

دور الذكاء الاصطناعي عبر التعلم المعزز في تعزيز كفاءة تخصيص الأرصفة البحرية

دراسة حالة ميناء المنطقة الحرة بمصراتة، ليبيا

أبوبكر علي الأميلس^{1*} ، علي محمد عبد الشاهد²

¹قسم الهندسة المدنية، كلية الهندسة، جامعة مصراتة، مصراتة، ليبيا.

²قسم الهندسة الكهربائية، كلية الهندسة، جامعة مصراتة، مصراتة، ليبيا.

البريد الإلكتروني: a.alamailes@eng.misuratau.edu.ly

الملخص

تُعد عملية تخصيص الأرصفة للسفن من أكثر التحديات التشغيلية تعقيدًا التي تواجه الموانئ البحرية على مستوى العالم، نظرًا للحاجة إلى تنسيق فعال بين الموارد المحدودة مثل الأرصفة والطلبات المتزايدة من السفن ذات الأحجام والأنواع المختلفة. في هذا السياق، تهدف هذه الدراسة إلى تطوير نموذج مبتكر يعتمد على تقنية التعلم المعزز (**Reinforcement Learning**)، أحد فروع الذكاء الاصطناعي (**Artificial Intelligence**)، لتخصيص الأرصفة للسفن بناءً على معايير تشغيلية متعددة تشمل طول السفينة (**Ship Length**)، الوزن الصافي (**Net Weight**)، والغطاس الأقصى (**Max Draft**). تم تطبيق النموذج على بيانات تشغيلية حقيقية من ميناء المنطقة الحرة بمصراتة في ليبيا، الذي يُعد أحد الموانئ الاستراتيجية في شمال إفريقيا. أظهرت النتائج الأولية للنموذج قدرة ملحوظة على تحسين كفاءة تخصيص الأرصفة وتقليل أوقات الانتظار، مما يعزز الكفاءة التشغيلية. ومع ذلك، أشارت الدراسة إلى وجود تحديات تتعلق بتعميم النموذج ودمجه مع الأنظمة اللوجستية الأخرى. تقدم هذه الدراسة إطارًا عمليًا ومساهمةً علميةً في توظيف الذكاء الاصطناعي لتحسين الأداء التشغيلي في الموانئ البحرية وتعزيز دورها في دعم التجارة العالمية.

الكلمات المفتاحية — الذكاء الاصطناعي، التعليم المعزز، تخصيص الموانئ، المنطقة الحرة بمصراتة، الكفاءة التشغيلية.

Abstract

The process of berth allocation for ships is among the most complex operational challenges faced by seaports worldwide. This process requires efficient coordination between limited resources, such as berths, and the increasing demand from diverse ship sizes and types. This study aims to develop an innovative model based on Reinforcement Learning (RL), a branch of Artificial Intelligence (AI), for dynamic berth allocation. The model considers multiple operational criteria, including ship length, net weight, and max draft. Real operational data from the Misurata Free Zone Port, a strategic port in North Africa, were used to validate the model. The initial results demonstrated the model's ability to enhance berth allocation efficiency and reduce waiting times, thereby improving overall operational performance. However, challenges related to generalizing the model and integrating it with other logistical systems were identified. This study provides a practical framework and significant contribution to leveraging AI for optimizing port operations and supporting global trade.

Keywords— Artificial Intelligence, Reinforcement Learning, Berth Allocation, Misurata Free Zone, Operational Efficiency.

المقدمة

تلعب الموانئ البحرية دورًا أساسيًا في تعزيز التجارة الدولية والتنمية الاقتصادية، حيث تُعتبر نقطة الربط الرئيسية بين النقل البحري والبري (World Bank Blogs, 2023). مع التزايد المستمر في الطلب على خدمات الموانئ نتيجة العولمة والتوسع التجاري، أصبح من الضروري تحسين كفاءة العمليات التشغيلية. تُعد عملية تخصيص الأرصفة للسفن واحدة من أكثر التحديات تعقيدًا التي تواجه الموانئ، حيث تتطلب اتخاذ قرارات ديناميكية تهدف إلى تقليل أوقات الانتظار وضمان الاستخدام الأمثل للموارد. الأساليب التقليدية المعتمدة على خبرة المشغلين أو خوارزميات محددة غالبًا ما تكون غير كافية للتعامل مع البيئة الديناميكية والتغيرات اللحظية، مما يبرز الحاجة إلى استخدام تقنيات ذكية تعتمد على تحليل البيانات واتخاذ قرارات تكيفية (Lee, Chatterjee, & Cho, 2023).

يُعد ميناء المنطقة الحرة بمصراتة أحد الموانئ التجارية المهمة في ليبيا، حيث يتميز بموقع جغرافي استراتيجي يربط شمال إفريقيا بأوروبا والشرق الأوسط. يشهد الميناء حركة بحرية نشطة تشمل استقبال السفن التجارية وناقلات البضائع العامة والحاويات والنفط، مما يزيد من تعقيد التحديات المتعلقة

بإدارة العمليات التشغيلية بكفاءة، خاصة مع تزايد حجم العمليات وتنوع السفن الوافدة (Misurata Free Zone, 2024). على الرغم من توفر بنية تحتية حديثة وأرصفتها متعددة، إلا أن تحسين الكفاءة التشغيلية يتطلب اعتماد تقنيات ذكية لتخصيص الموارد بفعالية، خاصة في ظل تزايد حجم العمليات وتنوع السفن الوافدة.

