

## پیش‌بینی شوری خاک با روش شبکه عصبی و رگرسیون چندمتغیره بر مبنای شاخص‌های سنجش از دور و مقایسه آن‌ها (مطالعه موردی: شوره‌زار دشت قزوین)

افشین یوسف گمرکچی<sup>۱\*</sup>، علیرضا حسن اقلی<sup>۲</sup>، مهدی اکبری<sup>۳</sup>، مهرزاد مستشاری محمص<sup>۴</sup>، دانیال امینی<sup>۵</sup>

تاریخ دریافت: ۱۳۹۸/۸/۲۵

تاریخ پذیرش: ۱۳۹۹/۳/۲۶

### چکیده

وسعت بالای بیابان‌های ایران و شرایط نامناسب اقلیمی حاکم بر آن‌ها، اندازه‌گیری میدانی شوری خاک را در برخی موارد غیرعملی کرده است. در تحقیق حاضر از قابلیت‌های شبکه عصبی و مدل‌های رگرسیونی برای تهیه نقشه شوری خاک در محدوده زهکش حائل شوره‌زار دشت قزوین استفاده شده است. به منظور تحلیل شوری خاک، شاخص شوری خاک و پوشش گیاهی با استفاده از قابلیت تصاویر ماهواره‌ای استخراج شد. نتایج تحلیل همبستگی میانگین داده‌های زمانی نشان داد شاخص گیاهی با استفاده از قابلیت تصاویر ماهواره‌ای استخراج شد. نتایج تحلیل همبستگی میانگین داده‌های زمانی نشان داد شاخص شاخص GVI دارای همبستگی منفی بالایی با همه شاخص‌های شوری داشته و بر اساس یک رابطه رگرسیون مرتبه ۳ و با ضریب تبیین ۰/۷۹ با شاخص شوری خاک (SI) همبستگی داشته و بر اساس نتایج آزمون من-کنندال، تغییرات سری زمانی دو شاخص، در بازه زمانی ۱۵ ساله معنی‌دار بوده است. به منظور پیش‌بینی شوری خاک دو مدل شبکه عصبی و رگرسیون با متغیرهای کمکی شامل شاخص‌های شوری خاک و پوشش گیاهی (مستخرج از تصاویر ماهواره‌ای)، داده‌های میدانی اندازه‌گیری شده شوری خاک و تراز آب زیرزمینی به کار گرفته شد. نتایج تحقیق نشان داد مدل شبکه عصبی مصنوعی با ضریب تبیین ۰/۶۹، دارای دقت بیشتری نسبت به مدل رگرسیون برای پیش‌بینی شوری خاک بوده همچنین در فرایند مدل‌سازی، دقت پیش‌بینی هدایت الکتریکی خاک (EC) بیشتر از شاخص SAR خاک بوده است.

**کلیدواژه‌ها:** سطح ایستابی، شبکه عصبی، شوری خاک، قزوین، زهکش حائل، مدل‌سازی.

۱. استادیار بخش تحقیقات فنی و مهندسی کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان قزوین، سازمان تحقیقات، آموزش و ترویج کشاورزی، قزوین، ایران، a.gomrokchi@areeo.ac.ir

۲. دانشیار مؤسسه تحقیقات فنی و مهندسی کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران

۳. دانشیار مؤسسه تحقیقات فنی و مهندسی کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران

۴. دانشیار بخش تحقیقات خاک و آب، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان قزوین، سازمان تحقیقات، آموزش و ترویج کشاورزی، قزوین، ایران

۵. کارشناسی ارشد مهندسی منابع آب، دانشگاه صنعتی شریف، تهران، ایران

این مقاله مستخرج از طرح پژوهشی است.

## مقدمه

پیشرفت‌های اخیر در کاربرد فناوری سنجش از دور در تهیه نقشه و مدیریت زمین‌های تحت‌تأثیر نمک، سبب کاهش هزینه‌های پایش اراضی وسیع نیز شده است (پیشنماز احمدی و همکاران، ۲۰۱۷). پژوهشگران بسیاری در نقاط مختلف دنیا اقدام به تهیه نقشه شوری خاک با استفاده از تصاویر ماهواره‌ای، عکس‌های هوایی، تکنیک‌های زمینی و رادیومتری، بر اساس همبستگی بین انعکاس‌های مربوط به حضور نمک و شاخص‌های شوری خاک کردند. آلبد<sup>۱</sup> و همکاران (۲۰۱۴) باند ۳ تصاویر ماهواره‌ای آیکنوس<sup>۲</sup> را برای مطالعه شوری سطحی خاک در منطقه‌ای در عربستان انتخاب کردند. آن‌ها بر اساس شاخص شوری (SI)<sup>۳</sup> و داده‌های زمینی، یک مدل رگرسیونی ساده خطی را اجرا و همبستگی معنی‌داری بین شوری سطحی خاک و شاخص شوری (SI) به دست آوردند. ال هارتی<sup>۴</sup> (۲۰۱۶) با استفاده از تصاویر سنجنده TM و سنجنده OLI در دشت تادلا در مرکز مراکش اقدام به تهیه نقشه شوری خاک کردند. آن‌ها یک بازه زمانی ۱۳ ساله (۲۰۰۰ تا ۲۰۱۳ میلادی) تصاویر ماهواره‌ای را به منظور بررسی روند تغییرات شوری خاک سطحی مورد بررسی قرار دادند و با تعیین مقادیر هدایت الکتریکی خاک منطقه، مدل‌های رگرسیونی را اجرا کردند. در مرحله اعتبارسنجی، ضریب تبیین  $R^2$  از ۰/۵۵ تا ۰/۷۷ برآورد گردید. همچنین نتایج تحقیق نشان داد شوری در بازه زمانی مورد مطالعه، روند کاهشی در منطقه داشته است. ویتنی<sup>۵</sup> و همکاران (۲۰۱۸) در تحقیقی به اعتبارسنجی استفاده از سری زمانی تصاویر ماهواره مودیس، برای ارزیابی شوری خاک در اراضی کشاورزی کالیفرنیا پرداختند. آن‌ها سری‌های زمانی شاخص‌های  $^{NDVI}$ ،  $^{EVI}$  و  $^{CRSI}$  را برای دوره زمانی ۲۰۰۷ تا ۲۰۱۳ میلادی بررسی کردند. نتایج تحقیق نشان داد شاخص CRSI وضعیت شوری

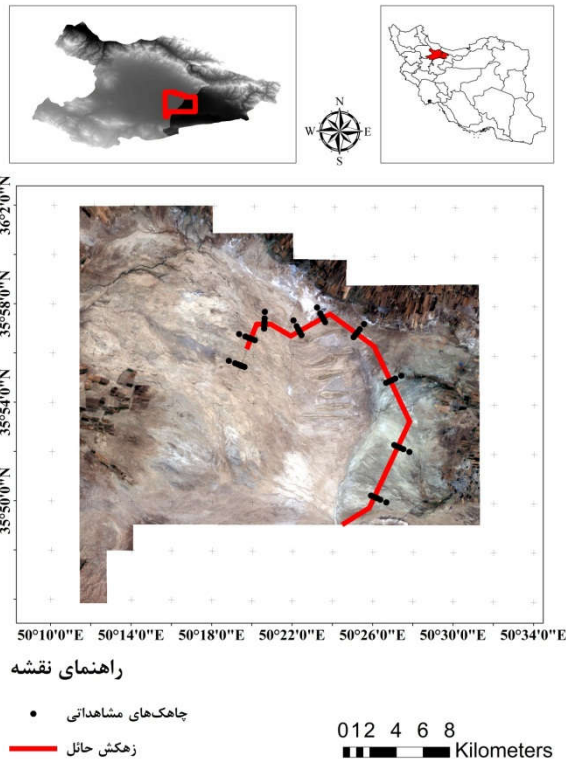
خاک را به نحو مطلوب‌تری پایش نموده است.

