

УДК 004:620.91

І.В. ГАРЯЧЕВСЬКА, С.Ю. МОВЕНКО
Харківський національний університет імені В.Н. Каразіна

РОЗРОБКА ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ СПОЖИВАННЯ ЕЛЕКТРОЕНЕРГІЇ

Основною метою роботи є розробка моделей прогнозування часових рядів для отримання якомога точнішого прогнозу споживання та вироблення електроенергії з урахуванням використання альтернативних джерел енергії. У роботі вивчаються основні методи прогнозування часових рядів та здійснюється їх порівняння на практиці. Пропонуються модернізації для отримання більшого ступеня точності за рахунок використання закону великих чисел. Досліджуються загальні фактори впливу на споживання та вироблення електроенергії за допомогою альтернативних джерел енергії. Досліджується ступінь точності створених моделей для довгострокового та короткострокового прогнозування. Пропонується програмна реалізація розроблених моделей у вигляді веб-програми. Розглянуто питання офлайн навчання штучних нейронних мереж за допомогою Jenkins CLI та системи розподіленого контролю версій Git.

Ключові слова: прогнозування, споживання електроенергії, штучні нейронні мережі, дерева рішень, часові ряди, альтернативні джерела енергії.

І.В. ГАРЯЧЕВСКАЯ, С.Ю. МОВЕНКО
Харьковский национальный университет имени В.Н. Каразина

РАЗРАБОТКА ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ

Основной целью работы является разработка моделей прогнозирования временных рядов для получения наиболее точного прогноза потребления и выработки электроэнергии с учётом использования альтернативных источников энергии. В работе изучаются основные методы прогнозирования временных рядов и осуществляется их сравнение на практике. Предлагаются модернизации для получения большей степени точности за счет использования закона больших чисел. Исследуются общие факторы влияния на потребление и выработку электроэнергии с помощью альтернативных источников энергии. Исследуется степень точности созданных моделей для долгосрочного и краткосрочного прогнозирования. Предлагается программная реализация разработанных моделей в виде веб-приложения. Рассмотрен вопрос офлайн обучения искусственных нейронных сетей с помощью Jenkins CLI и системы распределенного контроля версий Git.

Ключевые слова: прогнозирование, потребление электроэнергии, искусственные нейронные сети, деревья решений, временные ряды, альтернативные источники энергии.

I. GARYACHEVSKA, S. MOVENKO
V.N. Karazin Kharkiv National University

DEVELOPMENT OF ARTIFICIAL NEURAL NETWORKS FOR PREDICTING ELECTRICITY CONSUMPTION

The main purpose of the work is to develop models of forecasting of time series for obtaining as accurately as possible the forecast of electricity consumption and generation of electricity by alternative energy sources. In this paper, we study the basic methods of forecasting time series and perform their comparison in practice. In this paper, we consider such methods of forecasting time series as the autoregressive method, the method of decision tree and methods based on the use of the artificial neural networks. Modernization is proposed to obtain a greater degree of accuracy with the help of the law of large numbers. In this paper uses the artificial neural network with self-organization based on competition, namely the Kohonen's neural network in combination with the multilayer perceptron. This artificial neural network allows you to classify data on the results of which the forecast of electricity consumption will be fulfilled. The training of the created artificial neural network occurs by the method of back propagation of the error. Each artificial neural network performs prediction depending on the influence of its factor. Each artificial neural network serves as a perceptron in the classical model. The general factors of influence on the consumption of electric power and on production with the help of alternative energy sources are studied. The degree of accuracy of the created models for forecasting in the long-term and short-term perspective is investigated. The software implementation of the developed models in the form of a web application is offered. A database for storing user data was created in the developed web application. In this paper uses the hierarchical

database to store the settings of the artificial neural networks. The web application provides the ability to send emails to notifying users about the starting and finishing of training the artificial neural network. To increase the accuracy of the forecast, the model consisting of several artificial neural networks is used. The issue of offline training of artificial neural networks with the help of Jenkins CLI and the distributed control system of Git versions is considered.

Keywords: forecasting, electricity consumption, artificial neural networks, solution wood, time ranges, alternative sources of energy.

