

Wisniewski, Pedro Orival Luccas. Digital Image Analysis for the Colorimetric Determination of Aluminum, Total Iron, Nitrite and Soluble Phosphorus in Waters // Analytical Letters. Volume 50. Issue 2. 2017. P. 414-430. 4. Firdaus M. L., Trinoveldi W. Abwi, F., Rahayu I., Rahmidar L., Warsito K. Determination of Chromium and Iron Using Digital Image-based Colorimetry // Procedia Environmental Sciences. Volume 20. 2014. P. 298 - 304. 5. Luka G. S., Nowak E., Kawchuk J., Hoorfar M., Najjaran H. Portable device for the detection of colorimetric assays // Royal Society Open Science. Volume 4. Issue 11. 2017. 171025. 6. Helfer G. A., Magnus V. S., Bock F. C., Teichmann A., Ferrao M. F., A. B. da Costa. PhotoMetrix: An Application for Univariate Calibration and Principal Components Analysis Using Colorimetry on Mobile Devices // Journal of the Brazilian Chemical Society. Volume 28. Issue 2. 2017. P. 328-335. 7. Multilayer perceptron: Theory and Applications / ed.: R. Vang-Mata. New York. Nova Science Publishers, 2020. 153 p. 8. Brownlee J. When to Use MLP, CNN, and RNN Neural Networks. 2019. URL: <https://machinelearningmastery.com/when-to-use-mlp-cnn-and-rnn-neural-networks>. 9. Bernico M. Deep Learning Quick Reference: Useful hacks for training and optimization deep neural networks with TensorFlow and Keras. Birmingham, UK: Packt Publishing, 2018. 10. Hanchett E., Listwon B. Vue.js in Action. Manning Publications, 2018. 304 c. 11. Holovaty A., Kaplan-Moss J. The Definitive Guide to Django. Web Development Done Right. NY, Apress, 2009. 536 p.

Надійшла до редколегії 21.05.2021

Сафоник Андрій Петрович, доктор технічних наук, професор, професор кафедри автоматизації, електротехнічних та комп'ютерно-інтегрованих технологій Національного університету водного господарства та природокористування. Наукові інтереси: математичне та комп'ютерне моделювання природних, технологічних, техногенних процесів і систем та їх автоматизація. Адреса: Україна, 33018, м. Рівне, вул. Соборна 11, тел. +38 (050) 378 86 21.

Грицюк Іванна Михайлівна, асистент, асистент кафедри комп'ютерних наук та прикладної математики Національного університету водного господарства та природокористування. Наукові інтереси: математичне та комп'ютерне моделювання природних, технологічних, техногенних процесів і систем та їх автоматизація. Адреса: Україна, 33018, м. Рівне, вул. Соборна 11, тел. +38 (063) 345 46 11.

Мищанчук Максим Миколайович, студент. Наукові інтереси: математичне та комп'ютерне моделювання природних, технологічних, техногенних процесів і систем та їх автоматизація. Адреса: Україна, 33018, м. Рівне, вул. Соборна 11, тел. +38 (098) 083 90 80.

Льків Ігор Васильович, аспірант кафедри вищої математики Рівненського державного гуманітарного університету. Наукові інтереси: математичне та комп'ютерне моделювання природних, технологічних, техногенних процесів і систем. Адреса: Україна, 33017, м. Рівне, вул. Степана Бандери 12, тел. +38 (093) 487 26 89.

УДК 004.942

DOI: 10.30837/0135-1710.2021.177.043

Д.Е.СИТНИКОВ, Ю.О.АНДРУСЕНКО

РОЗРОБКА МЕТОДУ ФОРМУВАННЯ ЕФЕКТИВНОГО ПЛАНУ ПІДВИЩЕННЯ КВАЛІФІКАЦІЇ

Досліджено застосування моделі на основі згорткових нейронних мереж для задачі прогнозування поширення захворюваності COVID-19 в Україні. Серед сучасних моделей нейронних мереж для даної задачі обрана InceptionTime на основі архітектури Inception-v4. Дослідження реалізовано за допомогою високорівневої мови програмування Python. Проведено 30 експериментів з навчання моделі на вхідній вибірці даних з використанням різних ознак. Модель продемонструвала високу точність і швидкодію.

