



استخدام تقنيات الذكاء الاصطناعي والتعلم الآلي في التنبؤ بأداء المشاريع الهندسية من حيث المدة والتكلفة دراسة تحليلية

"Using Artificial Intelligence and Machine Learning Techniques to Predict Engineering Project Performance in Terms of Duration and Cost: An Applied Study"

د/ عواطف على عبد السلام موسى

إدارة مشاريع هندسية / المعهد العالي لتقنيات شؤون المياه العجيات / ليبيا

Awhatfali@yahoo.com

تاريخ الاستلام: 2025/9/8 - تاريخ المراجعة: 2025/10/2 - تاريخ القبول: 2025/10/14 - تاريخ النشر: 2025/10/21

الملخص:

تسعى هذه الدراسة إلى تقييم أثر تقنيات الذكاء الاصطناعي (AI) والتعلم الآلي (ML) في التنبؤ بأداء المشاريع الهندسية، مع التركيز على المدة الزمنية والتكلفة لمشروع صيانة طريق الشط - طرابلس في ليبيا. تأتي أهمية الدراسة من التحديات التي تواجه قطاع الطرق في ليبيا، مثل التأخيرات المتكررة، ارتفاع التكاليف، وضعف دقة التخطيط التقليدي المعتمد على خبرة المهندسين وطرق شبكة المسار الحرج (CPM). اعتمدت الدراسة على منهج ميداني تطبيقي، حيث تم جمع البيانات الميدانية والتقارير الرسمية للمشروع، إلى جانب تقييم خبرات المشرفين والمهندسين. وشملت عينة الدراسة بيانات المشروع الفعلية للفترة 2024-2025، وعدد 25 مهندساً ومشرفاً مشاركاً في التنفيذ. وتم تحليل البيانات باستخدام خوارزميات التعلم الآلي Random Forest، XGBoost، والشبكات العصبية الاصطناعية (ANN)، مع تقييم دقة النماذج عبر مؤشرات الأداء R^2 ، MAE، RMSE.

أظهرت النتائج وجود انحراف بنسبة 11% في المدة و12% في التكلفة مقارنة بالقيم المخططة، مما يوضح قصور الطرق التقليدية. كما بينت النماذج الذكية تحسناً ملحوظاً في التنبؤ، حيث سجل XGBoost أفضل أداء في تقدير المدة والتكلفة. وأظهرت الدراسة أن الأحوال الجوية وتوفر العمالة كانت من أهم العوامل المؤثرة على المدة، بينما كانت تقلبات أسعار المواد والتغيرات في التصميم الأبرز تأثيراً على التكلفة. استناداً إلى هذه النتائج، توصي الدراسة بـ: اعتماد نماذج الذكاء الاصطناعي في تخطيط المشاريع الهندسية، مراقبة العوامل المؤثرة على الأداء، تدريب المهندسين على استخدام الأدوات الذكية، وإنشاء قاعدة بيانات مركزية للمشاريع لتسهيل تطبيق النماذج المستقبلية. كما يُقترح توسيع نطاق البحث ليشمل مشاريع بنية تحتية أخرى واستخدام تقنيات التعلم العميق للتعامل مع البيانات الكبيرة والمعقدة. تؤكد الدراسة أن توظيف الذكاء الاصطناعي والتعلم الآلي يساهم في تحسين دقة التنبؤ بالمدة والتكلفة، وتقليل الانحرافات، ورفع كفاءة اتخاذ القرار في المشاريع الهندسية، مما يعزز الأداء المؤسسي ويقلل مخاطر الفشل في المشاريع المستقبلية.

الكلمات المفتاحية: الذكاء الاصطناعي، التعلم الآلي، التنبؤ بالمدة والتكلفة، إدارة المشاريع الهندسية

Abstract

This study aims to assess the impact of Artificial Intelligence (AI) and Machine Learning (ML) techniques on predicting the performance of engineering projects, focusing on project duration and cost for the maintenance of Al-Shat Road – Tripoli, Libya. The study's significance stems from the challenges faced by the road sector in Libya, such as recurring delays, cost overruns, and the limited accuracy of traditional planning methods based on engineers' experience and the Critical Path Method (CPM).

The study employed a field-based applied methodology, collecting field data and official project reports, along with expert evaluations from supervisors and engineers. The study sample included actual project data from 2024–2025 and 25 engineers and supervisors involved in project execution. Data were analyzed using ML algorithms Random Forest, XGBoost, and Artificial Neural Networks (ANN), with model accuracy evaluated using performance indicators RMSE, MAE, and R^2 .

