

Geospatial Artificial Intelligence (GeoAI) and Satellite Imagery (EOS), and Their Applications in Agriculture in Yemen

Ahmed Mohammed Eid

Ayoub Ahmed Abdulah Al-Mahab

Faculty of Agriculture- University of Ibb/ Yemen

Ministry of Agriculture and Irrigation/ Yemen

AYOUB.ALMHAB@GMAIL.COM

DOI:

<https://doi.org/10.59421/joats.v2i1.1896>



THIS WORK IS LICENSED UNDER A **CREATIVE**
COMMONS ATTRIBUTION 4.0
INTERNATIONAL LICENSE.

Abstract

The study aimed to present a proposed concept for the application of artificial intelligence in Yemeni universities, and the descriptive analytical method was used, using the forward-looking studies method (Deal Alfy) to identify the requirements of the application of artificial intelligence in Yemeni universities from the point of view of experts. Specialists with long experience and deep specialist knowledge in artificial intelligence, smart information systems, computer programming, information technology, IT, management and planning. (13) Experts, and the study reached several results, the most important of which are: there is consensus on experts on the application of the requirements of the dimensions of artificial intelligence (after the legislative and regulatory requirements, after the human requirements, after the technical requirements, after the financial requirements, after the ethical requirements). The study recommended the necessity of adopting and implementing the proposed vision for applying artificial intelligence in Yemeni universities.

Keywords: Artificial Intelligence, Yemeni Universities.

الذكاء الاصطناعي الجغرافي المكاني (GeoAI) والصور الفضائية (EOs)، وتطبيقاتهما على الزراعة في اليمن

أحمد محمد عيد

أيوب أحمد عبدالله المهاب

كلية الزراعة - جامعة إب / اليمن

وزارة الزراعة والري / اليمن

ayoub.almhab@gmail.com

الملخص

يعتبر الذكاء الاصطناعي الجغرافي المكاني والتصوير الفضائي (GeoAI- EO) علم ناشئ يستخدم التطورات في الحوسبة عالية الأداء لتطبيق التقنيات في الذكاء الاصطناعي، لا سيما التعلم الآلي (مثل التعلم العميق) واستخدام البيانات لاستخراج معلومات مفيدة من البيانات المكانية الضخمة. إنه مجال متخصص في العلوم المكانية على حد سواء؛ لأنه يوجب استخدام تقنيات مكانية معينة، بما في ذلك GIS، لمعالجة وتحليل البيانات المكانية، ونوع مطبق من علم البيانات المكانية، حيث يركز بشكل خاص على تطبيق تقنيات الذكاء الاصطناعي لتحليل البيانات المكانية الضخمة. تهدف الورقة إلى استعراض تطبيقات الذكاء الاصطناعي الجغرافي المكاني والصور الفضائية (GeoAI- EO)، وتحليل بيانات الصور الفضائية باستخدام الذكاء الصناعي عبر التعليم العميق باستخدام اللوغارتميات وبرامج الشبكة العصبية بأنواعها المختلفة وتطبيقاتها على الزراعة في اليمن، من خلال مراجعة الدراسات والأبحاث السابقة المنشورة. وقد خلصت الدراسة إلى أن تقنيات (GeoAI- EO) هي تقنية واعدة، لديها القدرة على إحداث ثورة في الزراعة. ومن خلال استخدام البيانات المكانية وخوارزميات الذكاء الاصطناعي، يمكن لـ (GeoAI- EO) مساعدة المزارعين على تحسين غلات المحاصيل، وتقليل النفايات، والحفاظ على الموارد. لا يزال البحث حول تطبيق (GeoAI- EO) في الزراعة في مراحله الأولى، لكن النتائج حتى الآن واعدة. مع استمرار تطور التكنولوجيا، من المرجح أن يلعب (GeoAI- EO) دوراً متزايد الأهمية في مستقبل الزراعة.

الكلمات المفتاحية: الذكاء الاصطناعي الجغرافي المكاني، التصوير الفضائي، القطاع الزراعي، الأنظمة الذكية، الزراعة الدقيقة.

DOI:

<https://doi.org/10.59421/joeats.v2i1.1896>



THIS WORK IS LICENSED UNDER A

CREATIVE COMMONS ATTRIBUTION 4.0

INTERNATIONAL LICENSE

المقدمة:

يعد الذكاء الاصطناعي الجغرافي المكاني (GeoAI) والتصوير الفضائي EO من التقنيات الناشئة بسرعة، التي لديها القدرة على إحداث ثورة في الزراعة في اليمن. ويمكن استخدام هذه التقنيات لجمع وتحليل البيانات حول الأرض والمحاصيل والطقس، والتي يمكن استخدامها بعد ذلك لتحسين الإنتاجية الزراعية والكفاءة والاستدامة. إن الذكاء الاصطناعي الجغرافي (GeoAI) هو مجال الذكاء الاصطناعي (AI) الذي يستخدم نظم المعلومات الجغرافية (GIS) لتحليل وتفسير البيانات المكانية. كما أن حلول الذكاء الاصطناعي التي تستخدم عمليات رصد الأرض عبر الأقمار الصناعية (EOs)، والتي تسمى: EO-AI، متاحة بشكل أكبر على المدى القريب (Almhab(2018). لغرض هذا البحث نستخدم المصطلح (GeoAI-EO) والذي يعني: الذكاء الاصطناعي الجغرافي المكاني (GeoAI) والتصوير الفضائي EO وتحليلاتها المعتمدة على الذكاء الاصطناعي EO-AI.

إن التكيف مع تغير المناخ والتخفيف من آثاره ومعالجة انعدام الأمن الغذائي، تعد من الأولويات القصوى في الدول النامية وفي اليمن، والتي تتطلب تقنيات لتحسين سبل العيش الريفية بأقل التكاليف البيئية (المهاب، 2022، ب، ج) (Sasson 2012). إن الذكاء الاصطناعي يقدم مجالاً كبيراً للحلول الذكية المناخية التي تعمل على تحسين نتائج الأمن الغذائي. في حين أن الزراعة الدقيقة Precision agriculture غالباً ما تكون أهم حالة استخدام للذكاء الاصطناعي في الزراعة، (على سبيل المثال، أتمتة المعدات الزراعية أو استخدام المغذيات)، فإن الزراعة الدقيقة بعيدة عن متناول معظم المزارعين اليمنيين بسبب رأس المال والبنية التحتية المطلوبة. لقد أصبحت حلول الذكاء الاصطناعي التي تستخدم عمليات رصد الأرض عبر الأقمار الصناعية (EOs Earth Observations)، والتي نسميها GeoAI-EO متاحة بشكل أكبر على المدى القريب (Almhab(2018). يتيح GeoAI-EO إجراء التحليلات والرؤى الزراعية على المستوى العالمي والإقليمي والمحلي، والعديد من مجموعات البيانات متاحة مجاناً؛ مما يجعل الحلول المستندة إلى SEO ميسورة التكلفة (Nakalembe et al (2021). تعد المنتجات المشتقة من GeoAI-EO، مثل خرائط أنواع المحاصيل وتقديرات الإنتاجية، ضرورية للتنبؤ بفائض أو عجز إنتاج الغذاء، وتوجيه قرارات التجارة والمساعدات (المهاب، 2022، أ، ب، ج). يمكن لهذه المنتجات أن تدعم السياسات التي تعمل على تسريع تصميم واعتماد الزراعة الذكية مناخياً والتأثير على سبل عيش المزارعين من خلال زيادة الوصول إلى الإنذار المبكر القابل للتنفيذ، أو تمويل المخاطر أو التأمين المهاب(2020) (Benami et al, (2021)، والمدخلات الزراعية، والأسواق، وتدخلات خفض التكاليف (Nakalembe et al., 2021) و (Nakalembe, 2020). على الرغم من أن حلول GeoAI-EO واعدة للزراعة في اليمن، إلا أنها لا تزال محدودة. كما أن معظم التقنيات غير قابلة للتعميم؛ نظر لاختلاف الطبوغرافية اليمنية والمناظر الطبيعية غير المتجانسة.

