

ЕНЕРГЕТИЧНІ СИСТЕМИ ТА КОМПЛЕКСИ

УДК 621.311:681.3

ПІДВИЩЕННЯ ТОЧНОСТІ КОРОТКОСТРОКОВОГО ПРОГНОЗУВАННЯ ЕЛЕКТРИЧНОГО НАВАНТАЖЕННЯ ЗА ДОПОМОГОЮ ШТУЧНОЇ НЕЙРОННОЇ МЕРЕЖІ З ВРАХУВАННЯМ ЗМІНИ СТРУКТУРИ СПОЖИВАННЯ ПРОТЯГОМ РОКУ

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

Описано методику підвищення точності короткострокового прогнозування сумарного електричного навантаження (СЕН) енергопостачальної компанії шляхом зміни режиму навчання та прогнозування штучної нейронної мережі типу багатошаровий перцептрон залежно від зміни складу електричного навантаження компанії протягом року. Розглянуто два підходи, які враховують різну поведінку СЕН в опалювальний сезон та міжсезоння. Як активаційну функцію нейронів прихованого шару використано функцію SELU (scaled exponential linear unit). При першому підході нейронна мережа включала додатковий вхідний нейрон, який набуває значення 1 – для днів, які входять до опалювального сезону, та 0 – для днів міжсезоння. При цьому вказана модель навчалась на річних даних. При другому підході розроблено дві окремі нейронні мережі для роботи протягом різних сезонів року. Оцінка точності та стабільності результатів прогнозування проводилась на реальних даних ПАТ «Київенерго» за 2015–2016 рр. Бібл. 8, рис. 3, таблиця.

Ключові слова: електричне навантаження, річна періодичність, короткострокове прогнозування, штучна нейронна мережа.

Результати короткострокового прогнозування (з упередженням від 1 до 7 діб) добових графіків сумарного електричного навантаження (СЕН), або попиту на електричну енергію є основою для планування режиму роботи ОЕС України. В ДП «Енергоринок» вони необхідні для формування графіка покриття, тобто визначення необхідної генеруючої потужності на кожну годину добового графіка. Згідно з Законом України "Про ринок електричної енергії" у всіх учасників ринку на завтра, внутрішньодобового та балансуєчого ринків підвищується відповідальність за недотримання заявленого добового графіка. До певної міри небаланс може бути зменшений за рахунок підвищення точності прогнозів споживання електричної енергії. Для трейдерів та електропостачальних компаній, які займаються роздрібною торгівлею, підвищення точності прогнозування є особливо актуальним, враховуючи відсутність ефективних засобів керування попитом своїх споживачів чи контрагентів.

З метою підвищення адекватності моделювання СЕН реальним процесам і забезпечення необхідної точності та стабільності прогнозування графіки СЕН представляються у вигляді нестационарних майже періодичних випадкових часових рядів, які змінюються в часі під впливом технологічних, метеорологічних та астрономічних факторів [1]. Оскільки в часових рядах присутні добова, тижнева, річна періодичності та залежність від зовнішніх факторів змінюється протягом року, то для побудови математичної моделі СЕН необхідно використовувати інформацію за один або, у деяких випадках, за декілька років.

В Інституті електродинаміки НАН України дослідження в галузі короткострокового прогнозування проводяться в двох напрямках: побудова аналітичної адитивної математичної моделі СЕН та розвиток методів прогнозування на основі теорії машинного навчання та штучного інтелекту.

Класичними підходами до розв'язання задачі прогнозування є застосування методів, заснованих на аналізі часових рядів [1, 8]. Перевагою цих методів є їх простота та можливість досить легко інтерпретувати результати. Головним недоліком цих моделей є те, що при їх побудові необхідно точно виділити окремі складові СЕН, які залежать від впливу зовнішніх факторів.