یکی از انواع مدل‌ها برای ارتباط بین داده‌های خاک و متغیرهای محیطی، شبکه‌های عصبی مصنوعی است. در رویکرد کاربرد شبکه‌های عصبی در مطالعات شوری خاک، می‌توان به تحقیقات انجام‌شده توسط خالقی و همکاران (۲۰۱۹) اشاره کرد. آن‌ها به پیش‌بینی شوری خاک با استفاده از روش رگرسیون چندمتغیره بر مبنای شاخص‌های استخراج‌شده از تصاویر ماهواره لندست پرداختند. نتایج تحقیق، مدلی به‌منظور پیش‌بینی شوری خاک در محدوده مطالعاتی با ضریب همبستگی  $0.70/3$  و خطای معیار برآورد  $0.10/0.3$  ارائه کرد. مورگان<sup>۹</sup> و همکاران (۲۰۱۸) از قابلیت‌های شبکه عصبی و تکنیک‌های سنجش از دور به منظور تهیه نقشه شوری خاک در منطقه‌ای واقع در کشور هندوستان استفاده کردند. آن‌ها از داده‌های وضوح بالای تصاویر ماهواره‌ای و شاخص‌های پوشش گیاهی به‌منظور پیش‌بینی نقشه شوری خاک بهره گرفتند. نتایج تحقیق نشان داد مدل مورد استفاده، شوری خاک را با ضریب تبیین  $R^2=0.94$  پیش‌بینی کرده است. هوا<sup>۱۰</sup> و همکاران (۲۰۱۹) در تحقیقی تغییرات شوری خاک در منطقه دلتایی رودخانه مکنونگ در ویتنام را با استفاده از قابلیت‌های تصاویر ماهواره‌ای و شبکه‌های عصبی مورد بررسی قرار دادند. برای این منظور ۶۳ نمونه خاک در محدوده مطالعاتی جمع‌آوری شد. نتایج خروجی پنج مدل شبکه عصبی بر اساس خطای میانگین مربعات و میانگین خطای مطلق (MAE) نشان داد مدل گوسین بالاترین دقت پیش‌بینی ( $RMSE=2/885$  و  $MAE=1/897$ ) را در بین مدل‌های مورد بررسی داشته است. نتایج تحقیق نشان داد مدل شبکه عصبی را می‌توان برای پایش شوری خاک استفاده کرد.


گسترش دامنه خاک‌های شور و تخریب اراضی کشاورزی و مراتع در بخش جنوب شرقی استان (شوره‌زار مرکزی) یکی از معضلات مهم دشت قزوین به شمار می‌رود؛ ازاین‌رو زهکشی اراضی منطقه یکی از راهکارهایی است که می‌تواند در مهار روند شور شدن اراضی و اصلاح خاک‌ها و مراتع آن مؤثر واقع شود. به همین دلیل و به‌منظور جلوگیری از پیشروی

1. Allbed
2. IKONOS
3. Salinity Index
4. Elharti
5. Whitney
6. Enhanced Vegetation Index
7. Normalized Difference Vegetation Index
8. Canopy Response Salinity Index

9. Morgan  
10. Hoa



شکل (۱): تصویر ماهواره‌ای از محدوده شورزار دشت قزوین  
Figure (1): Satellite image of the Qazvin plain



شکل (۲): موقعیت چاهک‌های مشاهداتی در حاشیه زهکش حائل دشت قزوین  
Figure (2): The position of the observed wells in the Interceptor Drain of Qazvin plain

داده‌ها، ابزارها و نرم‌افزارهای مورد استفاده

در تحقیق حاضر از داده‌های تراز آب زیرزمینی در ۹۹ چاهک مشاهداتی حاشیه زهکش حائل (طی سال‌های ۸۹ تا ۹۲) و ۹۵ داده شوری و ۹۹ داده SAR خاک در سال ۱۳۸۹ و ۱۳

منطقه شورزار در دشت قزوین، پروژه زهکشی شورزار از سال ۱۳۸۷ آغاز شده است. هدف تحقیق حاضر، پیش‌بینی شوری خاک محدوده زهکش حائل شورزار مرکزی دشت قزوین، با استفاده از قابلیت‌های سنجش از دور و شبکه عصبی مصنوعی است.

مواد و روش‌ها

موقعیت جغرافیایی محدوده مورد مطالعه

منطقه مورد مطالعه از نظر تقسیمات کشوری در بخشی از استان قزوین و در ۱۵۰ کیلومتری شمال غرب تهران قرار دارد که شامل حاشیه شورزار قزوین با محدوده جغرافیایی طول شرقی ۳۸۰۰۰۰ تا ۴۲۰۰۰۰ و عرض شمالی ۳۹۲۰۰۰۰ تا ۳۹۸۰۰۰۰ (برحسب UTM) است. ارتفاع این منطقه ۱۱۳۵ تا ۱۱۴۵ متر از سطح دریاست. شهرهای مهم مجاور منطقه در شمال غربی قزوین، تاکستان در غرب، آبیک در شمال شرقی و دانسفهان در جنوب غربی است. شورزار مرکزی دشت قزوین حدود ۶۵۰۰۰ هکتار وسعت دارد. وسعت هسته مرکزی حدود ۲۰۰۰۰ هکتار بوده و شوری این اراضی بسیار زیاد است. اندازه‌گیری‌ها نشان‌دهنده شوری ۲۸۰ دسی زیمنس بر متر (۷ تا ۸ برابر شوری خلیج فارس) است. حدود ۹۵٪ از اراضی این محدوده دارای هدایت الکتریکی بیش از ۲۰ دسی زیمنس بر متر و ۶۵٪ از اراضی، هدایت الکتریکی بیش از ۱۰۰ دسی زیمنس بر متر دارند (اکرم و ستوده‌نیا، ۲۰۱۴). در شکل (۱) موقعیت شورزار مرکزی دشت قزوین نشان داده شده است. طرح زهکشی شورزار مرکزی قزوین به طول ۴۵ کیلومتر و با ایجاد جاده‌های دسترسی با تعداد چندین سازه تقاطعی ساخته شده و ۹۹ حلقه چاهک مشاهده‌ای در ۹ راستا در مسیر طرح حفر شده، در حال حاضر شورابه موجود از زهکش احداثی تخلیه می‌شود. این چاهک‌ها در ۹ راستای عمود بر زهکش (A تا I) و ۱۱ چاهک در هر راستا قرار دارند. در بالادست هر مقطع، ۷ چاهک به فواصل ۱۰، ۲۵، ۵۰، ۱۰۰، ۲۵۰، ۵۰۰ و ۱۰۰۰ متر و در پایین دست ۴ چاهک به فواصل ۱۰، ۲۵، ۵۰ و ۲۵۰ متری از خط زهکش حفر شده است. در شکل (۲) موقعیت چاهک‌های مشاهداتی در حاشیه زهکش حائل دشت قزوین نشان داده شده است.

انتظار پیچیدگی های طیفی خاک نیز منطقی است. همین مسئله موجب شده بازتاب های طیفی مختلفی از شوره زارها حاصل شود. به همین دلیل روش و یا رابطه ریاضی مشخصی برای تهیه نقشه شوری خاک با استفاده از اطلاعات سنجنش از دور وجود ندارد. بر این اساس در این تحقیق از شاخص های مختلفی به منظور پایش شوری خاک در محدوده شوره زار استفاده شده است. از سوی دیگر به دلیل شرایط خاص منطقه که دارای پوشش گیاهی فقیر و گونه های گیاهی شورپسند بوده، از چند شاخص پوشش گیاهی جهت پایش استفاده شده است (بازتاب طیفی و تراکم پوشش گیاهی در محدوده مطالعاتی، با پوشش گیاهی اراضی زراعی و باغی بسیار متفاوت است). در جدول ۲ به شاخص های سنجنش از دور جهت پایش شوری خاک و پوشش گیاهی و در جدول ۳ به بازه زمانی تصاویر ماهواره ای مورد استفاده اشاره شده است.

داده شوری و ۱۳ داده SAR خاک در سال ۱۳۹۱ استفاده شد (اکرم و ستوده نیا، ۲۰۱۴). در جدول (۱) مقادیر کمینه، بیشینه و میانگین ویژگی های اندازه گیری شده خاک نشان داده شده است.

