

О. Ю. МЕЛЬНИКОВ, В. Б. ГІТІС

ДОСЛІДЖЕННЯ ВПЛИВУ ЯКОСТІ ЗАСВОЄННЯ ПОПЕРЕДНЬОГО МАТЕРІАЛУ НА УСПІШНІСТЬ ЗДОБУВАЧІВ ОСВІТИ З ОКРЕМОЇ ДИСЦИПЛІНИ

У роботі розглянуто основні поняття, пов'язані з якістю освіти у цілому та засвоєнням студентами навчального матеріалу. Сформульовано задачу прогнозування оцінки студента з будь-якої дисципліни, маючи дані щодо оцінок з «забезпечуючих» дисциплін. Наведено перелік методів, які можуть бути застосовані для розв'язання задачі (метод багатовимірного регресійного аналізу, метод штучних нейронних мереж, метод k найближчих сусідів), зроблено висновок щодо доцільності використання методу штучних нейронних мереж. Описано постановку задачі прогнозування засвоєння знань та навичок програмування; використана архітектура – перцептрон з чотирма вхідними нейронами, одним вихідним і 10 нейронами прихованого шару. Шляхом проведення низки числових експериментів підібрано оптимальну архітектуру нейронної мережі. У якості прикладу використано навчальний план та структурно-логічну схему освітньо-професійної програми «Інтелектуальні системи прийняття рішень» спеціальності 124 «Системний аналіз». Описано створену інформаційну модель проєктованої системи мовою візуального моделювання UML (діаграми варіантів використання, класів, кооперації, послідовності, станів, діяльності та компонентів). Описано можливості системи для дослідження впливу якості засвоєння попереднього матеріалу на прогнозування оцінок студентів з окремої дисципліни, наведено приклад функціонування цієї системи та проведено аналіз результатів розрахунків. Зазначено, що система дозволяє проведення аналізу результатів розрахунків для подальшого вибору найкращого методу для прогнозування.

Ключові слова: освітньо-професійна програма, структурно-логічна схема, прогнозування, штучна нейронна мережа, перцептрон, сигмоїда, навчання нейромережі, уніфікована мова моделювання, інформаційна модель, система підтримки прийняття рішень.

O. YU. MELNYKOV, V. B. GITIS

STUDY OF THE INFLUENCE OF THE QUALITY OF ASSIMILATION OF THE PREVIOUS MATERIAL ON THE PREDICTION OF STUDENT GRADES IN A PARTICULAR DISCIPLINE

The paper considers the basic concepts related to the quality of education in general and the assimilation of students of educational material. The problem of predicting a student's grade in any discipline is formulated, having grades in "providing" disciplines. A list of methods that can be applied to solve the problem (multivariate regression analysis method, artificial neural networks method, k nearest neighbors method) is presented, a conclusion is made about the expediency of using the artificial neural networks method. The formulation of the problem of predicting the assimilation of knowledge and programming skills is described. The architecture used was a perceptron with four input neurons, one output neuron, and 10 hidden layer neurons. By conducting a series of numerical experiments, the optimal architecture of the neural network was selected. As an example, the curriculum and the structural and logical scheme of the educational and professional program "Intelligent Decision Making Systems" of the specialty 124 "System Analysis" were used. The created information model of the designed system is described in the visual modeling language UML (diagrams of use cases, classes, cooperation, sequence, states, activities and components). The possibilities of the system for studying the influence of the assimilation of the previous material on the prediction of students' grades in a particular discipline are described, an example of the functioning of this system is given, and an analysis of the results of calculations is carried out. It is indicated that the system allows analysis of the results of calculations for further selection of the best method for forecasting.

Keywords: educational and professional program, structural logic diagram, forecasting, artificial neural network, perceptron, sigmoid, neural network training, unified modeling language, information model, decision support system.

Вступ. Оцінка засвоєного студентами у межах навчальної дисципліни матеріалу, а також об'єктивність проведення цього контролю знань є одними з основних елементів визначення якості освіти [1]. Відомо, що рівень засвоєння індивідуумом нових знань залежить насамперед від його старанності та базового рівня знань, що є майже постійним за період навчання, тому різке відхилення у процесі оцінювання може свідчити про наявність проблем, об'єктивних і суб'єктивних факторів, які здійснюють вплив на освітній процес. Усі освітні компоненти на відповідному рівні вищої освіти, перелік навчальних дисциплін і логічну послідовність їх вивчення, кількість кредитів ЄКТС, а також очікувані результати навчання та компетентності, які повинен опанувати здобувач відповідного рівня вищої освіти, містяться в освітній програмі [2]. Структурно-логічна схема підготовки надається у вигляді мережі міждисциплінарних зв'язків і діє протягом всього строку реалізації відповідної програми підготовки. Отже, одним з чинників, що впливають на оцінку, яку отримує здобувач освіти (студент) з окремої дисципліни, є оцінки з «забезпечуючих» дисциплін, тобто тих, що передують цій.