في هذه الورقة، تم عمل استعراض لبعض المجالات الرئيسية وبعض المحاولات التطبيقية لاستخدامات GeoAI-EO على الزراعة في اليمن، حيث تم مناقشة بعض الأمثلة التي تم تطبيقها وتم نشر تلك التطبيقات في مقالات علمية، إضافة إلى استعراض المعوقات والقيود التي تحد من إنجاز العمل الحالي. كما يقدم البحث بعض المقترحات التي تسهل العمل المستقبلي وتساعد في زيادة تأثير أبحاث GeoAI-EO في اليمن.

علاقة الذكاء الصناعي والتعلم الآلي في برامج نظم المعلومات الجغرافية و ArcGIS

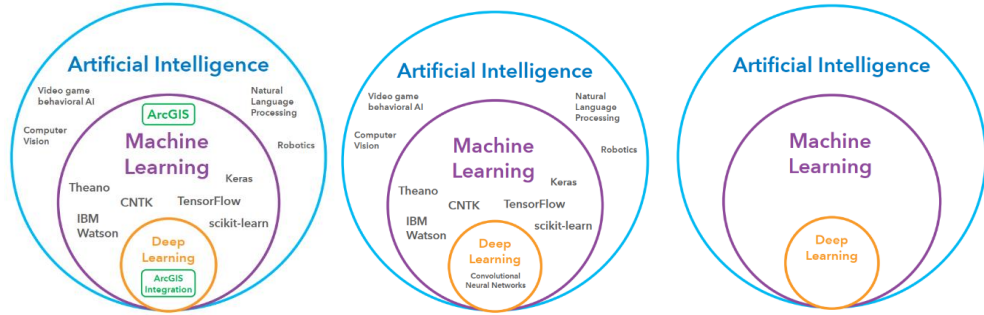
لقد أصبحت نظم المعلومات الجغرافية (Geographic Information System (GIS) ذات أهمية متزايدة في مجالات مختلفة، مثل: التخطيط الحضري، وإدارة البيئة، والنقل، والزراعة.

كون نظم المعلومات الجغرافية تسمح بجمع البيانات المكانية وتحليلها وتصورها، مما يمكن صناع القرار من اتخاذ قرارات مستنيرة؛ بناءً على الأنماط والعلاقات المكانية. ومع ذلك، مع استمرار نمو كمية البيانات المكانية بشكل كبير، تواجه أساليب نظم المعلومات الجغرافية التقليدية تحديات في التعامل مع مجموعات البيانات الكبيرة هذه وتحليلها.

يعد الذكاء الاصطناعي (Artificial intelligence (AI)، والتعلم الآلي (Machine Learning (ML)، والتعلم العميق (Deep Learning (DL) من التقنيات الناشئة التي أظهرت إمكانات كبيرة في تحسين نظم المعلومات الجغرافية. يتضمن الذكاء الاصطناعي تطوير آلات ذكية يمكنها أداء المهام التي تتطلب عادةً ذكاءً بشريًا، بينما يركز تعلم الآلة على تطوير الخوارزميات التي تمكن الآلات من التعلم من البيانات DL. هو حقل فرعي من ML يستخدم الشبكات العصبية لمعالجة مجموعات البيانات الكبيرة والمعقدة Nakalembe& Kerner(2023).

إن تكامل نظم المعلومات الجغرافية GIS مع الذكاء الاصطناعي AI والتعلم الآلي ML والتعلم عن بعد. يغطي مجموعة واسعة من المواضيع، بما في ذلك تصنيف الصور، واكتشاف الأشياء، ورسم خرائط الغطاء الأرضي، والتنبؤ بالنمو الحضري. تتمثل المساهمة الرئيسية في تطوير طرق جديدة لمعالجة وتحليل مجموعات البيانات المكانية الكبيرة. وقد أظهرت هذه الطرق إمكانات كبيرة في تحسين دقة وكفاءة هذه المهام مقارنة بطرق نظم المعلومات الجغرافية التقليدية.

الشكل 1 الآتي: يوضح طرق تقسيم الذكاء الصناعي والتعلم الآلي في برنامج ArcGIS. (ESRI, 2023).



شكل 1: طرق تقسيم الذكاء الصناعي والتعلم الآلي في برنامج ArcGIS. (ESRI, 2023).

مشكلة البحث:

تتلخص مشكلة البحث في: ضرورة إدخال تقنيات GeoAI-EO في القطاع الزراعي: بهدف التغلب على المشاكل المستعصية التي تواجه القطاع المتمثلة في ضعف الإنتاجية لوحدة المساحة بسبب شحة المياه، وضعف التسميد، وتأثير الآفات والأمراض النباتية، وتكلفة الأيدي العاملة، وصغر الحيازات، بالإضافة إلى مشاكل التغيرات المناخية.

أهمية البحث:

تكمن أهمية البحث في المساهمة في إيجاد حلول لمعالجة المشاكل المستعصية التي تحد من زيادة الإنتاج الزراعي في اليمن؛ ولاستشراف الثورة التكنولوجية القادمة المتمثلة في استخدام GeoAI-EO في جميع جوانب الحياة وخاصة القطاع الزراعي.

أبرز المصطلحات:

الذكاء الاصطناعي: (AI) يعد أحد التقنيات التي يمكن أن تحدث ثورة في التعليم الزراعي. يمكن استخدام AI لتوفير تجارب تعليمية أكثر تخصيصًا وتفاعلية للطلاب، وتحسين كفاءة التعليم، ومساعدة الطلاب على تعلم المزيد. ويرتبط الذكاء الصناعي ارتباطًا وثيقًا بالتحول الرقمي.

الذكاء الاصطناعي: هو مجال من علوم الكمبيوتر يركز على تطوير أجهزة الكمبيوتر التي يمكنها التفكير والتصرف مثل

البشر.

الذكاء الاصطناعي الجغرافي: (GeoAI) هو مجال الذكاء الاصطناعي (AI) الذي يستخدم نظم المعلومات الجغرافية (GIS) لتحليل وتفسير البيانات المكانية. الذكاء الاصطناعي التي تستخدم عمليات رصد الأرض عبر الأقمار الصناعية (EOS)، والتي نسّمها AI-EO. ولغرض هذا البحث نستخدم المصطلح (GeoAI-EO) والذي يدمج المصطلحين (الذكاء الاصطناعي الجغرافي المكاني والتصوير الفضائي).

منهجية البحث:

تم استخدام المنهج الوصفي التحليلي، من خلال استعراض مجموعة متنوعة من المصادر والبحوث والدراسات والكتب والتقارير الفنية والتجارب التي تم الحصول عليها حول دور GeoAI-EO في تنمية القطاع الزراعي.

