



۰۴۲۵۰-۳۲۰۳۱

مدیریت جامع نگر و هوشمند خاک و آب  
Holistic and Smart Soil and Water Management

دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران  
College of Agriculture & Natural Resources, University of Tehran



## مروری بر نقشه‌برداری شوری خاک توسط سنجش از دور نوری و راداری

لیلا اسماعیل نژاد<sup>۱\*</sup>، سعید سعادت<sup>۲</sup>، رسول میرخانی<sup>۳</sup>

۱ عضو هیات علمی، موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی؛ \*  
esmaeelnejad.leila@gmail.com

۲ و ۳ عضو هیات علمی، موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی

### چکیده

شوری از جمله مهم‌ترین محدودیت‌های منابع خاک و آب در بخش کشاورزی بوده که با فعالیت‌های بشری در حال گسترش روزافزون است. شناسایی وضع موجود شوری و تغییرات آن با چالش‌های بسیاری همانند تغییرپذیری بسیار زمانی، ترکیب شیمیایی متفاوت نمک‌ها، حساسیت بالا نسبت به مدیریت از جمله آبیاری در خاک‌های مختلف همراه می‌باشد. از دیگر سو هرگونه تصمیم‌گیری برای خاک‌های متأثر از شوری مستلزم نقشه‌برداری شوری خاکها با کم‌ترین هزینه و زمان می‌باشد. در سال‌های اخیر پیشرفت‌های چشم‌گیری در تشخیص، پیش‌بینی، کمی‌سازی و نقشه‌برداری شوری خاک توسط فناوری سنجش از دور فراهم شده است. از جمله این تکنیک‌ها، نقشه‌برداری مبتنی بر طبقه‌بندی، بهره‌گیری از شاخص‌های بیوفیزیکی و شاخص‌های طیفی، پتانسیل داده‌های راداری، و رگرسیون یادگیری ماشین می‌باشد. نتایج مطالعات مختلف نشان داده که شاخص‌های رایج شوری نسبت به زمان و مکان بسیار حساس بوده و برای کاربرد گسترده فاقد پایداری هستند. لذا بهتر است از سایر شاخص‌های کمکی همانند <sup>۱</sup>LST و شاخص‌های پوشش گیاهی (مانند <sup>۲</sup>GDVI، <sup>۳</sup>NDVI، <sup>۴</sup>SAVI، <sup>۵</sup>EVI، <sup>۶</sup>ARVI، <sup>۷</sup>COSRI و غیره برای این هدف استفاده شود. اگر چه داده‌های راداری پتانسیل بسیار بالایی در برآورد شوری خاک دارند، اما مجموعه داده‌های راداری-نوری ترکیبی، در پیش‌بینی و نقشه‌برداری دارای دقت و صحت بالاتری هستند. در استفاده از داده‌های راداری-نوری ترکیبی بهره‌گیری از تکنیک‌های رگرسیون یادگیری ماشین، به‌ویژه، <sup>۸</sup>RFR برای نقشه‌برداری دقیق‌تر شوری خاک توصیه می‌شود.

**واژگان کلیدی:** کیفیت آب آبیاری، شاخص خطر منیزیم، خاک‌های کشاورزی، استان البرز

### مقدمه

شوری خاک در واقع عبارت است از وجود املاح محلول در خاک به اندازه‌ای که بتواند رشد گیاه را تحت تأثیر قرار داده و باعث کاهش آن یا ایجاد محدودیت در رشد و عملکرد آن شود. با این تعریف، شوری، ویژگی‌هایی از خاک و یا آب را بیان می‌کند که گیاه محور بوده و با توجه به ویژگی‌های فیزیولوژیکی و مقدار تحمل گیاه، مقدار و میزان اثربخشی آن می‌تواند برای گیاهان مختلف متفاوت باشد (سعادت و همکاران، ۱۳۹۸ و Saadat, et al., 2020). شوری خاک با تجمع نمک‌ها در ناحیه ریشه‌ها از طریق تأثیر بر پتانسیل اسمزی، جذب آب توسط ریشه و اثرات ویژه یونی بر رشد و نمو گیاه تأثیر می‌گذارد (Saadat et al., 2020). شوری خاک یک خطر زیست محیطی متداول در اراضی آبی جهان، به‌ویژه در مناطق خشک و نیمه خشک است (Metternicht and Zinck 2003; Farifteh et al., 2006). بر اساس اطلاعات موجود، حدود ۲۰ درصد از اراضی آبی جهان تحت تأثیر شوری قرار دارند و این سطح در ایران و مصر به بیش از ۳۰ درصد افزایش می‌یابد (Metternicht and Zinck, 2003). در ازبکستان حدود ۵۰ درصد اراضی (Qadir et al., 2009; Ivushkin et al., 2017) و در بین‌النهرین عراق حدود ۶۰ درصد از اراضی آبی شور هستند (Buringh 1960; Wu et al., 2014a). شوری خاک از طریق افزایش فشار

<sup>1</sup> Land surface temperature

<sup>2</sup> Generalized difference vegetation index

<sup>3</sup> Normalized difference vegetation index

<sup>4</sup> Soil-adjusted vegetation index

<sup>5</sup> Enhanced vegetation index

<sup>6</sup> Atmospherically resistant vegetation index

<sup>7</sup> Combined spectral response index

<sup>8</sup> Random forest regression



۰۴۲۵۰-۳۲۰۳۱

مدیریت جامع نگر و هوشمند خاک و آب  
Holistic and Smart Soil and Water Management

دانشکده کشاورزی و منابع طبیعی دانشگاه تهران  
College of Agriculture & Natural Resources, University of Tehran



