

Т.В. Іваницька

НЕЙРОННІ МЕРЕЖІ ДЛЯ КОНТРОЛЮ ТА УПРАВЛІННЯ В ЕЛЕКТРОЕНЕРГЕТИЦІ

Стаття присвячена дослідженю можливостей застосування нових типів нейронних класифікаторів в задачах електроенергетики. На прикладі використання RTC-класифікатора розглянута можливість розв'язку задач прогнозування. Оговорені питання навчання класифікатора і представлення вхідної інформації. Показано, що RTC-класифікатор може бути успішно використаний в задачах прогнозування.

Ідея побудови штучних нейронних мереж, здатних імітувати роботу мозку, вперше була висловлена в роботі Мак-Калюка та Піттса понад півсторіччя тому [14]. Протягом 50-рр., завдяки роботам таких вчених, як Н. Вінер [1], Д. Хебб [12], Р. Ешбі [10] та багатьох інших, ця ідея перетворюється на актуальну міждисциплінарну наукову проблему, до вирішення якої залучаються значні сили математиків, кібернетиків, фізіологів та психологів [19]. Перші діючі моделі нейронних мереж були створені вже наприкінці 50-х – початку 60-х років. До них належали перцептрон Ф. Розенблата [16], система "Альфа" О. Івахненко [2], "Адалін" В. Уідроу [20].

Створення перцептрона та демонстрація його здатності до навчання шляхом поступової корекції ваги синаптичних зв'язків відповідно до оцінки реакції на вихіді мало значний вплив на розвиток досліджень в цій галузі. Однак після перших велими успішних експериментів стало очевидним, що простий перцептрон з одним шаром асоціативних нейронів здатен розпізнавати лише лінійно розграничимі сукупності стимулів, і це обмежує можливості його практичного використання. Ф. Розенблатом було показано, що цей недолік можна подолати в мережах з перехресними зв'язками між нейронами одного шару та в багатошарових системах [8]. Але тоді для них не були відомі такі ж ефективні методи навчання, як і для найпростішого перцептрона.

Треба відзначити, що хоч перші нейрокомп'ютери створювались без достатнього теоретичного обґрунтування, вони демонстрували дивовижну здатність до самоорганізації, що тоді сприймалось як виклик іншим моделям штучного інтелекту, побудованим на засадах класичної логіки. На початку 70-х рр. адепти класичної школи скористалися виявленими недоліками простішого перцептрона для дискредитації розробок в галузі штучних нейромереж [5].

Протягом наступного десятиліття дослідження в цій галузі були значно скорочені. Головним досягненням цього періоду можна вважати математичне обґрунтування методів ітеративного навчання нейромереж і розробку методу зворотного поширення похибки back propagation, що відкрив шлях для розробки і практичного застосування складних нейромереж типу багатошарових перцептронів [17]. Аналогічний ітеративний метод навчання на основі потенційного стимулювання нейронів ще раніше було запропоновано і використано Українськими вченими в роботах [6, 7], але ці результати не мали відповідного розголосу.

Наприкінці 80-х рр. в США, країнах ЄС та Японії були розгорнуті багатомільйонні державні програми, метою яких було створення до 1995 р. дослідних зразків та налагодження до 2000 р. промислового виробництва нейрокомп'ютерів та розробку нових поколінь ЕОМ на їх основі. Зараз дослідження в галузі нейрокомп'ютерів охоплюють практично всі сторони проблеми їх створення та виробництва. З'явилось спеціальне поняття нейротехнології, що охоплює комплекс питань впровадження та практичного використання нейрокомп'ютерів.

Існує велика різноманітність типів нейрокомп'ютерів – від спеціалізованих інтегральних схем, в які вводиться раніше визначена структура нейронної мережі, до універсальних програмованих сопроцесорів до обчислювальних машин, на яких можна реалізувати будь-яку модель нейронної мережі. Існує також цілий ряд проміжних типів нейрокомп'ютерів з тим чи іншим ступенем спеціалізації.

На нейрокомп'ютерах доцільно вирішувати задачі, в яких обчислювальні машини поступаються людському мозку.

