



Д. М. Карпа, І. Г. Цмоць, Ю. В. Опотяк

Національний університет "Львівська політехніка", м. Львів, Україна

НЕЙРОМЕРЕЖЕВІ ЗАСОБИ ПРОГНОЗУВАННЯ СПОЖИВАННЯ ЕНЕРГОРЕСУРСІВ

Досліджено та обгрунтовано вибір нейромережових структур для оброблення статистичних даних з метою прогнозування та виявлення аномальних показників споживання енергоресурсів. Показано, що системам на основі нейронних мереж завжди протиставлялись експертні системи, які, на відміну від перших, очевидно програмувались. Середовище, в якому працює система, не завжди є статичним і потрібні методи опрацювання даних, які могли б адекватно реагувати на зміну середовища та вміти відповідно адаптувати отримувані результати. Нейронні мережі володіють такою особливістю, як вміння навчатись. Ця особливість і є основним аргументом для застосування таких структур у системах управління енергоефективністю. Розроблена архітектура мережі та застосований процес навчання дав змогу прогнозувати показники спожитої електроенергії з урахуванням багатьох параметрів. Особливістю розробленої архітектури є можливість здійснювати перенавчання у процесі функціонування, не перериваючи його. Використання адаптивного та безперервного навчання нейромережі дасть змогу виявляти аномальні показники даних. Точність такого виявлення було перевірено на реальній вибірці даних. Аналіз отриманих результатів показує, що використання нейронних мереж хоч і потребує швидкодії і часу на навчання, проте, під час класифікації вхідного вектора, швидкодія нейронної мережі перевищує будь-який алгоритм кластеризації.

Ключові слова: нейронна мережа; машинне навчання; багатошаровий перцептрон; статистичні дані; нормалізація даних; прогнозування; виявлення аномалій.

Вступ. Енергоефективність – властивість обладнання, технології, виробництва або систем взагалі, яка характеризує міру використання енергії на одиницю кінцевого продукту. Енергоефективність можна оцінити за допомогою показників як кількісно (кВт·год, тонни умовного палива, кДж на одиницю кінцевого продукту), так і якісно (низька, висока). Підвищення енергоефективності досягається завдяки реалізації системи цілеспрямованих організаційних і технічних заходів.

Проблема підвищення енергоефективності тісно пов'язана з прогнозуванням споживання енергоресурсів, яке повинно бути своєчасним і надійним. Результати прогнозування є основою для формування ефективних управлінських рішень. Розроблення засобів прогнозування передбачає накопичення інформації, аналіз, виявлення закономірностей та тенденцій. Результатами прогнозування енергоефективності можна використовувати для передбачення нових ситуацій та проблем, які потребують свого вирішення. Окрім цього, на їх основі здійснюється планування розвитку енергетичного господарства підприємств. Прогнозування і планування споживання енергоресурсів тісно пов'язані та мають спільні риси. Прогноз забезпечує виявлення закономірностей і тенденцій споживання енергоресурсів, а план визначає необхідні заходи для досягнення встановлених завдань. Якщо внаслідок прогнозу виявляються нега-

тивні тенденції, то у плані визначаються заходи для їх нейтралізації.

Для перевірки точності прогнозу споживання енергоресурсів доцільно застосувати ретроспективний метод, тобто здійснювати прогноз за даними минулого періоду, а потім порівняти одержані результати з фактичними. Найчастіше таке порівняння проводять за величиною середньої квадратичної похибки або середньої похибки апроксимації. Якщо результати порівняння задовольняють заданому критерію точності, то засоби прогнозування можна рекомендувати для виконання прогнозів.

Сьогодні сфера енергоефективності потребує контролю з боку людини, проте велика кількість чинників, які впливають на показники, не дає змоги ефективно і точно опрацьовувати отримані дані. Частково це можуть виконати експертні системи. Проте тут потрібен механізм, який буде володіти великою відмовостійкістю і вміти знаходити приховані закономірності в даних.

