
TELECOMMUNICATION SYSTEMS AND NETWORKS

DOI 10.20535/2411-1031.2019.7.1.184395

УДК 004.942::519.216.3

ОЛЕГ БЕЛАС,
ПЕТРО БІДЮК,
АНДРІЙ БЕЛАС

ПОРІВНЯЛЬНИЙ АНАЛІЗ АВТОРЕГРЕСІЙНИХ ПІДХОДІВ ТА РЕКУРЕНТНИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ МОДЕЛЮВАННЯ І ПРОГНОЗУВАННЯ НЕЛІНІЙНИХ НЕСТАЦІОНАРНИХ ПРОЦЕСІВ

Нелінійні нестационарні процеси, представлені у вигляді часових рядів, можуть собою описувати динаміку процесів як в технічних, так і у економічних системах. Прогнозування таких процесів має численні застосування в енергетиці, мережевих системах, торгівлі, інвестиційній діяльності. Однак, на даний час не існує єдиного підходу для моделювання і прогнозування таких процесів. У роботі розглянуто найбільш уживані підходи. Вони вважаються ефективними для роботи з даними, представленими у вигляді послідовностей: авторегресійні моделі та рекурентні нейронні мережі. Класичні регресійні підходи прогнозують цільову змінну лінійною комбінацією минулих значень цієї змінної. Тому доволі просто використовуються як з теоретичної, так і з обчислювальної точок зору завдяки простій структурі. Проте даний підхід обмежується складністю врахування великої кількості зовнішніх факторів через проблему мультиколінеарності, а також їх можливий нелінійний вплив. Нейронні мережі навчаються на досвіді і адаптуються до змін середовища, яке моделюється. Нейронні технології застосовуються для нелінійного моделювання, стійкі до інформаційних завад і здатні до узагальнення на основі історичних даних. Використання нейронних мереж дозволяє отримувати точні та адекватні моделі, навіть за якісного аналізу взаємозв'язків факторів, що впливає на результат прогнозування. Тому для роботи з послідовностями використовують рекурентні нейронні мережі. Це дозволяє вирішити поставлену задачу моделювання з урахуванням нелінійного або комбінованого впливу зовнішніх факторів. Однак, застосування даного підходу обмежується великими обчислювальними витратами. До того ж цей підхід не може застосовуватися для дуже довгих послідовностей. Це є проблемою для вирішення сучасних задач з використанням великих за обсягом даних. З аналізу випливає необхідність розроблення, нового, ефективного з обчислювальної точки зору підходу до моделювання великих послідовностей з урахуванням нелінійного або комбінованого впливу зовнішніх факторів.

Ключові слова: математичне моделювання; обробка сигналів; нестационарні процеси; авторегресійні моделі; нейронні мережі; рекурентні нейронні мережі.

Постановка проблеми. Активний розвиток інформаційних технологій і розширення обсягів інформаційних послуг значною мірою ґрунтується на науково-технологічних розробках у галузі телекомунікаційних мереж. Дослідження показують, що сучасні мережеві технології своїм зростанням випереджають теоретичне та аналітичне розуміння мережевих взаємодій. Методи розрахунку характеристик комп'ютерної мережі (пропускної здатності каналів, ємності буферів), що засновані на класичних моделях, не відповідають необхідним вимогам і не дозволяють адекватно оцінювати навантаження в мережі. Прогнозування на основі моделей, побудованих за експериментальними (статистичними) даними – один із найпопулярніших підходів до прогнозування динаміки процесів у технічних системах, оцінювання альтернативних економічних стратегій, формування бюджетів підприємств та держави, прогнозування та менеджменту ризиків довільної природи та розв'язання інших

задач. Тому розробка математичної моделі та методів прогнозування перевантажень у мережевих системах розподілу інформації, що дозволить підвищити якість обслуговування мереж за рахунок зменшення затримок і втрат пакетів даних, а також задача прогнозування нелінійних нестационарних процесів є дуже актуальною на сьогоднішній день. Зокрема, проблемним є вирішення завдань з довготривалими залежностями у часових рядах.