Серед моделей, які можуть ефективно враховувати екзогенні фактори в неявному вигляді, найбільш розповсюдженими є метод опорних векторів (SVM) [3] та штучні нейронні мережі прямого розповсюдження типу багат шаровий перцептрон (MLP) [2]. Головними відмінностями цих моделей є підхід до постановки оптимізаційної задачі та вигляд нелінійної передаточної (активаційної) функції. Тоді як SVR відображає вхідні дані у простір більшої розмірності, MLP намагається знизити розмірність даних з мінімальними втратами інформації. Це призводить до того, що MLP зазвичай має менше параметрів (вагових коефіцієнтів), а значить, процедури навчання та прогнозування потребують менших ресурсів. Крім того, гнучкість у виборі активаційних функцій та кількості прихованих шарів MLP дає змогу будувати модульні нейронні мережі складної архітектури, які б могли відображати апріорну інформацію та навчатися як єдине ціле, а також рекурентні нейронні мережі зі зворотними зв'язками.

Зміна складу навантаження протягом року призводить до зміни залежності СЕН від метеорологічних та астрономічних факторів. Влітку спостерігається пряма кореляційна залежність між навантаженням та температурою, а зимою – зворотна кореляційна залежність. У зоні комфортних для людини температур від 16 до 21 °С температура практично не впливає на навантаження. Крім того, взимку сильно проявляється ефект насичення, який пов'язаний з тим, що при зниженні температури нижче певного значення навантаження не підвищується, оскільки всі додаткові електричні джерела опалення вже ввімкнено.

У початковому наближенні рік можна розділити на опалювальний сезон та міжсезоння. На рис. 1 (2014–2015 рр.) та рис. 2 (2015–2016 рр.) зображені графіки реальних значень сумарного електричного навантаження ПАТ «Київенерго»; «ящик з вусами», границі якого відповідають першому та третьому квартилям розподілу, а лінія між ними відображає медіану; емпіричний розподіл даних для опалювального сезону (а) та міжсезоння (б). Оскільки серед споживачів ПАТ «Київенерго» відсутні великі енергоємні підприємства, то при прогнозуванні технологічна складова у явному вигляді не враховувалась.

Аналізуючи гістограми, можна зробити висновок, що розподіли значень СЕН для опалювального сезону 2014–2015 рр. більш подібні до розподілу даних опалювального сезо-