جدول (۱): مقادیر کمینه، بیشینه و میانگین ویژگی های اندازه گیری شده خاک

Table (1): Minimum, maximum and mean values of measured soil properties

مقادیر	سال ۱۳۸۹		سال ۱۳۹۱	
	SAR	EC (ds/m)	SAR	EC (ds/m)
کمینه	۱۵/۳	۱۸/۰	۲۷/۰	۲۱/۱
بیشینه	۱۳۲/۳	۱۷۲/۶	۹۳/۰	۹۸/۸
میانگین	۷۹/۸	۱۰۱/۱	۵۸/۰	۵۹/۴
ضریب تغییرات	۰/۲۹	۰/۳۳	۰/۳۳	۰/۴۵

### مراحل روش تحقیق

با توجه به آنکه خاک های خیلی شور و شوره زارها تنوع ریخت شناختی و شیمیایی زیادی دارند لذا به دلیل پیچیدگی های زیاد فیزیکی، شیمیایی و بیولوژیکی خاک،

جدول (۲): شاخص های شوری خاک و پوشش گیاهی مورد استفاده در تحقیق

Table (2): Soil salinity indices and vegetation used in the study

شاخص	تعریف شاخص	متغیر	منبع
شوری خاک	$NDSI = (B3 - B4) / (B3 + B4)$	Normalized Differential Salinity Index	خان و همکاران (۲۰۰۵)
	$BI = \sqrt{B_3^2 + B_4^2}$	Brightness Index	خان و همکاران (۲۰۰۵)
	$SI = \sqrt{B_1 \times B_3}$	Salinity Index	دهنی و لونس (۲۰۱۲)
	$SI_1 = \sqrt{B_2 \times B_3}$	Salinity Index	دهنی و لونس (۲۰۱۲)
	$SI_2 = \sqrt{B_2^2 + B_3^2 + B_4^2}$	Salinity Index	دهنی و لونس (۲۰۱۲)
	$SI_3 = \sqrt{B_2^2 + B_3^2}$	Salinity Index	دهنی و لونس (۲۰۱۲)
پوشش گیاهی	$NDVI = (B4 - B3) / (B4 + B3)$	Normalized difference vegetation index	رز و همکاران (۱۹۷۴)
	$LAI = -\frac{1}{0.91} \ln \frac{0.69 - SAVI}{0.59}$	Leaf Area Index	خان و همکاران (۲۰۰۵)
	$EVI = ((2.5) \times ((B5 - B4) / (B5 + 6 \times B4 - 7.5 + B2 + 1)))$	Enhanced Vegetation Index	هیوت و همکاران (۲۰۰۲)
	$SAVI = (1 + L) \frac{\alpha_2 - \alpha_1}{L + \alpha_1 + \alpha_2}$	Soil Adjusted Vegetation Index	هیوت (۱۹۹۸)
	$GVI = 0.1603B_1 - 0.2819B_2 - 0.4934B_3 - 0.7940B_4 - 0.0002B_5 - 0.1446B_7$	Green Vegetation Index	کردون و همکاران (۲۰۱۲)

$B_1$  تا  $B_7$  به ترتیب باندهای ۱ تا ۷ تصاویر ماهواره لندست ۷،  $\alpha_1$  و  $\alpha_2$  به ترتیب قابلیت بازتاب در باند مرئی و فرورسرخ نزدیک و  $L$  فاکتور تنظیم بدون بعد است.

جدول (۳): تاریخ زمانی تصاویر ماهواره‌ای مورد استفاده در تحقیق

Table (3): Time Date of Satellite Images Used in Research

ردیف	بهار	تابستان	پاییز	زمستان
۱	-	-	-	۱۳۸۲/۱۲/۸
۲	۱۳۸۳/۰۱/۲۷	۱۳۸۳/۰۵/۱۵	۱۳۸۳/۰۹/۰۵	۱۳۸۳/۱۱/۰۹
۳	۱۳۸۴/۰۲/۳۰	۱۳۸۴/۰۶/۰۲	۱۳۸۴/۰۹/۰۷	۱۳۸۴/۱۱/۲۷
۴	-	۱۳۸۵/۰۴/۰۳ و ۱۳۸۵/۰۵/۲۰	۱۳۸۵/۰۹/۱۰	۱۳۸۵/۱۰/۲۸
۵	۱۳۸۶/۰۳/۲۱	۱۳۸۶/۰۵/۲۳	۱۳۸۶/۰۸/۱۱	۱۳۸۶/۱۲/۰۳
۶	۱۳۸۷/۰۲/۲۳	۱۳۸۷/۰۵/۲۶	۱۳۸۷/۰۷/۲۸	۱۳۸۷/۱۰/۱۸
۷	۱۳۸۸/۰۲/۲۵	۱۳۸۸/۰۵/۱۲	۱۳۸۸/۰۸/۱۶	۱۳۸۸/۱۱/۲۲
۸	۱۳۸۹/۰۲/۲۸	۱۳۸۹/۰۴/۳۰	۱۳۸۹/۰۸/۱۹	۱۳۸۹/۱۲/۲۷
۹	۱۳۹۰/۰۲/۱۵	۱۳۹۰/۰۶/۱۹	۱۳۹۰/۰۷/۲۰	۱۳۹۰/۱۰/۲۶
۱۰	۱۳۹۱/۰۲/۰۲	۱۳۹۱/۰۶/۰۶	۱۳۹۱/۰۸/۲۵	۱۳۹۱/۱۲/۰۱
۱۱	۱۳۹۲/۰۳/۰۵	۱۳۹۲/۰۶/۲۴ و ۱۳۹۲/۰۵/۱۵	۱۳۹۲/۰۷/۲۵	۱۳۹۲/۱۲/۰۳
۱۲	۱۳۹۳/۰۳/۲۴	۱۳۹۳/۰۵/۱۰ و ۱۳۹۳/۰۵/۱۸	۱۳۹۳/۰۸/۳۰	۱۳۹۳/۱۱/۰۴
۱۳	۱۳۹۴/۰۲/۱۰	۱۳۹۴/۰۵/۲۹ و ۱۳۹۴/۰۵/۲۱	۱۳۹۴/۰۹/۰۳	۱۳۹۴/۱۰/۲۱
۱۴	۱۳۹۵/۰۳/۱۴	۱۳۹۵/۰۶/۰۱	۱۳۹۵/۰۸/۲۰	-
۱۵	۱۳۹۶/۰۳/۱۶	۱۳۹۶/۰۵/۱۸	۱۳۹۶/۰۸/۲۲	۱۳۹۶/۱۰/۲۶
۱۶	۱۳۹۷/۰۳/۱۹	۱۳۹۷/۰۶/۰۶	۱۳۹۷/۰۸/۰۹	-

### اخذ تصاویر ماهواره‌ای

مقدار ارزش رقومی ( $DN^1$ ) به رادیانس تبدیل گردد. سپس به‌منظور انجام تصحیحات اتمسفریک دستور FLAASH در نرم‌افزار ENVI اجرا شد. این الگوریتم از معادله استاندارد که برای محدوده‌های طول موج خورشیدی در سطوح لامبرتی در نظر گرفته شده، برای تابش طیفی در سنجنده استفاده می‌کند. این مدل بیشتر بر روی تصاویر چندطیفی و فراطیفی کار می‌کند و می‌تواند تصویر را هم در هندسه قائم و هم در هندسه دید مایل از لحاظ تأثیرات اتمسفری تصحیح کند.

در این تحقیق تصاویر ماهواره لندست ۷ مربوط به سنجنده  $ETM^+$  در طی سال‌های ۲۰۰۴ تا ۲۰۱۸ میلادی از مسیر ۱۶۵ و ردیف ۳۵ از سایت (EarthExplore.Usgs.gov) اخذ شده است.

