

النمذجة التنبؤية بملوحة التربة لنخفض وادى النطرون

باستخدام تقنيات الاستشعار من المبعد والتعلم الآلي (ML)

د/ سحر نور الدين توفيق^(*)

ملخص البحث

تعتبر ملوحة التربة من أكثر عوامل تدهور الأراضي شيوعاً والتي تضعف خصوبتها وتأثير 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 (ديسيسمتر/م) بمنطقة الدراسة. تم تطبيق نماذج (الانحدار الخطى البسيط والمتمعدد) وخوارزميات الغابة العشوائية Random Forest، وXGBoost، وذلك من خلال الاعتماد على تقييم أداء (١٤) مؤشراً طيفياً مستمدة من بيانات القمر الصناعي Landsat 8 OLI وملوحة التربة المقاسة من (٢٥) عينة بعمق (٠ - ٣٠ سم). وسجل السيناريو الأول للتحليل أعلى معامل ارتباط لمؤشر (SI) بقيمة ($R=0.84$) وبمعامل تحديد ($R^2=0.69$) يليه مؤشر (VSSI) الذي يعبر عن ملوحة التربة والنبات بمعامل ارتباط ($R=0.70$) ومعامل تحديد ($R^2 = 0.49$)، وأمكن التوصل إلى تطوير نموذج انحدار خطى متعدد بتقنيات التعلم الآلي لملوحة التربة المتوقعة بمعامل خطأ (١.٢٢٤) 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 نسبة تركيز الأملاح المتوقعة في تربة وادى النطرون، حيث تراوحت بين (١٨١٠ و ٤١٩٨ ديسىسمتر/م) بمعامل خطأ (٠٠٥)، واتفقت نتائجه مع البيانات المقاسة بشكل كبير (٠٠١٨ و ٤١٠٢ ديسىسمتر/م). وكشفت نتائج الدراسة إمكانية فائقة لتقنيات التعلم الآلي في النمذجة التنبؤية لرسم خرائط ملوحة التربة المتوقعة لإدارة التربة المالحة ومعالجتها ومراقبتها واستخدامها، كما قدمت الدراسة رؤى 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

ABSTRACT

**Predictive Modeling of Soil Salinity for Wadi Natroun depression
Using RS and Machine Learning (ML) Techniques**

Soil salinity is one of the most common factors of land degradation that impairs land fertility and negatively affects agricultural production. The study discussed the application of predictive modeling, which is a powerful technique to enhance prediction accuracy and make informed decisions based on statistical algorithms and machine learning techniques in developing a predictive model to detect expected soil salinity (decimens/m) in the study area. Models (simple and multiple linear regression) and Random Forest and XGBoost algorithms were applied by relying on evaluating the performance of (14) spectral indicators derived from Landsat 8 OLI satellite data and soil salinity measured from (25) samples at a depth of (0 to 30 poison). The first scenario of the analysis recorded the highest correlation coefficient for the index (SI 6) with a value of ((R=0.84). With a coefficient of determination ($R^2 = 69$), followed by the index (VSSI), which expresses the salinity of soil and plants with a correlation coefficient (R = 0.70) and a coefficient of determination ($R^2 = 0.49$), it was possible to develop a multiple linear regression model using machine learning techniques for the predicted soil salinity with a coefficient of error (1.224) and coefficient of determination ($R^2 = 0.982$). While the second scenario relied on developing a predictive model based on the XGBoost algorithm, Through it, a map was prepared showing the percentage of expected salt concentrations in the soil of Wadi El Natroun, which ranged between (0.0181 and 41.198 decisiemens/m) with a factor of error (0.05), and its results agreed with the measured data to a large extent (0.18 and 41.2 decisiemens/m). The results of the study revealed the superior potential of machine learning techniques in predictive modeling to map expected soil salinity to manage, treat, monitor and use salty soils. The study also provided valuable insights into choosing appropriate spectral indicators to identify soil salinity in the Natroun region and in similar 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 سلباً على نمو النباتات وإنتاج المحاصيل وجودة التربة والمياه، خاصة عندما تبلغ درجة التوصيل الكهربائي بالترابة(EC) أكثر من ٤ ديسيسيمنز / م عند ٢٥ درجة مئوية (Morshed et al. 2016). كما تهدد هذه الظاهرة: الزراعة والأمن الغذائي المرتبط بصلاحية التربة، مما يؤدي إلى تدهور الأراضي وفقدان خصائصها الأساسية لاستدامة الحياة. كما لا يتوقف تأثير ملوحة التربة على ذلك، بل تؤثر أيضاً على تدهور الأراضي ومن ثم الاقتصاد القومي، لذا جاءت أهمية استخدام بيانات الاستشعار من بعد في إنتاج خرائط ملوحة

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

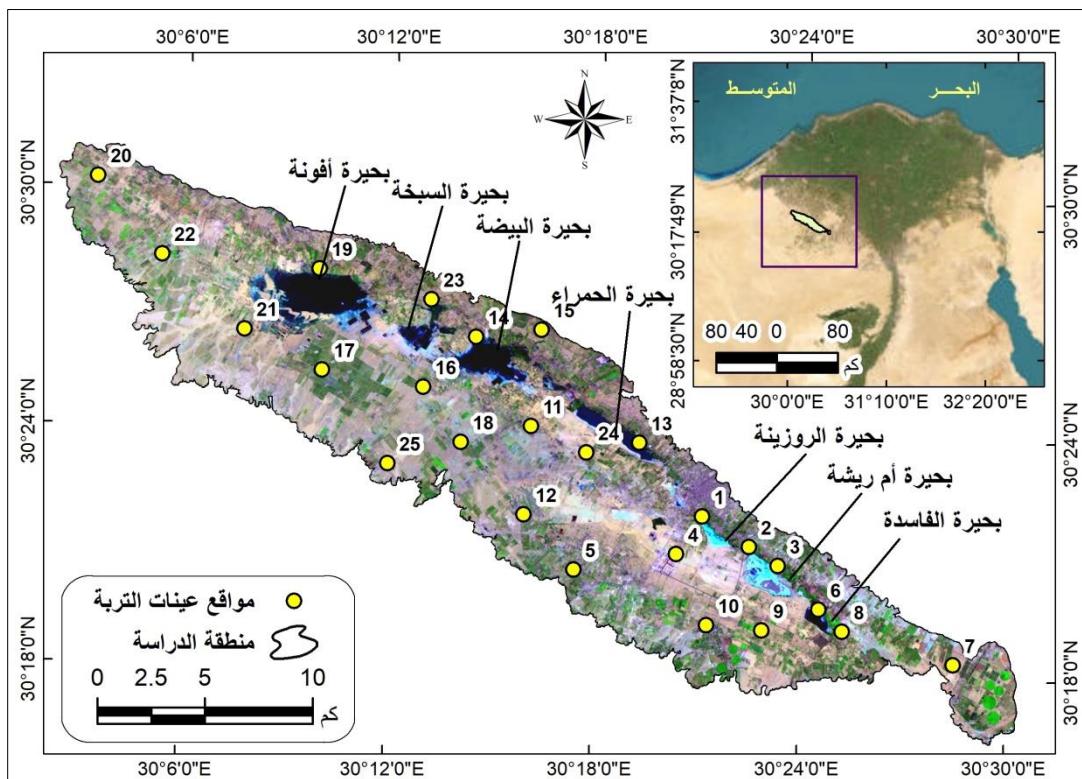
التربة (Schneier et al. 2010)، حيث يعد استخدام النطاق المركي للطيف الكهرومغناطيسي إلى الأشعة تحت الحمراء القريبة أكثر فعالية في تحديد نسبة الأملاح في التربة وخصائص المحاصيل المتأثرة بالملوحة. وقد تم الاستعانة حديثاً بالنمذجة الإحصائية خاصة نماذج الانحدار الخطي البسيط والمتعدد للتتبؤ بالتوزيع المكاني لملوحة التربة، وللوصول إلى نتائج أكثر دقة تم استخدام الذكاء الاصطناعي المكاني في الدراسة الحالية، خاصة: خوارزميات التعلم الآلي : XGBoost و Random Forest استناداً على المؤشرات الطيفية للكشف والتتبؤ بملوحة التربة بشكل فعال وكمي، ومن ثم تقييم ملوحة التربة 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 جيوبتقنية 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 مكаниاً و زمنياً، خاصة أن الطرق التقليدية لتقييم الملوحة المتعلقة بالترابة تهمل دور النباتات في حساب الملوحة؛ لذا تعمل بيانات الاستشعار من بعد عند نمذجتها وإدارتها بتقنيات التعلم الآلي (ML) في تكوين نظرة شاملة لتحليل الملوحة اعتماداً على (خصائص التربة، النبات، المياه، المناخ).

منطقة الدراسة:

يتبع منخفض وادي النطرون محافظة البحيرة إدارياً وهو منخفض ضيق يقع في الجزء الجنوبي الغربي من دلتا النيل -شكل (١)، ويقع فيما بين دائري عرض ٢٠°٠٦' و ٢٠°٣٠' و طول ٣١°١٨' و ٣٠°٣٠' شمالي، وبين خطى طول ٢١°٢١' و ٣٠°٥٠' و ٣٠°٢٨' شرقاً، وتصل مساحته نحو ٣٥٩,١٢ كم^٢، ويأخذ المنخفض اتجاه عام جنوب شرق / شمال غربي مع وجود انحدار عام من الغرب إلى الشرق، ويصل أدنى منسوب لقاع المنخفض ٢١٠٩٧- ٢١٠٩٨ م (تحت مستوى سطح البحر) ويمثله مجموعة من البحيرات -شكلي (١-٢) وقد تستخدم لتجمیع الملح الذي تشتهر به بحیرات المنطقة. بهذا الموقع فإن منطقة الدراسة تقع على هامش دلتا النيل بالقرب من مدینتي: القاهرة والإسكندرية والمراکز العمرانیة الجديدة غرب الدلتا، خاصة مدینتي: السادات والتحریر، مما شجع على بدء عمليات الاستصلاح الزراعي واستغلال الموارد الأرضية بالمنخفض.



المصدر/ اعتماداً على الخرائط الطبوغرافية مقياس رسم ٢٥٠٠٠/١ وصور ٨ ٢٥٠٠٠ وصور ٨ Land Sat OLI

شكل (١) مرئية فضائية Land Sat 8 توضح موقع منطقة الدراسة



إشكالية البحث:

تكمن مشكلة الدراسة في طبيعة منسوب المخلف من الماء يصل إلى (٢١٠.٩٧) م، واقتراض سطح المخلف من مستوى المياه الجوفية؛ ومن هنا جاءت الحاجة إلى إعداد خرائط لمراقبة ملوحة التربة والتنبؤ بها - صورة (٢) وذلك بتكلفة أقل وأسرع لزيادة الإنتاج الزراعي - صورة (١)، وتحديد ممارسات أفضل لإدارة الأراضي الزراعية والحد من تدهورها، خاصةً أن الدراسة الحالية تقدم رؤى جديدة تستند على تقنيات علمية حديثة بشأن التنبؤ بالتباين المكاني لتلخ التربة، 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 للتغير المناخي.