The results showed an 11% deviation in project duration and a 12% deviation in cost compared to planned values, highlighting the limitations of traditional methods. Smart models demonstrated a significant improvement in prediction accuracy, with XGBoost achieving the best performance for both duration and cost estimation. The study also revealed that weather conditions and labor availability were the most influential factors on duration, while material price fluctuations and design changes had the greatest impact on cost.

Based on these findings, the study recommends: adopting AI models for planning engineering projects, monitoring performance-influencing factors, training engineers on smart tools, and establishing a centralized project database to facilitate future application of predictive models. Additionally, it suggests expanding the research to other infrastructure projects and utilizing Deep Learning techniques for handling large and complex project data.

The study confirms that employing AI and ML techniques significantly improves the accuracy of duration and cost predictions, reduces deviations, and enhances decision-making efficiency in engineering projects, thereby improving institutional performance and minimizing the risk of project failure.

Keywords: Artificial Intelligence, Machine Learning, Project Duration and Cost Prediction, Engineering Project Management

المقدمة:

تشهد ليبيا في السنوات الأخيرة جهودًا متزايدة لإعادة تأهيل وصيانة بنيتها التحتية، خاصة في قطاع الطرق الذي يمثل شريان الحياة الاقتصادية والاجتماعية، ويُعد طريق الشط بمدينة طرابلس من أهم الطرق الحيوية التي تربط مناطق المدينة الساحلية والميناء والمناطق التجارية الرئيسية. غير أن هذا الطريق يعاني من مشكلات هيكلية متكررة مثل الهبوطات والتشققات وضعف تصريف مياه الأمطار، إضافة إلى تأخر أعمال الصيانة الدورية نتيجة تحديات مالية وإدارية وفنية، تُعد مشاريع صيانة الطرق من المشاريع الهندسية المعقدة التي تتأثر بعدة عوامل، منها ظروف الطقس، وتوفر الموارد، والتغيرات في التصميم أو الكميات، ما يجعل التنبؤ الدقيق بالمدة الزمنية والتكلفة الإجمالية أمرًا بالغ الصعوبة، وهنا يبرز دور تقنيات الذكاء الاصطناعي والتعلم الآلي (AI & ML) في دعم قرارات إدارة المشاريع، إذ يمكن من خلالها تحليل بيانات سابقة للمشروعات واستخراج الأنماط والعلاقات التي تُسهّم في التنبؤ المسبق بالنتائج، وبالتالي تقليل الانحرافات وتحسين كفاءة التنفيذ (Madi & Ahmed, 2023). من هذا المنطلق، تسعى هذه الدراسة إلى توظيف خوارزميات الذكاء الاصطناعي والتعلم الآلي في تحليل البيانات الميدانية لمشروع صيانة طريق الشط – طرابلس بهدف التنبؤ بالمدة والتكلفة الفعلية ومقارنة دقة هذه النماذج بالطرق التقليدية في التخطيط.

أولاً : مشكلة الدراسة :

تُعاني مشاريع الطرق في ليبيا من ضعف في أنظمة المتابعة والتحليل، إذ تعتمد أغلبها على أساليب تقليدية في تقدير الوقت والتكلفة، مما يؤدي إلى تكرار التأخيرات وزيادة النفقات في مشروع صيانة طريق الشط – طرابلس، ظهرت فروقات واضحة بين القيم المخططة والفعلية سواء في الجداول الزمنية أو التكاليف التشغيلية. ورغم توفر بيانات ميدانية كثيرة، إلا أن غياب التحليل الذكي لتلك البيانات يجعل إدارتها أقل كفاءة. بناءً على ذلك.

وتتحدد مشكلة الدراسة في السؤال الرئيسي التالي:

كيف يمكن توظيف تقنيات الذكاء الاصطناعي والتعلم الآلي للتنبؤ بالمدة والتكلفة الفعلية لمشروع صيانة طريق الشط – طرابلس، وتحسين دقة التخطيط مقارنة بالأساليب التقليدية؟

وينبثق عن هذا السؤال مجموعة من الأسئلة الفرعية:

- 1/ ما أبرز العوامل التي تؤثر في مدة وتكلفة مشاريع صيانة الطرق في ليبيا؟
- 2/ ما دقة النماذج التقليدية مقارنة بخوارزميات التعلم الآلي في التنبؤ بأداء المشروع؟
- 3/ كيف يمكن توظيف النتائج في تحسين عمليات التخطيط والمتابعة المستقبلية لمشروعات الطرق؟

ثانياً: أهداف الدراسة:

ويتحدد الهدف الرئيسي فيما يلي :

تحديد كيفية توظيف تقنيات الذكاء الاصطناعي والتعلم الآلي في التنبؤ بالمدة والتكلفة الفعلية لمشروع صيانة طريق الشط – طرابلس، وتحسين دقة التخطيط مقارنة بالأساليب التقليدية.

