Al-Farouk journal of sciences
Volume (2), Issue (5) (Nov, 2026)
ISSN: 3135-2359

مجلة الفاروق للعلوم
المجلد (2) العدد 5 نوفمبر 2026
عدد خاص بالمؤتمر العلمي الرابع للعلوم والتقنية
28–29 نوفمبر 2026 مصراتة – ليبيا
إدارة المعاهد العليا – وزارة التعليم التقني

تطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية: نحو زراعة نسيجية ذكية

نورية نوري مصطفى المغربي
قسم البستنة – كلية الزراعة – جامعة طرابلس/ليبيا

Artificial Intelligence Applications in Plant Tissue Culture: Towards Smart Tissue Culture

Dr Nuria Nuri Mustafa Almaghrabi/Libya
Department of Horticulture - Faculty of Agriculture- University of Tripoli – Libya

تاريخ الاستلام: 2026/7/30 تاريخ المراجعة 2026/8/20 تاريخ القبول:2026/8/28- تاريخ النشر: 2026/11/28

الملخص:

تهدف هذه الورقة إلى استعراض وتحليل تطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، مع التركيز على إمكانات التعلم الآلي والشبكات العصبية الاصطناعية وخوارزميات التحسين في تطوير بروتوكولات الزراعة النسيجية. واعتمدت الورقة على مراجعة سردية تحليلية انتقائية للأدبيات العلمية ذات الصلة، بهدف مقارنة الاتجاهات البحثية وتحديد التطبيقات الواعدة والتحديات المرتبطة بتوظيف التقنيات الذكية في هذا المجال.

وتشير الدراسات المستعرضة إلى إمكانية الاستفادة من نماذج الذكاء الاصطناعي في تحليل العلاقات المعقدة بين مكونات الأوساط الغذائية ومنظمات النمو والاستجابات النباتية، فضلًا عن دعم التنبؤ بتكوين الكالس والتجذير والتجديد النباتي. كما تبرز تقنيات الرؤية الحاسوبية بوصفها اتجاهًا واعدًا لمراقبة النمو وتقييم جودة المزارع النسيجية، إلا أن الأدلة المتعلقة بفاعليتها في الكشف المبكر عن التلوث وخفض التكاليف التشغيلية لا تزال بحاجة إلى مزيد من التحقق التجريبي.

وتخلص الورقة إلى أن دمج نماذج التعلم الآلي مع خوارزميات التحسين يمثل توجهًا بحثيًا واعدًا لتطوير زراعة الأنسجة النباتية، غير أن تعميم نتائجه يتطلب توفير بيانات تجريبية موثوقة، والتحقق من أداء النماذج في أنواع نباتية وبيئات مخبرية مختلفة، وتعزيز التعاون بين المتخصصين في علوم النبات والذكاء الاصطناعي.

الكلمات المفتاحية : الذكاء الاصطناعي، زراعة الأنسجة النباتية، التعلم الآلي، الشبكات العصبية الاصطناعية، خوارزميات التحسين، الإكثار الدقيق.

Abstract:

This paper aims to review and analyze the applications of artificial intelligence (AI) in plant tissue culture, focusing on the potential of machine learning, artificial neural networks, and optimization algorithms to improve in vitro culture protocols. A selective narrative review approach was adopted to examine relevant scientific literature, compare research trends, identify promising applications, and highlight the challenges associated with integrating intelligent technologies into plant tissue culture.

The reviewed literature suggests that AI-based models can support the analysis of complex relationships among culture medium components, plant growth regulators, and plant responses. These models also show potential for predicting callus formation, rooting, and plant regeneration. Furthermore, computer vision techniques represent a promising approach for monitoring plant growth and assessing tissue culture quality. However, evidence supporting their effectiveness in early contamination detection and operational cost reduction remains limited and requires further experimental validation.

The paper concludes that integrating machine learning models with optimization algorithms offers promising opportunities for advancing plant tissue culture. Nevertheless, the broader applicability of these approaches depends on the availability of reliable experimental datasets, validation across different plant species and laboratory conditions, and stronger interdisciplinary collaboration between plant scientists and artificial intelligence specialists.

Keywords: Artificial Intelligence, Plant Tissue Culture, Machine Learning, Artificial Neural Networks, Optimization Algorithms, Micropropagation.

المقدمة:

شهدت السنوات الأخيرة تطورًا متسارعًا في تطبيقات الذكاء الاصطناعي(Artificial Intelligence, AI) ، مما أتاح إمكانات جديدة لتحليل البيانات المعقدة وبناء النماذج التنبؤية وتحسين عمليات اتخاذ القرار في العديد من المجالات العلمية، ومن بينها الزراعة والتكنولوجيا الحيوية النباتية. وقد برزت تقنيات التعلم الآلي (Machine Learning) والشبكات العصبية الاصطناعية (Artificial Neural Networks) وخوارزميات التحسين (Optimization Algorithms) بوصفها أدوات واعدة لمعالجة المشكلات التي تتداخل فيها المتغيرات البيولوجية والبيئية، والتي يصعب أحيانًا تفسيرها باستخدام الأساليب التقليدية وحدها (أحمد وآخرون، 2026؛ Hesami & Jones, 2020)

وتُعد زراعة الأنسجة النباتية (Plant Tissue Culture) من التقنيات الحيوية المهمة في الإكثار الدقيق للنباتات، وحفظ الموارد الوراثية، وإنتاج مواد نباتية خالية من مسببات مرضية محددة عند تطبيق بروتوكولات مناسبة للفحص والتنقية. وتعتمد كفاءة هذه التقنية على مجموعة من العوامل المتداخلة، تشمل التركيب الوراثي للنبات، ونوع الجزء النباتي المزروع، ومكونات الوسط الغذائي، وتراكيز منظمات النمو، والظروف البيئية داخل المختبر. ويؤدي التفاعل المعقد بين هذه العوامل إلى صعوبة تحديد البروتوكولات المثلى، مما يستلزم إجراء تجارب متعددة للوصول إلى استجابات نباتية مناسبة (نصر الدين وآخرون، 2014؛ قابيل، 2016)

وفي هذا السياق، أظهرت الأدبيات العلمية اهتمامًا متزايدًا بتوظيف نماذج الذكاء الاصطناعي في تحليل بيانات زراعة الأنسجة النباتية والتنبؤ بالاستجابات المرتبطة بتكوين الكالس والتجذير والتجديد النباتي. كما تناولت الدراسات إمكانات الجمع بين نماذج التعلم الآلي وخوارزميات التحسين لتحديد التراكيب المناسبة للأوساط الغذائية ومنظمات النمو، بما يوفر أساسًا لتوجيه تصميم التجارب المخبرية واختيار المعاملات الواعدة. وتندرج هذه التطبيقات ضمن الاتجاهات الحديثة لتطوير المختبرات النباتية القائمة على البيانات والتحليل الحاسوبي.

وامتدت الاتجاهات البحثية الحديثة إلى دراسة إمكانات الرؤية الحاسوبية (Computer Vision) والتعلم العميق (Deep Learning)في متابعة نمو النباتات وتحليل الصور الرقمية وتقييم التغيرات المظهرية. وقد تناول أحمد وآخرون (2026) استخدام الشبكات العصبية الالتفافية في تحليل صور النباتات وتشخيص أمراضها، وهو تطبيق في الزراعة الذكية يمكن الاستفادة من مبادئه عند بحث إمكانات المراقبة الرقمية للمزارع النسيجية. ومع ذلك، فإن الانتقال إلى أنظمة مراقبة ذكية داخل مختبرات زراعة الأنسجة يتطلب بيانات متخصصة وإجراءات موحدة لجمع الصور وتحليلها، والتحقق من أداء النماذج في ظروف مخبرية متنوعة.

وعلى الرغم من تزايد الاهتمام بتطبيقات الذكاء الاصطناعي في المجالات الزراعية، فإن الدراسات تختلف من حيث الأنواع النباتية المدروسة، والخوارزميات المستخدمة، والمتغيرات المستهدفة، وطرائق تقييم النماذج. ويحد هذا التباين من إمكانية إجراء مقارنات مباشرة بين النتائج أو تعميمها على مختلف الأنواع النباتية والبيئات المخبرية. كما أن التطبيقات المتعلقة بالكشف المبكر عن التلوث داخل المزارع النسيجية تحتاج إلى أدلة تجريبية متخصصة، خاصة أن التلوث الميكروبي يمثل أحد التحديات المؤثرة في نجاح عمليات الإكثار والتجذير (السامر وآخرون، 2026).

وتتمثل الإضافة العلمية التي تسعى هذه الورقة إلى تقديمها في بناء إطار تحليلي مقارن لتطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، يربط بين نوع التطبيق والخوارزمية المستخدمة والاستجابة النباتية المستهدفة ومستوى التحقق التجريبي وحدود قابلية تعميم النتائج. كما تقترح الورقة إطارًا مفاهيميًا لتطوير الزراعة النسيجية الذكية، يقوم على التكامل بين جمع البيانات المخبرية، وبناء النماذج التنبؤية، وتحسين المعاملات، والتحقق التجريبي من التوصيات الناتجة عنها.

وبناءً على ذلك، تهدف هذه الورقة إلى تحليل أبرز تطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، ومقارنة الأدلة العلمية المتعلقة بفاعليتها، وتحديد التحديات المنهجية والتقنية التي تعوق تطبيقها على نطاق أوسع، وصولًا إلى تقديم تصور بحثي يدعم تطوير أنظمة زراعة نسيجية أكثر اعتمادًا على البيانات وأكثر قابلية للتحقق العلمي.

مشكلة البحث

على الرغم من التطور المتزايد في تطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، فإن توظيف هذه التقنيات لا يزال يواجه تحديات علمية وتطبيقية تتعلق بتنوع الخوارزميات المستخدمة، واختلاف الأنواع النباتية والظروف التجريبية، ومحدودية البيانات المتاحة للتحقق من كفاءة النماذج وإمكانية تعميم نتائجها. كما أن تفاوت الدراسات في أساليب التقييم والتحقق التجريبي يجعل من الصعب تحديد التطبيقات الأكثر ملاءمة لتحسين بروتوكولات الزراعة النسيجية.

وتتمثل مشكلة البحث في الحاجة إلى تحليل الأدلة العلمية المتاحة بشأن تطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، وتحديد مدى إسهامها في تحسين التنبؤ بالاستجابات النباتية ودعم تصميم التجارب، مع التمييز بين النتائج التي خضعت للتحقق التجريبي والإمكانات التي لا تزال بحاجة إلى مزيد من البحث.