Аналіз останніх досліджень і публікацій. На даний час проблема моделювання та прогнозування нелінійних нестационарних процесів знаходиться у стані активного дослідження. Основними підходами до вирішення задачі є класичні регресійні підходи та підходи на базі нейронних мереж. Регресійні підходи глибоко проаналізовані та мають широке практичне застосування [1] - [4]. Теорія і практика використання нейронних мереж, а саме рекурентних нейронних мереж, що можуть бути успішно застосовані для моделювання та прогнозування обраних процесів, активно розвивається [5] - [7].

Метою статті є обґрунтування необхідності розроблення нового підходу до моделювання та прогнозування нелінійних нестационарних процесів. Вона вимагає виконання таких завдань:

1. Проаналізувати авторегресійні підходи для моделювання та прогнозування нелінійних нестационарних процесів
2. Проаналізувати підходи на базі рекурентних нейронних мереж для моделювання та прогнозування нелінійних нестационарних процесів
3. Порівняти переваги та недоліки розглянутих підходів

Виклад основного матеріалу дослідження. Авторегресійні моделі. Розглянемо деякі можливі підходи до побудови моделей і обчислення прогнозованих значень за допомогою регресійних моделей. Моделлю лінійної регресії прогнозується цільова змінна, використовуючи лінійну комбінацію предикторів. В моделі авторегресії прогнозується цільова змінна, використовуючи лінійну комбінацію минулих значень самої змінної. Термін «авторегресія» вказує на регресію змінної відносно себе [3].

Таким чином, авторегресійну модель порядку p можна представити виразом:

$$y(k) = a_0 + \sum_{i=1}^p a_i y(k-i) + \varepsilon(k),$$

- де $y(k)$ – прогнозована змінна в момент часу k ;
 $y(k-i)$ – прогнозована змінна в момент часу $k-i$;
 a_0 – вільний член регресійної моделі;
 a_i – коефіцієнти регресійної моделі;
 $\varepsilon(k)$ – білий шум.

Це як множинна регресія, але з лаговими значеннями $y(k)$ як предикторами. Назвемо її авторегресійною моделлю порядку p (AR модель). Кількість регресорів (p) визначається шляхом аналізу автокореляційної або частково автокореляційної функції (АКФ, ЧАКФ) [1]. Так само, як кореляція вимірює ступінь лінійної залежності між двома змінними, автокореляція вимірює лінійну залежність між лаговими значеннями часових рядів. Відповідно, взявши певний рівень значимості можемо визначити необхідну кількість регресорів. Як правило, авторегресійні моделі потребують стаціонарних даних, в цьому випадку необхідні деякі обмеження на значення параметрів [3].

Модель ковзного середнього використовує минулі прогнозовані помилки в регресійній моделі для її коригування та моделювання залежностей в похибках AR моделі [4]. Тож, модель авторегресії з ковзним середнім має такий вид:

$$y(k) = a_0 + \sum_{i=1}^p a_i y(k-i) + \sum_{j=1}^q b_j \varepsilon(k-j) + \varepsilon(k),$$

- де b_j – коефіцієнти моделі ковзного середнього;

$\varepsilon(k - j)$ – лагові значення похибки моделі;

q – кількість членів моделі ковзного середнього.

Розглянуті моделі АР та АРКС вимагають стаціонарності вхідних даних. Проте дуже поширеними є задачі, в яких вхідні дані мають тренд [4]. У випадку коли математичне сподівання змінюється в часі, процес називають процесом з трендом або інтегрованим процесом або процесом з одиничними коренями (відповідного характеристичного рівняння).

При цьому під трендом будемо розуміти поточне середнє значення процесу, яке може бути отримане за допомогою процедури цифрової фільтрації. В простому випадку це може бути формула для обчислення поточного середнього значення.

Наявність нелінійного детермінованого тренду в процесі можна визначити шляхом оцінювання рівняння:

$$y(k) = a_0 + c_1 k + c_2 k^2 + \dots + c_m k^m$$

яке представляє собою поліном порядку m відносно часу.

