



УДК 721

НЕЙРОМЕРЕЖЕВЕ ПРОГНОЗУВАННЯ ЧАСОВИХ РЯДІВ ТЕМПЕРАТУРИ НАВКОЛИШНЬОГО ПРИРОДНОГО СЕРЕДОВИЩА

В.П. Лисенко, Н.А. Заєць, В.М. Штепа, *кандидати технічних наук*
А.О. Дудник, *аспірант**

Національний університет біоресурсів і природокористування України

Розроблено методику дослідження температурних часових рядів із використанням нейронних мереж. У програмному середовищі Statistica Neural Networks вирішено оптимізаційну задачу вибору архітектури нейронних мереж. Створено та проаналізовано нейромережеві проєкції температурних часових рядів.

Проблема. Прогнозування температури, яке базується на основі теорії статистичних рішень, у виробничих умовах демонструє прийнятну чутливість та адекватність [1]. При цьому очевидно, що додатковий значимий вхідний параметр інтелектуальної системи управління промисловим пташником лише підвищить ефективність її функціонування. В якості такої вхідної величини можна використати прогнозоване значення температури, якщо прогноз здійснюється на основі теорії аналізу часових рядів [2].

Серед подібних досліджень виділяється проєкт розподілених обчислень для прогнозування змін клімату Землі на найближчі 50 років – "Climate Prediction", де задіяні науковці університетів Оксфорду та Редінгу, метеорологічного центру Великобританії, Рутгерфорд-Аптонської лабораторії та софтверної компанії "Tessella Support Services 2".

Однак для задачі енергоефективного управління промисловим пташником, як біологічним об'єктом, таких довготривалих передбачень не потрібно – достатньо отримати адекватний прогноз на кілька годин. У зв'язку з цим, метою досліджень є синтез адекватного предиктора температури навколишнього природного середовища.

Методика дослідження та його результати. Загалом аналіз часових рядів – це сукупність математико-статистичних методів аналізу, призначених для виявлення структури часових рядів та їх прогнозування. Сюди належать, зокрема, методи класичного регресійного аналізу. Встановлення структури часового ряду потрібно для побудови математичної моделі того явища, яке є джерелом часового ряду, що аналізується.

Таким чином, ідея прогнозування базується на припущенні, що часовий ряд має деяку математичну структуру. Ця структура існує в фазовому просторі, ко-

*Науковий керівник – професор В.П. Лисенко.



ординати якого — незалежні змінні, що описують стан динамічної системи. Тому перше завдання, з яким доведеться зіткнутися при моделюванні, це визначення фазового простору. Для цього потрібно вибрати деякі характеристики системи в якості фазових змінних. Після цього ставиться завдання передбачення, або екстраполяції. У нашому випадку відсутні випадкові флуктуації і шум, що значно спрощує задачу прогнозування.

Доведено, що фактично всі моделі класичного статистичного аналізу часових рядів можуть бути реалізовані за допомогою нейронних мереж (НМ) [2, 3], оскільки певна залежність з безперервною нелінійною функцією може бути відтворена багаточисловою мережею. Тобто, замість відображення поверхні у вхідному (фазовому) просторі, утвореної даними за допомогою однієї гіперплощини (AR), кількох гіперплощин (TAR), або декількох гіперплощин, рівноз'єднаних одна з одною (STAR), НМ може здійснити її довільне нелінійне відображення.

У порівнянні з класичними методами аналізу часових рядів НМ мають певні переваги [2–5]:

- 1) постійну оптимізацію власної структури з метою мінімізації прогностичної помилки в режимі реального часу;
- 2) більш високі потенційні можливості при аналізі складних динамічних систем та закономірностей;
- 3) здатність успішно вирішувати завдання, спираючись на неповну, викривлену, і внутрішньосуперечливу вхідну інформацію.

