

1. Симуляція польотів – моделі забезпечують точне планування траєкторій польотів космічних апаратів, враховуючи вплив гравітації, магнітних полів та інших факторів. Це дає змогу уникнути помилок та знижує вартість місії.

2. Створення роботизованих систем – КММ застосовується для розробки роботів-дослідників, які можуть працювати в умовах екстремального холоду, радіації або низької гравітації, наприклад, на Марсі.

3. Підготовка астронавтів – моделі використовуються для симуляції умов перебування в космосі, зокрема впливу мікрогравітації на організм людини, що допомагає краще підготувати астронавтів до тривалих місій [4].

Висновки. Перспективи розвитку комп'ютерно-математичного моделювання є надзвичайно широкими. Інтеграція штучного інтелекту, використання квантових обчислень і впровадження хмарних технологій відкривають нові горизонти для науки та інженерії. Ці напрями дають змогу зробити КММ більш доступним, точним та ефективним, сприяючи прогресу в багатьох галузях людської діяльності.

Список використаних джерел

1. Berman F., Fox G., Hey A. J. G. Grid Computing: Making the Global Infrastructure a Reality. Wiley-Interscience, 2003. 1060 p.
2. Nielsen M. A., Chuang I. L. Quantum Computation and Quantum Information: 10th Anniversary Edition. Cambridge: Cambridge University Press, 2010. 702 p.
3. Russell S., Norvig P. Artificial Intelligence: A Modern Approach. 3rd edition, Pearson Education, 2010. 1152 p.
4. Peng L., Bao L., Huang M. Application of Matlab / Simulink Software in Physics. *High Performance Networking, Computing, and Communication Systems*. Springer Berlin Heidelberg, 2011. P. 140–146.

УДК 338.27:004.89

*Іваненко А. В., здобувач вищої освіти,
Січко Т. В., канд. техн. наук, доцент
кафедри інформаційних технологій*

РОЗВ'ЯЗАННЯ ЗАДАЧІ ПРОГНОЗУВАННЯ СПОЖИВЧОГО ПОПИТУ МЕТОДАМИ ШТУЧНОГО ІНТЕЛЕКТУ

Донецький національний університет імені Василя Стуса, м. Вінниця

Прогнозування попиту – це процес оцінки майбутнього попиту на товар або послугу, який дає підприємствам змогу передбачити кількість продукції чи послуг, які споживачі можуть придбати у певний період часу [1]. Точність прогнозування є критично важливою для ефективного управління бізнесом, оскільки вона дає змогу правильно планувати виробничі процеси, розподіляти ресурси, оптимізувати логістику та здійснювати стратегічні інвестиції. Неправильна оцінка попиту може призвести до надлишку запасів, що тягне за собою зайві витрати на зберігання, або до дефіциту продукції, що знижує задоволення споживачів і втрачає потенційний дохід. Тому точне прогнозування попиту є

основою для прийняття обґрунтованих рішень у плануванні виробництва та управлінні запасами.

Метою дослідження є застосування методів машинного навчання для прогнозування попиту, а саме прогнозування часових рядів.

Машинне навчання – це сфера штучного інтелекту, що фокусується на розробці алгоритмів і моделей, здатних навчатися на основі даних і покращувати свою роботу без явного програмування [2]. В основі машинного навчання лежить ідея, що системи можуть самостійно виявляти патерни та структури в даних, адаптуватися до нової інформації та приймати рішення на основі набутих знань. Передовими розробками у сфері машинного навчання є нейронні мережі, які поступово витісняють більш традиційні рішення.