Постановка задачі та вхідні фактори. Для

удосконалення керівництва навчальним процесом на випусковий кафедрі закладу вищої освіти вельми доцільним може бути прогнозування оцінок студентів за допомогою спеціалізованої інформаційної системи власної розробки. У зв'язку з тим, що існує достатня кількість методів для розв'язання задачі прогнозування, стає актуальним вибір такого методу, який буде максимально ефективними для аналізу конкретних даних.

Сформулюємо задачу таким чином. Нам потрібно спрогнозувати оцінку студента з будь-якої дисципліни, маючи дані щодо оцінок з «забезпечуючих» дисциплін:

$$y = \{x_1, x_2, \dots, x_n\}, \quad (1)$$

де y – оцінка з дисципліни, що прогнозується;

$x_i, i = 1 \dots n$ – оцінка з i -ї «забезпечуючої» дисципліни;

n – кількість «забезпечуючих» дисциплін.

У кожному випадку може бути застосовано окремий метод розв'язання задачі: багатofакторної лінійної регресії, штучних нейронних мереж, k найближчих сусідів. Слід провести дослідження, яке

дозволить визначити переваги та недоліки кожного з методів.

У [3] наведено алгоритм розв'язання поставленої задачі. Спочатку дослідник задає граничні значення параметрів для кожного методу (наприклад, мінімальну та максимальну кількість прихованих шарів штучних нейронних мереж тощо). Далі програмна система виконує розрахунок за кожним із методів, результати додаються до таблиці. Дослідник обирає найкращий, на його погляд, метод (як правило, за мінімальною сумарною помилкою, але можливі й інші критерії вибору). Обраний метод застосовується для прогнозування оцінок того ж предмета для нової групи. Вибір дисциплін, що забезпечують, не є явно пунктом наведеного алгоритму, оскільки здійснюється або безпосередньо з освітньої програми (її структурно-логічної схеми), або в результаті якихось попередніх досліджень.

Далі потрібно здійснити проектування інформаційної моделі системи [4] та її програмну реалізацію, але можна здійснити попередні розрахунки у середовищі Deductor Lite [5]. На прикладі даних щодо студентів спеціальності «Системний аналіз» [2] та предмета – засвоєння знань та навичок програмування – вже було здійснено розрахунки [6]. Було визначено чотири вхідних та один вихідний фактори:

x_1 – оцінка з дисципліни «Програмування та алгоритмічні мови»;

x_2 – оцінка з дисципліни «Алгоритми і структури даних»;

x_3 – оцінка з дисципліни «Математична логіка і теорія алгоритмів»;

x_4 – оцінка з дисципліни «Методи оптимізації та дослідження операцій»;

y – оцінка з дисципліни «Технологія створення програмних продуктів».

Назви груп та прізвища студентів є інформаційними факторами.

Рішення задачі методом штучних нейронних мереж. У якості даних були використані оцінки 77 студентів груп спеціальності «Системний аналіз» ДДМА – СМ-13-1, СМ-14-1, СМ-15-1, СМ-16-1 (змістовні наповнення навчальних курсів та викладачі за чотири роки не змінювалися). Спочатку здійснено розрахунок методом багатofакторної лінійної регресії, до таблиці результатів додано стовпці з перекладом результатів розрахунків зі 100-бальної системи до «національної» та співвідношення розрахункових результатів та наявних за «національною» шкалою («Помилка за балами»). Зроблено висновок, що багатofакторна лінійна регресія не може забезпечувати точності розв'язання задачі: 19 % даних мають відхилення за відносною помилкою більш ніж 10 %; 43 % даних мають невірне визначення балів.

Далі було здійснено рішення методом нейронних мереж. Спочатку для розрахунків використано мережу з чотирьох вхідних нейронів, одного вихідного і 10 нейронів прихованого шару (рис. 1). Різновид нейронної мережі – багатoshаровий перцептрон, метод на-

вчання мережі – зворотного поширення помилок, функція активації – експоненційна сигмоїда. Результати свідчать, що цей метод забезпечує більш адекватні результати: тільки 3 % даних мають відхилення за відносною помилкою більш ніж 10 %; тільки 16 % даних мають невірне визначення балів. Тому для побудови інформаційної системи було прийнято рішення про використання у якості модуля прогнозування багатoshарового перцептрон.