Якщо хоча б один із коефіцієнтів є статистично значимим, то гіпотеза щодо відсутності тренду відхиляється. Також існують спеціальні тести для оцінки стаціонарності часового ряду [1]. Тому для використання авторегресійних моделей ряд попередньо диференціюється – обчислюються різниці між послідовними спостереженнями. Так, перші різниці видаляють тренд першого порядку (лінійний тренд), другі різниці видаляють квадратичний тренд і т.і.

Наприклад, нехай $y(k) = a_0 + a_1 \cdot k$. Перші різниці цього процесу $\Delta y(k) = y(k) - y(k-1) = a_0 + a_1 \cdot k - [a_0 + a_1 \cdot (k-1)] = a_1$ приводять до видалення лінійного тренду. Отримана модель називається авторегресією із інтегрованим ковзним середнім (АРІКС). Якщо для процесу, що моделюється, можна виявити вхідну змінну, то вона записується у правій частині [2]:

$$y'(k) = a_0 + \sum_{i=1}^p a_i y'(k-i) + \sum_{j=1}^q b_j \varepsilon(k-j) + \varepsilon(k).$$

Відповідне характеристичне рівняння може мати одиничні корені, тобто один або більше коренів характеристичного рівняння можуть набувати значення “1”. Такі процеси називають процесами авторегресії з інтегрованим ковзним середнім – АРІКС (p, q, d), де d – число одиничних коренів характеристичного рівняння. Процеси цього класу нестаціонарні – вони мають тренд, порядок якого визначається числом одиничних коренів. Якщо $d = 1$, то тренд лінійний; якщо $d = 2$, то тренд квадратичний [1].

Отже, перевагами моделі АРІКС, є простота структури, завдяки якій відбувається суттєвий вииграш щодо обчислювальних витрат, а тому є можливість її оперативної адаптації до характеристик процесу в реальному часі. Однак, оскільки дана модель є звичайною лінійною регресією, що побудована на лагових значеннях, то вона не здатна враховувати нелінійний вплив як внутрішніх, так і зовнішніх факторів, комбінований вплив факторів. Водночас авторегресія не може бути адекватно побудована в разі наявності колінеарних факторів.

Нейронні мережі типу LSTM. Одним з ефективних альтернативних підходів є технологія штучних нейронних мереж. Методи, з використанням нейронних мереж, істотно відрізняються від розглянутих вище, оскільки нейронні мережі являють собою системи, здатні навчатися на досвіді і адаптуватися до змін середовища. Нейронні технології мають такі переваги: можливість нелінійного моделювання, стійкість до інформаційних завад і здатність до узагальнення на основі прикладів. Нейронні мережі дозволяють будувати точні та адекватні моделі, навіть там, де потрібний якісний аналіз взаємозв’язків факторів, що впливають на результат.

Для роботи з послідовностями (часові ряди, сигнали) використовують рекурентні нейронні мережі (РНМ) [10].

Мережі з довго короткостроковою пам'яттю (Long Short Term Memory) – зазвичай називають “LSTM” – особливий вид РНМ, здатних до навчання довгостроковим залежностям. Вони були запропоновані С. Хохрейтером і Дж. Шмідхубером [5] і доопрацьовані та популяризовані в роботах [6], [7]. Вони дають можливість отримати високоякісні результати на великій різноманітності проблем і в даний момент широко застосовуються для моделювання нелінійних процесів [9].

LSTM спеціально спроектовані таким чином, щоб уникнути проблеми довгострокових залежностей. Запам'ятовувати інформацію на тривалий період часу – це практично їх типова поведінка [8].

LSTM мають ланцюгову структуру як і класичні РНМ, але повторюваний модуль має іншу побудову. Замість одного нейронного шару їх чотири, причому вони взаємодіють особливим чином (див. рис. 1).