Постановка проблеми

Задача планування споживання електроенергії завжди була важлива для процесу отримання та використання електроенергії. На даний час існують три види тарифів на електроенергію: одноставковий, многоставковий та диференційований. Найбільший інтерес представляє диференційований тариф. Він дозволяє оплачувати фактично спожиту енергію, яка розподілена за добовими часовими зонами. Важливим є те, що цей тариф має фіксовані тарифні ставки для кожної зони. Потреба в такому регулюванні виникає в двох випадках: або в зв'язку з нестачею пікових потужностей, або внаслідок труднощів проходження нічного провалу графіка електричного навантаження. Для якісного розрахунку тарифу необхідна установка багатотарифного лічильника електроенергії для вимірювання спожитої енергії окремо для декількох добових часових зон. Найбільше споживання електроенергії (пікова зона) припадає на денний час. У зазначені години запускається обладнання, що генерує енергію, однак воно виробляє електроенергію з найбільш високою вартістю. Оскільки в нічний час споживання електричної енергії значно зменшується, з роботи виводиться обладнання, яке виробляє електроенергію з більш високою вартістю. Тому в нічний час ціна найнижча. Для того, щоб простимулювати населення використовувати електрику в нічний час доби, було прийнято рішення про зменшення нічного коефіцієнта до 0,5.

Прогнозування грає ключову роль при формуванні балансу електроенергії в енергосистемі, впливаючи на вибір режимних параметрів і розрахункових електричних навантажень. Баланс виробництва та споживання електроенергії – це основа технологічної стійкості енергосистеми, його порушення позначається на якості електроенергії (відбувається деградація частоти і напруги в мережі), що знижує ефективність роботи обладнання. Крім того, правильний прогноз дозволяє забезпечити оптимальний розподіл навантаження між об'єктами енергосистеми. Це дає можливість управляти вартістю покупки електроенергії шляхом регулювання завантаження устаткування, переводячи, наприклад, основні обсяги генерації електроенергії в години і зони оптового ринку енергії з найменшою ціною.

Мета дослідження

Метою роботи є аналіз існуючих методів прогнозування часових рядів та розробка технології для здійснення прогнозу споживання електроенергії з різною часовою перспективою.

Аналіз останніх досліджень і публікацій

Аналіз існуючих методів прогнозування часових рядів. Часовий ряд (ЧР) – це послідовність значень, які описують перебіг процесу в часі, виміряних в послідовні моменти часу, зазвичай через рівні проміжки. Дані цього типу широко поширені в різноманітних сферах діяльності людини. В економіці – це щоденні ціни на акції, курси валют, щотижневі і місячні обсяги продаж, річні обсяги виробництва. В нашому випадку – це дані, які характеризують споживання електроенергії. Розглянемо методи прогнозування часових рядів, які найбільш часто використовуються на практиці.

Метод авторегресії виражає залежність показника від факторів що впливають за допомогою лінійної моделі. Загальний вигляд моделі авторегресії порядку p визначається наступним чином:

$$X_t = c + \sum_{i=1}^p a_i X_{t-i} + \varepsilon_t,$$

де c – константа, яка описує ситуацію проходження факторів що впливають, через початок координат, тобто показує, який вигляд має модель в разі, коли фактори що впливають, дорівнюють нулю; a_i – коефіцієнти, які описують ступінь залежності підсумкового параметру X_t від факторів що впливають, в даному випадку, від того, яким був параметр X_t на минулому кроці регресії; ε_t – випадкова компонента або, як ще її прийнято називати, похибка моделі – це різниця між розрахунковим значенням моделі за певні періоди та відомими значеннями. Метод авторегресії дає можливість показати залежність параметру X_t від самого себе в попередній проміжок часу (день, місяць, рік і т.п.). Саме до цього зводиться суть авторегресійної моделі, тобто, цілком раціонально можливо припустити практично для будь-якого показника, що його поточне значення, в якійсь мірі, залежить від того, яке значення цього показника було в попередній проміжок часу. Саме пошук цієї залежності дозволяє будувати досить точні моделі, за якими дуже легко зробити прогноз.

ПЕРЕВАГИ МЕТОДУ:

1. Отримання високоякісної моделі з адекватним прогнозом при мінімумі витрат часу та вимог до вхідних даних.

НЕДОЛІКИ МЕТОДУ:

1. Прогноз за вхідними даними можливий тільки на один період вперед. Якщо потрібно зробити прогноз на більш тривалий проміжок часу, то в якості факторів, що впливають, для розрахунку доведеться брати не реально існуючий параметр X_t , а той, який розрахований за моделлю, що в підсумку дасть прогноз на прогнозі, а значить адекватність такого прогнозу, як мінімум, в два рази менша.
2. Зі збільшенням порядку авторегресії виникає необхідність розширювати діапазон вхідних даних.

