

ПРОГНОЗУВАННЯ ВТРАТ ПОТУЖНОСТІ В РОЗПОДІЛЬНИХ МЕРЕЖАХ НА БАЗІ НЕЙРОМЕРЕЖЕВОГО МОДЕЛЮВАННЯ

Черемісін М. М., Мірошник О. О., Федоровський І. А.

Харківський національний технічний університет сільського господарства імені Петра Василенка

У статті проведений порівняльний аналіз існуючих методів прогнозування втрат потужності в розподільних мережах двома способами: традиційним алгоритмом і нейромережовим моделюванням. Показано порівняння похибок прогнозування втрат потужності.

Постановка проблеми. Одним з істотних показників, що впливають на ефективність функціонування енергосистеми в цілому, і зокрема мережових компаній, є значення втрат потужності. Точне і достовірне визначення цього інтегрального показника режиму роботи є основою для вирішення широкого кола завдань управління розподільчими мережами.

Без детального розрахунку структури втрат, розрахунку фактичних і допустимих небалансів електроенергії неможливе рішення завдань оптимізації режимів і вибір обґрунтованого переліку пріоритетних заходів по зниженню технічних і комерційних складових втрат потужності.

Аналіз останніх досліджень і публікацій. Розвиток методів обчислювальної математики і інформаційних технологій дозволяє по новому ставити питання вдосконалення оперативного управління режимами регіональних електроенергетичних систем (рис. 1). Нині перспективним видається вирішення цих питань на базі технологій штучного інтелекту, зокрема штучних нейронних мереж (ШНМ).

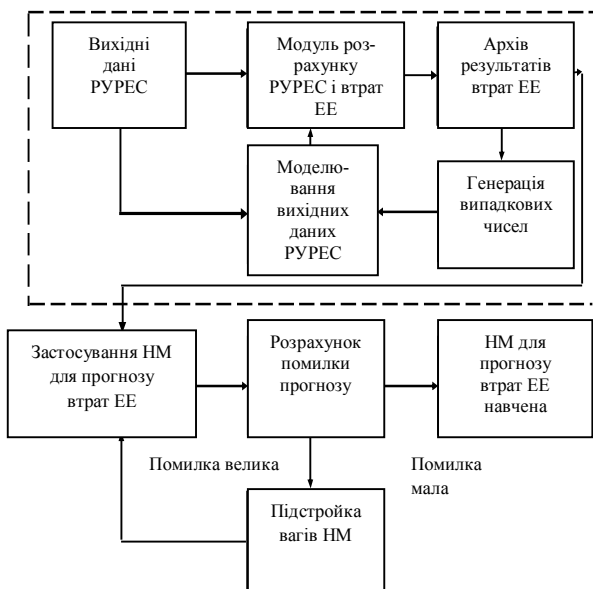


Рисунок 1 – Блок-схема алгоритму застосування ШНМ для розрахунку втрат.

Мета статті полягає в порівняльному аналізі існуючих методів прогнозування втрат потужності в розподільних мережах.

Основні матеріали дослідження. Приведена методологія розрахунку втрат потужності, традиційно вживана в розподільних мережах [1].

Величина струму в лініях розраховується за наступною формулою:

$$I = \frac{S_n}{\sqrt{3}U_n \cos \varphi}, \quad (1)$$

де S_n – середня денна потужність, кВА;

U_n – номінальна напруга мережі, кВ.

Втрати електроенергії в лініях розраховуються за наступною формулою:

$$\Delta W = I^2 \cdot R_{20} \left(1 + \alpha \left(t_{н.с}^0 + \frac{1 + \alpha(t_{н.с}^0 - 20)}{2c\sqrt{\pi F}} - 20 \right) \right) \cdot \Delta t \cdot l, \quad (2)$$

де R_{20} – питомий опір проводу при 20°C ;

α – температурний коефіцієнт електроопору, $1/^\circ\text{C}$;

$t_{н.с}^0$ – температура навколишнього середовища, $^\circ\text{C}$;

Δt – проміжок часу для вимірювання, год;

l – довжина лінії, км;

F – площа перерізу проводу, мм^2 ;

c – коефіцієнт тепловіддачі, $\text{Вт}/\text{м}^2 \cdot ^\circ\text{C}$.

