

**ОДНОФАКТОРНЕ КОРОТКОСТРОКОВЕ ПРОГНОЗУВАННЯ ВУЗЛОВИХ
ЕЛЕКТРИЧНИХ НАВАНТАЖЕНЬ ЕНЕРГОСИСТЕМИ****П.О. Черненко***, докт. техн. наук, **В.О. Мірошник****, **П.В. Шиманюк**Інститут електродинаміки НАН України,
пр. Перемоги, 56, Київ, 03057, Україна,e-mail: cher@ied.org.ua

Запропоновано комбіновану архітектуру штучної нейронної мережі глибокого навчання для векторного прогнозування вузлових навантажень, в якій використовується рекурентний модуль типу LSTM (Long short-term memory – мережі довгої короткострокової пам'яті), вихід якого подається до багатошарового перцептронну з активаційною функцією SELU (scaled exponential linear unit – масштабована експоненційно лінійна функція). Для підвищення ефективності навчання використовується обхідне з'єднання, яке полягає в додаванні входу нейронної мережі до виходу. Проведено порівняльний аналіз двох підходів до короткострокового прогнозування вузлових навантажень енергосистеми. При першому підході для кожного вузла навантаження будується окрема модель на базі штучної нейронної мережі eResNet, при другому – здійснюється векторне прогнозування значень вузлових навантажень з використанням побудованої комбінованої нейронної мережі. Другий підхід дозволяє використати взаємозв'язок між навантаженнями в вузлах енергосистеми та зменшити кількість обчислювальних операцій, необхідних для побудови моделі, особливо при значній кількості вузлів в енергосистемі. Бібл. 11, рис. 1, табл. 3.

Ключові слова: вузлове електричне навантаження, короткострокове прогнозування, штучна нейронна мережа, рекурентна мережа

Для розв'язання більшості технологічних задач планування режимів автоматизованої системи диспетчерського управління (АСДУ) необхідно розраховувати усталений режим енергосистеми (ЕС) з певним випередженням. Для розрахунку очікуваного усталеного режиму необхідно прогнозувати значення активної та реактивної потужності у вузлах заступної схеми енергосистеми. Зараз ця задача вирішується спрощено: спочатку прогнозується сумарне електричне навантаження (СЕН) активної потужності енергосистеми, а значення вузлових навантажень знаходяться за коефіцієнтами залежності (пропорційності) вузлових навантажень від значень СЕН, реактивні вузлові навантаження – таким же чином або по заданому $tg\varphi$. Ці коефіцієнти і значення $tg\varphi$ отримують за результатами спеціально організованих вимірів в період максимуму (взимку) та мінімуму (влітку) графіків сумарного навантаження ЕС. Завдяки тому, що зміни в часі сумарного і вузлових навантажень є нестационарними часовими рядами, то таким чином визначенні вузлові навантаження є наближеними і викривлено відображають їхню реальну зміну в часі. В результаті такими ж наближеними є результати розв'язання технологічних задач планування режимів ЕС.

З розробкою алгоритму та програми оперативного розрахунку усталеного режиму ЕС за даними телеметрії (State estimation) та використання їх в промисловій експлуатації в регіональній та об'єднаній ЕС з'явилась інформаційна база для прогнозування активних та реактивних вузлових навантажень. Розрахунок поточних і ретроспективних режимів в енергосистемах України та державах близького зарубіжжя в даний час, як правило, вирішується в умовах неповної спостережуваності режимів. Тому для проведення розрахунку всіх параметрів режиму необхідно використовувати певну кількість псевдовимірів у вигляді даних контрольних вимірів. З метою мінімізації їхньої кількості у роботі [1] використовуються обмеження на параметри режиму.