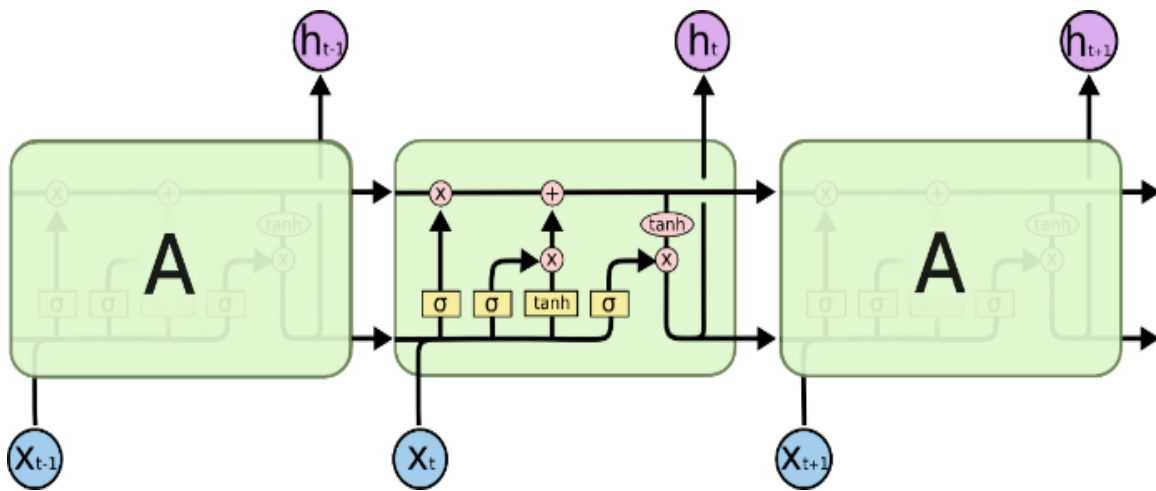


Рисунок 1 – Структура повторюваного модуля LSTM

Ключ до LSTM – клітинний стан (cell state) – горизонтальна лінія, що проходить крізь верхню частину діаграми. Клітинний стан подібний до стрічки конвеєра. Ця стрічка рухається прямо вздовж всього ланцюга тільки з невеликими лінійними взаємодіями. Інформація передається до наступних шарів мережі по ній без змін (див. рис. 2).

LSTM має здатність видаляти або додавати інформацію до клітинного стану, проте ця здатність ретельно регулюється структурами, що називаються вентилями (gates).




Рисунок 2 – Клітинний стан LSTM

Першим кроком в LSTM треба вирішити яку інформацію збираємося видалити з клітинного стану. Це рішення приймається сигмоїдним шаром, що називається “забуваючим вентиляем” (“forget gate layer”). Цей забуваючий вентиль “дивиться” на $h(t-1)$ і $x(t)$ та подає на вихід число між “0” і “1” для кожного числа в клітинному стані $C(t-1)$. Одиниця означає “збережи це повністю”, в той час як нуль означає “позбудься цього повністю” (див. рис. 3).

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

де σ – сигмоїдна функція активації;
 W_f – матриця ваг даного шару f в момент часу t ;
 b_f – вектор вільних членів шару f ;
 h_{t-1} – вихід h з попереднього кроку – вхід на цьому кроці;
 x_t – основний вхід нейронної мережі на кроці t .

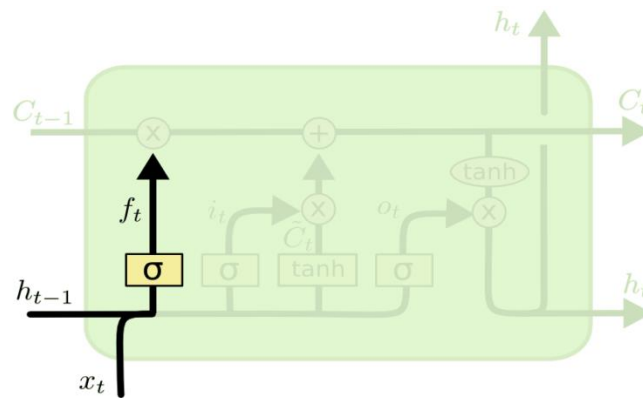


Рисунок 3 – Забуваючий вентиль LSTM

Наступним кроком треба вирішити, яку нову інформацію збираємося зберегти в клітинному стані. Цей крок складається з двох частин. По-перше, сигмоїдний шар, що називається “вхідним вентиляем” (“input gate layer”), вирішує, які значення оновимо. Далі, шар гіперболічного тангенса створює вектор кандидатів на нові значення $C(t)$, який може бути доданий до стану. На наступному кроці з’єднаємо ці дві частини, щоб створити оновлення для стану (див. рис. 4).