	
صورة (٤) تلخ التربة بمنطقة بحيرة الحمرا	صورة (٣) زراعات أشجار البرتقال بمنطقة 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 تناسب 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 سابقة:

تتمثل أبرز الدراسات فيما يلي - :

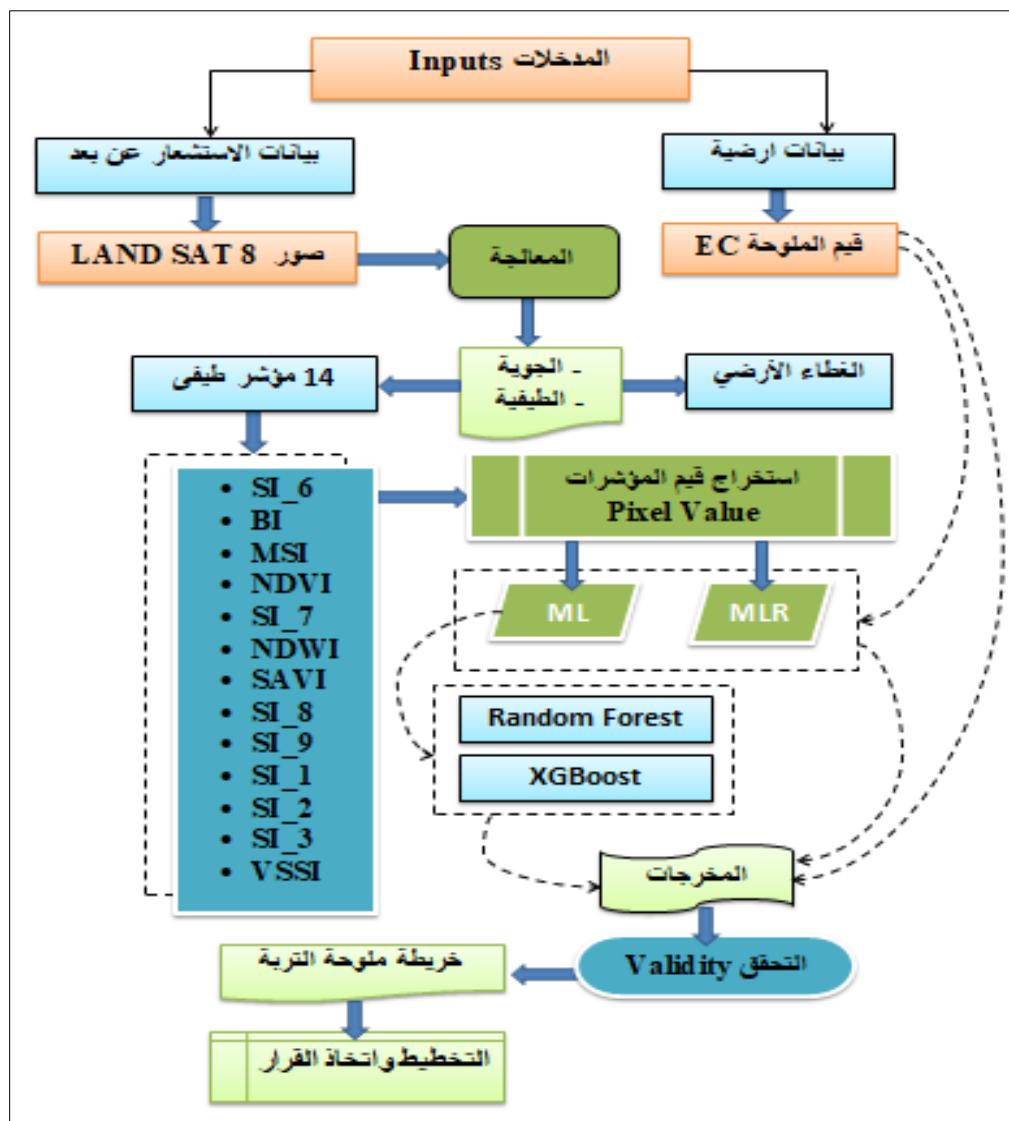
دراسة (Mahmoud, M. G , Mostafa H. A. 2022) ، وتناولت تقدير الملوحة باستخدام بيانات الاستشعار عن بعد على مدينة الشيخ زايد بمحافظة الجيزة في مصر. دراسة: طارق حمد أبو الفضل إبراهيم (٢٠٢٢) وتناولت التقييم البيئي لتلخ التربة منطقة غرب الموهوب- بالواحات الداخلة باستخدام نظم المعلومات الجغرافية، مجلة كلية الآداب، جامعة قنا. دراسة: Abd El Hamid HT, Hong, G.(2020) وتناولت استخدام الاستشعار عن بعد لاستخراج تلخ التربة شمال نينغشيا الصينية. دراسة: Hammam A.A. and Mohamed E.S.(2020) وانتجت خرائط لملوحة التربة في شرق دلتا النيل باستخدام عدة طرق منهجية لتقييم الملوحة. مصر. دراسة: صفاء حسن حامد، ٢٠٢١ : وفيها تم تحليل التباين المكانى 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 للتغير ملوحة التربة باستخدام بيانات الاستشعار عن بعد. دراسة: جاسم شهاب حمد العتابى، وآخرون (٢٠١٩) : دراسة التغير المكانى لملوحة التربة في مشروع شيخ سعد باستخدام تقنيات الاستشعار عن بعد دراسة: Shahid SA, Zaman M, Heng L.(2018) وتناولت ملوحة التربة: وجهات نظر تاريخية ونظرة عامة على المشكلة. دراسة: Triki Fourati H, Bouaziz M, Benzina M, Bouaziz S. (2015) وتناولت نبذة ملوحة التربة في المناطق شبه الجافة باستخدام التحليل الطيفي. دراسة: Abdel-Hamid, A. (2008) وتناولت الدراسة التحليل المكانى لبعض مؤشرات قدرة التربة للإنتاج الزراعي بمنخفض النطرون. دراسة: ALI and A.A. El Baroudy,(2008) وتناولت التحليل المكانى لتقييم الحساسية البيئية للتصحر في منخفض النطرون . دراسة حمديه عبد القادر السيد العوضي (٢٠٠٥) وتناولت دراسة الخصائص المورفومترية والمورفولوجية والهيروولوجية لبحيرات النطرون، وإمكاناتها. دراسة: Khan NM, Rastoskuev V V, Shalina E V, Sato Y(2001) وتناولت رسم خرائط للترابة المتأثرة بالملوحة باستخدام مؤشرات الاستشعار عن بعد. دراسة: أحمد حيدر الزبيدي (١٩٩٤) : وناقشت استصلاح الأراضي الملحة في الوطن العربي. دراسة: داود جاسم الريبيعي (١٩٨٨) : وتناولت ظاهرة ملوحة التربة في القسم الجنوبي من السهل الرسوبي بجنوب دولة العراق.

تساؤلات الدراسة:

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

٤- منهجية الدراسة وأساليبها:

اتبعـت الـدراسـة بـعـض المـناـهـج وـالـأـسـالـيـب الـعـلـمـيـة، يـأـتـي فـي مـقـدـمـتها المـنـهـج الـاستـبـاطـي فـي اـسـتـنـتـاجـ الـحـقـائـق لـتـقـسـيرـ التـغـيـرـ فـي مـلـوـحةـ التـرـبـةـ، وـالـمـنـهـجـ الـوـصـفـيـ لـوـصـفـ الـظـاهـرـاتـ الطـبـيعـيـةـ، وـالـمـنـهـجـ الـتـحـلـيلـيـ فـي مـعـالـجـةـ وـتـحـلـيلـ بـيـانـاتـ الـاـسـتـشـعـارـ مـنـ الـبـعـدـ، بـإـلـاـضـافـةـ إـلـى بـعـضـ الـأـسـالـيـبـ الـجـيـوـتـقـنيـةـ:ـ الـتـعـلـمـ الـآـلـيـ وـالـنـمـذـجـةـ الـإـحـصـائـيـةـ فـي التـبـؤـ بـمـلـوـحةـ التـرـبـةــ شـكـلـ (٢ـ).ـ وـتـمـ الـمـعـالـجـةـ الـمـسـبـقةـ الـمـطـلـوـبـةـ لـصـورـ الـأـقـمـارـ الـاـصـطـنـاعـيـةـ، وـحـاسـبـ أـهـمـ الـمـؤـشـراتـ الـطـيفـيـةـ لـمـلـوـحةـ التـرـبـةـ وـالـغـطـاءـ الـنبـاتـيـ الـمـوـصـيـ بـهــ جـدـولـ (١ـ)ـ وـرـسـمـ خـرـائـطـ لـهــ،ـ وـذـلـكـ بـعـدـ اـسـتـخـرـاجـ قـيمـ الـانـعـكـاسـ الـطـيفـيــ لـمـؤـشـراتـ الـغـطـاءـ الـنبـاتـيـ،ـ التـرـبـةـ وـالـمـيـاهـ،ـ وـالـتـيـ تـمـ حـاسـبـهــ بـاـسـتـخـدـامـ نـطـاقـاتـ الصـورـ الـفـضـائـيــ.



المصدر: إعداد الباحثة اعتماداً على الأساليب العلمية للدراسة.

شكل (٢) مخطط يوضح منهجية وأساليب الدراسة

مصادر البيانات ومعالجتها:

اعتمدت الدراسة على معطيات مكانية متعددة، حيث تم جمع إجمالي (٢٥) عينة للتربة بمنطقة الدراسة- شكل (١)- واستخدم نظام تحديد المواقع العالمي GPS في تحديد مواقعها، وأجرى على العينات التحليل المعملي لتحديد ملوحة مستخلص التربة من حيث التوصيل الكهربائي (EC) وفقاً لدراسة (Shaw, R.el 1994)، واستخدام برنامج ArcGIS 10,8.1 لإنشاء قاعدة بيانات تحتوي على قيم ملوحة التربة ديسسمينز /م (EC)، واستخدمت طريقة kriging لإنناج طبقة رقمية للقياسات الميدانية. كما اعتمدت الدراسة على بيانات الاستشعار من البعد (OLI-8).Landsat 8 Universal Transverse Mercator (UTM) ونظام الإحداثيات (WGS84). وتحتوي الصورة على غيوم أقل من ١٠٪، وسمت الشمس (١٢٧.٠٨°)، وارتفاع الشمس (٤٤.٤٠°). كما تم بناء نموذج المناسيب الرقمي بالاعتماد على أداة الاستكمال المكاني IDW اعتماداً على الخرائط الطبوغرافية مقاييس رسم ٢٥٠٠٠:١، 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 ومشاهدة الظاهرات الطبيعية والبشرية وإجراء عمليات التحقق الميداني.

جدول (١) البيانات المستخدمة في الدراسة

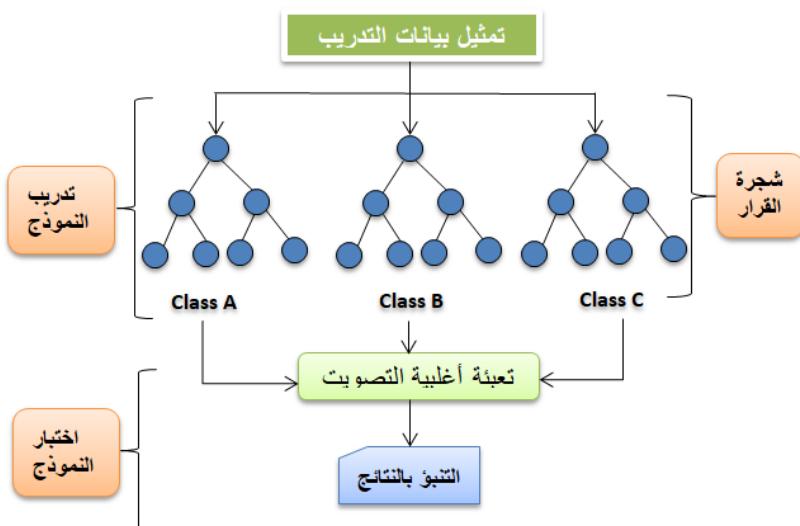
صور المرئيات الفضائية						
المصدر	الهدف	Row	PATH	الدقة المكانية	المستشعر	تاريخ التصوير
usgs	المؤشرات الطيفية			٣٠	OLI_TIRS	٢٠٢٣-٩-٢٦ لأندستس (٩)
نموذج المناسيب الرقمي						
المصدر	الهدف	الدقة المكانية	التاريخ		النوع	
وكالة الفضاء الأوروبية	خصائص السطح	12.5m	٢٠٠٨-٥-٢٠		Alos Palsar	
خصائص السطح	الخرائط الطبوغرافية	10m	١٩٩٢-٧-١٠		Dem	
عينات التربة						
المصدر	العمق	العدد		نوع التحليل		
الدراسة الميدانية	35-60 cm	٢٩		قياس ملوحة التربة		
الخرائط الجيولوجية والطبوغرافية						
الزيارة الميدانية						

المصدر/ إعداد الباحثة.

(٣-٦) أساليب الدراسة:

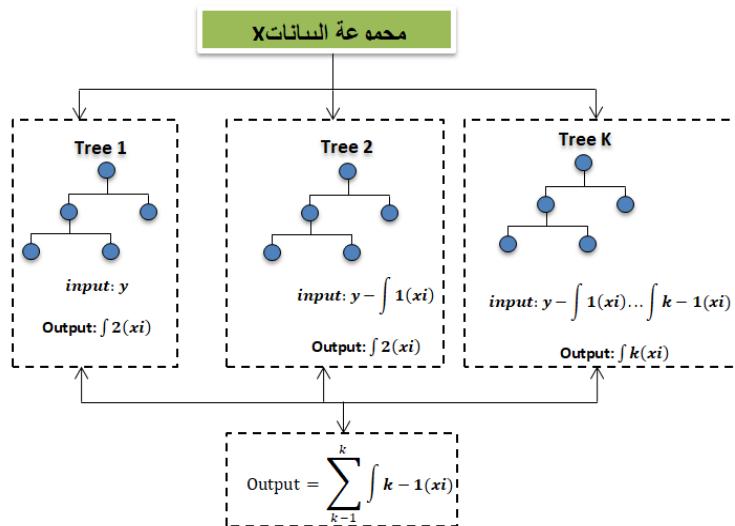
تم الاستعانة بمجموعة من الأساليب والأدوات البحثية الحديثة لمعالجة وتحليل بيانات الاستشعار من بعد المستخدمة في الدراسة، ويأتي في مقدمتها النمذجة التنبؤية باستخدام خوارزميات التعلم الآلي(ML) ونماذج الانحدار الخطى البسيط والمتعدد Multiple Linear Regression.

