



"مقاله پژوهشی"

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

زهرا احمدی^۱، آیدا عباسی کلو^۲، محمود شهبابی^۳ و عبدالحسین بوعلی^۴

۱- دانشجوی دکتری علوم خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران
 ۲- استادیار گروه علوم و مهندسی خاک، دانشگاه محقق اردبیلی، اردبیل، ایران، (نویسنده مسؤل: abbasiyada2014@gmail.com)
 ۳- دانش‌آموخته 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 مدل‌سازی شوری خاک از مدل‌های درخت تصمیم و شبکه عصبی مصنوعی استفاده شد. براین اساس داده‌ها به دو سری آموزشی (۸۰٪) و ارزیابی (۲۰٪) تقسیم شد. نتایج ارزیابی مدل‌ها بر اساس شاخص‌های ریشه‌ی مربعات خطا، میانگین خطا 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 رقومی شوری خاک از مدل‌های درختی و شاخص‌های CRSI و NDSI استفاده شود.

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

مقدمه


شوری‌زایی 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 به‌شمار می‌رود (۳). در ایران نیز مساحت خاک‌های تحت‌تاثیر شوری ۵/۱۵ تا 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 پرهزینه 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،۶). تا به‌حال 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

متغیرهای محیطی است. شبکه‌های عصبی مصنوعی یکی از روش‌های هوشمند پردازش داده‌ها هستند که برای اولین بار به‌وسیله پاپسفسکی^۱ و همکاران (۱۹۹۶)، بوتن و شاپ^۲ (۱۹۹۶) تماری^۳ 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 فراگیر و موفقیت‌آمیزی در پیش‌بینی بسیاری از خصوصیات خاک مورد استفاده قرار گرفته‌اند (۲۰،۷). یکی از مزیت‌های استفاده از شبکه‌های عصبی مصنوعی نسبت به مدل‌های قدیمی این است که نیازمند تعیین یک تابع خاص برای بیان رابطه میان داده‌های ورودی و خروجی نیست. رابطه بین داده‌های ورودی و خروجی از طریق فرایند آموزش به‌دست می‌آید. اسکاپا و همکاران (۱۵) نشان دادند که شبکه‌های عصبی می‌توانند پیش‌بینی‌هایی با خطاهای کمتر نسبت به روش‌های متداول رگرسیونی ارائه دهد. فریدون سرمیدیان 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 کلاسه‌بندی داده‌ها براساس مجموعه‌ای از قوانین ایجاد می‌شوند. روش درخت تصمیم طبقه‌بندی یک روش ناپارامتری الگوریتمی است که قادر است متغیرهای کمی یا متغیرهای طبقه‌بندی

خاک و افزایش آن در طی سال‌های اخیر می‌باشد. از این رو 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. بدیهی است مقایسه این روش‌ها با یکدیگر و معرفی کارآمدترین آنها در پیش‌بینی شوری خاک به درک صحیحی از کارایی هر یک از آنها می‌انجامد و به ارائه راهکار جهت برطرف کردن و کاهش شوری خاک در منطقه کمک می‌کند.

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 گلخانه و اراضی بدون پوشش در غرب دریاچه ارومیه می‌باشد. این منطقه بین طول جغرافیایی $45^{\circ} 12' 41''$ تا $45^{\circ} 14' 13''$ شرقی و عرض جغرافیایی $37^{\circ} 34' 79''$ تا $37^{\circ} 31' 17''$ شمالی قرار دارد. دما و بارندگی سالیانه به‌ترتیب برابر $10/8$ سانتی‌گراد و 375 میلی‌متر است. رژیم رطوبتی و حرارتی خاک منطقه به‌ترتیب زیریک خشک و مزیک طبقه‌بندی می‌شود.



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 ال ک ۲ میلیمتری عبور داده شدند. بعد از تهیه گل اشباع نمونه‌ها عصاره اشباع تهیه و با استفاده از دستگاه ECسنج، EC 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

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 به‌کار 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. لووتو و هجور (۱۰) چندین روش نقشه‌برداری از جمله رگرسیون و درخت تصمیم و شبکه عصبی، را برای نقشه‌برداری سطوح ژئومورفولوژیک در فنلاند به‌کار بردند 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 زنده متغیرهای ژنتیکی خاک استفاده می‌گردد که هر کدام از این شاخص‌ها با توجه به شرایط منطقه و فاکتور شوری اگر همبستگی بالایی داشته باشند به‌عنوان 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

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. بدین‌ترتیب ۳۰ نمونه از محدوده بدون پوشش دریاچه، ۲۰ نمونه از تپه گلخانه 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 به‌عنوان 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 نظر کارشناسان و با توجه به شرایط منطقه ۶ پارامتر جهت شیب، طول شیب، انحنای نیمرخ، 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.

