



Research Paper

## Comparison of Artificial Intelligence and Geostatistical Methods in Soil Surface Salinity Prediction in Ghorghori, Hirmand

Halimeh Piri<sup>1\*</sup> and Mojtab Mobarki<sup>2</sup>

<sup>1</sup>Assist. Professor, Department of Water Engineering, College of Water and Soil, University of Zabol, Zabol, Iran

<sup>2</sup>M. Sc. Alumni, Department of Water Engineering, College of Water and Soil, University of Zabol, Zabol, Iran

### Article information

**Received:** October 26, 2021

**Revised:** January 29, 2022

**Accepted:** January 30, 2022

### Keywords:

Decision Tree

Neural Network

Support Vector Machine

Zoning

\*Corresponding author:

[h\\_piri2880@uoz.ac.ir](mailto:h_piri2880@uoz.ac.ir)



### Abstract

In this study, geostatistical methods and artificial intelligence models (artificial neural network, decision tree, and support vector machine) were used to simulate the soil salinity of Ghorghori lands in Hirmand city. A total of 130 soil samples were collected from 0-30 cm layers of the soil. The electrical conductivity of each sample was measured using an electrical conductivity device. Soil salinity values were estimated using Geostatistical methods and artificial intelligence methods. Geostatistical and artificial intelligence models were applied and the best model was selected; the accuracy of the methods was compared using independent validation. The results showed that the artificial intelligence methods outperformed the geostatistical method in estimating the soil salinity of the artificial intelligence methods, the decision tree model was the superior model due to its coefficient of determination of 0.99 and RMSE and MAE statistics of 0.26 and 0.18 respectively. The salinity trend showed that the salinity of the soil of the region decreases from west to east first and then increases and decreases from north to south. In order to preserve the environment of the region, the field of planting plant species compatible with the region should be provided in accordance with soil salinity.

© Authors, Published by **Environment and Water Engineering** journal. This is an open-access article distributed under the CC BY (license <http://creativecommons.org/licenses/by/4.0/>).



### Introduction

Examining soil salinity changes over a large area is costly and time-consuming. Therefore, methods should be used that can easily study salinity on a large scale. In recent years, estimation methods have been used to estimate soil salinity. Among the estimation methods, can mention the use of Geostatistical and artificial intelligence methods. Much research has been done on the use of Geostatistical in identifying soil salinity. The spatial distribution of some soil

properties on the Zabol-Zahedan route was investigated using Geostatistical Method. The results of their study showed that geostatistical well models soil properties. Neural network in various sciences, including water science, these models have been widely used in recent years. Meanwhile, these models predict soil properties very well and very accurately. The decision tree and neural network methods were used in predicting soil salinity west of Urmia Lake. The results showed that the decision tree model



showed better estimation of soil salinity than the artificial neural network model. In literature, various methods have been used to predict soil salinity. In this study, the salinity of Ghorghori Plain soil in Hirmand city was investigated using Geostatistical and artificial intelligence methods and determining the appropriate method for determining the salinity of the region.

### Material and Methods

The study area is the Gharghari section of Hirmand city, located in the north of Sistan and Baluchestan province. To do the work, 130 soil samples were taken from a depth of 0-30 cm of soil. The collected samples were transferred to the laboratory. In the laboratory, the samples were dried. In the laboratory, after preparing the soil saturated extract, electrical conductivity was measured using a conductometer and pH was measured using a pH meter.

Artificial neural network, decision tree and support vector machine methods were used to predict soil salinity. Matlab software was used to perform artificial intelligence methods. Geostatistical was used to describe the spatial relationship between salinity. Using GS<sup>+</sup> software, salinity trend and spatial distribution map of salinity in the region were drawn. Artificial neural network methods for design require three categories of educational data, testing and validation. Training data is used to find the relationship between observable inputs and outputs. Validation data is used to control

and monitor the correct learning of the network, and test data is used to evaluate the performance of the proposed network. In this study, for the neural network method and decision tree method, 70, 15, and 15% of the total data, for training, testing, and model validation, respectively, and for the support vector machine model, 60 and 40% of the total data for training and testing, respectively. Method assigned. Content software was used to perform artificial intelligence methods.

To evaluate the accuracy and validity of the models used, the statistical indices, R<sup>2</sup> (Eq. 1) RMSE (Eq. 2), and MAE (Eq. 3) were used.

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - x_i^*)^2}{\sum_{i=1}^n (x_i - \bar{x}_i)^2} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - x_i^*)^2} \quad (2)$$

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

Where,  $x_i$  is the measured value,  $x_i^*$  is the estimated value, and  $n$  is the number of samples.

### Results

Some descriptive statistics indices of physical and chemical parameters of the studied soil are given in Table 1.

Table 1 Statistical description of physical and chemical properties of soil samples

Soil properties	Unit	Minimum	Maximum	Average	Middle	Standard deviation	Coefficient of Variation	Skewness
EC	ds/m	2.42	64	15.15	9.82	14.28	94.24	1.79
pH	-	6.7	10.22	7.96	8	0.53	6.72	0.23
Clay	%	0	17.5	4.65	3.5	3.43	73.87	0.99
Sand	%	73	96	82.89	82	5.86	7.07	0.41
Silt	%	1	21	12.44	12.5	4.63	37.26	-0.19

The coefficient of variation (dispersion) is an index that is used to measure the dispersion distribution of statistical data as well as to compare the dispersion of two or more variables. In this study, the minimum coefficient of variation for soil acidity was 6.72% and the maximum value was 94.24% for soil electrical conductivity.

Fig. 1 shows the trend of spatial changes in soil salinity in the study area. As can be seen, according to the green trend line, the salinity from the west of the region to the east first

decreases and then increases. The reason is the increase in wind intensity in this area and severe wind erosion, which has caused the destruction and instability of the soil structure and severely reduced vegetation and has led to salinity and alkalinity of the soil. Fig. 2 shows the spatial distribution of electrical conductivity in the Ghorghori area of Hirmand city. As can be seen, the salinity values are higher in the east and the northern and central parts.

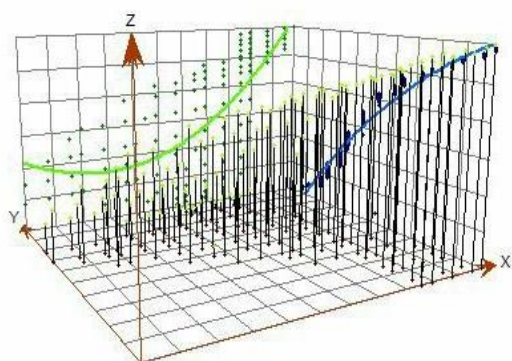


Fig. 1 The trend of changes in salinity




Fig. 2 Electrical conductivity zoning map

In Table (2) the results of the comparison of the three methods of artificial neural network, the support vector machine method, and the decision tree and the geostatistical method in predicting electrical conductivity are observed. Due to the high coefficient of determination (0.99) and low error statistics (0.26 and 0.18), the decision tree

model was selected as the superior method for predicting the electrical conductivity of soil salinity. It was also observed that artificial intelligence methods predicted salinity better than Geostatistical method.

Table 2 Results of the four models performances

error statistics	MAE	RMSE	R <sup>2</sup>
artificial neural network (ann)	0.36	0.29	0.93
support machine vector (svm)	0.28	0.35	0.94
decision tree (m5)	0.18	0.26	0.99
geostatistical (k)	0.59	0.86	0.91

### Conclusions

The results showed that soil salinity decreased from west to east first and then increased and decreased from north to south. Among the artificial neural network method, decision tree and support vector machine, decision tree method is the superior method for predicting soil salinity.

### Acknowledgment

This research has been done with the financial support University of Zabol, research code IR-UOZ-GR-1837.

### Data Availability

The data can be sent by the responsible author via email (h\_piri2880@uoz.ac.ir) upon request.

### Conflicts of Interest

The authors of this article declared no conflict of interest regarding the authorship or publication of this article.