### پیش‌پردازش داده‌های ماهواره‌ای

از آنجایی که تصاویر مربوط به زمان‌های مختلف هستند و با زاویه ارتفاعی و با تصحیحات و طرق تهیه مختلف‌اند، نیاز است تصحیحات رادیومتریک و اتمسفری بر روی تصاویر صورت گیرد و پس از آن با اعمال روابط ریاضی شاخص‌های مورد نظر استخراج شود. لذا به‌منظور پردازش و پیش‌پردازش تصاویر ماهواره‌ای و استخراج شاخص‌های مورد نظر از نرم‌افزار ENVI 5.3 و Arc GIS 10 استفاده شد. برای انجام تصحیحات رادیومتریک دستور Radiometric Calibration اجرا شد تا

### پردازش سری‌های زمانی

به‌منظور بررسی روند سری‌های زمانی مورد مطالعه (شاخص‌های شوری و پوشش گیاهی مستخرج از تصاویر ماهواره‌ای) از آزمون من-کندال استفاده شده است. آزمون من-کندال، آزمونی ناپارامتریک رتبه‌منا به‌منظور تعیین معنی‌داری روندهای خطی و غیرخطی می‌باشد که توسط من

1. Digital Number

و کندال<sup>۱</sup> ارائه شده است در این آزمون فرض صفر (H0) و فرض مقابل (H1)، به ترتیب معادل بدون روند و وجود روند در سری زمانی داده‌های مشاهده‌ای است. روابط مرتبط برای تعیین مقادیر آماره آزمون من-کندال به صورت رابطه (۱) است.

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sgn}(x_j - x_i) \quad (1)$$

$$\text{sgn}(x_j - x_i) = \begin{cases} +1 & (x_j - x_i) > 0 \\ 0 & (x_j - x_i) = 0 \\ -1 & (x_j - x_i) < 0 \end{cases}$$

که در روابط فوق، n تعداد داده مشاهده‌ای (طول دوره آماری) و  $X_i$  و  $X_j$  به ترتیب i امین و j امین داده مشاهده‌ای است. بر اساس این آزمون در صورتی که مقدار S اختلاف معنی‌داری با صفر نداشته باشد، روند وجود ندارد و در غیر این صورت روند، صعودی یا نزولی خواهد بود. برای آزمون معنی‌دار بودن روند، از متغیر Z نرمال استاندارد طبق رابطه (۲) استفاده شده است (کندال، ۱۹۷۵؛ من، ۱۹۴۵).

$$Z_M = \begin{cases} \frac{S-1}{\sqrt{\text{VAR}(S)}} & S > 0 \\ 0 & S = 0 \\ \frac{S+1}{\sqrt{\text{VAR}(S)}} & S < 0 \end{cases} \quad (2)$$

که واریانس داده‌ها بر اساس رابطه (۳) محاسبه شده است.

$$\text{var}(s) = \frac{1}{18} \left[ n(n-1)(2n+5) - \sum_{p=1}^q t_p(t_p-1)(2t_p+5) \right] \quad (3)$$

که در روابط فوق، q تعداد گروه‌های ایجاد شده (با داده‌های برابر و بیشتر از دو عضو) و  $t_p$  تعداد داده‌های برابر در p امین گروه و  $Z_M$  مقدار آماره من-کندال است. مقدار منفی  $Z_M$  بیانگر روند کاهش و مقدار مثبت آن نشان دهنده روند افزایشی در سری داده‌هاست.

### پیش‌بینی شوری خاک با استفاده از شبکه عصبی

شبکه‌های عصبی مدل‌های ریاضی انعطاف‌پذیری هستند که بر اساس ساختار و رفتار شبکه‌های عصبی طبیعی ساخته شده‌اند. شبکه‌های عصبی از مجموع چندین نرون ریاضی تشکیل شده‌اند. هر نرون ریاضی دارای شمای یک نرون

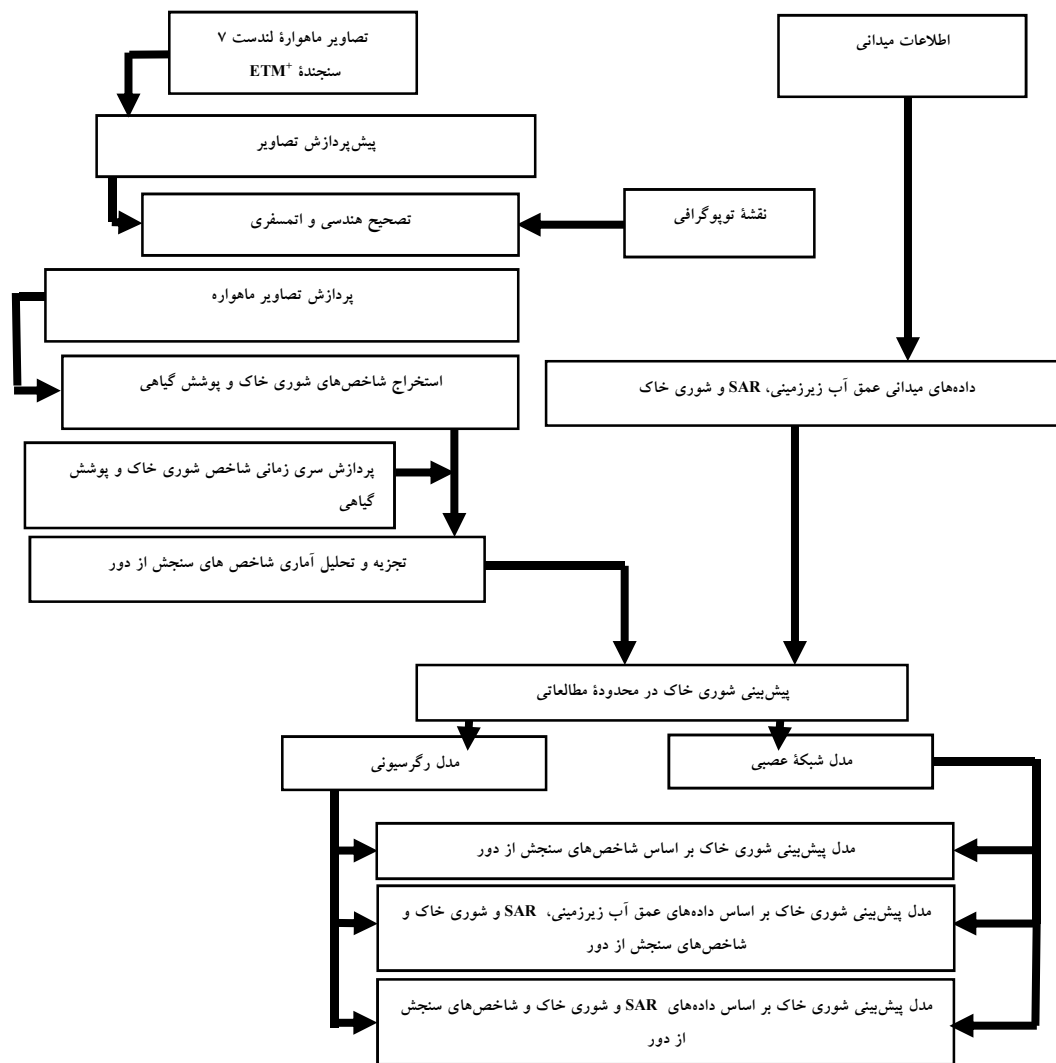
واقعی است. یکی از شبکه‌های عصبی نظارت‌شده و پرکاربرد در مدیریت منابع طبیعی، شبکه عصبی پیش‌خور با الگوریتم پس‌انتشار خطا<sup>۲</sup> (شبکه چندلایه پرسپترون) است که برای محدوده گسترده‌ای از کاربردها از قبیل شناسایی الگو، درون‌یابی، پیش‌بینی و مدل‌سازی فرایند مناسب است (روملهارت<sup>۳</sup> و همکاران، ۱۹۸۶). در این بررسی، ۷۰٪ از داده‌ها به عنوان داده آموزش و ۳۰٪ از داده‌ها به عنوان داده آزمون وارد شبکه شدند. برای ارزیابی دقت مدل‌سازی، از شاخص مجموع مربعات خطا و خطای آزمون استفاده شده است.

