



## "مقاله پژوهشی"

## مقایسه روش‌های درخت تصمیم و شبکه عصبی در پیش‌بینی شوری خاک در غرب دریاچه ارومیه

زهرا احمدی<sup>۱</sup>، آیدا عباسی کلو<sup>۲</sup>، محمود شهابی<sup>۳</sup> و عبدالحسین بوعلی<sup>۴</sup>

۱- دانشجوی دکتری علوم خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران

۲- استادیار گروه علوم و مهندسی خاک، دانشگاه حقوق اردبیلی، اردبیل، ایران، (نویسنده مسؤول: abbasiyada2014@gmail.com)

۳- داشتگار دکتری علوم خاک، دانشگاه تبریز

۴- دانشجوی دکتری مدیریت و کنترل بیابان، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، ایران

تاریخ دریافت: ۱۳۹۹/۰۶/۱۴ تاریخ پذیرش: ۱۳۹۹/۰۹/۰۴

صفحه: ۸۲ تا ۹۱

**چکیده**  
 شور شدن خاک یکی از مهمترین پدیده‌های تخریب خاک در مناطق خشک و نیمه‌خشک است. در سال‌های اخیر از روش‌های غیرمستقیم برای برآورد شوری خاک استفاده می‌شود. بدین‌منظور ۱۰۰ نمونه از عمق ۰-۳۰ سانتی‌متری اطراف دریاچه ارومیه برداشته و آزمایش شد و شوری خاک با استفاده از شاخص‌های تصویر ماهواره لندست ۸ و مدل رقومی ارتفاع برآورد شد. به‌منظور مدل سازی شوری خاک از مدل‌های درخت تصمیم و شبکه عصبی مصنوعی استفاده شد. براین اساس داده‌ها به دو سری آموزشی (%) و ارزیابی (%) تقسیم شد. نتایج ارزیابی مدل‌ها بر اساس شاخص‌های ریشه‌یاری مربuat خط، میانگین کاپا و ضریب تبیین نشان داد که مدل درخت تصمیم دارای بالاترین دقت در پیش‌بینی ویژگی‌های خاک است. نتایج ضریب کاپا و صحت کلی حاصل از دو مدل نشان داد که مدل درخت تصمیم با دارا بودن درصد ضریب کاپا (۵۶/۵۶) و صحت کلی (۷۳/۴۶) میزان توافق بیشتری با شوری خاک منطقه داشته است. به‌طور کلی براساس نتایج بدست آمده نشان داده شد که برای پیش‌بینی کلاس شوری خاک شاخص‌های CRSI و NDSI مهمترین پارامترها هستند و بیشترین همبستگی را با داده‌های زمینی دارند. لذا پیشنهاد می‌شود در مطالعات آینده برای تهیه نقشه شوری خاک از مدل‌های درختی و شاخص‌های CRSI و NDSI استفاده شود.

**واژه‌های کلیدی:** درخت تصمیم، شوری خاک، شبکه عصبی مصنوعی، مدل‌سازی

### مقدمه

متغیرهای محیطی است. شبکه‌های عصبی مصنوعی یکی از روش‌های هوشمند پردازش داده‌ها هستند که برای اولین بار بهوسیله پاچسفسکی<sup>۱</sup> و همکاران (۱۹۹۶)، بوتن و شاپ<sup>۲</sup> (۱۹۹۶) تماری<sup>۳</sup> و همکاران (۱۹۹۶) مورد استفاده قرار گرفته‌اند. شبکه عصبی مصنوعی یک روش شبیه‌سازی و الهام گرفته از مطالعه سیستم مغز و شبکه عصبی موجودات زنده است. اخیراً شبکه‌های عصبی به‌طور فرآگیر و موفقیت‌آمیزی در پیش‌بینی سیاری از خصوصیات خاک مورد استفاده قرار گرفته‌اند (۲۰۰۷). یکی از مزیت‌های استفاده از شبکه‌های عصبی مصنوعی نسبت به مدل‌های قدیمی این است که نیازمند تعیین یکتابع خاص برای بیان رابطه میان داده‌های ورودی و خروجی نیست. رابطه بین داده‌های ورودی و خروجی از طریق فرایند آموزش به‌دست می‌آید. اسکاپا<sup>۴</sup> و همکاران (۱۵) نشان دادند که شبکه‌های عصبی می‌تواند پیش‌بینی‌هایی با خطاهای کمتر نسبت به روش‌های متداول رگرسیونی ارائه دهد. فریدون سرمدیان و همکاران (۱۶) طی تحقیقی روش‌های مدل‌سازی شبکه عصبی و رگرسیون چند متغیره را مقایسه کردند و دریافتند شبکه عصبی کارایی بهتری نسبت به روش رگرسیون چند متغیره دارد. داده‌کاوی به بررسی و تجزیه و تحلیل مجموعه بزرگی از داده‌ها به‌منظور کاهش الگوها و قوانین پنهان و معنی‌دار درون داده‌ها اطلاق می‌شود (۱۶). از جمله روش‌های داده‌کاوی درختان تصمیم‌گیری هستند که به‌منظور پیش‌گویی یا کلاس‌بندی داده‌ها براساس مجموعه‌ای از قوانین ایجاد می‌شوند. روش درخت تصمیم طبقه‌بندی یک روش ناپارامتری الگوریتمی است که قادر است متغیرهای کمی یا متغیرهای طبقه‌بندی

شوری‌زنی یکی از دلایل اصلی تخریب خاک در مناطق خشک و نیمه‌خشک در جهان می‌باشد (۱۴، ۱۱). کاهش رشد گیاهان و تولیدات گیاهی و همچنین افزایش فرسایش خاک از جمله پیامدهای نامطلوب این پدیده به شمار می‌رود (۳). در ایران نیز مساحت خاک‌های تحت تاثیر شوری (۱۸ میلیون هکتار) برآورد شده است این خاک‌ها در مساحت‌های کوچک در نقاط مختلف کشور پراکنده است که اراضی مجاور خود را در اثر گسترش شوری مورد تهدید جدی قرار می‌دهد (۱۶). اصلاح خاک‌های شور نیاز به حجم زیاد آب شیرین دارد، بنابراین برای حل مشکل شوری خاک بایستی دنبال راه‌کارهای دیگری باشیم. برای تداوم پایدار کشاورزی، شوری باید شناسایی، پایش و مدیریت شود. اولین گام برای پایش و مدیریت، شناسایی مناطق شور و تهیه نقشه شوری خاک‌های کشور است. اقدامات انجام شده برای پایش، ارزیابی و تهیه نقشه شوری خاک، به‌طور فزاینده‌ای، در سطح دنیا در حال گسترش است. این در حالی است که نمونه‌برداری مستقیم همراه با اندازه‌گیری‌های آزمایشگاهی یا صحرایی معمولاً پُرهزینه و وقت‌گیر بوده و در نتیجه، برای اهداف کاربردی دارای محدودیت است. بنابراین، در سال‌های اخیر برای تخمین شوری خاک از روش‌های غیرمستقیم استفاده می‌شود (۱۷، ۱۸). تا به حال روش‌های متعددی برای پیش‌بینی و تخمین مکانی کلاس‌های شوری خاک ارائه شده است. که از جمله این روش‌ها می‌توان به روش‌های شبکه عصبی و داده‌کاوی (درخت تصمیم) اشاره کرد. شبکه‌های عصبی مصنوعی یکی از انواع مدل‌های مکانی جهت ارتباط دادن داده‌های خاک و

