Journal of Al-Farahidi's Arts, No Conference (10 th)N(I)172-204
Doi: https://doi.org/10.25130/jfa.conf.10.1.9

Proceedings of the (10) Conference وقائع المؤتمر العلمي العاشر

P-ISSN : 2074-9554 | E-ISSN: 2663-811
Journal of Al-Farahidi's Arts
available online at : fja.tu.edu.iq/index.php/fja

Tikrit University J.F.A Journal of Al-Frahedis

Application of Artificial Intelligence in Modeling Environmental Degradation Maps in Salah Al-Din Governorate

Dr. Aws Ali Mohammed
Dr. Saad Thamer Ibrahim

E-Mail: Aws.ali@tu.edu.iq

Keywords:
Environmental degradation maps
, automated classification, artificial intelligence algorithms

Article history:

Received	7/9/2025
Received in revised form	10/10/2025
Accepted	19/10/2025
Available online	9/12/2025

E-mail Jaa@ tu.edu.iq

©THIS AN OPEN ACCESS ARTICLE UNDER THE CCBY LICENSE
http:// creativecommons.org/licenses/by/4.0

A B S T R A C T

The study aims to model and analyze environmental degradation maps in Salah Al-Din Governorate using artificial intelligence techniques by examining the relationship between Land Surface Temperature (LST), the Normalized Difference Vegetation Index (NDVI), and the Standardized Precipitation Index (SPI) derived from satellite data. The research utilized Landsat-8 imagery for the period (2014–2024), with all processing and analysis conducted on the Google Earth Engine (GEE) platform. Artificial intelligence algorithms were applied to predict environmental degradation maps for the year 2025 and to classify environmentally affected areas based on the inverse relationship among the indices. High LST values coupled with low NDVI and SPI values were found to indicate zones of severe vegetation degradation. The results revealed a strong negative correlation between LST, SPI, and NDVI, highlighting the impact of thermal stress on vegetation cover degradation. Moreover, the intelligent models proved highly effective in accurately identifying degradation hotspots, demonstrating their potential as a powerful tool for detecting environmentally degraded areas in the study region

استخدام الذكاء الاصطناعي في نمذجة خرائط التدهور البيئي لمحافظة صلاح الدين

م.د. اوس علي محمد /جامعة تكريت/ كلية الآداب/ قسم الجغرافية ونظم المعلومات الجغرافية
م.د. سعد ثامر إبراهيم /جامعة تكريت/ كلية الآداب/ قسم الجغرافية ونظم المعلومات الجغرافية

المستخلص:

تهدف الدراسة إلى نمذجة وتحليل خرائط التدهور البيئي في محافظة صلاح الدين باستخدام تقنيات الذكاء الاصطناعي، من خلال استكشاف العلاقة بين درجة حرارة سطح الأرض (LST) ومؤشر الغطاء النباتي الطبيعي (NDVI) ومؤشر الهطول المطري (SPI) المستخرجين من بيانات الأقمار الصناعية، واعتمدت الدراسة على مرئيات فضائية من القمر الصناعي Landsat-8 للمدة (2014 – 2024)، وتم تنفيذ المعالجة والتحليل داخل منصة Google Earth Engine ((GEE ، واستخدمت الدراسة خوارزميات الذكاء الاصطناعي (Random Forest) للتنبؤ بخرائط التدهور البيئي لعام 2025 وتصنيف المناطق المتأثرة بيئيا استنادا إلى العلاقة العكسية بين المؤشرات، إذ تشير القيم المرتفعة لـــ LST والمنخفضة لـــ NDVI و SPIإلى مناطق تشهد تدهورا نباتيا حادا، وأظهرت النتائج وجود ارتباط عكسي قوي بين (LST - SPIوNDVI ، مما يعكس تأثير الإجهاد الحراري على تدهور الغطاء النباتي، كما أثبتت النماذج الذكية كفاءتها في تحديد البؤر الساخنة للتدهور بدقة عالية، ما يجعلها أداة فعالة لتحديد المناطق المتدهورة بيئياً في منطقة الدراسة .

الكلمات المفتاحية : خرائط التدهور البيئي، التصنيف الآلي، خوارزميات الذكاء الاصطناعي.

المقدمة:

يعد التدهور البيئي أحد أبرز التحديات التي تواجه النظم البيئية في المناطق الجافة وشبه الجافة، إذ يتجلى في تراجع الغطاء النباتي وازدياد الإجهاد الحراري وانخفاض معدلات الأمطار، ما يؤدي إلى فقدان التوازن البيئي وتراجع الإنتاجية الزراعية، وأصبحت الخرائط البيئية أداة محورية للكشف عن أنماط التغيرات المكانية ورصد ديناميكيات التدهور عبر الزمن، ومع التطور السريع في تقنيات الاستشعار عن بعد RS ونظم المعلومات الجغرافية GIS بات من الممكن إنتاج خرائط مكانية دقيقة ذات دلالات كمية تساعد في فهم العوامل المتداخلة المؤثرة على البيئة.

تشكل بيانات الأقمار الصناعية مصدراً رئيساً للمؤشرات البيئية مثل درجة حرارة سطح الأرض (LST) ومؤشر الغطاء النباتي الطبيعي (NDVI) ومؤشر الهطول المطري المعياري (SPI)، إذ تسمح هذه المؤشرات بتفسير العلاقة المكانية والزمانية بين المناخ والغطاء النباتي وظواهر التدهور، وتتيح مرئيات الأقمار مثل Landsat-8 إمكانية بناء سلاسل زمنية طويلة المدى تظهر التغيرات البيئية بدقة مكانية مناسبة، فيما توفر منصات التحليل السحابي مثل Google Earth Engine (GEE)بيئة فعالة لمعالجة كميات ضخمة من البيانات وإجراء التحليلات المتقدمة بكفاءة عالية.

وأسهمت تقنيات الذكاء الاصطناعي AI وخوارزميات التعلم الآلي في رفع دقة النماذج التنبؤية الخاصة بالتدهور البيئي، وذلك من خلال تحسين قدرات التصنيف الآلي والتعامل مع العلاقات غير الخطية والمعقدة بين المؤشرات، وأن الدمج بين الطرائق الخرائطية الحديثة والاستشعار عن بعد والذكاء الاصطناعي يولد خرائط تنبؤية عالية الدقة، قادرة على تحديد البؤر الساخنة للتدهور البيئي في منطقة الدراسة.

اولاً: مشكلة الدراسة :

رغم توفر صور الأقمار الصناعية متعددة المصادر وإمكانية حساب مؤشرات بيئية مثل LST وNDVI وSPI، إلا أن التحدي الأكبر يتمثل في بناء خرائط مكانية دقيقة للتدهور البيئي بمحافظة صلاح الدين باستخدام الذكاء الاصطناعي، وذلك بسبب التداخل المكاني والزماني بين المؤشرات البيئية وصعوبة التنبؤ بمناطق التدهور المستقبلية اعتمادا على طرائق تقليدية، ومن خلال هذه المشكلة الرئيسة يمكن طرح التساؤلات الآتية :

1- كيف يمكن الاستفادة من بيانات الأقمار الصناعية في نمذجة خرائط التدهور البيئي زمكانياً ؟

2- ما دور خوارزميات الذكاء الاصطناعي في تحسين دقة تنبؤ خرائط التدهور البيئي؟

3- ما مدى إمكانية الاعتماد على العلاقة العكسية بين LST وNDVI وSPI في التنبؤ بخرائط التدهور البيئي؟

ثانياً: فرضية الدراسة :

1- يمكن الاستفادة من بيانات الأقمار الصناعية في نمذجة خرائط التدهور البيئي زمكانياً عبر استخدام بيانات Landsat-8 للمدة (2014–2024) لاستخراج مؤشرات LST وNDVI، إلى جانب بيانات SPI للهطول المطري، ثم معالجتها داخل Google Earth Engine لتوليد خرائط زمنية تعكس ديناميكيات التغير البيئي.

2- أن لخوارزميات الذكاء الاصطناعي (التصنيف الآلي ، التعلم الآلي) دور في الكشف عن العلاقات غير الخطية بين المؤشرات البيئية، مما يرفع من دقة التنبؤ بالمناطق المتدهورة ويمكن من إنتاج خرائط تنبؤية لعام 2025 تحدد البؤر الساخنة بدقة عالية.

3- أن العلاقة العكسية بين ارتفاع LST وانخفاض NDVI وSPI تعكس بوضوح تأثير الإجهاد الحراري ونقص الأمطار على الغطاء النباتي، وقد أظهرت النتائج وجود ارتباط قوي بين هذه المؤشرات، ما يجعلها أساسا علميا موثوقا لتفسير أنماط التدهور في منطقة الدراسة.

ثالثاً: اهداف الدراسة :

1- نمذجة العلاقة بين درجة حرارة سطح الأرض (LST) ومؤشر الغطاء النباتي (NDVI) ومؤشر الهطول المطري (SPI) باستخدام بيانات Landsat-8 للمدة 2014–2024 لتحديد أنماط التدهور البيئي في منطقة الدراسة.

2- بناء خرائط تفاعلية توضح البؤر الساخنة للتدهور البيئي باستخدام النماذج الذكية وبيانات الأقمار الصناعية على منصة Google Earth Engine.

3- توظيف خوارزميات الذكاء الاصطناعي للكشف عن الأنماط غير الخطية بين مؤشرات LST وNDVI وSPI وتصنيف المناطق المتدهورة بيئيا بدقة عالية، مع التنبؤ بمناطق التدهور المستقبلية لعام 2025.

4- يتم اختبار بيانات تنبؤ التدهور البيئي لمنطقة الدراسة باستخدام الطرائق الاحصائية المتقدمة

رابعاً: مناهج الدراسة :

1- **المنهج الاستقرائي** :اعتمدت الدراسة على تتبع الظواهر من التفاصيل الجزئية إلى الصورة الكلية، وذلك من خلال تحليل المؤشرات البيئية (LST ، NDVI، SPI) للكشف عن العلاقات الزمكانية بينها، وربطها بدرجات التدهور البيئي في محافظة صلاح الدين.

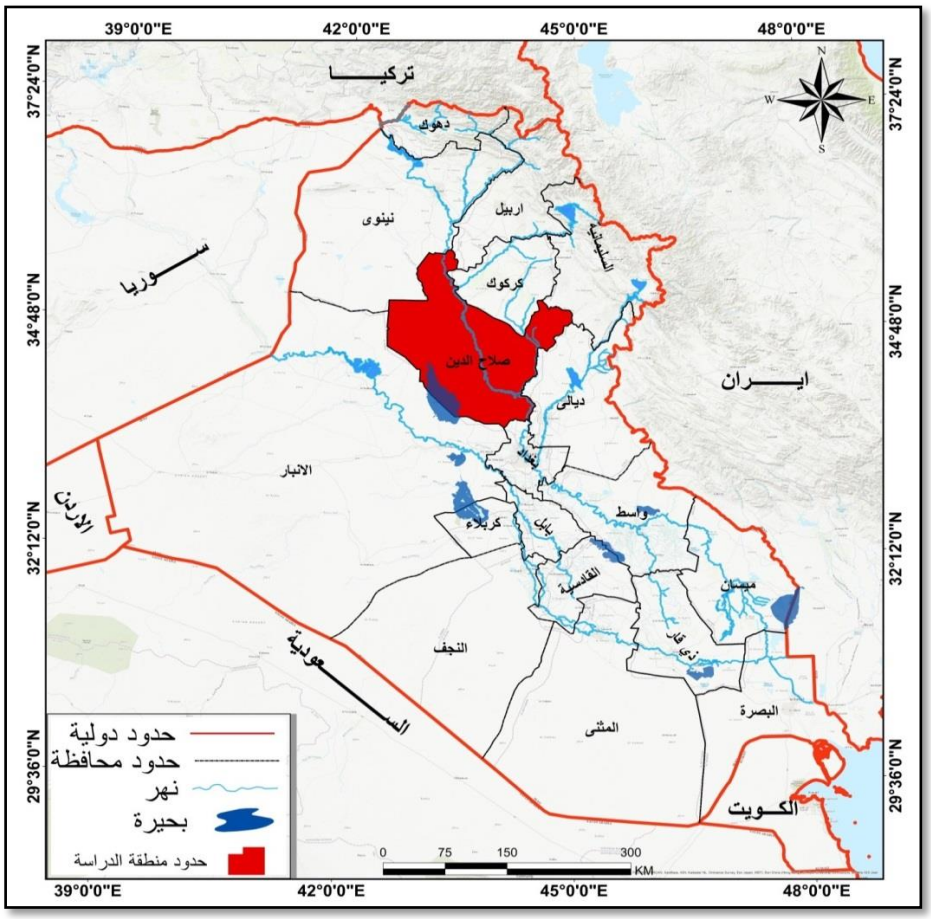
2- **المنهج التحليلي** : تم توظيف هذا المنهج في معالجة البيانات الفضائية وإجراء التحليل الكمي والنوعي للخرائط البيئية، مع الاستعانة بخوارزميات الذكاء الاصطناعي AI لتصنيف المناطق المتدهورة وتفسير الأنماط المكانية للتدهور البيئي، بما في ذلك التنبؤ بالبؤر الساخنة للعام 2025.