به منظور بهره‌گیری از قابلیت‌های شبکه عصبی و با توجه به نوع داده‌های پیش‌شده در محدوده طرح، فرایند پیش‌بینی شوری خاک در ۳ حالت انجام شده است. در حالت اول مدل پیش‌بینی شوری خاک صرفاً بر مبنای شاخص‌های شوری و پوشش گیاهی پیش‌شده در محدوده شورزار انجام گرفت؛ دلیل این امر آن است که داده‌های زمین مرجع صرفاً در چند سال محدود در منطقه ثبت شده بود، لیکن با توجه به قابلیت‌های سنجش از دور می‌توان روند تغییرات شوری خاک را در بازه زمانی وسیعی انجام داد. در حالت دوم با توجه به ثبت داده‌های زمین مرجع (تراز آب زیرزمینی و شاخص‌های SAR و EC) در محدوده زهکش، پیش‌بینی شوری خاک انجام گرفت. در حالت سوم با توجه به بازه زمانی ثبت داده‌های تراز آب زیرزمینی در چاهک‌های مشاهداتی، فرایند مدل‌سازی شوری خاک با حذف داده‌های تراز آب زیرزمینی انجام گرفت. دلیل این امر قابلیت کاربرد مدل در صورت عدم یادداشت برداری تراز آب زیرزمینی بوده است (در حال حاضر به دلیل از بین رفتن بخش عمده‌ای از چاهک‌های مشاهداتی و هزینه‌بر بودن تعمیرات چاهک‌ها، عملاً اندازه‌گیری تراز آب زیرزمینی در منطقه میسر نیست). در شکل (۳) روند نمای مراحل انجام مطالعه و در جدول (۴) ساختار شبکه عصبی مورد استفاده نشان داده شده است. بر این اساس مدل شبکه عصبی مورد استفاده در شکل (۴) اشاره شده است. در این شکل ورودی مدل متغیرهای  $\bar{x}_i$  بوده که در اینجا I شمارنده

2. Multi Layers Perceptron  
3. Rumelhart

1. Mann & Kendall

متغیر بین  $1 \leq n \leq 1$  است.



شکل (۳): روندنمای مراحل انجام مطالعه  
Figure (3): Flowchart Study Steps

جدول (۴): جدول توصیفی داده‌های ورودی و خروجی مدل شبکه عصبی و مدل رگرسیون  
Table (4): Descriptive table of input and output data of neural network model and regression model

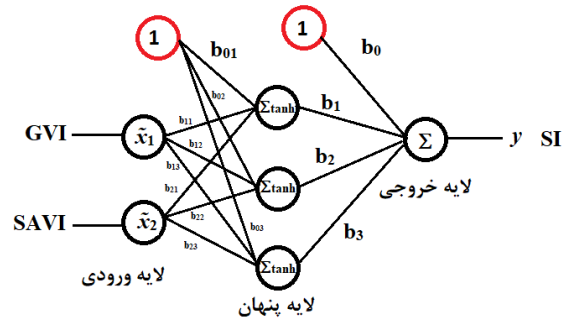
مدل رگرسیون	معماری شبکه عصبی		متغیر خروجی	متغیرهای ورودی به همراه محدوده تغییرات
	تابع انتقال - الگوریتم آموزش	(خروجی، لایه مخفی، لایه ورودی)		
مکعبی	تانژانت زیگموئید-ممتوم	۲-۳-۱	SI	*GVI و SAVI
خطی	تانژانت زیگموئید-ممتوم	۱۱-۳-۱	SAR EC	BI (0.39~0.51), EVI (0~0.08) GVI (-0.09~0.05), LAI (0~0.18), NDSI (-0.08~0), NDVI (0~0.08), SI (0.22~0.28), SI1 (0.24~0.31), SI2 (0.44~0.58), SI3 (0.34~0.45), GW (1.15~3.55)
خطی	تانژانت زیگموئید-ممتوم	۱۰-۳-۱	SAR EC	BI (0.39~0.51), EVI (0~0.08) GVI (-0.09~0.05), LAI (0~0.18), NDS (-0.08~0), NDV (0~0.08), SI (0.22~0.28), SI1 (0.24~0.31), SI2 (0.44~0.58), SI3 (0.34~0.45)

\* شاخص‌های GVI و SAVI قبل از برازش مدل نرمال شده و در بازه ۰ تا ۱ قرار گرفته‌اند.

جدول (۵): همبستگی شاخص شوری خاک و درصد پوشش گیاهی مستخرج از تصاویر ماهواره‌ای

Table (5): Correlation of Soil Salinity Index and Vegetation Percentage Derived from Satellite Images

شاخص	SI3	SI2	SI1	SI	BI
EVI	۰/۱۵	۰/۲۱	۰/۱۶	۰/۱۶	۰/۲۱
GVI	-۰/۸۰	-۰/۷۶	-۰/۸۰	-۰/۸۳	-۰/۷۵
LAI	۰/۱۲	۰/۱۷	۰/۱۲	۰/۱۲	۰/۱۸
NDSI	۰/۲۲	۰/۱۶	۰/۲۲	۰/۲۳	۰/۱۵
NDVI	-۰/۲۲	-۰/۱۶	-۰/۲۲	-۰/۲۳	-۰/۱۵
SAVI	۰/۲۶	۰/۳۲	۰/۲۷	۰/۲۵	۰/۳۳




شکل (۴): مدل شبکه عصبی مورد استفاده جهت پیش‌بینی شوری خاک  
Figure (4): Neural network model used to predict soil salinity

### نتایج

در شکل (۵) نمونه خروجی شاخص شوری خاک SI نشان داده شده است. نتایج مربوط به مقایسه ضریب همبستگی میانگین شوری خاک و درصد پوشش گیاهی مستخرج از تصاویر ماهواره‌ای در جدول (۵) اشاره شده است. نتایج تحلیل همبستگی میانگین داده‌های زمانی نشان داد شاخص GVI دارای همبستگی منفی بالایی با همه شاخص‌های شوری است ولی بین شاخص‌های شوری و پوشش گیاهی دیگر همبستگی کمتری وجود داشته است (با توجه به رابطه معکوس شوری خاک و درصد پوشش گیاهی، شاخص GVI نمایانگر بهتری از وضعیت پایش پوشش گیاهی در منطقه شورزار بوده است).


بر این اساس در شکل (۶) مدل رگرسیون مکعبی همبستگی شاخص‌های SI و GVI نشان داده شده است. نتایج پیش‌بینی مدل‌های رگرسیونی و شبکه عصبی، در شکل (۷) نشان داده شده است. در این شکل، خط تطابق کامل و خطوط خطای  $\pm 20\%$  درصد نیز ترسیم شده‌اند. همچنین مقادیر خطای مجذور میانگین مربعات خطا (RMSE) برای مجموعه‌های آموزش و آزمون نیز محاسبه شده است. نتایج خروجی بیانگر آن است که در هر دو حالت مدل‌سازی، خطای آموزش کمتر از خطای آزمون بوده و خطای مدل شبکه عصبی  $60\%$  کمتر از مدل رگرسیون مکعبی بوده است.

بررسی روند تغییرات سری زمانی شاخص‌ها با استفاده از آزمون من-کندال در محیط نرم‌افزاری R نشان داد، ضریب همبستگی متناظر  $\tau = -0/63$  و مقدار  $p \text{ value} = 2 \times 10^{-12}$  بوده که نشانگر وجود روند به صورت معنی‌دار است. در شکل (۸) سری زمانی متغیرهای بی‌بعد شده GVI- و SI و مقادیر پیش‌بینی شده SI نشان داده شده است (علت اینکه GVI- در نمودار ترسیم شده، آن است که تغییرات آن همزمان با SI قابل مشاهده باشد).

