

The role of machine learning in improving resource consumption monitoring: A survey study

Qasim H. Al Hatimi*

financial affair, directorate of education of Dhi Qar, Nasiriyah, Iraq

Article information:

Received: 28-07- 2025

Revised: 31-08- 2025

Accepted: 2-10- 2025

Published: 25-06- 2026

Corresponding author:

Qasim H. Al Hatimi

qasimhabeeb163@gmail.com



This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).

Abstract:

This research aims to provide a theoretical and applied framework for employing machine learning algorithms in management accounting and costing systems.

The research focuses on the importance of improving resource consumption monitoring, accurately tracking cost behavior, identifying unutilized energy, and supporting decision-making through historical data analysis to enhance the accuracy of production reports.

To achieve the research objective, a descriptive approach was adopted, drawing on available studies. A field study was also used, using a questionnaire to collect data from the research sample (the Electrical Cables and Wires Factory - Ur General Company).

The research also reached a number of conclusions, most notably that employing machine learning algorithms contributes to improving the prediction of quantitative resource consumption, which helps detect deviations and identify their potential causes, and enhances the accuracy and comprehensiveness of production reports.

The research concluded with a set of recommendations, most notably the need to establish an integrated data management system that includes operational data processing to provide real-time solutions and alternatives that contribute to supporting decision-making related to rationalizing resource consumption.

Keywords: Machine learning, resource consumption monitoring, quantitative forecasting, anomaly detection, cost measurement, production reporting, data classification.

Conclusions:

1. Machine learning technology contributes to improving the accuracy of production reports related to resource consumption through data analysis.
2. Machine learning technology helps provide innovative solutions for redesigning production processes and supporting decision-making related to rationalizing resource consumption.
3. Machine learning technology supports optimal resource allocation by analyzing the relationship between consumed resources and production activities.
4. Machine learning technology helps process data, enhancing the ability to detect deviations in real time, which helps quickly identify potential problems.
5. The application of machine learning contributes to quantitative production forecasting related to resource consumption, enhancing the accuracy and comprehensiveness of production processes, and identifying potential problems.

دور تقنية التعلم الآلي في تحسين مراقبة استهلاك الموارد: دراسة استطلاعية

قاسم حبيب ناشد الحاتمي*
الشؤون المالية، مديرية تربية ذي قار، الناصرية، العراق

المستخلص:

يهدف هذا البحث إلى تقديم إطار نظري وتطبيقي لتوظيف خوارزميات التعلم الآلي على أنظمة المحاسبة الإدارية والتكاليف. يركز البحث على أهمية تحسين مراقبة استهلاك الموارد في تتبع سلوك التكلفة بدقة وتحديد الطاقة غير المستغلة ودعم اتخاذ القرار من خلال تحليل البيانات التاريخية لتعزيز الدقة في تقارير الإنتاج. ولتحقيق هدف البحث تم اعتماد المنهج الوصفي والاستعانة بالدراسات المتاحة، إلى جانب أسلوب الدراسة الميدانية باستخدام أداة الاستبانة لجمع البيانات من عينة البحث (معمل القابلات الأسلاك الكهربائية - شركة اور العامة). كما توصل البحث الى مجموعة من الاستنتاجات، أهمها أن توظيف خوارزميات التعلم الآلي يُسهم في تحسين التنبؤ بالاستهلاك الكمي للموارد مما يساعد على الكشف عن الانحرافات وتحديد اسبابها المحتملة، ويُعزز دقة وشمولية تقارير الإنتاج. واختتم البحث بمجموعة من التوصيات، أهمها ضرورة إنشاء نظام متكامل لإدارة البيانات يتضمن معالجة البيانات التشغيلية، لتوفير الحلول والبدائل آنية تُسهم في دعم اتخاذ القرارات المتعلقة بترشيد استهلاك الموارد.

الكلمات المفتاحية: التعلم الآلي، مراقبة استهلاك الموارد، التنبؤ الكمي، اكتشاف الانحرافات، قياس للتكلفة، إعداد تقارير الإنتاج، تصنيف البيانات.

معلومات البحث:

- تاريخ استلام البحث: 2025-07-28
- تاريخ ارسال التعديلات: 2025-08-31
- تاريخ قبول النشر: 2025-10-02
- تاريخ النشر: 2026-06-25

المؤلف المراسل:

قاسم حبيب ناشد الحاتمي
qasimhabeeb163@gmail.com



هذا العمل مرخص بموجب
المشاع الإبداعي نسب المصنف 4.0 دولي
(CC BY 4.0)

المقدمة:

إن التعلم الآلي هو أحد فروع الذكاء الاصطناعي، والذي نشأ من فكرة مفادها أنه يمكن تعليم الآلات كيفية التعلم بطرق مماثلة لكيفية تعلم البشر، وبسبب ظهور الإنترنت والتقدم في سرعة المعالجة الحاسوبية وتخزين البيانات، جعل التعلم الآلي الآن مكوناً مهماً للحياة العملية الحديثة وكما أن التقدم التكنولوجي جعل البيانات أكثر سهولة في الوصول إليها، لم يعد تخزين البيانات ومعالجتها بهذه السهولة كما هو الحال اليوم.

وقد جاء هذا التطور بفرص وتحديات جديدة، يصبح اتخاذ القرار في أي مجال أكثر كفاءة عندما يكون مدعوماً بتحليل البيانات الكبيرة خاصة عندما يتعلق الأمر بالتنبؤ بنتائج القرارات وعلى الرغم من أن اتخاذ القرار ينطوي دائماً على نتائج مستقبلية، فإن تقنية التعلم الآلي تُمكن الحاسوب من تعلم المعرفة وفهمها والاحتفاظ بها بمرور الوقت، ان اتخاذ القرارات بتطبيق التعلم الآلي مُثمراً للغاية في هذا المجال، إذ يُمكن من اتخاذ قرارات ذكية تلقائياً بناءً على البيانات لتحسين الأداء في نظام التصنيع وتحليل البيانات التاريخية المتعلقة باستهلاك الموارد وتعزيز دقة وشمولية عمليات الإنتاج هذا يؤدي الى دقة قياس التكلفة من خلال الاستغلال الأمثل للموارد المتاحة للوحدة الاقتصادية بهدف تخفيض تكاليف الإنتاج والكشف عن الطاقة غير المستغلة وتعظيم قيمة المنتج

المحور الأول منهجية البحث

1. مشكلة البحث:

تكمن المشكلة في عجز أنظمة المحاسبة التقليدية عن تحديد وقياس الطاقة الإنتاجية غير المستغلة مما يؤدي هذا العجز إلى تضخم غير واقعي في تكاليف المنتج، والتي تُضاف إلى إجمالي التكاليف، مما يُعطي صورة مضللة عن الأداء ويجعل قرارات الإنتاج غير دقيقة. ويُضعف هذا العجز قدرة الإدارة على اتخاذ القرارات لاعتمادها على بيانات غير دقيقة حول أداء الإنتاج وحجم الموارد المستهلكة.

بناءً على هذه المشكلة، يُطرح السؤال التالي: هل يُمكن توظيف تقنية التعلم الآلي في أنظمة المحاسبة التكاليف لتحسين مراقبة استهلاك الموارد، وقياس التكاليف بدقة، وتحديد الطاقة الإنتاجية غير المستغلة في الوحدات الصناعية المحلية؟

2. أهمية البحث:

أهمية هذا البحث تكمن في توفير إطار نظري وتطبيقي، وتبسيط الضوء على الفجوة بين أنظمة المحاسبة الإدارية والتكاليف التقليدية والتقنيات الرقمية المعاصرة، ومن خلال دمج تقنيات التعلم الآلي مع محاسبة التكاليف، ويتحقق ذلك من خلال توظيف أدوات التحليل التنبؤي التي توفرها تقنية التعلم الآلي، والتي تساعد على قياس التكاليف بشكل آلي وتحديد مصادر الطاقة غير المستغلة، ويدعم

هذا التحول بشكل مباشر عملية اتخاذ القرارات الإدارية في بيئة الإنتاج، مما يعزز قدرتها على التخطيط الاستراتيجي في عصر التحول الرقمي.

3. أهداف البحث:

- توظيف أبعاد تقنية التعلم الآلي لتحديد الانحرافات المحتملة وقياس الطاقة غير المستغلة.
- توظيف أبعاد تقنية التعلم الآلي لتوفير قياس دقيق للتكلفة من خلال مراقبة استهلاك الموارد.
- توظيف أبعاد تقنية التعلم الآلي لتوفير معلومات حول سلوك التكلفة تساعد إعداد تقارير الإنتاجية.
- توظيف أبعاد تقنية التعلم الآلي لتحليل بيانات الإنتاج لدعم اتخاذ قرارات التخطيط والتنفيذ والإنتاج.

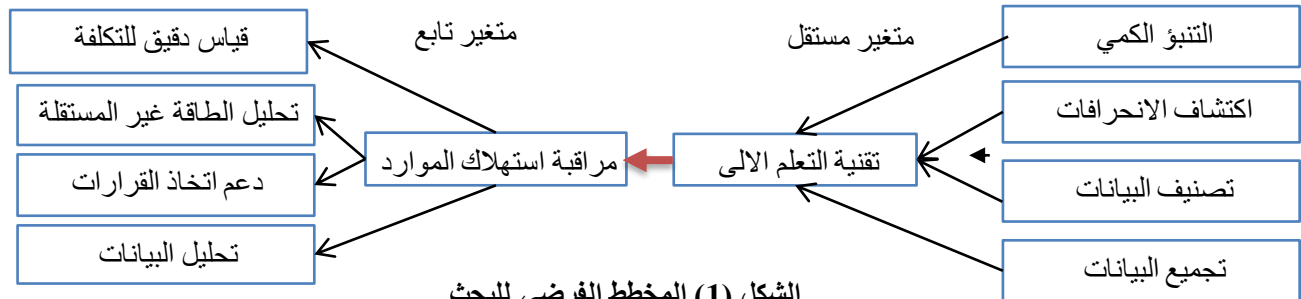
4. الفرضيات:

يستند البحث الحالي الى الفرضية الرئيسية الآتية:

- (H0): لا توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي وتحسين مراقبة استهلاك الموارد.
(H1): توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي وتحسين مراقبة استهلاك الموارد.
وتتفرع الفرضية الرئيسية الى أربع فرضيات.
- (H0): لا توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي وقياس دقيق للتكلفة.
(H1): توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي وقياس دقيق للتكلفة.
(H0): لا توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي وتحليل الطاقة غير المستغلة.
(H1): توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي وتحليل الطاقة غير المستغلة.
(H0): لا توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي ودعم اتخاذ القرارات لتحسين الإنتاج.
(H1): توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي ودعم اتخاذ القرارات لتحسين الإنتاج.
(H0): لا توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي وتحليل البيانات لتعزيز الدقة في تقارير الإنتاج.
(H1): توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي وتحليل البيانات لتعزيز الدقة في تقارير الإنتاج.

5. نموذج البحث الفرضي:

رسم توضيحي في الشكل (1) يُظهر الدور الافتراضية بين المتغيرات الرئيسية (المستقلة والتابعة) والمتغيرات الفرعية في البحث.



الشكل (1) المخطط الفرضي للبحث
إعداد الباحث

6. مجتمع وعينة البحث:

تم استخدام أسلوب المعاينة العمدية لاختيار عينة البحث من الأفراد المختصين الذين لهم صلة مباشرة مع موضوع البحث، كما يتكون مجتمع البحث من العاملين في معمل الكابلات والأسلاك الكهربائية التابع لشركة أور العامة وتألقت عينة البحث من (44) فردًا من العاملين، كما جُمعت البيانات من هذه العينة باستخدام استبانة صُممت خصيصًا للدراسة، وتكوّنت من محورين رئيسيين (متغير مستقل ومتغير تابع) واحتوى كل متغير على أربعة أبعاد فرعية، وتضمن كل بُعد أربعة أسئلة.

