

النمذجة التنبؤية بملوحة التربة لمنخفض وادي النطرون باستخدام تقنيات الاستشعار من البعد والتعلم الآلي (ML) دراسة في الجيومورفولوجيا التطبيقية

د/ سحر نور الدين توفيق(*)

ملخص البحث

تُعد ملوحة التربة من أكثر عوامل تدهور الأراضي شيوعاً والتي تضعف خصوبتها وتؤثر سلباً على الإنتاج الزراعي. ناقشت الدراسة تطبيق النمذجة التنبؤية التي تعد تقنية قوية لتعزيز دقة التنبؤ واتخاذ قرارات مستنيرة بالاعتماد على الخوارزميات الإحصائية وتقنيات التعلم الآلي في تطوير نموذج تنبؤي للكشف عن ملوحة التربة المتوقعة (ديسي سيمنز/م) بمنطقة الدراسة، وتم تطبيق نماذج (الانحدار الخطي البسيط والمتعدد) وخوارزمية الغابة العشوائية Random Forest، وخوارزمية تعزيز التدرج الشديد XGBoost، وذلك من خلال الاعتماد على تقييم أداء (14) مؤشر طيفي من بيانات القمر الاصطناعي Landsat 8 OLI وبيانات ملوحة التربة المقاسة من (25) عينة بعمق (0 - 30 سم)، وسجل السيناريو الأول للتحليل أعلى معامل ارتباط لمؤشر (SI 6) بقيمة ($R=0.84$) وبمعامل تحديد ($R^2=69$) يليه مؤشر (VSSI) الذي يعبر عن ملوحة التربة والنبات بمعامل ارتباط ($R=0.70$) ومعامل تحديد ($R^2 = 0.49$)، وتم تطوير نموذج انحدار خطي متعدد بتقنيات التعلم الآلي لملوحة التربة المتوقعة بمعامل خطأ (1.224) ومعامل تحديد ($R^2 = 0.982$)، في حين اعتمد السيناريو الثاني على تطوير نموذج تنبؤي اعتمد على خوارزمية XGBoost، ومن خلاله تم إعداد خريطة تبين التوزيع الجغرافي لنسبة تركيز الأملاح المتوقعة في تربة وادي النطرون، حيث تراوحت بين (0.0181 و 41.198 ديسي سيمنز/م) بمعامل خطأ (0.05)، وتوافقت نتائجه مع البيانات المقاسة بشكل كبير، وأوضحت نتائج الدراسة إمكانية فائدة لتقنيات التعلم الآلي في النمذجة التنبؤية لرسم خرائط ملوحة التربة المتوقعة لإدارة التربة المالحة ومعالجتها ومراقبتها واستخدامها، كما قدمت الدراسة رؤية قيمة لاختيار المؤشرات الطيفية المناسبة للتعرف على ملوحة التربة في منطقة النطرون وفي البيئات المماثلة.

الكلمات المفتاحية: النمذجة التنبؤية - ملوحة التربة - تقنيات التعلم الآلي - المؤشرات الطيفية - منخفض النطرون.

(*) مدرس الجيومورفولوجيا التطبيقية ونظم المعلومات الجغرافية - كلية الآداب - جامعة الإسكندرية. drsahargis@gmail.com

Predictive Modeling of Soil Salinity in Wadi Natroun Depression Using Remote Sensing and Machine Learning (ML) A Study in Applied Geomorphology

ABSTRACT

Soil salinity is one of the most common factors of land degradation, reducing soil fertility and negatively impacting agricultural production.. This study explores the application of predictive modeling as a powerful tool to enhance forecasting accuracy and support data-driven decision-making. By integrating statistical algorithms with advanced machine learning techniques, we developed a predictive model to estimate soil salinity levels (dS/m) within the study area. To achieve this, we employed simple and multiple linear regression models alongside Random Forest and extreme Gradient Boosting (XGBoost), leveraging 14 spectral indices derived from Landsat 8 OLI Satellite Imagery and soil salinity measurements obtained from 25 field samples collected at a depth of 0–30 cm. In the first analytical scenario, the SI6 spectral index demonstrated the highest correlation with measured salinity levels, achieving a correlation coefficient (R) of 0.84 and a coefficient of determination (R^2) of 0.69. This was followed by the VSSI index, which represents both soil and vegetation salinity, with $R = 0.70$ and $R^2 = 0.49$. Based on these findings, we developed a multiple linear regression model using machine learning techniques, achieving a mean absolute error (MAE) of 1.224 and an R^2 value of 0.982, indicating a high level of predictive accuracy. In the second scenario, an XGBoost-based predictive model was constructed to generate a soil salinity concentration Map Shows the Geographical Distribution of the expected salt concentration. for the Wadi El Natrun region, The predicted salinity values ranged from 0.0181 to 41.198 dS/m, with a mean absolute error of 0.05, and Its results were consistent with the measured data, The results underscore the exceptional potential of machine learning techniques in predictive soil salinity mapping, offering valuable insights for managing, mitigating, and monitoring saline soils. Furthermore, this study provides critical guidance for selecting optimal spectral indices to enhance soil salinity assessment in Wadi El Natrun and comparable environments.

Keywords:

Predictive Modeling - Soil Salinity - Machine Learning Techniques - Spectral Indicators - Natroun Depression.


مقدمة:

تشير ملوحة التربة إلى تراكم الأملاح القابلة للذوبان في الماء في الجزء السطحي من التربة. وتؤثر المستويات الحرجة من ملوحة التربة سلبًا على نمو النباتات وإنتاج المحاصيل وجودة التربة والمياه، خاصة عندما تبلغ درجة التوصيل الكهربائي بالتربة (EC) أكثر من 4 ديسي سيمنز/م عند 25 درجة مئوية (Morshed et al. 2016). كما تهدد هذه الظاهرة: الزراعة والأمن الغذائي المرتبط بصلاحية التربة، مما يؤدي إلى تدهور الأراضي وفقدان خصائصها الأساسية. كما لا يتوقف تأثير ملوحة التربة على ذلك، بل تؤثر أيضًا على تدهور الأراضي، لذا جاءت أهمية استخدام بيانات الاستشعار من البعد في إنتاج خرائط ملوحة التربة (Schneider et al., 2010)، حيث يعد استخدام

النطاق المرئي للطيف الكهرومغناطيسي إلى الأشعة تحت الحمراء القريبة أكثر فعالية في تحديد نسبة الأملاح في التربة وخصائص المحاصيل المتأثرة بالملوحة. وقد تم الاستعانة حديثاً بالنمذجة الإحصائية خاصة نماذج الانحدار الخطي البسيط والمتعدد للتنبؤ بالتوزيع المكاني لملوحة التربة، وللوصول إلى نتائج أكثر دقة تم استخدام الذكاء الاصطناعي المكاني في الدراسة الحالية، خاصة: خوارزميات التعلم الآلي Random Forest و XGBoost استناداً على المؤشرات الطيفية للكشف والتنبؤ بملوحة التربة بشكل فعال وكمي، ومن ثم تقييم ملوحة التربة بمنطقة الدراسة.

منطقة الدراسة:

يتبع منخفض وادي النطرون محافظة البحيرة إدارياً وهو منخفض ضيق يقع في الجزء الجنوبي الغربي من دلتا النيل-شكل (1)، ويقع فيما بين دائرتي عرض $30^{\circ}02'18''$ و $30^{\circ}31'06''$ شمالاً، وبين خطي طول $30^{\circ}21'06''$ و $30^{\circ}28'50''$ شرقاً، وتصل مساحته نحو 359,12 كم²، ويأخذ المنخفض اتجاه عام جنوبي شرقي / شمالي غربي مع وجود انحدار عام من الغرب إلى الشرق، ويصل أدنى منسوب لقاع المنخفض -21.97 م (تحت مستوى سطح البحر) ويمثله مجموعة من البحيرات- صورتي (1، 2) وقد تستخدم لتجميع الملح الذي تشتهر به بحيرات المنطقة بهذا الموقع ، فإن منطقة الدراسة تقع على هامش دلتا النيل بالقرب من مدينتي: القاهرة والإسكندرية والمراكز العمرانية الجديدة غرب الدلتا، خاصة مدينتي: السادات والتحرير، مما شجع على بدء عمليات الاستصلاح الزراعي واستغلال الموارد الأرضية بالمنخفض صورة (3) .



المصدر/ اعتماداً على الخرائط الطبوغرافية مقياس رسم 25000/1 وصور 8 Land Sat OLI.

شكل (1) صورة لمريئية فضائية Land Sat 8 توضح موقع منطقة الدراسة.



صورة (2) تكون الأملاح وجمعها بجوانب بحيرة الحمرا.

صورة (1) بحيرة الحمرا بمنطقة الدراسة.

أهمية الدراسة:

تأتي أهمية الدراسة في تحقيق أهدافها لصيانة ورفع كفاءة التربة بمنطقة النطرون التي تعتبر إحدى مناطق الإنتاج الزراعي الرئيسية في محافظة البحيرة من خلال تحسين إدارة الأراضي وتعزيز الإنتاجية الزراعية، وإعداد خرائط لمراقبة ملوحة التربة، ويتحقق ذلك بالاعتماد على أساليب جيوتقنية حديثة (النمذجة المكانية والتعلم الآلي)، كما تكمن أهمية الدراسة في دقة وسرعة الحصول على بيانات ملوحة التربة بالمقارنة بالأساليب التقليدية لرسم خرائط وتتبع التغيرات في ملوحة التربة مكانياً وزمانياً، خاصة أن الطرق التقليدية لتقييم الملوحة المتعلقة بالتربة تهمل دور النباتات في حساب الملوحة؛ لذا تعمل بيانات الاستشعار من البعد عند نمذجتها وإدارتها بتقنيات التعلم الآلي (ML) في تكوين نظرة شاملة لتحليل الملوحة اعتماداً على (خصائص التربة، النبات، المياه، المناخ).