Проте для подальшої побудови перцептрон для розв'язання поставленої задачі потрібно визначити оптимальну кількість нейронів у прихованому шарі за заданою навчальною вибіркою. Ця задача нині не має суворого математичного рішення (під оптимальною тут розуміється мінімально необхідна для вирішення задачі кількість нейронів). Експериментально доведено, що якість роботи нейронної мережі з прямими зв'язками монотонно зростає при збільшенні кількості шарів і кількості нейронів у кожному шарі [7].

Кількість нейронів прихованого шару пов'язана з кількістю даних для навчання та необхідною кількістю входів і виходів мережі. Оцінити кількість нейронів у прихованих шарах можна за допомогою нерівності для оцінки кількості вагових коефіцієнтів необхідної для освоєння заданої кількості прикладів у навчальній вибірці [8]:

$$\frac{N_y N_p}{1 + \log_2 N_p} \leq N_w \leq N_y \left(1 + \frac{N_w}{N_x} \right) \times (N_x + N_y + 1) + N_y, \quad (2)$$

де N_w – кількість ваг у мережі;

N_p – кількість елементів навчальної вибірки;

N_x і N_y – розмірність вхідного й вихідного сигналу відповідно.

Тоді кількість нейронів (N_H) у двoshаровій мережі можна визначити за формулою:

$$N_H = \frac{N_w}{N_x + N_y}. \quad (3)$$

Підставляючи у формулу (3) граничні значення N_w , розраховані за формулою (2), отримуємо мінімальну ($N_{H_{\min}}^w$) і максимальну ($N_{H_{\max}}^w$) кількість нейронів у прихованому шарі мережі. Усі значення округлюються до найближчого більшого цілого.

Для задачі, що вирішується, $N_x = 4$, а $N_y = 1$. Кількість прикладів у навчальній вибірці – $N_p = 78$. Підставляючи ці значення у формули (2) і (3), отримуємо наступні параметри нейромережі: $N_{H_{\min}}^w = 11$, $N_{H_{\max}}^w = 124$, $N_{H_{\min}}^w = 3$, $N_{H_{\max}}^w = 25$.

Окрім обсягу навчальної вибірки, на розмір мережі також впливає складність вирішуваної задачі. Складність задачі відповідає складності апроксимації вихідної функції нейронною мережею і визначається структурою і значеннями вихідних даних. Оцінити

складність апроксимації таблично заданої функції (навчальної вибірки) можна за допомогою вибіркової оцінки константи Ліпшица, що обчислюється за наступною формулою:

$$L_{\{x,y\}} = \max_{i \neq j} \frac{d_E(\bar{y}^i, \bar{y}^j)}{d_E(\bar{x}^i, \bar{x}^j)} = \max_{i \neq j} \frac{\sqrt{\sum_{k=1}^K (y_k^i - y_k^j)^2}}{\sqrt{\sum_{k=1}^K (x_k^i - x_k^j)^2}}, \quad (4)$$

де $i, j = 1 \dots n$ – індекси прикладів у масиві початкових даних;

n – кількість прикладів у початкових даних;

\bar{x}^i – вектори вхідних сигналів нейромережі;

\bar{y}^i – вектори необхідних вихідних сигналів нейромережі;

$d_E(\bar{y}^i, \bar{y}^j)$ – відстань Евкліда між векторами вихідних сигналів;

$d_E(\bar{x}^i, \bar{x}^j)$ – відстань Евкліда між векторами вхідних сигналів.

$k = 1 \dots K$ – індекс компоненти вхідного вектору;

K – кількість компонент вхідного вектору.

Обчислюючи константу Ліпшица для навчальної вибірки, отримано: $L_{\{x,y\}} = 15,11$.

Визначивши вибірку оцінку константи Ліпшица, можна перевірити можливість нейронної мережі заданої архітектури апроксимувати запропоновану навчальну вибірку. Для цього необхідно оцінити константу Ліпшица нейромережі й порівняти її з вибірковою оцінкою константи Ліпшица.