Проведемо аналіз і оцінку втрат потужності у розподільних мережах за допомогою нейромережового моделювання.

Побудова будь-якої нейромережової моделі ґрунтується на виконанні наступних етапів :

- Формулювання завдання в нейромережовому базисі.
- Формулювання вибірки навчання.
- Вибір архітектури нейромережової моделі.
- Навчання нейромережової моделі.
- Тестування нейромережової моделі в цілях встановлення точності результату.

1. Формулювання завдання в нейромережовому базисі.

Вибір найбільш ефективної нейромережової моделі, яка вирішує задачу прогнозування втрат потужності в розподільних мережах. Для оцінки втрат активної потужності моделі, повинна бути спроектована і навчена апроксимація функції [5]:

$$\Delta P = F([x]), \quad (3)$$

де ΔP – активні втрати; $[x]$ – вектор-стовпець змінних стану, компонентами якого є: номінальна

напруга мережі, графік навантаження, пора року, день тижня, метеорологічні фактори.

2. Формулювання вибірки навчання.

Відомо, що чим більша вибірка, тим точніша модель, але згідно з евристичними правилами, число спостережень в мережі має бути в 10 разів більше числа зв'язків в мережі [2]. З іншого боку, відомий вислів програмістів "garbage in, garbage out" справедливий в нейромережевому моделюванні.

На сьогодні не існує універсального правила, відповідно до якого встановлюється об'єм вибірки. Проте, визначення достатнього розміру вибірки залежить від специфікації вирішуваної задачі.

Таблиця 1 – Похибка розрахунку втрат залежно від розміру навчальної вибірки

Номер ШНМ	1	2	3	4
Навчальна вибірка, S	100	300	700	1000
Середня абсолютна помилка	0,0705	0,0152	0,0119	0,0128
Максимальна абсолютна похибка	1,2999	0,2504	0,299	0,1638
Средньоквадратична похибка	0,1299	0,0247	0,0223	0,0195

$$e_{cp} = \frac{1}{S} \sum_{i=1}^S |\Delta_i|, \quad (4)$$

де S – розмір вибірки;

$$\Delta_i = y_i - \hat{y}_i,$$

де y_i – фактичний результат,

\hat{y}_i – бажаний результат,

$$e_{\max} = \max \{ |\Delta_i| \}, \quad (5)$$

$$e_{ck} = \sqrt{\frac{S \sum (\Delta_i)^2 - \left(\sum \Delta_i \right)^2}{S(S-1)}}. \quad (6)$$

3. Вибір архітектури нейронної мережі.

Відомо, що архітектура виконує вирішальний вплив на весь процес обробки інформації нейронною мережею. У більшості випадків експертів потрібно провести ряд експериментів з різними конфігураціями мережі, що спричиняє за собою великі тимчасові витрати. Для пошуку оптимальної архітектури розглянуто рівноправне об'єднання генетичних алгоритмів і нейронних мереж (рис. 2) [4].

4. Навчання нейронної мережі.

