

УДК 621.316.9

© Бакулевський В.Л.*

**ЗАСТОСУВАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ РОЗРАХУНКІВ ТЕХНІЧНИХ
ВТРАТ ЕЛЕКТРОЕНЕРГІЇ В ПОВІТРЯНИХ ЛІНІЯХ ЕЛЕКТРОПЕРЕДАЧ
НАПРУГОЮ 6-35 кВ**

Розроблена модель для розрахунків технічних втрат електроенергії в повітряних лініях електропередач напругою 6-35 кВ на базі нейронних мереж з урахуванням метеофакторів; розглянуті основні складові моделі; досліджені і обрані оптимальні: набір вхідних змінних, об'єми виборок (навчальної, контрольної та тестової), архітектура та функція активації мережі, запропонований алгоритм навчання мережі.

Ключові слова: нейронні мережі, втрати електроенергії, повітряні лінії електропередач, модель.

Бакулевський В.Л. Применение нейронных сетей для расчётов технических потерь электроэнергии в воздушных линиях электропередач напряжением 6-35 кВ.

Разработана модель для расчетов технических потерь электроэнергии в воздушных линиях электропередач напряжением 6-35 кВ на базе нейронных сетей с учетом метеофакторов; рассмотрены основные составляющие модели; исследованы и выбраны оптимальные: набор входных переменных, объемы виборок (учебной, контрольной и тестовой), архитектура и функция активации сети, предложен алгоритм обучения сети.

Ключевые слова: нейронные сети, потери электроэнергии, воздушные линии электропередач, модель.

V.L. Bakulevsky. Application of neural networks for the calculation of technical losses of electric energy in air power lines 6-35 kV. *A model for the calculation of technical losses of electricity in the air lines with voltage of 6-35 kV based on neural networks with due regard to meteorological factors has been worked out; the main components of the model have been considered and researched; the best ones being selected, that is: a set of input variables, volume of excerpts (training, control and testing), architecture and network activation function, network learning algorithm was proposed. Simulation was conducted in OS STATISTICA Neural Networks. Input variables are: transmission line (TL) active load, transmission line rated voltage, transmission line cross section and length of wire, average air temperature, wind speed, rainfall availability; output variable – that is technical losses in electric transmission line. To select the optimal input vector model the data selection methods were used: variables testing using trial and error method, variables stepped inclusion and exclusion algorithm. It has been proved that the most important variables are TL active load and average air temperature. all input variables under review should be included in the created artificial neural network (ANN). It was determined that the optimal volume for ANN training set given parameters made 250 observations, control and test excerpts volume were respectively 250 and 332 observations. It has been proved that the best type of architecture is multilayer perceptron ANN that being compared to radial basis functions and generalized regression network is characterized by minimal errors and complexity of the network. ANN of the following architecture: multilayer perceptron, 7 neurons in the input layer, 5 neurons in the hidden layer, 1 output neuron, logistics as activation function – has been taken optimal.*

Keywords: neural networks, the loss of electricity, overhead power lines, model.

Постановка проблеми. У зв'язку з реформуванням ринку електроенергії шляхом розподілу більших або об'єднання дрібних суб'єктів, появою нових суб'єктів ринка, дефіциту енерго-

* викладач, Механіко-технологічний технікум Одеської національної академії харчових технологій, м. Одеса, bakulevsky_80@mail.ru

носіїв, прискорення науково-технічного прогресу постає питання про поліпшення розрахунково-технічної бази. Зокрема це притаманно і розрахунку втрат електроенергії, що є одним із ключових ланок енергозбереження в Україні. Багато методів і моделей на сьогоднішній день є застарілими або містять велику похибку, тому їх використання недоцільне. Саме тому для моделювання слід застосовувати передові технології, такі як нейронні мережі, що забезпечують можливість швидкої побудови моделі без участі експерта, роботи із зашумленими даними, що є актуальним при поточному стані каналів передачі телеметрії з устаткування. Крім того, суттєвими перевагами нейромереж є: відсутність необхідності побудови математичної моделі процесу, що аналізується; здатність відновлювати нелінійні функціональні залежності між параметрами (характеристиками), що вивчаються; ефективна робота в умовах неповноти вихідної інформації; можливість використання малих навчальних вибірок; швидкий відгук навченої нейромережі на надходження поточної інформації (на рівні обробки цих телевимірювань існуючими способами); забезпечення практично повного режимного діапазону роботи електричної мережі; облік практично необмеженої кількості чинників; висока міра адекватності режимів мережі; шляхом самонавчання відбувається автоматична адаптація моделі. Також до моделі доцільно включити метеофактори, які мають вплив на втрати електроненергії в повітряних ЛЕП [1].

