ماشین بردار پشتیبان^{۱۱}، برنامه ریزی خطی ماشین بردار پشتیبان^{۱۲} و ماشین های بردار پشتیبان^{۱۳} Nu. در این تحقیق از ماشین بردار پشتیبان حداقل مربعات استفاده شده است. حداقل مربعات ماشین بردار پشتیبان (LS-SVM) یک مدل SVM اصلاح شده است که توسط Suykenz (Suykenz et al., 2002) ارائه شده است و یک روش یادگیری ماشین که قابل اجرا برای طبقه‌بندی و رگرسیون است (Suykenz et al., 2002). راه حل LS-SVM به جای مسئله درجه دوم^{۱۴} SVM از معادلات KKT^{۱۵} خطی استفاده می‌کند. اشکال عمده LS-SVM این است که یک تابع تلفات درجه دوم بدون هیچ قانونی استفاده می‌کند که منجر به تخمین ضعیف تری می‌شود. از این رو به منظور جلوگیری از این، LS-SVM وزن‌دار اقتباس شد و در مواردی که وزن‌های کوچک به داده‌ها اختصاص داده شود، روش آموزشی دو مرحله‌ای ارائه می‌شود. این مدل به دلیل استفاده از معادلات خطی در حل مسائل، دقت محاسباتی بالاتری نسبت به ماشین بردار پشتیبان کلاسیک دارد (Seifi 2010; Shabri 2012). اگر یک مجموعه آموزشی از N داده $\{x_i, y_i\}_{i=1}^N$ در نظر گرفته شود که $y_i \in R^d$ داده ورودی $y_i \in R$ داده خروجی است. مدل‌های رگرسیون LS-SVM در فضای ویژگی به صورت زیر است:

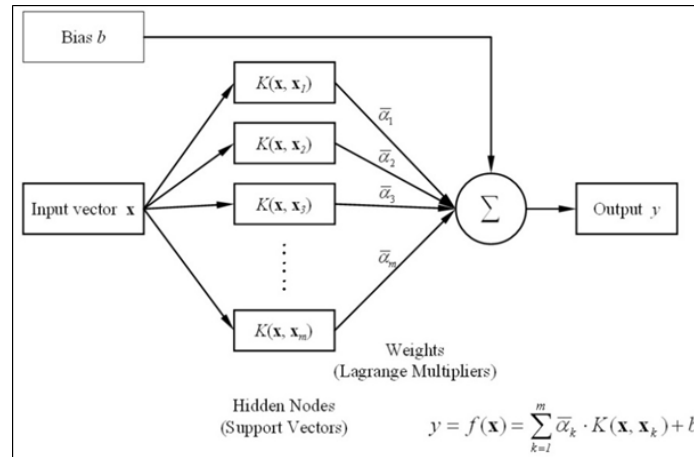
$$y(x) = w^T \varphi(x) + b \quad (\text{رابطه ۱۴})$$

- 9-Support vector classification
- 10-Support vector regression
- 11-Least-squares support vector machine
- 12-Linear programming support vector machine
- 13-Nu-support vector machines
- 14-Quadratic programming problem
- 15-Karush-Kuhn-Tucker equations

لذا باتوجه به آنچه ذکر گردید در این تحقیق جهت تخمین هدایت هیدرولیکی از الگوریتم خوشه بندی (روش دسته‌بندی) کاهشی استفاده شده است. پارامتر اصلی در این روش دسته‌بندی برای تعیین تعداد دسته‌ها و قوانین اگر- آنگاه، شعاع دسته بندی است. مقادیر این پارامتر بین ۰ و ۱ متغیر می‌باشد. بازه مدل بستگی به شعاع دسته بندی دارد که مقدار بهینه آن براساس کمترین خطا در این تحقیق ۰,۴ تعیین شد. همچنین نقطه حیاتی در طراحی پایگاه قوانین، انتخاب تعداد قوانین فازی است. زمانی که یک سیستم فازی با استفاده از دسته بندی فازی ساخته می‌شود، هر دسته به یک قاعده فازی مربوط می‌شود. بنابراین تعداد دسته‌ها، تعداد قوانین فازی را مشخص می‌کند. براین اساس داده‌ها به ۸ دسته تقسیم و ۸ قانون اگر- آنگاه تعیین شد (شکل ۱۰). نوع مدل فازی بکار رفته در ساختار ANFIS مورد مطالعه از نوع ساگنو است که براین اساس تابع عضویت خروجی نیز خطی می‌باشد.

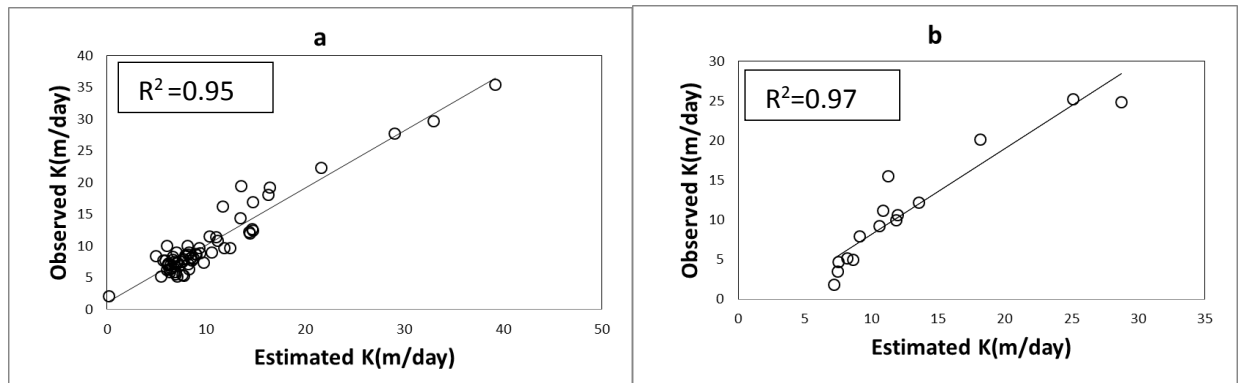
ماشین بردار پشتیبان

اساس روش ماشین‌های بردار پشتیبان (SVM) توسط کورتز و و پنیگ در سال ۱۹۹۵ ارائه گردیده است. ماشین بردار پشتیبان یک سیستم یادگیری کارآمد است که از اصل استقرایی کمینه سازی خطای ساختاری بهره می‌جوید و منجر به یک جواب بهینه کلی می‌گردد (Cristianini and Shawe, 2000). شکل ۸ تصویر شماتیکی از ماشین بردار پشتیبان را نشان می‌دهد. مهمترین کاربرد ماشین بردار پشتیبان در طبقه‌بندی و خطی سازی داده‌ها است. ویژگی مهم دیگر ماشین بردار پشتیبان که برخلاف الگوریتم‌های کلاسیک و رگرسیون‌های خطی که به وسیله کمینه کردن قدر مطلق خطا یا توان دوم خطا عمل می‌کنند، ریسک عملیاتی را کمینه می‌کنند. SVM، ریسک عدم طبقه‌بندی صحیح را به صورت یک سری عددی بیان می‌کند و بعد، مقدار کمینه این را حساب می‌کند اما شبکه عصبی پرسپترون چند لایه هر موقع خطای تقسیم‌بندی کم باشد آن را به عنوان یک راه حل ارائه می‌دهد. ماشین بردار پشتیبان برخلاف شبکه‌های عصبی با مشکل گیر افتادن در