Нейроподібні структури дають можливість по-новому підійти до вирішення цілого ряду задач, які вважаються традиційно складними для обчислювальних машин завдяки ряду своїх особливостей [3]. Наведемо деякі з них.

1. Паралельність обробки інформації. Даним процесом дослідники цікавились протягом всієї історії розвитку електронної обчислювальної техніки, створена велика кількість обчислювальних засобів, які дозволяють розпаралелювати рішення задач. Досвід роботи з такими пристроями пока-

зує, що хороші результати отримуються в тих випадках, коли дані, що обробляються, мають однорідну структуру (вектори, матриці та ін.), але спроби застосування їх для вирішення задач штучного інтелекту наштовхуються на великі труднощі. Нейроподібні структури дають можливість організувати дані у вигляді однорідних масивів та застосувати методи розпаралелювання, ала при цьому вони дають нові можливості пошуку інформації, яка зберігається в цих структурах, що дозволяє надіятись на нові підходи до вирішення задач штучного інтелекту.

2. Асоціативність. Це властивість нейроподібних структур відновлювати інформацію, яка в них зберігається, за її частиною. Подібну властивість намагались відтворити на всіх етапах розвитку обчислювальної техніки, але в переважній кількості випадків запропоновані асоціативні обладнання здійснюють пошук інформації за раніше виділеною її частиною (за ключем). Асоціативність нейроподібних структур відрізняється від асоціативності більшості інших типів технічних пристройів можливістю відтворення інформації за будь-якою її частиною.

3. Здатність до автоматичної класифікації. В обчислювальній техніці дакій властивості приділялась велика увага. Розроблені різноманітні автоматичні класифікатори та класифікаційні програми, які реалізуються на універсальних ЕОМ. Особливістю нейроподібних структур є те, що здатність до автоматичної класифікації внутрішне присутня багатьом таким структурам, та для її реалізації не потрібно вжити додаткових засобів.

4. Здатність до навчання. В процесі навчання нейроподібні структури здатні перебудовуватись для вирішення різноманітних задач. Більшість програм в тій чи іншій мірі такою здатністюолодіють, але в цілому основним способом підготовки обчислювальної техніки до вирішення нової задачі залишається створення нової програми, а основним способом підготовки нейроподібних структур до вирішення нових задач є навчання. В цьому між нейроподібними структурами та обчислювальними машинами немає принципової різниці, мова йде скоріше про кількісні співвідношення витрат, необхідних при розробці нових програм та параметричні настройці їх на задачі, що вирішуються. Однак потрібно мати на увазі, що в нейроподібних мережах під "програмою" розуміється початкова структура (яка вводиться виробником до початку навчання нейроподібної мережі), початкові значення параметрів та алгоритми функціонування різноманітних блоків нейроподібної мережі. Це поняття не зовсім точно відповідає поняттю програми в обчислювальній машині. Спільність їх заключається в тому, що в обох випадках виробник, використовуючи своє уявлення про задачу, підготовлює пристрій для її вирішення, а до пред'явлення прикладів, на яких будеться процес навчання, звертається лише після створення самої програми.

5. Надійність. Нейроподібні структури працюють з високою надійністю. Експерименти, проведені на обчислювальних машинах, показують, що вихід зі строю великої кількості елементів нейроподібної мережі (до 10 %, а іноді і більше) не призводить до збою в роботі всієї структури. Потрібно відмітити, що хоча джерело високої надійності нейроподібних структур звичайне – дублювання елементів, на відміну від традиційних схем дублювання воно не приводить до надмірних витрат апаратури, оскільки в нейроподібних структурах кожний елемент бере участь в реалізації багатьох функцій, що дозволяє при високому ступеню дублювання економно використовувати робочі елементи. Відказ кожного елемента в нейроподібній структурі веде до погіршення багатьох функцій, але це погіршення настільки незначне, що його, як правило, практично неможливо виявити.

Перераховані властивості приваблюють до нейроподібних структур.