7. أسلوب البحث:

تم انجاز البحث باستخدام منهجين وهما:

أ. **المنهج الاستنباطي:** اعتمدت هذه الدراسة على المنهج الاستنباطي لبناء إطارها النظري وشرح المفاهيم والمتغيرات الأساسية للدراسة، وذلك بهدف اختبار فرضياتها من خلال مقالات ودراسات نظرية سابقة من مصادر أجنبية وعربية، بما في ذلك مصادر الشبكة العنكبوتية (الإنترنت).

ب. **المنهج الاستقرائي:** ولتحقيق الأهداف التطبيقية للدراسة واختبار فرضياتها، اتبعت منهجًا ميدانيًا يجمع بين الوصفي والتحليلي، وذلك بجمع البيانات الأولية من خلال استبيانات وُزعت على أفراد عينة البحث في مجتمع الدراسة، والذي مثل معمل الكابلات والأسلاك الكهربائية التابع لشركة أور العامة. وقد تم تحليل استجابات أفراد العينة واستخلاص النتائج التي ساهمت في دعم الفرضيات.

المحور الثاني: الجانب النظري

أولاً: تقنية التعلم الآلي: يُعد التعلم الآلي بداية عصر رقمي جديد

أ. مفهوم التعلم الآلي

يعرف التعلم الآلي (Machine Learning) بأنه فرع من فروع الذكاء الاصطناعي (AI) الذي يمنح الحاسوب القدرة على التعلم دون برمجة صريحة". قدم توم ميتشل (Tom Mitchell) في عام 1997، تعريفًا للتعلم الآلي دراسة تطوير برامج الحاسوب التي يمكن أن تتحسن تلقائيًا مع الخبرة. باستخدام أدوات الحوسبة على التعرف على الأنماط وتطبيقها، وإنشاء خوارزمياته الخاصة بناءً على تلك الأنماط لحل المشكلات، وتحسين تلك الخوارزميات بناءً على التغذية الراجعة. بعبارة أخرى، تُمكن تقنية التعلم الآلي الحاسوب من تعلم و المعرفة وفهمها والاحتفاظ بها بمرور الوقت، وبالتالي تمكينه من اتخاذ القرارات. (Austin, 2022:54)

تُعد لغة البرمجة بايثون من أهم اللغات المستخدمة في مجالات التعلم الآلي التي تهدف إلى تمكين أنظمة الحاسوب من تعلم الأنماط واتخاذ القرارات بشكل مستقل.

(Moala & Hamid, 2020)

و أكد (Ucoglu, 2020:1) ان التعلم الآلي يهدف إلى تحديد النموذج الذي يوفر التنبؤ الأكثر تكرارًا ودقة للبيانات المستقبلية ونشر الخوارزميات نماذج رياضية بناءً على بيانات العينة (بيانات التدريب). ثم يتم تقييم دقة القدرة التنبؤية للنماذج على تعلم الأنماط والاتجاهات من البيانات التاريخية والتنبؤ بالمستقبل بدقة من خلال تعزيز أدائها في التعلم، و يستخدم تعلم الآلي الخوارزميات لتحليل البيانات لتنفيذ مهام محددة، مثل إجراء التنبؤات، كلما كانت مجموعة البيانات أكبر، زادت الأمثلة التي يمكن للخوارزمية التعلم منها من خلال التجربة والخطأ، أي قدرة الكمبيوتر على التعرف على الأنماط وتطبيقها (Austin, 2022:54)

ب. أهمية التعلم الآلي

يتضمن التعلم الآلي تدريب الأنظمة لتكون قادرة على أداء مهام معينة بشكل تلقائي وذلك باستخدام كميات ضخمة من البيانات، تُمكن هذه العملية للألة من تطور قدرات تحليله خاصة بها، مما يمكنها من معالجة البيانات الجديدة، يُعتبر التحليلات التنبؤية من أبرز أمثلة التعلم الآلي (Saleh, 2025:13) وتحلل الخوارزميات تقنية التعلم الآلي، الأنماط ويفهمها أثناء استقباله ومعالجة وتخزينه للبيانات بمرور الوقت، ومن ثم يبني خوارزميته الخاصة للتنبؤ بأسباب الإجراءات المستقبلية. (CRISTEA, 2020:773).

تم استخدام التعلم الآلي بشكل متزايد في السنوات القليلة الماضية في مجالي المحاسبة والتدقيق لغرض تحليل كميات كبيرة من البيانات، ويتنبأ بالأحداث المستقبلية، بشكل منظم وتحليل البيانات، وتقييم الإنتاج، واستخراج المعلومات من البيانات ولمعالجتها بسرعة وبدون أي أخطاء، فإن إمكانية التعلم الآلي بتحليل بيانات لتزويد المحاسبين والمدققين بالمعلومات تمتاز بالدقة. (Ucoglu, 2020:2)

من خلال منهجية حسابية تتعلم الأنماط من البيانات الكبيرة والمعقدة، يتم تطبيق التعلم الآلي على مهام مختلفة مثل تدقيق المواد، وتحليل المعاملات أو الأنشطة الصناعية، وتقييم عمليات الإنتاج للتنبؤ وتقديرات بالمواد المستخدمة واتخاذ القرارات (Cho et al., 2020:1).

ج. المزايا التعلم الآلي

1. **الدقة في اتخاذ القرار:** سيعزز التعلم الآلي قرار الإدارة بسبب توفر المعلومات الدقيقة وفي الوقت المناسب وتحسين أدائها تلقائياً. (Saleh, 2025:13) من خلال تحليلات البيانات المتقدمة والنمذجة التنبؤية، يُمكن والتعلم الآلي للوحدات الصناعية من اتخاذ قرارات أذكى وأسرع وأكثر دقة، مما يُحسن بشكل كبير من الكفاءة التشغيلية، ويُخفّض التكاليف، وقد أحدثت قدرة هذه التقنيات على معالجة كميات هائلة من البيانات واكتشاف الانحرافات يصعب على البشر اكتشافها. (Mohammed & Madhumithaa, 2024:22012)
2. **القدرة على معالجة كميات هائلة من البيانات** " يحقق التعلم الآلي أفضل للوصول إلى معلومات في الوقت المناسب ومن مصادر مختلفة وذلك بقيامه بالسماح للحاسوب " بالتعلم" من البيانات لتحسين التحليل وتفسيرها وفهمها وتصنيفها وتحليلها. (Alsuhaime et al., 2025:23)
3. **سرعة معالجة البيانات:** سيمكن التعلم الآلي من أتمته الأنشطة الروتينية بما في ذلك جمع وتسجيلها البيانات وتحليلها بسرعة. (Ucoglu, 2020:3)
4. **تحسين جودة التنبؤ:** يساهم التعلم الآلي في الحصول على تنبؤات أكثر دقة، مما يساعد الوحدات الصناعية على الاستعداد بشكل أفضل لمتطلبات السوق المستقبلية لاستجابة الفورية لرغبات الزبائن. (Moroff et al., 2021:40)
5. **تقليل الأخطاء وزيادة موثوقية المعلومات:** سيساعد التعلم الآلي على الوفاء بالمواعيد النهائية والامتثال بشكل أكبر لمتطلبات إعداد التقارير الإنتاج (Austin, 2022:58)

د. خطوات تطبيق التعلم الآلي

- الخطوات الأساسية في تنفيذ التعلم الآلي في تحليلات البيانات
1. **تحديد المشكلة:** الخطوة الأولى في تنفيذ التعلم الآلي هي تحديد المشكلة التي تريد معالجتها، يعتمد التعلم الآلي على خوارزميات مختلفة لحل مشكلات البيانات، لكن لا يوجد نوع واحد من الخوارزميات يناسب جميع مشكلات البيانات، يعتمد نوع الخوارزمية المستخدمة على نوع المشكلة التي ترغب في حلها، وعدد المتغيرات، ونوع النموذج الذي يناسبها بشكل أفضل وما إلى ذلك، يتضمن تحديد الهدف من العمل المحدد وتصنيف البيانات التي سيتم استخدامها لتدريب نموذج التعلم الآلي. (Vishwakarma, 2024:381).
 2. **جمع المعلومات (البيانات) ومعالجتها:** بمجرد تحديد المشكلة، الخطوة الثانية هي جمع وإعداد البيانات المطلوبة لغرض تدريب لنموذج التعلم الآلي يتضمن تحديد مصادر البيانات ذات الصلة بالمراقبة، مثل البيانات استهلاك الموارد

(Decision Tree): تُستخدم للتصنيف، حيث تقوم بترتيب البيانات في شكل شجرة بناءً على قيمها، وتتكون من فروع وعقد، الانحدار الخطي: (Linear Regression) نموذج يُستخدم للتنبؤ بقيم عددية، حيث يحدد العلاقة بين متغيرات مستقلة وتابعة والانحدار اللوجستي (Logistic Regression): خوارزمية تصنيف تُستخدم لتحويل مخرجاتها إلى قيم احتمالية (Iqbal et al., 2022:8).

4. تقييم النموذج وتحسينه: بمجرد تدريب النموذج، الخطوة الرابعة في تقييم أدائه وتحسينه للحصول على نتائج أفضل و تتطلب إجراء تجارب لتقييم النموذج بما يتناسب مع إعدادات التطبيق، يتضمن ذلك اختبار النموذج على مجموعة بيانات منفصلة تكون مقاييس الأداء المتعددة، ويتم اختيارها لتعكس الصحة جميع البيانات، يعد مراعاة عدم اليقين أو التباين في تقدير الأداء، إذا لم يكن أداء النموذج جيداً، يتم تحسين النموذج عن طريق ضبط معلماته أو تجربة خوارزمية مختلفة (Varoquaux & Colliot, 2023:27).