Метод авторегресії має як переваги, так і недоліки щодо задач прогнозування часових рядів. Традиційно для прогнозу споживання електроенергії використовується метод авторегресії: лінійний алгоритм, заснований на прогнозі майбутнього за найближчим минулим. При цьому всі інші фактори, що впливають на споживання електроенергії, використовуються опосередковано, тобто через їх вплив на минулі значення споживання електроенергії. Цей метод дозволяє отримувати гарні результати прогнозу в стабільних ситуаціях, наприклад, коли немає різких кліматичних змін. Однак при несподіваний різкій зміні зовнішніх параметрів застосування такого підходу не дозволяє правильно спрогнозувати ситуацію. Наприклад, при різкому сильному похолоданні, навіть в разі якщо відомий приблизно правильний прогноз погоди, метод не передбачає можливості його використання. У зв'язку з тим, що авторів цікавить задача прогнозування споживання електроенергії, яка має дуже багато факторів впливу, це призводить до неможливості використання даного методу.

Метод дерев рішень це один з найпопулярніших методів розв'язку задачі класифікації та прогнозування. Якщо залежна, тобто цільова змінна, набуває дискретних значень, то за допомогою методу дерева рішень розв'язується задача класифікації. Якщо ж залежна змінна приймає безперервні значення, то дерево рішень встановлює залежність цієї змінної від незалежних змінних. Вперше дерева рішень були запропоновані Ховілендом і Хантом в кінці 50-х років минулого століття. У найбільш простому вигляді дерево рішень – це спосіб представлення правил в ієрархічній, послідовній структурі. Основа такої структури – відповіді "Так" або "Ні" на ряд питань. На рис. 1. представлена одна з віток дерева рішень.

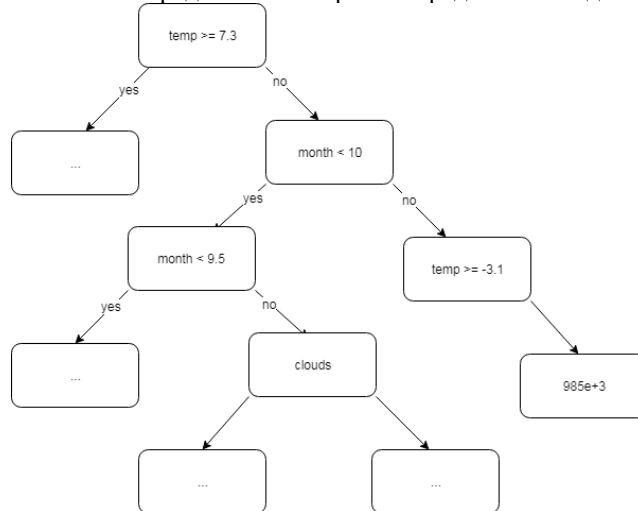


Рис. 1. Приклад відгалуження дерева рішень

Останнім часом все більшу увагу з боку фахівців, що займаються прогнозом часових рядів, і зокрема, рядів з споживання електроенергії, привертають штучні нейронні мережі (ШНМ). Основна привабливість застосування ШНМ для задач прогнозу споживання електроенергії полягає в можливості використання великої кількості різноманітних вхідних параметрів: історичні дані по споживанню електроенергії та відповідні історичні погодні умови, прогноз погоди, час доби, пора року, тип дня і т.д. При цьому функція впливу вхідного параметра на вихідний результат може бути якою завгодно складності (нелінійної, нестационарної).

ШНМ є аналітичними системами, в яких поставлені задачі не досить чітко сформульовані. Недостатня точність формулювання заповнюється здатністю ШНМ до самонавчання, вмінню знаходити в даних приховані і неясні образи. Важливою властивістю ШНМ є здатність до зміни своєї поведінки і знання в залежності від змін зовнішнього середовища.

Аналіз існуючих методів показав, що найперспективнішим є використання нейронних мереж, тому що споживання електроенергії залежить від безлічі параметрів, це можуть бути робочий день або вихідний, сезон, час року, температура, похмурість, вологість та інші.

Викладення основного матеріалу досліджень

Розробка нейронної мережі для розв'язання задачі прогнозування споживання електроенергії.

Для прогнозування електроспоживання краще використовувати конфігурацію ШНМ прямого поширення (перцептрон) з навчанням за методом зворотного поширення помилки. Тут необхідно

зауважити, що при виборі структури ШНМ важливо враховувати її розмірність, тобто кількість прихованих шарів і кількість нейронів в цих шарах. При недостатньому розмірі мережі для розв’язання поставленого завдання ШНМ буде погано навчатися та неправильно працювати, а при розмірі мережі, який перевищує складність розв’язуваної задачі, процес навчання ШНМ буде дуже тривалим, або мережа взагалі може бути непридатна для розв’язання даного завдання. Це питання в кожному конкретному випадку вирішується експериментальним шляхом.

