

## ДОДАТОК А

Графічний матеріал кваліфікаційної роботи

Харківський національний університет радіоелектроніки

## МЕТОДИ ПРОГНОЗУВАННЯ НЕСТАЦІОНАРНИХ ЧАСОВИХ РЯДІВ НА ОСНОВІ РЕКУРЕНТНИХ НЕЙРОННИХ МЕРЕЖ

Виконав:  
маг. гр. СПм-22-3 Близнюк О. В.

Науковий керівник:  
доц. каф. ЕОМ Іващенко Г. С.


### Актуальність задачі

Актуальність теми:

- Прогнозування часових рядів є критично важливим для багатьох галузей, таких як фінанси, медицина, енергетика, логістика та інші.
- Сучасні умови вимагають точних і швидких прогнозів для прийняття обґрунтованих рішень.

Практичне значення:

- Ефективне прогнозування може запобігти втратам, оптимізувати ресурси та підвищити ефективність управління.



## Розглянуте дослідження «Forecasting energy consumption using LSTM neural networks»

3

**Ціль дослідження:**

Прогнозування енергоспоживання з використанням LSTM.

**Аналіз часових рядів:**

Фактори: погода, час доби, день тижня, святкові дні.

Дані за останні 5 років: щогодинне споживання, температура, вологість, календарні дані.

**Розробка та навчання моделі:**

Моделі LSTM навчалась на 80% даних, тестування на 20%.

**Результат:**

Точність прогнозування: MAE = 2,5, MSE = 9,6.

Оптимізація управління для енергетичних компаній.

## Розглянуте дослідження «Weather prediction using recurrent neural networks»

4

**Ціль:**

Прогнозування погоди з використанням RNN.

**Аналіз часових рядів:**

Дані останніх 10 років з щогодинною деталізацією.

**Розробка моделі:**

Навчання RNN на 70% даних, тестування на 30%.

**Висновки:**

RNN показала точність: MAE - 1.2, MSE - 2.5, краще ніж традиційні методи.

## Постановка задачі

5

### ► Ціль:

- Розробка ефективних методів прогнозування нестационарних часових рядів за допомогою RNN.

### ► Планується:

- Проведення експериментів для оцінки впливу гіперпараметрів на результати прогнозування.

## Використовувані підходи

6

### Рекурентні нейронні мережі (RNN)

#### ► Основи:

- Обробка послідовних даних.
- Збереження контексту попередніх станів.

#### ► Типи:

- Прості RNN
- LSTM: Довгострокова пам'ять.
- GRU: Спрощена LSTM.

#### Застосування:

- Часові ряди, текст, мова.

#### Переваги:

- Врахування попередніх даних.
- Гнучкість.

#### Виклики:

- Проблеми з навчанням.
- Високі обчислювальні вимоги.

## Використовувані технології

### ► Використані технології

- **PyCharm:** середовище розробки для мови Python.
- **Pandas:** обробка та аналіз даних.
- **NumPy:** числові обчислення.
- **Matplotlib:** візуалізація даних.
- **Scikit-learn:** попередня обробка даних.
- **TensorFlow/Keras:** створення та навчання моделей RNN.
- **CSV:** збереження результатів.

## Експеримент: вплив кількості епох


- Фіксовані параметри: Розмір пакета = 32, горизонт прогнозу = 60, розмір вікна = 60.



| № | epochs | MAE         |
|---|--------|-------------|
| 1 | 10     | 432,538105  |
| 2 | 20     | 538,8836417 |
| 3 | 30     | 720,51431   |
| 4 | 40     | 504,2608033 |
| 5 | 50     | 414,938895  |
| 6 | 100    | 798,7181417 |
| 7 | 200    | 387,615905  |
| 8 | 400    | 445,1998941 |

