

УДК 629.423.3:681.518.54

Прогнозування технічного стану тягових редукторів електропоїздів нейромережею довгої короткострокової пам'яті

Пузир¹ В. Г., Михалків¹ С. В., Ходаківський¹ А. М., Бульба² В. І.

1 – Український державний університет залізничного транспорту, м. Харків, Україна

2 – Регіональна філія «Південна залізниця» ПАТ «Укрзалізниця», м. Харків, Україна

Для здійснення прогнозування технічного стану тягових редукторів електропоїздів запропоновано використовувати нейромережу довгої короткострокової пам'яті. На кожному технічному обслуговуванні (ТО-3) реєструвалися вібраційні реалізації попередньо відібраних чотирнадцяти тягових редукторів і розраховувалася фрактальна розмірність покриття. Прогнозування технічного стану здійснювалось із 61-го ТО-3 і до 70-го ТО-3 з наступним порівнянням розрахованої та прогнозованої фрактальної розмірності. Після розбирання 6 тягових редукторів на потоковому ремонті (ПП-1) було виявлено недостатню кількість мастила в одному редукторі, знос ролика підшипника передньої кришки другого редуктора, тріщину кільця підшипника передньої кришки третього редуктора, відкол зуба шестірні четвертого тягового редуктора, руйнування підшипника п'ятого редуктора і тріщина зуба його шестірні та справний шостий редуктор. Установлена здатність нейромережі LSTM демонструвати нижчу середньоквадратичну помилку після оновлення

Ключові слова: електропоїзд; прогнозування; нейромережа; тяговий редуктор; фрактальна розмірність

Прогнозування технічного стану відповідального обладнання машинобудівної промисловості й транспортної галузі є вкрай важливим завданням, розв'язання якого дозволить скоротити кількість відмов і заощадити суттєві ресурси. У прогнозуванні набули поширення детерміновані методи експоненційного згладжування, аналізу тренду й стохастичні методи. Останніми роками все більшої уваги привертають методи глибокого навчання, які позбавлені потреби здійснювати припущення щодо визначення залежності в моделі та автоматично визначають згадану залежність упродовж процесу навчання даних. У часових рядах є одна змінна та її попередні значення й завжди наявне припущення про випадковий вплив чинників з навколишнього середовища на змінну, величина якої має прогнозуватись, тому висновок про майбутню поведінку часових рядів робиться з їх попередніх значень. Зокрема прогнозування нейронними мережами зі структурою автокодування продемонструвало неспроможність виділяти залежні від часу ознаки, зважаючи на часову залежність даних, що подаються на вхід цих мереж. Усувати цей недолік і створювати часову залежність між послідовностями дозволяють рекурентні нейронні мережі (RNN), однак і вони не здатні запам'ятовувати довготривалу попередню інформацію. Ба більше, RNN володіють проблемою градієнтного зникнення в процесі зворотного розповсюдження помилки. Набагато кращі результати й потенціал демонструє нейромережа довгої короткострокової пам'яті (LSTM) у якій відбулася зміна в обчисленні вузлів завдяки підведенню попередньої інформації, що забезпечило отримання автокореляційних ознак і досягнуті результати в розпізнаванні мови та в інших додатках [1 — 3].

Перший крок у LSTM здійснює сигмоїдальний шар «шар фільтру забуття» (рис. 1), вага шару забуття W_f якого визначає інформацію, яку можна прибрати зі стану елемента. Цей шар аналізує вихідне h_{t-1} й вхідне x_t значення та повертає число від 0 до 1 для кожного числа зі стану елемента C_{t-1}

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

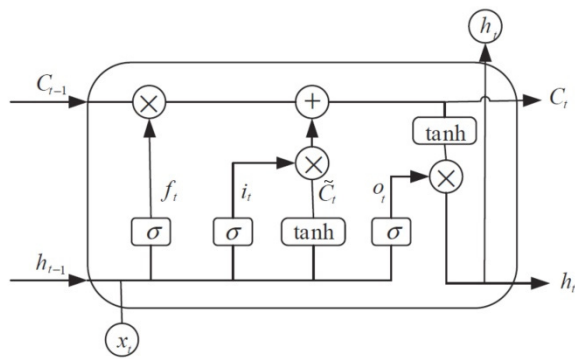


Рис. 1. Модель нейромережі LSTM

Наступний крок складається з двох частин, де вирішується яку нову інформацію зберігати в елементі. Спочатку сигмоїдальний шар «шар вхідного фільтру» визначає які значення потребують оновлення

