



П. Б. Вітинський, Р. О. Ткаченко, І. В. Ізонін

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

## АНСАМБЛЬ НЕЙРОМЕРЕЖ GRNN НА ПІДСТАВІ ЗМІЩЕНИХ ПОВЕРХОНЬ ВІДГУКУ ДЛЯ ЗАДАЧ ЕЛЕКТРОННОЇ КОМЕРЦІЇ

Розв'язок задач електронної комерції, які здебільшого характеризуються нелінійними поверхнями відгуку, є важливим завданням. Застосування сучасних засобів обчислювального інтелекту не завжди є доречним зважаючи на складність реалізації процедур навчання і налагодження. Неітеративні засоби та нейронні мережі без навчання також не забезпечують заданої точності результату. З огляду на це у роботі описано новий ансамбль на підставі нейронних мереж узагальненої регресії. Основна ідея розробленого ансамблю полягає в лінеаризації поверхні відгуку, що задається даними наявної вибірки. Для цього отримана за допомогою мережі GRNN поверхня подається на вхід лінійної нейроподібної структури. Така комбінація забезпечує підвищення точності роботи ансамблю під час розв'язання поставленої задачі. Описаний ансамбль застосовано для розв'язання задачі прогнозування ціни на вживані автомобілі. Експериментальним способом підібрано оптимальні параметри його роботи. Шляхом порівняння із відомими методами встановлено найвищу точність його роботи. Результати експериментальних досліджень порівняно з теоретичними оцінками на підставі висновків теореми Кондорсе про журі присяжних. Розроблений ансамбль нейронних мереж узагальненої регресії на підставі зміщення поверхонь відгуку та з додатковим використанням нейроподібних структур Моделі послідовних геометричних перетворень варто застосовувати під час розв'язання різноманітних задач електронної комерції підвищеної точності.

**Ключові слова:** ансамбль; алгоритми без навчання; зміщення поверхонь відгуку; нейронна мережа узагальненої регресії; прогнозування; електронна комерція.

**Вступ.** Ринок електронної комерції вражає своїми обсягами і темпами зростання. На відміну від традиційної торгівлі, для електронної комерції характерним є високий рівень інновацій та технологій. Дедалі частіше для розв'язку бізнес-задач застосовують методи машинного навчання (Vitynskyi, Tkachenko & Havrysh, 2019). До таких задач можна віднести оптимізацію та прогнозування вартості товару. Застосування інтелектуальних стратегій ціноутворення дає змогу значно підвищити рентабельність підприємства.

З підвищенням попиту на власний засіб пересування, актуальною стала задача прогнозування вартості автомобіля, особливо коли йдеться про вживаний автомобіль. Найчастіше потреба прогнозування вартості автомобіля виникає у великих компаній, які спеціалізуються на продажі вживаних автомобілів, та лізингових компаній. На підставі даних з пропозицій продажу можна побудувати різні моделі прогнозування вартості, де на вартість впливає безліч незалежних факторів (Kanwal & Sadaqat, 2017). Часто такі дані характеризуються багатьма входними ознаками, такими як: рік випуску, тип палива, об'єм двигуна, пробіг, колір тощо та

великими вибірками даних, внаслідок чого поставлені жорсткіші вимоги до методів машинного навчання, вони повинні забезпечувати достатню швидкість та високу точність (Kozich, Bondarenko & Bazhenov, 2015).

**Мета дослідження** – розроблення, застосування і оцінювання результатів функціонування ансамблю нейронних мереж узагальненої регресії на підставі зміщення поверхонь відгуку та з додатковим використанням нейроподібних структур моделі послідовних геометричних перетворень.

**Постановка завдання дослідження.** Для досягнення встановленої мети потрібно розробити топологію ансамблю штучних нейронних мереж, застосувати розроблений ансамбль для розв'язання задачі регресії, а також порівняти результати експериментальних досліджень з теоретичними оцінками на підставі висновків теореми Кондорсе про журі присяжних.