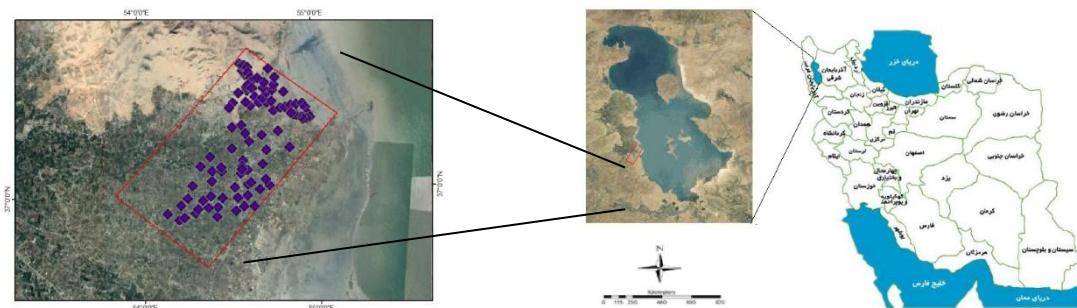
خاک و افزایش آن در طی سال‌های اخیر می‌باشد. از این‌رو تهیه نقشه شوری سطحی خاک جهت شناسایی و تشخیص وضعیت منطقه از نظر شوری در جهت مدیریت طرح‌های کشاورزی و بیابان‌زدایی اهمیت بسزایی دارد. براین اساس هدف از انجام پژوهش حاضر مقایسه روش‌های درخت تصمیم و شبکه عصبی در پیش‌بینی شوری خاک در غرب دریاچه ارومیه می‌باشد. بدینه است مقایسه این روش‌ها با یکدیگر و معروفی کارآمدترین آنها در پیش‌بینی شوری خاک به درک صحیحی از کارایی هر یک از آنها می‌انجامد و به ارائه راهکار جهت بطروف کردن و کاهش شوری خاک در منطقه کمک می‌کنند.

## مواد و روش‌ها

### منطقه مورد مطالعه

این دریاچه طبق آخرین تقسیمات کشوری بین دو استان آذربایجان شرقی و آذربایجان غربی تقسیم شده است. حوضه دریاچه ارومیه با داشتن دشت‌هایی مانند دشت تبریز، سلماس، پیرانشهر، مراغه و مهاباد یکی از کانون‌های ارزشمند فعالیت کشاورزی در ایران به‌شمار می‌رود. منطقه مورد مطالعه شامل ۴۰۰۰ هکتار از اراضی باغات، تپه گلمانخانه و اراضی بدون پوشش در غرب دریاچه ارومیه می‌باشد. این منطقه بین طول جغرافیایی  $34^{\circ}41'$  تا  $45^{\circ}12'$  و عرض جغرافیایی  $37^{\circ}31'$  تا  $37^{\circ}17'$  شمالی قرار دارد. دما و بارندگی سالیانه به ترتیب برابر  $10/8$  سانتی گراد و ۳۷۵ میلیمتر است. رژیم رطوبتی و حرارتی خاک منطقه به ترتیب زیریک خشک و مزیک طبقه‌بندی می‌شود.

شده را براساس مجموعه‌ای از متغیرهای پیش‌بینی کننده‌ی کمی و کیفی پیش‌بینی کند (۲۰). در این روش مجموعه‌ای از شرط‌های منطقی بهصورت یک الگوریتم با ساختار درختی برای طبقه‌بندی یا پیش‌بینی کمی یک متغیر به کار می‌رود (۱۶). مونجون و همکاران (۱۲) تکنیک شبکه عصبی مصنوعی و درخت تصمیم را برای پیش‌بینی واحدهای خاک مقایسه کردند. نتایج نشان داد بین دو تکنیک برای پیش‌بینی، تفاوتی معناداری وجود ندارد. علاوه بر این، در این مطالعه نشان داده شد که نقشه زمین‌شناسی متغیر کمکی مناسب جهت اجرای مدل‌ها معرفی شد. لوتو و هجور (۱۰) چندین روش نقشه‌برداری از جمله رگرسیون و درخت تصمیم و شبکه عصبی، را برای نقشه‌برداری سطوح ژئومورفولوژیک در فلات‌لند به کار برداشتند که نتایج کارایی بالاتر درخت تصمیم را نشان داد. جهت انجام فرآیند مدل‌سازی براساس روش درخت تصمیم و شبکه‌های عصبی نیاز به داده‌های آزمایشگاهی (شوری خاک) و داده‌های کمکی می‌باشد (۸). در نقشه‌برداری رقومی خاک، علاوه بر داده‌های خاک نیاز به داده‌های کمکی می‌باشد که یکی از این داده‌های کمکی استخراج پارامترهای مدل رقومی ارتفاع می‌باشد (۵). از مدل رقومی ارتفاعی برای استخراج اطلاعات کمکی یا تصاویر تخمین زننده متغیرهای ژنتیکی خاک استفاده می‌گردد که هر کدام از این شاخص‌ها با توجه به شرایط منطقه و فاکتور شوری اگر همیستگی بالایی داشته باشند به عنوان داده کمکی وارد مدل می‌شوند (۵). دریاچه ارومیه از جمله مناطقی است که در سال‌های اخیر با بحران پس‌روی آب، خشکی و افزایش شوری در خاک‌های اطراف آن مواجه شده است. از مهمترین عوامل موثر در کاهش عملکرد اراضی اطراف دریاچه ارومیه شوری بالای سطحی



شکل ۱- موقعیت منطقه مورد مطالعه در ایران و در اطراف دریاچه ارومیه  
Figure 1. Location of the study area in Iran and around Lake Urmia