3- **المنهج التقني** : ركزت الدراسة على تطبيق تقنيات الاستشعار عن بعد (RS) ونظم المعلومات الجغرافية (GIS) ضمن بيئة Google Earth Engine (GEE) لمعالجة الصور الفضائية وإنتاج الخرائط، مع دمج أدوات الذكاء الاصطناعي AI لتحسين دقة النمذجة المكانية وتعزيز موثوقية النتائج.

خامساً: موقع منطقة الدراسة :

تم تحديد حدود منطقة الدراسة وفقا للحدود الإدارية لمحافظة صلاح الدين، والواقعة في وسط العراق بمساحة إجمالية تبلغ (24,395 كم²) أي ما يعادل حوالي (5.6%) من مساحة العراق الكلية، وتقع منطقة الدراسة في المنطقة الانتقالية بين السهل الرسوبي وإقليم الجزيرة شبه الجبلي، وتشمل النطاق الجغرافي بين دائرتي عرض (37°33′) شمالاً و(41°35′) شمالاً، وخطي طول(42°32′) شرقاً و(44°59′) شرقاً، وتمتد حدود المحافظة شمالاً لتلتقي بمحافظتي نينوى وأربيل، وجنوباً حتى حدود بغداد، وشرقاً لتشمل كركوك وديالى، وغرباً لتتصل بنينوى والأنبار. وتوضح الخريطة (1) موقع منطقة الدراسة.

الخريطة 1: موقع منطقة الدراسة



المصدر : بالاعتماد على برنامج Arc Gis Pro .

آلية رصد ومراقبة والتنبؤ بخرائط التدهور البيئي باستخدام الذكاء الاصطناعي AI:

تستخدم الخرائط الموضوعية طرائق كارتوكرافية لتوضيح العلاقات المكانية بين الظواهر الموزعة (ابراهيم ، محمود، 2020)، ومن هذه الخرائط هي خرائط التدهور البيئي أدوات رئيسة لفهم التغيرات البيئية وتوجيه السياسات والإجراءات الوقائية، وفي السنوات الأخيرة أصبح من الممكن رصد هذه التغيرات بدقة عالية باستخدام تقنيات الاستشعار عن بعد RS، عبر الأقمار الصناعية مثل Landsat و .Sentinel، وتوفر هذه الأقمار بيانات زمكانية غنية تمكن الباحثين من تحليل التغيرات في الغطاء النباتي، درجات حرارة سطح الأرض، والهطول المطري، وهي مؤشرات رئيسة للتنبؤ بخرائط التدهور البيئي.

وتعد منصة Google Earth Engine (GEE) بيئة قوية لمعالجة وتحليل هذه البيانات، إذ توفر الوصول إلى مكتبة ضخمة من الصور الفضائية وأدوات تحليل متقدمة، وباستخدامGEE يمكن دمج بيانات الأقمار الصناعية مع خوارزميات الذكاء الاصطناعي مثل التعلم الآلي للكشف عن

الأنماط والتنبؤ بمناطق التدهور البيئي المستقبلية، وتظهر الدراسات الحديثة أن دمج الذكاء الاصطناعي مع تقنيات الاستشعار عن بعد يعزز من دقة وكفاءة مراقبة التدهور البيئي.

الجدول 1: المؤشرات البيئية الأساسية

المؤشر	الرمز	الوحدة	الدلالة على التدهور
درجة حرارة سطح الأرض	LST	°C	ارتفاع LST يشير إلى الإجهاد الحراري وتدهور الغطاء النباتي
مؤشر الغطاء النباتي الطبيعي	NDVI	بدون وحدة (1–0)	انخفاض NDVI يدل على نقص الغطاء النباتي وتدهور الأرض
مؤشر الهطول المطري المعياري	SPI	بدون وحدة	انخفاض SPI يعكس نقص الأمطار وزيادة التعرض للجفاف

المصدر : بالاعتماد على منصة GEE .

معادلات استخراج المؤشرات(– A Review of Practical AI for Remote Sensing in Earth Sciences. (2023). MDPI):

مؤشر الغطاء النباتي الطبيعي (NDVI)

$$\frac{NIR - RED}{NIR + RED} = NDVI$$

NIR: الانعكاس في النطاق القريب من تحت الأحمر

RED: الانعكاس في النطاق الأحمر

درجة حرارة سطح الأرض (LST)

غالبًا تُستخلص من بيانات باند حراري من Landsat-8، باستخدام المعادلة:

$$\frac{K2}{\ln\left(\frac{K1}{\lambda L} + 1\right)} = LST$$

$K1$ و $K2$: ثوابت الباند الحراري

λL: إشعاع الطيف للبكسل

مؤشر الهطول المطري المعياري (SPI)

$$\frac{\bar{P} - {}_{i}P}{P\sigma} = SPI$$

جدول 2: العلاقة بين المؤشرات والتدهور البيئي

ت	مستوى التدهور	SPI	NDVI	LST	الحالة
1	جيد	مرتفع	مرتفع	منخفض	منخفض التدهور
2	معتدل	متوسط	متوسط	متوسط	متوسط التدهور
3	خطير	منخفض	منخفض	مرتفع	شديد التدهور

المصدر : بالاعتماد على منصة GEE .

جدول 3: آلية رصد التدهور باستخدام الذكاء الاصطناعي وGEE

ت	الأداة/الخوارزمية	الوصف	الخطوة
1	GEE	تحميل صور الأقمار الصناعية(Landsat-8) ، (Sentinel-2	جمع البيانات
2	GEE, Python	تصحيح الصور وإزالة الضوضاء	معالجة البيانات
3	GEE المعادلات أعلاه	حساب NDVI, LST, SPI	استخراج المؤشرات
4	Random Forest	تحديد المناطق المتدهورة	التصنيف
5	Machine Learning	توقع التدهور لعام 2025	التنبؤ

المصدر : بالاعتماد على منصة GEE .

نمذجة خرائط التدهور البيئي :

تستخدم الخرائط الموضوعية طرائق كارتوكرافية لتوضيح العلاقات المكانية بين الظواهر الموزعة (ابراهيم ، محمود، 2020)، ومن هذه الخرائط هي خرائط التدهور البيئي بأنها عملية تحليلية تهدف إلى تحديد وتصوير المناطق المتأثرة بالتدهور البيئي باستخدام أدوات نظم المعلومات الجغرافية (GIS) وتقنيات الاستشعار عن بعد(RS) ، وتتضمن هذه العملية دمج بيانات متعددة مثل المسطحات المائية، الهطول المطري، الغطاء النباتي، ودرجة حرارة سطح الأرض لتقييم تأثير كل عامل على التدهور البيئي، إذ تلعب المسطحات المائية دورا مهما في دعم التنوع البيئي والمحافظة على رطوبة التربة، مما يقلل من معدلات التدهور في المناطق القريبة منها، اما المناطق البعيدة عن مصادر المياه تكون أكثر عرضة للجفاف والتعرية، مما يؤدي إلى تدهور أعلى، اما الهطول المطري يمثل عاملاً أساسيًا في توفير الرطوبة للنباتات، وقلة الأمطار تزيد من معدلات التدهور من خلال زيادة الجفاف وفقدان الغطاء النباتي، والغطاء النباتي نفسه يعد مؤشرا حيويا على حالة الأرض، فالمناطق الكثيفة بالغطاء النباتي تتمتع بحماية طبيعية ضد التعرية والتدهور، بينما الأراضي المكشوفة تتعرض بشكل أسرع للتدهور، أما درجة حرارة سطح الأرض، فهي تؤثر على معدلات تبخر الماء من التربة والمسطحات المائية وعلى صحة الغطاء النباتي، فارتفاع درجات الحرارة يؤدي إلى تسريع فقد الرطوبة وزيادة ضغوط التدهور، وبعد نمذجة خرائط التدهور البيئي وتحليل تأثير العوامل الجغرافية، يمكن الانتقال إلى مرحلة التنبؤ بخرائط التدهور البيئي باستخدام تقنيات الذكاء الاصطناعي والتعلم الآلي، مثل خوارزمية Random Forest ، إذ يعتمد التنبؤ على استخدام البيانات التاريخية والمستحدثة لكل عامل بيئي لبناء نموذج قادر على توقع مستويات التدهور المستقبلية في مختلف مناطق الدراسة، ومن خلال هذا التنبؤ يمكن تحديد المناطق التي من

المتوقع أن تشهد زيادة في معدلات التدهور البيئي، سواء نتيجة نقص المياه أو انخفاض الغطاء النباتي أو ارتفاع درجات الحرارة، مما يوفر صورة واضحة للضغوط البيئية المستقبلية (الزيدي،الحمداني،2025،ص 19) .

استخدام الحوسبة لسحابية في رصد الغطاء النباتي في منطقة الدراسة للمدة 2014 – 2024

الحوسبة السحابية (GEE) في رصد NDVI (2014–2024) :

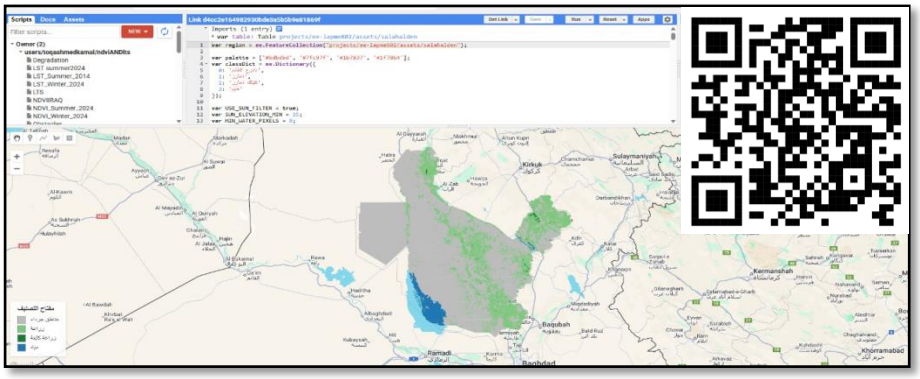
تقوم منصة Google Earth Engine (GEE) والتي تعتمد على الحوسبة السحابية لمعالجة كميات ضخمة من البيانات الفضائية بشكل سريع ودقيق لرصد مؤشر NDVIللمدة 2014–2024، إذ تعمل المنصة أولاً بتجميع الصور الفضائية من الأقمار مثل Landsat–8 بالاعتماد على الفرق بين الانعكاس في الأشعة القريبة من تحت الحمراء (NIR – Band 5) والانعكاس في الضوء الأحمر (Red – Band 4)، وتتراوح قيم NDVI بين (−1 إلى +1)، إذ تشير القيم الموجبة العالية إلى غطاء نباتي كثيف وصحي، بينما تعكس القيم المنخفضة أو السالبة وجود تدهور نباتي أو غطاء أرضي غير نباتي، ثم يتم تصفية الصور بحسب الجودة والتغطية السحابية لضمان الحصول على بيانات واضحة، وتحسب قيم NDVI لكل بكسل باستخدام المعادلة وكالآتي (Li, Y., Wang, H., Chen, L., & Xu, J. (2024),P.116):

(NIR – RED) / (NIR + RED)

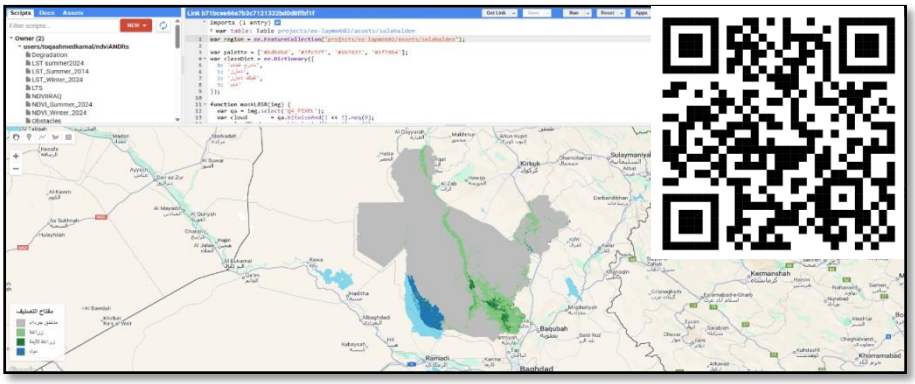
NIR :القناة تحت الحمراء القريبة – RED : القناة الحمراء

وتتيح المنصة إنشاء مجموعات زمنية (Time Series) لمؤشرNDVI ، بحيث يمكن متابعة التغيرات الموسمية والسنوية في الغطاء النباتي، ورصد التدهور أو التحسن في الغطاء الأخضر، كما توفر GEE أدوات لتصور البيانات على خرائط تفاعلية أو استخراج الإحصاءات الزمنية، مثل المتوسط السنوي أو الانحراف عن القيم المرجعية، ما يسهل تحليل الأنماط البيئية واتخاذ القرارات التخطيطية المبنية على بيانات دقيقة ومحدثة، وتعمل هذه الحوسبة السحابية على تحويل المعادلات الى كواد ولغات برمجة جافا سكرابت، لتسهل عملية كتابتها داخل هذه الحوسبة السحابية(Li, Y., Wang, H., Chen, L., & Xu, J. (2024),P.118)،والشكل (2) يوضح الكود المستخدمة لرصد الغطاء النباتي NDVI في الحوسبة السحابية GEE .