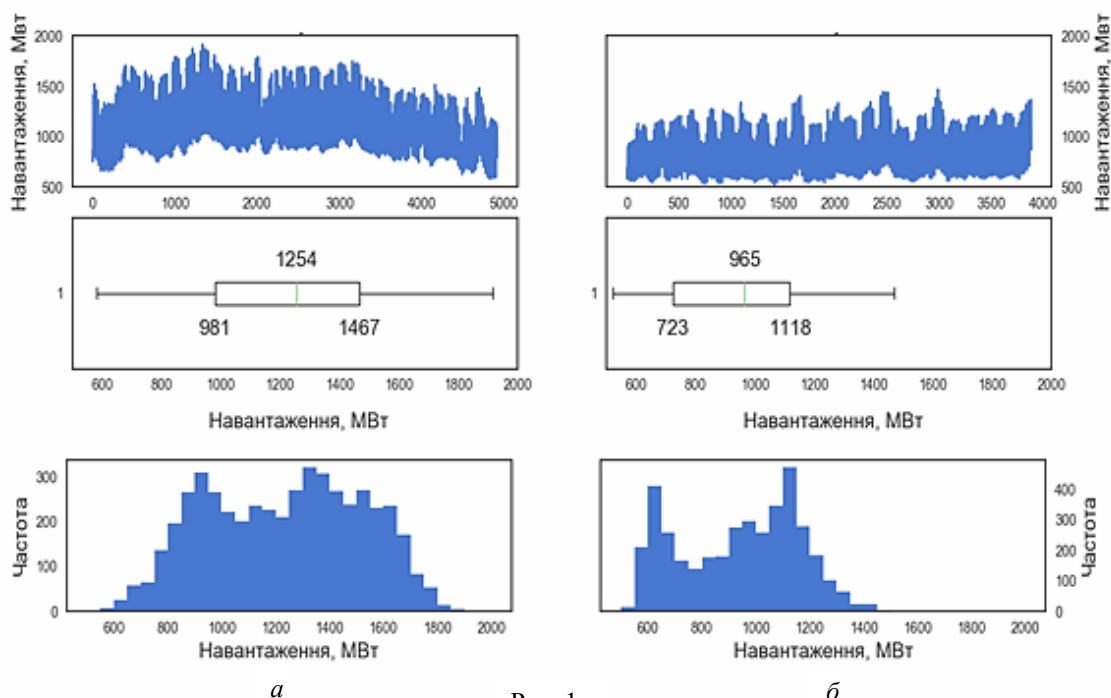


Рис. 1

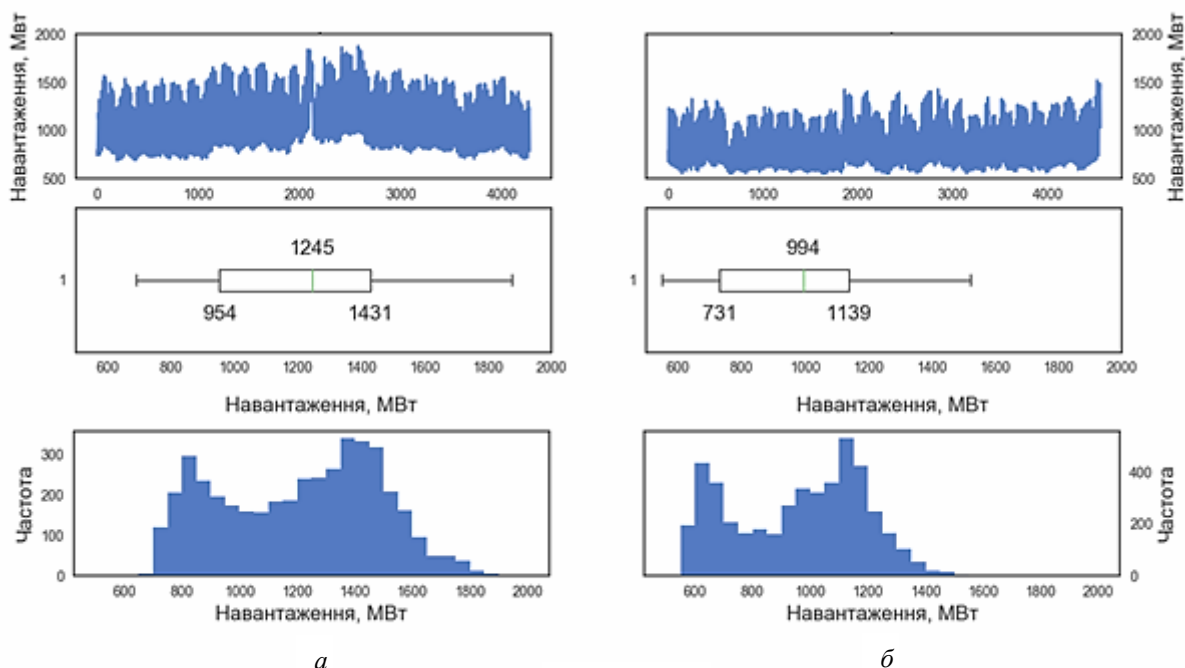


Рис. 2

ну 2015–2016 рр., ніж до розподілу міжсезоння 2015 р. Те ж саме спостерігається для даних міжсезоння 2015 та 2016 рр.

Отже, метою дослідження є підвищення точності та стабільності результатів короткострокового прогнозування СЕН, враховуючи зміну його структури протягом року. Для прогнозування використовувалась штучна нейронна мережа типу багатошаровий перцептрон.

Відбір вхідних змінних та масштабування даних проводяться на навчальній вибірці за такою процедурою:

1. На основі аналізу автокореляційної функції (рис. 3 *a*) навантаження відбираються десять значень лага відносно прогнозної години $L_p = \{l_1, l_2, \dots, l_{10} | 24 \leq l \leq 168\}$, в яких модуль кореляції найбільший. На вхід нейронної мережі подаються значення навантаження з відповідним лагом $P^L = \{P_{t-l} | l \in L\}$.

2. На основі аналізу перехресної кореляційної функції між температурою та навантаженням (рис. 3 *б*) відбираються десять значень лага відносно прогнозної години $L_c = \{l_1, l_2, \dots, l_{10} | 0 \leq l \leq 48\}$, для яких модуль кореляції найбільший. На вхід нейронної мережі подаються значення температури з відповідним лагом $T^L = \{T_{t-l} | l \in L\}$.