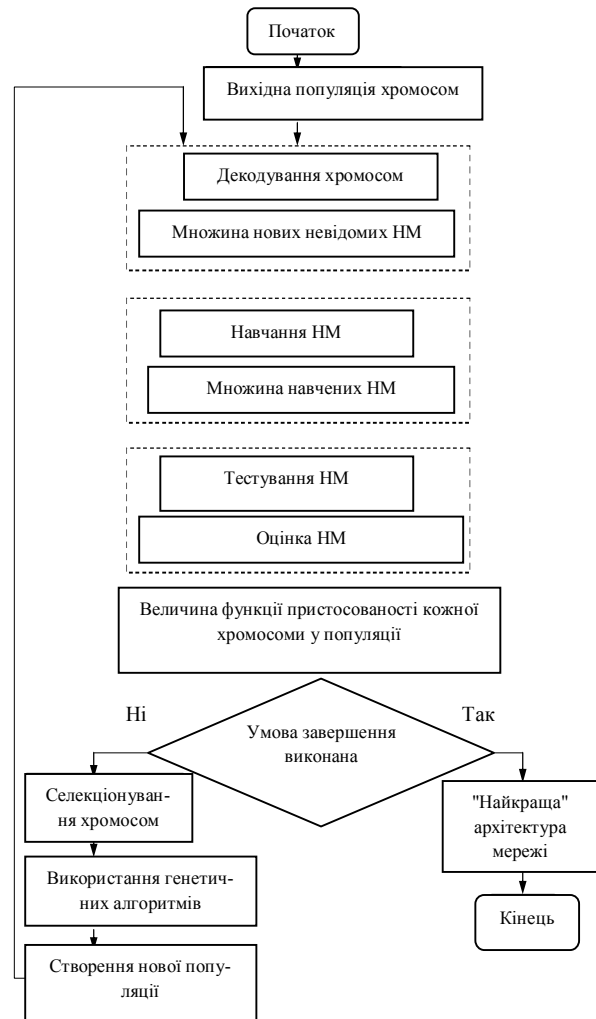


Рисунок 2 – Блок схема генетичного алгоритму для пошуку найкращої архітектури нейронної мережі (випадок еволюції архітектури)

При виборі оптимального правила навчання розглядали наступні алгоритми [2].

Алгоритм зворотного поширення помилки. Основу алгоритму зворотного поширення помилки складає цільова функція, що формулюється, як правило, у вигляді квадратичної суми різниць між фактичними і очікуваними значеннями вихідних сигналів. Для навчальної вибірки, що складається з p прикладів, цільова функція має вигляд

$$E(w) = \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^M (y_k^{(j)} - d_k^{(j)})^2. \quad (7)$$

Мінімізація цільової функції досягається уточненням вектору вагів (навчанням) по формулі:

$$w(k+1) = w(k) + \Delta w, \quad (8)$$

$$\Delta w = \eta s(w), \quad (9)$$

η – коефіцієнт навчання, а $s(w)$ – напрям в просторі вагів. Вибір цього напрямку зазвичай заснований на визначенні градієнта цільової функції відносно вагів усіх шарів мережі. Для вагів вихідного шару це завдання має очевидне рішення. Для інших шарів використовується алгоритм зворотного поширення помилки. Розглянемо цей алгоритм на прикладі двошарової мережі. В цьому випадку при $p = 1$ цільова функція визначається виразом:

$$E(w) = \frac{1}{2} \sum_{k=1}^M \left[f \left(\sum_{i=0}^K w_{ki}^{(2)} v_i \right) - d_k \right]^2 = \frac{1}{2} \sum_{k=1}^M \left[f \left(\sum_{i=0}^K w_{ki}^{(2)} f \left(\sum_{j=0}^N w_{ij}^{(1)} x_j \right) \right) - d_k \right]^2. \quad (10)$$

Алгоритм зв'язаних градієнтів. У цьому методі напрям пошуку мінімуму цільової функції вибирається так, щоб воно було ортогональним і зв'язаним до усіх попередніх напрямів s_0, s_1, \dots, s_{k-1} . Вектор, що задовольняє цим умовам, має вигляд:

$$s_k = -g_k + \beta_{k-1} s_{k-1}, \quad (11)$$

де $g_k = g(w_k)$ означає вектор градієнта, а коефіцієнт β_{k-1} оцінюється по формулі:

$$\beta_{k-1} = \frac{g_k^T (g_k - g_{k-1})}{g_{k-1}^T g_{k-1}}. \quad (12)$$

Метод зв'язаних градієнтів широко застосовується при великій кількості змінних. Завдяки невисоким вимогам до пам'яті і відносно низької обчислювальної складності цей метод дозволяє успішно вирішувати дуже серйозні оптимізаційні завдання.