Нині склалися сприятливі умови для розвитку робіт по нейроподібних структурах та нейрокомп'ютерах. Вибираючи конкретні напрямлення робіт, дуже важливо правильно оцінити ситуацію та свої реальні можливості. Зарубіжні дослідники, розробляючи універсальні пристрой для моделювання найрізноманітніших нейронних мереж, роблять ставку на високий рівень електронної технології, яка дозволяє реалізувати високовиробничі паралельні пристрої, але наша елементна база не залишає шансів на успішну конкуренцію в цій області. Тому доцільно вибрати конкретний тип нейроподібної мережі та розробити для нього спеціалізований обчислювальний пристрій, компенсуючи нестачу елементної бази високим рівнем спеціалізації. При цьому є ризик сильно звузити коло задач, які зможе вирішувати цей пристрій. На щастя, існують нейроподібні структури, які володіють великою універсальністю, і реалізація спеціалізованого пристроя для них дозволяє орієнтувати пристрій для вирішення широкого кола задач, зберігши переваги спеціалізації. Цей шлях дає можливість розробляти конкурентоздатні пристрой навіть на слабкій елементній базі.

Аналіз стану та управління об'єктами електроенергетики відносяться до проблем, вирішення яких традиційними методами потребують побудови важких математичних моделей, які б описували поведінку певнійніх об'єктів. Більшість задач управління електроенергосистемами являють собою важко придатні для формалізації проблеми, що пов'язані не тільки з складним ха-

рактером залежності поведінки системи від стану її компонент, але часто і просто з неповною або неточною інформацією про стан системи. Побудова точних моделей таких систем практично неможлива. Реально управління та аналіз стану електроенергосистем проводиться за допомогою спрощених, частіше лінійних моделей. В деяких випадках моделі поведінки електроенергосистем враховують статистичні дані роботи об'єкта. В результаті управління та оцінка стану об'єкта здійснюються із запізненням і можуть мати велику похибку.

Нині в області контролю та управління в електроенергетиці все частіше використовують алгоритми на базі нейронних мереж [11, 15, 18, 21]. Використання нейронних мереж в обговорюваних задачах обумовлено їх перевагами порівняно з класичними адаптивними методами:

- не потрібна побудова моделі об'єкта;
- роботоздатність мережі при неповній вхідній інформації;
- стійкість до перешкод.

Перераховані якості забезпечуються властивостями нейронних мереж.

Значний інтерес представляє пошук перспективних нейромережевих структур, спроможних працювати з великим числом вхідних параметрів та, за рахунок навчання, з заданою точністю описувати процеси в нелінійних розподільчих системах.

Для розпізнавання стану та прогнозу поведінки складних нелінійних систем з великим числом вхідних параметрів може використовуватись класифікатор на базі нейронних мереж з випадковими порогами RTC (Random Threshold Classifier) [4, 21], розроблений у відділі мережевих систем керування Інституту кібернетики НАН України. Перефарбою цього класифікатора в порівнянні з класифікаторами на основі методу зворотного поширення похибки (back propagation) є висока швидкість навчання та роботи. Модифікація RTC-класифікатора відповідає вимогам до алгоритмів для задач прогнозу. RTC-класифікатор дозволяє отримати взаємозалежності виходу від входів за рахунок навчання перцептронної частини і вводить ознаки різної природи та метрики за рахунок способу перетворення вхідного ознакового простору.

Складність аналізу стану електроенергосистеми полягає в тому, що на її поведінку впливають як підлягаючі обліку фактори, типу генеруючих потужностей або режиму роботи споживачів, так і не підлягаючі точній оцінці, типу погодних умов. Крім того, в системах часто відсутні деякі величини (показники датчиків та ін.). Аналіз роботи енергосистеми потребує вирішення задач, багато з яких погано алгоритмізуються, але можуть бути успішно вирішені нейронними мережами. До таких задач відносяться задачі прогнозу перетоків потужності між енергосистемами, оцінки неконтрольованих параметрів за відомими параметрами в системі, добовий графік навантажень та ін. Більшість цих задач за своїм характером відносяться до задач упереджуючого прогнозу за поточним станом об'єкта.