З усіх цих факторів можна зробити висновок, що метод ШНМ дуже добре підходить для прогнозування часових рядів в рамках задачі прогнозування споживання електроенергії. Він добре справляється з великою кількістю вхідних параметрів, з задачами, що погано формалізуються, вміє знаходити в даних неясні прихованні образи. Першим кроком під час навчання нейронної мережі ініціалізуємо вагові коефіцієнти випадковим чином, після чого у випадковому порядку подаємо дані навчальної вибірки. Для навчання кількох різних нейронних мереж, з однаковими вхідними даними, отримуємо на виході результат з похибкою. Крім того, частина вхідних параметрів моделі є чисельними (історичні значення споживання електроенергії, температура повітря, час доби і т.п.), а частина – категоріальними (пора року, тип дня, тип хмарності та інші). Можливо також неявно використання вхідних параметрів. Наприклад, через побудову системи ШНМ, кожний елемент якої (окрема ШНМ) навчений на певний випадок, наприклад, для певного типу дня або пори року. Загальний вхід системи ШНМ (ворота) служить для спрямування даних на вхід конкретної ШНМ, призначеної для відповідної прогнозованої ситуації. Структура розробленої нейронної мережі з конфігурацію прямого поширення з навчанням за методом зворотного поширення похибки наведена на рис. 2.

Задля збільшення точності прогнозу використовується модель, створена з декількох ШНМ. Кожна ШНМ виконує прогнозування згідно з впливом свого фактору. Кожна ШНМ виконує роль перцептрона в класичній моделі. Це дозволяє збільшити точність прогнозування. Згідно з заданим алгоритмом відбувається перерахування ваг для кожного вузла. Для кожного показника, що може впливати на прогнозування (температура, опади, вихідні дні), розпочинається навчання окремої ШНМ. Коли навчання кожної ШНМ закінчується, розпочинається навчання головної ШНМ, яка встановлює ваги для кожної ШНМ, тобто визначає вплив, якого показника більше впливає на споживання електроенергії. Стандартна схема процесу навчання багатошарового перцептрона наведена на рис. 3.



Рис. 2. Структура нейронної мережі з конфігурацію прямого поширення з навчанням за методом зворотного поширення помилки

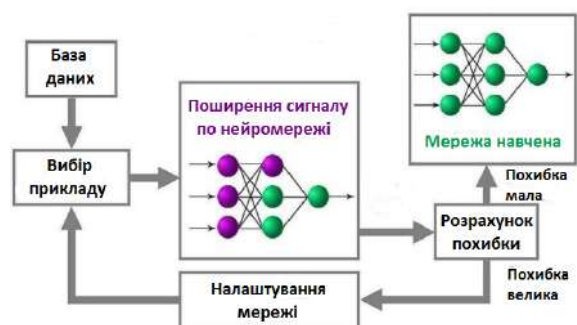


Рис. 3. Процес навчання нейронної мережі

Розглянемо детальніше алгоритм навчання ШНМ. На першому кроці відбувається ініціалізація вагових коефіцієнтів (v, w) випадковим чином. Кожний вхідний нейрон $\{x_i\}_{i=1}^n$ відправляє отриманий сигнал всім нейронам в наступному (прихованому) шарі. Кожний прихований нейрон $\{z_j\}_{j=1}^p$ підсумовує зважені вхідні сигнали:

$$z_{in_j} = \sum_{i=1}^n x_i v_{ij},$$

після чого застосовує активаційну функцію:

$$z_j = f(z_{in_j}).$$

Отриманий результат надходить всім елементам наступного (вихідного) шару. Кожний вихідний нейрон $\{y_k\}_{k=1}^m$ підсумовує зважені вхідні сигнали:

$$y_{in_k} = \sum_{j=1}^p z_j w_{jk}$$

і застосовує активаційну функцію, обчислюючи вихідний сигнал:

$$y_k = f(y_{in_k})$$

Далі визначається похибка. Кожний прихований нейрон $\{z_j\}_{j=1}^p$ підсумовує похибку, що надходить від нейронів попереднього шару:

$$\sigma_{in_j} = \sum_{k=1}^n \sigma_k w_{jk}$$

(σ_k – складова коригування вагових коефіцієнтів), після чого обчислює величину похибки, помножуючи отримане значення на похідну активаційної функції:

$$\sigma_j = \sigma_{in_j} f'(z_{in_j})$$

На наступному етапі відбувається коригування вагових коефіцієнтів, які в подальшому використовуються, як нові вхідні дані до ШНМ.

Модель прогнозування споживання електроенергії, заснована на використанні даної ШНМ, показує хороші результати, наприклад, для середніх значень за день. При застосуванні нейронних мереж для часового прогнозування є необхідність модифікації, а саме, для кожної години використовувати свою нейронну мережу. Результати такого прогнозу наведені на рис. 4. На графіку синім кольором позначені реальні дані, а червоним кольором позначені дані, які були отримані за допомогою прогнозу нейронною мережею.