Аналіз останніх досліджень і публікацій. В роботах вітчизняних [1-3] та закордонних фахівців [4-9] увага акцентується на необхідності удосконалення методологічного і технічного забезпечення, більш точного та повного врахування факторів, що впливають на втрати електроенергії в мережах, а також на застосуванні поліпшених моделей та методів розрахунку та прогнозування втрат електроенергії з метою досягнення мінімальної похибки.

Ціль статті. Розробити модель для розрахунків технічних втрат електроенергії в повітряних лініях електропередач напругою 6-35 кВ на базі нейронних мереж з урахуванням метеофакторів; розглянути основні складові моделі; дослідити і обрати оптимальні: набір вхідних змінних, об'єми вибірок (навчальної, контрольної та тестової), архітектуру та функцію активації мережі, алгоритм навчання мережі.

Виклад основного матеріалу. Моделювання штучних нейронних мереж (ШНМ) для завдання планування технічних втрат електроенергії в повітряних лініях електропередачі здійснюється за алгоритмом, який передбачає послідовне виконання наступних етапів [3-5]:

- Формулювання завдання в нейромережевому базисі.
- Формування навчальної і тестової вибірок для навчання і тестування ШНМ, а також контрольної вибірки, яка необхідна для визначення адекватності навчання ШНМ.
- Вибір архітектури ШНМ, у тому числі параметрів елементів мережі (ідентифікація структури моделі).
- Навчання ШНМ (оцінювання параметрів моделі).
- Тестування ШНМ в цілях встановлення адекватності отриманої моделі.

Аналіз проводиться в ОС STATISTICA Neural Networks.

Під формулюванням завдання в нейромережевому базисі розуміється визначення змісту, що вкладається в компоненти вхідного і вихідного векторів. Цей етап включає [3-5]:

- Визначення змісту, що вкладається в компоненти вхідного вектора X . Вхідний вектор повинен містити формалізовану умову завдання, тобто всю інформацію, необхідну для здобуття відповіді.
- Вибір вихідного вектора Y так, щоб його компоненти містили повну відповідь поставленому завданню.

Методи пониження розмірності і відбору даних, які реалізовані в програмі-нейроімітаторі Statistica Neural Networks: тестування змінних за допомогою проб і помилок, генетичний алгоритм, метод головних компонент [3, 4, 10].

Останні дослідження і розробки в області оцінки при плануванні втрат електроенергії [4-6, 8-9] показали, що необхідно: враховувати при розрахунках всі відомі складові втрат електроенергії; по можливості враховувати всілякі чинники, що впливають на втрати електроенергії (ЕЕ); полегшити процеси підготовки вихідних даних і результатів розрахунку.

Для більш точного прогнозування в модель необхідно включити додаткові фактори, які впливають на технічні втрати електроенергії, тобто вхідний вектор повинен містити чинники, які залежать від напруги мережі і фізичної природи технічних втрат з врахуванням динаміки процесу передачі і розподілу електроенергії в енергосистемі, а також метеофактори, доціль-

ність врахування яких описана в [1, 4-6, 8].

Пропонується наступне формулювання завдання прогнозування і аналізу технічних втрат електроенергії на основі апарату ШНМ для ПЛ напругою 6-35 кВ:

- вхідний вектор X : номінальна напруга; добове навантаження ПЛ; довжина ПЛ; марка проводу ПЛ; середньодобові значення температури повітря та сили вітру; переважаючі опади (або їх відсутність). У більшості класичних моделей реактивне навантаження в якості вхідного вектора не враховується; крім того, нейронні мережі працюють в умовах неповноти вхідної інформації, що є їх значною перевагою. Доцільність включення в модель метеофакторів наводиться в [1];

- вихідний вектор Y – технічні втрати електроенергії в ПЛ (для максимальної точності взяті з різниці даних АСКУЕ на початку та в кінці відповідних ПЛ).