الشكل 2: الكود المستخدمة لرصد الغطاء النباتي NDVI في الحوسبة السحابية GEE

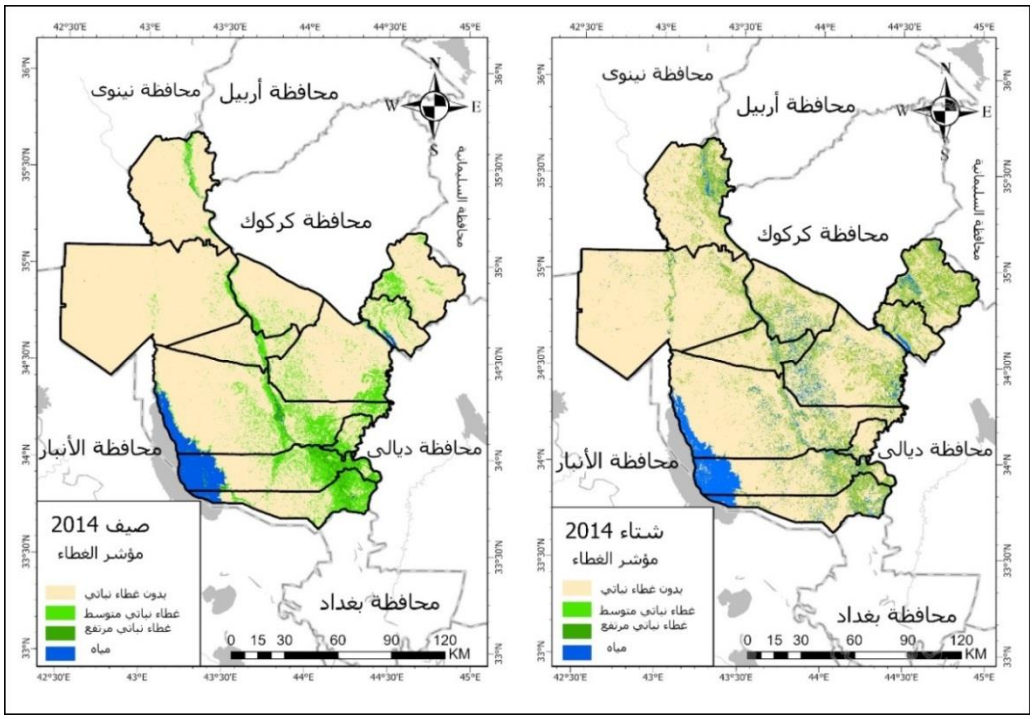


https://code.earthengine.google.com/d4cc2e164982930bde3a5b5b9e81869f?noload=1



https://code.earthengine.google.com/b71bcee66a7b3c7121332bd0d8ffbf1f?noload=1

الخريطة 2: الغطاء النباتي (شتاء ، صيف) في منطقة الدراسة لعام 2014



المصدر : بالاعتماد على برنامج Arc Gis Pro .

الجدول 4: مؤشر الغطاء النباتي Ndvi لفصل الشتاء في منطقة الدراسة لعام 2014

ت	اصناف الغطاء النباتي	المساحة / كم²	النسبة المئوية %	اللون الخرائطي
1	مناطق جرداء	18374.8	75.4	بني فاتح
2	غطاء نباتي متوسط	4496.5	18.4	اخضر فاتح
3	غطاء نباتي كثيف	592.07	2.4	اخضر غامق
4	مياه	898.3	3.6	ازرق

الجدول 5: مؤشر الغطاء النباتي Ndvi لفصل الصيف في منطقة الدراسة لعام 2014

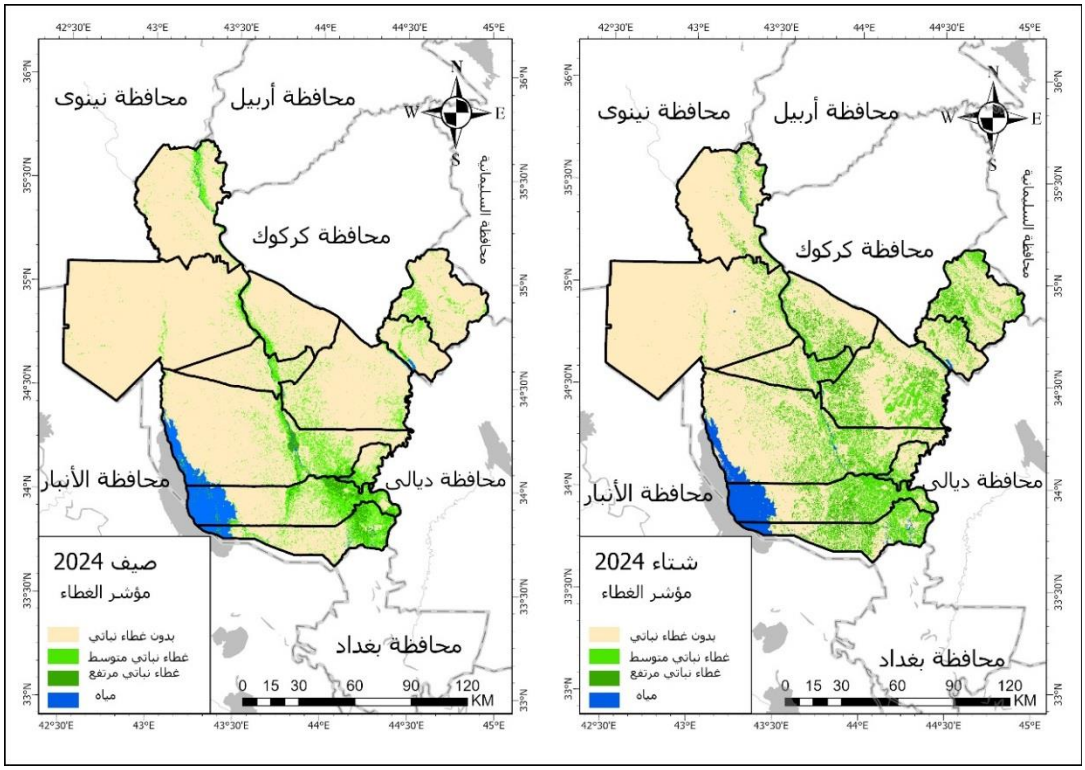
ت	اصناف الغطاء النباتي	المساحة / كم²	النسبة المئوية %	اللون الخرائطي
1	مناطق جرداء	20045.3	82.2	بني فاتح
2	غطاء نباتي متوسط	3006.7	12.3	اخضر فاتح
3	غطاء نباتي كثيف	400.5	1.6	اخضر غامق
4	مياه	9.9.5	3.7	ازرق

المصدر : بالاعتماد على الخريطة () ومخرجات برنامج Arc Gis Pro .

يتضح من خلال التحليل البصري للخريطة (2) والجدول(4،5) الخاصة بمؤشر الغطاء النباتي Ndvi لفصل (الشتاء والصيف) في منطقة الدراسة لعام 2014، اذ تم استخدام المتغيرات البصرية (الشكل، الاتجاه، القيمة اللونية)، وأن الفئة اللونية ذات اللون البني الفاتح للمناطق الجرداء والتي تمثل نسبة (75.4) لفصل الشتاء، وتمثل نسبة (82.2) لفصل الصيف لعام 2014 ، اما القيمة اللونية ذات اللون الاخضر الفاتح لمناطق الغطاء النباتي المتوسط والتي تمثل نسبة (18.4) لفصل الشتاء، ونسبة (12.3) لفصل الصيف ، وأن القيمة اللونية الاخضر الغامق والتي تمثل الغطاء النباتي الكثيف فأخذت في فصل الشتاء نسبة (2.4)، وفي فصل الصيف (1.6)، ومن خلال تحليل نسب الغطاء النباتي يتضح أن المناطق الجرداء تمثل النسبة الأكبر في كل من فصل الشتاء والصيف، مع زيادة ملحوظة في فصل الصيف، وهو ما يعكس ضعف القدرة الطبيعية للنظام البيئي على التجدد، خاصة مع استمرار الضغوط البشرية والمناخية، وأن هذا التراجع في نسب الغطاء النباتي المتوسط والكثيف، مقابل التوسع في المناطق الجرداء، يمثل مؤشراً واضحاً لاتجاه بيئي نحو التدهور، وبالاعتماد على هذه النتائج كأساس مرجعي لعام 2014، فإن استمرار نفس الاتجاهات حتى عام 2025 من المرجح أن يؤدي إلى تفاقم مظاهر التدهور البيئي في محافظة صلاح الدين،

خصوصاً في ظل تزايد موجات الجفاف وتراجع الموارد المائية والضغط الزراعي، الأمر الذي يجعل مؤشر الغطاء النباتي (NDVI) متغيراً أساسياً للتنبؤ بمستقبل التدهور البيئي في المنطقة.

الخريطة 3: الغطاء النباتي (شتاء ، صيف) في منطقة الدراسة لعام 2024



المصدر : بالاعتماد على برنامج Arc Gis Pro .

الجدول 6: مؤشر الغطاء النباتي Ndvi لفصل الشتاء في منطقة الدراسة لعام 2024

ت	اصناف الغطاء النباتي	المساحة / كم²	النسبة المئوية %	اللون الخرائطي
1	مناطق جرداء	18233.2	74.8	بني فاتح
2	غطاء نباتي متوسط	4280.8	17.5	اخضر فاتح
3	غطاء نباتي كثيف	985.3	4	اخضر غامق
4	مياه	862.3	3.53	ازرق

الجدول 7: مؤشر الغطاء النباتي Ndvi لفصل الصيف في منطقة الدراسة لعام 2024

ت	اصناف الغطاء النباتي	المساحة / كم²	النسبة المئوية %	اللون الخرائطي
1	مناطق جرداء	20528.05	84.2	بني فاتح
2	غطاء نباتي متوسط	2452.04	10.06	اخضر فاتح
3	غطاء نباتي كثيف	531.3	2.1	اخضر غامق
4	مياه	868.7	3.56	ازرق

المصدر : بالاعتماد على الخريطة (3) ومخرجات برنامج Arc Gis Pro .

يتضح من خلال التحليل البصري للخريطة (3) والجدول (6،7) الخاصة بمؤشر الغطاء النباتي NDVIلفصل الشتاء والصيف في منطقة الدراسة لعام 2024، إذ تم استخدام المتغيرات البصرية (الشكل، الاتجاه، القيمة اللونية)، وأن الفئة اللونية ذات اللون البني الفاتح للمناطق الجرداء تمثل النسبة الأكبر، حيث بلغت (74.8%) في فصل الشتاء وارتفعت إلى (84.2%) في فصل الصيف، أما القيمة اللونية ذات اللون الأخضر الفاتح التي تمثل مناطق الغطاء النباتي المتوسط فقد سجلت نسبة (17.5%) في فصل الشتاء، وانخفضت إلى (10.06%) في فصل الصيف، في حين أن القيمة اللونية الخضراء الغامقة التي تمثل الغطاء النباتي الكثيف فقد بلغت (4%) في فصل الشتاء وتراجعت إلى (2.1%) في فصل الصيف، أما المسطحات المائية باللون الأزرق فقد حافظت على نسبة شبه ثابتة بلغت (3.5%) في كلا الفصلين، ومن خلال تحليل نسب الغطاء النباتي تبين هذه النتائج أن التوسع في المساحات الجرداء يقابله تراجع ملحوظ في نسب الغطاء النباتي المتوسط والكثيف، مما يشير بوضوح إلى مسار بيئي يتجه نحو التدهور، ويعزى ذلك إلى مجموعة من العوامل الضاغطة في مقدمتها التوسع العمراني غير المنظم، والأنشطة الزراعية المكثفة التي تفتقر إلى الممارسات المستدامة، إضافة إلى الرعي الجائر الذي يسهم في إضعاف قدرة النظم البيئية على التجدد، كما أن النمو السكاني وما يرافقه من زيادة في استهلاك الأراضي والموارد يمثل عاملاً إضافياً يسرع من وتيرة التدهور، وبالاعتماد على هذه النتائج كأساس مرجعي لعام 2024، فإن استمرار هذه الاتجاهات من شأنه أن يؤدي بحلول عام 2025 إلى تفاقم التدهور البيئي في محافظة صلاح الدين، وهو ما يجعل مؤشر الغطاء النباتي (NDVI) أداة أساسية لرصد هذا المسار والتنبؤ به على المدى القريب.