وعليه، تتمحور مشكلة البحث حول السؤال الرئيس الآتي:

ما أبرز تطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، وما مستوى الأدلة العلمية الداعمة لفاعليتها وإمكانية توظيفها في تطوير الزراعة النسيجية الذكية؟

أهداف البحث

تهدف هذه الورقة إلى:

1. تحليل أبرز تطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، مع التركيز على التعلم الآلي والشبكات العصبية الاصطناعية وخوارزميات التحسين ودورها في التنبؤ بالاستجابات النباتية وتحسين بروتوكولات الزراعة.
2. مقارنة نتائج الدراسات العلمية المتعلقة بتطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، وتقييم مستوى التحقق التجريبي من النماذج المستخدمة وحدود إمكانية تعميم نتائجها.
3. تحديد التحديات العلمية والتقنية المرتبطة بتوظيف الذكاء الاصطناعي في مختبرات زراعة الأنسجة النباتية، واقتراح إطار مفاهيمي يدعم تطوير أنظمة زراعة نسيجية ذكية قائمة على البيانات والتحقق التجريبي.

منهجية البحث

تعتمد هذه الورقة على منهج المراجعة السردية التحليلية الانتقائية(Selective Narrative Review) ، بهدف استعراض وتحليل الأدبيات العلمية المتعلقة بتطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، مع التركيز على النماذج التنبؤية وخوارزميات التحسين والتطبيقات المحتملة للرؤية الحاسوبية في تطوير بروتوكولات الزراعة النسيجية.

وتقوم المراجعة على التحليل النوعي والمقارنة النقدية للدراسات ذات الصلة، دون إجراء تجارب مخبرية جديدة أو تحليل إحصائي تجميعي لنتائج الدراسات السابقة.

أولًا: مصادر الأدبيات العلمية

تستند المراجعة إلى الدراسات والأبحاث العلمية التي تناولت استخدام تقنيات الذكاء الاصطناعي والتعلم الآلي في زراعة الأنسجة النباتية، مع إعطاء الأولوية للدراسات الأصلية المنشورة في المجلات العلمية المحكمة.

وتشمل المصادر ذات الصلة الدراسات التي تبحث في تحسين الأوساط الغذائية ومنظمات النمو، والتنبؤ بتكوين الكالس والتجذير والتجديد النباتي، وتحليل الصور الرقمية ومراقبة نمو المزارع النسيجية.

ثانيًا: معايير اختيار الدراسات

تُعتمد المعايير الآتية لتحديد الدراسات المناسبة للتحليل:

1. ارتباط الدراسة المباشر بتطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية.
2. تناول الدراسة نماذج التعلم الآلي أو الشبكات العصبية الاصطناعية أو خوارزميات التحسين أو الرؤية الحاسوبية.
3. تقديم نتائج علمية تتعلق بالتنبؤ بالاستجابات النباتية أو تحسين ظروف الزراعة النسيجية.
4. تفضيل الدراسات الأصلية التي تتضمن بيانات تجريبية ومؤشرات واضحة لتقييم أداء النماذج.
5. الاستفادة من الدراسات المرجعية والمراجعات العلمية في توضيح الخلفية النظرية وتحديد الاتجاهات البحثية.

وتُستبعد من التحليل المقارن الدراسات غير المرتبطة مباشرة بزراعة الأنسجة النباتية، والمصادر التي لا يمكن التحقق من بياناتها الببليوغرافية، والمقالات الصحفية غير المحكمة عند الاستدلال على النتائج العلمية المتخصصة.

ثالثًا: تصنيف الدراسات وتحليلها

تُصنف الدراسات المختارة وفق أربعة محاور رئيسية:

1. **تحسين الأوساط الغذائية ومنظمات النمو :**تحليل استخدام النماذج الذكية في تحديد العوامل المؤثرة في الاستجابات النباتية واقتراح المعاملات المناسبة.
2. **التنبؤ بالنمو والتجديد النباتي :**دراسة تطبيقات التعلم الآلي في التنبؤ بتكوين الكالس والتجذير وتجديد الأفرع والنمو داخل المختبر.
3. **الرؤية الحاسوبية ومراقبة المزارع النسيجية :**استعراض التطبيقات المتعلقة بتحليل الصور وتقييم النمو، مع التمييز بين التطبيقات المختبرة والتطبيقات المقترحة.
4. **التحديات وإمكانية التعميم :**تحليل القيود المتعلقة بحجم البيانات وجودتها، والتحقق التجريبي، واختلاف الأنواع النباتية والظروف المخبرية.

رابعًا: أسلوب المقارنة وتقييم الأدلة

تعتمد الورقة على المقارنة النوعية بين الدراسات من خلال تحديد النوع النباتي المدروس، والخوارزمية المستخدمة، والمتغيرات المستهدفة، ومؤشرات تقييم النموذج، وطبيعة التحقق من النتائج.

ويُراعى في التحليل التمييز بين دقة النماذج على بيانات التدريب، وأدائها على بيانات الاختبار، ونتائج التحقق التجريبي المستقل متى توافرت هذه المعلومات.

كما تُناقش حدود تعميم النتائج على أنواع نباتية أو ظروف مخبرية مختلفة، مع تجنب استخلاص أحكام عامة من دراسات أُجريت على أنواع نباتية محددة.

خامسًا: حدود المنهجية

نظرًا إلى اعتماد الورقة على مراجعة سردية انتقائية، فإن نتائجها لا تمثل حصرًا شاملًا لجميع الدراسات المنشورة في المجال.

كما أن اختلاف التصميمات التجريبية والخوارزميات ومؤشرات التقييم بين الدراسات قد يحد من إمكانية المقارنة الكمية المباشرة بينها.

وعليه، تُفسر النتائج باعتبارها تحليلًا نقديًا للأدلة العلمية المختارة، وليس تقديرًا إحصائيًا موحدًا لفاعلية الذكاء الاصطناعي في جميع تطبيقات زراعة الأنسجة النباتية.

الدراسات السابقة:

الدراسة الأولى(2020) Hesami and Jones :

تناول Hesami و Jones (2020)تطبيقات نماذج الذكاء الاصطناعي وخوارزميات التحسين في زراعة الخلايا والأنسجة النباتية، من خلال مراجعة الأدبيات العلمية المتعلقة باستخدام النماذج الحاسوبية في تحليل الاستجابات النباتية وتحسين ظروف الزراعة داخل المختبر.

وركزت الدراسة على إمكانات توظيف الشبكات العصبية الاصطناعية(ANN) ، وآلات المتجهات الداعمة(SVM) ، وغيرها من تقنيات التعلم الآلي، إلى جانب خوارزميات التحسين، في نمذجة العلاقات المعقدة بين العوامل التجريبية والاستجابات النباتية.

وأبرزت المراجعة أهمية الجمع بين النماذج التنبؤية وخوارزميات التحسين في دعم تصميم التجارب واختيار المعاملات الواعدة، ولا سيما في التطبيقات المرتبطة بتحسين الأوساط الغذائية ومنظمات النمو والتنبؤ بالتجديد النباتي.

وتكمن أهمية هذه الدراسة بالنسبة إلى الورقة الحالية في تقديم أساس نظري لفهم تطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية. ومع ذلك، فإن طبيعتها بوصفها دراسة مراجعة تستلزم الرجوع إلى الدراسات التجريبية الأصلية عند تقييم دقة النماذج وفاعليتها، بدل الاعتماد على نتائج المراجعة وحدها.

الدراسة الثانية(2021) Hesami and Jones :

تناول Hesami و Jones (2021)استخدام نماذج التعلم الآلي وخوارزميات التحسين في نمذجة نمو الكالس وتطوره في نبات القنب(Cannabis sativa) ، من خلال تحليل العلاقات بين العوامل التجريبية والاستجابات النباتية داخل المختبر.

وركزت الدراسة على توظيف نموذج الغابات العشوائية (Random Forest) وآلات المتجهات الداعمة (Support Vector Machine)، إلى جانب الخوارزمية الجينية(Genetic Algorithm) ، بهدف بناء نماذج تنبؤية والبحث عن معاملات تجريبية مناسبة لتحسين نمو الكالس.

وتبرز أهمية الدراسة في توضيح إمكانية التكامل بين نماذج التعلم الآلي وخوارزميات التحسين في توجيه تصميم التجارب المرتبطة بزراعة الأنسجة النباتية، بدل الاعتماد على التجارب المتتابعة وحدها.

وتستفيد الورقة الحالية من هذه الدراسة في تحليل العلاقة بين التنبؤ الحاسوبي وتحسين المعاملات المخبرية، مع التأكيد على أن النتائج المستخلصة من نوع نباتي محدد لا يمكن تعميمها مباشرة على الأنواع النباتية الأخرى دون إجراء تحقق تجريبي مستقل.

الدراسة الثالثة(2022) .Fallah Ziarani et al :

أجرى Fallah Ziarani وزملاؤه (2022) دراسة تجريبية تناولت نمذجة وتحسين نسبة وسرعة تكوين الكالس في نبات الجزر (Daucus carota) داخل المختبر، باستخدام نماذج حاسوبية تعتمد على الشبكات العصبية الاصطناعية وخوارزميات التحسين.

واستخدم الباحثون نموذج الإدراك متعدد الطبقات(Multilayer Perceptron, MLP) ، ونموذج دالة الأساس الشعاعي (Radial Basis Function, RBF)، إلى جانب خوارزمية جينية منفصلة لتحسين المعاملات المرتبطة بتكوين الكالس.

وأظهرت النتائج قدرة النماذج المستخدمة على تمثيل العلاقات المعقدة بين العوامل التجريبية واستجابة الأنسجة النباتية، مع اختلاف الأداء التنبؤي بين النماذج. كما أبرزت الدراسة إمكانية الاستفادة من خوارزميات التحسين في اقتراح معاملات تجريبية مناسبة لتحسين تكوين الكالس.

وتكتسب هذه الدراسة أهمية خاصة لكونها تقدم تطبيقًا تجريبيًا مباشرًا للذكاء الاصطناعي في زراعة الأنسجة النباتية، مما يجعلها مناسبة للتحليل المقارن بين الخوارزميات المستخدمة ومؤشرات أدائها.

الدراسة الرابعة(2021) .Pepe et al :

أجرى Pepe وزملاؤه (2021) دراسة تجريبية تناولت استخدام التعلم الآلي وخوارزميات التحسين التطورية في تطوير الإكثار الدقيق لنبات القنب(Cannabis sativa) ، مع التركيز على تأثير نوع الإضاءة ومصادر الكربوهيدرات في نمو الأفرع النباتية داخل المختبر.

واعتمدت الدراسة على تحليل بيانات تجريبية ناتجة عن معاملات مختلفة من الإضاءة وتراكيز السكروز، باستخدام نماذج الإدراك متعدد الطبقات(MLP) ، والشبكات العصبية للانحدار المعمم(GRNN) ، ونظام الاستدلال العصبي الضبابي التكيفي.(ANFIS)

وأظهرت النتائج تفوق نموذج GRNN في الأداء التنبؤي ضمن ظروف الدراسة، مما دفع الباحثين إلى دمجه مع مجموعة من خوارزميات التحسين لتحديد معاملات الإضاءة والسكروز المناسبة للاستجابات النباتية المستهدفة.