ومن أهم خوارزميات التعلم الآلي التي اعتمدت عليها الدراسة، نموذج الغابة العشوائية Random Forest ونموذج XGBoost - شكلي(٤-٣). وتعد خوارزمية Random Forest إحدى تقنيات التعلم الآلي الشجري القوية، حيث تعتمد على مجموعة كبيرة جدًا 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" ، وتقسم كل شجرة تتبؤها، 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) Extreme Gradient Boosting algorithm (Gharineiat, Z,2021) (Gradient Boosting) هو نموذج تعلم آلي متكامل يعتمد على التعزيز المتدرج (XGBoost) وقدمه (Chenet al. 2016) ، ويعد من أكثر الخوارزميات قوة وكفاءة في حل مشاكل التصنيف والانحدار (Jinghui M, Zhongqi Y, Yuanhao Q,2020) ، و تستند فكرته الأساسية على بناء عدة نماذج بسيطة (عادةً أشجار قرار ضعيفة) بطريقة تدريجية وتحاول 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 معًا بطريقة تسلسليّة لتصحيح الأخطاء.



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

شكل(٣) مخطط يوضح خوارزمية التعلم الآلي الغابة العشوائية Random Forest



المصدر: اعداد الباحثة بناء علم، دراسة
(Chen.Q , Shaochun Y, Ya. W, Chao W, Yifan Z, 2021)
شكل(٤) مخطط يوضح خوارزمية التعلم الآلى XGBoost

نموذج Random Forest

معادلة (١)

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

التنبؤ النهائي للقيمة الخاصة بالنقطة $i\mathcal{x}$. متوسط التنبؤات لجميع الأشجار.

عدد الأشجار المستخدمة في الغابة **Random Forest** للتنبؤ

التنبؤ الناتج من الشجرة k للنقطة $i\mathcal{x}$ كل شجرة في الغابة تقوم باعطاء تنبؤ، ويستخدم المتوسط .
 النقطة أو العينة التي نريد التنبؤ لها.

نموذج XGBoost

معادلة (٢)

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

الدالة الهدف

$Obj(\theta)$

n

عدد العينات في مجموعة البيانات

$i\mathcal{g}$

المشتقة الأولي لدالة الخسارة بالنسبة للتنبؤات الحالية

$f_t(x_i)$

التنبؤ الجديد الناتج عن الشجرة t للعينة $i\mathcal{x}$

$k\gamma T$

جزء من مصطلح تنظيم للتأكد من أن عدد الأشجار لا تصبح معقدة

λ

مصطلح تنظيم آخر للتحكم في قيم الأوزان الكبيرة للأوراق

jw

الوزن المرتبط بالورقة 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

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

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

كما اعتمدت الدراسة على النمذجة الإحصائية المكانية، ويأتي في مقدمتها نموذج الانحدار الخطى المتعدد (MLR) ، وتم استخدام برامجيات، Multiple Linear Regression (MLR) و VC Cod spss و لكتابة الأكواد البرمجية والتحليل الإحصائى لبيانات الاستشعار من البعد.

$Y = a + b_1X_1 + b_2X_2 + \dots + e$	معادلة (٣)
	Y = المتغير التابع
	a = قيمة ثابتة أو Intercept
	b_1 = ميل الإنحدار y على المتغير المستقل الأول
	b_2 = ميل الإنحدار y على المتغير المستقل الثاني
	X_1 = المتغير المستقل الأول
	X_2 = المتغير المستقل الثاني

المصدر : (Ozgur, Ceyhun,et al,2016)

جدول (٢) المعادلات المستخدمة للتحليلات الطيفية لملوحة التربة

م	المؤشر الطيفي	العمليات الحسابية للقوى الموجية	المرجع
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 V V(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 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	$NDWI = \frac{(NIR - SWIR)}{(NIR + SWIR)}$	(Cheng Y, et al. 2008)
14	Soil adjusted vegetation index (L=0.5)	$SAVI = (1 + L) \times NIR - \frac{R}{L} + NIR + R$	(Dehni A et al.2012)

B= Blue , G= Green , R= Red ,NIR =Near Infrared

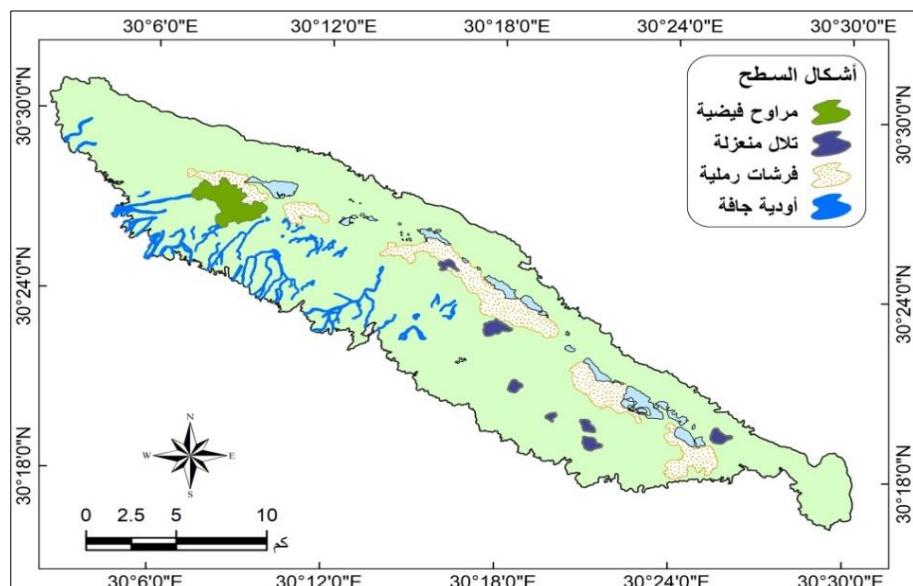
ثانياً: مناقشة وتحليل النتائج:

١- خصائص سطح لمنخفض النطرون:

يعد منخفض النطرون منخفضاً صحرائياً يمتد على حافة الدلتا والصحراء الغربية، وهو منخفض مغلق وله انحدار داخلي محسوس نوعاً 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 منها له مظاهره التضاريسية، وفيما يلي خصائص هذه الوحدات التضاريسية بمنطقة الدراسة:

أ- حواف المنخفض:

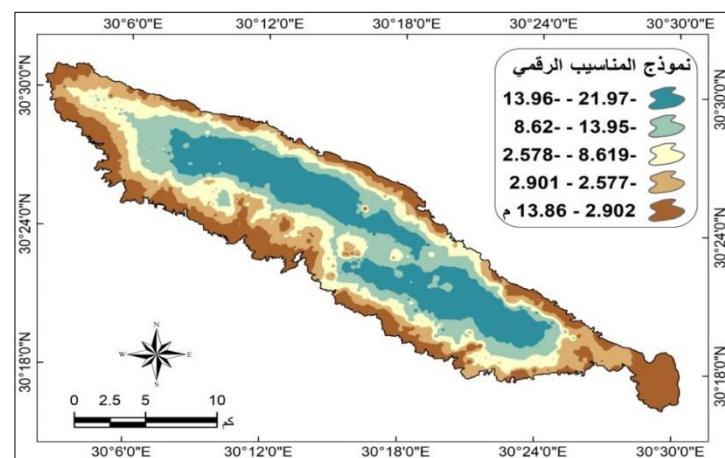
يعد منخفض وادي النطرون منخفضاً مغلقاً - شكلي(٦،٥)، حيث يحده من جميع الجهات حواف (جوانب) تحدر سفوها تدريجياً صوب قاعه، ونظراً للامتداد الطولي للمنخفض من الجنوب الشرقي إلى الشمال الغربي، فإن جوانبه تمثل في حافتين رئيسيتين هما الحافة الشمالية والحافة الجنوبية، وتمتد الحافة الشمالية: من الشمال الشرقي إلى الشمال الغربي، بينما تمتد الحافة الجنوبية من الجنوب الشرقي إلى الشمال الغربي بوجه عام، وإن كانت تشهد بعض التعرجات التي تحيد عن هذا الاتجاه العام، وهي تمثل أكثر النطاقات المحيطة بالمنخفض ارتفاعاً والتي تتراوح بين ٨٠ و ١٨٠ م، ويعتبر الجزء الأوسط منها المعروف باسم "جبل حديد" أعلى الأجزاء منسوباً. وتعد الأودية الجافة أحد الأشكال الرئيسية المرتبطة بحواف المنخفض.



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

شكل(٥) الوحدات الجيومورفولوجية بمنطقة الدراسة

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

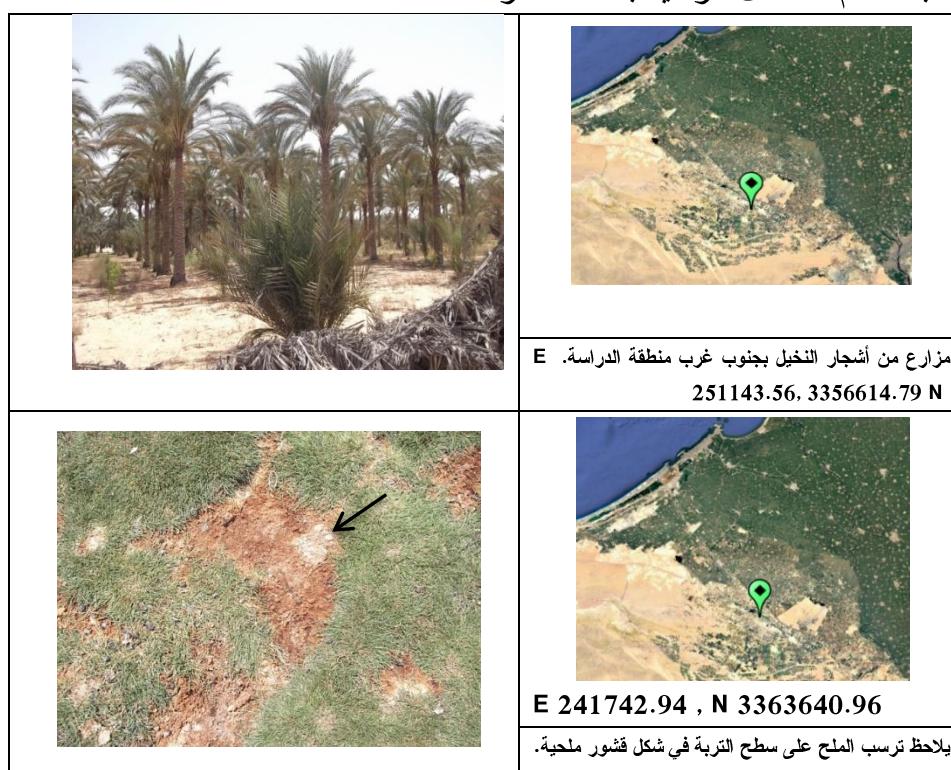


المصدر/ الخرائط الطبوغرافية وصور Arc GIS 8 بالاعتماد على برنامج Landsat 8

شكل (٦) نموذج المناسيب الرقى لمنخفض

ب- قاع المنخفض:

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



شكل (٧) مخطط يوضح أثر تملح التربة على زراعة النخيل بمنخفض

٢- خصائص ملوحة التربة بمنطقة الدراسة:

لمنطقة وادي النطرون سمات خاصة في درجة ملوحة التربة، وذلك لأنها تختلف عن مستوى السطح إلى ما دون مستوى سطح البحر مما يجعل لعامل المياه الأرضية والجوفية وترسب الأملاح دور كبير خاصة في موقع البحيرات والمواقع المحيطة بها في منطقة الدراسة، وبناء على نتائج التحليل المعملي لعدد (٢٥) عينة أخذت من التربة لقياس تركيز الملوحة وعلى حسب تصنيف (FAO, 1974) - جدول (٣) الذي يصنف ملوحة التربة إلى: غير مالحة، منخفضة، متوسطة، مرتفعة، ومرتفعة جداً، فإنه تم إنشاء (٥) نطاقات للتوزيع المكاني لملوحة التربة (EC) المقاسة ومساحتها (كم^٢) والنسبة المئوية لكل فئة مكانية.

جدول (٣) درجات تصنيف ملوحة التربة حسب تصنيف FAO.