Константа Ліпшица для гомогенної прямокутної нейронної мережі з функціями активації виду «експоненціальна сигмоїда» визначається за формулою [9, 10]

$$L_s \leq c^k \sqrt{N_x N_y} \prod_{i=1}^{k-1} N_{ni}, \quad (5)$$

де c – параметр активаційної функції (для експоненційної сигмоїди звичайно $c = 1$);

k – кількість шарів мережі (без урахування вхідного шару);

N_x – розмірність вхідного сигналу;

N_y – розмірність вихідного сигналу;

N_{ni} – кількість нейронів у i -му шарі.

Щоб нейронна мережа змогла апроксимувати вихідну функцію, необхідне виконання умови $L_{\{x,y\}} \leq L_s$. Тоді для двошарової мережі, виходячи з формул (4) і (5), кількість прихованих нейронів $N_{\text{нmin}}^L$ не має бути менше [11]

$$N_{\text{нmin}}^L = \frac{L_{\{x,y\}}}{c^k \sqrt{N_x N_y}}. \quad (6)$$

Підставляючи у формулу (5) обчислені вище параметри, отримуємо: $N_{\text{нmin}}^L = 8$.

Таким чином, з урахуванням формул (3) і (6) мінімальна кількість нейронів прихованого шару двошарової гомогенної прямокутної нейронної мережі з функціями активації виду «експоненціальна сигмоїда» складе [11]

$$N_{\text{нmin}} = \max \{ N_{\text{нmin}}^w, N_{\text{нmin}}^L \}. \quad (7)$$

Таким чином, для вирішуваної задачі $N_{\text{нmin}} = 8$.

Уточнити кількість нейронів у прихованому шарі можна в процесі налаштування нейронної мережі за допомогою конструктивного алгоритму [12]. Відповідно до нього первинна кількість нейронів приймається рівною мінімальній кількості (розрахованої за формулою (7)). У разі невдалого навчання в прихований шар додається один нейрон, ваговим коефіцієнтам якого привласнюються випадкові значення. Додавання нейронів триває до тих пір, поки якість роботи нейромережі не досягне необхідного значення.

Далі було здійснено дослідження щодо підбору оптимальної архітектури нейронної мережі. При цьому кількість прихованих нейронів у експериментах починалась нарощуватися із значень, отриманих тільки за формулою (3). Результати зведено до таблиці (табл. 1).

Таблиця 1 – Результати розрахунків з використанням різних архітектур нейронної мережі

Кількість шарів	Кількість нейронів	Середня відносна помилка	Середня помилка за балами	Середнє
1	3	12 %	19 %	15,5 %
1	4	5 %	27 %	16,0 %
1	5	4 %	8 %	6,0 %
1	6	5 %	13 %	9,0 %
1	7	4 %	13 %	8,5 %
1	8	4 %	17 %	10,5 %
1	9	1 %	10 %	5,5 %
1	10	3 %	16 %	9,5 %
2	2 + 2	9 %	19 %	14,0 %
2	3 + 3	8 %	17 %	12,5 %
2	4 + 4	3 %	13 %	8,0 %
2	5 + 5	3 %	10 %	6,5 %
2	6 + 6	3 %	8 %	5,5 %
3	2 + 2 + 2	26 %	22 %	24,0 %
3	3 + 3 + 3	4 %	14 %	9,0 %
3	4 + 4 + 4	4 %	9 %	6,5 %
3	5 + 5 + 5	1 %	8 %	4,5 %
3	6 + 6 + 6	3 %	8 %	5,5 %

Як можна побачити, кращий результат забезпечують такі архітектури:

– за середньою похибкою: MLP 4x5x5x5x1 (4,5 %);