سپس در معرض هوا خشک شده از الک ۲ میلیمتری عبور داده شدند. بعد از تهیه گل اشباع نمونه‌ها عصاره اشباع تهیه و با استفاده از دستگاه EC سنج، عصاره اشباع قرائت شد. تهیه داده‌های محیطی یا کمکی استخراج پارامترهای زمین‌نما و تصویر ماهواره‌ای خاک‌های گوناگون خصوصیات طیفی متفاوت دارند (۱۹). با توجه به اینکه اراضی اطراف دریاچه دارای تراکم کم پوشش گیاهی است و تغییر خصوصیات و نوع خاک‌ها در

### نمونه‌برداری

در این تحقیق سه نوع کاربری اراضی بدون پوشش، تپه و باغات در غرب دریاچه ارومیه مورد مطالعه قرار گرفت. نمونه‌برداری سطحی از عمق ۳۰ سانتی‌متر خاک با وزن یک کیلوگرم و بهروش تصادفی در سطح منطقه انجام شد. بدین ترتیب ۳۰ نمونه از محدوده بدون پوشش دریاچه، ۲۰ نمونه از تپه گلمانخانه و ۵۰ نمونه از باغات برداشت شد. نمونه‌ها برای تجزیه و تحلیل به آزمایشگاه منتقل شده و

بسیاری از مطالعات از این روش استفاده شده است. در روش دوم از تاثیر شوری خاک بر توسعه پوشش گیاهی استفاده می‌شود و بهترین راه برای تخمین شوری خاک منطقه‌ای که تحت پوشش محصولات کشاورزی است، می‌باشد. در این روش از بازتاب پوشش گیاهی به عنوان یک شاخص غیر مستقیم تخمین شوری خاک استفاده می‌شود. برای استخراج داده‌های کمکی، از مدل رقومی سازمان نقشه‌برداری با قدرت تفکیک مکانی ۳۰ متر استفاده شد. براساس نظرکارشناسان و با توجه به شرایط منطقه ۶ پارامتر جهت شیب، طول شیب، انحنای نیم‌خ، انحنای مسطح، شاخص قدرت جریان آب و شاخص خیسی جهت ارزیابی شوری خاک انتخاب و در محیط سامانه‌ی جغرافیایی ساگا (SAGA GIS) محاسبه و استخراج شد.

مناطقی که قادر پوشش گیاهی است به راحتی با اطلاعات ماهواره‌ای قابل تشخیص است (۱۳). در این مطالعه از تصاویر ماهواره‌ای سنجنده لندست ۸ از سنجنده TM استفاده شد که مربوط به ۱۵ سپتامبر سال ۲۰۱۸ می‌باشد. پس از انجام اصلاحات رادیومتریک بر روی تصاویر ماهواره‌ای و براساس نظر کارشناسان مربوطه و بررسی منابع انجام شده و همچنین شرایط منطقه، ۱۸ شاخص که در جدول (۱) آورده شده است جهت کمک به روند مدل‌سازی شوری خاک در منطقه محاسبه گردید.

در این مطالعه جهت تخمین شوری خاک از دو روش استفاده شد. در روش اول شوری خاک مستقیماً با استفاده از سنجش از دور و از روی خاک لخت اندازه‌گیری شد که در

جدول ۱- شاخص‌های استخراج شده از تصاویر ماهواره‌ای در منطقه مورد مطالعه

Table 1. Indicators extracted from satellite images in the study area

تعداد	شاخص	فرمول
۱	شاخص نرخ پوشش گیاهی	$\frac{\text{ref } 5}{\text{ref } 4}$
۲	Ratio vegetation index (RVI)	$\frac{\text{ref } 5 - \text{ref } 4}{\text{ref } 5 + \text{ref } 4}$
۳	شاخص گیاهی نرمال شده	$\frac{\text{ref } 5 - \text{ref } 4}{(\text{ref } 5 + \text{ref } 4 + 1) \times (1 + 1)}$
۴	Normalized Difference Vegetation Index (NDVI)	$\frac{\text{ref } 5 - \text{ref } 6}{\text{ref } 5 + \text{ref } 6}$
۵	شاخص پوشش گیاهی تعديل شده با خاک	$\frac{\text{ref } 6}{\text{ref } 8}$
۶	Soil Adjusted Vegetation Index (SAVI)	$\frac{\text{ref } 6 - \text{ref } 5}{\text{ref } 6 + \text{ref } 5}$
۷	شاخص تخمین میزان آب در گیاه	$\sqrt{\text{ref } 4^2 + \text{ref } 5^2}$
۸	Normalized Difference Water Index (NDWI)	$\frac{\text{ref } 4}{\text{ref } 3}$
۹	شاخص رس (Clay index)	$\frac{(\text{ref } 4 - \text{ref } 5)}{(\text{ref } 4 + \text{ref } 5)}$
۱۰	شاخص گچ (Gypsum index)	$\sqrt{(\text{ref } 5 \times \text{ref } 4) - (\text{ref } 3 \times \text{ref } 2)} / \sqrt{(\text{ref } 5 \times \text{ref } 4) + (\text{ref } 3 \times \text{ref } 2)}$
۱۱	شاخص روشنایی (Brightness Index)	$\frac{\text{ref } 4 - \text{ref } 5}{\text{ref } 3 + \text{ref } 5}$
۱۲	شاخص کربنات (Carbonate index)	$(\text{SI}) = \sqrt{\text{ref } 2 \times \text{ref } 4}$
۱۳	شاخص شوری استاندارد شده	$(\text{SI1}) = \sqrt{\text{ref } 3 \times \text{ref } 4}$
۱۴	Normalized Differential Salinity Index (NDSI)	$(\text{SI2}) = \sqrt{\text{ref } 2^2 + \text{ref } 5^2 + \text{ref } 3^2}$
۱۵	شاخص تاج پوشش در واکنش به تنفس شوری	$(\text{SI3}) = \sqrt{\text{ref } 4^2 + \text{ref } 3^2}$
۱۶	Canopy Response Salinity Index (CRSI)	$(\text{S3}) = \frac{(\text{ref } 3 \cdot \text{ref } 4)}{\text{ref } 2}$
		$(\text{S4}) = \frac{(\text{ref } 2 \cdot \text{ref } 4)}{\text{ref } 3}$
		$(\text{S5}) = \frac{(\text{ref } 4 \cdot \text{ref } 5)}{\text{ref } 3}$

گردید. بعد از آموزش شبکه مقدار میانگین مربعات خطای شبکه ثبت گردید. در تحقیق حاضر از نرم‌افزار مطلب برای نوشتن شبکه عصبی مصنوعی و از نرم افزار ENVI برای طراحی آن استفاده شده است. برای پنهانی‌بندی شوری خاک تمام لایه‌های اطلاعاتی یا کمکی به فرمت رستری با اندازه ۳۰۰ متری تهیه شدند. تمام اطلاعات (داده‌های شوری خاک و متغیرهای محیطی) به فرمت نهایی txt تبدیل شد و برای انجام فرآیند مدل‌سازی در نرم‌افزارهای مربوطه آماده شدند. در نهایت نقشه رقومی شوری خاک با استفاده از هر دو مدل تهیه شد.

