

نموذج تنبؤي لإنتاجية محطة حاويات ميناء عدن (ACT) اعتمادًا على الشبكات العصبية الاصطناعية وتحليل المؤشرات التشغيلية

اعداد

محمد علوي أمزربه^(١)، هشام هلال^(٢)، إيمان فاروق الحداد^(٣)
^(١) الرئيس التنفيذي ورئيس مجلس الإدارة مؤسسة موانئ خليج عدن اليمنية - اليمن
^(٢،٣) الأكاديمية العربية للعلوم والتكنولوجيا والنقل البحري
^(٢) رئيس هيئة تحرير مجلة الجمعية العربية للملاحة

DOI NO. <https://doi.org/10.59660/52729>

Received 01/05/2025, Revised 25/09/2025, Acceptance 12/01/2026, Available online and Published 01/07/2026

Abstract

This study aims to develop an advanced quantitative predictive model to measure and analyze the productivity of the Aden Container Terminal by employing Artificial Neural Networks (ANN) to assess the impact of implementing the Terminal Operating System (TOS), along with temporal and seasonal factors, on a set of key operational performance indicators. The research adopts a quantitative analytical approach, utilizing actual operational data collected over an extended period before and after system implementation. The data were preprocessed and normalized, then modeled using a multi-layer neural network trained with the Rprop+ algorithm. Predictive accuracy was evaluated using R^2 , RMSE, and MAE metrics. The results demonstrate the superior performance of the predictive models in explaining and forecasting three main indicators: container handling cost ($R^2 = 0.980$), number of containers handled ($R^2 = 0.935$), and number of vessel calls ($R^2 = 0.721$). In contrast, the remaining indicators exhibited moderate to weak predictive performance, reflecting differences in the complexity of the factors influencing them. Variable importance analysis further revealed that time was the most influential factor, followed by the implementation of the TOS, confirming the positive impact of digital transformation on the terminal's operational performance. The study recommends expanding the use of AI-based predictive models in operational planning, strengthening TOS integration with relevant stakeholders, upgrading handling equipment, and establishing a specialized operational data analytics unit to enhance efficiency, improve decision-making quality, and strengthen the competitive position of the Aden Container Terminal.

Keywords: Productivity; Aden Container Terminal; Artificial Neural Networks; Operational Performance Indicators.

المستخلص:

يهدف هذا البحث إلى تطوير نموذج تنبؤي كمي متقدم لقياس وتحليل إنتاجية محطة عدن للحاويات، من خلال توظيف الشبكات العصبية الاصطناعية (ANN) لقياس أثر تطبيق نظام تشغيل المحطات (TOS) والعوامل الزمنية والموسمية على مجموعة من المؤشرات التشغيلية الرئيسية. اعتمدت الدراسة على المنهج الكمي التحليلي، حيث جُمعت بيانات تشغيلية فعلية لفترة زمنية ممتدة قبل وبعد تطبيق النظام، وتمت معالجتها

وتطبيعها وبنائها ضمن نموذج شبكة عصبية متعددة الطبقات باستخدام خوارزمية Rprop+ ، مع تقييم دقة التنبؤ عبر مؤشرات R^2 و RMSE و MAE. أظهرت النتائج تفوق النماذج التنبؤية في تفسير والتنبؤ بثلاثة مؤشرات رئيسية هي تكلفة مناولة الحاويات ($R^2 = 0.980$)، وعدد الحاويات المتداولة ($R^2 = 0.935$)، وعدد السفن المترددة ($R^2 = 0.721$)، في حين حققت بقية المؤشرات مستويات أداء متوسطة إلى ضعيفة، مما يعكس اختلاف درجة تعقيد العوامل المؤثرة عليها. كما بين تحليل أهمية المتغيرات أن عامل الزمن كان الأكثر تأثيراً، يليه تطبيق نظام TOS ، مما يؤكد الأثر الإيجابي للتحويل الرقمي على الأداء التشغيلي للمحطة. ويوصي البحث بضرورة توسيع استخدام النماذج التنبؤية المعتمدة على الذكاء الاصطناعي في التخطيط التشغيلي، وتعزيز تكامل نظام TOS مع الجهات ذات العلاقة، وتحديث معدات المناولة، وإنشاء وحدة متخصصة لتحليل البيانات التشغيلية، بما يساهم في رفع الكفاءة، وتحسين جودة القرار، وتعزيز القدرة التنافسية لمحطة عدن للحاويات .

الكلمات الدالة: الإنتاجية، محطة عدن للحاويات، الشبكات العصبية الاصطناعية، المؤشرات التشغيلية.

١. المقدمة:

تمثل الخدمات اللوجستية أحد المرتكزات الأساسية لعمل الموانئ البحرية، إذ تضم منظومة متكاملة من العمليات التشغيلية تشمل مناولة السفن، ونقل وتخزين البضائع، وإدارة المخزون، وتنظيم تدفقات السلع داخل الميناء وخارجه. ويُعد حسن إدارة هذه العمليات عاملاً حاسماً في تحسين كفاءة الموانئ ورفع قدرتها التشغيلية، بما ينعكس مباشرة على فعالية سلاسل الإمداد ودعم النشاطين الاقتصادي والتجاري على المستويين المحلي والدولي (Liu, 2020). وفي هذا الإطار، تكتسب الأنشطة اللوجستية في ميناء عدن أهمية استراتيجية خاصة، نظراً لموقعه الجغرافي المتميز عند ملتقى خليج عدن وباب المندب والبحر الأحمر، وهي منطقة تمثل أحد أهم الممرات الحيوية للتجارة الدولية العابرة بين الشرق والغرب، الأمر الذي يُوْهله ليكون محوراً رئيسياً في شبكة النقل البحري العالمية. ويتطلب استغلال هذه الميزة الجغرافية تبني ممارسات إدارية متقدمة وتوظيف تقنيات حديثة تضمن تقديم خدمات لوجستية عالية الكفاءة والجودة، بما يعزز رضا العملاء ويرفع من تنافسية الميناء.

وفي ظل التحولات المتسارعة التي تشهدها صناعة النقل البحري والخدمات المينائية، برزت تكنولوجيا المعلومات بوصفها عنصراً محورياً في تطوير الأداء اللوجستي داخل الموانئ. فقد أكدت العديد من الدراسات أن اعتماد الأنظمة المعلوماتية المتقدمة يساهم في تبسيط الإجراءات التشغيلية وتحقيق التكامل بين مختلف الأطراف ذات العلاقة، من خلال توفير معلومات دقيقة وأنية تدعم اتخاذ القرار (علي، ٢٠١٨). كما تتيح هذه الأنظمة إمكانات متقدمة في التخطيط والتنبؤ، بما يؤدي إلى ترشيد التكاليف وتعظيم الاستفادة من الموارد المتاحة. وفيما يتعلق بمحطة حاويات ميناء عدن، فإن تطبيق نظام تشغيل المحطات (Terminal Operating System – TOS) يمثل خطوة نوعية قادرة على إحداث تحول جوهري في آليات إدارة المحطة، من خلال تحسين التنسيق المؤسسي، وتعزيز مستويات الشفافية والرقابة، والحد من الأخطاء التشغيلية، الأمر الذي يساهم في زيادة الثقة ورفع الإنتاجية الكلية. (نبيل بن عيفان، ٢٠٢٤)

ويُنظر إلى نظام تشغيل المحطات (TOS) بوصفه البنية العصبية الرئيسية لمحطات الحاويات، لما يتمتع به من قدرة عالية على أتمتة عدد كبير من العمليات التي كانت تُدار تقليدياً بأساليب يدوية. ويوفر هذا النظام مجموعة متكاملة من الوظائف التي تدعم إدارة الحمولات المختلفة داخل المحطة، مع تركيز واضح على تعزيز كفاءة

العمليات اللوجستية. كما يُعرّف TOS على أنه نظام حاسوبي متطور يُستخدم للتخطيط والتتبع والتحكم في حركة وتخزين الشحنات، إضافة إلى إدارة الأصول وتوزيع الموارد البشرية داخل المحطة البحرية أو المناطق الخلفية التابعة لها، وذلك بصورة لحظية ومستمرة (Jamal et al., 2017). ويُعد النظام محورًا أساسيًا في تخطيط وتنفيذ تدفقات الحاويات عبر مراحلها المختلفة داخل المحطة، فضلًا عن توفيره تطبيقات متعددة لجمع البيانات التشغيلية وتحليلها وتبادلها، بما يتيح رؤية شاملة ومتكاملة للعمليات ويضمن الاستخدام الأمثل للموارد. ويؤدي نظام (TOS) دور التطبيق المركزي المسؤول عن التخطيط والتنفيذ والمراقبة اللحظية لحركة الحاويات داخل المحطة، حيث يتولى تنظيم انتقال الحاويات بين السفن والساحات، وبين الساحات ووسائل النقل البرية، باستخدام معدات المناولة الثقيلة، بما يحقق التنسيق الكامل بين مختلف مراحل العمليات التشغيلية. ويسهم النظام في رفع كفاءة التشغيل من خلال تحسين عمليات تحميل وتفريغ السفن، وإدارة الساحات والمخازن، وتنظيم استخدام المعدات والعمالة (Min et al., 2017).

كما يُعد TOS منصة برمجية متكاملة لإدارة الأنشطة التشغيلية كافة داخل محطة الحاويات، إذ يشمل الإشراف اللحظي على مناطق متعددة مثل البوابات، والأرصفة، والحاويات المبردة، والبضائع الخطرة، وخطوط السكك الحديدية، إضافة إلى دعمه لتقنيات تبادل البيانات الإلكترونية (EDI) وخدمات الويب، بما يسهل تكامل البيانات والتواصل مع الأطراف الخارجية. وتبرز أهمية هذا النظام في قدرته على توحيد عناصر التشغيل المختلفة ضمن بيئة رقمية متكاملة، بما يؤدي إلى خفض التكاليف، وتسريع الإجراءات، وتعزيز موثوقية الأداء في محطات الحاويات (Weerasinghe et al., 2024; Hervás-Peralta et al., 2019).

