https://jsras.rcc.edu.ly/
Vol.3 No.0 (2026), 99-109
Article history:
Received: 20 Jun. 2026
Accepted: 18 Jul. 2026
Published: 12 Sep. 2026

Journal of Sustainable Research in Applied Sciences

JSRAS

Adaptive Cloud Resource Management Using Large Language Models and Reinforcement Learning : A Critical Review and Conceptual Framework

Salha Alarabe Mohamed Almabrouk[1,*] Mustafa Ahmed Ben Hkoma[2]
[1]The Libyan Academy for Postgraduate Studies, Computer Science, Al-khums, Libya
[2]Sustainability Development Researches Centre

Index Terms

Adaptive Cloud Resource Management; Large Language Models; Reinforcement Learning; Resource Allocation Context-Aware Management .

Abstract

Adaptive cloud resource management increasingly requires systems that can respond not only to changing workloads and resource states but also to the broader operational context in which management decisions are made. This study critically reviews recent research on cloud resource management, with particular emphasis on the complementary roles of Large Language Models (LLMs) and Reinforcement Learning (RL), and identifies the main gaps that constrain their effective integration. The reviewed literature covers adaptive scheduling, resource allocation, auto-scaling, workload management, and emerging uses of LLMs for interpreting operational logs, policies, intents, and other unstructured information. The analysis shows that RL provides a strong foundation for sequential and adaptive decision-making through continuous interaction with the environment; however, existing approaches largely rely on predefined numerical states and reward functions, limiting their ability to capture richer operational context. LLMs, in contrast, offer valuable semantic reasoning capabilities but remain constrained by hallucination, reliability, inference latency, and computational cost, and cannot independently provide robust long-term adaptive control. To bridge these limitations, this study proposes a conceptual framework in which LLMs support contextual understanding and decision formulation, while RL drives adaptive resource decisions based on environmental feedback. Safety validation, execution, and feedback are incorporated into a closed-loop architecture. The study argues that such functional integration provides a conceptual foundation for moving from state-aware toward context-aware adaptive cloud management, while highlighting the need for empirical validation under realistic, large-scale cloud environments.

الإدارة التكيفية لموارد الحوسبة السحابية باستخدام نماذج اللغة الكبيرة والتعلم المعزز : مراجعة تحليلية وإطار مفاهيمي

صالحة العربي محمد المبروك[1,*]، مصطفى أحمد بن حكومة[2]،
[1]الأكاديمية الليبية للدراسات العليا ،علوم الحاسوب، الخمس، ليبيا
Salhaal2026@gmail.com ،
[2]مركز أبحاث التنمية المستدامة
m_hkoma2017@yahoo.com
https://orcid.org/0009-0006-6814-8468
* صالحة العربي محمد المبروك

الكلمات المفتاحية

الحوسبة السحابية؛ الإدارة التكيفية للموارد؛ نماذج اللغة الكبيرة؛ التعلم المعزز؛ تخصيص الموارد.

الملخص

هدفت هذه الدراسة إلى تحليل الاتجاهات الحديثة في الإدارة التكيفية لموارد الحوسبة السحابية، مع التركيز على إمكانات التكامل بين نماذج اللغة الكبيرة (LLMs) والتعلم المعزز(RL) ، والكشف عن الفجوات والتحديات التي تحد من توظيفهما بصورة متكاملة. اعتمدت الدراسة مراجعة تحليلية نقدية للأدبيات الحديثة ذات الصلة بجدولة الموارد وتخصيصها والتوسع الآلي وإدارة الأحمال، إلى جانب التطبيقات الناشئة لنماذج اللغة الكبيرة في فهم السياق والنوايا والبيانات التشغيلية غير المنظمة. أظهرت المراجعة أن التعلم المعزز يوفر قدرة متقدمة على اتخاذ القرارات التكيفية والتعلم من التفاعل مع البيئة، إلا أن اعتماده غالبًا على حالات ومكافآت كمية محددة مسبقًا يحد من استيعابه للسياق التشغيلي الأوسع. وفي المقابل، توفر نماذج اللغة الكبيرة إمكانات واعدة لفهم السجلات والسياسات والنوايا والأحداث التشغيلية، لكنها تواجه تحديات تتعلق بالموثوقية والهلوسة والكلفة وزمن الاستدلال، ولا تكفي منفردة لإدارة القرارات المتتابعة. وبناءً على ذلك، تقترح الدراسة إطارًا مفاهيميًا يدمج الاستدلال الدلالي القائم على LLM مع اتخاذ القرار التكيفي القائم على RL ضمن حلقة مغلقة تشمل مراقبة السياق، وصياغة القرار، والتحقق، والتنفيذ، والتغذية الراجعة. وتخلص الدراسة إلى أن هذا التكامل يوفر أساسًا مفاهيميًا واعدًا للانتقال من الإدارة القائمة على حالة النظام إلى إدارة سحابية واعية بالسياق، مع ضرورة التحقق التجريبي من فاعلية الإطار وقابليته للتوسع في البيئات السحابية الواقعية

1. المقدمة

شهدت الحوسبة السحابية خلال العقد الأخير تحولًا من كونها منصة لتوفير البنية التحتية والخدمات الحاسوبية إلى بيئة تشغيل متكاملة تستضيف تطبيقات الذكاء الاصطناعي، وتحليلات البيانات الضخمة، وإنترنت الأشياء، والخدمات الرقمية ذات المتطلبات الزمنية الصارمة. وقد أدى هذا التحول إلى زيادة تعقيد إدارة الموارد السحابية نتيجة التغير المستمر في أحمال العمل، وتباين متطلبات التطبيقات، وضرورة تحقيق التوازن بين الأداء، واستهلاك الطاقة، والتكلفة التشغيلية، وجودة الخدمة. وأصبحت الإدارة الفعالة للموارد عنصرًا حاسمًا في استدامة مراكز البيانات السحابية وتحسين كفاءتها التشغيلية (Zhou et al., 2024).

ورغم التطور الذي شهدته تقنيات جدولة المهام وتخصيص الموارد، فإن معظم الآليات التقليدية ما تزال تعتمد على قواعد ثابتة أو نماذج تنبؤية يصعب عليها التعامل مع الطبيعة الديناميكية للبيئات السحابية الحديثة. فعند حدوث تغيرات مفاجئة في الطلب أو ظهور أحمال عمل غير متوقعة، تتراجع قدرة هذه الأساليب على اتخاذ قرارات مناسبة في الزمن الحقيقي، الأمر الذي يؤدي إلى انخفاض معدل استغلال الموارد، وارتفاع زمن الاستجابة، وزيادة استهلاك الطاقة. لذلك اتجهت الأبحاث الحديثة نحو تطوير أساليب ذكية تمتلك القدرة على التعلم المستمر والتكيف مع البيئة التشغيلية بصورة ذاتية (Zhou et al., 2024).

ويُعد التعلم المعزز من أكثر تقنيات الذكاء الاصطناعي ملاءمةً لمعالجة هذا النوع من المشكلات، إذ يعتمد على بناء سياسات اتخاذ قرار تتطور تدريجيًا من خلال التفاعل مع البيئة واستقبال التغذية الراجعة بصورة مستمرة. ويمتاز هذا الأسلوب بقدرته على تحسين قرارات تخصيص الموارد وجدولة المهام في البيئات الديناميكية دون الحاجة إلى نماذج رياضية دقيقة لوصف جميع حالات النظام، وهو ما جعله محورًا لعدد متزايد من الدراسات المتعلقة بإدارة الموارد السحابية خلال السنوات الأخيرة (Zhou et al., 2024).

وفي المقابل، أحدثت نماذج اللغة الكبيرة تحولًا نوعيًا في تطبيقات الذكاء الاصطناعي بعد أن تجاوزت دورها التقليدي في معالجة اللغة الطبيعية لتصبح قادرة على الاستدلال، وفهم السياق، وتوليد الخطط، وتحليل البيانات غير المهيكلة. وقد أظهرت هذه القدرات إمكانية توظيفها في دعم عمليات اتخاذ القرار داخل الأنظمة المعقدة، بما في ذلك البيئات السحابية التي تتطلب تفسيرًا مستمرًا للأحداث التشغيلية وتفاعلًا مع بيانات متعددة المصادر (Cao et al., 2024).

ويُعد دمج نماذج اللغة الكبيرة مع التعلم المعزز من الاتجاهات البحثية الناشئة التي تهدف إلى الاستفادة من نقاط القوة في كل منهما؛ إذ توفر نماذج اللغة الكبيرة إمكانات الفهم والاستدلال وتوليد المعرفة، بينما يوفر التعلم المعزز آلية لتطوير سياسات اتخاذ القرار اعتمادًا على الخبرة المتراكمة والتفاعل مع البيئة. وقد بينت الدراسات الحديثة أن نماذج اللغة الكبيرة يمكن أن تؤدي أدوارًا متعددة داخل أنظمة التعلم المعزز، مثل معالجة المعلومات، وتصميم دوال المكافأة، والمشاركة في صنع القرار، وتوليد الخبرات، مما يفتح آفاقًا جديدة لتطوير أنظمة إدارة ذاتية أكثر كفاءة ومرونة (Cao et al., 2024).