#### ارزیابی و عملکرد مدل‌ها

برای بررسی دقت مدل‌ها، با هدف پیش‌بینی شوری خاک، مدل‌ها به طور تصادفی به دو دسته آموزشی (۸۰ درصد از داده‌های نمونه‌برداری شده) و آزمون (۲۰ درصد از داده‌های نمونه‌برداری شده) تقسیم شدند. عملکرد شبکه عصبی مصنوعی و درخت تصمیم بر اساس سه معیار آماری یعنی مجدد میانگین مربعات خطای (RMSE)، میانگین قدر مطلق خطای (MAE) و  $R^2$  مورد بررسی قرار گرفت (رابطه ۱، ۲ و ۳). همچنین پس از بررسی عملکرد مدل‌ها، جهت ارزیابی طبقه‌بندی نقشه‌های خروجی مدل‌ها از ضریب کاپا و صحت کلی استفاده شد.

$$R^2 = 1 - \frac{\sum (ECreal - ECpredict)^2}{\sum (ECpredict - ECm)^2}$$

$$MAE = \frac{\sum |EC real - ECpredict|}{n}$$

$$RMSE = \sqrt{\frac{\sum (ECreal - ECpredict)^2}{n}}$$

که در این روابط ECpredict: مقدار پیش‌بینی شده EC توسط مدل، ECreal: مقدار اندازه‌گیری EC در آزمایشگاه، ECm: میانگین EC اندازه‌گیری شده و n: تعداد داده‌ها

بدون پوشش گیاهی و با شوری بیش از ۱۶ دسی‌زیمنس بر متر بوده و این مناطق اغلب با نمک پوشیده شده است. از محدوده تپه ۲۰ نمونه برداشت شد که حداکثر و حداقل هدایت الکتریکی این منطقه به ترتیب ۹۰/۱ و ۰/۳۷۴ دسی‌زیمنس بر متر بود و داده‌های هدایت الکتریکی نمونه‌های تپه غالباً در کلاس یک قرار گرفته‌اند. از محدوده باغات ۵۰ نمونه برداشت شد حداکثر و حداقل هدایت الکتریکی داده‌های این محدوده به ترتیب ۴/۲۷ و ۰/۵۰۲ دسی‌زیمنس بر متر بود و داده‌های هدایت الکتریکی باغات غالباً در کلاس ۱ و ۲ قرار گرفته است.

جدول ۲ - کلاس‌بندی ۱۰۰ نمونه برداشت شده در کاربری‌های ۳ گانه در منطقه مورد مطالعه

Table 2. Classification of 100 samples taken in three uses in the study area

FAO	کلاس بندی	باغ	تپه	دریاچه
-۳	۳۱	۱۸	۴	
۲-۴	۱۸	۱	۲	
۴-۸	۱	-	۲	
۸-۱۶	-	-	۳	
>۱۶	-	۱	۱۷	

#### مدل‌سازی

جهت برقراری ارتباط بین متغیرهای کمکی و شوری از مدل درخت تصمیم و شبکه عصبی مصنوعی استفاده شد. در مدل درخت تصمیم مجموعه‌ای از شرط‌های منطقی به صورت یک الگوریتم با ساختار درختی برای طبقه‌بندی یا پیش‌بینی کمی یک متغیر به کار می‌رود. در تحقیق حاضر از نرم‌افزار ENVI مطلب برای بدست آوردن درخت تصمیم و از نرم‌افزار ENV برای رسم آن استفاده شد. شبکه عصبی مصنوعی یک روش شبیه‌سازی می‌باشد که از مطالعه سیستم مغز و شبکه عصبی موجودات زنده الهام گرفته است. اولین گام در ساخت یک مدل مبتنی بر شبکه عصبی مصنوعی، انتخاب نوع شبکه است. یکی از متدالو ترین شبکه‌های عصبی مورد استفاده شبکه عصبی پرسپترون چند لایه می‌باشد. طبق تحقیقات انجام شده یک شبکه پرسپترون با یک لایه مخفی قادر به تخمین زدن هر تابع غیرخطی می‌باشد (۴). در این تحقیق از شبکه عصبی با ساختار پرسپترون چند لایه با فرایند پیشرو استفاده گردید. شبکه‌ها دارای تابع فعال‌سازی تانژانت هیبریبولیک در لایه مخفی و تابع فعال‌سازی سیگموئید در لایه خروجی در نظر گرفته شدند. از الگوریتم یادگیری لوینبرگ-مارکوارت و مومتومن بهدلیل کارایی بالا، سادگی و سرعت بالا استفاده شد که در نهایت الگوریتم مومتومن دقت بیشتر در تخمین داشت (۴). تعداد نورون‌ها از ۲ تا ۲۰ متغیر بوده و بهترین تعداد ۳ نورون بهروش سعی و خطای تعیین

رابطه (۱):

رابطه (۲):

رابطه (۳):

#### نتایج و بحث

##### اندازه‌گیری شوری خاک منطقه

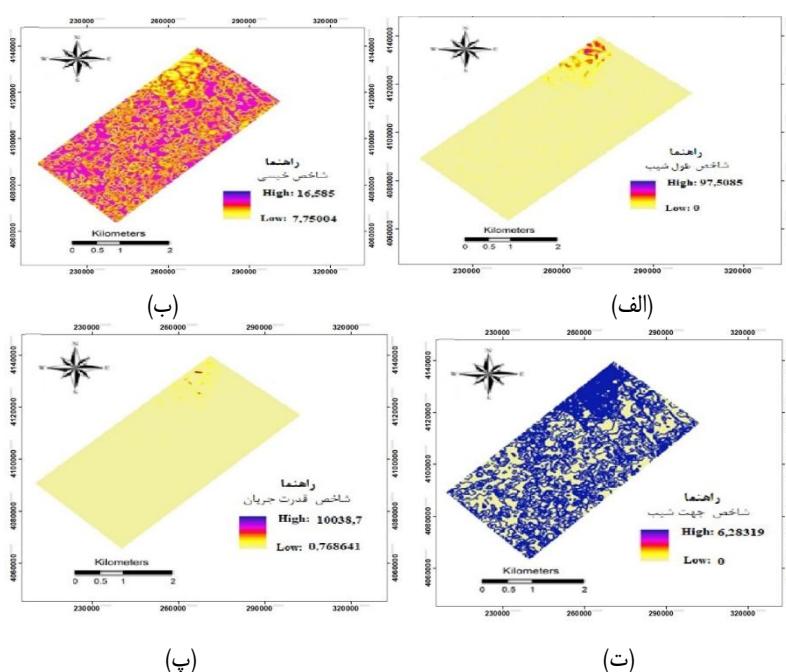
منطقه مورد مطالعه شامل سه نوع کاربری اراضی بدون پوشش، تپه و باغات در غرب دریاچه ارومیه می‌باشد. نتایج حاصل از اندازه‌گیری هدایت الکتریکی نمونه‌ها براساس طبقه‌بندی فائق کلاس‌بندی شد (جدول ۲). براساس نتایج آزمایشگاهی حداکثر و حداقل هدایت الکتریکی منطقه اراضی بدون پوشش به ترتیب ۱۳۹/۱ و ۰/۵۶ دسی‌زیمنس بر متر بود. در این محدوده پس روی آب دریاچه باعث افزایش پوسته‌های نمکی و گسترش خاک‌های با کلاس شوری ۴ و ۵ در نزدیک دریاچه شده است. محدوده اطراف دریاچه غالباً

