

МОДЕЛЬ ПРОГНОЗУВАННЯ ТОПОЛОГІЧНИХ ЗМІН ЛІТАЮЧИХ СЕНСОРНИХ МЕРЕЖ НА ОСНОВІ ВИКОРИСТАННЯ РЕКУРЕНТНИХ НЕЙРОННИХ МЕРЕЖ

¹Кошмак А.І., ¹Лисенко О.І., ²Алексєєва І.В., ¹Новіков В.І.

*¹Навчально-науковий Інститут телекомунікаційних
систем КПІ ім. Ігоря Сікорського, Україна*

*²Фізико-математичний факультет КПІ ім. Ігоря Сікорського, Україна
E-mail: novikov1967@ukr.net*

A MODEL FOR PREDICTING TOPOLOGICAL CHANGES IN FLYING SENSOR NETWORKS BASED ON THE VICINITY OF RECURRENT NEURAL NETWORKS

To achieve a high level of adaptability of routing methods in flying sensor networks, a vicarious model for predicting topological changes based on the vicarious recurrent neural networks using a long short-term memory.

Розвиток технологій літаючих сенсорних мереж (ЛСМ) відкриває нові можливості для передачі, обробки та аналізу інформації [1-3]. У зв'язку з необхідністю забезпечення ефективної маршрутизації в ЛСМ, виникає потреба у вдосконаленні існуючих та створенні нових методів маршрутизації, які враховують специфіку таких мереж, пов'язану з динамічними змінами топології, обмеженими енергетичними ресурсами, високою мобільністю вузлів та складністю середовища передачі даних. Урахування та інтеграція цих аспектів є необхідною умовою для забезпечення стабільної та надійної роботи ЛСМ в умовах складних і динамічних сценаріїв експлуатації.

Для досягнення високого рівня адаптивності методів маршрутизації у ЛСМ було запропоновано використання моделі прогнозування топологічних змін на основі використання рекурентних нейронних мереж (РНМ, англ. Recurrent neural network, RNN) із механізмом довгої короткочасної пам'яті (англ. Long short-term memory, LSTM) [4]. Структурна схема запропонованого рішення, яка відображає основні етапи обробки даних, включаючи прогнозування та оновлення маршрутів представлено на рис. 1.

На схемі зображено, як дані з сенсорів, що збирають координати вузлів і їхню швидкість, подаються у вигляді часових рядів на вхід модулю прогнозування. Цей модуль складається з кількох шарів LSTM, які аналізують часові залежності в рухах вузлів і формують прогноз майбутніх положень. На основі отриманого прогнозу виконується оцінка стабільності з'єднань між вузлами, і за необхідності коригуються маршрути передачі даних.

Рекурентна нейронна мережа отримує на вхід три основні параметри: координати вузлів (x , y) та їхню швидкість. Модель спочатку проходить навчання на синтетичних або реальних даних, які відображають поведінку вузлів у різних сценаріях. Під час роботи мережі прогнозовані значення координат дозволяють передбачити розриви зв'язків у мережі та забезпечити своєчасне оновлення маршрутів.




Рис. 1. Структурна схема прогнозування топологічних змін та оновлення маршрутів у ЛСМ.

Реалізація нейронної мережі відбувається через бібліотеку TensorFlow. У запропонованому коді на рис. 2 описана модель, яка використовує два шари LSTM для вилучення залежностей з даних. Перший шар забезпечує обробку короткочасних залежностей, а другий фокусується на довгих взаємозв'язках між вузлами мережі. Для запобігання перенавчанню використовується регуляризація у вигляді Dropout.

Запропонований код демонструє основний процес створення та навчання рекурентної нейронної мережі для прогнозування майбутніх положень вузлів у літаючих сенсорних мережах. Ця мережа використовує вхідні послідовності даних, які містять координати вузлів (x , y) та їхню швидкість (v), щоб передбачати їхні майбутні параметри. Такий підхід дозволяє алгоритмам маршрутизації заздалегідь враховувати можливі зміни топології мережі.