مناطقى که فاقد پوشش گیاهی است به‌راحتی 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 سنجنش از دور و از روی خاک لخت اندازه‌گیری شد که در

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

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

مدل‌سازی

گردید. بعد از آموزش شبکه مقدار میانگین مربعات خطا برای شبکه ثبت گردید. در تحقیق حاضر از نرم‌افزار مطلب برای نوشتن شبکه عصبی مصنوعی و از نرم‌افزار ENVI برای طراحی آن استفاده شده است. برای پهنه‌بندی شوری خاک تمام لایه‌های اطلاعاتی یا کمکی به فرمت رستری با اندازه پیکسل ۳۰ 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 به‌طور 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 مجذور میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (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.

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 به‌صورت یک الگوریتم با ساختار درختی برای طبقه‌بندی یا پیش‌بینی کمی یک متغیر به‌کار می‌رود. در تحقیق حاضر از نرم‌افزار مطلب برای بدست آوردن درخت تصمیم و از نرم‌افزار ENVI 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 متداول‌ترین 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 فرآیند پیشرو استفاده گردید. شبکه‌ها دارای تابع فعال‌سازی تانژانت هیپربولیک در لایه مخفی و تابع فعال‌سازی سیگموئید در لایه خروجی در نظر گرفته شدند. از الگوریتم یادگیری لوبنبرگ-مارکوارت و مونتوم به‌دلیل کارایی بالا، سادگی و سرعت بالا استفاده شد که در نهایت الگوریتم مونتوم دقت بیشتر در تخمین داشت (۴). تعداد نوروها از ۲ تا ۲۰ متغیر بوده و بهترین تعداد ۳ نورو به‌روشن سعی و خطا تعیین

رابطه (۱):

$$R^2 = 1 - \frac{\Sigma(EC_{real} - EC_{predict})^2}{\Sigma(EC_{predict} - EC_m)^2}$$

رابطه (۲):

$$MAE = \frac{\Sigma |EC_{real} - EC_{predict}|}{n}$$

رابطه (۳):

$$RMSE = \sqrt{\frac{\Sigma(EC_{real} - EC_{predict})^2}{n}}$$

که در این روابط $EC_{predict}$: مقدار پیش‌بینی شده EC توسط مدل، EC_{real} : مقدار اندازه‌گیری EC در آزمایشگاه، EC_m : میانگین EC اندازه‌گیری شده و n : تعداد داده‌ها

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 فائو کلاس‌بندی شد (جدول ۲). براساس نتایج آزمایشگاهی حداکثر و حداقل هدایت الکتریکی منطقه اراضی بدون پوشش به‌ترتیب ۱۳۹/۱ و ۱۵۶/۵۶ دسی‌زیمنس بر متر بود. در این محدوده پس‌روی آب دریاچه باعث افزایش پوسته‌های نمکی و گسترش خاک‌های با کلاس شوری ۴ و ۵ در نزدیک دریاچه شده است. محدوده اطراف دریاچه غالباً

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 به‌ترتیب ۹۰/۱ و ۳۷۴/۰ 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 به‌ترتیب ۴/۲۷ و ۵۰۲/۰ 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