النتائج والمؤشرات:

1- المؤشرات العامة:

وجد من مراجعة الأدبيات أن هناك مجموعة متزايدة من الأبحاث حول تطبيق GeoAI-EO في الزراعة. أظهرت الدراسات التي تمت مراجعتها: أن GeoAI-EO لديه القدرة على تحسين غلات المحاصيل، وتقليل النفايات، والحفاظ على الموارد، وتحسين عملية صنع القرار في الزراعة. ومع ذلك، لا يزال البحث في مراحله الأولى، وهناك عدد من التحديات التي يجب معالجتها قبل أن يتم اعتماد GeoAI-EO على نطاق واسع في الزراعة. إن استخدام GeoAI-EO في الزراعة لديه القدرة على تحقيق عدد من الفوائد الهامة، بما في ذلك: زيادة غلة المحاصيل، تقليل النفايات، المحافظة على الموارد، تحسين عملية صنع القرار، تعزيز الاستدامة. بالإضافة إلى: رسم خريطة ومراقبة استخدام الأراضي والتغيرات في الغطاء الأرضي، وتقييم جودة التربة ومستويات المغذيات، وتتبع غلات المحاصيل واتجاهات الإنتاج، وتحديد الآفات والأمراض المحتملة، والتنبؤ بأنماط الطقس وتأثيرات تغير المناخ وغيرها. شكل 2 الآتي: يلخص بعض المتغيرات الزراعية التي يتم رصدها بواسطة الذكاء الصناعي الجغرافي المكاني والصور الفضائية GeoAI-EO. ويمكن لهذه التطبيقات أن تساعد المزارعين على اتخاذ قرارات أفضل بشأن أراضيهم ومحاصيلهم ومواردهم المائية. وهذا يمكن أن يؤدي إلى تحسين الإنتاجية والكفاءة واستخدام الممارسات الزراعية.



شكل 2: بعض المتغيرات الزراعية التي يتم رصدها بواسطة GeoAI-EO (المهاب، 2022، ج)

2- التطبيقات العملية لل GeoAI-EO الرئيسية المنفذة على اليمن

في هذا القسم من المؤشرات والنتائج، تم استعراض أهم تطبيقات GeoAI-EO على الزراعة في اليمن، من خلال استعراض الأوراق المنشورة وخاصة تلك التي تم استخدام تقنيات الاستشعار عن بعد ونظم المعلومات الجغرافية واللوغاريتميات والشبكات العصبية والنماذج الرياضية وأنظمة تدعيم القرار لاستخراج الخرائط الغرضية، بالإضافة إلى التعرف على أهم الفرص والقيود أو المعوقات الحالية التي يجب معالجتها في العمل المستقبلي لتطوير تقنيات GeoAI-EO في اليمن.

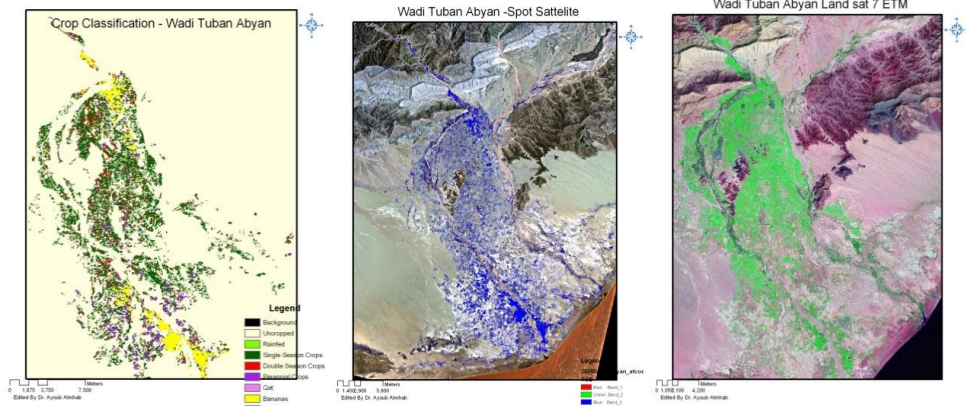
2.1. دور الذكاء الاصطناعي الجغرافي المكاني والصور الفضائية GeoAI-EO في رسم خرائط أنواع

المحاصيل والأراضي الزراعية:

تشير خرائط الأراضي الزراعية إلى الأماكن التي تنمو فيها المحاصيل مكانيا (الشكل 3)، في حين تشير خرائط أنواع المحاصيل إلى نمو المحصول المحدد في كل وحدة مكانية (مثل الذرة). في نمذجة الإنتاج أو الظروف المستندة إلى التصوير الفضائي، تكون هذه الخرائط مطلوبة لتقييد التحليل بوحدة البكسل التي تتضمن الأراضي الزراعية أو نوع محصول محدد. يجب تحديث خرائط أنواع المحاصيل موسميًا؛ لأن المزارعين قد يغيرون المحاصيل المزروعة في حقل معين (Nakalembe et al. (2021). يتضمن رسم خرائط الأراضي الزراعية تصنيف الوحدات المكانية، (مثل وحدات البكسل ذات الدقة المكانية المحددة) على أنها تحتوي على أراضي زراعية. عادةً ما يتم تأطير تعيين نوع المحاصيل كتصنيف متعدد الفئات، ولكن يمكن تأطيره في تصنيف ثنائي حيث تكون الفئة الإيجابية هي نوع المحصول محل الاهتمام، وتتضمن الفئة السلبية جميع أنواع المحاصيل الأخرى والفئات غير المحصولية. تعتمد الدقة المكانية للخريطة الناتجة على مدخلات بيانات القمر الصناعي.

معظم نماذج التعلم الآلي المستخدمة لتصنيف الأراضي الزراعية وأنواع المحاصيل: عبارة عن مصنفات قائمة على الأشجار المزروعة، مثل: أشجار مستديمة الخضرة أو الغابات العشوائية. لقد اكتسبت أساليب التعلم العميق DL - وخاصة الشبكات العصبية المتكررة Recurrent neural networks التي تتعلم أنماط نمو مهمة خاصة بالمحاصيل في بيانات السلاسل الزمنية- شعبية في السنوات الأخيرة، وهي أحدث ما توصلت إليه التكنولوجيا (Zanaga et al. (2021). في حين أن دقة خرائط الأراضي الزراعية العامة مرتفعة بشكل عام في المناطق الزراعية للدول المتقدمة، بينما نجد من خلال مراجعة الدراسات السابقة والتي أظهرت أن الدقة (Resolution) أقل بكثير في اليمن، وأحسن دقة كانت باستخدام القمر الصناعي لاندسات وسبوت (2015) Waterwach report. وجدت أن دقة المستخدم كانت منخفضة تصل إلى 17٪ في اليمن (على سبيل المثال، الشكل 3). ويرجع ذلك جزئيًا إلى: أن المزارع في اليمن هي في الغالب مزارع لأصحاب الحيازات الصغيرة والتي قد يكون من الصعب اكتشافها بدقة بدون مجموعات بيانات ساتلية عالية الدقة (والتي ليست متاحة مجانًا). كما أن هناك عامل مقيد آخر، وهو عدم وجود مجموعات بيانات زراعية متاحة للجمهور. في حين اقترحت بعض الأعمال الحديثة طرقًا لتحسين نتائج تصنيف أنواع المحاصيل باستخدام بيانات مصنفة محدودة باستخدام التصنيف الموجه (المهاب، 2020)، فإن معظم الأعمال السابقة التي قامت بها بعض الشركات (ITC، 2004)، (Waterwatch 2015)، (WAPOR، 2017) وغيرها، تعتمد على مجموعات بيانات كبيرة مصنفة غير متوفرة حاليًا لليمن. حتى لو كان من الممكن تدريب النموذج بكفاءة باستخدام عدد صغير من العينات الموسومة، فإن التقييم القوي لخريطة نوع المحصول الناتج (والتي تتضمن استدلالًا كثيفًا على المنطقة بأكملها) لا يزال يتطلب العديد من التسميات. في حين أنه يمكن عادةً وضع تعليقات توضيحية على تسميات الغطاء الأرضي (بما في ذلك الأراضي الزراعية)، باستخدام تفسير الصور لصور الأقمار الصناعية عالية الدقة، إلا أنه يجب تحديد نوع المحصول من خلال المراقبة الحقيقية الأرضية.