3. Два вхідних нейрони відповідають за день тижня D (від 1 до 7) та за годину доби H (від 1 до 24).

4. Після цього всі вхідні дані та бажаний результат нормалізуються за формулою

$$\hat{x}_j = \frac{x_j - \mu_j}{\sigma_j}, \quad (1)$$

де μ – середнє значення; σ – стандартне відхилення; m – кількість вхідних нейронів; $j \in \mathbb{R}^{m+1}$.

Після попередньої обробки даних навчальні вибірки мають наступну структуру:

$$\begin{pmatrix} \hat{P}_{169} & \hat{P}^L & \hat{T}^L & \hat{D}_{169} & \hat{H}_{169} \\ \ddots & \ddots & \ddots & \ddots & \ddots \\ \hat{P}_i & \hat{P}^L & \hat{T}^L & \hat{D}_i & \hat{H}_i \end{pmatrix},$$

де \hat{P}_i – нормалізовані фактичні значення навантаження в прогнозу годину $i = 1 \dots n$, n – кількість прикладів у навчальній вибірці.

Таким чином, нейронна мережа апроксимує залежність такого виду:

$$\hat{P}_i = f(\hat{P}^L, \hat{T}^L, \hat{D}_i, \hat{H}_i, W_1, b_1, W_2, b_2),$$

де W_1, W_2 – матриці вагових коефіцієнтів відповідно першого та другого шарів $W \in \mathbb{R}^{h \times k}$, k – кількість нейронів у шарі перед W , h – кількість нейронів у шарі після W ; b_1, b_2 – вектори

порогів відповідних шарів прихованих нейронів. W, b – підбираються у процесі навчання. Вектор-рядок вхідних змінних $x_i = \hat{P}^L, \hat{T}^L, \hat{D}_i, \hat{H}_i$.

Як нелінійну функцію активації нейронів прихованого шару було використано функцію selu (scaled exponential linear unit):

$$\text{selu} = \lambda \begin{cases} z & z > 0 \\ ae^z - a & z \leq 0 \end{cases}, \quad (2)$$

де z – лінійна комбінація виходів попереднього шару $z = Wx^T$; x^T – вектор-рядок виходів попереднього шару; λ, a – параметри, які необхідні для забезпечення властивості саморегуляризації.

Ця функція спроектована для обмеження середнього значення та дисперсії нейронів при розповсюдженні їх виходів по мережі:

$$\text{selu}: \begin{pmatrix} \mu \\ \nu \end{pmatrix} \rightarrow \begin{pmatrix} \tilde{\mu} \\ \tilde{\nu} \end{pmatrix}, \quad \mu \rightarrow 0, \nu \rightarrow 1,$$

де μ – середнє значення активацій нейронів попереднього шару; $\tilde{\mu}$ – середнє значення активацій нейронів поточного шару; ν – дисперсія активацій нейронів попереднього шару; $\tilde{\nu}$ – дисперсія активацій нейронів поточного шару.

Така поведінка мережі називається саморегуляризацією та спроможна прискорити навчання й підвищити якість результатів прогнозування на нових даних. Як показано в [9], це досягається за рахунок того, що:

- 1) функція може набувати позитивних та негативних значень для коригування середнього значення;
- 2) має область насичення для зменшення дисперсії;
- 3) має нахил, більший за одиницю для підвищення дисперсії;
- 4) має неперервну кривизну.

При ініціалізації вагових коефіцієнтів випадково з нормальним розподілом $\mathcal{N}(0, 1/k)$ значення параметрів, які забезпечують властивість саморегуляризації, $a = 1,6733$ та $\lambda = 1,0507$.

Результат прогнозування нейронної мережі у векторній формі можна записати у вигляді

$$\hat{P}_i^{\text{прогноз}} = W_2 \cdot \text{selu}(W_1 \cdot \hat{x}_i^T + b_1) + b_2. \quad (3)$$

Під час навчання нейронної мережі для оцінки параметрів проводилась мінімізація середньоквадратичних відхилень з регуляризацією у вигляді суми квадратів елементів матриць вагових коефіцієнтів W_1, W_2 . Для того щоб математичне очікування прогнозів наближалось до математичного очікування реальних даних, регуляризація не застосовувалась до порогів b_1, b_2 .