**Аналіз попередніх досліджень.** Для прогнозування вартості товару в багатьох працях застосовують засоби машинного навчання, зокрема штучні нейронні мережі (ШНМ) (Kryvinska & Gregus, 2014; Molnár et al., 2018).

### Інформація про авторів:

**Вітинський Павло Богданович**, аспірант, кафедра інформаційних технологій видавничої справи.

Email: pavlo.vitynsky@gmail.com; <https://orcid.org/0000-0002-3183-3596>

**Ткаченко Роман Олексійович**, д-р техн. наук, професор, завідувач кафедри інформаційних технологій видавничої справи.

Email: roman.tkachenko@gmail.com; <https://orcid.org/0000-0002-9802-6799>

**Ізонін Іван Вікторович**, канд. техн. наук, асистент кафедри інформаційних технологій видавничої справи.

Email: ivanizonin@gmail.com; <https://orcid.org/0000-0002-9761-0096>

**Цитування за ДСТУ:** Вітинський П. Б., Ткаченко Р. О., Ізонін І. В. Ансамбль нейромереж GRNN на підставі зміщених поверхонь відгуку для задач електронної комерції. Науковий вісник НЛТУ України. 2019, т. 29, № 9. С. 142–146.

**Citation APA:** Vitynskyi, P. B., Tkachenko, R. O., & Izonin, I. V. (2019). GRNN ensemble based on displacement of the surfaces of the response for E-commerce tasks. *Scientific Bulletin of UNFU*, 29(9), 142–146. <https://doi.org/10.36930/40290925>

Штучні нейронні мережі успішно зарекомендували себе у розв'язанні цієї задачі. Вони автоматично будують високоточні моделі, які можуть аналізувати великі та складноструктуровані дані, але незважаючи на велику кількість успішних застосувань, ці методи мають низку недоліків (Bodyanskiy, Tyshchenko & Kopalians, 2018; Zhernova et al., 2018).

Навчання ШНМ зводиться до вирішення багатокритеріальної і багатопараметричної задачі мінімізації похибок функціонування. Розроблені алгоритми навчання, що базуються на методі зворотного поширення похибки, є достатньо повільними, а їх прискорені варіанти втрачають у точності навчання. Додатково до традиційних алгоритмів застосовують методи оптимізації на підставі генетичних алгоритмів, або алгоритмів імітації відпалу металу (Doroshenko, 2018). Враховуючи специфіку задач великих даних, застосування для них штучних нейронних мереж неефективне в сенсі надто великої складності навчання і налагодження.

Лінійні ШНМ типу одношарових перцептронів і нейроподібних структур на підставі Моделі послідовних геометричних перетворень (МППГ) (Tkachenko et al., 2018) достатньо привабливі для використання в задачах великих даних, оскільки для них взагалі не використовується складна і тривала процедура налаштування параметрів, а навчання є швидким і ефективним. Отже, для класу лінійних задач саме ці типи нейромереж, в умовах застосування сучасних комп'ютерних засобів, можна рекомендувати для застосування. Щодо задач, які представлені нелінійними поверхнями відгуку, точність їх розв'язку подібними засобами здебільшого виявляється незадовільною.

Нейромережі радіальних базових функцій (РБФ). На відміну від БШП, які здійснюють апроксимацію поверхні відгуку за допомогою комбінації сигмоїдних поверхонь, ці ШНМ здійснюють наближення комбінацією гіперсфер. Мережі РБФ володіють очевидними перевагами перед БШП, зокрема, істотно простішим налагодженням структури, швидшим і ефективнішим навчанням. До загальновідомих недоліків ШНМ РБФ відносять відсутність можливості здійснювати екстраполяцію, великі об'єми мереж, що спричинені потребою використання значного числа центрів радіальних функцій у задачах великих даних (Tkachenko et al., 2018).

Імовірнісні нейромережі (PNN) та нейромережі узагальненої регресії (GRNN). Істотною перевагою подібних ШНМ є відсутність процедур налагодження і навчання. Однак точність подібних нейромереж є досить низькою, тому їх рекомендують застосовувати лише для попереднього аналізу результатів розв'язку задач. Як і ШНМ РБФ, ці нейромережі не володіють здатністю до екстраполяції (Tkachenko, Tkachenko & Izonin, 2017).