كما أن الزراعة البيئية تعتبر ممارسة شائعة في اليمن، وتمثل تحديًا إضافيًا لطرق GeoAI-EO. في حين أنه من الممكن التعرف فعليًا على محاصيل متعددة تنمو في الحقل من خلال المراقبة في الموقع، إلا أنه من الصعب تصنيفها في نفس موقع البكسل في بيانات الأقمار الصناعية. عادةً ما تتعامل الطرق الحالية مع الحقول المزروعة ضمانيًا كفتحة مجمعة واحدة، أو تستخدم الاسم الخاص بالمحصول المفترض أنه المحصول السائد.

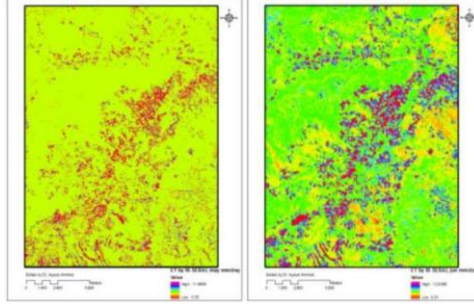


الشكل 3: (أ) الخريطة الطبيعية القمر الصناعي لاندسات 7 لمنطقة وادي بنا - أبين (ب) القمر الصناعي سبوت. (ج) تصنيف المحاصيل من صور لاندسات 7 لمنطقة وادي بنا - أبين (Waterwatch, 2015)

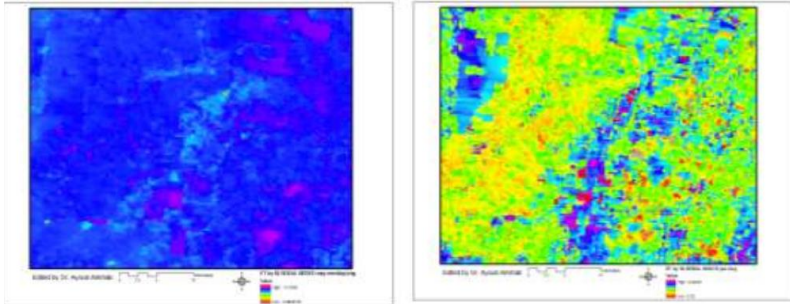
2,2- تطبيقات GeoAI-EOs في تقدير التبخر نتح والاحتياجات المائية للمحاصيل:

- يساعد الذكاء الاصطناعي الجغرافي المكاني والصور الفضائية في تقدير التبخر نتح والاحتياجات المائية للمحاصيل من خلال:
- تحديد الغطاء النباتي: يمكن استخدام الصور الفضائية لتحديد أنواع النباتات والمحاصيل الموجودة في منطقة معينة. يساعد هذا في تقدير المعدل الأساسي للتبخر نتح، وهو مقدار الماء الذي يتبخر من سطح الأرض في ظل ظروف معينة.
 - تقدير درجة الحرارة والرطوبة: يمكن استخدام الصور الفضائية لتقدير درجة الحرارة والرطوبة في منطقة معينة. تساعد هذه البيانات في تقدير معدل التبخر نتح الفعلي، وهو مقدار الماء الذي يتبخر من سطح الأرض في ظل الظروف الفعلية.
 - تحديد الاحتياجات المائية للمحاصيل: يمكن استخدام البيانات من مصادر مختلفة، بما في ذلك الصور الفضائية والبيانات الميدانية، لتقدير الاحتياجات المائية للمحاصيل. تساعد هذه البيانات في تحديد مقدار المياه الذي يحتاجه المحصول للبقاء على قيد الحياة والنمو بشكل صحي.
- يمكن أن تساعد هذه التقنيات في: تحسين كفاءة استخدام المياه في الزراعة. يمكن أن يساعد ذلك في: تقليل تكلفة الري وتحسين الإنتاجية الزراعية. فيما يلي بعض الأمثلة على تطبيقات الذكاء الاصطناعي الجغرافي المكاني والصور الفضائية في تقدير التبخر نتح والاحتياجات المائية للمحاصيل:
- نظام مراقبة التبخر نتح: يمكن استخدام الذكاء الاصطناعي الجغرافي المكاني لإنشاء نظام مراقبة التبخر نتح. يمكن أن يساعد هذا النظام في مراقبة التبخر نتح في منطقة معينة على مدار الوقت.
 - نظام توصيات الري: يمكن استخدام الذكاء الاصطناعي الجغرافي المكاني لإنشاء نظام توصيات الري. يمكن أن يساعد هذا النظام المزارعين في تحديد مقدار المياه التي يحتاجونها لري محاصيلهم.
 - نظام إدارة المياه الزراعية: يمكن استخدام الذكاء الاصطناعي الجغرافي المكاني لإنشاء نظام إدارة المياه الزراعية. يمكن أن يساعد هذا النظام في إدارة موارد المياه الزراعية بشكل أكثر فعالية.

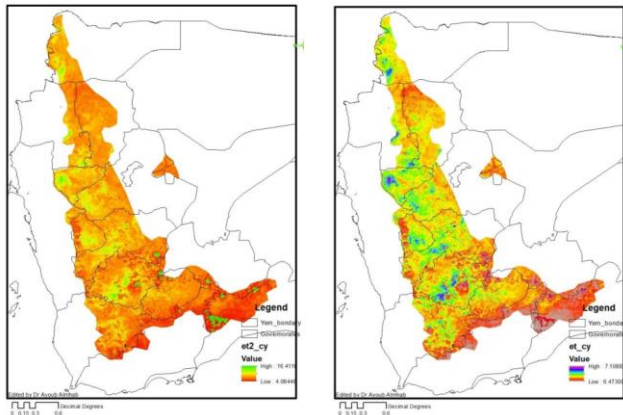
تستمر الأبحاث في مجال الذكاء الاصطناعي الجغرافي المكاني والصور الفضائية في تقدير التبخر نتح والاحتياجات المائية للمحاصيل، ومن المتوقع أن تؤدي هذه التطورات إلى تحسين دقة وكفاءة هذه التقنيات. شكل 4: نموذج من مخرجات تطبيق نموذج لوجاريتمية معادلة موازنة طاقة التربة على الأرض المحدثة M-SEBAL لتقدير التبخر نتح في منطقة حوض عمران - اليمن باستخدام صور القمر الصناعي لاندسات ETM. والشكل 5: باستخدام نموذج M-SEBA وصور القمر الصناعي MODIS (Almhab 2011). والشكل 6: استخدام M-SEBAL لتقدير التبخر نتح في مناطق زراعة البن في اليمن (المهاب، 2022).



الشكل 4 أ، ب: تقدير ET اليومي بواسطة نموذج M-SEBAL في حوض عمران، 15 مايو و 1 يونيو 2009 منصور ETM (Almhab, 2011).