Цільова функція для навчання нейронної мережі має такий вигляд:

$$\mathcal{L} = \frac{1}{2n} \sum_{i=1}^n (\hat{P}_i^{\text{факт}} - \hat{P}_i^{\text{прогноз}})^2 + r (\sum_{j=1}^k \sum_{i=1}^k |w_{ij}^1|^2 + \sum_{j=1}^k \sum_{i=1}^k |w_{ij}^2|^2), \quad (4)$$

де $\hat{P}_i^{\text{факт}}, \hat{P}_i^{\text{прогноз}}$ – відповідно фактичні та прогнозні нормалізовані значення навантаження для i -ї години у навчальній вибірці; w_{ij}^1, w_{ij}^2 – вагові коефіцієнти, які з'єднують нейрон l – наступного шару та нейрон j попереднього шару, верхній індекс вказує на матрицю W_1 або W_2 ; n – кількість прикладів (годин) у навчальній вибірці; k – кількість нейронів у попередньому шарі; h – кількість нейронів у наступному шарі; r – параметр, який відповідає за інтенсивність регуляризації.

Гرادієнт функції \mathcal{L} розраховується методом зворотного розповсюдження похибки. Для мінімізації \mathcal{L} з великою кількістю параметрів w та b , що характерно для нейронних мереж з великою кількістю шарів, на практиці застосовують різні модифікації градієнтних методів першого порядку [5]. Це зумовлено тим, що розрахунок та зберігання навіть апроксимованої матриці Гессе для великих нейронних мереж вимагає досить значних обчислювальних ресурсів. Але для нейронних мереж з одним прихованим шаром нейронів, які викорис-

товуються у цій роботі, значно ефективнішими виявляються квазі-Ньютонівські методи оптимізації, наприклад, алгоритм Бroyдена-Флетчера-Гольдфарба-Шано (BFGS), або метод спряжених градієнтів [7].

Якість прогнозування оцінювалась за допомогою показника середньої відносної похибки за модулем MAPE (mean absolute percentage error):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{P_t^{\text{прогноз}} - P_t^{\text{факт}}}{P_t^{\text{факт}}} \right| \cdot 100\%, \quad (5)$$

де n – кількість прикладів (годин) у тестовій вибірці.

Порівняння результатів прогнозування. Для визначення оптимального методу врахування річної періодичності було побудовано чотири нейронні мережі типу багатошаровий перцептрон з одним прихованим шаром нейронів. Мережа «net» навчалась на річних даних без ознаки сезону «net_add», яка навчалась на річних даних та мала ознаку у вигляді вхідного нейрона, що набуває значення 1 – опалювальний сезон та 0 – міжсезоння, «net_w» навчалась на даних опалювального сезону, а «net_s» – на даних міжсезоння.

Для побудови моделей та прогнозування було використано дані ПАТ «Київенерго» за такі періоди:

01.10.2014 – 30.04.2015 – опалювальний сезон 2014–2015 рр., вибірка «train_1»;

01.05.2015 – 09.10.2015 – міжсезоння 2015 р., вибірка «train_0»;

10.10.2015 – 04.04.2016 – опалювальний сезон 2015–2016 рр., "вибірка «test_1»;


05.04.2016 – 11.10.2016 – міжсезоння 2016 р., вибірка «test_0».

Об'єднані вибірки для 2015 та 2016 рр. відповідно train та test.

Для моделювання залежності СЕН від температури були використані дані метеорологічних авіаційних метеозведень аеропорту «Київ». Для побудови моделей та прогнозування використовувались фактичні погодинні значення температури навколишнього середовища.