٢. الدراسات السابقة:

هدفت دراسة (Chargui et al., 2021) إلى تحسين كفاءة إدارة العمليات اللوجستية البحرية من خلال تطوير نموذج تنبؤي دقيق لمعدل إنتاجية الرافعات الجسرية (Quay Cranes – QCs)، لما له من تأثير مباشر على جدولة الرافعات وأداء محطات الحاويات. واعتمدت الدراسة على منهج كمي تطبيقي، حيث اقترحت نموذجًا قائمًا على الشبكات العصبية الاصطناعية (ANN) مدعومًا بخوارزمية البحث بالجوار المتغير (Variable Neighbourhood Search – VNS) كآلية تدريب لبناء نموذج تنبؤي لمعدل إنتاجية الرافعات، أخذًا في الاعتبار خصائص الحاويات المنقولة على السفن المختلفة وفترات التوقف المتوقعة للمعدات. كما جرى تحليل أثر معدل الإنتاجية المنتبأ به على جدولة الرافعات الجسرية من خلال دمج كنواتج مدخل في نموذج تحسين لجدولة الرافعات، مع مقارنة الأداء بنموذج المتوسط المتحرك التقليدي. وأظهرت النتائج أن استخدام النموذج التنبؤي المقترح أدى إلى إنتاج جداول تشغيل للرافعات أكثر قربًا من الجداول المبنية على البيانات التشغيلية الفعلية للمحطة، مقارنة بالنماذج التقليدية، مما يؤكد فعالية توظيف الذكاء الاصطناعي في تحسين دقة التخطيط التشغيلي وتقليل الفجوة بين التخطيط النظري والتنفيذ العملي في محطات الحاويات.

قدمت دراسة (Kim et al., 2022) مقارنة تحليلية بين أداء محطات الحاويات المؤتمتة بالكامل والمحطات التقليدية خلال جائحة كوفيد-19، بالاعتماد على بيانات تشغيلية فعلية. استخدمت الدراسة أدوات تحليل كمي مدعومة بخوارزميات ذكية لتقييم المرونة التشغيلية. وأظهرت النتائج أن المحطات التي تعتمد على أنظمة تشغيل رقمية متقدمة ودرجة أعلى من الأتمتة حققت أداءً أفضل من حيث حجم المناولة وزمن بقاء السفن، مما يؤكد الدور المحوري للتقنيات الذكية وأنظمة TOS في تعزيز كفاءة الموانئ في الظروف غير المستقرة.

هدفت دراسة (Li et al., 2023) إلى تطوير نموذج تنبؤي دقيق للتنبؤ طويل الأجل بحجم مناولة الموانئ، باعتبارها أحد المؤشرات الأساسية لتقييم كفاءة الموانئ ودعم قرارات الاستثمار في البنية التحتية، وذلك من خلال تطبيقه على ميناء نينغبو-تشوشان. واعتمدت الدراسة على منهج كمي تحليلي قائم على تقنيات الذكاء الاصطناعي، حيث استخدمت أسلوب التحليل العلائقي الرمادي (Grey Relational Analysis) لاختيار اثني عشر متغيرًا الأكثر ارتباطًا بتغيرات حجم المناولة، ثم جرى توظيف هذه المتغيرات كمدخلات في نموذج الشبكات العصبية العميقة ثنائية الاتجاه (BiLSTM). وأظهرت النتائج تفوق النموذج المقترح من حيث الدقة التنبؤية مقارنة بنماذج التعلم الآلي والشبكات العصبية الشائعة، حيث حقق متوسط نسبة خطأ مطلق (MAPE) بلغ ٢.٩٥%، كما كشفت التنبؤات عن اتجاه نمو سريع في حجم المناولة بالميناء حتى عام ٢٠٢٦. وبناءً على ذلك، أوصت الدراسة بضرورة تبني النماذج التنبؤية القائمة على الذكاء الاصطناعي في التخطيط الاستراتيجي طويل الأجل للموانئ، ودعم قرارات التوسع الاستثماري، وتعزيز إدارة الطاقة الاستيعابية بما يواكب النمو المتوقع في الطلب على الخدمات المينائية.

تناولت دراسة (Weerasinghe et al., 2024) تقييم كفاءة محطات الحاويات من خلال مراجعة منهجية لتطبيقات بحوث العمليات والذكاء الاصطناعي في تشغيل الموانئ. ركزت الدراسة على استخدام نماذج التعلم الآلي، بما في ذلك الشبكات العصبية والخوارزميات التطورية، لتحسين تخطيط الأرصفة، وجدولة المعدات، وتقليل زمن انتظار السفن. وأظهرت النتائج أن دمج الأنظمة الذكية مع أنظمة تشغيل المحطات (TOS) يسهم بشكل مباشر في رفع الإنتاجية التشغيلية وخفض التكاليف التشغيلية في محطات الحاويات الحديثة.

هدفت دراسة (Novaes Mathias et al., 2024) إلى استكشاف دور توظيف علوم البيانات والتقنيات التحليلية الحديثة في تحسين كفاءة تشغيل محطات الحاويات وتعزيز قدرتها التنافسية، من خلال تحليل البيانات التشغيلية الفعلية لمحطة هاكاتا الدولية للحاويات في اليابان. واعتمدت الدراسة على منهج كمي تطبيقي قائم على استخدام البيانات التشغيلية اليومية لمعدات الرافعات المطاطية (RTG)، إلى جانب تقنيات تحليل البيانات، والتنقيب عن البيانات، ونماذج المحاكاة، لفهم أنماط حركة الحاويات داخل الساحات. وركزت الدراسة بشكل خاص على دعم عملية اتخاذ القرار المتعلقة بتحديد المواقع المثلى لتكديس الحاويات، باعتبارها من أكثر القرارات التشغيلية تعقيدًا نتيجة لتعدد العوامل المؤثرة. وأظهرت النتائج أن تطبيق استراتيجيات تشغيلية قائمة على البيانات، مدعومة بنماذج المحاكاة، أسهم بشكل ملموس في تقليل عدد حركات المناولة وإعادة المناولة غير الضرورية، مما انعكس إيجابًا على كفاءة العمليات وزيادة الطاقة الإنتاجية للمحطة. وأكدت الدراسة أن توظيف تحليلات البيانات التشغيلية يمثل أداة فعالة لتحسين التخطيط التشغيلي، وخفض الهدر، ودعم السياسات التشغيلية الذكية في محطات الحاويات الحديثة.

هدفت دراسة (Chhetri et al., 2025) إلى تحليل العوامل المؤثرة في زمن بقاء الحاويات داخل الميناء (Container Dwell Time – CDT) في ميناء مومباسا، من خلال توظيف تقنيات التعلم الآلي بهدف تحسين الكفاءة التشغيلية ودعم اتخاذ القرار الاستراتيجي. واعتمدت الدراسة على منهج كمي تطبيقي قائم على استخدام بيانات فعلية آنية لحركة الحاويات، حيث جرى اختبار مجموعة من نماذج التعلم الآلي، من بينها الشبكات العصبية الاصطناعية، والغابات العشوائية، وأشجار القرار. وأظهرت النتائج وجود تباين زمني واضح في زمن بقاء الحاويات، سواء على مستوى أيام الأسبوع أو فترات السنة، حيث سُجلت أعلى القيم خلال

فترات بعد الظهر وخلال شهري نوفمبر وديسمبر. ورغم تفوق نماذج الشبكات العصبية والغابات العشوائية من حيث الدقة التنبؤية، تم اعتماد نموذج شجرة القرار نظرًا لسهولة تفسيره وشفافيته التحليلية، على الرغم من ارتفاع معدل الخطأ نسبيًا. كما كشفت النتائج أن نمط النقل يمثل المتغير الأكثر تأثيرًا في زمن البقاء، إذ ارتبط النقل البري بالشاحنات بزمن بقاء أطول مقارنة بالنقل بالسكك الحديدية، إضافة إلى تأثيرات مكانية وزمنية أخرى مرتبطة بمواقع محددة وأيام معينة. وأوصت الدراسة بضرورة توظيف نماذج التعلم الآلي المعتمدة على البيانات الآنية لتحسين إدارة تدفقات الحاويات، وتقليل زمن البقاء، وتعزيز كفاءة التشغيل، مع الأخذ في الاعتبار العوامل الخارجية المؤثرة على أداء الميناء، بما يساهم في دعم التخطيط التشغيلي والاستراتيجي للموانئ، لا سيما في سياقات الدول النامية.

هدفت دراسة (Shiraishi et al., 2025) إلى تقييم كفاءة تشغيل محطات الحاويات من خلال تحليل تجريبي لأزمة دوران السفن والشاحنات والحوايات في عدد مختار من محطات الحاويات اليابانية، بوصفها مؤشرات محورية للأداء التشغيلي. واعتمدت الدراسة على منهج كمي تطبيقي قائم على دمج قواعد بيانات شاملة شملت سجلات مشغلي المحطات، وبيانات حركة السفن، وبيانات خدمات الخطوط الملاحية، بهدف تحليل أنماط رسو السفن، ووصول الشاحنات، وزمن دوران الشاحنات، ودورة حركة الحاويات، وزمن بقاء الحاويات داخل المحطة. وأظهرت النتائج وجود أنماط زمنية واضحة في العمليات التشغيلية، مع فروق ملحوظة بين حاويات الاستيراد والتصدير، كما بينت أن عدد زيارات السفن، ونوع الحاويات، وتوقيت العمليات خلال اليوم تمثل عوامل مؤثرة بشكل جوهري في مستويات الكفاءة التشغيلية. وأوضحت تحليلات الانحدار أن أزمة الدوران تتأثر بدرجة أكبر بالعوامل الخاضعة لسيطرة إدارة المحطة مقارنة بالعوامل الخارجية. وبناءً على ذلك، أوصت الدراسة بتبني أنظمة جدولة ديناميكية مدعومة بالرقمنة، وتعزيز توحيد الإجراءات التشغيلية، وتحسين استغلال البنية التحتية، بما يدعم جهود التحول الرقمي ويرفع كفاءة تشغيل محطات الحاويات، ويزود صانعي القرار بإرشادات قائمة على الأدلة لتحسين الأداء المينائي.

أ. الفجوة البحثية:

على الرغم من تعدد الدراسات التي تناولت أداء الموانئ وفعالية المؤشرات التشغيلية في بيئات لوجستية مختلفة، إلا أن الأدبيات العلمية ما تزال تفتقر إلى نماذج تنبؤية متقدمة توظف تقنيات الذكاء الاصطناعي وبشكل خاص الشبكات العصبية الاصطناعية لتفسير التباينات التشغيلية في محطات الحاويات في السياقات العربية. كما أن معظم الدراسات ركزت على التحليل الوصفي أو النماذج الخطية التقليدية التي تعجز عن التقاط العلاقات غير الخطية والتفاعلات المعقدة بين العوامل التشغيلية والزمنية. وفي حالة محطة حاويات ميناء عدن، لم تُجر أي دراسة سابقة تعتمد نماذج ANN لتقييم أثر تطبيق نظام TOS على الإنتاجية وقياس قدرته على تحسين مؤشرات الأداء المختلفة. وبالتالي، تكمن الفجوة البحثية في غياب إطار تنبؤي متكامل قائم على الذكاء الاصطناعي قادر على تحليل ديناميكيات الأداء التشغيلي للمحطة والتنبؤ بها بدقة، بما يعكس الحاجة إلى منهجية كمية متقدمة تتجاوز حدود النماذج التقليدية.