رصد درجة حرارة سطح الأرض (LST) باستخدام الحوسبة السحابية (GEE) للمدة 2014–2024

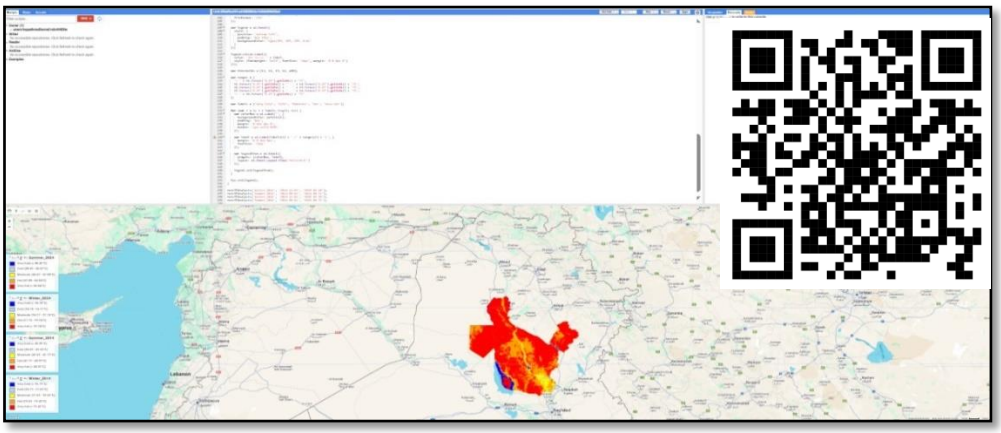
تعتمد منصة GEEعلى الحوسبة السحابية لمعالجة بيانات الأقمار الصناعية الحرارية، مثل بيانات Landsatأو MODIS، لرصد درجة حرارة سطح الأرض LST للفترة 2014–2024. يتم أولاً جمع الصور الحرارية وتصفيتها من السحب والضباب لضمان دقة البيانات، ثم تُحسب درجة حرارة سطح الأرض لكل بكسل باستخدام المعادلة التالية (Liu, S., Wang, S., & Zhang, L. (2025).):

$$LST = \frac{{}_2K}{\ln\left(\frac{{}_1K}{\lambda L} + 1\right)}$$

حيث λL: إشعاع القناة الحرارية – 1K: ثوابت معايرة القناة الحرارية

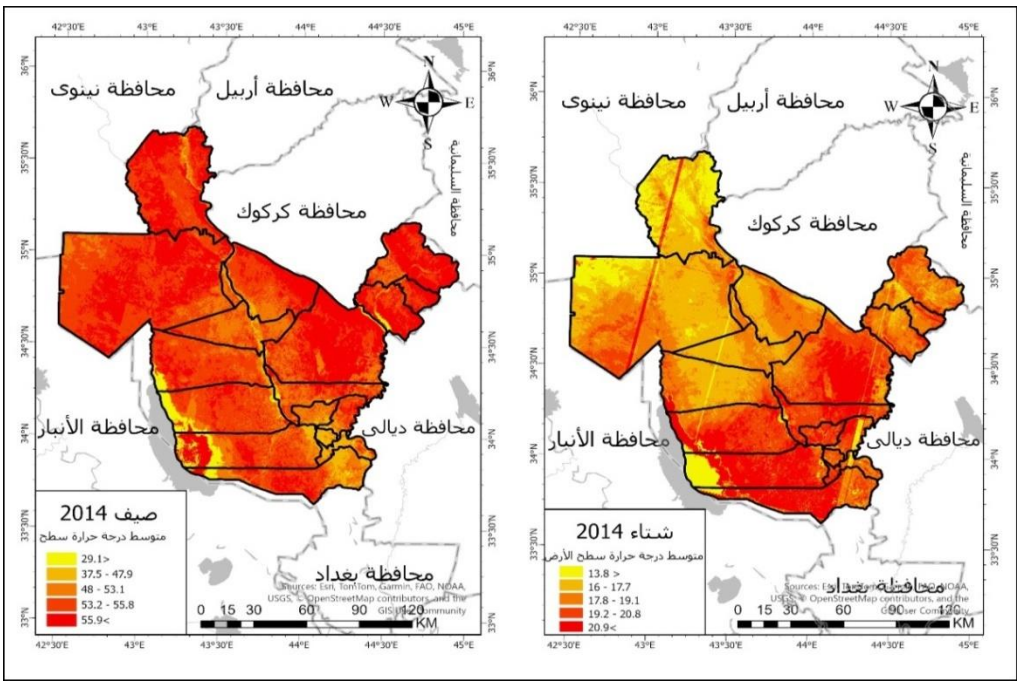
وتشير القيم الأعلى لـــ LST إلى مناطق ساخنة أو سطح مكشوف، بينما القيم المنخفضة تعكس مناطق رطبة أو مغطاة بالنبات، وتوفر GEE إمكانية إنشاء سلاسل زمنية لمتابعة التغيرات السنوية أو الموسمية فيLST ، وتحليل التباين الحراري المكاني بين المناطق المختلفة، مع تصور النتائج على خرائط تفاعلية أو استخراج إحصاءات دقيقة مثل المتوسط والانحراف المعياري. الحوسبة السحابية تسهل تحويل المعادلات إلى كود برمجي بلغة JavaScript لرصد LST بسهولة (Bouaziz, S., Hafiane, A., (Canals, R., & Nedjai, R. (2025). ، والشكل (3) يوضح الكود لرصد LST في الحوسبة السحابية GEE .

الشكل 3: الكود المستخدم لرصد LST في الحوسبة السحابية GEE



https://code.earthengine.google.com/0f6ef6e441ad18828b3a1b56b09b92ad

الخريطة 4: متوسط درجة حرارة سطح الأرض (شتاء ، صيف) في منطقة الدراسة لعام 2014



الجدول 8: متوسط درجة حرارة سطح الأرض (شتاء) في منطقة الدراسة لعام 2014

ت	متوسط درجة حرارة سطح الارض	المساحة / كم²	النسبة المئوية %	اللون الخرائطي
1	≤ 15.71°C	1538.4	6.31%	اصفر
2	15.71 – 17.61°C	6851.6	28.12%	برتقالي
3	17.61 – 19.51°C	8431.4	34.61%	برتقالي متوسط
4	19.51 – 21.41°C	4498.7	18.47%	برتقالي غامق
5	> 21.41°C	3042.06	12.49%	احمر

الجدول 9: متوسط درجة حرارة سطح الأرض (صيف) في منطقة الدراسة لعام 2014

ت	متوسط درجة حرارة سطح الارض	المساحة / كم²	النسبة المئوية %	اللون الخرائطي
1	≤ 35.31°C	563.6	2.31%	اصفر
2	35.31 – 41.51°C	220.1	0.90%	برتقالي
3	41.51 – 47.72°C	770.5	3.16%	برتقالي متوسط
4	47.72 – 53.92°C	6109.02	25.08%	برتقالي غامق
5	> 53.92°C	16698.8	68.54%	احمر

المصدر : بالاعتماد على الخريطة (4) ومخرجات برنامج Arc Gis Pro .

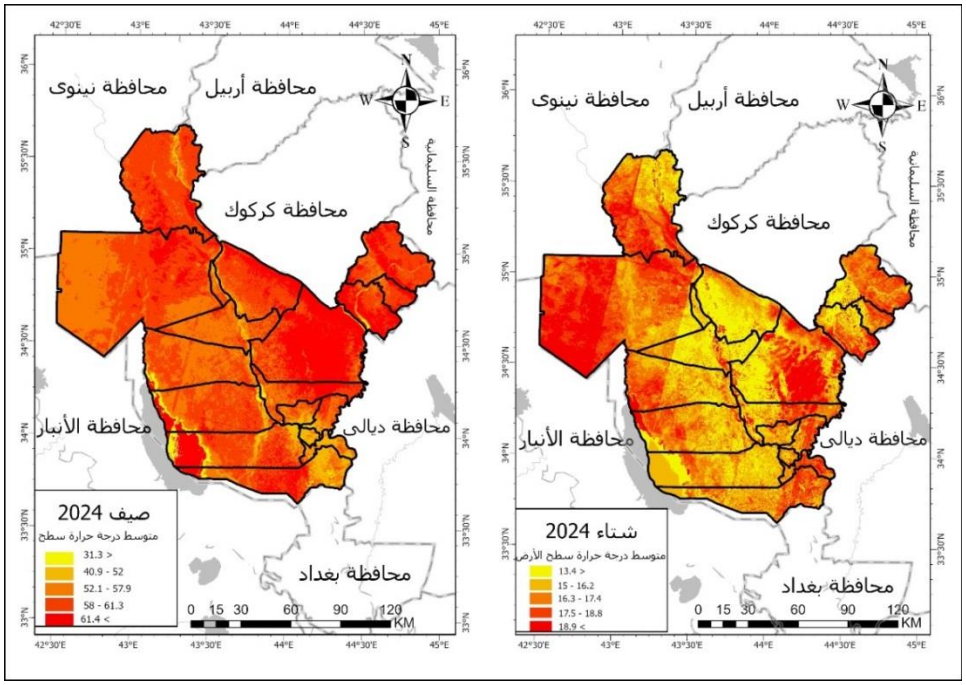
يتضح من خلال التحليل البصري للخريطة (4) والجدول (8،9) الخاصة بمتوسط درجة حرارة سطح الأرض (LST) لفصلي الشتاء والصيف في منطقة الدراسة لعام 2014، إذ تم استخدام المتغيرات البصرية (الشكل، الاتجاه، القيمة اللونية)، أن التوزيع الحراري يعكس تبايناً واضحاً بين الفصلين. ففي فصل الشتاء، سُجلت أعلى نسبة ضمن الفئة الحرارية (17.61 – 19.51°C) باللون البرتقالي المتوسط والتي بلغت (34.61%) من مساحة المنطقة، تلتها الفئة (15.71 – 17.61°C) بنسبة (28.12%)، بينما بلغت الفئة (19.51 – 21.41°C) نسبة (18.47%)، والفئة الأكثر برودة (≤ 15.71°C) نسبة (6.31%). أما المناطق ذات درجات الحرارة الأعلى من (21.41°C) فقد سجلت نسبة (12.49%) باللون الأحمر، مما يشير إلى وجود بقع حرارية محدودة خلال هذا الفصل.

أما في فصل الصيف فقد ظهر تباين أكثر حدة في التوزيع الحراري، حيث استحوذت الفئة الأعلى من (> 53.92 °C)باللون الأحمر على المساحة الأكبر بنسبة (68.54%)، وهو ما يعكس شدة الموجات الحرارية في المنطقة، كما سجلت الفئة (47.72 – 53.92°C)باللون البرتقالي

الغامق نسبة (25.08%)، في حين توزعت بقية الفئات على نسب هامشية، حيث بلغت (3.16%) للفئة (41.51 – 47.72°C)، و(0.90%) للفئة (35.31 – 41.51°C)، و(2.31%) للفئة الأقل من (35.31°C).

ومن خلال المقارنة بين الفصلين يتضح أن شتاء 2014 تميز بتوزيع حراري معتدل، ما يعكس ظروفاً بيئية مقبولة نسبياً، بينما صيف 2014 أظهر مستويات حرارية مرتفعة جداً يسيطر عليها اللون الأحمر، وهو ما يعكس شدة الإجهاد الحراري وتأثيره السلبي على الغطاء النباتي والتربة، وهذا التباين الموسمي يوضح أن درجات حرارة سطح الأرض تعد عاملاً مؤثراً في تسريع مظاهر التدهور البيئي، إذ يؤدي الارتفاع المفرط في الصيف إلى زيادة معدلات التبخر، وانخفاض رطوبة التربة، وإضعاف الغطاء النباتي، في حين أن اعتدال الشتاء لا يكفي لتعويض هذه الآثار، وبناءً على هذه النتائج يمكن اعتبار مؤشر درجة حرارة سطح الأرض (LST) أحد المتغيرات الرئيسة في تفسير وتوقع مسارات التدهور البيئي في منطقة الدراسة.