Моделювання вибірки проводиться шляхом зміни навантаження та метеоданих, які створюють вхідний вектор. Вибірка складала 732 добових спостереження, обраних для ПЛ напругою 10 та 35 кВ протягом всього 2008 року, щоб включити до моделі весь сезонний інтервал, тим самим зменшуючи похибки та невизначенність. Розглянутий об'єкт являє собою окремі лінії напругою 6-35 кВ. Необхідність застосування нейронних мереж обумовлена неповнотою вхідної інформації, наявної в сучасних мережах. Область застосування методу обумовлена тим, що в ПЛ напругою 110 кВ і вище істотний вплив на технічні втрати електроенергії мають втрати на корону, тобто такий же підхід до ПЛ напругою 110 кВ і вище, як до розглянутих мереж напругою 6-35 кВ, неприйнятний. У пропонованій моделі прийняті припущення, наприклад, постійність параметрів схем заміщення і оперативного стану схеми, тобто при формуванні вхідного вектора для моделювання ШНМ не застосовується попередня обробка даних, оскільки модель будуватиметься в програмі-нейроімітаторі Statistica Neural Networks [4, 10].

Можна передбачити, що вхідні параметри корелюють, враховуючи їх фізичну природу, тому необхідно скористатися одним з методів пониження розмірності і відбору даних – тестування змінних за допомогою проб і помилок [1, 4, 10]. При тестуванні вхідних змінних на вхід мережі подаються їх різні комбінації, далі відбувається етап побудови і навчання ШНМ. Висновок про доцільність вживання змінної проводиться, виходячи із значення похибок обчислення втрат електроенергії і рангу вхідної змінної, який привласнюється в результаті навчання ШНМ. Для вирішення завдання був задіяний автоматичний конструктор мережі – функція пакету Statistica Neural Network [10], яким була побудована наступна ШНМ: тип – багатошаровий перцептрон з 6 вхідними нейронами, 5 прихованими нейронами в прихованому шарі і 1 вихідним нейроном; функція активації – лінійна, вибірка була автоматично розділена на 3 частини: 366 спостережень – навчальна вибірка, 183 – контрольна, 183 – тестова.

У таблиці 1 і рисунку 1 наведені значення похибок обчислення втрат електроенергії і введені наступні позначення: P – активне навантаження ПЛ; U – номінальна напруга ПЛ; S – переріз проводу ПЛ; L – довжина проводу ПЛ; T – середньодобова температура повітря; V – швидкість вітру; O – наявність опадів.

Таблиця 1

Похибки обчислення втрат в залежності від набору вхідних змінних

Похибка/ набір вхідних змінних	PUSLTV (без врахування опадів)	PUSLTO (без врахування швидкості вітру)	PUSLVO (без врахування температури)	PUSTVO (без врахування довжини проводу)	PULTVO (без врахування перерізу проводу)	PSLTVO (без врахування напруги)	USLTVO (без врахування навантаження)
Помилка навчання	0,067494	0,061896	0,110904	0,050740	0,063761	0,056326	0,156492
Контрольна помилка	0,049753	0,059727	0,124642	0,071494	0,055463	0,057126	0,178821
Тестова помилка	0,057444	0,066974	0,109739	0,067247	0,059764	0,072795	0,192722

У таблиці 2 представлені рівні значущості наборів вхідних змінних, привласнених після навчання ШНМ програмою – нейроімітатором, виходячи із значень похибок обчислення втрат,

отриманих внаслідок побудови і навчання ШНМ (таблиця 1). Рівень значущості змінної тим вище, чим меншу похибку має набір вхідних змінних (найбільш значущий набір вхідних змінних відповідає 1, менш значущі – 2, 3, 4 тощо).