ب. الأضافة العلمية:

يقدم هذا البحث إضافة علمية نوعية من خلال تطوير نموذج تنبؤي قائم على الشبكات العصبية الاصطناعية لقياس إنتاجية محطة عدن للحاويات وتحليل المؤشرات التشغيلية المرتبطة بها، وهو ما يساهم في إثراء الأدبيات

الحديثة المتعلقة بإدارة الموانئ عبر إدخال منهجيات تعلم آلي قادرة على معالجة الأنماط غير الخطية والتفاعلات الديناميكية بين المتغيرات. وتبرز الإضافة العلمية في الجمع بين بيانات تشغيلية واقعية ونماذج ANN متعددة الطبقات وتجريب دقتها عبر ثمانية مؤشرات أداء حيوية، بالإضافة إلى تقديم تحليل مقارنة لأهمية المتغيرات المدخلة، مما يسمح بفهم أعمق للعوامل المؤثرة في الأداء. وتوفر الدراسة إطاراً منهجياً يمكن تعميمه على موانئ أخرى، كما تسهم في سد فجوة منهجية تتعلق بضعف استخدام الذكاء الاصطناعي في تقييم أثر الأنظمة الرقمية مثل TOS على الأداء التشغيلي، الأمر الذي يعزز من القيمة العلمية والعملية لهذه الدراسة في حقل الدراسات اللوجستية وإدارة الموانئ.

٣. مشكلة البحث:

تعاني محطة عدن للحاويات، باعتبارها أحد أهم الموانئ المحورية في المنطقة، من تذبذب واضح في مستويات الإنتاجية وصعوبة في التنبؤ الدقيق بالمؤشرات التشغيلية المستقبلية، وذلك نتيجة تعقد العوامل المؤثرة في الأداء وتداخلها عبر الزمن. فالاعتماد التقليدي على الأساليب الإحصائية الخطية في تقدير الإنتاجية أثبت محدوديته، حيث تفشل هذه الأساليب في التقاط العلاقات غير الخطية والأنماط العميقة الموجودة في البيانات التشغيلية، وخاصة تلك المتعلقة بالتغيرات الموسمية، وتذبذب حجم المناولة، وتغير بنية الطلب، إضافة إلى تأثيرات الأنظمة الرقمية الحديثة مثل نظام TOS.

وعلى الرغم من إدخال هذا النظام بهدف تحسين كفاءة العمليات، إلا أن تأثيره الفعلي على الإنتاجية لم يُدرس بشكل علمي معمق باستخدام أدوات تنبؤية متقدمة قادرة على نمذجة البيانات الضخمة. ونظراً لعدم وجود نماذج دقيقة تساعد الإدارة في اتخاذ قرارات مبنية على توقعات موثوقة فإن المحطة قد تواجه مخاطر تشغيلية تؤدي إلى ضعف الكفاءة وارتفاع التكلفة وانخفاض القدرة التنافسية.

وبناءً على ما سبق، تتبلور مشكلة البحث في غياب نموذج تنبؤي متطور قادر على تحليل إنتاجية محطة عدن للحاويات والتنبؤ بها بدقة، مع القدرة على قياس تأثير نظام التشغيل TOS، مما يستلزم استخدام الشبكات العصبية الاصطناعية بوصفها منهجية أكثر قدرة على معالجة الأنماط المعقدة والتفاعلات غير الخطية في البيانات التشغيلية.

٤. أهمية البحث:

أ. الأهمية العلمية:

تتبع الأهمية العلمية لهذا البحث من كونه يقدم نموذجاً تنبؤياً متقدماً يعتمد على الشبكات العصبية الاصطناعية لتحليل إنتاجية محطة عدن للحاويات، وهو ما يمثل اتجاهاً حديثاً في دراسات الموانئ التي ما زالت تهيمن عليها الأساليب الإحصائية التقليدية. يسهم البحث في سد فجوة معرفية تتعلق بضعف استخدام تقنيات الذكاء الاصطناعي في التنبؤ بالمؤشرات التشغيلية للموانئ العربية، كما يضيف إطاراً منهجياً قادراً على التقاط العلاقات غير الخطية والتفاعلات الزمنية التي لا تستطيع النماذج الخطية تفسيرها. بذلك يعزز البحث الأدبيات المعاصرة من خلال دمج التحليل التشغيلي مع تقنيات التعلم العميق، ويقدم نموذجاً قابلاً للتكرار والتطوير في دراسات كفاءة الموانئ وإدارة العمليات اللوجستية.

ب. الأهمية العملية:

تكمن الأهمية العملية للبحث في قدرته على تزويد إدارة محطة عدن للحاويات وصانعي القرار بنموذج تنبؤي دقيق يساعد في التخطيط التشغيلي واتخاذ قرارات فورية مبنية على بيانات، مما يساهم في تحسين تخصيص الموارد، وتقليل الاختناقات، ورفع مستوى الطاقة الإنتاجية. يتيح النموذج التنبؤ المسبق بتقلبات حجم المناولة وتأثير العوامل الزمنية والموسمية، مما يمكن الإدارة من تحسين الجداول التشغيلية وتقليل فترات التأخير. كما يساعد في تقييم الأثر العملي لتطبيق نظام TOS على الأداء، وهو ما يزود الإدارة بأدلة كمية داعمة لقياس العائد من الاستثمار وتحسين عمليات التشغيل المستقبلية، وبالتالي رفع القدرة التنافسية للميناء ضمن ممرات التجارة الإقليمية.

هـ. أهداف البحث:

يهدف البحث الحالي الى بناء نموذج تنبؤي متكامل يعتمد على الشبكات العصبية الاصطناعية لتحليل وتقدير إنتاجية محطة عدن للحاويات، وقياس تأثير العوامل التشغيلية والزمنية وتطبيق نظام TOS على مستوى الأداء الكلي للمحطة. ويتفرع من الهدف الرئيس عدة أهداف فرعية وتتمثل فيما يلي:
تطوير نموذج تنبؤي يعتمد على الشبكات العصبية الاصطناعية بهدف تقدير إنتاجية محطة عدن للحاويات وتحليل سلوك المؤشرات التشغيلية عبر الزمن.

تحديد أثر تطبيق نظام TOS علي مؤشرات أداء محطة عدن للحاويات.

تقديم توصيات عملية قائمة على نتائج النموذج التنبؤي بهدف تحسين الكفاءة التشغيلية لمحطة عدن للحاويات، وتعزيز دقة التخطيط المستقبلي، ودعم قرارات الإدارة فيما يتعلق بتوزيع الموارد، وجدولة العمليات، وتطوير الأنظمة الرقمية الداعمة للأداء.

٦. منهجية البحث:

تتبع الدراسة المنهج الكمي التحليلي المعتمد على بناء نماذج تنبؤية باستخدام الشبكات العصبية الاصطناعية ANN لتحليل تأثير نظام TOS على إنتاجية ومحاور الأداء التشغيلي في محطة عدن للحاويات. يقوم هذا المنهج على جمع البيانات التشغيلية لفترة زمنية طويلة قبل وبعد تطبيق النظام، ثم معالجتها إحصائياً وتطبيعتها وتجهيزها كمدخلات للنموذج التنبؤي. بعد ذلك يتم تصميم شبكة عصبية متعددة الطبقات وتدريبها باستخدام خوارزمية Rprop+ بهدف تعلم الأنماط الكامنة في السلاسل الزمنية والتغيرات الموسمية والانقطاعات الناتجة عن تطبيق النظام. يعتمد التحليل على تقسيم البيانات إلى مجموعة تدريب واختبار، وتقييم أداء النموذج باستخدام مؤشرات R^2 و RMSE و MAE للتحقق من دقة التنبؤ، بالإضافة إلى تحليل أهمية المتغيرات لتحديد مدى تأثير كل من الزمن والموسمية وتطبيق TOS على مستويات الإنتاجية. يتيح هذا المنهج تقدير أثر النظام بدقة أعلى مقارنة بالأساليب التقليدية، مستفيداً من قدرة الشبكات العصبية على التقاط العلاقات غير الخطية والتفاعلات المعقدة بين المتغيرات.

أ. مفهوم الشبكات العصبية وآلية عملها ANN Concept and Mechanism

تمثل الشبكات العصبية الاصطناعية أحد أكثر تقنيات التعلم الآلي تطوراً في معالجة البيانات المعقدة واستخلاص الأنماط غير الخطية. تستمد هذه الشبكات إلهامها من البنية العصبية للدماغ البشري، حيث تحاكي

طريقة تواصل الخلايا العصبية ومعالجتها للمعلومات عبر شبكة من الوصلات المترابطة (Goodfellow et al., 2016). تكمن قوتها الحقيقية في قدرتها على التعلم من البيانات دون برمجة صريحة للعلاقات بين المتغيرات، مما يجعلها أداة مثالية للمشكلات المعقدة وغير الخطية التي يصعب نمذجتها بالأساليب التقليدية (Bishop, 2006; Hastie et al., 2009).

تتكون البنية الأساسية للشبكة العصبية من وحدات معالجة تسمى العصبونات، تنتظم في طبقات متتالية: طبقة إدخال تستقبل المتغيرات المستقلة، طبقة أو أكثر من الطبقات المخفية لمعالجة المعلومات واستخلاص التمثيلات المجردة، وطبقة مخرجات تنتج التنبؤات النهائية (LeCun et al., 2015). تتميز الطبقات المخفية بعملها كوسيط تحويلي يستخلص الخصائص المعقدة من البيانات، مما يمنح الشبكات قدرتها الفريدة على اكتشاف العلاقات غير الخطية والتفاعلات المعقدة بين المتغيرات (Bengio et al., 2013).

يعتمد عمل الشبكة على الانتشار الأمامي للمعلومات عبر الطبقات، حيث تتلقى كل عصبونة مدخلات من العصبونات السابقة، وتحسب مجموعاً مرجحاً، ثم تطبق دالة تنشيط غير خطية. يمكن التعبير عن مخرج العصبونة z في الطبقة l بالمعادلة:

$$a_j^{(l)} = f \left(\sum w_{ji}^{(l)} \times a_i^{(l-1)} + b_j^{(l)} \right)$$

حيث $a_j^{(l)}$ يمثل مخرج العصبونة z في الطبقة l ، و $w_{ji}^{(l)}$ هو الوزن الرابط، و $b_j^{(l)}$ معامل الانحياز، و f دالة التنشيط (Nielsen, 2015). تلعب دالة التنشيط دوراً محورياً في تمكين الشبكة من تعلم الأنماط المعقدة، إذ أن استخدام دوال خطية فقط سيحول الشبكة لنموذج خطي بسيط. من أشهر دوال التنشيط السيجمويد $f(z) = 1/(1 + e^{-z})$ ، والظل الزائدي $f(z) = \tanh(z)$ ، و ReLU المعدلة $f(z) = \max(0, z)$ التي أصبحت الخيار المفضل للشبكات العميقة (LeCun et al., 2015).