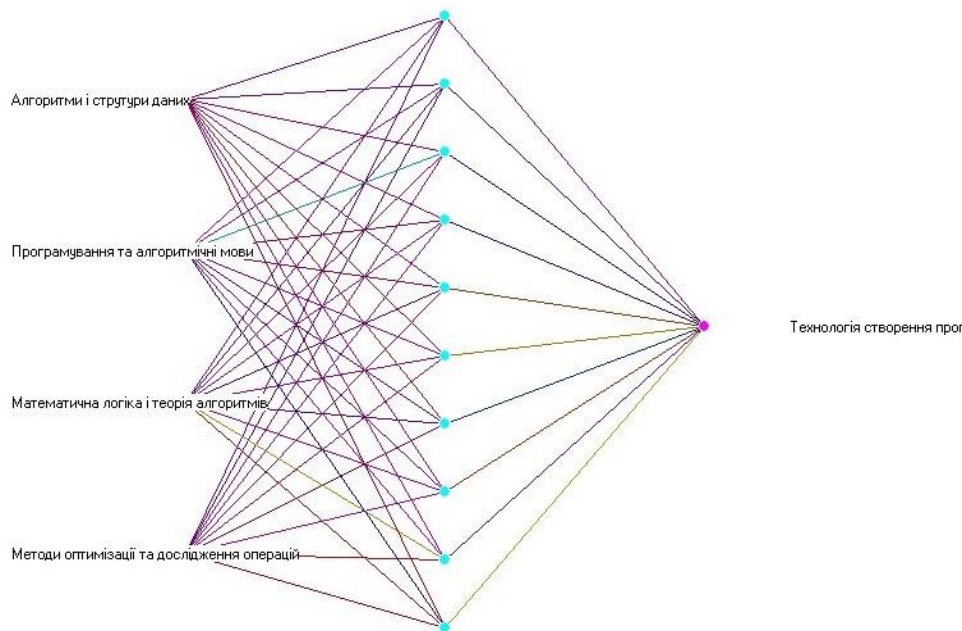


Рис. 1. Архітектура нейронної мережі MLP 4x10x1

– тільки за середньою відносною похибкою: MLP 4x9x1 або MLP 4x5x5x5x1 (1 %);

– тільки за середньою похибкою за балами: MLP 4x5x1, MLP 4x6x6x1, MLP 4x5x5x5x1 або MLP 4x6x6x6x1 (8 %).

Вочевидь, кращим будемо вважати архітектуру з трьома прихованими шарами з п'ятьома нейронами у кожному.

Формулювання алгоритму рішення. Оскільки для кожного конкретного набору даних співвідношення похибок прогнозування різних методів може відрізнятися від отриманих вище результатів, доцільно надати змогу користувачеві самостійно визначити переваги та недоліки кожного з методів (багатофакторної лінійної регресії, штучних нейронних мереж, k найближчих сусідів) для поточної задачі.

Алгоритм розв'язання поставленої задачі сформулюємо так.

1. Дослідник, спираючись на формули (2) – (7), задає граничні значення (параметри) для методу штучних нейронних мереж (мінімальну $N_{\text{нmin}}^L$ та максимальну $N_{\text{нmax}}^L$ кількість прихованих шарів, мінімальну $N_{\text{нmin}}$ та максимальну $N_{\text{нmax}}$ кількість нейронів у кожному прихованому шарі) та методу k найближчих сусідів (саме число k – діапазон значень від мінімального K_{min} до максимального K_{max}). Метод багатофакторної лінійної регресії зміни параметрів не передбачає.

2. Програмна система виконує розрахунок за кожним із методів, причому у кожному випадку повторює його задане число разів, вибираючи найкращий за сумарною помилкою (тобто де сумарна помилка мінімальна). Результати зводяться до таблиці з числом рядків N_s :

$$N_s = 1 + (N_{\text{нmax}}^L - N_{\text{нmin}}^L + 1) \cdot (N_{\text{нmax}} - N_{\text{нmin}} + 1) + (K_{\text{max}} - K_{\text{min}} + 1). \quad (8)$$

Число 1 на початку формули означає, що розрахунок за методом багатофакторної лінійної регресії проводиться рівно 1 раз.

3. Дослідник обирає найкращий, на його погляд, метод (як правило, за мінімальною сумарною помилкою, але можливі й інші критерії вибору).

4. Обраний метод (а у випадку вибору методу штучних нейронних мереж – обрана архітектура нейронної мережі) використовується для прогнозування оцінок того ж предмета для нової групи.

Вибір дисциплін, що забезпечують, не є явно пунктом наведеного алгоритму, оскільки здійснюється або безпосередньо з освітньої програми (її структурно-логічної схеми), або в результаті якихось попередніх досліджень. Дослідник повинен мати можливість обирати відсоток «навчаючої множини» для методів штучних нейронних мереж та k найближчих сусідів, тобто визначити, яка частка даних буде використана для навчання нейронної мережі та розрахунку помилок відповідно. Власне різновид нейронної мережі не обирається – це буде завжди перцептрон. Також не будуть обиратися метод навчання мережі (метод зворотного поширення помилок) та функція активації (експоненційна сигмоїда).

Отримані результати можна буде застосувати у роботі кафедри під час аналізу успішності студентів тощо.

Розробка спеціального застосунку. У процесі проектування інформаційної моделі системи мовою моделювання UML [4] створюються діаграми варіантів використання (рис. 2), класів (рис. 3), кооперації, послідовності, станів (рис. 4), діяльності та компонентів.