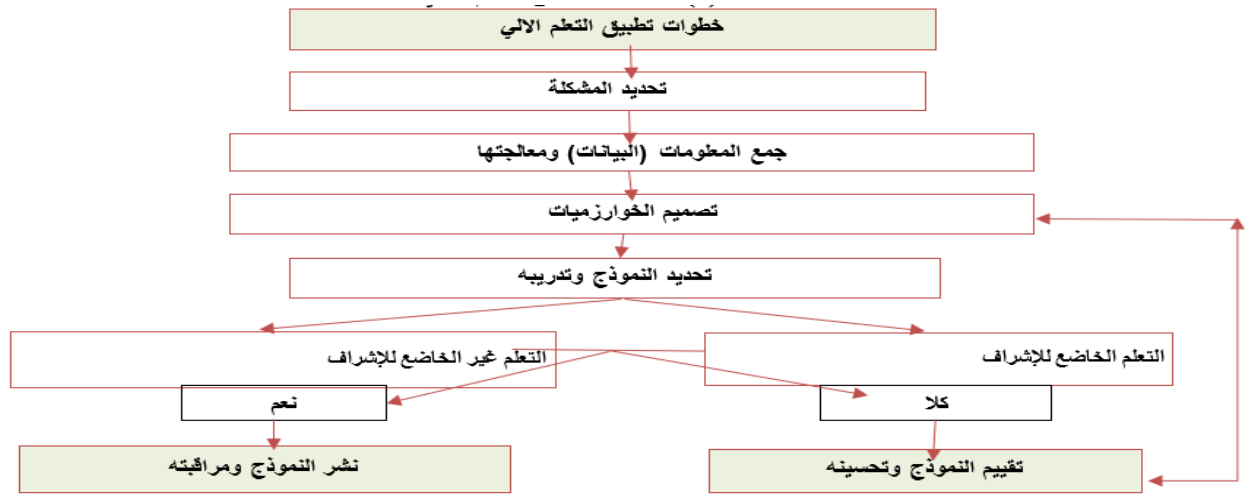
5. نشر النموذج ومراقبته: الخطوة الأخيرة في تنفيذ تقنية التعلم الآلي في تحليلات البيانات هي مراقبة نشر نموذج التعلم الآلي لضمان الموثوقية، خاصة وأن مدخلات المستخدم الجديدة قد تختلف عن بيانات التدريب النموذج. يعد مراقبة نموذج التعلم الآلي جزءاً أساسياً من أي مشروع للتعلم الآلي (Bodor et al., 2023:126-132). ومن خلال مراقبة النماذج يمكن التأكد من أنها تعمل كما هو متوقع ولا تتجرف مع مرور الوقت. يمكن أن يساعد هذا في تحسين دقة وموثوقية نماذج التعلم الآلي، ويمكن أن يساعد أيضاً في تحديد المجالات التي يمكن تحسين النماذج فيها وتطويرها (Nigenda et al., 2022:3671-3672). الشكل (2) يوضح الخطوات تطبيق التعلم الآلي

وسجلات العاملين و تحليل البيانات ومعالجتها مسبقاً لضمان جودتها وتناسقها مع خوارزميات التعلم الآلي. تعتمد النماذج التعلم الآلي على البيانات التاريخية، ويتم التحقق من صحتها ومراجعة جودتها بشكل مستمر، لكون نتائج التعلم الآلي تعتمد على جودة بيانات الإدخال، ينبغي أن تكون بيانات حقيقية و التأكد بشكل خاص من أن معدل أخذ العينات مناسب. (Stodt & Reich, 2021:188-189).

3. تحديد النموذج وتدريبه: بعد إعداد البيانات، تتمثل الخطوة الثالثة في تحديد نموذج التعلم الآلي المناسب الذي يمكنه حل المشكلة المحددة بشكل مناسب، يمكن اعتماد نهجين أساسيين لتنفيذ التعلم الآلي، اعتماداً على توفر البيانات المناسبة وما إذا كانت هناك بنية تحتية قائمة.

أولاً: التعلم الخاضع للإشراف: تُستخدم هذه الخوارزميات لتصنيف وتوقع النتائج بناءً على بيانات التدريب المصنفة أو البيانات التاريخية للتنبؤ بالنتائج المستقبلية، مثل تحديد مصادر الأكثر عرضة لهدر الموارد، ويمكن استخدام أدوات في تصنيف العمليات الإنتاجية لمراقبة استهلاك الموارد والتصنيف (Classification) لتصنيف البيانات إلى فئات محددة (مثل "مهم" أو "غير مهم) ولانحدار (Regression) للتنبؤ بقيمة (سعر أو إيرادات). (DICKEY et al., 2019:2).

ثانياً: التعلم غير الخاضع للإشراف: يُستخدم التعلم غير الخاضع للإشراف حيث لا توجد تسميات على متغيرات الإخراج فلا يتم "إخبار" النظام بالإجابة المفترضة، بل يقوم بدلاً من ذلك بحساب أنماط البيانات من تلقاء نفسه، وقد يكون مفيداً إذا تم استخدامه كجزء من عملية تقييم المخاطر لاكتشاف المخاطر غير المتوقعة سابقاً، أي عكس التعلم الخاضع للإشراف تكشف الانحرافات بدون تدريب مسبق (Jane & Ganesh, 2019:1123).



الشكل (2) الخطوات تطبيق التعلم الآلي
إعداد الباحث

التي وردت في الأدبيات المحاسبية، نورد فيما يلي مجموعة من التعاريف.

عرف (Al-Janabi & Mohammed, 2018:262) هذا المفهوم بأنه نظام إداري يركز على توفير معلومات موثوقة

ثانياً: مراقبة استهلاك الموارد

أ. مفهوم مراقبة استهلاك الموارد

يشير الفكر المحاسبي إلى عدم وجود تعريف شامل ومتفق عليه لمفهوم مراقبة استهلاك الموارد، إذ تعددت التعريفات

وتنتهي عند وجهتها، بناءً على اعتبارات التكلفة والكمية لتلك الموارد، بهدف خفض التكاليف وزيادة الإنتاجية. (Salman & Alghabban, 2023:281)

يرى (AI-Qizi, 2022:136) مراقبة استهلاك الموارد توفر معلومات تساعد في اتخاذ قرارات أكثر دقة خاصة بالنسبة للموارد النادرة و استهلاك الموارد وسلوك التكلفة بهدف تحويل عملية التركيز من متابعة التكلفة إلى مراقبة الموارد أكثر دقة وموثوقية مما يؤدي الى توفر مستوى رقابي على الموارد والتكاليف وذلك من خلال الربط مباشرة بين الموارد وقياس التكاليف.

ويرى الباحث أن مراقبة استهلاك الموارد وإنتاج منتجات عالية الجودة من خلال استخدام الطاقة والتخطيط الفعال لاستهلاك الموارد وتحسين عمليات الإنتاج وتقليل الهدر وتحديد الكميات المعيارية كل ذلك يُسهم في تحسين عمليات اتخاذ القرار والتخطيط ومراقبة الموارد المتاحة ومن ثم توزيعها بشكل سليم على المنتجات المختلفة.

ج. فلسفة مراقبة استهلاك الموارد

مراقبة استهلاك الموارد، تُعد الركيزة الأساسية في إدارة الموارد حيث تركز فلسفتها على أن الموارد هي المكون الأساسي للتكلفة، يركز النظام على الموارد بمفهومها الشامل ومن ثم تنظيمها في مجموعات تُسمى "مجموعات الموارد". يتم تجميع التكاليف المرتبطة بموارد متجانسة في "مجموعات الموارد" تحتوي كل مجموعة موارد على مجموعة من المدخلات التي تُستخدم لإنتاج مخرجات تستخدمها مجموعات المواد الأخرى، أو تُستخدم لإنتاج سلع وخدمات نهائية ومن ثم توزيع تكاليفها لتلك الموارد لتحديد التكاليف الكلية لمجموع الموارد. (Farag, 2024:329)

تحديد الطاقة غير المستغلة خطوة جوهرية، فهي تؤدي إلى قياس دقيق للتكلفة للموارد المتاحة للوحدة الاقتصادية، بهدف خفض تكاليف الإنتاج وكيفية استخدامها على النحو الأمثل. من خلال تتبع كميات الموارد المتاحة، يتم تحقيق مفاهيم الرقابة المختلفة، وذلك بالتحكم ومراقبة مصادر التكلفة هذا يؤدي الى التحقق الرقابة المانعة بين العرض والطلب على الموارد، ومن ثم تحقيق التحكم اللاحق والمتزامن، مما يساعد على ترشيد

تكاليف استهلاك الموارد. (Al-Sayed et al., 2019:860) كما اكد (AI-Qizi, 2022:51) على أهمية حساب معدلات الطاقة النظرية والعملية لكل مجموعة موارد، في هذه الخطوة، تُحدد معدلات الطاقة النظرية والعملية لكل مجموعة موارد. ثم تُقدر التكاليف الإجمالية لمجموعتي الموارد الأساسية والثانوية، ويُحسب معدل التكلفة الثابتة ومعدل التكلفة التناسبية لتوزيع تكاليف الموارد على الأنشطة. يتعلق الأول بالتكاليف الثابتة، بينما يتعلق الثاني بالتكاليف التناسبية. من خلال الشكل (3) يبين خطوات فلسفة مراقبة استهلاك الموارد.

لترشيد التكاليف وتعظيم الإيرادات لتعزيز القدرة الإنتاجية للوحدة الاقتصادية، بهدف تحقيق نجاح أكبر في السوق التنافسية.

بينما عرفها (AI-Jabali, 2020:518) بأنها "تقنية لقياس تدفق المواد وتوازنها في العمليات أو خطوط الإنتاج في كلٍ من الوحدات المادية والمالية".

اما (Mohammad, 2021:3) فيراها منهج محاسبي يتميز بتوفير معلومات شاملة وكافية تُسهم في التخطيط السليم للموارد، وخفض التكاليف، ومراقبة وتحديد الطاقة الإنتاجية غير المستغلة. كما يُساعد في اتخاذ القرارات الاستراتيجية. ويعتمد بشكل كبير على منهج المحاسبة الإدارية الألماني (GPK) باستخدام موجبات التكلفة على اساس النشاط.

في حين يرى (AI-Qizi, 2022:29) بأنها "تقنية ادارية استراتيجية متكاملة تعمل على إدارة التكلفة وفصل تكاليف الطاقة العاطلة لتحقيق الرقابة الفعالة على موارد الوحدة الاقتصادية مع دعم فلسفة التحسين المستمر عن طريق اعادة صياغة الاستراتيجيات بطريقة يمكن ان تسهم في تحقيق الاستغلال الكفء للطاقة العاطلة.

اما (Farag, 2024:326) انها أسلوب محاسبي قائم على أساس كمي ويركز على أن سبب التكاليف هو استهلاك الموارد، ويدعم عملية صنع القرار، ويركز على الاستخدام الأمثل للموارد، مما يؤدي إلى خفض تكلفة المنتج وتوفير معلومات يمكن الاعتماد عليها.

وبناءً على ما تقدم يمكن تقديم تعريف "مراقبة استهلاك الموارد"

يرى الباحث ان مراقبة استهلاك الموارد هي نهج إداري ومحاسبي شامل يوفر معلومات دقيقة حول استهلاك الموارد، ويُسهم في تحديد الطاقة غير مستغلة (الطاقة العاطلة)، بهدف هذا نهج بشكل اساسي الى قياس وتتبع تدفق الموارد (كمياً، مالياً، أو طاقة) وتحليل استهلاكها بهدف ترشيد التكاليف وتحقيق الاستخدام الأمثل للطاقة المتاحة. كما يُمكن الإدارة من اتخاذ قرارات استراتيجية، وتُعظّم قيمة المنتجات من خلال التحسين المستمر للإنتاج

ب. أهمية مراقبة استهلاك الموارد

إن مفهوم مراقبة استهلاك الموارد يتعلق بالأساس بالاستغلال الأمثل للموارد المتاحة مما يؤدي إلى اتخاذ قرارات استراتيجية تتعلق بخفض تكاليف المنتج من خلال تحديد وقياس اتجاهات خفض التكاليف في الموارد المستخدمة ومدى الهدر وتحديد مقدار الكمية المعيارية بهدف ترشيد تكاليف الطاقة المستخدمة والتركيز على التكاليف التي تضيف قيمة للمنتج. (Saeed & Khalil, 2021:169)

كما تُعد وهي نهج تشغيلي لقياس وتخصيص التكاليف، بالتركيز على ما يُضيف قيمة للمنتجات بناءً على علاقات سببية، دون تحميل المنتجات تكاليف الطاقة غير المستغلة والتخصيص الأمثل للموارد لدعم الإدارة الاستراتيجية للتكاليف من خلال مراقبة استهلاك الموارد برؤية مستقبلية. الاستخدام الأمثل للموارد مع رقابة صارمة تبدأ من مصدرها



الشكل (3) الخطوات مراقبة استهلاك الموارد
إعداد الباحث


ثالثاً: دور تقنية التعلم الآلي في مراقبة استهلاك الموارد

تعد تقنية التعلم الآلي (ML) باستخدام أجهزة استشعار متصلة بإنترنت الأشياء ، يمكن تحليل البيانات التي تساعد في تقليل الهدر في مواد الإنتاج الناتجة عن الانحرافات غير المكتشفة، تتميز معظم مهام مراقبة استهلاك الموارد بطبيعة ميكانيكية ومتكررة، مما يجعلها مناسبة لتطبيقات التعلم الآلي سيؤدي ذلك إلى تحسين وظيفة الإنتاج على زيادة القدرة على توليد أنواع جديدة من الأفكار التي تزيد من قيمة المنتج وترفع جودة الإنتاج إلى مستوى جديد. (Joshi, 2021:7)

وباستخدام أدوات التعلم الآلي للحصول على فهم أفضل للنشاط وراء الأرقام قد يتمكن مراقبة استهلاك الموارد من الاستفادة من البيانات المتوفرة، قد تجد خوارزمية التعلم الآلي تناقضات او انحرافات مع المقاييس التقليدية مثل (ومتوسط الإيرادات لكل دورة الإنتاج) أن يوفر قيمة أثناء محاولتهم تقديم تنبؤات مستقلة للإجراءات التحليلية قد تكشف عن مخاطر مخفية سابقاً يمكنها أن تقدم تنبؤات تحليله دقيقة (DICKY et al., 2019:4).