شاخص SAVI تنها زمانی برای ارزیابی شوری خاک مناسب است که مناطق تحت شوری کم بوده و توسط گیاهان حساس به نمک احاطه شده باشد (۲۱). در شاخص‌های توپوگرافی با توجه به اینکه شیب تپه زیادتر از منطقه اراضی بدون پوشش و باغات می‌باشد، بنابراین میزان توپوگرافی هموارانی مشتبی با طول شیب، جهت شیب و قدرت جریان نشان می‌دهد. در حالی که با شاخص‌های خیسی خاک همبستگی منفی نشان می‌دهد که علت آن عدم نگهداری سطحی آب در شیب‌های تند می‌باشد (۱). به علت مسطح بودن بیش از ۹۰ درصد ناحیه مورد مطالعه بعضی از شاخص‌های مدل رقومی ارتفاع مانند انحنای نیم‌رخ و انحنای مسطح تغییرات معنی‌داری را نشان ندادند و نقشه‌های تقریباً یکنواختی از این شاخص‌ها حاصل شد. در شکل ۲ و ۳ نقشه شاخص‌هایی که بیشترین همبستگی را با هدایت الکتریکی خاک داشتند نشان داده شده است. به طور کلی در منطقه مورد مطالعه شاخص‌های سنجش از دور در زمین‌های بدون پوشش و شوره‌زار کارابی بالاتری نسبت به کاربری‌های باغات و تپه برای تخمین شوری داشتند که با نتایج تقریزاده و همکاران (۱۸) مطابقت دارد. در کاربری باغ به علت متنوع بودن نوع محصول NDVI و سایر شاخص‌های پوشش گیاهی کارابی خوبی در تخمین شوری نداشتند و همچنین در کاربری تپه به علت شیب‌دار بودن آن شاخص‌های سنجش از دور به خوبی جواب نداد بلکه پارامترهای استخراج شده از مدل رقومی ارتفاع در منطقه تپه که دارای ارتفاع بیشتری است نتایج بهتری داشت.

### بررسی همبستگی بین هدایت الکتریکی خاک و داده‌های کمکی

نتایج بررسی ضریب همبستگی پیرسون بین شاخص‌های سنجش از دور و هدایت الکتریکی نشان داد از میان شاخص‌های مورد بررسی، بیشترین همبستگی بین شاخص CRSI و هدایت الکتریکی خاک وجود داشت. وقتی خاک شور باشد ریشه گیاه به عمق پروفیل نفوذ می‌کند و اندازه تاج پوشش گیاه در زمان مشخص تاثیر تجمعی شوری را مشخص می‌کند. شاخص‌های NDSI و روشنایی نیز در رتبه‌های بعدی بالاترین همبستگی بین شاخص‌های مورد بررسی در منطقه بودند. خان و همکاران (۹) نیز در تحقیق خود دریافتند که شاخص‌های CRSI و NDSI نتایج رضایت‌بخشی برای تعیین غلظت نمک‌های مختلف در سطوح خاک ارائه می‌دهند. عملکرد خوب شاخص‌های CRSI و NDSI به احتمال زیاد حاصل باند قرمز و مادون قرمز است که برای اصلاح الگوها و ویژگی‌های شوری خاک از قبیل پوسته سطح مورد استفاده قرار گرفته است (۱۳).

با توجه به نتایج به دست آمده مشخص گردید که شاخص‌های NDVI و SAVI در مناطقی که پوشش گیاهی کم است نتایج ضعیفی در تخمین میزان هدایت الکتریکی دارند در حالیکه در این مناطق شاخص‌های شوری کارابی بالاتری دارند. فن و همکاران نیز دریافتند که شاخص‌های NDVI و SAVI در مناطق با پوشش گیاهی کم کارابی کمی در تخمین شوری دارند در حالیکه در این مناطق شاخص‌های شوری کارابی بالاتری در تخمین شوری دارند.