FAO ds/m	درجة الملوحة	m
٢-٠	غير مالحة	١
٤-٢	قليلة	٢
٨-٤	متوسطة	٣
١٦-٨	مرتفعة	٤
أكثر من ١٦	مرتفعة جداً	٥

Source: FAO, 1985.

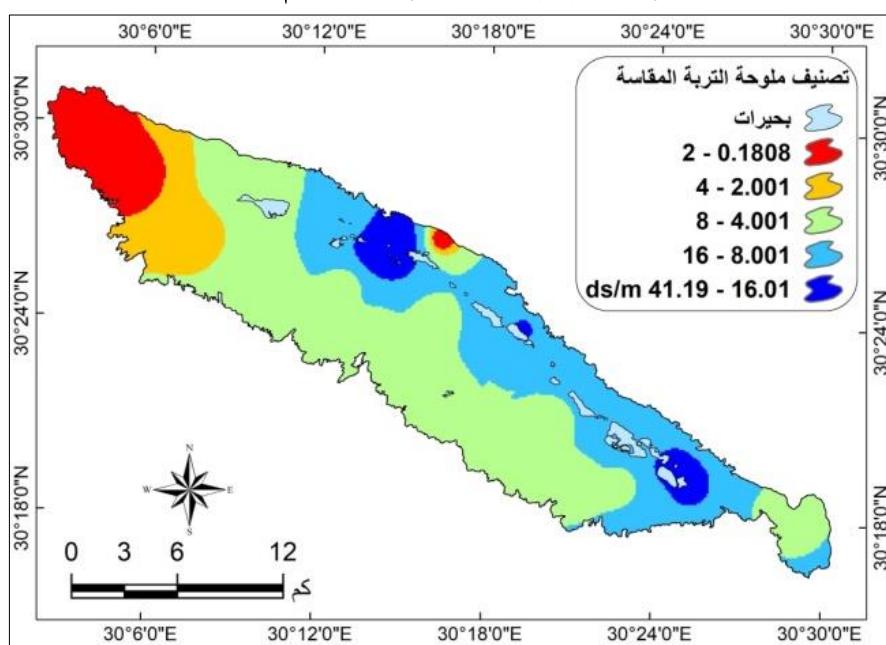
من خلال شكل (٨-٩) وجدول (٤) تتراوح درجة ملوحة التربة المقاسة بمنطقة الدراسة (EC) بين ٠.١٨ و ٤١.٢ ديسيمتر/م، وتغطي التربة غير المالحة ٣١.١٧٣ كم^٢ (٨.٦٧٪)، بينما تصل مساحة فئة التربة المالحة قليلاً ٣٠.٢٧١ كم^٢ (٨.٤٢٪)، في حين تبلغ مساحة فئة التربة متوسطة الملوحة ١٦٨.٨٦٩ كم^٢ (٤٧.٠٠٪)، والتربة مرتفعة الملوحة ١١٠.١٣ كم^٢ (٣٠.٦٥٪)، وبلغت فئة مساحة التربة شديدة الملوحة ١٨.٧٩٨ كم^٢ (٥.٢٣٪) من منطقة الدراسة. وتبيّن وقوع المناطق شديدة الملوحة في معظمها بالقرب من البحيرات، خاصة بحيرات (البيضة-السبخة-الروزينة) شكل (٧). وتبيّن خرائط التوزيع المكاني أن نسبة الملوحة أعلى من ٤ ديسيمتر/م في 82.89% من مساحة منطقة الدراسة. وترتفع نسبة الملوحة بشكل كبير في المناطق الشمالية والغربية من المنخفض، في حين تتحفظ الملوحة في المناطق الجنوبية والجنوبية الشرقية لأقل من ٤ ديسيمتر/م.

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

جدول (٤) قياسات ملوحة التربة لعينات منطقة الدراسة (ديسمبر/م^٣)

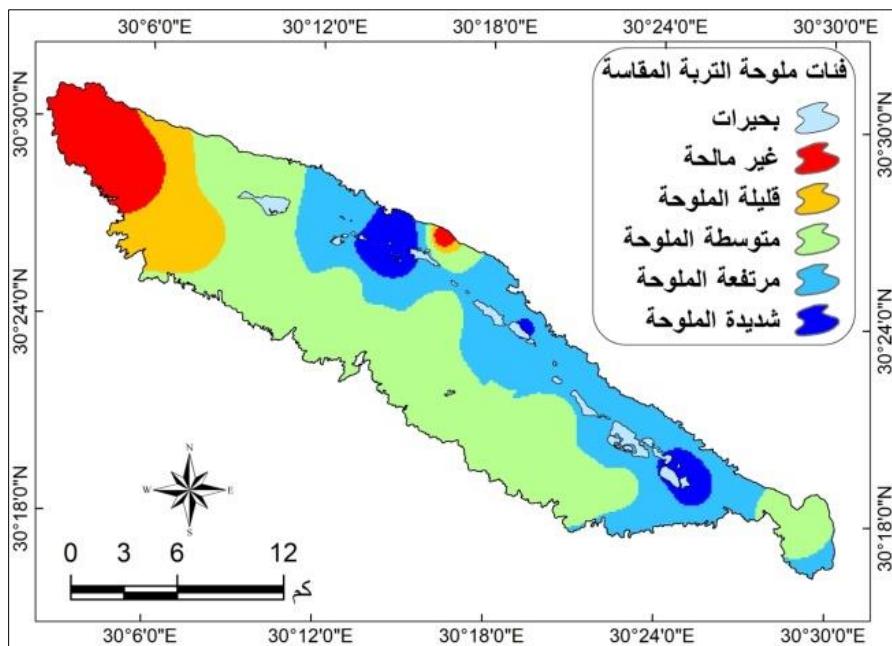
CODE	EC	X_Coordinat	y_Coordinat
1	8.16	245497.77	3362380.56
2	12.41	247687.36	3360950.71
3	12.40	249011.62	3360067.59
4	5.43	244292.73	3360634.34
5	5.44	239508.04	3359898.94
6	18.95	250905.59	3358044.11
7	5.50	257167.85	3355448.37
8	17.82	252004.54	3357002.23
9	5.35	248254.90	3357079.11
10	5.36	245681.71	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 ٢٠٢٢



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

شكل (٨) قيم ملوحة التربة (EC) ديسمنز/سم^٣ بمنخفض النطرون.



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

شكل(٩) تصنیف فنات ملوحة التربة حسب معايير FAO بمنخفض النطرون.

٣- تطوير نموذج انحدار تنبؤى لملوحة التربة بمنطقة الدراسة:

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 البعد وخصائص التربة(Gorji T, Sertel E, Tanik A, 2017).

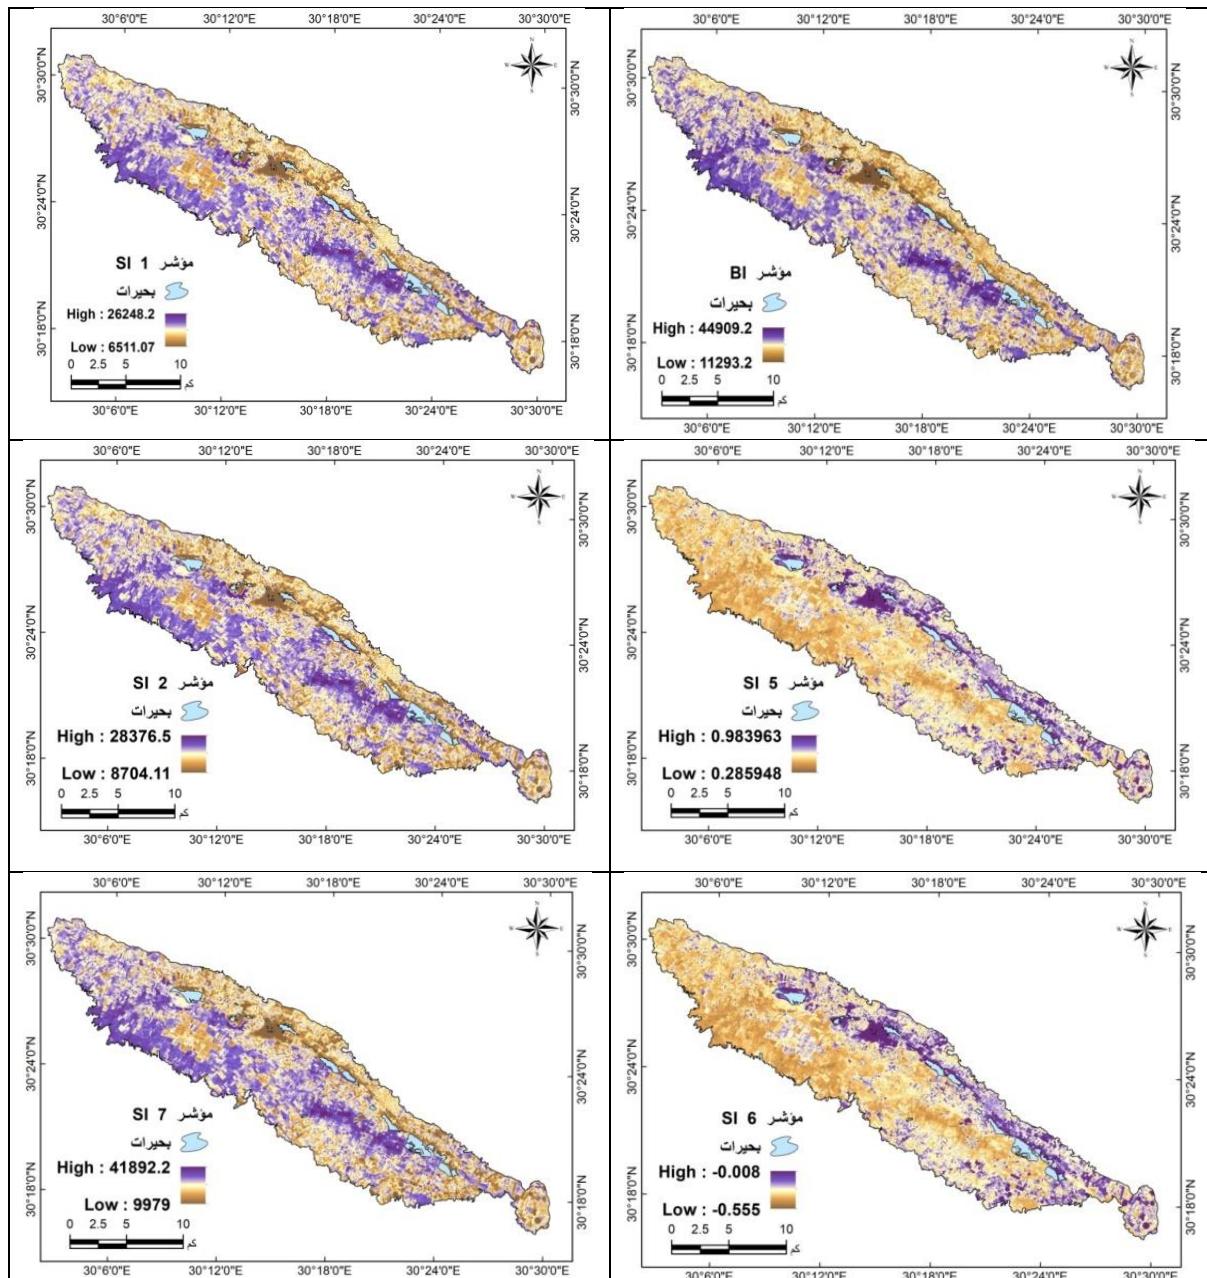
أ- الانحدار الخطي البسيط والتنبؤ بملوحة التربة:

تم حساب (٤) مؤشر طيفي لملوحة التربة والغطاء النباتي - الشكل (١٠-أ و ١٠-ب) باستخدام صور 8 Landsat OLI بناءً على الاستجابات الطيفية المختلفة للتربة المالحة والنباتات والمياه لمختلف النطاقات الطيفية-جدول (٢)، وتم اختيار هذه المؤشرات الطيفية بناء على مدى التفاعل بين الانعكاس الطيفي والمحتوى الملحي ومدى تناسبها مع البيانات الجافة وشبكة الجافة (Wardlow,B. D and Egbert, S. L. 2008). وت分成 المؤشرات المستخدمة في حساب ملوحة التربة إلى ثلات مجموعات طيفية على حسب مصدر الانبعاث الطيفي، وهما: المؤشرات الطيفية الخاصة: بالتربيه، النباتات والمياه.