كما تضمنت الدراسة تجربة تحقق لمقارنة القيم المتوقعة بالقيم الفعلية، ولم تُظهر المقارنة فروقًا معنوية بين النتائج المتنبأ بها والنتائج المرصودة في معاملات التحقق.

وتتميز هذه الدراسة بتقديم دليل تجريبي على إمكانية الجمع بين التعلم الآلي وخوارزميات التحسين لتوجيه تصميم التجارب النسيجية. ومع ذلك، فإن نتائجها ترتبط بنبات القنب والظروف التجريبية المستخدمة، ولا يمكن تعميمها مباشرة على جميع الأنواع النباتية.

الدراسة الخامسة(2025) .Narra et al :

قدم Narra وزملاؤه (2025) مراجعة علمية تناولت التطورات المرتبطة بتطبيقات الذكاء الاصطناعي في التكنولوجيا الحيوية النباتية، مع التركيز على زراعة الأنسجة النباتية وتقنيات التحرير الجيني.

واستعرضت الدراسة تطبيقات التعلم الآلي والشبكات العصبية الاصطناعية والتعلم العميق في تحليل البيانات البيولوجية، والتنبؤ بالاستجابات النباتية، وتحسين بروتوكولات الزراعة داخل المختبر.

كما ناقشت إمكانات استخدام الذكاء الاصطناعي في تطوير تطبيقات التحرير الجيني، ولا سيما النماذج المستخدمة للتنبؤ بمواقع التحرير الجيني ونتائجه.

وأبرزت المراجعة مجموعة من التحديات المرتبطة بتطبيق هذه التقنيات، من بينها محدودية البيانات، وصعوبة تفسير بعض النماذج، والحاجة إلى التحقق التجريبي من النتائج قبل تطبيقها على نطاق أوسع.

وتكمن أهمية هذه الدراسة في تقديم رؤية حديثة للتكامل بين الذكاء الاصطناعي والتكنولوجيا الحيوية النباتية، مع ضرورة التمييز بين نتائج الدراسات التجريبية الأصلية والاستنتاجات العامة المستخلصة من المراجعات العلمية.

التعقيب على الدراسات السابقة

يتضح من استعراض الدراسات السابقة أن تطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية تتجه بصورة متزايدة نحو استخدام النماذج التنبؤية وخوارزميات التحسين لمعالجة العلاقات المعقدة بين العوامل التجريبية والاستجابات النباتية.

وقد ركزت الدراسات المرجعية، مثل Hesami and Jones (2020) و Narra et al. (2025)، على توضيح الإمكانات العلمية والتطبيقية لهذه التقنيات، بينما قدمت الدراسات التجريبية، مثل Fallah Ziarani et al. (2022) و Pepe et al. (2021)، تطبيقات مباشرة يمكن الاستفادة منها في تقييم أداء النماذج ومدى قدرتها على تحسين المعاملات المخبرية.

وتشير المقارنة بين الدراسات إلى أن كفاءة النماذج لا تعتمد على نوع الخوارزمية وحده، بل تتأثر أيضًا بجودة البيانات وحجمها، وطبيعة المتغيرات المدروسة، ونوع النبات، وطريقة تقييم النموذج والتحقق من نتائجه.

كما يتضح أن بعض التطبيقات، ولا سيما التنبؤ بالاستجابات النباتية وتحسين المعاملات التجريبية، تستند إلى دراسات تطبيقية مباشرة، في حين أن تطبيقات أخرى، مثل أنظمة المراقبة الذكية المتكاملة والكشف الآلي المبكر عن التلوث، تحتاج إلى مزيد من الدراسات المتخصصة والتحقق التجريبي.

وتتمثل الفجوة البحثية التي تسعى الورقة الحالية إلى معالجتها في الحاجة إلى تحليل مقارن يربط بين نوع التطبيق والخوارزمية المستخدمة والاستجابة النباتية المستهدفة ومستوى التحقق التجريبي، بدل الاكتفاء بعرض الإمكانات العامة للذكاء الاصطناعي.

وبناءً على ذلك، تسعى الورقة إلى تقديم إطار تحليلي يساعد على التمييز بين التطبيقات المدعومة بأدلة تجريبية والتطبيقات التي لا تزال في مرحلة التطوير، مع تحديد المتطلبات العلمية والتقنية اللازمة للانتقال نحو زراعة نسيجية ذكية قائمة على البيانات.

المبحث الأول: الإطار المفاهيمي للذكاء الاصطناعي ومزارع الأنسجة النباتية

يشهد القطاع الزراعي تطورًا متسارعًا في توظيف تقنيات الذكاء الاصطناعي، ولا سيما في تحليل البيانات الزراعية ودعم اتخاذ القرار وتحسين إدارة الموارد. وقد امتد الاهتمام بهذه التقنيات إلى مجال التكنولوجيا الحيوية النباتية، وخاصة مزارع الأنسجة النباتية، التي تتطلب التحكم في مجموعة من العوامل المتداخلة، مثل مكونات الأوساط الغذائية وتراكيز منظمات النمو والظروف البيئية. وتتيح نماذج التعلم الآلي إمكانية تحليل العلاقات المعقدة بين هذه المتغيرات والتنبؤ بالاستجابات النباتية، بما يساعد على توجيه التجارب المخبرية واختيار المعاملات الواعدة. ومع ذلك، فإن مدى إسهام هذه النماذج في تحسين الكفاءة أو تقليل الوقت والتكلفة يعتمد على طبيعة التطبيق وجودة البيانات ومدى التحقق التجريبي من النتائج (Hesami & Jones, 2020).

أولًا: مفهوم الذكاء الاصطناعي

ويضم الذكاء الاصطناعي مجموعة من المجالات والتقنيات المترابطة، من أبرزها التعلم الآلي(Machine Learning) ، الذي يعتمد على بناء نماذج تتعلم الأنماط والعلاقات من البيانات بهدف التنبؤ أو التصنيف. وتندرج ضمن التعلم الآلي خوارزميات متعددة، مثل الغابات العشوائية (Random Forest) وآلات المتجهات الداعمة (Support Vector Machines)، إضافة إلى الشبكات العصبية الاصطناعية .(Artificial Neural Networks) ويُعد التعلم العميق (Deep Learning)مجالًا فرعيًا من التعلم الآلي يعتمد على الشبكات العصبية متعددة الطبقات، ويُستخدم بصورة خاصة في معالجة البيانات المعقدة والصور الرقمية. أما الخوارزميات الجينية(Genetic Algorithms) ، فتندرج ضمن خوارزميات التحسين التطورية، ويمكن دمجها مع النماذج التنبؤية للبحث عن المعاملات التجريبية المناسبة وتحسين الاستجابات النباتية.

جدول (1): التصنيف العلمي لأبرز تقنيات الذكاء الاصطناعي وتطبيقاتها في مزارع الأنسجة النباتية

التقنية	التصنيف العلمي	الاستخدام في مزارع الأنسجة النباتية
التعلم الآلي(ML)	مجال فرعي من الذكاء الاصطناعي	تحليل البيانات والتنبؤ بالاستجابات النباتية
الشبكات العصبية الاصطناعية (ANN)	نماذج ضمن التعلم الآلي	نمذجة العلاقات غير الخطية بين المتغيرات
التعلم العميق(DL)	مجال فرعي من التعلم الآلي	تحليل الصور الرقمية والخصائص المظهرية
الغابات العشوائية(RF)	خوارزمية تعلم آلي	التنبؤ بالنمو وتحديد أهمية المتغيرات
آلات المتجهات الداعمة(SVM)	خوارزمية تعلم آلي	التنبؤ بالاستجابات النباتية وتصنيف البيانات
الخوارزميات الجينية(GA)	خوارزميات تحسين تطورية	تحسين مكونات الأوساط الغذائية وتراكيز منظمات النمو

المصدر :إعداد الباحثة بالاستناد إلى(2020) Hesami & Jones ، مع إعادة تنظيم التصنيف العلمي للتقنيات.

ثانيًا: مفهوم مزارع الأنسجة النباتية

تُعرف زراعة الأنسجة النباتية بأنها مجموعة من التقنيات الحيوية التي تعتمد على استزراع الخلايا أو الأنسجة أو الأعضاء النباتية في أوساط غذائية معقمة وتحت ظروف بيئية محكمة، بهدف إكثار النباتات أو تجديدها أو حفظ مواردها الوراثية أو دراسة استجاباتها الفسيولوجية. وتُستخدم هذه التقنيات في الإكثار الدقيق، وإنتاج مواد نباتية خالية من مسببات مرضية محددة عند تطبيق بروتوكولات مناسبة للفحص والتنقية، وحفظ الأصول الوراثية، ودعم برامج التربية النباتية. ولا تؤدي جميع طرائق زراعة الأنسجة بالضرورة إلى إنتاج نباتات مطابقة وراثيًا للنبات الأم، إذ قد تظهر تغيرات وراثية أو فوق جينية تبعًا لنوع النسيج المزروع وظروف الاستزراع وطريقة التجديد (Hesami & Jones, 2020; Isak et al., 2025).

جدول (2): أهم استخدامات مزارع الأنسجة النباتية

الاستخدام	الفائدة
الإكثار الدقيق	إنتاج أعداد كبيرة من النباتات
إنتاج نباتات خالية من الأمراض	تحسين جودة الإنتاج

حفظ الأصول الوراثية	المحافظة على التنوع الوراثي
إنتاج النباتات الطبية	زيادة الإنتاج التجاري
دعم برامج التربية النباتية	استنباط أصناف جديدة

المصدر: إعداد الباحثة بالاستناد إلى Isak et al. (2025).

ثالثًا: العلاقة بين الذكاء الاصطناعي ومزارع الأنسجة النباتية

يمكن توظيف الذكاء الاصطناعي في تطوير مزارع الأنسجة النباتية من خلال تحليل البيانات الناتجة عن التجارب المخبرية، وبناء نماذج تنبؤية تساعد على دراسة تأثير مكونات الأوساط الغذائية وتراكيز منظمات النمو والظروف البيئية في الاستجابات النباتية. كما يمكن دمج نماذج التعلم الآلي مع خوارزميات التحسين لاقتراح معاملات تجريبية واعدة تسهم في توجيه تصميم التجارب وتقليل الاعتماد على المحاولات العشوائية. وتُعد تقنيات الرؤية الحاسوبية من التطبيقات الواعدة في تحليل الصور الرقمية ومتابعة الخصائص المظهرية للأنسجة النباتية، إلا أن استخدامها للكشف المبكر عن التلوث الميكروبي يحتاج إلى أدلة تجريبية متخصصة. وعلى الرغم من الإمكانات التي توفرها هذه التقنيات، فإن تحسين الكفاءة وتقليل الوقت والتكاليف لا يُعدان نتائج مضمونة، بل يتطلب إثباتهما إجراء مقارنات تجريبية واقتصادية مناسبة (Hesami & Jones, 2020).