В результаті проведеної в останні часи роботи по інформатизації енергетичних об'єктів, особливо в частині впровадження автоматизованих систем комерційного обліку електроспоживання (АСКОЕ), з'явилась можливість отримання графіків активних вузлових навантажень з дискретністю в тридцять хвилин або одну годину. Ця інформація часто має пропуски даних в одну, декілька годин,

дів, а іноді і місяців, тому підвищення достовірності цих даних є досить складною задачею і потребує багато часу. В таких випадках застосовують два підходи: перший – коли в аналіз і прогноз включають тільки вузли з повною інформацією; другий – аналіз проводять за повною заступною схемою зі свідомо наближеною оцінкою навантаження в неповно спостережуваних вузлах.

З метою підвищення точності розрахунків сталого режиму проводились роботи із статистичного аналізу [2] та прогнозування вузлових навантажень енергосистеми [3]. Однак ці роботи проводились тільки для вузлів навантаження, по яких була вимірювана інформація з різною дискретністю, або за допомогою експертних методів з врахуванням подібності коефіцієнтів математичної моделі для вимірюваних і невимірюваних значень навантаження різних вузлів [4]. В останніх випадках важко оцінити похибку таких штучно модельованих вузлових навантажень.

Останнім часом з'явилося більше публікацій щодо прогнозування сумарних і вузлових навантажень ЕС із застосуванням методів штучного інтелекту у вигляді нейронних мереж (НМ) різної архітектури: багатшарового перцептрон (MLP) в поєднанні з методом інверсій [5], методу опорних векторів [6], нелінійних авторегресійних моделей [7] та більш удосконалених НМ глибинного навчання [8, 16]. Так у [9] для прогнозування вузлових навантажень використовувався метод опорних векторів (SVM – Support Vector Machine). **Метою** даного дослідження є порівняння двох підходів до розв'язання задачі короткострокового прогнозування навантаження вузлів енергосистеми. При першому підході для кожного вузла навантаження будується окрема модель і прогноз проводиться незалежно; при другому – здійснюється векторне прогнозування значень вузлових навантажень з використанням однієї нейронної мережі, що дозволяє врахувати взаємозв'язок між навантаженням вузлів однієї енергосистеми. Особливістю даної роботи є використання методу непрямой оцінки для вузлів з наявністю пропущених або недостовірних даних.



Рис. 1

У проведених Інститутом електродинаміки НАН України дослідженнях, частина яких викладається у статті, як оператор прогнозування активної складової вузлового навантаження пропонується комбінована архітектура нейронної мережі глибинного навчання з використанням модуля LSTM та НМ типу багатшаровий перцептрон. Архітектуру даної моделі наведено на рис. 1. Далі під вузловим навантаженням мається на увазі активна складова, бо інформація про реактивну складову відсутня.

При однофакторному прогнозуванні на вхід НМ подаються погодинні нормовані значення активного навантаження вузлів $X_t \in R^{l \times n}$, де n – кількість вузлів, l – кількість погодинних значень (лагів), які передують прогнозній годині з врахуванням горизонту упередження (p). Так, наприклад, якщо горизонт упередження становить 24 години і $n=3$, то для прогнозу на годину t на вхід мережі подається

$$X_t = \begin{pmatrix} y_{t-24}^1 & y_{t-24}^2 & y_{t-24}^3 \\ y_{t-25}^1 & y_{t-25}^2 & y_{t-25}^3 \\ \dots & \dots & \dots \\ y_{t-24-l}^1 & y_{t-24-l}^2 & y_{t-24-l}^3 \end{pmatrix}.$$

У пакетному режимі роботи на вхід НМ подається 3-вимірна матриця $X \in R^{m \times l \times n}$. Виходом нейронної мережі є вектор погодинних значень навантаження $y_t \in R^n$.

