

خوارزمية جديدة لتحسين توزيع سيارات الأجرة باستخدام الذكاء الاصطناعي والتعلم المعزز

تأليف

مدرس الدكتور محمد لوتي

فبراير 22, 2026

اقتبس من هذا المقال

مدرس الدكتور محمد لوتي (2026). خوارزمية جديدة لتحسين توزيع سيارات الأجرة باستخدام الذكاء الاصطناعي والتعلم المعزز. عرب سايكولوجي. تم الاسترجاع من <https://arabpsychology.com/?p=119296>

تخيل أنك في مدينة مزدحمة مثل القاهرة أو الرياض، تحاول طلب سيارة أجرة عبر تطبيق هاتفك. غالبًا ما تواجه لحظات انتظار طويلة، أو تجد أن السائق يتخذ طريقًا أطول من اللازم للوصول إليك. هذه المشكلات ليست مجرد إزعاج شخصي، بل هي تحديات كبيرة تواجه شركات نقل الركاب وتؤثر على كفاءة حركة المرور في المدن. هل يمكن للذكاء الاصطناعي أن يحل هذه المعضلة؟

منهجية البحث

باحثون قاموا بتطوير خوارزمية جديدة تعتمد على تقنيات التعلم المعزز متعددة الوكلاء (Multi-Agent Reinforcement Learning - MARL) لتحسين عملية إرسال سيارات الأجرة. هذه الخوارزمية، التي أطلقوا عليها اسم DualG-MARL، لا تعتمد على قواعد ثابتة أو حلول بدائية، بل تتعلم باستمرار من البيانات لتحسين أدائها. الفكرة الأساسية هي تمثيل نظام نقل الركاب على شكل رسمين بيانيين (graphs): الأول يمثل حالة المركبات (مواقعها، حالتها، إلخ)، والثاني يمثل طلبات الركاب (مواقعهم، وجهاتهم، إلخ).

الخوارزمية تستخدم تقنية تسمى "انتشار النواة متعدد الأوامر" (multi-order diffusion kernels) لاستخلاص الخصائص المكانية الهيكلية من هذه الرسوم البيانية. بمعنى آخر، تحاول فهم العلاقات بين المركبات والركاب بناءً على مواقعهم وتوزيعهم في المدينة. ثم، تستخدم الخوارزمية "قناع جدوى" (feasibility mask) وآلية "تصفية Top-K" لضمان أن عملية مطابقة المركبات بالركاب تتم بكفاءة وفعالية. هذه الآلية تحد من عدد الخيارات المتاحة للمطابقة، مما يقلل من الوقت اللازم لاتخاذ القرار ويحسن جودة التعيين.

التعلم المعزز متعدد الوكلاء

التعلم المعزز هو نوع من الذكاء الاصطناعي حيث يتعلم الوكيل (في هذه الحالة، نظام إرسال سيارات الأجرة) من خلال التجربة والخطأ. يتلقى الوكيل مكافآت أو عقوبات بناءً على أفعاله، ويتعلم بمرور الوقت كيفية اتخاذ القرارات التي تزيد من مكافآته. في هذه الحالة، هناك العديد من "الوكلاء" (المركبات) الذين يتعاونون معًا لتحقيق هدف مشترك (خدمة الركاب بكفاءة).

النتائج

قام الباحثون باختبار خوارزمية DualG-MARL على بيانات حقيقية من مدينتي مانهاتن وكوينز في نيويورك. وقارنوا أدائها مع خوارزمية أخرى تعتبر من أحدث ما توصل إليه العلم في هذا المجال، وهي CoopRide. النتائج كانت مذهلة. أظهرت DualG-MARL تحسنًا كبيرًا في جميع المقاييس الرئيسية للأداء.

على سبيل المثال، انخفض متوسط وقت الانتظار (Average Waiting Time - AWT) بمقدار 0.27 و 0.35 دقيقة في مانهاتن وكوينز على التوالي. كما زادت نسبة استجابة الطلبات (Order Response Rate - ORR) بنسبة 2.3٪ و 2.7٪. بالإضافة إلى ذلك، تحسن معدل استخدام المركبات (Vehicle Utilization Rate - VUR) بنسبة 3.5٪ و 3.9٪، وانخفض متوسط نسبة الانحراف (Average Detour Ratio - ADR) بنسبة 0.05 و 0.06. هذه التحسينات تعني أن الركاب ينتظرون وقتًا أقل، وأن المزيد من الطلبات يتم تلبيةها، وأن المركبات تعمل بكفاءة أكبر، وأن السائقين يتخذون طرقًا أكثر مباشرة.

الآثار

هذه النتائج لها آثار كبيرة على مستقبل أنظمة نقل الركاب في المدن. توضح أن استخدام تقنيات الذكاء الاصطناعي المتقدمة، مثل التعلم المعزز متعدد الوكلاء والنمذجة الرسومية، يمكن أن يحسن بشكل كبير كفاءة وفعالية هذه الأنظمة. هذا لا يفيد الركاب والسائقين فحسب، بل يساهم أيضاً في تقليل الازدحام المروري والانبعاثات الضارة.

الخوارزمية الجديدة التي طورها الباحثون تمثل "نموذجاً واعياً بالهيكل" (structure-aware paradigm) لأنظمة التنقل الحضري واسعة النطاق. فهي لا تعامل المركبات والركاب ككيانات منفصلة، بل تحاول فهم العلاقات بينها واستغلالها لتحسين الأداء. هذا النهج يمكن أن يفتح الباب أمام تطوير أنظمة نقل أكثر ذكاءً ومرونة وقدرة على التكيف مع الظروف المتغيرة.

من المرجح أن نشهد في المستقبل القريب المزيد من التطبيقات المماثلة للذكاء الاصطناعي في مجال النقل، مما سيؤدي إلى تحسين تجربتنا في التنقل في المدن وجعلها أكثر استدامة.

Reference

Sha J. (2026). *A multi-agent reinforcement learning scheduling algorithm integrating state graph and task graph structural modeling for ride-sharing dispatching*. Scientific Reports, 16(1), 5461-5461

DOI: [10.1038/s41598-026-35004-8](https://doi.org/10.1038/s41598-026-35004-8)