يرى الباحث الآن المزيد من أدوات الذكاء الاصطناعي ممكن تتكامل مع تقنيات محاسبة التكاليف، ومن الواضح أن عمليات الإنتاج ومراقبة استهلاك الموارد سوف تتغير نتيجة لهذه الأدوات، لتحقيق مخرجات عالية الجودة بتكلفة معقولة. وأن دمج أدوات الذكاء الاصطناعي الحالية مع تقنيات محاسبة التكاليف سيؤدي إلى تغييرات نوعية في عمليات الإنتاج ومراقبة استهلاك الموارد. هذا التكامل قد يحقق مخرجات عالية الجودة بتكلفة معقولة. الشكل (4) دور التعلم الآلي في مراقبة استهلاك الموارد.

تعزيز الدقة في تقارير الإنتاج
اتخاذ القرارات القائمة على البيانات
تحسين استهلاك الموارد على الأنشطة
أتمتة عمليات الإنتاج لتحديد الانحرافات واكتشاف الهدر
توفير رؤى في الوقت الفعلي بمخاطر ارتفاع التكاليف



الشكل (4) الخطوات مراقبة استهلاك الموارد
إعداد الباحث

أ. أهداف مراقبة استهلاك الموارد

تهدف مراقبة استهلاك الموارد إلى تحقيق مجموعة من الأهداف، والتي نذكر بعضها أدناه..

1. **قياس دقيق للتكلفة وتخفيضها:** تهدف مراقبة استهلاك الموارد بشكل رئيسي إلى دقة قياس التكلفة من خلال الاستغلال الأمثل للموارد المتاحة للوحدة الاقتصادية بهدف تخفيض تكاليف الإنتاج والكشف عن الطاقة العاطلة وتعظيم قيمة المنتج. (Al-Sayed et al., 2019:858)

2. **توزيع تكاليف الموارد وتحليل الطاقة غير المستغلة:** يُركز نظام محاسبة استهلاك الموارد على تكاليف الموارد بدلاً من الأنشطة مما يُحقق توزيعاً أدق للتكاليف ويُميز بين الموارد المتاحة والمُستخدمة. وهذا يُمكنه من حساب الطاقة الإنتاجية غير المُستخدمة بدقة، هذا يُساهم في زيادة الإنتاجية وخفض تكاليف المنتجات (Elesawee, 2022:111)

3. **دعم اتخاذ القرارات الإدارية لتحسين الإنتاج:** يهدف نظام مراقبة استهلاك الموارد نموذج لقياس التكلفة مصمم لتزويد المديرين بمعلومات التكاليف اللازمة لدعم عملية اتخاذ القرارات بغرض تحسين الوضع الانتاجي وذلك من خلال تحقيق أفضل ترشيد ممكن للموارد المتاحة بما يؤدي إلى خفض تكلفة المنتج وتحقيق أفضل قيمة مضافة للمنتج. (Omer, 2020:181)

4. **توفير معلومات تفصيلية عن الموارد وعلاقتها بالأنشطة:** تحديد العلاقة بين الموارد والأنشطة، يساعد الإدارة في ادراك علاقات السبب والنتيجة وفهم أوجه استهلاك الموارد وذلك من خلال توفير معلومات مفصلة عن الموارد المتاحة، وتكاليفها، وعلاقتها المتبادلة، وكيفية استخدامها بكفاءة (AI- (Qizi, 2022:31

مما يؤدي هذا الكشف الفوري على تقليل الهدر وتكاليف الطاقة غير المستغلة بسرعة. (Adelakun & Fatogun, 2024:1003)

ه. توفير رؤى في الوقت الفعلي بمخاطر ارتفاع التكاليف أو نقص الموارد: يساعد التعلم الآلي على تحليل البيانات المتعلقة بالإنتاج، وتقلبات أسعار المواد الخام، وهو نظام للكشف تلقائيًا عن انحراف البيانات في النماذج في الوقت الفعلي وتوفير التنبيهات يسمح باتخاذ تدابير استباقية، (Achakzai & Peng, 2023:1) ومن ثم البحث عن موردين بديلين حتى تتمكن من اتخاذ إجراءات تصحيحية ويمكن أن يساعد هذا في منع تفاقم المشكلات أو تعديل خطط الإنتاج للحد من المخاطر في الوقت الفعلي. (Nigenda et al., 2022)

المحور الثالث الجانب التطبيقي

1. عينة البحث

اختيرت عينة البحث لتشمل مختصين ذوي صلة مباشرة بموضوع البحث، تألفت العينة من محاسبي ومُدققي ومهندسي يعملون في "شركة اور العامة". وُزِع استبيان إلكتروني على هذه عينة الدراسة، وقد تم تحليل (44) استبيانًا بنجاح، مُمثلاً نسبة استجابة 100% من المشاركين المُستهدفين، لتحديد صحة فرضيات البحث، تم استخدام مقياس ليكرت الخماسي لجميع فقرات الاستبيان. وبيّن الملحق رقم (1) و(2) التحليلات الإحصائية المتعلقة بتقنية التعلم الآلي، بمراقبة استهلاك الموارد.

2. تحليل استجابات عينة البحث

أ. اختبار الصدق والثبات

التأكد من ثبات المقياس من خلال حساب معاملات لفا كرونباخ، وبالإستعانة ببرنامج spss كانت النتائج كالآتي:

تفسير النتائج

تجاوزت جميع قيم معامل Cronbach's Alpha للأبعاد الفرعية والمحاور العامة (70%). تُعد هذه القيم عالية إحصائيًا، متجاوزة الحد الأدنى المقبول للثبات (عادةً 60%) في الدراسات.

بالنسبة للمحور الأول، قيم ألفا كرونباخ القيمة الكلية للمحور الأول (905.)

بالنسبة للمحور الثاني قيم ألفا كرونباخ القيمة الكلية للمحور الثاني (917.). كما هو موضح في الجدول (1).

فيما يلي شرح أكثر تفصيلاً لكل نقطة في الشكل (1):
أ. تعزيز الدقة في تقارير الإنتاج: تُعد تقارير الإنتاج أداة مهمة لنظام التصنيع، أن تطبيق التعلم الآلي إذ يُمكن برامج الحاسوب من اتخاذ قرارات ذكية تلقائيًا بناءً على البيانات لتحسين الأداء في نظام التصنيع يُمكن تحليل البيانات التاريخية المتعلقة باستهلاك الموارد وتعزيز دقة وشمولية عمليات الإنتاج ولتحديد الأنماط والانحرافات التي قد تشير إلى الانحرافات أو هدر في المواد الأخرى. في الوقت الفعلي وتحديد المشكلات المحتملة على الفور، مما يقلل من الفارق الزمني بين حدوث الانحراف واكتشافه. (Adelakun & Fatogun, 2024:1000)

ب. اتخاذ القرارات القائمة على البيانات: يوفر التعلم الآلي حلاً بديلة تدعم اتخاذ القرارات المتعلقة بترشيد استهلاك الموارد من خلال تطوير خوارزميات لمعالجة البيانات في الوقت الفعلي ويعطي نتائج وتحليلات دقيقة يمكن استخدامها لتوليد بدائل من بيانات الإنتاج والتي يمكن استخدامها لدعم عملية اتخاذ القرار، بمجرد أن تجد الخوارزمية أو تفهم كيفية تحليل البيانات، فإنها ستقوم بعملها تلقائيًا، مما قد يساعد محاسبي الكلف تطوير خطط احتساب التكاليف أو إعادة تصميم العمليات الإنتاج (Jane & Ganesh, 2019:1122)

ج. تحسين استهلاك الموارد على الأنشطة: توفر تقنية التعلم الآلي من معالجة البيانات بسرعة وبدون أي أخطاء أو تحيز على نطاق واسع في العديد من المجالات المختلفة بتحليل العلاقة بين الموارد المستهلكة والأنشطة المنتجة و لتحسين استهلاك الموارد ، من الضروري تخصيص التكاليف بشكل دقيق للأنشطة المختلفة. ، فإن إمكانات خوارزميات التعلم الآلي لتزويد المحاسبيين بتحليل محسن للأنشطة الإنتاجية، باستخدام الأتمتة التعلم الآلي يمكن من اعاده تخصيص الموارد بشكل افضل لتحقيق أقصى استفادة. (Ucoglu, 2020:1).

د. أتمتة عمليات الإنتاج لتحديد الانحرافات واكتشاف الهدر : يراقب التعلم الآلي استهلاك الموارد أنياً ويقارنه بالأنماط الطبيعية أو المتوقعة ، مما يوفر الوقت والموارد، بالإضافة إلى ذلك، يمكن للتعلم الآلي تحسين كفاءة الإنتاج في حالة وجود انحرافات كبيرة بين الكميات المعيارية و الكميات الفعلية في الإنتاج ، مما يسمح بإجراء المزيد من عمليات مراقبة في وقت أقل وبموارد أقل (Achakzai & Peng, 2023:1) كما يوفر دمج التعلم الآلي في عمليات مراقبة استهلاك الموارد في الإنتاج السرعة في اكتشاف ارتفاع مفاجئ في استهلاك الموارد، وتحسين واختيار البديل الأفضل، وتوفير التكاليف،

الجدول (1) اختبار الصدق والثبات

المحور الأول (A)	اسم البعد	عدد الفقرات	Cronbach's Alpha	المحور الثاني (B)	اسم البعد	عدد الفقرات	Cronbach's Alpha
البعد الأول (A1)	التنبؤ الكمي	4	.920	البعد الأول (B1)	قياس دقيق للتكلفة	4	.941
البعد الثاني (A2)	تصنيف البيانات	4	.762	البعد الثاني (B2)	تحليل الطاقة	4	.925
البعد الثالث (A3)	اكتشاف	4	.890	البعد الثالث	دعم اتخاذ	4	.856

		القرارات	(B3)			الانحرافات	
.835	4	تحليل البيانات	البعد الرابع (B4)	.961	4	تجميع البيانات	البعد الرابع (A4)
.917		إجمالي المحور		.905		إجمالي المحور	

المصدر: إعداد الباحث بالاعتماد على برنامج spss

ب. نتائج الاحصاء الوصفي
وبعد التأكد من صدق وثبات المقياس قام الباحث بتحليل عينة الاستبانة وفيما يلي نتائج الإحصاء الوصفي لاستجابات (الإجابات التي تم الحصول عليها):

تؤكد النتائج المبينة في الجدول (1) أن أبعاد الاستبانة تتمتع بثبات داخلي عالٍ، أي أن فقرات كل بُعد ومحور تقيس المفهوم نفسه بثبات، كما أن ثبات مرتفع. لذلك يمكن الاعتماد على هذه الاستبانة لجمع بيانات.