تهدف هذه الدراسة إلى استخدام الذكاء الاصطناعي في تطوير نموذج يعتمد على التعلم المعزز لتخصيص الأرصفة للسفن بشكل ديناميكي. يهدف النموذج إلى تحسين كفاءة العمليات التشغيلية وتقليل أوقات الانتظار، مع التركيز على معايير تشغيلية متعددة تشمل طول السفينة، الوزن الصافي، والغطاس الأقصى. تم اختبار النموذج باستخدام بيانات تشغيلية حقيقية مأخوذة من المنطقة الحرة بمصراتة في ليبيا. كما تسعى الدراسة إلى تحليل أداء النموذج واقتراح تحسينات مستقبلية من شأنها تعزيز الفعالية التشغيلية. تساهم هذه الدراسة في توفير إطار عملي لتطبيق تقنيات التعلم المعزز في تحسين العمليات اللوجستية في الموانئ، مما يمكن أن يساهم في تعزيز الكفاءة التشغيلية وتقليل التكاليف. قدمت الدراسات السابقة في هذا المجال العديد من الحلول لتخصيص الموارد في الموانئ باستخدام تقنيات الذكاء الاصطناعي Zhen وآخرون (2020) استخدموا التعلم العميق لتحسين عمليات الجدولة، وأظهرت نتائجهم قدرة الخوارزميات الذكية على تقليل أوقات الانتظار وزيادة الكفاءة التشغيلية Wang وآخرون (2018) درسوا استخدام التعلم المعزز لتحسين العمليات اللوجستية في الموانئ، مع التأكيد على أهمية تحسين وظيفة المكافآت في أنظمة التعلم المعزز لتجنب القرارات غير المثلى Lee وآخرون (2019) اقترحوا نموذجًا تنبؤيًا يعتمد على تحليل بيانات السفن والتدفقات المرورية لتحسين تخصيص الأرصفة، مشيرين إلى أهمية دمج البيانات التاريخية مع النماذج الذكية. كما حلل Chen وآخرون (2021) تطبيقات الذكاء الاصطناعي لتحسين العمليات التشغيلية في الموانئ، وبيّنوا كيف يمكن لتقنيات مثل التعلم المعزز والتعلم العميق أن تساهم في تقليل التكاليف وتحسين الكفاءة.

على الرغم من الجهود السابقة، إلا أن هناك نقصًا واضحًا في الدراسات التي تركز على تخصيص الأرصفة للسفن باستخدام بيانات تشغيلية حقيقية، خاصة في الموانئ التي تمر بمرحلة تطوير مثل ميناء المنطقة الحرة بمصراتة. تهدف هذه الدراسة إلى سد هذه الفجوة البحثية من خلال تقديم نموذج تطبيقي يعتمد على تقنيات التعلم المعزز لتحسين تخصيص الأرصفة، مما يعزز من فهم أعمق

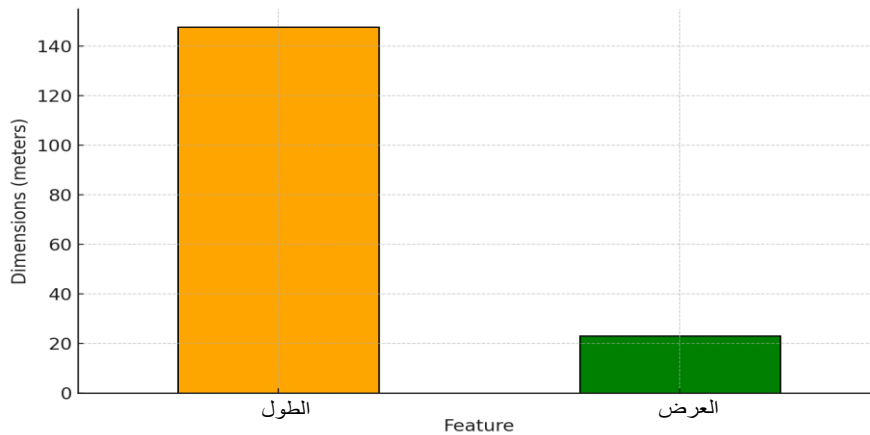
لتطبيقات الذكاء الاصطناعي في إدارة الموانئ ويسهم في تطوير الكفاءة التشغيلية للموانئ البحرية في العصر الرقمي.

الوضع الحالي لميناء المنطقة الحرة بصبراتة:

يُعد ميناء المنطقة الحرة بصبراتة أحد الموانئ الاستراتيجية الأكثر أهمية في شمال إفريقيا، حيث يلعب دورًا رئيسيًا في دعم التجارة الإقليمية والدولية. كما يتمتع الميناء بموقع جغرافي متميز يربط بين أوروبا وشمال إفريقيا والشرق الأوسط، مما يجعله محورًا لوجستيًا رئيسيًا لاستقبال أنواع مختلفة من السفن (Misurata Free Zone, 2024). ومع تزايد حركة التجارة العالمية، تزايد الحاجة إلى تحسين العمليات التشغيلية في الميناء، مما يعزز أهميته كعنصر فاعل في سلاسل الإمداد الدولية.