Для успішної роботи мережі повинна бути проведена попередня обробка вхідної інформації. Необхідність попередньої обробки вхідної інформації пов'язана з нестабільною роботою контрольної та вимірювальної апаратури. Зокрема, при настройці нейронного класифікатора (НК) повинна бути підготовлена навчаюча послідовність, яка завідомо не має суттєвих помилок вимірювання, типу відказу конкретного датчика або збою в системі збору інформації. Крім того, від розмірів навчаючої послідовності залежить точність настройки НК, тому з усього доступного об'єму інформації вибираються всі дані, які явно не протирічать можливому стану системи.

Для вирішення задач контролю та управління в електроенергетиці, зокрема, задачі коротко-часного прогнозу міжсистемного перетоку потужності, використовується НК, який відповідає наступним вимогам:

- велике число вхідних параметрів (в ідеалі – довільне);
- реальний час навчання на великих послідовностях;
- висока швидкість роботи (розпізнавання в реальному часі);
- можливість отримання результату з потрібною точністю.

Як вказувалось вище, цим вимогам відповідає RTC-класифікатор (або класифікатор з випадковими порогами).

Модифікація RTC-класифікатора відповідає вимогам до алгоритмів для задач прогнозу. RTC-класифікатор дозволяє отримати взаємозалежності виходу від входів за рахунок навчання перцептронної частини і вводить ознаки різної природи та метрики за рахунок способу перетворення вхідного ознакового простору.

RTC- класифікатор складається з двох функціональних частин, в одній з яких створюється перетворення вхідного ознакового простору в простір більшої розмірності, а друга представлє собою перцепtron [9], навчаючі зв'язки якого дозволяють настроювати вихідну функцію в залежності від конкретних параметрів процесу.

Введемо визначення, якими будемо користуватись при описанні роботи класифікатора (див. рис. 1). $F(i)$ – вхідний вектор з компонентами f_1, \dots, f_i . Представляє собою деякий вхідний “образ”, підлягаючий класифікації, де складаючі вектор компоненти можна розглядати як ознаки даного “образу”. **Box** – блок, який призначається для перетворення початкового простору, в якому визначені вектори $F(i)$ в новий простір значно більшого розміру. Кожний блок відповідає одній координаті нового простору, розмірність якого J задається споживачем. b_j – для простоти будемо називати цей елемент нейроном шару В – показує результат перетворення вхідного вектора для даного **Box**. Може приймати значення “0” або “1”. a_i – проміжні елементи, будемо називати їх нейронами шару А. h_{ij} і l_{ij} – верхній та нижній пороги відповідно. Це випадкові числа, які визначаються заздалегідь і відповідають умові $l_{ij} < h_{ij}$ та лежать в діапазоні зміни даної ознаки. Ці числа не повторюються як всередині **Box**, так і для інших **Box**-ів. Блок вихідних сум **S** та вихідного нормування **Out** призначені для формування виходу.