مشكلة الدراسة:

تكمن مشكلة الدراسة في طبيعة منسوب المنخفض الذي يصل إلى (-21.97) م، واقترب سطح المنخفض من مستوى المياه الجوفية؛ ومن هنا جاءت الحاجة إلى إعداد خرائط لمراقبة ملوحة التربة والتنبؤ بها وذلك بتكلفة أقل وأسرع لزيادة الإنتاج الزراعي، وتحديد ممارسات أفضل لإدارة الأراضي الزراعية والحد من تدهورها، خاصة أن الدراسة الحالية تقدم رؤى جديدة تستند على تقنيات علمية حديثة بشأن التنبؤ بالتباين المكاني لتملح التربة صورة (4)، في ظل عدم القدرة على حساب المساحة الإجمالية للتربة المتأثرة بالملح، والتحيز الجغرافي في القياسات الأرضية لملوحة التربة، والافتقار إلى المعلومات والبيانات التي توضح عمليات الملوحة، خاصة فيما يتعلق بالاستجابات لتغير المناخ.



صورة (4) تملح التربة بمنطقة بحيرة الحمرا.



صورة (3) زراعات أشجار البرتقال بمنطقة الدراسة.

تساؤلات الدراسة:

- أ- هل تسهم تقنيات التعلم الآلي في التعرف على ملوحة التربة المتوقعة؟
- ب- ما مدى الاعتماد على بيانات الاستشعار من البعد في التنبؤ بملوحة التربة؟
- ج - ما المشكلات الناتجة عن تملح تربة منطقة الدراسة؟

أهداف الدراسة:

تهدف الدراسة إلى تحقيق ما يلي:

- أ- دراسة التباين المكاني لملوحة التربة من خلال تطبيق أساليب مختلفة جيومكانية حديثة بالاعتماد على بيانات الاستشعار من البعد.
- ب-التوصل إلى أكثر المؤشرات الطيفية التي تتناسب منطقة الدراسة والمناطق التي تتشابه معها في الظروف المناخية والطبوغرافية.
- ج- إعداد نماذج رياضية ونماذج بالتعلم الآلي للكشف عن ملوحة التربة والتنبؤ بها وإعداد خرائط لها.
- د- بناء منهجية للإشراف بكفاءة على مشكلات ملوحة التربة وحلها عبر مجموعة واسعة من الظروف البيئية في ظل ديناميكية التغير المناخي وأنواع التربة مع الحفاظ على وقت وتكلفة منخفضة.

الدراسات السابقة:


تتمثل أبرز هذه الدراسات فيما يلي :-

دراسة (Mahmoud, M. G , Mostafa H. A(2022) : وتناولت تقدير الملوحة باستخدام بيانات الاستشعار عن بعد على مدينة الشيخ زايد بمحافظة الجيزة في مصر. دراسة: طارق حمد أبو الفضل إبراهيم (2022) ناقشت التقييم البيئي لتملح التربة منطقة غرب الموهوب- بالواحات الداخلة باستخدام نظم المعلومات الجغرافية، مجلة كلية الآداب، جامعة قنا. دراسة: Abd El-Hamid

HT, Hong, G (2020) وتناولت استخدام الاستشعار عن بعد لاستخراج تملح التربة شمال نينغشيا الصينية. دراسة: (2020) Hammam A.A. and Mohamed E.S وانتجت خرائط لملوحة التربة في شرق دلتا النيل باستخدام عدة طرق منهجية لتقييم الملوحة. مصر. دراسة: صفاء حسن حامد، 2021 : وتناولت تحليل التباين المكاني لمؤشرات ملوحة التربة باستخدام تقنيات الاستشعار عن بعد ونظم المعلومات الجغرافية. دراسة: Ivushkin K, Bartholomeus H, Bregt AK, Pulatov A, Kempen B(2019) وتناولت رسم خرائط عالمية لتغير ملوحة التربة باستخدام بيانات الاستشعار عن بعد. دراسة: جاسم شهاب حمد العتابي، وآخرون (2019) : دراسة التغيرات المكاني لملوحة التربة في مشروع شيخ سعد باستخدام تقنيات الاستشعار عن بعد دراسة: (2018) Shahid SA, Zaman M, Heng L. وتناولت ملوحة التربة: وجهات نظر تاريخية ونظرة عامة على المشكلة. دراسة: Triki Fourati H, Bouaziz M, Benzina M, Bouaziz S. (2015) وتناولت نمذجة ملوحة التربة في المناطق شبه الجافة باستخدام التحليل الطيفي. دراسة: (2008) Abdel-Hamid, A. وتناولت الدراسة التحليل المكاني لبعض مؤشرات قدرة التربة للإنتاج الزراعي بمنخفض النطرون. دراسة: (2008) ALI and A.A. El Baroudy وتناولت التحليل المكاني لتقييم الحساسية البيئية للتصحّر في منخفض النطرون . دراسة حمدينه عبد القادر السيد العوضي (2005) وتناولت دراسة الخصائص المورفومترية والمورفولوجية والهيدرولوجية لبحيرات النطرون، وإمكاناتها. دراسة: Khan NM, Rastoskuev V V, Shalina E V, Sato Y(2001) وتناولت رسم خرائط للتربة المتأثرة بالملوحة باستخدام مؤشرات الاستشعار عن بعد. دراسة: أحمد حيدر الزبيدي (1994): وناقشت استصلاح الأراضي الملحية في الوطن العربي. دراسة: داود جاسم الربيعي (1988): وتناولت ظاهرة ملوحة التربة في القسم الجنوبي من السهل الرسوبي بجنوب دولة العراق.

المنهجية والأساليب البحثية:

اتبعت الدراسة بعض المناهج والأساليب العلمية، يأتي في مقدمتها: **المنهج الاستقرائي التحليلي** Analytical Inductive Method ويعتمد على فهم أعمق للظواهر والمفاهيم المعقدة من خلال تحليل البيانات والعلاقات والأنماط، ومن خلاله يتم جمع ومعالجة البيانات المدخلة في الدراسة (محمد عبدالعال النعيمي وآخرون، 2014، ص 73، 74)، **والمنهج الوصفي التحليلي** Descriptive Analytical Method بهدف وصف الظاهرة (ملوحة التربة) وحالتها الراهنة من خلال جمع البيانات والمعلومات عنها.




المصدر: إعداد الباحثة اعتماداً على المناهج والأساليب العلمية للوراثة.

شكل (2) مخطط يوضح مراحل الوراثة.


كما تم توظيف بعض المداخل كالمدخل الإقليمي Regional Approach (خير، صفوح، 2000، ص24) بهدف معالجة الظاهرة أو المشكلة قيد البحث من خلال ارتباطها بالظروف السائدة في منطقة الدراسة، ومن أهم الأساليب العلمية: الأسلوب الإحصائي في إجراء التحليلات الإحصائية للمؤشرات الطيفية لملوحة التربة، الأسلوب الكارتوجرافي في إعداد الخرائط ورسمها، والأسلوب التحليلي وتم الاعتماد عليه لتطبيق التعلم الآلي (ML) والنمذجة التنبؤية بملوحة التربة- شكل (2)، وتمت المعالجة المسبقة المطلوبة لصور الأقمار الاصطناعية، وحساب أهم المؤشرات الطيفية لملوحة التربة والغطاء النباتي الموصي بها- جدول (1) ورسم خرائط لها، وذلك بعد استخراج قيم الانعكاس الطيفي لمؤشرات الغطاء النباتي، التربة والمياه، والتي تم حسابها باستخدام نطاقات الصور الفضائية،

وقامت الدراسة بتطبيق النمذجة التنبؤية باستخدام خوارزميات التعلم الآلي (ML) ونماذج الانحدار الخطي البسيط والمتعدد Multiple Linear Regression، ومن أهم خوارزميات التعلم الآلي التي اعتمدت عليها الدراسة، خوارزمية الغابة العشوائية Random Forest وخوارزمية تعزيز التدرج الشديد xtreme Gradient Boosting algorithm (XGBoost) -شكلي (3-4). وتعد خوارزمية Random Forest إحدى تقنيات التعلم الآلي الشجري القوية، حيث تعتمد على مجموعة كبيرة جداً من أشجار القرار (Decision Trees) بحيث لا يتم الاعتماد على شجرة قرار واحدة التي قد تكون عرضة للانحياز أو التكيف المفرط مع البيانات "over fitting"، وتقدم كل شجرة تنبؤاتها، ثم يتم اتخاذ القرار النهائي بناءً على تصويت الأغلبية (في حالة التصنيف) أو متوسط التوقعات (في حالة الانحدار) (Steven J. Rigatti, MD, DBIM, 2017)، وإذا كان الهدف هو التنبؤ بقيمة عددية، فإن النتيجة النهائية تكون متوسط تنبؤات كل شجرة (Wijdan, F. T, Amakhchan K, and Gharineiat, Z, 2021)، بينما خوارزمية (XGBoost) هو نموذج تعلم آلي متكامل يعتمد على التعزيز المتدرج (Gradient Boosting) وقدمه (Chene, t A., 2016)، ويعد من أكثر الخوارزميات قوة وكفاءة في حل مشاكل التصنيف والانحدار (Jinghui, M, Zhongqi Y, Yuanhao, Q, 2020)، وتستند فكرته الأساسية على بناء عدة نماذج بسيطة (عادةً أشجار قرار ضعيفة) بطريقة تدرجية ويحاول كل نموذج تصحيح أخطاء النماذج السابقة (Tianqi, c., Carlos G., 2016)، وتعتمد كل شجرة جديدة على الشجرة التي قبلها لتحسين الدقة، ويتم تحسين النموذج تدريجياً، حيث يتم تدريب كل شجرة جديدة بناءً على الأخطاء التي نتجت من النماذج السابقة (Pan, B.Y., 2018)، على عكس الغابة العشوائية، التي تعتمد على التصويت الجماعي لأشجار القرار، لكن في خوارزمية XGBoost تعمل أشجار القرار معاً بطريقة تسلسلية لتصحيح الأخطاء.