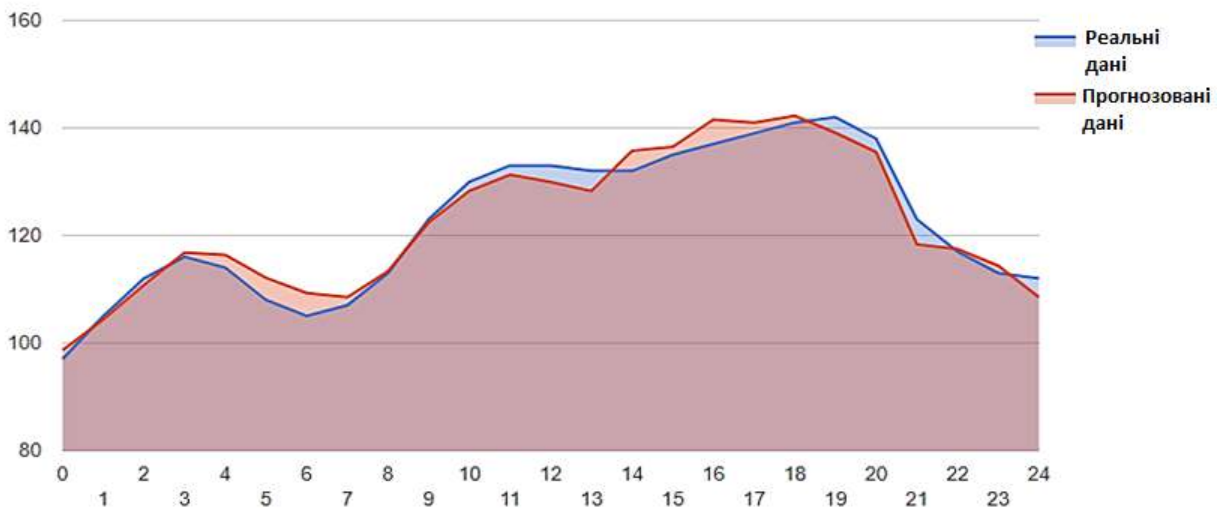


Рис.4. Прогноз споживання електроенергії за день.

Авторами було створено 24 ШНМ для кожного часу. Кількість нейронних мереж, які попали в проміжок похибок до 2%, до 5% та більше 5% наведена в табл. 1.

Таблиця 1

Похибки нейронних мереж

Дата	Число погодинної похибки		
	До 2%	До 5%	Більш 5%
28.01.2017	12	24	0
29.01.2017	11	22	2
30.01.2017	12	21	3
31.01.2017	9	22	2
01.02.2017	15	22	2
02.02.2017	4	9	15
03.02.2017	3	13	11
04.02.2017	11	13	11
05.02.2017	10	17	7
06.02.2017	10	16	8
07.02.2017	10	19	5

Виходячи з даних табл. 1 бачимо, що спочатку результат прогнозування споживання електроенергії є задовільним, проте, згодом спостерігається різке збільшення похибки. Це обумовлено тим фактом, що графіки щоденного споживання дуже сильно різняться. Наприклад, дні можуть бути вихідними або робочими. Виходячи з цього, можна зробити висновок, що за допомогою нейронної мережі з статичною архітектурою неможливо здійснити ефективне погодинне прогнозування.

Для розв'язання цієї задачі було вирішено застосувати нейронну мережу з самоорганізацією на основі конкуренції, а саме мережу Кохонена. Принцип дії даної нейронної мережі наступний. В ШНМ з самого початку присутні входні дані, але відсутні нейрони. За результатами входних даних, створюються нейрони з деякими випадковими ваговими коефіцієнтами. Коли в ШНМ подаються наступні входні дані, розраховується так звана евклідова відстань – це різниця входного вектора та вагових коефіцієнтів. Якщо ця відстань велика, то створюється новий нейрон. Таким чином, виконується розбиття, на так звані, кластери. Стандартна схема нейронної мережі Кохонена наведена на рис. 5.




Рис. 5. Нейронна мережа Кохонена




Рис. 6. Схема навчання нейронної мережі Кохонена

Алгоритм навчання нейронної мережі Кохонена, в графічному вигляді, наведено на рис. 6.

Для розв'язання задачі кожний вхідний сигнал подається на кожний нейрон, після чого визначається нейрон-переможець, це означає, що цей нейрон відповідає за певний день енергоспоживання і тільки для нього здійснюється перерозподіл вагових коефіцієнтів. Розглянемо більш детально алгоритм роботи даної нейронної мережі.

На першому кроці відбувається завдання структури нейронної мережі (кількості нейронів шару Кохонена). Після чого відбувається випадкова ініціалізація вагових коефіцієнтів:

$$|w_{ij}| \leq \frac{1}{\sqrt{M}},$$

де M – кількість вхідних змінних мережі.