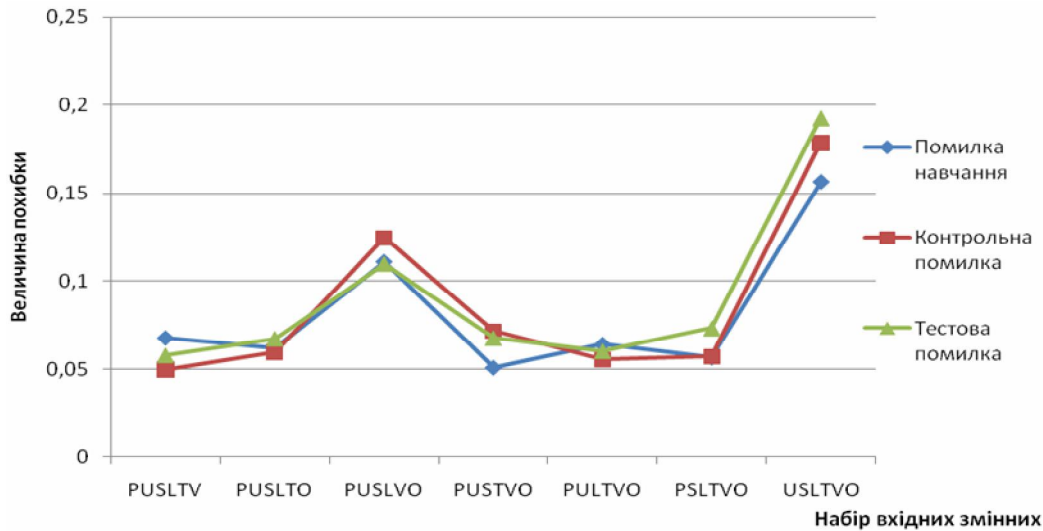


Рис. 1 – Похибки обчислення втрат в залежності від набору вхідних змінних

Таблиця 2

Рівні значущості вхідних змінних

Рівень значущості/набір вхідних змінних	PUSLTV (без врахування опадів)	PUSLTO (без врахування швидкості вітру)	PUSLVO (без врахування температури)	PUSTVO (без врахування довжини проводу)	PULTVO (без врахування перерізу проводу)	PSLTVO (без врахування напруги)	USLTVO (без врахування навантаження)
Помилка навчання	5	3	6	1	4	2	7
Контрольна помилка	1	4	6	5	2	3	7
Тестова помилка	1	3	6	4	2	5	7
Сумарний рівень значущості	7	10	18	10	8	10	21

Набори вхідних змінних PUSLVO (без врахування температури) і USLTVO (без врахування навантаження) в якості вхідного вектора використовувати не можна, що пов'язано з великою похибкою. Оптимальними наборами вхідних змінних є PUSLTV (без врахування опадів) та PULTVO (без врахування перерізу проводу). Найбільш значущими змінними є активне навантаження ПЛ та середньодобова температура повітря. Вони повинні обов'язково включатися в набір вхідних змінних. Всі інші змінні також доцільно включити в створювану ШНС з наступних міркувань: по-перше, їх сумарний рівень значущості практично однаковий, а по-друге, включення даних змінних зменшить похибку прогнозування і поліпшить результат.

Для дослідження оптимальних об'ємів навчальної, контрольної та тестової виборок була побудована ШНМ, тип – багатосаровий перцептрон з 7 вхідними нейронами, 5 прихованими нейронами в прихованому шарі і 1 вихідним нейроном; функція активації – лінійна. Набір даних ШНМ (732 спостереження), був розділений на 3 частини: навчальний набір даних (змінювався автором вручну), контрольний та тестовий набори (змінювались автоматично в залежності від зміни навчальної вибірки). Алгоритм навчання ШНМ – Квазі-Ньютона. В результаті виконаних експериментів були отримані похибки, які представлені в таблиці 3 і на рисунку 2.