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (2)$$

далі tanh-шар будує вектор нових значень-кандидатів \tilde{C}_t , які можна додати до стану елемента

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

У подальшому відбувається заміна старого стану елемента C_{t-1} на новий стан C_t

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

Вихід із шару вихідного фільтру

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

Вихід нейромережі LSTM

$$h_t = o_t * \tanh(C_t) \quad (6)$$

Експериментальні дослідження проводилися вибірково на чотирнадцяти тягових редукторах трьох електропоїздів серії EP2T [4]. На кожному ТО-3 та ПР-1 в оглядовому стійлі здійснювалася реєстрація вібраційних реалізацій чотирнадцяти тягових редукторів з боку підшипника кочення передньої кришки редуктора. Реєстрація відбувалася на шістдесяти шести ТО-3 та чотирьох ПР-1. Розбирання відбулося на п'ятому ПР-1. Для кожного із зареєстрованих вібраційних реалізацій розраховувалась фрактальна розмірність покриття. Прогнозування технічного стану здійснювалось із 61-го ТО-3 і до 70-го ТО-3 з наступним порівнянням розрахованої та прогнозованої фрактальної розмірності. Із чотирнадцяти редукторів справними виявилися дев'ять, решта мали такі несправності:

- 1) недостатня кількість мастила в редукторі;
- 2) знос ролика підшипника передньої кришки редуктора;
- 3) тріщина кільця підшипника передньої кришки редуктора;
- 4) відкол зуба шестерні редуктора;
- 5) руйнування підшипника передньої кришки редуктора й тріщина зуба шестерні.

Точність прогнозування оцінюється за величиною середньоквадратичної помилки (RMSE) й зведена в таблицю 1 [5]

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

де \hat{y}_i — прогнозовані значення фрактальної розмірності;

u_i — зареєстровані значення фрактальної розмірності;
 n — кількість ТО-3 (рис. 2).