На наступному кроці відбувається подача на входи мережі випадкового навчального прикладу поточної епохи навчання і здійснюється розрахунок евклідових відстаней від вхідного вектора до центрів всіх кластерів:

$$R_j = \sqrt{\sum_{i=1}^M (\tilde{x}_i - w_{ij})^2}.$$

За найменшим зі значень R_j обирається нейрон-переможець j , найбільшою мірою близький за значеннями з вхідним вектором. Для обраного нейрона (і тільки для нього) виконується корекція вагових коефіцієнтів:

$$w_{ij}^{(q+1)} = w_{ij}^{(q)} + v(\tilde{x}_i - w_{ij}^{(q)}),$$

де v – коефіцієнт швидкості навчання.

Дана нейронна мережа виконує тільки класифікацію вхідних даних, тобто є непридатною для здійснення прогнозу. У зв'язку з чим, було прийняте рішення об'єднати мережу Кохонена та багатозаровий перцептрон для попередньої класифікації даних, за результатами якої буде виконуватися прогноз споживання електроенергії.

Схема отриманої нейронної мережі наведена на рис. 7.

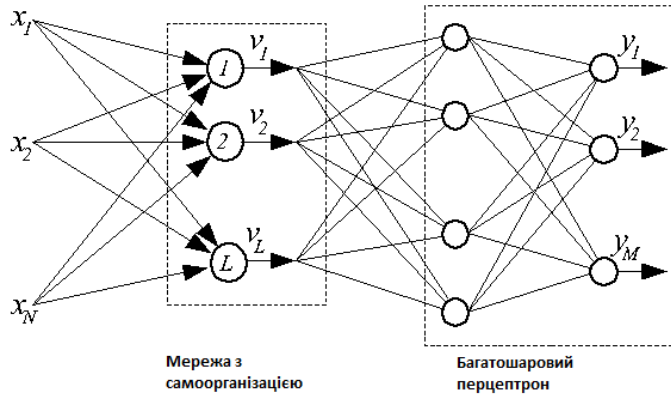


Рис.7. Схема модернізованої нейронної мережі

На рис. 8 наведено результат роботи модифікованої нейронної мережі.




Рис. 8. Графік прогнозування споживання електроенергії отриманий модифікованою нейронною мережею

Синім кольором на графіку зазначені реальні значення, жовтим – результат роботи не модернізованої моделі нейронної мережі, червоним – поліпшена, модернізована модель нейронної мережі. Дана модифікація дозволила отримати прогноз з похибкою в 19 з 24 випадків до 5%.

Покращити створену модель можливо за рахунок збільшення кількості вхідних даних. Під час тестування ШНМ були застосовані дані споживання електроенергії Харківським національним університетом імені В.Н. Каразіна за термін, який складає п'ять років. Однак, в отриманих даних був відсутній ряд показників, наприклад, таких як погодні умови. За наявності цих показників можна суттєво поліпшити якість класифікації, а відповідно й прогнозу.

Розроблена штучна нейронна мережа була реалізована у вигляді веб-програми. Стартове вікно даної програми наведено на рис. 9.

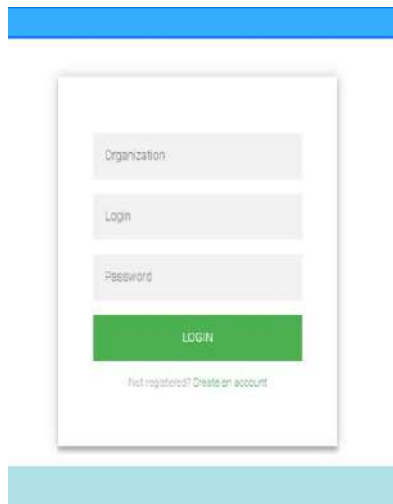


Рис. 9. Стартове вікно програми прогнозування споживання електроенергії.

В розробленій програмі для збереження даних користувачів була реалізована база даних. Ця реляційна база даних складається з трьох таблиць наведених на рис. 10.

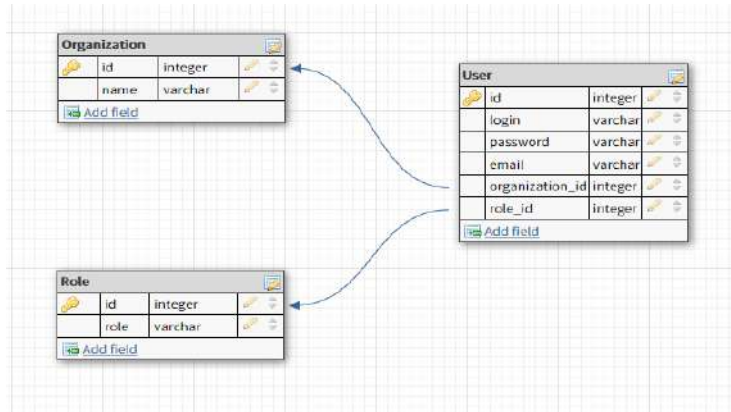


Рис. 10. Структура реляційної бази даних.

