

УДК 681.5.

Лабжинський В. А. канд. тех. наук, доцент

Національний технічний університет України «Київський політехнічний інститут ім. Ігоря Сікорського»

## ПРОГНОЗУВАННЯ СТАНУ СКЛАДНИХ ТЕХНІЧНИХ СИСТЕМ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ ГЛИБИННОГО НАВЧАННЯ

**Лабжинський В. А. Прогнозування стану складних технічних систем за допомогою нейронних мереж глибинного навчання.** У рамках даної роботи проведено систематичний аналіз теорії керування з прогнозуючими моделями. Розроблено методологію побудови систем прогнозування на базі нейронних мереж глибинного навчання. В результаті узагальнення сучасних розробок у даній галузі створено універсальну математичну модель прогнозування і контролю. Розроблена модель забезпечує задовільну ідентифікацію протікання системних процесів, базуючись на критерії стійкості за Ляпуновим та нелінійної авторегресійної екзогенної моделі. Адекватність даного математичного апарату показано на прикладі МІМО-системи зв'язку.

**Ключові слова:** керування з прогнозуючими моделями, глибинне навчання, нейромережеві моделі, критерій стійкості за Ляпуновим, нелінійна авторегресійна екзогенна модель.

**Лабжинский В. А. Прогнозирование состояния сложных технических систем за помощью нейронных сетей глубинной учебы.** В рамках данной работы проведен систематический анализ теории управления с прогнозирующими моделями. Разработана методология построения систем прогнозирования на базе нейронных сетей глубинной учебы. В результате обобщения современных разработок в данной отрасли создана универсальная математическая модель прогнозирования и контроля. Разработанная модель обеспечивает удовлетворительную идентификацию протекания системных процессов, базируясь на критерии стойкости за Ляпуновым и нелинейной авторегрессионной экзогенной модели. Адекватность данного математического аппарата показана на примере МІМО-системы связи.

**Ключевые слова:** управление с прогнозирующими моделями, глубинная учеба, нейросетевые модели, критерий стойкости за Ляпуновым, нелинейная авторегрессионная экзогенная модель.

**Labzhynskiy V. A. Forecasting the status of complex technical systems through the neural networks of deep learning.** Nowadays artificial neural network model predictive control is widely used in the area of automatic control. There was performed systematic analysis of different cases of application of model predictive control. We analyzed a control scheme for the multi-variable nonlinear steel pickling process, multi-joint robotic manipulator with a cubic trajectory and random disturbances, robust control of a pH neutralization process, nonlinear model predictive controller applied to a pneutralization process, etc. It was shown that the appearance of external disturbances and internal system parameter variations affect the prediction system output by inducing steady state error. To overcome the problem was proposed to use deep neural network model predictive controller system. To provide the convergence of the adaptive process during artificial neural weights coefficients network updating there was used Lyapunov stability theory. Lyapunov stability theory algorithm allows to update the control signal of the predictive controller model. It was proposed to linearize the neural model locally by Taylor series and use of the Lyapunov function that depends on the square norm of the tracking error. Updating of the weights of the artificial neural network up to the procedure provide convergence of the neural weights. Deep neural network predictor should be linearized during updating stage which allows achieving the local stability of the process around the current operating point. Also resources of the deep neural network could be used to express nonlinear systems. There was exploited the approximation ability of deep artificial neural network which allowed to establish robustness to internal system variations and external disturbances. Development of update laws of the artificial neural network weights helped to stabilize training process up to the Lyapunov criteria. By ensuring of the satisfactory identification of the unknown system process, which have to be analyzed and predicted by applying Lyapunov criteria it was calculated the update control signal. The procedure was performed by analyzing of the error between the output of the deep artificial neural network and the desired output which should be converged to zero value according to Lyapunov stability theory. There were shown simulation results for two satisfactory cases of model approbation for nonlinear MIMO system.

**Keywords:** model predictive control, artificial neural network model, deep learning, Lyapunov stability criteria, nonlinear autoregressive exogenous modeling.

**1. Вступ.** Керування з прогнозуючими моделями (MPC: Model Predictive Control) на сьогоднішній день є одним з найбільш ефективних методів теорії керування динамічними системами [1-5], що активно використовується у промисловості, енергетиці, робототехніці, сфері побудови наукового експерименту, тощо. Базисом даної теорії є передбачення поведінки об'єкта керування на різні типи входних впливів, при цьому модель об'єкта керування може бути лінійною або нелінійною, а стратегія керування обирається такою, щоб враховувати взаємозв'язки між параметрами, що описують стан об'єкта керування, а також обмеження, що накладаються ключовими елементами системи. У рамках теорії керування динамічними системами розглядається можливість обрання найкращої траєкторії зміни станів системи з повної множини потенційно можливих станів.