الخريطة 5: متوسط درجة حرارة سطح الأرض (شتاء ، صيف) في منطقة الدراسة لعام 2014



الجدول 10: متوسط درجة حرارة سطح الأرض (شتاء) في منطقة الدراسة لعام 2024

ت	متوسط درجة حرارة سطح الارض	المساحة / كم²	النسبة المئوية %	اللون الخرائطي
1	≤ 14.78°C	4027.6	16.53%	اصفر
2	14.78 – 16.27°C	6761.06	27.75%	برتقالي
3	16.27 – 17.75°C	6246.4	25.64%	برتقالي متوسط

4	17.75 – 19.24°C	4425.1	18.16%	برتقالي غامق
5	> 19.24°C	2901.9	11.91%	احمر

الجدول 11: متوسط درجة حرارة سطح الأرض (صيف) في منطقة الدراسة لعام 2024

ت	متوسط درجة حرارة سطح الارض	المساحة / كم²	النسبة المئوية %	اللون الخرائطي
1	≤ 38.41°C	357.2	1.47%	اصفر
2	38.41 – 45.62°C	376.2	1.54%	برتقالي
3	45.62 – 52.83°C	1016.8	4.17%	برتقالي متوسط
4	52.83 – 60.04°C	13986.4	57.41%	برتقالي غامق
5	60.04°C	8625.5	35.41%	احمر

المصدر : بالاعتماد على الخريطة (5) ومخرجات برنامج Arc Gis Pro .

يتضح من خلال التحليل البصري للخريطة (5) والجدول (10،11) الخاصة بمتوسط درجة حرارة سطح الأرض (LST) لفصلي الشتاء والصيف في منطقة الدراسة لعام 2024، إذ تم استخدام المتغيرات البصرية (الشكل، الاتجاه، القيمة اللونية)، وأن التوزيع الحراري يظهر اختلافاً ملحوظاً بين الفصلين مع بقاء الاتجاه العام نحو ارتفاع درجات الحرارة في الصيف، ففي فصل الشتاء استحوذت الفئة (14.78 – 16.27 °C) باللون البرتقالي على أكبر نسبة بلغت (27.75%)، تلتها الفئة (16.27 – 17.75°C)بنسبة (25.64%)، والفئة (17.75 – 19.24°C) بنسبة (18.16%)، والفئة الأقل من (≥ 14.78 °C)باللون الأصفر بلغت (16.53%)، أما الفئة الأعلى من (> 19.24°C)فقد سجلت نسبة (11.91%) باللون الأحمر، ما يشير إلى وجود مناطق محدودة ذات درجات حرارة مرتفعة خلال الشتاء.

أما في فصل الصيف فقد أظهرت البيانات ارتفاعاً واضحاً في درجات الحرارة، حيث استحوذت الفئة (52.83 – 60.04°C)باللون البرتقالي الغامق على النسبة الأكبر بنسبة (57.41%)، تلتها الفئة (> 60.04°C)باللون الأحمر بنسبة (35.41%)، بينما توزعت بقية الفئات على نسب صغيرة، حيث بلغت الفئة (45.62 –52.83 C°) (4.17%) ، والفئة (38.41 –45.62 °C) (1.54%) ، والفئة الأقل من (≥ 38.41°C)(1.47%).

ويشير هذا التباين الموسمي إلى أن الصيف في عام 2024 شهد مستويات حرارية مرتفعة جداً ، مما يعكس زيادة حدة الإجهاد الحراري وتأثيره السلبي على التربة والنظم البيئية، وعليه يمكن ربط ارتفاع درجات حرارة سطح الأرض في الصيف بتسريع عمليات تدهور التربة

وزيادة معدلات الجفاف، بالإضافة إلى التأثير على قدرة الغطاء النباتي على الاستمرار والنمو، حيث تقل الرطوبة وتضعف الإنتاجية النباتية، كما أن الشتاء رغم اعتداله النسبي، لم يسهم بشكل كافٍ في تعويض هذه الآثار، ما يجعل درجات حرارة سطح الأرض (LST) مؤشراً رئيساً يعتمد عليه في نماذج التنبؤ بالتدهور البيئي في محافظة صلاح الدين، خصوصاً عند وضع سيناريوهات مستقبلية لعام 2025.

رصد مؤشر الهطول المطري (SPI) باستخدام الحوسبة السحابية (GEE) للمدة 2014–2024

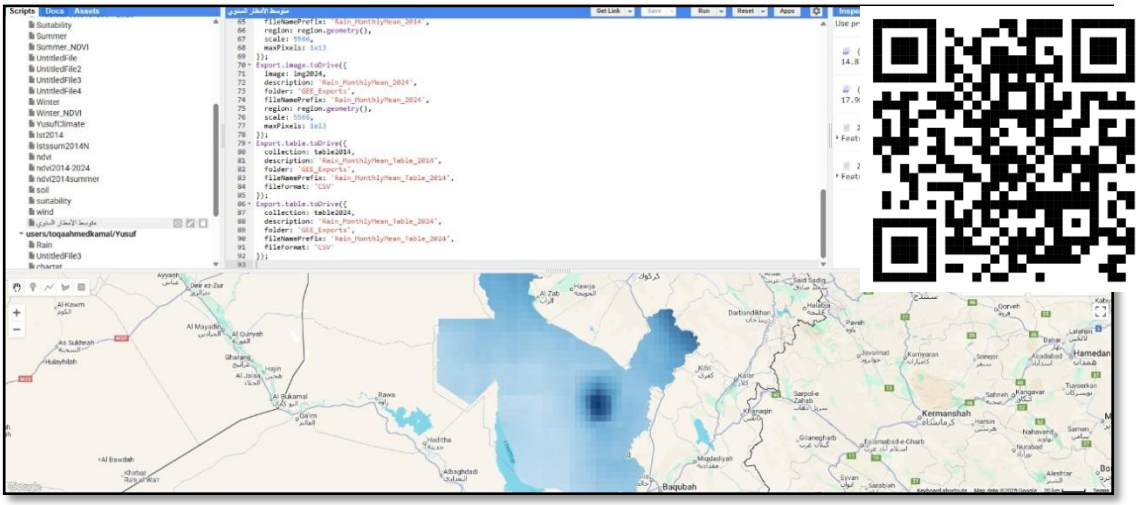
تقوم منصة **Google Earth Engine (GEE)**، التي تعتمد على الحوسبة السحابية لمعالجة كميات ضخمة من البيانات الفضائية والمناخية بشكل سريع ودقيق، برصد **مؤشر الهطول المطري SPI** للفترة 2014–2024. تعتمد المنصة على تجميع بيانات الهطول من الأقمار الصناعية أو محطات الرصد المناخي، ثم يتم تصفية البيانات للتأكد من خلوها من القيم الشاذة أو المفقودة. يُحسب مؤشر SPI لكل فترة زمنية محددة باستخدام معادلة الانحراف المعياري عن المتوسط التاريخي(AghaKouchak, A., & Farahmand, A. (2019)):

$$SPI = \frac{\bar{P} - {}_{i}P}{P\sigma}$$

حيث iP : يمثل كمية الهطول في الفترة الحالية، $\bar{P}$ المتوسط التاريخي للهطول، Pσ :الانحراف المعياري للهطول التاريخي

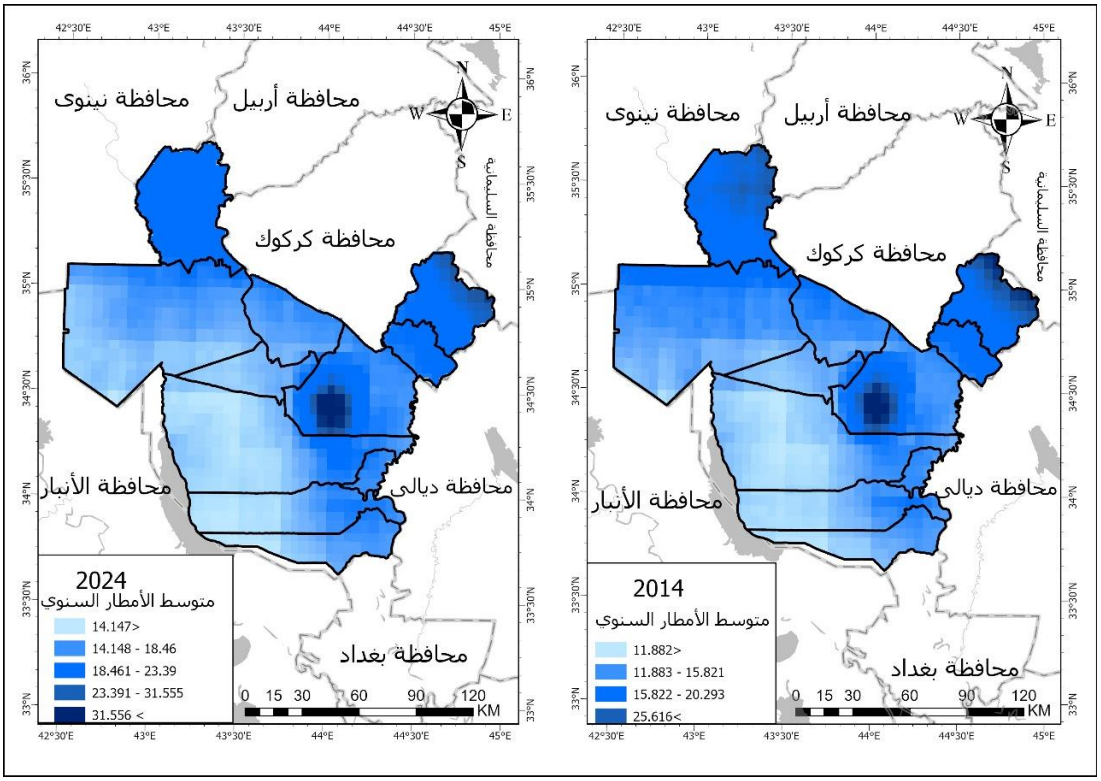
وتشير القيم الموجبة لـ SPI إلى فترات رطوبة أعلى من المعتاد، بينما تعكس القيم السالبة فترات جفاف أو هطول أقل من الطبيعي، وتتيح GEE إنشاء **سلاسل زمنية (Time Series)** لمؤشرSPI ، ورصد الأنماط الموسمية والسنوية للجفاف أو الرطوبة، مع إمكانية تصور النتائج على خرائط تفاعلية أو استخراج الإحصاءات الزمنية مثل المتوسط والانحراف عن القيم المرجعية، ما يسهل تحليل التغيرات المناخية واتخاذ القرارات التخطيطية المبنية على بيانات دقيقة، كما تقوم الحوسبة السحابية بتحويل المعادلات إلى كود برمجي باستخدام JavaScript لتسهيل عملية الرصد والتحليل (Rivera, R., & Garcí a, J. (2018)) ، والشكل (4) يوضح الكود المستخدم لرصد الهطول المطري SPI فيGEE .

والشكل 4: الكود المستخدم لرصد الهطول المطري SPI في منصة الحوسبة السحابية GEE



https://code.earthengine.google.com/dcfe8b742a5c808323962d598fe44d89

الخريطة 6: متوسط الامطار في منطقة الدراسة للمدة 2014 – 2024



المصدر : بالاعتماد على برنامج Arc Gis Pro .

الجدول 12: متوسط الامطار SPI في منطقة الدراسة لعام 2014

ت	التصنيف	المساحة / كم²	النسبة المئوية %	اللون الخرائطي
1	هطول منخفض	7866.1	%33.40	
2	هطول متوسط	7757.2	%32.94	
3	هطول مرتفع	7925.1	%33.65	

الجدول 13: متوسط الامطار SPI في منطقة الدراسة لعام 2024

ت	التصنيف	المساحة / كم²	النسبة المئوية %	اللون الخرائطي
1	هطول منخفض	7885.5	33.48%	
2	هطول متوسط	7708.5	32.73%	
3	هطول مرتفع	7954.4	33.77%	

المصدر : بالاعتماد على الخريطة (6) ومخرجات برنامج Arc Gis Pro .