## Експеримент: вплив розміру пакета

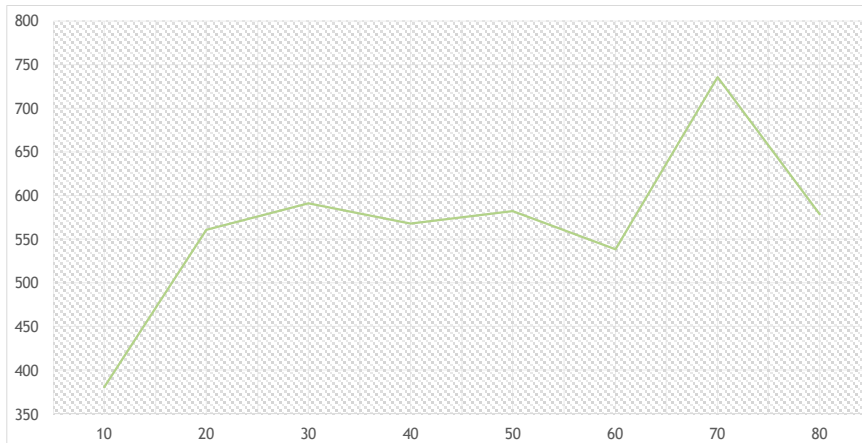
- Фіксовані параметри: Епохи = 50, горизонт прогнозу = 60, розмір вікна = 60.



| № | batch_size | MAE         |
|---|------------|-------------|
| 1 | 4          | 376,8841933 |
| 2 | 8          | 226,0692767 |
| 3 | 16         | 298,6666667 |
| 4 | 32         | 538,8836417 |
| 5 | 64         | 838,9370217 |
| 6 | 128        | 735,8446367 |
| 7 | 256        | 692,5444767 |
| 8 | 512        | 464,2444767 |

## Експеримент: вплив горизонту прогнозу

- Фіксовані параметри: Епохи = 50, розмір пакета = 32, розмір вікна = 60.



| № | horizont | MAE         |
|---|----------|-------------|
| 1 | 10       | 380,64595   |
| 2 | 20       | 561,054165  |
| 3 | 30       | 591,5938533 |
| 4 | 40       | 567,704755  |
| 5 | 50       | 582,081448  |
| 6 | 60       | 538,8836417 |
| 7 | 70       | 735,6843657 |
| 8 | 80       | 578,2885225 |

## Експеримент: вплив розміру вікна

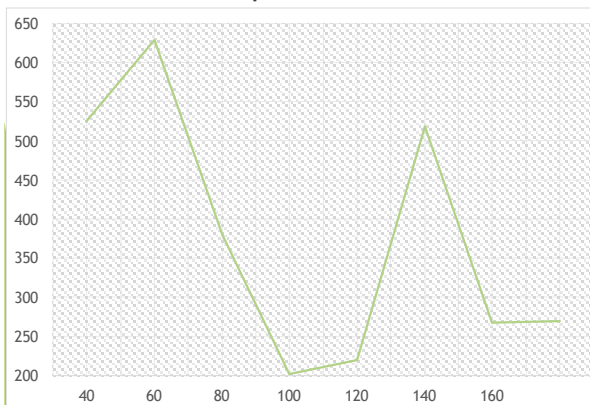
- Фіксовані параметри: Епохи = 50, розмір пакета = 32, горизонт прогнозу = 60.



| № | Window_size | MAE         |
|---|-------------|-------------|
| 1 | 20          | 501,6021617 |
| 2 | 40          | 718,8064467 |
| 3 | 60          | 795,3677633 |
| 4 | 80          | 856,4461783 |
| 5 | 100         | 651,6773917 |
| 6 | 120         | 760,8953783 |
| 7 | 140         | 766,7327533 |
| 8 | 160         | 623,05766   |

## Експеримент: вплив кількості нейронів у шарах

- Фіксовані параметри: Епохи = 50, розмір пакета = 32, горизонт прогнозу = 60, розмір вікна = 60, кількість шарів = 3.



| № | Нейронів у шарі (3 шари) | MAE         | MAPE        |
|---|--------------------------|-------------|-------------|
| 1 | 40                       | 524,9315837 | 8,272021379 |
| 2 | 60                       | 628,4324137 | 9,873688085 |
| 3 | 80                       | 379,9315999 | 5,959300303 |
| 4 | 100                      | 201,9811442 | 3,232335981 |
| 5 | 120                      | 219,8934163 | 3,534161258 |
| 6 | 140                      | 518,7171387 | 8,154393758 |
| 7 | 160                      | 268,1054362 | 4,239372226 |
| 8 | 180                      | 269,90271   | 4,246480152 |

## Висновки

- Ефективність RNN:** RNN є ефективним методом для прогнозування нестационарних часових рядів, показуючи високу точність і робастність.
- Обмеження RNN:** Виявлено складність навчання та високі обчислювальні витрати, що є основними обмеженнями у застосуванні RNN.
- Необхідність досліджень:** Потребується подальше дослідження для оптимізації та підвищення ефективності RNN в прогнозуванні часових рядів.
- Майбутній розвиток:** З розвитком технологій та оптимізації методів можна очікувати подальшого зростання використання RNN для прогнозування часових рядів.
- Публікація:** В процесі роботи опублікована стаття на тему «Моделі глибокого навчання для прогнозування часових рядів» у журналі «Системи управління навігації та зв'язку», №1(75).