Одним з найбільш перспективних та сучасних методів покращення точності прогнозування є побудова ансамблів моделей. Тема ансамблевих методів добре вивчена в машинному навчанні. У ролі математичного обґрунтування ідеї ансамблів можна розглянути теорему Кондорсе про журі присяжних, яка надає імовірнісну оцінку правильної класифікації відповідно до ймовірностей правильних відповідей членів журі:

$$\mu = \sum_{i=m}^N C_N^i p^i (1-p)^{N-1}, \quad (1)$$

де:  $N$  – кількість членів журі;  $p$  – ймовірність правильної відповіді одного члена журі;  $\mu$  – ймовірність правильної відповіді журі.

Згідно з теоремою Кондорсе, однією з ключових передумов отримання хороших результатів ансамблю є застосування у ролі членів ансамблю методів, ймовірності похибки яких не перевищує 0,5 і є некорельованими між собою. Якщо кожен з членів ансамблю здатен спрогнозувати результат з ймовірністю похибки меншим ніж 0,5 і кореляція між результатами прогнозування членів ансамблю – відсутня, то шляхом голосування/зваження кінцевий результат буде кращим за результати окремих членів ансамблю (Barmak et al., 2018).

**Ансамбль нейромереж GRNN на підставі зміщених поверхонь відгуку.** Основна ідея розробленого ансамблю полягає в лінеаризації поверхні відгуку, що задається даними наявної тренувальної вибірки. Для цього отримана за допомогою мережі GRNN (з достатньо помітними похибками) поверхня подається на вхід лінійної мережі (рис. 1). Ще вищий рівень лінеаризації, а отже – більша точність моделювання, досягається при подачі на входи лінійної нейромережі виходів декількох мереж GRNN, для яких вектори вхідних сигналів випадково зміщені відносно рухомої точки.

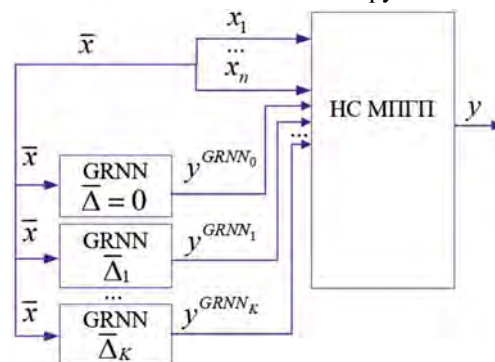


Рис. 1. Структурна схема ансамблю

**Алгоритмічна реалізація ансамблю.** Нехай задано вибірку для підготовки ансамблю (перша вибірка) з  $N$  векторів і вибірку для застосування ансамблю (друга вибірка) з  $N_1$  векторів. Зазначимо, що для другої вибірки невідоме значення вихідної компоненти.

Алгоритмічна реалізація запропонованого ансамблю передбачає виконання таких кроків:

1. Виконуємо нормування компонентів векторів, внаслідок чого отримуємо вектори для першої вибірки виду  $\dots x_{i,j} \dots \Rightarrow y_i$ , де  $i = \overline{1, N}$ ;  $j = \overline{1, n}$  і use  $\dots x_{u,j} \dots$ , де  $u = \overline{1, N_1}$ ;  $j = \overline{1, n}$ .
2. За результатами обчислення відгуків для всіх точок першої вибірки підбираємо оптимальне значення коефіцієнта розмаху гаусівської функції  $\sigma_{GRNN}$ , використовуючи обраний критерій відхилення. На відміну від базового методу GRNN, у цьому випадку вводиться етап навчання, що виконується так:
  - 2.1. Формуємо (випадково) набір відхилень, які будуть однотипними для кожного  $i$ -го вектора першої вибірки і  $u$ -го другої вибірки –  $\dots \Delta_{k,j} \dots$ , де  $k = \overline{1, k_{\max}}$ ;  $j = \overline{1, n}$ ; для кожної пари  $k, j$  величина  $\Delta_{k,j}$  є випадковим числом у заданому діапазоні  $\pm \Delta$  однакова для першої та другої вибірок; необхідна умова  $\Delta < 1$ ; величина  $k_{\max}$  обирається і задає кількість входів розширення ШНМ.