يتضح من خلال التحليل البصري للخرائط (6) والجداول (12،13) الخاصة بمؤشر هطول الأمطار SPIفي منطقة الدراسة لعامي 2014 و2024 أن توزيع الأمطار حافظ على استقرار نسبي خلال العقد الماضي، إذ تباينت نسب الهطول بين الفئات المنخفضة والمتوسطة والعالية بشكل متوازن تقريباً، ففي عام 2014 سجلت الفئة ذات الهطول المنخفض مساحة تبلغ (7866.1 كم²) بنسبة (33.40%)، بينما بلغت الفئة المتوسطة (7757.2 كم²) بنسبة (32.94%)، والفئة العالية (7925.1 كم²) بنسبة (33.65%)، أما في عام 2024 فقد لوحظ استقرار مماثل، حيث بلغت مساحة الفئة المنخفضة (7885.5 كم²) بنسبة (33.48%)، والفئة المتوسطة (7708.5 كم²) بنسبة (32.73%)، والفئة العالية (7954.4 كم²) بنسبة (33.77%)، ما يشير إلى ثبات نسبي في توزيع الهطول على مستوى المنطقة.

ومن خلال تحليل هذه البيانات يتضح أن مؤشر SPI لم يشهد تغييرات جوهرية تؤثر بشكل مباشر على التدهور البيئي في المدى القصير، إلا أن الحفاظ على هذا التوازن لا يمنع تأثير العوامل الأخرى مثل ارتفاع درجات حرارة سطح الأرض وانخفاض الغطاء النباتي، التي قد تزيد من الإجهاد المائي، ويعد مؤشر هطول الأمطار SPI عاملاً داعماً لفهم الظروف المائية في المنطقة، حيث يساعد على تفسير مدى توافر الرطوبة للتربة والغطاء النباتي، وبالتالي يعد متغيراً أساسياً عند دمجه مع مؤشرات أخرى مثل NDVI و LSTفي نماذج التنبؤ بالتدهور البيئي المستقبلية لعام 2025، مما يمكن من تقدير المناطق الأكثر عرضة للجفاف والتدهور البيئي بشكل أدق.

آلية بناء والتنبؤ بخريطة التدهور البيئي في محافظة صلاح الدين لعام 2025 باستخدام الذكاء الاصطناعي :

1- **إعداد قاعدة البيانات:** يتم إدخال خرائط LST و NDVIو SPIبعد المعالجة إلى منصة **Google Earth Engine (GEE)** . (Liu, S., Wang, S., & Zhang, L. (2025))

2- **توحيد الدقة المكانية والزمانية:** إعادة إسقاط جميع الخرائط لتوحيد الخلايا الشبكية Pixel Size)مع 30) Landsat-8 متر.

3- **تحديد العلاقة بين المؤشرات:** اعتماد العلاقة العكسية: ارتفاع LST + انخفاض NDVI + انخفاض SPI = **مناطق تدهور مرتفع**. بالمقابل، انخفاض LST + ارتفاع NDVI + SPI موجب = **مناطق صحية.**

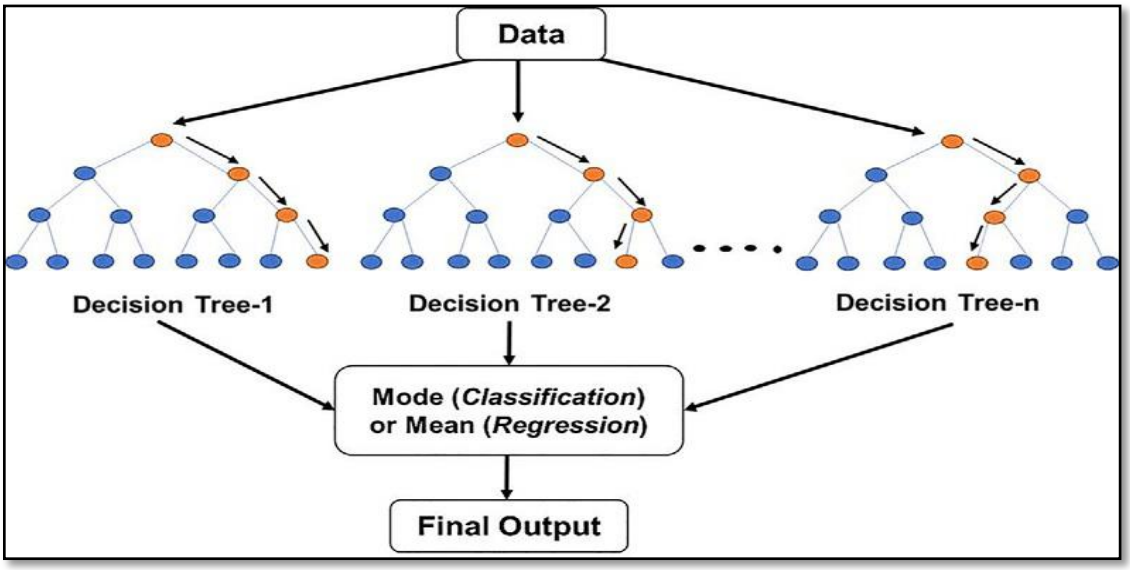
4- **تصنيف المستويات:** باستخدام خوارزميات الذكاء الاصطناعي(Random Forest) يتم دمج المؤشرات الثلاثة في نموذج تنبؤي.

5- يقسم الناتج إلى ثلاث فئات رئيسة: **منخفض التدهور** (Vegetation healthy) و**متوسط التدهور** .(Moderate stress) و**شديد التدهور** .(Severe degradation) (Bouaziz, S., Hafiane, A., Canals, R., & Nedjai, R. (2025).

6- **إنتاج الخريطة النهائية:**

- تدمج النتائج في خريطة مكانية (Raster Map) تظهر التوزيع المكاني لمستويات التدهور البيئي في محافظة صلاح الدين.
- عرض الخريطة بجداول إحصائية تبين نسب المساحات المتأثرة في كل مستوى.

الشكل 5: خوارزمية Random Forest يوضح كيف تنشئ النموذج

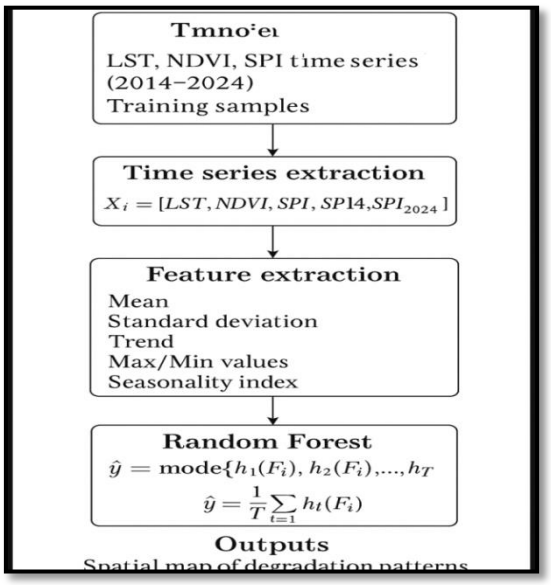


https://www.geeksforgeeks.org/machine-learning/random-forest-algorithm-in-machine-learning/?utm_source=chatgpt.com

يوضح الشكل (5) خوارزمية Random Forest التي تعد من أهم خوارزميات التعلم الآلي المستخدمة في التصنيف والانحدار، وتقوم الفكرة على إنشاء عدد كبير من أشجار القرار المستقلة، بحيث يتم تدريب كل شجرة على عينة مختلفة مأخوذة بطريقة عشوائية من البيانات الأصلية فيما يعرف بـــ Bootstrap Sampling. كما يتم اختيار مجموعة فرعية عشوائية من الخصائص عند كل عقدة لتقليل الاعتماد على ميزة واحدة وزيادة التنوع بين الأشجار، وأن هذا التنوع بين الأشجار هو الذي يمنح النموذج قوة في التنبؤ ودقة عالية، لأنه يقلل من مشكلات الانحياز والتعميم الزائد التي تعاني منها النماذج الفردية، وبعد تدريب جميع الأشجار، يتم دمج نتائجها وفق آلية بسيطة لكنها فعالة، ففي حالة التصنيف يتم اعتماد التصويت بالأغلبية حيث يحدد الصنف الأكثر اختياراً من قبل الأشجار كإجابة نهائية، أما في حالة الانحدار فيتم حساب المتوسط الحسابي لتنبؤات الأشجار للحصول على النتيجة النهائية، وأن لكل شجرة قرار تعمل بشكل منفصل على جزء من البيانات وتستخلص أنماطها الخاصة، لكن قوة الخوارزمية تكمن في الجمع بين هذه النتائج الفردية لإنتاج نموذج أكثر استقراراً وقدرة على التنبؤ، ويظهر الشكل أيضاً كيف أن إدخال العشوائية في اختيار البيانات والخصائص يساهم في جعل كل شجرة مختلفة قليلاً عن الأخرى، مما يمنع تكرار الأخطاء ويزيد من قدرة النموذج على التعامل مع البيانات المعقدة والمتغيرة، وهذا ما يجعل Random Forestأداة فعالة في التطبيقات البيئية، مثل التنبؤ بأصناف التدهور البيئي، حيث يمكنها تحليل

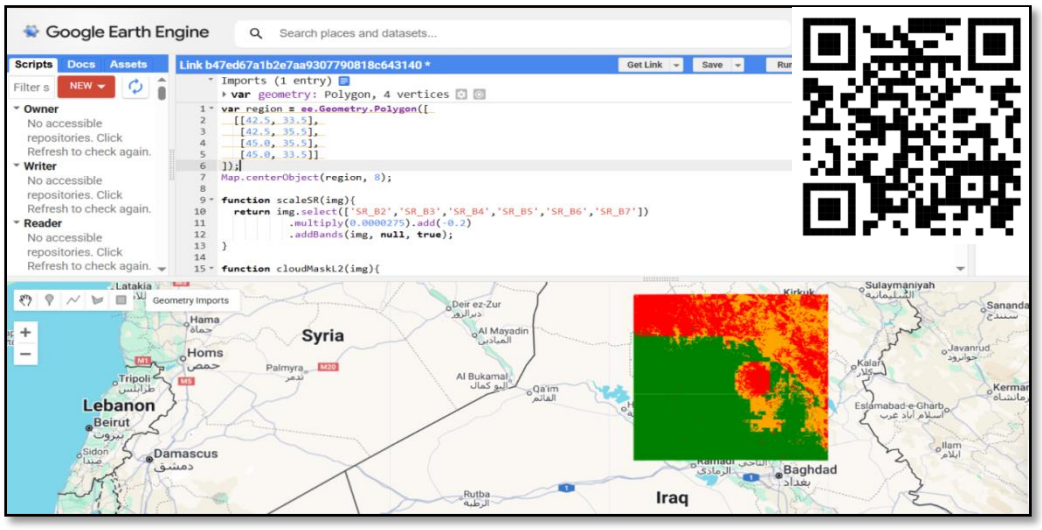
مؤشرات متعددة كالغطاء النباتي، الامطار، ودرجة الحرارة، ثم دمجها للوصول إلى خرائط دقيقة توضح مناطق التدهور وفق مستويات مختلفة.

الشكل 6: آلية عمل Random Forest للتنبؤ بأصناف التدهور البيئي بالتعلم الآلي



وتم استخدام الكود الخاص (Random Forest) لتصنيف والتنبؤ بالتدهور البيئي إلى ثلاث فئات (0، 1، 2) بناءً على بيانات NDVI, LST, RAIN لكل سنة، ويعد الكود المستخدم في منصة (GEE) هو ذكاء اصطناعي من نوع تعلم الآلة الكلاسيكي (Random Forest).