Важливою проблемою методики керування з прогнозуючими моделями є визначення балансу між точністю моделі, що дозволяє підвищує вірогідність отримання потрібного рівня

якості керування та зменшення рівня чутливості системи керування до помилок процесу, що зростає разом зі збільшенням точності моделі. Іншою проблемою підвищення точності є збільшення складності моделі, збільшення кількості ітерацій, що подекуди виходить за межі ресурсоемності апаратного комплексу та обмежень на термін виконання програмного алгоритму. Ефективним рішенням даної проблеми виступає побудова систем керування на основі нейромережових моделей (НММ), зокрема НММ глибинного навчання [6-8].

**Аналіз останніх досліджень і публікацій** у даній галузі вказує на те, що нейромережові системи MPC можуть розглядатися як ефективне оптимізаційне рішення у багатьох областях, де потребуються машинні методи прогнозування стану складної системи [9-16]. У представлених роботах були розглянуті методики застосування нейромережових систем прогнозування і контролю у металургії та хімічній промисловості [7, 8], промисловій робототехніці [9-12], а також складні системи, що включають у себе роботу з розпізнавання природної мови (natural language processing) та візуальних образів [13-16]. Проведений аналіз вказав на актуальні підходи до математичного моделювання у даній галузі [17-28] та показав необхідність побудови цілісної методології прогнозування складних систем та керування з прогнозуючими моделями, що у рамках даної роботи **виділяється як не вирішена частина загальної проблеми** побудови нейромережових алгоритмів керування.

**Метою дослідження**, таким чином, є проведення систематичного аналізу теорії MPC та отримання математичної апарату, що базується на критерії стійкості динамічної системи Ляпунова (Lyapunov stability theory) для НММ глибинного навчання [17-20].

## 2. Базова модель побудови нейромережових алгоритмів MPC

Універсальна архітектура застосування НММ глибинного навчання у системах керування з прогнозуючими моделями показана на рис. 1. Базова НММ складається з шару вхідних нейронів  $X_i$ , шарів прихованих нейронів  $H_{i|j}$  (на рис. 1 їх позначено темно-сірим кольором), шару вихідних нейронів  $Y_i$  та нейронів зміщення  $B_i$ . У даної НММ  $p$  входів,  $m$  виходів та  $p$  прихованих шарів.




Рис. 1. Архітектура застосування НММ глибинного навчання у системах MPC.

Вихідний вектор кожного прихованого шару може бути охарактеризовано через  $H_i(k)$ , де  $i \in [1..p]$ , вхідні вектори всієї НММ через  $U(k)$ , вихідні вектори всієї НММ, відповідно, через  $Y(k)$ , а вагові коефіцієнти через матрицю  $W^{(i-1,i)}(k)$ :

$$\begin{cases} H_i(k) = f(W^{(i-1,i)}(k) \cdot H_i(k-1)) \\ \quad \quad \quad i = 2..p \\ H_1(k) = f(W^{(0,1)}(k) \cdot U(k)) \\ Y(k) = f(W^{(p,p+1)}(k) \cdot H_p(k)) \end{cases} \quad (1)$$

Слід зауважити, що для нейромережових MPC  $f()$  представляє собою нелінійну передавальну функцію.

Введемо поняття вектору  $\theta(k)$ , що утримує усі вагові коефіцієнти НММ під час ітерації  $k$ , а також перейдемо до нелінійного відображення системи НММ:  $Y(k) \rightarrow G(U(k), \theta(k))$ . Нехай для кожного  $U(k)$  бажане значення вихідного вектору  $Y(k)$  складає  $\tilde{Y}(k)$ , відповідний  $\tilde{Y}(k)$  ваговий вектор може бути визначено як  $\tilde{\theta}(k-1)$ . Таким чином бажаний результат навчання НММ можна описати математично у вигляді ряду Тейлора, як

$$Y(k) = G(U(k), \theta(k)) + \hat{J}(\theta(k)) \cdot (\theta(k) - \tilde{\theta}(k-1)) + \xi(k), \quad (2)$$

де  $\hat{J}(\theta(k))$  — матриця Якобі функції  $G()$  для  $\theta(k) = \tilde{\theta}(k-1)$ , яка у даному випадку застосовується як матриця спостережень (observation matrix), а  $\xi()$  — член більш високого порядку ряду Тейлора.