اسمزی باعث اختلال در رشد گیاهان می‌شود. طبق آمار ارائه شده (Wu *et al.*, 2014a, 2018) تولید محصولات زراعی در بین النهرین عراق، در خاکهای متأثر از نمک در مقایسه با زمین‌های زراعی غیرشور ۶۰-۳۰ درصد کاهش یافته است. بنابراین، بررسی شدت و توزیع مکانی و زمانی شوری خاک جهت ارائه توصیه‌های کارشناسی به تصمیم‌گیرندگان در برنامه‌ریزی توسعه کشاورزی از اهمیت بالایی برخوردار است. به‌طور سنتی، ارزیابی و نقشه‌برداری شوری خاک با بررسی خاک و درون‌یابی نتایج تحلیلی نمونه‌های خاک انجام می‌شود که به زمان و سرمایه زیادی نیاز دارد (Ghabour and Daels, 1993) و تنها در یک منطقه کوچک قابل انجام است (Wu *et al.*, 2014b). چنین وضعیتی با ظهور فناوری سنجنش از دور در دهه ۱۹۷۰ تغییر کرد. تکنیک سنجنش از دور امکان و فرصتی را برای نقشه‌برداری و ارزیابی شوری خاک به‌طور کارآمدتر و اقتصادی‌تر از مقیاس محلی به مقیاس منطقه‌ای فراهم کرده است (Garcia *et al.* 2005; Wu *et al.* 2014a, b). محققان زیادی از تکنیک سنجنش از دور برای بررسی شوری خاک استفاده کردند (Mougenot *et al.*, 1993; Metternicht and zink, 2003; Allbed and Kumar, 2013; Gorji *et al.*, 2015). با این حال، با توسعه رویکردها و الگوریتم‌های جدید فرصتهای جدیدی برای افزایش صحت و دقت در ارزیابی شوری فراهم شده است. سنجنش از دور نوری بر بازتابش نور استوار می‌باشد. مقدار و نوع نمک‌ها، رطوبت خاک، رنگ و زبری سطح و حتی زاویه ارتفاع خورشید از عوامل اصلی موثر بر بازتاب می‌باشند (Mougenot *et al.*, 1993). غالباً تشخیص شوری توسط سنجنش از دور نوری امری دشوار است (Farifteh *et al.*, 2006; Wu *et al.*, 2014b). با این حال، می‌توان با اندازه‌گیریهای ژئوفیزیک و استفاده از ابزار الکترومغناطیسی EM38 و سنجنش از دور راداری (Wu *et al.* 2014a, b, 2018, 2019) این محدودیت را کاست. زیرا هر دو تکنیک سنجنش از دور نوری و راداری قابل استفاده برای اعماق تا ۵/۰ تا ۱/۵ متر هستند. از این رو، در این نوشتار سعی خواهد داشت عوامل و روشهای پیشرفته جدید مورد بررسی قرار گیرند. به‌طور کلی برای سنجنش از راه دور دو نوع بازتاب نوری و راداری مورد سنجنش قرار می‌گیرد. در روش دورسنجی نوری عمدتاً از دو تکنیک کلی طیفه بندی و شاخصهای طیفی و بیوفیزیکی استفاده می‌شود.

### نقشه‌برداری مبتنی بر طبقه‌بندی

یکی از مرسوم‌ترین کاربردهای سنجنش از دور، نقشه‌برداری شوری خاک از طریق رویکردهای طبقه‌بندی است. برخی از محققین طبقه‌بندی تصاویر را برای تهیه نقشه خاک‌های متأثر از نمک و خاک‌های گچی انجام دادند (Dale *et al.*, 1986; Singh and Dvivedi, 1989; Goosness and van Ranst, 1989). برخی محققین، بهترین ترکیب باندی (مثلاً باندهای ۱۳۵ لندست TM) یا ترکیب باندی بهینه (مانند TM 234 به علاوه باند حرارتی) را برای نقشه‌برداری خاک‌های متأثر از نمک پیشنهاد کردند (Dwivedi and Rao, 1992; Verma *et al.*, 1994). Rodriguez و همکاران (Rodriguez *et al.*, 2007) PCA<sup>9</sup> و NDVI را برای این هدف معرفی کردند. در حالی که Furby و همکاران (Furby *et al.*, 2010) این کار را با استفاده از داده‌های لندست TM همراه با DEM<sup>10</sup> و مشتقات آن انجام دادند. آنها به این نتیجه رسیدند که ادغام داده‌های DEM می‌تواند دقت طبقه‌بندی را بهبود بخشد. برخلاف نویسندگان فوق، Garcia و Eldeiry (Garcia and Eldeiry, 2010) بهترین ترکیب باند لندست مثل NDVI را با استفاده از روش‌های کریجینگ مختلف برای درون‌یابی پیکسل‌های نمونه‌برداری نشده در حین تهیه نقشه شوری خاک در زمین‌های زراعی مختلف آزمایش کردند. نتایج آنها نشان داد که باندهای R<sup>11</sup>، NIR<sup>12</sup> و NDVI بهترین ترکیب باندی برای تهیه نقشه شوری اراضی تحت کشت یونجه و NIR، TIR<sup>13</sup> و NDVI برای اراضی تحت کشت ذرت و B همراه با TIR برای گندم هستند. در بین رویکردهای مختلف کریجینگ، یعنی کریجینگ معمولی (OK)، کریجینگ رگرسیون (RK) و کوکریجینگ (CK)، مدل OK بهترین عملکرد را داشت. Douaoui و همکاران (Douaoui and Bannari, 2006) نیز نتیجه مشابهی را به دست آوردند و بر این اساس، OK از دیگر روش‌های رگرسیون و طبقه‌بندی عملکرد بهتری داشت. Bannari و همکاران (Bannari *et al.*, 2018) پیشنهاد کردند که از باندهای ۱ و ۳<sup>14</sup> SWIR از ماهواره

<sup>9</sup> Pricipal component analysis

<sup>10</sup> Digital elevation model

<sup>11</sup> Red

<sup>12</sup> Near infrared

<sup>13</sup> Termal infrared

<sup>14</sup> Shortwave infrared



۰۴۲۵۰-۳۲۰۳۱

مدیریت جامع نگر و هوشمند خاک و آب  
Holistic and Smart Soil and Water Management

دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران  
College of Agriculture & Natural Resources, University of Tehran