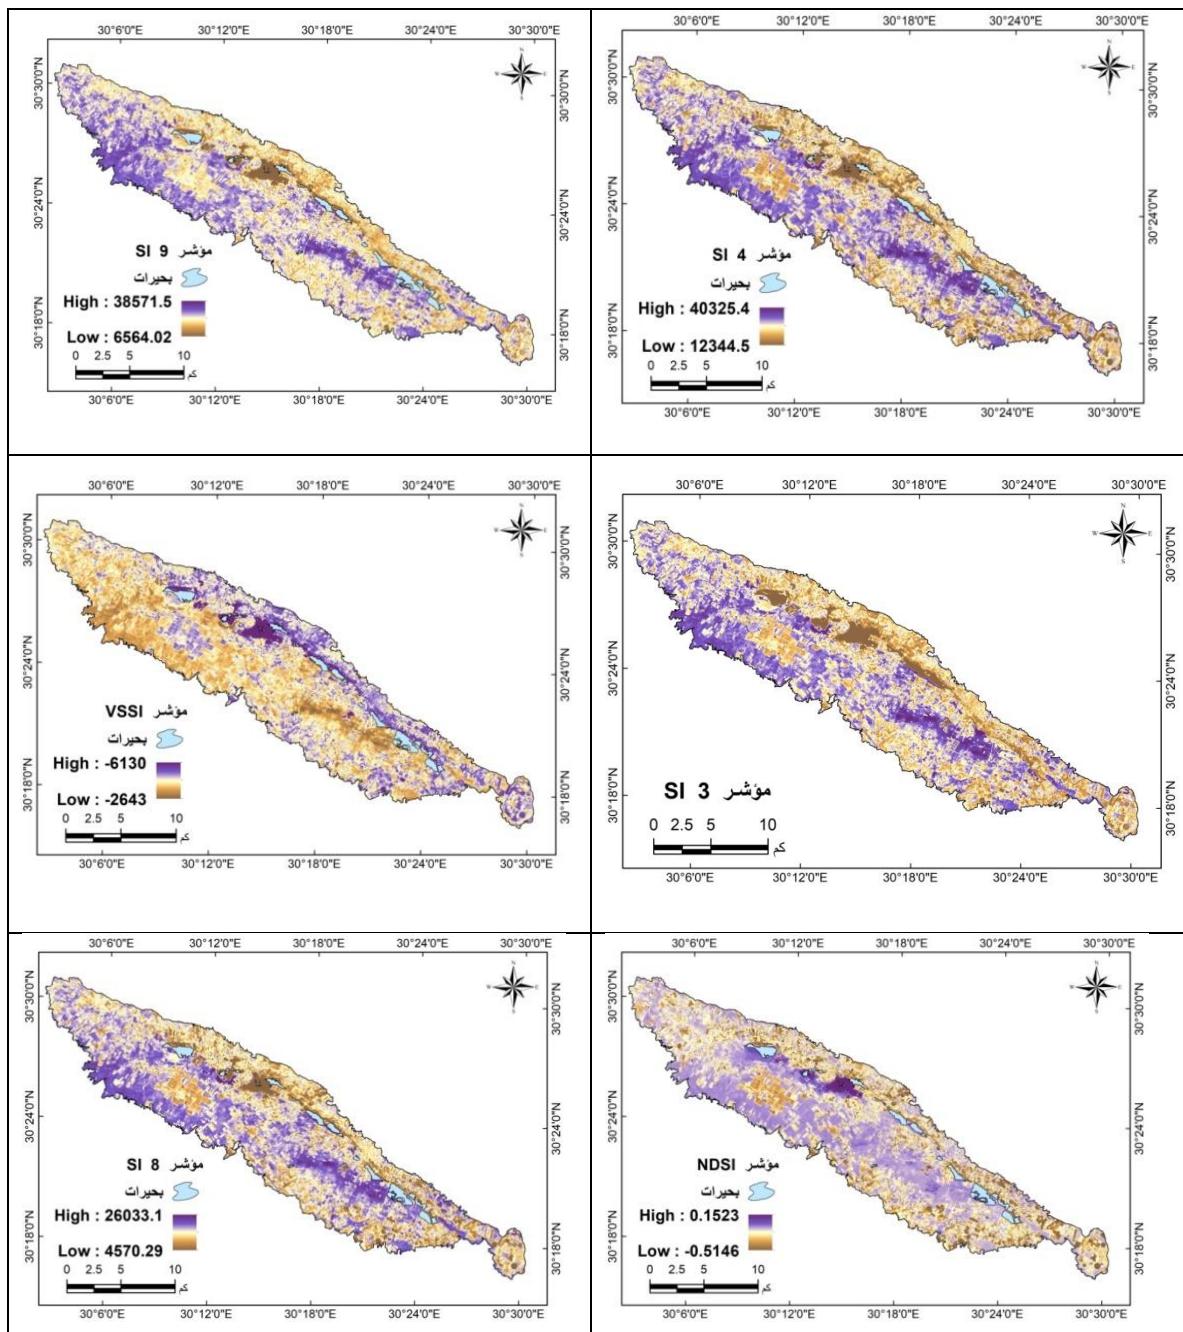
ويأتي في مقدمة المؤشرات الطيفية الملحية الخاصة بالتربيه: مؤشر (SI) الذي يجمع بين النطاقين الأزرق والأحمر، مؤشر الملوحة الفرفية الطبيعية (NDSI)، ومؤشر السطوع (BI) ، في حين يأتي في مقدمة المؤشرات الطيفية الخاصة بالنباتات: مؤشر الغطاء النباتي المعدل للتربيه

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

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



المصدر/ تحليل صور 8 Landsat بالاعتماد على برنامج Arc GIS .
 شكل (١٠ - أ) المؤشرات الطيفية لملوحة التربة لمنخفض النطرون.



المصدر/ تحليل صور 8 Landsat بالاعتماد على برنامج Arc GIS 8
شكل (١٠ - ب) المؤشرات الطيفية لملوحة التربة لمنخفض النطرون.

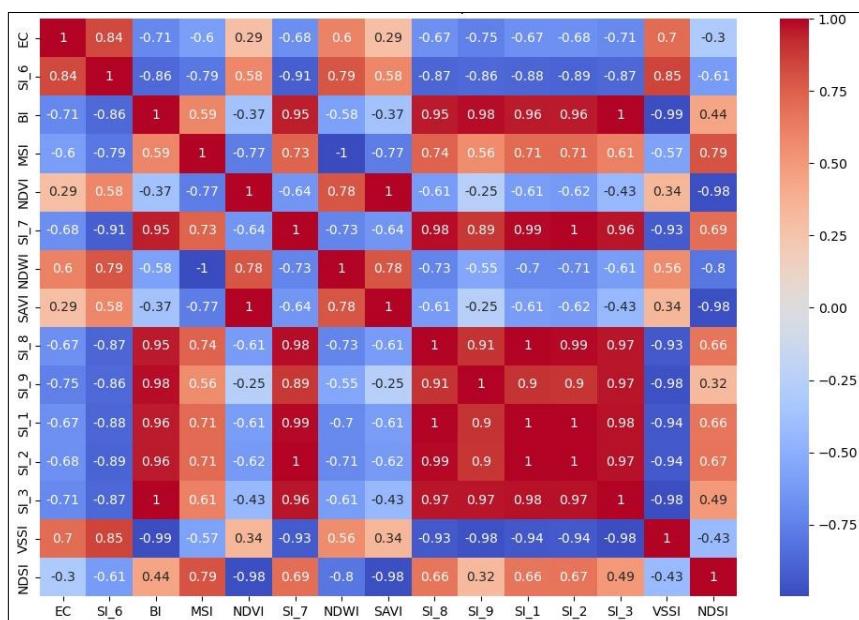
وساعد في بناء هذه المؤشرات الانبعاث الطيفي الصادر من الغطاء النباتي الذي يعبر عن العلاقة بين حالة الغطاء النباتي وتفاعل التربة (Davis E, Wang C, Dow K., 2019)، مما يحسن من دقة التنبؤ بملوحة التربة في حالة الغطاء النباتي ضعيف النمو (Davis E, Wang C, Dow .K., 2019)

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

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 الطفيفة في المحتوى المائي للمسطحات المائية والسبخات الملحة الرطبة.

وتم استخدام ارتباط بيرسون لفحص الروابط فيما بين مجموعة بيانات الاستشعار من بعد وقيم EC للترابة ، فمن خلال شكل (١١) يتضح أن أقوى معاملات ارتباط سُجلت بين المؤشرات الطيفية -SAVI -NDWI -VSSI -SI6 () وقيم ملوحة التربة EC المقاسة وكانت بين مؤشرات (NDVI) وبلغت (-٠.٢٩ -٠.٦٠ -٠.٧٠ -٠.٨٤) على التوالي وجميعهم عند مستوى دلالة إحصائية (1-tailed) Sig أقل من ٠٠٠٥ مما يشير إلى أن هذا الارتباط دال إحصائياً، في حين يعد مؤشر BI ذو علاقة عكسية قوية (-٠.٧١) بمستوى دلالة إحصائية أقل من ٠٠٥ مما يدل على أن الارتباط دال معنوياً، ويلاحظ من خلال شكل (١١) أن المؤشرات الطيفية الملحة (SI 6 - VSSI) المنتجة من بيانات OLI Landsat 8 سُجلت أقوى معاملات ارتباط (R=0.7) على التوالي.

وقد تم تمثيل معادلات خط الانحدار البسيط لكل مؤشر طيفي من بيانات OLI وقيم الملوحة(EC) المقاسة -شكل (١٢) ويوضح وجود تأثير واضح بين انعكاس التربة وخواصها، مثل: لون التربة ومحتوها من الرطوبة والأملاح.