У такому разі вихідний вектор  $Y(k)$ , а також його лінеаризоване значення  $\tilde{Y}(k)$  для НММ глибинного навчання системи MPC під час ітерації  $k$  становитимуть :

$$\begin{cases} Y(k) = F_k(k) \cdot \theta(k) + \eta(k) + \xi(k) \\ \eta(k) = G(U(k), \tilde{\theta}(k-1)) \cdot (1 - F_k(k)) \\ \quad \quad \quad \begin{cases} F_k = \hat{J}(\theta(k)) \\ \theta(k) = \tilde{\theta}(k-1) \end{cases} \\ \tilde{Y}(k) = F_k(k) \cdot \theta(k) \end{cases} \quad (3)$$

Визначення матриці  $F_k(k)$  базується на рівнянні (1) з подальшим застосуванням правила диференціювання складної функції (ланцюгове правило), а завдяки лінеаризації нейронної системи можна досягти відносної простоти математичної моделі. Таким чином, запропонований підхід дозволить оновлювати вагові коефіцієнти НММ для забезпечення стабільності у відповідності стійкості за Ляпуновим з мінімальним завантаження апаратного комплексу системи.

### 3. Забезпечення стабільності нейромережових алгоритмів MPC

Визначення похибки оцінки  $E(k)$  та апіорної похибки оцінки  $A(k)$  НММ для ітерації  $k$  базується на  $F_k(k)$  представленому у рівнянні (3):

$$\begin{cases} E(k) = F_k(k) \cdot \theta(k-1) - \tilde{Y}(k) \\ A(k) = F_k(k) \cdot \tilde{\theta}(k-1) - \tilde{Y}(k) \end{cases} \quad (4)$$

Правило оновлення вагових коефіцієнтів у рамках забезпечення стабільності у відповідності стійкості за Ляпуновим може бути сформульовано у математичній формі у вигляді представленому на рис. 2.




Рис. 2. Оновлення вагових коефіцієнтів у рамках стійкості за Ляпуновим.

У моделюванні рядів високу ефективність показує нелінійна авторегресійна екзогенна модель (NARX: Nonlinear Autoregressive Exogenous Model), яка характеризується екзогенними входами, що встановлюють поточне значення часового ряду у відповідності до минулих значень та значень зовнішньо визначеного ряду, який впливає на цільовий ряд. Вхідний вектор НММ визначається у рамках даного підходу як:

$$U(k-1) = [y \cdot (k-p)^T, u \cdot (k-p+1)^T, y \cdot (k-p+1)^T \dots (k-1)^T]^T, \quad (5)$$

де  $u \cdot (k-p)$  і  $y \cdot (k-p)$  — вектори, що відповідають попереднім вхідним та вихідним векторам системи на етапі  $(k-p)$ . Таким чином НММ прогнозує вихідні вектори системи на наступному етапі у відповідності до попередніх ітерацій.

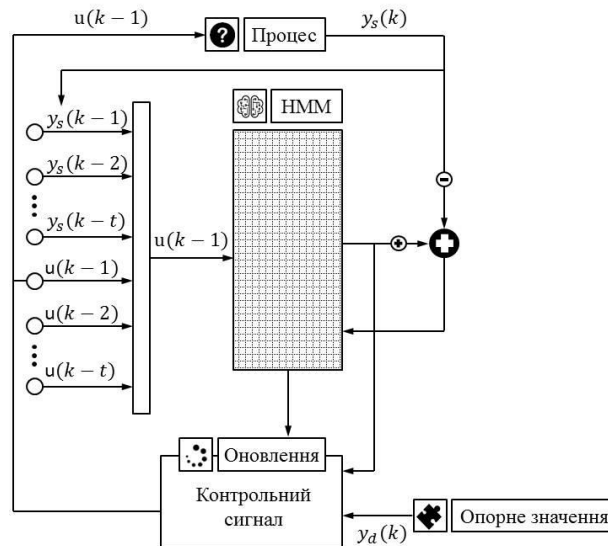


Рис. 3. Архітектура однорівневої нейромережевої системи прогнозування.

Архітектура однорівневої нейромережевої системи прогнозування представлена на рис. 3. Під час контрольної фази НММ глибокого навчання тренується у відповідності до критерію стійкості за Ляпуновим, використовуючи розбіжність між фактичним виходом системи та виходом НММ. Таким чином, ідентифікується процес, що підлягає прогнозуванню, за допомогою адаптації НММ через забезпечення сходження вагового вектора. Нейромережева система прогнозованого контролю лінеаризується за допомогою рядів Тейлора, що використовують значення  $\bar{U}(k-1)$ . При цьому під час розрахунку наступного керуючого сигналу ми вважаємо, ваговий вектор НММ залишається постійним. У той час як сам сигнал оновлюється, і розбіжність між виходом системи прогнозування та бажаним результатом зменшується відповідно до критерію стійкості за Ляпуновим.