Для оцінки вагових коефіцієнтів НМ використовується критерій мінімуму квадратів відхилень прогнозних значень від фактичних

$$L(y, X, W) = \frac{1}{2m} \sum_{j=1}^n \sum_{t=1}^m \left(y_t^j - f^j(X_t, W) \right)^2,$$

де $L(y, X, W)$ – скалярна функція векторних аргументів; n – кількість вузлів; m – кількість годин в навчальній вибірці або мініпакетів; y_t^j – фактичне значення електричного навантаження в t -ту годину j -го вузла; $f^j(X_t, \hat{W})$ – прогнозне значення електричного навантаження j -го вузла в годину t ;

X_t – вхідний масив даних для t -ої прогнозованої години; \hat{W} – оцінки вагових коефіцієнтів нейронної мережі.

Використання рекурентного модулю LSTM [10] дозволяє НМ враховувати попередні значення часового ряду, які несуть інформацію про прогнозне значення. Модуль LSTM складається з чотирьох матриць вагових коефіцієнтів W_f, W_i, W_c, W_o та вектору стану, які зв'язані наступними співвідношеннями:

$$\begin{aligned} f_k &= \sigma(W_f [h_{k-1}, x_k] + b_f); & i_k &= \sigma(W_i [h_{k-1}, x_k] + b_i); & \tilde{c}_k &= \tanh(W_c [h_{k-1}, x_k] + b_c); \\ c_k &= f_k \cdot c_{k-1} + i_k \cdot \tilde{c}_k; & o_k &= \sigma(W_o [h_{k-1}, x_k] + b_o); & h_k &= o_k \tanh(c_k), \end{aligned}$$

де k – номер рядка матриці X_t ; f_k, i_k, o_k – вихідні вектори прихованих шарів модулю LSTM; σ – сигмоїдальна функція активації нейрону, $\sigma(z) = (1 + e^{-z})^{-1}$; W_f, W_i, W_c, W_o – вагові коефіцієнти; b_f, b_i, b_c, b_o – коефіцієнти зсуву; x_k – матриця вхідних значень; h_{k-1}, h_k – прогнозные значення; c_k, c_{k-1} – вектор пам'яті.

Вектори пам'яті (c_k) та вихід LSTM попереднього кроку (h) ініціалізуються нульовими значеннями на кожному прикладі x_k . Вектор \tilde{c}_k представляє новий варіант значень пам'яті, а вектори f_k та i_k регулюють ступінь оновлення вектору пам'яті новими значеннями. За рахунок того, що значення W_f, W_i і b_f, b_i оцінюються в процесі навчання, нейронна мережа регулює динаміку оновлення c_k оптимальним чином з точки зору мінімізації критерію y, X, W . Крім того, наявність вектору пам'яті дає змогу зменшити ефект екстремального зменшення або збільшення норми градієнту при зворотному розповсюдженні похибки, що поряд з використанням обхідного з'єднання, яке згладжує поверхню похибки нейронної мережі, суттєво прискорює навчання та дозволяє досягти меншої похибки прогнозування. Першим на вхід LSTM подається останній рядок x_t .

Вихід модулю LSTM вводиться в багатошаровий перцептрон з двома прихованими шарами (Dense_1, Dense_2). Розмірність Dense_1 обирається більшою за n , розмірність Dense_2 повинна дорівнювати n , оскільки вихід перцептрону поелементно додається до входу нейронної мережі. В однофакторному варіанті в обхідному з'єднанні не використовуються додаткові матриці вагових коефіцієнтів. Як активаційна функція прихованого шару MLP використовується функція *selu* (scaled exponential linear unit) [11], яка має вигляд

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

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

Вихід НМ задається формулою $\hat{y}_k = x_1 + W_2 \cdot \text{selu}(W_1 \cdot h_k + b_1) + b_2$.

Обхідне з'єднання полягає в додаванні до вихідних значень нейронної мережі її вхідних значень. В запропонованій нейронній мережі передається тільки перший рядок x_1 .