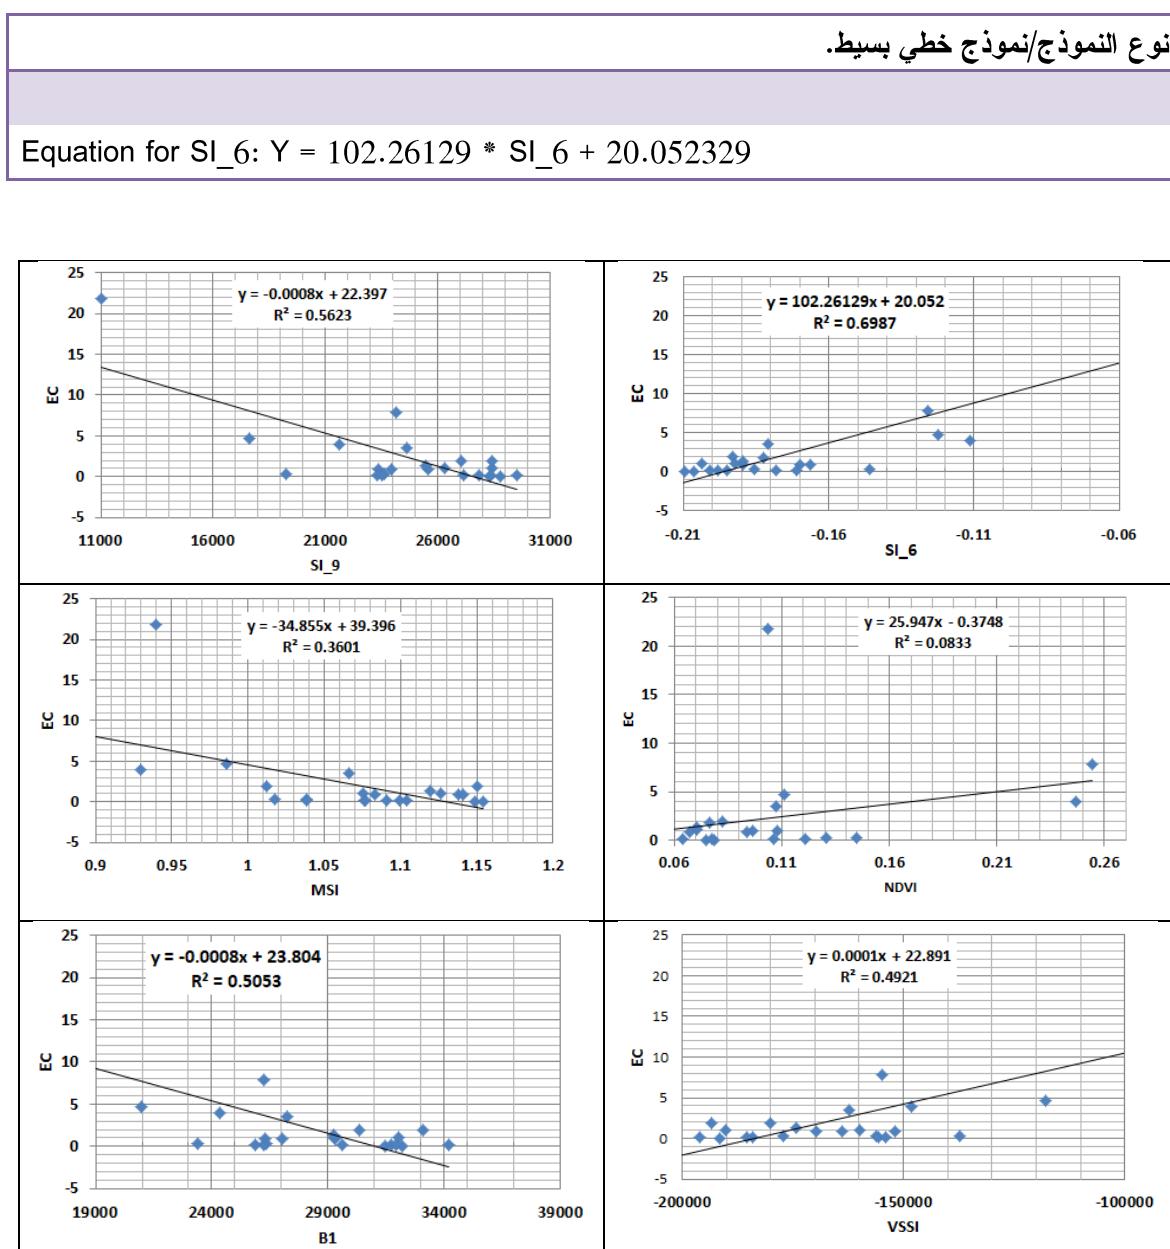


المصدر/ استخدام لغة برمجة Python والتعلم الآلي في برنامج VS code

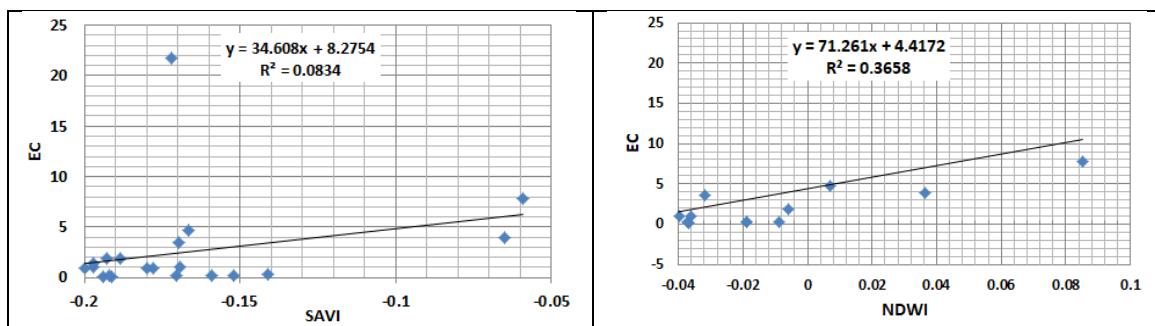
شكل (١١) مخطط حراري لمعاملات قوة الارتباط فيما بين المؤشرات الطيفية وقيم EC بمنطقة الدراسة.

أوضح نموذج الانحدار الخطي البسيط أن المؤشر الطيفي SI_6 الذي تم إنشاؤه من صورة Landsat 8 OLI يمتلك أقوى ارتباط طردي ($r = 0.84$) (معامل تحديد $R^2=69$)؛ لذا يمكن حساب ملوحة التربة بناء على هذا المؤشر الطيفي - جدول (٥).

جدول (٥) نموذج خطى بسيط للتنبؤ بملوحة التربة بالاعتماد على المؤشر SI_6



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



شكل(١٢) معاملات الانحدار وقيم الارتباط بين المؤشرات الطيفية والقيم المقاسة لملوحة التربة.

ب- 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 (٦)، وتبيّن 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(٦) نتائج تحليل الانحدار المتعدد وتأثير المعاملات ^a للمؤشرات الطيفية.

المتغيرات	coef	قيمة (t)	t دلالة (t)	.Sig	P> t	Std. Error
(Constant)	-2.799	-1.368	0.079	0.209	0.209	2.05
SI_6	501.068	1.889	0.000	0.096	0.096	265.23
B1	0.101	2.062	0.012	0.073	0.073	0.049
MSI	114.605	0.605	0.070	0.562	0.562	189.33
NDVI	8.395	1.367	0.002	0.209	0.209	6.14
SI_7	-0.058	-1.796	0.008	0.110	0.110	0.033
NDWI	271.070	0.674	0.000	0.519	0.519	402.05
SAVI	-1.120	-1.367	0.000	0.209	0.209	402.05
SI_8	0.0672	1.338	0.195	0.218	0.218	0.05
SI_9	-0.004	-0.581	0.093	0.577	0.577	0.00
SI_1	-0.336	-1.719	0.010	0.124	0.124	0.19
SI_2	0.349	1.816	0.060	0.107	0.107	0.19
SI_3	-0.100	-1.854	0.010	0.101	0.101	0.05
VSSI	-0.000	-0.924	0.027	0.382	0.382	0.00
NDSI	-103.789	-1.146	0.014	0.285	0.285	90.54

a. Dependent Variable: EC

المصدر/ تحليل الانحدار المتعدد داخل برنامج spss,v20

ومن خلال جدول (٧) أمكن التوصل إلى نموذج الانحدار الخطى المتعدد الذى يوضح العلاقة بين: المؤشرات الطيفية وقيم الملوحة المقاسة (EC) والتتبؤ بملوحة التربة المتوقعة Predicted EC، وذلك بناء على قيم (coef) لكل متغير والرقم الثابت (Constant) .

جدول(٧) معادلة الانحدار الخطى المتعدد للتتبؤ بملوحة التربة اعتمادا على بيانات الاستشعار من البعد.	
Predicted (JS) =	ال코드 المستخدم لتدريب نموذج الانحدار المتعدد واستخراج معادلة النموذج
$ \begin{aligned} & -279907.6980 + 501.0680 * SI_6 + 0.1011 * BI \\ & + 114.6055 * MSI + 839537.4220 * NDVI - 0.0584 \\ & * SI_7 + 271.0703 * NDWI - 1119874.9658 * SAVI \\ & + 0.0672 * SI_8 - 0.0049 * SI_9 - 0.3369 * SI_1 \\ & + 0.3495 * SI_2 - 0.1005 * SI_3 - 0.0001 * VSSI \\ & - 103.7892 * NDSI \end{aligned} $	<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 خطى متعدد باستخدام python داخل برنامج . vs code

تم فحص صحة نموذج الانحدار الخطى المتعدد باستخدام مخطط التشتت وتحليل التباين (ANOVA)، ومعامل التحديد (R^2) ، حيث تتم الإشارة إلى الارتباط القوى والنموذج المناسب من خلال قيم R و R^2 التي تعبّر عن معامل التحديد والذي يستخدم لمعرفة القوة التفسيرية للنموذج ويُشترط أن تكون قريبة من ١٠٠ (IBM SPSS Inc., 2012)، فمن من خلال جدول (٨) بلغت قيمة متوسط معامل ارتباط بيرسون ($R=0.979^a$) فيما بين المتغير التابع (EC) وجميع المتغيرات المستقلة (المؤشرات الطيفية) ويعتبر ارتباط قوى، كما بلغت قيمة معامل التحديد R Square (٠.٩٨٢) بمعامل تحديد معدل Adjusted R Square نحو (٠.٩٥٢) ومعامل خطأ معياري قدره (١.٢٢٤) ، كما يتضح أن المتغيرات المستقلة تفسّر ٩٧٪ من التباين في قيم EC الملوحة المقاسة.

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

جدول(٨) 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	٣٢٠٧	.000 ^a

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

وياستخدام 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(٩) نلاحظ أن قيمة التباين F بلغت (33.634) وسجلت قيمة (المعنوية) Sig (0.00^a) وهي أقل من (0.000) وبالتالي نرفض الفرض الصفرى ونقبل الفرض البديل الذى يعتبر دال معنوي، وبالتالي يوجد تأثير للمتغيرات المستقلة على المتغير التابع، كما يستطيع نموذج الانحدار الخطى المتعدد الذى تم إعداده التنبؤ بقيم المتغير التابع (Predicted EC) ملوحة التربة المتوقعة بالاعتماد على المتغيرات المستقلة (المؤشرات الطيفية) بمستوى دلالة إحصائية (0.00^a).

جدول(٩) تحليل التباين^b ANOVA للمؤشرات الطيفية ودرجة EC

Model	Sum of Squares	df	Mean Square	F	Sig.
1 Regressi on	454.003	9	50.445	32.07	.000a
	19.498	13	1.500		
	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,v20

٤- التعلم الآلي وتطوير نموذج تنبؤى بملوحة تربة منطقة الدراسة:

اعتمدت الدراسة في التنبؤ بملوحة التربة بمنطقة الدراسة على خوارزميات: الغابة العشوائية XGBoost و Random Forest، وتم استخدام لغة البايثون داخل برمجية vs code ومكتبة pandas لقراءة البيانات و scikit-learn 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: (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 معياري: متوسط نسبة الخطأ (Mean Squared Error) (MSE) ومعامل التحديد (R-squared) لتحديد كفاءة النموذج ومعرفة مدى تأثير (أهمية كل مؤشر طيفي) من المدخلات على أداء النموذج، وكان متوسط نسبة الخطأ Mean Squared Error (MSE = 0.3293) وقيمة R-squared (R² = 0.3693) . جدول (١٠).

جدول (١٠) 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
<hr/>							
	Actual ec	Predicted ec	MSE=0.3293487 R2=0.3963053				
15	1.68	1.6950					
9	0.09	0.9040					
0	0.96	1.5061					

. المصدر/ استخدام python داخل برنامج vs code

وتهدف التجربة الثانية إلى اختيار المدخلات وتحديد أفضل المؤشرات الطيفية، وتم فيها اختبار النموذجين (Random Forest, XGBoost) مع كل التباديل الممكنة من المدخلات المتاحة. على سبيل المثال تم تدريب النموذجين على قيمة مؤشر 'SI_6' فقط كمدخل، ثم مؤشر 'BI' وحدها، وتلي ذلك ضم المدخلات معاً، ثم إضافة مدخلات أخرى 'SI_6', 'BI', 'MSI' إلى أن يتم إعداد مجموعات من المؤشرات من جميع الاحتمالات الممكن دمجها معاً، وبالتالي تم تدريب نموذج لكل متغير بشكل مفرد، ثم تدريب كل مؤشر طيفي مع مؤشر آخر إلى أن يتم ضم كل المؤشرات الطيفية معاً، وبالتالي بلغ عدد الاحتمالات التي تم تجربتها ٢٤٦٣٨٤ احتمالاً بمجموع (١٦٣٨٤) احتمال لكل من النموذجين.

كما اهتمت التجربة الثانية باختلاص مجموعة المؤشرات الطيفية التي أعطت أقل متوسط خطأ لاستخدامها كمدخلات افتراضية لكلا النموذجين في 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 (١١) المتغيرات التي تمت تجربتها مع Random Forest بمتوسط خطأ Mean Squared Error (MSE=0.17) ومعامل تحديد R-squared (R²=0.6438)

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

جدول (١١) المتغيرات التي تمت تجربتها في خوارزمية XGBoost & Random Forest

اسم الخوارزمية	عدد الحالات	المتغيرات	م
Random Forest	١٢٦٩	' 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]}	
XGBoost	٨٢٩٤٤	' param_grid} = ' n_estimators': [50, 100, 200, 300,[' learning_rate': [0.01 324, 0.5[

المصدر/ استخدام python داخلي 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 بقية المتغيرات بقيمها الافتراضية. ويتبيّن من الجدول (١٢) أفضل نموذج تعلم آلي للتنبؤ بملوحة التربة في منطقة الدراسة، وهو نموذج XGBoost وتم تدريسه بشكل عام، حيث سجل متوسط خطأ Squared Error (MSE=0.0566).

جدول (١٢) قيم المتغيرات الافتراضية المستخدمة في نموذج XGBoost

وأفضل متغيرات في نموذج Random Forest

النموذج	قيم المتغيرات الافتراضية
Random Forest	'bootstrap': False 'max_depth': None 'max_features': 'sqrt' 'min_samples_leaf': 1 'min_samples_split': 5 'n_estimators': 1000
XGBoost	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:

المصدر/ استخدام python داخلي برنامج . vs code

وبناء على نموذج التعلم الآلي XGBoost تم إنتاج خريطة تبين نسبة تركز الأملاح المتوقعة(EC) في تربة منطقة الدراسة - جدول (١٣) - بأقل معامل خطأ (٠٠٠٥) مما يعطى أهمية كبيرة لتقنيات التعلم الآلي في النمذجة المكانية وانتاج خرائط تحاكي الواقع بأقل معدلات خطأ.