الجدول (2) وصف عينة البحث

التخصص الوظيفي			سنوات الخدمة			التحصيل الدراسي		
النسبة المئوية	التكرار	الفئات المستهدفة	النسبة المئوية	التكرار	الفئات المستهدفة	النسبة المئوية	التكرار	الفئات المستهدفة
34.09%	15	محاسب	15.90%	7	فما دون 5	4.50 %	2	دكتوراه
27.72%	10	مدقق	27.20%	12	من 5-10	36.40 %	16	دبلوم عالي
20.45%	9	فني	38.60%	17	من 11-15	27.30 %	12	ماجستير
27.72%	10	مهندس	18.10%	8	واكثر 15	31.40 %	14	بكالوريوس
100%	44	المجموع	100%	100%	المجموع	100%	44	المجموع

المصدر: إعداد الباحث بالاعتماد على برنامج spss

• **معنوية النموذج (قيمة F)** بلغت قيمة "F المحسوبة (44.330) بدلالة احصائية (Sig. = 0.000) وهي أكبر من قيمتها الجدولية (2.18) عند درجات الحرية -1-42 (df). ومستوى دلالة (0.05)، هذا يؤكد ان النموذج الاحصائي المستخدم ذو دلالة احصائية وقادر على تفسير التباين.
• **قوة العلاقة معامل الارتباط (R)** بلغت قيمته "R" (0.717) "يدل على وجود علاقة خطية قوية وطردية وموجبة بين تقنية التعلم الآلي في تحسين مراقبة استهلاك الموارد) اي قيمة الارتباط R قوية جداً.

وتظهر نتائج الاحصاء الوصفي كما مبين في الجدول (2) لعينة الدراسة، والتي تكونت من (44) فرداً يعملون في معمل القابلات والنتائج جاءت متنوعة في المستويات التعليمية والخبرات الوظيفية والتخصصات، مما يعزز من دقة إجابات العينة وقدرتهم على تقديم الفقرات المطروحة بالاستبانة.

اختبار الفرضيات

أ. الفرضية الرئيسية: " لا توجد علاقة ذات دلالة احصائية بين تقنية التعلم الآلي ومراقبة استهلاك الموارد"

تفسير شامل لنتائج جدول (3)

جدول (3) نتائج اختبار الفرضية الرئيسية

R	R Square	B1	Std. Error	T	البيان
.717a	0.513	.723	.109	6.658	القيمة
				.000b	.Sig
		44.330			قيمة F
		.717			Beta
		44			N

المصدر: إعداد الباحث بالاعتماد على برنامج spss

الفرضية ويشير إلى أن المتغير المستقل له دلالة إحصائية في التنبؤ بالمتغير التابع.

• **القرار:** رفض الفرضية الصفرية وقبول الفرضية البديلة التي تنص " توجد علاقة ذات دلالة احصائية بين تقنية التعلم الآلي وتحسين مراقبة استهلاك الموارد".

ب. الفرضية الفرعية الاولى: "لا توجد علاقة ذات دلالة احصائية بين تقنية التعلم الآلي في قياس دقيق للتكلفة".

تفسير شامل لنتائج جدول (4)

القدرة التفسيرية R Square بلغت بقيمة معامل التحديد (0.513)، هذا يعني القوة التفسيرية (51.3%) من التباين في المتغير التابع (مراقبة استهلاك الموارد) يمكن تفسيره بالمتغير المستقل. أما نسبة (48.8%) المتبقية فهي بسبب عوامل أخرى غير مدرجة في النموذج المستخدم.

• **معنوية معامل الانحدار Sig** بقيمة (0.000b) وهي أقل من قيمة الخطأ المقبول والمحدد سابقاً بمقدار (0.05). وهذا ما يدل على ملائمة النموذج الاحصائي المستخدم لاختبار

- **قيمة F = (53.238)** بدرجة حرية (4,39) ودلالة إحصائية (0.000.Sig) أقل من (0.05) يعني نموذج دال إحصائي
بناءً على مستوى الدلالة الإحصائية (.Sig).
- **القرار:** نرفض الفرضية الصفرية ونقبل الفرضية البديلة: "توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي في قياس دقيق للتكلفة".

- **تفسير النموذج -** يشير النموذج إلى أن بُعدي "جمع البيانات" و"التنبؤ الكمي" هما العاملان ذوو دلالة إحصائية على قياس دقة التكلفة، لذيهما تأثير جوهري بينما لم تُظهر المتغيرات الأخرى دلالة إحصائية.
- **قيمة معامل R Square = 0.845**، مما يشير إلى أن 84.5% من التباين في المتغير (مراقبة استهلاك الموارد البعد الأول - قياس دقة التكاليف وتخفيضها) يُفسر بأبعاد تقنية التعلم الآلي

جدول (4) نتائج اختبار الفرضية الفرعية الأولى

المتغير المستقل	Beta	Sig.	مستوى الدلالة	تفسير
التنبؤ الكمي	.407	.003	0.05>.Sig	البعد ذو دلالة إحصائية وله تأثير إيجابي
جمع البيانات	.545	.000	0.05>.Sig	البعد ذو دلالة إحصائية وله تأثير إيجابي
تصنيف البيانات	.015	.863	0.05<.Sig	البعد غير دال إحصائياً ليس له تأثير
كشف الانحرافات	.027	.777	0.05<.Sig	البعد غير دال إحصائياً ليس له تأثير

المصدر: إعداد الباحث بالاعتماد على برنامج spss

- البعد الثاني - تحليل الطاقة غير مستغلة) يُفسر بأبعاد تقنية التعلم الآلي.
- ب. **قيمة F = 32.412** بدرجة حرية (4,39) ودلالة إحصائية (0.000.Sig) أقل من 0.05 يعني نموذج دال إحصائي.
بناءً على مستوى الدلالة الإحصائية (.Sig).
- ج. **القرار:** نرفض الفرضية الصفرية ونقبل الفرضية البديلة: "توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي في تحليل الطاقة غير مستغلة".

- ب. **الفرضية الفرعية الثانية:** "لا توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي في تحليل الطاقة غير مستغلة".
تفسير شامل لنتائج جدول (5)
- **تفسير النموذج** إلى أن بُعدي "جمع البيانات" و"التنبؤ الكمي" هما العاملان ذوو دلالة إحصائية على تحليل الطاقة غير مستغلة، لذيهما تأثير جوهري بينما لم تُظهر المتغيرات الأخرى دلالة إحصائية.
- أ. **قيمة معامل R Square = 0.769**، مما يشير إلى أن 76.9% من التباين في المتغير (مراقبة استهلاك الموارد

جدول (5) نتائج اختبار الفرضية الفرعية الثانية

المتغير المستقل	Beta	Sig.	مستوى الدلالة	تفسير
التنبؤ الكمي	.471	.005	0.05>Sig	البعد ذو دلالة إحصائية وله تأثير إيجابي
جمع البيانات	.384	.030	0.05>.Sig	البعد ذو دلالة إحصائية وله تأثير إيجابي
تصنيف البيانات	.125	.234	0.05<.Sig	البعد غير دال إحصائياً ليس له تأثير
كشف الانحرافات	.124	.287	0.05<.Sig	البعد غير دال إحصائياً ليس له تأثير

المصدر: إعداد الباحث بالاعتماد على برنامج spss

- الثالث - دعم اتخاذ القرارات لتحسين الانتاج) يُفسر بأبعاد تقنية التعلم الآلي.
- د. **قيمة F = 22.59** حرية (4,39) ودلالة إحصائية (0.000.Sig) أقل من 0.05 يعني نموذج دال إحصائي.
بناءً على مستوى الدلالة الإحصائية (.Sig).
- القرار:** نرفض الفرضية الصفرية ونقبل الفرضية البديلة: "توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي دعم في اتخاذ القرارات لتحسين الانتاج".

- ج. **الفرضية الفرعية الثالثة:** "لا توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي في دعم اتخاذ القرارات في تحسين الانتاج"
تفسير شامل لنتائج جدول (6)
- تفسير النموذج إلى أن بُعد "التنبؤ الكمي" هو العامل ذو دلالة إحصائية على دعم اتخاذ القرارات لتحسين الانتاج، لديه تأثير جوهري اما الأبعاد الأخرى فليس لها تأثير ذو دلالة إحصائية.
- قيمة معامل R Square = 0.699**، مما يشير إلى أن 69.9% من التباين في المتغير (مراقبة استهلاك الموارد البعد

جدول (6) نتائج اختبار الفرضية الفرعية الثالثة

المتغير المستقل	Beta	Sig.	مستوى الدلالة	تفسير
التنبؤ الكمي	.651	.001	0.05 >.Sig	البعد ذو دلالة إحصائية وله تأثير إيجابي
جمع البيانات	.034	.797	0.05 <.Sig	البعد غير دال إحصائياً ليس له تأثير

البعد غير دال احصائيا ليس له تأثير	0.05 < .Sig	.176	.181	تصنيف البيانات
البعد غير دال احصائيا ليس له تأثير	0.05 < .Sig	.495	.134	كشف الانحرافات

المصدر: إعداد الباحث بالاعتماد على برنامج spss

- قيمة معامل **R Square** = 0.886، مما يشير إلى أن 88.6% من التباين في المتغير (مراقبة استهلاك الموارد البعد الرابع - تحليل البيانات تعزيز الدقة في تقارير الانتاج) يُفسر بأبعاد تقنية التعلم الآلي.
- قيمة **F** = 75.541 بدرجة حرية (4,39) ودلالة احصائية (0.000.Sig) أقل من 0.05 يعني نموذج دال احصائي بناءً على مستوى الدلالة الإحصائية (.Sig).
- القرار: نرفض الفرضية الصفرية ونقبل الفرضية البديلة: "توجد علاقة ذات دلالة إحصائية بين تقنية التعلم الآلي في تحليل البيانات لتعزيز الدقة في تقارير الانتاج".

- الفرضية الفرعية الرابعة: لا توجد علاقة ذات دلالة احصائية بين تقنية التعلم الآلي في تحليل البيانات لتعزيز الدقة في تقارير الانتاج.
- تفسير شامل لنتائج جدول (7):
يشير النموذج إلى أن بُعدي " التنبؤ الكمي " و" جمع البيانات " هما العاملان ذو دلالة إحصائية على تحليل البيانات تعزيز الدقة في تقارير الانتاج، ليهما تأثير جوهري بينما لم تُظهر المتغيرات الأخرى دلالة إحصائية.