جدول (3): تطبيقات الذكاء الاصطناعي في مزارع الأنسجة النباتية

التطبيق	الفائدة
التنبؤ بالنمو	رفع نسبة نجاح الإكثار
تحسين الوسط الغذائي	تقليل عدد التجارب
تحليل الصور	إمكانية دعم الكشف عن التلوث بعد التحقق التجريبي من دقة النموذج
دعم اتخاذ القرار	تحسين كفاءة المختبر
تحسين منظمات النمو	زيادة سرعة التجذير والتضاعف

المصدر: إعداد الباحثة بالاستناد إلى Hesami and Jones (2020) و Isak et al. (2025)، مع التمييز بين التطبيقات المدعومة بأدلة تجريبية والتطبيقات المحتملة.

المبحث الثاني: تطبيقات الذكاء الاصطناعي في تقنية مزارع الأنسجة النباتية

أولًا: دور الذكاء الاصطناعي في تحسين الإكثار الدقيق

تُعد تقنية الإكثار الدقيق من أهم تطبيقات زراعة الأنسجة النباتية، إذ تهدف إلى إنتاج أعداد كبيرة من النباتات تحت ظروف مخبرية محكمة. ويمكن توظيف الذكاء الاصطناعي في دعم هذه التقنية من خلال تحليل البيانات التجريبية والتنبؤ بالظروف المناسبة لنمو الأنسجة النباتية، مثل تركيب الوسط الغذائي وتراكيز منظمات النمو والظروف البيئية.

وقد تناولت الدراسات العلمية إمكانات استخدام نماذج التعلم الآلي وخوارزميات التحسين في اقتراح معاملات تجريبية مناسبة لتحسين الاستجابات النباتية. كما أظهرت دراسة تطبيقية على نبات القنب إمكانية الجمع بين النمذجة التنبؤية والتحسين الرياضي لدعم اختيار ظروف الإكثار الدقيق، مع التحقق من النتائج داخل المختبر.

ومع ذلك، فإن تحديد مدى إسهام هذه التطبيقات في زيادة كفاءة الإنتاج أو تقليل الوقت والجهد يتطلب إجراء مقارنات تجريبية مناسبة، ولا يمكن اعتبار هذه الفوائد نتائج مؤكدة في جميع أنواع النباتات (Hesami & Jones, 2020; Pepe et al., 2021).

جدول (4): دور الذكاء الاصطناعي في تحسين الإكثار الدقيق

التطبيق	الأثر المحتمل
اختيار الوسط الغذائي	تحسين ظروف الإكثار
تحسين تراكيز منظمات النمو	دعم عمليات التجذير والتضاعف
تحليل البيانات	توجيه اختيار المعاملات التجريبية
دعم اتخاذ القرار	المساعدة في اختيار الظروف المناسبة

المصدر: إعداد الباحثة بالاعتماد على Hesami and Jones (2020) وPepe et al. (2021).

ثانيًا: استخدام الذكاء الاصطناعي في مراقبة مزارع الأنسجة النباتية

تُعد تقنيات الرؤية الحاسوبية والتعلم العميق من الاتجاهات الواعدة في تطوير أنظمة المراقبة الرقمية للنباتات، إذ تتيح إمكانية تحليل الصور واستخلاص مؤشرات مرتبطة بالنمو والخصائص المظهرية. وقد تناولت بعض الدراسات الحديثة استخدام الشبكات العصبية الالتفافية في مراقبة صحة المحاصيل وتحليل الصور النباتية، مما يوفر أساسًا تقنيًا يمكن الاستفادة منه عند تطوير تطبيقات متخصصة في مختبرات زراعة الأنسجة النباتية (أحمد وآخرون، 2026).

وفي هذا السياق، يمكن بحث إمكانات استخدام الصور الرقمية لمتابعة نمو الأنسجة النباتية وتقييم خصائصها المظهرية، مثل تغير اللون ومساحة الكالس وعدد الأفرع وطول الجذور. غير أن الانتقال من هذه الإمكانات إلى تطبيقات عملية موثوقة يتطلب توفير بيانات صور متخصصة، وتوحيد ظروف التصوير، والتحقق من أداء النماذج باستخدام عينات مستقلة.

أما الكشف المبكر عن التلوث الميكروبي وتقليل الفاقد وتسريع العمليات المخبرية، فلا ينبغي اعتبارها فوائد مثبتة استنادًا إلى الأدبيات المستعرضة وحدها، بل تمثل تطبيقات محتملة تحتاج إلى دراسات تجريبية متخصصة قبل اعتمادها أو تعميم نتائجها.(Narra et al., 2025)

جدول (5): أهم تطبيقات الذكاء الاصطناعي في مراقبة المزارع النسيجية

التطبيق	الاستخدام المحتمل
تحليل الصور الرقمية	متابعة مراحل النمو
الكشف المبكر عن التلوث	تطبيق يحتاج إلى تحقق تجريبي
قياس النمو النباتي	تقييم الخصائص المظهرية للنباتات
التصنيف الآلي للعينات	دعم تنظيم العينات وتقييمها

المصدر: إعداد الباحثة بالاستناد إلى أحمد وآخرين (2026) وNarra et al. (2025)، مع عرض التطبيقات بوصفها إمكانات تحتاج إلى تحقق تجريبي متخصص في مزارع الأنسجة النباتية.

ثالثًا: التحديات والآفاق المستقبلية

على الرغم من الإمكانات التي توفرها تطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، فإن توظيف هذه التقنيات يواجه تحديات علمية وتقنية متعددة، من أبرزها محدودية قواعد البيانات التجريبية المتخصصة، واختلاف طرق تسجيل المتغيرات والاستجابات النباتية، وصعوبة تعميم النماذج على أنواع وأصناف نباتية مختلفة، فضلًا عن الحاجة إلى خبرات تجمع بين علوم النبات والحاسوب والإحصاء.

كما تتطلب التطبيقات المتقدمة، مثل المراقبة الرقمية والأتمتة المخبرية، بنية تقنية مناسبة وإجراءات موحدة لجمع البيانات وتقييم أداء النماذج. وتشير الاتجاهات البحثية الحديثة إلى أهمية تطوير نماذج قابلة للتفسير وإجراء تحقق تجريبي مستقل قبل اعتماد التوصيات الناتجة عنها.

وتتمثل الآفاق المستقبلية في إمكانية تطوير مختبرات زراعة نسيجية أكثر اعتمادًا على البيانات، من خلال التكامل بين النماذج التنبؤية وخوارزميات التحسين وأنظمة التصوير والمراقبة، مع مراعاة الجدوى التقنية والاقتصادية لكل تطبيق (Hesami & Jones, 2020; Narra et al., 2025).

جدول (6): أبرز التحديات والحلول المستقبلية

التحديات	الحلول المقترحة
نقص قواعد البيانات	إنشاء قواعد بيانات متخصصة
ارتفاع تكلفة التقنيات	التوسع التدريجي في التحول الرقمي
نقص الكفاءات	التدريب المستمر للباحثين
محدودية التطبيقات	تعزيز التعاون بين الباحثين والمبرمجين

المبحث الثالث: التحليل المقارن لنتائج الدراسات السابقة وآفاق توظيف الذكاء الاصطناعي في مزارع الأنسجة النباتية

اعتمد هذا المبحث على تحليل نتائج الدراسات السابقة المتعلقة باستخدام الذكاء الاصطناعي والتعلم الآلي وخوارزميات التحسين في تقنية مزارع الأنسجة النباتية. وقد جرى تصنيف نتائج هذه الدراسات وفق مجموعة من المحاور، شملت تحسين تصميم التجارب النسيجية، وتحسين الأوساط الغذائية ومنظمات النمو، والتنبؤ بتكوين الكالس والتجديد النباتي، وتحليل تأثير الضوء والسكروز وظروف التحضين، واستخدام الرؤية الحاسوبية في تقييم المزارع النسيجية، إلى جانب التحديات المنهجية والتطبيقية المرتبطة بهذه التقنيات.

ويهدف هذا التحليل إلى المقارنة بين التطبيقات المختلفة، وتحديد طبيعة الأدلة التي تستند إليها، وبيان حدود النتائج وإمكانات تعميمها، مع التمييز بين التطبيقات التي خضعت للتحقق التجريبي والتطبيقات التي لا تزال بحاجة إلى دراسات إضافية(Hesami & Jones, 2020 ؛ Narra et al., 2025).

أولًا: تحليل دور الذكاء الاصطناعي في تحسين تصميم التجارب النسيجية

تعتمد الطرق التقليدية في تطوير بروتوكولات زراعة الأنسجة النباتية على إجراء تجارب متتابعة لتحديد التركيب المناسب للوسط الغذائي وتراكيز منظمات النمو والظروف البيئية. وتزداد صعوبة هذه العملية عندما تتعدد المتغيرات وتتداخل تأثيراتها بصورة غير خطية، مما يجعل تحليل العلاقات بينها أكثر تعقيدًا.

وقد أوضحت مراجعة Hesami and Jones (2020) أن نماذج الذكاء الاصطناعي يمكن استخدامها لتحليل العلاقات المتداخلة بين المتغيرات التجريبية والاستجابات النباتية، والتنبؤ بنتائج معاملات لم تُختبر بعد. وشملت التطبيقات التي تناولتها المراجعة التنبؤ بنمو الأفرع والجذور، وإنتاج الكتلة الحيوية، وتكوين الكالس والأجنة الجسدية، وتحسين إنتاج المركبات الثانوية.

وتتمثل أهمية الجمع بين النماذج التنبؤية وخوارزميات التحسين في إمكانية تحديد مجموعة من المعاملات الواعدة لاختبارها داخل المختبر، بدل الاعتماد على اختبار جميع التركيبات الممكنة. ومع ذلك، فإن تقليل عدد التجارب أو استهلاك المواد والوقت يظل فائدة محتملة تتطلب التحقق منها في كل تطبيق.

كما أشارت دراسة Pepe et al. (2021) إلى أهمية التحقق التجريبي من المعاملات التي تقترحها النماذج الحاسوبية، من خلال مقارنة النتائج المتوقعة بالاستجابات النباتية الفعلية. وتبرز هذه الخطوة بوصفها عنصرًا أساسيًا في تقييم فاعلية النموذج، لأن جودة التنبؤ وحدها لا تكفي لإثبات نجاح المعاملة المقترحة.