1. Вступ

Пандемія раніше невідомого коронавірусу SARS-CoV-2, що викликає атипову пневмонію COVID-19, впливає на життя людей по всьому світу. У багатьох країнах введені карантинні обмеження, які істотно позначаються на всіх соціально-економічних сферах і світовій економіці в цілому.

Наслідком COVID-19 в Україні стало падіння ВВП і майже повна зупинка діяльності у сфері роздрібною торгівлі, готельного та ресторанного бізнесу, авіаперевезень. В регіонах, де існує пом'якшення карантинних обмежень, спостерігаються піки захворюваності. Через те, що вакцинація від COVID-19 в Україні розпочата нещодавно та довіра населення до вакцинації дуже низька, перспективи завершення карантину, а, відповідно, і нормалізації життя населення віддалені.

В таких умовах значно підвищується актуальність задач прогнозування фінансово-економічних, логістичних та навіть продовольчих показників, на які впливає поширення COVID-19 в Україні. Тому для прийняття рішення про посилення або пом'якшення карантинних обмежень необхідно прогнозувати поширення захворюваності по регіонах України в довгостроковій і короткостроковій перспективі з максимальною точністю.

Отже, розглянемо задачу прогнозування поширення COVID-19 в Україні в такій постановці. Вхідними даними є часові ряди показників захворюваності по регіонах: кількість підтверджених випадків, кількість смертей, кількість активних випадків, приріст підтверджених випадків і приріст активних випадків. Необхідно спрогнозувати приріст підтверджених випадків з мінімальною похибкою.

2. Основна частина

На сьогоднішній день існує значна кількість методів прогнозування часових рядів (time series, TS). Умовно їх можна розділити на статистичні, структурні і комбіновані [1].

Загальним недоліком статистичних моделей є складність вибору типу моделі і підбору її параметрів. При вирішенні задач прогнозування аналітику доводиться приймати рішення щодо таких характеристик часового ряду як тренд, сезонна і циклічна компоненти, робити припущення про модель часового ряду - адитивної, мультиплікативної тощо. Автоматичного способу виявлення трендів у часових рядах не існує. У той же час при вивченні кривої, що відображує результати спостережень, аналітику важко робити припущення щодо повторюваності форми кривої через рівні проміжки часу [2]. Все це істотно збільшує суб'єктивний внесок учасників процесу аналізу і прогнозування TS. Таким чином, результат аналізу і прогнозування TS залежить як від кваліфікації аналітика в предметній галузі, так і від його кваліфікації в методах аналізу.

Серед структурних моделей варто відзначити моделі на основі нейронних мереж (artificial neural networks, ANN). Здатність нейронної мережі до різнобічної обробки інформації впливає з її здатності до узагальнення і виділення прихованих залежностей між вхідними та вихідними даними [3]. Великою перевагою нейронних мереж є те, що вони здатні до навчання і узагальнення накопичених знань. Апарат ANN передбачає мінімальну участь аналітика в формуванні моделі часового ряду, оскільки здатність нейромережевих моделей до навчання дозволяє виявити приховані взаємозв'язки і закономірності між даними, а алгоритми навчання адаптують вагові коефіцієнти відповідно до структури даних, представлених для навчання [4].

Використання апарату ANN для прогнозування TS полягає в формуванні ANN певної структури, в її параметричному налаштуванні на основі поведінки досліджуваної системи в заздалегідь відомі моменти часу, в передбаченні майбутньої поведінки системи за її передісторією. Вибір архітектури нейронної мережі обумовлюється специфікою і складністю розв'язуваної задачі.