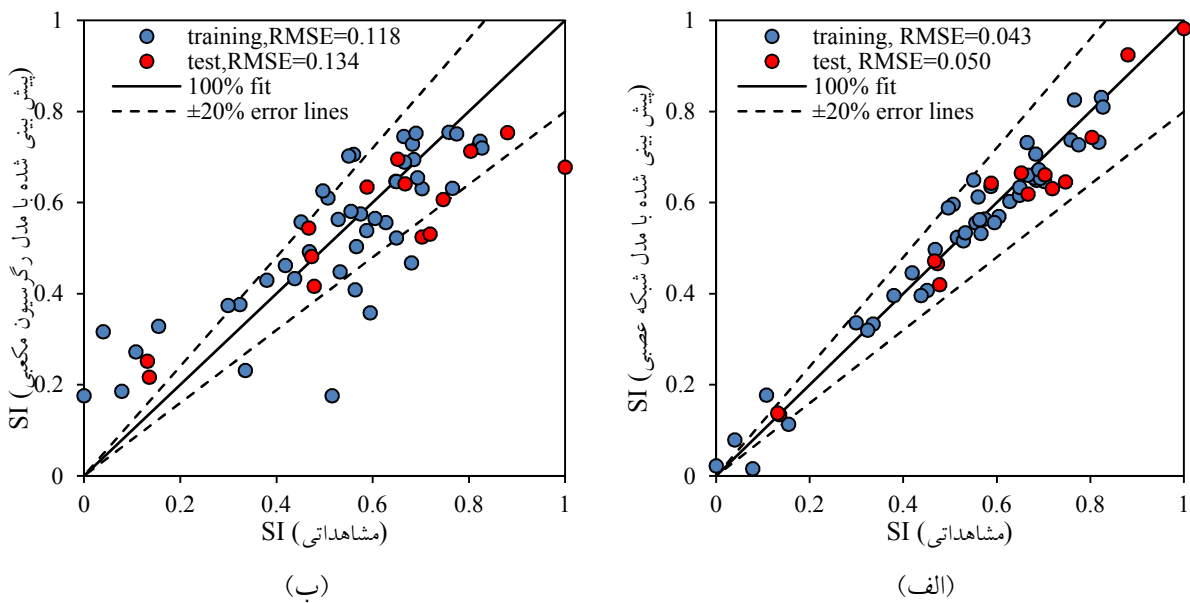


شکل (۵): نقشه تغییرات شاخص SI در محدوده زهکش حائل در تاریخ ۱۳۹۲/۰۵/۱۵  
Figure (5): Map of SI Index Changes in the Drainage Area at 2013/08/06






شکل (۶): مدل رگرسیونی همبستگی شاخص‌های SI و GVI  
Figure (6): Correlation regression model of SI and GVI indices



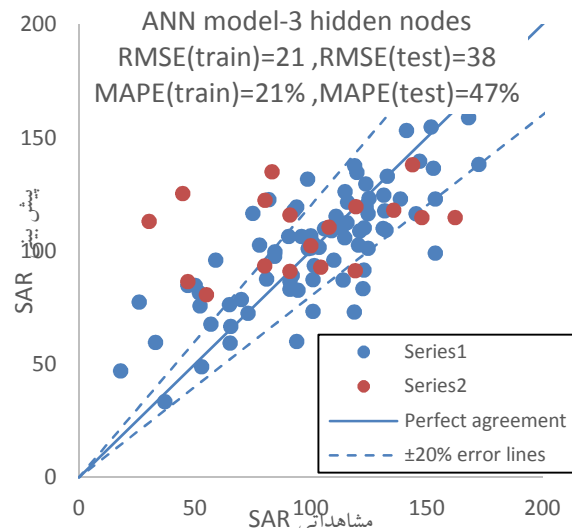
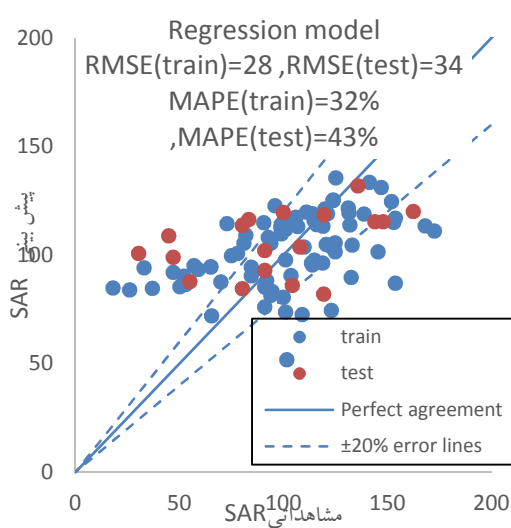
شکل (۷): (الف) و (ب) به ترتیب پیش‌بینی شاخص شوری خاک بر اساس مدل شبکه عصبی و رگرسیون مکعبی (حالت ۱)  
Figure (7): (a) and (b) respectively, prediction of soil salinity index based on neural network model and cubic regression (mode 1)



شکل (۸): روند تغییرات سری زمانی شاخص‌ها در مدل رگرسیونی و شبکه عصبی  
Figure (8): Trend of time series changes indices in regression model and neural network

رگرسیون نشان داد. در حالت سوم مدل سازی، پیش بینی شوری خاک بدون در نظر گرفتن مقادیر تراز آب زیرزمینی انجام شد (شکل های ۱۱ و ۱۲). نتایج پیش بینی در حالت سوم مدل سازی نشان داد دقت شبکه عصبی تنها در حالت آموزش بهتر بوده و در حالت آزمون تفاوتی حاصل نشده است.

در شکل (۹) مدل رگرسیون و شبکه عصبی برای پیش بینی SAR خاک در حالت دوم مدل سازی نشان داده است. طبق نتایج، مدل شبکه عصبی دقت بیشتری از نظر خطای آموزش نسبت به مدل رگرسیون داشته، ولی خطای آزمون آن بیشتر از مدل رگرسیونی بوده است. نتایج پیش بینی شوری خاک (EC) در شکل (۱۰) نشان داده شده است. در این حالت نیز مدل شبکه عصبی، دقت بیشتری نسبت به مدل


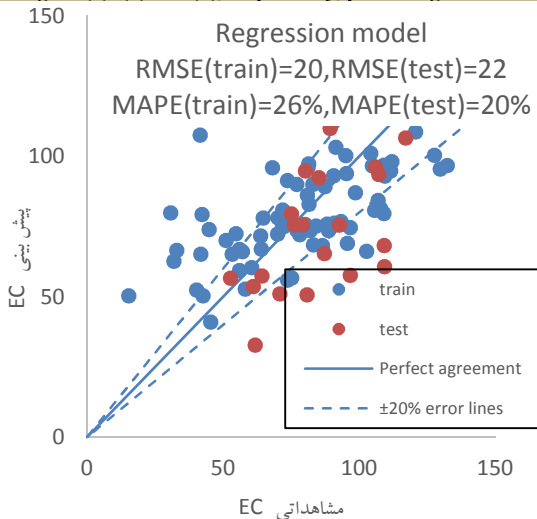


(ب)

(الف)

شکل (۹): (الف) و (ب) به ترتیب پیش بینی شاخص SAR خاک بر اساس مدل شبکه عصبی و رگرسیون مکعبی (حالت ۲)

Figure (9): (a) and (b), respectively, predicting soil SAR index based on neural network model and cubic regression (mode 2)

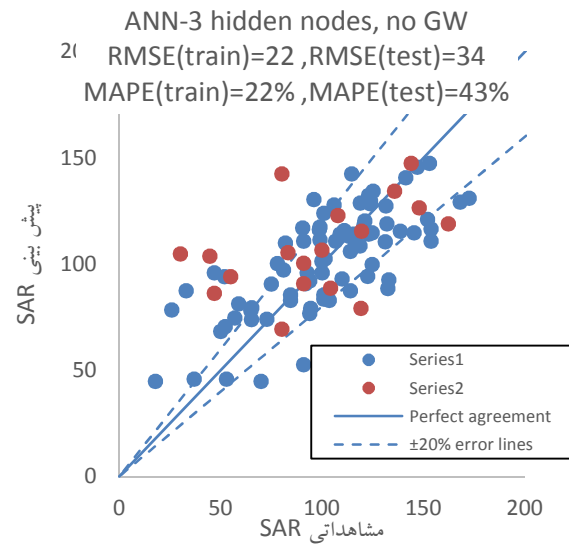



(ب)

(الف)

شکل (۱۰): (الف) و (ب) به ترتیب پیش بینی شاخص شوری خاک بر اساس مدل شبکه عصبی و رگرسیون مکعبی (حالت ۲)

Figure (10): (a) and (b), respectively, predicting soil salinity index based on neural network model and cubic regression (mode 2)


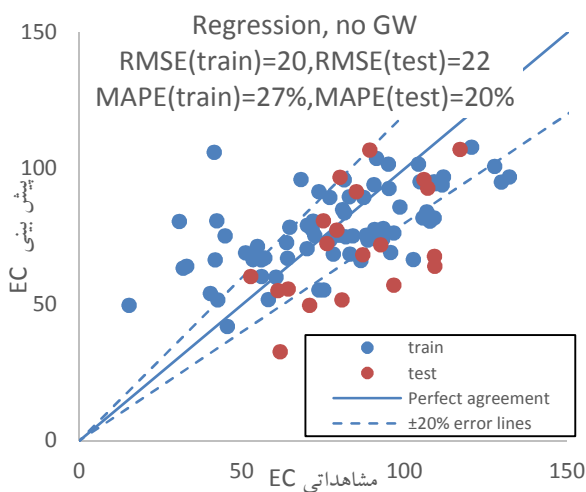


(الف) (ب)

شکل (۱۱): (الف) و (ب) به ترتیب پیش‌بینی شاخص SAR خاک بر اساس مدل شبکه عصبی و رگرسیون مکعبی (حالت ۳)  
 Figure (11): (a) and (b) respectively, prediction of soil SAR index based on neural network model and cubic regression (mode 3)

و (۱۴) نتایج پیش‌بینی شاخص‌های EC و SAR خاک بر اساس داده‌های ورودی مدل شبکه عصبی نشان داده شده است.