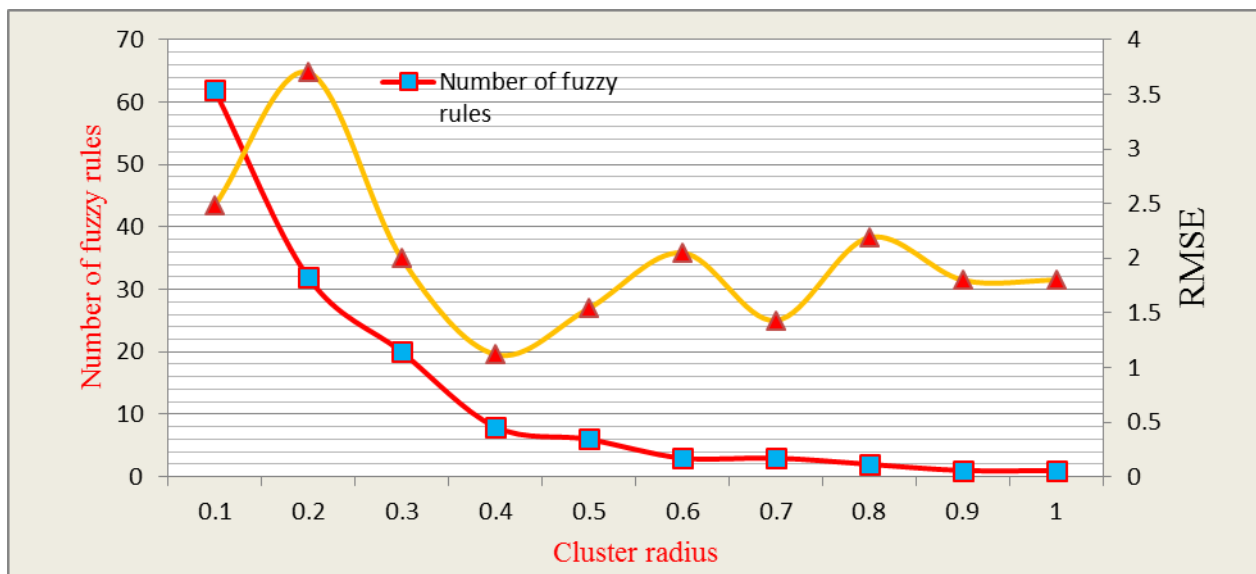
شکل ۸- ساختار کلی ماشین بردار پشتیبان.

Fig. 8. Structure of SVM.



شکل ۹- نمودار مقادیر مشاهداتی در مقابل مقادیر محاسباتی مدل ANN؛ (a) مرحله آموزش و (b) مرحله آزمایش.

Fig. 9. Observed vs estimated values for ANN model; (a) Test step and (b) Train step.



شکل ۱۰- شعاع دسته بندی و تعداد قوانین براساس کمینه RMSE.

Fig. 10. Clustering radius and rules number based on minimum RMSE.

پارامتر تابع کرنل است. در مدل سازی با حداقل مربعات ماشین بردار پشتیبان، انتخاب مقادیر مناسب دو پارامتر γ و σ از اهمیت بسیار زیادی برخوردار است. مقادیر این دو پارامتر هم می‌تواند با روش آزمون و خطا تعیین شود و هم با کدنویسی در محیط نرم افزار متلب. در این مطالعه با نوشتن دستوری که بتواند مقادیر بهینه این پارامترها را تعیین کند، بهره گرفته شد.

ارزیابی دقت مدل‌ها

مانند بسیاری از روش‌های مدلسازی در هیدروژئولوژی، کارایی مدل آموزش داده شده را می‌توان به وسیله داده‌هایی که در حین آموزش شبکه به کار نرفته اند سنجید. کارایی مدل آموزش داده شده را می‌توان از طریق محاسبه خطا بین داده‌های مشاهداتی و داده‌های تخمین زده شده ارزیابی کرد. معیارهای اصلی که برای ارزیابی و دقت شبکه آموزش داده شده به کار می‌روند، شاخص بازده R^2 (نسبت) است که به طور گسترده‌ای در مطالعات هیدروژئولوژی مورد استفاده قرار می‌گیرد. شاخص دوم برای ارزیابی کارایی مدل، میانگین مربعات خطا (RMSE) است که این هم نشانگر میزان بازده شبکه می‌باشد. شاخص سوم که برای ارزیابی کارایی مدل به کار می‌رود، ضریب همبستگی حجمی (I_{VF}) است. میانگین خطای مطلق (MAE) و ضریب همبستگی (r) نیز از معیارهای ارزیابی کارایی مدل هستند. هر یک از این ضرایب در رابطه‌های ۲۱ تا ۲۴ نشان داده شده‌اند. در روابط زیر y_i مقدار مشاهداتی، \hat{y}_i مقدار محاسباتی، \bar{y}_i میانگین داده‌ها و N تعداد کل داده‌ها می‌باشند.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (\text{رابطه ۲۱})$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{N}} \quad (\text{رابطه ۲۲})$$

$$I_{VF} = \frac{\sum_{i=1}^n (\hat{y}_i)}{\sum_{i=1}^n (y_i)} \quad (\text{رابطه ۲۳})$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{N} \quad (\text{رابطه ۲۴})$$

نتایج و بحث

در این مطالعه به منظور تخمین هدایت هیدرولیکی در دشت مراغه - بناب، از سه نوع از روش‌های هوش مصنوعی شامل ANN، ANFIS و SVM استفاده شد و نتایج آنها با همدیگر مقایسه گردید. براساس دسته‌بندی مدل‌های تجربی نسل جدید، این مدل‌ها به مدل‌های جعبه سیاه و جعبه خاکستری تقسیم می‌شوند و همینطور مدل‌های جعبه سیاه خود به مدل‌های هوش مصنوعی و مدل‌های یادگیری ماشین تقسیم می‌گردند. لذا از هر یک از این دسته‌ها یک

b و W به ترتیب مقادیر وزن‌ها و بایاس تابع رگرسیون هستند. $\varphi(x)$ ترسیم غیرخطی ورودی‌ها در فضای ویژگی با ابعاد بالا است. زمانی که LS-SVM برای تخمین تابع استفاده می‌شود، مسئله بهینه‌سازی بوسیله مینیمم کردن تابع معین فرموله می‌شود (Suykens et al., 2002):

$$\min R(w, e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 \quad (\text{رابطه ۱۵})$$

براساس این محدودیت:

$$y(x) = w^T \varphi(x_i) + b + e_i \quad (\text{رابطه ۱۶})$$

$$i = 1, 2, \dots, n$$

γ پارامتر تنظیم کننده خطا و e میزان خطا را نشان می‌دهد. برای حل این مسئله بهینه سازی از تابع لاگرانژ استفاده شده است:

$$l(w, b, e, a) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 - \quad (\text{رابطه ۱۷})$$

$$\sum_{i=1}^n a_i \{w^T \varphi(x_i) + b + e_i - y_i\}$$

حل معادله ۱۷ را می‌توان با مشتق جزئی w, b, e_i, a_i بدست آورد.