المصدر: إعداد الباحثة اعتماداً على دراسة (Huan Wang, 2023)

شكل (3) مخطط يوضح خوارزمية التعلم الآلي الغابة العشوائية Random Forest



المصدر: إعداد الباحثة بناء على دراسة (Chen.Q , Shaochun Y, Ya, W,

شكل (4) مخطط يوضح خوارزمية التعلم الآلي XGBoost

نموذج Random Forest

معادلة (1)

$$\hat{y}_i = \frac{1}{K} \sum_{k=1}^K T_k(x_i)$$

الرمز

$\hat{y}_i$ التنبؤ النهائي للقيمة الخاصة بالنقطة x_i . متوسط التنبؤات لجميع الأشجار.

k عدد الأشجار المستخدمة في الغابة Random Forest للتنبؤ.

$T_k(x_i)$ التنبؤ الناتج من الشجرة k للنقطة x_i كل شجرة في الغابة تقوم باعطاء تنبؤ، ويستخدم المتوسط.

x_i النقطة أو العينة التي نريد التنبؤ لها.

نموذج XGBoost

معادلة (2)

$$Obj(\theta) = \sum_{i=1}^n \left(g_i f_t(x_i) + \frac{1}{2} h_i f_t(x_i)^2 \right) + \sum_{k=1}^K \left(\gamma T_k + \frac{1}{2} \lambda \sum_{j=1}^{T_k} w_j^2 \right)$$

الرمز

$Obj(\theta)$ الدالة (الهدف).

n عدد العينات في مجموعة البيانات.

g_i المشتق الأول لدالة الخسارة بالنسبة للتنبؤات الحالية.

$f_t(x_i)$ التنبؤ الجديد الناتج عن الشجرة t للعينة x_i

γT جزء من مصطلح التنظيم للتأكد من أن عدد الأشجار لا تصبح معقدة.

λ مصطلح تنظيم آخر للتحكم في قيم الأوزان الكبيرة للأوراق.

w_j الوزن المرتبط بالأوراق j في الشجرة. يمثل التأثير التي تملكه كل ورقة في الشجرة على التنبؤ النهائي.

K عدد الأشجار المستخدمة في النموذج.

kT عدد الأوراق في الشجرة k

المصدر: (Chen.Q , Shaochun Y, Ya, W, Chao W, Yifan Z, 2021)

كما اعتمدت الدراسة على النمذجة الإحصائية المكانية، ويأتي في مقدمتها نموذج الانحدار الخطي المتعدد (Multiple Linear Regression (MLR)، وتم استخدام برمجيات SPSS و VC Code لكتابة الأكواد البرمجية والتحليل الإحصائي لبيانات الاستشعار من بعد.

معادلة (3)	$Y = a + b_1X_1 + b_2X_2 + \dots + e$
Y	= المتغير التابع
a	= قيمة ثابتة Constant أو Intercept
b1	= ميل الانحدار y على المتغير المستقل الأول
b2	= ميل الانحدار y على المتغير المستقل الثاني
X1	= المتغير المستقل الأول
X2	= المتغير المستقل الثاني

المصدر: (Ozgur, Ceyhun, et al, 2016)

جدول (2) المعادلات المستخدمة في التحليلات الطيفية لملوحة التربة.

م	المؤشر الطيفي	العمليات الحسابية للقنوات الموجية	المصدر
1	Normalized difference salinity index	$NDSI = \frac{(R - NIR)}{2(R + NIR)}$	(Rastoskuev, V et al. 2001)
2	Vegetation soil salinity index	$VSSI = 2 \times G - 5 \times (R + NIR)$	(Dehni A, et al. 2012)
3	Brightness index	$BI = \sqrt{R^2 + NIR^2}$	Khan NM, Rastoskuev (2001)
4	Salinity Index-1	$SI = \sqrt{(B \times R)}$	(Rastoskuev, et al. 2001)
5	Salinity Index-2	$SI = \sqrt{(G \times R)}$	Khan NM, Rastoskuev V (2001)
6	Salinity Index-3	$SI = \sqrt{(G^2 + R^2 + NIR^2)}$	(Douaoui AEK, et al. 2006)
7	Salinity index-6	$SI = \frac{(B - R)}{(B + R)}$	(Bannari A et al. 2008)
8	Salinity index-7	$SI = \frac{(G \times R)}{R}$	(Bannari A, et al. 2008)
9	Salinity index-8	$SI = \frac{(B \times R)}{G}$	(Abbas A, et al. 2007)
10	Salinity index-9	$SI = \frac{(NIR \times R)}{G}$	(Abbas A, et al. 2007)
11	Moister stress index	$MSI = \frac{(SWIR)}{NIR}$	(Elhag M, et al. 2017)
12	Normalized difference vegetation index	$NDVI = \frac{(NIR - R)}{(NIR + R)}$	(Cheng Y, et al. 2008)
13	Normalized difference water index	$NDWI = \frac{(NIR - SWIRI)}{(NIR + SWIRI)}$	(Cheng Y, et al. 2008)
14	Soil adjusted vegetation index (L=0.5)	$SAVI = (1 + L) \times \frac{NIR - R}{L + NIR}$	(Dehni A et al. 2012)
المصدر: اعداد الباحثة اعتماداً على المراجع بالجدول.			
B= Blue, G= Green, R= Red, NIR =Near Infrared			

مصادر البيانات ومعالجتها:

اعتمدت الدراسة على معطيات مكانية متعددة، منها: **الدراسة الميدانية** حيث تم جمع إجمالي (25) عينة للتربة بمنطقة الدراسة - شكل (1) - من خلال الدراسة الميدانية التي أجريت خلال شهري يناير ويونيو عام (2022م) واستخدم نظام تحديد المواقع العالمي GPS Garmin في تحديد مواقع العينات، وأجرى التحليل المعملية عليها لتحديد ملوحة مستخلص التربة من حيث التوصيل الكهربائي (EC) وفقاً لدراسة (Shaw, R., 1994)، واستخدام برنامج ArcGIS 10,8 لإنشاء قاعدة بيانات جغرافية تحتوي على قيم ملوحة التربة ديسمينز/م (EC)، واستخدمت طريقة kriging لإنتاج الطبقات الرقمية للقياسات الميدانية. كما اعتمدت الدراسة على بيانات الاستشعار من بعد Landsat (OLI-8). وتم إجراء التصحيحات الجوية والإشعاعية وتحسين الدقة المكانية. كما تم تحويل صور Landsat 8 إلى انعكاس سطحي، واختيار نظام إسقاط (Universal Transverse Mercator (UTM ونظام الإحداثيات (WGS84). وتحتوي الصورة على غيوم أقل من 10%، وسمت الشمس (127.08°). كما تم بناء نموذج المناسيب الرقمي بالاعتماد على أداة الاستكمال المكاني IDW اعتماداً على الخرائط الطبوغرافية مقياس رسم 1:25000، وذلك من خلال عملية الترقيم Digitizing لخطوط الكنتور ونقاط المناسيب. كما استقت الدراسة بياناتها من الزيارات الميدانية التي أجريت على منطقة الدراسة من أجل رصد وقياس وملاحظة الظواهر الطبيعية والبشرية وإجراء عمليات التحقق الميداني.

جدول (1) المعطيات المكانية المستخدمة في الدراسة.

صور المرئيات الفضائية							
تاريخ التصوير	المستشعر	الدقة المكانية	PATH	Row	الهدف	المصدر	
2022-9-26	Land Sat	OLI 8	30	177	39	المؤشرات الطيفية	USGS
نموذج المناسيب الرقمي							
النوع	التاريخ	الدقة المكانية	الهدف	المصدر			
Alos Palsar	2008-5-20	12.5m	خصائص السطح	وكالة الفضاء الأوربية			
DEM	1992-7-10	10m	خصائص السطح	الخرائط الطبوغرافية			
عينات التربة							
نوع التحليل	عدد العينات	العمق	المصدر				
قياس ملوحة التربة	25	35-60 cm	الدراسة الميدانية				
الخرائط الجيولوجية (1 : 500000) والخرائط الطبوغرافية (1 : 25000)							
القياسات الميدانية : الزيارات الميدانية، شهري يناير ويونيو عام (2022م).							

المصدر/ إعداد الباحثة تبعاً لمتطلبات الدراسة.

محاور الدراسة:


أولاً: الخصائص الطبيعية لمنطقة الدراسة:

1- خصائص السطح لمنخفض النطرون:

يعد منخفض النطرون منخفضاً صحراوياً يمتد على حافة الدلتا والصحراء الغربية، وهو منخفض مغلق، فهو ينحدر نسبياً من الجنوب الشرقي إلى الشمال الغربي ويستمد مائتيه من الماء الباطني وتستقر في قاعه سلسلة بحيراته الملحية الشهيرة. ويمكن تقسيم سطح المنخفض إلى وحدتين رئيسيتين هما حواف (جوانب) المنخفض وقاع المنخفض وكل منهما له مظاهر التضاريسية، وفيما يلي خصائص هذه الوحدات التضاريسية بمنطقة الدراسة:

أ- حواف المنخفض:


يعد منخفض وادي النطرون منخفضاً مغلقاً- شكلي(5,6)، حيث يحده من جميع الجهات حواف (جوانب) تنحدر سفوحها تدريجياً صوب قاعه، ونظراً للامتداد الطولي للمنخفض من الجنوب الشرقي إلى الشمال الغربي، فإن جوانبه تتمثل في حافتين رئيسيتين هما الحافة الشمالية والحافة الجنوبية، وتمتد الحافة الشمالية: من الجنوب الشرقي إلى الشمال الغربي، كما تمتد أيضاً الحافة الجنوبية من الجنوب الشرقي إلى الشمال الغربي بوجه عام، وإن كانت تشهد بعض التعرجات التي تحيد عن هذا الاتجاه العام، وهي تمثل أكثر النقاط المحيطة بالمنخفض ارتفاعاً والتي تتراوح بين 80 : 180 متر ، ويعتبر الجزء الأوسط منها والمعروف باسم "جبل حديد" أعلى الأجزاء منسوباً. وتعد الأودية الجافة أحد الأشكال الرئيسية المرتبطة بحواف المنخفض.