جدول (7): مقارنة بين الأسلوب التقليدي والأسلوب القائم على الذكاء الاصطناعي في تصميم التجارب النسيجية

وجه المقارنة	الأسلوب التقليدي	الأسلوب القائم على الذكاء الاصطناعي
اختيار المعاملات	يعتمد على الخبرة والتجارب المتتابعة	يعتمد على تحليل البيانات والتنبؤ بالاستجابات
عدد التجارب	قد يتطلب اختبار عدد كبير من المعاملات	يمكن توجيه اختيار المعاملات الواعدة
تحليل التداخلات	يعتمد على التصميم التجريبي والتحليل الإحصائي	يمكنه تمثيل العلاقات غير الخطية المعقدة
الوقت والتكلفة	يتأثران بعدد التجارب والمواد المستخدمة	قد يسهم في ترشيد الموارد بعد التحقق من فاعليته
قابلية التنبؤ	ترتبط بحدود البيانات والنماذج المستخدمة	تعتمد على جودة البيانات والتحقق من النموذج
دعم اتخاذ القرار	يستند إلى نتائج التجارب وخبرة الباحث	يقدم تنبؤات وتوصيات قابلة للاختبار

المصدر :إعداد الباحثة بالاعتماد على Hesami and Jones (2020) و.Pepe et al. (2021)

ثانيًا: نتائج الدراسات المتعلقة بتحسين الأوساط الغذائية ومنظمات النمو

يمثل تركيب الوسط الغذائي أحد العوامل الأساسية المؤثرة في نجاح زراعة الأنسجة النباتية، نظرًا إلى احتوائه على مجموعة من المكونات، تشمل الأملاح المعدنية والفيتامينات ومصادر الكربون ومنظمات النمو النباتية. وتؤدي الاختلافات في تراكيز هذه المكونات والتفاعلات فيما بينها إلى تباين الاستجابات النباتية، مثل تكوين الكالس والتضاعف والتجذير والتجديد النباتي، مما يجعل تحديد التراكيب المناسبة للأوساط الغذائية من التحديات التي تتطلب تحليلًا دقيقًا للمتغيرات التجريبية.

وفي هذا السياق، تناولت دراسة Jamshidi et al. (2019) استخدام برمجة التعبير الجيني (Gene Expression Programming)والخوارزمية الجينية (Genetic Algorithm) في نمذجة مكونات الأوساط الغذائية وتحسينها، مع التركيز على زراعة أنسجة الأصول الجذرية للكمثرى. وتبرز أهمية هذه الدراسة في توضيح إمكانية دمج النماذج التنبؤية مع خوارزميات التحسين لدعم اختيار التراكيب الغذائية المناسبة للاستجابات النباتية المستهدفة.

كما تناولت دراسة Jafari and Daneshvar (2023) استخدام خوارزميات التعلم الآلي وتحسين المعاملات التجريبية للتنبؤ بالتجديد غير المباشر للأفرع في نبات زهرة الآلام الزرقاء .(Passiflora caerulea) وأبرزت الدراسة إمكانية

الاستفادة من النماذج الحاسوبية في تحليل العوامل المؤثرة في التجديد النباتي وتوجيه اختيار المعاملات المناسبة. ومع ذلك، فإن النتائج ترتبط بالنوع النباتي والظروف التجريبية المستخدمة، مما يستلزم التحقق من أدائها قبل تعميمها على أنواع نباتية أو بيئات مخبرية مختلفة.

وفيما يتعلق بمنظمات النمو النباتية، تناولت دراسة Hesami et al. (2020) استخدام آلات المتجهات الداعمة (Support Vector Machine)والشبكات العصبية الاصطناعية (Artificial Neural Networks) في نمذجة تأثير منظمات النمو على التكوين الجنيني الجسدي في نبات الأقحوان. وتوضح هذه الدراسة أهمية توظيف نماذج التعلم الآلي في تحليل العلاقات المعقدة بين تراكيز منظمات النمو والاستجابات النسيجية، بما يدعم فهم العوامل المؤثرة في نجاح عمليات التجديد النباتي.

ومن خلال المقارنة بين هذه الدراسات، يتضح أن توظيف الذكاء الاصطناعي في تحسين الأوساط الغذائية ومنظمات النمو لا يقتصر على التنبؤ بالاستجابات النباتية، بل يمتد إلى دعم اختيار المعاملات التجريبية الواعدة من خلال التكامل بين النمذجة التنبؤية وخوارزميات التحسين. ومع ذلك، فإن فاعلية هذه التطبيقات تعتمد على جودة البيانات التجريبية، ومدى تمثيلها للمتغيرات المدروسة، وإمكانية تكرار النتائج والتحقق منها مخبريًا، الأمر الذي يؤكد ضرورة الجمع بين التحليل الحاسوبي والتجارب البيولوجية قبل اعتماد البروتوكولات المقترحة.

جدول (8): عناصر الوسط الغذائي والعوامل التجريبية التي يمكن تحليلها باستخدام الذكاء الاصطناعي

مجموعة المتغيرات	أمثلة عليها	الاستجابة المستهدفة
الأملاح المعدنية	النيتروجين والفوسفور والبوتاسيوم والكالسيوم	النمو وإنتاج الكتلة الحيوية
منظمات النمو	الأوكسينات والسيتوكينينات والجبريلينات	تكوين الكالس والأفرع والجذور
مصادر الكربون	السكروز وتراكيزه المختلفة	النمو والتمايز
الظروف الفيزيائية	الضوء والحرارة وفترة التحضين	النمو والتطور
نوع الجزء النباتي	العقد والقمة النامية والأوراق والأجنة	تحسين الاستجابة النباتية
مدة المعاملة	فترة التعرض لمنظمات النمو أو الضوء	تحسين التجذير وتقليل التشوهات

المصدر: إعداد الباحثة بالاعتماد على(Jamshidi et al. (2019 ، و(Hesami et al. (2020، و.Hesami and Jones (2020)

ثالثًا: تحليل نتائج التنبؤ بتكوين الكالس والتجديد النباتي

يُعد تكوين الكالس والتجديد النباتي من العمليات الحيوية المعقدة التي تتأثر بمجموعة من العوامل المتداخلة، من أبرزها النوع والصنف النباتي، ومصدر الجزء المزروع، وتركيب الوسط الغذائي، وتراكيز منظمات النمو النباتية. وقد تختلف الاستجابات بين الأصناف حتى عند استخدام المعاملات التجريبية نفسها، مما يجعل تطوير بروتوكولات موحدة قابلة للتطبيق على جميع الأنواع والأصناف النباتية أمرًا صعبًا.

وفي هذا السياق، ناقشت دراسة Narra et al. (2025) التحديات المرتبطة بالتباين الوراثي بين الأنواع النباتية وتأثيره في إمكانية توظيف تقنيات الذكاء الاصطناعي في التكنولوجيا الحيوية النباتية، مع التأكيد على أهمية توفير بيانات تجريبية متنوعة وموثوقة لدعم بناء النماذج التنبؤية وتحسين قدرتها على التعميم.

كما تناولت دراسة Jafari and Daneshvar (2023) توظيف خوارزميات التعلم الآلي في تحليل العوامل المؤثرة في التجديد غير المباشر للأفرع في نبات زهرة الآلام الزرقاء(Passiflora caerulea) ، والتنبؤ بالاستجابات النباتية المرتبطة بالمعاملات التجريبية المختلفة. وتبرز أهمية هذه الدراسة في توضيح إمكانية استخدام النماذج الحاسوبية لدعم اختيار المعاملات الواعدة، مع ضرورة التحقق من نتائجها في الظروف المخبرية المستهدفة قبل اعتمادها أو تعميمها على أنواع نباتية أخرى.

وتشير المقارنة بين الدراسات إلى أن نماذج التعلم الآلي يمكن أن تسهم في تحديد المتغيرات الأكثر ارتباطًا بتكوين الكالس والتجديد النباتي، إلا أن دقة التنبؤ تتأثر بجودة البيانات وحجمها ومدى تمثيلها للأصناف النباتية والمعاملات التجريبية المختلفة. فإذا جرى تدريب النموذج باستخدام بيانات صنف واحد أو ظروف مخبرية محددة، فإن نجاحه في التنبؤ ضمن نطاق الدراسة لا يضمن تحقيق الأداء نفسه عند تطبيقه على أصناف أخرى أو في بيئات مخبرية مختلفة.

كما تختلف الخوارزميات في خصائصها وقدراتها التحليلية؛ إذ يمكن استخدام الغابات العشوائية (Random Forest) في تقدير الأهمية النسبية للمتغيرات، بينما تتميز الشبكات العصبية الاصطناعية (Artificial Neural Networks) بقدرتها على تمثيل العلاقات غير الخطية المعقدة بين العوامل التجريبية والاستجابات النباتية. ولذلك، ينبغي أن يستند اختيار النموذج إلى طبيعة البيانات وهدف الدراسة ومؤشرات تقييم الأداء ومدى الحاجة إلى تفسير النتائج، مع ضرورة التحقق من قدرة النموذج على التنبؤ باستخدام بيانات مستقلة.(Hesami & Jones, 2020)

رابعًا: تحليل نتائج الدراسات المتعلقة بالضوء والسكروز وظروف التحضين

تُعد ظروف الإضاءة ومصادر الكربون من العوامل المؤثرة في النمو المختبري للأنسجة النباتية، نظرًا إلى دورها في العمليات الفسيولوجية المرتبطة بالنمو والتمايز وتكوين الأفرع. وتختلف الاستجابات النباتية لهذه العوامل تبعًا للنوع النباتي وطبيعة الوسط الغذائي والظروف البيئية المستخدمة في الزراعة.

وفي هذا الإطار، تناولت دراسة Pepe et al. (2021) استخدام نماذج التعلم الآلي وخوارزميات التحسين التطورية لدراسة تأثير الإضاءة ومصادر الكربوهيدرات، بما فيها السكروز، في النمو المختبري لأفرع نبات القنب (Cannabis sativa). وركزت الدراسة على بناء نماذج تنبؤية لتحليل العلاقات بين العوامل التجريبية والاستجابات النباتية، ثم الاستفادة من خوارزميات التحسين في اقتراح المعاملات المناسبة للنمو المستهدف.

وأبرزت الدراسة أهمية التكامل بين النمذجة الحاسوبية والتحقق التجريبي، من خلال اختبار المعاملات المقترحة داخل المختبر ومقارنة النتائج الفعلية بالقيم المتوقعة. وتوضح هذه النتائج إمكانية توظيف نماذج التعلم الآلي في دعم اختيار ظروف الإضاءة ومصادر الكربون المناسبة، مع مراعاة أن النتائج ترتبط بالنوع النباتي والظروف التجريبية المستخدمة، ولا يمكن تعميمها مباشرة على جميع تطبيقات زراعة الأنسجة النباتية.