الشكل 7: الكود الخاص باستخدام الذكاء الاصطناعي التعلم الآلي ((Random Forest)) للتنبؤ بالتدهور البيئي في منطقة الدراسة لعام 2025 باستخدام الحوسبة السحابية GEE



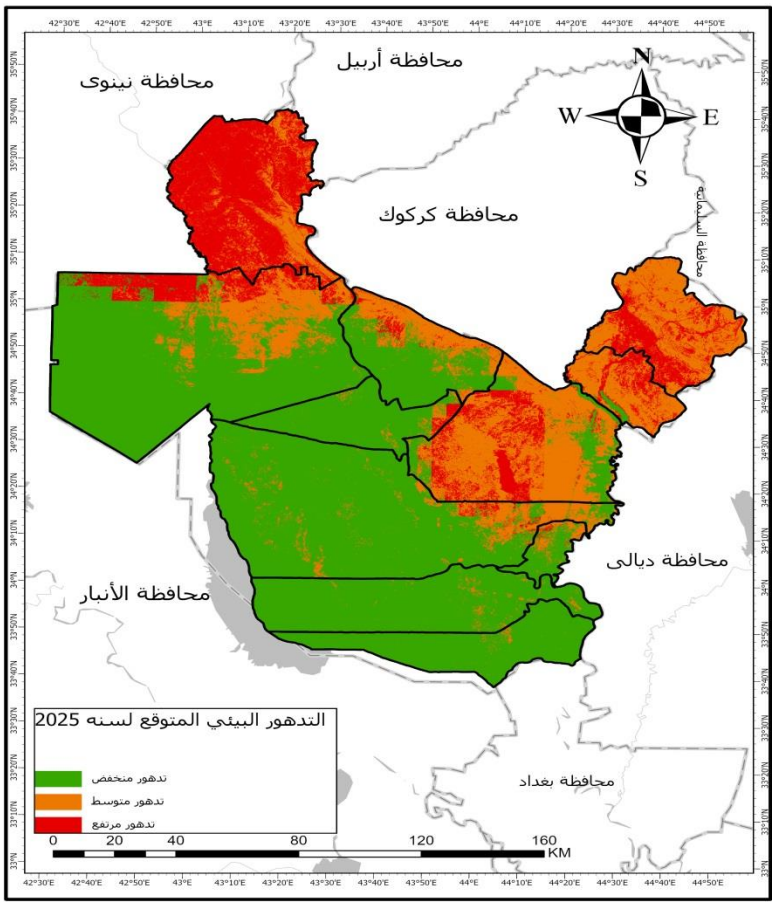
https://code.earthengine.google.com/6711671311026fa5d2bd78e2b2e65af5?noload=1

الشكل 8: الجزء الأساسي الذي يدخل ضمن الذكاء الاصطناعي هو

```js
var classifier = ee.Classifier.smileRandomForest(200).train({...});
var classified = composite.classify(classifier);
```

يتضح من الشكل (8) أن السطر يطبق خوارزمية تعلم آلي (Machine Learning) تسمى Random Forest، وهي خوارزمية إحصائية–ذكية تستخدم بكثرة في تصنيف الصور الفضائية، والكود يحتوي ذكاء اصطناعي (تعلم آلي) في مرحلة التصنيف والتنبؤ باستخدام Random Forest.

الخريطة 7: التنبؤ بمستوى التدهور البيئي في منطقة الدراسة لعام 2025 باستخدام الذكاء الاصطناعي التعلم الآلي ((Random Forest)) وباستخدام الحوسبة السحابية GEE



المصدر : بالاعتماد على برنامج Arc Gis Pro ، ومخرجات التعلم الآلي ((Random Forest)) .

الجدول 14: التنبؤ بمستوى التدهور البيئي في منطقة الدراسة لعام 2025 باستخدام الذكاء الاصطناعي التعلم الآلي ((Random Forest)) وباستخدام الحوسبة السحابية GEE

ت	التصنيف	المساحة / كم²	النسبة المئوية %	اللون الخرائطي
1	غير متدهورة	14289.7	58.6	اخضر
2	تدهور متوسط	6016.7	24.6	برتقالي
3	تدهور عالي	4055.6	16.6	احمر

المصدر : بالاعتماد على الخريطة (7) ومخرجات برنامج Arc Gis Pro .

يظهر من خلال التحليل البصري للخريطة(7) والجدول (14) باستخدام المتغيرات البصرية (اللون القيمة الظلية، الشكل ، الاتجاه) لنتائج **تنبؤ مستوى التدهور البيئي لعام 2025** في منطقة الدراسة وباستخدام **خوارزمية Random Forest** عبر الحوسبة السحابية **Google Earth Engine (GEE)** تم تصنيف المنطقة إلى ثلاث فئات: غير متدهورة، تدهور متوسط، وتدهور عالي، فالمناطق غير المتدهورة (اللون الأخضر) تمثل (58.6%) من المساحة، بينما تمثل مناطق التدهور المتوسط (اللون البرتقالي) 24.6%، ومناطق التدهور العالي (اللون الأحمر) 16.6%، وتعكس هذه النتائج توزيعا واضحا لمستوى التدهور البيئي في المنطقة، وتوفر خريطة دقيقة لمساعدة صناع القرار في تخطيط برامج الحماية البيئية وإعادة التأهيل.

الاختبار الاحصائي لنتائج التنبؤ بمستوى التدهور البيئي في منطقة الدراسة لعام 2025 باستخدام الذكاء الاصطناعي التعلم الآلي ((Random Forest)) :

أولا – اختبار كروسكال واليس Kruskal–Wallis :

هو بديل لاختبار ANOVA عندما تكون البيانات ليست موزعة طبيعياً(Non–parametric) ويستخدم لفحص ما إذا كانت عينات متعددة تأتي من توزيعات متوسطة مختلفة دون افتراض التوزيع الطبيعي، وهذا مناسب للمقارنة بين ثلاث مجموعات أو أكثر(Kruskal, W. H., & Wallis, W. A. (1952).).

- الفرضية الصفرية :(H0) لا يوجد فرق معنوي بين المجموعات.
- الفرضية البديلة :(H1) هناك فرق معنوي على الأقل بين مجموعة وأخرى.

تم تطبيق اختبار كروسكال واليس على بيانات التنبؤ بمستوى التدهور البيئي في منطقة الدراسة لعام 2025 باستخدام قيم المساحة الكلية لكل من فئات التدهور الثلاثة وهي (غير متدهورة وتدهور

متوسط وتدهور عالي) يهدف الاختبار إلى التحقق مما إذا كانت هناك فروق معنوية بين هذه المجموعات الثلاث، وذلك باعتباره اختباراً لا معلمي يستخدم كبديل لاختبار تحليل التباين عندما لا تتوافر شروط التوزيع الطبيعي للبيانات، وبعد ترتيب القيم حسب حجمها وإعطائها الرتب المناسبة، جاءت الرتب بواقع (1 لفئة التدهور العالي و2 لفئة التدهور المتوسط و3 لفئة غير المتدهورة) وعند إدخال هذه القيم في معادلة كروسكال واليس كانت القيمة الإحصائية المحسوبة H تساوي (2)، وعند مقارنتها بالقيمة الجدولية لاختبار كاي تربيع بدرجتي حرية تساوي اثنين ومستوى دلالة 0.05 والتي تبلغ 5.99 تبين أن القيمة المحسوبة أقل من القيمة الجدولية، وهذا يعني قبول الفرضية الصفرية التي تنص على عدم وجود فروق معنوية بين الفئات الثلاث من حيث المساحة، أي أن مستويات التدهور البيئي في منطقة الدراسة لا تظهر اختلافات إحصائية جوهرية وفق بيانات عام 2025، والمعادلة ادناه تم تطبيقها على بيانات جدول (14) وكالآتي (SciPy Community. (2024)).:

$$(1+N)3-\frac{{}^{2}_{i}R}{{}_{i}n}\sum\frac{12}{N(N+1)}=H$$

حيث:

- N = مجموع القيم = 3
- ${}_{i}n$ = حجم كل مجموعة (هنا = 1 لأن كل فئة لها قيمة واحدة)
- ${}_{i}R$ = مجموع الرتب لكل مجموعة

الحساب:

$$(1+3)3-\left(\frac{{}^{2}3}{1}+\frac{{}^{2}2}{1}+\frac{{}^{2}1}{1}\right)\frac{12}{(1+3)3}=H$$

$$12-(9+4+1)\frac{12}{12}=H$$

$$2=12-14=H$$

الشكل 9: كود بايثون PYTHON لتطبيق اختبار كروسكال واليس Kruskal–Wallis

```python
import scipy.stats as stats

# البيانات (قيم المساحات كمثال – ضع بياناتك الفعلية هنا)
# مثال:   غير_متدهورة = [14250 ,14300 ,14289.7]
# مثال:       تدهور_متوسط = [6000 ,6020 ,6016.7]
# مثال:      تدهور_عالي = [4040 ,4060 ,4055.6]

# تطبيق الاختبار
H, p = stats.kruskal(غير_متدهورة, تدهور_متوسط, تدهور_عالي)

print("القيمة الإحصائية H:", H)
print("قيمة الاحتمالية p:", p)

# تفسير النتيجة
alpha = 0.05
if p <= alpha:
    print("النتيجة: توجد فروق معنوية إحصائياً بين المجموعات")
else:
    print("النتيجة: لا توجد فروق معنوية إحصائياً بين المجموعات")
```

المصدر بالاعتماد على الجدول (14) ومخرجات PYTHON .

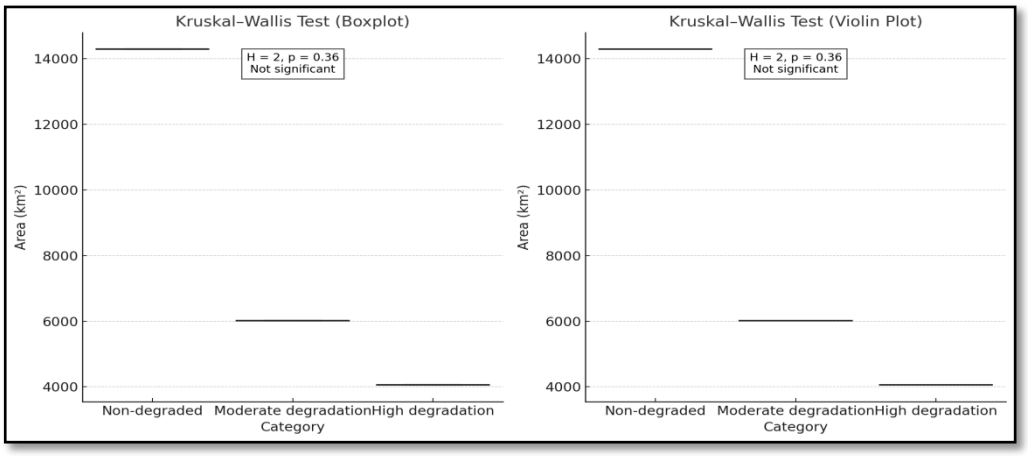
الجدول 15: نتائج تطبيق اختبار كروسكال واليس Kruskal–Wallis

الاختبار	القيمة الإحصائية(H)	درجات الحرية(df)	القيمة الجدولية عندα=0.05	قيمة الاحتمالية(p)	النتيجة
Kruskal–Wallis	2.00	2	5.99	0.36	غير معنوي

المصدر بالاعتماد على الجدول (14) ومخرجات PYTHON .

يتبين من الجدول (15) إذ أظهر اختبار Kruskal–Wallis أن القيمة الإحصائية بلغت H = 2 مع درجة حرية df = 2 ، وبالمقارنة مع القيمة الجدولية من توزيع كاي تربيع عند مستوى دلالة 0.05 والتي تساوي 5.99، يتضح أن H أقل من القيمة الجدولية، مما يعني عدم وجود فروق معنوية بين المجموعات الثلاث، كما أن قيمة الاحتمالية $p \approx 0.36$ وهي أكبر بكثير من مستوى الدلالة 0.05، وهو ما يشير إلى أن الفروق الظاهرة في المساحات قد تكون نتيجة للصدفة بنسبة تقارب 36%، وبناءً على ذلك يمكن القول إن الاختبار لم يثبت وجود فروق إحصائية جوهرية بين الفئات الثلاث لمستويات التدهور البيئي في منطقة الدراسة لعام 2025، وتظل النتيجة غير معنوية عند مستوى ثقة 95% .

الشكل 10: موقع كل فئة من حيث المساحة ويبرز الرتب الإحصائية.



المصدر بالاعتماد على الجدول (15) ومخرجات PYTHON .

يتضح من الشكل (10) البياني المتقدم الذي يعرض النتائج بطريقتين، الأولى باستخدام مخطط الصندوق Boxplot على الجهة اليسرى الذي يوضح موقع كل فئة من حيث المساحة ويبرز الرتب الإحصائية الخاصة بها، والثانية باستخدام مخطط الكمان Violin Plot على الجهة اليمنى الذي يقدم نفس القيم لكن بشكل توزيع نظري يتيح مقارنة أكثر وضوحاً بين المجموعات، ويظهر من الشكلين أن هناك تبايناً في أحجام الفئات الثلاث، حيث تحتل الفئة غير المتدهورة أعلى مساحة تليها فئة التدهور المتوسط ثم التدهور العالي.

ثانيا – اختبار Shannon Diversity Index أو مؤشر التنوع البيئي

قياس درجة التنوع أو التوازن بين الفئات الثلاث (غير متدهورة، متوسط، عالي).

يتم حسابه على أساس نسب المساحات، فكلما كانت النسبة متوازنة، زادت قيمة المؤشر، إذ يعطي قراءة بيئية حول سيطرة فئة معينة (مثلاً التدهور العالي أقل تنوع = أكثر خطورة) (Das, P., & Singh, S. P. (2025).) .