Рис. 2. Діаграма варіантів використання

«control», «CalcModule») і чотирьох допоміжних (з умовними іменами «LMFR», «MLP», «KNN» та «Data») [13].

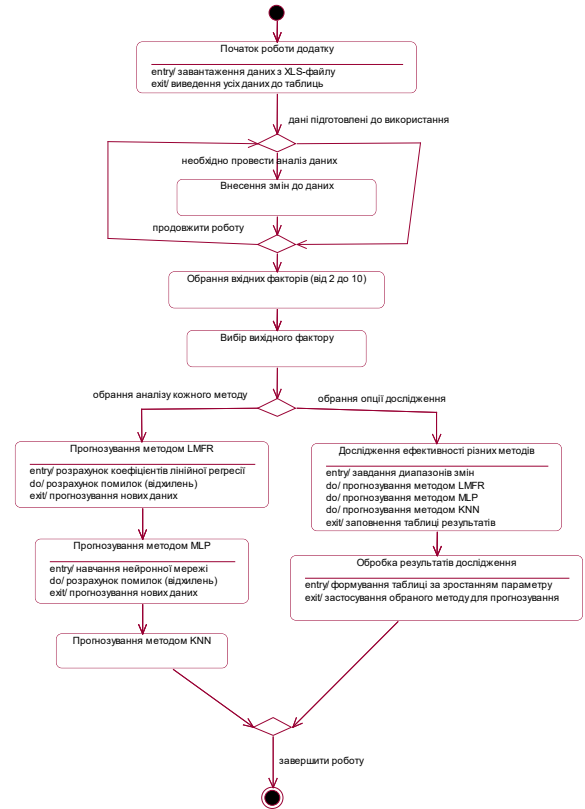


Рис. 4. Діаграма станів

У середовищі візуального програмування було розроблено додаток – систему підтримки прийняття рішень (рис. 5), що дозволяє здійснювати усі наведені раніше дії.

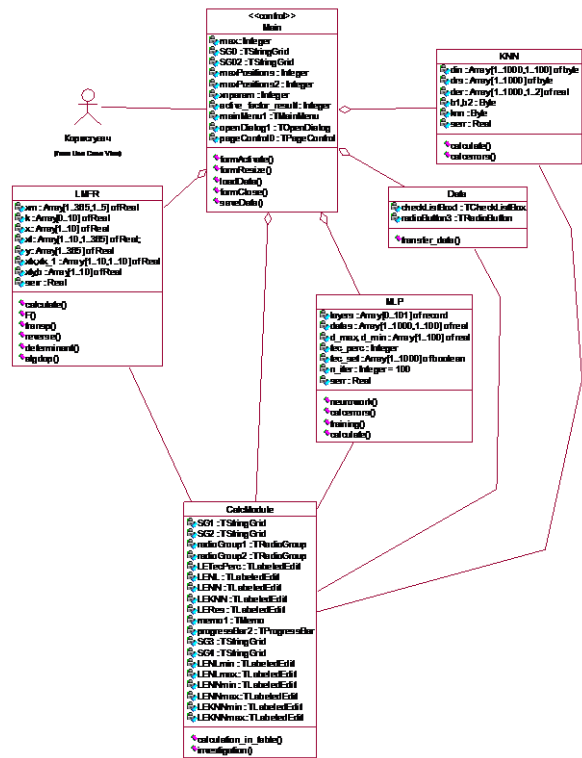


Рис. 3. Діаграма класів

Передбачається робота шести класів: двох основних («Main», керуючий клас – з атрибутом

Група	ПІБ	Історія	Економіка	Вступні Діагностика	Дисципліна	Алгоритми	Інформація	Програма	Математика	Економіка	Колібри	Програма	Колібри	Дисципліна	Філософія	Фізика	Математика	Англійська	Українська	Інформація	
DM133	Коваленко	75	79	75	75	60	55	73	65	75	55	90	70	55	55	64	90	75	75	67	54
DM133	Коваленко	50	100	90	90	90	55	80	80	78	90	90	50	50	55	52	90	52	90	76	69
DM133	Коваленко	75	75	100	75	90	64	90	67	75	90	75	75	100	76	55	55	76	90	75	75
DM133	Бордан	75	69	100	75	100	100	75	93	90	100	90	99	100	92	55	55	91	100	52	90
DM133	Гайда	75	56	70	75	85	76	75	75	75	100	75	75	90	77	60	55	76	75	75	90
DM133	Дзюба	60	75	80	75	75	75	75	75	75	75	75	75	75	92	60	55	79	90	65	91
DM133	Коваленко	75	90	90	90	90	75	80	75	99	95	61	92	65	55	75	90	90	81	78	75
DM133	Коваленко	69	56	75	55	55	70	55	61	55	55	55	75	79	58	55	55	64	61	55	61
DM133	Коваленко	76	83	71	75	75	83	80	69	75	88	67	90	75	78	55	55	75	90	75	77
DM133	Коваленко	75	75	91	75	90	59	75	62	75	90	69	75	92	76	55	55	76	90	65	90
DM133	Коваленко	68	56	76	75	75	75	75	75	75	97	75	75	92	60	55	55	79	90	65	91
DM133	Коваленко	64	75	80	75	75	75	80	82	60	98	77	90	95	79	55	55	77	65	65	63
DM133	Коваленко	100	55	83	75	75	75	75	75	75	90	60	90	79	57	55	55	61	90	55	90
DM133	Коваленко	75	90	75	75	75	75	80	75	90	70	55	84	92	55	55	55	70	75	77	55