الشكل 5 أ، ب: تقدير يومي لتوقيت ET بواسطة نموذج M-SEBAL في حوض عمران، 16 مايو و 7 يونيو 2009 من صورة MODIS (Almhab, 2011)



الشكل 6: الاحتياجات المائية أ. التبخر نتح المحصولي. ب. التبخر نتح الحقيقي لمناطق زراعة البن ملم/يوم (المهاب، 2022)

3.2. دور GeoAI-EO في تقدير العائد أو الغلة

إن النماذج القادرة على دعم استراتيجيات زيادة الغلة ضرورية للزراعة الذكية مناخياً في اليمن، حيث كانت الزيادات في إنتاج المحاصيل مدفوعة إلى حد كبير بالزيادات في المساحات المزروعة، وليس الغلة. تقدير المحصول هو مهمة تراجمية، حيث تقوم النماذج بتقدير المحصول المحصود لكل وحدة مساحة (على سبيل المثال: كجم لكل هكتار). يتم إجراء معظم أعمال تقدير الإنتاجية على المستوى المحلي أو الوطني، مع عمل أقل على المستوى الميداني (Nakalembe & Kerner, 2023). يمكن أيضاً تقييم طرق تقدير العائد من خلال مدى إمكانية التنبؤ الدقيق بعائد نهاية الموسم في موسم النمو. تستخدم معظم أساليب التعلم الآلي لتقدير العائد الأساليب المستندة إلى العديد من حلول التعلم العميق (deep learning)، بما في ذلك العمليات الغوسية العميقة (Deep Gaussian Processes)، والشبكات العصبية الرسومية (Graph Neural Networks)، والشبكات العصبية المتكررة (Recurrent Neural Networks). وتستفيد الأساليب الأخرى من محاكاة المحاصيل ونماذج الانحدار الإحصائي. ومع ذلك، فقد ركزت دراسات قليلة على تقدير الإنتاجية مثل: (Van et al. (2022)، Jin, et al (2019)، وخاصة تقدير الإنتاجية في بعض مناطق من اليمن (تهامة) شكل 7: (Almhab, 2014). كما يمكن أن يلعب الذكاء الاصطناعي الجغرافي المكاني والصور الفضائية GeoAI-EO دوراً مهماً في تقدير العائد أو الغلة. حيث يمكن استخدام هذه التقنيات لجمع بيانات دقيقة ومحدثة حول مجموعة متنوعة من العوامل التي يمكن أن تؤثر على العائد أو الغلة، مثل: كثافة الغطاء الخضري، ومعدل التمثيل الضوئي كفاءة استخدام الضوء، ونمو الكتلة الحيوية، شكل 7.



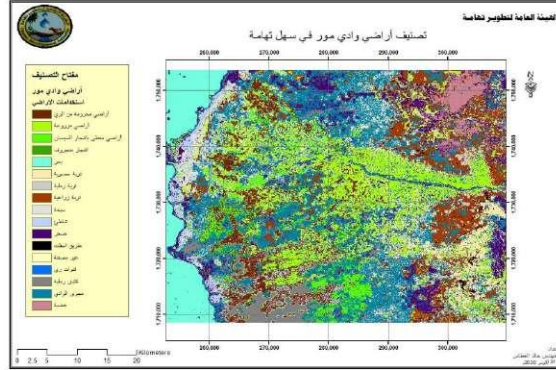
الشكل 7: التباين المكاني لمختلف عوامل نمو المحاصيل في منطقة تهامة اليمن. (أ) PAR، (ب) NDVI، (ج) APAR، (د) الجزء المتبخر، (هـ) كفاءة استخدام الضوء، (و) نمو الكتلة الحيوية (Almhab, 2014)

4.2. ترسيم حدود الحقول

ترسيم حدود الحقول وتقدير المساحة وطرق أخذ العينات لتوفير تقديرات سليمة إحصائية للمساحة المزروعة، وتكون مفيدة للتقييمات الميدانية الفرعية للمدخلات وأداء المحاصيل والإنتاج (Masoul, et al. (2019). استخدمت بعض الدراسات طرق تجزئة المثيلات من رؤية الكمبيوتر، مثل Mask R-CNN (Meyer et al. (2020)، لكن أحدث الأعمال استخدمت طرق التجزئة الدلالية، مثل U-Nets متبوعة بالمعالجة اللاحقة لعزل الحالات الميدانية الفردية Wang et al. (2022). يتمثل أحد العوائق الرئيسية أمام ترسيم الحدود الميدانية في اليمن في عدم كفاية الدقة المكانية لمجموعات البيانات الساتلية المتاحة للجمهور. غالباً ما تكون حقول أصحاب الحيازات الصغيرة أصغر من 1 هكتار (100 م × 100 م)، وبالتالي، يتطلب ترسيم الحدود مجموعات بيانات عالية الدقة متاحة حالياً تجارياً فقط (المهاب، 2022). ويتمثل التحدي الآخر في: أن القليل من مجموعات البيانات العامة توفر تسميات حدود الحقول في اليمن. اقترح بعض البحوث حلولاً

تستخدم التعلم النشط (Estes etal. (2022)، والجمع بين نقل التعلم والإشراف الضعيف (Wang etal. 2022). الشكل 8:

مثال تصنيف الأراضي الزراعية نهاية وادي مور - تهامة - اليمن الععاس(2020).



الشكل 8: مثال تصنيف الأراضي الزراعية نهاية وادي مور - تهامة - اليمن (الععاس، 2020)

5.2. دور GeoAI-EO في تقدير رطوبة التربة

هناك العديد من الطرق التي يمكن استخدامها لتقدير رطوبة التربة باستخدام GeoAI-EO، تتضمن بعض الأساليب الشائعة

ما يأتي:

- استشعار الرادار: يمكن استخدام الرادار لقياس مدى امتصاص الماء بواسطة التربة. يمكن استخدام هذه البيانات لإنشاء خرائط رطوبة التربة.
- استشعار الأشعة تحت الحمراء: يمكن استخدام الأشعة تحت الحمراء لقياس درجة حرارة التربة. يمكن استخدام هذه البيانات لتقدير رطوبة التربة باستخدام معادلات محددة.
- المسح الثنائي الطيفي: يمكن استخدام المسح الثنائي الطيفي لقياس انعكاس الضوء من التربة. يمكن استخدام هذه البيانات لإنشاء نماذج تنبؤية لرطوبة التربة.

يمكن أن يكون GeoAI-EO دوراً مهماً في تقدير رطوبة التربة. يمكن استخدام هذه التقنيات لجمع بيانات دقيقة ومحدثة حول

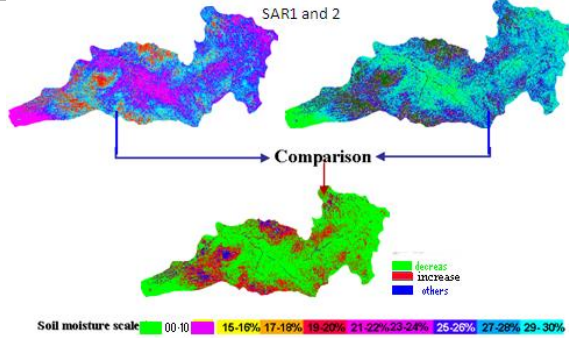
رطوبة التربة من مساحات شاسعة من الأرض. يمكن استخدام هذه البيانات لتحسين فهمنا لعمليات الرطوبة في التربة وتطوير نماذج تنبؤية أكثر دقة.