Є категорії проблем, які не можна сформулювати як алгоритм, проблеми, які залежать від багатьох тонких чинників, які мозок може (приблизно) розрахувати. Нейронна мережа є нелінійною системою, що дає змогу набагато краще класифікувати дані, ніж будь-які лінійні методи. Система на основі такого потужного механізму буде здатна отримувати результат, засновуючись на

Інформація про авторів:

Карпа Дмитро Михайлович, аспірант, кафедра АСУ. Email: dmytrokarpa@gmail.com

Цмоць Іван Григорович, д-р техн. наук, професор, завідувач кафедри автоматизованих систем управління.

Email: ivan.tsmots@gmail.com

Опотяк Юрій Володимирович, канд. техн. наук, ст. наук. співробітник, кафедра АСУ. Email: yuvoua@yahoo.com

Цитування за ДСТУ: Карпа Д. М., Цмоць І. Г., Опотяк Ю. В. Нейромережові засоби прогнозування споживання енергоресурсів.

Науковий вісник НЛТУ України. 2018, т. 28, № 5. С. 140–146.

Citation APA: Karpa, D. M., Tsmots, I. H., & Opotiak, Yu. V. (2018). Neural network tools for forecasting energy consumption. *Scientific Bulletin of UNFU*, 28(5), 140–146. <https://doi.org/10.15421/40280529>

прихованих закономірностях. Найважливішою перевагою такої системи і відсутність необхідності її програмування – нейронна мережа "навчається" на основі величезної навчальної вибірки, що відрізняє її від експертної системи.

У роботі досліджено використання нейромережових структур для прогнозування та виявлення аномальних значень показників енергоспоживання (газ, вода, електроенергія тощо). Також розглянуто підвищення швидкодії під час навчання та видавання результату навченою мережею користувачу. Метою є розроблення архітектури та імплементації компоненту системи управління енергоефективністю регіону на основі нейронної мережі, знаходження оптимальної структури мережі та алгоритму навчання.

Отже, використання штучних нейронних мереж мотивується їхньою подібністю до успішно функціонуючих біологічних систем, які працюють у широкому масштабі паралельно і (що, ймовірно, є одним із найбільш важливих аспектів) мають можливість вчитися. Одним із результатів процедури навчання є здатність нейронних мереж узагальнювати і асоціювати дані. Після успішного навчання нейронної мережі можна знайти адекватні рішення для аналогічних завдань одного і того ж класу, що не були очевидно визначені в процесі навчання. Це призводить до високого ступеня відмовостійкості за зміни вхідних даних. Прогнозування за допомогою нейронних мереж можна використовувати для пошуку аномальних значень або значень, які значно виділяються з потоку статистики.

Аналіз останніх досліджень та публікацій. Концепцію нейронних мереж запропоновано ще в середині минулого століття, проте саме зараз, з огляду на зростання продуктивності обчислювальних засобів, вони набули великої популярності. У роботах (Adams, 2017; Galushkin, 2000) викладено методику синтезу багатопшарових нейромереж різної структури: з повними і неповними послідовними зв'язками, перехресними і зворотними зв'язками, що функціонують у режимах навчання, самонавчання, навчання з учителем. Наведено етапи дослідження надійності та діагностики нейронних мереж. У роботі (Khaikin, 2006) розглядають основні парадигми штучних нейронних мереж та міститься математичне обґрунтування всіх нейромережових парадигм, що ілюструють прикладами, описом комп'ютерних експериментів, містяться практичні завдання, а також велика бібліографія. Аналізують роль нейронних мереж під час розв'язання задач, щодо розпізнавання образів, управління і оброблення сигналів. Роботи (Goodfellow, 2016; Pukach, et al., 2011; Shankar, 2016; Kruglov & Borisov, 2001; Christopher, 2005) стосуються одного з сучасних напрямів у галузі інформатики та обчислювальної техніки – нейрокомп'ютерних технологій. Розглянуто не тільки питання теорії штучних нейронних мереж, але й сучасні програмні емулятори нейронних мереж та вирішення з їх допомогою практичних завдань розпізнавання образів, кластеризації, прогнозування, оптимізації, побудови і використання нейромережових експертних систем.

Мета та задачі дослідження. Мета роботи – розроблення структури та архітектури нейронної мережі для задач прогнозування та аналізу статистичних даних енергоефективності для застосування як на рівні окремих установ, підрозділів, так і регіону.