Sentinel-2 (ابزار چند طیفی) و داده‌های Landsat 8 OLI برای تمایز و مدل‌سازی شوری خاک استفاده شود، زیرا نسبت به سایر باندهای VNIR<sup>۱۵</sup> با شوری اندازه‌گیری شده همبستگی بهتری دارند. جدا از طبقه‌بندی‌کننده‌های معمولی مانند ML<sup>۱۶</sup> (Wu and Zhang, 2003; Wu et al. 2016) و همکاران (۱۹۹۸) از چندین طبقه‌بندی‌کننده یادگیری ماشین، یعنی C4.5 مبتنی بر درخت تصمیم (یک یادگیری استقرایی)، IBL<sup>۱۷</sup> (بر اساس نزدیک‌ترین همسایه)، یادگیری نمونه‌ای چندگذری (MPIL<sup>۱۸</sup>) و پس‌انتشار (شبکه‌های عصبی) برای نقشه‌برداری شوری ثانویه خاک با استفاده از Landsat TM، داده‌های ژئومورفیک و زمین‌شناسی آب استفاده کردند. آنها دریافتند که الگوریتم C4.5 که مبتنی بر درخت تصمیم است از بقیه عملکرد بهتری داشت. Cai و همکاران (۲۰۱۰) از SVM (Vapnik and Lerner, 1963 و 1963) برای طبقه‌بندی خاک‌های متأثر از نمک بر اساس ویژگی‌های بافت استفاده کردند. Wu و Zhang (۲۰۰۳) و Wu و همکاران (۲۰۱۶) از طبقه‌بندی‌کننده‌های معمولی و الگوریتم‌های یادگیری ماشین مانند ANN<sup>۱۹</sup>، SVM<sup>۲۰</sup> و RF (Breiman, 2001) برای نقشه‌برداری دقیق پوشش زمین و تعیین مناطق شور یا در حال شور شدن استفاده کردند. در تحقیقات آنها، علاوه بر باندهای TM ۱۴۷ فاقد همبستگی (Wu and Zhang, 2003)، GDVI (Wu, 2014)، LST، ویژگی‌های مشتق شده از DEM، و ویژگی‌های فنولوژیکی پوشش گیاهی نیز در نظر گرفته شدند. در نهایت، دقت نقشه‌برداری مطالعه فوق‌الذکر بسیار بالا با ضریب تبیین ۹۵-۹۶ درصد گزارش شده است. یک روش جدید در طبقه‌بندی تصاویر، یادگیری عمیق است (Dechter 1986; LeCun et al. 2015) که توسط الگوریتم CNN<sup>۲۱</sup> نشان داده می‌شود (Matusugu et al. 2003; Ciresan et al. 2011; Krizhevsky et al. 2012; LeCun et al. 2015). بر اساس نتیجه تحقیقات مختلف، CNN می‌تواند به طبقه‌بندی دقیق دست یابد. از این رو، می‌تواند یک برنامه کاربردی بالقوه برای تهیه نقشه شوری خاک به‌عنوان یک طبقه بندی مکمل برای SVM و RF باشد.

شاخص‌های طیفی و شاخص‌های بیوفیزیکی برای تشخیص و نقشه‌برداری شوری

در دهه‌های گذشته، در حالی که تلاش‌هایی برای نشان دادن پاسخ طیفی خاک‌های متأثر از نمک انجام شد (Mougenot et al., 1993; Major et al., 1990; Steven et al., 1992; Brunner et al., 2007; Lobell et al., 2010; Rao et al., 1995)، برخی از محققان (Wu et al., 2014a,b; Mokarram et al., 2015; Zhang et al., 2015; Rahmati and Hamzehpour, 2017; Paliwal et al., 2018, 2019; Wu et al., 2018, 2019) شاخص‌های مختلف پوشش گیاهی (VIs) نظیر SAVI و NDVI (Huete, 1988)، SARVI و ARVI (Kaufman and Tanré 1992)، OS-AVI (Rondeaux et al., 1996)، EVI (Huete et al., 1997; Huete et al., 2002) و GDVI (Wu, 2014) و غیره را برای تشخیص و نقشه‌برداری شوری خاک اعمال کردند. در عین حال، محققان دیگری نیز به‌همین منظور، برخی شاخص‌های خاص شوری را پیشنهاد کرده‌اند که در اینجا به نمونه‌هایی اشاره می‌کنیم. Hardisky و همکاران (۱۹۸۳) و Steven و همکاران (۱۹۹۲) از NDII<sup>۲۲</sup> (TM4 و TM5) و ND23 (تفاضل نرمال شده بین TM2 و TM3) برای تجزیه و تحلیل تنش تاج پوشش گیاهی ناشی از شوری یا کلروز استفاده کردند و دریافتند که NDII (TM4 و TM5) بهترین عملکرد را دارد. Khan و همکاران (۲۰۰۱)، Alkhair (۲۰۰۳)، Khan و همکاران (۲۰۰۵)، Douaoui و همکاران (۲۰۰۶)، Iqbal (۲۰۱۱) و Elhag (۲۰۱۶) چندین شاخص شوری (SI<sup>۲۳</sup>) را پیشنهاد کرده‌اند. Fernandez-Buces و همکاران (۲۰۰۶) نیز یک شاخص پاسخ طیفی ترکیبی (COSRI) بر اساس NDVI توسعه دادند. این شاخص‌ها در جدول یک ارائه شده است.

جدول یک- شاخص‌های شوری (SI) و پوشش گیاهی (VI)

نام شاخص	رابطه طیفی	منبع
----------	------------	------

<sup>15</sup>Visible and near infrared

<sup>16</sup> Maximum likelihood

<sup>17</sup> Instance-based learning

<sup>18</sup> Multi-pass instance learning

<sup>19</sup> Artificial neural network

<sup>20</sup> Support vector machines

<sup>21</sup> Convolutional neural networks

<sup>22</sup> Normalized difference infrared index

<sup>23</sup> Salinity index



۰۴۲۵۰-۳۲۰۳۱

مدیریت جامع نگر و هوشمند خاک و آب  
Holistic and Smart Soil and Water Management

دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران  
College of Agriculture & Natural Resources, University of Tehran



SI1	$SI1=(B \times R)^{1/2}$	Khan <i>et al.</i> , (2001) Khan <i>et al.</i> , (2005)
SI2	$SI2=(G \times R)^{1/2}$	Khan <i>et al.</i> , (2005)
SI3	$SI3=(R \times NIR)^{1/2}$	Wu, (2019)
SI4	$SI4=[(G)^2+(R)^2+(NIR)^2]^{1/2}$	Douaoui <i>et al.</i> , (2006)
SI5	$SI5=[(G)^2+(R)^2]^{1/2}$	Douaoui <i>et al.</i> , (2006)
SI6	$SI6=(SWIR1-SWIR2)/(SWIR1+SWIR2)$	Al-Khaier (2003)
SI7	$SI7=(SWIR1-NIR)/(SWIR1+NIR)$	Al-Khaier (2003)
SI8	$SI8=(NIR \times R)/G$	Elhag (2016)
BI	$BI=[(R)^2+(NIR)^2]^{1/2}$	Khan <i>et al.</i> , (2001) Khan <i>et al.</i> , (2005)
NDII	$(NIR-SWIR1)/(NIR+SWIR1)$	Hardisky <i>et al.</i> , (1983) Steven <i>et al.</i> , (1992)
ND23	$(G-R)/(G+R)$	Steven <i>et al.</i> , (1992)
ND47	$(NIR-SWIR2)/(NIR+SWIR2)$	Steven <i>et al.</i> , (1992)
NDSI	$(TIR-NIR)/(TIR+NIR)$	Iqbal (2011)
COSRI	$[(B+G)/(R+NIR)]$	(2006) Fernandez-Buces <i>et al.</i> ,