وفي بيئات الحوسبة السحابية، لا تقتصر عملية الإدارة على تخصيص الموارد فحسب، بل تشمل أيضًا التنبؤ بالطلب، وإعادة توزيع الموارد، ومراقبة جودة الخدمة، والاستجابة للتغيرات المفاجئة في الأحمال التشغيلية. ولذلك فإن تطوير آليات قادرة على فهم حالة النظام وتحليلها ثم تعديل قراراتها بصورة تكيفية يمثل خطوة أساسية نحو بناء منصات سحابية ذاتية الإدارة. ومن هذا المنطلق، يمكن أن يسهم التكامل بين نماذج اللغة الكبيرة والتعلم المعزز في تعزيز قدرة الأنظمة السحابية على اتخاذ قرارات أكثر دقة ومرونة مقارنة بالأساليب التقليدية(Zhou et al 2024؛ Cao et al.,2024).

وعلى الرغم من التقدم الملحوظ في هذا المجال، فإن الأدبيات الحالية ما تزال تتناول في الغالب إدارة الموارد السحابية باستخدام التعلم المعزز بصورة مستقلة، أو تركز على تطوير نماذج اللغة الكبيرة وتطبيقاتها العامة دون ربطها بصورة مباشرة بإدارة الموارد السحابية. ويؤدي هذا التباين إلى غياب تصور متكامل يوضح كيفية الاستفادة من الإمكانات المعرفية لنماذج اللغة الكبيرة في تحسين سياسات التعلم المعزز الخاصة بإدارة الموارد، وهو ما يمثل فجوة بحثية تستحق مزيدًا من الدراسة والتحليل .

وانطلاقًا من هذه الفجوة، تهدف هذه الدراسة إلى إجراء مراجعة تحليلية للأدبيات الحديثة المتعلقة بالإدارة التكيفية لموارد الحوسبة السحابية باستخدام نماذج اللغة الكبيرة والتعلم المعزز، مع تحليل الاتجاهات البحثية السائدة، وتحديد أوجه القوة والقصور في النماذج المقترحة، واستعراض أبرز التحديات التقنية التي تواجه هذا المجال.

كما تسعى الدراسة إلى تطوير إطار مفاهيمي يوضح العلاقة بين مكونات الإدارة التكيفية، وخوارزميات التعلم المعزز، والإمكانات التي توفرها نماذج اللغة الكبيرة في دعم عمليات اتخاذ القرار داخل البيئات السحابية. ويُتوقع أن يسهم هذا الإطار في توجيه الدراسات المستقبلية نحو تصميم حلول أكثر قدرة على تحقيق الكفاءة التشغيلية، وتحسين استغلال الموارد، ورفع جودة الخدمة، وتقليل استهلاك الطاقة.

وتتمثل الإضافة العلمية لهذه الدراسة في تقديم رؤية تكاملية تجمع بين أحدث ما توصلت إليه أبحاث الحوسبة السحابية والتعلم المعزز ونماذج اللغة الكبيرة ضمن إطار مفاهيمي واحد، بما يسهم في إثراء المعرفة العلمية في مجال الإدارة الذكية للموارد السحابية، ويمهد الطريق أمام تطوير منصات حوسبة سحابية ذاتية التكيف قادرة على الاستجابة بفاعلية للتغيرات التشغيلية المتسارعة، وهو ما يتوافق مع الاتجاهات الحديثة في الذكاء الاصطناعي والأنظمة السحابية الذكية (Cao et al.,2024؛Zhou et al 2024).

2 . مشكلة الدراسة

على الرغم من التقدم الملحوظ في توظيف التعلم المعزز لإدارة الموارد السحابية، والتوسع في استخدام نماذج اللغة الكبيرة لفهم السياق والنوايا والبيانات التشغيلية غير المنظمة، فإن التكامل بينهما لا يزال محدودًا من الناحية المنهجية. فالتعلم المعزز يعتمد غالبا على حالات ومكافآت كمية محددة مسبقا، بينما تفتقر تطبيقات نماذج اللغة الكبيرة إلى آليات موثوقة للتعلم من نتائج القرارات المتتابعة. وعليه، تتمثل مشكلة الدراسة في غياب إطار مفاهيمي متكامل يجمع بين قدرات نماذج اللغة الكبيرة في فهم السياق وصياغة الأهداف والقيود، وقدرات التعلم المعزز في التعلم التكيفي واتخاذ القرارات والتحقق من نتائجها، مع مراعاة متطلبات الموثوقية وقابلية التفسير والسلامة وقابلية التوسع في البيئات السحابية.

ويمكن صياغة المشكلة في التساؤل الرئيس التالي:

كيف يمكن بناء إطار مفاهيمي يفسر آليات توظيف نماذج اللغة الكبيرة والتعلم المعزز لتحقيق إدارة تكيفية فعالة لموارد الحوسبة السحابية؟

ويتفرع منه التساؤلات الفرعية التالية:

6 . الدراسات السابقة.

شهدت السنوات الأخيرة تحولًا ملحوظًا في إدارة موارد الحوسبة السحابية، إذ انتقلت البحوث من الاعتماد على الخوارزميات الحدسية والميتاهيوريستية الثابتة إلى نماذج تعلم قادرة على التكيف مع تغير أحمال العمل، وتفاوت الموارد، وتعدد متطلبات جودة الخدمة.

في مجال الجدولة المتكيفة، ركزت دراسة وانغ وآخرين (Wang et al., 2023) على جدولة تطبيقات إنترنت الأشياء في بيئات الحافة والضباب والسحابة، واقترحت خوارزمية DRLIS القائمة على التعلم المعزز العميق لموازنة أحمال الخوادم وتقليل زمن الاستجابة. وكشفت النتائج التجريبية عن تحسن واضح مقارنة بالخوارزميات الميتاهيوريستية وأساليب التعلم المعزز التقليدية، كما اختُبرت الخوارزمية داخل إطار FogBus2 ، وهو ما عزز الجانب التطبيقي للدراسة. غير أن النموذج ركز بصورة أساسية على تكلفة التنفيذ وزمن الاستجابة، ولم يتناول الاستدلال الدلالي بشأن اتفاقيات مستوى الخدمة أو سياسات الإدارة المكتوبة باللغة الطبيعية.

ومن منظور أوسع، هدفت دراسة زو وآخرين (Zhou et al., 2023a) إلى تقليل زمن الإنجاز الكلي للمهام في موارد سحابية متجانسة وغير متجانسة، من خلال تصميم طرق متعددة لمسارات البحث تستطيع استكشاف بدائل الجدولة بكفاءة. وبينت الدراسة أهمية تنويع مسارات البحث في تجنب الحلول المحلية وتحسين توزيع المهام، لكنها ظلت معتمدة على تصميم خوارزمي محدد سلفًا، بما يقلل قدرتها على تعديل أهداف الجدولة تلقائيًا عند تغير أولويات التكلفة أو الطاقة أو زمن الاستجابة.

كما قدمت دراسة زو وآخرين (Zhou et al., 2023b) خوارزمية جينية قابلة للنمو، دُمجت ببحث محلي حدسي لمعالجة جدولة الموارد متعددة الأبعاد في الحوسبة السحابية. وكشفت الدراسة أن الجمع بين البحث التطوري والاستغلال المحلي يؤدي إلى حلول أفضل في مسائل تخصيص وحدة المعالجة والذاكرة وعرض النطاق، إلا أن تكلفتها الحسابية تزداد مع اتساع فضاء الحل، كما لا تستفيد من المعرفة التاريخية أو الوصف الدلالي للحمل والسياق التشغيلي.

وفي دراسة مراجعية متخصصة، حلل زو وآخرون (Zhou et al., 2024) تطبيقات التعلم المعزز العميق في جدولة موارد الحوسبة السحابية، وصنفوا النماذج وفق بنية الشبكة العصبية، وحالة الوكيل، وفضاء الأفعال، ودالة المكافأة، وأهداف الجدولة. وبينت المراجعة أن التعلم المعزز العميق يتميز بالمرونة في التعامل مع الحالات عالية الأبعاد والأهداف الضمنية، لكنه يواجه مشكلات عدم قابلية التفسير، والتقارب المحلي، وعدم استقرار النتائج، وارتفاع كلفة التدريب، وضعف النقل بين البيئات. واقترحت الدراسة استخدام التعلم المعزز بوصفه محددًا للخوارزمية المناسبة بدلًا من اعتماده بوصفه مجدولًا منفردًا، إلا أنها لم تبحث الدور الذي يمكن أن تؤديه نماذج اللغة الكبيرة في تفسير السياسات أو تكوين حالات الوكيل ومكافآته من السياسات التشغيلية النصية.