$$\frac{\partial l}{\partial w} = 0 \rightarrow w = \sum_{i=1}^n a_i \varphi(x_i) \quad (\text{رابطه ۱۸})$$

$$\frac{\partial l}{\partial b} = 0 \rightarrow \sum_{i=1}^n a_i = 0$$

$$\frac{\partial l}{\partial e_i} = 0 \rightarrow a_i = \gamma e_i$$

$$\frac{\partial l}{\partial a_i} = 0 \rightarrow w^T \varphi(x_i) + b + e_i - \gamma_i = 0$$

با استفاده از شرایط KKT مدل حداقل مربعات ماشین بردار پشتیبان به منظور تخمین تابع به صورت رابطه ۱۸ نتیجه می‌گردد:

$$y(x) = \sum_{i=1}^n a_i k(x_i, x) + b \quad (\text{رابطه ۱۹})$$

$k(x_i, x)$ تابع کرنل نامیده می‌شود. انواع مختلفی تابع کرنل مانند؛ خطی، سیگموئیدی، پایه شعاعی (RBF) و چند جمله‌ای وجود دارد. در این مطالعه از تابع نوع RBF استفاده شده است (معادله ۲۰).

$$k(x_i, x) = \exp\left(-\frac{\|x_i - x\|^2}{\sigma^2}\right) \sigma \quad (\text{رابطه ۲۰})$$

نتایج مدل ANFIS

برای تخمین هدایت هیدرولیکی با ANFIS، شبکه‌ای با ۵ متغیر ورودی شامل UTMX، UTM Y، مقاومت ویژه عرضی (R_t)، ضخامت اشباع (B) و هدایت الکتریکی (EC)، انتخاب شد. تنها خروجی مدل نیز هدایت الکتریکی می‌باشد. در اجرای مدل ANFIS، هر ورودی در شعاع‌های با مقادیر متفاوتی دسته‌بندی می‌شوند. در مرحله بعد تعداد قوانین فازی برای فازی سازی تعیین می‌شوند. مقادیر شعاع دسته‌بندی و تعداد قوانین فازی باید متناسب با کمترین میزان خطای مدل باشد. برای این منظور از روش آزمون و خطا برای تعیین تعداد قوانین فازی و شعاع دسته‌بندی استفاده شد. نتایج نشان داد که مدل در شعاع دسته‌بندی ۰٫۴ و تعداد قوانین فازی برابر با ۸، کمترین میزان RMSE را دارد. جهت ارزیابی کارایی ANFIS مورد استفاده، ابتدا نمودار پراکندگی مقادیر مشاهداتی در مقابل مقادیر محاسباتی مربوط به هریک از مراحل آموزش و آزمایش رسم شد (شکل ۱۱ و b) سپس ضریب تعیین (R^2) و مجذور میانگین مربعات خطا (RMSE) برای هریک از مراحل آموزش و آموزش محاسبه شد (جدول ۱). نتایج کمی نشان می‌دهد که این مدل نسبت به مدل ANN، مقدار RMSE کمتری در مرحله تست دارد. اما با وجود این، در برخی نقاط عملکرد بسیار بدتری داشته است مانند نقاط ۱۳ و ۶. شکل ۱۵ نشان می‌دهد که این نقاط در یک لیتولوژی قرار دارند، اما عملکرد دو مدل فوق در این نقاط متفاوت است. علاوه بر این، با بررسی مقادیر پارامترهای ورودی موثر در هدایت هیدرولیکی، در نقطه مجاور نقاط فوق، یعنی نقطه ۷ (شکل ۱۵)، در می‌یابیم که مقادیر هر یک از این پارامترها (R_t ، B، EC) در نقطه ۷ نسبت به نقاط ۶ و ۱۳ کاهش یافته‌اند. بنابراین می‌توان نتیجه گرفت که در محدوده نقاط ۶، ۷ و ۱۲ با کاهش مقادیر ورودی، توانایی مدل در تخمین هدایت هیدرولیکی بهتر شده است. اما در محدوده نقاط ۲، ۱۲ و ۱۵ که در مجاورت هم قرار دارند، نتایج متفاوتی بدست آمده است. مقادیر هر یک از پارامترهای ورودی (R_t ، B، EC) برای نقاط ۲، ۶، ۷، ۱۲، ۱۳ و ۱۵ در جدول ۲ آورده شده است. طبق مقادیر این جدول، مقدار R_t در نقطه ۱۵ کمتر از نقاط ۲ و ۱۳ بوده و مقدار B کمتر از دو نقطه فوق اما مقدار EC بیشتر از نقطه ۲ و کمتر از نقطه ۱۲ می‌باشد، با این اوصاف، عملکرد مدل در نقطه ۱۵ در مدل ANFIS و ANN بهتر شده است. این تفاوت اولاً می‌تواند ناشی از موقعیت نقطه ۱۵ باشد که تقریباً در مرز دو نوع لیتولوژی متفاوت قرار دارد. به این معنی که این نتایج نشان می‌دهد در شرایط پیچیده، قابلیت‌های ذاتی این مدلها منجر به تخمین بهتر شده است. بنابراین برای دستیابی به مدلسازی جامع‌تر، استفاده از مدل‌های مختلف و مقایسه کارایی آنها تحت شرایط مختلف، بسیار مهم به نظر می‌رسد. ثانیاً می‌تواند ناشی از سایر عوامل زمین‌شناختی و هیدروژئولوژیکی باشد، مانند ارتباط هیدروژئولوژیکی، هیدروژئوشیمیایی دو نوع سازند متفاوت و ... باشد که عملکرد مدل را تحت تاثیر قرار داده است. این مسئله دو نتیجه-

مدل که بیشترین کاربرد را در مدلسازی‌های هیدروژئولوژیکی داشته‌اند مورد استفاده قرار گرفت، از آن جمله مدل شبکه‌های عصبی مصنوعی به عنوان مدل هوش مصنوعی، مدل نروفازی به عنوان مدل جعبه خاکستری و مدل SVM به عنوان یادگیری ماشین استفاده شده است. بعد از اجرای مدلها، نقشه‌های توزیع هدایت هیدرولیکی حاصل از هر یک از این روش‌ها و همچنین نمودارهای پراکندگی برای هریک از مدل‌ها، تهیه و نشان داده شد. اطلاعات و داده‌های آزمایشات پمپاژ و مطالعات ژئوفیزیک انجام گرفته در دشت مراغه - بناب از سازمان آب منطقه ای آذربایجان شرقی جمع‌آوری و مورد تجزیه و تحلیل قرار گرفت و تعداد ۸۰ داده شامل مقادیر مقاومت ویژه عرضی، هدایت الکتریکی، ضخامت اشباع و $UTM(X)$ و $UTM(Y)$ نقاط برداشت هدایت هیدرولیکی تهیه گردید. از میان ۸۰ داده، ۶۵ داده برای مرحله آموزش و ۱۵ داده برای مرحله آزمایش انتخاب شدند. موقعیت نقاط اندازه‌گیری مربوط به مرحله تست نیز در شکل ۱۵ نشان داده شده است. همچنین نمودار مقایسه‌ای مقادیر مشاهداتی و محاسباتی برای هر یک از مدلها تهیه و در شکل ۱۵ آورده شده است. اجرای مدلها از طریق کدنویسی در محیط نرم افزار MATLAB (MATLAB,) انجام شد. (2015)