تكتسب الشبكة معرفتها عبر عملية تدريب تكرارية تهدف لتحديد القيم المثلى لجميع الأوزان بما يقلل دالة الخطأ التي تقيس الفرق بين التنبؤات والقيم الحقيقية. تتم هذه العملية باستخدام خوارزمية الانتشار العكسي مع التدرج الهابط (Rumelhart et al., 1986). يبدأ التدريب بتهيئة عشوائية للأوزان، ثم في كل دورة يتم تمرير البيانات عبر الشبكة، حساب الخطأ، حساب تدرج دالة التكلفة، وتحديث الأوزان عكس اتجاه التدرج.

قاعدة تحديث الأوزان تأخذ الصيغة:

$$w_{ji}^{(l)}(t + 1) = w_{ji}^{(l)}(t) - \eta \times \partial E / \partial w_{ji}^{(l)}$$

حيث η معدل التعلم و E دالة الخطأ الكلية (Mitchell, 1997). اختيار معدل التعلم المناسب حاسم للنجاح، فالقيم الكبيرة تسبب تذبذباً، والصغيرة تبطئ التدريب. لذا تم تطوير خوارزميات متطورة مثل Adam و RMSprop و Rprop التي تستخدم معدلات تعلم متكيفة، مما يحسن سرعة التقارب والاستقرار (Riedmiller & Braun, 1993; Tieleman & Hinton, 2012).

تواجه الشبكات العصبية تحدي الإفراط في التلاوم حيث تتعلم الضجيج بدلاً من الأنماط العامة، مما يضعف أداءها على بيانات جديدة (Hawkins, 2004). لمكافحة ذلك تستخدم تقنيات تنظيمية متعددة مثل إيقاف المبكر، عقوبات L1 أو L2، و Dropout التي تعطل عشوائياً نسبة من العصبونات أثناء التدريب (Srivastava et al., 2014). كما يعتبر تطبيع المدخلات ضرورياً لتسهيل التدريب وضمان أن جميع المتغيرات على نفس المقياس (Ioffe & Szegedy, 2015).

في سياق هذه الدراسة لتحليل أثر نظام TOS على أداء ميناء عدن، تقدم الشبكات العصبية ميزات جوهرية: التقاط العلاقات غير الخطية المعقدة، اكتشاف التفاعلات الضمنية بين المتغيرات دون تحديدها مسبقاً، والتعامل الفعال مع البيانات الزمنية عبر إدخال متغيرات زمنية وتحولاتها (Breiman, 1996).

ب) مواصفات النموذج المطبق في البحث ANN Model Specifications

يعتمد النموذج المطبق على شبكة عصبية متعددة الطبقات Multi-Layer Perceptron باستخدام حزمة neuralnet في بيئة R، وهي حزمة متخصصة توفر مرونة عالية في تصميم وتدريب الشبكات للمسائل الانحدارية (Günther & Fritsch, 2010). تتكون الشبكة من بنية هرمية متدرجة: طبقة إدخال بأربعة متغيرات، طبقتين مخفيتين بأحجام متناقصة، وطبقة مخرجات بقيمة واحدة مستمرة.

تحتوي طبقة الإدخال على أربعة متغيرات محورية: متغير TOS الثنائي (صفر قبل التطبيق وواحد بعده)، الزمن المقيس الموحد بالتقييس القياسي، مربع الزمن المقيس للتقاط الاتجاهات غير الخطية، ومتغير الموسم الثنائي (واحد للنصف الأول من السنة وصفر للثاني) (Hyndman & Athanasopoulos, 2018). تم تطبيع جميع المتغيرات للنطاق بين صفر وواحد مع حدود معقولة لكل متغير لضمان واقعية القيم.

تضم الشبكة طبقتين مخفيتين بنمط هرمي متناقص: الأولى بخمسة عصبونات لاستخلاص التمثيلات الأساسية، والثانية بثلاثة عصبونات لمستوى إضافي من التجريد. هذه البنية تتبع مبدأ التشفير التدريجي حيث تستخلص خصائص أكثر تجريداً مع التعمق في الطبقات (Bengio et al., 2013). إجمالي الأوزان القابلة للتدريب: $25 = 5 + (5 \times 4)$ وزناً للطبقة الأولى، $18 = 3 + (3 \times 5)$ وزناً للطبقة الثانية، $4 = 1 + (1 \times 3)$ أوزان للمخرجات، بمجموع 47 معاملاً، وهو عدد معتدل يتناسب مع حجم التدريب.

تستخدم جميع العصبونات المخفية دالة التنشيط اللوجستية السيجمويد $f(z) = 1/(1 + e^{-z})$ ، وهي دالة ناعمة تحول المدخلات لقيم بين صفر وواحد، وتضيف اللاخطية الضرورية للشبكة (Han & Moraga, 1995). أما طبقة المخرجات فتستخدم دالة هوية خطية لأن المسألة انحدارية، ثم يحول المخرج للنطاق الأصلي بعكس التطبيع.

تعتمد عملية التدريب على خوارزمية Resilient Backpropagation المحسنة (Rprop+)، وهي نسخة متقدمة تتغلب على نقاط ضعف الانتشار العكسي التقليدي، خاصة الحساسية لمعدل التعلم (Riedmiller, 1994). تعمل Rprop+ بتعديل حجم خطوة التحديث لكل وزن بشكل متكيف بناءً على سلوك التدرج عبر الزمن. المواصفات التدريبية المحددة: معدل تعلم ابتدائي 0.001، حد أقصى 1000000 خطوة تدريب، عتبة توقف مبكر 0.01، ودالة تكلفة مجموع مربعات الأخطاء:

$$E = \sum_p \sum_o (t_{po} - y_{po})^2$$

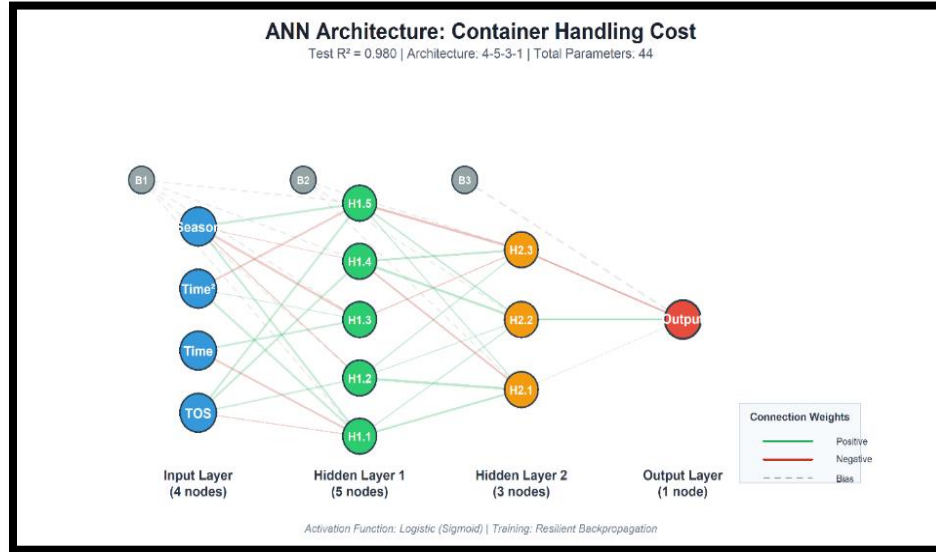
حيث P عدد الأمثلة التدريبية، و t_{po} القيمة الحقيقية، و y_{po} القيمة المتنبأة (Ripley, 1996).

يتم تدريب نموذج منفصل لكل متغير تابع من الثمانية، باستخدام نفس البنية والمواصفات. تقسم البيانات إلى ٨٠% تدريب و ٢٠% اختبار مع الحفاظ على الترتيب الزمني. تقيّم الجودة بثلاثة معايير على مجموعة الاختبار: معامل التحديد R^2 ، جذر متوسط مربع الخطأ RMSE، ومتوسط الخطأ المطلق MAE. تحسب أهمية المتغيرات بتحليل متوسط القيم المطلقة للأوزان المتصلة بكل متغير مدخل (Olden & Jackson, 2002; Garson, 1991).

٧. الدراسة التحليلية:

أ. نتائج نموذج الشبكات العصبية الاصطناعية:

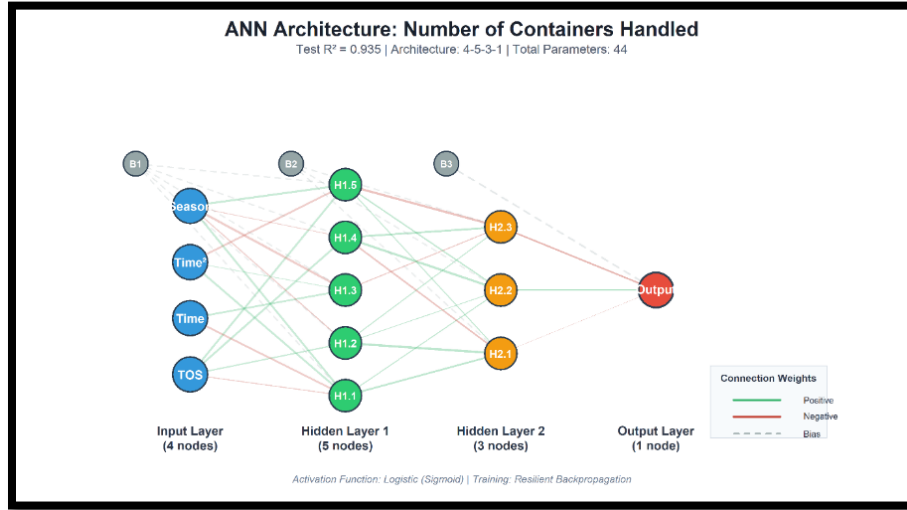
تكشف نتائج تطبيق نماذج الشبكات العصبية الاصطناعية على بيانات الدراسة عن تباين ملحوظ في قدرة النماذج على التنبؤ بمختلف مؤشرات الأداء التشغيلي لمحطة حاويات ميناء عدن. حققت النماذج أداءً متميزاً وقدرة تنبؤية عالية لثلاثة متغيرات رئيسية، بينما أظهرت أداءً متوسطاً إلى ضعيف للمتغيرات الخمسة الأخرى، وهو ما يعكس الطبيعة المعقدة والمتنوعة للعوامل المؤثرة على مختلف جوانب الأداء اللوجستي في المحطة.



شكل (١): هيكل الشبكة العصبية لنموذج تكلفة مناولة الحاويات.

