

ЕНЕРГЕТИЧНІ СИСТЕМИ ТА КОМПЛЕКСИ

УДК 621.311:681.3

КОРОТКОСТРОКОВЕ ПРОГНОЗУВАННЯ ЕЛЕКТРИЧНОГО НАВАНТАЖЕННЯ ЕЛЕКТРОПОСТАЧАЛЬНОЇ КОМПАНІЇ З ВИКОРИСТАННЯМ ШТУЧНОЇ НЕЙРОННОЇ МЕРЕЖІ ГЛИБИННОГО НАВЧАННЯ

П.О. Черненко, докт. техн. наук, **В.О. Мірошник**, інж.

Інститут електродинаміки НАН України,
пр. Перемоги, 56, Київ-57, 03680, Україна
e-mail: cher@ied.org.ua

Запропоновано нову архітектуру штучної нейронної мережі глибинного навчання eResNet для короткострокового прогнозування електричного навантаження електропостачальної компанії. Базовими блоками такої архітектури є шари автокодувального типу з обхідними з'єднаннями. Перший шар блока зменшує розмірність даних для виділення найбільш інформативних сигналів, другий – відновлює розмірність. Кожний шар включає нелінійну функцію SELU (scaled exponential linear unit). Обхідні з'єднання спрощують розповсюдження градієнта похибки, що дає змогу однаково ефективно навчати всі шари нейронної мережі. Проведено дослідження впливу розміру навчальної вибірки на точність прогнозування. Похибка MAPE нейронної мережі eResNet становить 3,69 % (у разі навчання на інформації за 11 років), похибка базатошарового перцептрона становить 3,85 % (у разі використання інформації за вісім років). Бібл. 13, рис. 3, таблиця.

Ключові слова: електричне навантаження, короткострокове прогнозування, штучна нейронна мережа, глибинне навчання.

Для розв'язання більшості технологічних задач планування режимів автоматизованої системи диспетчерського управління (АСДУ) енергосистемою необхідні добові графіки погодинного навантаження з певним упередженням (як правило, від 1 до 7 діб). Ця інформація отримується в результаті розв'язання задачі короткострокового прогнозування електричного навантаження (ЕН), тому ефективність розв'язання технологічних задач АСДУ суттєво залежить від точності та надійності результатів короткострокового прогнозування ЕН.

В умовах майбутнього лібералізованого ринку електричної енергії України у електропостачальних організаціях з'являються прямі економічні стимули для підвищення точності погодинних прогнозів свого ЕН. Згідно з прийнятим ЗУ «Про ринок електричної енергії» [1] та затвердженими «Правилами ринку» [2] електропостачальники є сторонами, відповідальними за баланс своїх споживачів та зобов'язані нести фінансову відповідальність за небаланси електричної енергії перед оператором системи передачі. Ціна небалансу буде залежати від маржинальної ціни на балансуєчому ринку за розрахунковий період.

В Інституті електродинаміки НАН України дослідження в галузі короткострокового прогнозування проводяться в двох напрямках: побудова аналітичної адитивної математичної моделі ЕН [3] та розвиток методів прогнозування з застосуванням штучних нейронних мереж (ШНМ).

Модульність аналітичної моделі та універсальність ШНМ дають можливість розробляти гібридні моделі, які використовують переваги обох підходів.

Процес розробки моделі для прогнозування можна розділити на два етапи:

- визначення форми функціонального зв'язку $y = f(x)$ між прогнозною величиною та факторами, які на неї впливають;
- оцінка параметрів θ моделі $y = f(x, \theta)$.

Зазвичай визначення форми функціонального зв'язку є набагато складнішою задачею і потребує від розробника додаткових знань про характер прогнозованої величини та факторів, які на неї впливають.

При побудові адитивної математичної моделі процес визначення $f(\cdot)$ полягає в розкладанні ЕН на складові залежно від характеру зовнішніх факторів, які впливають на зміну ЕН. У результаті кожна складова моделюється окремо, що дає змогу застосовувати математичні методи, які враховують особливості кожної складової оптимальним чином. Прогнозні значення ЕН формуються як сума прогнозів усіх складових. Такий підхід дає змогу коректно інтерпретувати результати прогнозування, аналізувати причини виникнення похибок та незалежно удосконалювати моделювання окремих складових. Недоліком такого підходу є те, що для розробки моделі розробник має глибоко розуміти особливості ЕН цього об'єкта.