Для прогнозування TS широко застосовуються архітектури рекуррентної нейронної мережі (recurrent neural network, RNN) і згорткової нейронної мережі (convolutional neural network, CNN).

Ідея RNN полягає в послідовному використанні інформації, тобто виконується одна й та ж задача для кожного елемента послідовності, причому вихід залежить від попередніх обчислень. На відміну від інших алгоритмів машинного навчання, рекуррентні нейронні мережі з довгою короткочасною пам'яттю (long short-term memory, LSTM) здатні автоматично виявляти ознаки з тимчасових послідовностей, обробляти багатовимірні дані, а також виводити послідовності змінної довжини, завдяки чому їх можна використовувати для прогнозування [5].

Однією з найвідоміших архітектур є згорткова. CNN широко застосовується для ефективного розпізнавання зображень. Її особливість полягає в використанні згорткових і пулінгових шарів. Згортковий шар нейронної мережі являє собою застосування операції згортки до виходів з попереднього шару, де ваги ядра згортки є навчальними параметрами. Ядро являє собою фільтр, який ковзає по вихідній матриці і знаходить певні ознаки об'єктів. Операція пулінг на результатах згортки - перетворення цієї множини результатів в меншу кількість елементів. Типова CNN має кілька згорткових і пулінгових шарів, розташованих послідовно. Для класифікації і прогнозування часових рядів застосовуються одномірні CNN.

У багатьох сучасних публікаціях увага приділяється методам, для яких характерні висока точність і масштабованість. Одним з таких методів є InceptionTime, представлений у грудні 2020 року, який демонструє високу швидкість навчання для часових рядів за декількома ознаками.

Модель InceptionTime - ансамбль 5 моделей глибоких згорткових нейронних мереж, на основі архітектури Inception-v4. Кожна модель створюється шляхом каскадування декількох модулів Inception [6]. Основна ідея модуля Inception - одночасне застосування декількох фільтрів до вхідного часового ряду. Модуль включає фільтри різної довжини, які дозволяють мережі автоматично отримувати відповідні характеристики як з довгих, так і з коротких часових рядів [7]. Фактично, отримано мережі з фільтрами більшого розміру, ніж у тих, що будь-коли досліджувалися для задач комп'ютерного зору, безпосередньо використовуючи той факт, що часові ряди демонструють на один вимір менше, ніж зображення. За даними авторів, InceptionTime за рівнем точності відповідає HIVE-COTE та більш масштабована: модель може навчатись на 1500 часових рядах за одну годину, що повністю недоступно для HIVE-COTE [7].

Архітектура моделі InceptionTime представлена 2 блоками, кожен складається з 3 модулів Inception, розміщених один за одним. Вхід кожного блоку передається за допомогою лінійного з'єднання, щоб подати його на вхід наступного блоку, таким чином пом'якшуючи проблему зникнення градієнта, дозволяючи прямиий потік градієнта [8]. Після блоків Inception застосовується шар глобального об'

єднання (global average pooling, GAP), який усереднює вихідні багатовимірні часові ряди за весь часовий вимір. Завершує модель традиційний повністю зв'язаний шар softmax із кількістю нейронів, рівною кількості класів у наборі даних. Схематично архітектуру моделі InceptionTime представлено на рис. 1.




Рис. 1. Архітектура моделі InceptionTime

Зважаючи на переваги моделі InceptionTime, доцільно застосувати її для вирішення поставленої задачі та дослідити точність моделі в залежності від використовуваних ознак часового ряду.

Дослідження реалізовано за допомогою високорівневої мови програмування Python з використанням бібліотеки tsai, орієнтованої на сучасні методи класифікації, регресії та прогнозування часових рядів. Вхідні дані отримуємо з офіційного сайту РНБО за допомогою API. Нормалізація вхідних даних проведена в інтервалі від 0 до 1. Цільовий параметр прогнозування - приріст активних випадків. Точність прогнозування оцінюється середньою абсолютною похибкою (mean absolute error, MAE), середньою абсолютною похибкою у відсотках (mean absolute percentage error, MAPE), середньоквадратичною похибкою (mean squared error, MSE) та квадратного кореня з середньоквадратичною похибки (root-mean square error, RMSE).