ومن الاتجاهات المستقبلية المقترحة إمكانية ربط أنظمة الإضاءة والمستشعرات بنماذج التعلم الآلي، بهدف متابعة ظروف التحضين وتحليل الاستجابات النباتية بصورة مستمرة، بما قد يدعم تطوير أنظمة أكثر قدرة على توجيه المعاملات المخبرية وتحسين التحكم في الظروف البيئية.

ومع ذلك، فإن تطبيق هذا التوجه يتطلب توفير بيانات زمنية منتظمة، وأنظمة قياس وتصوير موحدة، وإجراء اختبارات مخبرية مستقلة للتحقق من دقة النماذج وفاعلية التوصيات الناتجة عنها، قبل اعتمادها في عمليات الإنتاج أو تعميم نتائجها على مختبرات زراعة الأنسجة النباتية المختلفة.

خامسًا: تحليل استخدام الرؤية الحاسوبية في تقييم المزارع النسيجية

تمثل الرؤية الحاسوبية (Computer Vision) أحد الاتجاهات البحثية الواعدة لتوظيف الذكاء الاصطناعي في مختبرات زراعة الأنسجة النباتية، إذ تتيح إمكانية معالجة الصور الرقمية واستخلاص بيانات كمية ووصفية تتعلق بالخصائص المظهرية للأنسجة النباتية، بما قد يسهم في تطوير أساليب متابعة النمو وتقييم الاستجابات النباتية داخل المختبر.

ويمكن الاستفادة من تقنيات معالجة الصور والتعلم العميق في دراسة مجموعة من المؤشرات المظهرية، مثل مساحة الكالس، وعدد الأفرع المتكونة، وطول الجذور، والتغيرات اللونية المرتبطة بمراحل النمو والتمايز. وقد تساعد هذه التطبيقات في دعم التقييم البصري التقليدي الذي يجريه الباحث، من خلال توفير قياسات قابلة للتوثيق والمقارنة، شريطة التحقق من دقتها باستخدام طرق قياس مرجعية مناسبة.

وفي هذا السياق، تناولت دراسة أحمد وآخرين (2026) توظيف الشبكات العصبية الالتفافية (Convolutional Neural Networks, CNN) في مراقبة صحة المحاصيل وتحليل الصور النباتية. وعلى الرغم من أن هذه الدراسة لا تتناول مزارع الأنسجة النباتية بصورة مباشرة، فإنها تقدم مثالًا على الإمكانات التقنية لتحليل الصور باستخدام التعلم العميق، والتي يمكن بحث مدى ملاءمتها للتطبيق في البيئات المخبرية المتخصصة.

ومن التطبيقات المستقبلية المحتملة للرؤية الحاسوبية تطوير نماذج لتصنيف الصور الرقمية بهدف التمييز بين العينات النباتية السليمة والعينات التي تظهر عليها مؤشرات تلوث، اعتمادًا على الخصائص المظهرية، مثل التغيرات اللونية والعكارة وأنماط النمو غير الطبيعية. ومع ذلك، فإن هذه المؤشرات لا تكفي وحدها لإثبات وجود تلوث ميكروبي أو تحديد نوعه، نظرًا إلى احتمال تشابه بعض مظاهر التلوث مع التغيرات الفسيولوجية الناتجة عن ظروف الاستزراع.

ولذلك، فإن الكشف المبكر عن التلوث الميكروبي داخل المزارع النسيجية لا ينبغي عرضه بوصفه تطبيقًا مثبت الفاعلية استنادًا إلى الأدبيات المستعرضة وحدها؛ إذ يتطلب تطويره إنشاء قواعد بيانات متخصصة تضم صورًا لعينات سليمة وملوثة، وتحديد حالات التلوث باستخدام وسائل تشخيص مخبرية معتمدة، وإجراء اختبارات مستقلة لتقييم حساسية النماذج ونوعيتها ودقتها وقدرتها على التمييز بين الحالات المختلفة.

كما يتأثر أداء نماذج تحليل الصور بجودة البيانات المستخدمة في التدريب، ودقة تصنيف العينات، واختلاف ظروف الإضاءة والتصوير والخلفيات والأوعية الزجاجية ومراحل النمو النباتي. وقد تؤدي هذه الاختلافات إلى انخفاض أداء النماذج عند تطبيقها في مختبرات تختلف ظروفها عن البيئة التي جُمعت فيها بيانات التدريب.

وبناءً على ذلك، فإن تطوير تطبيقات موثوقة للرؤية الحاسوبية في زراعة الأنسجة النباتية يستلزم توحيد إجراءات التصوير، وتوفير مجموعات بيانات متنوعة، والتحقق من أداء النماذج باستخدام عينات مستقلة تمثل أنواعًا نباتية وظروفًا

مخبرية مختلفة. كما ينبغي التمييز بين التطبيقات التي خضعت للاختبار التجريبي المباشر في المزارع النسيجية والتطبيقات المقترحة المستمدة من التطورات التقنية في مجالات الزراعة الذكية الأخرى.

سادسًا: التحليل المقارن للدراسات السابقة

يكشف التحليل المقارن للدراسات العلمية المستعرضة عن وجود تباين في طبيعة تطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، سواء من حيث الأهداف البحثية أو الخوارزميات المستخدمة أو الأنواع النباتية المدروسة أو مستوى التحقق التجريبي من النتائج. ويمكن التمييز في هذا السياق بين الدراسات المرجعية التي تناولت الاتجاهات العامة والتحديات العلمية، والدراسات التطبيقية التي اعتمدت على بيانات تجريبية لبناء نماذج تنبؤية وتحسين المعاملات المخبرية.

فقد قدمت مراجعتا Hesami and Jones (2020) و Narra et al. (2025) إطارًا عامًا لفهم إمكانات توظيف الذكاء الاصطناعي في التكنولوجيا الحيوية النباتية، مع إبراز التحديات المتعلقة بجودة البيانات وتفسير النماذج وإمكانية تعميم النتائج. وتتمثل أهمية هاتين المراجعتين في تحديد مجالات التطبيق والاتجاهات البحثية، إلا أنهما لا تمثلان في حد ذاتهما دليلًا تجريبيًا مستقلًا على فاعلية جميع التطبيقات التي تناولتاها.

وفي المقابل، قدمت دراسات تطبيقية، مثل Jamshidi et al. (2019) و Hesami et al. (2020) و Fallah Ziarani et al. (2022)، أمثلة على توظيف النماذج الحاسوبية في تحليل العوامل المؤثرة في زراعة الأنسجة النباتية، بما يشمل تحسين مكونات الأوساط الغذائية، ونمذجة تأثير منظمات النمو، والتنبؤ بتكوين الكالس. كما تناولت دراسة Jafari and Daneshvar (2023) التنبؤ بالتجديد غير المباشر للأفرع، بينما ركزت دراسة Pepe et al. (2021) على تحسين ظروف الإضاءة ومصادر الكربوهيدرات في الإكثار الدقيق.

ومن حيث التقنيات المستخدمة، شملت الدراسات الشبكات العصبية الاصطناعية(ANN) ، وآلات المتجهات الداعمة (SVM)، والغابات العشوائية(RF) ، وبرمجة التعبير الجيني(GEP) ، والخوارزميات الجينية .(GA) ويعكس هذا التنوع تعدد الأساليب المتاحة لتحليل العلاقات غير الخطية بين المتغيرات التجريبية والاستجابات النباتية، إلا أنه لا يسمح بتحديد خوارزمية واحدة بوصفها الأفضل في جميع التطبيقات.

وتتأثر كفاءة النماذج بطبيعة البيانات وحجمها، وعدد المتغيرات المدروسة، ونوع الاستجابة النباتية المستهدفة، وطريقة تقسيم البيانات إلى مجموعات تدريب واختبار، فضلًا عن مؤشرات تقييم الأداء المستخدمة. ولذلك، فإن المقارنة بين نتائج الدراسات ينبغي أن تراعي اختلاف تصميماتها التجريبية، بدل الاعتماد على قيم الدقة التنبؤية وحدها للحكم على تفوق نموذج معين.

ومن حيث مستوى التحقق التجريبي، تبرز أهمية الدراسات التي لم تقتصر على بناء النماذج التنبؤية، بل استخدمت مخرجاتها لاقتراح معاملات جديدة واختبارها داخل المختبر. وتقدم دراسة Pepe et al. (2021) مثالًا على هذا الاتجاه من خلال الجمع بين النمذجة التنبؤية وخوارزميات التحسين والتحقق من الاستجابات النباتية الفعلية. ويُعد هذا المستوى من التحقق أكثر ارتباطًا بإمكانات التطبيق العملي من الاكتفاء بتقييم أداء النموذج على البيانات المتاحة.

كما يوضح التحليل أن التطبيقات المتعلقة بالتنبؤ بالاستجابات النباتية وتحسين الأوساط الغذائية ومنظمات النمو تستند إلى دراسات تجريبية مباشرة، في حين أن بعض التطبيقات الأخرى، مثل المراقبة الرقمية المتكاملة والكشف الآلي المبكر عن التلوث داخل المزارع النسيجية، لا تزال بحاجة إلى أدلة تجريبية متخصصة قبل الحكم على فاعليتها.

وبناءً على ذلك، يمكن استخلاص أن القيمة العلمية لتوظيف الذكاء الاصطناعي في زراعة الأنسجة النباتية لا ترتبط بتعقيد الخوارزمية المستخدمة وحده، وإنما بقدرتها على تقديم تنبؤات موثوقة وتوجيه اختيار معاملات قابلة للتحقق والتكرار داخل المختبر. كما يؤكد التحليل أهمية تطوير قواعد بيانات تجريبية منظمة، وتوحيد إجراءات تقييم النماذج، وتعزيز التكامل بين النمذجة الحاسوبية والتحقق البيولوجي، بوصفها متطلبات أساسية للانتقال من التطبيقات البحثية المحدودة إلى أنظمة زراعة نسيجية ذكية أكثر موثوقية.