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

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C),$$

де \tanh – функція гіперболічного тангенса активації шару нейронної мережі.




Рисунок 4 – Вхідний вентиль LSTM

Далі необхідно оновити попередній клітинний стан, $C(t-1)$, новим клітинним станом $C(t)$ (див. рис. 5).

Нарешті, потрібно вирішити, який результат збираємося подати на вихід. Цей результат отримано на основі клітинного стану, але буде його відфільтрованою версією. Спочатку запускаємо сигмоїдний шар, який вирішує, які частини клітинного стану збираємося відправити на вихід.

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t$$

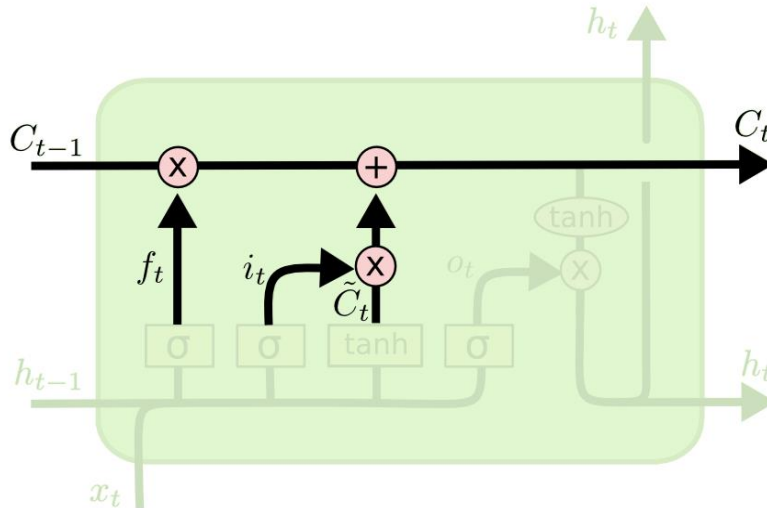


Рисунок 5 – Оновлення клітинного стану LSTM

Потім пропускаємо клітинний стан крізь гіперболічний тангенс (\tanh) (щоб вмістити значення в проміжок від “-1” до “1”) і множимо його на вихід сигмоїдного вентиля так, що відправляємо на вихід тільки ті частини, які бажаємо (див. рис. 6).

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

$$h_t = o_t \tanh(C_t),$$




Рисунок 6 – Формування виходу LSTM шару

Однак, побудова таких мереж пов’язана з великими обчислювальними труднощами. Крім того, стикаємося з численними проблемами [9], які не дадуть працювати з надто довгими послідовностями (наприклад, при обробленні потокового сигналу з високою частотою дискретизації 500-100 Гц).

Висновки. Задача прогнозування процесів у технічних системах дуже глибоко проаналізована з використанням класичних регресійних підходів, які доволі просто використовуються як з теоретичної, так і з обчислювальної точки зору. Проте даний підхід обмежується складнощами врахування великої кількості зовнішніх факторів, через проблему мультиколінеарності, до того ж, якщо вони впливають нелінійно. Тому в статті запропоновано розглянути нейронні мережі типу LSTM, які також вирішують задачу моделювання послідовностей. Вони враховують нелінійний або комбінований вплив зовнішніх факторів. Проте застосування даного підходу потребує великих обчислювальних витрат, тому цей підхід не може бути застосований для дуже довгих послідовностей, що є проблемою для вирішення сучасних задач з використанням великих за обсягом даних. За результатами аналізу встановлено необхідність розроблення нового підходу, що дозволило би ефективно з обчислювальної точки зору моделювати великі послідовності, враховуючи нелінійний або комбінований вплив зовнішніх факторів.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