المصدر/ الخرائط الطبوغرافية وصور Landsat 8 باستخدام برنامج Arc GIS 8

شكل (5) الوحدات الجيومورفولوجية بمنطقة الدراسة

مجلة كلية الآداب بالوادي الجديد- مجلة علمية محكمة- العدد السابع عشر (الجزء الثاني)



المصدر/ الخرائط الطبوغرافية وصور Landsat 8 باستخدام على برنامج Arc GIS 8

شكل (6) نموذج المناسيب الرقمي لمنخفض النطرون

ب- قاع المنخفض:

تؤثر خصائص سطح قاع المنخفض على استخدامات الأرض من زراعات وتجمعات عمرانية والتي ترتبط بقاعه نظراً لارتفاع منسوب الماء الجوفي الذي يرتبط بأكثر جهات المنطقة انخفاضاً مما أثر على العديد من الظواهر الطبيعية كالبحيرات والسبخات، ويضم قاع المنخفض بعض الأشكال الجيومورفولوجية، وهي الأشكال الرملية، التلال المنعزلة والبحيرات، وتعد الفرشات الرملية والنبات أهم الأشكال الرملية بمنطقة الدراسة.



موقع أحد مزارع النخيل بالمنطقة

شكل (7) يوضح أثر تملح التربة على زراعة النخيل بمنخفض النطرون.

2- خصائص ملوحة التربة بمنطقة الدراسة:

لمنطقة وادي النطرون سمات خاصة في درجة ملوحة التربة؛ وذلك لانخفاض مستوى السطح إلى ما دون مستوى سطح البحر مما يجعل لعامل المياه الأرضية والجوفية وترسب الأملاح دور كبير خاصة في مواقع البحيرات والمواقع المحيطة بها في منطقة الدراسة، وبناء على نتائج التحليل المعمل لعدد (25) عينة أخذت من التربة لقياس تركيز الملوحة وعلى حسب تصنيف (FAO,1974) - جدول (3) الذي يصنف ملوحة التربة إلى: غير مالحة، منخفضة، متوسطة، مرتفعة، ومرتفعة جداً، فإنه تم إنشاء (5) نطاقات للتوزيع المكاني لملوحة التربة (EC) المقاسة ومساحتها (كم²) والنسبة المئوية لكل فئة مكانية.

جدول (3) درجات تصنيف ملوحة التربة حسب تصنيف FAO.

م	درجة الملوحة	FAO ds/m
1	غير مالحة	2-0
2	قليلة	4-2
3	متوسطة	8-4
4	مرتفعة	16-8
5	مرتفعة جدا	أكثر من 16

Source: FAO,1985.


ومن خلال جدول (4) وشكلي (8-9) تتراوح درجة ملوحة التربة المقاسة بمنطقة الدراسة (EC) بين 0.18 و 41.2 ديسي سيمنز/م، وتغطي التربة غير المالحة 31.173 كم² (8.67%)، بينما تصل مساحة فئة التربة المالحة قليلاً 30.271 كم² (8.42%)، في حين تبلغ مساحة فئة التربة متوسطة الملوحة 168.869 كم² (47.00%)، والتربة مرتفعة الملوحة 110.13 كم² (30.65%)، وبلغت فئة مساحة التربة شديدة الملوحة 18.798 كم² (5.23%) من منطقة الدراسة. وتبين وقوع المناطق شديدة الملوحة في معظمها بالقرب من البحيرات، خاصة بحيرات (البيضة-السبخة-الروزينة) شكل (9). وتبين خرائط التوزيع المكاني أن نسبة 82.89% من مساحة منطقة الدراسة نسبة الملوحة بها أعلى من 4 ديسي سيمنز/م في وترتفع نسبة الملوحة بشكل كبير في المناطق الشمالية والشرقية من المنخفض خاصة بجوار البحيرات والسبخات، في حين تنخفض الملوحة في المناطق الجنوبية والغربية لأقل من 4 ديسي سيمنز /م.

مجلة كلية الآداب بالوادي الجديد- مجلة علمية محكمة- العدد السابع عشر (الجزء الثاني)

جدول (4) قياسات ملوحة التربة لعينات منطقة الدراسة (ديسي سيمنز/م³)


رقم العينة	(EC) ملوحة التربة	الإحداثيات	
		X	Y
1	8.16	245497.77	3362380.56
2	12.41	247687.36	3360950.71
3	12.40	249011.62	3360067.59
4	5.43	244292.73	3360634.34
5	5.44	239508.04	3359898.94
6	18.95	250905.59	3358044.11
7	5.50	257167.85	3355448.37
8	17.82	252004.54	3357002.23
9	5.35	248254.90	3357079.11
10	5.36	245681.71	3357320.58
11	5.46	237544.46	3366595.39
12	5.37	237194.19	3362485.03
13	16.68	242589.03	3365817.93
14	41.20	234986.03	3370749.02
15	0.20	238040.90	3371073.01
16	5.42	232523.10	3368428.10
17	5.41	227819.97	3369215.92
18	5.40	234280.51	3365856.09
19	5.50	227705.02	3373935.33
20	0.21	217418.02	3378286.97
21	2.30	224206.17	3371144.92
22	0.18	220386.97	3374629.70
23	8.07	232922.30	3372492.17
24	10.02	240121.98	3365352.91
25	7.75	230863.70	3364873.66

المصدر/ إعداد الباحثة من خلال الدراسة الميدانية لمنطقة الدراسة، عام 2022م



المصدر: أداة KRIGING داخل برنامج Arc GIS, 10.8 بالاعتماد على عينات ملوحة التربة .

شكل (8) قيم ملوحة التربة (EC) ديسيسيمنز /م³ بمنخفض النظرون.



المصدر: بالاعتماد على أداة KRIGING داخل برنامج Arc GIS,10.8 وعينات ملوحة التربة الدراسة الميدانية

شكل (9) تصنيف فئات ملوحة التربة حسب معايير FAO بمنخفض النطرون.

ثانياً : النمذجة التنبؤية لملوحة تربة منطقة الدراسة باستخدام الانحدار Regression:


تم إجراء تحليل الانحدار والتباين (ANOVA) للمؤشرات الطيفية لملوحة التربة بمنطقة الدراسة، حيث يمكن استخدام نماذج الانحدار الخطي للحصول على معاملات الارتباط المحتملة فيما بين بيانات الاستشعار من بعد وخصائص التربة (Gorji T, Sertel E, Tanik A,2017).

1- الانحدار الخطي البسيط والتنبؤ بملوحة التربة:

تم حساب (14) مؤشر طيفي لملوحة التربة والغطاء النباتي - الشكل (10-أ و 10-ب) باستخدام صور Landsat OLI 8 بناءً على الاستجابات الطيفية المختلفة للتربة المالحة والنباتات والمياه لمختلف النطاقات الطيفية - جدول (2)، وتم اختيار هذه المؤشرات الطيفية بناءً على مدى التفاعل بين الانعكاس الطيفي والمحتوى الملحي ومدى تناسبها مع البيانات الجافة وشبه الجافة (Wardlow, B. D and Egbert, S. L.2008). وتنقسم المؤشرات المستخدمة في حساب ملوحة التربة إلى ثلاث مجموعات طيفية على حسب مصدر الانبعاث الطيفي، وهما: المؤشرات الطيفية الخاصة: بالتربة، النباتات والمياه.


ويأتي في مقدمة المؤشرات الطيفية الملحية الخاصة بالتربة: مؤشر (SI) الذي يجمع بين النطاقين الأزرق والأحمر، ومؤشر السطوع (BI)، في حين يأتي في مقدمة المؤشرات الطيفية الخاصة بالنباتات: مؤشر الغطاء النباتي المعدل للتربة (SAVI) (Zhang T-T, Qi J-G,

(Gao Y, Ouyang Z-T, Zeng S-L, Zhao B.,2015) مؤشر الملوحة الفرق الطبيعي (NDSI)، (Khan NM, Rastoskuev V V, Shalina E V, Sato Y.,2001)، مؤشر ملوحة التربة النباتية VSI (Dehni A, Lounis M.,2012)، ومؤشر الغطاء النباتي المعدل للتربة المرتبط بالملوحة MSAVI-SI . (Abd El-Hamid HT, Hong G.,2020) .



المصدر/ تحليل صور 8 Landsat باستخدام برنامج Arc GIS 8.

شكل (10- أ) المؤشرات الطيفية لملوحة التربة لمنخفض النطرون.




المصدر/ تحليل صور Landsat 8 باستخدام برنامج Arc GIS 8 .
شكل (10- ب) المؤشرات الطيفية لملوحة التربة لمنخفض النطرون.

وساعد في بناء هذه المؤشرات الانبعاث الطيفي الصادر من الغطاء النباتي الذي يعبر عن العلاقة بين حالة الغطاء النباتي وتفاعل التربة (Davis E, Wang C, Dow K.,2019)، مما يحسن من دقة التنبؤ بملوحة التربة في حالة الغطاء النباتي ضعيف النمو (Davis E, Wang C, Dow K.,2019).