Рис. 5 Завантажені таблиці даних

Результати розрахунків. Після завантаження усіх даних треба обрати перелік дисциплін, які впливають на результат, та власне дисципліну, оцінки з якої маємо спрогнозувати (рис. 6).

Після переходу до третьої вкладки усі вхідні дані автоматично будуть перероблені (рис. 7).

Стовпець 7 – вихідний фактор (оцінка з обраного предмета), стовпець 8 – результати розрахунків вихідного фактору, стовпець 9 – відносна різниця між наявними та розрахунковими (прогнозними) значеннями,

стовпець 10 – довідкова інформація про належність запису до навчальної («Teach») або тестувальної («Test») множини.

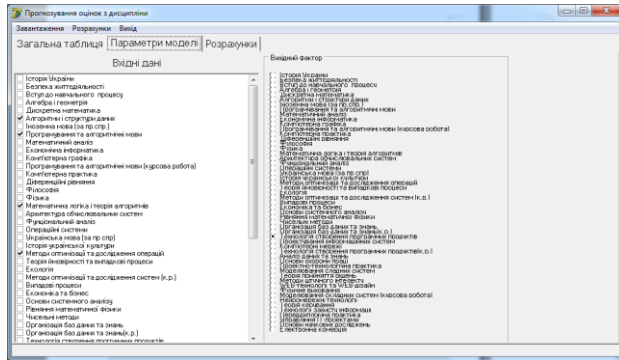


Рис. 6. Визначення факторів

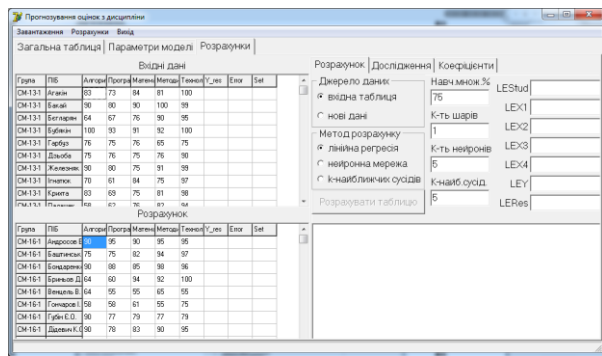


Рис. 7. Визначення факторів

Далі починаємо розрахунки усіма методами. По-перше, це метод багатofакторної лінійної регресії (рис. 8), який майже миттєво забезпечує користувача результатами (рис. 9).




Рис. 8. Головне меню застосунку

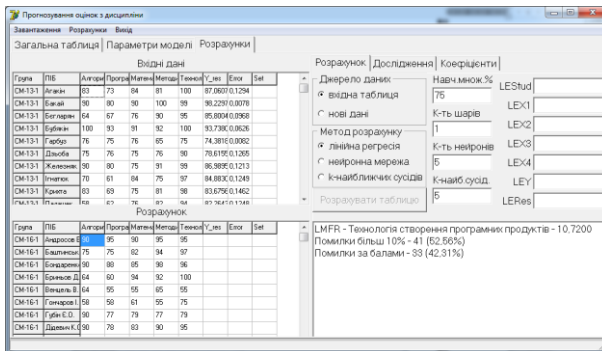


Рис. 9. Результати методу LMFR

Як можна побачити, цей метод створює значні помилки – близько 50 % за вхідною таблицею. Застосуємо цей же метод до нових даних шляхом вибору «Нові дані» та натискання кнопки «Розрахувати таблицю» (рис. 10). Помилки тут значно нижчі – 25 % за балами, але 40 % за відхиленням.