يمكن أن يلعب GeoAI-EO دوراً مهماً في تقدير رطوبة التربة. يمكن استخدام هذه التقنيات لجمع بيانات دقيقة ومحدثة حول

رطوبة التربة من مساحات شاسعة من الأرض. يمكن استخدام هذه البيانات لتحسين فهمنا لعمليات الرطوبة في التربة وتطوير نماذج تنبؤية أكثر دقة.

الشكل 9 التالي يوضح: أ) محتوى رطوبة التربة الحجمي %Mv في أكتوبر، ب) %Mv في نوفمبر و ج) والتغير بين أكتوبر ونوفمبر

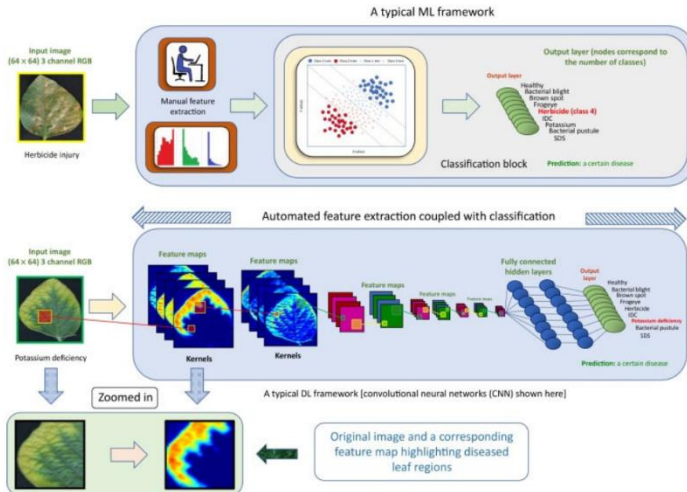
لمسقط مياه وادي سهام اليمن (Almhab, 2016)



الشكل 9: (أ) محتوى رطوبة التربة الحجي Mv في أكتوبر، (ب) Mv في نوفمبر، (ج) والتغير بين أكتوبر ونوفمبر لمسقط مياه وادي سهام اليمن (Almhab, 2016)

كشف الآفات والأمراض:

وجد هناك بعض الأبحاث حول الكشف عن الآفات/الأمراض، باستخدام بيانات صور الأقمار الصناعية، ولكن معظم الدراسات تستخدم مجموعات بيانات عالية الدقة غير متاحة للعامّة أو عالمياً ولا تستفيد من تقنيات الذكاء الاصطناعي الحديثة. يمكن أن تكون التقنيات التي تستفيد من GeoAI-EO مفيدة للكشف عن تأثيرات الآفات والأمراض على مساحات واسعة خلال موسم النمو لتقليل تلف المحاصيل. ويمكن لهذه الأساليب أيضاً اكتشاف حالات شاذة أخرى في الحقل، مثل نقص المغذيات أو الأعشاب الضارة. ومع ذلك، استخدمت القليل من الدراسات GeoAI-EO للكشف عن الحالات الشاذة في مناطق واسعة، ويرجع ذلك جزئياً إلى محدودية الوصول إلى مجموعات بيانات الأقمار الصناعية عالية الدقة والمؤشرات الحقيقية الميدانية اللازمة لتدريب نماذج الذكاء الاصطناعي وتقييمها (Gold (2021). تركز تقنيات الذكاء الاصطناعي الحالية لمراقبة أمراض المحاصيل في الغالب على تشخيص أمراض النبات في الموقع باستخدام صور الهاتف الخليوي أو الروبوتات الأرضية (Mrisho et al. (2020). على سبيل المثال (Alam et al. (2020): استخدام خوارزمية تعتمد على التعلم العميق لاستخراج الميزات المرئية للتمييز بين الأوراق المريضة والأوراق السليمة، كما هو موضح في الشكل 10 الآتي.



شكل 10: التعرف على أوراق النباتات المريضة باستخدام تقنية CNN (Alam et al., 2020)

7.2. هناك العديد من الأوراق العلمية المنشورة الأخرى، يمكن تلخيصها فيما يلي:

- دور GeoAI-EO في تحديد أماكن الواحات الصحراوية في اليمن (Almhah & Busu, 2008).
- دور GeoAI-EO في رسم خرائط الغطاء الأرضي وتحديد التغير وتحسين إدارة المساقط المائية وتنمية المجتمعات الريفية المهاب (2022ب).
- دور GeoAI-EO في تحديد الأماكن الكامنة للتغذية الجوفية (Almhah, 2010).
- دور GeoAI-EO في تحديد الأماكن المناسبة لبناء السدود (Almhah, 2018).
- دور GeoAI-EO في تحديد الأماكن الملائمة لزراعة البن اليمني عالي الجودة المهاب (2022أ).
- دور GeoAI-EO في تحسين إدارة الموارد المائية وتقدير الموازنة المائية للمستجمعات المائية في اليمن (Almhah, 2010).
- دور GeoAI-EO في تحسين إدارة الموارد المائية وتقدير الموازنة المائية للمستجمعات المائية في اليمن (المهbab, 2020ب).
- دور GeoAI-EO في تحديد المناطق الزراعية AEZ في اليمن (Almhah, 2017).

الفوائد المحتملة لاستخدام GeoAI-EO:

- تحسين دقة وكفاءة عملية اختيار المواقع قيد الدراسة.
- توفير التكلفة والوقت.
- انخفاض التأثير البيئي.

التحديات المحتملة لاستخدام GeoAI-EO:

- ارتفاع تكلفة التكنولوجيا وكذا التكلفة العالية لتقنية GeoAI-EO.
- الحاجة إلى بيانات عالية الجودة وبيانات موحدة.
- الحاجة إلى الخبرة في الذكاء الاصطناعي وأنظمة دعم القرار، وتدريب الكوادر.
- الحاجة إلى مزيد من البحوث.
- وهناك أيضاً بعض التحديات التي تواجه اعتماد تقنية GeoAI والتصوير الفضائي في الزراعة في اليمن. وتشمل هذه التحديات ما يلي:
- عدم وجود العمالة الماهرة لتشغيل وصيانة هذه التقنيات.
- عدم القدرة على الوصول إلى الإنترنت الموثوق واتصال البيانات.
- وعلى الرغم من هذه التحديات، فإن الفوائد المحتملة لـ GeoAI-EO للزراعة في اليمن كبيرة. ومع استمرار تطور هذه التقنيات قد تصبح ميسورة التكلفة، ويمكن الوصول إليها، فمن المرجح أن تلعب دوراً متزايد الأهمية في مساعدة المزارعين اليمنيين على تحسين سبل عيشهم.

الاستنتاجات والمقترحات:

مما سبق نستنتج: أن GeoAI-EO هي تقنية واعدة، تستخدم الصور الفضائية ونظم المعلومات الجغرافية والذكاء الصناعي، ولديها القدرة على إحداث ثورة في الزراعة. كما تم استنتاج: أنه باستخدام البيانات المكانية وخوارزميات الذكاء الصناعي AI، يمكن لـ GeoAI-EO مساعدة المزارعين على تحسين إنتاجية المحاصيل، والحد من الهدر، والحفاظ على الموارد، والتغلب على العديد من المشاكل التي تواجه المزارعين وخاصة في اليمن التي تعاني من شحة في التساقطات المطرية وعدم انتظامها، إضافة إلى آثار التغيرات المناخية من: زيادة درجة الحرارة، وانتشار بعض الآفات الزراعية، وتدهور الموارد الأرضية، وزيادة مساحة الأراضي المتصحرة سنوياً.