Ньютонівські методи. Напрямок пошуку, що відповідає найшвидкішому спуску, пов'язаний з лінійною апроксимацією цільової функції. Методи, що використовують другі похідні, виникли з квадратичної апроксимації цільової функції, тобто при розкладанні функції в ряд Тейлора відкидаються члени третього і вищих порядків.

$$f(x) \approx f(X^k) + \nabla^T f(X^k)(X - X^k) + \frac{1}{2} (X - X^k)^T G(X^k)(X - X^k), \quad (13)$$

де $G(X^k)$ - матриця Гессе.

Мінімум правої частини (якщо він існує) досягається там же, де і мінімум квадратичної форми. Запишемо формулу для визначення напрямку пошуку \bar{S} :

$$f(X^k + \bar{S}) = f(X^k) + \nabla^T f(X^k) \bar{S} - \frac{1}{2} \bar{S}^T G(X^k) \bar{S}. \quad (14)$$

Мінімум досягається при

$$G(X^k) \bar{S} = -\nabla f(X^k), \quad (\bar{S} = -G^{-1}(X^k) \nabla f(X^k)).$$

Алгоритм оптимізації, в якому напрям пошуку визначається з цього співвідношення, називається методом Ньютона, а напрям \bar{S} – ньютонівським напрямом.

Запорукою ефективності методів ньютонівського типу є облік інформації про кривизну функції, що мінімізується, міститься в матриці Гессе і що дозволяє будувати локально точні квадратичні моделі цільової функції. Але ж можливо інформацію про кривизну функції збирати і накопичувати на основі спостереження за зміною градієнта під час ітерацій спуску. Відповідні методи, що спираються на можливість апроксимації кривизни нелінійної функції без явного формування її матриці Гессе, називають Квазі-Ньютонівськими методами.

Відмітимо, що при побудові оптимізаційної процедури ньютонівського типу (у тому числі і Квазі-Ньютонівської) необхідно враховувати можливість появи сідлової точки. В цьому випадку вектор найкращого напрямку пошуку буде увесь час спрямований до сідлової точки, замість того, щоб йти від неї в напрямі "вниз".

Скоротити обчислення дозволяє алгоритм Левенберга-Маркуардта [2], у основі якого лежить заміна точного значення матриці Гессе її апроксимованим значенням, яке розраховується на основі інформації, що міститься в градієнті з урахуванням деякого регуляризаційного чинника. Апроксимована матриця Гессе представляється у вигляді:

$$G(w) = [J(w)]^T J(w) + R(w), \quad (15)$$

де

$$J(w) = \begin{bmatrix} \frac{de_1}{dw_1} & \frac{de_2}{dw_2} & \dots & \frac{de_1}{dw_n} \\ \frac{de_2}{dw_1} & \frac{de_2}{dw_2} & \dots & \frac{de_2}{dw_n} \\ \dots & \dots & \dots & \dots \\ \frac{de_M}{dw_1} & \frac{de_M}{dw_2} & \dots & \frac{de_M}{dw_n} \end{bmatrix}.$$

Тут e – помилка, визначувана вираженням

$$e_i = [y_i(w) - d_i],$$

де y – вихідне значення нейромережі, а d – її очікуване значення; $R(w)$ – компонента, що містить вищі похідні, відносно w . Суть алгоритму Левенберга-Маркуардта полягає в апроксимації $R(w)$ за допомогою регуляризаційного чинника vkI . В цьому випадку апроксимована матриця набуває вигляду:

$$G(wk) = [J(wk)]^T J(wk) + vkI. \quad (16)$$

Змінна v – скалярна величина, алгоритм зміни якої в процесі навчання здійснюється таким чином,

що спочатку, коли значення вектору похибки велике, її вплив у виразі (16) відіграє домінуючу роль, а потім, по мірі зменшення похибки, величина параметра vk зменшується і вплив першого доданку збільшується. Існують різні способи підбору значення vk [5]. Вибір того або іншого способу залежить від конкретного завдання. У [5] показано, що цей алгоритм за багатьма показниками перевершує ряд інших алгоритмів оптимізації.