Дана модель зберігання інформації, для роботи з нейронною мережею, володіє одним явним недоліком – це час навчання. Це пов’язано з тим, що одночасно виконується навчання декількох нейронних мереж, крім того системою можуть скористатися різні користувачі, і для кожного потрібно проводити власні розрахунки на даних, які вони надають. Кожний користувач навчає свою нейронну мережу. Необхідно зберігати для кожного користувача його модель. Тому була застосована ієрархічна база даних для збереження налаштування мережі.

Програма написана на мові Java, вона дозволяє зберегти стан класу об’єкта в файл, після чого він з’являється в ієрархічній структурі в базі даних. На рис. 11 представлена структура, в якій зберігаються дані в ієрархічній базі даних.

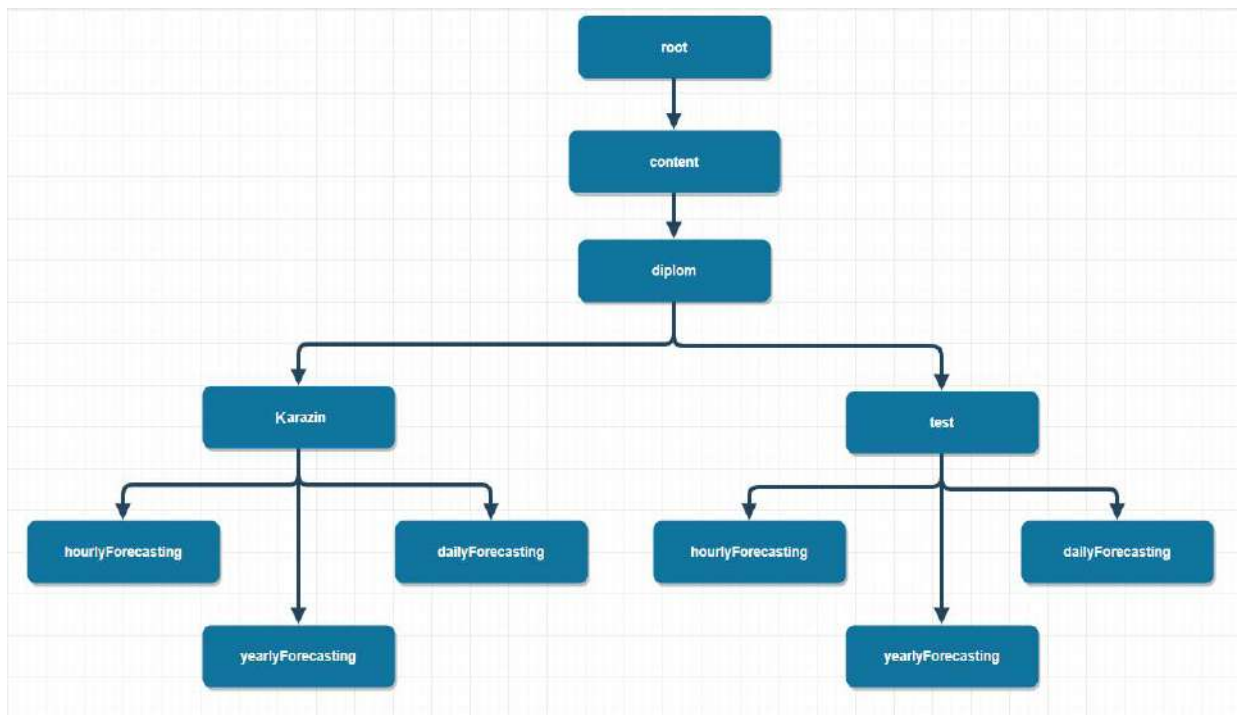


Рис. 11. Фрагмент структури ієрархічної бази даних.

На Рис.12 представлено вікно розробленої бази даних.