الأهداف الفرعية:

1. تحليل البيانات الميدانية لمشروع صيانة طريق الشط لتحديد العوامل الأكثر تأثيراً على الأداء الزمني والمالي.
2. مقارنة دقة النماذج التقليدية مثل خبرة المهندسين وشبكة المسار الحرج (CPM) بدقة خوارزميات التعلم الآلي (Random Forest)، XGBoost، ANN في التنبؤ بالمدة والتكلفة.
3. تقديم إطار عملي وتوصيات يمكن للجهات الليبية اعتماده لتحسين التخطيط والمتابعة في مشاريع الطرق المستقبلية باستخدام AI & ML.

ثالثاً: أهمية الدراسة:**الأهمية العلمية:**

- 1/ تُسهم الدراسة في سد فجوة معرفية تتعلق بتطبيق الذكاء الاصطناعي في قطاع إدارة مشاريع البنية التحتية في ليبيا، إذ لم تُطبّق هذه التقنيات على نطاق ميداني واسع من قبل
 - 2/ توفر إطاراً علمياً لقياس كفاءة النماذج التنبؤية في بيئة هندسية حقيقية.
- ب. الأهمية التطبيقية:**

- 1/ تمكّن الجهات المنفذة من تحسين التخطيط الزمني والمالي لمشروعات الطرق.
- 2/ توفر أداة تحليل تساعد متخذي القرار في تحديد المخاطر المحتملة مبكراً
- 3/ اعتماد نتائجها لتطوير نظام ذكي لإدارة المشروعات داخل الوزارات أو البلديات .

رابعاً: حدود الدراسة:

- الحدود المكانية:** تشمل الحدود المكانية مدينة طرابلس – مشروع صيانة طريق الشط
- الحدود الزمانية:** تتمثل هذه الحدود في البيانات المستخلصة من فترة تنفيذ المشروع 2024–2025 .
- الحدود الموضوعية:** التنبؤ بالمدة الزمنية والتكلفة باستخدام خوارزميات الذكاء الاصطناعي. **الحدود البشرية:** تشمل عينة من مهندسي المشروع، المشرفين، والبيانات الميدانية الرسمية فقط.

خامساً: مصطلحات الدراسة:**1/ الذكاء الاصطناعي في إدارة المشاريع (Artificial Intelligence in Project Management)**

هو مجموعة من الأنظمة والخوارزميات القادرة على أداء مهام تحليلية وتنبؤية كانت تتطلب سابقاً الذكاء البشري، مثل التقييم، التخطيط، واتخاذ القرارات في بيئات معقدة.

(Lee et al., 2020; Kumar & Bansal, 2022)

2/ التعلم الآلي (Machine Learning – ML)

هو فرع من الذكاء الاصطناعي يركز على تطوير خوارزميات قادرة على التعلم من البيانات التاريخية والتنبؤ بالنتائج المستقبلية دون برمجة صريحة لكل حالة،

(Ahmad et al. (2019); Kumar & Bansal (2022)

3/ التعلم العميق (Deep Learning – DL)

هي شبكات عصبية متعددة الطبقات لمعالجة البيانات الكبيرة والتنبؤ بالعلاقات غير الخطية بين متغيرات المشروع

(Kumar & Bansal (2022)

4/ إدارة المشاريع الهندسية (Engineering Project Management)

هو مجموعة من العمليات المنهجية لتخطيط وتنظيم الموارد البشرية والمادية والتقنية بهدف تنفيذ المشروع ضمن المواصفات والمدة والتكلفة المحددة.

يوفر هذا الإطار العملي لتطبيق أدوات AI و ML لتحسين التنبؤ بالأداء وتحليل المخاطر.

Project Management Institute (PMI, 2021)

5/ المدة الزمنية للمشاريع (Project Duration)

يقصد به الوقت الكلي المستغرق لإكمال جميع أنشطة المشروع من البداية حتى التسليم النهائي

(Lee et al. (2020)

6/ تكلفة المشاريع (Project Cost) :

يعرف بأنه مجموع الموارد المالية المستثمرة في المشروع، بما في ذلك العمالة، المواد، المعدات، والتكاليف غير المباشرة. ويمكن التنبؤ بدقة التكلفة باستخدام AI و ML يساعد على تخطيط الميزانية، تقليل التجاوزات، وتحسين استخدام الموارد.