به‌طور کلی نتایج مدل‌سازی نشان داد با حذف داده‌های تراز آب زیرزمینی، در اکثر موارد دقت پیش‌بینی مدل کاهش یافته است. در جدول (۶) نتایج ارزیابی مدل‌ها بر اساس ضریب تبیین ( $R^2$ ) نشان داده شده است. در شکل‌های (۱۳)




(الف) (ب)

شکل (۱۲): (الف) و (ب) به ترتیب پیش‌بینی شاخص شوری خاک بر اساس مدل شبکه عصبی و رگرسیون مکعبی (حالت ۳)  
 Figure (12): (a) and (b) respectively, prediction of soil salinity index based on neural network model and cubic regression (mode 3)

جدول (۶): مقایسه ضریب تبیین مدل‌های پیش‌بینی شوری خاک


Table (6): Comparison of correlation coefficients of Soil Salinity Prediction Models

ضریب تبیین	نوع مدل - ورودی مدل
۰/۶۹	شبکه عصبی - شاخص‌های سنجش از دور و داده‌های زمینی
۰/۳۲	رگرسیون - شاخص‌های سنجش از دور و داده‌های زمینی
۰/۵۴	شبکه عصبی - شاخص‌های سنجش از دور و داده‌های زمینی بدون داده تراز آب زیرزمینی
۰/۳۱	رگرسیون - شاخص‌های سنجش از دور و داده‌های زمینی بدون داده تراز آب زیرزمینی



شکل (۱۳): (الف) و (ب) به ترتیب پیش‌بینی شوری خاک در محل چاهک‌های مشاهداتی بدون داده تراز آب زیرزمینی و با داده تراز آب زیرزمینی (مدل شبکه عصبی)

Figure (13): (a) and (b), respectively, predict soil salinity at observation wells without groundwater level data and with groundwater level data (neural network model)



شکل (۱۴): (الف) و (ب) به ترتیب پیش‌بینی SAR خاک در محل چاهک‌های مشاهداتی بدون داده تراز آب زیرزمینی و با داده تراز آب زیرزمینی (مدل شبکه عصبی)

Figure (14): (a) and (b) respectively, predict soil SAR index at observation wells without groundwater level data and with groundwater level data (neural network model)

شوره‌زار مرکزی دشت قزوین با استفاده از مدل شبکه عصبی و مدل رگرسیون، شبیه‌سازی و پیش‌بینی شد. برای نیل به این

بحث و نتیجه‌گیری در این تحقیق، شوری خاک در محدوده زهکش حائل

دانست؛ به‌نحوی که بر اساس نظریات اسکاپ و همکاران (۱۹۹۸)، در طراحی شبکه‌های عصبی نوع خاصی از معادلات لازم نیست و با ایجاد رابطه مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسبی دست یافت. نکته حائز اهمیت آن است که مدل‌های شبکه عصبی با هر ساختاری، نتایج قابل قبولی نخواهد داشت و ارائه نتایج کاربردی نیازمند دقت در انتخاب عوامل ورودی به مدل، انجام تکرارهای زیاد در فرایند آموزش و انتخاب عوامل مناسب تشکیل‌دهنده شبکه است. به‌طور کلی نتایج مدل‌سازی نشان داد با حذف داده‌های تراز آب زیرزمینی، در اکثر موارد دقت پیش‌بینی مدل کاهش یافته است. نتایج پیش‌بینی شوری خاک در محل چاهک‌های مشاهداتی نشان داد در مقاطع C، D و E شوری خاک بالاتر از سایر مقاطع بوده است. همچنین نتایج پیش‌بینی‌ها در حالت‌های سه‌گانه مورد بررسی نشان داد مدل شبکه عصبی و مدل رگرسیون خطی با دقت بیشتری، EC خاک را نسبت به SAR خاک برآورد کرده‌اند. به‌طور کلی استفاده از قابلیت‌های مدل شبکه عصبی و یا مدل رگرسیون به همراه اندازه‌گیری‌های هدفمند و محدود میدانی، می‌تواند به کاهش هزینه‌های اجرایی طرح‌های پایش، به‌خصوص در مناطق شورزار و بیابانی منجر شود.

مقصود، از داده‌های زمین مرجع و شاخص‌های مستخرج از تصاویر ماهواره استفاده و مدل پیش‌بینی شوری خاک ارائه شد. نتایج تحلیل همبستگی میانگین داده‌های زمانی نشان داد شاخص GVI دارای همبستگی منفی بالایی با همه شاخص‌های شوری داشته است؛ به‌عبارتی شاخص پوشش گیاهی GVI به‌منظور پایش روند تغییرات پوشش گیاهی منطقه شورزار توصیه می‌شود. شاخص مذکور بر اساس یک رابطه رگرسیون چندجمله‌ای مرتبه ۳ و با ضریب تبیین ۰/۷۹ با شاخص شوری خاک (SI) در محدوده شورزار مرکزی دشت قزوین همبستگی داشته و روند تغییرات سری زمانی دو شاخص در یک بازه زمانی ۱۵ ساله، بر اساس آزمون من-کندال، معنی‌دار بوده است؛ به‌عبارتی با توجه به مفهوم آزمون من-کندال، افزایش میزان شوری خاک تأثیر مستقیمی بر زوال پوشش گیاهی در منطقه داشته است.

در فرایند مدل‌سازی و پیش‌بینی شوری خاک، نتایج تحقیق نشان داد مدل‌های شبکه عصبی به‌خوبی قادرند شوری خاک را با دقتی قابل قبول و عوامل مورد نیاز کمتری در مقایسه با مدل رایانه‌ای شبیه‌سازی کنند. علت این امر را می‌توان به دو عامل تکرارهای زیاد در فرایند مدل‌سازی شبکه عصبی و پیچیدگی بالاتر شبکه عصبی نسبت به مدل رگرسیون مرتبط

## منابع

1. Akram, M. and Sotoodehnia, A., 2014. Monitoring plan of interceptor drain in Qazvin. Company Reports, Kamab Pars & Saman Abran, Ministry of Jihad Agricultural.
2. Allbed, A., kumar, L. and Sinha, P., 2014. Mapping and modelling spatial variation in soil salinity in the Al Hasa oasis based one remote sensing indication and regression techniques. *Remote Sens* 6, 1137-1157.
3. Cruden, B. A., Prabhu, D. and Martinez, R., 2012. Absolute radiation measurement in Venus and mars entry conditions, *Journal of Spacecraft and Rockets* 49(6), 1069-1079.
4. Dehni, A. and Lounis, M., 2012. Remote sensing techniques for salt affected soil mapping: application to the Oran region of Algeria. *Procedia Eng* 33, 188-198.
5. Elharti, A., Lhissou, R., Chokmani, K., Ouzemou, J., Hassouna, M., Bachaoui, E. and Ghmari, A., 2016. Spatiotemporal monitoring of soil salinization in irrigated Tadla plain (Morocco) using satellite spectral indices, *International journal of applied earth Observation and geoinformation* 50, 64-73.
6. Hoa, P.V., Giang, N.V., Binh, N.A., Hai, L.V.H., Pham, T.D., Hasanlou, M. and Tien Bui, D., 2019. Soil Salinity Mapping Using SAR Sentinel-1 Data and Advanced Machine Learning Algorithms: A Case Study at Ben Tre Province of the Mekong River Delta (Vietnam). *Remote Sens* 11(2), 1-20.