2.2. На базі кожного  $i$ -го вектора першої вибірки формуємо  $(k_{\max}+1)$  додаткових вхідних векторів  $\dots x_{i,k,j}, \dots$ , де  $x_{i,k,j} = x_{i,j} + \Delta_{k,j}$  для  $i = \overline{1, N}$ ;  $k = \overline{1, k_{\max}}$ ;  $j = \overline{1, n}$ , а також  $x_{i,k+1,j} = x_{i,j}$ .

2.3. Для кожного додаткового вектора отримуємо передбачення методом GRNN:

$$y_{i,k}^G = \frac{\sum_{i=1}^{N-1} (y_i \cdot G_{k,i})}{\sum_{i=1}^N G_{k,i}}, \quad (2)$$

де:  $G_{k,i} = \exp\left(-\frac{E_{k,i}^2}{\sigma^2}\right)$ ;  $E_{k,i}$  – евклідова віддаль між векторами  $\dots x_{i,j}, \dots$  та  $\dots x_{i,k,j}, \dots$ ; де  $k = \overline{1, k_{\max}}$ ; беручи до уваги, що у формулі для розрахунків  $y_{i,k}^G$  з першої вибірки вилучається  $i$ -й вектор, який розглядаємо за п.3.2. Для  $(k_{\max}+1)$ -го вектора маємо:

$$y_{i,k_{\max}+1}^G = \frac{\sum_{i=1}^{N-1} (y_i \cdot G_{k_{\max}+1,i})}{\sum_{i=1}^N G_{k_{\max}+1,i}}, \quad (3)$$

де:  $G_{k_{\max}+1,i} = \exp\left(-\frac{E_{k_{\max}+1,i}^2}{\sigma_{opt}^2}\right)$ .

2.4. Формуємо розширений  $i$ -й вектор першої вибірки –  $\dots x_{i,j}, \dots y_{i,1}^G, y_{i,2}^G, \dots, y_{i,k}^G, \dots \Rightarrow y_i$ , де  $i = \overline{1, N}$ ;  $k = \overline{1, k_{\max}}$ ;  $j = \overline{1, n}$ .

3. Режим застосування ансамблю мереж. Виконується після навчання лінійної ШНМ на векторах першої вибірки.

3.1. На базі рухомого вектора з другої вибірки формуємо  $k_{\max}$  додаткових вхідних векторів з використанням наборів відхилень, введених для першої вибірки  $\dots x_{u,k,j}, \dots$ , де  $x_{u,k,j} = x_{u,j} + \Delta_{k,j}$  при  $u = \overline{1, N1}$ ;  $k = \overline{1, k_{\max}}$ ;  $j = \overline{1, n}$ .

3.2. Для кожного додаткового вектора другої вибірки знаходимо прогнозоване значення методом GRNN:

$$y_{u,k}^G = \frac{\sum_{i=1}^N (y_i \cdot G_{u,i})}{\sum_{i=1}^N G_{u,i}}, \quad (5)$$

$$G_{u,i} = \exp\left(-\frac{E_{u,i}^2}{\sigma^2}\right), \quad (6)$$

де  $E_{u,i}$  – евклідова віддаль між векторами  $\dots x_{u,j}, \dots$  та  $\dots x_{u,k,j}, \dots$ .

**Моделювання.** Розроблений ансамбль застосовувався до розв'язання задачі прогнозування цін на вживані автомобілі з використанням реальної вибірки даних (Corolla, 2019). Прогнозування ціни відбувалося на підставі дев'яти незалежних ознак, які подано у табл. 1.