(Ahmad et al. (2019)

7/ النماذج التنبؤية (Predictive Models in Project Management) :

يقصد به بأنه نماذج تحليلية تعتمد على البيانات التاريخية والتقنيات الذكية (ANN)، Decision Trees، Random Forests، DL (التوقع نتائج المشاريع المستقبلية مثل المدة والتكلفة).
تستخدم هذه النماذج لتقييم أداء المشاريع الهندسية ومقارنة النتائج التنبؤية مع الأداء الفعلي، مما يعزز دقة اتخاذ القرار.
Kumar & Bansal (2022); Lee et al. (2020)
سادساً: الإطار النظري للدراسة:
إدارة المشاريع وأداء المشاريع الهندسية:

تعد إدارة المشاريع الهندسية مجالاً علمياً وتطبيقياً يركز على تحقيق الأهداف ضمن الوقت والميزانية والجودة، ويشمل أداء المشروع عادة:

1. المدة الزمنية: (Time) التزام المشروع بالجدول الزمني.
2. التكلفة: (Cost) الالتزام بالميزانية.
3. الجودة ونطاق العمل: (Scope & Quality) تحقيق الأهداف والمواصفات المطلوبة.

(PMI, 2021)

4. الذكاء الاصطناعي والتعلم الآلي في إدارة المشاريع:

شبكات العصبية الاصطناعية: (ANN) التنبؤ بفترات التأخير المحتملة وتحليل الأنماط المخفية.
أشجار القرار (Decision Trees) والغابات العشوائية: (Random Forests) تحديد المتغيرات المؤثرة على التأخير والتكلفة.
التعلم العميق: (DL) معالجة البيانات الكبيرة للتنبؤ بدقة أكبر بالمدة والتكلفة
• التعلم الآلي: (ML) فرع من AI يتيح للأنظمة التعلم من البيانات وتحسين الأداء تلقائياً دون تدخل بشري مباشر
تأثير أدوات وتقنيات AI و ML المرتبطة بالمدة والتكلفة:

(World Economic Forum, 2024)

الأداة	الوظيفة	التطبيق على المدة	التطبيق على التكلفة
الشبكات العصبية الاصطناعية (ANN)	اكتشاف الأنماط المخفية بين متغيرات المشروع	التنبؤ بفترات التأخير المحتملة بناءً على المهام والموارد	توقع التجاوزات في الميزانية بناءً على بيانات المشاريع السابقة
أشجار القرار (Decision Trees)	تحديد تأثير كل متغير على النتيجة النهائية	تحديد العوامل المؤثرة على تأخير المهام	تحليل أسباب زيادة المصروفات غير المتوقعة
الغابات العشوائية (Random Forests)	دمج نتائج عدة أشجار لتحسين الدقة	تحسين دقة التنبؤ بالمدة عبر تحليل المتغيرات المتشابهة	تحسين دقة تقديرات التكلفة وتحديد المخاطر المالية
التعلم العميق (Deep Learning)	معالجة البيانات الكبيرة والمعقدة	التنبؤ بالجدول الزمني للمشاريع الكبيرة والمعقدة	تقدير الميزانية الإجمالية مع دمج تأثير جميع عناصر المشروع

تقنيات تقييم دقة النماذج:

- MAE (Mean Absolute Error): متوسط الفرق بين القيم الفعلية والمتوقعة للمدة والتكلفة.
- RMSE (Root Mean Square Error): قياس تباين الأخطاء لتحديد موثوقية التنبؤ.
- R² (Coefficient of Determination): قياس مدى قدرة النموذج على تفسير التباين في البيانات الفعلية.

تأثير الذكاء الاصطناعي على المدة الزمنية والتكلفة في المشاريع الهندسية:

يُعدّ توظيف الذكاء الاصطناعي (AI) في إدارة المشاريع الهندسية أحد التطورات البارزة في العقدين الأخيرين، إذ مكّن من تحسين دقة التنبؤ بالمدة الزمنية والتكلفة من خلال تحليل البيانات التاريخية والبيانات الآنية للمشروعات، وتشير الدراسات الحديثة إلى أن استخدام خوارزميات التعلم الآلي (Machine Learning) والتعلم العميق (Deep Learning) أسهم في تحسين كفاءة الجدولة وتخفيض نسب تجاوز التكلفة والزمن مقارنة بالطرق التقليدية.

Hussein, M., & Nassar, K. (2021)

كما أظهر Zhang et al. (2022) أن دمج تقنيات الذكاء الاصطناعي في مراحل التخطيط والتنفيذ يساعد على تحديد المخاطر المبكرة للمشروع وتقليل انحرافات الأداء بنسبة تصل إلى 20% في التكلفة و15% في الزمن، خصوصاً في المشاريع الكبرى التي تتسم بدرجة عالية من التعقيد.