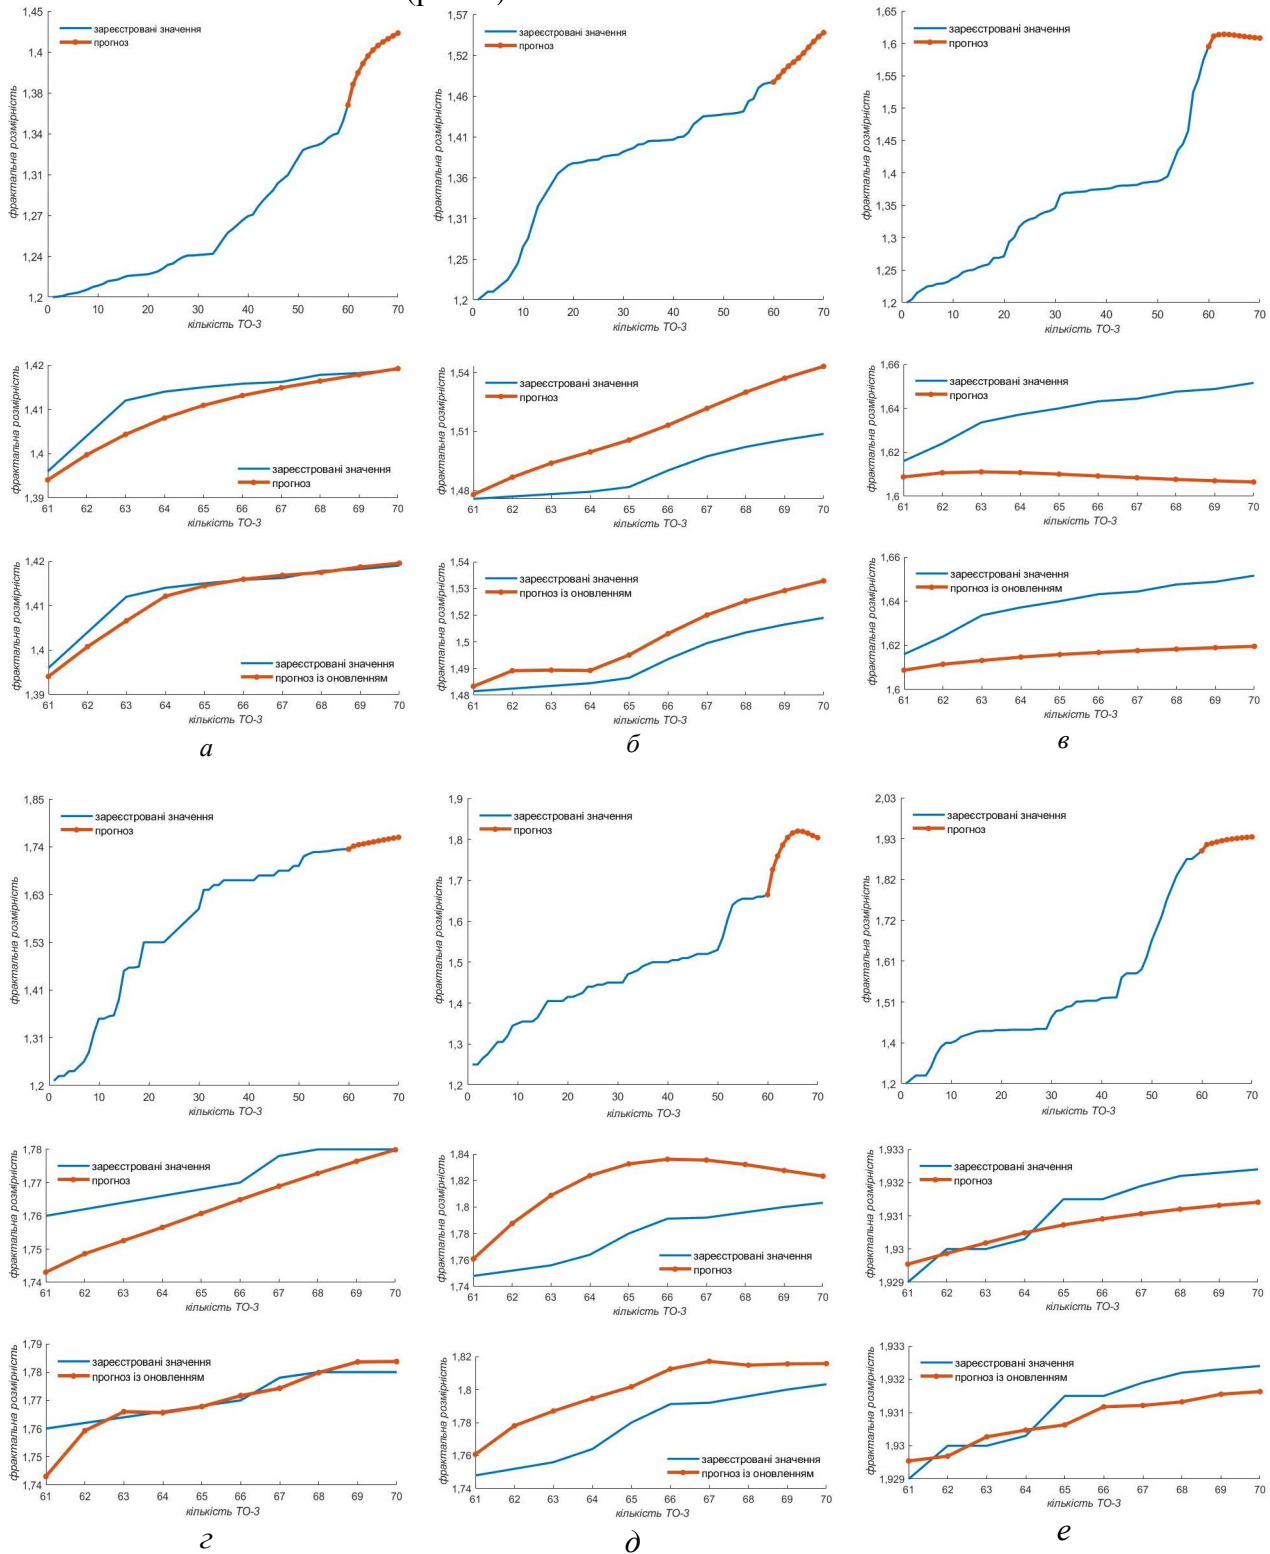


Рис. 2. Прогнозування значень фрактальної розмірності тягових редукторів у різних технічних станах: *а* — справний; *б* — недостатня кількість мастила; *в* — знос ролика підшипника передньої кришки редуктора; *з* — тріщина кільця підшипника передньої кришки редуктора; *д* — відкол зуба шестерні редуктора; *е* — руйнування підшипника передньої кришки редуктора й тріщина зуба шестерні.