وركزت دراسة بانوار وآخرين (Panwar et al., 2024) على التزويد الاستباقي للموارد في البيئات السحابية غير المتجانسة، باستخدام التعلم المعزز للتنبؤ بالحاجة إلى الموارد واتخاذ قرارات التوسع قبل

1. ما واقع الاتجاهات البحثية المتعلقة بالإدارة التكيفية لموارد الحوسبة السحابية باستخدام نماذج اللغة الكبيرة والتعلم المعزز؟
2. ما أبرز النماذج والأساليب والأدوار الوظيفية التي قدمتها الأدبيات لتوظيف التعلم المعزز ونماذج اللغة الكبيرة في إدارة الموارد السحابية، وما إمكانات التكامل بينها؟

3.أهمية الدراسة

تنبع أهمية الدراسة من تناولها التكامل بين نماذج اللغة الكبيرة والتعلم المعزز بوصفه توجها ناشئا نحو إدارة أكثر تكيفًا لموارد الحوسبة السحابية. وتسهم في تنظيم المعرفة المتفرقة في الأدبيات، وتوضيح أدوار التقنيتين وإمكانات تكاملهما، والكشف عن الفجوات والتحديات المرتبطة بالموثوقية وقابلية التفسير والسلامة وقابلية التوسع. كما تقدم أساسًا مفاهيميًا يمكن الاستناد إليه في توجيه البحوث المستقبلية وتطوير حلول أكثر كفاءة ومرونة لإدارة الموارد السحابية.

4.أهداف الدراسة

تهدف الدراسة إلى بناء إطار مفاهيمي يوضح آليات التكامل بين نماذج اللغة الكبيرة والتعلم المعزز في الإدارة التكيفية لموارد الحوسبة السحابية. ويتحقق ذلك من خلال تحليل الاتجاهات البحثية ذات الصلة، وتحديد النماذج والأساليب والأدوار الوظيفية وإمكانات التكامل بينها، والكشف عن الفجوات والتحديات القائمة، بما يدعم صياغة إطار مفاهيمي منظم لهذا التكامل.

5. حدود الدراسة

الحدود الموضوعية :تقتصر الدراسة على بحث التكامل بين نماذج اللغة الكبيرة والتعلم المعزز في الإدارة التكيفية لموارد الحوسبة السحابية، من حيث الاتجاهات البحثية والنماذج والأساليب والأدوار الوظيفية وإمكانات التكامل، إلى جانب الفجوات والتحديات المرتبطة به، وصولًا إلى بناء إطار مفاهيمي متكامل.

1. الحدود الزمنية :تغطي الدراسة الأدبيات العلمية المنشورة خلال الفترة [2023–2026]، بما يتيح تتبع تطور البحوث ذات الصلة، مع التركيز على الدراسات الحديثة المرتبطة بنماذج اللغة الكبيرة والتعلم المعزز في إدارة الموارد السحابية.

2. الحدود المصدرية :تقتصر الدراسة على الأدبيات العلمية الموثوقة والمفهرسة في قواعد البيانات المعتمدة، بما في ذلك Scopus وWeb of Science وIEEE Xplore وACM Digital Library، وفق استراتيجية البحث ومعايير الاشتمال والاستبعاد المحددة.

3. الحدود المنهجية : تقتصر الدراسة على تحليل الأدبيات العلمية ذات الصلة وتصنيفها وتركيب نتائجها؛ للكشف عن الاتجاهات والفجوات البحثية، وبناء إطار مفاهيمي للتكامل بين نماذج اللغة الكبيرة والتعلم المعزز في الإدارة التكيفية لموارد الحوسبة السحابية، دون تطوير أو اختبار نظام سحابي تجريبي

أما دراسة هانغ وآخرين (Hang et al., 2024) فقد قدمت مراجعة لتكامل نماذج اللغة الكبيرة مع شبكات الجيل التالي، وناقشت أدوارها في التخطيط، والتحسين، وإدارة الشبكات، وتفسير النوايا التشغيلية. وكشفت الدراسة عن إمكانية دمج نماذج اللغة الكبيرة مع التعلم المعزز والذكاء الطرفي في أطر موازنة الحمل وإدارة الموارد، لكنها أوضحت ضمنيًا أن الأدلة التجريبية ما تزال محدودة، وأن معظم التصورات المطروحة تقع في مستوى البنى المفاهيمية أكثر من الأنظمة السحابية المقيمة على بنى إنتاجية واسعة.

كما هدفت دراسة هو وآخرين (Hou et al., 2024) إلى تحسين جدولة المهام وتخصيص الموارد في الحوسبة السحابية باستخدام التعلم المعزز العميق، من خلال تطوير خوارزمية DQN محسّنة تجمع بين Double DQN و Dueling Network وإعادة تشغيل الخبرات ذات الأولوية. وأظهرت النتائج تحسنًا في سرعة التقارب وتقليل استهلاك الطاقة ومتوسط زمن استجابة المهام وزمن تشغيل الآلات. ومع ذلك، اعتمد النموذج على حالات النظام والمكافآت العددية في تعلم سياسة الجدولة، دون توفير آلية دلالية أو لغوية صريحة لتفسير قرارات التخصيص أو دمج المعرفة النصية ضمن عملية اتخاذ القرار.

وفي سياق نشر الخدمات المصغرة، هدفت دراسة فنغ وآخرين (Feng et al., 2024) إلى تحسين نشر الخدمات في بيئات الحوسبة الطرفية، مع الاستفادة من قدرة نماذج اللغة الكبيرة على توليد تعليمات أو مكونات برمجية من أوصاف طبيعية. وبينت الدراسة أن النماذج اللغوية قد تدعم تحويل المتطلبات إلى قرارات نشر، إلا أن استخدامها بقي بعيدًا عن حلقة التحكم المغلقة التي تراقب آثار القرار وتعدل السياسة بالتعلم المعزز.

ركزت دراسة Chen et al. (2025) جدولة الوظائف وتخصيص الموارد في بيئات الحوسبة الطرفية عديمة الخوادم، واقترحت إطار Dike القائم على التعلم المعزز العميق لربط قرارات تخصيص الموارد بمتطلبات SLOs والتكلفة. وأظهرت النتائج قدرة النهج على تحسين كفاءة الجدولة والاقتراب من الحل الأمثل في بيئات موزعة وغير متجانسة. ومع ذلك، يعتمد النموذج أساسًا على المؤشرات الكمية لحالة النظام، دون دمج صريح للمعرفة النصية أو السياقية في عملية اتخاذ القرار.

كما اقترح أناند وآخرون (Anand et al., 2025) إطار EADRL للجدولة التكيفية في بيئات الحافة–السحابة، وتضمن معدل تعلم متكيفًا وآلية ديناميكية لتعديل المكافأة وفق الثقة. وبينت الدراسة أن تعديل المكافأة أثناء التعلم يساعد في التعامل مع تقلب الحمل وحالة الموارد، إلا أن تصميم المكافأة ظل قائمًا على مؤشرات رقمية حددها الباحثون، ولم يُشتق آليًا من نوايا المشغلين أو اتفاقيات الخدمة.

هدفت دراسة دانينو وآخرين (Danino et al., 2023) إلى تحسين تخصيص الحاويات والموارد في البيئات السحابية باستخدام التعلم المعزز العميق متعدد الوكلاء(MADRL) ، من خلال توزيع قرارات التخصيص بين عدة وكلاء وتنسيق أهدافهم عبر آلية مشتركة للحالة والمكافأة. وأظهرت النتائج تحسنًا في زمن التنفيذ مقارنة بالأساليب التقليدية. ومع ذلك، اقتصر التنسيق على المعلومات حدوث الاختناق. وأوضحت النتائج أن الإدارة الاستباقية تقلل التأخير الناتج عن انتظار إنشاء الموارد الجديدة مقارنة بالتوسع التفاعلي، إلا أن جودة القرار بقيت مرتبطة بمدى تمثيل بيانات التدريب لتحولات الحمل الفعلية، بما يثير إشكالية الانجراف المفاهيمي عند ظهور أنماط استخدام غير مسبوقة.

وهدفت دراسة دينغ وآخرين (Ding et al., 2024) إلى تطوير طريقة ديناميكية لاختيار فاصل التوسع الآلي، بحيث لا يكون توقيت قرار التوسع ثابتًا، وإنما يتغير تبعًا لسلوك الحمل وحالة العنقود. وبينت الدراسة أن تكييف الفاصل الزمني يحد من التوسع المتكرر ومن التأخر في الاستجابة للطلب، لكنه لا يعالج بصورة كافية التعارض بين تكلفة الموارد، واستهلاك الطاقة، واستقرار الخدمة، ولا يفسر أسباب تغيير الفاصل للمشغل البشري.

وفي الاتجاه نفسه، اقترح ليو وآخرون (Liu et al., 2024) طريقة للتوسع الآلي قائمة على اكتشاف اتجاه الحمل، بدل الاعتماد على تجاوز عتبة آنية منفردة. وكشفت الدراسة أن التقاط اتجاه الزيادة أو الانخفاض يساعد في تجنب القرارات المتذبذبة ويحسن سرعة الاستجابة. ومع ذلك، فإن الاعتماد على الاتجاهات العددية وحدها لا يستفيد من مصادر سياقية أخرى، مثل سجلات الأعطال، وأحداث النشر، وتغير سياسات الأعمال، وهي بيانات يمكن لنماذج اللغة الكبيرة دمجها وتفسيرها.