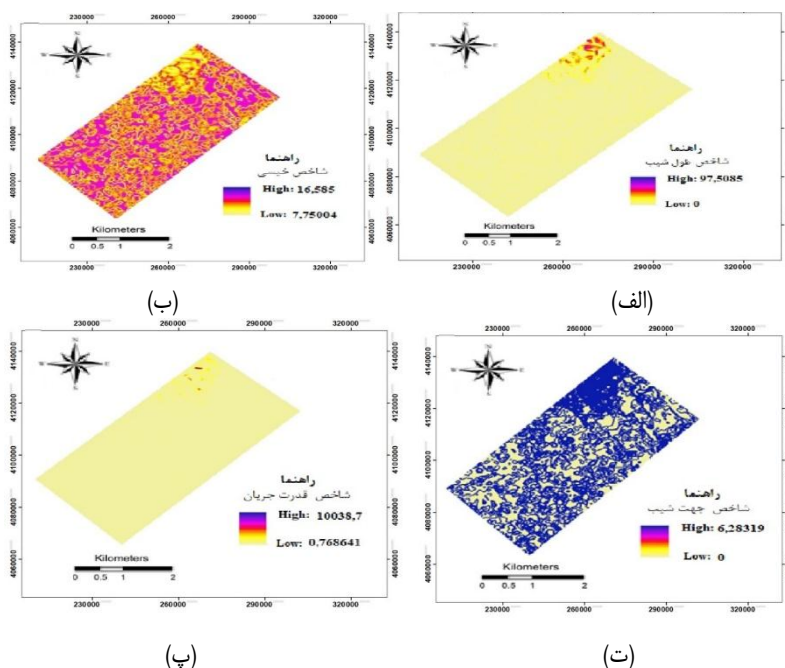
کلاس بندی FAO	باغ	تپه	دریاچه
۰-۲	۳۱	۱۸	۴
۲-۴	۱۸	۱	۲
۴-۸	۱	-	۲
۸-۱۶	-	-	۳
>۱۶	-	۱	۱۷

شاخص SAVI تنها زمانی برای ارزیابی شوری 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 زیادتیر از منطقه اراضی بدون پوشش و باغات می‌باشد، بنابراین میزان توپوگرافی همخوانی مثبتی با طول شیب، جهت شیب و قدرت جریان نشان می‌دهد. در حالی که با شاخص‌های خیزی خاک همبستگی منفی نشان می‌دهد که علت آن عدم نگهداشت سطحی آب در شیب‌های تند می‌باشد (۱). به‌علت مسطح بودن بیش از ۹۰ درصد ناحیه مورد مطالعه بعضی از شاخص‌های مدل رقومی ارتفاع مانند انحنا، نیرخ و انحنا، 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 منطقه داشتند نشان داده شده است. به‌طور کلی در منطقه مورد مطالعه شاخص‌های سنجش از دور در زمین‌های بدون پوشش و شوره‌زار کارایی بالاتری نسبت به کاربری‌های باغات و تپه برای تخمین شوری داشتند که با نتایج تقی‌زاده و همکاران (۱۸) مطابقت دارد. در کاربری باغ به‌علت متنوع بودن نوع محصول NDVI و سایر شاخص‌های پوشش گیاهی کارایی خوبی در تخمین شوری نداشتند و همچنین در کاربری تپه به‌علت شیب‌دار بودن آن شاخص‌های سنجش از دور به‌خوبی 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 تأثیر 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 NDSI و CRSI نتایج رضایت‌بخشی برای تعیین غلظت نمک‌های مختلف در سطوح خاک ارائه می‌دهند. عملکرد خوب شاخص‌های NDSI و CRSI 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 به‌دست آمده مشخص گردید که شاخص‌های SAVI و NDVI در مناطقی که پوشش گیاهی کم است نتایج ضعیفی در تخمین میزان هدایت الکتریکی دارند در حالیکه در این مناطق شاخص‌های شوری کارایی بالاتری دارند. فن و همکاران نیز دریافتند که شاخص‌های SAVI و NDVI در مناطق با پوشش گیاهی کم کارایی کمی در تخمین شوری دارند در حالیکه در این مناطق شاخص‌های شوری کارایی بالاتری در تخمین شوری دارند.