Для досягнення мети необхідно вирішити такі задачі:

- розробити архітектуру нейронної мережі;
- розробити модуль навчання нейронної мережі для задач безперервного навчання у реальності;
- розробити архітектуру бази даних для задач навчання нейронної мережі.

Основні результати дослідження. Найважливішою властивістю нейронних мереж є їх здатність "навчатися" на основі даних, що описують об'єкти навколишнього середовища. Навчання нейронної мережі відбувається способом інтерактивного процесу коректування синаптичних ваг і порогів. В ідеальному випадку, нейронна мережа навчається взаємозв'язкам, що містяться у навчальних даних на кожній ітерації процесу навчання. Першим кроком побудови системи з використанням нейронних мереж є вибір архітектури. Архітектуру завжди підбирають експериментально, базуючись на технічному завданні. Для запропонованої системи було обрано нейронну мережу прямого поширення (рис. 1).




Рис. 1. Повнозв'язна нейронна мережа прямого поширення для вирішення задач прогнозування

Основним завданням нейронної мережі в запропонованій системі є прогнозування. На вхід нейронної мережі подають значення показників попередніх днів. На виході отримуємо значення показника на наступний день. Архітектура нейронної мережі є повнозв'язною. Кількість прихованих шарів також підбираємо експериментально. Чим більша їх кількість – тим точніший результат, проте тривалість навчання буде зростати. Прогнозоване значення у системі порівнюємо з реальним. Отримане реальне значення записуємо в базу даних і система проходить ще одну ітерацію навчання з деяким зсувом значень за днями (рис. 2).



Рис. 2. Зсув значень за днями для навчальної вибірки

Під час розв'язання реальних задач переважно одним з основних вимірів у процесі навчання є простір, а іншим – час. Просторово-часову структуру навчання підтверджують багатьма прикладами. Вважають, що біологічні види мають здатність представляти часову структуру власного досвіду. Таке представлення дає їм змогу адаптувати свою поведінку до часової структури подій у просторі. Якщо нейронна мережа працює у стаціонарному середовищі, то її, теоретично можна навчити статистичним характеристикам середовища за допомогою учителя. Наприклад, синаптичні ваги можна

прорахувати у процесі навчання для множини даних, які представляють середовище. Після завершення процесу навчання, синаптичні ваги відображають статистичну структуру середовища, яку з цього моменту вважають незмінною. Отже, для отримання і використання набутого досвіду, система спирається на певну форму пам'яті. Однак зазвичай навколишнє середовище є нестационарним, а отже, статистичні параметри вхідних сигналів, які генерує середовище, змінюються з часом. У таких випадках методи навчання з учителем непридатні, оскільки мережа не має змоги відстежувати варіації середовища. Отже, варто постійно адаптувати параметри мережі до варіацій вхідних даних у режимі реальності, а процес навчання в адаптивній системі не завершується, допоки надходять нові дані для оброблення. Такий процес називають неперервним навчанням. Алгоритм його зображено на рис. 3.

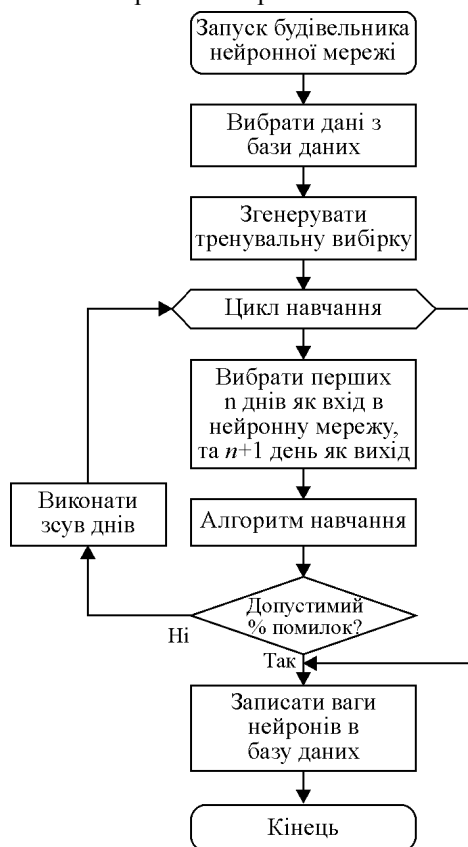


Рис. 3. Загальний алгоритм навчання системи на основі нейронної мережі

Перед застосуванням та навчанням нейронної мережі потрібно нормалізувати значення, що істотно пришвидшує процес навчання системи. Нормалізацію даних здійснюємо за формулою (1)

$$X'_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

Приклад нормалізованих даних наведено в таблиці.