نکته: باندهای Landsat TM شامل: B آبی، G سبز، R قرمز، NIR نزدیک مادون قرمز، SWIR1 ( $\lambda=1.65$  میکرومتر) باند مادون قرمز موج کوتاه ۵، SWIR2 ( $\lambda=2.16$  میکرومتر) باند مادون قرمز موج کوتاه ۷ و TIR مادون قرمز حرارتی

Gorji و همکاران (۲۰۱۵) در مطالعه‌ای در دریاچه توز ترکیه، به این نتیجه رسیدند که SI1 و پس از آن SI2 بهترین همبستگی را با شوری اندازه‌گیری شده نشان دادند. Elhag (۲۰۱۶) دریافت که برای پیش‌بینی و تهیه نقشه شوری خاک‌های منطقه وادی الدواسیر عربستان سعودی، SI8 بهترین عملکرد را نسبت به SI های دیگر دارد و پس از آن SI4 و BI قرار داشتند. اما همان‌طور که در جداول دو و سه دیده می‌شود، شاخص‌های شوری در دو مکان در مرکز عراق عملکرد متفاوتی داشتند. به‌عنوان مثال، SI1، SI4، SI8 در سایت Dujaila معنی‌دار بودند، در حالی که در سایت Mussiab کارکرد مناسبی نداشتند. همچنین شاخص‌های BI و NDSI<sup>۲۴</sup> رابطه خوبی با شوری خاک نشان ندادند. برعکس، NDII<sup>۴۵</sup> ارائه شده توسط Hardisky و همکاران (۱۹۸۳) یا نسخه معکوس آن از Al-Khaier (۲۰۰۳) و COSRI از جمله شاخص‌های شوری پایدار در بین شاخص‌های شوری مختلف بودند. بر اساس داده‌های فراطیفی، Zhang و همکاران (۲۰۱۱) تعدادی از شاخص‌های شوری خاک تعدیل شده (SASI<sup>۲۵</sup>) را پیشنهاد کردند که عملکرد بهتری نسبت به NDVI و SAVI دارند. هنگام استفاده از داده‌های فراطیفی، این SASI ها ممکن است برای ارزیابی شوری خاک استفاده شوند. به‌طور خلاصه، برای داده‌های ماهواره‌ای پهن باند، VI ها مانند SAVI، EVI، ARVI<sup>۲۶</sup> و SARVI<sup>۲۷</sup> به خوبی با شوری همبستگی دارند، با این حال، GDVI ها بهترین عملکرد را داشته‌اند (Wu *et al.* 2014a, b, 2019). از این رو، VI<sup>۲۸</sup> و SI های توصیه شده برای تشخیص و نقشه‌برداری شوری شامل LST، GDVI2، GDVI3، NDVI، NDII<sup>۴۵</sup> و COSRI هستند که در بین تمام سایت‌های مطالعاتی، عملکرد تقریباً ثابت و پایداری داشتند.

#### کاربرد داده‌های راداری

در دهه‌های گذشته تلاش زیادی برای استفاده از داده‌های راداری در نقشه‌برداری شوری خاک صورت گرفته است. پتانسیل استفاده از باندهای میکروویو P، C و به‌ویژه، L برای تشخیص شوری در تنظیمات مختلف مورد بررسی قرار گرفته است (Singh and Srivastav (1990)، (1990)، Singh *et al.*, (1990)، Sreenivas *et al.*, (1995)، Taylor *et al.*, (1996)، Shao *et al.*, (2003)، Aly *et al.*, (2004).