## ДОДАТОК Б

## Фрагмент вихідного коду розробленого програмного засобу

```

import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense, LSTM, Dropout
data = pd.read_csv('nasdaq.csv', date_format = True)
data.head(10)
data_training = data[data['Date']<'2023-01-01'].copy()
data_test = data[data['Date']>='2023-01-01'].copy()
data_training = data_training.drop(['Date', 'Adj Close'], axis =
1)
scaler = MinMaxScaler()
data_training = scaler.fit_transform(data_training)
window_size = 60
data_training[0:5]
X_train = []
y_train = []
for i in range(window_size, data_training.shape[0]):
    X_train.append(data_training[i-window_size:i])
    y_train.append(data_training[i, 0])
X_train, y_train = np.array(X_train), np.array(y_train)
model = Sequential()
model.add(LSTM(units = 60, activation = 'relu', return_sequences
= True, input_shape = (X_train.shape[1], X_train.shape[2])))
model.add(Dropout(0.2))
model.add(LSTM(units = 60, activation = 'relu', return_sequences
= True))
model.add(Dropout(0.2))
model.add(LSTM(units = 80, activation = 'relu', return_sequences
= True))
model.add(Dropout(0.2))
model.add(LSTM(units = 120, activation = 'relu'))
model.add(Dropout(0.2))
model.add(Dense(units = 1))
model.compile(optimizer='adam', loss = 'mean_squared_error')
model.fit(X_train, y_train, epochs=50, batch_size=32)
data_test.head()
data_training = data[data['Date']<'2023-01-01'].copy()
past_days = data_training.tail(window_size)
df = pd.concat([past_days, data_test], ignore_index=True)
df = df.drop(['Date', 'Adj Close'], axis = 1)
df.head()
inputs = scaler.transform(df)
inputs
max_forecast_horizon = 60

```

```

X_test = []
y_test = []
for i in range(window_size, min(inputs.shape[0], window_size +
max_forecast_horizon)):
    X_test.append(inputs[i-window_size:i])
    y_test.append(inputs[i, 0])
X_test, y_test = np.array(X_test), np.array(y_test)
X_test.shape, y_test.shape
y_pred = model.predict(X_test)
scaler.scale_
scale = 1/scaler.scale_[0]
scale
y_pred = y_pred*scale
y_test = y_test*scale
results_df = pd.DataFrame({'Date': data_test['Date'].values[-
y_test.shape[0]:],
                           'Actual': y_test,
                           'Predicted': y_pred.flatten()})
merged_df = pd.merge(data_test, results_df, on='Date',
how='inner')
mae = np.mean(np.abs(merged_df['Actual'] -
merged_df['Predicted']))
mape = np.mean(np.abs((merged_df['Actual'] -
merged_df['Predicted']) / merged_df['Actual'])) * 100
summary_df = pd.DataFrame({'Date': [None],
                           'Actual': [None],
                           'Predicted': [None],
                           'MAE': [mae],
                           'MAPE': [mape]})
summary_df = summary_df.dropna(axis=1, how='all')
final_df = pd.concat([summary_df, merged_df], ignore_index=True)
final_df.to_csv('таблица.csv', index=False, columns=['Date',
'Actual', 'Predicted', 'MAE', 'MAPE'])
plt.figure(figsize=(14,5))
plt.plot(merged_df['Date'], merged_df['Actual'], color='red',
label='Real Nasdaq Stock Price')
plt.plot(merged_df['Date'], merged_df['Predicted'],
color='blue', label='Predicted Nasdaq Stock Price')
plt.title('Nasdaq Stock Price Prediction')
plt.xlabel('Time')
plt.ylabel('Nasdaq Stock Price')
plt.legend()
plt.xticks(plt.xticks()[0][::5], rotation=25)
plt.savefig('график.png', bbox_inches='tight')

```