تشير البيانات الواردة من الميناء إلى تنوع كبير في السفن التي يتم استقبالها، وهو ما يعكس دوره الحيوي في التعامل مع الشحنات المتنوعة (Misurata Free Zone, 2024). تتراوح الأنشطة بين استقبال سفن الحاويات والسفن المخصصة للشحن المقولب وغيرها من السفن التجارية، مما يتطلب بنية تحتية مرنة قادرة على التكيف مع متطلبات عمليات التشغيل المختلفة. هذا التنوع يبرز الحاجة إلى تحسين القدرة التشغيلية وتطوير الأنظمة المستخدمة.

يوضح شكل 1 أبعاد السفن التي تصل إلى الميناء متوسط أطوال تتجاوز 150 مترًا، مما يفرض ضرورة توفير أرصفة بحرية طويلة مجهزة بأنظمة مناولة متقدمة. إضافة إلى ذلك، يُبرز عرض السفن المتزايد أهمية وجود معدات متطورة لإدارة عمليات الرسو والمناورة بدقة وسلامة. هذه المتطلبات التشغيلية تعزز الحاجة إلى استثمارات مستدامة لتطوير البنية التحتية.



شكل 1: متوسط حجم السفن (الطول، العرض) التي يستقبلها الميناء.

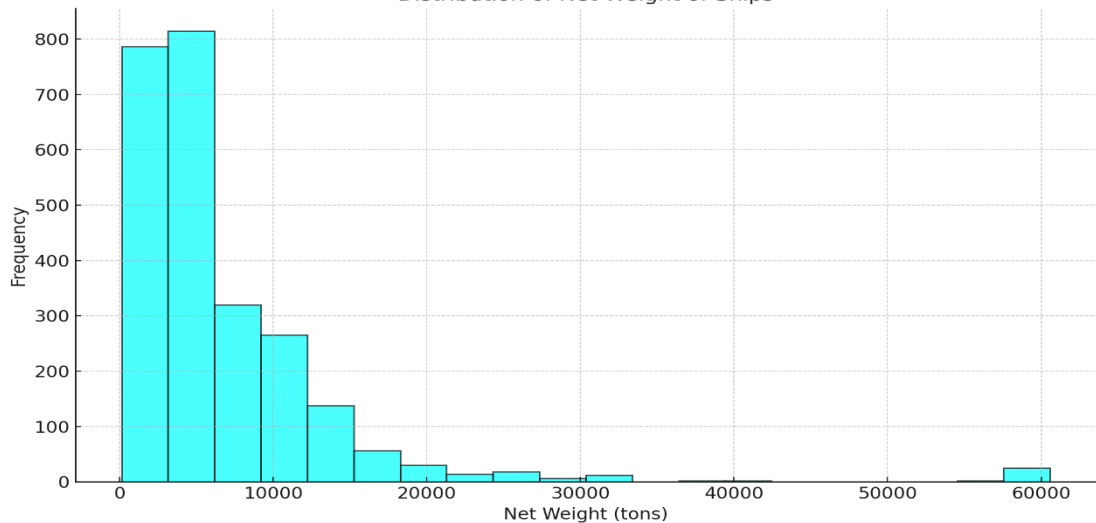
بالنظر إلى شكل 2 الذي يوضح مدد الحركة للسفن، يتبين وجود تفاوت في أوقات البقاء داخل الميناء، وهو ما يشير إلى إمكانية تحسين كفاءة العمليات التشغيلية. تطبيق تقنيات الذكاء الاصطناعي وأنظمة التشغيل الآلي يمكن أن يساهم في تقليل مدد الانتظار وزيادة انسيابية العمليات، مما ينعكس إيجابًا على رضا العملاء وتعزيز التنافسية.




شكل 2: متوسط مدد حركة للسفن

تعكس أوزان السفن الصافية والعاظم (انظر شكل 3، شكل 4) الأقصى الحاجة إلى تجهيزات قادرة على استقبال السفن ذات الحمولات الثقيلة والمتنوعة. يشير تحليل العاطس إلى أهمية توافق الأعماق البحرية للأرصفة مع متطلبات السفن الكبيرة، مما يستلزم استمرارية التحديث في البنية التحتية لضمان سلامة العمليات وكفاءتها. هذه الجوانب التشغيلية تشكل حجر الأساس لتحقيق التنمية المستدامة للميناء.

Distribution of Net Weight of Ships



شكل 3: توزيع أوزان السفن.



شكل 4 : متوسط طول الغطاس.

رغم الإمكانيات الكبيرة التي يتمتع بها ميناء المنطقة الحرة بمصراتة، تبرز تحديات تتعلق بزيادة حجم السفن وتعقيد العمليات التشغيلية. يمكن مواجهة هذه التحديات من خلال تبني تقنيات متقدمة مثل الذكاء الاصطناعي لتحسين تخصيص الأرصفة وإدارة الموارد، ما يسهم في تقليل الأوقات المهذرة وزيادة الفعالية.


يلعب الميناء دورًا محوريًا في تعزيز التكامل الإقليمي والدولي للشبكات اللوجستية. تظهر البيانات الحالية إمكانيات كبيرة للتطوير، ولكنها تشير في الوقت ذاته إلى الحاجة الملحة لتحسين الكفاءة التشغيلية من خلال تبني التكنولوجيا الحديثة وتطوير البنية التحتية. يمثل ذلك أساسًا لضمان استمرار الميناء كمركز لوجستي عالمي مستدام وقادر على تلبية متطلبات التجارة المتزايدة.