<sup>24</sup> Normalized difference salinity index

<sup>25</sup> Soil adjusted salinity indices

<sup>26</sup> Atmospherically resistant vegetation index

<sup>27</sup> Soil-adjusted and atmospherically resistant vegetation index

<sup>28</sup> Vegetation indices



۰۴۲۵۰-۳۲۰۳۱

مدیریت جامع نگر و هوشمند خاک و آب

Holistic and Smart Soil and Water Management

دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران

College of Agriculture & Natural Resources, University of Tehran



Lasne et al., (2008), Shao و همکاران (۲۰۰۳) و Gong و همکاران (۲۰۱۳) دریافتند که شوری خاک سهم قابل توجهی در ضریب پس انتشار RADARSAT SAR دارد، زیرا سیگنال‌های آن می‌توانند از سطح خاک نفوذ کرده و بسته به ویژگی‌های خاک و رطوبت به عمق ۲-۱/۵ متری خاک نیز برسند. استقلال از شرایط جوی، از جمله برتری‌های رادارها نسبت به سنسورهای ماهواره‌ای نوری و فرورسرخ است. در حالی که بخش واقعی مستقل از شوری و قلیائیت خاک است، بخش تصویری به تغییر هر دو ویژگی هدایت الکتریکی و رطوبت خاک بسیار حساس بوده و همین امر باعث تمایز خاک‌های شور از بقیه می‌شود. با این حال، Mougenot و همکاران (۱۹۹۳) بیان کردند نقطه ضعف کاربرد رادار این است که توصیف خاک‌های شور، با استفاده از ثابت‌های دی‌الکتریک پیچیده تعیین شده توسط تکنیک‌های وارونگی پس‌انتشار راداری، به برخی از داده‌های رطوبت خاک نیاز دارد. احتمالاً به دلیل دشواری جداسازی یا بازیابی شوری از رطوبت خاک، شناسایی موفق شوری بر اساس رادار و مطالعات نقشه‌برداری به ندرت گزارش شده است. Wu و همکاران (۲۰۱۸)، از داده‌های رادار باند ALOS-L، از تصاویر Landsat TM که همزمان با تصاویر رادار به دست آمده بودند، برای تصحیح یا به حداقل رساندن تأثیر پوشش گیاهی بر ضرایب پس انتشار بر اساس مدل ابر-آب پیشنهاد شده توسط (Ulaby و Attema، ۱۹۷۸) استفاده کردند. در این روش کمینه‌سازی، لازم بود توصیف‌کننده‌های تاج پوشش گیاهی V1 و V2 به دست آید که به ترتیب با شاخص سطح برگ (LAI) و محتوای آب گیاهی (VWC) نشان داده شدند (Kumar et al., (2012)). آنها از مدل LAI-GDVI (Wu et al., 2014) برای محاسبه LAI (V1) و مدل Jackson VWC-NDVI و همکاران (۲۰۰۴) برای محاسبه VWC (V2) استفاده کردند. با توجه به پارامترهای پوشش گیاهی، A و B، از داده‌های راداری باند L برای پردازش کمینه‌سازی انتخاب شدند (Wu et al., 2019). پس از حذف یا اصلاح پوشش گیاهی، ضرایب بازیابی پس‌انتشار خاک به شدت با شوری خاک اندازه‌گیری شده، همبستگی داشت ( $R^2=0.1565-0.1677$ ). این تصحیح، همبستگی بین ضرایب پس انتشار راداری خاک و شوری خاک اندازه‌گیری شده را به ترتیب ۲۵/۶-۱۶/۶٪، برای HH و ۲۱/۴-۱۱/۵٪، برای باندهای پلاریزه شده HV بهبود بخشید. نقشه‌های شوری خاک مبتنی بر داده‌های راداری با دقت ۷۰ تا ۷۹ درصد تهیه شدند. به همین دلیل، قرائت‌های EM38 (اندازه‌گیری ژئوفیزیک) و داده‌های راداری باند L ترکیبی ایده‌آل برای تشخیص شوری خواهند بود زیرا هر دوی آنها می‌توانند شوری را تا عمق خاک نشان دهند و بر کمبودهای داده‌های نوری غلبه کنند. افزون بر این، Wu و همکاران (۲۰۱۸، ۲۰۱۹) نشان دادند که حذف یا به حداقل رساندن تأثیرات پوشش گیاهی از مجموع ضرایب پس‌انتشار به جای جدا کردن شوری از رطوبت در بخش تصویری داده‌های رادار، عملی‌تر به نظر می‌رسد.

رگرسیون یادگیری ماشین

الگوریتم‌های مختلفی مانند ANN، SVM، RF و C4.5 به عنوان الگوریتم‌های یادگیری ماشینی رگرسیونی قوی برای نقشه‌برداری شوری خاک استفاده شده‌اند. Farifteh و همکاران (۲۰۰۷) از PLSR و ANN، Taghizadeh-Mehrjardi و همکاران (۲۰۱۴) از درخت رگرسیون و Wu و همکاران (۲۰۱۸) از SVR و RFR برای پیش‌بینی و نقشه‌برداری شوری استفاده کردند. با مقایسه رایج‌ترین الگوریتم‌های یادگیری ماشین، Wilkinson (۲۰۰۵)، Mas and Flores (2008) و Wu و همکاران (۲۰۱۶) دریافتند که ANN اغلب نسبت به سایر الگوریتم‌ها مانند SVM و RF و حتی ML عملکرد بهتری دارد. الگوریتم PLSR در سایت Mussaib در مرکز عراق آزمایش شد، اما دقت پیش‌بینی ایده‌آل نبود و بسیار کمتر از RFR و SVR بود (Wu et al., 2018). بنابراین، هر دو الگوریتم PLSR و ANN برای پیش‌بینی شوری خاک توصیه نمی‌شود. همچنین Taghizadeh-Mehrjardi و همکاران (۲۰۱۴) شوری ظاهری خاک اندازه‌گیری شده توسط EM38 را به عنوان یکی از متغیرهای مستقل و نه به عنوان داده‌های واقعی برای آموزش یا اعتبارسنجی در نظر گرفتند، و همین موضوع یکی از محدودیتهای این مطالعه است. بیشتر پیکسل‌های لایه شوری ظاهری خاک از قرائت‌های EM38 درون‌یابی شدند، و اعتبار چنین داده‌های درون‌یابی به عنوان ورودی برای مدل‌سازی مشکوک است. با توجه به این موارد، Wu و همکاران (۲۰۱۸) از الگوریتم‌های رگرسیون SVR و RFR برای پیش‌بینی شوری خاک با استفاده از مجموعه داده‌های رادار TM و باند L نلدست ترکیبی استفاده کردند. بدین منظور، به حداقل رساندن تأثیر پوشش گیاهی فوق به منظور بازیابی ضرایب پس‌انتشار خاک انجام شد و شوری ظاهری خاک (mS/m) اندازه‌گیری شده به عنوان مجموعه آموزشی (TS) برای مدل‌سازی در نظر گرفته شد. آنها دریافتند که هر دو الگوریتم های RFR و SVR می‌توانند به پیش‌بینی شوری مربوطه دست یابند اما RFR به لحاظ دارا بودن دقت بالاتر و خطای میانگین ریشه مربعات نرمال شده کمتر، عملکرد بهتری داشت. همچنین، آنها بیان کردند که MLR می‌تواند با داشتن NRMSE کمتر از SVR نقشه‌های شوری خوبی با استفاده از مجموعه



۰۴۲۵۰-۳۲۰۳۱

مدیریت جامع نگر و هوشمند خاک و آب  
Holistic and Smart Soil and Water Management

دانشکده کشاورزی و منابع طبیعی دانشگاه تهران  
College of Agriculture & Natural Resources, University of Tehran



داده‌های ترکیبی رادار نوری ایجاد کند. مزیت دیگر MLR، ظرفیت آن برای ارائه مدل‌های دیداری قابل اعمال در مکان‌های دیگر است. از این‌رو، آنها استفاده از RFR و MLR را برای کمی‌سازی و نقشه‌برداری شوری خاک توصیه کردند.

### نتیجه‌گیری کلی

با توجه به فن تشخیص و نقشه‌برداری شوری خاک توسط فناوری سنجنش از دور، الگوریتم CNN باید برای نقشه‌برداری مبتنی بر طبقه‌بندی، تطبیق و توسعه یابد. شاخص‌های شوری نسبت به مکان حساس بوده و برای کاربرد گسترده فاقد پایداری هستند و بهتر است از LST و شاخص‌های پوشش گیاهی مانند GDVI, NDVI, SAVI, EVI, ARVI, COSRI و غیره برای این هدف استفاده شود. داده‌های راداری پتانسیل بسیار بالایی دارند، اما مجموعه داده‌های رادار نوری ترکیبی، به پیش‌بینی و نقشه‌برداری بهتر با دقت بیشتر منتج می‌شوند. رگرسیون یادگیری ماشین، به‌ویژه، RFR برای نقشه‌برداری دقیق شوری خاک توصیه می‌شود.