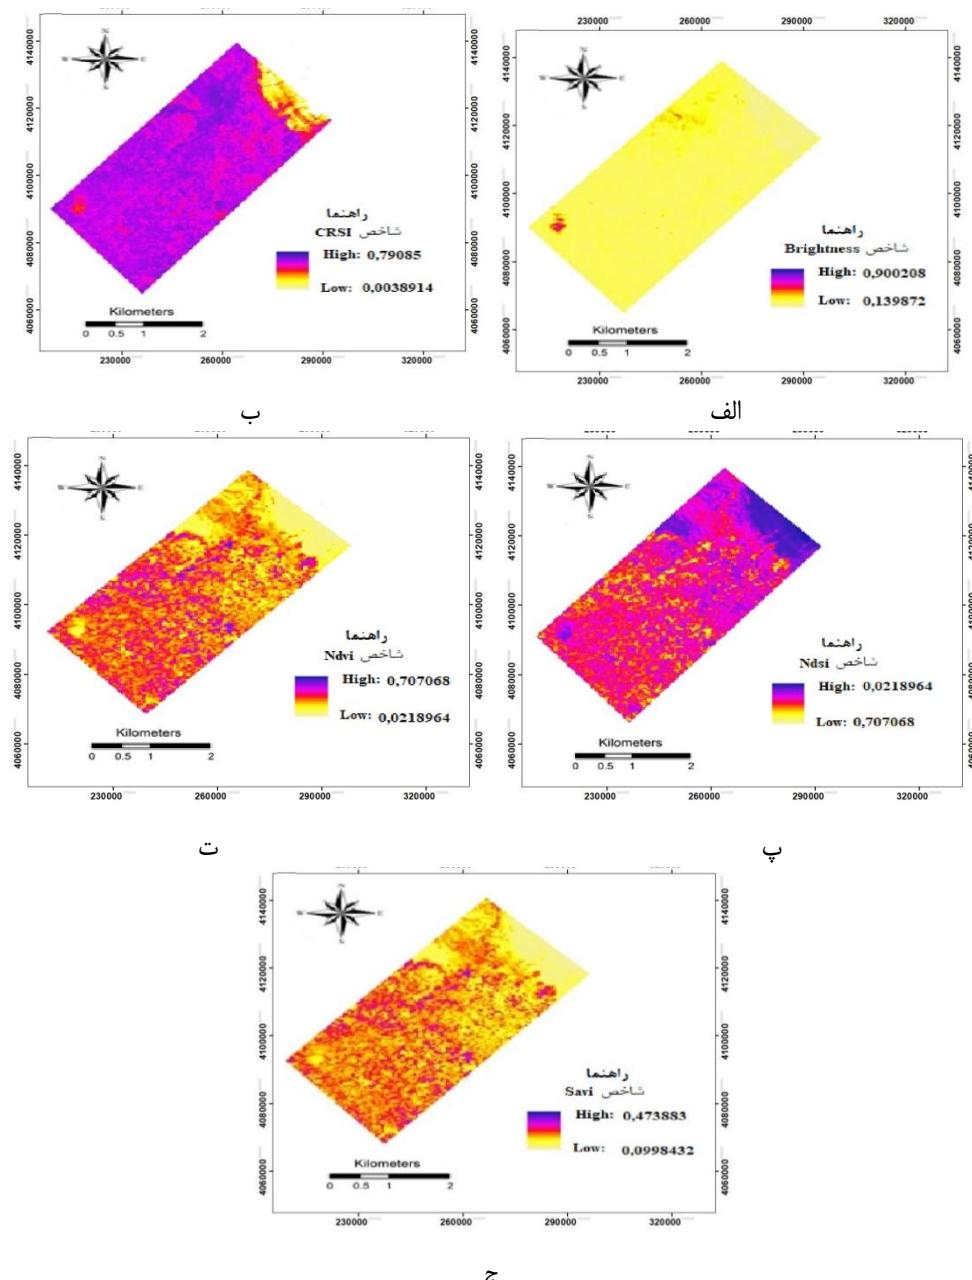


شکل ۲-الف، ب، پ و ت به ترتیب نقشه شاخص طول شیب، خیسی، قدرت جریان و جهت شیب استخراج شده از مدل رقومی ارتفاعی  
Figure 2. A, B, C and D, respectively, slope length, wetness, flow strength and slope direction index map extracted from digital elevation model

کند. مدل شبکه عصبی مصنوعی با ساختار ۳۳۱ (قدرت جریان، طول شبیب و شاخص CRSI) به عنوان ورودی و EC به عنوان خروجی با یک لایه ساختار پنهان (بر اساس روش آزمون و خطا برای پیش‌بینی EC) برای منطقه مورد مطالعه طراحی شد. منججون و همکاران نیز در تحقیق خود به صحت و دقت نتایج بست آمده از شبکه عصبی مصنوعی جهت پیش‌بینی شوری خاک اشاره کردند (۲). شکل ۴ نقشه شوری خاک منطقه براساس مدل را نشان می‌دهد (شکل ۴). بر اساس نقشه شوری خاک بست آمده از مدل شبکه عصبی، پیش‌ترین مقدار شوری در قسمت‌های شمالی و جنوبی منطقه و در کاربری اراضی بدون پوشش و باغ‌ها مشاهده می‌شود.

### مدل سازی شبکه عصبی مصنوعی

تعداد لایه‌های مخفی و تعداد نورون‌ها اجزای اصلی پرسپترون در شبکه‌های عصبی مصنوعی هستند. تعداد اپوک نیز در مرحله یادگیری بسیار مهم است. در این تحقیق یک لایه مخفی برای ایجاد شبکه پرسپترون استفاده شد. تعداد نورون‌های لایه مخفی و تعداد اپوک در فرآیند آموزش به صورت سعی و خطا به دست آمد. براساس نتایج بست آمده ساختار ۳-۱-۳ برای پیش‌بینی گروه خاک بهترین ساختار است. نتایج نشان داد مدل شبکه‌های عصبی از ۶۹ درصد از تغییرات شوری خاک در منطقه مورد مطالعه را می‌تواند تفسیر



شکل ۳- الف، ب، پ، ت و ج به ترتیب نقشه‌های شاخص‌های CRSI، NDVI، NSDI و SAVI استخراج شده از تصاویر ماهواره‌ای منطقه

Figure 3. A, B, C, T and C, respectively, CRSI, NDVI, NSDI, and SAVI indices maps extracted from satellite images of the region.

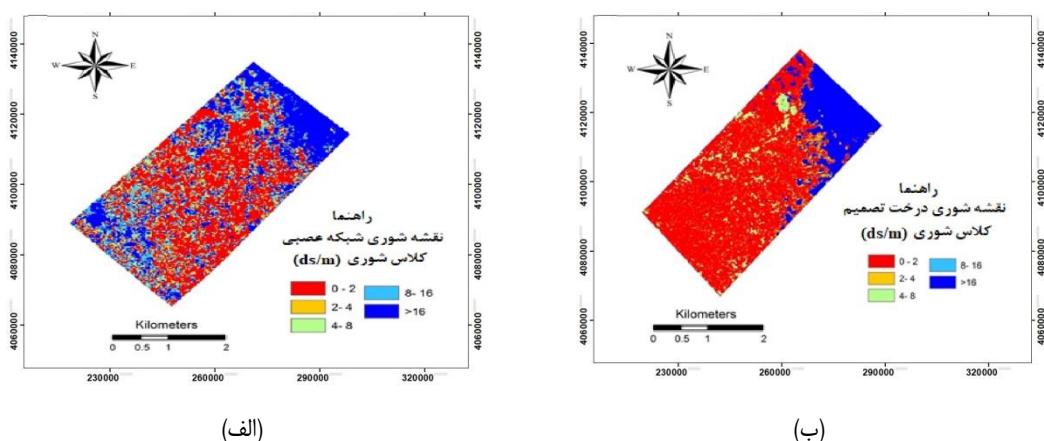
میانگین کلی از متغیر EC است تقسیم شد. مقدار متغیر تخمین زده شده در هر گره میانگینی از کل گره است. با حرکت به سمت گره‌های پایین‌تر، همگنی درگره افزایش و واریانس کاهش یافته و آن گره برآورده دقیق‌تر از ویژگی EC را ارائه می‌دهد. شکل ۴ نقشه شوری حاصل از مدل درخت تصمیم را نشان می‌دهد (شکل ۴).