Рис. 12. Вікно бази даних

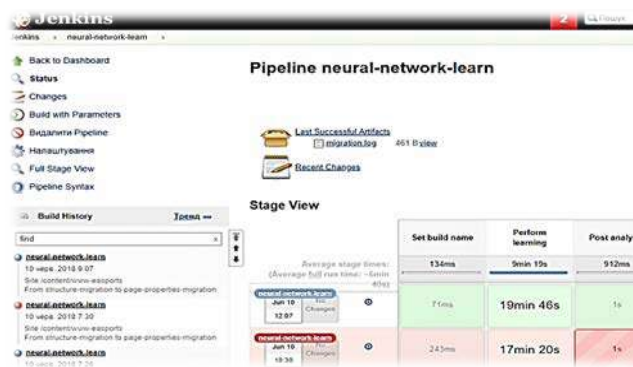


Рис. 13. Служба Jenkins

Коли користувач запускає навчання нейронної мережі, йому не зручно чекати кінця, тому що він не знає, коли закінчиться навчання. Як ми бачимо на рис. 13, навчання тривало 19 хвилин. Для взаємодії з користувачем було використано службу Jenkins, яка дозволяє автоматизувати деякі процеси. Дана служба має доступ до коду за допомогою розподіленої системи контролю версій Git. Після початку навчання нейронної мережі, система надсилає листа користувачеві з інформацією про час налаштування мережі, а після закінчення навчання користувачеві надається посилання для подальшої роботи з мережею.

Приклад вікна програми наведено на рис. 14. Користувачу дається можливість налаштувати свою нейронну мережу, а також обрати, який саме прогноз він хоче отримати: на день, місяць чи рік. Тобто обрати часову перспективу прогнозу.

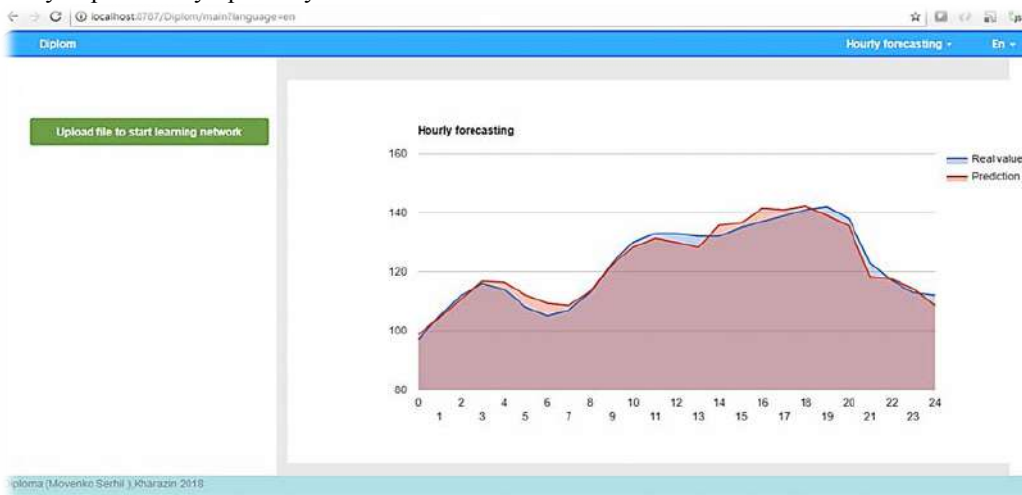


Рис. 14. Результат прогнозу на день.

На Рис. 15 представлено приклад прогнозу на рік з урахуванням впровадження в університеті альтернативних джерел енергії. Прогноз було здійснено з урахуванням виробітки енергії сонячними панелями площею 200 м². Червоним кольором позначені показники вироблення електроенергії, синім – споживання. Окупність такої модернізації становить 5 років.




Рис. 15. Приклад прогнозу на рік для Харківського національного університету імені В.Н. Каразіна з урахуванням впровадження сонячних панелей.

Висновки

Під час дослідження було проведено аналіз існуючих методів прогнозування часових рядів. Здійснена модифікація нейронної мережі для прогнозування споживання електроенергії та виробітки за допомогою альтернативних джерел енергії. Розроблені структури баз даних для зберігання інформації про користувачів та налаштування штучних нейронних мереж. Реалізована програма на мові Java у вигляді веб-додатку зі застосуванням служби Jenkins, та розподіленої системи контролю версій Git. Проведено тестування на реальних даних.

Список використаної літератури

1. Хайкин С.В. Нейронные сети: полный курс / С.В. Хайкин [2-е изд. Пер. с англ.] — М.: Издательский дом "Вильямс", 2006. — 1104 с.
2. Хорстманн Кей. Java. Библиотека профессионала. Основы / Кей Хорстманн, Гари Корнелл. — Т.1. — М.: Издательский дом "Вильямс", 2015. — 1008 с.
3. Блинов И.Н. Java. Промышленное программирование / И.Н. Блинов, В.С. Романчик. — Минск: УниверсалПресс, 2007. — 704 с.
4. Гранд Марк. Шаблоны проектирования в Java / Марк Гранд. — М.: Новое знание, 2004. — 559 с.