نتایج مدل ANN

در این تحقیق برای تخمین هدایت هیدرولیکی، از شبکه عصبی پرسپترون چندلایه با الگوریتم لوبنبرگ - مارکوارت (MLP-LM) استفاده شد. ساختار ANN مورد بررسی در این تحقیق دارای ۵ گره ورودی (همبسته با پارامترهای ورودی شامل؛ مقاومت ویژه عرضی، ضخامت اشباع، هدایت الکتریکی و UTMX و UTM Y) نقاط برداشت هدایت هیدرولیکی) و ۹ گره میانی می‌باشد. تعداد گره‌های میانی براساس روش آزمون و خطا و بهینه ترین حالت مدل انتخاب شد. به این صورت که از حداقل ۲ نود و حداکثر ۱۲ نود مدلسازی انجام گرفت و در نود میانی برابر با ۹، خطا تخمین در کمترین میزان قرار داشت. تنها گره خروجی مدل نیز هدایت هیدرولیکی می‌باشد. همچنین از تعداد تکرار ۵۰۰ که شبکه مورد نظر در این مقدار مناسب ترین عملکرد و کمترین خطا را دارد، استفاده شد. پس از نرمالیزه کردن داده‌ها و اجرای مدل میزان ضریب تعیین (R^2) و مجذور میانگین مربعات خطا (RMSE) و ضریب همبستگی حجمی، محاسبه و در جدول ۱ نشان داده شد. همچنین نتایج مدلسازی در شکل ۹ بصورت نمودار پراکندگی نمایش داده شد. با توجه به نتایج کیفی بدست آمده، که در جدول ۱ خلاصه شده‌اند، با وجود اینکه مدل LS-SVM کارایی بهتری را نسبت به مدل ANN نشان می‌دهد، اما مدل ANN نیز در برخی نقاط (شکل ۱۴) عملکرد بهتری در تخمین هدایت هیدرولیکی داشته است. در این مدل بهترین شبکه طراحی شده، مربوط به نقاط ۵ و ۱۳ می‌باشد. در این نقاط، مدل دارای بیشترین بازده و کمترین خطا می‌باشد.

به تغییرات عوامل، شرایط و خطاها، بستگی زیادی دارد. بنابراین باید تحت شرایط مختلفی، مدلها با همدیگر مقایسه شوند تا مشخص شود که کدام نوع مدل، پاسخ دقیق تری به مسئله مورد بررسی می دهد.

گیری مهم را بدست می دهد. اول اینکه عوامل دیگری غیر از لیتولوژی، در کارایی مدل در تخمین هدایت هیدرولیکی تاثیر دارند. دوم اینکه کارایی مدلها در تخمین هدایت هیدرولیکی، به پاسخ آنها

جدول ۱- مقایسه نتایج مدل ها براساس معیارهای ارزیابی.

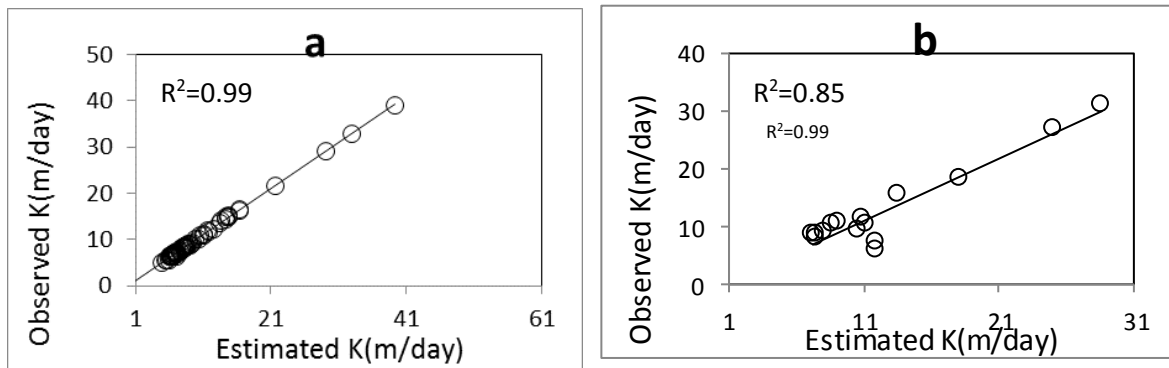
Table 1. Comparison of models results based on criterion.

Steps	Criterion		Model
Train	R^2	0.97	ANN
	RMSE	1.81	
	MAE	0.22	
	I_{VF}	0.99	
Test	R^2	0.95	
	RMSE	2.81	
	MAE	0.74	
	I_{VF}	0.87	
Train	R^2	0.99	ANFIS
	RMSE	0.23	
	MAE	0.015	
	I_{VF}	1	
Test	R^2	0.85	
	RMSE	1.12	
	MAE	0.069	
	I_{VF}	0.99	
Train	R^2	0.999	SVM
	RMSE	0.04	
	MAE	0.005	
	I_{VF}	1	
Test	R^2	0.97	
	RMSE	1.08	
	MAE	0.054	
	I_{VF}	1.03	

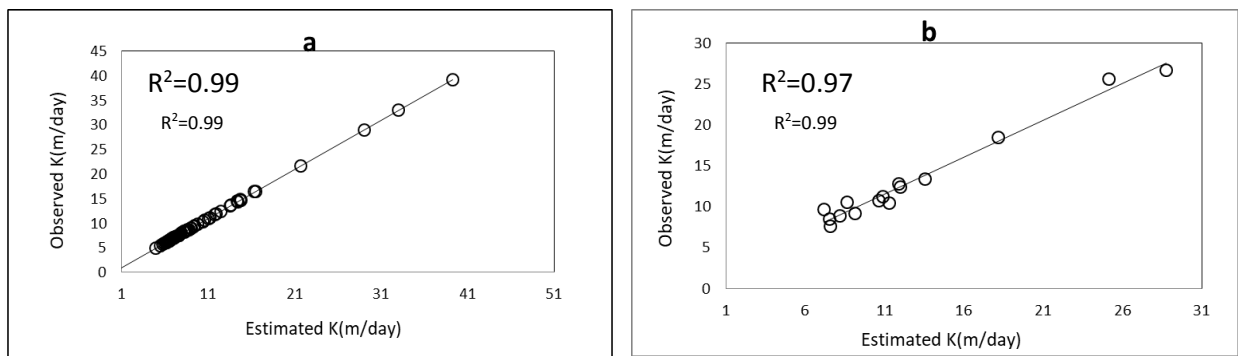
جدول ۲- مقادیر پارامترهای (EC , B , R_t) در نقاط ۲، ۶، ۷، ۱۲، ۱۳ و ۱۵.

Table 2. Parameters (EC , B , and R_t) values at points 2, 6, 7, 12, 13, and 15.