Таблиця 3

Похибки обчислення втрат в залежності від об'єму навчальної вибірки

Об'єм навчальної вибірки	Помилка навчання	Контрольна помилка	Тестова помилка
100	0,113832	0,109299	0,126672
150	0,104773	0,143514	0,104490
200	0,063827	0,075923	0,061595
250	0,051757	0,067472	0,072237
300	0,058532	0,068606	0,070284
350	0,062869	0,061484	0,059147
400	0,066695	0,066691	0,072729




Рис. 2 – Похибки обчислення втрат в залежності від об'єму навчальної вибірки

Оптимальний об'єм навчальної вибірки для даної ШНМ, що проектується, при заданих параметрах склав 250 спостережень, об'єми контрольної і тестової вибірок приймаються рівними відповідно 250 та 332 спостереження.

Критерії вибору оптимального типу архітектури ШНМ визначаються [1, 4, 7, 10]: тестовою помилкою; помилкою навчання; контрольною помилкою; складністю архітектури мережі (прямопропорційна складності навчання). Отже, тип архітектури ШНМ, який буде мати найменші похибки і характеризуватися найменшою складністю мережі, буде оптимальним. При виборі оптимального типу архітектури ШНМ для даного завдання використана програмна нейроімітатор STATISTICA Neural Networks, в якій були побудовані 10 найкращих ШНМ наступних конфігурацій: багатосаровий перцептрон, радіально-базисна функція і узагальнено-регресійна мережа (таблиця 4).

Таблиця 4

Результати найкращих архітектур мереж, які отримані в STATISTICA Neural Networks

Архітектура мережі	Помилка навчання	Контрольна помилка	Тестова помилка	Вхід	Приховані шари	
					1 шар	2 шар
ОРНС 7:7-250-2-1:1	4,274141	4,346222	3,669047	7	250	2
РБФ 7:7-14-1:1	3,833628	3,995193	3,101599	7	14	0
ОРНС 7:7-250-2-1:1	3,384848	3,712948	3,150827	7	250	2
РБФ 7:7-29-1:1	2,303887	2,428618	1,958460	7	29	0
МП 1:1-6-5-1:1	0,189972	0,205554	0,200392	1	6	5
МП 1:1-6-4-1:1	0,191509	0,202157	0,198880	1	6	4
МП 5:5-4-1:1	0,067834	0,080368	0,065184	5	4	0
МП 5:5-5-1:1	0,067084	0,071118	0,065293	5	5	0
МП 7:7-5-1:1	0,059038	0,069098	0,065109	7	5	0
МП 7:7-10-6-1:1	0,067096	0,066738	0,054334	7	10	6

Скорочення, які прийняті в таблиці 4: МП – багатoshаровий персептрон; РБФ – радіально-базисна функція; ОРНС – зворотнє поширення нейронної мережі (узагальнено – регресійна мережа).

Використовуючи отримані результати програми-нейроімітатора і виходячи з критеріїв вибору оптимального типу архітектури ШНМ, на основі порівняльного аналізу визначається шукана оптимальна архітектура нейромережі (таблиця 5). В ній найбільш значущому результату присвоєно значення 1, менш значущим – значення в порядку убудання значущості.

Таблиця 5

Результат порівняльного аналізу значущості критеріїв вибору оптимального типу архітектури ШНМ

Архітектура мережі	Мінімальна помилка навчання	Мінімальна контрольна помилка	Мінімальна тестова помилка	Мінімальна складність архітектури	Сумарний рівень значущості
ОРНС 7:7-250-2-1:1	10	10	10	10	40
РБФ 7:7-14-1:1	9	9	9	6	33
ОРНС 7:7-250-2-1:1	8	8	8	9	33
РБФ 7:7-29-1:1	7	7	7	8	29
МП 1:1-6-5-1:1	5	6	6	5	22
МП 1:1-6-4-1:1	6	5	5	4	20
МП 5:5-4-1:1	4	4	3	1	12
МП 5:5-5-1:1	2	3	4	2	11
МП 7:7-5-1:1	1	2	2	3	8
МП 7:7-10-6-1:1	3	1	1	7	12

Вживання узагальнено-регресійної мережі та радіальної базисної функції недоцільно, оскільки похибки даних архітектур мереж значно більші, ніж відповідні похибки, отримані за допомогою багатoshарового персептрона. Для даного типу завдання оптимальним типом архітектури ШНМ є багатoshаровий персептрон, який порівняно з радіально-базисною функцією та узагальнено-регресійною мережею характеризується найменшими помилками та складності мережі. Тому за основну приймається ШНМ з наступною архітектурою: багатoshаровий персептрон, 7 нейронів – у вхідному шарі, 5 нейронів – в прихованому шарі і 1 вихідний нейрон (рис. 3).