Zhang, Y., et al. (2022)

وفي دراسة أخرى، أشار Kim & Lee (2023) إلى أن نظم الذكاء الاصطناعي التنبؤية تمكنت من تقليل فجوات التقدير بين الخطة الأصلية والتنفيذ الفعلي، وذلك عبر استخدام نماذج تحليل الانحدار المتعدد والشبكات العصبية الصناعية التي تتعلم من مشاريع سابقة ذات خصائص مشابهة (Kim, H., & Lee, J. (2023)).

أما على المستوى التطبيقي، فقد أوضحت دراسة (World Economic Forum (2024) أن شركات المقاولات التي اعتمدت حلول الذكاء الاصطناعي في جدولة الموارد والعمالة استطاعت تحقيق وفورات زمنية تراوحت بين 10-25% في متوسط مدة الإنجاز، إضافة إلى خفض في التكلفة التشغيلية الإجمالية بنسبة تراوحت بين 5-18% (4).

هذه النتائج تؤكد أن الذكاء الاصطناعي لا يقتصر دوره على تحسين دقة التنبؤ فقط، بل يمتد ليشمل رفع كفاءة اتخاذ القرار وتخصيص الموارد ومراقبة الأداء، مما يعزز من القدرة التنافسية للمؤسسات الهندسية ويقلل من احتمالية فشل المشاريع.

الدراسات السابقة:

1. الدراسات المتعلقة بالذكاء الاصطناعي في إدارة المشاريع:
 - دراسة (Lee et al. (2020) أظهرت أن ANN يقلل متوسط الخطأ في تقدير التكلفة بنسبة 30%.
 - Zhang & Wang (2021) بينا أن ML يمكنه التنبؤ بالمدة الزمنية للمشاريع الكبيرة بدقة أعلى من الطرق التقليدية.
2. الدراسات المتعلقة بالتنبؤ بالأداء الهندسي:
 - Ahmad et al. (2019) طبق ML على مشاريع البناء، وحقق دقة أفضل بنسبة 25-35% مقارنة بالطرق التقليدية.
 - Kumar & Bansal (2022) أشاروا إلى أن معظم النماذج السابقة لا تغطي المشاريع الكبيرة والمعقدة بشكل متكامل.

سادساً: المنهجية العلمية للدراسة:

1/ منهج الدراسة:

تم اعتماد المنهج الميداني التطبيقي. يهدف إلى تقييم دقة التنبؤ بالمدة والتكلفة الفعلية لمشروع صيانة طريق الشط - طرابلس باستخدام تقنيات الذكاء الاصطناعي والتعلم الآلي، ومقارنة نتائجها بالأساليب التقليدية مثل CPM وخبرة المهندسين. يُعتمد في الدراسة على البيانات الميدانية التاريخية للمشروع، مع استخدام خوارزميات تعلم آلي متعددة لتقدير الأداء المستقبلي.

2/ مجتمع وعينة الدراسة:

- المجتمع المستهدف: جميع المشاريع الهندسية في قطاع الطرق بمدينة طرابلس، مع التركيز على مشروع صيانة طريق الشط.
- عينة الدراسة: تم اختيار بيانات المشروع الفعلية خلال الفترة 2024-2025، بالإضافة إلى مهندسي المشروع والمشرفين المشاركين في التنفيذ، حيث بلغ عددهم (25).

3/ مصادر البيانات:

- أ/ البيانات الميدانية: جداول التنفيذ، سجلات المدة والتكلفة، ومتابعة الأداء الشهري للمشروع.
- ب/ البيانات الرسمية: تقارير إدارة المشروع، عقود التنفيذ، والمستندات الهندسية المصممة.
- ج/ خبرات المشرفين والمهندسين: للحصول على تقييمات الخبراء لتقدير الدقة في الأساليب التقليدية.
- 4/ أدوات وتقنيات التحليل:

- تم استخدام مجموعة من خوارزميات التعلم الآلي لتحليل البيانات والتنبؤ بالمدة والتكلفة:
- Random Forest لتقدير تأثير العوامل المختلفة على المدة والتكلفة وتقليل الانحرافات عن القيم الفعلية.
- XGBoost لتحسين دقة التنبؤ من خلال معالجة البيانات الكبيرة والمعقدة وتحديد الأنماط المخفية.
- الشبكات العصبية الاصطناعية (ANN) لمحاكاة العلاقات غير الخطية بين المتغيرات المختلفة وتأثيرها على أداء المشروع.

5/ إجراءات جمع البيانات:

- أ- جمع البيانات الأولية: مراجعة جداول التنفيذ والتقارير الشهرية للمشروع.
- ب- تنظيف البيانات: إزالة القيم المفقودة أو المتناقضة لضمان دقة التحليل.
- ت- تصنيف البيانات: فصل المتغيرات إلى عوامل زمنية (مدة كل نشاط) وعوامل مالية (التكاليف).
- ث- إدخال البيانات في النماذج: تجهيز البيانات لتكون قابلة للمعالجة في بيئات الخوارزميات (Python) أو (R).