Табл. 1. Набір незалежних змінних

№ з/п	Назва атрибута
1	Вік, років
2	Пробіг автомобіля, км
3	Тип палива
4	Потужність двигуна
5	Колір
6	Наявність автоматичної коробки передач
7	Об'єм циліндра, см <sup>3</sup>
8	Кількість дверей
9	Вага автомобіля, кг

Оскільки ряд змінних були категоріальними, для їхнього представлення було використане унітарне кодування (one-hot encoding). Отже, кількість незалежних ознак, на підставі яких визначалася ціна вживаного автомобіля, становила 11. Вибірка даних містила 1436 векторів, з яких у режимі підготовки ансамблю використано 1077 векторів, а у режимі застосування – відповідно 359 векторів.

У роботі проведено ряд експериментів щодо підбору оптимальних параметрів роботи ансамблю. Перший з них передбачає пошук такої кількості членів ансамблю, який забезпечував би оптимальний результат. Експеримент проводився при зміні кількості членів ансамблю з 5 до 35 при випадкових ( $\sigma=0,1$ ;  $\delta=0,25$ ). Оцінювання відбувалося із використанням середньоквадратичної похибки (RMSE). Результати експерименту у вигляді значень RMSE як для режиму підготовки (червоні стовпці гістограми), так і застосування (жовті стовпці гістограми) ансамблю візуалізовано на рис. 2.




Рис. 2. Зміна похибок RMSE (для режимів підготовки та застосування ансамблю) при зміні кількості членів ансамблю за інших рівних умов ( $\sigma = 0,1$ ;  $\delta = 0,25$ )

Як видно з цього рисунку, найменшу похибку з режимі застосування розробленого ансамблю отримано для випадку, коли кількість членів ансамблю дорівнює 15. Окрім цього, в цьому випадку отримано найменше відхилення між значеннями похибок в обох режимах ансамблю. Це свідчить про досягнення запропонованою моделлю певної оптимальної складності. У разі подальшого збільшення кількості членів ансамблю спостерігається істотне підвищення похибки режиму застосування. Окрім цього, як видно з рис. 2, у цьому випадку спостерігається істотна різниця між RMSE режимів підготовки та застосування ансамблю. При цьому похибка в режимі застосування істотно більша. Це може свідчити про перенавчання запропонованого ансамблю при виборі великої кількості його членів.

Наступний експеримент передбачав пошук найкращих параметрів роботи ансамблю:

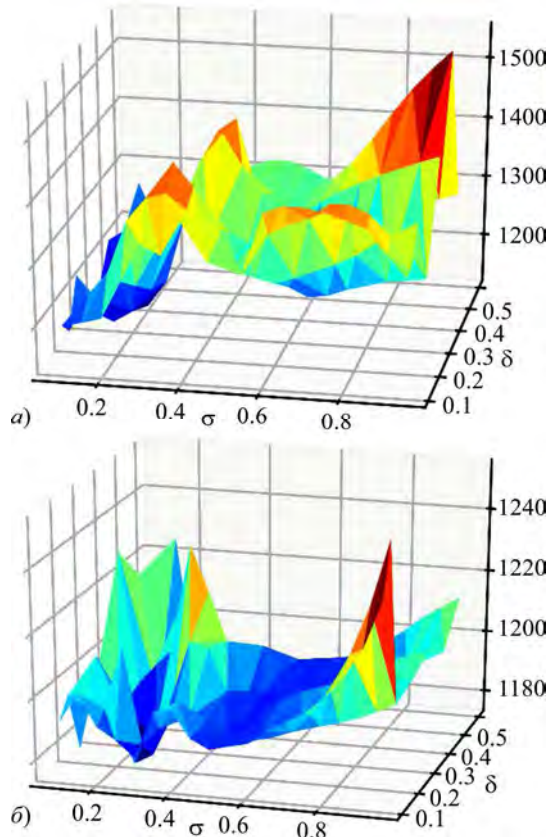
- $\sigma$  – величини розмаху гаусівської функції методу GRNN;
- $\delta$  – величини відхилень, на підставі яких формуються члени ансамблю.