Рис. 3 – Архітектура оптимальної мережі

Дослідження вибору оптимальної функції активації схеми полягає в знаходженні і порівнянні похибок навчання, контрольної та тестової помилок в отриманій ШНМ з оптимальними архітектурою та об'ємами виборок з різними функціями активації (лінійною та логістичною). Цей вибір визначили наступні обставини: наявність цих функцій в програмному пакеті Statistica Neural Networks і типом даного завдання [1, 4, 7, 10]. Результати представлені в таблиці 6.

Таблиця 6

Вибір функції активації ШНМ

Функція активації	Помилка навчання	Контрольна помилка	Тестова помилка
Лінійна	0,084740	0,099548	0,092458
Логістична	0,057665	0,059522	0,058583

Як видно з таблиці 6, оптимальною функцією активації є логістична функція.

Для вибору оптимального алгоритму навчання ШНМ була побудована ШНС з відповідним оптимальними архітектурою, об'ємом вибірок та функцією активації. Навчання ШНМ здійснювалося за допомогою алгоритмів, представлених в пакеті програм Statistica Neural Network: зворотне поширення (ЗП), швидке поширення (ШП), спуск по зв'язаних градієнтах (СЗГ), Левенберга-Марквардта (ЛМ), Квазі-Ньютона (КН). Були отримані помилки навчання, контрольна та тестова помилки для кожного алгоритму, також фіксувався сумарний час навчання мережі. Алгоритм навчання, який має найменші вказані похибки та час навчання, буде оптимальний. Спочатку мережа навчається в один етап різними алгоритмами, результати аналізуються і виключаються неефективні методи, які мають неприпустимі похибки. Далі проводиться навчання мережі в два етапи, аналізуючи всі можливі комбінації алгоритмів навчання. Результати дослідження представлені в таблицях 7, 8 та на рисунку 4.

Таблиця 7

Похибки алгоритмів навчання ШНМ в один етап

Результати навчання/ Алгоритми навчання	ЗП	ШП	СЗГ	ЛМ	КН
Помилка навчання	0,112562	0,080551	0,046875	0,091003	0,112388
Контрольна помилка	0,134033	0,089106	0,067834	0,068000	0,100995
Тестова помилка	0,126493	0,073998	0,055933	0,085069	0,115200
Час навчання, с	2	3	4	4	4

Таблиця 8

Похибки алгоритмів навчання ШНМ в два етапи

Результати навчання/ Алгоритми навчання	ШП/ШП	ЛМ/ЛМ	СЗГ/СЗГ	ШП/ЛМ	ЛМ/СЗГ	СЗГ/ШП	ЛМ/ШП	СЗГ/ЛМ	ШП/СЗГ
Помилка навчання	0,0607	0,0607	0,0547	0,0399	0,0625	0,0945	0,1231	0,2824	0,0595
Контрольна помилка	0,0731	0,0731	0,0650	0,0581	0,0632	0,0978	0,1314	0,3011	0,0669
Тестова помилка	0,0699	0,0699	0,0649	0,0646	0,0661	0,0877	0,1565	0,3422	0,0757
Час навчання, с	4	4	5	5	5	5	5	5	5