Рис. 4. Перевірка роботи моделі прогнозування системи зв'язку.

Застосування рядів Тейлора по відношенню до нейромережевої моделі у відповідності до значення  $\bar{U}(k-1)$  можна представити як:

$$Y(k) = G(\bar{U}(k-1), \theta(k)) + \hat{j}(U(k)) \cdot (U(k) - \bar{U}(k-1)) + \tau(k) \quad (6)$$

де  $\tau(k)$  — член більш високого порядку ряду Тейлора. Для спрощення моделі можна припустити, що для окремих ітерацій:

$$\begin{cases} \tau(k) \approx 0 \\ Y_d(k) \approx Y_d(k-1) \end{cases} \quad (7)$$

і визначити ключове для подальшого аналізу значення між бажаним результатом та значенням на виході системи як:

$$e_c = G(\bar{U}(k-1), \theta(k)) + \hat{j}(U(k)) \cdot (U(k) - \bar{U}(k-1)) - Y_d(k) \quad (8)$$

Розроблений математичний апарат дозволяє узагальнити сучасний досвід побудови нейромережевих систем керування з прогнозуючими моделями. Так на рис. 4 показано модель прогнозування системи зв'язку [29] з рознесеними передавальними і приймальними антенами (MIMO Multiple Input Multiple Output), використання яких дозволяє проводити просторову і часову обробку сигналів, суттєво знижуючи негативний вплив завад (пропускна спроможність MIMO-систем збільшується пропорційно числу антенних елементів). Графіки дозволяють визначити час адаптації нейромережевої моделі глибинного навчання, що може бути неадекватним для конкретного технічного завдання, а також можливість скорочення даного часу (порівняння експерименту «1» і «2»).

**4. Висновки.** У рамках даної роботи було запропоновано базові підходи для побудови системи керування з прогнозуючими моделями, що використовує нейронні мережі глибинного навчання у якості системи прогнозування. Розроблений математичний апарат є універсальним і дозволяє забезпечити задовільну ідентифікацію протікання системних процесів, базуючись на критерії стійкості за Ляпуновим. Подальший аналіз даної методології має включати побудову комплексних нейромережевих моделей прогнозування та визначення їх продуктивності у разі наявності зовнішніх перешкод та змін системних параметрів під час процесу прогнозування та контролю.

1. Wei, D., Li, X., & Lei, C. (2016). Model Predictive Control for Electric Heaters. 2016 International Conference on Industrial Informatics - Computing Technology, Intelligent Technology, Industrial Information Integration (ICIIII).
2. S. Qin and T. A. Badgwell, "A survey of industrial model predictive control technology," Control Engineering Practice, vol. 11, no. 7, pp. 733 – 764, 2003.