براساس نقشه شوری خاک بدست آمده از مدل درخت تصمیم بیشترین مقدار شوری در قسمت‌های شمال شرقی و غرب دریاچه ارومیه و در کاربری اراضی بدون پوشش مشاهد می‌شود.

علت آن می‌تواند داشتن شیب کم و توپوگرافی مقعر، تجمع املاح منتقل شده از قسمت‌های مرتفع اطراف منطقه و همچنین عقب نشینی دریاچه در گذر زمان باعث افزایش میزان شوری خاک در این قسمت شده است.

#### درخت تصمیم

در روش درخت تصمیم ابتدا متغیر مستقل EC برای برآورد به نرم‌افزار ترسیم رگرسیون درختی معوفی شدند. سپس متغیرهای موثر توسط نرم‌افزار انتخاب و بر اساس اولویت به طور متوالی به دو گره تقسیم شدند. بر این اساس، متغیرهای موثر برای درخت تصمیم Brightness، NDSI، SI، Carbon، Clay، S5، StreamPower، CRSI انتخاب گردید. نخستین متغیر که درخت تصمیم انتخاب کرد و تنها اصلی درخت را ایجاد می‌کند شاخص Brightness بود و این بیانگر این بود که شاخص روشنایی بیشترین تاثیر را در تخمین شوری توسط سنجش از دور دارد. در واقع این شاخص بیشترین سهم را در درخت تصمیم در توجیه تغییرات EC دارد. سایر شاخص‌ها در برگ‌های درخت قرار گرفته‌اند و آخرین شاخص Si بود. هر گره به دو گره فرزندی که در واقع



شکل ۴- (الف)- نقشه رقومی شوری حاصل از شبکه عصبی و (ب)- نقشه رقومی شوری حاصل از درخت تصمیم  
Figure 4. Digital map of salinity from the decision tree and Digital salinity map of neural network

تصمیم با ضریب تبیین  $46/46$ ، ضریب کاپا  $25/25$  و صحت کلی  $52/52$  درصد کارایی بالاتری در جداسازی خاک‌ها دارد به این علت از این روش برای طبقه‌بندی خاک‌ها استفاده کردند. به منظور مقایسه عملکرد مدل‌های درخت تصمیم و شبکه عصبی از پارامترهای مجدد میانگین مربعات خطای (RMSE)، میانگین خطای (MAE) و ضریب تبیین ( $R^2$ ) استفاده شد که در واقع این سه پارامتر برای نشان دادن دقت مدل‌ها می‌باشد. نتایج این فاکتورها در جدول (۳) آورده شده است.

Table 3. Evaluation indicators of models

نام مدل	MAE	RMSE	$R^2$
شبکه عصبی	۱۱/۳۰	۱۸/۹۹	.۶۹
درخت تصمیم	۲/۷۶	۵/۸۹	.۹۸

درخت تصمیم با داشتن کمترین مجدد میانگین خطای و میانگین خطای و همچنین با داشتن بیشترین میزان ضریب تبیین مدل بهتری نسبت به شبکه عصبی برای پیش‌بینی شوری خاک در عمق  $0-30$  سانتی‌متر در منطقه می‌باشد.

نتایج ضریب کاپا و صحت کلی حاصل از دو مدل نشان داد که مدل درخت تصمیم با دارا بودن درصد ضریب کاپا  $56/56$  و صحت کلی  $73/73$  میزان توافق بیشتری نسبت به مدل شبکه عصبی با درصد ضریب کاپا  $48/48$  و صحت کلی  $32/16$  داشته و طبقه‌بندی نقشه رقومی را نسبت به این مدل دقیق‌تر ارائه می‌دهد. تقریباً  $70\%$  همکاران  $17/17$  روش‌های شبکه عصبی مصنوعی و درخت تصمیم را برای تهیه نقشه رقومی خاک مقایسه کردند و دریافتند درخت

جدول ۳- شاخص‌های ارزیابی مدل‌ها

مقایسه مقدار پارامترهای فوق برای ارزیابی مدل‌ها در مرحله تست نشان داد مدل درخت تصمیم از دقت بیشتری نسبت به مدل شبکه عصبی برای تخمین شوری در منطقه مورد برخوردار می‌باشد. در واقع براساس سه پارامتر بالا روش

محلی مورد استفاده قرار گیرد. ارتباط قوی بین داده خاک و پارامترهای محیطی نیز یکی دیگر از عوامل تاثیرگذار بر دقت مدل درخت تصمیم می‌باشد. به طور کلی براساس نتایج بدست آمده نشان داده شد که تکنیک‌های خاک آماری، به خصوص درخت تصمیم، می‌توانند فرآیند نقشه‌برداری خاک‌ها را در گستره‌ای وسیع و متiskل از هر گونه عوارض طبیعی به یک باره انجام دهند، روش سنتی را ارتقا بخشنده، سرعت عمل و کارآمدی نقشه‌ها را در انتقال داده‌ها و اطلاعات افزایش دهند و قابلیت استفاده از آنها را برای قشر وسیعی از شاخه‌های علمی امکان‌پذیر کنند. پیشنهاد می‌شود برای تهیه نقشه رقمی خاک از مدل‌های درختی در مطالعات آینده استفاده شود.

### نتیجه‌گیری کلی

منطقه مورد مطالعه به دلیل نزدیکی به دریاچه ارومیه با مشکل شوری خاک مواجه بوده و شناسایی و طبقه‌بندی خاک‌های منطقه برای اعمال مدیریت صحیح امری ضروری است. در این پژوهش به منظور برآورد میزان شوری خاک‌های اطراف دریاچه ارومیه در کاربری‌های مختلف از علم سنجش از دور و مدل‌های درخت تصمیم و شبکه‌های عصبی استفاده شد. با توجه به نتایج بدست آمده نشان داده شد که مدل درخت تصمیم نسبت به مدل شبکه عصبی، مدل برتری جهت پیش‌بینی شوری خاک منطقه بوده و طبقه‌بندی بهتری از شوری در منطقه ارائه می‌دهد. نتایج درخت تصمیم می‌تواند به عنوان یک راه برای بهبود دقت پیش‌بینی مکانی شوری خاک و برای پیشبرد نقشه‌برداری دیجیتال خاک در مقیاس