التعلم المعزز: المفهوم والأهمية والتطبيق في تخصيص الأرصفة

يُعدّ التعلم المعزز (**Reinforcement Learning**) أحد الفروع الهامة في مجال التعلم الآلي، حيث يركز على تدريب وكيل (**Agent**) على اتخاذ قرارات مُثلى في بيئة ديناميكية، وذلك بهدف تعظيم المكافأة (**Reward**) المتوقعة على المدى الطويل. يختلف التعلم المعزز عن أنواع التعلم الآلي الأخرى، مثل التعلم الخاضع للإشراف (**Supervised Learning**) والتعلم غير الخاضع للإشراف (**Unsupervised Learning**)، في كونه يعتمد على التفاعل المستمر بين الوكيل

والبيئة، حيث يتعلم الوكيل من خلال التجربة والخطأ مُستفيدًا من التغذية الراجعة التي يتلقاها في صورة مكافآت أو عقوبات (Chen, Zhang, & Liu, 2021).

يتمحور نظام التعلم المعزز حول مجموعة من العناصر الأساسية التي تتفاعل مع بعضها البعض لتشكيل عملية التعلم (أنظر شكل 5). أول هذه العناصر هو الوكيل (Agent) ، وهو الكيان الذي يتخذ القرارات بناءً على الحالة الراهنة للبيئة. أما العنصر الثاني فهو البيئة (Environment) ، وهي النظام الذي يتفاعل معه الوكيل ويتلقى منه المعلومات والتغذية الراجعة. يُمثل فضاء الحالة (State Space) جميع الحالات المُمكنة التي يُمكن أن تكون عليها البيئة، حيث يُمثل كل حالة وصفًا مُحددًا للظروف المُحيطة بالوكيل. العنصر الرابع هو الإجراءات (Actions) ، وهي مجموعة القرارات التي يُمكن للوكيل اتخاذها للتأثير على البيئة والانتقال من حالة إلى أخرى. وأخيرًا، تأتي وظيفة المكافأة (Reward Function) كآلية لتقييم أداء الوكيل، حيث تُحدد المكافأة أو العقوبة التي يتلقاها الوكيل بناءً على الإجراء الذي اتخذه وتأثيره على البيئة (Sutton & Barto, 2018).



شكل 5: مفهوم التعليم المعزز.

تتجلى أهمية التعلم المعزز في قدرته على حل المشكلات المُعقدة والديناميكية التي يصعب حلها باستخدام الأساليب التقليدية. من بين هذه المشكلات: تخصيص الموارد المُتغيرة، وتحسين الجداول الزمنية في ظل ظروف مُتغيرة، والتحكم في الأنظمة الذكية التي تتطلب اتخاذ قرارات مُتكيفة مع الظروف المُحيطة. كما يتميز التعلم المعزز بقدرته على العمل في بيئات غير معروفة مسبقًا، حيث يتعلم الوكيل بشكل تدريجي من خلال التفاعل والتجربة، مُكتسبًا الخبرة اللازمة لاتخاذ القرارات المُثلى (Tymoteusz, Polina, Sofiia, & Grzegorz, 2023).

في سياق تخصيص الأرصفة للسفن في الموانئ، يُمكن تطبيق التعلم المعزز لتحسين كفاءة هذه العملية بشكل كبير. يتمثل دور التعلم المعزز هنا في تمكين نظام ذكي من اتخاذ قرارات ديناميكية لتخصيص الأرصفة للسفن بناءً على الظروف الحالية للميناء، مثل عدد الأرصفة المتاحة، وأحجام وأنواع السفن القادمة، وأوقات وصولها المُتوقعة. يُمكن للوكيل في هذه الحالة أن يتعلم كيفية تخصيص الأرصفة بشكل يُقلل من أوقات انتظار السفن، ويُحسن من استخدام الأرصفة المُتاحة، ويُقلل من الازدحام في الميناء. يُوفر هذا النهج حلولاً أكثر كفاءة ومرونة مقارنةً بالطرق التقليدية الثابتة التي تعتمد على قواعد مُحددة مُسبقاً أو على خبرة المُشغلين فقط (Chen et al. 2021). من خلال التفاعل المُستمر مع بيانات الميناء الحقيقية، يُمكن للوكيل أن يتكيف مع التغيرات في الظروف ويتعلم استراتيجيات جديدة لتحسين عملية تخصيص الأرصفة.

منهجية البحث

تهدف هذه الدراسة إلى تطوير نموذج مُبتكر يعتمد على تقنية التعلم المعزز لتحسين كفاءة تخصيص الأرصفة في الموانئ البحرية، وذلك من خلال تطبيق النموذج على بيانات تشغيلية حقيقية من ميناء المنطقة الحرة بمصراتة. لتحقيق هذا الهدف، تم اتباع منهجية بحثية مُنظمة تتكون من عدة مراحل رئيسية، تشمل جمع البيانات، ومعالجة البيانات، وإنشاء بيئة المحاكاة، وتصميم نموذج التعلم المعزز، وتدريب النموذج وتقييمه، وأخيراً تحليل النتائج.