Для синтезу та дослідження відповідних НМ використали програмний пакет Statistica Neural Networks. Критерій — мінімізація помилки НМ. У контексті нашої задачі його перевага над аналогічними розробками полягає у реалізації функціонального блоку оптимізації архітектури нейромоделей, який використовує лінійні підхо-

ди та метод імітації "відпалювання" на основі розподілу ймовірностей Гіббса:

$$P(\bar{x}^i \rightarrow \bar{x}_{i+1} | \bar{x}_i) = \begin{cases} 1, & F(\bar{x}^i) - F(\bar{x}_i) < 0 \\ \exp\left(-\frac{F(\bar{x}^i) - F(\bar{x}_i)}{Q_i}\right), & F(\bar{x}^i) - F(\bar{x}_i) \geq 0 \end{cases}, \quad (1)$$

де $Q_i > 0$ — елементи довільно спадаючої до нуля послідовності.

За часовий температурний ряд візьмемо статистичні дані за вересень 2006 року. Дискретність вимірювання — 3 год. Довжина часового ряду — 243 елементи.

Для підвищення якості функціонування НМ проведемо попереднє нормування вхідних даних (діапазон [0, 1]):

$$x_{ni} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, \quad (2)$$

де x_i — реальне значення елемента часового ряду; x_{\min} — елемент часового ряду, який має мінімальне значення; x_{\max} — елемент часового ряду, який має максимальне значення.

Активуємо конструктор мереж із завданням видати 5 НМ із найкращими показниками моделювання. При цьому задаємо прогноз на один крок вперед із довжиною часового вікна, що дорівнює 5.

Задля ефективного моделювання у пакеті Statistica Neural Networks вхідні дані автоматично розбиваються на три блоки: навчальні, контрольні, тестові. Наявність трьох блоків необов'язкова, однак тестовий блок покращує якість подальшої роботи, оскільки дає можливість впевнитись, що не відбулося "перенавчання" (overfitting) мережі. Для підвищення наочності прогнозування не задамо останні 8 елементів (24 год) температурного часового ряду.

За результатами розв'язку оптимізаційної задачі кращими НМ були вибрані (рис. 1, 2): радіально-базисна функція (помилки: навчальна — 2,617 °С, контрольна — 2,617 °С, тестова — 2,06 °С), лінійна з двома нейронами у вхідному шарі (помилки: навчальна — 0,103 °С, контрольна —

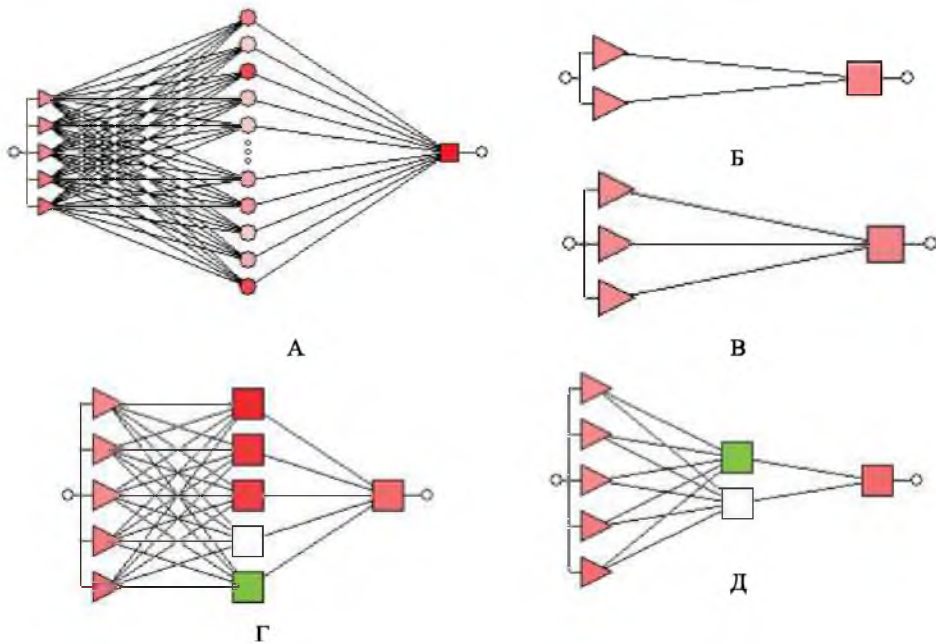


Рис. 1. Оптимальні архітектури НМ прогнозування температурних часових рядів:

А – радіально-базисна функція (RBF); Б – лінійна з двома нейронами у вхідному шарі (Linear 1); В – лінійна з трьома нейронами у вхідному шарі (Linear 2); Г – багатошаровий перцептрон із п'ятьма нейронами у прихованому шарі (MLP 1); Д – багатошаровий перцептрон із двома нейронами у прихованому шарі (MLP 2)

0,086 °С, тестова – 0,097 °С), лінійна з трьома нейронами у вхідному шарі (помилки: навчальна – 0,103 °С, контрольна – 0,086 °С, тестова – 0,096 °С), багатошаровий перцептрон із п'ятьма нейронами у прихованому шарі (помилки: навчальна – 0,077 °С, контрольна – 0,068 °С, тестова – 0,074 °С), багатошаровий перцептрон із двома нейронами у прихованому шарі (помилки: навчальна – 0,073 °С, контрольна – 0,065 °С, тестова – 0,07 °С).

Незважаючи на відносно погану якість навчання (build), НМ радіально-базисної функції також використовуватимемо для подальших досліджень, оскільки, враховуючи внутрішньофункціональні особливості, при прогнозуванні

(validation) вона потенційно може продемонструвати необхідну якість.

Подальшим кроком аналізу часових рядів температури навколишнього природного середовища буде отримання відповідних предиктів, котрі виходитимуть за межі навчальної вибірки.

Для цього реалізуємо проєкцію часового ряду для кожної з мереж, задавши глибину прогнозу на 8 елементів уперед (рис. 3).

При прогнозуванні на добу вперед спостерігається (рис. 3) достатня точність прогнозу (середньоквадратична помилка – 1,789107–3,220811 °С). Найкращі передбачувальні властивості продемонструвала мережа Linear 2 – 1,789107 °С (табл. 1), що пояснюється

Таблиця 1. Середньоквадратичні помилки прогнозування температури при глибині проєкції 8 елементів часового ряду

RBF, °C	Linear 1, °C	Linear 2, °C	MLP 1, °C	MLP 2, °C
3,220811	2,503599	1,789107	3,007316	2,555901




Рис. 2. Графіки навчального прогнозування температурних часових рядів НМ:

А – радіально-базисна функція (RBF); Б – лінійна з двома нейронами у вхідному шарі (Linear 1); В – лінійна з трьома нейронами у вхідному шарі (Linear 2); Г – багатошаровий перцептрон із п'ятьма нейронами у прихованому шарі (MLP 1)



Температура, °C

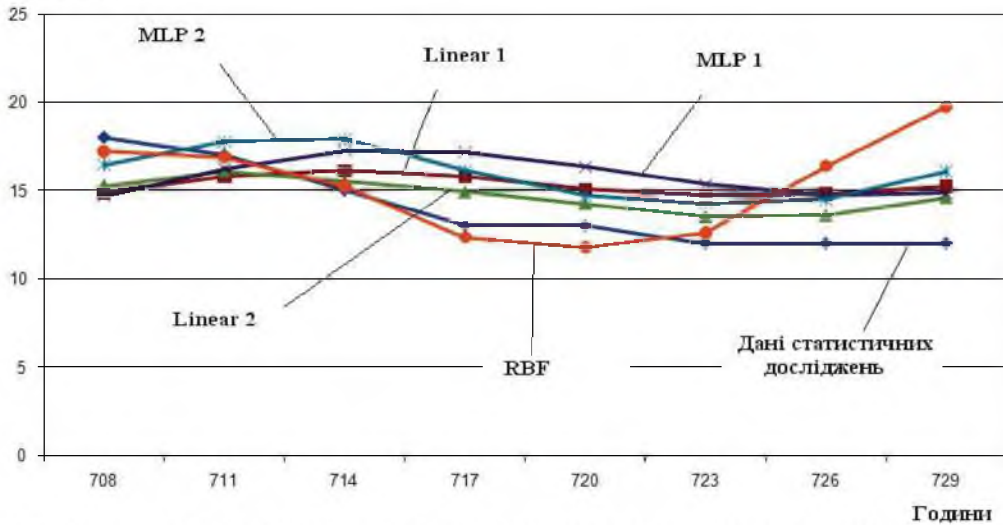


Рис. 3. Нейромережеві проєкції часових рядів температури навколишнього природного середовища

Таблиця 2. Середньоквадратичні помилки прогнозування температури при глибині проєкції 6 елементів часового ряду

RBF, °C	Linear 1, °C	Linear 2, °C	MLP 1, °C	MLP 2, °C
0,6055	1,992287	1,419686	2,657	1,912155

певною лінійністю зміни температури на цьому часовому інтервалі.