В результаті проведено 30 експериментів навчання моделі з різним набором ознак: кількість активних випадків, приріст активних випадків, кількість підтверджених випадків, приріст підтверджених випадків, кількість смертельних випадків. Часове вікно - 56 днів, горизонт прогнозування - 14 днів. Час навчання та кількість епох навчання для кожного експерименту представлені на рис. 2.

Отже, навіть при максимальній кількості епох, час навчання не перевищує 6 хвилин 29 секунд, що




Рис. 2. Час та кількість епох навчання моделі

підтверджує швидкодню моделі InceptionTime.

Значення показників точності роботи моделі представлено на рис. 3-6.




Рис. 3. Значення MAE для 30 експериментів




Рис. 4. Значення MSE для 30 експериментів




Рис. 5. Значення RMSE для 30 експериментів

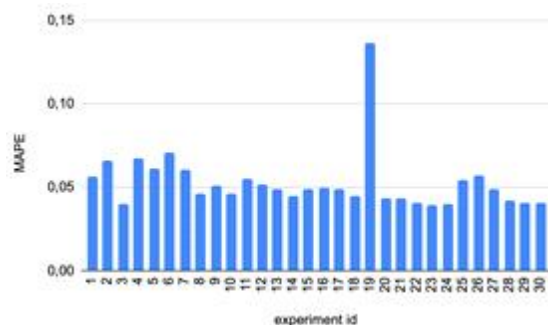


Рис. 6. Значення MAPE для 30 експериментів

Дослідження моделі InceptionTime демонструє стійкість результату, за винятком експерименту № 19. Параметри експерименту № 19 повторені у експериментах № 20 та № 21 для перевірки роботоспроможності моделі для даних ознак. Отримані результати відповідають загальній картині і вказують на технічну помилку навчання.

3. Висновки

Застосування моделі InceptionTime для задачі прогнозування поширення захворюваності на COVID-19 в Україні цілком можливе. Серед переваг даної моделі варто відмітити високу швидкість навчання та одночасну роботу з декількома часовими рядами, що можливо застосувати для прогнозування показників по кожному регіону окремо.

Отримані результати значень похибки демонструють високу точність роботи моделі для навчальної вибірки, де середньоквадратична похибка не перевищує 0,014, а середня абсолютна похибка - 13,6%.

Подальші дослідження мають на меті пошук найефективніших моделей на основі нейронних мереж та серед статистичних моделей. На разі розглядаються моделі CNN ResNet, FCNPlus, ResCNN, RNN_FCPlus, LSTM_FCPlus. Кращі моделі планується об'єднати в ансамбль для отримання оптимального прогнозу.

Список літератури: 1. Андрусенко Ю. О. Аналіз основних моделей прогнозування часових рядів. // Збірник наукових праць ХНУПС. 2020. №3(). С. 91-96. 2. Бокс Дж., Дженкінс Г. Аналіз временных рядов. Прогноз и управление: М. Мир, 1974. 406 с. 3. Bishop C.M. Neural Networks for Pattern Recognition. Oxford University Press, 2014. 482 p. 4. Хайкин С. Нейронные сети. Полный курс. М: Вильямс, 2006. 1104 с. 5. Wei, J., Nan, Z., Xiaoming, X. and Yanhe, X. Intelligent Deep Learning Method for Forecasting the Health Evolution Trend of Aero-Engine With Dispersion Entropy-Based Multi-Scale Series Aggregation and LSTM Neural Network. // IEEE Access, 2020. 34350-34361 pp. 6. Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A. Going deeper with convolutions. // In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2015. 1-9 pp. 7. Hassan Ismail Fawaz, Benjamin Lucas, Germain Forestier. InceptionTime: Finding AlexNet for Time Series Classification. // Data Mining and Knowledge Discovery. 2020. Vol. 34, 1936-1962

pp. 8. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. // In: IEEE Conference on Computer Vision and Pattern Recognition, 2016. 770-778 pp.