واعتمدت المؤشرات الطيفية الخاصة بالمياه على خصائص الإشعاع المنعكس بالقرب من الضوء الأخضر المرئي والأشعة تحت الحمراء، ويأتي في مقدمتها مؤشر NDWI، ويتم حساب هذا المؤشر باستخدام مجموعة GREEN-NIR الأخضر المرئي والأشعة تحت الحمراء القريبة، مما يسمح له باكتشاف التغيرات الطيفية في المحتوى المائي للمساحات المائية والسبخات الملحية الرطبة. وتم استخدم ارتباط بيرسون لفحص الروابط فيما بين مجموعة بيانات الاستشعار من بعد وقيم EC للتربة، فمن خلال شكل (11) يتضح أن أقوى معاملات ارتباط سُجلت بين المؤشرات الطيفية وقيم ملوحة التربة EC المقاسة وكانت بين مؤشرات (NDWI - VSSI - SI6) وبلغت (0.84 - 0.70) على التوالي وجميعهم عند مستوى دلالة إحصائية (Sig (1-tailed) أقل من 0.005 مما يشير إلى أن هذا الارتباط دال إحصائياً، في حين يعد مؤشر SI9، BI ذو علاقة عكسية قوية (-0.79، -0.71) بمستوى دلالة إحصائية أقل من 0.05 مما يدل على أن الارتباط دال معنوياً، ويلاحظ من خلال شكل (11) أن المؤشرات الطيفية الملحية (SI6 - VSSI) المنتجة من بيانات Landsat 8 OLI سُجلت أقوى معاملات ارتباط (R=0.84, 0.7) على التوالي.

وقد تم تمثيل معادلات خط الانحدار البسيط لكل مؤشر طيفي من بيانات Landsat 8 OLI وقيم الملوحة (EC) المقاسة -شكل (12) ويتضح وجود تأثير واضح بين انعكاس التربة وخواصها، مثل: لون التربة ومحتواها من الرطوبة والأملاح.


أوضح نموذج الانحدار الخطي البسيط أن المؤشر الطيفي SI6 الذي تم إنشاؤه من صورة Landsat 8 OLI يمتلك أقوى ارتباط طردي (r = 0.84) بمعامل تحديد (R²=69) ؛ لذا يمكن حساب ملوحة التربة بناء على هذا المؤشر الطيفي - جدول (5).



المصدر/ استخدام لغة برمجة Python والتعلم الآلي في برنامج VS. شكل (11) مخطط حراري لمعاملات قوة الارتباط فيما بين المؤشرات الطيفية وقيم EC بمنطقة الدراسة.

جدول (5) نموذج خطي للتنبؤ بملوحة التربة بالاعتماد على المؤشر SI_6

نوع النموذج/نموذج خطي بسيط.
Equation for SI_6: $Y = 102.26129 \times SI_6 + 20.052329$



المصدر: تحليل معاملات الانحدار داخل برنامج SPSS.

شكل (12) معاملات الانحدار وقيم الارتباط بين المؤشرات الطيفية والقيم المقاسة لملوحة التربة.

2- الانحدار الخطي المتعدد والتنبؤ بملوحة التربة:

يقدم الانحدار الخطي المتعدد MLR نماذج تفسيرية أكثر موثوقية لتقدير ملوحة التربة (Farifteh J, Van der Meer F, Atzberger C, Carranza E, 2007)، حيث يتم التعامل مع مجموعة متغيرات مستقلة بدلاً من متغير مستقل واحد، ففي الدراسة الحالية تم تحديد قيم الانعكاس التي يعبر عنها بالمؤشرات الطيفية كمتغيرات مستقلة في نمذجة الانحدار، بينما تم تحديد قيم EC المقاسة للتربة كمتغير تابع. ولبناء نموذج الانحدار الخطي المتعدد وزيادة القدرة التفسيرية للتنبؤ بملوحة تربة منطقة الدراسة بالاعتماد على بيانات الاستشعار من بعد ؛ تم حساب القيم الرقمية لتأثير المعاملات Coefficients التي تعبر عن المتغيرات المستقلة للمؤشرات الطيفية المدخلة في النموذج -جدول (6)، وتبين أن هذه المعاملات ذات أثر كبير في تفسير التباين في قيم ملوحة التربة (EC)، إلا أنه تعد مؤشرات (SI6 و SI9) أكثر المؤشرات الطيفية تأثيراً في تباين ملوحة التربة حسب مستوى الدلالة الإحصائية (Sig).

جدول (6) نتائج تحليل الانحدار المتعدد وتأثير المعاملات ^a Coefficients للمؤشرات الطيفية.

المتغيرات	coef	قيمة (ت) t	دلالة (ت) Sig	P> t	Std. Error
(Constant)	-2.799	-1.368	.079	0.209	2.05
SI 6	501.068	1.889	.000	0.096	265.23
B1	0.101	2.062	.012	0.073	0.049
MSI	114.605	0.605	.070	0.562	189.33
NDVI	8.395	1.367	.002	0.209	6.14
SI_7	-0.058	-1.796	.008	0.110	0.033
NDWI	271.070	0.674	.000	0.519	402.05
SAVI	-1.120	-1.367	.000	0.209	402.05
SI_8	0.0672	1.338	.195	0.218	0.05
SI_9	-0.004	-0.581	.093	0.577	0.00
SI_1	-0.336	-1.719	.010	0.124	0.19
SI_2	0.349	1.816	.060	0.107	0.19
SI_3	-0.100	-1.854	.010	0.101	0.05
VSSI	-0.000	-0.924	.027	0.382	0.00
NDSI	-103.789	-1.146	.014	0.285	90.54

a. Dependent Variable: EC

المصدر/ تحليل الانحدار المتعدد داخل برنامج SPSS .

ومن خلال جدول (7) أمكن التوصل إلى نموذج الانحدار الخطي المتعدد الذي يوضح العلاقة بين: المؤشرات الطيفية وقيم الملوحة المقاسة (EC) والتنبؤ بملوحة التربة المتوقعة Predicted EC، وذلك بناء على قيم (coef) لكل متغير والرقم الثابت (Constant) .

جدول (7) معادلة الانحدار الخطي المتعدد للتنبؤ بملوحة التربة اعتمادا على بيانات الاستشعار من البعد.	
Predicted (JS) =	
$-279907.6980 + 501.0680 \times SI_6 + 0.1011 \times BI$ $+ 114.6055 \times MSI + 839537.4220 \times NDVI$ $- 0.0584 \times SI_7 + 271.0703 \times NDWI$ $- 1119874.9658 \times SAVI + 0.0672 \times SI_8$ $- 0.0049 \times SI_9 - 0.3369 \times SI_1 + 0.3495 \times SI_2$ $- 0.1005 \times SI_3 - 0.0001 \times VSSI - 103.7892 \times NDSI$	
الكود المستخدم لتدريب نموذج الانحدار المتعدد واستخراج معادلة النموذج	
<pre>import pandas as pd import statsmodels.api as sm # Load the data data = pd.read_csv('ec.csv') # Define the features (X) and target (y) X = data.drop('EC', axis=1) y = data['EC'] # Add a constant to the features (for the intercept term) X = sm.add_constant(X) # Fit the model model = sm.OLS(y, X).fit() # Print the summary of the model print(model.summary()) # Extract the coefficients coefficients = model.params # Create the equation string equation = "EC = " for i, (param, value) in enumerate(coefficients.items()): if i == 0: equation += f"{value:.4f} + " else: equation += f"{value:.4f} * {param} + " equation = equation.rstrip(" + ") print(equation)</pre>	

المصدر/ تدريب نموذج انحدار خطي متعدد باستخدام python داخل برنامج vs code .

تم فحص صحة نموذج الانحدار الخطي المتعدد باستخدام مخطط التشتت وتحليل التباين (ANOVA)، ومعامل التحديد (R^2)، حيث تتم الإشارة إلى الارتباط القوي والنموذج المناسب من خلال قيم R و R^2 التي تعبر عن معامل التحديد والذي يستخدم لمعرفة القوة التفسيرية للنموذج ويشترط أن تكون قريبة من 1.0 (IBM SPSS Inc., 2012)، فمن خلال جدول (8) بلغت قيمة متوسط معامل ارتباط بيرسون ($R=0.979a$) فيما بين المتغير التابع (EC) وجميع المتغيرات المستقلة (المؤشرات الطيفية) ويعتبر ارتباط قوي، كما بلغت قيمة معامل التحديد R Square (0.982) بمعامل تحديد معدل Adjusted R Square نحو (0.952) ومعامل خطأ معياري قدره (1.224)، كما يتضح أن المتغيرات المستقلة تفسر 97% من التباين في قيم EC الملوحة المقاسة .

مجلة كلية الآداب بالوادي الجديد- مجلة علمية محكمة- العدد السابع عشر (الجزء الثاني)

جدول (8) درجة الارتباط فيما بين المتغير التابع EC والمتغيرات المستقلة.

المتغير	R	R ²	Adjusted R Square	Std. Error	F	Sig.
الدرجة	0.979 ^a	0.982	0.952	1.224	32.07	.000 ^a

المصدر/ تدريب نموذج الانحدار الخطي المتعدد باستخدام python داخل برنامج vs code .

وباستخدام تحليل (ANOVA) تم اختبار معنوية الانحدار لمعرفة مدى تأثير المتغيرات المستقلة (المؤشرات الطيفية) على المتغير التابع قيم الملوحة المقاسة (EC) ومدى قدرته في التنبؤ بملوحة التربة، فمن خلال جدول (9) نلاحظ أن قيمة التباين F بلغت (33.634) وسجلت قيمة (المعنوية) Sig^a (.000) وهي أقل من (0.001) وبالتالي نرفض الفرض الصفري ونقبل الفرض البديل الذي يعتبر دال معنوي، وبالتالي يوجد تأثير للمتغيرات المستقلة على المتغير التابع، كما يستطيع نموذج الانحدار الخطي المتعدد الذي تم إعداده التنبؤ بقيم المتغير التابع (Predicted EC) ملوحة التربة المتوقعة بالاعتماد على المتغيرات المستقلة (المؤشرات الطيفية) بمستوى دلالة إحصائية (0.00^a).

جدول (9) تحليل التباين ANOVA ^b للمؤشرات الطيفية ودرجة EC						
Model	Sum of Squares	df	Mean Square	F	Sig.	
1	Regression	454.003	9	50.445	32.07	.000a
	Residual	19.498	13	1.500		
	Total	473.500	22			
a. Predictors: (Constant), NDSSI, SI 9, MSI, SI 6, NDVI, SI 7, VSSI, SI 1, NDWI						
b. Dependent Variable: EC						

المصدر/ تحليل ANOVA^b داخل برنامج SPSS .