1. جمع البيانات

تم جمع البيانات التشغيلية من ميناء المنطقة الحرة بمصراتة، حيث تم التركيز على المعايير التشغيلية التالية التي تُعتبر حاسمة في عملية تخصيص الأرصفة:

- **طول السفينة (Length):** يُعبر هذا المعيار عن الحجم الكلي للسفينة، ويُعتبر عاملاً مُهماً في تحديد مدى ملائمة الرصيف لاستقبال السفينة.
- **الوزن الصافي (Net Weight):** يُمثل هذا المعيار الحمولة الصافية للسفينة، ويُؤثر على عمق الغاطس المطلوب للرصيف.
- **الغاطس الأقصى (Max Draft):** يُشير هذا المعيار إلى العمق الذي تغوص فيه السفينة عند تحميلها بالكامل، وهو مُحدد أساسي في اختيار الرصيف المُناسب.

يُعتبر جمع هذه البيانات من مصادر حقيقية من الميناء خطوة حاسمة لضمان واقعية النموذج وقابليته للتطبيق على أرض الواقع.

2. معالجة البيانات

لتحسين جودة البيانات وضمان تناسقها، تم إجراء معالجة مسبقة للبيانات قبل إدخالها إلى نموذج التعلم المعزز. شملت هذه الخطوة استخدام تقنية **التطبيع الخطي (Linear Normalization)** لتوحيد القيم المختلفة، مما يضمن توافقها ضمن نطاق محدد. تم تطبيق المعادلة التالية للتطبيع:

$$(1) x_{normalized} = \frac{(x - x_{min})}{(x_{max} - x_{min})}$$

حيث:

القيمة بعد التطبيع ($x_{normalized}$)

القيمة الأصلية (x)

الحد الأدنى للقيم في الخاصية (x_{min})

الحد الأقصى للقيم في الخاصية (x_{max})

تهدف هذه العملية إلى تحقيق التوازن بين الخصائص المختلفة، مثل طول السفينة، الوزن الصافي، والغطاس الأقصى، بحيث تأخذ جميعها نفس الأهمية عند إدخالها إلى النموذج. يساعد ذلك في تقليل التحيز الناتج عن اختلاف نطاقات القيم وضمان كفاءة أداء النموذج.

3. إنشاء البيئة

لإنشاء بيئة محاكاة ديناميكية لعملية تخصيص الأرصفة، تم استخدام مكتبة **Gym** من **OpenAI** ، وهي مكتبة شهيرة تُستخدم لتطوير واختبار خوارزميات التعلم المعزز. تم تصميم البيئة على النحو التالي:

• **فضاء الحالة (State Space):** يُمثل فضاء الحالة وصفاً كاملاً لوضع الميناء في لحظة

زمنية معينة. يتكون فضاء الحالة من مزيج من حالة الأرصفة (فارغة أو مشغولة) وخصائص

السفينة الحالية (طولها، وزنها الصافي، وغطاسها الأقصى). هذا التمثيل يسمح للوكيل بفهم

الوضع الحالي للميناء واتخاذ القرارات المناسبة.

• **فضاء الإجراء (Action Space):** يُمثل فضاء الإجراءات مجموعة الخيارات المتاحة

للكيل لاتخاذها. في سياق تخصيص الأرصفة، يُمثل فضاء الإجراءات الخيارات المتاحة

لتخصيص رصيف لسفينة معينة، حيث يُمكن للوكيل اختيار أي رصيف فارغ من بين الأرصفة المتاحة.

• **وظيفة المكافآت (Reward Function):** تُعتبر وظيفة المكافآت عنصراً حاسماً في عملية

التعلم المعزز، حيث تُحدد المكافأة أو العقوبة التي يتلقاها الوكيل بناءً على الإجراء الذي

اتخذه. في هذه الدراسة، تم تصميم وظيفة المكافآت على النحو التالي :

○ **مكافأة إيجابية (+1):** يحصل عليها الوكيل عند تخصيص رصيف فارغ بشكل

صحيح لسفينة معينة.

○ **عقوبة (-1):** يتلقاها الوكيل عند محاولة تخصيص رصيف مشغول.

يُساعد هذا التصميم لوظيفة المكافآت الوكيل على تعلم كيفية اتخاذ القرارات الصحيحة وتجنب

الأخطاء، وبالتالي تحسين كفاءة تخصيص الأرصفة.

4. عرض النموذج المقترح

في هذه الدراسة، تم استخدام **DQN** من مكتبة **Stable Baselines3** ، وهي مكتبة شهيرة في

مجال التعلم المعزز تُوفر تطبيقات لخوارزميات التعلم المعزز الحديثة. يُعتبر **DQN** تطوراً لخوارزمية

Q-learning التقليدية، حيث يستخدم شبكة عصبية عميقة عادةً ما تكون شبكة عصبية متعددة

الطبقات (**MLP**) لتقدير دالة القيمة **Q**. هذا يسمح للنموذج بالتعامل مع فضاءات حالة كبيرة ومعقدة،

وهو ما يُناسب مشكلة تخصيص الأرصفة التي تتضمن متغيرات متعددة مثل طول السفينة ووزنها

وغاطسها الأقصى، بالإضافة إلى حالة الأرصفة المتغيرة.