من خلال استعراض المؤشرات السابقة، نجد: أن البحث في مجال تطبيق GeoAI-EO في الزراعة في اليمن قد بدأ وبخطوات جيدة، وكانت النتائج حتى الآن واعدة، إلا أنه لا يزال في مراحله الأساسية، بينما يتطور بسرعة رهيبية في الدول المتقدمة والنامية، وستكون الفجوة كبيرة جدا في المستقبل القريب إذا لم يتم وضع القواعد والأسس اللازمة للحاق بركب التطور بصورة سريعة على الأقل من الجوانب الأكاديمية. إضافة إلى أنه -ومع استمرار تطوير التكنولوجيا- من المرجح: أن يلعب GeoAI-EO دورًا متزايد الأهمية في مستقبل الزراعة وتوفير الغذاء ومكافحة الجوع على مستوى العالم.

كما أن استخدام GeoAI-EO في الزراعة يعد مجالًا بحثيًا واعدًا مع إمكانية تحقيق فوائد كبيرة في اليمن، وخاصة مع توفر الصور الفضائية المجانية وتطور التقنيات والمتحسسات الحديثة، ووجود العديد من الباحثين المؤهلين.

إلا أن هناك العديد من التحديات والعقبات التي يجب معالجتها والتغلب عليها؛ حتى يتم اعتماد GeoAI-EO على نطاق واسع في الزراعة في اليمن، لعل أهمها: توسيع خدمات الكهرباء وشبكات الاتصالات والإنترنت، وتقوية مراكز البحوث والكلية والمؤسسات بالتقنيات والبرامج الحديثة، وعمل الدورات التدريبية والتأهيلية اللازمة لتوطين التقنية.

ومما سبق، يجب التأكيد على عدة مقترحات، ينبغي دمجها في العمل المستقبلي لزيادة التأثير الإيجابي لأبحاث GeoAI-EO في اليمن، هي:

- (1) التأكيد على أن تطوير أساليب الذكاء الاصطناعي GeoAI-EO القوية والعملية وذات الصلة بالسياق في الزراعة في اليمن، يتطلب فرقًا متعددة التخصصات، بما في ذلك خبراء في الذكاء الاصطناعي، والزراعة/الهندسة الزراعية، والاستشعار عن بعد، وعلوم المناخ، وعلوم التربة، والممارسات المحلية والإقليمية.
- (2) يجب مراعاة سياق موارد أصحاب المصلحة المقصودين، (مثل: التكلفة أو الطاقة أو النطاق الترددي للإنترنت) في جميع مراحل عملية البحث، بما في ذلك اختيار/تصميم الخوارزمية ونشر النتائج. تحديد أولويات البحث حول أساليب EO-GeoAI التي تعمل على تحسين الأداء باستخدام البيانات المصنفة المحدودة أمرًا ضروريًا لمعالجة عدم توفر البيانات المصنفة للزراعة في اليمن. يجب على المجتمع أيضًا إعطاء الأولوية لمزيد من الجهود على مستوى المجتمع لإنشاء مجموعات بيانات مصنفة متاحة للجمهور للزراعة في اليمن.
- (3) هناك حاجة لمزيد من التوثيق المناسب والأساليب المفتوحة مع التفاصيل الكافية التي تمكن الباحثين من تتبع وتكرار العمل السابق ومقارنة الأساليب لتتبع التقدم المحرز في هذا المجال مباشرة.
- (4) ينبغي استشارة أصحاب المصلحة والمستخدمين النهائيين في وقت مبكر من البحث والتطوير لضمان عمل الباحثين على حل المشكلات التي تحل احتياجات المستخدم النهائي الحقيقية. يمكن لأصحاب المصلحة المساعدة في تحديد اختيار المقاييس لتقييم أساليب GeoAI-EO التي تمثل أداء الواقع الحقيقي بدلًا من الالتزام بالمقاييس شائعة الاستخدام في الذكاء الاصطناعي.
- (5) لكي تكون الاستثمارات المذكورة أعلاه مستدامة، هناك حاجة إلى إضفاء الطابع المؤسسي على الاستثمارات في البحوث، من قبل منظمات دائمة تركز على الصالح العام، مثل الجامعات أو الحكومة.
- (6) يعد الوصول إلى مجموعات بيانات الأقمار الصناعية عالية الدقة عائقًا كبيرًا أمام تطوير تطبيقات GeoAI-EO كون الزراعة الغالبة هي من أصحاب الحيازات الصغيرة. وهناك حاجة إلى بذل جهود مجتمعية ومشاركة بين المؤسسات لشراء البيانات من مقدمي الخدمات التجاريين، مثل: Planet أو Maxar لأغراض البحوث المتعلقة بالزراعة في اليمن. (على سبيل المثال، قام برنامج بيانات الأقمار الصناعية التابع للمبادرة الدولية للمناخ والغابات في الترويج بإنشاء خرائط أساس الكوكب عالية الدقة مجانًا للمشروع المتعلقة بالغابات في المناطق الاستوائية في العالم. وينبغي تنفيذ مبادرة مماثلة في مجال الزراعة).

(7) في حين تظهر الأبحاث المنشورة فوائدها المحتملة، فإن التطبيقات العملية التي تحقق وعد هذه الحلول لأصحاب المصلحة لا تزال محدودة. لذا من الأهمية بمكان، إجراء تقييمات صارمة لتقييم نقاط القوة والقيود في نماذج GeoAI-EO وتطبيقها في الواقع، ونشر هذه التقييمات والنتائج، وإصدار قرارات بإدراجها ضمن السياسات وخاصة تلك التي تؤثر على سبل عيش الناس ونتائجهم بشكل شامل وإبلاغها بشكل شامل.

التوصيات:

- إجراء المزيد من الدراسات حول الفوائد المحددة لاستخدام GeoAI-EO في الممارسات الزراعية المختلفة في اليمن.
- المساهمة في تطوير تقنيات GeoAI-EO أكثر بأسعار معقولة وسهلة الاستخدام.
- إنشاء مجموعات بيانات موحدة للتطبيقات GeoAI-EO
- تدريب المزيد من الموظفين على استخدام تقنيات GeoAI-EO

المراجع

المراجع باللغة العربية:

برنامج الأمم المتحدة الإنمائي (UNDP). (2021). *التكنولوجيا الرقمية في الزراعة: إمكانات وحدود التحول الرقمي*. البنك الدولي، الزراعة الذكية. (2020). *الاستفادة من التقنيات الرقمية لتحسين الإنتاجية والاستدامة*. العطاس، أحمد. (2020). *نتائج التصنيف الموجه لمنطقة مشروع وادي مور، مشروع تخرج دورة أساسيات الاستشعار عن بعد (مشروع غير منشور)*، الهيئة العامة لتطوير تهمامة، وزارة الزراعة والري، اليمن. المركز الوطني للمعلومات. (2023). *موقع المركز، صنعاء*. www.nec.org.ye

منظمة الأغذية والزراعة للأمم المتحدة، (الفاو). (2022). *التحول الرقمي في الزراعة: فرصة لتعزيز الإنتاجية والاستدامة*. المهباب، أيوب أحمد. (2022). *تطبيق تقنيات الاستشعار عن بعد ونظم المعلومات الجغرافية دراسة الوضع الحالي لليمن العربي وتصور مقترح لتحسين كميته ونوعيته في اليمن، مجلة جامعة صعده، (2)، 1-27*.

