

ДОДАТОК А

Харківський національний університет радіоелектроніки
Кафедра КІТС

Прогнозування часових рядів на основі використання штучних нейронних мереж

Атестаційна робота
Другий (магістерський)
рівень

Автор:
магістрантка гр. КІТм-19-1
Корецька П.С.

Науковий керівник:
д.т.н., проф. каф. КІТС
Корабльов М.М.

1

Актуальність

Сьогодні завдання прогнозування часових рядів стає особливо актуальним у різних сферах людської діяльності: у природничих науках - прогнози кількості опадів, забруднення природних ресурсів, показники різних біологічних та біохімічних показників; в економічній науці - прогнозувати поточні коливання цін на акції, щотижневі та щомісячні продажі, курси валют, річний обсяг виробництва тощо.

За останні роки було проведено багато досліджень щодо здатності прогнозувати економічні часові ряди. Вони працюють над визначенням того, які активи компанія збільшить у вартості, а який бізнес буде прибутковим при інвестуванні.

Предметом дослідження є методи прогнозування часових рядів. Метою даної роботи є аналіз вивченого, вивчення відомих і найпопулярніших методів прогнозування часових рядів та визначення параметрів, що впливають на ефективність і точність деяких моделей. Метод дослідження полягає у побудові прогнозних моделей та аналізі результатів.

2

Мета і задачі роботи

- **Мета:** дослідити методи прогнозування часових рядів, виконати їх порівняльний аналіз та виявити параметри впливу на ефективність і точність моделей на прикладі аналізу та прогнозування вартості акцій.
- **Задачі:**
 - 1) огляд предметної області;
 - 2) аналіз предмету дослідження;
 - 3) дослідження методів прогнозування часових рядів;
 - 4) побудова прогнозних моделей;
 - 5) моделювання прогнозних моделей;
 - 6) оцінка основних характеристик програмного продукту.

3

МЕТОДИ ПРОГНОЗУВАННЯ ЧАСОВИХ РЯДІВ

Класичні методи прогнозування:

- Методи згладжування
- Методи авторегресії

Методи прогнозування на основі використання штучних нейронних мереж:

- Багатошаровий перцептрон
- Згорткові нейронні мережі
- Рекурентні нейронні мережі

4

Методи згладжування

- Просте ковзне середнє

(англ. Simple Moving Average – SMA)

$$SMA = \frac{\sum_{i=1}^n P_i}{n}$$

- Зважене ковзне середнє

(англ. Weighted Moving Average – WMA)

$$WMA = \frac{\sum_{i=1}^n P_i * W_i}{\sum_{i=1}^n W_i}$$

- Експоненційне ковзне середнє

(англ. Exponential Moving Average – EMA)

$$EMA = \frac{EMA_{i-1} * (n - 1) + 2 * P_i}{n + 1}$$

5

Методи згладжування

- Подвійне експоненційне згладжування

$$\begin{aligned} \hat{y}_{t+h|t} &= l_t + hb_t \\ l_t &= \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}) \\ b_t &= \beta^*(l_t - l_{t-1}) + (1 - \beta^*)b_{t-1} \end{aligned}$$

- Потрійне експоненційне згладжування (Метод Холта-Вінтерса)

$$\begin{aligned} \hat{y}_{t+h|t} &= l_t + hb_t + s_{t+h-m(k+1)} \\ l_t &= \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \\ b_t &= \beta^*(l_t - l_{t-1}) + (1 - \beta^*)b_{t-1} \\ s_t &= \gamma(y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m} \end{aligned}$$

6

Методи авторегресії

- Проста модель авторегресії
(англ. Autoregression – AR)
- Модель авторегресії - ковзного середнього
(англ. Autoregressive moving average – ARMA)
- Модель авторегресії-інтегрованого ковзного середнього
(англ. Autoregressive integrated moving average – ARIMA)
- Модель Бокса-Дженкінса

$$y_n = \sum_{i=1}^p a_i e_{n-i} + e_n$$

$$y_n = \sum_{i=1}^p a_i y_{n-i} + \sum_{i=1}^q b_i e_{n-i} + e_n$$

$$y_n = \sum_{i=1}^p a_i y_{n-i} + \sum_{i=1}^q b_i e_{n-i} + e_n$$

$$\Delta y_t = y_t - y_{t-1}$$



$$\Delta^d X_t = c + \varepsilon_t + \sum_{i=1}^p a_i \Delta^d X_{t-i} + \sum_{j=0}^q b_j \varepsilon_{t-j}$$

7

Методи на основі використання штучних нейронних мереж

Перцептрон - це лінійний класифікатор, визначений вагами w_i , зміщенням b і функцією активації f .