### منابع:

- ۱) سعادت، س. ۱۳۹۸. گزارش نهایی طرح پایش کیفیت خاک‌های کشاورزی. مؤسسه تحقیقات خاک و آب. سازمان تحقیقات، آموزش و ترویج کشاورزی.
- 2) Al-Khaier F (2003) Soil salinity detection using satellite remote sensing (MS Thesis), ITC (International Institute for Geo-information Science and Earth Observation), The Netherlands.
- 3) Allbed A, Kumar L (2013) Soil salinity mapping and monitoring in arid and semi-arid regions using remote sensing technology: a review. *Adv Remote Sens* 2:373–385
- 4) Aly Z, Bonn FJ, Magagi R (2004) Modelling the backscattering coefficient of salt-affected soils: application to Wadi El-Natron bottom, Egypt. *EARSel eProceedings* 3, 3/2004, pp 372–381.
- 5) Attema EPW, Ulaby FT (1978) Vegetation modeled as a water cloud. *Radio Sci J* 13:357–364. Bannari A, El-Battay A, Bannari R, Rhinane H (2018) Sentinel-MSI VNIR and SWIR bands sensitivity analysis for soil salinity discrimination in an arid landscape. *Remote Sens* 10:855. <https://doi.org/10.3390/rs10060855>
- 6) Breiman L (2001) Random forests. *Mach Learn* 45(1):5–32. <https://doi.org/10.1023/A:1010933404324>
- 7) Brunner P, Li HT, Kinzelbach W, Li WP (2007) Generating soil electrical conductivity maps at regional level by integrating measurements on the ground and remote sensing data. *Int J Remote Sens* 28:3341–3361
- 8) Buringh P (1960) Soils and soil conditions in Iraq. Ministry of Agriculture of Iraq (337 pp)
- 9) Cai S, Zhang R, Liu L, Zhou D (2010) A method of salt-affected soil information extraction based on a support vector machine with texture features. *Math Comput Model* 51:1319–1325. <https://doi.org/10.1016/j.mcm.2009.10.037>
- 10) Ciresan D, Meier U, Masci J, Gambardella LM, Schmidhuber J (2011) Flexible, high performance convolutional neural networks for image classification. In: *Proceedings of the twenty-second international joint conference on Artificial Intelligence*, vol 2, pp 1237–1242.
- 11) Dabrowska-Zielinska K, Inoue Y, Kowalik W, Gruszczynska M (2007) Inferring the effect of plant and soil variables on C- and L-band SAR backscatter over agricultural fields, based on model analysis. *Adv Space Res* 39:139–148
- 12) Dale PER, Hulsman K, Chandica AL (1986) Classification of reflectance on colour infrared aerial photographs and sub-tropical salt-marsh vegetation types. *Int J Remote Sens* 7(12):1783–1788.
- 13) Dechter R (1986) Learning while searching in constraint-satisfaction-problems. *AAAI-86 proceedings*, pp 178–183. University of California
- 14) Douaoui AEK, Nicolas H, Walter C (2006) Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data. *Geoderma* 134:217–230
- 15) Dwivedi RS (1989) Delineation of salt-affected soils through digital analysis of Landsat MSS data. *Int J Remote Sens* 10(1):83–92. <https://doi.org/10.1080/01431168908903849> Singh RP, Srivastav SK (1990) Mapping of waterlogged and salt affected soils using microwave radiometers. *Int J Remote Sens* 11:1879–1887
- 16) Dwivedi RS, Rao BRM (1992) The selection of the best possible Landsat TM band combination for delineating salt-affected soils. *Int J Remote Sens* 13:2051–2058.
- 17) Eklund PW, Kirkby SD, Salim A (1998) Data mining and soil salinity analysis. *Int J Geogr Inf Sci* 12(3):247–268



19<sup>th</sup> Iranian Soil Science Congress  
2-4 December, 2025



نوزدهمین کنگره علوم خاک ایران  
۱۱ تا ۱۳ آذرماه ۱۴۰۴



۰۴۲۵۰-۳۲۰۳۱

مدیریت جامع نگر و هوشمند خاک و آب  
Holistic and Smart Soil and Water Management

دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران  
College of Agriculture & Natural Resources, University of Tehran