Надійшла до редколегії 14.05.2021

Ситніков Дмитро Едуардович, кандидат технічних наук, доцент, професор кафедри системотехніки ХНУРЕ. Наукові інтереси: Data Mining and Knowledge Discovery. Адреса: Україна, 61166, м. Харків, пр. Науки 14, тел. (057) 702 10 06.

Андрусенко Юлія Олександрівна, аспірантка кафедри електронних обчислювальних машин ХНУРЕ. Наукові інтереси: методи прогнозування часових рядів. Адреса: Україна, 61166, м. Харків, пр. Науки 14, тел. +38 (063) 407 06 09.

УДК 004.4

DOI: 10.30837/0135-1710.2021.177.047

Н.С. КРАВЕЦЬ

ВИЗНАЧЕННЯ ОБМЕЖЕНЬ РЕАЛІЗАЦІЇ ОБРОБКИ ПОДІЙ В ХМАРНОМУ ДОДАТКУ ЗА ДОПОМОГОЮ БЕЗСЕРВЕРНИХ ОБЧИСЛЕНЬ

У статті розглядаються безсерверні обчислення як нова і перспективна парадигма для розгортання хмарних додатків, зокрема таких що мають подієво-орієнтовану архітектуру. Платформи FaaS провідних постачальників хмарних послуг є найсучаснішою реалізацією безсерверної моделі. На основі порівняння характеристик та переліку джерел оброблюваних подій платформ FaaS від Amazon і Azure визначено переваги та обмеження використання цієї моделі для реалізації високопродуктивних систем, що обробляють події в режимі реального часу.

1. Вступ

У теперішній час розробникам все частіше доводиться вирішувати проблеми, пов'язані із обробкою в реальному часі потоку різноманітних подій, що надходять з різних джерел і вимагають різної обробки. Подібні проблеми покликана вирішувати подієво-орієнтована архітектура. Для вирішення проблем використовуються: асинхронна обробка подій, черги різних типів, механізм підписки на події тощо. Хмарні провайдери пропонують значну кількість рішень на базі своїх платформ, які також припускають використання безсерверних обчислень.

Безсерверні обчислення - це новий підхід, який концептуально ще більше дистанціює програмне забезпечення від інфраструктури, на якій воно виконується. Цей рівень абстракції істотно полегшує життя розробникам, дозволяючи зосередитися тільки на реалізації конкретних функцій. Хоча для реалізації безсерверних обчислень клієнта використовуються фізичні сервери, розробникам не потрібно думати про їх конфігурацію, характеристики та обслуговування. Компанія, що користується послугами безсерверного постачальника, по факту сплачує за використовувані ресурси і не повинна резервувати і оплачувати фіксовану пропускну здатність або кількість серверів, оскільки послуга автоматично масштабується.

У багатьох хмарних провайдерів, що пропонують безсерверні обчислення як послугу, є платформи Function-as-a-Service (FaaS), які дозволяють створювати прості функції, які незалежно запускаються при настанні якоїсь події і виконують одну задачу. За допомогою FaaS розробники можуть створювати модульну архітектуру, роблячи код більш масштабованим, не витрачаючи ресурси на підтримку бекенда. Основними перевагами безсерверних обчислень є низькі експлуатаційні витрати і ефективне управління та використання ресурсів. На теперішній час безсерверні обчислення пропонуються декількома постачальниками загальнодоступних хмарних сервісів. Безсерверні обчислення активно розвиваються, а їх реалізації від різних хмарних провайдерів мають істотні відмінності, аналіз яких є метою даної статті. AWS Microsoft і Azure на даний момент є лідерами ринку хмарних послуг, порівняємо можливості їх платформ FaaS з точки зору обробки подій.