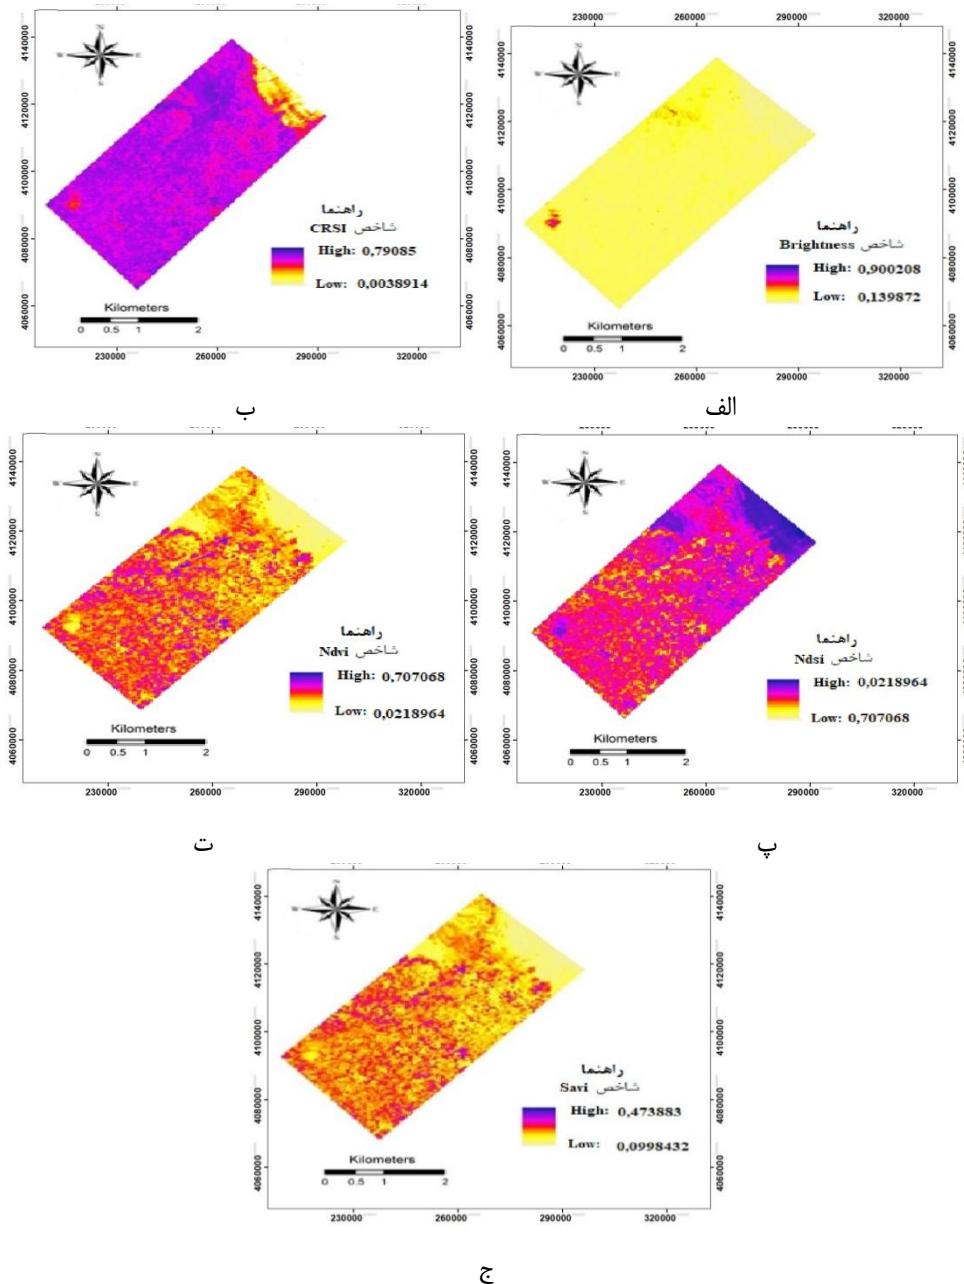
شکل ۲- الف، ب، پ و ت به‌ترتیب نقشه شاخص طول شیب، خیزی، قدرت جریان و جهت شیب استخراج شده از مدل رقومی ارتفاعی
Figure 2. A, B, C and D, respectively, slope length, wetness, flow strength and slope direction index map extracted from digital elevation model

مدل سازی

شبکه عصبی مصنوعی

کند. مدل شبکه عصبی مصنوعی با ساختار ۳۳۱ (قدرت جریان، طول شیب و شاخص CRSI به عنوان ورودی و EC به عنوان خروجی با یک لایه ساختار پنهان) بر اساس روش آزمون و خطا برای پیش بینی EC برای منطقه مورد مطالعه طراحی شد. مونچون و همکاران نیز در تحقیق خود به صحت و دقت نتایج بدست آمده از شبکه عصبی مصنوعی جهت پیش بینی شوری خاک اشاره کردند (۲). شکل ۴ نقشه شوری خاک منطقه براساس مدل را نشان می دهد (شکل ۴). بر اساس نقشه شوری خاک بدست آمده از مدل شبکه عصبی، بیشترین مقدار شوری در قسمت های شمالی و جنوبی منطقه و در کاربری اراضی بدون پوشش و باغها مشاهده می شود.