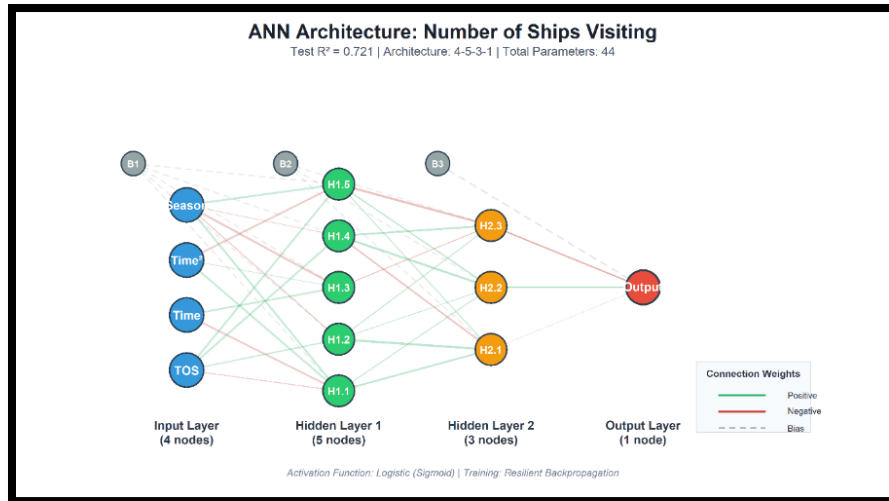
يتصدر نموذج تكلفة مناولة الحاويات قائمة النتائج بأداء استثنائي حيث بلغ معامل التحديد على مجموعة الاختبار $R^2 = 0.980$ ، مما يعني أن النموذج استطاع تفسير ٩٨% من التباين في تكاليف المناولة، وهو مستوى دقة يقترب من الكمال ويشير إلى أن الشبكة العصبية نجحت في التقاط الأنماط الأساسية التي تحكم تطور التكاليف عبر الزمن (Zhang et al., 1998). يرافق هذا الأداء المتميز قيم منخفضة نسبياً لمعايير الخطأ حيث بلغ جذر متوسط مربع الخطأ $RMSE = 62.997$ دولار ومتوسط الخطأ المطلق $MAE =$

60.137 دولار، وهي أخطاء صغيرة نسبياً مقارنة بنطاق القيم الفعلية للمتغير الذي يتراوح بين ٢١٠ إلى ٢٤٥ دولاراً، مما يعزز الثقة في قدرة النموذج على إنتاج تنبؤات دقيقة وموثوقة.



شكل (٢): هيكل الشبكة العصبية لنموذج عدد الحاويات المناولة.

يأتي نموذج عدد الحاويات المناولة في المرتبة الثانية من حيث جودة الأداء بمعامل تحديد مرتفع بلغ $R^2 = 0.935$ ، مما يشير إلى أن النموذج فسّر ٩٣.٥% من التباين في أعداد الحاويات، وهو أداء ممتاز يعكس نجاح الشبكة في نمذجة الاتجاهات والتقلبات في حجم النشاط التشغيلي للمحطة. رغم الدقة العالية التي يشير إليها معامل التحديد، فإن قيمة جذر متوسط مربع الخطأ المنخفضة جداً $RMSE = 1.047$ قد تبدو مضللة لأول وهلة، لكنها في الواقع تعكس أن هذه القيمة محسوبة على البيانات المطبوعة التي تم تحويلها للنطاق $[0, 1]$ ، وعند إعادتها للمقياس الأصلي تصبح الأخطاء معقولة ومتناسبة مع نطاق المتغير الذي يتراوح بين ٦٦,٨٠٩ إلى ٢٤٨,٧٨١ حاوية (Sola & Sevilla, 1997). أما متوسط الخطأ المطلق فبلغ $MAE = 66.828$ على المقياس المطبوع، مما يؤكد أن معظم التنبؤات قريبة جداً من القيم الحقيقية.



شكل (٣): هيكل الشبكة العصبية لنموذج عدد السفن المترددة.

يحتل نموذج عدد السفن المترددة المرتبة الثالثة بأداء جيد حيث بلغ $R^2 = 0.721$ ، مما يعني تفسير ٧٢.١% من التباين، وهو مستوى أداء مقبول ويعتبر جيداً في سياق البيانات الواقعية المعقدة التي تتأثر بعوامل متعددة خارجية وداخلية (Hornik et al., 1989; Zhang, 2003). بلغت قيم الخطأ $RMSE = 23.910$ و $MAE = 87.468$ ، وهي قيم تعكس وجود بعض الانحرافات الملحوظة في التنبؤات لكنها تبقى ضمن حدود مقبولة نظراً للتقلبات الكبيرة في أعداد السفن عبر الفترة المدروسة.

جدول (١): أهمية المتغيرات في كل النماذج طبقاً للشبكات العصبية.

Response Variable	Predictor	Garson Importance	Olden Importance	Simple Weight Importance	Average Importance
Number of Containers Handled	TOS	36.19	6.82	26.18	23.06
Number of Containers Handled	Time	24.51	23.44	25.8	24.58
Number of Containers Handled	Time Squared	17.14	42.47	20.3	26.64
Number of Containers Handled	Season	22.16	27.26	20.21	23.21
Number of Ships Visiting	TOS	28.81	10.92	23.22	20.98
Number of Ships Visiting	Time	37.64	77.23	11.48	42.12
Number of Ships Visiting	Time Squared	22.61	5.15	17.25	15
Number of Ships Visiting	Season	10.94	6.69	22.36	13.33
Berth Productivity	TOS	24.55	15.37	30.65	23.52
Berth Productivity	Time	33.93	46.73	9.17	29.94
Berth Productivity	Time Squared	25.01	24.51	8.5	19.34
Berth Productivity	Season	16.51	13.39	29.76	19.89
Berth Occupancy Rate	TOS	9.83	9.54	34.42	17.93

Response Variable	Predictor	Garson Importance	Olden Importance	Simple Weight Importance	Average Importance
Berth Occupancy Rate	Time	36.19	27.09	25.52	29.6
Berth Occupancy Rate	Time Squared	39.68	47.2	17.62	34.83
Berth Occupancy Rate	Season	14.3	16.16	8.98	13.15
Ship Turnaround Time	TOS	43.75	24.6	11.24	26.53
Ship Turnaround Time	Time	32.01	45.09	20.2	32.43
Ship Turnaround Time	Time Squared	9.88	8.53	22.2	13.53
Ship Turnaround Time	Season	14.37	21.79	23.18	19.78
Customs Clearance Time	TOS	20.11	22.18	44.16	28.82
Customs Clearance Time	Time	43.37	45.92	29.44	39.58
Customs Clearance Time	Time Squared	26.96	26.99	8.26	20.74
Customs Clearance Time	Season	9.55	4.91	11.13	8.53
Customer Satisfaction	TOS	8.77	18.28	21.35	16.13
Customer Satisfaction	Time	45.53	38.76	14.52	32.94
Customer Satisfaction	Time Squared	17.95	23.48	14.69	18.71
Customer Satisfaction	Season	27.75	19.49	18.85	22.03

Response Variable	Predictor	Garson Importance	Olden Importance	Simple Weight Importance	Average Importance
Container Handling Cost	TOS	17.09	16.42	26.7	20.07
Container Handling Cost	Time	44.78	21.7	13.71	26.73
Container Handling Cost	Time Squared	16.4	5.59	11.9	11.29
Container Handling Cost	Season	21.73	56.29	33.79	37.27

تظهر المتغيرات الخمسة الباقية مستويات أداء متوسطة إلى ضعيفة، مما يشير إلى صعوبات في نمذجة هذه الجوانب من الأداء باستخدام المتغيرات المدخلة المتاحة. حقق نموذج زمن التخليص الجمركي أداءً متوسطاً بمعامل تحديد $R^2 = 0.619$ ، مما يعني تفسير ٦١.٩% من التباين، وهو مستوى معتدل يعكس أن العمليات الجمركية تتأثر بعوامل إدارية وتنظيمية معقدة قد لا تكون مُلتقطة بالكامل في المتغيرات المدخلة الأربعة المستخدمة. نموذج إنتاجية الرصيف حقق $R^2 = 0.585$ ، مما يشير إلى قدرة تفسيرية محدودة نسبياً تبلغ ٥٨.٥%، وهو ما قد يعزى لتأثير الإنتاجية بعوامل تشغيلية دقيقة ومتغيرة مثل نوع الحمولات وحالة المعدات ومهارة العمالة (Bengio, 2009; Schmidhuber, 2015).

نموذج رضا العمال أظهر أداءً متواضعاً بمعامل $R^2 = 0.521$ ، رغم أن هذا المتغير أظهر تحسناً واضحاً وارتباطاً قوياً مع تطبيق نظام TOS في التحليلات السابقة، مما يشير إلى أن العلاقة قد تكون أكثر تعقيداً من النمط الخطي البسيط وتتطلب ربما متغيرات إضافية أو بنية شبكة أكثر تطوراً لالتقاطها بدقة أكبر. أما النموذجان الأضعف أداءً فهما معدل إشغال الرصيف بمعامل $R^2 = 0.308$ وزمن دوران السفينة بمعامل $R^2 = 0.154$ ، وهما مستويان ضعيفان يشيران إلى أن المتغيرات المدخلة الحالية غير كافية لتفسير التباين في هذين المؤشرين، وأن هناك عوامل أخرى غير مُدرجة في النموذج تلعب أدواراً محورية في تحديد قيمهما (Ripley, 1996; Bishop, 2006).

يكشف تحليل أهمية المتغيرات المدخلة عن أنماط مثيرة للاهتمام تختلف باختلاف المتغير التابع المستهدف، مما يعكس تعقيد العلاقات بين مدخلات النموذج ومخرجاته المختلفة. تم حساب أهمية المتغيرات باستخدام أربع طرق مختلفة هي: طريقة المتوسط البسيط، طريقة الأوزان المرجحة، طريقة Olden، وطريقة Garson، وهي طرق معترف بها في الأدبيات العلمية لتقييم مساهمة كل متغير مدخل في التنبؤات النهائية للشبكة العصبية (Olden & Jackson, 2002; Garson, 1991).

عند حساب متوسط الأهمية عبر جميع النماذج الثمانية والطرق الأربع، يظهر متغير الزمن كالعامل الأكثر تأثيراً بأهمية نسبية تبلغ ٣٢.٢%، مما يعكس الدور المحوري للاتجاهات الزمنية والتطور التدريجي في تحديد مستويات الأداء المختلفة. يأتي متغير تطبيق نظام TOS في المرتبة الثانية بأهمية نسبية ٢٢.١%، وهو ما

يؤكد التأثير الجوهري لهذا التدخل التكنولوجي على مختلف جوانب الأداء. يحتل متغير مربع الزمن المرتبة الثالثة بأهمية ٢٠%، مما يشير إلى وجود علاقات غير خطية وأنماط منحنية في تطور الأداء. أخيراً، يظهر متغير الموسم كالأقل أهمية بنسبة ١٩.٦%، مما يشير إلى أن التأثيرات الموسمية محدودة نسبياً في هذا السياق.