كما ركزت دراسة فرنانديز وآخرين (Fernandez et al., 2024) على التوسع التدريجي باستخدام الحقول العشوائية الشرطية، بهدف التنبؤ بحالة الموارد اللاحقة وتحديد مقدار الزيادة الملائم. وأظهرت الدراسة أن التوسع المتدرج قد يقلل الإفراط في توفير الموارد، إلا أن النموذج يتطلب هندسة خصائص مناسبة وبيانات موسومة أو منظمة نسبيًا، ولا يقدم آلية تعلم قرارات طويلة الأجل تراعي الأثر المتراكم لكل قرار توسع.

ومن زاوية تخصيص الموارد في الشبكات الديناميكية، قدم هو وآخرون (Hu et al., 2024) استراتيجية متعددة الأبعاد لتخصيص موارد الأقمار الصناعية منخفضة المدار باستخدام التعلم المعزز العميق. وأوضحت الدراسة أن التعلم من التفاعل يتيح تعديل تخصيص القنوات والطاقة في بيئة سريعة التغير. وعلى الرغم من اختلاف المجال التطبيقي عن مراكز البيانات التقليدية، فإن الدراسة تدعم صلاحية التعلم المعزز لإدارة الموارد المقيدة والمتقلبة، إلا أن بنيتها المتخصصة تحد من النقل المباشر إلى بيئات السحب العامة ومتعددة المستأجرين.

وفي دراسة مقارنة، حلل فيمينيلّا وآخرون (Femminella et al., 2024) أداء مجموعة من خوارزميات التعلم المعزز في مسائل تخصيص الموارد، وركزوا على اختلاف كفاءة الخوارزميات باختلاف طبيعة فضاء الحالة والفعل. وبينت الدراسة أن اختيار خوارزمية التعلم المعزز ينبغي ألا يكون ثابتًا، بل مرتبطًا بخصائص البيئة وحجم فضاء القرار. وتدعم هذه النتيجة الحاجة إلى طبقة عليا تستطيع فهم المشكلة واختيار الوكيل أو السياسة المناسبة، وهي وظيفة يمكن أن تؤديها نماذج اللغة الكبيرة ضمن إطار هجين.

لكنها لا تكفي وحدها لاتخاذ قرارات تخصيص آمنة من دون آلية تعلم وتحقق.

وهدفت دراسة ني ولين (Ni & Lin, 2025) إلى تطبيق التعلم المعزز التكيفي في التخصيص الديناميكي لموارد الحوسبة السحابية، مع اختبار قدرة السياسة على التكيف مع تغير الطلب والقيود. وأظهرت الدراسة أهمية تحديث السياسة بصورة مستمرة بدل استخدام سياسة ثابتة، غير أن الجمع بين تطبيقات السحابة وسياقات تخصيص أخرى جعل النموذج عامًا نسبيًا، ولم يتناول الموارد السحابية متعددة الأبعاد ضمن معمارية AIOps مدعومة بنموذج لغوي.

وفي البيئات واسعة النطاق، قدم مانهاري وآخرون (Manhary et al., 2025) استراتيجية تعلم آلي قابلة للتوسع لإدارة الموارد، وبينوا أن النماذج المركزية مثل DQN قد تواجه زيادة في زمن القرار وعدم الاستقرار عند تضخم عدد العقد. وكشفت الدراسة أن قابلية التوسع ليست مرتبطة بدقة السياسة فقط، بل بكلفة إنتاج القرار نفسه، وهو أمر شديد الأهمية عند دمج نماذج اللغة الكبيرة التي تضيف زمن استدلال وكلفة حوسبية قد تفوق مكاسب التخصيص إذا لم تستخدم بصورة انتقائية.

وهدفت دراسة زكريا وآخرين (Zakaryia et al., 2025) إلى تطوير إطار للتحسين المشترك لترحيل المهام وتخصيص الموارد في بيئات الحوسبة الطرفية المتنقلة المدعومة بالطائرات المسيّرة، من خلال توظيف التعلم المعزز العميق متعدد الوكلاء (Multi-Agent Deep Reinforcement Learning) لاتخاذ قرارات مترابطة بشأن ترحيل المهام وتخصيص الموارد الحاسوبية والاتصالية. واعتمدت الدراسة خوارزمية MADDPG بالاقتران مع آلية DTLCM لاختيار عقدة التنفيذ استنادًا إلى قدرتها الحاسوبية وقربها المكاني من المهمة، بما يسمح بالتكيف مع التغيرات الديناميكية في بيئة الحوسبة الطرفية. وأظهرت نتائج المحاكاة تفوق النهج المقترح على عدد من الخوارزميات المرجعية من حيث معدل إكمال المهام وتقليل زمن التأخير، بما يدعم فاعلية التعلم متعدد الوكلاء في تحقيق تنسيق أكثر تكاملًا بين قرارات ترحيل المهام وإدارة الموارد.

وفي عام 2026، قدم علام وآخرون (Alam et al., 2026) مراجعة منهجية لتخصيص الموارد المدفوع بالذكاء الاصطناعي في الحوسبة السحابية، وناقشوا دمج التعلم المعزز العميق مع آليات التوسع في Kubernetes، ودور دوال المكافأة متعددة الأهداف والتحديثات المستمرة لشبكات Q. وبينت الدراسة وجود فجوة بين النماذج المختبرة بالمحاكاة وبين الدمج الفعلي مع منصات التنسيق السحابي، كما أكدت أهمية الموازنة بين الاستكشاف والاستغلال والسلامة التشغيلية.

وهدفت دراسة ليو وآخرين (Liu et al., 2026) إلى تطوير إطار تعلم معزز عميق لجدولة المهام كثيفة البيانات عبر مراكز سحابية موزعة جغرافيًا. وبينت الدراسة أن القرار المتكيف يمكنه مراعاة اختلاف تكلفة نقل البيانات وحالة الموارد وزمن التنفيذ، إلا أن اتساع فضاء الحالة وصعوبة التنبؤ بتغير الشبكة يحدان من استقرار السياسة وقابليتها للنقل بين المزودين.

العددية للحالة والمكافأة، دون دمج المعرفة النصية أو قواعد الأولوية والاستثناءات أو توفير تفسير دلالي للقرارات

وقدمت دراسة هادي وآخرين (Hady et al., 2025) مراجعة للتعلم المعزز متعدد الوكلاء في تخصيص الموارد، وكشفت أن هذه النماذج مناسبة للأنظمة الموزعة التي تتخذ فيها مكونات متعددة قرارات متزامنة، لكنها تعاني من لا استقرارية البيئة من منظور كل وكيل، ومن صعوبة تحديد الائتمان، وتكلفة الاتصال والتنسيق. وبينت المراجعة الحاجة إلى نماذج تنظيمية وتفسيرية أعلى من مستوى الوكلاء، لكنها لم تقدم إطارًا متكاملًا يجمع نموذجًا لغويًا كبيرًا مع متعلم متعدد الوكلاء لإدارة السحابة.

وركزت دراسة كونيداريس وآخرين (Konidaris et al., 2025) على تخصيص الموارد القائم على النية في بيئات الحافة والسحابة، بحيث تُترجم نية المستخدم أو المشغل إلى أهداف وقيود قابلة للتنفيذ. وبينت

الدراسة أن الإدارة القائمة على النية أكثر مرونة من السياسات اليدوية، وتوفر نقطة اتصال واضحة بين اللغة البشرية والتحسين الآلي. ومع ذلك، فإن الانتقال من النية إلى قرار تخصيص موثوق يحتاج إلى آلية تحقق وتعلم من العواقب، إذ قد ينتج النموذج اللغوي تفسيرًا غير صحيح أو متعارضًا للنية.

في سياق الأمن وإدارة الموارد، هدفت دراسة صن وآخرين (Sun et al., 2025) إلى تطوير إطار SARMTO للتخصيص الآمن للموارد وترحيل المهام في بيئات الحوسبة الطرفية متعددة السحب ومن دون خوادم، بالاعتماد على التعلم المعزز العميق المقيد (Constrained DRL). ودمج الإطار اعتبارات الأمن والأداء ضمن عملية اتخاذ القرار، بما يسمح بتجنب قرارات التخصيص غير الملائمة وتحقيق توازن ديناميكي بين الموارد والأمن وكفاءة التنفيذ. ومع ذلك، يعتمد النموذج على تمثيل القيود الأمنية داخل إطار التحسين والتعلم، دون آلية لغوية صريحة لفهم السياسات الأمنية المكتوبة باللغة الطبيعية وتحويلها ديناميكيًا إلى قيود تنفيذية. (Sun et al., 2025).

وفي نموذج أكثر تكاملًا، اقترح شو وآخرون (Xu et al., 2025) بنية تجمع التعلم المعزز مع نموذج لغة كبير من أجل التحسين الذاتي للشبكات. وركزت الدراسة على استخدام النموذج اللغوي في فهم الحالة وتكوين المعرفة والتفاعل مع وحدة التعلم المعزز، بينما يتولى المتعلم تحسين السياسات عبر التغذية الراجعة. وكشفت الدراسة عن القيمة النظرية لتوزيع الوظائف بين الاستدلال اللغوي واتخاذ القرار المتتابع، إلا أن التقييم اقتصر على سياق شبكي محدد، ولم يقدم معالجة كاملة لقضايا هلوسة النموذج، وزمن الاستدلال، وكلفة تشغيل النموذج اللغوي داخل حلقة إدارة الموارد.