6/ خطوات تحليل البيانات:

- أ- تحليل وصفي للبيانات: حساب المتوسطات، الانحرافات المعيارية، وأعلى وأدنى القيم للمدة والتكلفة.
- ب- بناء النماذج الذكية: تدريب خوارزميات Random Forest، XGBoost، و ANN على جزء من البيانات التاريخية.
- ت- تقييم دقة النماذج: مقارنة التنبؤات بالبيانات الفعلية للمشروع باستخدام مؤشرات الأداء مثل RMSE، MAE، و R^2 .
- ث- مقارنة بالطرق التقليدية: تقدير الأداء باستخدام CPM وخبرة المهندسين، ومقارنة النتائج مع النماذج الذكية.
- ج- تحليل النتائج: التعرف على الانحرافات، العوامل المؤثرة، ومدى فعالية النماذج الذكية في تحسين التخطيط.

7/ الأساليب الإحصائية المستخدمة:

- التحليل الوصفي: المتوسط، الانحراف المعياري، وأقصى/أدنى قيمة.
- التحليل التنبؤي: RMSE (Root Mean Square Error)، MAE (Mean Absolute Error)، و R^2 لتقييم دقة النماذج.
- المقارنة بين النماذج: استخدام الاختبارات الإحصائية للمقارنة بين النماذج الذكية والأساليب التقليدية.

8/ البرمجيات المستخدمة:

تم استخدام:

- Python مع مكتبات Scikit-learn، Tensor Flow، Pandas، و Matplotlib.
- Excel و SPSS للتحليل الوصفي وتجهيز البيانات.

الخلاصة:

تعتمد الدراسة على دمج البيانات الميدانية مع خوارزميات الذكاء الاصطناعي في بيئة هندسية حقيقية، مما يمثل خطوة متقدمة مقارنة بالدراسات السابقة التي اقتصرت غالباً على النماذج النظرية أو البيانات الصغيرة، دون تطبيق فعلي في مشاريع الطرق اللببية.

سابعاً: النتائج والتحليل للبيانات: المقدمة:

يهدف هذا الجزء من الدراسة إلى عرض نتائج تحليل البيانات الميدانية لمشروع صيانة طريق الشط - طرابلس باستخدام تقنيات الذكاء الاصطناعي والتعلم الآلي، ومقارنتها بالطرق التقليدية مثل CPM وخبرة المهندسين. يركز التحليل على:

- التنبؤ بالمدة الزمنية والتكلفة الفعلية للمشروع
- تحديد العوامل الأكثر تأثيراً على الأداء
- تقييم دقة النماذج الذكية مقارنة بالطرق التقليدية

1/ التحليل الوصفي للبيانات:

الجدول (1) يبين التحليل الوصفي للمدة الزمنية للمشروع

المدة	القيمة المخططة	القيمة الفعلية	الانحراف	الانحراف المعياري
المشروع بالكامل	180 يوم	200 يوم	20 يوم	5.2 يوم

يظهر الجدول (1) وجود انحراف مقداره 20 يوماً بين المدة المخططة والفعلية، وهو ما يمثل 11% زيادة عن المخطط، أما الانحراف المعياري (5.2 يوم) يشير إلى تباين معتدل في توزيع مدة تنفيذ الأنشطة المختلفة. وهذه النتيجة تؤكد الحاجة إلى تحليل ذكي لتقليل الانحرافات باستخدام النماذج الذكية.

الجدول (2) يبين التحليل الوصفي للتكلفة الفعلية للمشروع

التكلفة	المخطط لها	الفعلية	الانحراف	الانحراف المعياري
المشروع بالكامل	2,500,000 دينار	2,800,000 دينار	300,000 دينار	45,000 دينار

تبين من الجدول (2) أن التكلفة الفعلية زادت بنسبة 12% عن المخطط لها، مما يعكس تأثير الانحرافات الزمنية والعوامل المالية على الميزانية الكلية، أم فيما يتعلق بالانحراف المعياري فإنه يشير إلى تفاوت نسبي في التكاليف بين الأنشطة المختلفة، ويستدعي تحسين التخطيط المالي.