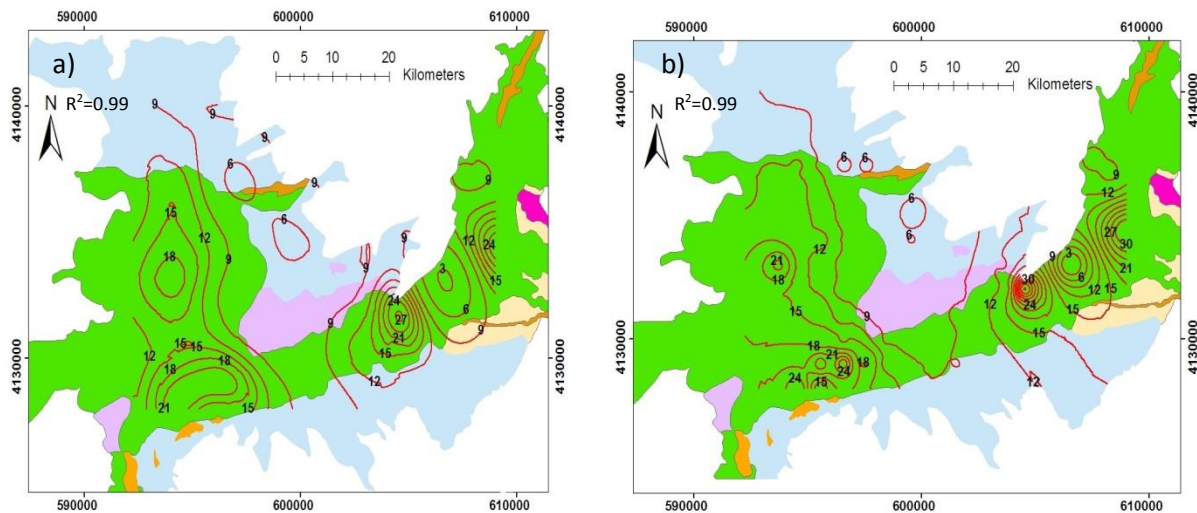
$EC(\mu s/cm)$	$B(m)$	$R_t(\Omega m)$	Test points
1686.62	27.64	936.79	2
1676.98	22.74	486.98	6
1940.18	26.64	1441.7	7
2290.45	24.02	116.77	12
1835.4	24.81	1325.95	13
1748.38	22.98	22.09	15



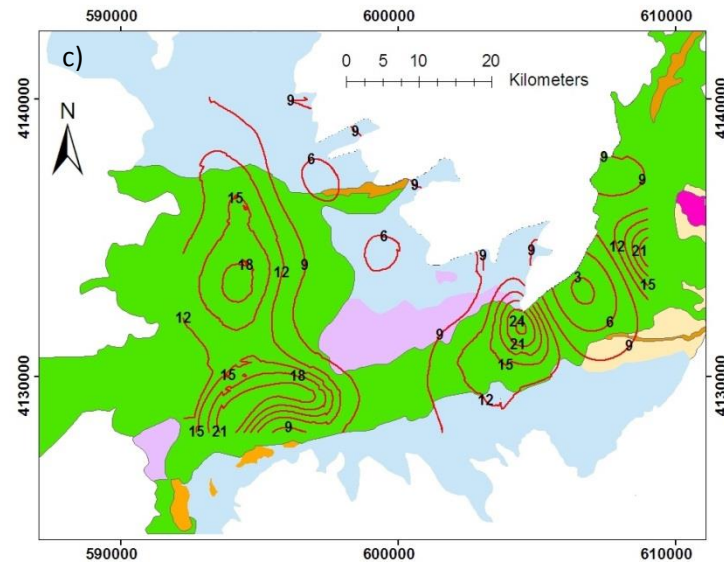
شکل ۱۱- نمودار اسکاتر مقادیر مشاهداتی در مقابل محاسباتی مدل ANFIS؛ (a) مرحله آموزش و (b) مرحله آزمایش.
 Fig. 11. Scatter diagram for observed vs estimated K(m/day); (a) Test step, and (b) Train step.



شکل ۱۲- نمودار اسکاتر نتایج مدل LS-SVM؛ (a) آموزش و (b) آزمایش.
 Fig. 12. Scatter diagram of LS-SVM results; (a) Train step, and (b) Test step.