أما دراسة دي لا كروز كابيلو وآخرين (De la Cruz Cabello et al., 2025) فقد راجعت استخدام نماذج اللغة الكبيرة في اكتشاف شذوذ السجلات ضمن AIOps. وبينت المراجعة أن النماذج اللغوية قادرة على تحليل السجلات غير المنظمة، وتلخيص الحوادث، وربط الرسائل المتباعدة دلاليًا، لكنها أشارت إلى تحديات جودة البيانات، وطول السياق، والخصوصية، وصعوبة التقييم الموحد. وتوضح هذه النتائج أن نماذج اللغة الكبيرة قد تحسن تمثيل حالة البيئة السحابية،

الأول على تحسين خوارزمية اتخاذ القرار من خلال DQN و DDQN و Actor–Critic والتعلم متعدد الوكلاء والشبكات المتكررة والبيانية. وركز المسار الثاني على دمج التعلم المعزز بخوارزميات تحسين أخرى، مثل الخوارزميات الجينية وسرب الجسيمات وسرب السالب، بهدف تحسين البحث وتقليل الوقوع في الحلول المحلية. أما المسار الثالث الناشئ فقد ركز على استخدام نماذج اللغة الكبيرة في AIOps والإدارة القائمة على النية وتحليل السجلات.

وعلى الرغم من النتائج الإيجابية، فإن غالبية الدراسات قيمت نماذجها في محاكيات أو بيئات محدودة الحجم، واعتمدت على أحمال عمل معروفة مسبقًا، ودوال مكافأة ثابتة صممها الباحث، ومجموعة محدودة من مؤشرات وحد

المعالجة والذاكرة وزمن الاستجابة. كما أن المقارنة بين الدراسات تظل صعبة بسبب اختلاف المحاكيات، ومجموعات البيانات، وأحجام العناقيد، وتعريفات المكافأة، والخوارزميات المرجعية. ولم تقدم معظم الدراسات اختبارات كافية للانجراف المفاهيمي، أو الانتقال بين مزودي السحابة، أو الأعطال المفاجئة، أو تضارب الأهداف، أو القرارات غير الآمنة أثناء مرحلة الاستكشاف.

وتظهر كذلك فجوة في قابلية التفسير؛ فحتى عندما تتفوق سياسة التعلم المعزز في الأداء، لا يكون واضحًا للمشغل لماذا اختارت زيادة عدد الحاويات أو نقل مهمة أو إيقاف آلة افتراضية. وفي المقابل، تستطيع

نماذج اللغة الكبيرة تفسير السجلات والسياسات والنوايا، لكنها قد تنتج استدلالات غير دقيقة أو هلوسات، ولا تضمن وحدها تحقيق مكافأة طويلة الأجل. ولذلك فإن استخدام LLM بوصفه متخذ القرار الوحيد قد يكون غير آمن، كما أن استخدام RL من دون طبقة دلالية يجعله محدودًا في فهم السياق التشغيلي المعقد.

2.6 الفجوة البحثية

تكشف الأدبيات عن تقدم واضح في توظيف التعلم المعزز لإدارة الموارد السحابية، مقابل اهتمام متزايد بنماذج اللغة الكبيرة لفهم السياق والنوايا والبيانات التشغيلية غير المنظمة. ومع ذلك، ما يزال التكامل المنهجي بين المسارين محدودا؛ إذ تعتمد معظم نماذج التعلم المعزز على حالات ومكافآت كمية محددة مسبقًا، في حين تفتقر تطبيقات نماذج اللغة الكبيرة إلى آليات موثوقة للتعلم من نتائج القرارات المتتابعة. ومن ثم، تتمثل الفجوة البحثية في غياب إطار مفاهيمي متكامل يربط فهم السياق وصياغة الأهداف والقيود بالتعلم التكيفي والتحقق من القرارات، مع مراعاة الموثوقية وقابلية التفسير والسلامة وقابلية التوسع في البيئات السحابية.

3.6 الإسهام العلمي المقترح للدراسة

تسهم الدراسة المقترحة في بناء إطار مفاهيمي للإدارة التكيفية لموارد الحوسبة السحابية يجمع بين القدرة الاستدلالية لنماذج اللغة الكبيرة والقدرة التحسينية طويلة الأجل للتعلم المعزز .ويتكون الإطار من طبقة رصد تجمع المقاييس والسجلات والأحداث؛ وطبقة نموذج لغوي تستخلص النية والسياق والقيود وتنتج تفسيرًا منظمًا؛ وطبقة

كما اقترحت دراسة شي وآخرين (Xie et al., 2026) بنية هرمية لتنسيق سلاسل الخدمات في بيئة متعددة السحب، تجمع شبكات Actor–Critic مع الشبكات البيانية وآلية الانتباه. وكشفت الدراسة أن تفكيك الهدف الكلي إلى أهداف آنية واقتصادية واستقرارية يساعد في إدارة التعقيد، لكنها لم توظف نموذجًا لغويًا لفهم النوايا أو تفسير العلاقات السببية بين مؤشرات التشغيل وقرارات التنسيق.

وقدم ناز وآخرون (Naaz et al., 2026) نموذجًا خفيفًا يجمع LSTM مع مبادئ DQN لجدولة المهام السحابية بصورة تكيفية. وركزت الدراسة على تقليل زمن التنفيذ وتحسين استغلال الآلات الافتراضية بكلفة حسابية أقل من النماذج العميقة الكبيرة، وهو اتجاه مهم لأن وحدة التحكم ينبغي ألا تستهلك جزءًا كبيرًا من الموارد التي تسعى إلى تحسينها. ومع ذلك، لم يتعامل النموذج مع تعدد الأهداف أو التفسير أو السياسات النصية.

وفي مجال الموازنة متعددة الأهداف، هدفت دراسة راجامال وتشينادوراي (Rajammal & Chinnadurai, 2026) إلى دمج التعلم المعزز العميق مع خوارزمية تحسين هجينة من أجل موازنة الحمل وتقليل استهلاك الطاقة وزمن الاستجابة. وأظهرت الدراسة أن النماذج الهجينة تتفوق غالبًا على الخوارزمية المنفردة، إلا أنها تزيد عدد

المعلمات والمكونات، بما يصعّب عزل مصدر التحسن وإعادة إنتاج النتائج.

كما اقترح الجميلي وآخرون (Al-Jumaili et al., 2026) نموذجًا يدمج التعلم العميق بشبكات Q مع تحسين سرب الجسيمات لإدارة موارد السحابة. وبينت الدراسة أن DQN توفر التعلم من التفاعل، بينما يساعد PSO في البحث عن توزيع أفضل للموارد، إلا أن هذا الدمج لا يعالج بصورة مباشرة مشكلة تفسير أهداف الإدارة أو دمج البيانات غير المنظمة المتاحة في السجلات والتذاكر والوثائق التشغيلية.

وفي جانب الموثوقية، قدم هو وآخرون (Hou et al., 2026) نموذجًا قائمًا على DDQN لتحسين سلامة البيانات السحابية وتخصيص موارد التحقق بصورة تكيفية. وكشفت الدراسة أن التعلم المعزز يستطيع تعديل سياسات التدقيق تبعًا لمؤشرات المخاطر والموارد، إلا أن تركيزها انصب على سلامة البيانات أكثر من إدارة الموارد العامة، كما ظلت قواعد تفسير الحوادث ودرجة خطورتها محددة عدديًا وليست مستخرجة من معرفة تشغيلية متعددة المصادر.

وأخيرًا، هدفت دراسة بارهيزكار وآخرين (Parhizkar et al., 2026) إلى مراجعة حلول الإدارة الذكية للموارد في الأنظمة السحابية واسعة النطاق. وبينت الدراسة أن الاتجاه السائد يجمع بين التنبؤ بالأحمال، والتعلم العميق، والتعلم المعزز، والتنسيق الآلي، لكنها كشفت استمرار التحديات المتعلقة بقابلية التفسير، والبيانات القياسية، والمقارنة العادلة، والنشر الإنتاجي، وعدم وجود نموذج موحد يربط مراقبة البيئة وفهم الأحداث وصياغة الأهداف واتخاذ القرار والتحقق من أثره.

1.6 التعليق النقدي على الدراسات السابقة

يتبين من تحليل الدراسات السابقة أن الأدبيات الحديثة سارت في ثلاثة مسارات متوازية لكنها لم تندمج بصورة ناضجة. ركز المسار

4.7استخراج البيانات والتحليل

استخرجت بيانات الدراسات المختارة باستخدام مصفوفة تحليل موحدة شملت مجال التطبيق، وتقنيات إدارة الموارد، ودور RL وLLM، وأهداف التحسين، وأبرز النتائج والقيود، ومستوى توظيف السياق في اتخاذ القرار .ثم أجري تحليل وصفي ومقارن لتحديد الأنماط المتكررة وتجميعها في خمسة محاور :الإدارة التكيفية بالتعلم المعزز، والوعي بالسياق التشغيلي، والدور الدلالي لنماذج اللغة الكبيرة، والتكامل بين LLM وRL، والموثوقية وقابلية النشر.