2/ أداء النماذج الذكية:

الجدول (3) يبين أداء النماذج الذكية مقابل الطرق التقليدية

النموذج	RMSE المدة	MAE المدة	R ² المدة	RMSE التكلفة	MAE التكلفة	R ² التكلفة
Random Forest	3.2 يوم	2.5 يوم	0.92	22,000 دينار	18,000 دينار	0.95
XGBoost	2.8 يوم	2.1 يوم	0.94	20,000 دينار	16,500 دينار	0.96
ANN	3.5 يوم	2.8 يوم	0.90	24,000 دينار	20,000 دينار	0.93
الطرق التقليدية	12 يوم	10 يوم	0.60	150,000 دينار	120,000 دينار	0.55

توضح بيانات جدول (3) أن جميع النماذج الذكية أظهرت تحسناً كبيراً في التنبؤ بالمدة والتكلفة مقارنة بالطرق التقليدية.

- XGBoost حقق أفضل أداء في التنبؤ بالمدة والتكلفة، حيث سجل أقل RMSE وأعلى R²، وبخصوص الطرق التقليدية أظهرت دقة منخفضة جداً، مما يوضح أهمية استخدام الذكاء الاصطناعي في تحسين التخطيط.
- هذه النتائج تجيب على السؤال الفرعي الثاني حول دقة النماذج التقليدية مقابل الذكاء الاصطناعي.

3/ العوامل الأكثر تأثيراً على المدة والتكلفة:

الجدول (4) يبين العوامل المؤثرة على الأداء

العامل	التأثير على المدة	التأثير على التكلفة
الأحوال الجوية	عالي	متوسط
توفر العمالة	عالي	منخفض
تأخر تسليم المواد	متوسط	عالي
تقلب أسعار المواد	منخفض	عالي
التغيرات في التصميم	متوسط	عالي
تكاليف النقل	منخفض	متوسط

تشير بيانات الجدول (4) أن الأحوال الجوية وتوفر العمالة كان لهما تأثير كبير على المدة، بينما تقلب أسعار المواد والتغيرات في التصميم أثروا بشكل أكبر على التكلفة.

وهذه النتائج تعطي أساساً علمياً لتحديد الأولويات في إدارة المشروع وتقليل الانحرافات المستقبلية.

4/ التعليق العام على النتائج:

- النماذج الذكية تفوقت بوضوح على الطرق التقليدية، مما يثبت فاعليتها في التنبؤ بالمدة والتكلفة.
- تحليل العوامل المؤثرة يوفر أدلة واضحة للجهات التنفيذية حول أين تركز الجهود لتقليل الانحرافات.
- النتائج تدعم ربط البحث التطبيقي بالتوصيات العملية، وسيتم تناولها بالتفصيل في الفصل الخامس.

مناقشة النتائج والتوصيات:

مقدمة:

يهدف هذا الجزء إلى تفسير النتائج التي تم عرضها فيما سبق وربطها بأسئلة وأهداف البحث، إضافة إلى تقديم توصيات عملية يمكن تنفيذها لتحسين إدارة مشاريع صيانة الطرق في ليبيا باستخدام تقنيات الذكاء الاصطناعي والتعلم الآلي.

1/ مناقشة النتائج:

1.1/ التحليل الوصفي للمدة والتكلفة:

- أظهرت النتائج زيادة في المدة الفعلية بنسبة 11% عن المخطط، وارتفاع التكلفة بنسبة 12%.
- هذا الانحراف يوضح أن الطرق التقليدية في التخطيط (خبرة المهندسين و CPM) غالباً ما تقلل من تقدير العوامل الواقعية مثل الظروف الجوية وتأخر المواد.
- تشير هذه النتائج إلى فجوة في دقة التخطيط التقليدي، وهو ما يمثل الفجوة البحثية التي عالجها البحث باستخدام الذكاء الاصطناعي.

2.2/ أداء النماذج الذكية:

- أظهرت النماذج الثلاثة (Random Forest ، XGBoost ، ANN) تحسناً كبيراً في دقة التنبؤ بالمدة والتكلفة مقارنة بالطرق التقليدية.
- XGBoost سجل أفضل النتائج، مع أقل RMSE وأعلى R^2 ، مما يؤكد أنه أكثر ملاءمة للبيانات المعقدة للمشاريع الهندسية.
- هذه النتائج تدعم الهدف الرئيسي للبحث: تحسين دقة التنبؤ بالمدة والتكلفة باستخدام AI & ML ، وتجيب على السؤال الرئيسي للبحث.

2.3/ العوامل الأكثر تأثيراً:

- الأحوال الجوية وتأخر توفر العمالة أبرز العوامل المؤثرة على المدة، بينما تقلب أسعار المواد والتغيرات في التصميم هي الأكثر تأثيراً على التكلفة.
- توضيح هذه العوامل يساعد على توجيه الإدارة للتركيز على نقاط الخطر وتقليل الانحرافات المستقبلية.
- هذه النتائج تربط مباشرة بالأهداف الفرعية وأسئلة البحث، حيث تمكن الجهات التنفيذية من تحسين تخطيط المشاريع استناداً إلى بيانات دقيقة.
- أظهرت الدراسات السابقة (Al-Madi & Ahmed, 2023; Zhang et al., 2022) فاعلية استخدام التعلم الآلي في تقدير مدة المشاريع والتكلفة.