### منابع

- Allbed, A., L. Kumar and Y. Aldakheel. 2014. Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS highspatial resolution imageries: Applications in a date palm dominated region. *Geoderma*, 230(43): 1-8.
- Afkhami, H., M.T. Dastoorani and F. Fotouhi. 2015. The impact probability distribution to increase accuracy of prediction of suspended sediment using artificial neural networks and neuro-fuzzy inference system (Case Study :Watershed Dez). *Iranian Journal of Watershed Management Science and Engineering*, 4(21): 21-35 (In Persian).
- Azhirabi, R., B. Kamkar and O. Abdi. 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).
- Amini, M., K.C. Abbaspour, H. Khademi, N. Fathianpour, M. Afyuni and R. Schulin. 2005. Neural network models to predict cation exchange capacity in arid regions of Iran. *European Journal of Soil Science*, 4(53): 748-757.
- Abdelfattah, M.A., SH.A. Shahid and Y.R. Othman. 2008. A model for salinity mapping using Remote Sensing and Geographic Information System- A case study from Abu Dhabi Emirate. UAE. 2<sup>nd</sup> International Salinity Forum.123. Adelaide, Australia.
- Bouma, J. 1989. Using soil survey data for quantitative land evaluation. *Soil Science*, 9: 177-213.
- Bannari, A., A.M. Guedon, A. El-Harti, F.Z. Cherkaoui and A. El-Ghmari. 2008. Characterization of slightly and moderately saline and sodic soils in irrigated agricultural land using simulated data of advanced land imaging (EO-1) sensor. *Commun. Soil Sci. Plant Anal*, 39(20): 2795-2811.
- Hongyan, C., G. Zhao, L. Sun, R. Wang and Y. Liu. 2016. Prediction of soil salinity using near-infrared reflectance spectroscopy with nonnegative matrix factorization. *Applied spectroscopy*, 70(9): 1589-1597.
- Khan, N.M., V. Rastoskuev, Y. Sato and S. Shiozawa. 2005. Assessment of hydrosaline land degradation by using a simple approach of remote sensing indicators. *Agric. Water Manag*, 77(1): 96-109.
- Luoto, M. and J. Hjort. 2005. Evaluation of current statistical approaches for predictive geomorphological mapping, *Geomorphology*, 26(67): 299-315.
- Mokhtari, M. and A. Najafi. 2015. Comparison of Support Vector Machine and Neural Network Classification Methods in Land Use Information Extraction through Landsat TM Data. *Journal of Water and Soil Science*, 19(12): 35-45 (In Persian).
- Moonjun, R., A. Farshad, D.P. Shrestha and C. Vaiphasa. 2010. Artificial Neural Network and Decision Tree in Predictive Soil Mapping of Hoi NumRin Sub-Watershed, Thailand, Digital Soil Mapping. *Progress in Soil Science*, 2(23): 151-164.
- Metternicht, G. and J.A. Zinck. 2003. Remote sensing of soil salinity: potentials and constraints. *Remote Sensing of Environment*, 58(12): 1-10.
- Soltaninejad, A., H. Ranjbar, M. Honarmand and S. Dargahi .2018. Evaporite mineral mapping and determining their source rocks using remote sensing data in Sirjan playa, Kerman, Iran. *Carbonates and Evaporites*, 33(2): 255-274.
- Schaap, M.G., F.J. Leij and M.T. Genuchten. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Sciences*, 62(32): 847-855.
- Sarmadian, F., R. Taghizadeh, H.M. Askari and A. Akbarzadeh. 2011. Comparison of neurophasic methods, neural network and multivariate regression in predicting some soil properties. *Iranian Journal of Soil and Water Research*, 41(1): 220-211.

17. Taghizadeh, R., B. Minasny, F. Sarmadian and P.B. Malone. 2016. Digital mapping of soil salinity in Ardakan region, central Iran. *Geoderma*, 213(56): 15-28.
18. Taghizadeh, R., K. Nabiollahi, B. Minasny and J. Triantafilis. 2015. Comparing data mining classifiers to predict spatial distribution of USDA-family soil groups in Baneh region, Iran. *Geoderma*, 253(254): 67-77.
19. Vafaei, S., J. Soosani, K. Adeli, H. Fadaei, H. Naghavi, T.D. Pham and D.T. Bui. 2018. Improving Accuracy Estimation of Forest Aboveground Biomass Based on Incorporation of ALOS-2 PALSAR-2 and Sentinel-2A Imagery and Machine Learning: A Case Study of the Hyrcanian Forest Area (Iran). *Remote Sensing*, 10(3): 1-21.
20. Yu, H., M. Liu, B. Du, Z. Wang, L. Hu and B. Zhang. 2018. Mapping Soil Salinity/Sodicity by using Landsat OLI Imagery and PLSR Algorithm over Semiarid West Jilin Province, China. *Sensors*, 18(4): 1043-1017.
21. Zhang, T., T. Zeng, S. YuGao, Z. Ouyang, B. Li, G. Fang and B. Zhao. 2011. Using hyperspectral vegetation indices as a proxy to monitor soil salinity. *Ecological Indicators*, 11(4): 1552-1562.

## Comparison of Decision Tree and Neural Network Methods in Predicting Soil Salinity in the West of Lake Urmia

Zahra Ahmadi<sup>1</sup>, Aida Abbasi<sup>2</sup>, Mahmood Shahabi<sup>3</sup> and Abdolhossein Boali<sup>4</sup>

1- Ph.D. Student in Soil Science, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

2- Assistant Professor, Department of Soil Science and Engineering, University of Mohaghegh Ardabili, Ardabil, Iran, (Corresponding author: abbasiayda2014@gmail.com)

3- PhD Graduate of Soil Science, University of Tabriz

4- Ph.D. Student in Desert Management and Control, University of Agriculture and Natural Recourses Sciences of Gorgan, Gorgan, Iran

Received: September 4, 2020

Accepted: November 24, 2020

### Abstract

Soil salinization is one of the most important soil degradation phenomena in arid and semi-arid regions. In recent years, indirect methods have been used to estimate soil salinity. For this purpose, 100 samples were taken from a depth of 0-30 cm around Lake Urmia and tested, and soil salinity was estimated using Landsat 8 satellite image indicators and digital elevation model. In order to model soil salinity, decision tree models and artificial neural network were used. Accordingly, the data were divided into educational duality (80%) and evaluation (20%). The results of evaluating the models based on the square root indices of error, mean error and coefficient of explanation showed that the decision tree model has the highest accuracy in predicting soil properties. The results of kappa coefficient and overall accuracy obtained from the two models showed that the decision tree model with having kappa coefficient percentage (56.56) and overall accuracy (73.46) had a greater agreement with the soil salinity of the region. In general, based on the obtained results, it was shown that CRSI and NDSI indices are the most important parameters for predicting soil salinity class and have the highest correlation with terrestrial data. Therefore, in the future studies, it is suggested to use tree models and CRSI and NDSI indices to prepare a digital soil salinity map.

**Keywords:** Artificial neural network, Decision tree, Modeling, Soil Salinity