تعداد لایه های مخفی و تعداد نورون ها اجزای اصلی پرسپترون در شبکه های 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 نورون های لایه مخفی و تعداد اپوک در فرآیند آموزش به صورت سعی و خطا به دست آمد. براساس نتایج بدست آمده ساختار ۳-۳-۱ برای پیش بینی گروه خاک بهترین ساختار است. نتایج نشان داد مدل شبکه های عصبی ۶۹ درصد از تغییرات شوری خاک در منطقه مورد مطالعه را می تواند تفسیر



شکل ۳- الف، ب، پ، ت و ج به ترتیب نقشه های شاخص های CRSI، روشنایی، NDVI، NSDI و SAVI استخراج شده از تصاویر ماهواره ای منطقه

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


درخت تصمیم

در روش درخت تصمیم ابتدا متغیر مستقل EC برای برآورد به نرم‌افزار ترسیم رگرسیون درختی معرفی شدند. سپس متغیرهای موثر توسط نرم‌افزار انتخاب و بر اساس اولویت به‌طور متوالی به دو گره تقسیم شدند. بر این اساس، متغیرهای موثر برای درخت تصمیم Brightness، NDSI، SI، Carbon، Clay، S5، CRSI، Streampower انتخاب گردید. نخستین متغیر که درخت تصمیم انتخاب کرد و تنه 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. هرگره به دو گره فرزندی که در واقع

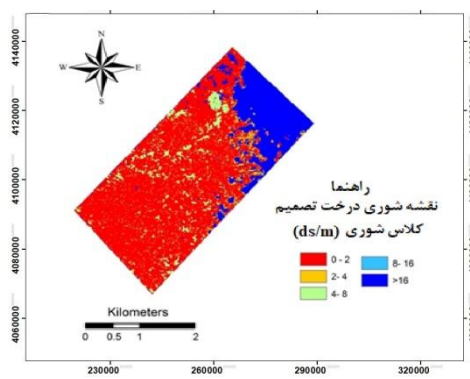
میانگین کلی از متغیر EC است تقسیم شد. مقدار متغیر تخمین زده شده در هر گره میانگینی از کل گره است. با حرکت به سمت گره‌های پایین‌تر، همگنی درگره افزایش و واریانس کاهش یافته و آن گره برآوردی دقیق‌تر از ویژگی EC را ارائه می‌دهد. شکل ۴ نقشه شوری حاصل از مدل درخت تصمیم را نشان می‌دهد (شکل ۴).

بر اساس 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 مشاهده 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.



(الف)



(ب)

شکل ۴- الف- نقشه رقمی شوری حاصل از شبکه عصبی و ب- نقشه رقمی 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 ۰/۴۶، ضریب کاپا ۰/۲۵ و صحت کلی ۵۲ 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 مجذور میانگین مربعات خطا (RMSE)، میانگین خطا (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.

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 نسبت به مدل شبکه عصبی با درصد ضریب کاپا (۸/۴۸) و صحت کلی (۱۶/۳۲) داشته و طبقه‌بندی نقشه رقمی را نسبت به این مدل دقیق‌تر ارائه می‌دهد. تقی‌زاده و همکاران (۱۷) نیز روش‌های شبکه عصبی مصنوعی و درخت تصمیم را برای تهیه نقشه رقمی خاک مقایسه کردند و دریافتند درخت

جدول ۳- شاخص‌های ارزیابی مدل‌ها

Table 3. Evaluation indicators of models

نام مدل	MAE	RMSE	R^2
شبکه عصبی	۱۱/۳۰	۱۸/۹۹	۰/۶۹
درخت تصمیم	۲/۷۶	۵/۸۹	۰/۹۸

درخت تصمیم با داشتن کمترین مجذور میانگین خطا و میانگین خطا و همچنین با داشتن بیشترین میزان ضریب تبیین مدل بهتری نسبت به شبکه عصبی برای پیش‌بینی شوری خاک در عمق ۰-۳۰ سانتی‌متر در منطقه می‌باشد.

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

نتیجه‌گیری کلی

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. به‌طور کلی براساس نتایج بدست آمده نشان داده شد که تکنیک‌های خاک آماری، به‌خصوص درخت تصمیم، می‌توانند فرآیند نقشه‌برداری خاک‌ها را در گستره‌ای وسیع و متشکل از هر گونه عوارض طبیعی به یک باره انجام دهند، روش سنتی را ارتقا بخشند، 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 رقومی خاک از مدل‌های درختی در مطالعات آینده استفاده شود.

منطقه مورد مطالعه به‌دلیل 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 به‌منظور 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 به‌عنوان 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. 2nd 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 Ahmadi¹, Aida Abbasi², Mahmood Shahabi³ and Abdolhossein Boali⁴

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 Resources 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