جدول (7) نتائج اختبار الفرضية الفرعية الرابعة

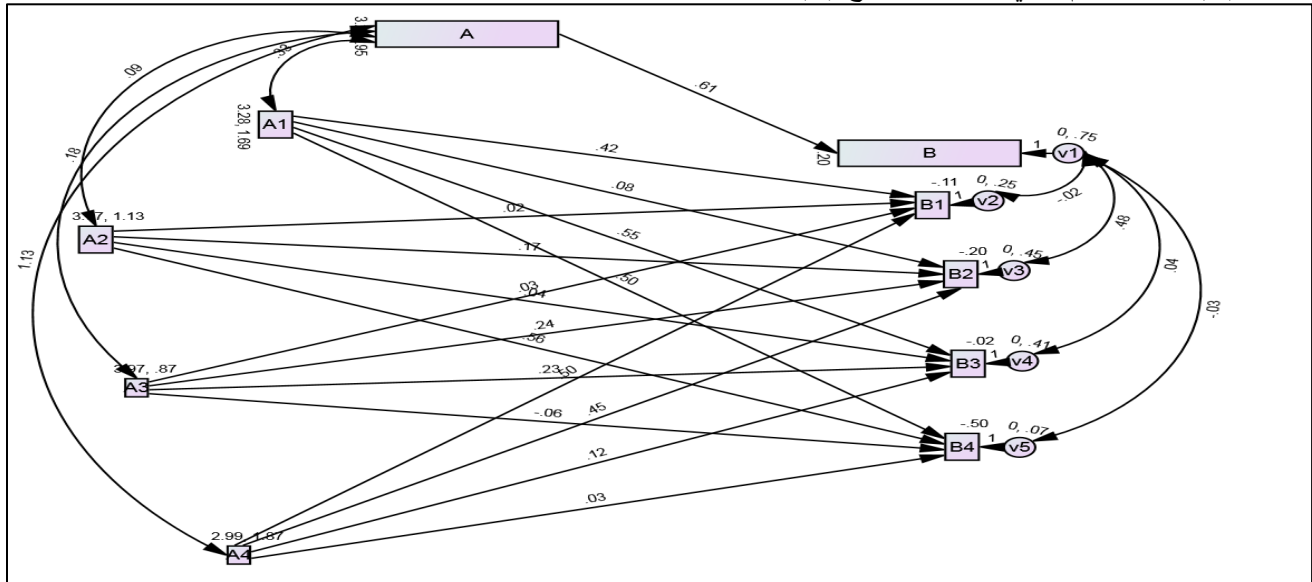
المتغير المستقل	Beta	Sig.	مستوى الدلالة	تفسير
التنبؤ الكمي	.774	.000	0.05 > .Sig	البعد غير دال احصائيا ليس له تأثير
جمع البيانات	.745	.000	0.05 > .Sig	البعد غير دال احصائيا ليس له تأثير
تصنيف البيانات	-.062	.448	0.05 < .Sig	البعد ذو دلالة إحصائية وله تأثير إيجابي
كشف الانحرافات	.068	.573	0.05 < .Sig	البعد ذو دلالة إحصائية وله تأثير إيجابي

المصدر: إعداد الباحث بالاعتماد على برنامج spss

استهلاك الموارد كما يعرض النموذج الأبعاد الأربعة لكل متغير (A1-A4) و (B1-B4) والعلاقات المباشرة بينهما، كما تشير الأرقام على الأسهم إلى قوة وتأثير كل علاقة.

و. نموذج المعادلات الهيكلية (Structural Equation Modeling - SEM).

يوضح الشكل (5) نموذج المسار الذي يربط بين المتغير المستقل (A)، تقنية التعلم الآلي، والمتغير التابع (B)، مراقبة



الشكل رقم (1): نموذج المعادلات الهيكلية بين المتغيرين تقنية التعلم الآلي (A و B) مراقبة استهلاك الموارد

المصدر: مخرجات برنامج Amos, SPSS

هذه النتيجة تتوافق مع ما أكدته دراسات سابقة، مثل دراسة (Ucoglu, 2020) التي أبرزت دور التعلم الآلي في تحليل البيانات المحاسبية وان تطبيق أدوات التعلم الآلي له مزايا عديدة، مثل زيادة الكفاءة

ز.مناقشة النتائج

1. الفرضية الرئيسية: تؤكد النتائج التحليل الاحصائي على وجود علاقة قوية ذات دلالة إحصائية بين تقنية التعلم الآلي و مراقبة استهلاك الموارد (R = 0.717, Sig. = 0.000)،

2. ان توظيف ابعاد تقنية التعلم الآلي توفر أدوات رقمية عالية الدقة تساعد على تحليل انحرافات الإنتاج ومسبباتها ومن ثم قياس دقيق للتكاليف.
3. ان توظيف ابعاد تقنية التعلم الآلي توفر معلومات دقيقة حول سلوك التكلفة، ومن ثم إعداد تقارير إنتاجية تعكس الأداء الحقيقي مما يساعد على اتخاذ قرارات لتحسين الإنتاج.
4. أظهرت النتائج الإحصائية وجود علاقة ذات دلالة إحصائية قوية بين تقنية التعلم الآلي ومراقبة استهلاك الموارد.
5. أظهرت النتائج وجود علاقة إحصائية قوية بين بُعدي "التنبؤ الكمي" و "جمع البيانات" الأكثر تأثيرًا على ابعاد مراقبة استهلاك الموارد،

التوصيات:

1. إنشاء مركز استشاري متخصص في تحليل البيانات داخل الوحدات الصناعية، مهمته جمع البيانات الإنتاج ومعالجتها باستخدام تقنية التعلم الآلي، ويعمل على توفير تقارير استباقية دقيقة للإدارة العليا.
2. استخدام ادوات رقمية لكشف عن الانحرافات في الوقت الفعلي، بهدف تقليل الهدر في الموارد وتحديد الطاقة غير المستغلة بشكل مبكر لدعم الاستخدام الأمثل للموارد.
3. لضمان نجاح تطبيق التحول رقمي، ينبغي التعامل مع مقاومة الموظفين للتغيير كأولوية قصوى. لا تكتف بتطبيق التكنولوجيا، بل تركز على بناء ثقافة داعمة من خلال اشرح بوضوح لماذا يتم هذا التغيير وكيف سيعود بالنفع على الوحدة.
4. تأهيل الكوادر من المحاسبي التكاليف عبر برامج تدريبية متخصصة في تقنيات التحليل الرقمي والتعلم الآلي، بما يمكنهم من دعم القرارات الاستراتيجية المبنية على البيانات تكاليف الإنتاج.
5. بدمج تقنيات التعلم الآلي ضمن نظم محاسبة التكاليف لتحويلها من أداة تقليدية ذات طبيعة تاريخية إلى أداة تنبؤية واستراتيجية، تُسهم في رفع كفاءة الأداء الإنتاجي

توافر البيانات:

تم تضمين البيانات المستخدمة لدعم نتائج هذه الدراسة في المقالة.

تضارب المصالح:

يعلن المؤلفون أنه ليس لديهم تضارب في المصالح.

مصادر التمويل:

لم يتم تلقي اي دعم مالي.

شكر وتقدير:

لا أحد.

References:

1. Achakzai, M. A. K., & Peng, J. (2023). Detecting financial statement fraud using

من خلال تحليل أسرع للبيانات، ومراقبة تدفق الموارد، وتقليل الأخطاء، والكشف المبكر عن الانحرافات، وخلق ميزة انتاجية.

2. **الفرضية الفرعية الاولى:** تؤكد النتائج التحليل الاحصائي على وجود علاقة قوية ذات دلالة إحصائية بين أبعاد التعلم الآلي فسرت نسبة ($R^2 = 0.845$) من التباين في قياس التكلفة، حيث كان التنبؤ الكمي و جمع البيانات الأكثر تأثيرًا، هذه النتيجة تتوافق مع دراسته (Moroff et al., 2021) حول أهمية البيانات والتنبؤ في تحسين دقة احتساب التكاليف تمثل ميزة الأساليب القائمة على الذكاء الاصطناعي في التحليل لبيانات، واكدتها دراسة (Cho et al., 2020) أهمية التنبؤ الاستباقي لقياس دقيق للتكلفة.

3. **الفرضية الفرعية الثانية:** تؤكد النتائج التحليل الاحصائي على وجود علاقة قوية ذات دلالة إحصائية بين أبعاد التعلم الآلي فسرت نسبة ($R^2 = 0.769$) من التباين في تحليل الطاقة غير المستغلة، مما يؤكد أن دقة البيانات التشغيلية تسهم وتحليل الطاقة غير المستغلة وهو ما يتفق مع نتائج دراسة (Al-Qizi, 2022:29) (على انها توفير معلومات كمية ملائمة أكثر تفصيلا عن الطاقة غير المستغلة).

4. **الفرضية الفرعية الثالثة:** تؤكد النتائج التحليل الاحصائي على وجود علاقة قوية ذات دلالة إحصائية بين أبعاد التعلم الآلي فسرت نسبة ($R^2 = 0.699$) من التباين في دعم اتخاذ القرارات لتحسين الإنتاج حيث كان التنبؤ الكمي هو المؤثر الوحيد بين المتغيرات البعد التعلم الآلي، وتتفق هذه النتائج مع ما توصلت إليه الدراسات (Saleh, 2025) و (Mohammed & Madhumithaa, 2024) والتي أكدت أن التعلم الآلي يُسهم بشكل فعال في تحسين العمليات التشغيلية التحليلات التنبؤية في صنع القرار الذي يُعد جزءًا أساسيًا من التنبؤ الكمي، في توجيه القرارات الاستراتيجية.

5. **الفرضية الفرعية الرابعة:** تؤكد النتائج التحليل الاحصائي على وجود علاقة قوية ذات دلالة إحصائية بين أبعاد التعلم الآلي فسرت نسبة ($R^2 = 0.886$) من التباين في تحليل البيانات لتعزيز الدقة في تقارير الإنتاج، حيث كان التنبؤ الكمي وجمع البيانات الأكثر تأثيرًا هذه النتيجة تُشير إلى أن دقة تقارير الإنتاج تعتمد بشكل كبير على دقة جمع البيانات. تتوافق هذه النتيجة مع دراسة (Adelakun & Fatogun, 2024) تُعد تقارير الإنتاج أداة مهمة لنظام التصنيع، بناءً على البيانات لتحسين الأداء يُمكن تحليل البيانات المتعلقة باستهلاك الموارد. باختصار، تؤكد النتائج أن دمج تقنيات التعلم الآلي في أنظمة المحاسبة، تسهم في دقة قياس التكلفة، وتحديد الطاقة غير المستغلة، وتوفير معلومات تحليلية دقيقة تدعم اتخاذ قرارات الإنتاج.

الاستنتاجات:

1. ان توظيف ابعاد تقنية التعلم الآلي تساعد في تحليل الطاقة غير المستغلة ومن ثم تقليل التضخم من التكاليف الإنتاجية.