Багатошаровий перцептрон (Multilayer Perceptron - MLP) - має три або більше шарів. Він використовується для класифікації даних, які неможливо розділити лінійно.




8

Методи на основі використання штучних нейронних мереж

Згортова нейронна мережа
(англ. Convolutional Neural Networks – CNN)




Рекурентна нейронна мережа
(англ. Recurrent Neural Networks – RNN)




9


Реалізація методів згладжування




Графік прогнозу простого ковзного середнього




Графік прогнозу методом експоненційного ковзного середнього



Графік прогнозу методом подвійного експоненційного ковзного середнього



Графік прогнозу методом експоненційного ковзного середнього



Графік прогнозу методом потрійного експоненційного ковзного середнього (Холта-Вінтерса)

10

Результати реалізації методів згладжування

Метод	Характерні параметри	Test MSE	Test MAE
Ковзне середнє SMA	Вікно $N = 30$	0.0029	0.0455
	Вікно $N = 10$	0.0012	0.0281
	Вікно $N = 5$	0.0005	0.0180
Зважене ковзне середнє WMA	half-life = 12	0.0025	0.0419
	half-life = 1	0.0001	0.0089
	half-life = 0.5	0.000026	0.0037
Експоненційне ковзне середнє EMA	Рівень згладжування $\alpha = 0.1$	0.0018	0.0340
	Рівень згладжування $\alpha = 0.2$	0.0011	0.0259
	Рівень згладжування $\alpha = 0.6$	0.00049	0.0165
Подвійне експоненційне ковзне середнє	$\alpha = 0.1, \beta = 0.3$	0.00244	0.0388
	$\alpha = 0.2, \beta = 0.8$	0.00163	0.0322
	$\alpha = 0.6, \beta = 0.6$	0.00054	0.0177
Потрійне експоненційне ковзне середнє	period = 10	0.00045	0.0162
	period = 6	0.00042	0.0154

11

Реалізація методів авторегресії

Метод	Характерні параметри	Test MSE	Test MAE
Проста модель авторегресії AR	$p = 2$	0.000347	0.013322
Модель авторегресії — ковзного середнього ARMA	$p = 3, q = 1$	0.000348	0.013346
Модель авторегресії — інтегрованого ковзного середнього ARIMA	$p = 2, q = 1, d = 1$	0.000345	0.013335

12

Результати навчання багатозарового перцептрону (MLP)

#	Модель	Кількість параметрів	Training MAE	Training MSE	Test MAE	Test MSE	Алгоритм	Функція активації
1	MLP 20-10-1	221	0.0645	0.0074	0.090	0.014	adam	relu
2	MLP 20-20-1	441	0.0462	0.0038	0.052	0.005	adam	relu
3	MLP 20-100-1	2201	0.0438	0.0038	0.037	0.002	adam	relu
4	MLP 20-500-1	11001	0.0398	0.0032	0.036	0.002	adam	relu
5	MLP 30-500-1	16001	0.0387	0.0029	0.035	0.002	adam	relu
6	MLP 10-500-1	6001	0.0354	0.0025	0.034	0.002	adam	relu
7	MLP 20-100-1	2201	0.0035	0.0428	0.032	0.002	adam	tanh
8	MLP 20-100-1	2201	0.0593	0.0064	0.046	0.004	sgd	tanh
9	MLP 20-100-1	2201	0.0668	0.0078	0.093	0.014	sgd	relu
10	MLP 20-100-1	2201	0.0572	0.0064	0.059	0.005	rmsprop	relu

13

Результати навчання згорткових нейронних мереж (CNN)