جدول (9): التحليل المقارن لأبرز الدراسات الواردة في البحث

الدراسة	طبيعة الدراسة	مجال التطبيق	أبرز الدلالات	النماذج أو التقنيات
Hesami & Jones (2020)	مراجعة علمية	تطبيقات الذكاء الاصطناعي في زراعة الأنسجة	توضيح مجالات التنبؤ والتحسين والتحديات المرتبطة بالبيانات والتعميم	ANNو SVMو RF وخوارزميات التحسين
Jamshidi et al. (2019)	دراسة تطبيقية بحسب الملف	تحسين مكونات الوسط الغذائي	إمكانية الجمع بين التنبؤ وتحسين المعاملات	برمجة التعبير الجيني والخوارزمية الجينية
Hesami et al. (2020)	دراسة تطبيقية	التكوين الجنيني الجسدي في الأقحوان	نمذجة تأثير منظمات النمو في الاستجابة النباتية	SVMوANN

	بحسب الملف			
Pepe et al. (2021)	دراسة تجريبية	تحسين الضوء والسكروز للنمو المختبري	أهمية التحقق التجريبي من المعاملات المقترحة	التعلم الآلي وخوارزميات التحسين
Jafari & Daneshvar (2023)	دراسة تطبيقية بحسب الملف	التجديد غير المباشر للأفرع	تحليل العوامل المرتبطة بالتجديد واقتراح معاملات مناسبة	خوارزميات التعلم الآلي
Narra et al. (2025)	مراجعة علمية	الذكاء الاصطناعي في التكنولوجيا الحيوية النباتية	عرض التطبيقات الحديثة وتحديات البيانات والتعميم	التعلم الآلي والتعلم العميق والرؤية الحاسوبية

المصدر :إعداد الباحثة بالاعتماد على الدراسات الواردة في البحث الأصلي.

يقتصر التحليل المقارن على المعلومات الوصفية المتاحة في الدراسات المستعرضة، نظرًا إلى اختلاف التصميمات التجريبية والأنواع النباتية والخوارزميات ومؤشرات تقييم النماذج. ولذلك، لا تسمح المقارنة بتحديد خوارزمية واحدة بوصفها الأفضل في جميع تطبيقات زراعة الأنسجة النباتية، كما لا يمكن تعميم النتائج التجريبية على أنواع نباتية أو ظروف مخبرية مختلفة دون تحقق مستقل.سابعًا: أبرز النتائج المستخلصة من تحليل الدراسات

يشير تحليل الدراسات الواردة في البحث إلى أن نماذج الذكاء الاصطناعي توفر إمكانات لتحليل العلاقات المعقدة وغير الخطية بين المتغيرات التجريبية والاستجابات النباتية، ولا سيما في التطبيقات التي تتداخل فيها مكونات الوسط الغذائي ومنظمات النمو والظروف البيئية.

كما يوضح التحليل أهمية التكامل بين النماذج التنبؤية وخوارزميات التحسين؛ إذ يمكن استخدام النموذج لتقدير الاستجابة النباتية، ثم الاستفادة من خوارزمية التحسين في اقتراح معاملات واعدة لاختبارها داخل المختبر.

وتؤكد التطبيقات التجريبية المعروضة أهمية التحقق البيولوجي من التنبؤات؛ لأن ارتفاع مؤشرات الأداء الإحصائي لا يعني بالضرورة نجاح المعاملة عند تطبيقها عمليًا.

كما تكشف الدراسات عن تحديات تتعلق بقابلية تعميم النماذج، خاصة عند تطويرها باستخدام بيانات نوع نباتي واحد أو صنف محدد أو ظروف مخبرية معينة.

وتبرز جودة البيانات وتوحيد طرق القياس والتسجيل بوصفهما من المتطلبات الأساسية لتطوير نماذج قابلة للمقارنة والتقييم.

أما الانتقال نحو المنصات المتكاملة والمختبرات الذكية، فيمثل اتجاهًا مستقبليًا يتطلب الربط بين تصميم التجارب وتحليل البيانات وبناء النماذج والتحقق من نتائجها.

جدول (10): النتائج الرئيسة المستخلصة من تحليل الدراسات

النتيجة	الدلالة العلمية
إمكانية تمثيل العلاقات غير الخطية	دعم تحليل العمليات النسيجية المعقدة
اقتراح معاملات تجريبية واعدة	إمكانية توجيه تصميم التجارب
تحسين مكونات الوسط ومنظمات النمو	دعم تطوير بروتوكولات الإكثار والتجديد
التحقق من بعض التنبؤات مخبريًا	أهمية الانتقال من النمذجة إلى التطبيق
محدودية تعميم النماذج	ضرورة الاختبار على أصناف وظروف مختلفة
نقص البيانات المتخصصة	الحاجة إلى قواعد بيانات موحدة
تطور التطبيقات الحاسوبية المتكاملة	إمكانية تطوير مختبرات أكثر اعتمادًا على البيانات

المصدر :إعداد الباحثة بالاعتماد على(2020) Hesami and Jones ، و(2021) Pepe et al.، و Narra et al. (2025)، وفق النتائج المعروضة في البحث.

ثامنًا: التحديات المنهجية والتطبيقية

تواجه تطبيقات الذكاء الاصطناعي في مزارع الأنسجة النباتية مجموعة من التحديات المنهجية والتطبيقية التي تؤثر في دقة النماذج وإمكانية الاستفادة منها.

1. **محدودية حجم البيانات :**تُجرى تجارب زراعة الأنسجة في كثير من الحالات باستخدام عدد محدود من المعاملات والمكررات، مما قد يزيد احتمال الإفراط في التوافق، أي نجاح النموذج في تمثيل بيانات التدريب دون تحقيق أداء مماثل عند استخدام بيانات جديدة.
2. **اختلاف طرق القياس والتسجيل :**تتباين الدراسات في مؤشرات الاستجابة النباتية المستخدمة، مثل عدد الأفرع وطولها والوزن الطازج ونسبة التجذير، كما تختلف فترات التحضين والظروف البيئية، مما يصعب المقارنة المباشرة بين نتائج النماذج.
3. **قابلية تفسير النماذج :**قد توفر بعض الخوارزميات تنبؤات جيدة دون تقديم تفسير واضح للعلاقات البيولوجية المؤثرة في النتائج، مما يستدعي الاهتمام بالنماذج القابلة للتفسير وتحليل أهمية المتغيرات.
4. **محدودية قابلية التعميم :**قد ينخفض أداء النموذج عند تطبيقه على أنواع أو أصناف نباتية أو ظروف مخبرية تختلف عن البيانات المستخدمة في تطويره، مما يؤكد أهمية التحقق الخارجي.
5. **ارتفاع تكلفة الأتمتة :**قد تتطلب الأنظمة المتقدمة تجهيزات تشمل الكاميرات والمستشعرات والروبوتات وأنظمة التحكم، وهو ما قد يشكل عائقًا أمام المختبرات محدودة الموارد.
6. **نقص الخبرات المشتركة :**يحتاج تطوير التطبيقات الذكية إلى تعاون بين المتخصصين في زراعة الأنسجة النباتية وعلوم الحاسوب والإحصاء والهندسة، لضمان جودة تصميم التجارب وتفسير النتائج.

جدول (11): تحديات استخدام الذكاء الاصطناعي وسبل معالجتها

التحدي	التأثير	المعالجة المقترحة
صغر حجم البيانات	ارتفاع خطر الإفراط في التوافق وضعف التعميم	زيادة المكررات وتبادل البيانات بين المختبرات
اختلاف طرق القياس	صعوبة المقارنة ودمج البيانات	وضع بروتوكولات موحدة للتسجيل
عدم توازن البيانات	انحياز النموذج نحو النتائج الأكثر تكرارًا	استخدام أساليب تحقق مناسبة ومعالجة عدم التوازن
ضعف قابلية التفسير	صعوبة فهم الأساس البيولوجي للتنبؤ	استخدام نماذج قابلة للتفسير وتحليل أهمية المتغيرات
اختلاف الأنواع والأصناف	احتمال انخفاض الدقة عند التعميم	إجراء تحقق خارجي متعدد الأصناف
ارتفاع تكلفة الأتمتة	محدودية التطبيق في بعض المختبرات	تبني حلول تدريجية ومنخفضة التكلفة
نقص الخبرات المشتركة	ضعف تصميم النماذج أو تفسير النتائج	تشكيل فرق تجمع علوم النبات والحاسوب والإحصاء

المصدر :إعداد الباحثة بالاعتماد على Hesami and Jones (2020) و.Narra et al. (2025)

تاسعًا: التوصيات

في ضوء التحليل السابق، يوصي البحث بإنشاء قواعد بيانات وطنية وعربية متخصصة في مزارع الأنسجة النباتية، تتضمن النوع والصنف النباتي ومصدر الجزء المزروع ومكونات الوسط الغذائي ومنظمات النمو وظروف التحضين والاستجابات الناتجة، مع اعتماد طرق موحدة لتسجيل البيانات وتنظيمها.

كما يوصى بإجراء دراسات تطبيقية تجمع بين بناء النماذج الحاسوبية والتحقق المخبري، وعدم الاكتفاء بتقييم الأداء باستخدام بيانات التدريب والاختبار. وينبغي أن تتضمن هذه الدراسات مقارنة المعاملات التي تقترحها النماذج بمعاملات ضابطة وبالبروتوكولات التقليدية، لتحديد مقدار التحسن الفعلي في النتائج.

ويوصى كذلك باختبار النماذج باستخدام بيانات وأصناف نباتية لم تدخل في مرحلة التدريب، ويفضل إجراء التحقق في أكثر من مختبر لتقييم مدى قابلية النتائج للتعميم.

كما ينبغي تشجيع استخدام نماذج الذكاء الاصطناعي القابلة للتفسير، التي تساعد على تحديد المتغيرات الأكثر تأثيرًا في الاستجابات النباتية، بما يدعم فهم العلاقات البيولوجية المرتبطة بعمليات النمو والتجديد.

ويوصي البحث بتطوير أنظمة تصوير معيارية منخفضة التكلفة داخل مختبرات مزارع الأنسجة النباتية، بهدف جمع صور دورية للعينات تحت ظروف ثابتة، والاستفادة منها في تقييم النمو وبناء قواعد بيانات مناسبة لتطوير تطبيقات الرؤية الحاسوبية.

كما يوصى بتعزيز التعاون بين تخصصات زراعة الأنسجة النباتية وعلوم النبات والحاسوب والإحصاء والهندسة، وتطوير برامج تدريبية في تحليل البيانات والتعلم الآلي ضمن برامج التكنولوجيا الحيوية الزراعية.

وأخيرًا، يوصى بتوجيه الدراسات المستقبلية نحو النباتات ذات الأهمية الاقتصادية والغذائية والطبية، ولا سيما الأنواع التي تواجه صعوبات في الإكثار أو التجديد داخل المختبر، مع التركيز على التحقق من النتائج قبل التوسع في تطبيق النماذج الذكية.