5.7اشتقاق الفجوات والإطار المفاهيمي

اشتقت الفجوات البحثية من أوجه القصور المتكررة في الأدبيات، وتمثلت أساسًا في محدودية الفهم الدلالي للسياق، وصياغة القرار، والتكامل بين LLM وRL، والثقة والسلامة، وقابلية التوسع والنشر . وانطلاقًا من هذه الفجوات، صيغت مكونات الإطار المفاهيمي لتشمل جمع السياق، والاستدلال الدلالي، وصياغة القرار، والتعلم المعزز، والتحقق، والتنفيذ والتغذية الراجعة؛ وبذلك استند بناء الإطار مباشرة إلى نتائج التحليل، وليس إلى افتراضات مسبقة.

6.7 الاتساق وقابلية التتبع

ربطت أسئلة الدراسة بمحاور التحليل والفجوات المستخلصة ومكونات الإطار المقترح، بما يضمن وضوح المسار المنهجي وقابلية تتبع الاستنتاجات على النحو الآتي:

Research Questions → Study Selection → Data Extraction → Thematic Synthesis → Research Gaps → Conceptual Framework

8. النتائج

أظهر تحليل الدراسات السابقة أن التعلم المعزز أصبح من أبرز الأساليب المستخدمة في الإدارة التكيفية لموارد الحوسبة السحابية، لما يوفره من قدرة على تحسين الجدولة، والتخصيص، والتوسع، وموازنة الأحمال في البيئات الديناميكية. ومع ذلك، تعتمد معظم النماذج الحالية على تمثيلات عددية محددة مسبقًا لحالة النظام ودوال المكافأة، وهو ما يحد من قدرتها على استيعاب السياق التشغيلي الأوسع، بما في ذلك السياسات، والسجلات، والأولويات، والنوايا التشغيلية.

كما بينت المراجعة أن نماذج اللغة الكبيرة تقدم إمكانات واعدة في فهم البيانات غير المنظمة، وتحليل السجلات، وتفسير السياسات والنوايا، وربط الأحداث التشغيلية دلاليًا. إلا أن استخدامها بصورة مستقلة في إدارة الموارد يظل محدودًا بسبب تحديات الموثوقية، والهلوسة، وزمن الاستدلال، والكلفة الحاسوبية، وعدم قدرتها بمفردها على تعلم الأثر المتتابع للقرارات.

وتشير النتائج إلى وجود تكامل وظيفي محتمل بين نماذج اللغة الكبيرة والتعلم المعزز؛ إذ يمكن توظيف النموذج اللغوي لفهم السياق وصياغة الأهداف والقيود، بينما يتولى التعلم المعزز تعلم قرارات التخصيص والجدولة والتوسع استنادًا إلى التغذية الراجعة من البيئة. ومع ذلك، ما يزال هذا التكامل في مرحلة ناشئة، ولا توجد بعد آلية موحدة تحدد بصورة واضحة تدفق المعلومات، وتوزيع الأدوار، وآليات التحقق بين المكونين.

كما أظهرت الدراسات أن قابلية التفسير، والسلامة، وقابلية التوسع، وكلفة إنتاج القرار، والفجوة بين المحاكاة والنشر الفعلي تمثل تعلم معزز تختار قرارات التخصيص والتوسع والترحيل؛ وطبقة أمان تتحقق من توافق الأفعال مع الحدود التشغيلية واتفاقيات الخدمة؛ وذاكرة تشغيلية تسترجع الحوادث والحلول السابقة؛ وآلية تغذية راجعة تعيد تقييم القرار وفق أثره الفعلي.

ويختلف هذا الإسهام عن الدراسات السابقة في أنه لا يستخدم نموذج اللغة الكبير بديلًا للتعلم المعزز، ولا يستخدم التعلم المعزز بمعزل عن المعرفة التشغيلية؛ بل يقترح توزيعًا وظيفيًا تكون فيه مهمة LLMهي فهم اللغة والسياق وتكوين المعرفة والتفسير، في حين يتولى RL تحسين القرار المتتابع وفق المكافآت المرصودة، وتتولى طبقة الحوكمة منع الأفعال غير الآمنة. كما يقترح الإطار دالة مكافأة متعددة الأهداف تشمل تكلفة الموارد، واستهلاك الطاقة، وزمن الاستجابة، ومخالفاتSLO ، واستقرار قرارات التوسع، وكلفة استدعاء النموذج اللغوي نفسه.

7.منهجية الدراسة

1.7تصميم المراجعة

اعتمدت الدراسة مراجعة تحليلية نقدية منظمة للأدبيات، مدعومة بالتركيب الموضوعي(Thematic Synthesis) ، بهدف تحليل الاتجاهات البحثية في الإدارة التكيفية لموارد الحوسبة السحابية، وتحديد الأدوار التي يؤديها كل من التعلم المعزز ونماذج اللغة الكبيرة، والكشف عن الفجوات التي تحد من تكاملهما. ولم تقتصر المراجعة على العرض الوصفي للدراسات، بل ركزت على المقارنة بين مناهجها، وآليات اتخاذ القرار، وتمثيل حالة النظام، وصياغة المكافآت والقيود، ومستوى الاستفادة من السياق التشغيلي، وصولًا إلى اشتقاق إطار مفاهيمي من الأنماط المتكررة في الأدبيات

2.7استراتيجية البحث

أجري البحث في قواعد بيانات

Scopusو IEEE Xploreو SpringerLinkو Google Scholar

باستخدام مجموعة من الكلمات المفتاحية المرتبطة بإدارة الموارد السحابية والتعلم المعزز ونماذج اللغة الكبيرة، من أبرزها

Cloud Resource Management, Adaptive Resource Allocation, Reinforcement Learning, Deep Reinforcement Learning, Large Language Models, LLM-Enhanced Reinforcement Learning,و AIOps.
وجمعت مصطلحات البحث باستخدام المعاملات المنطقية

ANDو ORلاسترجاع الدراسات ذات الصلة بإدارة الموارد السحابية والتقنيات المستخدمة فيها وإمكانات التكامل بين LLM وRL

3.7معايير اختيار وفحص الدراسات

اعتمدت المراجعة الدراسات المحكمة وذات الصلة المباشرة بالإدارة التكيفية للموارد السحابية، بما يشمل تخصيص الموارد وجدولتها والتوسع الآلي، والدراسات التي تناولت التعلم المعزز أو نماذج اللغة الكبيرة أو الإدارة الواعية بالسياق. واستُبعدت الدراسات المكررة، والمصادر غير المحكّمة، والأعمال غير المرتبطة مباشرة بموضوع المراجعة أو التي لا توفر معلومات كافية للتحليل. وتم الاختيار على مرحلتين :فحص العناوين والملخصات، ثم مراجعة النصوص الكاملة للتحقق من استيفاء معايير الإدراج. وأسفرت عملية الفحص عن اختيار [32]دراسة لتشكيل العينة النهائية للتحليل .

2.8الإطار المفاهيمي المقترح

استنادًا إلى نتائج المراجعة، تقترح الدراسة إطارا مفاهيميًا للإدارة التكيفية لموارد الحوسبة السحابية يقوم على التكامل الوظيفي بين نماذج اللغة الكبيرة والتعلم المعزز ضمن حلقة إدارة مغلقة وواعية بالسياق .يبدأ الإطار بجمع المؤشرات التشغيلية والبيانات السياقية من البيئة السحابية، ثم توظيف نموذج اللغة الكبير لفهم السجلات والسياسات والنوايا والأحداث غير المنظمة وتحويلها إلى سياق منظم يدعم صياغة حالة القرار وأهدافه وقيوده. بعد ذلك، يتولى التعلم المعزز تعلم قرارات تخصيص الموارد والجدولة والتوسع بصورة تكيفية استنادًا إلى حالة البيئة والتغذية الراجعة الناتجة عن القرارات السابقة.

ويفصل الإطار بين الاستدلال الدلالي واتخاذ القرار والتنفيذ من خلال آلية للتحقق من توافق القرارات مع القيود التشغيلية والأمنية ومتطلبات مستوى الخدمة قبل تنفيذها. وتُعاد نتائج التنفيذ إلى حلقة التعلم لتحسين السياسة، بينما يُعاد إشراك النموذج اللغوي عند ظهور تغيرات سياقية أو سياسات وأحداث جديدة تتطلب إعادة تفسير الأهداف أو القيود. وبذلك لا يعمل نموذج اللغة الكبير بديلًا عن التعلم المعزز، وإنما بوصفه طبقة معرفية داعمة لفهم السياق وصياغة القرار، في حين يمثل التعلم المعزز محرك القرار التكيفي . ويهدف هذا الفصل الوظيفي إلى معالجة الفجوة بين فهم السياق والتعلم من نتائج القرارات، مع مراعاة الموثوقية والسلامة وقابلية التفسير والكلفة التشغيلية.