Для цього застосовано оптимізацію методом перебору для ансамблю з 15 членів при  $\sigma(\sigma \in [0,1; 0,5], \Delta_\sigma=0,1)$  та  $\delta(\delta \in [0,1; 0,95], \Delta_\delta=0,05)$ . Результати цього експерименту відображено на рис. 3. Зазначимо, що на рис. 3,а наведено значення величини похибки RMSE отриманою для режиму підготовки ансамблю, а на рис. 3,б – відповідно для режиму застосування розробленого ансамблю.

Як видно з обох рисунків, найменше значення похибки (темно-синій колір поверхонь) отримано для найменшого значення відхилень, з яких формуються



члени ансамблю. Це випадок, коли величина відхилень значень розмаху гаусівської функції методу GRNN дорівнює 0,25. Отож, у табл. 2 зведено оптимальні значення параметрів роботи розробленого ансамблю, що забезпечують найкращі значення похибок.



**Рис. 3.** Візуалізація величини похибки RMSE в режимі підготовки (а) та застосування (б) ансамблю з 15 членів з використанням оптимізації методом перебору при  $\sigma \in [0,1; 0,5]$ ,  $\Delta_{\sigma}=0,1$  та  $\delta \in [0,1; 0,95]$ ,  $\Delta_{\delta}=0,05$

**Табл. 2.** Результати роботи розробленого ансамблю при підборі оптимальних параметрів

Кількість членів ансамблю	Величина відхилень	Величина розмаху гаусівської функції	RMSE в режимі підготовки	RMSE в режимі застосування
15	0,1	0,25	1187,38	1174,07

Порівняння отриманих результатів відбувалося із результатами за відомими методами, які описано у роботі (Corolla, 2019). Також у цій роботі наведено основні параметри відомих методів. У табл. 3 зведено значення похибок режиму застосування усіх методів, що використовувалися для розв'язання цієї задачі.

**Табл. 3.** Результати порівняння розробленого методу з результатами за наявними

№ з/п	Метод	RMSE
1	Розроблений ансамбль	1174,077
2	НС МПГП	1398,459
3	Нейромережа RBF	1320,376
4	Нейромережа узагальненої регресії	1416,262
5	Лассо-регресія*	1177,509
6	Гребенева регресія*	1359,385
7	Лінійна регресія*	1398,459
8	Регресор на підставі Дерев Рішень*	1485,501
9	Регресор на підставі Машини Опорних Векторів*	1525,525
10	Поліноміальна регресія (2-го степеня)*	1837,846

Примітка: \* – (Molnár, Molnár, Kryvinska & Greguš, 2018)

Як видно з табл. 3, найменшу похибку отримано у випадку застосування розробленого ансамблю. Це свідчить про можливість його використання до інших задач регресії, що виникають у різних прикладних областях (Babichev et al., 2018; Kryvinska, 2012; Gregus & Kryvinska, 2012; Kaczor & Kryvinska, 2013).

Порівняємо результати експериментальних досліджень з оцінкою теореми Кондорсе про журі присяжних. Для експерименту використаємо ансамбль з трьох членів.

**Табл. 4.** Результати прогнозування ансамблю і його окремих членів

№ члена ансамблю	MAPE, %	MAPE, %
1	13,538	9,2261
2	14,333	
3	13,293	

Підставимо значення MAPE окремих членів ансамблю замість ймовірностей у формулу (1):

$$0,13538 \cdot 0,14333 \cdot 0,86707 + 0,13538 \cdot 0,85667 \cdot 0,13293 + \\ + 0,86462 \cdot 0,14333 \cdot 0,13293 + 0,13538 \cdot 0,14333 \cdot 0,13293 = \\ = 0,05129 \cdot 100 = 5,129 \, \%$$

Як показали експерименти, точність розробленого ансамблю помітно вища, ніж його окремих членів. Певні відхилення експериментальних результатів від теоретичних пояснюють наявністю незначної корельованості між параметрами членів ансамблю.