Перевагою ж штучних нейронних мереж є те, що визначення, а точніше апроксимація, форми функціонального зв'язку проводиться безпосередньо в процесі навчання [4]. Оскільки обидві операції включені в одну оптимізаційну задачу, то нейронна мережа в процесі навчання прагне як краще з точки зору цільової функції апроксимувати форму функціонального зв'язку.

З теорії машинного навчання відомо, що за допомогою штучної нейронної мережі з одним прихованим шаром нейронів та нелінійною активаційною функцією можна апроксимувати будь-яку неперервну функцію з довільною точністю. Але на практиці далеко не завжди вдається досягти бажаної точності за допомогою ШНМ з одним прихованим шаром нейронів.

Протягом останніх 10 років у галузях комп'ютерного зору, автоматичного керування, обробки тексту та звуків досягнуто значних результатів, які в окремих задачах досягають та перевершують можливості людини. Основою для прориву стало значне зростання обчислювальних можливостей за рахунок сучасних графічних процесорів (GPU), збільшення кількості доступних даних, використання штучних нейронних мереж більш складної архітектури та вдосконалення методів їх навчання.

У роботах [5, 6] запропоновано використовувати послідовно декілька шарів одновимірної згортки (convolution) для короткострокового прогнозування електричного навантаження. Вихід згорткових шарів об'єднується зі значеннями зовнішніх факторів та подається у повнозв'язний шар або послідовність таких шарів. Запропонована у роботі [5] архітектура показує точність на рівні з мережами LSTM-S2S та FCRBM, а у [6] згорткова ШНМ показує значно кращий результат, ніж мережа типу LSTM. В обох роботах мережі глибинного навчання перевершують за точністю звичайні перцептрони та SVM.

Гібридна архітектура, яка запропонована в роботі [7], поєднує шари одновимірної згортки типу Insertion (входом яких є попередні 168 значень ЕН) та послідовно з'єднаний шар LSTM. Паралельно інформація щодо зовнішніх факторів подається до повнозв'язного шару, вихід якого об'єднується з виходом LSTM та подається в два послідовних повнозв'язних шари. Як і в попередніх роботах, подібна архітектура показує кращі результати, ніж проста LSTM та звичайний багатошаровий перцептрон (БШП).

Рекурентні ШНМ глибинного навчання типу LSTM та GRU у роботі [8] порівнюються зі звичайною рекурентною нейронною мережею. Особливістю цієї роботи є декомпозиція рядів ЕН з 15-хвилинною дискретністю на чотири ряди з різною періодичністю, які подаються на окремі рекурентні модулі. Обидві рекурентні мережі глибинного навчання перевершують за точністю просту рекурентну мережу. Загальним недоліком згаданих робіт можна назвати те, що у разі порівняння різних моделей не враховується кількість параметрів, що на пряму впливає на ефективність навчання, узагальнюючу здатність та точність моделі.

У роботі [9] доводиться, що причиною ефективності глибинних нейронних мереж є їх природня можливість відображати композиційні залежності виду

$$f(x_1, \dots, x_n) = h_1 \left(h_2 \left(h_3 \left(h_4 \left(\dots h_i(x_{n-k}, \dots, x_n) \right) \right) \right) \right), \quad (1)$$

де h_i можна інтерпретувати як вихід прихованого шару нейронів.




Рис. 1

Нейронна мережа з більшою кількістю прихованих шарів здатна точніше апроксимувати складні функціональні залежності, що дає змогу досягти кращих результатів.

Значного збільшення кількості шарів у мережі було досягнуто завдяки використанню обхідних з'єднань (shortcut connections) [10] між шарами прихованих нейронів (рис. 1 а). У роботі використовуються згорткові шари. Вихід блока з обхідним зв'язком можна записати як

$$y = W_2 * \sigma(W_1 * x) + x, \quad (2)$$

де y – вихідний вектор блока; W_1, W_2 – матриці вагових коефіцієнтів прихованих шарів; σ – функція логістичної сигмоїди; x – вхідний вектор першого прихованого шару; $*$ – операція згортки.

У цій й же роботі автори запропонували архітектуру на базі блоків з обхідними зв'язками *ResNet*, яка включає 152 згорткових шари. На момент створення ця нейронна мережа досягла найкращих результатів у конкурсі щодо розпізнавання зображень (ISVRC, 2015). Враховуючи універсальний характер обхідних з'єднань, вони можуть бути адаптовані для використання в задачі короткострокового прогнозування ЕН.