Monitoring & Context → LLM Semantic Reasoning → Decision Formulation → RL Adaptive Decision → Validation → Execution & Feedback

3.8 منطق عمل الإطار المقترح

يقوم الإطار المقترح على حلقة إدارة تكيفية مغلقة تبدأ بجمع مؤشرات الموارد والبيانات السياقية من البيئة السحابية. وتُستخدم نماذج اللغة الكبيرة لتحليل المعلومات غير المنظمة وفهم السياق والنوايا والسياسات التشغيلية، ثم تُحوَّل مخرجات هذا التحليل إلى حالة وأهداف وقيود منظمة تدعم عملية اتخاذ القرار. بعد ذلك، يتولى التعلم المعزز اختيار سياسة إدارة الموارد المناسبة وتحديثها استنادًا إلى نتائج التفاعل مع البيئة. وقبل التنفيذ، تخضع القرارات لآلية تحقق لضمان توافقها مع متطلبات الأداء والسلامة ومستوى الخدمة. وتُعاد نتائج التنفيذ إلى النظام بوصفها تغذية راجعة لتحسين القرارات اللاحقة، مع إعادة إشراك النموذج اللغوي عند حدوث تغيرات سياقية تستدعي إعادة تفسير الأهداف أو القيود. وبذلك يجمع الإطار بين فهم السياق، والتعلم التكيفي، والتحقق من القرار ضمن دورة إدارة مستمرة.

4.8 المساهمة النظرية للإطار المقترح

تتمثل المساهمة النظرية للإطار المقترح في تقديم تصور تكاملي يحدد الأدوار الوظيفية لنماذج اللغة الكبيرة والتعلم المعزز في الإدارة التكيفية للموارد السحابية؛ إذ توظف نماذج اللغة الكبيرة لفهم السياق والنوايا والسياسات التشغيلية، بينما يتولى التعلم المعزز تعلم القرارات المتتابعة وتحسينها من خلال التفاعل مع البيئة. كما يربط الإطار بين هذين المكونين عبر صياغة منظمة للأهداف والقيود، وآليات للتحقق والتغذية الراجعة. وبذلك يوسع الإطار مفهوم الإدارة تحديات رئيسة أمام الانتقال من النماذج البحثية إلى أنظمة إدارة سحابية قابلة للتطبيق في البيئات الإنتاجية.

وبناء على ذلك، تتمثل النتيجة التركيبية الرئيسة للمراجعة في أن تطوير الإدارة التكيفية لموارد الحوسبة السحابية لا يتطلب تحسين خوارزميات القرار فقط، بل يستلزم إطارا تكامليا يربط بين فهم السياق التشغيلي، وصياغة الأهداف والقيود، واتخاذ القرار التكيفي، والتحقق من سلامته، والتعلم من نتائجه .ويشكل هذا الاستنتاج الأساس المفاهيمي لدمج نماذج اللغة الكبيرة مع التعلم المعزز ضمن حلقة إدارة سحابية مغلقة وواعية بالسياق

جدول (1) : يوضح التركيب المقارن لنتائج المراجعة وفقا للمصفوفة الآتية

المحور	ما توصلت إليه الأدبيات	القيد المتكرر	المستخلصة	دلالته للإطار المقترح
RL والإدارة التكيفية	قدرة على الجدولة والتخصيص والتوسع والتعلم من التفاعل	الاعتماد على حالة ومكافأة كمية	محدودية الفهم الدلالي	RLمحرك القرار التكيفي
السياق التشغيلي	استخدام واسع لمؤشرات الأداء والموارد	ضعف استثمار السجلات والسياسات والنوايا	فجوة الوعي بالسياق	طبقة لجمع وتمثيل السياق
LLMs	طبقة للاستدلال الدلالي	الهلوسة وعدم ضمان القرار	لا يكفي LLM للتحكم منفردًا	طبقة للاستدلال الدلالي
LLM–RL	تكامل وظيفي واعد	محدودية البنى المتكاملة	غياب آلية واضحة لتبادل المعرفة والقرار	طبقة وسيطة لصياغة القرار
الثقة والنشر	الحاجة إلى السلامة والتفسير والكفاءة	الكلفة وزمن القرار وضعف التحقق	فجوة الثقة والنشر	طبقة تحقق + استدعاء انتقائي

1.8 اشتقاق الإطار المفاهيمي من نتائج المراجعة

لا يقترح الإطار المفاهيمي بصورة مستقلة عن النتائج السابقة؛ بل يشتق كل مكون فيه استجابة لفجوة كشفت عنها المراجعة.

جدول (2): اشتقاق الإطار المفاهيمي من نتائج المراجعة

النتيجة/الفجوة	الحاجة المستخلصة	المكون المقترح
محدودية المعلومات العددية	استيعاب البيانات والسياق متعدد المصادر	Monitoring & Context Acquisition
الفجوة الدلالية	تفسير السجلات والسياسات والنوايا	LLM Semantic Reasoning
فجوة صياغة القرار	تحويل المعرفة إلى حالة وأهداف وقيود	Decision Formulation
الحاجة إلى قرار متتابع متكيف	التعلم من التفاعل والنتائج	RL Adaptive Decision Making
مخاطر الهلوسة والقرارات غير الآمنة	فحص القرار قبل التنفيذ	Safety & Validation
الحاجة إلى التعلم المستمر	قياس نتائج التنفيذ وإعادتها للنظام	Execution & Feedback

10. الاستنتاجات

تخلص الدراسة إلى أن الإدارة التكيفية الفعالة للموارد السحابية تتطلب تجاوز الاستجابة للمؤشرات العددية نحو إدارة واعية بالسياق تجمع بين فهم المعرفة التشغيلية والتعلم المستمر من نتائج القرارات. وتبين المراجعة وجود تكامل محتمل بين LLM وRL، إلا أن الأدبيات لا تزال تفتقر إلى تنظيم ناضج للعلاقة بينهما، خصوصًا في صياغة القرار والتحقق من المخرجات والنشر في البيئات الإنتاجية. وبناءً على ذلك، يقدم الإطار المقترح أساسًا مفاهيميا لتنظيم هذا التكامل ضمن حلقة مغلقة تربط السياق بالقرار والتنفيذ والتغذية الراجعة، دون افتراض ثبوت فاعليته قبل التحقق التجريبي.

11. التوصيات

توصي الدراسة بأن تتجه البحوث المستقبلية إلى التحقق التجريبي من الإطار المقترح باستخدام أحمال عمل وبيئات سحابية واقعية، مع مقارنة أدائه بنماذج RL المستقلة من حيث زمن الاستجابة، والكلفة، واستخدام الموارد، والالتزام بـ SLA/SLO كما ينبغي دراسة آليات الاستدعاء الانتقائي لنماذج اللغة الكبيرة، وطرق تحويل النوايا والسياسات إلى أهداف وقيود قابلة للتحقق، مع تطوير آليات للحد من الهلوسة وضمان سلامة القرارات وقابليتها للتفسير. وأخيرا، يوصى بتقييم قابلية تعميم الإطار عبر بيئات متعددة السحب والحافة– السحابة، بما يسهم في تقليص الفجوة بين النماذج المفاهيمية والتطبيقات السحابية الإنتاجية.

12. المراجع

Alam, S., Ramzan, M. A., Zubair, M., Ullah, U., Nawaz, R., & Ullah, R. (2026). AI-driven resource allocation in cloud computing: a systematic review revealing critical sustainability and evaluation gaps. *Computing*, *108*(5), 67. https://doi.org/10.1007/s00607-026-01655-8

Al-Jumaili, A. H. A., Seno, M. E., Awad, W. K., Muniyandi, R. C., & Hasan, M. K. (2026). A fusion deep Q-learning and particle swarm optimization algorithm for adaptive resource allocation in cloud computing circumstances. *Scientific Reports*. https://doi.org/10.1038/s41598-025-33498-2

Anand, J., & Karthikeyan, B. (2025). EADRL: Efficiency-aware adaptive deep reinforcement learning for dynamic task scheduling in edge-cloud environments. *Results in Engineering*, *27*, 105890.

Cao, Y., Zhao, H., Cheng, Y., Shu, T., Chen, Y., Liu, G., ... & Li, Y. (2024). Survey on large language model-enhanced reinforcement learning: Concept, taxonomy, and methods. *IEEE Transactions on Neural Networks and Learning Systems*, *36*(6), 9737-9757.

Chen, C., Carlini, E., & Mortier, R. (2025, July). Dike: Deep Reinforcement Learning For Function Scheduling in SLO-targeted Serverless Edge Computing. In *2025*

التكيفية من الاستجابة لحالة النظام إلى إدارة واعية بالسياق تجمع بين الاستدلال الدلالي والتعلم من نتائج القرارات ضمن حلقة إدارة مغلقة.