Нейромережі – це моделі, натхненні біологічними нейронними мережами, що складаються зі штучних нейронів – структурних одиниць, які приймають дані, виконують над ними прості обчислення та передають цю інформацію далі [2, 3]. Нейронні мережі складаються з шарів нейронів: вхідного для прийому даних, прихованих для їх обробки та вихідного для видачі результатів. Для прогнозування часових рядів застосовують такі архітектури нейромереж:

- RNN (Recurrent Neural Network) – є архітектурою нейронних мереж, яка ефективно працює з послідовними даними, як-от часові ряди. Особовості RNN – це наявність зворотних зв'язків між прихованими шарами мережі, що дає змогу їм використовувати інформацію з попередніх кроків. Рекурентні зв'язки допомагають зберігати інформацію з попередніх кроків обробки даних, що робить цю архітектуру здатною до аналізу залежностей між елементами послідовності;
- GRU (Gated Recurrent Unit) – тип рекурентної нейронної мережі, що вирішує проблеми довготривалої залежності у послідовностях. Окрім стандартних вхідних, прихованих та вихідних шарів, мережа GRU також має дві затворні структури: затвор оновлення (update gate) та затвор скидання (reset gate), які визначають, яку інформацію зберігати або ігнорувати. Затвор оновлення контролює, скільки нової та старої інформації зберігати, а затвор скидання – скільки даних з минулого забути. Це забезпечує ефективну роботу з послідовними даними, наприклад, у прогнозуванні часових рядів;
- LSTM (Long Short-Term Memory) – архітектура нейронної мережі, що також була створена для вирішення проблеми довготривалої залежності у послідовних даних, з якою стикалися звичайні рекурентні нейронні мережі (RNN). LSTM використовують спеціальні механізми для збереження важливої інформації на тривалий період часу, що робить їх ефективними у задачах обробки послідовностей, як-от прогнозування часових рядів;
- CNN (Convolutional Neural Network) – архітектура, спочатку розроблена для обробки зображень, яка також використовується для аналізу сигналів і часових рядів. Вона складається зі вхідного шару, згорткових шарів (convolution layers), шару активації, агрегувальних шарів (pooling layers), пов'язаних шарів (fully connected layers) і вихідного шару. Шари згортки є основними шарами цієї мережі, у яких до вхідних даних застосовуються фільтри, що дає змогу виділяти локальні ознаки. Кожен фільтр зчитує невеликий набір даних і застосовує операцію згортки для виявлення патернів у цьому локальному наборі.

У випадку часових рядів використовуються одновимірні згортки (1D Convolution), де фільтри переміщаються уздовж часової осі, що допомагає моделі вивчати послідовні залежності. Агрегувальні шари зменшують розмірність даних, а повнозв'язні шари узагальнюють ознаки та приймають рішення, наприклад, прогнозують наступне значення.

До того ж новітніми розробками в цій сфері є гібридні нейронні мережі, що поєднують у собі ознаки декількох типів нейромереж або нейронної мережі з іншими, більш традиційними методами машинного навчання. Така інтеграція різних моделей дає змогу використовувати їх сильні сторони для обробки різноманітних типів даних і врахування складних взаємозв'язків, що робить прогнозування попиту більш ефективним і точним. Прикладами гібридних моделей, використовуваних під час прогнозування часових рядів, є:

- LSTM-CNN – гібридна мережа, що поєднує переваги CNN і LSTM. Ця архітектура спочатку використовує CNN для виявлення локальних, короткотермінових патернів у даних [4]. CNN працює шляхом застосування фільтрів до послідовностей даних, виявляючи важливі характеристики (наприклад, різкі зміни чи локальні піки). Після цього вихід CNN передається до LSTM, яка відома своєю здатністю запам'ятовувати довготривалі залежності у послідовностях. LSTM має механізми збереження та забування інформації, що дає їй змогу зберігати релевантні патерни у довгостроковій перспективі і одночасно позбавлятися зайвих. Така комбінація допомагає враховувати як короткострокові, так і довгострокові характеристики, що підвищує точність прогнозів, зокрема за високої мінливості або сезонності даних.

