

تعزيز التعلم العميق يتنبأ باستهلاك وأسعار الطاقة بدقة متزايدة

تأليف

مدرس الدكتور محمد لوتي

مارس 28, 2026

اقتبس من هذا المقال

مدرس الدكتور محمد لوتي (2026). تعزيز التعلم العميق يتنبأ باستهلاك وأسعار الطاقة بدقة متزايدة. عرب سايكولوجي. تم الاسترجاع من <https://arabpsychology.com/?p=120214>

تخيل أنك تدير شبكة كهرباء ذكية تغذي مدينة بأكملها. كل قرار تتخذه بشأن توزيع الطاقة، وشراء الوقود، وتحديد الأسعار له تأثير مباشر على ملايين الأشخاص. الدقة في التنبؤ بالطلب على الطاقة وأسعارها في المدى القصير ليست مجرد مسألة كفاءة، بل هي ضرورة لضمان استقرار الشبكة وتجنب الانقطاعات المكلفة. ولكن كيف يمكننا تحسين هذه التوقعات في عالم يتسم بالتعقيد والتغير المستمر؟

منهجية البحث

قام الباحث وو.ي. بتطوير طريقة جديدة للتنبؤ بالطلب على الطاقة وأسعارها تعتمد على التعلم المعزز العميق (Deep Reinforcement Learning - DRL). هذا النهج المبتكر لا ينظر إلى التنبؤ على أنه مجرد مسألة إحصائية، بل كعملية اتخاذ قرار مستمر. الفكرة الأساسية هي تحويل عملية التنبؤ إلى ما يسمى "عملية قرار ماركوف" (Markov Decision Process - MDP)، وهي إطار رياضي لوصف المشكلات التي تتضمن اتخاذ قرارات متسلسلة في بيئة غير مؤكدة.

تتكون عملية قرار ماركوف هذه من أربعة عناصر رئيسية. أولاً، "الحالة" (State) وهي مجموعة البيانات التي يعتمد عليها نظام التنبؤ لاتخاذ قراره. تشمل هذه البيانات الاتجاهات التاريخية للطلب على الطاقة والأسعار، بالإضافة إلى عوامل خارجية مثل الظروف الجوية وأسعار الوقود. ثانياً، "الفعل" (Action) وهو القيمة المتوقعة للطلب على الطاقة والسعر في الفترة الزمنية التالية. ثالثاً، "المكافأة" (Reward) وهي مقياس لمدى جودة التنبؤ. تم تصميم دالة المكافأة بحيث تعاقب الأخطاء في التنبؤ بالطلب والسعر، وتشجع على الدقة. وأخيراً، "السياسة" (Policy) وهي الاستراتيجية التي يتبعها النظام لاتخاذ أفضل القرارات بناءً على الحالة الحالية.

جوهر هذا النموذج هو "شبكة Q-عميقة" (Deep Q-Network - DQN)، وهي نوع من الشبكات العصبية العميقة (Deep Neural Networks - DNNs) تستخدم لتقدير "دالة Q-value function" (Q)، والتي تحدد القيمة المتوقعة لاتخاذ فعل معين في حالة معينة. يتعلم النظام باستمرار من خلال التفاعل مع البيانات التاريخية والبيانات الآنية للسوق، باستخدام خوارزمية "Q-learning" لتحسين دالة Q بمرور الوقت.

النتائج

قام الباحثون بتطبيق هذه الطريقة على بيانات من "اتصال PJM Interconnection" (PJM)، وهي أكبر مشغل لشبكة كهرباء في الولايات المتحدة، تغطي الفترة من 2021 إلى 2023. وقد أظهرت النتائج تحسناً ملحوظاً في دقة التنبؤ، حيث انخفض "متوسط الخطأ المطلق بالنسبة المئوية" (Mean Absolute Percentage Error - MAPE) بنسبة تتراوح بين 15% و 20% مقارنة بالطرق التقليدية مثل "ARIMA" (AutoRegressive Integrated Moving Average)، و "LSTM" (Long Short-Term Memory)، و "XGBoost".

هذا التحسن في الدقة ليس مجرد رقم إحصائي، بل يعكس قدرة النموذج الجديد على التقاط العلاقات المعقدة في بيانات الطاقة والسوق. فمن خلال التعامل مع التنبؤ كعملية اتخاذ قرار، يمكن للنموذج التكيف مع التغيرات في الظروف واتخاذ قرارات أفضل بناءً على المعلومات المتاحة. أظهرت التجارب أن هذا النهج القائم على التعلم المعزز العميق يقلل بشكل كبير من أخطاء التنبؤ، مما يؤدي إلى تحسين الكفاءة التشغيلية والاستخدام الذكي للموارد وزيادة الموثوقية في شبكات الطاقة الذكية.

آثار البحث

تتجاوز أهمية هذا البحث مجرد تحسين دقة التنبؤ. فهو يفتح الباب أمام تطوير أنظمة إدارة طاقة أكثر ذكاءً ومرونة. فمن خلال التنبؤ الدقيق بالطلب على الطاقة وأسعارها، يمكن لمشغلي الشبكات اتخاذ قرارات أفضل بشأن شراء الوقود وتوزيع الطاقة، مما يؤدي إلى خفض التكاليف وتقليل الانبعاثات.

بالإضافة إلى ذلك، يمكن استخدام هذه الطريقة لتحسين إدارة مصادر الطاقة المتجددة، مثل الطاقة الشمسية وطاقة الرياح، والتي تتسم بتقلبات في الإنتاج. فمن خلال التنبؤ الدقيق بالإنتاج المتوقع من هذه المصادر، يمكن لمشغلي الشبكات دمجها بشكل أكثر فعالية في الشبكة، مما يساهم في تحقيق أهداف الاستدامة.

في الختام، يمثل هذا البحث خطوة مهمة نحو بناء شبكات طاقة ذكية أكثر كفاءة وموثوقية واستدامة. ومن خلال الاستفادة من قوة التعلم المعزز العميق، يمكننا مواجهة التحديات المتزايدة التي تواجه قطاع الطاقة في القرن الحادي والعشرين.

Reference

Wu Y. (2026). *A novel reinforcement learning-based approach for short-term load and price forecasting in energy markets*. Scientific Reports, 16(1), 5141-5141.

DOI: [10.1038/s41598-026-37366-5](https://doi.org/10.1038/s41598-026-37366-5)