Архітектура моделі побудована на базі двох шарів довгої короткочасної пам'яті, що є основою для обробки часових залежностей. LSTM-шари здатні зберігати інформацію про попередні стани в мережі, дозволяючи моделі враховувати динаміку змін у русі вузлів. Перший LSTM-шар обробляє

короткочасні залежності між вхідними даними, тоді як другий фокусується на довготривалих взаємозв'язках, що є важливим для складних сценаріїв динамічних мереж. Додатково використовується регуляризація у вигляді Dropout. Dropout знижує ймовірність перенавчання, випадково виключаючи частину нейронів із процесу навчання. Це забезпечує стійкість моделі до змін у даних та покращує її узагальнюючі здібності.

Навчання моделі здійснюється за допомогою навчальних даних (`x_train` та `y_train`), які представляють часові послідовності координат вузлів та їхніх швидкостей, а також прогнозовані значення для наступних часових кроків. Важливою частиною цього процесу є використання валідаційних даних, що дозволяють оцінити продуктивність моделі на раніше невідомих наборах даних. Такий підхід запобігає перенавчанню та забезпечує можливість адаптації до реальних сценаріїв роботи мережі.

```
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout

input_dim = 3
output_dim = 3
time_steps = 10

model = Sequential([
    LSTM(64, return_sequences=True, input_shape=(time_steps, input_dim)),
    Dropout(0.2),
    LSTM(32, return_sequences=False),
    Dropout(0.2),
    Dense(output_dim, activation='linear')
])

model.compile(optimizer='adam', loss='mean_squared_error')

history = model.fit(
    x_train, y_train,
    epochs=50,
    batch_size=32,
    validation_data=(x_val, y_val)
)
```

Рис. 2. Код для реалізації прогнозування топологічних змін у ЛСМ із використанням LSTM.

Ключовим компонентом є функція втрат, яка в цьому випадку представлена середньоквадратичною похибкою (`mean_squared_error`). Ця

функція використовується для оцінки точності моделі, визначаючи різницю між реальними координатами вузлів та передбаченими. Оптимізація здійснюється за допомогою алгоритму Adam, що дозволяє ефективно налаштовувати ваги нейронної мережі та забезпечує швидку збіжність навіть для великих наборів даних.

Результатом навчання є модель, яка може обробляти поточні дані з вузлів мережі, прогножуючи їхні майбутні положення. Наприклад, у реальній системі модель отримує на вхід послідовності даних про координати та швидкості вузлів, обробляє їх через LSTM-шари та видає прогнозовані значення координат. Ці значення передаються маршрутизатору, який на основі прогнозу оновлює маршрути передачі даних. Це дозволяє забезпечити безперервність з'єднання, зменшити затримки передачі та уникнути втрат пакетів у мережі.

Таким чином, запропонований підхід дозволяє інтегрувати прогнозування топологічних змін у процес маршрутизації. Окрім високої точності, модель демонструє гнучкість та стійкість до змін у топології мережі. Подальші вдосконалення можуть включати оптимізацію архітектури моделі, вибір гіперпараметрів або використання глибших мереж для обробки складніших залежностей.

Література

1. Ільченко М.Ю., Кравчук С.О. Телекомунікаційні системи. – Київ: Наукова думка, 2017. – 730 с. Досягнення в телекомунікаціях 2019 / за наук. ред. М.Ю.Ільченка, С.О.Кравчука: монографія. - Київ: Інститут обдарованої дитини НАПН України, 2019.- 336 с.
2. Міночкін А.І., Романюк В.А., Жук О.В. Перспективи розвитку тактичних сенсорних мереж// Збірник наукових праць №4. – К.: ВІТІ НТУУ “КПІ”. – 2007. – С. 112 – 119.
3. Лисенко О.І., Романченко І.С., Чумаченко С.М., Данилюк С.Л., Новіков В.І., Тачиніна О.М., Кірчу П.І., Валуйський С.В. Моделі застосування інформаційно-телекомунікаційних технологій на основі безпілотних авіаційних комплексів у надзвичайних ситуаціях. – К.: НАУ, 2016. – 332 с.
4. Dupond S. A thorough review on the current advance of neural network structures //Annual Reviews in Control. – 2019. – Т. 14. – №. 14. – С. 200-230.