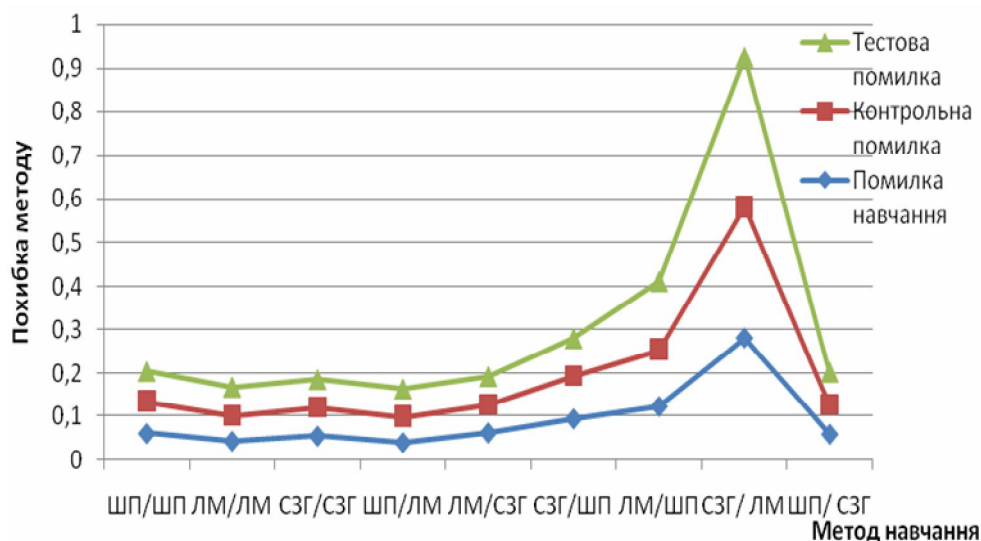


Рис. 4 – Значення похибок алгоритмів навчання ШНМ в 2 етапи

З таблиці 7 видно, що для подальшого дослідження алгоритми навчання ШНС зворотне поширення та Квазі-Ньютона не припустимі, тому що мають великі похибки. Алгоритми швидкого поширення, Левенберга-Марквардта, Квазі-Ньютона дають прийнятні похибки.

В якості оптимального алгоритму навчання для даного завдання приймається навчання ШНМ в 2 етапи: на першому етапі застосовується метод швидкого поширення, на другому – метод Левенберга-Марквардта (має швидку збіжність і найменшу похибку).

Висновки

1. В результаті проведених досліджень, автором розроблена модель нейромережі для розрахунку технічних втрат електроенергії в повітряних лініях електропередачі напругою 6-35 кВ: архітектура – багатошаровий персептрон, 7 нейронів – у вхідному шарі, 5 нейронів – в прихованому шарі і 1 вихідний нейрон; вхідні змінні: активне навантаження ПЛ, номінальна напруга ПЛ, переріз проводу ПЛ, довжина проводу ПЛ, середньодобова температура повітря, швидкість вітру, наявність опадів; вихідна змінна – технічні втрати активної електроенергії в ПЛ; об'єми вибірок: навчальна – 250 спостережень, контрольна – 250 спостережень, тестова – 232 спостереження; функція активації – логістична; алгоритм навчання – в 2 етапи: на першому етапі – метод швидкого поширення, на другому – метод Левенберга-Марквардта.

2. В порівнянні з існуючими моделями розрахунку втрат електроенергії в повітряних ЛЕП, авторська модель має наступні переваги: менша похибка розрахунку, можливість роботи з зашумленими даними, можливість використання малих навчальних вибірок, швидкий відгук навченої нейромережі на надходження поточної інформації, забезпечення практично повного режимного діапазону роботи електричної мережі, облік великої кількості чинників, висока міра адекватності режимів мережі, автоматична адаптація моделі відбувається шляхом самонавчання, врахування метеофакторів, які мають вплив на втрати електроненергії в повітряних ЛЕП.

Список використаних джерел:

1. Бакулевський В.Л. Вибір оптимальної моделі нейромережі для розрахунку втрат електроенергії в повітряних лініях електропередачі з урахуванням температурного чинника і графіків навантаження / В.Л. Бакулевський // Наукові праці Донецького національного технічного університету / ДВНЗ «ДонНТУ». – Донецьк, 2011. – Вип. 11 (186). – С. 31-35.
2. Курбацкий В.Г. Анализ потерь в распределительных сетях / В.Г. Курбацкий, Н.В. Томин // Интеллектуальные и материальные ресурсы Сибири : Сб. науч. тр. – Иркутск : БГУЭП, 2006. – С. 120-127.
3. Генетические алгоритмы, искусственные нейронные сети и проблемы виртуальной реальности / Г.К. Вороновский, К.В. Махотило, С.Н. Петрашев, С.А.Сергеев. – Харьков : Основа, 1997. – 112 с.
4. Заиграева Ю.Б. Нейросетевые модели оценки и планирования потерь электроэнергии в электроэнергетических системах : автореф. дис. ...канд. техн. наук : 05.14.02 / Ю.Б. Заиграева; Новосибир. гос. техн. ун-т. – Новосибирск, 2008. – 20 с.
5. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М. : Горячая линия-Телеком, 2006. – 452 с.
6. Царегородцев В.Г. Взгляд на архитектуру и требования к нейроимитатору для решения современных промышленных задач / В.Г. Царегородцев // Нейроинформатика и ее приложения : материалы XI Всеросс. семинара. – Красноярск : КГТУ, 2003. – С.171-175.
7. Царегородцев В.Г. К определению информативности независимых переменных для нейронной сети / В.Г. Царегородцев // Нейроинформатика и ее приложения : материалы XI Всеросс. Семинара. – Красноярск : КГТУ, 2003. – С. 176-177.
8. Novel approach to electrical load. Forecasting based on a neural network / D.A. Srinivasan [and oth.] // INNC-91. – Singapore, 1991. – P. 1172-1177.
9. Hamid B. Automated load forecasting using neural networks / Bacha Hamid, Mayer Walter // Proc. Amer. Power Conf. – 1992. – Vol. 54. – P. 1149-1153.
10. Нейронные сети. STATISTICA Neural Networks. – М. : Горячая линия-Телеком, 2001. – 654 с.

Bibliography:

1. Bakulevskiy V.L. Selection of optimal neural network model to calculate the energy losses in overhead transmission lines based on the temperature factor and load charts / V.L. Bakulevskiy // Proceedings of Donetsk National Technical University / SHEE «DonNTU». – Donetsk, 2011. – Issue 11 (186). – P.31-35. (Ukr.)
2. Kurbatskiy V.G. Analysis of losses in distribution networks / V.G. Kurbatskiy, N.V. Tomin // Intellectual and material resources of Siberia : Collection of scientific works. – Irkutsk : BGUEP, 2006. – P. 120-127. (Rus.)
3. Genetic algorithms, artificial neural networks and problems of virtual reality / G.K. Voronovskiy, K.V. Makhotilo, S.N. Petrashev, S.A. Sergeev. – Kharkiv : Osnova, 1997. – 112 p. (Rus.)
4. Zaigraeva J.B. Neural network model evaluation and planning of electric power losses in electric power systems: phd. thesis : 05.14.02 / J.B. Zaigraeva; Novosibirsk State Technical University. – Novosibirsk – 2008 – 20 p. (Rus.)
5. Rutkovskaya D. Neural networks, genetic algorithms and fuzzy systems / D. Rutkovskaya, M. Pilinsky, L. Rutkowski. – M. : Goryachaya liniya-Telecom, 2006. – 452 p. (Rus.)
6. Tsaregorodcev V.G. A look at the architecture and requirements neuroimitatoru to solve problems of modern industrial / V.G. Tsaregorodcev // Neuroinformatics and its applications : Proceedings XI All-Russia seminar. – Krasnoyarsk : KSTU, 2003. – P. 171-175. (Rus.)
7. Tsaregorodcev V.G. By the definition of informativeness independent re-variables for the neural network / V.G. Tsaregorodcev // Neuroinformatics and its applications : Proceedings XI All-Russia seminar. – Krasnoyarsk : KSTU, 2003. – P. 176-177. (Rus.)
8. Novel approach to electrical load. Forecasting based on a neural network / D.A. Srinivasan [and oth.] // INNC-91. – Singapore, 1991. – P. 1172-1177.
9. Hamid B. Automated load forecasting using neural networks / Bacha Hamid, Mayer Walter // Proc. Amer. Power Conf. – 1992. – Vol. 54. – P. 1149-1153.
10. Neural Networks. STATISTICA Neural Networks. – M. : Goryachaya liniya-Telecom, 2001. – 654 p. (Rus.)

Рецензент: В.А. Водічев
д-р техн. наук, проф., ОНПУ

Стаття надійшла 17.03.2015