- 18) Eldeiry AA, Garcia LA (2010) Comparison of ordinary kriging, regression kriging, and cokriging techniques to estimate soil salinity using Landsat images. *J Irrig Drain Eng* 136:355–364
- 19) Elhag M (2016) Evaluation of different soil salinity mapping using remote sensing techniques in arid ecosystems, Saudi Arabia. *J Sens*, 2016, Article ID: 7596175, 8 pages.
- 20) Farifteh J, Farshad A, George RJ (2006) Assessing salt-affected soils using remote sensing, solute modelling, and geophysics. *Geoderma* 130(3–4):191–206
- 21) Farifteh J, van der Meer F, Atzberger C, Carranza E (2007) Quantitative analysis of salt affected soil reflectance spectra: a comparison of two adaptive methods (PLSR and ANN). *Remote Sens Environ* 110:59–78
- 22) Fernández-Buces N, Siebe C, Cram S, Palacio JL (2006) Mapping soil salinity using a combined spectral response index for bare soil and vegetation: a case study in the former lake Texcoco, Mexico. *J Arid Environ* 65:644–667
- 23) Furby S, Caccetta P, Wallace J (2010) Salinity monitoring in Western Australia using remotely sensed and other spatial data. *J Environ Qual* 39:16–25
- 24) Garcia L, Eldeiry A, Elhaddad A (2005) Estimating soil salinity using remote sensing data. In: *Proceedings of the 2005 central plains irrigation conference*, pp 1–10. Available at: <http://www.ksre.ksu.edu/irrigate/OOW/P05/Garcia.pdf>. Accessed Jan 2013
- 25) Ghabour TK, Daels L (1993) Mapping and monitoring of soil salinity of ISSN. *Egypt J Soil Sci* 33 (4):355–370
- 26) Gong H, Shao Y, Brisco B, Hu Q, Tian W (2013) Modeling the dielectric behavior of saline soil at microwave frequencies. *Canadian J Remote Sens* 39(1):1–10
- 27) Goossens R, van Ranst E (1998) The use of remote sensing to map gypsiferous soils in the Ismailia Province (Egypt). *Geoderma* 87:47–56
- 28) Gorji T, Tanik A, Sertel E (2015) Soil salinity prediction, monitoring and mapping using modern technologies. *Procedia Earth Planet Sci* 15:507–512
- 29) Hardisky MA, Klemas V, Smart RM (1983) the influences of soil salinity, growth form, and leaf moisture on the spectral reflectance of *Spartina alterniflora* canopies. *Photogramm Eng Remote Sens* 49:77–83
- 30) Huete AR (1988) A soil adjusted vegetation index (SAVI). *Remote Sens Environ* 25:295–309.
- 31) Huete AR, Didan K, Miura T, Rodriguez EP, Gao X, Ferreira LG (2002) Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sens Environ* 83:195–213
- 32) Huete AR, Liu HQ, Batchily K, van Leeuwen W (1997) A comparison of vegetation indices global set of TM images for EOS-MODIS. *Remote Sens Environ* 59: 440–451
- 33) Iqbal F (2011) Detection of salt affected soil in rice–wheat area using satellite image. *Afr J Agric Res* 6:4973–4982
- 34) Ivushkin K, Bartholomeus H, Bregt AK, Pulatov A (2017) Satellite thermography for soil salinity assessment of cropped areas in Uzbekistan. *Land Degrad Dev* 28:870–877.
- 35) Jackson TJ, Chen D, Cosh M, Li F, Anderson M, Walthall C, Doriaswamy P, Hunt ER (2004) Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. *Remote Sens Environ* 92:475–482
- 36) Kaufman YJ, Tanré D (1992) atmospherically resistant vegetation index (ARVI) for EOS-MODIS. *IEEE Trans Geosci Remote Sens* 30:261–270
- 37) Khan NM, Rastokuev VV, Sato Y, Shiozawa S (2005) Assessment of hydrosaline land degradation by using a simple approach of remote sensing indicators. *Agric Water Manag* 77 (1–3):96–109.
- 38) Khan NM, Rastokuev VV, Shalina E, Sato Y (2001) Mapping salt-affected soil using remote sensing indicators. A simple approach with the use of GIS Idrissi. In: *Proceedings of the 22nd Asian conference on remote sensing*, 5–9 November 2001, Singapore. Available at: [www.crisp.nus.edu.sg/~acrs2001/pdf/206khan.PDF](http://www.crisp.nus.edu.sg/~acrs2001/pdf/206khan.PDF).
- 39) Krizhevsky A, Sutskever I, Hinton GE (2012) Imagenet classification with deep convolutional neural networks. *Adv Neural Inf Proces Syst* 1:1097–1105
- 40) Kumar K, Hari Prasad KS, Arora MK (2012) Estimation of water cloud model vegetation parameters using a genetic algorithm. *Hydrol Sci J* 57(4):776–789



19<sup>th</sup> Iranian Soil Science Congress  
2-4 December, 2025



نوزدهمین کنگره علوم خاک ایران  
۱۱ تا ۱۳ آذرماه ۱۴۰۴



۰۴۲۵۰-۳۲۰۳۱

مدیریت جامع نگر و هوشمند خاک و آب  
Holistic and Smart Soil and Water Management

دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران  
College of Agriculture & Natural Resources, University of Tehran



- 40) Lasne Y, Paillou P, Ruffle G, Serradilla C, Demontoux F, Freeman A, Farr T, McDonald K, Chapman B, Malezieux J-M (2008) Effect of salinity on the dielectric properties of geological materials: implication for soil moisture detection by means of remote sensing. *IEEE Trans Geosci Remote Sens* 46:3689–3693
- 41) LeCun Y, Bengio Y, Hinton G (2015) Deep learning. *Nature* 521(7553):436–444. <https://doi.org/10.1038/nature14539>
- 42) Lobell DB, Lesch SM, Corwin DL, Ulmer MG, Anderson KA, Potts DJ, Doolittle JA, Matos MR, Baltes MJ (2010) Regional-scale assessment of soil salinity in the red river valley using multiyear MODIS EVI and NDVI. *J Environ Qual* 39:35–41
- 43) Major DJ, Baret F, Guyot G (1990) A ratio vegetation index adjusted for soil brightness. *Int J Remote Sens* 11(5):727–740 2 A Brief Review on Soil Salinity Mapping by Optical and Radar Remote Sensing 63
- 44) Mas JF, Flores JJ (2008) the application of artificial neural networks to the analysis of remotely sensed data. *Int J Remote Sens* 29(3):617–663.
- 45) Matusugu M, Mori K, Mitari Y, Kaneda Y (2003) Subject independent facial expression recognition with robust face detection using a convolutional neural network. *Neural Netw* 16 (5):555–559.
- 46) Metternicht GI, Zinck JA (2003) Remote sensing of soil salinity: potentials and constraints. *Remote Sens Environ* 85:1–20
- 47) Mokarram M, Hojati M, Roshan G, Negahban S (2015) Modeling the behavior of Vegetation Indices in the salt dome of Korsia in North-East of Darab, Fars, Iran. *Model Earth Syst Environ* 1:27.
- 48) Mougenot B, Pouget M, Epema G (1993) Remote sensing of salt-affected soils. *Remote Sens Rev* 7:241–259
- 49) Paliwal A, Laborte A, Nelson A, Singh RK (2018) Salinity stress detection in rice crops using time series MODIS VI data. *Int J Remote Sens*.
- 50) Qadir M, Noble AD, Qureshi AS, Gupta RK, Yuldashev T, Karimov A (2009) Salt-induced land and water degradation in the Aral Sea basin: a challenge to sustainable agriculture in Central Asia. *Nat Res Forum* 33(2):134–149.
- 51) Qadir M, Qureshi AS, Cheraghi SAM (2008) Extent and characterisation of salt-affected soils in Iran and strategies for their amelioration and management. *Land Degrad Dev* 19(2):214–227.
- 52) Rahmati M, Hamzehpour N (2017) Quantitative remote sensing of soil electrical conductivity using ETM+ and ground measured data. *Int J Remote Sens* 38(1):123–140. <https://doi.org/10.1080/01431161.2016.1259681>
- 53) Rao B, Sankar T, Dwivedi R, Thammappa S, Venkataratnam L, Sharma R, Das S (1995) Spectral behaviour of salt-affected soils. *Int J Remote Sens* 16:2125–2136
- 54) Rodríguez PG, González MEP, Zaballos AG (2007) Mapping of salt-affected soils using TM images. *Int J Remote Sens* 28:2713–2722
- 55) Rondeaux G, Steven M, Baret F (1996) Optimization of soil-adjusted vegetation index. *Remote Sens Environ* 55:95–107 Shao Y, Hu Q, Guo H, Lu Y, Dong Q, Han C (2003) Effect of dielectric properties of moist salinized soils on backscattering coefficients extracted from RADARSAT image. *IEEE Trans Geosci Remote Sens* 41:1879–1888 Singh AN,
- 56) Saadat, S., Dehghany, F., Rezaei, H., Esmaeelnejad, L., and Maleki, P. 2020. Effects of salinity and Ca:Mg ratio of irrigation water on pistachio seedlings phosphorus planted under greenhouse conditions. *Desert* (25):1, 25-32
- 57) Singh R, Kumar V, Srivastav S (1990) Use of microwave remote sensing in salinity estimation. *Int J Remote Sens* 11:321–330
- 58) Sreenivas K, Venkataratnam L, Rao PVN (1995) Dielectric properties of salt affected soils. *Int J Remote Sens* 16:641–649
- 59) Steven MD, Malthus TJ, Jaggard FM, Andrieu B (1992) Monitoring responses of vegetation to stress. In: Cracknell AP, Vaughan RA (eds), *Remote sensing from research to operation: proceedings of the 18th annual conference of the remote sensing society*. UK
- 60) Taghizadeh-Mehrjardi R, Minasny B, Sarmadian F, Malone BP (2014) Digital mapping of soil salinity in Ardakan region, central Iran. *Geoderma* 213:15–28.