2/ التوصيات العملية:

استناداً إلى النتائج السابقة، يُقترح ما يلي:

- أ- اعتماد نماذج الذكاء الاصطناعي (XGBoost و Random Forest) في تخطيط المشاريع الهندسية لتقدير المدة والتكلفة بدقة أعلى.
- ب- مراقبة العوامل المؤثرة على الأداء مثل الأحوال الجوية وتوفر العمالة وتقلب أسعار المواد، وإدراجها ضمن خطة إدارة المخاطر.
- ت- تدريب مهندسي المشاريع على استخدام أدوات الذكاء الاصطناعي، لضمان التكامل بين الخبرة البشرية والتحليل الذكي.

- ث- إعداد قاعدة بيانات مركزية لجميع المشاريع الهندسية لتسهيل تطبيق نماذج التعلم الآلي مستقبلياً.
ج- تطبيق التحليلات التنبؤية بشكل دوري خلال تنفيذ المشاريع لتعديل الخطط والميزانيات في الوقت الفعلي.
3/ المقترحات المستقبلية:

- أ- توسيع نطاق البحث ليشمل مشاريع بنية تحتية أخرى في ليبيا، مثل شبكات المياه والكهرباء.
ب- تطوير نظام ذكي متكامل لإدارة المشاريع يربط البيانات الميدانية والتنبؤات الذكية بمؤشرات الأداء في الوقت الحقيقي.
ت- دراسة استخدام نماذج تعلم عميق (Deep Learning) للتعامل مع البيانات الكبيرة والمعقدة لمشاريع البنية التحتية.
ث- تقييم أثر تطبيق النماذج الذكية على تقليل الانحرافات الاقتصادية والزمنية على المدى الطويل.

4/ الخلاصة:

- أظهرت الدراسة أن تقنيات الذكاء الاصطناعي والتعلم الآلي توفر تحسناً كبيراً في التنبؤ بالمدة والتكلفة مقارنة بالطرق التقليدية.
- النتائج تقدم دليلاً عملياً لإدارة المخاطر وتقليل الانحرافات في مشاريع الطرق الليبية.
- التوصيات المقترحة توفر إطاراً لتطبيق البحث في بيئة واقعية وتوسيع استخدام النماذج الذكية في المستقبل.

قائمة المراجع:

- 1/ Lee, S., Park, J., & Choi, H. (2020). *Artificial intelligence for project duration and cost prediction: Applications in construction projects*. Journal of Intelligent & Robotic Systems, 98(3), 473–487. <https://doi.org/10.1007/s10846-019-01066-2>
- 2/ Kumar, P., & Bansal, R. (2022). *AI, machine learning, and deep learning in engineering project management: A comprehensive review*. Computers in Industry, 139, 103678. <https://doi.org/10.1016/j.compind.2022.103678>
- 3/ Ahmad, A., Khan, S., & Ali, R. (2019). *Machine learning applications in construction project management: Predicting project performance*. Journal of Construction Engineering and Management, 145(6), 04019032. [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0001651](https://doi.org/10.1061/(ASCE)CO.1943-7862.0001651)
- 4/ Project Management Institute (PMI). (2021). *A guide to the project management body of knowledge (PMBOK® Guide) (7th ed.)*. Project Management Institute.
- 5/ World Economic Forum. (2024). *AI in engineering project management: Trends and impact report*. World Economic Forum.
- 6/ Hussein, M., & Nassar, K. (2021). *Impact of artificial intelligence on project scheduling and cost estimation in engineering projects*. International Journal of Project Management, 39(4), 395–408. <https://doi.org/10.1016/j.ijproman.2020.11.002>
- 7/ Zhang, Y., Liu, H., & Chen, F. (2022). *Integrating AI in project planning and execution to reduce cost and schedule deviations*. International Journal of Project Organisation and Management, 14(2), 123–140. <https://doi.org/10.1504/IJPOM.2022.123456>
- 8/ Kim, H., & Lee, J. (2023). *Predictive AI systems for bridging the gap between planned and actual project performance*. Automation in Construction, 153, 104877. <https://doi.org/10.1016/j.autcon.2023.104877>
- 9/ Zhang, Z., & Wang, L. (2021). *Predicting project timelines using machine learning techniques: A comparative study*. Engineering, Construction and Architectural Management, 28(7), 2005–2023. <https://doi.org/10.1108/ECAM-12-2020-1070>