Ефективність обхідних з'єднань розглянуто в ряді теоретичних робіт. У [12] показано, що така архітектура еквівалентна ансамблю простих нейронних мереж. Завдяки наявності обхідних з'єднань інформація передається з входу на вихід декількома шляхами з різною кількістю шарів. Це дозволяє градієнту похибки досягати відповідних вагових коефіцієнтів через меншу кількість шарів, що значно зменшує вплив ефекту нестабільності градієнту при навчанні (зменшенні чи збільшенні норми градієнту при розповсюдженні через шари НМ). У [13] даний ефект інтерпретується з точки зору геометрії гіперплощини функції втрат. В роботі стверджується, що наявність обхідних з'єднань згладжує гіперплощину втрат та суттєво полегшує навчання нейронних мереж з великою кількістю шарів.

У роботі навчання проводиться у мініпакетному режимі за допомогою алгоритму оптимізації ADAM [14] з параметрами $lr=0,001$, $b_1=0,9$ та $b_2=0,999$. Цей алгоритм використовує градієнт функції похибки для уточнення вагових коефіцієнтів та квадрат градієнту для оцінки її кривизни. Оновлення вагових коефіцієнтів проводиться за наступною процедурою:

$$w_t = w_{t-1} - \alpha \hat{m}_t / (\sqrt{v_t} + \varepsilon), \quad \hat{m}_t = m_t / (1 - \beta_1^t), \quad m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t,$$

де t – номер ітерації процедури навчання; w_t, w_{t-1} – векторизовані матриці вагових коефіцієнтів на ітерації t та $t-1$; α – крок навчання, рекомендоване значення 0,001; ε – константа, що запобігає похибкам обчислення при діленні на 0, зазвичай $\varepsilon = 10^{-8}$; \hat{m}_t – вектор скоригованих експоненційно згладжених значень градієнту; m_t – експоненційно згладжений вектор градієнту; g_t – градієнт функції похибки; β_1 – коефіцієнт згладжування; \hat{v}_t – вектор скоригованих експоненційно згладжених значень квадрату градієнту, який обчислюється за процедурою

$$\hat{v}_t = v_t / (1 - \beta_2^t), \quad v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2.$$

де v_t – експоненційно згладжений вектор квадрату градієнту

Квадрат градієнту розраховується поелементно. На першій ітерації m_0 та v_0 ініціалізуються нульовими векторами. Дана процедура навчання адаптивно коригує значення кроку навчання для кожного окремого параметру і зменшує його з кожною ітерацією. Цей алгоритм показав високу ефективність в задачах оптимізації з великою кількістю параметрів, до яких відносяться НМ глибинного навчання.

За результатами процедури перехресної перевірки кількість прихованих нейронів в LSTM = 50, Dense_1 = 20, Dense_2 = n.

Для апробації запропонованої моделі використовувались погодинні дані про вузлове електричне навантаження енергосистеми континентальної частини Європи [15]. У даному наборі представлено погодинні значення для 1494 вузлів за період з 2012 по 2014 рр. Значення навантаження вузлів отримано шляхом зваження сумарного навантаження конкретної країни (або регіону) по щільності населення в околі кожного вузла. В результаті такої підготовки даних суттєвою проблемою є сильна кореляція між вузлами, оскільки дані відрізняються тільки масштабом.

Для навчання НМ використовувались дані за 2012-2013 рр. Оцінювання показників точності прогнозу проводилася за даними 2014 року.

Для прогнозування обрано 11 вузлів за критеріями мінімуму кореляції і компактного місцерозташування. Узагальнені статистичні показники для даних часових рядів наведено у табл. 1.