Установлено, що наявний доступ до фактичних значень часових рядів між прогнозами дозволяє оновлювати стан мережі й робити прогнозування точнішим із постійно меншою величиною RMSE.

Таблиця 1

Точність прогнозування нейромережею LSTM

	Види несправностей тягових редукторів					
	<i>справний</i>	<i>1) вид</i>	<i>2) вид</i>	<i>3) вид</i>	<i>4) вид</i>	<i>5) вид</i>
RMSE прогнозування	$1,9 \cdot 10^{-3}$	$3,9 \cdot 10^{-3}$	$7,9 \cdot 10^{-3}$	$4,8 \cdot 10^{-4}$	0,01	$7,1 \cdot 10^{-4}$
RMSE прогнозування з оновленням	$1,1 \cdot 10^{-3}$	$1,9 \cdot 10^{-3}$	$6,1 \cdot 10^{-3}$	$2,9 \cdot 10^{-4}$	$5,6 \cdot 10^{-3}$	$6,1 \cdot 10^{-4}$

Зважаючи на вищу тривалість обчислення нейронними мережами та їх складну архітектуру, а також на брак чітких або емпіричних правил із вибору найкращої моделі для прогнозування технічного стану обладнання локомотивів та електропоїздів, доцільно обирати ту модель, яка володіє найменшими помилками за результатами моделювання, де дослідник має шукати компроміс між точністю прогнозування та складністю метода, якщо точність однакова, то переваги надаються простішому методу.

Список літератури

1. Zhou F. RUL prognostics method based on real time updating of LSTM parameters / F. Zhou, P. Hu, X. Yang // Chinese Control and Decision Conference (CCDC), 9 — 12 June 2018: proceedings. — Shenyang, 2018 — P. 3966 — 3971. <https://doi.org/10.1109/CCDC.2018.8407812>
2. Tai K. S. Improved Semantic Representations From Tree-Structured Long Short-Term Memory Networks / K. S. Tai, R. Socher, C. D. Manning // 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing, July 2015.: proceedings. — Beijing, China, 2015. — P. 1556 — 1566. <https://doi.org/10.3115/v1/P15-1150>
3. Wu Y. Remaining Useful Life Estimation of Engineered Systems using vanilla LSTM Neural Networks / Y. Wu, M. Yuan, S. Dong, L. Lin, Y. Liu // Neurocomputing. — 2018. — Vol. 275. — P. 167 — 179. <https://doi.org/10.1016/j.neucom.2017.05.063>
4. Пузир В. Г. Обчислення частотних смуг вібрації підшипників тягового редуктора електропоїзда кратномасштабним аналізом / В. Г. Пузир, С. В. Михалків, А. М. Ходаківський, В. І. Бульба // Збірник наукових праць Українського державного університету залізничного транспорту. — 2019. — Вип. 185. — С. 32 — 44. <https://doi.org/10.18664/1994-7852.185.2019.180784>
5. Jin X. Prediction for Time Series with CNN and LSTM / X. Jin, X. Yu, X. Wang, Y. Bai, T. Su, J. Kong // Lecture Notes in Electrical Engineering, vol 582: 11th International Conference on Modelling, Identification and Control (ICMIC2019), 2020.: proceedings. — Springer, Singapore, 2020. — P. 631 — 641. https://doi.org/10.1007/978-981-15-0474-7_59

The forecasting of the technical state of the traction gearboxes of electric trains with long-short-term memory network

Puzyr Volodymyr, Mykhalkiv Serhii, Khodakivskyi Andrii, Bulba Vladyslav

For the forecasting of the technical state, among the broadcast deterministic methods of exponential smoothing and trend analysis, the most effective long-short-term memory neural network (LSTM) was selected. During every 3rd level maintenance, the vibration signals of the previously selected fourteen traction gearboxes were recorded, and the box counting dimension was estimated. The forecasting of the LSTM neural network was done for the period since the 61st up to the next 70th 3rd level maintenance. After disassembling 14 traction gearboxes during the 5th 1st level current repair, the insufficient amount of a lubricant in the first gearbox, wear of a roller bearing of the front cover in the second gearbox, a crack of a bearing ring of the front cover in the third gearbox, a tooth break of a gear in the fourth traction gearbox, destruction of a bearing in the fifth gearbox and a tooth crack of its gear were detected. It was established that the LSTM neural network had a lower root-mean-square error when the information was updated.

Keywords: box counting dimension; electric train; forecasting; neural network; traction gearbox