ISSN: 2476-3683

محیط‌زیست و مهندسی آب

Homepage: [www.jewe.ir](http://www.jewe.ir)

مقاله پژوهشی

## مقایسه روش‌های هوش مصنوعی و زمین‌آمار در پیش‌بینی شوری سطحی خاک در قرقری، هیرمند

حلیمه پیری<sup>۱\*</sup> و مجتبی مبارکی<sup>۲</sup>

<sup>۱</sup>استادیار، گروه مهندسی آب، دانشکده آب و خاک، دانشگاه زابل، زابل، ایران  
<sup>۲</sup>کارشناسی ارشد، گروه مهندسی آب، دانشکده آب و خاک، دانشگاه زابل، زابل، ایران

## اطلاعات مقاله

## چکیده

تاریخ دریافت: [۱۴۰۰/۰۸/۰۴]

تاریخ بازنگری: [۱۴۰۰/۱۱/۰۹]

تاریخ پذیرش: [۱۴۰۰/۱۱/۱۰]

## واژه‌های کلیدی:

پهنه‌بندی  
 درخت تصمیم  
 ماشین بردار پشتیبان  
 شبکه عصبی

## \*نویسنده مسئول:

[h\\_piri2880@uoz.ac.ir](mailto:h_piri2880@uoz.ac.ir)


در این پژوهش از روش زمین‌آمار و روش‌های هوش مصنوعی شامل شبکه عصبی مصنوعی، درخت تصمیم و ماشین بردار پشتیبان برای پیش‌بینی شوری خاک اراضی قرقری شهرستان هیرمند استفاده شد. برای این منظور تعداد ۱۳۰ نمونه خاک از عمق صفر تا ۳۰ cm خاک برداشت شد. نمونه‌های برداشت‌شده به آزمایشگاه منتقل و هدایت الکتریکی با استفاده از دستگاه هدایت‌سنج اندازه‌گیری شد. مقادیر شوری خاک با استفاده از روش زمین‌آمار و روش‌های هوش مصنوعی، برآورد شد. روش‌های زمین‌آمار و هوش مصنوعی برازش و بهترین مدل انتخاب و با استفاده از اعتبارسنجی مستقل دقت روش‌ها باهم مقایسه شد. نتایج نشان داد روش‌های هوش مصنوعی نسبت به روش زمین‌آمار شوری خاک را بهتر برآورد می‌کنند. بین روش‌های هوش مصنوعی روش درخت تصمیم با توجه به ضریب تبیین ۰/۹۹ و آماره‌های RMSE و MAE به ترتیب برابر ۰/۲۶ و ۰/۱۸ به‌عنوان روش برتر انتخاب شد. نتایج روند شوری نشان داد شوری خاک منطقه از غرب به شرق ابتدا کاهش و سپس افزایش و از شمال به جنوب کاهش می‌یابد. بنابراین با توجه به نتایج برای حفظ محیط‌زیست منطقه، باید زمینه کاشت گونه‌های گیاهی سازگار با منطقه، منطبق با شوری خاک فراهم شود.

## ۱- مقدمه

اهمیت خاک به‌دلیل رشد فزاینده جمعیت و بروز نیازهای جدید برای تأمین غذا جهت مصرف بی‌رویه جمعیت رو به رشد بیشتر مشخص می‌شود. یکی از مخرب‌ترین فرآیندها در خاک‌ها به‌خصوص در خاک‌های مناطق خشک و نیمه‌خشک، شوری است. کاهش رشد گیاهان و افزایش فرسایش خاک از پیامدهای نامطلوب این پدیده می‌باشد (Azhirabi et al., 2015). در این شرایط، نمک‌های محلول در سطح خاک

جمع یافته و باعث کاهش عملکرد و حاصلخیزی خاک می‌شوند. شناسایی و نقشه‌برداری خاک‌های شور می‌تواند به اصلاح و بهبود مدیریت آن‌ها کمک کند. برای پایداری کشاورزی، شوری باید شناسایی و مدیریت شود (Taghizadeh et al., 2016). بررسی تغییرات شوری خاک در مساحت زیاد پرهزینه و وقت‌گیر است. بنابراین باید از روش‌هایی استفاده کرد که بتواند به‌آسانی شوری را در سطح



مصنوعی و هوش مصنوعی می‌باشد. شبکه عصبی پردازنده‌ای است که دانشی را که از راه تجربه کسب نموده است برای استفاده‌های بعدی ذخیره می‌کند. پیاده‌سازی ساختارهای محاسباتی سیستم بیولوژیک می‌تواند منجر به ایجاد الگوهای محاسباتی بهتری برای گروه‌های معینی از مسائل شود. از آن جمله به گروهی از مسائل که با داده‌های ناقص، کم، متناقض، مبهم یا احتمالی موردبررسی قرار می‌گیرند، می‌توان اشاره نمود. با توجه به قابلیت‌های زیاد مدل‌های شبکه عصبی در علوم مختلف از جمله علوم آب، این مدل‌ها در سالیان اخیر در گستره وسیعی به کار گرفته شده‌اند. همچنین این مدل‌ها به خوبی و با دقت بسیار بالایی ویژگی‌های خاک را پیش‌بینی می‌کنند (Sharma et al. 2003). یکی از مزایای روش‌های هوش مصنوعی نسبت به سایر روش‌ها این است که این روش برای رابطه بین داده‌های خروجی و ورودی به یک تابع خاص نیاز ندارد (Yu et al. 2018). Ahmadi et al. (2020) از روش درخت تصمیم و شبکه عصبی در پیش‌بینی شوری خاک غرب دریاچه ارومیه استفاده و این دو روش را مورد مقایسه قرار دادند. نتایج تحقیق نشان داد مدل درخت تصمیم نسبت به مدل شبکه عصبی مصنوعی شوری خاک منطقه را بهتر نشان داد. (Moonjun et al. 2010) از روش شبکه عصبی مصنوعی و درخت تصمیم برای پیش‌بینی واحدهای خاک استفاده کردند. نتایج مطالعه آن‌ها نشان داد بین دو روش تفاوت معنی‌داری بری پیش‌بینی وجود ندارد. (Moradian et al. 2016) با استفاده از روش رگرسیون خطی و درخت تصمیم به بررسی شوری خاک منطقه قروه استان کردستان پرداختند. نتایج مطالعه آن‌ها نشان داد روش شبکه عصبی مصنوعی نسبت به روش رگرسیون درختی دقت بیشتری در پیش‌بینی شوری خاک دارد. Hossein Abadi et al. (2021) روش بیان ژن در پیش‌بینی مکانی شوری آب زیرزمینی و مقایسه آن با روش‌های زمین‌آماری را برای شوری دشت مشهد مورد ارزیابی قرار دادند. نتایج مطالعه آن‌ها نشان داد مدل بیان ژن به دلیل ضریب تبیین بالاتر و آماره خطای کم‌تر بهتر از سایر روش‌های موردبررسی بود.

همان‌طور که ملاحظه شد در پژوهش‌های انجام شده از روش‌های مختلفی برای پیش‌بینی شوری خاک استفاده شده است. با توجه به این‌که همه روش‌ها در هر منطقه کارایی ندارد و از طرف دیگر مقایسه بین روش‌های هوش مصنوعی و

وسیع بررسی کند (Ranjbar et al. 2016). در سال‌های اخیر از روش‌های تخمینی برای برآورد شوری خاک استفاده می‌شود (Taghizadeh et al. 2016). از جمله روش‌های تخمین می‌توان به استفاده از زمین‌آمار<sup>۱</sup> و روش‌های هوش مصنوعی<sup>۲</sup> نام برد. زمین‌آمار پیوستگی طبیعی خاک را مشخص کرده و واریانس تصادفی در مدل‌سازی مکانی خاک را در همبستگی با سایر خصوصیات خاک نشان می‌دهد (Watt and Palmer 2010). تحقیقات زیادی در خصوص استفاده از زمین‌آمار در شناسایی شوری خاک انجام شده است. Ahmadi et al. (2019) شوری خاک اراضی بولاق ساوه را با استفاده از زمین‌آمار پهنه‌بندی کردند. نتایج تحقیق آن‌ها نشان داد از پنج کلاس شوری خاک، شوری خاک منطقه بولاق ساوه در چهار کلاس غیرشور، تا اندازه‌ای شور، شوری متوسط و شوری زیاد قرار گرفته است که بیشترین مقادیر مربوط به میانه جنوبی منطقه مورد مطالعه است. (Akramkhanov et al. 2014) به بررسی شوری خاک اراضی ازبکستان با استفاده از زمین‌آمار پرداختند. نتایج تحقیق آن‌ها نشان داد در دوره ۲۰۰۸-۲۰۱۱ بیشتر اراضی منطقه شور نبوده و تنها چند نقطه دارای شوری ۶ دسی زیمنس بر متر بود. (Nawar et al. 2011) نقشه شوری خاک مصر را با استفاده از زمین‌آمار رسم کردند. ایشان بیان داشتند مدل کریجینگ با واریوگرام کروی بهترین مدل برای رسم نقشه پهنه‌بندی در منطقه می‌باشد. (Juan et al. 2011) در پژوهش خود بیان داشتند مدل کریجینگ با واریوگرام گوسی در اراضی کشاورزی جنوب اسپانیا، شوری خاک را بهتر نشان می‌دهد که می‌تواند به مدیریت بهتر اراضی کمک کند. (Sokouti Scoei et al. 2007) پراکنش شوری خاک را با استفاده از روش زمین‌آمار مورد ارزیابی قرار دادند و مشاهده کردند که روش کریجینگ دقت بالایی در برآورد شوری در نقاطی که نمونه‌برداری نشده است، دارد. (Behnam et al. 2019) به بررسی توزیع مکانی برخی ویژگی‌های خاک در مسیر زابل به زاهدان با استفاده از روش زمین‌آمار پرداختند. نتیجه مطالعه آن‌ها نشان داد زمین‌آمار به خوبی ویژگی‌های خاک را مدل‌سازی می‌نماید.