٥- تحليل وتفسير 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 - SI9 - SI6 - MSSV) الأكثر قدرة على التنبؤ بالتبين 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) (ديسيمنز/م) في منطقة الدراسة - شكل (١٣) .

جدول (١٣) مقارنة قياسات ملوحة التربة المتوقعة (ديسيمنز/م) باستخدام (ML , MLR) بالعينات المقاسة

CODE	EC	المقاسة (XJboost)	MLR	X_Coordinat	y_Coordinat
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/ تحليلات خوارزميات التعلم الآلي للتبيؤ بملوحة التربة المتوقعة (ديسيمنز/م) في منطقة الدراسة.

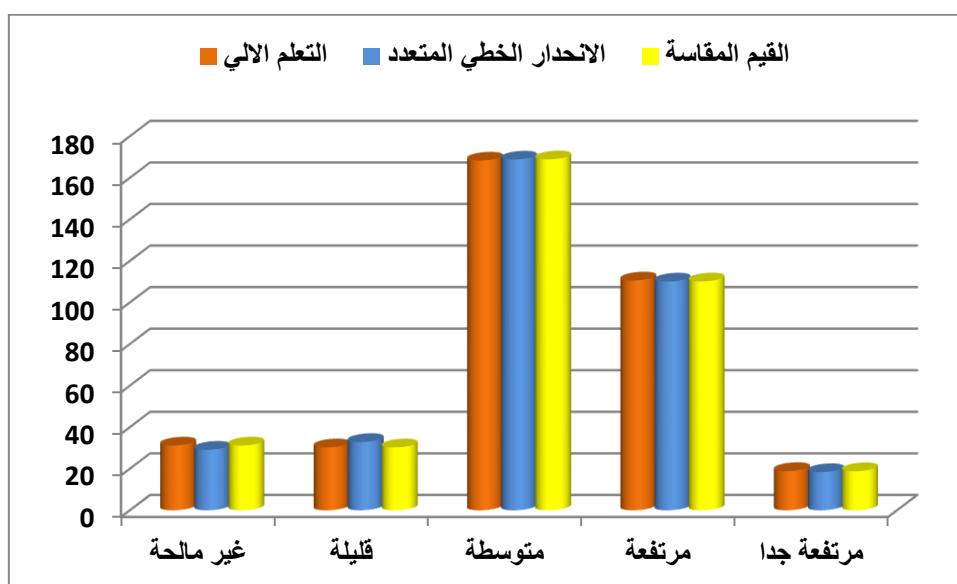
مجلة كلية الآداب بالوادي الجديد - مجلة علمية محكمة - العدد السابع عشر (الجزء الثاني)

وبتحليل جدولي (١٤) وخرائط الملوحة المتوقعة الناتجة عن تقنيات التعلم الآلي (XJboost) -أشكار (٦١ و ١٧)- يتبيّن 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 (٠٠١٨١ و ٠١٩٨ ديسىسمنز/م) وتغطي التربة غير المالحة ٣١.١٧٣ كم^٢ (٨.٦٧٪)، في حين تغطي التربة المالحة قليلاً ٣٠.٢٨٩ كم^٢ (٨.٤٣٪)، وتغطي التربة متوسطة الملوحة ٣٠.٧٨٥ كم^٢ (٤٦.٨٤٪)، وتصل مساحة التربة مرتفعة الملوحة ١١٠.٦٠١ كم^٢ (٥٠.٢٥٪) من منطقة الدراسة. وتتركز المناطق شديدة الملوحة بالموقع المحيطة بالبحيرات، خاصة بحيرات: البيضة، السبخة والروزينة. كما أوضحت نتائج نموذج التحليل المتعدد للمعايير (MLR) الذي تم تدريبه باستخدام تقنيات التعلم الآلي قدرة عالية في دقة الكشف عن ملوحة التربة المتوقعة (Predict EC) ديسىسمنز/م في منطقة الدراسة بمتوسط خطأ (١.٢)، فمن خلال جدول (١٤) وشكل (٤١ و ١٥) يتضح أن قيم ملوحة التربة المتوقعة تتراوح بين ٠.٢٧٥ و ٤١.٢٣٠ ديسىسمنز/م في منطقة الدراسة وتغطي التربة غير المالحة ٢٩.١٣٨ كم^٢ (٨.١١٪)، وتغطي التربة المالحة قليلاً ٣٢.٨٧٢ كم^٢ (٩.١٥٪)، وتغطي التربة متوسطة الملوحة ١٦٨.٧٧٦ كم^٢ (٤٦.٩٨٪)، في حين تغطي التربة مرتفعة الملوحة ١٨.٣٧٥ كم^٢ (٥.١١٪) من منطقة الدراسة. وتقع المناطق شديدة الملوحة في معظمها بالموقع المحيطة بالبحيرات، خاصة بحيرات: البيضة، السبخة والروزينة.

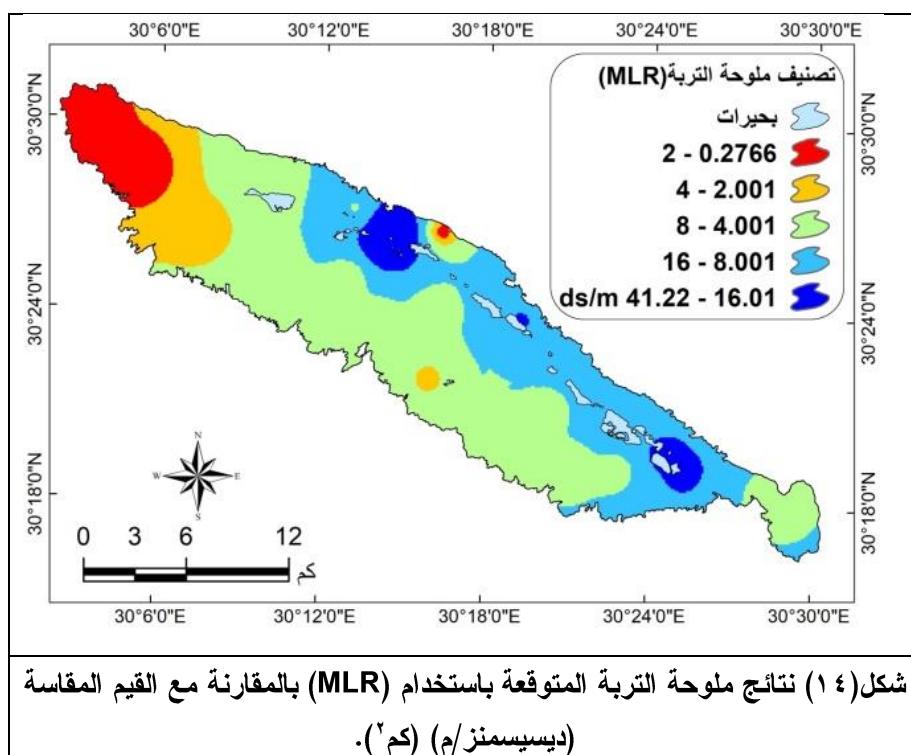
ومن خلال جدول (٤) وشكل (١٣) نلاحظ انخفاض الفرق بشكل واضح بين نتائج قياس الملوحة المتوقعة (Predict EC) ديسىسمنز/م المستندة على بيانات الاستشعار من بعد استخدام نماذج التعلم الآلي والملوحة المقاسة ميدانياً.

جدول (٤) خصائص الفئات المكانية لقياسات ملوحة التربة (ديسىسمنز/م) تبعاً لطرق القياس المتبعة.

التعلم الآلي (XJboost)		الانحدار الخطى المتعدد		الملوحة المقاسة		درجة الملوحة	م
%	كم ^٢	%	كم ^٢	%	كم ^٢		
8.67	31.173	8.11	29.138	8.67	31.173	غير مالحة	1
8.43	30.289	9.15	32.872	8.42	30.271	قليلة	2
46.84	168.295	46.98	168.776	47.00	168.869	متوسطة	3
30.78	110.601	30.64	110.097	30.65	110.13	مرتفعة	4
5.25	18.883	5.11	18.375	5.23	18.798	شديدة الملوحة	5
100	359.241	100	359.241	100	359.241	مج	-

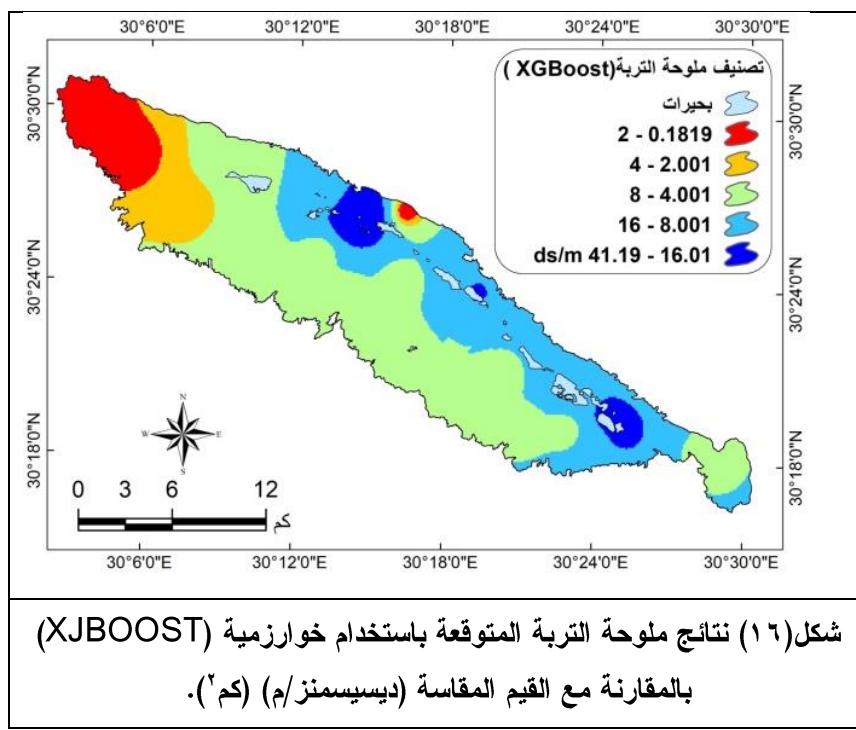
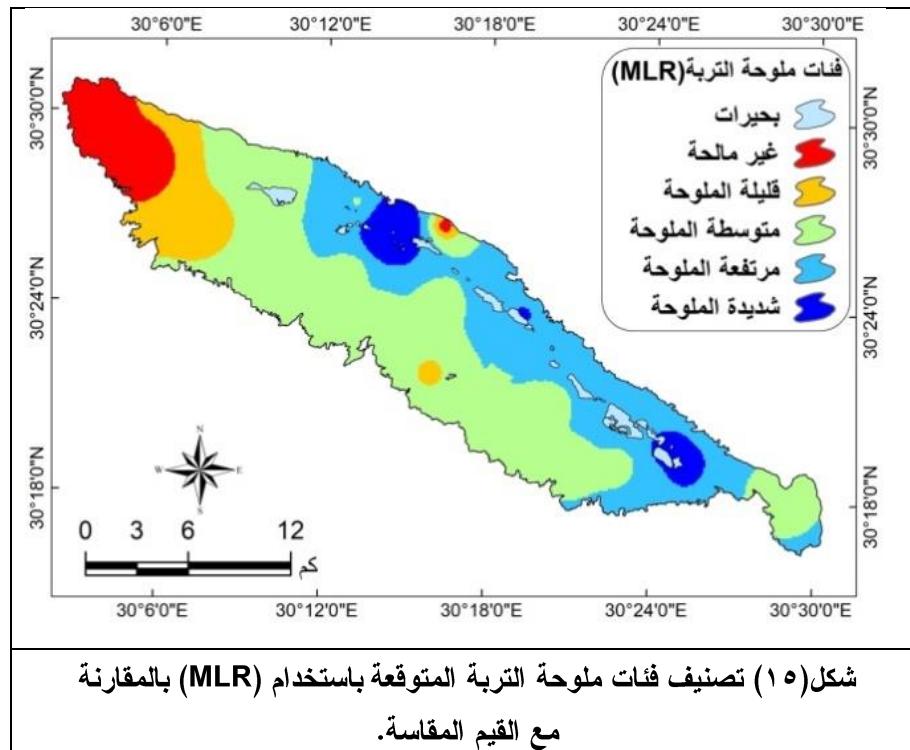