- ES-RNN – гібридна модель, що об'єднує експоненційне згладжування (ES) і рекурентну нейронну мережу (RNN) [5]. Експоненційне згладжування – це один із традиційних методів машинного навчання для прогнозування часових рядів, який базується на використанні зваженого середнього попередніх значень ряду, де ваги експоненційно зменшуються в часі. Ця модель розроблена для того, щоб обробляти як короткострокові, так і довгострокові залежності в часі, що є ключовим фактором для точного передбачення тенденцій у часових рядах. Експоненційне згладжування використовується для виділення основних трендів і сезонних компонентів у даних. Завдяки своїм властивостям експоненційне згладжування здатне адаптивно враховувати зміни в трендах і циклах, зменшуючи вплив короткострокових коливань. З іншого боку, рекурентна нейронна мережа добре підходить для обробки складних часових залежностей і взаємозв'язків між попередніми та поточними значеннями в ряді. RNN здатна запам'ятовувати інформацію про минулі стани завдяки своїй рекурентній структурі, що дає змогу їй краще моделювати послідовні процеси. Ця комбінація допомагає ефективно фільтрувати дані та точно прогнозувати складні часові ряди.

Отже, було розглянуто різноманітні методи для прогнозування попиту, а саме сучасні підходи на основі технологій нейронних мереж. Приділено увагу як поширеним архітектурам нейромереж, так і більш комплексним гібридним моделям, які є одним із новітніх шляхів розвитку сфери машинного навчання. Розробка нових більш ефективніших рішень дасть змогу значно підвищити точність прогнозування попиту, що є критичним для успішної стратегії управ-

ління підприємств. Це допоможе краще оптимізувати ресурси, знижувати витрати на зберігання запасів, покращувати логістичні процеси та забезпечити більшу гнучкість у відповідь на зміни ринку для підприємств.

Список використаних джерел

1. Jr C. C. W., Chase C. W. Demand-Driven Forecasting: A Structured Approach to Forecasting. Wiley Sons, Limited, John, 2015.
2. Huang C., Petukhina A. Applied time series analysis and forecasting with python. Springer International Publishing AG, 2022.
3. Method of neural network detection of anomalies in data of waste-free production audit / Т. Нескородєва, Є. Федоров, А. Нескородєва, Т. Січко, П. Римар. *Computer systems and information technologies*. 2021. № 2. С. 20–32.
4. Aguiar-Pérez J. M., Pérez-Juárez M. Á. An insight of deep learning based demand forecasting in smart grids. 2023. Т. 23. № 3. С. 1467.
5. Smyl S., Dudek G., Peřka P. ES-dRNN: a hybrid exponential smoothing and dilated recurrent neural network model for short-term load forecasting. *IEEE transactions on neural networks and learning systems*. 2023. P. 1–13. DOI: 10.1109/tnnls.2023.3259149 (date of access: 15.11.2024).

УДК 004.62:519.6;681.586

*Канюка Р. Ю., здобувач вищої освіти,
Ротштейн О. П., д-р техн. наук, професор,
професор кафедри інформаційних
технологій*

МАТЕМАТИЧНА ОБРОБКА ОТРИМАНИХ ДАНИХ УЛЬТРАЗВУКОВОГО ДАТЧИКА

Донецький національний університет імені Василя Стуса, м. Вінниця

Вступ. Звукові сигнали мають широке застосування в різних сферах. Одним з найбільш поширеного використання є звукова локалізація, яка дає змогу визначити місце та напрямок джерела звуку шляхом аналізу сигналу та часу його повернення. Ця методика активно використовується в наукових дослідженнях для вивчення атмосферних явищ, як-от блискавки та турбулентність, а також у геофізичних дослідженнях, зокрема для аналізу сейсмічної активності.

У промисловості звукова локалізація слугує для неінвазійного обстеження матеріалів та конструкцій, таких як-от труби, мости та будівлі. Завдяки простоті цієї технології можна легко створити прототип, використовуючи базові знання, оскільки для реалізації достатньо мікрофона або подібного пристрою. Використовуючи швидкість звуку в повітрі та вимірний час між моментом випромінювання та отриманням відбитого сигналу, можна обчислити відстань до об'єкта.

Це можна виразити через формулу (1.1), що базується на методі часу польоту:

$$d = \frac{vt}{2}. \quad (1.1)$$