**Висновки.** У роботі описано розроблений авторами ансамбль нейронних мереж. За основу побудови ансамблю обрано нейронні мережі узагальненої регресії у зв'язку із найкращими властивостями генералізації цього типу нейронних мереж серед наявних. Побудова ансамблю відбувається на підставі зміщень поверхні відгуку. Додатково, в алгоритмічну реалізацію ансамблю введено нейроподібні структури Моделі послідовних геометричних перетворень, що забезпечують високошвидкісне навчання та підвищення точності роботи усього ансамблю. Наведено структурну схему роботи розробленого ансамблю, подано його алгоритмічну реалізацію.

Моделювання роботи ансамблю здійснено шляхом розв'язання задачі прогнозування вартості вживаних автомобілів. За основу обрано реальні дані. У роботі проведено ряд експериментів щодо підбору оптимальним параметрів роботи запропонованого ансамблю. Встановлено оптимальну кількість членів ансамблю з огляду на обчислювальні витрати його роботи та точність прогнозу. Оптимізацією методом перебору встановлено найкращі значення двох параметрів ансамблю: величина зміщень та величина розмаху гаусівської функції. Подано графічні результати виконання зазначених вище процедур. Здійснено порівняння з наявними методами регресії. Встановлено найвищу точність роботи на підставі середньоквадратичного відхилення запропонованого ансамблю порівняно з усіма розглянутими методами. Розроблений ансамбль нейронних мереж узагальненої регресії на підставі зміщення поверхонь відгуку із застосуванням нейроподібних структур Моделі послідовних геометричних перетворень варто застосовувати під час розв'язання різноманітних задач електронної комерції підвищеної точності.

## References

- Babichev, S., Lytvynenko, V., Gozhyj, A., Korobchynskyi, M., & Voronenko, M. (2018). A Fuzzy Model for Gene Expression Profiles Reducing Based on the Complex Use of Statistical Criteria and Shannon Entropy. *Advances in Computer Science for Engineering and Education*, 545–554.
- Barmak, O. V., Manziuk, E. A., Krak, Yu. V., & Kulias, A. I. (2018). Pryntsypy ta pidkhody do formuvannia ansambliv klasyfikatoriv na pidstavi ahrehatuvannia yikh rezultativ. *Shtuchnyi intelekt*, 3(81), 64 p. [In Ukrainian].
- Bodyanskiy, Y. V., Tyshchenko, O. K., & Kopalani, D. S. (2018). An evolving connectionist system for data stream fuzzy clustering and its online learning. *Neurocomputing*, 262, 41–56. <https://doi.org/10.1016/j.neucom.2017.03.081>
- Corolla. (2019). *Toyota Corolla Prices Regression Analysis*. Retrieved from: <https://www.kaggle.com/tolgahancepel/toyota-corolla-prices-regression-analysis>. (Accessed: 28.09.2019).
- Doroshenko, A. (2018). Piecewise-Linear Approach to Classification Based on Geometrical Transformation Model for Imbalanced Dataset. *IEEE Second International Conference on Data Stream Mining Processing (DSMP)*, august, 2018, (pp. 231–235).
- Gregus, M., & Kryvinska, N. (2012). *Service Orientation of Enterprises – Aspects, Dimensions, Technologies*. Comenius University in Bratislava.
- Kaczor, S., & Kryvinska, N. (2013). It is all about Services – Fundamentals, Drivers, and Business Models. The Society of Service Science. *Journal of Service Science Research, Springer*, 5(2), 125–154.
- Kanwal Noor, & Sadaqat Jan (2017). Vehicle Price Prediction System using Machine Learning Techniques. *International Journal of Computer Applications*, 167(9), 27–31. <https://doi.org/10.5120/ij-ca2017914373>
- Kozich, V. G., Bondarenko, V. V., & Bazhenov, R. I. (2015). Primenenie regressionnogo analiza i neironnykh setei dlia postroeniia modeli rynka poderzhannykh avtomobilei Toyota Prius. *Postulat*, 1(1), 4 p. [In Russian].
- Kryvinska, N. (2012). Building Consistent Formal Specification for the Service Enterprise Agility Foundation. The Society of Service Science. *Journal of Service Science Research, Springer*, 4(2), 235–269.
- Kryvinska, N., & Gregus, M. (2014). *SOA and its Business Value in Requirements, Features, Practices and Methodologies*. Comenius University in Bratislava.
- Molnár, E., Molnár, R., Kryvinska, N., & Greguš, M. (2018). Web Intelligence in practice. *Journal of Service Science Research, Springer*, 6(1), 149–172.
- Tkachenko, R. O., Tkachenko, P. R., & Izonin, I. V. (2017). *Neiromerzhevi zasoby shtuchnoho intelektu*. Lviv: Publishing house of Lviv Polytechnic, 204 p. [In Ukrainian].
- Tkachenko, R., Kutucu, H., Izonin, I., Doroshenko, A., & Tsymbal, Y. (2018). Non-iterative Neural-like Predictor for Solar Energy in Libya. *Proceedings of the 14th International Conference on ICT in Education, Research and Industrial Applications*. Integration, Harmonization and Knowledge Transfer. Volume I: Main Conference, Kyiv, Ukraine, May 14–17, 2018, Vol. 2105, (pp. 35–45).
- Vitynskyi, P. B., Tkachenko, R. O., & Havrysh, B. M. (2019). Doslidzhennia ta eksperymentalnyi analiz metodiv mashynnoho navchannia v zadachakh elektronnoi komertsii. *Naukovi zapysky*, 1(58), 62–70. [In Ukrainian].
- Zhernova, P. Y., Deineko, A. O., Bodyanskiy, Y. V., & Riepin, V. O. (2018). Adaptive Kernel Data Streams Clustering Based on Neural Networks Ensembles in Conditions of Uncertainty about Amount and Shapes of Clusters. *IEEE First International Conference on Data Stream Mining & Processing (DSMP)*, Lviv, 2016, (pp. 7–12). <https://doi.org/10.1109/DSMP.2018.8478616>