#	Модель	Кількість параметрів	Training MAE	Training MSE	Test MAE	Test MSE	Алгоритм	Функція активації
1	CNN 20-256-3	199,937	0.0212	9.4573e04	0.1243	0.0216	adam	relu
2	CNN 20-256-5	201,367	0.0182	7.4266e04	0.174	0.0388	adam	relu
3	CNN 10-256-3	198,657	0.0238	0.0011	0.096	0.0137	adam	Relu
4	CNN 20-256-3	199,937	0.0513	0.0050	0.29	0.110	sgd	relu
5	CNN 20-500-3	756,501	0.0515	0.0050	0.2592	0.0890	sgd	relu
6	CNN 20-300-3	273,901	0.0342	0.0021	0.121	0.0282	prmsprop	relu
7	CNN 20-300-3	273,901	0.0414	0.0030	0.255	0.079	prmsprop	tanh

14

Реалізація рекурентних нейронних мереж (RNN)

#	Модель	Кількість параметрів	Training MAE	Training MSE	Test MAE	Test MSE	Алгоритм	Функція активації
1	LSTM 20-30-30-30-1	18,631	0.0074	1.0564e04	0.0198	0.0005	adam	relu
2	LSTM 20-30-30-40-1	22,681	0.0079	1.8716e04	0.0188	0.0005	adam	relu
3	LSTM 30-30-30-30-1	18,631	0.0106	1.9467e04	0.0159	0.0004	adam	relu
4	LSTM 10-30-30-30-1	18,631	0.0099	1.7086e04	0.0150	0.0003	adam	relu
5	LSTM 10-30-30-30-1	18,631	0.0082	1.2895e04	0.01522	0.00036	sgd	relu

15

Порівняльна таблиця реалізованих методів

Моделі	Переваги	Недоліки
Згладжування	Здатність обробляти тенденції змінних рівнів і компоненти сезонності	Вразливі до екстремальних значень
Авторегресія	Можна легко автоматизувати	Сильні обмеження в припущеннях
Штучні нейронні мережі - ANN	Можливість обробки складних нелінійних шаблонів. Висока точність прогнозу	Потребує велику кількість даних.

16

ВИСНОВКИ

- У даній магістерській атестаційній роботі були досліджені класичні методи прогнозування часових рядів та методи прогнозування часових рядів на основі використання штучних нейронних мереж, визначені їх переваги та недоліки.
- Проведено їх порівняльний аналіз та визначено їх ефективність. Порівнювалися показники прогнозування між нейромережевими та класичними методами прогнозування часових рядів на прикладі аналізу та прогнозування вартості акцій.
- На основі проведеного аналізу для реалізації прогнозування часових рядів було обрано нейронні мережі, а саме, згорткова нейронна мережа (CNN-20-256-3) та рекурентна нейронна мережа (LSTM 10-30-30-30-1).
- На основі отриманих результатів були визначені напрямки наступних досліджень.

ДОДАТОК Б



ГІБРИДНІ НЕЙРО-СИМВОЛІЧНІ МЕТОДИ ОБРОБКИ ІНФОРМАЦІЇ

Чупріна А.О., Корецька П.С.

Науковий керівник – д.т.н., проф. Корабльов М.М.
Харківський національний університет радіоелектроніки
(61166, Харків, пр. Науки, 14, каф. КІТС, тел. (057) 702-13-54)
e-mail: chupina2610@gmail.com, тел. (093) 580-50-93
e-mail: polina.koretska@nure.ua, тел. (063) 731-00-95

The given work is devoted to the modern development in the field of artificial neural networks, deep learning, but also neuro-symbolic AI. They are not new scientists have been thinking about how to model computers after the human brain for a very long time. It's only fairly recently that technology has developed the capability to store huge amounts of data and significant processing power, allowing AI systems to finally become practically useful.

Нещодавня комерційна революція штучного інтелекту була в значній мірі викликана глибокими нейронними мережами. Глибокі мережі стали самостійними, завдяки комбінації Інтернет масштабованих наборів даних і розподілених графічних процесорів. Але галузь штучного інтелекту набагато ширша, ніж тільки цей тип нейронних мереж. Алгоритми символічного мислення, такі як системи штучної логіки, можуть виявитися в центрі уваги - в деякій мірі самі по собі, а також гібридизуючись з нейронними мережами в формі так званих «нейронно-символічних».