У роботі [11] показано, що така архітектура еквівалентна ансамблю простих нейронних мереж. Завдяки наявності обхідних з'єднань інформація передається з входу на вихід кількома шляхами з різною кількістю шарів. Це дає змогу градієнту похибки досягати відповідних вагових коефіцієнтів через меншу кількість шарів, що значно зменшує вплив ефекту нестабільності градієнта при навчанні (зменшенні чи збільшенні норми градієнта при розповсюдженні через шари ШНМ).

У цій роботі пропонується архітектура штучної нейронної мережі глибокого навчання для короткострокового прогнозування ЕН (рис. 1 в) – *eResNet*. Ця нейронна мережа складається з трьох блоків автокодувального типу (АК) з обхідними з'єднаннями (рис. 1 б). Особливістю архітектури такого типу є однакова кількість вхідних (d_x) та вихідних (d_y) нейронів та менша кількість прихованих (d_n) нейронів $d_x = d_y > d_n$. Вихід АК подається у звичайний багатозаровий перцептрон, виходом якого є прогнозне значення навантаження. Вихід блока АК задається формулою

$$y_{AK} = \text{selu}(\text{selu}(x \cdot W_1 + b_1) \cdot W_2 + b_2) + x. \quad (3)$$

Вихід всієї мережі розраховується таким чином:

$$y = \text{selu}(y_{AK} \cdot W_7 + b_7) \cdot W_8 + b_8. \quad (4)$$

Функція *selu* (scaled exponential linear unit) [12] має вигляд

$$\text{selu} = \lambda \begin{cases} z & z > 0 \\ \alpha e^z - \alpha & z \leq 0 \end{cases} \quad (5)$$

де z – лінійна комбінація виходів попереднього шару $z = Wx$; x – вектор-рядок виходів попереднього шару; λ, α – параметри, які необхідні для забезпечення властивості саморегуляризації $\alpha = 1,6733$ та $\lambda = 1,0507$.

Внаслідок великої кількості параметрів глибинні ШНМ більш схильні до перенавчання, але збільшення навчальної вибірки як за допомогою нових даних, так і штучно та застосування адекватних технік регуляризації дають змогу покращити узагальнюючі властивості мережі.

Для оцінки ефективності запропонованої архітектури точність прогнозування годинних значень ЕН *eResNet* порівнювалась з точністю прогнозу звичайного багатошарового персептрона з одним прихованим шаром нейронів (рис. 1 з). Кількість прихованих нейронів кожного блока АК $d_h = 10$, розмірність вхідного вектора $d_x = 168$, розмірність виходу $d_y = 168$. Сумарна кількість параметрів трьох блоків АК та багатошарового персептрона з $d_h = 10$ дорівнює 12 315. Альтернативна модель персептрона включає 72 прихованих нейрони, що сумарно дає 12 241 параметр. Для побудови моделей та прогнозування було використано дані ПАТ «Київенерго» за період з 01.01.2002 по 25.05.2017 (рис. 2) всього 134 760 годинних значень ЕН. Незважаючи на тривалий період часу та вплив фінансової кризи 2008–2009 років, дані є досить рівномірними, для того щоб використовувати для навчання ШНМ.




Рис. 2

Усі дані розбивались на навчальну та тестову вибірки. Тестова вибірка складалася з 8760 прикладів (вхідних векторів та відповідних бажаних вихідних значень) за період з 25.05.2016 по 25.05.2017, 10 % прикладів, які вибрані випадково з навчальної вибірки, використовувались тільки для контролю та не брали участі в розрахунку градієнта похибки.

Для обмеження ефекту перенавчання застосовувалась рання зупинка у разі незменшення значення функції втрат на контрольній вибірці в межах 0,001 протягом 40 епох, максимальна кількість епох навчання 100. При цьому зберігались всі нейронні мережі, які зменшували значення втрат на контрольній вибірці. Для розрахунку тестової похибки вибиралась нейронна мережа з найменшими значеннями втрат на контрольній вибірці.