Таблиця 1

	1	2	3	4	5	6	7	8	9	10	11
Математичне сподівання, МВт	187,3	183,5	61,7	67,3	49,5	42,7	44,4	25,0	16,0	15,5	21,9
Середньоквадратичне відхилення, МВт	35,5	38,8	14,0	11,3	8,6	8,4	7,7	4,1	2,8	2,7	3,6
Мін. значення, МВт	100,1	95,3	33,1	40,8	29,5	19,7	26,6	15,6	9,5	9,6	13,9
Макс. значення, МВт	271,3	275,2	114,6	102,2	74,7	66,6	67,8	37,7	24,6	25,8	33,2

Результати прогнозів із застосуванням комбінованої НМ мережі глибинного навчання порівнювались з прогнозами нейронної мережі eResNet [16]. Остання складається з 3-х блоків автокодуючого типу (АК) з обхідними з'єднаннями. Особливістю архітектури даного типу є однакова кількість вхідних (d_x) та вихідних (d_y) нейронів та менша кількість прихованих (d_h) нейронів ($d_x = d_y > d_h$). Вхід АК блоку поелементно додається з його виходом, тим самим утворюючи обхідне з'єднання. Вихід останнього блоку АК подається на вхід багат шарового перцептронну, виходом якого є прогнозне значення навантаження.

Для оцінки похибки прогнозу навантаження одного вузла використовувалась функція MAPE

$$MAPE = \frac{1}{m} \sum_{t=1}^m \left| \frac{y_t - \hat{y}_t}{y_t} \right| \cdot 100\%, \quad \text{де } y_t, \hat{y}_t - \text{фактичні та прогнозні значення навантаження в } t\text{-ту годину.}$$

Для порівняння моделей використовується середнє значення MAPE (μ) по всіх 11 вузлах та стандартне відхилення MAPE (σ). У табл. 2 та на рис. 2 наведено значення μ в залежності від значення лагу l . В мережі eResNet параметр l впливає на розмірність вхідного вектору, в той час як в мережі LSTM кількість параметрів залишається незмінною через те, що дані використовуються

поступово по 24 значення за один цикл роботи LSTM. При цьому для прогнозу використовується тільки останнє значення, яке повертає модуль LSTM.

В практиці експлуатації енергосистем виникають ситуації, коли необхідно збільшувати горизонт упередження прогнозу. В табл. 3 та на рис. 3 наведено значення похибки при прогнозуванні з різним горизонтом упередження для мереж з різними використаними модулями LSTM та eResNet.

Таблиця 2

	1	2	3	4	5	6	7	8	9	10	11	μ	σ
LSTM													
$l = 24$	5,13	6,36	4,23	4,31	4,84	5,21	4,54	4,24	4,64	3,95	4,15	4,69	0,68
$l = 48$	5,11	5,76	3,72	3,87	4,43	5,09	4,03	3,67	4,23	3,34	3,68	4,26	0,76
$l = 72$	4,43	3,8	2,91	2,89	3,11	4,28	2,8	2,52	2,93	2,4	2,63	3,16	0,7
$l = 96$	3,71	3,81	2,8	2,93	2,98	3,99	2,44	2,41	2,6	2,37	2,57	2,97	0,6
$l = 120$	3,26	4,13	2,95	2,94	3,3	4,39	3,12	2,64	3,2	2,4	2,7	3,18	0,6
$l = 144$	3,98	4,59	3,03	3,33	3,57	4,39	3,18	2,92	3,34	2,73	3,07	3,47	0,61
$l = 168$	4,02	4,23	3,18	3,47	3,58	4,71	3,18	3,01	3,28	2,78	3,15	3,51	0,58
$l = 192$	3,99	4,29	3,16	3,15	3,67	4,7	3,27	2,87	3,43	2,68	2,97	3,47	0,63
eResNet													
$l = 24$	11,72	11,03	9,6	7,2	7,85	6,87	7,15	9,29	7,53	6,85	7,23	8,39	1,74
$l = 48$	5,13	6,36	4,23	4,31	4,84	5,21	4,54	4,24	4,64	3,95	4,15	4,69	0,68
$l = 72$	6,1	6,91	5,75	4,99	5,57	5,96	5,09	4,82	5,22	4,9	4,92	5,48	0,66
$l = 96$	5,64	6,46	5,37	4,51	5,18	5,58	4,71	4,41	4,8	4,67	4,42	5,07	0,65
$l = 120$	4,54	5,55	5,14	3,74	4,57	5,1	3,87	3,68	4,04	4,03	3,66	4,36	0,67
$l = 144$	4,25	5,01	4,62	3,53	4,09	4,91	3,59	3,34	3,68	3,51	3,35	3,99	0,62
$l = 168$	2,99	4,36	3,66	2,75	3,36	4,12	2,84	2,65	2,9	2,67	2,76	3,19	0,61
$l = 192$	3,02	4,22	3,39	2,72	3,31	4,11	2,63	2,5	2,76	2,58	2,54	3,07	0,62
$l = 216$	2,83	4,27	3,41	2,67	3,29	4,14	2,67	2,53	2,73	2,55	2,57	3,06	0,64
$l = 240$	2,92	4,17	3,33	2,73	3,24	4,13	2,56	2,44	2,65	2,56	2,59	3,03	0,62
$l = 264$	2,99	4,13	3,41	2,81	3,27	4,21	2,56	2,48	2,67	2,61	2,7	3,08	0,61