- [1] П. І. Бідюк, В. Д. Романенко, та О. Л. Тимошук, *Аналіз часових рядів*. Київ, Україна: Політехніка, 2010.
- [2] R. S. Tsay, *Analysis of Financial Time Series*. New Jersey, USA: Wiley, 2010.
- [3] R. Hyndman, G. Athanasopoulos, *Forecasting: Principles and Practice*. Melbourne, Australia: OTexts, 2013.
- [4] R. Shumway, and D. Stoffer, *Time Series Analysis and Its Applications*. New York, USA: Springer, 2011.
doi: 10.1007/978-1-4757-3261-0.
- [5] S. Hochreiter, and J. Schmidhuber, “Long Short-Term Memory”, *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, 1997.
- [6] F. A. Gers, D. Eck, and J. Schmidhuber, “Applying LSTM to Time Series Predictable Through Time-Window Approaches”, in *Proc. of International Conference on Artificial Neural Networks*, Vienna, 2001, pp. 669-676.
doi: 10.1007/3-540-44668-0_93.
- [7] S. Hochreiter, Y. Bengio, and J. Schmidhuber, “Gradient flow in recurrent nets: the difficulty of learning long-term dependencies”. [Online]. Available: <http://www.bioinf.jku.at/publications/older/ch7.pdf> . Accessed on: Dec. 12, 2018.
- [8] Understanding LSTM Networks. [Online]. Available: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>. Accessed on: May 11, 2019.
- [9] F. Chollet, and J. Allaire, *Deep Learning with R*. New York, USA: Manning, 2018.
- [10] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, USA: MIT Press, 2016.

Стаття надійшла до редакції 17.03.2019.

REFERENCE

- [1] P. I. Bidyuk, V. D. Romanenko, and O. L. Timoschuk, *Analysis of time series*. Kyiv, Ukraine: Polytechnic, 2010.
- [2] R. S. Tsay, *Analysis of Financial Time Series*. New Jersey, USA: Wiley, 2010.
- [3] R. Hyndman, G. Athanasopoulos, *Forecasting: Principles and Practice*. Melbourne, Australia: OTexts, 2013.
- [4] Shumway R., Stoffer D., *Time Series Analysis and Its Applications*. New York, USA: Springer, 2011.
- [5] S. Hochreiter, and J. Schmidhuber, “Long Short-Term Memory”, *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, 1997.

- [6] F. A. Gers, D. Eck, and J. Schmidhuber, "Applying LSTM to Time Series Predictable Through Time-Window Approaches", in *Proc. of International Conference on Artificial Neural Networks*, Vienna, 2001, pp. 669-676.
doi: 10.1007/3-540-44668-0_93.
- [7] S. Hochreiter, Y. Bengio, and J. Schmidhuber, "Gradient flow in recurrent nets: the difficulty of learning long-term dependencies". [Online]. Available: <http://www.bioinf.jku.at/publications/older/ch7.pdf> . Accessed on: Dec. 12, 2018.
- [8] "Understanding LSTM Networks". [Online]. Available: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>. Accessed on: March 9, 2018.
- [9] F. Chollet, and J. Allaire, *Deep Learning with R*. New York, USA: Manning, 2018.
- [10] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, USA: MIT Press, 2016.

OLEG BELAS,
PETRO BIDIUK,
ANDRII BELAS

COMPARATIVE ANALYSIS OF AUTOREGRESSIVE APPROACHES AND RECURRENT NEURAL NETWORKS FOR MODELING AND FORECASTING NONLINEAR NONSTATIONARY PROCESSES

Nonlinear nonstationary processes presented in the form of time series can describe the dynamics of processes in both technical and economic systems. Forecasting of such processes has numerous applications in power engineering, network systems, trade, and investment activities. However, there is no single approach to modeling and predicting such processes currently. This paper considers the most commonly used approaches. They are considered to be effective in working with data presented in the form of sequences: autoregressive models and recurrent neural networks. Classical regression approaches predict a target variable by a linear combination of past values of this variable. Therefore, they are quite simply used both from the theoretical and computational point of view due to the simple structure. However, this approach is limited to the complexity of taking into account a large number of external factors due to the problem of multicollinearity, as well as their possible nonlinear influence. Neural networks learn from experience and adapt to a changing environment that is modeled. Neural technologies are used for nonlinear modeling, resistant to information noise and capable of generalization based on historical data. The use of neural networks allows obtaining accurate and adequate models, even with a qualitative analysis of the interconnections factors that influence the result of forecasting. Therefore, recurrent neural networks are used to work with sequences. This allows solving the problem of modeling taking into account the nonlinear or combined effects of external factors. However, the application of this approach is limited to large computational costs. In addition, this approach can't be applied to very long sequences. This is a problem for solving modern problems using large amount of data. From the analysis, it follows from the necessity of developing a new, effective from a computational point of view approach to modeling large sequences taking into account the nonlinear or combined effects of external factors.