Вихід обох нейронних мереж складається з одного нейрона, який відповідає навантаженню P_t на момент часу t . Вхідний шар нейронної мережі складається з 168 нейронів, які відповідають попереднім значенням ЕН з лагом від 24 до 192 годин:

$$y = P_t, x = [P_{t-24}, \dots, P_{t-192}]. \quad (6)$$

Попередня підготовка вхідних та вихідних змінних включала три етапи:

- виключення аномальних викидів;
- логарифмування для стабілізації дисперсії $x_{in} = \ln(x), y_{in} = \ln(y)$;

- нормалізація, середнє арифметичне та дисперсія розраховувались тільки на навчальній вибірці:

$$\tilde{x} = \frac{x_{in} - m_{x_{in}}^{НАВЧ}}{s_{x_{in}}^{НАВЧ}}, \tilde{y} = \frac{y_{in} - m_{y_{in}}^{НАВЧ}}{s_{y_{in}}^{НАВЧ}}, \quad (7)$$

де \tilde{x}, \tilde{y} – безпосередні значення входів та виходів нейронної мережі; $m_{x_{in}}^{НАВЧ}, m_{y_{in}}^{НАВЧ}$ – середньо-арифметичні значення вибірки; $s_{x_{in}}^{НАВЧ}, s_{y_{in}}^{НАВЧ}$ – середньоквадратичне відхилення вибірки.

Після зворотних перетворень виходів ШНМ (\tilde{y}) отримуємо значення ЕН в МВт, яке використовується для розрахунку похибок:

$$\hat{y} = e^{\tilde{y}} \cdot s_{y_{in}}^{НАВЧ} + m_{y_{in}}^{НАВЧ}. \quad (8)$$

Для оцінки похибки використовувалась функція MAPE:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100\%, \quad (9)$$

де y_i – фактичне значення навантаження в i -ту годину; \hat{y}_i – прогнози значення навантаження в i -ту годину.

Навчання проводилось у міні-пакетному режимі з допомогою алгоритму оптимізації AMSGrad [13] з 10 прикладами у кожному міні-пакеті, які вибираються з навчальної вибірки випадково згідно з рівномірним законом розподілу.

Для дослідження ефективності нейронних мереж глибокого навчання у разі наявності великої кількості даних процедура навчання проводилась 14 разів зі збільшенням навчальної вибірки на 8760 прикладів на кожному кроці. На 14 кроці використовувались усі доступні дані.

Залежність похибки на тестовій

вибірці від розміру навчальної вибірки зображена на рис. 3, числові значення наведені в таблиці.




Рис. 3

Нейронна мережа		Кількість років, які включено у навчальну вибірку													
		1	2	3	4	5	6	7	8	9	10	11	12	13	14
MAPE	БШП	4,43	4,09	4,00	3,92	3,86	3,89	3,93	3,85	3,99	3,90	3,95	3,89	3,88	3,85
	eResNet	4,48	4,24	4,08	3,95	3,91	3,92	3,79	3,78	3,82	3,92	3,69	3,74	3,83	3,86

З таблиці видно, що мінімальна похибка MAPE eResNet становить 3,69 % у разі навчання на вибірці, яка включає інформацію за 11 років. Мінімальна похибка багатосарового перцептрона становить 3,85 % у разі використання інформації за вісім років.

Висновки:

1. Враховуючи стохастичний характер навчання ШНМ, на основі наведених результатів можна зробити однозначний висновок, що запропонована архітектура штучної нейронної мережі глибокого навчання eResNet спроможна робити точніші прогнози, ніж стандартний багатосаровий перцептрон за наявності достатньої кількості даних.
2. Оскільки кількість параметрів в обох мережах приблизно рівна, то це підвищення точності пов'язано виключно з наявністю більшої кількості шарів та використанням об'єднаних з'єднань.
3. Для обох нейронних мереж збільшення навчальної вибірки до певного розміру призводить до зменшення похибки, після чого спостерігається ефект насичення, для звичайного багатосарового перцептрона він виявляється набагато раніше.

4. При використанні меншої кількості інформації (до шести років) звичайний перцептрон дає меншу точність прогнозів.