Порівняльний аналіз точності і достовірності результатів оцінки втрат потужності представлений в таблиці 2. В даному випадку говориться не лише про абсолютну похибку, але і про розкид значення похибки (дисперсії).

Таблиця 2 – Похибки при розрахунку втрат потужності

Методи розрахунку похибок потужності	Середня абсолютна похибка	Дисперсія похибки
Традиційне планування	8,651	4,023
Нейромережеве моделювання	2,331	1,924

Переваги застосування нейромережевого моделювання при розрахунку втрат потужності очевидні. При нейромережевому моделюванні необхідно виявити оптимальну вибірку, структуру нейронної мережі, алгоритм навчання, але також не слід забувати, що застосування тих або інших параметрів залежить від складності поставленого завдання.

Висновки.

1. У статті показана необхідність розвитку методів прогнозування втрат потужності в розподільних мережах. Розглянуті методи прогнозування втрат потужності традиційним алгоритмом і нейромережевим моделюванням. Вхідними параметрами завдання для планування втрат потужності в розподільних мережах можуть бути сумарна потужність навантаження і середня напруга розподільної мережі. Вибірка, у свою чергу, повинна бути сформована від графіку навантаження, пори року, дня тижня, метеорологічних факторів.

2. При роботі зі штучними нейронними мережами даються рекомендації по формуванню вибірки, оптимізації структури і алгоритму навчання нейронної мережі при плануванні втрат потужності в розподільних мережах.

3. Приведений порівняльний аналіз точності і достовірності результатів оцінки втрат показав, що перед традиційним алгоритмом метод нейромережевого моделювання має меншу похибку, яка склала для традиційного алгоритму – 8,6%, нейромережевій моделі – 2,3%.

4. Встановлено, що прогнозування втрат електроенергії в розподільних мережах енергосистем із

застосуванням штучних нейронних мереж має вищу точність в порівнянні з традиційними методами і успішно може бути застосоване в завданнях прогнозування.

5. Проаналізовані практичні розробки по застосуванню нейротехнологій для вирішення завдань прогнозування втрат потужності і встановлено, що нині немає оптимального підходу, який би дозволив досить прозоро описати параметри нейромоделі. Отже, необхідно розвивати існуючі наукові і методичні принципи оцінки втрат на базі нейронних мереж для швидкого отримання достовірного результату.

Список використаних джерел

1. Баламетов А. Б. Методы расчета потерь мощности и энергии в электрических сетях энергосистем / А. Б. Баламетов – Баку: Елм, 2006. – 337 с.
2. Бодянский Е. В., Искусственные нейронные сети: архитектуры, обучение, применения / Е. В. Бодянский, О. Г. Руденко – Харьков: Телетех, 2004. – 152 с.
3. Осовский С. Нейронные сети для обработки информации / С. Осовский, пер. с польск. И. Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с.
4. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилинский, Л. Рутковский; пер. с польск. Рудинским И. Д. М.: Горячая линия – Телеком, 2008. – 256 с.
5. Mandic D. P. Recurrent Neural Networks for Prediction / D. P. Mandic, J. A. Chambers. – Chichester: John Wiley&Sons, 2001. – 285 p.

Аннотация

ПРОГНОЗИРОВАНИЕ ПОТЕРЬ МОЩНОСТИ В РАСПРЕДЕЛИТЕЛЬНЫХ СЕТЯХ НА БАЗЕ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ

Черемисин Н. М., Мирошник А. А., Федоровский И. А.

В статье проведен сравнительный анализ существующих методов прогнозирования потерь мощности в распределительных сетях двумя способами: традиционным алгоритмом и нейросетевым моделированием. Показано сравнение погрешностей прогнозирования потерь мощности.

Abstract

POWER LOSS FORECASTING IN DIVIDING NETWORKS BASED ON NEURAL NETWORK MODELING

N. Cheremisin, O. Miroshnyk, I. Fedorovskiy

The author of the article presents the comparative analysis of current methods in forecasting of power-loss in dividing networks. It is stressed that the procedure is coming in two ways: traditional algorithm and Neural Network modeling. The paper shows the comparison of errors in possible power-loss.