Глибокі нейронні мережі можуть використовуватися для вирішення певних завдань, таких як розпізнавання зображень і машинний переклад. Однак для більш складних додатків традиційні підходи глибокого навчання не можуть зрівнятися зі здібностями систем гібридної архітектури, які додатково використовують інші методи штучного інтелекту, такі як імовірнісні міркування, початкові онтології і здатність самопрограмування. Глибокі нейронні мережі самі по собі не мають сильного узагальнення, тобто виявлення нових закономірностей і екстраполявання за межі навчальних наборів. Вони інтерполують і наближають те, що вже відомо, тому вони не можуть бути по-справжньому креативними в тому сенсі, в якому це можуть робити люди, хоча вони можуть використовуватися для реалізації робіт, що залежать від даних, які вони прийняли. Великі набори даних необхідні для навчання глибоких нейронних мереж, а також збільшення обсягу даних є важливим компонентом глибокого навчання. Навіть інтерполяція не може бути повністю виконана без вивчення основних закономірностей.

У цьому світлі варто відзначити, недавні успіхи в глибоких нейронних мережах які насправді є гібридними архітектурами, наприклад архітектура AlphaGo від Google DeepMind об'єднує дві нейронні мережі з одним ігровим деревом. Їх недавня архітектура MuZero, яка може справлятися

як з настільними іграми, так і з іграми Atari, йде далі цим шляхом, використовуючи глибокі нейронні мережі разом з плануванням з вивченої моделі.

Важливо відмітити те, що недоліками глибоких нейронних мереж є сильні сторони символічних систем, які за своєю природою мають композиційні, інтерпретованих і можуть демонструвати справжнє узагальнення. Попередні знання також можуть бути легко включені в символічні системи на відміну від нейронних мереж.

Як приклад практичного застосування імовірнісних нейро-символічних методів є аналіз вуличних сцен на платформі OpenCog AGI разом з глибокими нейронними мережами. Платформа OpenCog AGI надає нейронно-символічну платформу, яка багата символічної стороною і взаємодіє з популярними каркасами глибоких нейронних мереж. Вона включає в себе комбінацію імовірнісних логічних мереж (PLN), імовірнісного еволюційного навчання програмам (MOSES) і імовірнісних генеративних нейронних мереж.

Система аналітики трафіку використовує засновані на OpenCog символічні міркування поверх глибинних нейронних моделей для камер вуличних сцен, забезпечуючи такі можливості, як виявлення семантичних аномалій (маркування зіткнень, прогулянок по мосту і інших відхилень від очікування), маркування сцен без перегляду для нових камер і одноразове навчання передачі (наприклад, вивчення нових сигналів для автобусних зупинок на одному прикладі). З глибокими нейронними мережами, розгорнутими прямим способом, кожна нейронна мережа моделює те, що бачить одна камера. Формування цілісного уявлення про те, що відбувається на даному перехресті, не кажучи вже про цілий місто, є більш складним завданням. Різниця між чисто глибоким підходом нейронної мережі і нейро-символічним підходом була очевидна.

У нейронно-символічній архітектурі символічний рівень забезпечує загальну онтологію, тому всі камери можуть бути підключені до інтегрованої системи управління трафіком. Та сама архітектура може бути застосована до багатьох інших пов'язаних випадків використання, де можна використовувати нейронно-символічний штучний інтелект для збагачення локального інтелекту і з'єднання декількох джерел в цілісне уявлення для міркувань і дій. В інших, більш абстрактних галузях застосування, таких як математичне доведення теорем або біомедичне відкриття, критичне значення символічної боку нейронно-символічного гібрида ще більш значуще.

Символьний штучний інтелект потужний в маніпулюванні і моделюванні абстракцій, але погано працює з масивними емпіричними потоками даних. Ось чому ми вважаємо, що глибока інтеграція нейронних і символічних систем штучного інтелекту – найжиттєздатніший шлях до AGI рівню людини на сучасному комп'ютерному обладнанні.