1. Про ринок електричної енергії: Закон України від 13.04.2017 р. № 2019-VIII. URL: <http://zakon3.rada.gov.ua/laws/show/2019-19> (дата звернення 21.07.2017).
2. Постанова НКРЕКП Про затвердження Правил ринку №307. URL: <http://zakon2.rada.gov.ua/laws/show/v0307874-18#n9> (дата звернення 14.03.2018).
3. Черненко П.О., Мартинюк О.В. Декомпозиція добового графіка електричного навантаження енергосистеми та моделювання його складових під час короткострокового прогнозування. *Вісник Вінницького політехнічного інституту*. 2017. Вип. 135. № 6. С. 86–93.
4. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*. 2015. Vol. 521. P. 436–444.
5. Amarasinghe K., Marino D.L., Manic M. Deep Neural Networks for Energy Load Forecasting. *Proc. 2017 IEEE 26TH International Symposium on Industrial Electronics (ISIE)*. 2017. P. 1483–1488.
6. Kuo P.H., Huang, C.J. A High Precision Artificial Neural Networks Model for Short-Term Energy Load Forecasting. *Energies*. 2018. Vol. 11. Issue 1. P. 213–226.
7. He W. Load Forecasting via Deep Neural Networks. *Proc. 5TH International Conference On Information Technology And Quantitative Management*. 2017. Vol. 122. P. 308–314.
8. Zhang B., Wu J.L., Chang P.C. A multiple time series-based recurrent neural network for short-term load forecasting. *Soft Computing*. 2018. Vol. 22. Issue 12. P. 4099–4112.
9. Mhaskar H.N., Poggio T. Deep vs. shallow networks: An approximation theory perspective. *Analysis and Applications*. 2016. Vol.14. Issue 6. P. 829–848.
10. He K.M., Zhang X.Y., Ren S.Q., Sun J. Deep Residual Learning for Image Recognition. *Proc. Conference on Computer Vision and Pattern Recognition*. 2016. P. 770–778.
11. Veit A., Wilber M., Velongie S. Residual networks behave like ensembles of relatively shallow networks. *Proc. Advances in Neural Information Processing Systems 29*. 2016. P. 550–558.
12. Klambauer G., Unterthiner T., Mayr A., Hochreiter S. Self-Normalizing Neural Networks. *Proc. Advances in Neural Information Processing Systems 30*. 2017. P. 971–980.
13. Reddi S.J., Kale S., Kumar S. On the Convergence of Adam and Beyond. ICLR 2018 Conference Submission. URL: <https://openreview.net/pdf?id=ryQu7f-RZ>

УДК 621.311:681.3

П.А. Черненко, докт. техн. наук, **В.А. Мирошник**, инж.

Институт электродинамики НАН Украины,

пр. Победы, 56, Киев-57, 03057, Украина

КРАТКОСРОЧНОЕ ПРОГНОЗИРОВАНИЕ ЭЛЕКТРИЧЕСКОЙ НАГРУЗКИ ЭНЕРГОСНАБЖАЮЩЕЙ КОМПАНИИ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ГЛУБИННОГО ОБУЧЕНИЯ

При внедрении нового рынка электрической энергии Украины у энергоснабжающих компаний появятся прямые экономические стимулы для повышения точности краткосрочных прогнозов своего потребления. В последнее время благодаря развитию вычислительной техники и наличию огромных объемов данных большую популярность в задачах классификации образов и прогнозирования приобрели нейронные сети глубинного обучения. В данной работе предложена новая архитектура искусственной нейронной сети глубинного обучения eResNet для краткосрочного прогнозирования электрической нагрузки энергоснабжающей организации. Базовыми блоками такой архитектуры являются слои типа автокодировщика с обходными соединениями. Первый слой блока уменьшает размерность данных для выделения наиболее информативных сигналов, второй слой восстанавливает размерность. Каждый слой включает нелинейную функцию SELU (scaled exponential linear unit). Обходные соединения упрощают распространение градиента погрешности, что позволяет одинаково эффективно обучать все слои нейронной сети. Проведено исследование влияния размера обучающей выборки на точность прогнозирования. Погрешность MAPE нейронной сети eResNet составляет 3,69 % (при обучении на информации за 11 лет), погрешность многослойного перцептрона составляет 3,85 % (при использовании информации за 8 лет). Библ. 13, рис. 3, таблица.

Ключевые слова: электрическая нагрузка, краткосрочное прогнозирование, искусственная нейронная сеть, глубинное обучение.

P. Chernenko, V. Miroshnyk

Institute of Electrodynamics of the National Academy of Sciences of Ukraine,

Peremohy, 56, Kyiv-57, 03680, Ukraine

SHORT-TERM ELECTRICAL LOAD FORECASTING FOR THE ELECTRICAL SUPPLY COMPANY WITH DEEP NEURAL NETWORK

With liberalization of the electricity market of Ukraine, electricity supply companies will have direct economic incentives to increase the accuracy of hourly load forecasts. Over the past 10 years, significant results achieved in the areas of computer vision, automated control, text and sound processing which outperform human-level. The basis for the

breakthrough was a significant increase in computing capabilities, due to modern graphics processors (GPUs), increased the availability of data, the development of more sophisticated machine learning algorithms. We present a new deep learning architecture eResNet for short-term forecasting of the hourly electrical load of the electrical supply company. Basic blocks of this architecture are the layers of the autoencoder type with the shortcut connections. The first layer of the block reduces the dimension of the data, to select the most informative signals, the second layer restores the dimension. Each layer includes a non-linear SELU (scaled exponential linear unit) function. Shortcut connections simplify the error gradient flow, which allows to effectively train all layers of the neural network. The study of the influence of the size of the training set on the accuracy of forecasting conducted. The MAPE of the eResNet is 3.69 % (when training set includes information for 11 years), the error of the multilayer perceptron is 3.85 % (using information for 8 years). References 13, figures 3, table.