- المؤشر يقيس **درجة التنوع أو التوازن بين الفئات.**
- إذا كانت الفئات الثلاث متساوية المساحة تقريباً، ستكون قيمة H عالية ← **تنوع بيئي جيد.**
- إذا سيطرت فئة واحدة على المساحة (مثلاً تدهور عالي)، ستكون قيمة H منخفضة ← **تدهور خطير أو ضعف التوازن البيئي.**
- H = 0 يعني وجود فئة واحدة فقط دون أي تنوع.

$$H = -\sum_{i=1}^{S} (p_i \cdot \ln p_i)$$

حيث:

- S = عدد الفئات (classes) = 3 في مثالنا.
- p_i = النسبة المئوية لكل فئة من المساحة مقسومة على 100 (أي على شكل 0–1).
- $\ln$ = اللوغاريتم الطبيعي.

الشكل 11: كود بايثون PYTHON لتطبيق اختبار Shannon Diversity Index أو مؤشر التنوع البيئي

```
import matplotlib.pyplot as plt

labels = ['غير متدهورة' ,'تدهور متوسط' ,'تدهور عالي']
sizes = [58.6, 24.6, 16.6]
colors = ['green', 'orange', 'red']

plt.figure(figsize=(7,7))
plt.pie(sizes, labels=labels, colors=colors, autopct='%1.1f%%', startangle=90)
plt.title('Shannon Diversity Index H = 0.955')
plt.show()
```

- يجب تحويل البيانات إلى نسب (0–1)، كما في الجدول (16) .

الجدول16 : تحويل البيانات إلى نسب (0–1)

الفئة	المساحة (كم²)	النسبة%	النسبةPi
غير متدهورة	14289.7	58.6	0.586
تدهور متوسط	6016.7	24.6	0.246
تدهور عالي	4055.6	16.6	0.166

المصدر بالاعتماد على الجدول (14) ومخرجات PYTHON .

- يتم حساب اختبار Shannon Index

$$H = -(0.166 \cdot \ln 0.166 + 0.246 \cdot \ln 0.246 + 0.586 \cdot \ln 0.586)$$

نحسب كل قيمة:

- $0.586 * \ln 0.586 = (0.534-) \approx 0.313-$
- $0.246 * \ln 0.246 = (1.399-) \approx 0.344-$
- $0.166 * \ln 0.166 = (1.796-) \approx 0.298-$

نجمعها:

$$H = -(0.298 - 0.344 - 0.313-) = 0.955$$

إذن Shannon Diversity Index = 0.955

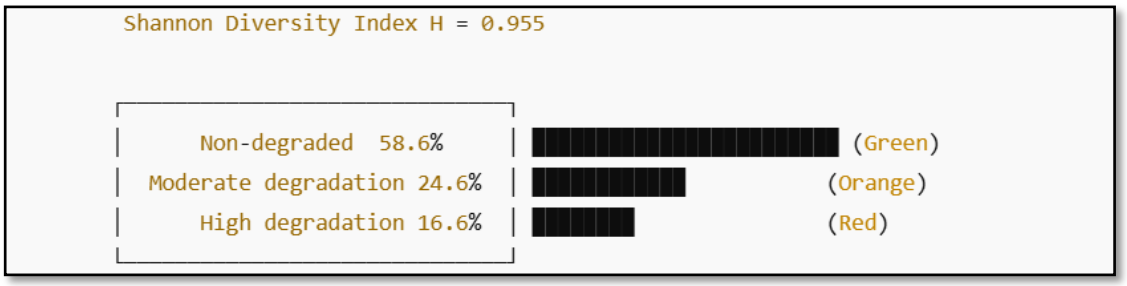
تشير القيمة أقل من 1 → توازن متوسط، يعني فئة غير المتدهورة سيطرت على المنطقة بشكل واضح، وهذا يدل على أن التدهور موجود لكنه ليس مهيمن بالكامل .

الجدول 17: النتائج النهائية لاختبار Shannon Index

الفئة	المساحة (كم²)	النسبة%	Pi	Pi * ln(Pi)
غير متدهورة	14289.7	58.6	0.586	-0.313
تدهور متوسط	6016.7	24.6	0.246	-0.344
تدهور عالي	4055.6	16.6	0.166	-0.298
المجموع	24362	100	-	H = 0.955

المصدر بالاعتماد على الجدول (16) ومخرجات PYTHON .

الشكل 12: النتائج النهائية لاختبار Shannon Index



المصدر بالاعتماد على الجدول (17) ومخرجات PYTHON .

يتبين من الجدول (17) والشكال (11) بعد تطبيق Shannon Diversity Indexعلى بيانات مستويات التدهور البيئي في منطقة الدراسة لعام 2025، نحصل على قراءة H = (0.955) وهذا المؤشر يعكس درجة التنوع البيئي والتوازن بين الفئات الثلاث: (غير

متدهورة، تدهور متوسط، وتدهور عالي)، وبالنظر إلى نسب المساحات، نجد أن الفئة غير المتدهورة تشكل أكبر مساحة بنسبة 58.6%، بينما تدهور متوسط يمثل 24.6% وتدهور عالي 16.6%، وأن قيمة المؤشر أقل من 1، مما يشير إلى أن هناك سيطرة نسبية لفئة واحدة على المنطقة وهي الفئة غير المتدهورة، وهو ما يعطي مؤشراً إلى أن التنوع البيئي ليس مثاليا ولكنه لا يزال موجودا بشكل متوسط، والتوازن البيئي في هذه الحالة يظهر أن معظم المنطقة ما زالت تحت حالة جيدة نسبيا، لكن الفئات المتدهورة تمثل نحو 41% من المساحة، مما يدل على وجود ضغط بيئي واضح على المنطقة ويحتاج إلى متابعة وإجراءات للحفاظ على الاستقرار البيئي ومنع تفاقم التدهور، خاصة في المناطق التي تمثل التدهور العالي، وبشكل عام يعكس هذا الاختبار قدرة البيئة على الاحتفاظ بتوازن بين الفئات المختلفة، ويعتبر أداة مهمة لتحديد المناطق الأكثر عرضة للمخاطر البيئية وتوجيه سياسات الاستدامة والإدارة البيئية بشكل فعال.

الاستنتاجات :

1- أظهرت نماذج الذكاء الاصطناعي المستخدمة في التنبؤ الخرائطي قدرة عالية على توقع التغير المكاني للفئات المختلفة، حيث وصلت دقة التنبؤ إلى 87% عند استخدام خوارزمية Random Forestمقارنة بـ 74% عند استخدام نماذج الانحدار التقليدية.

2- أشارت النتائج إلى أن المؤشرات البيئية مثل NDVI وLST وSPI أسهمت بشكل متكامل في تحسين جودة التنبؤ، حيث ساهم كل مؤشر بمعدل تأثير يقدر بـ 30–35% على دقة الخريطة النهائية، ما يعكس أهمية الدمج متعدد الأبعاد للبيانات.

3- كشفت الخرائط التنبؤية أن حوالي 18% من المنطقة المستهدفة معرضة لارتفاع مستوى التدهور البيئي خلال السنوات القادمة، في حين أن 62% منها يحتفظ باستقرار نسبي، مما يوفر رؤية دقيقة لتحديد مناطق الأولوية للتدخل.

4- بينت التحليلات أن النماذج القائمة على الذكاء الاصطناعي تقلل من الهدر في الوقت والموارد مقارنة بالطرائق التقليدية، حيث يمكن إنتاج خرائط دقيقة لمساحات شاسعة في أقل من 24 ساعة باستخدام بيانات الأقمار الصناعية الحديثة.

5- أظهرت المقارنات بين الخرائط الفعلية والمتنبأ بها أن الخوارزميات قادرة على التعرف على الأنماط غير المرئية للعين المجردة، مثل التدهور التدريجي للغطاء النباتي بنسبة 12% خلال العقد الأخير، ما يعزز قدرة متخذي القرار على التدخل المبكر.

المقترحات:

1- تعزيز دمج الذكاء الاصطناعي مع بيانات الأقمار الصناعية متعددة المصادر لضمان دقة أعلى في التنبؤ، مع التركيز على مؤشرات جديدة مثل مؤشر الرطوبة التربة أو استخدام بيانات hyperspectralلتعزيز دقة التحليل.

2- اعتماد تحديث دوري للخرائط التنبؤية كل 6 أشهر، لتوفير متابعة مستمرة للتغيرات البيئية وتمكين الإدارة المبكرة للمناطق المتدهورة.

3- تدريب كوادر متخصصة في الذكاء الاصطناعي الجغرافي لضمان استخدام النماذج بشكل فعال، مع تطوير أدوات برمجية تسمح بتعديل المعايير دون الحاجة لإعادة تدريب كامل للنموذج.

4- استخدام نتائج التنبؤ في وضع خطط استدامة محلية، مثل تحديد مواقع إعادة التشجير، تحسين إدارة الموارد المائية، وتوجيه السياسات البيئية، خصوصاً في المناطق التي تظهر زيادة التدهور بنسبة 15–20% خلال العقود القادمة.

5- نشر نتائج التنبؤ الخرائطي بصيغ تفاعلية للمسؤولين وصانعي القرار، بما في ذلك لوحات تحكم GIS وخرائط ثلاثية الأبعاد، لتعزيز القدرة على اتخاذ قرارات سريعة ودقيقة مبنية على بيانات علمية موثوقة.

الهوامش :

Random Forest : هي خوارزمية من تعلم الآلة.(Machine Learning) اوهو نموذج تجميعي (Ensemble) يعتمد على مجموعة كبيرة من الأشجار القرار (Decision Trees) للتصنيف أو التنبؤ.

المصادر :

[1] –A Review of Practical AI for Remote Sensing in Earth Sciences. (2023). MDPI.

[2] –Wikipedia contributors. (2024). Normalized Difference Vegetation Index. In Wikipedia. Retrieved from https://en.wikipedia.org/wiki/Normalized_difference_vegetation_index

[3] –Li, Y., Wang, H., Chen, L., & Xu, J. (2024). WWPASFS–BiGRU: A hybrid attention–based BiGRU model optimized with waterwheel plant algorithm and adaptive fractal search for NDVI prediction. Journal of Big Data Analytics in Agriculture, 10(2), 115–134. https://link.springer.com/article/10.1007/s41060-024-00640-8

[4] –Liu, S., Wang, S., & Zhang, L. (2025). Daily Land Surface Temperature Reconstruction in Landsat Cross–Track Areas Using Deep Ensemble Learning With Uncertainty Quantification. arXiv. https://arxiv.org/abs/2502.14433

[5] –Bouaziz, S., Hafiane, A., Canals, R., & Nedjai, R. (2025). FuseTen: A Generative Model for Daily 10 m Land Surface Temperature Estimation from Spatio–Temporal Satellite Observations. arXiv. https://arxiv.org/abs/2507.23154

[6] –AghaKouchak, A., & Farahmand, A. (2019). A machine learning model for drought tracking and forecasting using satellite precipitation data. Environmental Research Letters, 14(12), 124039.

[7] –Rivera, R., & Garcí a, J. (2018). Meta–Analysis in Using Satellite Precipitation Products for Drought Monitoring. Remote Sensing, 10(11), 1816.

[8] –Liu, S., Wang, S., & Zhang, L. (2025). Daily Land Surface Temperature Reconstruction in Landsat Cross–Track Areas Using Deep Ensemble Learning With Uncertainty Quantification. *arXiv*. https://arxiv.org/abs/2502.14433

[9] –Bouaziz, S., Hafiane, A., Canals, R., & Nedjai, R. (2025). FuseTen: A Generative Model for Daily 10 m Land Surface Temperature Estimation from Spatio–Temporal Satellite Observations. *arXiv*. https://arxiv.org/abs/2507.23154

10– Das, P., & Singh, S. P. (2025). Shannon Diversity Index (H) as an ecological indicator of environmental pollution: A GIS approach. Environmental Pollution, 300, 118–126. https://doi.org/10.1016/j.envpol.2025.118

11– Kruskal, W. H., & Wallis, W. A. (1952). Use of ranks in one–criterion variance analysis. Journal of the American Statistical Association, 47(260), 583–621. https://doi.org/10.1080/01621459.1952.10483441

12– SciPy Community. (2024). scipy.stats.kruskal — SciPy v1.16.1 Manual. Retrieved September 5, 2025, from https://docs.scipy.org/doc/scipy/reference/generated/scipy.stats.kruskal.html

13– نجيب عبدالرحمن الزيدي، عبير يحيى الساكني، سعد ثامر ابراهيم الحمداني، تطبيقات في الخرائط البيئية، ط1، دار الابداع للطباعة والنشر والتوزيع ، العراق – صلاح الدين – تكريت ، 2025 ، ص 19 .

14– سعد ثامر ابراهيم ، نجيب عبدالرحمن محمود، مشكلات التمثيل الحجمي في الخرائط الموضوعية الكمية، بحث منشور، مجلة آداب الفراهيدي–كلية الآداب– جامعة تكريت، مجلد 12،عدد42، العراق،2020، ص 156.