المهباب، أيوب أحمد. (2022). *الإدارة المتكاملة للمساقط المائية من أجل التنمية المستدامة للمناطق الريفية باستخدام تقنيات الاستشعار عن بعد ونظم المعلومات الجغرافية، دراسة حالة وادي مور اليمن، مجلة جامعة صعده، (1)، 110-141*.

المهباب، أيوب أحمد. (2022). *مساهمة التحول الرقمي للتعليم العالي في تحقيق التنمية المستدامة - نموذج قطاع الزراعة، مجلة جامعة الرازي للعلوم الإدارية والإنسانية، 3 (6)، 110-128*.

موسوعة ويكيبيديا بالعربي. (2023). *الموقع بالإنترنت* www.wikipedia.org

وزارة الزراعة والري. (2023). *تقارير متفرقة غير منشورة، وزارة الزراعة والري، صنعاء*.

المراجع باللغة الأجنبية:

Benami E, Jin Z, Carter M R, Ghosh A, Hijmans R J, Hobbs A, Kenduywo B and Lobell D B., 2021, Uniting remote sensing, crop modelling and economics for agricultural risk management Nat. Rev. Earth Environ. 2 140–59

Gold K., 2021, Plant disease sensing: studying plantpathogen interactions at scale Msystems 6 e01228–21

- ITC, (2004). Crop classification and estimation of water needs in the Sana'a Basin using satellite images, a report submitted to the Sana'a Basin Project, Sana'a, Yemen.
- Jin Z, Azzari G, You C, Di Tommaso S, Aston S, Burke M and Lobell D B., (2019). Smallholder maize area and yield mapping at national scales with Google Earth Engine Remote Sens. Environ. 228 115–28
- Khatri, Arun., (2023). JK Business School, Gurgaon; Hriday Khatri, MBA Scholar, DCRUST Murthal, India.
- Kumar, S., Gupta, R., & Singh, S. (2018). Geo-spatial artificial intelligence for precision agriculture: A review. Computers and Electronics in Agriculture, 143, 151-162.
- Alam, M.; Alam, M.S.; Roman, M.; Tufail, M.; Khan, M.U.; Khan, M.T.,(2020). Real-Time Machine-Learning Based Crop/Weed Detection and Classification for Variable-Rate Spraying in Precision Agriculture. In Proceedings of the 2020 7th International Conference on Electrical and Electronics Engineering, ICEEE 2020, Antalya, Turkey, 14–16 April 2020; IEEE: Piscataway, NJ, USA, 2020; pp. 273–280.
- Almhah A. A., (2014). Regional Yield Prediction for Sorghum based on Crop Biomass Estimation using Satellite Remote Sensing Data in Arid Areas, 9th Science Conference, IBB University, Yemen, 2014..
- Almhah A. A., (2015). Remote Sensing and GIS Application in Agro-Ecological Zoning, 1th Agro-ecological & modern agriculture Conference, Cairo University, Egypt 2015.abstract pdf.
- Almhah A. A., (2016). Application of SAR and Optical Remote Sensing for Operational Mapping of Soil Moisture in watershed scale, Yemen. ISNET/NARSS Workshop on "Earth Remote Sensing with Synthetic Aperture Radar (SAR)- 27 Nov-01 Dec 2016; Cairo, Egypt".
- Almhah A. A., (2017). Remote Sensing and GIS Application in Agro-Ecological Zoning in Yemen Mountains. 37th Asian Conference on Remote Sensing (37th ACRS) from 17th to 21st October 2017 at Galadari Hotel, Colombo, Sri Lanka.
- Almhah A. A., (2018). Dams decision support system for site selection using remote sensing and GIS techniques in Yemen 38th Asian Conference on Remote Sensing (38th ACRS) 2018, Kuala Lumpur, Malaysia.
- Almhah A. A. (2011). Assessment of Crop Water Requirement and annual planning of water allocation in Yemen using remote sensing data and M-SEBAL model, ISNET/ RJGC Workshop on application of satellite technology in water resources management, 18 -22/9/2011. Amman,
- Almhah A. A., C. V. Tol (2010). Estimation of Water Balance Using Combined TRMM and MODES Satellite Products: A Case Study in Yemen, [The 7th Scientific Conference Yemen 27-29/9/2010, Tareem, Yemen.](#)
- Almhah A., (2009). Prediction of Groundwater availability in arid areas using integration of Remote Sensing, GIS, and DSS mapping, The 10th International Arab Conference on Information Technology, 15-17 December, 2009 Sana'a, Organized by University of Science & Technology, Sana'a, Yemen.
- Almhah A., (2009). Investigation of Vegetation Covers change on Arabia Peninsula using Remote Sensing and GIS, The 10th International Arab Conference on Information Technology, 15-17 December, 2009 Sana'a, Organized by University of Science & Technology, Sana'a, Yemen.

- Almhhab, A. and Ibrahim Busu (2008). the approaches for oasis desert vegetation information abstraction based on medium -resolution Lansat TM image: A case study in desert wadi Hadramut Yemen, EMS2008, *IEEE computer society*, pp.356-360, 2008 IEEE,
- Meyer L, Lemarchand F and Sidiropoulos P., (2020). A deep learning architecture for batch-mode fully automated field boundary detection The Int. Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences vol 43 pp 1009–16
- Mrisho L M, Mbilinyi N A, Ndalawa M, Ramcharan A M, Kehs A K, McCloskey P C, Murithi H, Hughes D P and Legg J P., (2020). Accuracy of a smartphone-based object detection model, PlantVillage Nuru, in identifying the foliar symptoms of the viral diseases of cassava-CMD and CBSD Front. Plant Sci. 11 590889
- Nakalembe C. and Kerner H., (2022). Department of Geographical Sciences, University of Maryland, College Park, MD 20740, United States of America.
- Nakalembe C. et al., (2021). A review of satellite-based global agricultural monitoring systems available for Africa Glob. Food Secur. 29 100543
- Nakalembe C., (2020). Urgent and critical need for Sub-Saharan African countries to invest in earth observation-based agricultural early warning and monitoring systems Environ. Res. Lett. 15 121002
- Sasson A., 2012, Food security for Africa: an urgent global challenge Agric. Food Secur. 1 1–16
- Singh, J., Kaur, A., & Singh, J. (2020). Artificial intelligence in agriculture: A review of recent trends. Computers and Electronics in Agriculture, 168, 105473.
- SRI, (2023). Machine Learning in ArcGIS, Esri Website. www.esri.com.
- Van Klompenburg T, Kassahun A and Catal C., (2020). Crop yield prediction using machine learning: a systematic literature review Comput. Electron. Agric. 177 105709
- Wang S, Waldner F and Lobell D B., (2022). Unlocking large-scale crop field delineation in smallholder farming systems with transfer learning and weak supervision Remote Sens. 14 5738
- WAPOR., (2018). FAO Water Productivity Open-access portal (WaPOR), Remote sensing for water productivity - the WaPOR portal from FAO. [FAO Water Productivity](http://FAOWaterProductivity).
- Waterwach, (2014). Crop classification and estimation of water needs in three different basins of Yemen using satellite images, a report submitted to the Groundwater and Soil Conservation Project, Sana'a, Yemen.
- Yang, J., Li, J., & Li, S. (2017). Application of geospatial artificial intelligence in precision agriculture: A review. International Journal of Remote Sensing, 38(22), 7199-7223.
- Zanaga D et al., (2021). ESA WorldCover 10 m 2020 v100 (version v100)[data set].
- Zhang, J., Zhang, Y., & Wang, S. (2019). Application of geospatial artificial intelligence in precision agriculture: A review. Sensors, 19(18), 3727.