Keywords: mathematical modeling; signal processing; nonstationary processes; autoregressive models; neural networks; recurrent neural networks.

Белас Олег Миколайович, доктор технічних наук, професор, професор кафедри спеціальних телекомунікаційних систем, Інститут спеціального зв'язку та захисту інформації Національного технічного університету України "Київський політехнічний інститут імені Ігоря Сікорського", Київ, Україна.

ORCID: 0000-0002-1595-3029.

E-mail: belas@ukr.net.

Бідюк Петро Іванович, доктор технічних наук, професор, професор кафедри математичних методів системного аналізу, Інститут прикладного системного аналізу Національного технічного університету України “Київський політехнічний інститут імені Ігоря Сікорського”, Київ, Україна.

ORCID: 0000-0002-7421-3565.

E-mail: pbidyuke_00@ukr.net.

Белас Андрій Олегович, аспірант кафедри математичних методів системного аналізу, Інститут прикладного системного аналізу Національного технічного університету України “Київський політехнічний інститут імені Ігоря Сікорського”, Київ, Україна.

ORCID: 0000-0001-7883-2489.

E-mail: andrii.belas@gmail.com.

Belas Oleg, doctor of technical sciences, professor, professor at the department of special telecommunications systems, Institute of special communication and information protection of National technical university of Ukraine “Igor Sikorsky Kyiv polytechnic institute”, Kyiv, Ukraine.

Bidiuk Petro, doctor of technical sciences, professor, professor at the mathematical methods for system analysis academic department, Institute for applied system analysis of National Technical University of Ukraine “Igor Sikorsky Kyiv Polytechnic Institute”, Kyiv, Ukraine.

Belas Andrii, Ph.D. student, at the mathematical methods for system analysis academic department, Institute for applied system analysis of National Technical University of Ukraine “Igor Sikorsky Kyiv Polytechnic Institute”, Kyiv, Ukraine.

DOI 10.20535/2411-1031.2019.7.1.184397

УДК 621.396

ОЛЕКСАНДР ЖУК,
АНАСТАСІЯ ДНІПРОВСЬКА,
ОЛЕКСАНДР ЯРОВИЙ,
ОЛЕГ РУЩАК

АНАЛІЗ ЕФЕКТИВНОСТІ ВИКОРИСТАННЯ АТМОСФЕРНИХ ОПТИЧНИХ СИСТЕМ ПЕРЕДАЧІ

Одна з характерних рис науково-технічного прогресу початку XXI століття – зростання потреби в обробці, передачі і збереженні різних видів інформації. Широка смуга і двовимірність електромагнітних коливань оптичного діапазону, доступність візуального сприйняття, електрична нейтральність фотонів щонайкраще відповідають обробці і передачі великих масивів інформації, у тому числі представлених у зображеннях і відео. Приклади таких систем – атмосферні (відкриті) оптичні системи передачі. Відмінна риса їх – гранично великі щільності інформації в каналі і гранично високі швидкості її передачі. Для введення, обробки, ретрансляції інформації у атмосферних оптичних системах передачі потрібні пристрої – аналоги функціональних пристроїв надвисокої частоти, але працюючі в оптичному діапазоні з обсягами інформації і швидкостями її обробки. Такий же рівень техніки потрібно для обробки сигналів радіопроменевих систем, систем розпізнавання і відновлення образів і читаючих автоматів. Мережі волоконно-оптичних систем передачі інформації складаються з активних та пасивних компонентів і пристроїв (модулів), за допомогою яких здійснюється передача інформації. Остання має вигляд електричного групового