الأساس النظري لـ DQN:

يعتمد **DQN** على فكرة تقريب دالة **Q** باستخدام شبكة عصبية. تأخذ الشبكة العصبية حالة البيئة

كمدخلات وتُخرج تقديرات لقيم **Q** لجميع الإجراءات الممكنة في تلك الحالة. يتم تدريب الشبكة

العصبية لتقليل الفرق بين تقديراتها والقيم الفعلية لـ **Q** ، وذلك باستخدام خوارزمية تدرج التباين

(**Gradient Descent**) ودالة الأمثلة (**Sutton & Barto, 2018**). من أهم التحسينات التي

يُقدمها **DQN** على **Q-learning** التقليدية:

• **تخزين الخبرة (Experience Replay)** : يتم تخزين تجارب الوكيل (الحالة، الإجراء، المكافأة، الحالة التالية) في ذاكرة مؤقتة، ويتم اختيار عينات عشوائية من هذه الذاكرة لتدريب الشبكة العصبية. هذا يُساعد على كسر الارتباط بين التجارب المتتالية ويُحسن استقرار التدريب.

• **شبكة الهدف (Target Network)** : يتم استخدام شبكة عصبية ثانية (شبكة الهدف) لتقدير قيم **Q** الهدفية في معادلة التحديث. يتم تحديث أوزان شبكة الهدف بشكل دوري بأوزان الشبكة الرئيسية. هذا يُساعد على استقرار التدريب ويمنع التذبذب.

5. إعدادات التدريب

تم تدريب نموذج **DQN** على بيئة تخصيص الأرصفة المُصممة باستخدام الإعدادات التالية:

• **عدد الخطوات (Timesteps)** : 10,000 خطوة، ويُمثل هذا عدد مرات تفاعل الوكيل مع البيئة واتخاذ الإجراء.

• **معدل التعلم (Learning Rate)** : 0.001، و يُحدد هذا المُعامل حجم التغيير في أوزان الشبكة العصبية في كل خطوة تدريب.

• **حجم الدفعة (Batch Size)** : 64، و يُمثل عدد التجارب التي يتم استخدامها في كل تحديث لأوزان الشبكة العصبية.

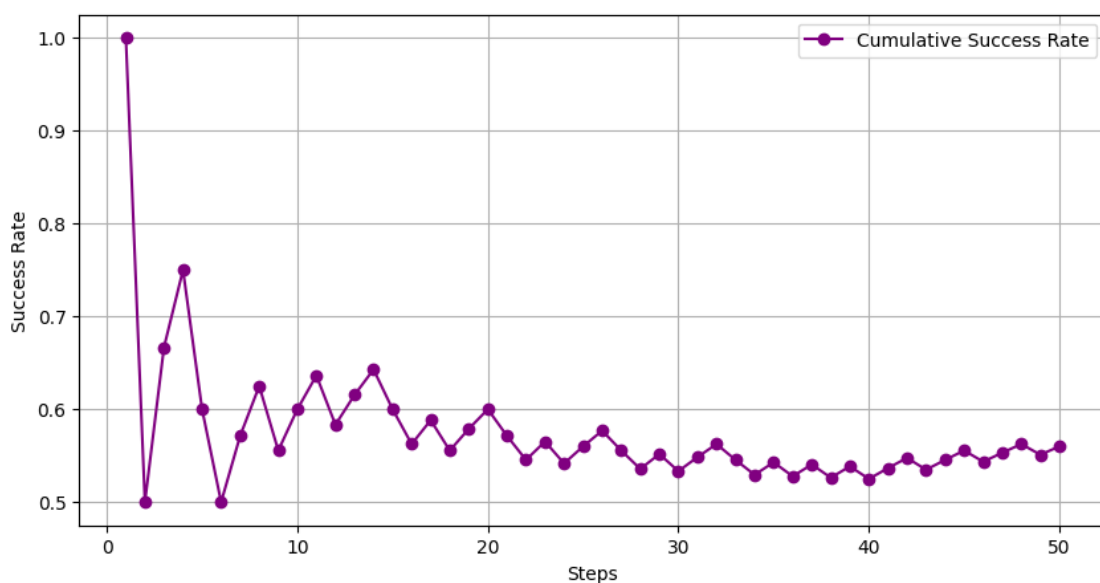
• **خصائص تكرارية (Episodic Training)**: تم تدريب النموذج على عدة سيناريوهات مُختلفة لزيادة قدرته على التعميم والتكيف مع الظروف المُتغيرة في الميناء. هذا يعني أن التدريب تم على دفعات من البيانات المُتغيرة وليس على بيانات ثابتة.