3. Industrial Power Electronics. (2016). Model Predictive Control of High Power Converters and Industrial Drives, 29-76. doi:10.1002/9781119010883.ch2
4. Grüne, L., & Pannek, J. (2016). Nonlinear Model Predictive Control. Nonlinear Model Predictive Control Communications and Control Engineering, 45-69. doi:10.1007/978-3-319-46024-6\_3
5. Lee, K., Moase, W. H., & Manzie, C. (2018). Mesh adaptation in direct collocated nonlinear model predictive control. International Journal of Robust and Nonlinear Control. doi:10.1002/rnc.4235
6. Y. Calleecharan, "Nonlinear identification and control: a neural network approach" International Journal of Adaptive Control and Signal Processing, vol. 21, no. 10, pp. 911–912, 2007.
7. Daosud, W., Thitiyasook, P., Arpornwichanop, A., Kittisupakorn, P., & Hussain, M. A. (2005). Neural network inverse model-based controller for the control of a steel pickling process. Computers & Chemical Engineering, 29(10), 2110-2119.
8. P. Kittisupakorn, P. Thitiyasook, M. Hussain, and W. Daosud, "Neural network based model predictive control for a steel pickling process," Journal of Process Control, vol. 19, no. 4, pp. 579 – 590, 2009.
9. Belda, K. (2018). Nonlinear Design of Model Predictive Control Adapted for Industrial Articulated Robots. Proceedings of the 15th International Conference on Informatics in Control, Automation and Robotics. doi:10.5220/0006833500710080
10. F. Temurtas, H. Temurtas, and N. Yumusak, "Application of neural generalized predictive control to robotic manipulators with a cubic trajectory and random disturbances," Robotics and Autonomous Systems, vol. 54, no. 1, pp. 74 – 83, 2006.
11. Zhang, B. (2018). Continuous Approximation of Nonlinear L1 Problem Based on BP Neural Network. DEStech Transactions on Computer Science and Engineering, (Cmee). doi:10.12783/dtsc/cmee2017/19991
12. B. M. Kesson, H. T. Toivonen, J. B. Waller, and R. H. Nyström, "Neural network approximation of a nonlinear model predictive controller applied to a pneumatic process," Computers & Chemical Engineering, vol. 29, no. 2, pp. 323 – 335, 2005.
13. Awad, M., & Khanna, R. (2015). Deep Neural Networks. Efficient Learning Machines, 127-147. doi:10.1007/978-1-4302-5990-9\_7
14. J. Schmidhuber, "Deep learning in neural networks: An overview," Neural Networks, vol. 61, pp. 85 – 117, 2015.
15. Iba, H. (2018). Meta-heuristics, Machine Learning, and Deep Learning Methods. Evolutionary Approach to Machine Learning and Deep Neural Networks, 27-75. doi:10.1007/978-981-13-0200-8\_2
16. Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," Nature, vol. 521, no. 7553, pp. 436–444, 5 2015.
17. Acir, N., & Mengüç, E. C. (2014). Lyapunov theory based adaptive learning algorithm for multilayer neural networks. Neural Network World, 24(6), 619-636. doi:10.14311/nnw.2014.24.035
18. Z. Man, H. R. Wu, S. Liu, and X. Yu, "A new adaptive backpropagation algorithm based on Lyapunov stability theory for neural networks," IEEE Transactions on Neural Networks, vol. 17, no. 6, pp. 1580–1591, Nov 2006.
19. Aftab, M. S., & Shafiq, M. (2015). Adaptive PID controller based on Lyapunov function neural network for time delay temperature control. 2015 IEEE 8th GCC Conference & Exhibition. doi:10.1109/ieeeecc.2015.7060094
20. K. H. Lim, K. P. Seng, L. M. Ang, and S. W. Chin, "Lyapunov theory based multilayered neural network," IEEE Transactions on Circuits and Systems II: Express Briefs, vol. 56, no. 4, pp. 305–309, April 2009.
21. Learning in Feed-Forward Neural Networks. (2015). Encyclopedia of Computational Neuroscience, 1495-1495. doi:10.1007/978-1-4614-6675-8\_100303
22. S. C. Douglas and T. H. Y. Meng, "Linearized least-squares training of multilayer feed forward neural networks," in IJCNN-91-Seattle International Joint Conference on Neural Networks, vol. 1, Jul 1991, pp. 307–312 vol.1.
23. Sahoo, H., Dash, P., & Rath, N. (2013). NARX model based nonlinear dynamic system identification using low complexity neural networks and robust H<sub>∞</sub> filter. Applied Soft Computing, 13(7), 3324-3334.
24. H. Sahoo, P. Dash, and N. Rath, "Narx model based nonlinear dynamic system identification using low complexity neural networks and robust H<sub>∞</sub> filter," Applied Soft Computing, vol. 13, no. 7, pp. 3324 – 3334, 2013.
25. Wang, X., & Zhang, W. (2017). A Sample-Based Dynamic CPU and GPU LLC Bypassing Method for Heterogeneous CPU-GPU Architectures. 2017 IEEE Trustcom/BigDataSE/ICSS.
26. J. Bergstra, O. Breuleux, F. Bastien, P. Lamblin, R. Pascanu, G. Desjardins, J. P. Turian, D. Warde-Farley, and Y. Bengio, "Theano: A CPU and GPU math compiler in python," 2011.
27. Rajbhaj, P. K., Parvat, B., & Kadu, C. (2015). Design of feedback-feedforward controller for level control in a coupled tank system. 2015 International Conference on Energy Systems and Applications.
28. H. Pan, H. Wong, V. Kapila, and M. S. de Queiroz, "Experimental validation of a nonlinear backstepping liquid level controller for a state coupled two tank system," Control Engineering Practice, vol. 13, no. 1, pp. 27 – 40, 2005.
29. Spyridon, P., & Boutalis, Y. S. (2018). Adaptive One-Step Model Predictive Control Using Lyapunov Theory-Based Deep Neural Networks. 2018 26th Mediterranean Conference on Control and Automation (MED).