ثالثاً: النمذجة التنبؤية لملوحة تربة منطقة الدراسة باستخدام التعلم الآلي: (ML)

اعتمدت الدراسة في التنبؤ بملوحة التربة بمنطقة الدراسة على خوارزميات: الغابة العشوائية Random Forest وخوارزمية تعزيز التدرج الشديد (extreme Gradient Boosting) algorithm (XGBoost)، وتم استخدام لغة البايثون داخل برمجية vs code والمكتبة البرمجية pandas لقراءة البيانات؛ لتصميم وتدريب وصناعة نماذج التعلم الآلي المستخدمة، تلي ذلك عملية فحص البيانات، خاصة فحص القيم المفقودة، ثم عملية فحص الارتباطات بين مؤشرات الاستشعار من بعد فيما بينها البعض وبين قيم الملوحة المقاسة (EC).

وقد تم إعداد عدة تجارب للخروج بأفضل توقع لملوحة التربة وبأقل متوسط خطأ حيث يتم في هذه المرحلة اختبار خوارزمية التعلم الآلي المطبقة وتشغيل النص البرمجي لها وفهرست الملفات

الموجودة داخل قاعدة البيانات الجغرافية (عزيز، الخزامى وآخرون، 2023، ص 158) : (التجربة الأولى): تم فيها إنشاء نموذج Random Forest باستخدام جميع المدخلات (Features) التي يقصد بها المؤشرات الطيفية بدون أي تعديل على قيم متغيرات النموذج الافتراضية. وتم استخدام معياران هما : متوسط نسبة الخطأ Mean Squared Error (MSE) ومعامل التحديد (R^2) squared لتحديد كفاءة النموذج ومعرفة مدى تأثير (أهمية كل مؤشر طيفي) من المدخلات على أداء النموذج، وكان متوسط نسبة الخطأ Mean Squared Error (MSE) تساوى 0.3293 و $R^2=0.3963$ R-squared

جدول (10) نتائج تطبيق التجربة الأولى في خوارزمية التعلم الآلي Random forest.

feature	SI6	VSSI	B1	SI8	SI3	NDWI	SI7
importance	0.284	0.1432	0.0835	0.0833	0.06105	0.056	0.0549
feature	SI9	SI1	SI2	MSI	SAVI	NDSI	NDVI
importance	0.0549	0.05	0.0384	0.0312	0.02699	0.02144	0.01599
	Actual EC	Predicted EC	MSE=0.3293487 R ² =0.3963053				
15	1.68	1.6950					
9	0.09	0.9040					
0	0.96	1.5061					
المصدر/ استخدام لغة python داخل برنامج VS code.							

وتهدف التجربة الثانية إلى اختيار المدخلات وتحديد أفضل المؤشرات الطيفية للتعرف على ملوحة التربة، وتم فيها اختبار النموذجين (Random Forest, XGBoost) مع كل التباديل الممكنة من المدخلات المتاحة، حيث تم تدريب النموذجين على قيمة كل مؤشر طيفي إلى أن يتم إعداد مجموعات من المؤشرات من جميع الاحتمالات الممكن دمجها معاً، وفي ذلك تم تدريب النموذج لكل مؤشر بشكل مفرد، ثم تدريب كل مؤشر طيفي مع مؤشر آخر إلى أن يتم ضم كل المؤشرات الطيفية معاً، وقد بلغ عدد الاحتمالات للتباديل التي تم تجربتها 2 مرفوعاً لأس 14 احتمال بمجموع قدره (16384) احتمال لكلا النموذجين؛ لذا تم استخلاص مجموعة المؤشرات الطيفية التي أعطت أقل متوسط خطأ لاستخدامها كمدخلات افتراضية لكلا النموذجين في عملية التنبؤ.

واعتمدت التجربة الثالثة Grid Search على أن لكل نموذج متغيراته الخاصة التي يمكن تعديلها، حيث احتوت على تجربة عدة مجموعات من المتغيرات بقيم مختلفة فيما يسمى Grid Search وذلك للتوصل بأفضل مجموعة من المتغيرات، ويوضح جدول (11) المتغيرات التي تمت

تجربتها مع Random Forest بمتوسط خطأ (MSE=0.17) Mean Squared Error ومعامل تحديد ($R^2=0.6438$) R-squared

جدول (11) المتغيرات التي تمت تجربتها في خوارزمية XGBoost & Random Forest

م	المتغيرات	عدد الحالات	اسم الخوارزمية
1	param_grid = { 'n_estimators': [100, 200, 500, 1000], 'max_depth': [None, 10, 20, 30, 40, 50], 'min_samples_split': [2, 5, 10], 'min_samples_leaf': [1, 2, 4], 'max_features': ['auto', 'sqrt', 'log2'], 'bootstrap': [True, False]	1269	Random Forest
2	param_grid = { 'n_estimators': [50, 100, 200, 300] 'learning_rate': [0.01, 0.05, 0.1]	82944	XGBoost
المصدر/ استخدام لغة python داخل برنامج VS code.			

وبالاعتماد على تجربة Grid Search تم التوصل إلى أفضل مجموعة متغيرات تخص خوارزمية Random Forest، في حين كانت أفضل مجموعة متغيرات لخوارزمية التعلم الآلي XGBoost ($n_estimators=100$, $random_state=42$) مع إبقاء المتغيرات الأخرى بقيمتها الافتراضية. ويتبين من الجدول (12) أفضل نموذج تعلم آلي للتنبؤ بملوحة التربة في منطقة الدراسة، وهو نموذج XGBoost وتم تدريبه بشكل عام، حيث سجل متوسط خطأ Mean Squared Error ($MSE=0.0566$).

وبناء على نموذج التعلم الآلي XGBoost تم إنتاج خريطة تبين نسبة تركيز الأملاح المتوقعة (EC) في تربة منطقة الدراسة - جدول (13) - بأقل معامل خطأ (0.05) مما يعطى أهمية كبيرة لتقنيات التعلم الآلي في النمذجة المكانية وإنتاج خرائط تحاكي الواقع بأقل معدلات خطأ. وبناء على نموذج التعلم الآلي XGBoost تم إنتاج خريطة تبين نسبة تركيز الأملاح المتوقعة (EC) في تربة منطقة الدراسة - جدول (13) - بأقل معامل خطأ (0.05) مما يعطى أهمية كبيرة لتقنيات التعلم الآلي في النمذجة المكانية وإنتاج خرائط تحاكي الواقع بأقل معدلات خطأ.

جدول (12) قيم المتغيرات الافتراضية المستخدمة في نموذج XGBoost

وتحديد أفضل متغيرات في نموذج Random Forest

المتغيرات الافتراضية	النموذج
'bootstrap': False 'max_depth': None 'max_features': 'sqrt' 'min_samples_leaf': 1 'min_samples_split': 5 'n_estimators': 1000	Random Forest
n_estimators: int = 1, *, booster: typing.Literal["gbtree", "dart"] = "gbtree", dart_normalized_type: typing.Literal["tree", "forest"] = "tree", tree_method: typing.Literal["auto", "exact", "approx", "hist"] = "auto", min_tree_child_weight: int = 1, colsample_bytree: float = 1.0, colsample_bylevel: float = 1.0, colsample_bynode: float = 1.0, gamma: float = 0.0, max_depth: int = 6, subsample: float = 1.0, reg_alpha: float = 0.0, reg_lambda: float = 1.0, learning_rate: float = 0.3, max_iterations:	XGBoost

المصدر/ استخدام python داخل برنامج vs code.

رابعاً: مناقشة وتحليل النتائج:

تظهر النتائج إمكانية التنبؤ بملوحة التربة المتوقعة في منطقة الدراسة، وذلك من خلال تطبيق المؤشرات الطيفية المختلفة وتقنيات التعلم الآلي، وتعتبر المؤشرات الطيفية: (MDWI - MSSV - SI6- SI9) الأكثر قدرة على التنبؤ بالتباين المكاني لملوحة تربة منطقة الدراسة؛ ويرجع ذلك لاستيفاء جميع معايير اختبار النماذج وتقنيات التعلم الآلي. فقد أوضحت نتائج تطبيق خوارزميات التعلم الآلي (XGBoost) القدرة الفائقة في دقة الكشف عن ملوحة التربة المتوقعة (Predict EC) ديسى سيمنز/م بمنطقة الدراسة - شكل (13).

وبتحليل جدول (13 و 14) وخرائط الملوحة المتوقعة الناتجة عن تقنيات التعلم الآلي (XGboost) - أشكال (16 و 17) - يتبين القدرة الفائقة في التنبؤ بملوحة التربة في منطقة الدراسة، حيث يتضح التقارب الكبير في النتائج مع قيم الملوحة المقاسة، فتتراوح قيم الملوحة الناتجة عن التنبؤ بين (0.0181 و 41.198 ديسى سيمنز/م) وتغطي التربة غير المالحة 31.173 كم² (8.67%)، في حين تغطي التربة المالحة قليلاً 30.289 كم² (8.43%)، وتغطي التربة متوسطة الملوحة 168.295 كم² (46.84%)، وتصل مساحة التربة مرتفعة الملوحة 110.601 كم² (30.78%) وتبلغ مساحة التربة شديدة الملوحة 18.883 كم² (5.25%) من منطقة الدراسة. وتتركز المناطق شديدة الملوحة بالمواقع المحيطة بالبحيرات، خاصة بحيرات: البيضة، السبخة والروزيّة.