یکی دیگر از انواع مدل‌های مکانی جهت ارتباط دادن داده‌های خاک و متغیرهای محیطی شبکه‌های عصبی

<sup>1</sup>Geostatistic

<sup>2</sup>Artificial Intelligence

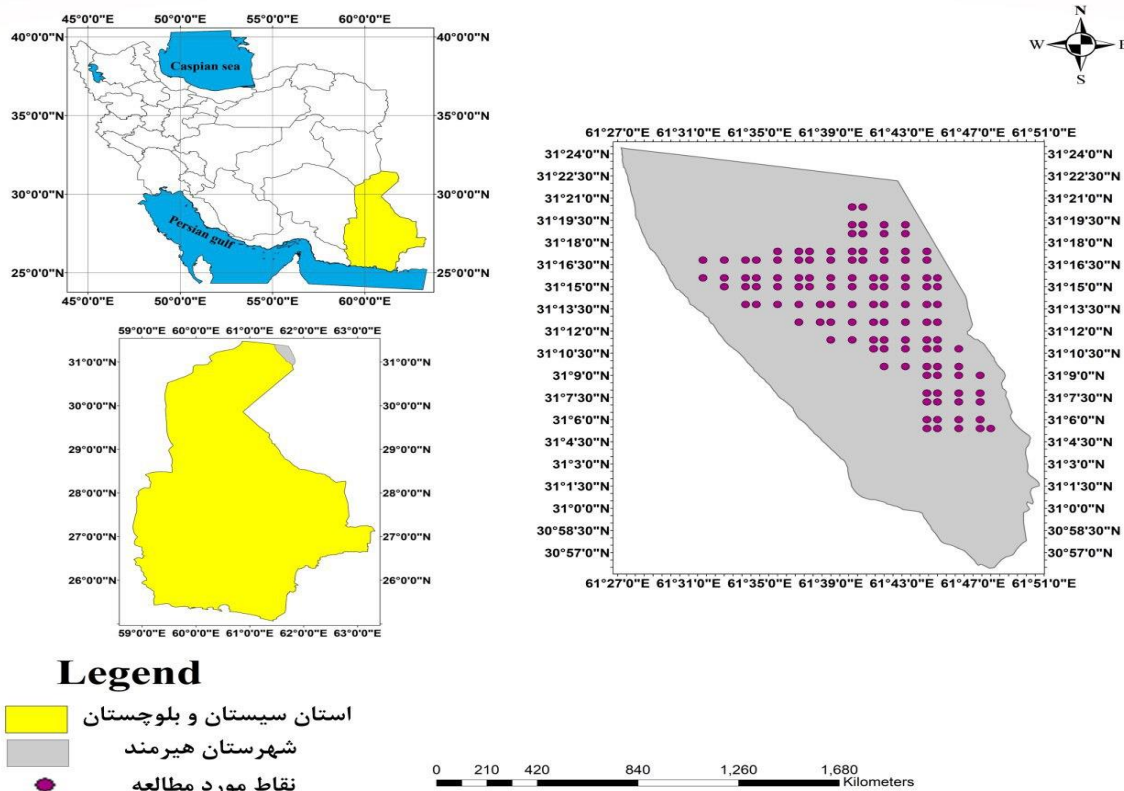
(Jahantigh and Jahantigh 2019). به همین دلیل می‌توان آثار شوره را به‌وضوح در سطح خاک‌های منطقه مشاهده نمود. بادهای ۱۲۰ روزه در این منطقه منحصربه‌فرد بوده و یکی از مهم‌ترین عوامل دخیل در مقدار بالای تبخیر و تعرق است. فرسایش بادی یکی از چالش‌های این منطقه است که اثرات منفی بر محیط‌زیست و تأسیسات زیربنایی آن دارد. کاربری زمین‌های منطقه شامل کشاورزی، مرتع و همچنین زمین‌های غیرقابل استفاده می‌باشند. عمق خاک منطقه پایین و این خاک‌ها حاصل رسوبات ته‌نشین شده ناشی از سیلاب‌های ورودی از کشور افغانستان است (Jahantigh and Jahantigh 2019). در اراضی تحت کشت معمولاً گندم، جو و یونجه به‌صورت غرقابی کشت می‌شوند که منابع آب آن‌ها از رودخانه هیرمند، چاه نیمه‌ها و آب زیرزمینی در منطقه تأمین می‌گردد. شکل (۱) موقعیت منطقه مورد مطالعه و نقاط نمونه‌برداری شده را نشان می‌دهد.

زمین‌آمار در بررسی شوری خاک نشده است. لذا در این تحقیق به بررسی شوری خاک دشت قرقری از توابع شهرستان هیرمند با استفاده از زمین‌آمار و روش‌های هوش مصنوعی و تعیین روش مناسب برای تعیین شوری منطقه پرداخته شد.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه مورد مطالعه

بخش قرقری از توابع شهرستان هیرمند واقع شده در شمال استان سیستان و بلوچستان می‌باشد که از لحاظ قرارگیری جغرافیایی نسبت به شهرستان زابل در ۳۳ km شمال شرقی شهرستان زابل به طول جغرافیایی  $61^{\circ} 45' 0''$  تا  $30' 0''$  شرقی و عرض جغرافیایی  $31^{\circ} 0' 0''$  تا  $31^{\circ} 30' 0''$  شمالی واقع شده است. متوسط بارندگی سالیانه آن ۵۰ mm و ارتفاع از سطح دریا به‌طور متوسط ۴۷۵ m می‌باشد. تبخیر و تعرق سالانه در این منطقه ۴۵۰۰ الی ۵۰۰۰ mm می‌باشد



شکل ۱- موقعیت نقاط در منطقه مورد مطالعه

Fig. 1 Location of the points in the study area

منتقل شد. در آزمایشگاه نمونه‌ها خشک و سپس از الک ۲ mm عبور داده شدند. در آزمایشگاه بعد از تهیه عصاره اشباع از خاک، هدایت الکتریکی با استفاده از دستگاه هدایت‌سنج و pH با استفاده از دستگاه pH متر اندازه‌گیری

### ۲-۲- نمونه‌برداری و آنالیز آزمایشگاهی

برای انجام کار تعداد ۱۳۰ نمونه خاک از عمق صفر تا ۳۰ cm خاک بر اساس شبکه‌بندی منظم با ابعاد ۱۵۰×۱۵۰×۱۵۰ برداشت شده به آزمایشگاه