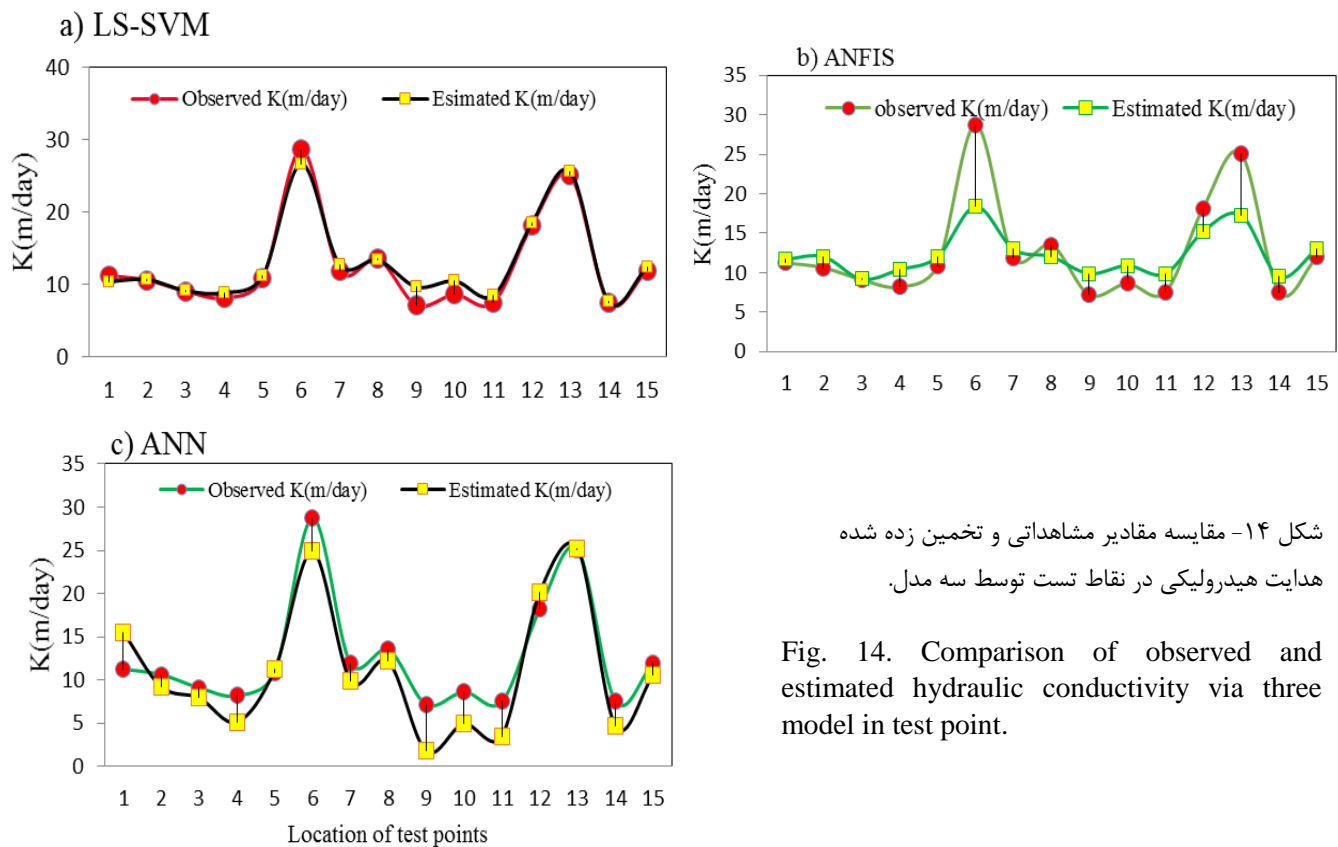


شکل ۱۳- نقشه توزیع مقادیر هدایت هیدرولیکی؛ (a) مدل ANN، (b) مدل SVM و (c) مدل ANFIS.
 Fig. 13. Distribution of hydraulic conductivity via (a) ANN model, (b) SVM model, and (c) ANFIS model.



شکل ۱۳- ادامه.

Fig. 13. Continued.



شکل ۱۴- مقایسه مقادیر مشاهداتی و تخمین زده شده هدایت هیدرولیکی در نقاط تست توسط سه مدل.

Fig. 14. Comparison of observed and estimated hydraulic conductivity via three model in test point.

تابع کرنلی که در این مطالعه مورد استفاده قرار گرفته است، براساس روش آزمون و خطا، تابع کرنل با پایه شعاعی (RBF) انتخاب گردید و مقادیر بهینه γ و σ با کدنویسی در محیط نرم افزار متلب (MATLAB, 2015) تعیین شدند. در انتها نیز مقادیر مشاهداتی و محاسباتی هدایت هیدرولیکی حاصل از مدل LS-SVM به صورت نمودارهای پراکنندگی تهیه شد (شکل ۱۲). برای نشان دادن توزیع مکانی هدایت هیدرولیکی در محدوده آبخوان مراغه - بناب،

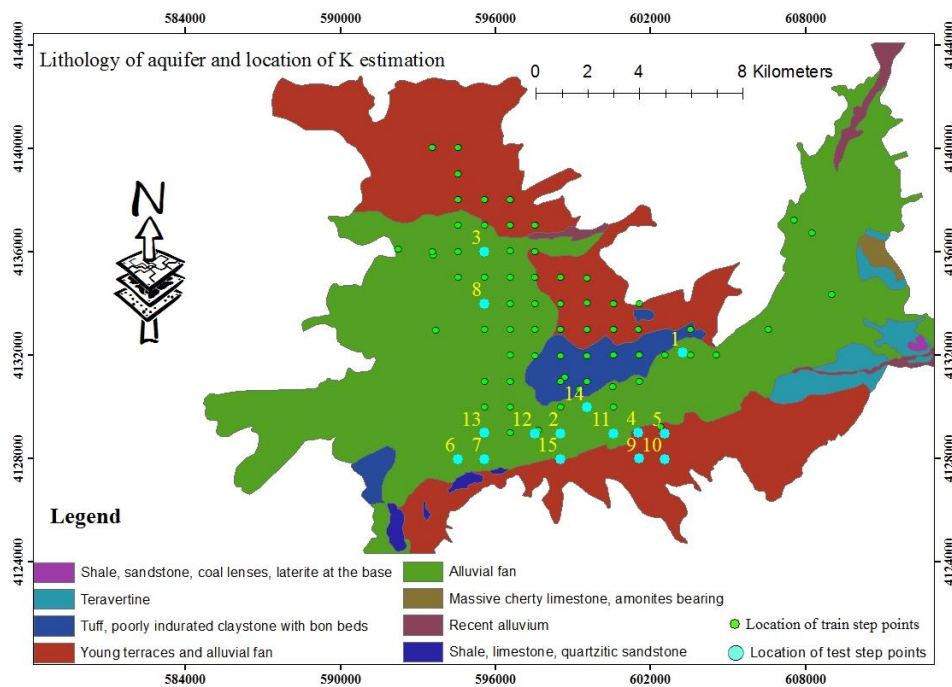
نتایج مدل SVM

ماشین بردار پشتیبان که در این مطالعه مورد استفاده قرار گرفته است از نوع مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM) می باشد. برای ارزیابی این نوع مدل، بررسی نوع توابع کرنل و تخمین پارامترهای γ و σ از اهمیت بالایی برخوردار است. برای تعیین نوع

نتیجه گیری

بر اساس تحقیق انجام یافته در خصوص مقایسه کارایی روش‌های مختلف هوش مصنوعی در تخمین پارامترهای هیدروژئولوژیکی، واضح است که توانایی این تکنیک‌ها با توجه به ساختارهای مختلف آنها و نیز طبیعت مسئله مورد نظر، متفاوت است. نتایج این تحقیق نشان می‌دهد که با انتخاب نوع و تعداد مناسب ورودی‌ها و نیز استفاده از تکنیک‌های هوش مصنوعی مناسب و سازگار با مسئله مورد بررسی، این تکنیک‌ها می‌توانند ابزاری مناسب و کارا برای تخمین پارامترهای هیدروژئولوژیکی مانند هدایت هیدرولیکی باشند. نتایج این تحقیق مشتمل بر نتایج مدل شبکه عصبی مصنوعی (ANN) با ساختار پرسپترون سه لایه با الگوریتم LM، سیستم استنتاج فازی - عصبی تطبیقی (ANFIS) و ماشین بردار پشتیبان (SVM) می‌باشد. مدل ANFIS که ترکیبی از مدل ANN و FIS می‌باشد و از قابلیت آموزش شبکه عصبی مصنوعی و قابلیت دسته‌بندی در سیستم فازی استفاده می‌کند. بر این اساس، این روش در این مطالعه خطای کمتری در مقایسه با شبکه عصبی مصنوعی نشان داد. برای انتخاب بهترین نوع مدل که بتواند با دقت بالایی هدایت هیدرولیکی را در دشت مراغه - بناب تخمین بزند، به مقایسه بین معیارهای ارزیابی پرداخته شد. با بررسی مقادیر R^2 و RMSE برای هر یک از مدل‌های مورد استفاده در این پژوهش، مشاهده شد که مقدار RMSE برای مدل‌های ANN، LS-SVM، ANFIS، به ترتیب برابر با ۰،۰۸، ۰،۸۱ و ۱،۱۲ می‌باشد.