Key words: electrical load, short-term forecasting, artificial neural network, deep learning.

1. Pro rynok elektrychnoi enerhii: Zakon Ukrainy vid 13.04.2017 r. № 2019-VIII. URL: <http://zakon3.rada.gov.ua/laws/show/2019-19> (data zatverdzhennia 21.07.2017).
2. Postanova NKREKP Pro zatverdzhennia Pravyl rynku №307. URL: <http://zakon2.rada.gov.ua/laws/show/v0307874-18#n9> (data zatverdzhennia 14.03.2018).
3. Chernenko P.O., Martyniuk O.V. Dekompozitsiia dobovoho hrafika elektrychnoho navantazhennia enerhosystemy ta modeliuvannia yoho skladovykh pid chas korotkostrokovoho prohnouzuvannia. Visnyk Vinnytskoho politekhnichnoho instytutu. Vinnytsia, 2017. № 6. Vyp. 135. S. 86–93.
4. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*. 2015. Vol. 521. P. 436–444.
5. Amarasinghe K., Marino D.L., Manic M. Deep Neural Networks for Energy Load Forecasting. Proc. 2017 IEEE 26TH International Symposium on Industrial Electronics (ISIE). 2017. P. 1483–1488.
6. Kuo P.H., Huang, C.J. A High Precision Artificial Neural Networks Model for Short-Term Energy Load Forecasting. *Energies*. 2018. Vol. 11. Issue 1. P. 213–226.
7. He W. Load Forecasting via Deep Neural Networks. Proc. 5TH International Conference On Information Technology And Quantitative Management. 2017. Vol. 122. P. 308–314.
8. Zhang B., Wu J.L., Chang P.C. A multiple time series-based recurrent neural network for short-term load forecasting. *Soft Computing*. 2018. Vol. 22. Issue 12. P. 4099–4112.
9. Mhaskar H.N., Poggio T. Deep vs. shallow networks: An approximation theory perspective. *Analysis and Applications*. 2016. Vol.14. Issue 6. P. 829–848.
10. He K.M., Zhang X.Y., Ren S.Q., Sun J. Deep Residual Learning for Image Recognition. Proc. Conference on Computer Vision and Pattern Recognition. 2016. P. 770–778.
11. Veit A., Wilber M., Velongie S. Residual networks behave like ensembles of relatively shallow networks. Proc. Advances in Neural Information Processing Systems 29. 2016. P. 550–558.
12. Klambauer G., Unterthiner T., Mayr A., Hochreiter S. Self-Normalizing Neural Networks. Proc. Advances in Neural Information Processing Systems 30. 2017. P. 971–980.
13. Reddi S.J., Kale S., Kumar S. On the Convergence of Adam and Beyond. ICLR 2018 Conference Submission. URL: <https://openreview.net/pdf?id=ryQu7f-RZ>

Надійшла 30.05.2018

Received 30.05.2018

УДК 621.316.1.016.25

ДЕКОМПОЗИЦІЯ ЕЛЕКТРИЧНИХ МЕРЕЖ ПРИ ОПТИМІЗАЦІЇ РЕАКТИВНИХ ПОТУЖНОСТЕЙ

Ю.І. Тугай^{1*}, докт. техн. наук, О.Д. Демов^{2**}, канд. техн. наук, Д.А. Нікішин^{3***},
Ю.Ю. Півнюк^{4****}

1, 3 –Інститут електродинаміки НАН України,
пр. Перемоги, 56, Київ-57, 03057, Україна
e-mail: tugay@ied.org.ua

2, 4 –Вінницький національний технічний університет,
вул. Хмельницьке шосе, 95, Вінниця, 21021, Україна,
e-mail: odemov@ukr.net

© Тугай Ю.І., Демов О.Д., Нікішин Д.А., Півнюк Ю.Ю., 2018

ORCID ID: *<https://orcid.org/0000-0002-0704-1863>; **<https://orcid.org/0000-0002-2999-0656>;

<https://orcid.org/0000-0002-2888-3699>; *<https://orcid.org/0000-0003-2963-8019>