از جمله دلایل استفاده از روش درختی می‌توان به این موارد اشاره کرد که روش درختی به‌طور مستقیم با متغیرهای پیش‌بینی کننده مرتبط می‌باشد، بنابراین نتایج روش برای فهم و شبیه‌سازی آسان هستند. همچنین درخت‌های تصمیم‌گیری غیرپارامتریک بوده و هیچ دخالتی از سوی کاربر بر روی آن‌ها صورت نمی‌گیرد. از طرف دیگر خروجی روش از دقت بالایی برخوردار است که می‌توان آن را با سایر روش‌ها مقایسه کرد (Debeljak and Džeroski 2011). درخت تصمیم برای انجام پیش‌بینی، ساختاری مشابه درخت ایجاد می‌کند به این صورت که ابتدا کار خود را با استفاده از تمام نمونه‌های آموزشی شروع می‌کند و متغیری که بهترین دسته‌بندی را انجام می‌دهد، انتخاب می‌کند و زیرمجموعه‌هایی تشکیل می‌دهد. شاخه‌های درخت نتیجه آزمونی است که در هر مرحله توسط الگوریتم بر روی گره‌های میانی صورت می‌گیرد. پیش‌بینی‌ها نیز در برگ‌های درخت ظاهر می‌شود (Debeljak and Džeroski 2011). روش درختی قابلیت پیش‌بینی متغیرهای پیوسته عددی از روی صفات عددی را دارد و نتایج پیش‌بینی شده به‌صورت مدل‌های رگرسیونی خطی چندمتغیره در برگ‌های درخت ظاهر می‌شود. معیار تقسیم در یک گره بر اساس انتخاب انحراف معیار مقادیر خروجی که به آن گره می‌رسند به‌عنوان معیاری از خطا است. با آزمودن هر پارامتر در گره کاهش مورد انتظار در خطا محاسبه می‌شود. خطای مدل عموماً با اندازه‌گیری دقت پیش‌بینی مقادیر هدف موارد دیده نشده، سنجش می‌شود. فرمول محاسبه کاهش انحرافات (SDR) به‌صورت روابط (۱) و (۲) می‌باشد (Debeljak and Džeroski 2011).

$$SDR = Sd(T) - \sum_{i=1}^N \frac{|Ti|}{|T|} Sd(Ti) \quad (1)$$

$$Sd(T) = \sqrt{\frac{1}{N} \left( \sum_{i=1}^N Yi^2 - \frac{1}{N} \left( \sum_{i=1}^N Yi \right)^2 \right)} \quad (2)$$

که، SDR: کاهش انحراف معیار، T مجموعه‌ای از نمونه‌ها است که به هر گره وارد می‌شود، Ti نشان‌دهنده‌ی زیرمجموعه‌ای از نمونه‌ها است که i امین نتیجه آزمون پتانسیلی را دارند، Sd بیانگر انحراف معیار، Yi مقدار عددی ویژگی هدف نمونه i و N شماره داده‌ها را نشان می‌دهد (Debeljak and Džeroski 2011).

شد. همچنین بافت خاک در آزمایشگاه به روش هیدرومتری تعیین شد.

### ۲-۳- تقسیم‌بندی داده‌ها

روش‌های شبکه عصبی مصنوعی جهت طراحی نیازمند سه دسته داده آموزشی، آزمون و اعتبارسنجی می‌باشند. از داده‌های آموزشی به‌منظور پیدا کردن رابطه بین ورودی‌ها و خروجی‌های مشاهده‌ای، استفاده شد. از داده‌های صحت-سنجی به‌منظور کنترل و نظارت بر یادگیری صحیح شبکه استفاده شد و از داده‌های آزمون برای ارزیابی عملکرد شبکه پیشنهادی استفاده گردید. در این پژوهش برای روش شبکه عصبی و روش درخت تصمیم ۷۰، ۱۵ و ۱۵٪ کل داده‌ها، به ترتیب برای آموزش، آزمون و اعتبارسنجی مدل و برای مدل ماشین بردار پشتیبان ۸۰ و ۲۰٪ کل داده‌ها به‌ترتیب برای آموزش و آزمون روش اختصاص یافت. برای انجام روش‌های هوش مصنوعی از نرم‌افزار مطلب استفاده شد (Siasar and Honar 2019).

### ۲-۴- شبکه عصبی مصنوعی

به‌منظور آموزش شبکه عصبی مصنوعی<sup>۱</sup>، شبکه پرسپترون چندلایه مورد استفاده قرار گرفت. فرایند آموزش که شامل تغییر وزن‌ها بین لایه‌های مختلف در طول زمان آموزش است، انجام شد تا جایی که تفاوت بین داده‌های واقعی (برای داده‌های آزمون) و داده‌های پیش‌بینی شده به حداقل برسد. الگوریتم آموزشی لونیبرگ-مارکوات<sup>۲</sup> و تابع سیگموئید تانژانتی هیپربولیک<sup>۳</sup> در لایه پنهان و تابع خطی<sup>۴</sup> در لایه خروجی برای فرآیند آموزش به‌کار گرفته شدند. تعداد نرون‌ها در لایه پنهان به روش سعی و خطا تعیین و در نهایت بهترین ساختارهای شبکه برای برآورد شوری خاک بر اساس شاخص‌های آماری انتخاب شد.

### ۲-۵- درخت تصمیم

روش درخت تصمیم<sup>۵</sup> زیرمجموعه‌ای از روش‌های یادگیری ماشینی و داده‌کاوی است. روش‌های یادگیری ماشینی و داده‌کاوی قابلیت کشف نیمه‌اتوماتیک الگوهای ارزشمندی از داده‌ها را دارند. در سال‌های اخیر مدل درختی تحول قابل توجهی در مسائل طبقه‌بندی و پیش‌بینی ایجاد نموده است.

<sup>1</sup>Artificial Neural Network

<sup>2</sup>Levenberg-Marquart

<sup>3</sup>Tansig

<sup>4</sup>purlin

<sup>5</sup>Decision Tree





## ۲-۶- ماشین بردار پشتیبان

هدف ماشین‌های بردار پشتیبان<sup>۱</sup>، یافتن یک تابع پیوسته با مقدار حقیقی است که بتواند به ازای مقادیر ورودی، پیش-بینی دقیقی از مقدار خروجی داشته باشد ( Nikbakht, Shahbazi et al. 2012). به‌طور کلی ماشین بردار پشتیبان نوعی سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که توسط ویپنیک<sup>۲</sup> ارائه شده است ( Nikpour et al. 2017).

در یک روش رگرسیونی SVM لازم است وابستگی تابع متغیر وابسته (y) به مجموعه‌ای از متغیرهای مستقل (x) تخمین زده شود. فرض بر این است که مانند دیگر مسائل رگرسیونی، رابطه بین متغیرهای وابسته و مستقل توسط یک تابع معین f به‌علاوه یک مقدار اضافی نویز مشخص می‌شود (رابطه ۳).

$$y = f(x) + noise \quad (3)$$

بنابراین موضوع اصلی پیدا کردن فرم اصلی تابع f است که بتواند به‌صورت صحیح، موارد جدیدی را که SVM تاکنون تجربه نکرده است، پیش‌بینی کند. در روش SVM -  $\epsilon$  از توابع هسته‌ای (کرنل) به‌منظور جداسازی صفحات و بهینه‌سازی فواصل موجود بین داده‌های مشاهداتی و تخمینی استفاده می‌شود اما در مدل V-SVM از روش برنامه‌ریزی غیرخطی برای کاهش خطای پیش‌بینی استفاده می‌شود. در این مطالعه مدل SVM -  $\epsilon$  به‌دلیل کاربرد گسترده آن در مسائل رگرسیونی استفاده گردید. برای این مدل، تابع خطا به‌صورت رابطه (۴) تعریف می‌شود ( Siasar and Honar, 2019).

$$C \sum_{i=1}^n \epsilon_i^* + C \sum_{i=1}^n \epsilon_i + \frac{1}{1} W^T W \quad (4)$$

تابع خطای مذکور لازم است که با توجه به محدودیت‌های زیر حداقل شود (روابط ۵ تا ۷) ( Siasar and Honar, 2019).

$$W^T \phi(x_i) + b - y_i \leq \epsilon + \epsilon_i \quad (5)$$

$$y_i - W^T \phi(x_i) + b \leq \epsilon + \epsilon_i \quad (6)$$

$$\epsilon_i \times \epsilon^* \geq 0 \quad (7)$$

در این روابط C ثابت گنجایش، W بردار ضریب،  $W^T$  ترانهاده بردار ضریب،  $\epsilon_i$  و  $\epsilon_i^*$  ضرایب کمبود، b ضریب ثابت، n الگوی آموزش مدل و  $\phi$  تابع کرنل است.

ماشین‌های بردار پشتیبان برای حل مسائل غیرخطی، ابعاد مسئله را از طریق توابع کرنل تغییر می‌دهند. انتخاب کرنل برای SVM به حجم داده‌های آموزشی و ابعاد بردار ویژگی بستگی دارد. به‌عبارت دیگر، باید با توجه به این پارامترها تابع کرنلی را انتخاب نمود که توانایی آموزش برای ورودی‌های مسئله را داشته باشد. در عمل کرنل خطی به‌کاربرده می‌شود (Siasar and Honar 2019).