Таблиця 3

Горизонт прогнозування	1	2	3	4	5	6	7	8	9	10	11	μ	σ
LSTM													
24	3,71	3,81	2,8	2,93	2,98	3,99	2,44	2,41	2,6	2,37	2,57	2,97	0,6
48	4,84	5,15	3,85	4,14	4,02	4,95	3,42	3,48	3,64	3,22	3,72	4,04	0,66
72	5,66	6,29	4,42	4	4,43	5,02	3,7	3,48	3,81	3,38	3,74	4,36	0,94
96	5,27	6,22	5	4,29	4,48	5,37	3,78	3,66	4,04	3,72	3,97	4,53	0,83
eResNet													
24	2,92	4,17	3,33	2,73	3,24	4,13	2,56	2,44	2,65	2,56	2,59	3,03	0,62
48	3,82	5	4,34	3,36	3,78	4,63	3,14	2,98	3,27	3,23	3,16	3,7	0,68
72	4,29	5,48	4,76	3,68	4,07	4,73	3,38	3,25	3,48	3,57	3,41	4,01	0,72
96	4,6	5,62	5,28	3,79	4,24	4,84	3,53	3,38	3,61	3,69	3,6	4,2	0,78

Наведені результати показують, що нейронна мережа з модулем LSTM дещо випереджає за точністю мережі eResNet, і перевагою рекурентної мережі є її масштабованість. При кількості прихованих нейронів LSTM = 50, Dense_1 = 20 кількість вагових коефіцієнтів в рекурентній мережі становить 13651 і не залежить від лагу l . При окремому прогнозуванні навантаження кожного вузла використовується 11 мереж з 17571 ваговим коефіцієнтом, що сумарно складає 193281 при $l=240$. Із

зростанням кількості вузлів сумарна кількість параметрів eResNet зростає швидше, ніж в рекурентній мережі, що підвищує вимоги до обчислювальних ресурсів. Проте, за рахунок рекурентних операцій в мережі LSTM, час навчання однієї мережі eResNet менший, але сумарно для навчання 11 НМ необхідно більше обчислювальних ресурсів.




Рис. 2




Рис. 3

Висновки. Запропоновано комбіновану архітектуру штучної нейронної мережі глибинного навчання, яка включає рекурентний модуль LSTM та багатoshаровий перцептрон, що дозволяє прогнозувати всі вузли навантаження енергосистеми одночасно, враховуючи взаємозв'язок між ними. Безперечною перевагою мережі на базі LSTM є значно менша кількість вагових коефіцієнтів, що знижує необхідний об'єм ресурсів для навчання НМ, навіть при використанні рекурентних операцій. Цей ефект є особливо важливим для прогнозування навантаження значної кількості вузлів, що може сягати декількох сотень у реальних енергосистемах. Середня похибка прогнозу на 24 години мережі на базі модуля LSTM становить 2,97%, в той час як при окремому прогнозуванні кожного вузла середня похибка складає 3,03%. При цьому зі збільшенням горизонту прогнозування похибка мереж eResNet росте повільніше, ніж при векторному прогнозі за допомогою мережі з модулем LSTM.