- Artificial Intelligence and Machine Learning on Accounting Functions (Evidence from Selected Companies). *International Journal of Research and Innovation in Applied Science*, 07(02), 53–69. <https://doi.org/10.51584/ijrias.2022.7203>
9. Bodor, A., Hnida, M., & Daoudi, N. (2023). Interactive Mobile Technologies. *Interactive Mobile Technologies Online-Journals.Org*, 17(23), 125–139.
10. Cho, S., Vasarhelyi, M. A., Sun, T. (Sophia), & Zhang, C. (Abigail). (2020). Learning from Machine Learning in Accounting and Assurance. In *Annals of Tourism Research* (Vol. 3, Issue 4, p. 45). <http://www.ncbi.nlm.nih.gov/pubmed/25926610%5Cnhttp://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC4492060%0Ahttp://www.sciencedirect.com/science/article/pii/S0160738315000444>
11. DICKEY, G., Blanke, S., & Seaton, L. (2019). *Machine Learning in Auditing Current and Future Applications*. 1–7.
12. Elesawee, M. M. A. A. (2022). A proposed framework for improving energy management effectiveness using resource consumption accounting and value stream management - a case study. *Journal of Accounting Research*, 2(2), 104–140.
13. Farag, D. E.-M. R. (2024). Using a Resource Consumption Accounting System to Enhance Competitive Advantage: An Applied Study. *The Scientific Journal for Financial and Administrative Studies and Research*, 6(4).
14. Iqbal, T., Elahi, A., Wijns, W., & Shahzad, A. (2022). Exploring Unsupervised Machine Learning Classification Methods for Physiological Stress Detection. *Frontiers in Medical Technology*, 4(March), 1–12. <https://doi.org/10.3389/fmedt.2022.782756>
15. Jane, J. B., & Ganesh, E. N. (2019). *A Review On Big Data With Machine Learning And Fuzzy Logic For Better Decision Making*. 8(10), 1121–1125.
16. Joshi, P. L. (2021). *Will Artificial Intelligence (AI) Replace Accountants and Auditors in Future?* March, 27–48. <https://www.researchgate.net/publication/350579109>
- dynamic ensemble machine learning. *International Review of Financial Analysis*, 89(102827), 1–9.
2. Adalakun, B. O., & Fatogun, D. T. (2024). *Integrating machine learning algorithms into audit processes : Benefits and challenges*. 6(6), 1000–1016. <https://doi.org/10.51594/farj.v6i6.1233>
3. Al-Jabali, W. S. A.-A. (2020). A Proposed framework for the integration of material flow cost (MFCA) and Resource Consumption Accounting accounting (RCA) to support the competitiveness of business enterprises - field study -. *Journal of Financial and Business Research*, 21(3), 511–580.
4. Al-Janabi, A. M. S., & Mohammed, M. (2018). Study), Priority of resource consumption accounting system on cost-based costing system / Applied Research in Diyala General Company for Electrical Industries (Case. *Journal of Financial and Accounting Studies, Special Is*(1), 121–161. <https://repositorio.ufsc.br/bitstream/handle/123456789/186602/PPAU0156-D.pdf?sequence=1&isAllowed=y%0Ahttp://journal.stainkudus.ac.id/index.php/equilibrium/article/view/1268/1127%0Ahttp://www.scielo.br/pdf/rae/v45n1/v45n1a08%0Ahttp://dx.doi.org/10.1016/j>
5. Al-Qizi, S. S. J. M. (2022). *Integrating between Resource Consumption Accounting & Theory of Constraints to support Corporate Governance*. College of Management & Economics – Karbala University.
6. Al-Sayed, A. M. A., Al-Tantawi, H. A.-S. I., & El-Kassas, A. S. A.-D. (2019). The Role of Resource Consumption Accounting System in Supporting the Competitiveness Capabilities of Business Organizations (With a Field Study). *International Journal of Research and Innovation in Applied Science (IJRIAS)*, 8(12), 163-183.
7. Alsuhaimee, R. M., Aldhafeeri, S. A., & Maha Mohammed Alotaibi. (2025). Strategies for solving administrative problems using machine learning technology on Amazon. *Journal of Economic, Administrative and Legal Sciences (JEALS)*, 9(4), 17–33.
8. Austin, O. E. (2022). Probing the Effect of

- (2023). Learning from Machine Learning in Accounting and Assurance. *Journal of Accounting and Financial Studies*, 18(63), 277–290.
26. Stodt, J., & Reich, C. (2021). *Machine Learning Development Audit Framework : Assessment and Inspection of Risk and Quality of Data , Model and Development Process*. 15(3), 187–193.
27. Ucoglu, D. (2020). Current machine learning applications in accounting and auditing. *Pressacademia*, 12(1), 1–7. <https://doi.org/10.17261/pressacademia.2020.1337>
28. Varoquaux, G., & Colliot, O. (2023). Evaluating Machine Learning Models and Their Diagnostic Value. *Neuromethods*, 197, 601–630. https://doi.org/10.1007/978-1-0716-3195-9_20
29. Vishwakarma, A. (2024). Machine Learning Algorithms - A Review Batta. *International Journal of Science and Research (IJSR)*, January 2019, 162–175. <https://doi.org/10.58532/nbennurch299>
- Achakzai, M. A. K., & Peng, J. (2023). Detecting financial statement fraud using dynamic ensemble machine learning. *International Review of Financial Analysis*, 89(102827), 1–9.
30. Adelakun, B. O., & Fatogun, D. T. (2024). *Integrating machine learning algorithms into audit processes : Benefits and challenges*. 6(6), 1000–1016. <https://doi.org/10.51594/farj.v6i6.1233>
31. Al-Jabali, W. S. A.-A. (2020). A Proposed framework for the integration of material flow cost (MFCA) and Resource Consumption Accounting accounting (RCA) to support the competitiveness of business enterprises - field study -. *Journal of Financial and Business Research*, 21(3), 511–580.
32. Al-Janabi, A. M. S., & Mohammed, M. (2018). Study), Priority of resource consumption accounting system on cost-based costing system / Applied Research in Diyala General Company for Electrical Industries (Case. *Journal of Financial and Accounting Studies*, Special Is(1), 121–161.
17. Moala, B., & Hamid, M. A. (2020). First Steps Toward Machine Learning. *Al-Manara University Journal*, 1(1), 1–16.
18. Mohammad, M. K. (2021). Effect of Resources Consumption Accounting to Reduce Cost A Case Study in Slaughter House Poultry Itmad/Erbil. *Tikrit Journal of Administrative and Economic Sciences*, 54(17), 1–18.
19. Mohammed, I. A., & Madhumithaa, N. (2024). Transforming Decision-Making: The Impact of AI and Machine Learning on Strategic Business Operations. *Library Progress International*, 44(3), 22005–22013. www.bpasjournals.com
20. Moroff, N. U., Kurt, E., & Kamphues, J. (2021). Machine Learning and Statistics: A Study for assessing innovative Demand Forecasting Models. *Procedia Computer Science*, 180(2019), 40–49. <https://doi.org/10.1016/j.procs.2021.01.127>
21. Nigenda, D., Karnin, Z., Zafar, M. B., Ramesha, R., Tan, A., Donini, M., & Kenthapadi, K. (2022). *Amazon SageMaker Model Monitor : A System for Real-Time Insights into Deployed Machine Learning Models*. i, 3671–3681. <https://doi.org/10.1145/3534678.3539145>
22. Omer, muhamad salih dawood. (2020). *Integration Between the Two Methods of Targeted Cost and Resource Consumption Accounting and Its Role in Achieving Competitive Advantage in Industrial Establishments (A field study on Sega Industrial Company)*. Al Neelain University.
23. Saeed, M. A.-Q. M., & Khalil, R. A. (2021). THE CONSUMPTION RESOURCES ACCOUNTING AND ITS ROLE IN SUPPORT COMPETITIVE ADVANTAGE. *Humanitarian & Natural Sciences Journal*, 2(12), 163–183.
24. Saleh, S. M. M. M. (2025). The impact of applying machine learning algorithms on predicting the direction of stock prices: An applied study on companies listed in the Egyptian Stock Exchange. *Journal of Managerial, Financial & Quantitative Research*, 5(2), 3–46.
25. Salman, H. D., & Alghabban, F. I. M.

and Future Applications. 1–7.

40. Elesawee, M. M. A. A. (2022). A proposed framework for improving energy management effectiveness using resource consumption accounting and value stream management - a case study. *Journal of Accounting Research*, 2(2), 104–140.

41. Farag, D. E.-M. R. (2024). Using a Resource Consumption Accounting System to Enhance Competitive Advantage: An Applied Study. *The Scientific Journal for Financial and Administrative Studies and Research*, 6(4).

42. Iqbal, T., Elahi, A., Wijns, W., & Shahzad, A. (2022). Exploring Unsupervised Machine Learning Classification Methods for Physiological Stress Detection. *Frontiers in Medical Technology*, 4(March), 1–12. <https://doi.org/10.3389/fmedt.2022.782756>

43. Jane, J. B., & Ganesh, E. N. (2019). A Review On Big Data With Machine Learning And Fuzzy Logic For Better Decision Making. 8(10), 1121–1125.

44. Joshi, P. L. (2021). Will Artificial Intelligence (AI) Replace Accountants and Auditors in Future? March, 27–48. <https://www.researchgate.net/publication/350579109>

45. Moala, B., & Hamid, M. A. (2020). First Steps Toward Machine Learning. *Al-Manara University Journal*, 1(1), 1–16.

46. Mohammad, M. K. (2021). Effect of Resources Consumption Accounting to Reduce Cost A Case Study in Slaughter House Poultry Itmad/Erbil. *Tikrit Journal of Administrative and Economic Sciences*, 54(17), 1–18.

47. Mohammed, I. A., & Madhumithaa, N. (2024). Transforming Decision-Making: The Impact of AI and Machine Learning on Strategic Business Operations. *Library Progress International*, 44(3), 22005–22013. www.bpasjournals.com

48. Moroff, N. U., Kurt, E., & Kamphues, J. (2021). Machine Learning and Statistics: A Study for assessing innovative Demand Forecasting Models. *Procedia Computer Science*, 180(2019), 40–49. <https://doi.org/10.1016/j.procs.2021.01.127>

49. Nigenda, D., Karnin, Z., Zafar, M. B.,

<https://repositorio.ufsc.br/bitstream/handle/123456789/186602/PPAU0156-D.pdf?sequence=1&isAllowed=y%0Ahttp://journal.stainkudus.ac.id/index.php/equilibrium/article/view/1268/1127%0Ahttp://www.scielo.br/pdf/rae/v45n1/v45n1a08%0Ahttp://dx.doi.org/10.1016/j>

33. Al-Qizi, S. S. J. M. (2022). *Integrating between Resource Consumption Accounting & Theory of Constraints to support Corporate Governance*. College of Management & Economics – Karbala University.

34. Al-Sayed, A. M. A., Al-Tantawi, H. A.-S. I., & El-Kassas, A. S. A.-D. (2019). The Role of Resource Consumption Accounting System in Supporting the Competitiveness Capabilities of Business Organizations (With a Field Study). *International Journal of Research and Innovation in Applied Science (IJRIAS)*, 8(12), 163-183.

35. Alsuhaime, R. M., Aldhafeeri, S. A., & Maha Mohammed Alotaibi. (2025). Strategies for solving administrative problems using machine learning technology on Amazon. *Journal of Economic, Administrative and Legal Sciences (JEALS)*, 9(4), 17–33.

36. Austin, O. E. (2022). Probing the Effect of Artificial Intelligence and Machine Learning on Accounting Functions (Evidence from Selected Companies). *International Journal of Research and Innovation in Applied Science*, 07(02), 53–69. <https://doi.org/10.51584/ijrias.2022.7203>

37. Bodor, A., Hnida, M., & Daoudi, N. (2023). Interactive Mobile Technologies. *Interactive Mobile Technologies Online-Journals.Org*, 17(23), 125–139.