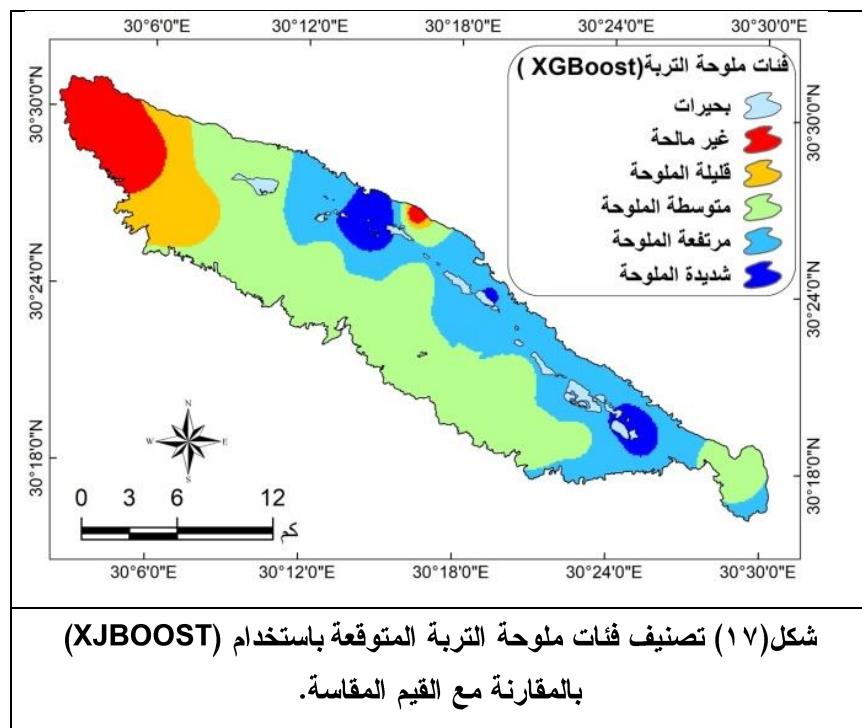
شكل (١٣) نتائج حساب فئات المساحة المتوقعة لقيم ملوحة التربة بمنطقة الدراسة



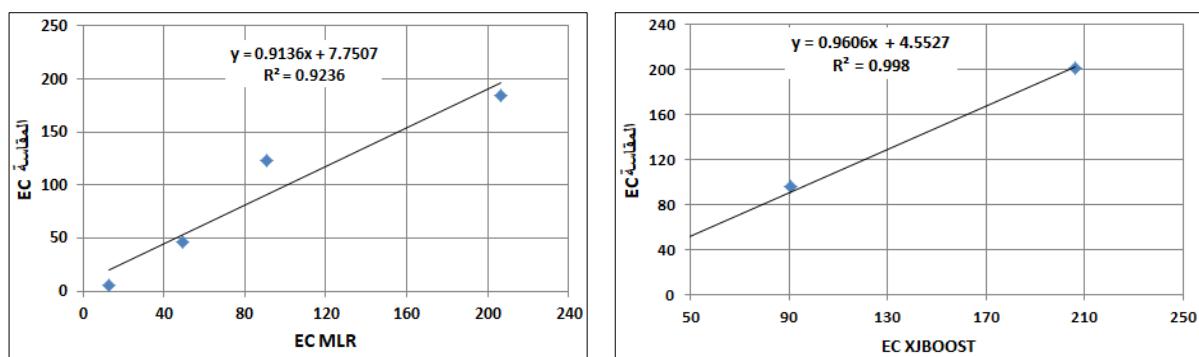
شكل (١٤) نتائج ملوحة التربة المتوقعة باستخدام (MLR) بالمقارنة مع القيم المقاسة (ديسيمنتر/م) (كم²).

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





وللحصول على دقة نتائج نموذج التعلم الآلي XJBOOST ، فإنه تم قياس علاقه الارتباط فيما بين القيم الناتجه للملوحة EC المقاسة والمتوقعة (Predict EC)، حيث أظهرت قيم معامل الارتباط أن كلا النموذجين قد توقعوا ملوحة تربة المنطقه بمستويات متباينة، ومع ذلك، فإن نتائج نموذج XJBOOST المستمدۃ من بيانات الاستشعار من بعد لها صلاحية أفضل مقارنة بنموذج الانحدار الخطی المتعدد MLR، حيث سجلت علاقه ارتباط قوية ($R^2 = 0.99$) فيما بين فئات الملوحة EC المقاسة والمتوقعة لنموذج XJBOOST ، بينما سجلت علاقه الارتباط فيما بين فئات الملوحة EC المقاسة والمتوقعة لنموذج الانحدار الخطی المتعدد ($R^2 = 0.9236$) - شکل (١٨ - ١٩) .



المصدر / برنامج SPSS,V20

شكل (١٩) علاقه الارتباط بين الملوحة المتوقعة من نموذج الانحدار المتعدد والقيم المرصودة.

المصدر / برنامج SPSS,V20

شكل (١٨) علاقه الارتباط بين الملوحة المتوقعة من التعلم الآلى والقيم المرصودة.

من خلال أشكال (١٤-١٥-١٦-١٧) والدراسة الميدانية نجد أن ملوحة تربة منطقة الدراسة تتباين من موقع لآخر؛ ويرجع ذلك لتأثيرها ببعض العوامل المهمة ويأتي في مقدمتها : خصائص منسوب سطح المنخفض، حيث تزداد ملوحة التربة في المواقع ذات المنسوب المنخفض لقربها من مستوى المياه الباطنية، ويتبين ذلك بالقرب من البحيرات التي تعد أبرز الظاهرات الطبيعية التي توجد بمنخفض وادي النطرون، وتقع على أدنى نقاط المنطقة انخفاضاً، وهو قاع المنخفض متذكرة مجموعة من البحيرات الملحة تمتد في سلسلة من الجنوب الشرقي إلى الشمال الغربي لمسافة ٣٠ كم تقريباً، وأظهرت دراسة (حمديه عبدالقادر العوضي، ٢٠٠٥، ص ٣) وجود سبع وثلاثين بحيرة في قاع المنخفض يتعرض معظمها للجفاف الكلي في الصيف بينما يظل بعضها باقياً دون جفاف وبلغ عددها الحالي بالمنخفض نحو ١٢ بحيرة رئيسية، وتحصر فيما بينها عدد من البرك صغيرة الحجم .

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

شكل (٢٠) مخطط يوضح مدى تملح التربة بجانب البحيرات بمنخفض النطرون.

وتتسم هذه البحيرات بأنها دائمة وإنما مؤقتة فالبحيرات الدائمة كبحيرة أم ريشا وبحيرة الجعار - شكل (٢٠)، 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 ويعود 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 للمعايير بالاعتماد على بيانات الاستشعار من بعد من خلال المؤشرات الطيفية المختصة بدراسة تركيز الأملاح بالترابة والنبات والمياه توصلت الدراسة للنتائج التالية:-

- ١- استخدام صور Landsat 8 OLI لمنطقة الدراسة يمكن أن يستفاد منها في تحديد ملوحة التربة، حيث تتسبب التربة المتأثرة بملوحة والتي تحتوي على قشرة ملحية على السطح في انعكاس مرتفع للمناطق المرئية والأشعة تحت الحمراء القريبة.
- ٢- تظهر الدراسة كفاءة تقنيات التعلم الآلي وتحليل الانحدار الخطي المتعدد للتنبؤ بملوحة التربة بمنطقة الدراسة.
- ٣- أظهر نموذج التعلم الآلي XJBOOST القدرة الكبيرة على التنبؤ بملوحة تربة منطقة الدراسة من بيانات الاستشعار من بعد، حيث سجل علاقة ارتباط قوية ($R^2 = 0.99$) فيما بين قيم الملوحة EC المقاسة والمتواعدة لنموذج بمتوسط خطأ (٠٠٥).
- ٤- يرتفع المحتوى الملحي لترابة منطقة الدراسة بالقرب من البحيرات، حيث تعد البحيرات من أبرز الظاهرات الطبيعية المتغيرة التي توجد بمنخفض وادى النطرون، وتقع على أدنى نقاط المنطقة انخفاضاً.
- ٥- يظهر نموذج الانحدار المتعدد المطور قدرة كبيرة في التنبؤ بملوحة التربة بالاعتماد على بيانات الاستشعار من بعد، حيث سجلت علاقة الارتباط فيما بين مساحات الملوحة EC المقاسة (كم^٢) والمساحات المتوقعة لنموذج الانحدار المتعدد ($R^2 = 0.9236$).
- ٦- تراوحت قيم ملوحة التربة المقاسة بمنطقة الدراسة (EC) بين (٠١٨ و ٤١.٢ ديسىمسنتر/م) في حين أظهرت نتيجة نموذج XJBOOST أن قيم ملوحة التربة تراوحت بين (٠٠١٨١ و ٤١.٩٨ ديسىمسنتر/م)، في حين تراوحت قيم ملوحة التربة الناتجة عن تطبيق نموذج الانحدار المتعدد بين (٢٧٥ و ٤٠.٢٣٠ ديسىمسنتر/م) في منطقة الدراسة.
- ٧- أظهرت الدراسة أن تقنيات تحسين صور الأقمار الصناعية التي تتكون من مؤشرات طيفية تمثل إمكانات كبيرة في دراسة خصائص التوزيع المكاني لملوحة التربة بمنطقة الدراسة.

الوصيات

توصى الدراسة بما يلى:

- ١- تطبيق تقنيات التعلم الآلي (ML) المعتمدة على بيانات الاستشعار من بعد في دراسات ملوحة التربة، خاصة خوارزمية XJBOOST .
- ٢- الاستفادة من التقنيات الجيومكانية خاصة تحليل الانحدار الخطي المتعدد (MLR) وتكاملها في دراسات ملوحة التربة.
- ٣- توصى الدراسة بالتوسيع في أبحاث مشابهة على مناطق أخرى بجمهورية مصر العربية.
- ٤- تشجيع الاستثمار الحكومي والخاص للتوسيع في مشروعات الاستصلاح الزراعي بمنطقة وادى النطرون.
- ٥- ضرورة التوسع في معالجة التربة المتأثرة بملوحة في أماكن البحيرات بمنطقة الدراسة من قبل الجهات البحثية العلمية.

المصادر والمراجع العربية

١. صفاء حسن حامد: التباین المکانی لمؤشرات ملوحة التربة باستخدام تقانات الاستشعار عن بعد ونظم المعلومات الجغرافية، رسالة ماجستير، جامعة النيلين السودان (٢٠٢١)
٢. جاسم شهاب حمد العتابي، وأخرون: دراسة التغایر المکانی لملوحة التربة الترب في مشروع شیخ سعد باستخدام تقنيات الاستشعار عن بعد RS ونظم المعلومات الجغرافية GIS، مجلة الزراعة العراقية البحثية، مجلد ٢٤ عد (١) العراق (٢٠١٩).
٣. طارق حمد أبو الفضل إبراهيم (٢٠٢٢) التقييم البيئي لتلخ الرتبة منطقة غرب الموهوب- بالواحات الداخلة: باستخدام نظم المعلومات الجغرافية، مجلة كلية الآداب بقنا، جامعة جنوب الوادي - العدد (٥٧) أكتوبر ٢٠٢٢.
٤. داود جاسم الريبيعي: ظاهرة الملوحة في القسم الجنوبي من السهل الرسوبي، مجلة الخليج العربي، مج ٢٠، العدد ٢ مركز دراسات الخليج العربي، جامعة البصرة (١٩٨٨).
٥. أحمد حيدر الزبيدي: استصلاح الأراضي الملحة في الوطن العربي، مجلة الزراعة والتنمية في الوطن العربي، المنظمة العربية للتنمية الزراعية، السنة ١٣ ، العدد ١، بغداد (١٩٩٤).
٦. حمدينه عبد القادر العوضي (٢٠٠٥) بحيرات منخفض وادي النطرون. دورية الإنسانيات العدد ١٦.

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-Natrun,Egypt (unpublished masters thesis). Faculty of Agriculuture, 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, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
5. Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
6. 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 .
7. 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.

8. 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.
9. 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.
10. FAO. (1985): Land evaluation for irrigated agriculture. Soils Bulletin 55-FAO. FAO. Rome.
11. 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.
12. 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.
13. 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.
14. 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.
15. Machinery, A. F. C. (2016). Advancing Computing as a Science & Profession.
16. 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.
17. 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).
18. 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.
19. Rigatti, S. J. (2017). Random forest. *Journal of Insurance Medicine*, 47(1), 31-39.
20. Schneier-Madanes, G., & Courel, M. F. (2010). Water and sustainability in arid regions. *High demand in a land of water scarcity: Iran*, 75-87.
21. 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.
22. Spss, I. B. M. (2012). Statistics for windows. Armonk, Ny: IBM Corp.
23. 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).
24. 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).
25. 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.
26. 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.