Згідно з процедурою відбору вхідних параметрів для обох сезонів з навчальної вибірки було побудовано автокореляційну функцію (рис. 3 а) та функцію перехресної кореляції (рис. 3 б), на основі аналізу яких було отримано наступні значення лагів і відповідні значення навантаження та температури:

$$P_{\text{net}}^L = [P_{t-24}, P_{t-25}, P_{t-48}, P_{t-72}, P_{t-120}, P_{t-143}, P_{t-144}, P_{t-145}, P_{t-167}, P_{t-168}];$$



a

б

Рис. 3

$$\begin{aligned}
P_{net_add}^L &= [P_{t-24}, P_{t-25}, P_{t-48}, P_{t-72}, P_{t-120}, P_{t-143}, P_{t-144}, P_{t-145}, P_{t-167}, P_{t-168}]; \\
P_{net_w}^L &= [P_{t-24}, P_{t-25}, P_{t-48}, P_{t-72}, P_{t-120}, P_{t-143}, P_{t-144}, P_{t-145}, P_{t-167}, P_{t-168}]; \\
P_{net_s}^L &= [P_{t-24}, P_{t-25}, P_{t-47}, P_{t-48}, P_{t-120}, P_{t-143}, P_{t-144}, P_{t-145}, P_{t-167}, P_{t-168}]; \\
T_{net}^L &= [T_{t-9}, T_{t-10}, T_{t-11}, T_{t-12}, T_{t-13}, T_{t-33}, T_{t-34}, T_{t-35}, T_{t-36}, T_{t-37}]; \\
T_{net_add}^L &= [T_{t-9}, T_{t-10}, T_{t-11}, T_{t-12}, T_{t-13}, T_{t-33}, T_{t-34}, T_{t-35}, T_{t-36}, T_{t-37}]; \\
T_{net_w}^L &= [T_{t-9}, T_{t-10}, T_{t-11}, T_{t-12}, T_{t-13}, T_{t-33}, T_{t-34}, T_{t-35}, T_{t-36}, T_{t-37}]; \\
T_{net_s}^L &= [T_{t-9}, T_{t-10}, T_{t-11}, T_{t-12}, T_{t-13}, T_{t-24}, T_{t-25}, T_{t-45}, P_{t-46}, P_{t-47}].
\end{aligned}$$

Мінімізація цільової функції \mathcal{L} (4) проводилась методом спряжених градієнтів у модифікації Полака-Райбера. Було використано реалізацію алгоритму з бібліотеки програмних засобів SciPy [4] для мови програмування Python. Критерієм зупинки навчання є зменшення L_2 норми градієнта функції похибки нижче певного заданого наперед значення $tol = 0,00001$. Для вказаних нейронних мереж параметр регуляризації цільової функції $r = 1$.

Внаслідок перехресної перевірки отримано такі архітектури нейронних мереж: net 22 – 13 – 1, net_add 23 – 13 – 1, net_w 22 – 13 – 1, net_s 22 – 11 – 1. Результати прогнозування наведено в таблиці.

Нейронна мережа	Період року, на якому проводилась оцінка точності		
	Опалювальний сезон 2015–2016 рр.	Міжсезоння 2016 р.	Річні дані
	MAPE, %	MAPE, %	MAPE, %
Мережа навчена на річних даних без ознаки сезону, net	3,61	4,23	3,93
Мережа навчена на річних даних з ознакою сезону, net_add	3,49	4,18	3,85
Мережа навчена на даних за опалювальний сезон, net_w	3,58		3,65
Мережа навчена на даних за міжсезоння, net_s		3,73	

З таблиці видно, що додавання нейрона, який вказує на сезон року, знизило середньорічну похибку MAPE з 3,93 до 3,85 %, або у відносному вираженні на 2 %. При цьому навчання окремих нейронних мереж для різних сезонів знизило середньорічну похибку MAPE з 3,93 до 3,65 %, або на 7,1 %.

Висновки. 1. Під впливом зміни режиму електроспоживання електропостачальної компанії протягом року суттєво змінюється склад навантаження (наприклад, ввімкнення кондиціонерів та додаткових холодильних агрегатів влітку, а також ввімкнення та вимкнення додаткового опалювального навантаження). Це призводить до зміни характеристики залежності СЕН від метеорологічних та астрономічних факторів. При цьому для підвищення точності короткострокового прогнозування необхідно вводити додаткову вхідну інформацію та використовувати більш складний апарат штучних нейронних мереж.