جدول (13) مقارنة قياسات ملوحة التربة المتوقعة (ديسي سيمنز/م) باستخدام (MLR , ML) بالعينات المقاسة

CODE	المقاسة EC	(XGboost)	MLR	X_Coordnat	y_Coordnat
1	8.16	8.02	8.46	245497.77	3362380.56
2	12.41	12.41	12.00	247687.36	3360950.71
3	12.40	12.40	13.03	249011.62	3360067.59
4	5.43	5.43	5.95	244292.73	3360634.34
5	5.44	5.44	6.08	239508.04	3359898.94
6	18.95	18.95	18.65	250905.59	3358044.11
7	5.50	5.50	5.31	257167.85	3355448.37
8	17.82	17.82	17.94	252004.54	3357002.23
9	5.35	5.43	5.28	248254.90	3357079.11
10	5.36	5.83	5.73	245681.71	3357320.58
11	5.46	5.46	5.30	237544.46	3366595.39
12	5.37	5.37	3.33	237194.19	3362485.03
13	16.68	16.68	16.44	242589.03	3365817.93
14	41.20	41.20	41.23	234986.03	3370749.02
15	0.20	0.20	1.28	238040.90	3371073.01
16	5.42	5.23	4.99	232523.10	3368428.10
17	5.41	5.41	5.61	227819.97	3369215.92
18	5.40	5.48	5.25	234280.51	3365856.09
19	5.50	5.50	5.43	227705.02	3373935.33
20	0.21	0.21	1.05	217418.02	3378286.97
21	2.30	2.30	2.38	224206.17	3371144.92
22	0.18	0.18	0.28	220386.97	3374629.70
23	8.07	8.07	7.81	232922.30	3372492.17
24	10.02	9.98	9.84	240121.98	3365352.91
25	7.75	7.73	7.55	230863.70	3364873.66

المصدر/ خوارزميات التعلم الآلي للتنبؤ بملوحة التربة المتوقعة (ديسي سيمنز/م) بمنطقة الدراسة.


كما أوضحت نتائج نموذج التحليل المتعدد المعايير (MLR) الذي تم تدريبه باستخدام تقنيات التعلم الآلي قدرة عالية في دقة الكشف عن ملوحة التربة المتوقعة (Predict EC) دي سي سيمنز/م في منطقة الدراسة بمتوسط خطأ (1.2) ، فمن خلال جدول (13 و 14) وشكل (14 و 15) يتضح أن قيم ملوحة التربة المتوقعة تتراوح بين 0.275 و 41.230 دي سي سيمنز/م في منطقة الدراسة وتغطي التربة غير المالحة 29.138 كم² (8.11%)، وتغطي التربة المالحة قليلاً 32.872 كم² (9.15%)، وتغطي التربة متوسطة الملوحة 168.776 كم² (46.98%)، في حين تغطي التربة مرتفعة الملوحة 110.097 كم² (30.64%) وتغطي التربة شديدة الملوحة 18.375 كم² (5.11%) من منطقة الدراسة. وتقع المناطق شديدة الملوحة في معظمها بالمواقع المحيطة بالبحيرات، خاصة بحيرات: البيضاء، السبخة والروزيّة .

ومن خلال جدول (14) وشكل (13) نلاحظ انخفاض الفرق بشكل واضح بين نتائج قياس الملوحة المتوقعة (Predict EC) ديي سي سيمنز/م المستندة على بيانات الاستشعار من بعد باستخدام نماذج التعلم الآلي والملوحة المقاسة ميدانياً.

جدول (14) خصائص الفئات المكانية لقياسات ملوحة التربة (ديي سي سيمنز/م) تبعا لطرق القياس المتبعة.


م	درجة الملوحة	الملوحة المقاسة		الانحدار الخطي المتعدد		التعلم الآلي (XGboost)	
		%	كم ²	%	كم ²	%	كم ²
1	غير مالحة	8.67	31.173	8.11	29.138	8.67	31.173
2	قليلة	8.42	30.271	9.15	32.872	8.43	30.289
3	متوسطة	47.00	168.869	46.98	168.776	46.84	168.295
4	مرتفعة	30.65	110.13	30.64	110.097	30.78	110.601
5	شديدة الملوحة	5.23	18.798	5.11	18.375	5.25	18.883
-	مجموع	100	359.241	100	359.241	100	359.241

المصدر/ استخدام python داخل برنامج VS code.



المصدر/ نتائج جدول 14


شكل (13) نتائج حساب فئات المساحة المتوقعة لقيم ملوحة التربة بمنطقة الدراسة.



المصدر/ تطبيق الانحدار الخطي باستخدام python داخل برنامج VS code واستخدام برنامج Arc GIS .


شكل (14) ملوحة التربة المتوقعة باستخدام (MLR) بالمقارنة مع القيم المقاسة

(ديسى سيمنز/م)




المصدر/ تطبيق الانحدار الخطي باستخدام python داخل برنامج VS code واستخدام برنامج Arc GIS .

شكل (15) فئات ملوحة التربة المتوقعة باستخدام (MLR) تبعاً لتصنيف FAO.




المصدر/ تطبيق (XGBOOST) باستخدام python داخل برنامج VS code واستخدام برنامج Arc GIS .
شكل (16) ملوحة التربة المتوقعة باستخدام خوارزمية بالمقارنة مع القيم المقاسة (ديسي سيمنز/م)



المصدر/ تطبيق (XGBOOST) باستخدام python داخل برنامج VS code واستخدام برنامج Arc GIS .


شكل (17) فئات ملوحة التربة المتوقعة باستخدام (XGBOOST) تبعاً لتصنيف FAO.

وللتحقق من دقة نتائج خوارزمية التعلم الآلي XGBOOST، فإنه تم قياس علاقة الارتباط فيما بين القيم الناتجة للملوحة EC المقاسة والمتوقعة (Predict EC)، حيث أظهرت قيم معامل الارتباط أن كلا النموذجين قد توقعا ملوحة تربة المنطقة بمستويات متباينة، ومع ذلك، فإن نتائج نموذج XGBOOST المستمدة من بيانات الاستشعار من البعد لها صلاحية أفضل مقارنة بنموذج الانحدار الخطي المتعدد MLR، حيث سجلت علاقة ارتباط قوية ($R^2 = 0.99$) فيما بين فئات الملوحة EC المقاسة والمتوقعة لنموذج XGBOOST، بينما سجلت علاقة الارتباط فيما بين فئات الملوحة EC المقاسة والمتوقعة لنموذج الانحدار الخطي المتعدد ($R^2 = 0.9236$) -شكلي (18- 19).



المصدر/ برنامج SPSS,V20 .



شكل (19) علاقة الارتباط بين الملوحة المتوقعة من نموذج الانحدار المتعدد والقيم المرصودة.



المصدر/ برنامج SPSS,V20 .

شكل (18) علاقة الارتباط بين الملوحة المتوقعة من التعلم الآلي والقيم المرصودة.

من خلال أشكال (14-15-16-17) والدراسة الميدانية نجد أن ملوحة تربة منطقة الدراسة تتباين من موقع لآخر؛ ويرجع ذلك لتأثرها ببعض العوامل المهمة ويأتي في مقدمتها : خصائص منسوب سطح المنخفض، حيث تزداد ملوحة التربة في المواقع ذات المنسوب المنخفض لقربها من مستوى المياه الباطنية، ويتضح ذلك بالقرب من البحيرات التي تعد أبرز الظواهر الطبيعية التي توجد بمنخفض وادي النظرون، وتقع على أدنى نقاط المنطقة انخفاضاً، وهو قاع المنخفض متخذة مجموعة من البحيرات الملحية تمتد في سلسلة من الجنوب الشرقي إلى الشمال الغربي لمسافة 30 كم تقريباً، وأظهرت دراسة (حمدينه عبدالقادر العوضي، 2005، ص3) وجود سبع وثلاثين بحيرة في قاع المنخفض يتعرض معظمها للجفاف الكلي في الصيف بينما يظل بعضها باقياً دون جفاف ويبلغ عددها الحالي بالمنخفض نحو 12 بحيرة رئيسية، وتحصر فيما بينها عدد من البرك صغيرة الحجم .

البحيرة	صورة مرئية Land Sat 8 OLI	البحيرة	صورة مرئية Land Sat 8 OLI
البيضة		الحمراء	
السبخة		الروزينة	

شكل (20) مخطط يوضح مدى تملح التربة بجانب البحيرات بمنخفض النطرون.

وتتسم هذه البحيرات بأنها دائمة وإما مؤقتة فالبحيرات الدائمة كبحيرة أم ريشا وبحيرة الجعار - شكل (20)، وتعد هذه البحيرات كبيرة المساحة ولا يقل عمق المياه بها عن نصف المتر، ورغم وجود المياه في بعض البحيرات على مدار السنة فإن منسوب المياه بها متذبذب، حيث يرتفع بداية من منتصف الخريف ويزداد في فصل الشتاء بينما يأخذ في الانخفاض بداية من منتصف الربيع ويعاود الارتفاع في الصيف، أما البحيرات المؤقتة كبحيرة السبخة التي تظهر بشكل موسمي في الخريف والشتاء فإنها تتحول إلى أراضٍ سبخية ملحية في نهاية الربيع وأثناء الصيف نظراً لارتفاع معدلات التبخر وقلة مياه الري المنصرفة للمنخفض.

الخاتمة:

تعد خرائط ملوحة التربة ذات أهمية كبيرة للإدارة الحديثة للأراضي الزراعية، كما أن التقنيات الجغرافية المكانية ضرورية لتطوير نماذج التنبؤ بملوحة التربة. ومن خلال تطبيق تقنيات التعلم الآلي وتدريب نموذج الانحدار المتعدد المعايير بالاعتماد على بيانات الاستشعار من البعد من خلال المؤشرات الطيفية المختصة بدراسة تركيز الأملاح بالتربة والنبات والمياه توصلت الدراسة للنتائج والتوصيات التالية: -

النتائج

- 1- استخدام صور Landsat 8 OLI لمنطقة الدراسة يمكن أن يستفاد منها في تحديد ملوحة التربة، حيث تتسبب التربة المتأثرة بالملوحة والتي تحتوي على قشرة ملحية على السطح في انعكاس مرتفع للطاقة المرئية والأشعة تحت الحمراء القريبة.
- 2- تظهر الدراسة كفاءة تقنيات التعلم الآلي وتحليل الانحدار الخطي المتعدد للتنبؤ بملوحة التربة بمنطقة الدراسة.