Таблиця. Приклад нормалізованих даних

Параметр	Значення показника	Нормалізоване значення
День 1	60	0,0171
День 2	1	0,0003
День 3	1,8	0,0005
День 4	75	0,0214
День 5	28	0,0893

Отже, система оперує значеннями в межах від 0 до 1, що дає змогу використати сигмоїдальну функцію

(формула 2) як функцію активації нейронної мережі (рис. 4):

$$\phi(u) = \frac{1}{1 + \exp(-au)} \quad (2)$$

Отже, дані на виході нейронної мережі денормалізуються за зворотною формулою.




Рис. 4. Сигмоїдальна функція для системи прогнозування на основі нейронної мережі

Структуру таблиці, в якій зберігатиметься вага нейрона, зображено на рис. 5. Важливо, що разом із вагами зберігається номер прихованого шару і порядковий індекс нейрона для того, щоб для зчитування цих даних їх можна було зберігати у вигляді словника. Це дає змогу звертатись до даних безпосередньо без необхідності перебору всього масиву.

Column Name	Data Type	Allow Nulls
WeightID	int	<input type="checkbox"/>
InputLayerIndex	int	<input type="checkbox"/>
OutputLayerIndex	int	<input type="checkbox"/>
InputNeuronIndex	int	<input type="checkbox"/>
OutputNeuronIndex	int	<input type="checkbox"/>
WeightValue	float	<input type="checkbox"/>

Рис. 5. Структура таблиці даних для збереження ваг нейронів

Структуру нейрона вибрано такою, щоб один із входів був статичний, який дорівнює 1. Він замінює роль порогу нейрона (рис. 6).




Рис. 6. Модель нейрона в системі прогнозування

У процесі навчання вага нейрона зберігається в оперативній пам'яті, що зроблено для збільшення швидкодії. Після завершення навчання нейронної мережі, ваги нейронів записують у базу даних і надалі їх будуть завантажувати вже зі бази даних. Використаний алгоритм дає змогу прогнозувати дані з заданою точністю. Кількість прихованих шарів нейронної мережі визначає те, наскільки точним буде результат, проте процес навчання буде тривалішим під час їх зростання. Зазвичай цю кількість підбирають експериментально.

Вибір архітектури нейронної мережі залежить від поставленого завдання. Багатошарові перцептрони успішно використовують для вирішення складних завдань. Навчання з учителем здійснюється за допомогою такого популярного алгоритму, як алгоритм зворотного поширення похибки. Цей алгоритм заснований на корекції помилок та можна використати як узагальнення популярного алгоритму мінімізації середньоквадратичної помилки.

Для розв'язання задачі прогнозування було розроблено програмний комплекс на мові C#, основним елементом якого є нейронна мережа. Вибір архітектури мережі базується на типі прогнозування. Оскільки в нашому випадку є короткострокове прогнозування, було

вибрано мережу прямого поширення похибки з кількістю входів, що дорівнює п'яти. Ваги нейронів мережі зберігаються у базі даних MS SQL. Для доступу до даних використовують технологію ADO.NET, оскільки необхідно забезпечити максимальну швидкодію.

Для прогнозування динаміки показника енергоспоживання будівлі, експериментальним способом було визначено оптимальну структуру нейронної мережі: 5 входів, які будуть відповідати показникам параметра за попередні 5 днів, та два прихованих шари по 5 нейронів у кожному. На рис. 7 зображено реальні дані споживання електроенергії в одній з будівель району, отримані впродовж місяця. Ці дані є взірцевим показником і використовували їх для навчання нейронної мережі.