النتائج والاستنتاجات

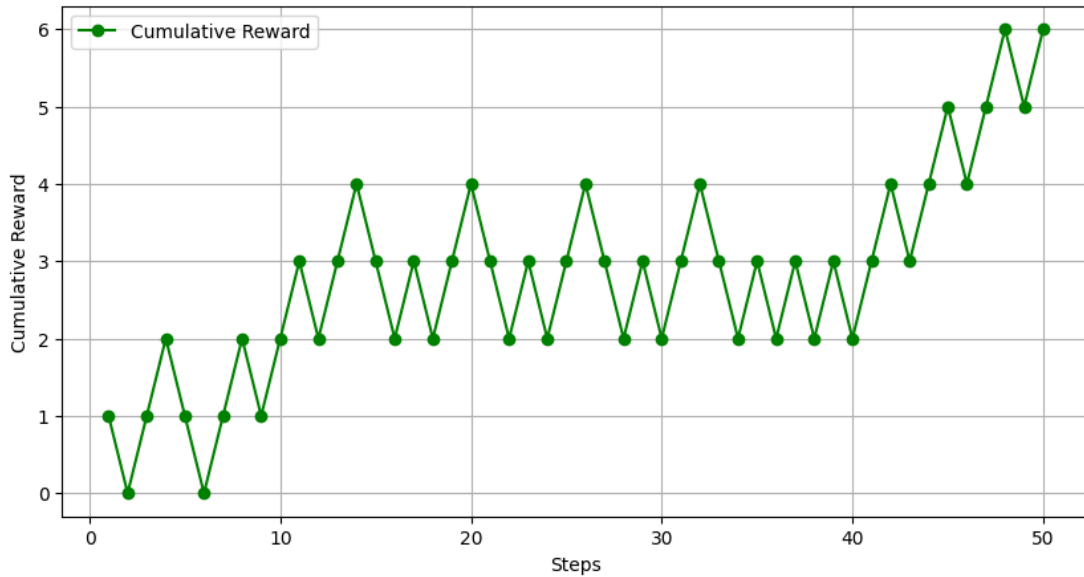
يُقدم هذا القسم عرضًا مُفصلاً للنتائج التي تم الحصول عليها من تطبيق نموذج **DQN** على بيانات ميناء المنطقة الحرة بمصراتة، بالإضافة إلى تحليل هذه النتائج ومناقشتها في سياق أهداف الدراسة. خلال مرحلة الاختبار، تم تنفيذ النموذج المُدرَّب على 50 خطوة، حيث تم تسجيل نسبة نجاح بلغت 40%، ومجموع مكافآت وصل إلى 10. يُشير تحليل النتائج إلى أن النموذج تمكن من تحقيق مكافآت إيجابية بنسبة 20% من إجمالي الخطوات، ما يُؤكد قدرته على التعرف على الأرصفة

الفارغة وتخصيصها بشكل صحيح. في المقابل، نتجت المكافآت السلبية عن محاولات تخصيص أرصفة مشغولة، ما يُشير إلى الحاجة لتطوير آليات اتخاذ قرارات أكثر دقة. أظهر النموذج أداءً واعدًا في المراحل الأولى من تخصيص الأرصفة، إلا أنه مع زيادة عدد السفن وتعدد الأرصفة، ظهرت تحديات في التعميم على الحالات الجديدة. تم تسجيل معدلات خطأ بنسبة 60% عند تخصيص الأرصفة، وهو مؤشر على تحديات متعلقة بالتعميم، يُمكن تحسينها من خلال تدريب النموذج على المزيد من الحالات الواقعية. ومع ذلك، أظهر منحني المكافآت تحسنًا تدريجيًا في الأداء مع زيادة عدد الحلقات التدريبية، حيث انخفضت الأخطاء وزادت المكافآت الإيجابية (أنظر شكل 6). كما يوضح شكل 7 توزيع المكافآت عبر الخطوات التدريبية، وتؤكد هذا التحسن التدريجي في الأداء مع مرور الوقت، حيث تظهر النتائج انخفاض تدريجي في معدلات الخطأ وزيادة في معدلات النجاح.

تُظهر هذه النتائج إمكانات النموذج في تحسين عملية تخصيص الأرصفة، ما يُمهد الطريق لتطبيق تقنيات التعلم المعزز في مجالات أخرى ضمن إدارة الموانئ، مثل إدارة الجداول الزمنية وعمليات المناولة. ومع ذلك، تُشير النتائج أيضًا إلى وجود تحديات، منها ضرورة تضمين معايير إضافية في البيئة، كأوقات الوصول والمغادرة المتوقعة للسفن، والحاجة إلى زيادة حجم البيانات التدريبية لتحسين الأداء.



شكل 6: التحسن التدريجي في الأداء.



شكل 7: توزيع المكافآت عبر الخطوات التدريبية.

بناءً على ما سبق، يُمكن استخلاص أنه يُمكن استخدام التعلم المعزز، وخاصةً نموذج **DQN**، بفعالية في تخصيص الأرصفة في الموانئ باستخدام بيانات تشغيلية حقيقية، كما يتضح من تطبيق النموذج على بيانات ميناء المنطقة الحرة بمصراتة. يُظهر النموذج قدرة واعدة على تحسين كفاءة هذه العملية، إلا أن هناك حاجة إلى مزيد من التحسينات، خاصةً فيما يتعلق بتعميم النموذج وزيادة حجم البيانات التدريبية وتضمين معايير إضافية في البيئة.

الخاتمة والتوصيات

تُقدم هذه الدراسة مساهمة في مجال إدارة الموانئ من خلال استكشاف إمكانية استخدام تقنيات التعلم المعزز، لتحسين كفاءة تخصيص الأرصفة للسفن. من خلال تطبيق النموذج على بيانات تشغيلية حقيقية مُستقاة من ميناء المنطقة الحرة بمصراتة، تم التوصل إلى نتائج واعدة تُشير إلى إمكانية تعزيز كفاءة هذه العملية الحيوية.