- 3- أظهر نموذج التعلم الآلي XGBOOST القدرة الكبيرة على التنبؤ بملوحة تربة منطقة الدراسة من بيانات الاستشعار من البعد، حيث سجل علاقة ارتباط قوية ($R^2 = 0.99$) فيما بين قيم الملوحة EC المقاسة والمتوقعة لنموذج بمتوسط خطأ (0.05).
- 4- يرتفع المحتوى الملحي لتربة منطقة الدراسة بالقرب من البحيرات، حيث تعد البحيرات من أبرز الظواهر الطبيعية المتغيرة التي توجد بمنخفض وادي النطرون، وتقع على أدنى نقاط المنطقة انخفاضاً.
- 5- يظهر نموذج الانحدار المتعدد المطور قدرة كبيرة في التنبؤ بملوحة التربة بالاعتماد على بيانات الاستشعار من البعد، حيث سجلت علاقة الارتباط فيما بين مساحات الملوحة EC المقاسة (كم²) والمساحات المتوقعة لنموذج الانحدار المتعدد ($R^2 = 0.9236$).
- 6- تراوحت قيم ملوحة التربة المقاسة بمنطقة الدراسة (EC) بين (0.18 و 41.2 ديسي سيمنز/م) في حين أظهرت نتيجة نموذج XGBOOST أن قيم ملوحة التربة تراوحت بين (0.0181 و 41.198 ديسي سيمنز/م)، في حين تراوحت قيم ملوحة التربة الناتجة عن تطبيق نموذج الانحدار المتعدد بين (0.275 و 41.230 ديسي سيمنز/م) في منطقة الدراسة.
- 7- أظهرت الدراسة أن تقنيات تحسين صور الأقمار الاصطناعية التي تتكون من مؤشرات طيفية تمتلك إمكانيات كبيرة في دراسة خصائص التوزيع المكاني لملوحة التربة بمنطقة الدراسة.

التوصيات

توصى الدراسة بما يلي:

- 1- تطبيق تقنيات التعلم الآلي (ML) المعتمدة على بيانات الاستشعار من بعد في دراسات ملوحة التربة، خاصة خوارزمية XGBOOST.
- 2- الاستفادة من التقنيات الجيومكانية خاصة تحليل الانحدار الخطي المتعدد (MLR) وتكاملها في دراسات ملوحة التربة.
- 3- توصي الدراسة بالتوسع في أبحاث مشابهة على مناطق أخرى بجمهورية مصر العربية.
- 4- تشجيع الاستثمار الحكومي والخاص للتوسع في مشروعات الاستصلاح الزراعي بمنطقة وادي النطرون.
- 5- ضرورة التوسع في معالجة التربة المتأثرة بالملوحة في أماكن البحيرات بمنطقة الدراسة من قبل الجهات البحثية العلمية.

المصادر والمراجع العربية

1. أبو الفضل، طارق حمد (2022) التقييم البيئي لملح الرتبة منطقة غرب الموهوب- بالوحدات الداخلة :باستخدام نظم المعلومات الجغرافية، مجلة كلية الآداب بقنا، جامعة جنوب الوادي - العدد (57) أكتوبر.
2. النعيمي، محمد عبد العال وآخرون (2009): طرق ومناهج البحث العلمي، الوراق للنشر والتوزيع، عمان، الأردن.
3. حامد ، صفاء حسن (2021): التباين المكاني لمؤشرات ملوحة التربة باستخدام تقانات الاستشعار عن بعد ونظم المعلومات الجغرافية، رسالة ماجستير، جامعة النيلين السودان.

4. خير، صفوح (2000): الجغرافية، موضوعها ومناهجها وأهدافها، دار الفكر: دمشق.
5. الربيعي، داود جاسم (1988): ظاهرة الملوحة في القسم الجنوبي من السهل الرسوبي، مجلة الخليج العربي، مج 20، العدد 2 مركز دراسات الخليج العربي، جامعة البصرة.
6. الزبيدي ، أحمد حيدر(1994): استصلاح الأراضي الملحية في الوطن العربي، مجلة الزراعة والتنمية في الوطن العربي، المنظمة العربية للتنمية الزراعية، السنة 13، العدد 1، بغداد.
7. العتايي ، جاسم شهاب حمد وآخرون (2019): دراسة التغيرات المكانية لملوحة التربة الترب في مشروع شيخ سعد باستخدام تقنيات الاستشعار عن بعد RS ونظم المعلومات الجغرافية GIS، مجلة الزراعة العراقية البحثية، مجلد 24 عدد (1) العراق.
8. عزيز، محمد الخزامي وآخرون (2023) : تكامل نظم المعلومات الجغرافية مع البرمجة والذكاء الاصطناعي الجيومكاني لدعم اساليب تحليل البيانات المكانية ، مجلة كلية الآداب جامعة جنوب الوادي ، المجلد 32 ، العدد 60 ، يوليو.
9. العوضي ، حمدينه عبد القادر (2005) : بحيرات منخفض وادي النطرون. دورية الإنسانيات العدد 16.

المراجع الأجنبية

1. Abd El-Hamid, H. T., & Hong, G. (2020). Hyperspectral remote sensing for extraction of soil salinization in the northern region of Ningxia. *Modeling Earth Systems and Environment*, 6(4), 2487-2493.
2. Abdel-Hamid, A. (2008). Integration of new technology systems for soil reclamation and evaluation at El-Gahar area, Wadi El-Natron, Egypt (unpublished masters thesis). Faculty of Agriculture, Alexandria.
3. Ali, R. R., & Shalaby, A. (2012). Response of topsoil features to the seasonal changes of land surface temperature in the arid environment. *International Journal of Soil Science*, 7(2), 39.
4. Chen, T., & Guestrin, C. (2016). XGboost: A scalable tree boosting system. In *Proceedings of the 22nd international conference on knowledge discovery and data mining* (pp. 785-794).
5. Chen.Q , Shaochun Y, Ya, W, Chao W, Yifan Z,(2021): Prediction and modeling of petrophysical parameters of deep-buried, low permeability glutenite reservoirs in Yubei area, Turpan-Hami Basin, China, *Journal of Petroleum Science and Engineering*, Volume 207 .
6. Davis, E., Wang, C., & Dow, K. (2019). Comparing Sentinel-2 MSI and Landsat 8 OLI in soil salinity detection: A case study of agricultural lands in coastal North Carolina. *International Journal of Remote Sensing*, 40(16), 6134-6153.
7. Dehni, A., & Lounis, M. (2012). Remote sensing techniques for salt affected soil mapping: application to the Oran region of Algeria. *Procedia Engineering*, 33, 188-198.
8. FAO. (1985): Land evaluation for irrigated agriculture. Soils Bulletin 55-FAO. FAO. Rome.

9. Farifteh, J., Van der Meer, F., Atzberger, C., & Carranza, E. J. M. (2007). Quantitative analysis of salt-affected soil reflectance spectra: A comparison of two adaptive methods (PLSR and ANN). *Remote Sensing of Environment*, 110(1), 59-78.
10. Gorji, T., Sertel, E., & Tanik, A. (2017). Monitoring soil salinity via remote sensing technology under data scarce conditions: A case study from Turkey. *Ecological indicators*, 74, 384-391.
11. Khan, N. M., Rastoskuev, V. V., Shalina, E. V., & Sato, Y. (2001). Mapping salt-affected soils using remote sensing indicators-a simple approach with the use of GIS IDRISI.
12. Ma, J., Yu, Z., Qu, Y., Xu, J., & Cao, Y. (2020). Application of the XGBoost machine learning method in PM2. 5 prediction: a case study of Shanghai. *Aerosol and Air Quality Research*, 20(1), 128-138.
13. Machinery, A. F. C. (2016). Advancing Computing as a Science & Profession.
14. Morshed, M. M., Islam, M. T., & Jamil, R. (2016). Soil salinity detection from satellite image analysis: an integrated approach of salinity indices and field data. *Environmental monitoring and assessment*, 188, 1-10.
15. Ozgur, C., Hughes, Z., Rogers, G., & Parveen, S. (2016). Multiple linear regression applications in real estate pricing. *International Journal of Mathematics and Statistics Invention (IJMSI)*, 4(8).
16. Pan, B. (2018, February). Application of XGBoost algorithm in hourly PM2. 5 concentration prediction. In *IOP conference series: earth and environmental science* (Vol. 113, p. 012127). IOP publishing.
17. Rigatti, S. J. (2017). Random forest. *Journal of Insurance Medicine*, 47(1), 31-39.
18. Schneier-Madan, G., & Courel, M. F. (2010). Water and sustainability in arid regions. *High demand in a land of water scarcity: Iran*, 75-87.
19. Shaw, R. J. (1994). *Estimation of the electrical conductivity of saturation extracts from the electrical conductivity of 1: 5 soil: water suspensions and various soil properties*. Department of Primary Industries Queensland.
20. SPSS, I. B. M. (2012). *Statistics for windows*. Armonk, Ny: IBM Corp.
21. Tarsha Kurdi, F., Amakhchan, W., & Gharineiat, Z. (2021). Random forest machine learning technique for automatic vegetation detection and modelling in LiDAR data. *International Journal of Environmental Sciences and Natural Resources*, 28(2).
22. Wang, H. (2023). Research on the application of Random Forest-based feature selection algorithm in data mining experiments. *International Journal of Advanced Computer Science and Applications*, 14(10).
23. Wardlow, B. D., & Egbert, S. L. (2008). Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the US Central Great Plains. *Remote sensing of environment*, 112(3), 1096-1116.
24. Zhang, T. T., Qi, J. G., Gao, Y., Ouyang, Z. T., Zeng, S. L., & Zhao, B. (2015). Detecting soil salinity with MODIS time series VI data. *Ecological Indicators*, 52, 480-489.