Рис. 7. Дані, отримані за показами лічильника електроенергії




Рис. 8. Дані, отримані способом прогнозування нейронною мережею

Дані, отримані способом прогнозування з використанням застосованої нейронної мережі, зображено на

рис. 8. Нейронну мережу варто навчати з використанням даних споживання для кожної будівлі окремо, що

пов'язано з її специфікою – площа, особливості виробничої діяльності, робочі дні, кількість працівників тощо. Однак структура мережі буде абсолютно ідентичною, а для врахування цієї специфіки потрібно зберегти синаптичні ваги навченої мережі для зазначеної будівлі.

Цю архітектуру можна адаптувати, наприклад, для прогнозування споживання електроенергії, визначення енергоефективності окремого району (міста), виконавши її навчання на відповідних масивах даних, і цей процес можна легко автоматизувати.

Прогнозування з використанням нейронної мережі має достатню точність для виявлення аномальних показників (рис. 9). Виявлення аномалій за допомогою

нейронних мереж можливе, оскільки мережа "вміє" враховувати зміни показників, коли це не є аномалією (наприклад, зменшення використання енергоносія весною). Експертна система "визнала" б таке зменшення показників аномалією, проте нейронна мережа, яка навчена на показниках минулих періодів, "знатиме", що це очікуваний результат. Тому виявлення аномалій зводиться до того, що система повинна виявляти великі розбіжності між прогнозованим і реальним показниками, причому розбіжність повинна бути не випадковою, а проявлятися протягом певного періоду. На рис. 9 виявлені аномальні показники позначено іншим кольором.




Рис. 9. Виявлення аномальних показників даних за допомогою прогнозування нейронною мережею

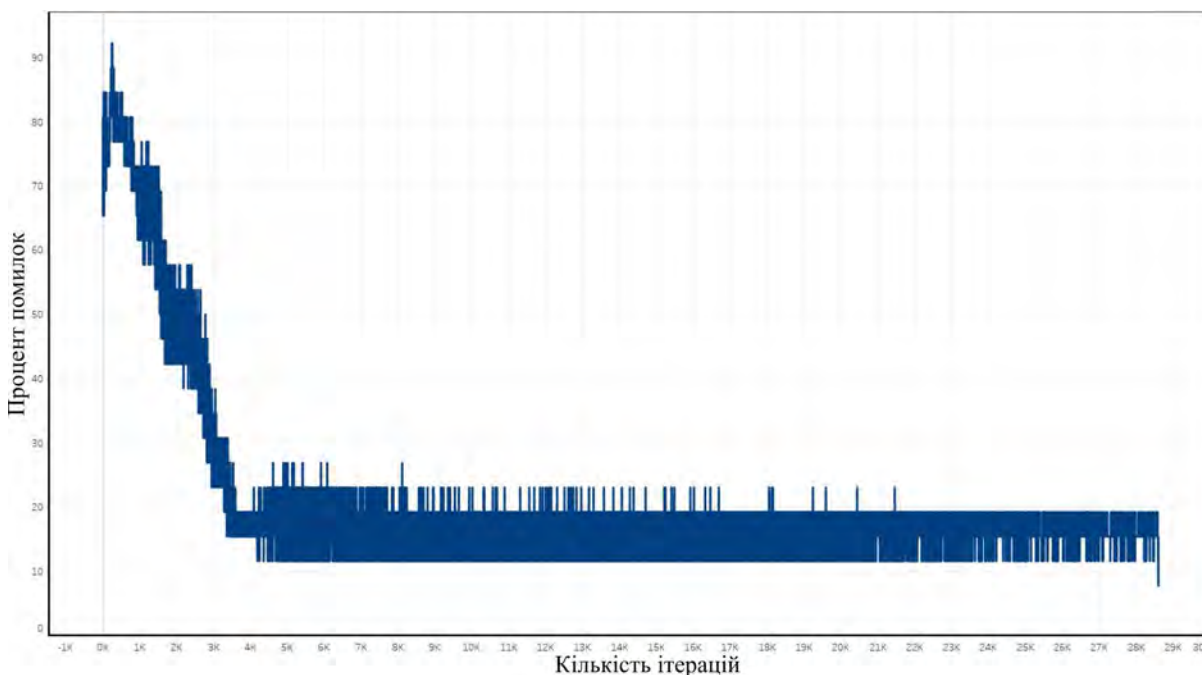


Рис. 10. Процес навчання нейронної мережі

Продуктивність та точність функціонування нейронної мережі залежить від її структури та часу навчання. На рис. 10 зображено зміну рівня похибок у процесі