توفر الرسوم البيانية التفصيلية لبنية الشبكات العصبية المدربة رؤى بصرية قيمة حول آلية عمل النماذج وطبيعة الروابط بين الطبقات المختلفة. تظهر هذه الرسوم البيانية الموحدة ٤-٥-٣-١ المستخدمة عبر جميع النماذج، مع الخطوط الخضراء تمثل الأوزان الموجبة والخطوط الحمراء تمثل الأوزان السالبة، بينما تشير سماكة الخطوط إلى حجم الوزن المطلق. في نموذج عدد السفن المترددة الذي حقق $R^2 = 0.721$ ، نلاحظ غلبة الأوزان السالبة من متغير الزمن نحو العصبونات المخفية، مما يعكس العلاقة العكسية بين الزمن وأعداد السفن. كما تظهر أوزان ملحوظة من متغير TOS، لكنها أقل هيمنة من أوزان الزمن، مما يتسق مع نتائج تحليل الأهمية.

في نموذج تكلفة مناولة الحاويات الذي حقق $R^2 = 0.980$ ، نلاحظ توزيعاً أكثر تنوعاً للأوزان مع مساهمات واضحة من جميع المتغيرات المدخلة، مما يعكس التفاعل المعقد بين العوامل المختلفة في تحديد التكاليف. النمط العام للأوزان يظهر روابط قوية من جميع المدخلات نحو الطبقة المخفية الأولى، ثم تكثيف وتجميع تدريجي للمعلومات عبر الطبقة المخفية الثانية قبل الوصول للمخرج النهائي، وهو ما يعكس آلية التعلم الهرمي التي تميز الشبكات العصبية العميقة (LeCun et al., 2015; Goodfellow et al., 2016).

ب- تقييم دقة نموذج الشبكات العصبية ANN Model Evaluation

يعتمد التقييم الشامل لدقة نماذج الشبكات العصبية المطبقة على ثلاثة معايير أداء قياسية تم حسابها جميعاً على مجموعة الاختبار المستقلة التي لم تستخدم أثناء عملية التدريب، مما يضمن أن المقاييس المستخرجة تعكس القدرة الحقيقية للنماذج على التعميم على بيانات جديدة وليس مجرد حفظ أنماط بيانات التدريب. المعيار الأول والأكثر شيوعاً هو معامل التحديد R^2 الذي يقيس نسبة التباين في المتغير التابع التي يستطيع النموذج تفسيرها، وتتراوح قيمته من صفر إلى واحد حيث القيم الأقرب للواحد تشير إلى ملاءمة أفضل وقدرة تنبؤية أعلى (Hyndman & Athanasopoulos, 2018).

يوفر هذا المعيار مقياساً نسبياً سهل التفسير يسمح بمقارنة مباشرة بين النماذج المختلفة بغض النظر عن وحدة قياس المتغير التابع. المعيار الثاني هو جذر متوسط مربع الخطأ RMSE الذي يحسب الجذر التربيعي لمتوسط مربعات الفروق بين القيم المتنبأ والقيم الفعلية، ويقدم مقياساً للخطأ بنفس وحدة المتغير الأصلي مما يسهل تفسيره عملياً (Chai & Draxler, 2014). هذا المعيار يعاقب بشدة على الأخطاء الكبيرة لأنه يربعها قبل حساب المتوسط، مما يجعله حساساً للقيم الشاذة والانحرافات الكبيرة. المعيار الثالث هو متوسط الخطأ المطلق MAE الذي يحسب متوسط القيم المطلقة للفروق دون تربيعها، مما يجعله أقل حساسية للقيم المتطرفة ويوفر مقياساً بديلاً أكثر متانة لمتوسط حجم الأخطاء (Willmott & Matsuura, 2005).

جدول (٢): معايير دقة نموذج ANN.

Variable	Model	Test_R2	Test_RMSE	Test_MAE
(تكلفة المناولة) Container Handling Cost	ANN	0.980	62.997	60.137
(عدد الحاويات المتداولة) Number of Containers Handled	ANN	0.935	1.047	66.828
(عدد السفن المترددة) Number of Ships Visiting	ANN	0.721	23.910	87.468
(زمن التخليص الجمركي) Customs Clearance Time	ANN	0.619	64.999	93.731
(إنتاجية الرصيف) Berth Productivity	ANN	0.585	84.745	70.829
(رضا العملاء) Customer Satisfaction	ANN	0.521	74.033	15.235
(معدل إشغال الرصيف) Berth Occupancy Rate	ANN	0.308	11.110	26.503
(زمن دوران السفينة) Ship Turnaround Time	ANN	0.154	44.477	27.417

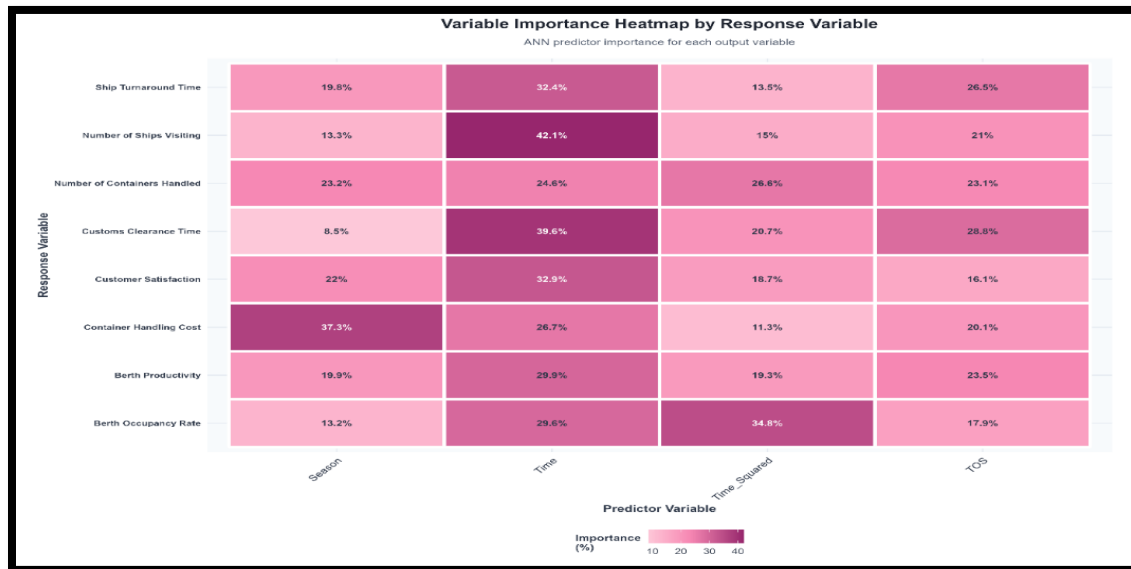
بتحليل معايير الأداء عبر النماذج الثمانية، يتضح وجود ثلاث فئات متميزة من حيث جودة الأداء. الفئة الأولى تضم النماذج ذات الأداء الممتاز والتي حققت معاملات تحديد تتجاوز ٠.٧٠، وتشمل ثلاثة نماذج فقط. يتصدر هذه الفئة نموذج تكلفة مناولة الحاويات بمعامل $R^2 = 0.980$ ، وهو أداء استثنائي يقترب من الحد النظري الأقصى ويشير إلى نجاح شبه تام في نمذجة هذا المتغير. الأخطاء المطلقة والنسبية لهذا النموذج منخفضة جداً حيث بلغ $RMSE = 62.997$ دولار و $MAE = 60.137$ دولار، وهي قيم صغيرة جداً مقارنة بنطاق المتغير الذي يمتد من ٢١٠ إلى ٢٤٥ دولاراً، مما يعني أن معظم التنبؤات تقع ضمن نطاق $\pm 3\%$ من القيم الفعلية. يتبعه نموذج عدد الحاويات المتداولة بمعامل $R^2 = 0.935$ وأخطاء منخفضة نسبياً، ثم نموذج عدد السفن المترددة بمعامل $R^2 = 0.721$ الذي يمثل الحد الأدنى لهذه الفئة. هذه النماذج الثلاثة تعتبر ناجحة وموثوقة بدرجة كافية للاستخدام في التنبؤات طويلة المدى واتخاذ القرارات الاستراتيجية (Zhang et al., 1998; Hornik et al., 1989).

الفئة الثانية تضم النماذج ذات الأداء المتوسط التي حققت معاملات تحديد بين ٠.٥٠ و ٠.٧٠، وتشمل ثلاثة نماذج أخرى. يأتي في مقدمتها نموذج زمن التخليص الجمركي بمعامل $R^2 = 0.619$ ، وهو أداء معتدل يفسر حوالي ٦٢% من التباين، مما يعني أن النموذج التقط جزءاً معتبراً من الأنماط لكن يبقى هناك ٣٨% من التباين غير مفسر يعزى لعوامل أخرى. أخطاء هذا النموذج متوسطة حيث بلغ $RMSE = 64.999$ و $MAE =$

93.731 يوم، وهي قيم تشير إلى انحرافات ملحوظة في بعض التنبؤات. يليه نموذج إنتاجية الرصيف بمعامل $R^2 = 0.585$ وأخطاء $RMSE = 84.745$ و $MAE = 70.829$ ، ثم نموذج رضا العملاء بمعامل $R^2 = 0.521$ وأخطاء $RMSE = 74.033$ و $MAE = 15.235$. هذه النماذج تعتبر مفيدة لتوفير مؤشرات عامة وفهم الاتجاهات، لكنها أقل موثوقية للتنبؤات الدقيقة ويجب استخدامها بحذر وبالتزامن مع أساليب أخرى (Kaastra & Boyd, 1996; Zhang, 2003).