أظهرت النتائج أن نموذج **DQN** قادر على تعلم استراتيجيات فعالة لتخصيص الأرصفة، حيث تمكن من تحقيق نسبة نجاح بلغت 40% في تخصيص الأرصفة الفارغة بشكل صحيح خلال مرحلة الاختبار. يُؤكد هذا الإنجاز إمكانية استخدام التعلم المعزز في حل مشاكل تخصيص الموارد في البيئات الديناميكية والمعقدة مثل الموانئ. ومع ذلك، كشف التحليل أيضاً عن بعض التحديات، مثل

صعوبة تعميم النموذج على الحالات الجديدة وارتفاع معدل الخطأ في بعض الأحيان، ما يُشير إلى الحاجة إلى مزيد من التحسينات.

تؤكد الدراسة أهمية زيادة حجم البيانات التدريبية وتنوعها لتحسين قدرة النموذج على التكيف والتكيف مع الظروف المتغيرة في الميناء. كما تُبرز الحاجة إلى تضمين معايير إضافية في البيئة، مثل أوقات الوصول والمغادرة المتوقعة للسفن، ونوع السفينة وحجم الحمولة، لجعل المحاكاة أكثر واقعية وتمثيلاً لسير العمل الحقيقي في الميناء.

بناءً على هذه النتائج والاستنتاجات، تُقدم التوصيات التالية بهدف تعزيز أداء نماذج التعلم المعزز في تخصيص الأرصفة وتحقيق أقصى استفادة من هذه التقنية الواعدة: يُوصى بتحسين وظيفة المكافآت لتكون أكثر دقة في تقييم أداء النموذج وتشجيعه على اتخاذ القرارات المثلى، وذلك من خلال إضافة مكافآت أو عقوبات مناسبة لحالات مُحددة، مثل تقليل وقت انتظار السفن أو زيادة استخدام الأرصفة المتاحة. كما يُوصى بزيادة حجم البيانات التدريبية وتنوعها لتغطية أكبر قدر ممكن من السيناريوهات الواقعية التي قد يواجهها الميناء، ما يُساعد النموذج على التعميم بشكل أفضل. من الضروري أيضاً توسيع البيئة لتشمل معايير إضافية، مثل حالة الازدحام في الميناء وأوقات الوصول والمغادرة المتوقعة للسفن، لجعل المحاكاة أقرب إلى الواقع. أخيراً، يُوصى باختبار النموذج في بيئات موانئ أخرى ذات خصائص مختلفة لتقييم أدائه في ظروف مُتنوعة، واستخدام تقنيات تعلم معزز مختلفة، التي قد تُقدم أداءً أفضل في بعض الحالات وتُساعد على تسريع عملية التدريب.

في الختام، تُقدم هذه الدراسة دليلاً على إمكانية استخدام التعلم المعزز لتحسين كفاءة تخصيص الأرصفة في الموانئ، وتُفتح آفاقاً جديدة للبحث والتطوير في هذا المجال. من خلال معالجة التحديات المُحددة وتنفيذ التوصيات المُقترحة، يُمكن تحقيق تحسينات كبيرة في أداء نماذج التعلم المعزز، ما يُساهم في تعزيز كفاءة الموانئ وتقليل التكاليف التشغيلية وتحسين الخدمات اللوجستية، وبالتالي دعم حركة التجارة العالمية. تُشجع هذه الدراسة على إجراء المزيد من البحوث والدراسات لتطوير وتطبيق تقنيات الذكاء الاصطناعي في مختلف جوانب إدارة الموانئ والقطاعات اللوجستية الأخرى.

المراجع:

- Chen, L., Lu, K., Rajeswaran, A., Dubrawski, A., Gupta, A., & Levine, S. (2021). Decision transformer: Reinforcement learning via sequence modeling. *Advances in Neural Information Processing Systems*, 34, 15084–15097.
- Chen, X., Zhang, Y., & Liu, H. (2021). Artificial intelligence in port operations. *International Journal of Logistics Management*.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- Lee, H., Chatterjee, I., & Cho, G. (2023). A systematic review of computer vision and AI in parking space allocation in a seaport. *Applied Sciences*, 13(18), Article 10254. <https://doi.org/10.3390/app131810254>
- Lee, S. H., Park, K. T., & Kim, J. (2019). Predictive models for berth allocation. *Transportation Research Part E*.
- Misurata Free Zone. (2024). Seaport. Retrieved October 27, 2024, from https://mfzly.com/?lang=en&page_id=1847
- OpenAI. (2021). Advancements in deep reinforcement learning: Applications and challenges.
- Stable Baselines3. (2023). Stable Baselines3 documentation. Retrieved October 26, 2023, from <https://stable-baselines3.readthedocs.io/en/master/>
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). MIT Press.
- Tymoteusz, M., Polina, K., Sofiia, M., & Grzegorz, B. (2023, April). Reinforcement learning: A driving force in the evolution of science and information activity. In *The 13th International Scientific and Practical Conference: Information Activity as a Component of Science Development* (pp. 449–450). Edmonton, Canada: International Science Group.
- Wang, T., Chen, Y., & Zhou, L. (2018). Reinforcement learning for port logistics scheduling. *Journal of Operational Research*.
- World Bank Blogs. (2023, June 16). لماذا تمثل الموانئ أهمية للاقتصاد العالمي؟. Retrieved from <https://blogs.worldbank.org/ar/voices/lmadha-tmthl-almwany-ahmyt-llaqtsad-alalmy>
- Zhen, L., Wang, K., & Zhang, R. (2020). Deep learning for port operation optimization. *Maritime Policy & Management*.