Роботу виконано за бюджетною темою «Розвиток засобів комп'ютерного моделювання ЕЕС для оперативного та короткострокового прогнозування навантаження та рівня стійкості ОЕС України» (шифр «Система-6»), державний реєстраційний номер 0115U005309.

1. Chernenko P.A., Pryhno. V.L. Operational calculation of the stationary mode of energy connection with a shortage telemetry. *Elektrichestvo*. 1985. No 12. Pp. 12-15. (Rus)
2. Gusejnov F.G., Chernenko P.A. To the statistic analysis of the load node of the energy system. *Problemy tekhnicheskoi elektrodinamiki*. 1971. No 30. Pp. 15-20. (Rus)
3. Chernenko P.A., Kuznecov G.G. Determination of information content and short-term forecasting of periodically unsteady random processes in electric power systems. Prieprint-157. Kiev: Institut Elektrodinamiki Natsionalnoi Akademii Nauk Ukrainy, 1977. P. 39. (Rus)
4. Valtin Yu.Yu., Meldorf M.V. Forecasting the load of power system nodes according to expert data. *Trudy Tallinskogo politekhnicheskogo instituta*. 1978. No 453. Pp. 17-22. (Rus)
5. Shumilova G.P., Gotman N.Je., Starceva T.B. Prediction of the active and reactive load of EPS units using inversion of an artificial neural network. *Elektrichestvo*. No 6. 2007. Pp. 7-13.
6. Han X.S., Han L., Gooi H.B., Pan Z.Y. Ultra-short-term multi-node load forecasting - a composite approach *IET Generation, Transmission & Distribution*. 2012. No 6. DOI: <http://dx.doi.org/10.1049/iet-gtd.2011.0524>
7. Falcao D.M., Bezerra U.H. Short-term forecasting of nodal active and reactive load in electric power system'. 2nd IEE Int. Conf. on Power Systems Monitoring and Control Durham, UK, July. 1986. Pp. 18-22.
8. Chernenko P., Miroshnyk V. Increasing the accuracy of short-term electrical load forecasting with considering to changes in the structure of consumption during the year. *Pratsi Instytutu Elektrodinamiki Natsionalnoi Akademii Nauk Ukrainy*. 2017. No 48. Pp. 5-11. (Ukr) DOI: <https://doi.org/10.15407/publishing2017.48.005>
9. Aoyang Han, Bin Zhang, Zhongliang Sun, Zhiqiang Niu, Junxiong Wang Nodal load forecast model considering network topology constraints. *IEEE PES Asia-Pacific Power and Energy Conference*. Xi'an.China. 2016. Pp. 939-943.
10. Hochreiter Sepp, Schmidhuber Jürgen. Long Short-term Memory. *Neural computation*. 1997. No 9. Pp 1735-1780. DOI: <https://doi.org/10.1162/neco.1997.9.8.1735>

11. Klambauer G., Unterthiner T., Mayr A., Hochreiter S. Self-Normalizing Neural Networks. *Advances in Neural Information Processing Systems*. 2017. No 30. Pp. 971-980.
12. Veit A., Wilber M., Velongie S. Residual networks behave like ensembles of relatively shallow networks. *Advances in Neural Information Processing Systems*. 2016. No 29. Pp. 550-558.
13. Li H., Xu Z., Taylor G., Studer C., Goldstein T. Visualizing the loss landscape of neural nets. Proceedings of the 32nd International Conference on *Neural Information Processing Systems (NIPS'18)*. Montréal. Canada. 2018. Pp. 6391-6401.
14. Kingma D.P., Ba J. Adam. A Method for Stochastic Optimization. Proc. of the 3rd International Conference on *Learning Representations (ICLR)*. San Diego. USA. 2014. Pp.1-15.
15. Jensen T.V., Pinson P. RE-Europe, a large-scale dataset for modeling a highly renewable European electricity system. *Scientific Data*. 2017. 4, 170175. DOI: <https://doi.org/10.1038/sdata.2017.175>
16. Chernenko P.O., Miroschnik V.O. Short-term electrical load forecasting for the electrical supply company with deep neural network. *Pratsi Instytutu Elektrodynamiky Natsionalnoi Akademii Nauk Ukrainy*. 2018. No 50. Pp. 5-11. (Ukr) DOI: <https://doi.org/10.15407/publishing2018.50.005>