نقشه توزیع هدایت هیدرولیکی هریک از مدل‌ها ArcGIS گردید (شکل ۱۳ تا c). برای مقایسه دقت و کارایی هریک از مدل‌ها، معیارهای ارزیابی که در رابطه‌های ۲۱ تا ۲۴ ارائه شدند، محاسبه و در جدول ۱ نشان داده شدند. این مدل در تمامی نقاط تست، عملکرد بهتری نسبت به دو نوع مدل دیگر را نشان می‌دهد. با وجود این، در نقاط ۹ و ۱۲، عملکرد ضعیفی را نسبت به سایر نقاط نشان می‌دهد، این مسئله می‌تواند ناشی از تغییرات لیتولوژی نسبت به سایر نقاط باشد (شکل ۱۵). با وجود این، نسبت به دو نوع مدل دیگر بسیار قوی‌تر عمل کرده و توانسته خطای بین مقایسه‌های مشاهده‌ای و محاسباتی را بشدت کاهش دهد. یکی از مسائلی که تخمین پارامترهای هیدروژئولوژیکی مانند هدایت هیدرولیکی را تحت تاثیر قرار می‌دهد، وجود برخی روابط غیر خطی بین پارامترها و شرایط پیچیده حاکم بر آبخوان است. نتایج بدست آمده نشان می‌دهد که مدل ماشین بردار پشتیبان (از مدل‌های یادگیری ماشین)، برای یادگیری رابطه پیچیده برای داده‌های ورودی داده شده و فیلتر کردن خطاهای احتمالی، در نقاط تست بهتر از مدل‌های ANN و ANFIS عمل کرده است. با این وجود، همانطور که در شکل ۱۴ نشان داده شده است، هر سه این مدل‌ها در برخی نقاط، دقت قابل قبولی در تخمین هدایت هیدرولیکی در مرحله تست داشته‌اند. علت این تخمین دقیق را می‌توان ناشی از صحت بیشتر داده‌های ورودی مشاهده‌ای دانست.



شکل ۱۵- لیتولوژی محدوده مطالعاتی و موقعیت نقاط اندازه گیری هدایت هیدرولیکی در نقاط تست و آزمایش.

Fig. 15. Lithology map of study area and location of hydraulic conductivity estimation points at train and test steps.

مسئله نشان می‌دهد که ماهیت داده‌های ورودی، ساختار مدلها و پیچیدگی شرایط حاکم بر محیط هیدروژئولوژیکی، می‌توانند عملکرد مدلها در تخمین هدایت هیدرولیکی را در نقاط مختلف تحت تاثیر قرار دهند. بنابراین پیشنهاد می‌شود برای ارزیابی بهتر کارایی مدلها در تخمین هدایت هیدرولیکی در آبخوان دشت مراغه - بناب و دیگر آبخوانهای مشابه، از انواع روشهای هوش مصنوعی استفاده شود. علاوه بر این می‌توان از مدلهای ترکیبی با ترکیب کننده‌های خطی مختلف، برای کاهش هرچه بیشتر خطای اندازه گیری، استفاده شود.

این مقادیر نشان می‌دهند که مدل LS-SVM قدرتمندترین مدل در تخمین هدایت هیدرولیکی در آبخوان دشت مراغه - بناب می‌باشد. با این حال، رسم نمودار مقادیر هدایت هیدرولیکی تخمین زده شده در مقابل مقادیر مشاهداتی در مرحله تست (شکل ۱۴)، نشان داد که دو مدل دیگر نیز تخمین قابل قبولی را در برخی نقاط ارائه داده‌اند. با وجود اینکه مدلهای ANN و ANFIS نسبت به مدل LS-SVM از حساسیت بیشتری در ساختار مدل و تعداد داده‌ها برخوردار هستند، اما عملکرد ضعیف‌تری را نشان داده‌اند، این

منابع

- Alyamani, M., Sen, Z., 1993. Determination of hydraulic conductivity from complete grain size distribution curves. *GroundWater*, 31, 551-555.
- Anifowose, F., Abdurraheem, A., 2011. Fuzzy logic-driven and SVM-driven hybrid computational intelligence models applied to oil and gas reservoir characterization. *Journal of Natural Gas Science and Engineering* 3(3), 505-517.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000. Artificial neural network in hydrology, part I and II.
- Bárdossy, A., Disse, M., 1993. Fuzzy rule-based models for infiltration. *Water Resource Research* 29(2), 373-382.
- Batyrshin, I., Sheremetov, L., Markov, M., Panova, A., 2005. Hybrid method for porosity classification in carbonate formations. *Journal of Petroleum Science and Engineering* 47(1-2), 35-50.
- Boulton, G.S., 1954. The drawdown of the water table under non-steady condition near a pumped well in an unconfined formation. *Proceedings of the Institution of Civil Engineers* 3, 564-579.
- Boulton, G.S., 1963. Analysis of data from non-equilibrium pumping tests allowing from delayed yield from storage. *Proceedings of the Institution of Civil Engineers* 26, 469-482.
- Boulton, G.S., Stretsova, T.D., 1975. New equation for determining the formation constant of an aquifer from pumping test data. *Water Resources Research* 11, 148-153.
- Carman, P.C., 1956. *Flow of Gases Through Porous Media*. Butterworths, London, Great Britain.
- Chitsazan, N., Nadiri, A.A., Tsai, F.T.C., 2015b. Prediction and structural uncertainty analyses of artificial neural networks using hierarchical Bayesian model averaging. *Journal of Hydrology* 528, 52-62.
- Chiu, S., 1994. Fuzzy model identification based on cluster estimation. *Journal of Intelligent and Fuzzy Systems* 2, 267-278.
- Chow, V.T., 1952. On the determination of transmissibility and storage coefficients from pumping test data. *Trans American Geophysical Union* 33, 397-404.
- Cooper, H.H., Jacob, C.E., 1946. A generalized graphical method for evaluating formation constants and summarizing well field history. *Trans American Geophysical Union* 27, 526-534.
- Corinna, C., Vapnik, V., 1995. Support-vector networks. *Machine learning* 20, 273-297.
- Cristianini, N., Shawe-Taylor, J., 2000. *An Introduction to Support Vector Machines*. Cambridge University Press, New York, USA.
- Fair, G.M., Hatch, L.P., 1933. Fundamental factors governing the stream line flow of water through sand. *Journal of American Water Work Association* 25, 1551-1565.
- Fijani, A., 2013. *Hydrogeology and Hydrogeochemistry of Maragheh-Bonab Aquifer Aia Ground water modeling*. M.Sc Thesis.
- Gorzalczany, M.B., 2001. *Computational Intelligence Systems and Applications*. Physica-Verlag, Heidelberg 362pp.
- Hazen, A., 1892. Some physical properties of sands and gravels. *Massachusetts state board of health 24th Annual Report*, p. 539-556.
- Helmy, T., Fatai, A., Faisal, K., 2010. Hybrid computational models for the characterization of oil and gas reservoirs. *Expert Systems with Applications* 37(7), 5353-5363.
- Hong, W.C., 2011. Traffic flow forecasting by seasonal SVR with chaotic simulated annealing algorithm. *Neurocomputing* 74, 2096-2107.