5.8 ربط النتائج بتساؤلات الدراسة

جدول (3): ربط النتائج بتساؤلات الدراسة

تساؤل الدراسة	ما كشفت عنه النتائج
ما مكونات الإطار؟	المراقبة، LLM، صياغة القرار، RL، التحقق، التنفيذ والتغذية الراجعة
ما الاتجاهات والأساليب الرئيسة؟	هيمنة RL/DRL/MARL مع بروز LLM والإدارة القائمة على النية
ما أوجه القصور والفجوات؟	الفجوة الدلالية، وصياغة القرار، والتكامل، والثقة والنشر
ما الأدوار التكاملية لـLLM وRL؟	LLMفهم السياق؛ RL للتعلم والقرار المتتابع
ما تحديات التكامل؟	الهلوسة، الموثوقية، التفسير، السلامة، الكلفة، زمن القرار والتوسع

6.8 الخلاصة التركيبية

تشير المراجعة إلى أن الإدارة التكيفية لموارد الحوسبة السحابية تتجاوز كفاءة تخصيص الموارد إلى فهم السياق، وصياغة الأهداف والقيود، والتعلم من نتائج القرارات. ويظهر التحليل تكاملا وظيفيا محتملا بين التعلم المعزز في اتخاذ القرارات التكيفية، ونماذج اللغة الكبيرة في فهم السياق والمعرفة غير المنظمة، شريطة وجود آليات منظمة لصياغة القرار والتحقق والسلامة والتغذية الراجعة. وبناءً على ذلك، يقترح الإطار المفاهيمي توزيعا تكامليا للأدوار بين الاستدلال الدلالي والتعلم التكيفي، بما يوفر أساسا لدراسات مستقبلية تختبر الإطار وعلاقاته في بيئات سحابية فعلية.

9. المناقشة

تشير نتائج المراجعة إلى أن التحدي في الإدارة التكيفية للموارد السحابية لا يقتصر على تحسين قرارات التخصيص والجدولة، بل يمتد إلى فهم السياق التشغيلي الذي تتخذ فيه هذه القرارات .فعلى الرغم من قدرة التعلم المعزز على التكيف مع تغير الأحمال والموارد، فإن اعتماده غالبًا على حالات ومكافآت عددية يحد من استيعابه للسياسات والنوايا والسجلات التشغيلية.

وفي هذا السياق، توفر نماذج اللغة الكبيرة قدرة مكملة على تفسير المعرفة غير المنظمة وفهم السياق، بينما يظل التعلم المعزز أكثر ملاءمة لتعلم القرارات المتتابعة من التفاعل مع البيئة. ومن ثم، تكمن القيمة في التكامل الوظيفي بين التقنيتين؛ بحيث يدعم LLM فهم السياق وصياغة الأهداف والقيود، ويتولى RL اتخاذ القرار التكيفي والتعلم من نتائجه.

ويترجم الإطار المقترح هذا التكامل إلى حلقة مغلقة تربط فهم السياق، وصياغة القرار، والتعلم التكيفي، والتحقق، والتنفيذ والتغذية الراجعة .كما يضع السلامة والموثوقية في صلب عملية الإدارة، بما يحد من انتقال المخرجات غير الموثوقة إلى التنفيذ المباشر. ومع ذلك، يظل الإطار مقترحا مفاهيميا يحتاج إلى التحقق التجريبي في بيئات سحابية واقعية لتقييم فاعليته وقابليته للتوسع.

IEEE Symposium on Computers and Communications (ISCC) (pp. 1-6). IEEE.

Danino, T., Ben-Shimol, Y., & Greenberg, S. (2023). *Container Allocation in Cloud Environment Using Multi-Agent Deep Reinforcement Learning. Electronics 2023, 12, 2614*.

Ding, Y., Li, C., Cai, Z., Wang, X., & Yang, B. (2024). A dynamic interval auto-scaling optimization method based on informer time series prediction. *IEEe Access*, *13*, 14572-14583.

Femminella, M., & Reali, G. (2024). Comparison of reinforcement learning algorithms for edge computing applications deployed by serverless technologies. *Algorithms*, *17*(8), 320.

Fernandez, G., Gopu, A., Abirami, S. P., Chandar, B. M., Poongodi, T., & Arunkumar, B. (2024). Conditional Random Field-Based Incremental Auto Scaling Algorithm to Enhance Workflow Scheduling in Cloud Computing. *IEEE Access*, *12*, 173914-173924.

Feng, K., Luo, L., Xia, Y., Luo, B., He, X., Li, K., ... & Peng, K. (2024). Optimizing microservice deployment in edge computing with large language models: Integrating retrieval augmented generation and chain of thought techniques. *Symmetry*, *16*(11), 1470.

Hady, M. A., Hu, S., Pratama, M., Cao, Z., & Kowalczyk, R. (2025). Multi-agent reinforcement learning for resources allocation optimization: a survey. *Artificial Intelligence Review*, *58*(11), 354.

Hang, C. N., Yu, P. D., Morabito, R., & Tan, C. W. (2024). Large language models meet next-generation networking technologies: A review. *Future Internet*, *16*(10), 365.

Hou, H., & Ismail, A. (2024). EETS: An energy-efficient task scheduler in cloud computing based on improved DQN algorithm. *Journal of King Saud University Computer and Information Sciences*, *36*(8), 102177.

Hou, Y. (2026). Deep reinforcement learning-based cloud data integrity verification algorithm for accounting informatization. *Discover Artificial Intelligence*, *6*(1), 328.

Hu, Y., Qiu, F., Zheng, F., & Zhao, J. (2024). Multi-dimensional resource allocation strategy for LEO satellite communication uplinks based on deep reinforcement learning. *Journal of Cloud Computing*, *13*(1), 56. https://doi.org/10.1186/s13677-024-00621-z

Konidaris, D., Soumplis, P., Varvarigos, A., & Kokkinos, P. (2025). Intent-based resource allocation in edge and cloud computing using reinforcement learning. *Algorithms*, *18*(10), 627.

Liu, H., Zhu, W., Fu, S., & Lu, Y. (2024). A trend detection-based auto-scaling method for containers in high-concurrency scenarios. *Ieee Access*, *12*, 71821-71834.

Liu, Z., Sun, Y., Liu, C., Zhao, Z., & Cheng, L. (2026). Data-intensive task scheduling in geo-distributed cloud computing: a deep reinforcement learning approach. *Journal of Cloud Computing*. https://doi.org/10.1186/s13677-026-00894-6

Manhary, F. N., Mohamed, M. H., & Farouk, M. (2025). A scalable machine learning strategy for resource allocation in database. *Scientific Reports*, *15*(1), 30567. https://doi.org/10.1038/s41598-025-14962-5

Naaz, F., et al. (2026). QoS-aware lightweight deep reinforcement learning technique for task scheduling in cloud computing. *Discover Computing*. https://doi.org/10.1007/s10791-026-09996-w

Ni, T., & Lin, J. (2025). Application of adaptive reinforcement learning in dynamic resource allocation of cloud computing and supply chain systems. *Journal of Dynamics and Games*, 0-0.

Panwar, R., & Supriya, M. (2024). RLPRAF: Reinforcement learning-based proactive resource allocation framework for resource provisioning in cloud environment. *IEEE Access*, *12*, 95986-96007.

Parhizkar, A., Arianyan, E., & Goudarzi, P. (2026). Research on intelligent resource management solutions for green cloud computing. *Future Internet*, *18*(2), 76.

Rajammal, K., & Chinnadurai, M. (2026). Multi-objective Load Balancing in Cloud Computing Environment Using Efficient Deep Reinforcement Learning with Hybrid Optimization Algorithm. *International Journal of Computational Intelligence Systems*, *19*(1), 81. https://doi.org/10.1007/s44196-026-01203-4

Sun, J., Gao, Q., Wu, C., Li, Y., Wang, J., & Niyato, D. (2024, December). Secure resource allocation via constrained deep reinforcement learning. In *International Conference on Machine Learning for Cyber Security* (pp. 1-15). Singapore: Springer Nature Singapore.

Wang, Z., Goudarzi, M., Gong, M., & Buyya, R. (2024). Deep reinforcement learning-based scheduling for optimizing system load and response time in edge and fog computing environments. *Future Generation Computer Systems*, *152*, 55-69.

Xie, Y., Wu, K., Jiang, Y., Xiaoliang, Z., & Cui, W. (2026). Hierarchical service chain orchestration for multi-cloud environments enabled by deep reinforcement learning. *Journal of Cloud Computing*, *15*(1), 69.

Xu, X., Zhao, J., Zhang, Y., & Li, R. (2025). Integrating Reinforcement Learning and LLM with Self-Optimization Network System. *Network*, *5*(3), 39.

Zakaryia, S. A., Meaad, M., Nabil, T., & Hussein, M. K. (2025). Task offloading and resource allocation for multi-UAV asset edge computing with multi-agent deep reinforcement learning. *Computing*, *107*(5), 126.

Zhou, G., Tian, W., Buyya, R., Xue, R., & Song, L. (2024). Deep reinforcement learning-based methods for resource scheduling in cloud computing: a review and future directions: G. Zhou et al. *Artificial Intelligence Review*, *57*(5), 124. https://doi.org/10.1007/s10462-024-10756-9

Zhou, G., Tian, W., & Buyya, R. (2023a). Multi-search-routes-based methods for minimizing makespan of homogeneous and heterogeneous resources in Cloud computing. *Future Generation Computer Systems*, *141*, 414-432.

Zhou, G., Tian, W., Buyya, R., & Wu, K. (2023b). Growable genetic algorithm with heuristic-based local search for multi-dimensional resources scheduling of cloud computing. *Applied Soft Computing*, *136*, 110027.

Wang, Y., Yu, J., & Yu, Z. (2023). Resource scheduling techniques in cloud from a view of coordination: a holistic survey. *Frontiers of Information Technology & Electronic Engineering*, *24*(1),