7. Huete, A., 1988. A soil-adjusted vegetation index (SAVI). *Remote Sens Environ* 25, 295-309.
8. Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X. and Ferreira, L.G., 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices, *Remote Sensing of Environment* 83(1-2), 195-213.
9. Kendall, M., 1975. *Rank Correlation Methods*, Griffin, London.
10. Khaleghi, R., Behmanesh, J. and Azad, N., 2019. Prediction of soil salinity using multivariable regression on the basis of extracted indices from Landsat 8 satellite (Case study: Urmia). *Applied Soil Research* 7(1), 108-121.
11. Khan, N.M., Rastoskuev, V.V., Sato, Y. and Shiozawa, S., 2005. Assessment of hydro saline land degradation by using a simple approach of remote sensing indicators. *Agric. Water Manage* 77, 96-109.
12. Mann, H.B., 1945. Nonparametric tests against trend. *Econometrical* 13, 245-259.
13. Morgan, R.S., El Hady, M.A. and Rahim, I.S., 2018. Soil salinity mapping utilizing sentinel-2 and neural networks. *Indian Journal of Agricultural Research* 52 (5), 524-529.
14. Pishnamaz Ahmadi, M., Rezaei Moghadam, M. and Feizizadeh, B., 2017. Study indexes and mapping of soil salinity using remote sensing data (Case study: Aji Chay river delta). *Journal of RS and GIS for Natural Resources* 8(1), 85-96.
15. Rouse, J.r.J., Haas, R.H., Schell, J.A. and Deering, D.W., 1974. *Monitoring vegetation systems in the Great Plains with ERTS*. NASA special publication.
16. Rumelhart, D.E., Hinton G.E. and Williams R.J., 1986. Learning internal representation by back-propagation errors. In: Rumelhart DE, McClelland JL, the PDP Research Group (Eds.), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. MIT Press, MA.
17. Schap, M.G., Leij, F.J. and Van Genuchten, M.T., 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Journal of Soil Science Society of America* 62, 847-855.
18. Whitney, K., Scudiero, E., El-Askary, H., Skaggs, T.H., Allali, M. and Corwin, D.L., 2018. Validating the use of MODIS time series for salinity assessment over agricultural soils in California, USA. *Ecological indicators* 93, 889-898.

## Prediction of Soil Salinity Using Neural Network and Multivariate Regression Based on Remote Sensing Indices and Comparison: A Case Study of Qazvin plain's Salt Marsh

Afshin Uossef Gomrokchi<sup>1\*</sup>, Alireza Hassanoghli<sup>2</sup>, Mehdi Akbari<sup>3</sup>, Mehrzad Mostashari Mohasses<sup>4</sup>, Danial Amini<sup>5</sup>

Received: 16/11/2019

Accepted: 15/06/2020

### Expanded abstracts

**Introduction:** The spatial and temporal distribution of salts in the soil, the great extent of the Iranian deserts, and the adverse climatic conditions prevailing over them make it difficult to accurately determine the parameters and field measurements in some cases. In the last two decades, the use of field techniques and their combination with remote sensing data has contributed significantly to preparing baseline maps on saline soils. Accordingly, recent advances in the application of remote sensing technology in salt-affected mapping and management have also reduced the costs of large-scale land monitoring. Many researchers worldwide have been preparing soil salinity maps using satellite imagery, aerial photographs, terrestrial and radiometric techniques based on correlations between salt reflection and soil salinity indices. One of the significant problems in Qazvin Plain is the drainage of the area, which may affect the control of the process of salinization and improvement of its soils and rangelands. Thus, to prevent the progress of the salt area in Qazvin plain, the drainage project had started in 2008. The aim of this study, therefore, was to predict soil salinity in the central drainage basin of Qazvin plain using remote sensing capabilities and an artificial neural network.

**Materials and methods:** The study area was part of Qazvin province 150 km northwest of Tehran that included the saline margin of Qazvin with a longitude of 380000 to 420000 and north latitude of 3920000 to 3980000 (according to UTM). The height of the area was 1135 to 1145 meters above sea level. The major cities adjacent to the area were northwest of Qazvin, vineyards in the west, Abyek in the north, and Dansfahan in the southwest. The central salinity area of the Qazvin plain was about 65,000 hectares. The core area was about 20,000 hectares, and the salinity of these lands was very high. The measurements showed a salinity of 280 dS/m (7 to 8 times the Persian Gulf salinity). About 95% of the lands in this area had an electrical conductivity of more than 20 dS/m, and 65% of the lands had an electrical conductivity of more than 100 dS/m. As for the purposes of this study, soil salinity and vegetation status of the study area were analyzed using satellite imagery and remote sensing indices. Mann-Kendall test was also used to study the time series trends (salinity and vegetation indices derived from satellite images). In order to take advantage of the neural network capabilities and based on the type of data monitored in the design area, the soil salinity prediction process was performed in three cases. In the

1. Assistant Professor, Agricultural Engineering Research Department, Qazvin Agricultural and Natural Resources Research and Education Center, AREEO, Qazvin, Iran; a.gomrokchi@areeo.ac.ir

2. Associate Professor, Agricultural Engineering Research Institute; Agricultural Research, Education and Extension Organization, Karaj, Iran

3. Associate Professor, Agricultural Engineering Research Institute; Agricultural Research, Education and Extension Organization, Karaj, Iran

4. Associate Professor, Soil and Water Research Department, Qazvin Agricultural and Natural Resources Research and Education Center, AREEO, Qazvin, Iran.

5. M.Sc. of Water Resources Engineering, Sharif University of Technology, Tehran, Iran

DOI: 10.22052/deej.2020.9.28.51

first case, the soil salinity prediction model was based solely on salinity and vegetation indices monitored in the saline area because the reference land data were only recorded for a few years in the region. However, remote sensing capabilities enabled us to study the process of soil salinity changes over a broad period of time. In the second case, soil salinity was predicted according to the reference land data (groundwater level and SAR and EC indices) of the drainage area. In the third case, considering the timeframe of recording groundwater level data in the observed wells, the process of soil salinity modeling was performed by deleting groundwater level data to keep the model applicable even if the groundwater level was not recorded.

**Result:** : the results of correlation analysis of mean temporal data showed that GVI had a high negative correlation with all salinity indices, but there was a lower correlation between salinity and other vegetation indices. The results also suggested that the training error was less than the test error in both modeling modes, and the neural network model error was 60% lower than the cubic regression model. The R software showed that the corresponding correlation coefficient was  $\tau = -0.63$  and the  $p\text{-value} = 2 \times 10^{-12}$ , indicating a significant trend. It was found that using multivariate regression modeling had acceptable accuracy in predicting soil salinity in the study area. In the second modeling, EC and SAR indices in the catchment drainage area, vegetation indices, soil salinity indices derived from satellite images, and groundwater level values in the observed wells were used. According to the results, the neural network model had a higher accuracy than the regression model, but its test error was higher than the regression model, and in this case, the results of the neural network model were proved to be of higher accuracy. In the third modeling case, soil salinity was predicted regardless of groundwater levels. In this case, the neural network accuracy was only better in the training mode, and no difference was found in the test mode. Also, by eliminating groundwater level data, the model's prediction accuracy was considerably reduced.

**Discussion and Conclusion:** In this study, soil salinity was simulated and predicted using the neural network model and regression model in the drainage area of the central saline delta of Qazvin plain. To this end, reference land data and the indices derived from satellite images were used, and a soil salinity prediction model was presented. The results showed that the neural network models could simulate soil salinity with acceptable accuracy, requiring fewer factors than the computer model. Poor results for some models and states also indicated that any structure's neural network models would not principally yield good results, but they require careful selection of the constituent factors. Performing many repetitions and selecting the appropriate factors constitute the network.

**Keywords:** Drainage, Modeling, Neural network, Qazvin, Soil salinity, Water level.