الإضافة العلمية للبحث والإطار المقترح للزراعة النسيجية الذكية

تتمثل الإضافة العلمية لهذا البحث في تقديم إطار تحليلي ومفاهيمي لتطبيقات الذكاء الاصطناعي في زراعة الأنسجة النباتية، يقوم على الربط بين البيانات التجريبية والنمذجة التنبؤية وخوارزميات التحسين والتحقق المخبري، مع التمييز بين التطبيقات المدعومة بأدلة تجريبية والتطبيقات التي لا تزال بحاجة إلى مزيد من البحث والتحقق. ويسعى هذا الإطار إلى توضيح الآلية التي يمكن من خلالها توظيف التقنيات الذكية في دعم تطوير بروتوكولات الزراعة النسيجية وتحسين عملية اختيار المعاملات التجريبية.

ويقوم الإطار المقترح على أربع مراحل مترابطة، تتمثل فيما يأتي:

المرحلة الأولى: جمع البيانات التجريبية وتنظيمها

تتضمن هذه المرحلة جمع البيانات المتعلقة بالنوع والصنف النباتي، ومصدر الجزء النباتي المزروع، ومكونات الوسط الغذائي، وتراكيز منظمات النمو، والظروف البيئية داخل المختبر، إلى جانب تسجيل الاستجابات النباتية الناتجة، مثل تكوين الكالس والتجذير والتضاعف والتجديد النباتي. وتهدف هذه المرحلة إلى توفير قاعدة بيانات منظمة يمكن الاعتماد عليها في بناء النماذج التنبؤية.

المرحلة الثانية: بناء النماذج التنبؤية

تتمثل هذه المرحلة في استخدام تقنيات التعلم الآلي والشبكات العصبية الاصطناعية لتحليل العلاقات بين المتغيرات التجريبية والاستجابات النباتية، وبناء نماذج قادرة على التنبؤ بالنتائج المحتملة للمعاملات المختلفة. كما تشمل تقييم أداء النماذج باستخدام بيانات اختبار مناسبة، بما يساعد على تحديد مدى دقتها وموثوقيتها وحدود إمكانية تعميم نتائجها.

المرحلة الثالثة: تحسين المعاملات التجريبية

تعتمد هذه المرحلة على توظيف خوارزميات التحسين، مثل الخوارزميات الجينية، بالتكامل مع النماذج التنبؤية، بهدف اقتراح توليفات مناسبة من مكونات الوسط الغذائي ومنظمات النمو والظروف البيئية التي يُتوقع أن تحقق الاستجابات النباتية المستهدفة. وتسهم هذه المرحلة في توجيه اختيار المعاملات الواعدة لإخضاعها للاختبار المخبري، دون اعتبار التوصيات الحاسوبية بديلًا عن التجارب الفعلية.

المرحلة الرابعة: التحقق المخبري من النتائج

تتضمن هذه المرحلة اختبار المعاملات المقترحة داخل المختبر، ومقارنة الاستجابات النباتية الفعلية بالقيم التي تنبأت بها النماذج الحاسوبية، بهدف تقييم مدى دقة التنبؤ وفاعلية المعاملات المقترحة. كما يمكن الاستفادة من البيانات الجديدة الناتجة عن التجارب في إعادة تدريب النماذج وتحسين أدائها، بما يتيح تطوير عملية تكرارية تجمع بين التحليل الحاسوبي والتحقق التجريبي.

ويؤكد الإطار المقترح أن توظيف الذكاء الاصطناعي في زراعة الأنسجة النباتية ينبغي أن يستند إلى التكامل بين التحليل الحاسوبي والتجارب البيولوجية، وأن التحقق المخبري يمثل شرطًا أساسيًا قبل اعتماد المعاملات التي تقترحها النماذج الذكية أو تعميم نتائجها على أنواع نباتية وظروف تجريبية مختلفة.

ويمثل هذا الإطار تصورًا مفاهيميًا مستخلصًا من التحليل النقدي للأدبيات العلمية التي تناولها البحث، وليس نظامًا تجريبيًا جرى تطويره أو اختباره ضمن هذه الورقة. وتكمن أهميته في تقديم تصور منظم للخطوات التي يمكن أن تستند إليها الدراسات المستقبلية عند تطوير أنظمة زراعة نسيجية ذكية قائمة على البيانات والنمذجة التنبؤية والتحسين والتحقق التجريبي.

الخاتمة

تناول هذا البحث تطبيقات الذكاء الاصطناعي في مزارع الأنسجة النباتية، من خلال تحليل الدراسات العلمية التي بحثت استخدام التعلم الآلي والشبكات العصبية الاصطناعية وخوارزميات التحسين والرؤية الحاسوبية في تطوير العمليات المرتبطة بالزراعة النسيجية.

وأظهر تحليل الدراسات أن تقنيات الذكاء الاصطناعي توفر إمكانات واعدة في نمذجة العلاقات المعقدة بين مكونات الأوساط الغذائية ومنظمات النمو والظروف البيئية والاستجابات النباتية، إلى جانب المساعدة في التنبؤ بتكوين الكالس والتجذير والتجديد النباتي. كما أبرزت الدراسات أهمية الجمع بين النماذج التنبؤية وخوارزميات التحسين في اقتراح معاملات تجريبية يمكن اختبارها داخل المختبر.

وتبين أن فاعلية هذه التطبيقات تعتمد على طبيعة البيانات المستخدمة وجودتها، ونوع النبات، والمتغيرات التجريبية، وطريقة تقييم النماذج والتحقق من نتائجها. ولذلك، فإن نجاح النموذج في التنبؤ داخل نطاق دراسة معينة لا يضمن إمكانية تعميم نتائجه على أصناف نباتية أو ظروف مخبرية مختلفة.

كما أوضح التحليل أن استخدام الرؤية الحاسوبية في متابعة نمو الأنسجة النباتية وتحليل خصائصها المظهرية يمثل مجالًا واعدًا، إلا أن التطبيقات المتعلقة بالكشف المبكر عن التلوث تحتاج إلى مزيد من الدراسات التجريبية المتخصصة. كذلك لا يمكن الجزم بأن استخدام الذكاء الاصطناعي يؤدي بالضرورة إلى تقليل الوقت والتكاليف دون إجراء مقارنات كمية مناسبة.

وتتمثل أبرز التحديات في محدودية قواعد البيانات المتخصصة، واختلاف طرق القياس والتسجيل، وصعوبة تفسير بعض النماذج، ومحدودية قابليتها للتعميم، إلى جانب المتطلبات التقنية والبشرية اللازمة لتطبيقها.

وفي ضوء ذلك، يخلص البحث إلى أن الانتقال نحو مزارع أنسجة نباتية ذكية يتطلب التكامل بين جمع البيانات التجريبية وتنظيمها، وبناء النماذج التنبؤية، واستخدام خوارزميات التحسين، والتحقق المخبري من المعاملات المقترحة. ويُعد هذا التكامل أساسًا لتطوير تطبيقات أكثر اعتمادًا على البيانات، مع المحافظة على الدور الأساسي للتجارب البيولوجية في تقييم النتائج وإثبات فاعليتها.

قائمة المراجع

أولًا: المراجع العربية

1. أحمد، أيمن أحمد محمد، والمبروك، حاتم أحمد، ورحومة، قيس ميلود، والبراني، أحمد علي. (2026). دعم الزراعة الذكية لمراقبة صحة المحاصيل باستخدام تقنيات التعلم العميق .CNN *مجلة الأبعاد العلمية والإنسانية*، *2*(1)، 882.896–
2. السامر، إسراء، والبندر، انتصار، وكاظم، مصطفى، والسامر، شيماء. (2026). دور تقنية النانو في السيطرة على التلوث البكتيري في زراعة الأنسجة النباتية: مراجعة .*مجلة الكوفة للعلوم*.
3. قابيل، طارق يوسف .(2016) .*الزراعة النسيجية: تكنولوجيا زراعة الخلايا والأنسجة والأعضاء النباتية*.
4. نصر الدين، تيمور، وعبد المقصود، إبراهيم، ونجاتي، محمد أحمد محمد .(2014) .*تقنيات وتطبيقات زراعة الأنسجة النباتية*.

ثانيًا: المراجع الأجنبية

1. Fallah Ziarani, M., Tohidfar, M., & Navvabi, M. (2022). Modeling and optimizing in vitro percentage and speed callus induction of carrot via multilayer perceptron-single point discrete GA and radial basis function. *BMC Biotechnology, 22*, Article 34. DOI: 10.1186/s12896-022-00764-4.
2. Hesami, M., & Jones, A. M. P. (2020). Application of artificial intelligence models and optimization algorithms in plant cell and tissue culture. *Applied Microbiology and Biotechnology, 104*(22), 9449–9485. DOI: 10.1007/s00253-020-10888-2.
3. Hesami, M., & Jones, A. M. P. (2021). Modeling and optimizing callus growth and development in Cannabis sativa using random forest and support vector machine in combination with a genetic algorithm. *Applied Microbiology and Biotechnology, 105*, 5201–5212. DOI: 10.1007/s00253-021-11375-y.
4. Hesami, M., Naderi, R., Tohidfar, M., & Yoosefzadeh-Najafabadi, M. (2020). Development of support vector machine-based model and comparative analysis with artificial neural network for modeling the plant tissue culture procedures: Effect of plant growth regulators on somatic embryogenesis of chrysanthemum, as a case study. *Plant Methods, 16*, Article 112. DOI: 10.1186/s13007-020-00655-9.
5. Isak, M. A., Fatima, S., Haider, I., Sajedi, S., Abidin, Z. U., & Karataş, M. (2025). Applications of artificial intelligence and machine learning in plant tissue culture. *International Journal of Agricultural and Natural Sciences, 18*(3), 392–412.
6. Jafari, M., & Daneshvar, M. H. (2023). Prediction and optimization of indirect shoot regeneration of Passiflora caerulea using machine learning and optimization algorithms. *BMC Biotechnology, 23*, Article 27. DOI: 10.1186/s12896-023-00796-4.
7. Jamshidi, S., Yadollahi, A., Arab, M. M., Soltani, M., Eftekhari, M., Sabzalipoor, H., Sheikhi, A., & Shiri, J. (2019). Combining gene expression programming and genetic algorithm as a powerful hybrid modeling approach for pear rootstocks tissue culture media formulation. *Plant Methods, 15*, Article 136. DOI: 10.1186/s13007-019-0520-y.
8. Narra, M., Ray, A., Polley, B., Yang, H., & Bhowmik, P. K. (2025). AI-driven advances in plant biotechnology: Sharpening the edge of plant tissue culture and

genome editing. *Frontiers in Plant Science, 16*, Article 1718810. DOI: 10.3389/fpls.2025.1718810.

9. Pepe, M., Hesami, M., Small, F., & Jones, A. M. P. (2021). Comparative analysis of machine learning and evolutionary optimization algorithms for precision micropropagation of Cannabis sativa: Prediction and validation of in vitro shoot growth and development based on the optimization of light and carbohydrate sources. *Frontiers in Plant Science, 12*, Article 757869. DOI: 10.3389/fpls.2021.757869.