## ۲-۷- زمین‌آمار

اساسی‌ترین ابزار در زمین‌آمار نیم‌تغییرنا می‌باشد که برای تشریح و توصیف ارتباط مکانی یک متغیر به کار می‌رود. نیم‌تغییرنا کمیتی برداری می‌باشد که درجه همبستگی مکانی و شباهت بین نقاط اندازه‌گیری‌شده را برحسب مربع تفاضل مقدار دو نقطه و با توجه به جهت و فاصله آن‌ها برآورد می‌کند. از مهم‌ترین ویژگی‌های نیم‌تغییرنا می‌توان به اثر قطعه‌ای<sup>۳</sup>، آستانه<sup>۴</sup> و دامنه تأثیر<sup>۵</sup> اشاره کرد (Soleimani et al. 2005). به‌منظور بررسی روابط مکانی بین نقاط اندازه‌گیری‌شده از مدل‌سازی واریوگرام یا نیم-تغییرنا استفاده شد. سپس با استفاده از روش کریجینگ به میان‌یابی و پیش‌بینی داده‌ها پرداخته شد. کریجینگ یکی از روش‌های متداول میان‌یابی زمین‌آمار است که بهترین تخمینگر خطی ناریب نام گرفته است. این روش با استفاده از مقادیر معلوم و یک نیم‌تغییرنا، مقادیر متغیر در نقاط فاقد آمار را برآورد می‌کند. در عمل نیم‌تغییرنمای تجربی که با نماد  $\gamma^*(h)$  نشان داده می‌شود، که با استفاده از رابطه (۸) محاسبه شد (Isaaks and Srivastava 1989).

$$\gamma^*(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (8)$$

که،  $N(h)$ : تعداد جفت نمونه‌ها به ازای هر فاصله h،  $Z(x_i)$ : مقدار متغیر در نقطه‌ای به مختصات  $x_i$  و  $Z(x_i+h)$ : مقدار متغیر در نقطه‌ای به مختصات  $(x_i+h)$  می‌باشد.

با افزایش h، مقدار نیم‌تغییرنا تا فاصله معینی اضافه می‌شود و پس‌از آن به حد ثابتی می‌رسد که حد آستانه نامیده

<sup>3</sup>Nugget Structure<sup>4</sup>Range<sup>5</sup>Still<sup>1</sup>Support Vector Machine<sup>2</sup>Vapnik

این اطلاعات استفاده می‌کند تا بهترین و از لحاظ آماری قوی‌ترین نقشه‌های ممکن را برای منطقه نمونه‌برداری شده ارائه نماید (Hassani Pak 2010).

### ۲-۸- معیارهای ارزیابی مدل

برای ارزیابی صحت و اعتبار مدل‌های مورد استفاده از شاخص‌های آماری ریشه میانگین مربعات خطا (RMSE)، ضریب تبیین ( $R^2$ )، و میانگین مطلق خطا (MAE) استفاده به صورت روابط (۱۰) تا (۱۲) محاسبه شد (Amini et al. 2019).

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - x_i^*)^2}{\sum_{i=1}^n (x_i - \bar{x}_i)^2} \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - x_i^*)^2} \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x_i^*| \quad (12)$$

که،  $x_i$  مقدار اندازه‌گیری شده،  $x_i^*$  مقادیر برآورد شده و  $n$  تعداد نمونه می‌باشد.

### ۳- یافته‌ها و بحث

برخی نمایه‌های آمار توصیفی پارامترهای فیزیکی و شیمیایی خاک مورد مطالعه در جدول (۱) آورده شده است.

جدول ۱- توصیف آماری خصوصیات فیزیکی و شیمیایی نمونه‌های خاک

Table 1 Statistical description of physical and chemical properties of soil samples

Soil Properties	Unit	Minimum	Maximum	Average	Middle	Standard Deviation	Coefficient of Variation	Skewness
EC	ds/m	2.42	64	15.15	9.82	14.28	94.24	1.79
pH	-	6.7	10.22	7.96	8	0.53	6.72	0.23
Clay	%	0	17.5	4.65	3.5	3.43	73.87	0.99
Sand	%	73	96	82.89	82	5.86	7.07	0.41
Silt	%	1	21	12.44	12.5	4.63	37.26	-0.19

Foroughifar et al. (2010) بیان داشته‌اند که ضریب تغییرات کم برای اسیدیته متأثر از عوامل ذاتی همچون مواد مادری در رفتار این ویژگی است. درحالی‌که ضریب تغییرات زیاد می‌تواند ناشی از اثر متقابل عوامل مدیریتی، مانند مصرف کود و عوامل ذاتی مانند وضعیت زهکشی در خاک‌ها باشد. ضریب تغییرات هدایت الکتریکی در منطقه مورد مطالعه ۹۴/۲۴٪ بود که می‌تواند ناشی از بالا بودن سطح

می‌شود. به فاصله بین نمونه‌ها که از آن به بعد مقادیر متغیر در نقاط مجاور تأثیر چندانی بر یکدیگر ندارند و با افزایش بیشتر فاصله مقدار نیم‌تغییرنا تفاوت معنی‌داری نمی‌کند، دامنه یا شعاع تأثیر گفته می‌شود. به مقدار نیم‌تغییرنا به ازای  $h=0$  اثر قطعه‌ای گفته می‌شود (Isaaks and Srivastava 1989). معمولاً اثر قطعه‌ای ناشی از خطاهای نمونه‌برداری، اندازه‌گیری و آنالیز داده‌هاست. مقادیر متغیر در نقاط فاقد آمار در کلیه روش‌های میان‌یابی زمین‌آماری از جمله کریجینگ با استفاده از رابطه (۹) محاسبه شد (Hassani Pak 2010).

$$Z^*(x_0) = \sum_{i=1}^n \lambda_i Z(x_i) \quad \text{with} \quad \sum_{i=1}^n \lambda_i = 1 \quad (9)$$

که،  $Z^*(x_0)$  مقدار تخمین زده شده متغیر  $Z$  در نقطه‌ای به مختصات  $x_0$ ، مقدار مشاهده شده متغیر  $Z$  در نقطه-ای به مختصات  $x_i$ ،  $\lambda_i$  وزن یا اهمیت نسبت داده شده به متغیر  $Z$  در نقطه‌ای به مختصات  $x_i$  و  $n$ : تعداد نقاط همسایگی می‌باشد.

برای انجام محاسبات و رسم واریوگرام‌های مربوط به زمین-آمار از نرم‌افزار  $GS^+$  استفاده شد. نرم‌افزار  $GS^+$  یک برنامه تحلیل زمین‌آماری و تهیه نقشه است که کمک می‌کند تا روابط مکانی موجود در داده‌های ژئورفرنس شده را سریع و به‌طور کارآمدی استخراج نماید. نرم‌افزار  $GS^+$  داده‌های مکانی را از لحاظ روابط درونی آن‌ها تحلیل کرده و سپس از

ضریب تغییرات (پراکندگی) شاخصی است که برای اندازه‌گیری توزیع پراکندگی داده‌های آماری و همچنین مقایسه پراکندگی دو یا چند متغیر به‌کار می‌رود. در این پژوهش کم‌ترین مقدار ضریب تغییرات برای اسیدیته خاک به مقدار ۶/۷۲٪ و بیش‌ترین مقدار آن ۹۴/۲۴٪ برای هدایت الکتریکی خاک بود. (Gholami et al. 2011) کمترین ضریب تغییرات را برای اسیدیته خاک گزارش کرده‌اند.