навчання нейронної мережі. Зупинка навчання відбувається під час досягнення допустимої кількості помилок. Як показали експерименти, достатньо точних ре-

зультатів можна досягти в середньому після 20–30 тис. ітерацій. Це є відомим недоліком нейронних мереж. Проте, для вже навченої нейронної мережі, час опрацювання нових даних відбувається за декілька ітерацій.

Розробка і навчання нейронної мережі є надзвичайно затратною щодо обчислювальних ресурсів, а перенавчання мережі за кожної зміни середовища є марним їх витрачанням. Окрім цього, під час навчання нейронної мережі існує проблема її "перенасичення". Якщо нейронна мережа буде навчатися на великих обсягах нових даних, то вона втратить свою чутливість і буде поводитися себе неадекватно до даних, яких не було у тренувальному наборі.

Для усунення цього недоліку застосовано адаптивне навчання. У разі надходження нового навчального вектора, система повинна визначити окіл найближчих векторів поруч із новим, відстань між векторами визначається евклідовою відстанню. Після цього визначається вектор, який знаходиться найдалше в цьому колі. Цей вектор буде видалено в майбутньому. Після цього нейронна мережа може дозвичитись з оновленим набором зразків. Як показали проведені експерименти, незалежно від застосованої архітектури нейронної мережі та розміру навчальної вибірки, проведення однієї епохи навчання відбувається досить швидко. Внаслідок цієї процедури нейронна мережа буде адекватно реагувати на зміни навколишнього середовища і не доведеться перенавчати систему знову.

Висновки:

1. Розроблено архітектуру нейронної мережі та підхід до безперервного навчання в реальності, який дає змогу підтримувати систему в ідеальному стані.
2. Розроблено архітектуру системи на основі нейронної мережі. Архітектура включає серверну частину системи, реалізовану у вигляді Web API. Реалізовано роботу з елементами нейронної мережі за допомогою хеш-таблиці для збільшення швидкодії системи.

3. Розроблено архітектуру бази даних, яка включає таблиці для збереження параметрів навченої нейронної мережі та таблиці для зберігання прогнозованих даних.

Описаний алгоритм адаптації нейронної мережі дає змогу ввести часові властивості даних в її архітектуру, реалізуючи в такий спосіб принцип неперервного навчання на впорядкованих у часі даних. Під час використання такого підходу нейронну мережу можна вважати нелінійним адаптивним фільтром, що є узагальненням лінійного адаптивного фільтру. Однак для реалізації такого динамічного підходу, необхідні значні обчислювальні ресурси, щоб дати змогу виконувати всі необхідні розрахунки в реальності за один інтервал дискретизації даних. Для розв'язання задач енергоефективності та застосованих даних, коли темп їх надходження невеликий, таку вимогу виконують, що свідчить про доцільність застосування запропонованого підходу.

Перелік використаних джерел

- Adams, T. (2017). *Training an artificial neural network*. Retrieved from: <https://www.solver.com/training-artificial-neural-networkintro>.
- Christopher, M. Bishop. (2005). *Neural Networks for Pattern Recognition* (Advanced Texts in Econometrics (Paperback)), Clarendon Press, 205–215 pp.
- Galushkin, A. I. (2000). *Teoriia neuronnykh setei*. Moscow: IPRZhR. 415 p. [In Russian].
- Goodfellow, I. (2016). *Deep Learning* (Adaptive Computation and Machine Learning series), 230–245, MA: MIT Press.
- Khaikin, S. (2006). *Neironnie seti. Polnui kyrs*. Moscow: Williams. 1104 p. [In Russian].
- Kruglov, V. V., & Borisov, V. V. (2001). *Iskusstvennye neuronnye seti: teoriia i praktika*. Moscow: Goriachaia liniia-Telekom. 382 p. [In Russian].
- Pukach, A. I., Teslyuk, V. M., Tkachenko, R. O., & Ivantsiv, R.-A. D. (2011). "Implementation of neural networks for fuzzy and semi-structured data," in Proceedings of 11-th International Conference on The Experience of Designing and Application of CAD Systems in Microelectronics, CADSM, Lviv – Polyana, Ukraine, 350–352.
- Shankar, R. (2016). *Neural Networks*. MA: MIT Press. 124–132 pp.