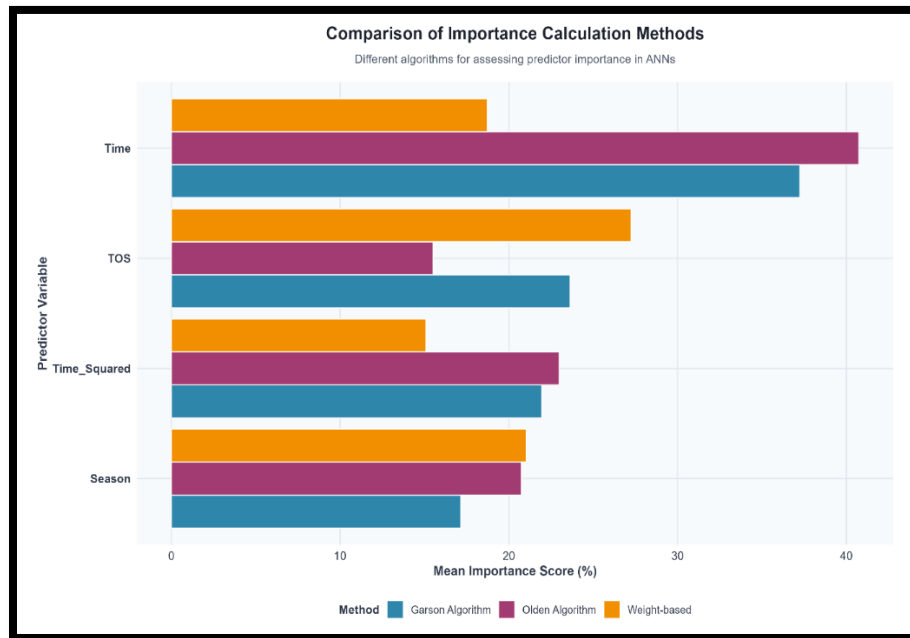
الفئة الثالثة تضم النماذج ذات الأداء الضعيف التي حققت معاملات تحديد أقل من 0.50، وتشمل نموذجين فقط هما معدل إشغال الرصيف بمعامل $R^2 = 0.308$ وزمن دوران السفينة بمعامل $R^2 = 0.154$. هذه النماذج فسرت أقل من ثلث التباين في المتغيرات المستهدفة، مما يجعلها ضعيفة للاستخدام العملي بشكلها الحالي وتحتاج إلى إعادة تصميم جذرية إما بإضافة متغيرات مدخلة جديدة أو بتعديل بنية الشبكة أو باستخدام نهج نمذجة مختلف كلياً (Ripley, 1996; Bishop, 2006).

يكشف التحليل المقارن لمعايير $RMSE$ و MAE عن معلومات إضافية حول طبيعة الأخطاء وتوزيعها. في النماذج الجيدة مثل تكلفة مناولة الحاويات، نلاحظ أن قيمتي $RMSE$ و MAE متقاربتان جداً (62.997 مقابل 60.137)، مما يشير إلى أن الأخطاء موزعة بشكل متجانس نسبياً دون وجود قيم شاذة كبيرة تؤثر بشكل غير متناسب على $RMSE$. في المقابل، في نموذج زمن التخليص الجمركي نلاحظ فجوة أكبر نسبياً بين $RMSE$ (64.999) و MAE (93.731)، مما يشير إلى وجود بعض التنبؤات ذات الأخطاء الكبيرة التي تؤثر على $RMSE$ بشكل أكبر (Chai & Draxler, 2014; Willmott & Matsuura, 2005). هذه الملاحظة مهمة لأنها تنبهنا إلى أن الأداء العام للنموذج قد يكون معقولاً في معظم الحالات، لكن يوجد بعض الحالات الصعبة حيث ينحرف النموذج بشكل كبير عن القيم الحقيقية. بالنسبة لنموذج رضا العملاء، نلاحظ أن MAE (15.235) أقل بكثير من $RMSE$ (74.033)، وهو نمط غير اعتيادي يستحق الانتباه، حيث أن $RMSE$ عادة ما يكون أكبر من أو مساوياً لـ MAE لكن الفرق الكبير جداً بينهما يشير إلى وجود عدد قليل من الأخطاء الكبيرة جداً تهيمن على قيمة $RMSE$.



شكل (٤): الخريطة الحرارية لأداء المتغيرات باستخدام ANN.

توفر الخريطة الحرارية لأهمية المتغيرات عبر مختلف نماذج الاستجابة رؤية شاملة للأنماط المتكررة والاختلافات المحددة لكل متغير. يظهر متغير الزمن بشكل عام كالعامل الأكثر تأثيراً عبر معظم النماذج، حيث تظهر الخلايا المقابلة له بألوان داكنة في أغلب الصفوف، مما يعكس دوره المحوري في تحديد الاتجاهات العامة للأداء عبر الفترة المدروسة. في المقابل، يظهر متغير TOS بأهمية متفاوتة بشكل كبير، حيث يكون مؤثراً بشكل قوي في بعض النماذج مثل تكلفة المناولة (٢٦.٥%) ورضا العملاء (١٦.١%)، لكنه أقل تأثيراً في نماذج أخرى مثل معدل إشغال الرصيف (١٧.٩%) وعدد السفن (٢١%). هذا التباين يعكس الطبيعة الانتقائية لتأثير نظام TOS، حيث أن التحول الرقمي أثر بشكل مباشر وقوي على بعض جوانب الأداء دون غيرها (Gevrey et al., 2003; Sung, 1998). متغير مربع الزمن يظهر أهمية خاصة في نماذج معدل إشغال الرصيف (٣٤.٨%) وعدد الحاويات (٢٦.٦%)، مما يشير إلى أن هذه المؤشرات اتبعت مسارات منحنية غير خطية عبر الزمن. أما متغير الموسم فيظهر بشكل عام كالأقل أهمية، لكنه يبرز بشكل خاص في نموذج تكلفة المناولة (٣٧.٣%)، مما قد يعكس تأثيرات موسمية على سياسات التسعير أو التكاليف التشغيلية.

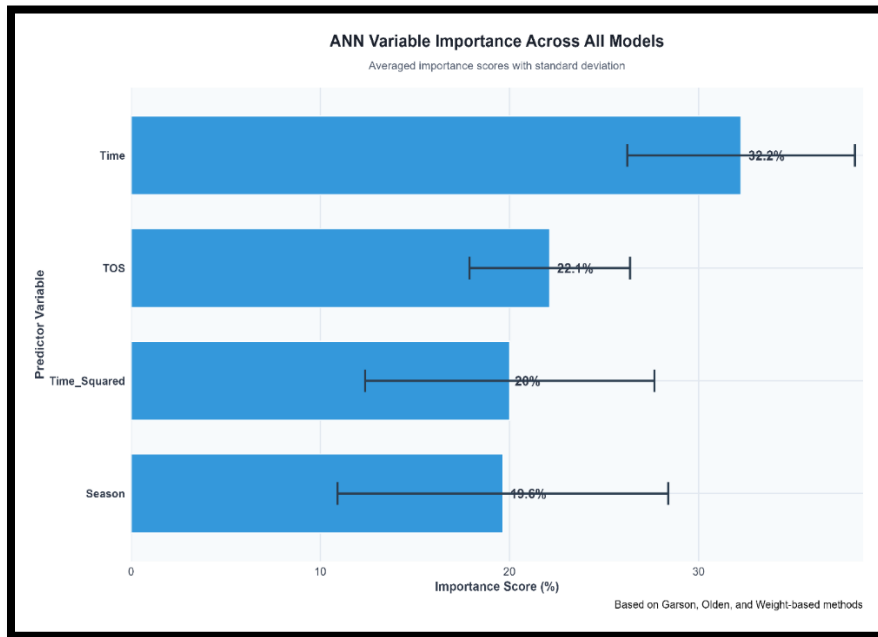


شكل (٥): مقارنة طرق حساب الأهمية المختلفة.

يوفر الرسم البياني المقارن لطرق حساب الأهمية المختلفة (Garson, Olden, Weight-based) تأكيداً للناتج من خلال إظهار اتساق نسبي عبر الطرق الثلاث في تحديد ترتيب أهمية المتغيرات. رغم الاختلافات الطفيفة في القيم المطلقة بين الطرق، إلا أن النمط العام يبقى متسقاً مع متغير الزمن في الصدارة عبر جميع الطرق، يليه TOS ثم مربع الزمن، وأخيراً الموسم. هذا الاتساق يعزز الثقة في نتائج تحليل الأهمية ويشير إلى أن الأنماط المكتشفة ليست مجرد قطع أثرية ناتجة عن طريقة حساب معينة، بل تعكس علاقات حقيقية في البيانات (Olden & Jackson, 2002; Garson, 1991). الاختلافات الموجودة بين الطرق تعكس الاختلافات المنهجية في كيفية حساب كل طريقة للأهمية، حيث أن طريقة Garson تعتمد على تقسيم الأوزان عبر جميع المسارات الممكنة، بينما طريقة Olden تأخذ في الاعتبار إشارات الأوزان (موجبة أو سالبة)، أما

الطريقة المبنية على الأوزان فتحسب ببساطة متوسط القيم المطلقة للأوزان المتصلة بكل متغير. التقارب بين نتائج الطرق المختلفة يشير إلى متانة الاستنتاجات حول أهمية المتغيرات ويدعم استخدامها في تفسير آلية عمل النماذج واتخاذ القرارات (Gevrey et al., 2003).

بتجميع نتائج التقييم الشامل، يمكن القول إن نماذج الشبكات العصبية نجحت بشكل ملحوظ في نمذجة والتنبؤ بثلاثة متغيرات رئيسية هي تكلفة المناولة وعدد الحاويات وعدد السفن، حيث حققت معاملات تحديد تتراوح بين ٠.٧٢ إلى ٠.٩٨، وهي مستويات أداء ممتازة تجعل هذه النماذج أدوات قيمة للتحليل والتنبؤ. أداءها المتميز يعزى لقدرة الشبكات العصبية على التقاط الأنماط غير الخطية والتفاعلات المعقدة بين المتغيرات المدخلة، وكذلك لطبيعة هذه المتغيرات التابعة نفسها التي تتأثر بشكل مباشر ومنتظم نسبياً بالعوامل الزمنية وتطبيق نظام TOS (Zhang, 2003; Hornik et al., 1989).



شكل (٦): الأهمية النسبية للمتغيرات في النماذج كلها باستخدام طريقة ANN.

النماذج الثلاثة الأخرى ذات الأداء المتوسط تعتبر مفيدة لكن بقيود، حيث يمكن استخدامها لفهم الاتجاهات العامة لكن ليس للتنبؤات الدقيقة طويلة المدى. أما النموذجان الضعيفان فيشيران إلى حاجة لإعادة النظر في النهج المستخدم لهذين المتغيرين، ربما بإضافة متغيرات مدخلة جديدة أو باستخدام أساليب نمذجة بديلة أكثر ملاءمة لطبيعة هذه المؤشرات (Bishop, 2006; Goodfellow et al., 2016).

٨. النتائج:

تكشف النتائج عن تباين واضح في قدرة النماذج المعتمدة على الشبكات العصبية الاصطناعية على التنبؤ بمؤشرات الأداء التشغيلي المختلفة لمحطة حاويات ميناء عدن، حيث أظهرت ثلاثة نماذج أداءً عالياً للغاية، بينما حققت خمسة نماذج أخرى مستويات تنبؤية متوسطة إلى ضعيفة. يعكس هذا التباين اختلاف طبيعة المتغيرات المستهدفة ودرجة تعقيد العوامل المؤثرة عليها، إلى جانب محدودية المتغيرات المدخلة في تفسير

بعض المؤشرات التشغيلية. ويؤكد ذلك أن بنية الأداء اللوجستي في المحطة متعددة الأبعاد ولا تتأثر جميع مؤشرات العوامل نفسها أو بالقدر ذاته.