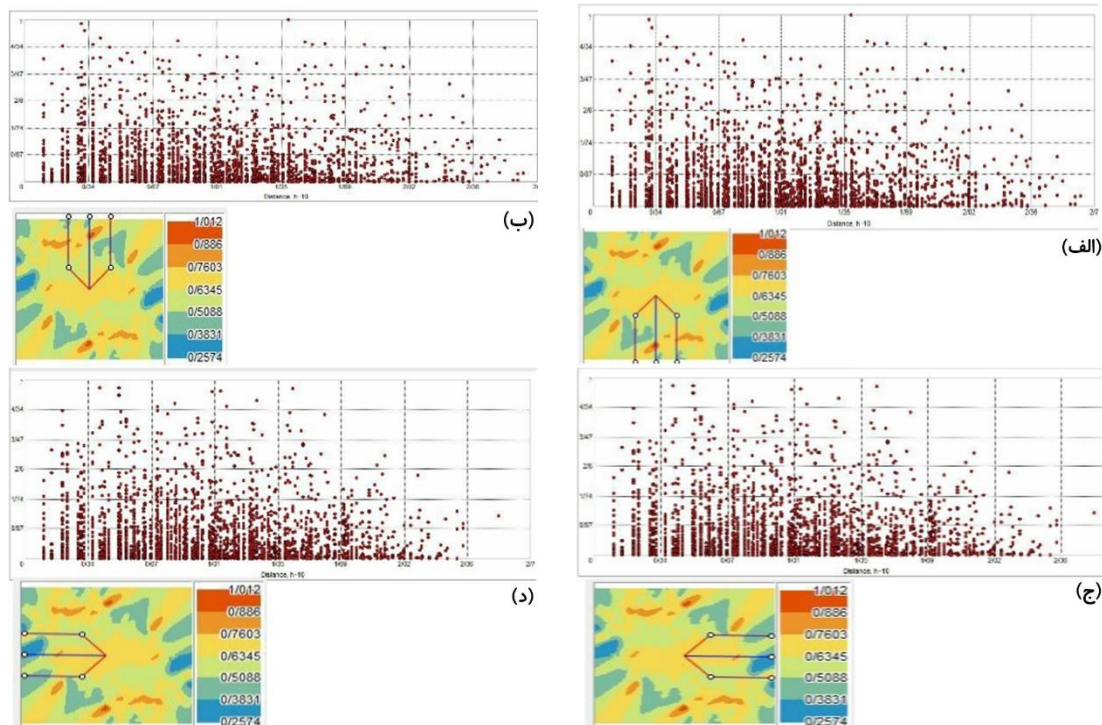
آمد که نشان می‌دهد وابستگی مکانی هدایت الکتریکی خاک در این منطقه در حد متوسطی بوده و از پیوستگی بینابینی برخوردار است. نتایج به‌دست‌آمده با نتایج Ahmadi et al. (2019) مطابقت دارد.

### ۳-۱- خودهمبستگی بین داده‌ها

در شکل (۲) خودهمبستگی سمی‌واریوگرام داده‌های EC خاک را در چهار جهت جغرافیایی نشان می‌دهد. همان‌طور که در شکل مشاهده می‌شود همبستگی بین مقادیر پایین‌تر EC بیش‌تر از مقادیر بالاتر بوده است.

آب‌های زیرزمینی و شدت بالای تبخیر ۴۵۰۰ تا ۵۰۰۰ mm و همچنین ناشی از کنده شدن و به‌جا ماندن رسوبات بادرفتی سطح دریاچه هامون باشد که در سال‌های اخیر خشک‌شده و باعث به‌جا ماندن نمک‌های محلول در سطح خاک منطقه مورد مطالعه شده است.

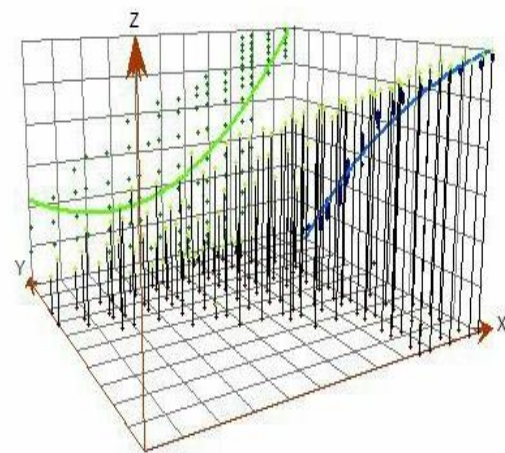
پارامترهای مدل برازش داده‌شده به هدایت الکتریکی با استفاده از زمین‌آمار نشان داد نسبت مؤلفه ساختاردار نیم-تغییرنما به سقف  $(C/(C_0+C))$  برابر  $0/56$  و نسبت اثر قطعه‌ای به حد آستانه (Nugget/sill) برابر  $49/59\%$  به‌دست



شکل ۲- نمودار خودهمبستگی سمی‌واریوگرام EC خاک در جهت‌های: الف) شمال، ب) جنوب، ج) غرب و د) شرق  
Fig. 2 Autocorrelation chart of soil EC variogram in different orientations: a) north, b) south, c) west, and d) east

### ۳-۲- روند تغییرات مکانی شوری خاک

شکل (۳) روند تغییرات مکانی شوری خاک در منطقه مورد مطالعه را نشان می‌دهد. همان‌طور که مشاهده می‌شود با توجه به خط روند سبز، شوری از غرب منطقه (منتهی‌الیه محور Y) به سمت شرق (منتهی‌الیه محور X) ابتدا کاهش و سپس افزایش می‌یابد. بیش‌ترین مقادیر شوری در شرق منطقه مشاهده می‌شود. علت آن افزایش شدت وزش باد در این قسمت و فرسایش شدید بادی می‌باشد که باعث تخریب و ناپایداری ساختمان خاک شده و پوشش گیاهی را به‌شدت کاهش داده و شوری و قلیائیت خاک را در پی داشته است. خط آبی‌رنگ روند کاهشی شوری را نشان می‌دهد. مطابق



شکل ۳- روند تغییرات شوری  
Fig. 3 The trend of changes in salinity

تعداد لایه پنهان، تعداد نرون در لایه پنهان و تعداد بهینه‌ی تکرار برای هر شبکه مورد آزمایش قرار گرفت و بهترین ساختار شبکه‌ها با روش سعی و خطا به دست آمد. همان‌طور که گفته شد ۷۰٪ داده‌ها برای آموزش، ۱۵٪ داده‌ها برای صحت‌سنجی و ۱۵٪ داده‌ها برای آزمون مورد استفاده قرار گرفت. تعداد نرون لایه پنهان برای پیش‌بینی هدایت الکتریکی ۱۰ به دست آمد. تکرار بهینه در ساختارهای به دست آمده ۱۰۰۰ و کارآترین تابع انتقال در لایه میانی تانژانت هایپربولیک و در لایه خروجی خطی بود.

برخلاف روش شبکه عصبی که از سه مرحله آموزش، صحت‌سنجی و آزمون استفاده شد، در روش ماشین بردار پشتیبان از دو مرحله آموزش و آزمون استفاده می‌شود. از ۶۰٪ داده‌ها برای مرحله آموزش و ۴۰٪ داده‌ها برای مرحله آزمون استفاده شد. نتایج شبیه‌سازی با درخت تصمیم همانند روش شبکه عصبی از سه مرحله آموزش، صحت‌سنجی و آزمون برای شبیه‌سازی تشکیل شده است. از ۷۰٪ داده‌ها برای مرحله آموزش و ۱۵٪ داده‌ها برای مرحله صحت‌سنجی و ۱۵٪ داده‌ها برای مرحله آزمون قرار داده شد. الگوریتم مورد استفاده  $M_5$  بود و فرآیندهای هموارسازی و هرس کردن برای شبیه‌سازی استفاده شدند. نتایج دقت آزمایی هر سه روش در برآورد هدایت الکتریکی برای سری داده‌های آموزش، صحت‌سنجی و آزمون در جدول (۲) آورده شده است.

جدول ۲- نتایج معیارها برای مرحله آموزش، صحت‌سنجی و آزمون


Table 2 Results of the models training, testing and validation

Model	Error statistics	MAE	RMSE	R <sup>2</sup>
Artificial Neural Network (ANN)	Train	0.17	0.65	0.86
	Validation	0.13	0.51	0.83
	Test	0.24	0.79	0.82
Support Machine Vector (SVM)	Train	0.32	0.75	0.82
	Validation	0.28	0.42	0.86
Decision Tree (M <sub>5</sub> )	Train	0.15	0.42	0.91
	Validation	0.41	0.65	0.85
	Test	0.46	0.78	0.82

۳-۴- مقایسه روش‌های زمین‌آمار و هوش مصنوعی  
ضریب تبیین مهم‌ترین معیاری است که به کمک آن می‌توان رابطه بین دو متغیر را توضیح داد و مقدار آن بین صفر و یک می‌باشد. هر چه این معیار به یک نزدیک‌تر باشد، نشان‌دهنده برآورد خوب می‌باشد. برای دستیابی به اطلاعات بیشتر، نمودار پراکنش نقاط و بهترین خط برازنده به این نقاط برای

این خط شوری از شمال (منتهی‌الیه محور X) به سمت جنوب (منتهی‌الیه محور Y) کاهش می‌یابد.