UNIVARIABLE SHORT-TERM FORECAST OF NODAL ELECTRICAL LOADS OF ENERGY SYSTEMS

P.O. Chernenko V.O. Miroschnik P.V. Shymaniuk

Institute of Electrodynamics of National Academy of Sciences of Ukraine

Pr. Peremohy, 56, Kyiv, 03057, Ukraine, e-mail: cher@ied.org.ua

The paper proposes the architecture of deep learning neural network for short-term nodal electrical load forecasting. The neural network combines the recurrent module LSTM (Long short-term memory) and the multilayer perceptron on the top. Input and output of the network connected with shortcut connection. In multilayer perceptron used scaled exponential linear unit (SELU) function as a nonlinear transformation in hidden neurons. A comparative analysis of two approaches to the short-term prediction of node loadings of the grid is conducted. In the first approach, a separate model based on the artificial neural network eResNet is built for each load node. In the second approach, vector prediction of the values of the nodal load is performed using the proposed neural network. The second approach makes it possible to exploit the relationship between the loads in the nodes and reduce the number of computational operations required to build the model, especially at a large number of nodes. Recurrent network showed slightly better result when forecasting horizon was 24 hours, but eResNet showed more accurate forecast with longer horizons. References 11, figure 1, tables 3.

Keywords: nodal electrical load, short-term forecasting, artificial neural network, recurrent network

ОДНОФАКТОРНОЕ КРАТКОСТРОЧНОЕ ПРОГНОЗИРОВАНИЕ УЗЛОВЫХ ЭЛЕКТРИЧЕСКИХ НАГРУЗОК ЭНЕРГОСИСТЕМЫ

П.А. Черненко., докт. техн. наук, В.А. Мирошник, П.В. Шиманюк

Институт электродинамики НАН Украины,

пр. Победы, 56, Киев, 03057, Украина, e-mail: cher@ied.org.ua

Предложена комбинированная архитектура искусственной нейронной сети глубокого обучения для векторного прогнозирования узловых нагрузок. Особенностью данной нейронной сети есть использование рекуррентного модуля типа LSTM (Long short-term memory – сети долгой краткосрочной памяти), выход которого подается в многослойный перцептрон с активационной функцией SELU (scaled exponential linear unit – масштабированная экспоненциально линейная функция). Для повышения эффективности обучения используется обходное соединение, суть которого заключается в поэлементном суммировании входа и выхода нейронной сети. Проведен сравнительный анализ двух подходов к краткосрочному прогнозированию узловых нагрузок энергосистемы. При первом подходе для каждого узла нагрузки строится отдельная модель на базе искусственной нейронной сети eResNet. При втором подходе осуществляется векторное прогнозирование значений узловых нагрузок с применением предложенной комбинированной нейронной сети. Второй подход позволяет, используя взаимосвязь между нагрузками узлов энергосистемы, уменьшить количество вычислительных операций, необходимых для построения модели, особенно при большом количестве узлов в энергосистеме. Библ. 11, рис. 1, табл. 3.

Ключевые слова: узловая электрическая нагрузка, краткосрочное прогнозирование, искусственная нейронная сеть, рекуррентная сеть

Надійшла 03.12.2019
Остаточний варіант 20.01.2020