19<sup>th</sup> Iranian Soil Science Congress  
2-4 December, 2025



نوزدهمین کنگره علوم خاک ایران  
۱۱ تا ۱۳ آذرماه ۱۴۰۴



۰۴۲۵۰-۳۲۰۳۱

مدیریت جامع نگر و هوشمند خاک و آب  
Holistic and Smart Soil and Water Management

دانشکده‌گان کشاورزی و منابع طبیعی دانشگاه تهران  
College of Agriculture & Natural Resources, University of Tehran



- 61) Taylor GR, Mah AH, Kruse FA, Kierein-Young KS, Hewson RD, Bennett BA (1996) Characterization of saline soils using airborne radar imagery. *Remote Sens Environ* 57:127–142 Vapnik V, Lerner A (1963) Pattern recognition using generalized portrait method. *Autom Remote Control* 24:774–780
- 62) Vapnik V, Golowich S, Smola A (1997) Support vector method for function approximation, regression estimation, and signal processing. In: Mozer MC, Jordan MI, Petsche T (eds) *Advances in neural information processing systems*, vol 9. MIT Press, Cambridge, pp 281–287 64 W. Wu
- 63) Verma KS, Saxena RK, Barthwal AK, Deshmukh SN (1994) Remote sensing technique for mapping salt affected soils. *Int J Remote Sens* 15(9):1901–1914.
- 64) Wilkinson GG (2005) Results and implications of a study of fifteen years of satellite image classification experiments. *IEEE Trans Geosci Remote Sens* 43:433–440.
- 65) Wu W (2014) The generalized difference vegetation index (GDVI) for dryland characterization. *Remote Sens* 6:1211–1233
- 66) Wu W, Al-Shafie WM, Mhaimed AS, Ziadat F, Nangia V, Payne W (2014a) Soil salinity mapping by multiscale remote sensing in Mesopotamia, Iraq. *IEEE J Sel Topics Appl Earth Obs Remote Sens* 7(11):4442–4452.
- 67) Wu W, Mhaimed AS, Al-Shafie WM, Ziadat F, Nangia V, De Pauw E (2014b) Mapping soil salinity changes using remote sensing in Central Iraq. *Geoderma Reg* 2-3:21–31.
- 68) Wu W, Muhaimed AS, Al-Shafie WM, Fadhil AM (2019) Using radar and optical data for soil salinity modeling and mapping in Central Iraq. In: Fadhil AM, Negm A (eds) *Environmental remote sensing in Iraq*. Springer, Berlin.
- 69) Wu W, Zhang W (2003) Present land use and cover patterns and their development potential in North Ningxia, China. *J Geogr Sci* 13(1):54–62
- 70) Wu W, Zucca C, Karam F, Liu G (2016) Enhancing the performance of regional land cover mapping. *Int J Earth Obs Geoinf* 52:422–432.
- 71) Wu W, Zucca C, Muhaimed AS, Al-Shafie WM, Fadhil Al-Quraishi AM, Nangia V, Zhu M, Liu G (2018) Soil salinity prediction and mapping by machine learning regression in Central Mesopotamia. *Land Degrad Dev* 29(11): 4005–4014
- 72) Zhang T, Qi J, Gao Y, Ouyang Z, Zeng S, Zhao B (2015) Detecting soil salinity with MODIS time series VI data. *Ecol Indic* 52:480–489.
- 73) Zhang T, Zeng S, Gao Y, Ouyang Z, Li B, Fang C, Zhao B (2011) Using hyperspectral vegetation indices as a proxy to monitor soil salinity. *Ecol Indic* 11:1552–1562

#### ABSTRACT

Salinity is one of the most important limitations of soil and water resources in the agricultural sector and is expanding due to secondary factors and human activities. Currently, about 20% of the world's irrigated lands are facing some kind of salinity limitation, and every year about 1.5 million hectares of agricultural lands are removed from the production cycle due to salinity. This paper summarized the recent progress in soil salinity detection, prediction, quantification, and mapping by remote sensing technology. The following aspects such as classification-based mapping technique, biophysical indicators and spectral indices application, potential of radar data, and machine learning regression were all reviewed. As the state of the art of soil salinity detection and mapping by remote sensing technology, the algorithm of CNN shall be adapted or developed for classification based mapping. The so-called salinity indices are sensitive to locality and lack stability for widespread application, and it would be better to use LST and vegetation indices such as GDVI, NDVI, SAVI, EVI, ARVI, COSRI, etc., for this purpose. Radar data have really great potential, but combined optical-radar datasets may allow to derive better prediction and mapping with higher accuracy. Machine learning regression, especially, RFR is recommended for accurate soil salinity mapping.

Keywords: Salinity index, spectroscopy, machine learning regression, vegetation index