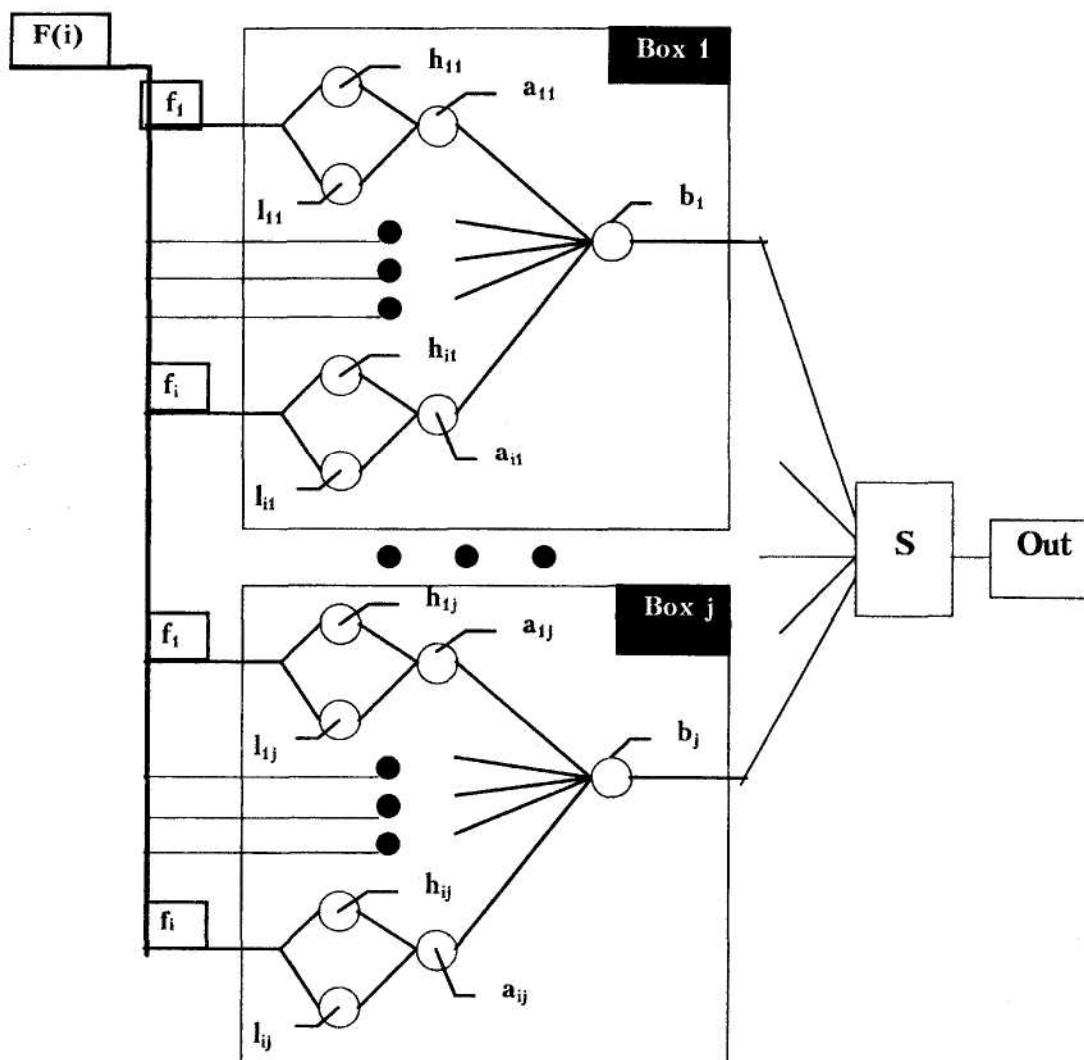


Рис. 1. Загальна схема алгоритму RTC-klassifікатора

Пороги I та h формуються за допомогою двох наборів випадкових чисел m і d , де m – випадкове число, з щільністю ймовірності рівномірно розподіленої в інтервалі зміни вхідної ознаки, а d – випадкове число, яке задає діапазон для даного набору порогів. При цьому:

$$l = \max\{f \min ; m - kd\}; \quad h = \min\{m + kd; f \ max\}, \quad (1)$$

де k – коефіцієнт, який вибирається в залежності від кількості ознак вхідного простору та числа нейронів в шарі В, звичайно $k = 0,2 \div 0,5(f_{\max} - f_{\min})$.

Коефіцієнт вибирається таким, щоб після перетворення для будь-якої точки вхідного простору кількість ненульових нейронів n шару В було приблизно однаковим і близько до $0,1 \pm 0,5$.

Для детермінованих ознак типу вихідний або робочий день пороги можуть вводитися за звичайною схемою, тоді така ознака представляється числовово величиною в раніше обумовленому діапазоні значень, або безпосередньо як переключаюча функція, коли частина **Box**-ів реагує на відповідне значення ознаки. Другий спосіб представлення зручний, якщо ознаки цього типу 1–2. При великій кількості детермінованих ознак, а такими ознаками можуть служити різного роду експертні оцінки, необхідно користуватись першим способом представлення.

Вибір випадкових величин для первинного перетворення простору обумовлений тим, що точка вхідного простору кодується групою нейронів шару В, та в довільному багатомірному просторі досить важко визначити жорсткий алгоритм рівномірного розподілення **Box**-ів.

Перетворення вхідного простору проводиться наступним чином – в кожному **Box** виконується порівняння для всіх ознак з відповідними порогами та визначаються значення нейронів шару А за умовою:

$$a_i = \begin{cases} 1, & \text{якщо } l_i < f_i < h_i; \\ 0, & \text{інакше.} \end{cases} \quad (2)$$

Результатом порівняння всіх ознак в блоці є значення відповідного нейрону шару В, значення якого визначається за правилом:

$$b_j = \begin{cases} 1, & \text{якщо } \forall i \text{ виконується } a_{ij} = 1; \\ 0, & \text{інакше.} \end{cases} \quad (3)$$

Формування вихідної функції організовано як накопичення суми коефіцієнтів ваги зв'язку перцептрона від активних нейронів шару В та вихідного нормування.

$$S = \sum_j b_j W_j, \quad (4)$$

$$Out = f(S),$$

де W_j – коефіцієнт ваги зв'язку між нейронами B_j і S .

Функція $f(S)$ залежить від виду та метрики параметра, що прогнозується.

Зокрема, якщо параметр градуальний, наприклад, електрична потужність, ця функція може бути просто коефіцієнтом нормування, якщо прогнозується лише наявність вихідного параметру в наступний момент часу, то функція $f(S)$ буде пороговою.

Вхідне перетворення простору в простір більшого розміру дозволяє отримати в новому просторі умови, при яких різні стани процесу стають лінійно роздіlimими і групи нейронів шару В з ненульовими значеннями для поточного стану процесу, в ідеалі, однозначно визначають стан процесу. Наскільки близько до ідеального буде представлення процесу в класифікаторі залежить від декількох факторів. В першу чергу, це складність (кількість можливих станів) процесу, що прогнозується. По-друге, повнота та адекватність навчаючої послідовності процесу, що прогнозується, та, по-третє, точність прогнозу визначається кількістю та розташуванням **Box**-ів в просторі ознак, а також точністю настройки коефіцієнтів ваги зв'язків W_j .

Настройка класифікатора для вирішення конкретної задачі може проводитися в два етапи. Перший, не обов'язковий, настройка параметрів перетворення вхідного простору та другий – настройка коефіцієнтів ваги зв'язків W_j .

Настройка коефіцієнтів ваги зв'язків найбільш просто здійснюється наступним чином. Шляхом нормування представляємо діапазон зміни вихідної величини так, що вона змінюється з точністю до цілого. Для вихідної функції вводимо перетворення

$$Out = [S / n], \quad (5)$$

де $[\cdot]$ – ціла частина числа.

Тоді для навчаючої послідовності коефіцієнт ваги зв'язку вираховуються так, що

$$(Out - 0,5) \cdot n = \sum_j b_j W_j < (Out + 0,5) \cdot n. \quad (6)$$

Настройка коефіцієнтів ваги зв'язку може здійснюватися як прямим розрахунком, так і ітераційно шляхом додавання та віднімання констант до відповідних коефіцієнтів ваги зв'язку. Ітераційний процес настройки коефіцієнтів ваги зв'язку може служити для донавчання класифікатора в процесі роботи та як цільова функція (або її складова) при використанні алгоритмів генетичної оптимізації параметрів перетворення вхідного простору.

Попереднє тестування класифікатора для задач прогнозу на прикладі задачі короткочасного прогнозу перетоків потужності електроенергії в мережі Київенерго засвідчило, що застосування

такого типу класифікаторів не гірше, а в точках, де друга похідна вихідної функції не дорівнює нулю, значно точніше (до 50 %), ніж звичайні математичні методи короткосрочного прогнозу.

ЛІТЕРАТУРА:

1. Винер Н. Кибернетика. – М.: Сов. радио, 1968. – 90 с.
2. Ивахненко А.Г. Самонастраивающиеся системы с положительными обратными связями. – Киев: Изд-во АН УССР, 1963. – 392 с.
3. Куссуль Э.М. Ассоциативные нейроподобные структуры. – Киев: Наук. думка, 1992. – 144 с.
4. Куссуль Э.М., Байдык Т.Н. О кодировании информации в ассоциативно проективных нейронных сетях. – Киев, 1993. – 18 с. (Преп./АН Украины. Ин-т кибернетики им. В.М. Глушкова; 93-3).
5. Минский М., Пейперт С. Перцептроны. – М.: Мир, 1971. – 255 с.
6. Резник А.М. Обучение на нейронном уровне и спонтанная активность // Стат. электрофизиология, материалы симпозиума 12-18 авг. 1968, Паланга, ч.1. – Вильнюс: Изд. Вильнюс. гос. унів-та, 1968. – С. 481-496.
7. Резник А.М. Статистическая модель пластического нейрона // Проблемы нейрокибернетики: Материалы 2-й научн. конф. по нейрокибернетике, т. 2 – Ростов-на-Дону: Изд-во РГУ, 1966. – С. 198-203.
8. Розенблatt Ф. Принципы нейродинамики. – М.: Мир, 1965. – 480 с.
9. Розенблatt Ф. Принципы нейродинамики. Перцептроны и теория механизмов мозга. – М.: Мир, 1965. – 480 с.
10. Эшиби У.Р. Конструкция мозга. – М.: Изд-во иностр. лит., 1962. – 395 с.
11. Bakirtzis A.G., Theocharis J.B., Kiartzis S.J., Satsios K.J. Short Term Load Forecasting Using Fuzzy Neural Networks // IEEE Transactions on Power Systems, August, 1995.
12. Hebb D.O. The organization of the behavior. – N.-Y.: John Wiley, 1949. – 409 p.
13. Kussul E.M., Baidyk T.N., Lukovich V.V., Rachkovskij D.A. Adaptive High Performance Classifier Based on Random Threshold Neurons / Cybernetics and Systems'94, vol.II. World Scientific, 1994. – P. 1687-1694.
14. McCulloch W.S., Pitts W. A logical calculus of the ideas immanent in nervous activity // Bull & Math. Biophys, 1943. – № 5. – P. 115-133.
15. Mori H., Itou K., Uematsu H., Tsusuki S. An artifical neural-net based method for predicting power system voltage harmonics // IEEE Power Engineering Review. – 1991. – 12. № 1. – P. 61-62.
16. Rosenblatt F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain // Psychol. Rev. – 1958. – № 65. – P. 386-408.
17. Rumelhardt D.E., Hinton G.E., Williams R.I. Learning Internal Representations by Error Propagation // Parallel Distributed Processing: Explorations in the Microstructure of Cognition. -Cambridge, Mass.: MIT Press. – 1986. – V. 1. – P. 318-362.
18. Sasaki H., Watanabe M., Kubokawa J., Yorino N., Yokoyama R. Solution method of unit commitment by artificial neural networks. // IEEE Power Engineering Review. – 1992. – 12. № 8. – P. 36-37.
19. Self-organizing systems: Proc. of Interdisciplinary conf. 5 and 6 May, 1959. Ed. M. Yovits, S. Cameron. – Pergamon Press, 1960.
20. Widrow B. Adaptive sampled-data systems, a statistical theory of adaptation // IRE WESCON Conv. record. part 4. – N.-Y.: Inst. of Radio Engineers. – 1959.
21. Yuan-Yih Hsu, Chao-Rong Chen. Turning of power system stabilizers Using an artifical neural network // IEEE Power Engineering Review. – 1991. – 11. № 12. – P. 38-39.

ІВАНИЦЬКА Тетяна Володимирівна – науковий співробітник кафедри електричних станцій факультету електроенерготехніки та автоматики Національного технічного університету України “Київський політехнічний інститут”.

Наукові інтереси:

- нейронні мережі;
- класифікатори;
- прогнозування в електроенергетиці.