2. Підвищення точності короткострокового прогнозування СЕН можна досягнути простішим шляхом, якщо навчання нейронної мережі (в цьому випадку багатосаровий перцептрон) проводити на окремих інтервалах року з врахуванням різного складу навантаження та проводити прогноз на тих же інтервалах наступного року.

1. Черненко П.А. Идентификация параметров, моделирование и многоуровневое взаимосвязанное прогнозирование электрических нагрузок энергообъединения // Техн. електродинаміка. Темат. вип. "Проблеми сучасної електротехніки". – 2010. – Ч. 3. – С. 57–64.

2. Brodowski S., Bielecki A., Filocha M. A hybrid system for forecasting 24-h power load profile for Polish electric grid // Applied soft computing. – 2017. – Vol. 58. – P. 527–539.
3. Ceperic E., Ceperic V., Baric A. A strategy for short-term load forecasting by support vector regression machines // IEEE Transactions on power systems. – 2013. – Vol. 28, Issue 4. – P. 56–64.
4. Jones E., Oliphant E., Peterson P., et al. SciPy: Open Source Scientific Tools for Python, 2001. <http://www.scipy.org/>.
5. Kingma D.P., Ba J. Adam: A method for stochastic optimization // 3rd International Conference for Learning Representations, San Diego, 2015.
6. Klambauer, G., Unterthiner, T., Mayr, A., Hochreiter, S. Self-Normalizing Neural Networks. In Advances in Neural Information Processing Systems, 2017.
7. Nocedal J., Wright S.J. Numerical Optimization: Second Edition // Springer, New-York, 2006. – P. 664.
8. Suganthi L., Samuel A.A. Energy models for demand forecasting – A review // Renewable & sustainable energy reviews. – 2012. – Vol. 16, Issue 2. – P. 23–40.

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

Повышение точности краткосрочного прогнозирования электрической нагрузки с помощью искусственных нейронных сетей с учетом изменения структуры потребления в течение года

Представлен анализ влияния годовой периодичности на точность и стабильность результатов краткосрочного прогнозирования электрической нагрузки. Рассмотрены два подхода, учитывающие различное поведение электрической нагрузки в отопительный сезон и межсезонье. Для прогнозирования использован многослойный перцептрон с нелинейной функцией масштабированного экспоненциально-линейного элемента (SELU), используемой в качестве нелинейного преобразования в скрытых нейронах. Эта функция стабилизирует среднее значение и дисперсию слоев, ускоряет процесс обучения. В первом подходе нейронная сеть включала дополнительный входной нейрон, который принимает значения 1 в течение дней, являющихся частью отопительного сезона, и 0 для внесезонных дней. В этом случае такая модель устанавливается на годовые данные. Во втором подходе две отдельные нейронные сети разрабатываются для работы в разные сезоны года. Входной вектор генерировался отдельно для каждой сети. Оценка точности и стабильности результатов прогнозирования была проведена на основе годовых данных реальной электросетевой компании. Библ. 8, рис. 3, таблица.

Ключевые слова: электрическая нагрузка, годовая периодичность, краткосрочное прогнозирование, искусственная нейронная сеть

P. Chernenko, V. Miroshnyk,

Institute of Electrodynamics of the National Academy of Sciences of Ukraine,
Peremohy, 56, Kyiv-57, 03057, Ukraine

Increasing the accuracy of short-term electrical load forecasting with considering to changes in the structure of consumption during the year

The paper presents an analysis of the influence of annual periodicity on the accuracy and stability of the electrical load short-term forecasting results. Two approaches are considered which take into account the different behavior of the electrical load in the heating season and off-season. For forecasting, we used the multilayer perceptron with scaled exponential linear unit (SELU) function used as a nonlinear transformation in hidden neurons. This function stabilizes mean and variance of layers and accelerates the learning process. In the first approach, the neural network included an additional input neuron that takes values of 1 for days that are part of the heating season and 0 for the off-season days. In this case, the given model fitted on the annual data. In the second approach, two separate neural networks are developed for work in different seasons of the year. Input vector was generated separately for each network. Estimation of the accuracy and stability of the forecasting results was carried out on year data for real electricity supply company. References 8, figures 3, table.

Key words: electrical load, annual periodicity, short-term forecasting, artificial neural network.

Надійшла 27.09.2017
Received 27.09.2017