Д. М. Карпа, И. Г. Цмоць, Ю. В. Опотяк

Национальный университет "Львовская политехника", г. Львов, Украина

НЕЙРОСЕТЕВЫЕ СРЕДСТВА ДЛЯ ПРОГНОЗИРОВАНИЯ ПОТРЕБЛЕНИЯ ЭНЕРГОРЕСУРСОВ

Исследован и обоснован выбор нейросетевых структур для обработки статистических данных, с целью прогнозирования и выявления аномальных показателей потребления энергоресурсов. Показано, что системам на основе нейронных сетей всегда противопоставлялись экспертные системы, которые в отличие от первых, явно программировались. Среда, в которой работает система, не всегда является статичной, и нужны методы обработки данных, которые могли бы адекватно реагировать на изменение среды и уметь соответственно адаптировать получаемые результаты. Нейронные сети обладают такой особенностью, как умение учиться. Эта особенность и является основным аргументом для применения таких структур в системах управления энергоэффективностью. Разработанная архитектура сети и применённый процесс обучения дал возможность прогнозировать показатели потребленной электроэнергии с учетом многих параметров. Особенностью разработанной архитектуры является возможность осуществлять переобучение в процессе функционирования, не прерывая его. Использование адаптивного и непрерывного обучения нейросети позволит выявлять аномальные показатели данных. Точность такого обнаружения было проверено на реальной выборке данных. Анализ полученных результатов показывает, что использование нейронных сетей хоть и требует быстрейшего и времени на обучение, однако, при классификации входного вектора, быстрейшее нейронной сети превышает любой алгоритм кластеризации.

Ключевые слова: нейронная сеть; машинное обучение; многослойный персептрон; статистические данные; нормализация данных; прогнозирование; выявление аномалий.

Д. М. Карпа, I. H. Tsmots, Yu. V. Opotiak

Lviv Polytechnic National University, Lviv, Ukraine

NEURAL NETWORK TOOLS FOR FORECASTING ENERGY CONSUMPTION

The authors in the article present the idea of creating the architecture of the component of the energy efficiency management system. The main idea is to use neural network architectures. For energy efficiency systems, an important task that the neural network can solve is the task of forecasting and detecting abnormal values in the flow of statistical data. Implementation of systems based on neural networks has always been very complicated and expensive, that is why so-called expert systems have been their

main rival. They, unlike neural networks, that in fact were self-taught, were programmed. Unfortunately, not so many systems based on neural networks entered our daily lives. A neural network is an example of a nonlinear system, it allows much better categorize data than any linear methods. The system is based on this powerful mechanism able to make decision based on hidden regularity. The most important advantage of such system is that it is not programmed; a neural network is a mechanism that learns from the huge training set. This differs them from any of the expert system. Not the latest requirement for systems based on neural networks is the requirement of well performance. The neural network is a component that always responds quickly enough, but the learning process takes a lot of time. Therefore, it is very important to choose the right architecture for the network and technologies that the system uses. Another advantage of the proposed forecasting system is also the possibility of continuous learning. Continuous learning provides the system with such a feature as fault tolerance and adaptability. Thus, the system will not lose its relevance over time. Ultimately, the proposed adaptive learning algorithm will help overcome the excessive saturation of the neural network. The analysis of the results shows that the use of neural networks requires computer speed and time to study, however, in the classification of the input vector, the performance of the neural network exceeds any algorithm of clustering. The built-in software allows you to detect hidden patterns in a large number of statistical data and to greatly help in solving data processing problems.

Keywords: neural network; machine learning; multilayer perceptron; statistical data; data normalization; forecasting; the detection of anomalies.