38. Cho, S., Vasarhelyi, M. A., Sun, T. (Sophia), & Zhang, C. (Abigail). (2020). Learning from Machine Learning in Accounting and Assurance. In *Annals of Tourism Research* (Vol. 3, Issue 4, p. 45). <http://www.ncbi.nlm.nih.gov/pubmed/25926610%5Cnhttp://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC4492060%0Ahttp://www.sciencedirect.com/science/article/pii/S0160738315000444>

39. DICKEY, G., Blanke, S., & Seaton, L. (2019). *Machine Learning in Auditing Current*

53. Salman, H. D., & Alghabban, F. I. M. (2023). Learning from Machine Learning in Accounting and Assurance. *Journal of Accounting and Financial Studies*, 18(63), 277–290.
54. Stodt, J., & Reich, C. (2021). *Machine Learning Development Audit Framework: Assessment and Inspection of Risk and Quality of Data, Model and Development Process*. 15(3), 187–193.
55. Ucoglu, D. (2020). Current machine learning applications in accounting and auditing. *Pressacademia*, 12(1), 1–7. <https://doi.org/10.17261/pressacademia.2020.1337>
56. Varoquaux, G., & Colliot, O. (2023). Evaluating Machine Learning Models and Their Diagnostic Value. *Neuromethods*, 197, 601–630. https://doi.org/10.1007/978-1-0716-3195-9_20
57. Vishwakarma, A. (2024). Machine Learning Algorithms - A Review Batta. *International Journal of Science and Research (IJSR)*, January 2019, 162–175. <https://doi.org/10.58532/nbennurch299>
- Ramesha, R., Tan, A., Donini, M., & Kenthapadi, K. (2022). *Amazon SageMaker Model Monitor: A System for Real-Time Insights into Deployed Machine Learning Models*. i, 3671–3681. <https://doi.org/10.1145/3534678.3539145>
50. Omer, muhamad salih dawood. (2020). *Integration Between the Two Methods of Targeted Cost and Resource Consumption Accounting and Its Role in Achieving Competitive Advantage in Industrial Establishments (A field study on Sega Industrial Company)*. Al Neelain University.
51. Saeed, M. A.-Q. M., & Khalil, R. A. (2021). THE CONSUMPTION RESOURCES ACCOUNTING AND ITS ROLE IN SUPPORT COMPETITIVE ADVANTAGE. *Humanitarian & Natural Sciences Journal*, 2(12), 163–183.
52. Saleh, S. M. M. M. (2025). The impact of applying machine learning algorithms on predicting the direction of stock prices: An applied study on companies listed in the Egyptian Stock Exchange. *Journal of Managerial, Financial & Quantitative Research*, 5(2), 3–46.

الملحق رقم (1)، (2) التحليلات الإحصائية المتعلقة بتقنية التعلم الآلي ومراقبة استهلاك الموارد.							
الملحق رقم (1) المحور الأول: تقنية التعلم الآلي							
البعد الأول: التنبؤ الكمي باستهلاك الموارد: يركز هذا البعد على دور تقنية التعلم الآلي على التنبؤ بدقة بالكميات المطلوبة لاستهلاك الموارد.							
الفقرة	المتوسط (Mean)	الانحراف المعياري (Std. Deviation)	التكرار (N)	لا أتفق تمامًا (%)	لا أتفق (%)	محايد (%)	أتفق تمامًا (%)
تساعد تقنية التعلم الآلي في التنبؤ بدقة بالكميات المستقبلية من الموارد المطلوبة؟	2.86	1.47	44	22.7	29.5	2.3	29.5
تساعد تقنية التعلم الآلي في تحديد العوامل الرئيسية المؤثرة على حجم استهلاك الموارد؟	2.75	1.51	44	22.7	38.6	0	18.2
تساعد تقنية التعلم الآلي في تقدير الكميات المعيارية من الموارد بناءً على البيانات التاريخية؟	3.25	1.53	44	15.9	27.3	2.3	29.5
تساعد تقنية التعلم الآلي توفير معلومات كمية تساهم في تخطيط الإنتاج؟	3.18	1.24	44	0	45.5	13.6	18.2
المجموع الكلي	3.01	1.44					
البُعد الثاني: تصنيف البيانات حسب مستوى الاستهلاك يركز هذا البُعد استخدام التعلم الآلي لتصنيف الأنواع إلى فئات مُحددة مسبقاً بناءً على مستويات استهلاكها.							
الفقرة	المتوسط (Mean)	الانحراف المعياري (Std. Deviation)	التكرار (N)	لا أتفق تمامًا (%)	لا أتفق (%)	محايد (%)	أتفق تمامًا (%)
يساعد التعلم الآلي على تصنيف أنواع الموارد أو المواد بناءً على مستويات استهلاكها؟	2.36	1.46	44	34.1	38.6	0	11.4
يساعد التعلم الآلي على تصنيف بيانات الإنتاج بناءً على معدل استهلاك الموارد؟	3.8	1.34	44	13.6	2.3	11.4	36.4
يساعد التعلم الآلي على تصنيف عناصر التكلفة بناءً على استهلاكها في	3.05	1.6	44	31.8	6.8	6.8	34.1

المجموع الكلي								الفقرة
25	52.3	11.4	6.8	4.5	44	1.03	3.86	عمليات الإنتاج؟ يساعد التعلم الآلي على تصنيف الأنشطة أو العمليات الصناعية بناءً على استهلاكها للموارد؟
المجموع الكلي								3.27
المجموع الكلي								1.36
البعد الثالث: اكتشاف الانحرافات في استهلاك الموارد يركز هذا البعد قدرة التعلم الآلي على تحديد الأنماط غير العادية أو غير الطبيعية في استهلاك الموارد.								
المتوسط (Mean)	الانحراف المعياري (Std. Deviation)	التكرار (N)	لا أتفق تمامًا (%)	لا أتفق (%)	محايد (%)	أتفق (%)	أتفق تمامًا (%)	الفقرة
4.16	0.71	44	2.3	0	4.5	65.9	27.3	تساعد تقنية التعلم الآلي في اكتشاف أي زيادات غير طبيعية في استهلاك الموارد؟
4	1.03	44	4.5	6.8	4.5	52.3	31.8	تساعد تقنية التعلم الآلي في توفير تحذيرات مبكرة بشأن الهدر أو الأعطال المحتملة بناءً على أنواع الاستهلاك غير الطبيعية؟
3.77	1.05	44	4.5	9.1	13.6	50	22.7	تساعد تقنية التعلم الآلي في تحديد اساليب الإنتاج المتعلقة باستهلاك الموارد؟
3.23	1.33	44	4.5	38.6	11.4	20.5	25	تساعد تقنية التعلم الآلي في تحسين عمليات مراقبة استهلاك الموارد من خلال الكشف التلقائي عن الانحرافات؟
المجموع الكلي								3.79
المجموع الكلي								1.03
البعد الرابع: تجميع البيانات بناءً على نوع الاستهلاك: يركز هذا البعد على توظيف التعلم الآلي لتجميع نقاط البيانات المتشابهة في مجموعات بناءً على أنماط استهلاكها.								
المتوسط (Mean)	الانحراف المعياري (Std. Deviation)	التكرار (N)	لا أتفق تمامًا (%)	لا أتفق (%)	محايد (%)	أتفق (%)	أتفق تمامًا (%)	الفقرة
3.23	1.22	44	2.3	38.6	11.4	29.5	18.2	
3.09	1.41	44	6.8	45.5	6.8	13.6	27.3	تساعد تقنية التعلم الآلي في اكتشاف أنماط الاستهلاك غير المتوقعة التي لم تكن معروفة سابقًا.
2.75	1.66	44	38.6	11.4	9.1	18.2	22.7	تساعد تقنية التعلم الآلي في فهم شرائح مختلفة من المستهلكين أو الأجهزة بناءً على أوجه التشابه في استهلاكهم.
2.86	1.55	44	25	27.3	6.8	18.2	22.7	تساعد تقنية التعلم الآلي في صياغة استراتيجيات مخصصة لإدارة الموارد لكل مجموعة محددة.
المجموع الكلي								2.98
المجموع الكلي								1.46

المحور الثاني: مراقبة استهلاك الموارد								الملحق رقم (2)
البعد الأول في قياس دقيق للتكلفة								الفقرة
المتوسط (Mean)	الانحراف المعياري (Std. Deviation)	التكرار (N)	لا أتفق تمامًا (%)	لا أتفق (%)	محايد (%)	أتفق (%)	أتفق تمامًا (%)	الفقرة
2.39	1.45	44	31.8	38.6	6.8	4.5	18.2	تساعد مراقبة استهلاك الموارد في تحديد قياس دقيق لتكاليف الإنتاج.
2.68	1.49	44	25	36.4	2.3	18.2	18.2	تساعد مراقبة استهلاك الموارد في توفير البيانات عن تكاليف الإنتاج.
3.32	1.38	44	4.5	38.6	6.8	20.5	29.5	تساعد مراقبة استهلاك في التنبؤ بالتكاليف الإنتاج
3.27	1.44	44	6.8	38.6	6.8	15.9	31.8	تساعد مراقبة استهلاك من تحديد انحرافات الموارد وتكاليف الإنتاج المعيارية.

المجموع العام								1.44	2.92
البعد الثاني: تحليل الطاقة غير المستغلة؟								المتوسط (Mean)	الانحراف المعياري (Std. Deviation)
المتوسط (Mean)	الانحراف المعياري (Std. Deviation)	التكرار (N)	لا أتفق تمامًا (%)	لا أتفق (%)	محايد (%)	أتفق (%)	أتفق تمامًا (%)	الفقرة	
3.57	1.44	44	18.2	4.5	9.1	38.6	29.5	مراقبة استهلاك الموارد تساعد على تحديد الطاقة غير المستغلة.	
3.2	1.32	44	4.5	40.9	6.8	25	22.7	توظيف الطاقة الإنتاجية غير المستغلة، يسهم في زيادة الإنتاجية.	
2.8	1.27	44	4.5	59.1	6.8	11.4	18.2	توظيف الطاقة الإنتاجية غير المستغلة، يؤدي إلى قياس دقيق للتكلفة.	
2.82	1.28	44	4.5	59.1	4.5	13.6	18.2	تحديد الطاقة غير المستغلة يسهم في توفير معلومات كمية ومالية.	
المجموع الكلي								3.09	1.35
البعد الثالث: دعم اتخاذ القرارات لتحسين الإنتاج									
المتوسط (Mean)	الانحراف المعياري (Std. Deviation)	التكرار (N)	لا أتفق (%)	لا أتفق تمامًا (%)	محايد (%)	أتفق (%)	أتفق تمامًا (%)	الفقرة	

(%)	(%)	(%)	(%)	أُتفق تمامًا (%)		المعياري (Std. Deviation)	سط (Me an)	
18.2	15.9	11.4	47.7	6.8	44	1.29	2.91	لمراقبة استهلاك الموارد توفر معلومات عن التكلفة لدعم اتخاذ القرارات الإنتاجية.
20.5	9.1	18.2	47.7	4.5	44	1.26	2.93	مراقبة استهلاك الموارد توفر معلومات حول مستويات الإنتاج لدعم اتخاذ القرارات الإنتاجية.
31.8	18.2	6.8	4.5	38.6	44	1.77	3	يساعد مراقبة استهلاك الموارد على تحديد نقص الموارد في عملية الإنتاج.
31.8	18.2	2.3	15.9	31.8	44	1.72	3.02	يساعد مراقبة استهلاك الموارد تحسين جودة المنتج واكتشاف المشكلات المحتملة في وقت مبكر.
						1.44	2.96	
البعد الرابع: تحليل البيانات التاريخية لتعزيز الدقة في تقارير الإنتاج؟								
أُتفق تمامًا (%)	أُتفق (%)	محايد (%)	لا أُتفق (%)	لا أُتفق تمامًا (%)	التكرار (N)	الانحراف المعياري (Std. Deviation)	المتوسط (Mean)	الفقرة
63.6	27.3	4.5	4.5	0	44	0.79	4.5	تساعد مراقبة استهلاك الموارد في تحليل البيانات التاريخية، مما يعزز دقة تقارير الإنتاج.
61.4	31.8	6.8	0	0	44	0.63	4.55	اتخاذ قرارات تصحيحية سريعة استنادًا إلى تحليل للبيانات التاريخية.
59.1	29.5	4.5	2.3	4.5	44	1.01	4.36	مراقبة استهلاك تساعد على نُقل من الأخطاء في إعداد تقارير الإنتاج من خلال اتمتة تحليل البيانات.
47.7	36.4	2.3	11.4	2.3	44	1.08	4.16	تحليل البيانات للتنبؤ بالإنتاج وتحسين الاستهلاك، مما يساهم في زيادة الإنتاجية.
						0.88	4.3925	