شکل (۴) توزیع مکانی هدایت الکتریکی در منطقه قرقری شهرستان هیرمند را بر اساس داده‌های نرمال شده نشان می‌دهد. همان‌طور که مشاهده می‌گردد مقادیر شوری در شرق و بخش‌های شمالی و مرکزی بیش‌تر است.



شکل ۴- نقشه پهنه‌بندی هدایت الکتریکی

Fig. 4 Electrical conductivity zoning map

در ادامه پژوهش به پیش‌بینی هدایت الکتریکی با استفاده از روش شبکه عصبی مصنوعی، درخت تصمیم و ماشین بردار پشتیبان پرداخته شد.

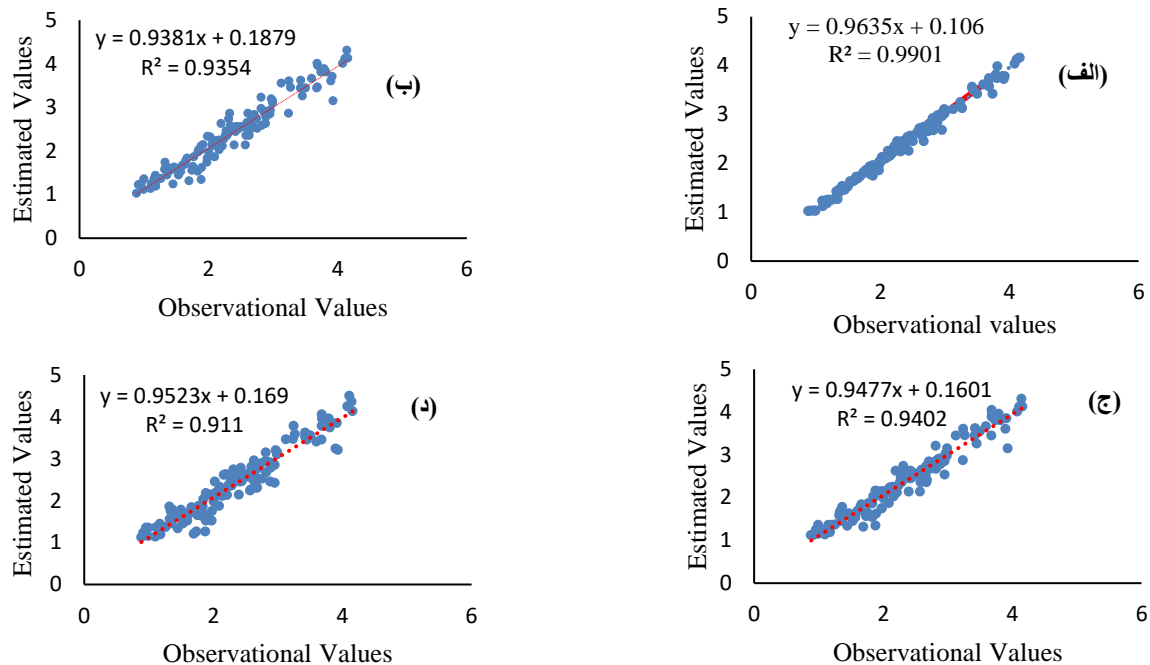
### ۳-۳- روش‌های هوش مصنوعی

در این پژوهش از شبکه پرسپترون چندلایه به منظور پیش‌بینی هدایت الکتریکی خاک استفاده شد و توابع انتقال،

همان‌طور که از جدول (۲) مشخص است مقادیر معیارهای ارزیابی روش‌ها (R<sup>2</sup> بالا و RMSE و MAE پایین) نشان‌دهنده عملکرد بسیار خوب هر سه روش در پیش‌بینی شوری خاک منطقه قرقری بود.

آن‌ها را کم‌تر از مقدار واقعی تخمین زده است و نقاط بالاتر از این خط نشان می‌دهند که روش مقدار آن‌ها را بیش‌تر تخمین زده است. همان‌طور که شکل نشان می‌دهد همه روش‌ها به‌خوبی هدایت الکتریکی را پیش‌بینی کرده‌اند.

هر سه روش رسم شد (شکل ۵). با توجه به نمودارها پراکنش ارتباط مستقیم خطی بین داده‌های اندازه‌گیری شده و پیش‌بینی شده مشاهده می‌شود. بیش‌تر نقاط حول خط رگرسیونی و نزدیک به آن هستند. نقاطی که زیر این خط مرجع قرار گرفته‌اند، نشان‌دهنده این هستند که روش مقدار



شکل ۵- مقادیر شبیه‌سازی شده و مشاهده‌ای شوری خاک: الف) دخت تصمیم، ب) شبکه عصبی مصنوعی، ج) ماشین بردار پشتیبانی، و د) زمین‌آمار

Fig. 5 The soil simulated and observed EC: a) decision tree, b) artificial neuron network, c) support machine vector, and d) geostatistical

جدول ۳- نتایج ارزیابی روش‌ها (شبکه عصبی مصنوعی، ماشین بردار پشتیبان، درخت تصمیم، زمین‌آمار) که با نتایج Sitharam et al. (2008) همخوانی داشت. آن‌ها نیز برتری روش شبکه عصبی را نسبت به زمین-آمار مشاهده کردند. (Ahmadi et al. (2020 نیز در بررسی شوری اراضی غرب دریاچه ارومیه به نتایج مشابه رسیدند و بیان داشتند از بین دو روش شبکه عصبی مصنوعی و درخت تصمیم، روش درخت تصمیم طبقه‌بندی رقوم خاک را دقیق‌تر بیان می‌کند. ایشان علت آن را ارتباط قوی بین داده خاک و پارامترهای محیطی تأثیرگذار بر دقت روش درخت تصمیم دانستند. (Taghizadeh et al. (2016 روش شبکه عصبی مصنوعی و درخت تصمیم را برای تهیه نقشه رقومی خاک مورد استفاده قرار دادند. نتایج تحقیق آن‌ها نشان داد درخت تصمیم با ضریب تبیین ۰/۴۶ و داشتن کم‌ترین مقادیر آماره‌های خطا برای طبقه‌بندی خاک‌ها مناسب‌تر می‌باشد.

جدول ۳- نتایج ارزیابی روش‌ها (شبکه عصبی مصنوعی، ماشین بردار پشتیبان، درخت تصمیم، زمین‌آمار)

Table 3 Results of the models performances (ANN, SVM, M5, K)

Error Statistics	MAE	RMSE	R <sup>2</sup>
Artificial Neural Network (ANN)	0.36	0.29	0.93
Support Machine Vector (SVM)	0.28	0.35	0.94
Decision Tree (M5)	0.18	0.26	0.99
Geostatistical (K)	0.59	0.86	0.91

در جدول (۳) کارایی سه روش شبکه عصبی مصنوعی، روش ماشین بردار پشتیبان و درخت تصمیم و روش زمین‌آمار در پیش‌بینی هدایت الکتریکی با استفاده از آماره‌های مجذور میانگین مربعات خطا و ضریب تبیین مقایسه شده است. با توجه به ضریب تبیین بالا (۰/۹۹) و آماره‌های خطای پایین (۰/۲۶ و ۰/۱۸)، مدل درخت تصمیم به‌عنوان روش برتر برای پیش‌بینی هدایت الکتریکی شوری خاک منطقه قرقری

**۴- نتیجه‌گیری**

در این پژوهش به‌منظور برآورد شوری خاک اراضی قرقری شهرستان هیرمند از روش‌های هوش مصنوعی و زمین‌آمار استفاده و نتایج آن‌ها با هم مقایسه شد. ابتدا با استفاده از روش زمین‌آمار روند تغییرات شوری و همبستگی بین داده‌ها مورد بررسی قرار گرفت. سپس نقشه شوری رسم شد. نتایج نشان داد:

۱- شوری خاک از غرب به شرق منطقه مورد مطالعه ابتدا کاهش و سپس افزایش و از شمال به جنوب کاهش می‌یابد.