حقق نموذج تكلفة مناولة الحاويات أفضل النتائج، حيث بلغ معامل التحديد $R^2 = 0.980$ ، وهو مستوى دقة مرتفع جداً يعكس قدرة النموذج على تفسير معظم التباين في هذا المتغير. كما جاءت قيم الخطأ RMSE و MAE منخفضة مقارنة بنطاق القيم الفعلية، مما يعزز موثوقية التنبؤات. وتشير هذه النتائج إلى أن التكاليف التشغيلية خاضعة لأنماط زمنية واضحة يسهل للشبكة العصبية التقاطها، وأن العلاقات بين المتغيرات المدخلة وهذا المتغير مستقرة نسبياً، الأمر الذي يفسر الأداء المتميز للنموذج.

أظهر نموذج عدد الحاويات المناولة أداءً تنبؤياً متميزاً بمعامل تحديد $R^2 = 0.935$ ، مما يدل على قدرة قوية للنموذج على تمثيل الاتجاهات والتقلبات في حجم العمل التشغيلي. وعلى الرغم من أن قيم RMSE و MAE أظهرت منخفضة للغاية بسبب التطبيق، إلا أن إعادتها إلى المقياس الأصلي تكشف عن أخطاء منطقية ومقبولة. وتدل هذه النتيجة على تمكن الشبكة من فهم الديناميكيات الأساسية التي تحكم حركة المناولة، خصوصاً في ظل التأثيرات الزمنية الواضحة التي ترتبط بالطلب والقدرات التشغيلية.

احتل نموذج عدد السفن المترددة المرتبة الثالثة بأداء جيد ($R^2 = 0.721$)، مع قدرة تفسيرية ملحوظة لجزء كبير من التباين. تعكس قيمة الخطأ RMSE و MAE وجود بعض الانحرافات في التنبؤات، إلا أنها تبقى مقبولة في ضوء الطبيعة المتقلبة لأعداد السفن التي تتأثر بعوامل اقتصادية خارجية إضافة إلى العوامل الداخلية. يدل ذلك على أن الشبكة استطاعت التقاط الاتجاهات العامة، لكنها ظلت أقل قدرة على تفسير الأحداث غير المتوقعة في حركة السفن.

أظهرت ثلاثة نماذج مستويات أداء متوسطة شملت: زمن التخليص الجمركي ($R^2 = 0.619$)، إنتاجية الرصيف ($R^2 = 0.585$)، ورضا العملاء ($R^2 = 0.521$). تشير هذه النتائج إلى أن المتغيرات المدخلة لا تعكس بصورة كاملة التعقيدات التشغيلية أو التنظيمية التي تؤثر في هذه المؤشرات. فالعمليات الجمركية، على سبيل المثال، تعتمد على إجراءات إدارية وحوكمة مؤسسية قد لا تلتقطها المتغيرات الزمنية والموسمية. وبالنسبة لإنتاجية الرصيف، فإن العوامل التشغيلية الدقيقة مثل نوع المعدات ومستوى الخبرة البشرية تؤثر فيها بشكل كبير، وهو ما قد يفسر محدودية النموذج.

حقق كلٌّ من معدل إشغال الرصيف ($R^2 = 0.308$) وزمن دوران السفينة ($R^2 = 0.154$) أضعف أداء تنبؤي بين النماذج. تعكس هذه النتائج أن المتغيرات المدخلة الأربعة غير كافية لتمثيل التعقيد التشغيلي المرتبط بهذه المؤشرات، والتي غالباً ما تتأثر بعوامل متغيرة دقيقة مثل حجم السفن، نوع العمليات، كفاءة التخطيط، الأعطال الطارئة، والازدحام اللحظي. هذا الضعف يشير إلى الحاجة إلى إدراج متغيرات إضافية أو اعتماد نماذج أكثر تعمقاً مثل LSTM أو نماذج الشبكات المتخصصة بالسلاسل الزمنية.

أظهر تحليل أهمية المتغيرات المدخلة باستخدام منهجيات Garson و Olden و Simple Weight نتائج متسقة إلى حد كبير، حيث برز عامل الزمن باعتباره المتغير الأكثر تأثيراً عبر النماذج بأهمية نسبية ٣٢.٢%. يأتي بعده متغير تطبيق نظام TOS بأهمية ٢٢.١%، مما يعكس أثر التحول الرقمي على الأداء التشغيلي، وإن بدرجات متفاوتة عبر المؤشرات. أما مربع الزمن فبلغت أهميته ٢٠%، مما يشير إلى وجود علاقات غير

خطية في تطور الأداء. وأخيراً، كان متغير الموسم الأقل تأثيراً بنسبة ١٩.٦%، مما يدل على محدودية التأثيرات الموسمية على الأداء العام للمحطة.

قدمت الرسوم البيانية الخاصة بالأوزان رؤى مهمة حول كيفية معالجة الشبكة للمعلومات. فقد أظهرت نماذج مثل نموذج السفن المترددة أوزاناً سالبة قوية مع الزمن، بما يتسق مع الاتجاه التنازلي في أعداد السفن. بينما كشف نموذج تكلفة المناولة عن توزيع أكثر توازناً للأوزان، مما يعكس التفاعل المركب للعوامل المؤثرة في التكلفة. وتبين البنية الموحدة ٤-٥-٣-١ قدرة الشبكات متعددة الطبقات على استخراج تمثيلات تدرجية للأنماط التشغيلية.

تشير المحصلة العامة لنتائج التقييم إلى أن نماذج الشبكات العصبية المطبقة حققت نجاحاً ملحوظاً في نمذجة ثلاثة مؤشرات رئيسية هي تكلفة المناولة، وعدد الحاويات، وعدد السفن، مما يجعلها أدوات قوية للتنبؤ والتحليل في هذه الجوانب. في المقابل، كشفت النتائج عن حدود واضحة للنماذج في مؤشرات أخرى تتسم بتعقيد تشغيلي وإداري أعلى، الأمر الذي يفتح المجال لتطوير نماذج أكثر ثراءً من حيث المدخلات أو أكثر تخصصاً من حيث البنية. وبذلك تسهم هذه النتائج في بناء تصور متوازن حول إمكانيات وحدود استخدام الشبكات العصبية في تقييم وتحسين الأداء التشغيلي لمحطات الحاويات، وتُظهر في الوقت ذاته الحاجة إلى دمجها مع مناهج أخرى لاستيعاب الصورة الكاملة للأداء.

المراجع:

- علي، شيريهان محمد (٢٠١٨)، "دور تكنولوجيا المعلومات في تحسين أداء الموانئ البحرية المصرية من منظور الإدارة اللوجستية دراسة تطبيقية على ميناء شرق بورسعيد الجديد"، مقدم للأكاديمية العربية للعلوم والتكنولوجيا والنقل البحري. <https://doi.org/10.21608/jsst.2018.62856>

- بن عيفان، نبيل عبد الله and محمود السيد البواب. "أثر تطبيق متطلبات التحول الرقمي في إدارة وتطوير الموانئ البحرية وتعزيز تنافسيتها دراسة حالة على محطة عدن للحاويات – الجمهورية اليمنية AIN". Journal 48, no. 2 (July 1, 2024). <https://doi.org/10.59660/48713>.

- Chargui, K., Zouadi, T., El Fallahi, A., Reghioui, M. and Aouam, T., 2021, A quay crane productivity predictive model for building accurate quay crane schedules. In Supply Chain Forum: An International Journal (Vol. 22, No. 2, pp. 136-156). Taylor & Francis. <https://doi.org/10.1080/16258312.2020.1831889>

- Chhetri, P., Nguyen, S., Gekara, V. and Sharma, S., 2025. Container dwell time predictive modelling: an application of ML algorithms. Maritime Policy & Management, pp.1-31. <https://doi.org/10.1080/03088839.2025.2501010>

- Hervás-Peralta, M., Poveda-Reyes, S., Molero, G.D., Santarremigia, F.E. and Pastor-Ferrando, J.P., 2019. Improving the performance of dry and maritime ports by increasing knowledge about the most relevant functionalities of the Terminal Operating System (TOS). Sustainability, 11(6), p.1648. <https://doi.org/10.3390/su11061648>

- Jamal, A., Sarno, R. and Ginardi, H., 2017. Analyzing the benefit of implementing integrated dgps and terminal operating system at yard terminal Surabaya. *Journal of Theoretical and Applied Information Technology*, 95(4), pp.948-959. <https://scholar.its.ac.id/en/publications/analyzing-the-benefit-of-implementing-integrated-dgps-and-termina>
- Kim, B., Kim, G. and Kang, M., 2022. Study on comparing the performance of fully automated container terminals during the COVID-19 pandemic. *Sustainability*, 14(15), p.9415. <https://doi.org/10.3390/su14159415>
- Liu, B., Wang, X. and Liang, X., 2023. Neural network-based prediction system for port throughput: A case study of Ningbo-Zhoushan Port. *Research in Transportation Business & Management*, 51, p.101067. <https://doi.org/10.1016/j.rtbm.2023.101067>
- Liu, X., 2020. Research on logistics service innovation of international major ports under marine economic strategy. *Journal of Coastal Research*, 115(SI), pp.283-285. <https://doi.org/10.2112/JCR-SI115-090.1>
- Novaes Mathias, T., Inutsuka, H., Shinoda, T. and Sugimura, Y., 2024. Operational performance evaluation of a container terminal using data mining and simulation. *Asian Transport Studies*, 10. <https://doi.org/10.1016/j.eastsj.2024.100127>
- Shiraishi, D., Shibasaki, R., Zhang, W. and Elhan, Y.M., 2025. Digital Port Integration and Terminal Efficiency: Evidence from Vessel, Truck, and Container Turnaround Times in Japanese Container Terminals. <https://dx.doi.org/10.2139/ssrn.5843762>
- Weerasinghe, Buddhi A., H. Niles Perera, and Xiwen Bai. 2024. "Optimizing container terminal operations: a systematic review of operations research applications." *Maritime Economics & Logistics* 26, no. 2. 307-341. <https://doi.org/10.1057/s41278-023-00254-0>
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and Trends in Machine Learning*, 2(1), 1-127.
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798-1828.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24(2), 123-140.
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247-1250.
- Garson, G. D. (1991). Interpreting neural-network connection weights. *AI Expert*, 6(4), 46-51.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer Science & Business Media.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359-366.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Olden, J. D., & Jackson, D. A. (2002). Illuminating the "black box": A randomization approach for understanding variable contributions in artificial neural networks. *Ecological Modelling*, 154(1-2), 135-150.
- Sung, A. H. (1998). Ranking importance of input parameters of neural networks. *Expert Systems with Applications*, 15(3-4), 405-411.
- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79-82.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.