- Hsieh, B., Kewis, C., Lin, Z.S., 2005. Lithology identification of aquifer from geophysical well logs and fuzzy logic analysis: shui-lin area, Taiwan. *Computer and Geosciences* 31, 263-275.
- Hu, C., Hao, Y., Yeh, T.C.J., Pang, B., Wu, Z., 2008. Simulation of spring flows from a karst aquifer with an artificial neural network. *Hydrological Processes* 22, 596-604.
- Huang, Y., Gedeon, T.D., 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), 15-21.
- Jang, J.S.R., 1993. ANFIS: adaptive network-based fuzzy inference system. *IEEE Transactions on Systems, Man and Cybernetics* 23(3), 665-685.
- Jiajian, Y., 2011. Log prediction for blocked tripeptides with amino acids descriptors (HMLP) by multiple linear regression and support vector regression. *Procedia Environmental Sciences* 8, 173-178.
- Karam-Beygi, M., Hekmat, Z., Mohebi, A., Nezam Abadi Pour, H., 2008. Determination of groundwater aquifers lithology using neural fuzzy model using well surveying data. 12th Conference of the Geological Society of Iran, Ahvaz, Iran.
- Khashei, A., Ghahreman, B., Kouchak Zadeh, M., 2013. Comparison of artificial neural style models, ANFIS and regression in estimating the water table of Neishabour plain aquifer. *Iranian Journal of Irrigation and Drainage* 1(7), 10-22.
- Kurtulus, B., 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.
- Merdun, H., Çınar, Ö., Meral, R., Apan, M., 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil Tillage Research* 90(1-2), 108-116.
- Moench, A.F, 1997. Flow to a well of finite diameter in a homogeneous, anisotropic water table aquifer. *Water resource Research* 33(6), 1397-1407.
- Mokhtari, Z., Nazemi, A., Nadiri, A., 2012. Groundwater level prediction using artificial neural network model (Case study: Shabestar plain). *Journal of Applied Geology* 4, 345-353.
- Motaghian, H.R., Mohammadi, J., 2011. Spatial estimation of saturated hydraulic conductivity from terrain attributes using regression, kriging, and artificial neural networks. *Pedosphere* 21(2), 170-177.
- Nadiri, A., Asghari Moghadam, A., Abgari, H., Kalantari, A., Hosain Pour, A., Habib zadeh, A., 2014. Fuzzy logic model in estimating aquifer portability. Case study: Tasuj plain. *Journal of Soil and Water Science* 1(24), 209-223.
- Nadiri, A., Asgharimoghddam, A., Nourani, V., 2006. Basic of artificial neuran networks model (ANNs) and its application in hydrogeology. *Proceeding of the 24th Symposium of Geosciences, Geological Survey of Iran, Tehran, Iran.*
- Nadiri, A., Chitsazan, N., Tsai, F., Moghaddam, A., 2014. Bayesian Artificial Intelligence Model Averaging for Hydraulic Conductivity Estimation. *Journal of Hydrologic Engineerin* 19(3), 520-532.
- Nadiri, A.A., Fijani, E., Tsai, F.T.C., Asghari Moghaddam, A.A. 2013b. Supervised Committee Machine with Artificial Intelligence for Prediction of Fluoride Concentration. *Hydroinformatics Journal* 15.4, 1474-1490.
- Nauck, D., Kruse, R., 1999. Obtaining interpretable fuzzy classification rules from medical data. *Artificial Intelligence in Medicine* 16 (2), 149-169.
- Neuman, S.P., 1972. Theory of flow in unconfined aquifers considering delayed response of the water table. *Water Resources Research* 8, 1031-1045.
- Neuman, S.P., 1973. Supplementary common on "Theory of flow in unconfined aquifers considering delayed response of the water table". *Water Resources Research* 9, 1102-1103.
- Neuman, S.P., 1975. Analysis of pumping test data from anisotropic unconfined aquifers considering delayed gravity response. *Water Resources Research* 11, 329-342.
- Nourani, V., Asgharimoghaddam, A., Nadiri, A., Singh, V. P., 2008b. Forecasting spatiotemporal water level of Tabriz aquifer. *Trends in Applied Sciensses Reserch* 3(4), 319-329.
- Nourani, V., Asgharimoghddam, A., Nadiri, A., 2008a. An ANN-based model for spatiotemporal groundwater level forecasting. *Hydrogeological Procrsses* 22(26), 5054-5066.
- Ortega, R.M.V., Miranda, W.R., 2004. Resolution power of well log geophysics in karst aquifers. *Journal of Environmental Hydrology* 12, 1-7.
- Raghavendra, S., Paresh, C.D., 2014. Support vector machine applications in the field of hydrology: A review. *Applied Soft Computing* 19, 372-386.

- Sadeghfam, S., Hassanzadeh, Y., Nadiri, A.A., Khatibi, R., 2016. Mapping groundwater potential field using catastrophe fuzzy membership functions and Jenks optimization method: a case study of Maragheh-Bonab plain, Iran. *Environmental Earth Sciences* 75, p. 545.
- Samani, N., Gohari-Moghadam, M., Safavi, A.A., 2007. A simple neural network model for the determination of aquifer parameters. *Journal of Hydrology* 340(1-2), 1-11.
- Samani, N., Zare, M., Shahsavand, D., Nouri, M.H., 2005. Estimation hydraulic conductivity via adoptive neuro-fuzzy system and Gis. Ninth Conference of the Iranian Geological Society, University of Tarbiat Moalem, Tehran, Iran, p. 81-91.
- Schaap, M.G., Leij, F.J., 1998. Using neural networks to predict soil water retention and soil hydraulic conductivity. *Soil Tillage Research* 47(1-2), 37-42.
- Seifi, A., 2010. Developing of expert system to prediction of daily evapotranspiration by support vector machine and compare results to ANN, ANFIS and experimental method. M.Sc. Thesis, Tarbiat Modarres University, Tehran, Iran.
- Shabri, A., Suhartono., 2012. Streamflow forecasting using least-squares support vector machines. *Hydrological Sciences journal* 57(7), 1275-1293.
- Shepherd, R.G., 1989. Correlations of permeability and grain size. *Ground Water* 27, 633-638.
- Srivastav, R.K., Sudheer, K.P., Chaubey, I., 2007. A simplified approach to quantifying predictive and parametric uncertainty in artificial neural network hydrologic models. *Water Resource Research* 43(10), 10407.
- Suykens, J.A.K., Tony, V.G., De, B.J., Bart, D.M., Joos, V., 2002. *Least Squares Support Vector Machines*, World Scientific Publishing, Singapore.
- Taheri Tizro, A., Voudouris, K., Basami, Y., 2012. Estimation of porosity and specific yield by application of geoelectrical. *Journal of Hydrology* 454-455, 160-172
- Tayfur, G., Nadiri, A.A., Moghaddam, A., 2014. Supervised Intelligent Committee Machine Method for Hydraulic Conductivity Estimation. *Water Resour Manage* 28, 1173-1184.
- Theis C.V., 1935. The relation between lowering of the piezometric surface and the rate and duration of discharge of the well using groundwater storage. *Trans American Geophysics Union* 2, 519-524.
- Tutmez, B., 2010. Assessment of porosity using spatial correlation-based radial basis function and neuro-fuzzy inference system. *Neural Computing and Applications* 19(3), 499-505.
- Tutmez, B., Hatipoglu, Z., 2007. Spatial estimation model of porosity. *Computers & Geosciences* 33(4), 465-475.
- Walton, W.C., 1962. Selected analytical methods for well and aquifer evaluation. *Bulletin* 49, Illinois State Water Survey, Urban, pp. 18.
- Yoon, H., Jun, S.C., Hyun, Y., Bae, G.O., Lee, K.K., 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of Hydrology* 396, 128-138.