Проєкційний графік (рис. 3), також показує що максимальна предиктивність має місце при глибині проєкції 6 елементів – 18 год (табл. 2), особливо стосовно НМ RBF (середньоквадратична помилка – 0,6055 °C). Це пояснюється логістичною функцією активації вихідного шару мережі, яка здійснює "зрізання" вихідних значень, не дозволяючи екстраполювати, оскільки такий тип функцій приймає, як аргумент, відстань між вхідним вектором і деяким наперед заданим центром активаційної функції.

Значення цієї функції тим вище, чим ближче до центру вхідний вектор:

$$y = \exp\left(-\frac{(S-R)^2}{2\sigma^2}\right), \quad (3)$$

де $S = X - C$ – відстань між центром C і вектором вхідних сигналів X ;

σ – параметр визначає швидкість спадання функції при віддаленні вектора від центру; R – параметр, який визначає зсув активаційної функції за віссю абсцис.

Аналізуючи проєкції часових рядів температури (рис. 3), також слід зазначити, що НМ при загальному трендові зниження температури (708–717 год), відносно вірно спрогнозували її стабілізацію на елементах 717–720 год та збільшення на елементі 723 год.

Висновки

1. Нейромережеве прогнозування часових рядів температури навколишнього природного середовища є достатньо точним для того, щоб застосовуватись у якості одного із вхідних параметрів інтелектуальної системи управління промисловим пташником як біологічним об'єктом.

2. Глибину проєкції нейромережевого предикту температури доцільно взяти рівною 6 елементам.

**Література**

1. Лисенко В.П. Адаптивний алгоритм оперативного управління промисловим пташником на основі теорії статистичних рішень / В.П. Лисенко, Б.Л. Головінський, В.М. Решетюк, А.А. Руденський // Науковий вісник НУБіП України. – К.: НУБіП України. – 2010. – Вип. 153. – С. 235–244.
2. Ясницкий Л.Н. Введение в искусственный интеллект. – М.: Академия. – 2005. – 176 с.
3. Тихомирова Н.П. Интеллектуальные информационные системы в экономике. – М.: Экзамен. – 2003. – 496 с.
4. Нейроінформаційна модель фізіологічних властивостей дикорослих тварин / В.П. Лисенко, Н.А. Заєць, В.М. Штепа, В.А. Петришина // Науковий вісник НУБіП України. – К.: НУБіП України. – 2010. – Вип. 153. – С. 111–118.
5. Лисенко В.П., Штепа В.М., Наконечна К.В. Нейромережева модель розвитку державного регулювання в АПК України // Вісник аграрної науки. – К.: УААН. – 2009. – № 11 (679). – С. 71–74

АННОТАЦІЯ

Лисенко В.Ф., Заєць Н.А., Штепа В.М., Дудник А.О. Нейросетевое прогнозирование временных рядов температуры окружающей среды // Биоресурсы и природопользование. – 2011. – 3, № 3–4. – С. 102–107.

Разработана методика исследования температурных временных рядов с использованием нейронных сетей. В программной среде Statistica Neural Networks решена оптимизационная задача выбора архитектуры нейронных сетей. Созданы и проанализированы нейросетевые проекции температурных временных рядов.

SUMMARY

V. Lysenko, N. Zayets, V. Shtepa, A. Dudnyk. Neural Networks forecasting of the ambient temperature time series // Biological Resources and Nature Management. – 2011. – 3, № 3–4. – P. 102–107.

The method for study of the temperature time series using neural networks has been developed. In a software environment Statistica Neural Networks the optimization problem of selecting architectures of neural networks is solved. Neural networks projections of the temperature time series have been created and analyzed.