۲- نتایج بررسی روش‌های هوش مصنوعی و زمین‌آمار نشان داد روش‌های هوش مصنوعی نسبت به زمین‌آمار برآورد بهتری از شوری خاک منطقه دارند.

۳- از بین روش شبکه عصبی مصنوعی، درخت تصمیم و ماشین بردار پشتیبان، روش درخت تصمیم روش برتری برای پیش‌بینی شوری خاک منطقه می‌باشد.

۴- نتایج درخت تصمیم می‌تواند به‌عنوان یک روش برای بهبود دقت پیش‌بینی مکانی خاک مورد استفاده قرار گیرد.

**سپاسگزاری**

این پژوهش با حمایت مالی دانشگاه زابل کد پژوهانه IR-UOZ-GR-1837 انجام شده است.

**دسترسی به داده‌ها**

داده‌ها حسب درخواست، از طرف نویسنده مسئول از طریق ایمیل (h\_piri2880@uoz.ac.ir) قابل ارسال می‌باشد.

**تضاد منافع نویسندگان**

نویسندگان این مقاله اعلام می‌دارند که، هیچ‌گونه تضاد منافی در رابطه با نویسندگی و یا انتشار این مقاله ندارند.

**References**

- Ahmadi, A., Taranjozar, H. and Kazemi, A. (2019). Surface salinity zonation in saline lands of Bolagh Saveh using geostatistical methods. *Nat. Environ. Hazard.*, 8(19), 1-14. [In Persian]
- Ahmadi, Z., Abbasi Kloo, A., Shahabi, M. and Bouali, A. (2020). Comparison of decision tree methods and artificial neural network in predicting soil salinity in the west of Lake Urmia. *Destruct. Rehabil. Nat. Land.*, 1(1), 82-91 [In Persian].
- Akramkhanov, A., Brus, D. J. and Walvoort, D. J. J. (2014). Geostatistical monitoring of soil salinity in Uzbekistan by repeated EMI surveys. *Geoderm.*, 213, 600-607.
- Amini, A., Kolahchi, A. A., Al-Ansari, N., Moghadam, M. K., and Mohammad, T. (2019). Application of TRMM precipitation data to evaluate drought and its effects on water resources instability. *Applied Sciences (Switzerland)*, 9(24) doi:10.3390/app9245377
- Azhirabi, R., Kamkar, B. and Abdi, O. (2015). Comparison of different indices adopted from Landsat images to map soil salinity in the army field of Gorgan. *J. Soil Manage. Sust. Prod.*, 5(1), 173-176 [In Persian].
- Behnam, V., Gholamalizadeh, A., Rahmanian, M. and Bameri, A. (2019). Investigation of spatial distribution of some physical and chemical properties of soil using Geostatistical methods (Case study: Zabol to Zahedan route). *Environ. Water Eng.*, 5(3), 251-263 [In Persian].
- Debeljak, M. and Džeroski, S. (2011). Decision trees in ecological modelling. In: Jopp, F., Reuter, H., Breckling, B. (eds), *Modelling complex ecological dynamics*. (197-209). Springer, Berlin, Heidelberg.
- Foroughifar H., Jafarzadah A. A., Torabi Gelsefidi H., Aliasgharzadah N., Toomanian N. and Davatgar, N. (2010). Spatial variations of surface soil physical and chemical properties on different landforms of Tabriz plain. *J. Soil Water Sci.*, 21(3), 1-21 [In Persian]
- Gholami, S., Hosseini, S. M., Mohammadi, J. and Mahini, A. S. (2011). Spatial variability of soil macrofauna biomass and soil properties in riparian forest of Karkhe River. *J. Water Soil*, 25, 248-257 [In Persian].
- Hassani Pak, A. (2010). *Geostatistics*. University of Tehran Press, 3<sup>rd</sup> Ed., p 325, Tehran [In Persian].



- Hossein Abadi, S., Khozeime Nezhad, H. and Khashei Sioki., A. (2021). Evaluation of gene expression model in spatial prediction of groundwater salinity and comparison with geostatistical models Case Study: Mashhad Plain. *Echo. Hydrol.*, 8(3), 855-866.
- Isaaks, E. H. and Srivastava, R. M. (1989). An introduction to applied geostatistics: Oxford University Press, 561.
- Jahantigh, M. and Jahantigh M. (2019). Study effect of flood productivity on vegetation changes using field work and Landsat satellite images (Case study: Shandak of Sistan region). *J. RS GIS Nat. Resour.*, 10(4), 57-73 [In Persian].
- Juan P., Mateu, J. Jordan, M. M, Mataix-Solera, J., Meléndez-Pastor, I. and Navarro-Pedreño, J. (2011). Geostatistical methods to identify and map spatial variations of soil salinity. *J. Geochem. Explor.*, 108, 66-72.
- Moonjun, R., Farshad A., Shrestha, D. P. and Vaiphasa, C. (2010). Artificial neural network and decision tree in predictive soil mapping of Hoi NumRin Sub-Watershed, Thailand, *Digital Soil Mapping. Prog. Soil Sci.*, 2(23), 151-164.
- Moradian, S., Nabiollahi, K. and Taghizadeh Mehrjerdi, R. (2017). Prediction of soil salinity using tree regression and artificial neural network in Qorveh region of Kurdistan province. *Soil Manage. Sustain. Product.*, 7(4), 115-129 [In Persian].
- Nawar, S., Reda, M., Farag, F. and El-Nahry, A. (2011). Mapping soil salinity in El-Tina plain in Egypt using geostatistical approach. *Geoinformatics Forum, Salzburg, Austria.* 211-216.
- Nikbakht Shahbazi, A., Zahraei, B. and Naseri, M. (2012). Seasonal forecast of meteorological drought using support vector machines. *Water Wastewater*, 2(23), 73-85 [In Persian].
- Nikpour, M. R., Thanikhani, H., Mahmoudi Babalan, S. and Mohammadi, A. (2017). Application of SVM, ANN, WNN and GEP models in rainfall-runoff simulation of Khiavachai river. *Echo. Hydrol.*, 4(2), 627-639 [In Persian].
- Ranjbar, F. and Jalali, M. (2016). The combination of geostatistics and geochemical simulation for the site-specific management of soil salinity and sodicity. *Comput. Electron. Agri.*, 121, 301-322.
- Sharma, V., Negi, S. C., Rudra, R. P. and Yang, S. (2003). Neural networks for predicting nitrate-nitrogen in drainage. *Agri. Water Manage.*, 63, 169-183.
- Siasar, H. and Honar, T. (2019). Application of support vector machine models, chad and random forest in estimating daily reference transpiration evaporation in northern Sistan and Baluchestan province. *Irrig. Drain. Iran.*, 2(13), 378-388 [In Persian].
- Sitharam, T. G., Samui, P. and Anbazhagan, P. (2008). Spatial variability of rock depth in temperate forests. *Geotech. Geol. Eng.*, 26(5), 503-517.
- Sokouti Scoei, R., Mahdian, R. and Mahmoodi, S. H. (2007). Comparing the applicability of semigeostatistic methods to predict the variability of soil salinity, a case study of Uromia plain. *Pajuhesh Sajandegi*, 74, 90-98 [In Persian].
- Soleimani, K., Habibnejad, M., Abkar, A. and Bani Asadi, M. (2006). Analysis of depth, surface and continuity curves using geostatistical methods in arid and semi-arid rainfall areas (D.A.D) Case study: Sirizjan salt pan). *J. Desert*, 11(1), 32-41 [In Persian].
- Taghizadeh, R., Minasny. B., Sarmadian, F. and Malone, P. B. (2016). Digital mapping of soil salinity in Ardakan region, central Iran. *Geoderm.*, 213(56), 15-28.
- Watt, M. and Palmer, S. (2010). Use of regression kriging to develop a Carbon: Nitrogen ratio surface for New Zealand. *Geoderm*, 183,49-57.
- Yu, H., Liu, M, Du, B., Wang, Z., Hu, L. and Zhang, B. (2018). Mapping Soil Salinity/Sodicity by using Landsat OLI Imagery and PLSR Algorithm over Semiarid West Jilin Province, China. *Sensor.*, 18(4), 1043-1017.

### How to cite this paper:

Piri, H. and Mobarki, M. (2022). Comparison of artificial intelligence and geostatistical methods in soil surface salinity prediction (case study: Ghorghori, Hirmand). *Environ. Water Eng.*, 8(3), 622-635. DOI:



