

С. М. Авакін, С. О. Довгополий, О. В. Запорожець, І. О. Мощенко

Харківський національний університет радіоелектроніки, Харків, Україна

КОРИГУВАННЯ ФУНКЦІЇ ПЕРЕТВОРЕННЯ ЗАСОБІВ ВИМІРЮВАННЯ З ВИКОРИСТАННЯМ НЕЙРОМЕРЕЖЕВОГО ПІДХОДУ

Анотація. У статті розглянуто способи зменшення впливу нелінійності функції перетворення засобів вимірювання на точність результату вимірювання шляхом застосування додаткового пристрою-коректора, який реалізує зворотну по відношенню до функції перетворення залежність. Метою дослідження є вивчення можливостей застосування у якості такого коректора штучних нейронних мереж, а саме багатошарового перцептрона та радіально-базисної нейромережі. За допомогою імітаційного комп'ютерного моделювання досліджено працездатність запропонованих методів коригування функції перетворення, вплив виду нелінійності на якість такого коригування. Здійснено порівняльний аналіз з традиційними підходами, а саме коректором на базі поліноміального апроксиматора. Результати моделювання свідчать про те, що точність нейромережових коректорів не поступається точності поліноміального коректора, а у деяких випадках навіть вище. Це відкриває перспективи ширшого застосування у вимірювальній техніці таких сучасних методів обробки даних вимірювань, як штучні нейронні мережі.

Ключові слова: нелінійність, коригування, функція перетворення, штучна нейронна мережа, багатошаровий перцептрон, радіально-базисна нейромережа, навчання.

Вступ

Кілька останніх десятиліть ознаменувались стрімким розвитком інформаційних технологій, які радикально і докорінно змінили не тільки звичний уклад людського життя, а й цілі сектори економіки у більшості розвинених країн світу. Безумовним досягненням наукової думки стали успіхи в розробці штучного інтелекту. Дослідження в царині штучних нейронних мереж, глибокого навчання, фаззі-систем дозволили реалізувати досить складні методи математичної обробки та аналізу великих масивів даних та розв'язувати цілий ряд задач класифікації, оптимізації, управління, розпізнавання образів, ідентифікації, апроксимації складних нелінійних залежностей, діагностики тощо.

Галузь вимірювань та вимірювальної техніки теж не залишається осторонь і намагається активно використовувати більш ефективні методи обробки інформації, які дозволять підвищити точність і достовірність результатів вимірювань. Роль таких методів стає більш важливою з ускладненням вимірювань і підвищенням вимог до їх точності.

Нові напрямки прикладної математики, такі як теорія штучних нейронних мереж, інтервальный аналіз, робасна та непараметрична статистика, нечітка логіка, вейвлет-аналіз та ряд інших, дають математичний апарат для розв'язання тих задач, для яких класичні методи обробки даних є непридатними або малоефективними. До розробки нових методів обробки вимірювальної інформації спонукають потреби сучасної вимірювальної практики, для якої є характерним ускладнення вимірювальних задач і засобів вимірювання.

Розширення можливостей інтелектуальної обробки даних та результатів вимірювання тісно пов'язано з розвитком методології вимірювань, удосконаленням математичних методів, а також широ-

ким впровадженням засобів обчислювальної техніки у вимірювальний ланцюг, включаючи мікропроцесори і мікроконтролери.

Постановка задачі

Для засобу вимірювання одними з найбільш важливих є метрологічні характеристики, що впливають на результат вимірювання та точність цього результату. Однією з таких характеристик є номінальна статична функція перетворення засобу вимірювання (інші її назви – рівняння перетворення, градувальна характеристика). Вона встановлює залежність $y = F(x)$ інформативного параметра вихідного сигналу y від значення інформативного параметра вхідного сигналу x .

Зазвичай до функції перетворення висувається вимога лінійності у робочому діапазоні вимірювань. Однак, досить часто при вирішенні практичних вимірювальних задач доводиться мати справу з вимірювальними пристроями, які мають нелінійну функцію перетворення. Так, наприклад, аналогові електронні мегаомметри в режимі вимірювання великих опорів (одиниці і десятки мегаомів) мають зворотну нерівномірну шкалу. Чутливість приладу на різних ділянках такої шкали буде різною, що не зовсім зручно і при взятті відліку, і при оцінюванні похибки результату вимірювання. Окремі елементи вимірювального тракту, такі як напівпровідникові терморезистори або діоди, теж мають суттєво нелінійну робочу характеристику, що відбивається на функції перетворення приладу. Іноді наблизити функцію перетворення до лінійної вдається за допомогою схемотехнічних рішень, але не завжди. Зазвичай на практиці функцію перетворення апроксимують лінійною залежністю

$$\hat{y} = a + bx,$$

невідомі коефіцієнти якої a і b знаходять за допомогою методу найменших квадратів. Проте у випадку,

коли нелінійність функції перетворення є суттєвою, такий підхід не дає бажаного результату, оскільки внаслідок відхилення номінальної функції перетворення від реальної виникає велика методична похибка (рис. 1).




Рис. 1. Похибки лінеаризації функції перетворення

Для зменшення цієї похибки можна спробувати привести нелінійну функцію $y = F(x)$ до лінійного вигляду $\tilde{y} = a + b\tilde{x}$ шляхом заміни змінних

$$\tilde{y} = \varphi(y), \quad \tilde{x} = \psi(x)$$

з подальшим визначенням коефіцієнтів a і b лінійної функції за методом найменших квадратів [1]. Але у цьому випадку потрібно заздалегідь знати, як виглядає нелінійна функція перетворення, тобто мати апріорну інформацію про структуру математичної моделі засобу вимірювання. Обґрунтований вибір виду цієї нелінійної залежності є доволі складною задачею, яка погано піддається формалізації і здійснюється, виходячи з відомих фізичних законів або особистого досвіду фахівця, який займається розв'язанням задачі.

Одним з відомих підходів до зменшення впливу нелінійності функції перетворення на похибку результату вимірювання, який можна вважати універсальним, є алгоритмічна корекція функції перетворення. Послідовно із засобом вимірювання включається спеціальний пристрій-коректор, який здійснює зворотне по відношенню до його характеристики перетворення $\hat{x} = F^{-1}(y)$. В результаті такої корекції ми отримуємо оцінку $\hat{x}$ вхідного сигналу (вимірюваної величини) x , а результуюча функція

перетворення стає лінійною. Важливою додатковою умовою є інваріантність такого перетворювача до виду нелінійної функції, що коригується, тобто можливість адаптації до довільної функції перетворення.

Метою даної статті є дослідження адаптивної системи коригування функції перетворення засобу вимірювання, яка буде використовувати у якості пристрою корекції штучну нейронну мережу та забезпечуватиме лінійність функції перетворення в усьому діапазоні можливих значень вимірюваної вхідної величини.

Коригування функції перетворення за допомогою штучної нейронної мережі

Штучні нейронні мережі (ШНМ) – це обчислювальні структури, побудовані за принципом функціонування біологічних нейронних мереж, утворених клітинами мозку живих організмів. Відмінною особливістю ШНМ є здатність до навчання, що зробило їх пріоритетним напрямком досліджень в області штучного інтелекту. Теорія ШНМ стрімко розвивається в останні роки, що сприяє підвищенню зацікавленості до їх використання в різноманітних галузях науки, техніки, економіки, медицини, військової справи тощо. Завдяки таким властивостям, як висока надійність функціонування, завадостійкість, здатність до узагальнення, можливість реалізації складних багатовимірних відображень, нейромережі широко застосовуються для розпізнавання образів і класифікації, прийняття рішень і управління, оптимізації, апроксимації функцій, прогнозування, фільтрації, організації пам'яті [2-5].

Виходячи з вищевказаних особливостей ШНМ, зокрема здатності бути універсальним апроксиматором складних нелінійних залежностей, саме нейромережу найбільш доцільно використовувати у якості коригуючого пристрою, як було показано у ряді досліджень [6-10]. На рис. 2 наведено структуру такої адаптивної системи коригування функції перетворення засобу вимірювання. Дію внутрішніх та зовнішніх випадкових факторів на вимірювальний процес представлено адитивним шумом $\xi(t)$ на виході засобу вимірювання, де t – поточний час. Вихідний сигнал $y(t)$ подається на вхід нейромережі-коректора, яка здійснює зворотне перетворення та формує оцінку вхідного сигналу (вимірюваної величини) $\hat{x}(t)$.




Рис. 2. Структура адаптивної системи корекції нелінійності функції перетворення засобу вимірювання

Алгоритм навчання здійснює настроювання синаптичних вагових коефіцієнтів нейромережі таким чином, щоб забезпечити найкраще наближення її вихідного сигналу $\hat{x}(t)$ до відомого значення вхідного сигналу $x(t)$. При цьому мінімізується середньоквадратичне значення помилки корекції $e(t) = x(t) - \hat{x}(t)$ за допомогою однієї з відомих градієнтних процедур оптимізації.

Пристрій корекції на базі багатошарового персептрона

Багатошарова нейронна мережа прямого поширення, або багатошаровий персептрон (Multilayer Perceptron, MLP) складається з декількох послідовно з'єднаних між собою шарів формальних нейронів: вхідного, прихованих та вихідного (рис. 3). Нейрони одного шару не зв'язані між собою, виходи нейронів n -го шару надходять на входи нейронів наступного $n+1$ -го шару. Вхідний векторний сигнал надходить на входи нейронів першого шару, а вихідні сигнали останнього шару формують вихідний векторний сигнал мережі. Конфігурація MLP визначається кількістю шарів, кількістю нейронів у кожному шарі та функціями активації нейронів. Навчання полягає у коригуванні коефіцієнтів зв'язків між нейронами таким чином, щоб забезпечити необхідні значення вихідних сигналів мережі. У процесі навчання багатошарова нейромережа здатна виявляти складні залежності між вхідними та вихідними сигналами та здійснювати узагальнення. При використанні парадигми навчання «з учителем» датасет, на якому навчається нейромережа, повинен бути розмічений або промаркований, тобто містити правильні відповіді (виходи нейромережі) на кожен вхідний зразок навчальної послідовності.




Рис. 3. Багатошаровий персептрон

Пропонується реалізувати пристрій для коригування нелінійності функції перетворення засобу вимірювання на базі тришарового персептрона, структуру якого наведено на рис. 4.

Вихідний шар персептрона утворено одним нейроном, який формує сигнал $\hat{x}$ як зважену суму вихідних сигналів нейронів прихованого шару

$$\hat{x} = \sum_{j=1}^n V_j O_j, \quad (1)$$

де O_j – вихідний сигнал j -го нейрона прихованого шару; V_j – синаптична вага j -го входу нейрона вихідного шару; n – кількість нейронів у прихованому шарі.

Прихований шар MLP утворено нейронами з сигмоїдальними функціями активації. Кожен нейрон цього шару описується такими рівняннями

$$O_j = \frac{1}{1 + e^{-S_j}},$$

$$S_j = \sum_{i=1}^m W_{ij} O_i,$$

де O_i – вихідний сигнал i -го нейрона вхідного шару; W_{ij} – синаптична вага i -го входу j -го нейрона прихованого шару; m – кількість нейронів у вхідному шарі.

Вхідний шар нейронів утворено самими вхідними сигналами нейромережі, якими у рамках задачі, що розглядається, є вихідний сигнал засобу вимірювання у та постійний сигнал, який дорівнює одиниці і вводиться для опису постійного зміщення.




Рис. 4. MLP-коректор

Навчання MLP базується на мінімізації середньоквадратичної помилки

$$E = \frac{1}{2} \sum_{k=1}^N e^2(k) = \frac{1}{2} \sum_{k=1}^N (x(k) - \hat{x}(k))^2 \quad (2)$$

шляхом настроювання синаптичних вагових коефіцієнтів нейронів за допомогою градієнтних методів. Найбільш популярними є два алгоритми навчання:

– метод зворотного поширення помилки (back propagation);

– алгоритм Левенберга-Марквардта (Levenberg-Marquardt algorithm, LMA), який є комбінацією методу Гауса-Ньютона та методу градієнтного спуску.

У нашому випадку для навчання MLP доцільніше використовувати алгоритм Левенберга-Марквардта, оскільки він має вищу швидкість збіжності порівняно з іншими градієнтними методами оптимізації.

Датасет для процедури навчання нейромережі-коректора буде складатися з пар значень

$$\{ \langle y(1), x(1) \rangle, \langle y(2), x(2) \rangle \dots \langle y(N), x(N) \rangle \},$$

які отримують при калібруванні засобу вимірювання, подаючи на вхід зразковий сигнал $x(k)$ і отримуючи відповідне йому значення вихідного сигналу $y(k)$.

Пристрій корекції на базі радіально-базисної нейромережі

Ще одним універсальним апроксиматором складних функціональних залежностей є радіально-базисна нейронна мережа (Radial Basis Function Net, RBFN). Архітектура такої мережі складається з трьох шарів: вхідного, на який поступає вектор вхідних сигналів; прихованого, що складається з нейронів радіального типу; вихідного, який формує зважену лінійну комбінацію виходів нейронів прихованого шару (рис. 5).




Рис. 5. RBFN-коректор

Якщо в якості функції активації нейронів прихованого шару використовувати функцію Гауса, то рівняння такого перетворювача матиме вигляд

$$\hat{x} = \sum_{i=1}^n V_i \exp\left(-\frac{(y - c_i)^2}{2\sigma_i^2}\right), \quad (3)$$

де c_i – центр i -ої базисної функції, а σ_i – її радіус (ширина). Навчання RBFN полягає у визначенні лінійних вагових коефіцієнтів V_i вихідного нейрона, центрів c_i та радіусів σ_i нейронів прихованого шару. При цьому можливі такі варіанти:

1) задаються фіксовані значення центрів та радіусів нейронів прихованого шару, а вагові коефіцієнти вихідного нейрона визначаються шляхом навчання;

2) центри і радіуси визначаються шляхом самонавчання (найчастіше за допомогою методів кластеризації), а потім корекцією ваг вихідного нейрона мінімізується цільова функція (2);

3) всі параметри мережі визначаються за допомогою навчання з учителем, наприклад методом зворотного поширення помилок.

Результати експериментальних досліджень

Для вивчення властивостей запропонованих нейромережових систем коригування функції перетворення засобів вимірювання застосовувалось комп'ютерне моделювання в середовищі MATLAB з використанням бібліотеки Neural Network Toolbox.

У процесі моделювання досліджувався вплив виду нелінійності на якість коригування функції перетворення, при цьому для моделювання нелінійного засобу вимірювання використовувались такі види функцій [1]:

1) синусоїдальна $y = \sin(ax + b)$;

2) степенева $y = ax^b$;

3) гіперболічна $y = a + b/x$;

4) дробово-лінійна I $y = \frac{1}{a + bx}$;

5) дробово-лінійна II $y = \frac{cx}{a + bx}$;

6) показникова I $y = ae^{bx}$;

7) показникова II $y = ae^{b/x}$;

8) логарифмічна I $y = a + b \ln x$;

9) логарифмічна II $y = a + b/\ln x$.

Адитивний шум на виході засобу вимірювання моделювався гаусівським випадковим процесом з нульовим середнім і стандартним відхиленням 0,005. Якість коригування оцінювалась середньоквадратичним відхиленням оцінки сигналу після коригування від його дійсного значення

$$s = \sqrt{\frac{1}{N-1} \sum_{k=1}^N (x(k) - \hat{x}(k))^2}. \quad (4)$$

Для порівняння здійснювалось моделювання аналогічної системи коригування функції перетворення на базі поліноміального апроксиматора 5-го степеню. Результати моделювання наведено на рисунках 6-10 та в табл. 1.




Рис. 6. Коригування синусоїдальної функції перетворення




Рис. 7. Коригування степеневі функції перетворення




Рис. 8. Коригування дробово-лінійної II функції перетворення




Рис. 9. Коригування показникової I функції перетворення

Таблиця 1 – Середньоквадратична похибка корекції для різних нелінійних функцій і коректорів

Функція	Формула	Середньоквадратична похибка корекції		
		POLY	MLP	RBFN
1. Синусоїдальна	$y = \sin(0,3x - 1,7)$	0,0615	0,0752	0,0700
2. Степенева	$y = 2 \cdot x^{-1,5}$	0,2621	0,1992	0,1983
3. Гіперболічна	$y = 5 + 3/x$	0,1360	0,1374	0,1414
4. Дробово-лінійна I	$y = \frac{1}{0,05 + 0,1x}$	0,0974	0,0985	0,1016
5. Дробово-лінійна II	$y = \frac{10x}{0,5 + 1,2x}$	0,1076	0,1061	0,1053
6. Показникова I	$y = 5 \cdot e^{-0,5 \cdot x}$	0,2160	0,1870	0,1611
7. Показникова II	$y = 5 \cdot e^{0,5/x}$	0,1780	0,1727	0,1590
8. Логарифмічна I	$y = 5 + 3 \cdot \ln x$	0,0704	0,0715	0,0911
9. Логарифмічна II	$y = 5 + 3/\ln x$	0,3099	0,2814	0,2849

Кружечками на графіку функції позначено точки навчальної вибірки.




Рис. 10. Похибки коригування

Висновки

Аналіз результатів моделювання, наведених на рис. 6-10 та в табл.1, свідчить про те, що запропонована нейромережева система коригування нелінійності функції перетворення засобу вимірювання на базі MLP та RBFN є придатною для коригування

досить широкого класу нелінійних функцій перетворення, які зустрічаються у вимірювальних задачах. Порівняння характеристик нейромережевих коректорів і аналогічної системи на базі поліноміального апроксиматора показує, що середньоквадратична похибка корекції для деяких видів нелінійної функції перетворення у традиційного та нейромережевих коректорів відрізняється несуттєво, а для інших нейромережевий підхід показує кращі результати.

З цього можна зробити висновок, що результати моделювання повністю підтверджують працездатність запропонованої адаптивної системи коригування нелінійності функції перетворення на базі ШНМ і узгоджуються з теоретичними припущеннями. Перевагою запропонованого підходу є інваріантність нейромережевих коректорів до виду нелінійної характеристики засобу вимірювання та можливість синтезувати такі системи через навчання, без залучення складних методів проєктування. Це значно розширює можливості застосування таких систем у метрологічній практиці, зокрема в каналах інформаційно-вимірювальних систем, де досить просто

реалізувати методи цифрової обробки вимірювальної інформації. Використання запропонованого коректора на базі нейромережевого підходу дозволить суттєво зменшити систематичну похибку вимірювання, викликану невідповідністю номінальної та реальної функції перетворення засобу вимірювання.

СПИСОК ЛІТЕРАТУРИ

1. Грановский В.А., Сирая Т.Н. Методы обработки экспериментальных данных при измерениях. Л.: Энергоатомиздат, 1990. 288 с.
2. Bishop C.M. Pattern Recognition and Machine Learning. Springer. 2006. 738 p.
3. Haykin S. Neural Networks and Learning Machines. 3 rd. ed. Pearson, 2009. 906 p.
4. Теорія та практика нейронних мереж : навч. посіб. /Л. М. Добровська, І. А. Добровська. К.: НТУУ «КПІ» Вид-во «Політехніка», 2015. 396 с.
5. Hornik K., Stinchcombe M., White H. Multilayer feedforward networks are universal approximators. *Neural Networks*. 1989. 2(5). pp. 359–366.
6. Запорожец О.В., Коротенко В.А., Овчарова Т.А. Компенсация нелинейности функции преобразования измерительных устройств с помощью искусственной нейронной сети. *Системы управления, навигации та зв'язку*. Вип. 4(16). 2010. С. 99–103.
7. Дегтярев А.В., Запорожец О.В., Овчарова Т.А. Адаптивная система компенсации нелинейности функции преобразования измерительных устройств на базе трехслойного персептрона. *Электротехнические и компьютерные системы*. № 06(82). 2012. С. 235–241.
8. Запорожец О.В., Овчарова Т.А. Компенсация нелинейности динамических измерительных преобразователей при помощи нейросетевых моделей. *Метрологія та прилади*. Вип. № 1/П/(45). 2014. С. 74–77.
9. Запорожец О.В., Овчарова Т.А., Руженцев И.В. Компенсация нелинейности полупроводникового терморезистора с помощью искусственной нейронной сети. *Системы обробки інформації*. 2015. №6 (131). С. 64–67.
10. Zaporozhets O.V., Shtefan N.V. Using Artificial Neural Network for Compensation of Semiconductor Thermistor Nonlinearity. *2019 IEEE 8th International Conference on Advanced Optoelectronics and Lasers (CAOL)*, Sozopol, Bulgaria, 6–8 Sept. 2019. PP. 703–706.

Received (Надійшла) 23.01.2025

Accepted for publication (Прийнята до друку) 09.04.2025

ВІДОМОСТІ ПРО АВТОРІВ / ABOUT THE AUTHORS

Авакін Сергій Миколайович – студент кафедри електронних обчислювальних машин, Харківський національний університет радіоелектроніки, Харків, Україна;

Serhii Avakin – student, Department of Electronic Computers, Kharkiv National University of Radio Electronics, Kharkiv, Ukraine;

e-mail: serhii.avakin@nure.ua; ORCID Author ID: <https://orcid.org/0009-0004-4372-1913>.

Довгополий Сергій Олександрович – аспірант кафедри інформаційно-вимірювальних технологій, Харківський національний університет радіоелектроніки, Харків, Україна;

Serhii Dovhopolyi – PhD student, Department of Information and Measurement Technologies, Kharkiv National University of Radio Electronics, Kharkiv, Ukraine;

e-mail: serhii.dovhopolyi@nure.ua; ORCID Author ID: <https://orcid.org/0009-0008-8423-8812>.

Запорожець Олег Васильович – доктор філософії, доцент, доцент кафедри інформаційно-вимірювальних технологій, Харківський національний університет радіоелектроніки, Харків, Україна;

Oleg Zaporozhets – PhD, Associate Professor, Department of Information and Measurement Technologies, Kharkiv National University of Radio Electronics, Kharkiv, Ukraine;

e-mail: oleg.zaporozhets@nure.ua; ORCID Author ID: <https://orcid.org/0000-0002-7831-8479>;

Scopus Author ID: <https://www.scopus.com/authid/detail.uri?authorId=15728942500>.

Мощенко Інна Олексіївна – доктор філософії, доцент, доцент кафедри інформаційно-вимірювальних технологій, Харківський національний університет радіоелектроніки, Харків, Україна;

Inna Moshchenko – PhD, Associate Professor, Department of Information and Measurement Technologies, Kharkiv National University of Radio Electronics, Kharkiv, Ukraine;

e-mail: inna.moshchenko@nure.ua; ORCID Author ID: <https://orcid.org/0000-0002-2738-0037>;

Scopus Author ID: <https://www.scopus.com/authid/detail.uri?authorId=57547207800>.

Correction of transformation function in measurement devices using neural network approach

S. Avakin, S. Dovhopolyi, O. Zaporozhets, I. Moshchenko

Abstract. The article considers ways to reduce the impact of the nonlinearity of the transformation function of measuring instruments on the measurement result accuracy by using an additional corrector device that implements the inverse dependence of the transformation function. The purpose is to study the possibilities of using artificial neural networks as such a corrector, namely a multilayer perceptron and a radial-basis neural network. Using computer simulation modeling, the performance of the proposed methods for correcting the transformation function and the influence of the type of nonlinearity on the quality of such correction were investigated. A comparative analysis with traditional approaches, namely a corrector based on a polynomial approximator was carried out. The modeling results indicate that the accuracy of neural network correctors is not inferior to the accuracy of the polynomial corrector, and in some cases even higher. This opens up prospects for wider application in measuring equipment of such modern methods of processing measurement data as artificial neural networks.

Keywords: nonlinearity, correction, transformation function, artificial neural network, multilayer perceptron, radial basis neural network, learning.