**P. B. Vitynskyi, R. O. Tkachenko, I. V. Izonin**

*Lviv Polytechnic National University, Lviv, Ukraine*

## GRNN ENSEMBLE BASED ON DISPLACEMENT OF THE SURFACES OF THE RESPONSE FOR E-COMMERCE TASKS

Solving e-commerce problems being represented in most cases by non-linear response surfaces is an important task. The use of existing computing intelligence methods is not always appropriate due to the significant complexity of training and debugging procedures. Non-iterative tools and neural networks without training also do not provide satisfactory accuracy of the result. The accuracy can be improved using different ensembling techniques. Therefore, the paper describes a new ensemble method based on generalized regression neural networks. The basic idea of the developed ensemble is to linearize the response surface given by the data of the available sample. Therefore, the surface obtained by means of the general regression neural network is given to the input of a linear neural structure. This combination helps improve the accuracy of solving the task by the ensemble. The described ensemble is used to solve the problem of predicting the price of used cars. Application of the ensemble developed enables predicting the price of the used cars based on the most suitable independent attributes. In common practice solving this task requires expert knowledge. The urgency of solving this problem is substantiated. The dataset contains vehicle characteristics and sale prices of 1436 used cars. The main attributes of the considered dataset are provided. The optimal parameters were experimentally selected. Performances of different existing methods were compared. The methods were evaluated by the root mean square error using a test data sample. By comparison with known methods such as General Regression Neural Network, Radial Basis Function Neural Network, Linear Regression, Lasso Regression, and Support Vector Machines Regressor, the highest accuracy of its work is established. The results are compared with Condorcet's jury theorem estimations. The implementation of the proposed method was done on Python programming language. Thus, we can summarize that the developed general regression neural network ensemble based on offsets of response surfaces and with additional use of the linear-type Neural-like Structure of a Successive Geometric Transformations Model can be used to solve various high-precision e-commerce tasks.

**Keywords:** ensemble; algorithms without training; displacement surfaces of the response; generalized regression neural networks ensemble; forecasting; e-commerce.