Рис. 10. Застосування методу LMFR до нових даних

Метод штучних нейронних мереж для одного прихованого шару з 5 нейронами (рис. 11) показує помилки близько 35 %. Застосування цього методу до нових даних видає 15 % (рис. 12).




Рис. 11. Результати методу MLP




Рис. 12. Застосування методу MLP до нових даних

Зміна архітектури нейронної мережі шляхом збільшення кількості шарів до двох, а кількості нейронів до десяти майже не впливає на результат: – на вхідних даних (рис. 13) маємо 35 %; – на нових даних (рис. 14) маємо 20 %.




Рис. 13. Застосування методу MLP-2 до нових даних




Рис. 16. Застосування методу KNN-5 до нових даних




Рис. 14. Застосування методу MLP-2 до нових даних

Результат дослідження отримаємо на рис. 17 у таблицях «Результати розрахунку». Таблиця ліворуч зображає дані за порядком розрахунку, а праворуч – з упорядкуванням за зростанням обраного поля. Як правило, це середня похибка (останній стовпець). Мінімальне значення середньої похибки – 31 % (для архітектури з трьома нейронами у прихованому шарі).

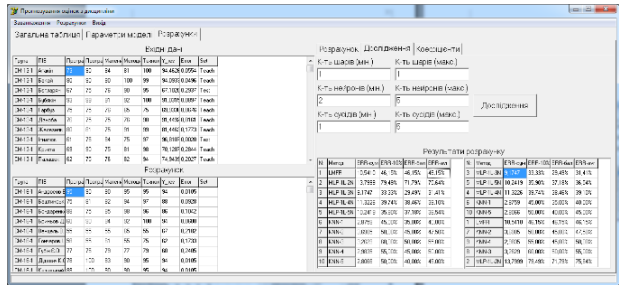


Рис. 17. Дослідження методів з MLP 4-1(2..5)

Метод k найближчих сусідів при заданні числа k рівним п'яти показує такі результати:

- на вхідних даних (рис. 15) маємо 60 %;
- на нових даних (рис. 16) маємо 45 %.

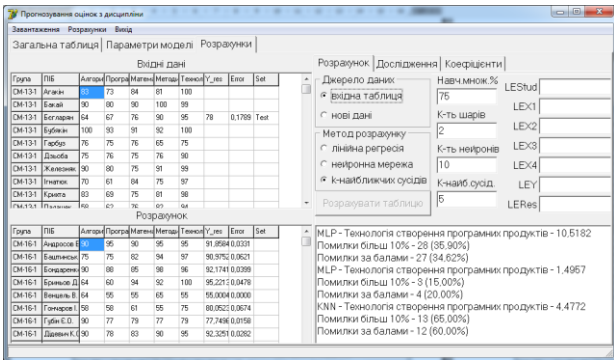


Рис. 15. Результати методу KNN-5

Далі розглянемо роботу розділу «Дослідження». Спочатку залишимо параметри дослідження такими, як пропонується за замовчуванням:

- мінімальна кількість шарів мережі: 1;
- максимальна кількість шарів мережі: 1;
- мінімальна кількість нейронів у кожному шарі мережі: 2;
- максимальна кількість нейронів у кожному шарі мережі: 5;
- мінімальне значення k у методі «сусідів»: 2;
- максимальне значення k у методі «сусідів»: 5.

- мінімальна кількість шарів мережі: 1;
- максимальна кількість шарів мережі: 2;
- мінімальна кількість нейронів у кожному шарі мережі: 2;
- максимальна кількість нейронів у кожному шарі мережі: 5;
- мінімальне значення k у методі «сусідів»: 2;
- максимальне значення k у методі «сусідів»: 5.

Результат дослідження отримаємо на рис. 18. Мінімальне значення середньої похибки також майже 31 % (для архітектури з п'ятьма нейронами у прихованому шарі).




Рис. 18. Дослідження методів з MLP 4-1(1..2)(2..5)

Знову змінюмо параметри дослідження:

- мінімальна кількість шарів мережі: 1;
- максимальна кількість шарів мережі: 2;
- мінімальна кількість нейронів у кожному шарі мережі: 2;
- максимальна кількість нейронів у кожному шарі мережі: 10;
- мінімальне значення k у методі «сусідів»: 2;
- максимальне значення k у методі «сусідів»: 5.

Результат дослідження наведено на рис. 19. Мінімальне значення середньої похибки також майже 27% (для архітектури з дев'ятьма нейронами у двох прихованих шарів).

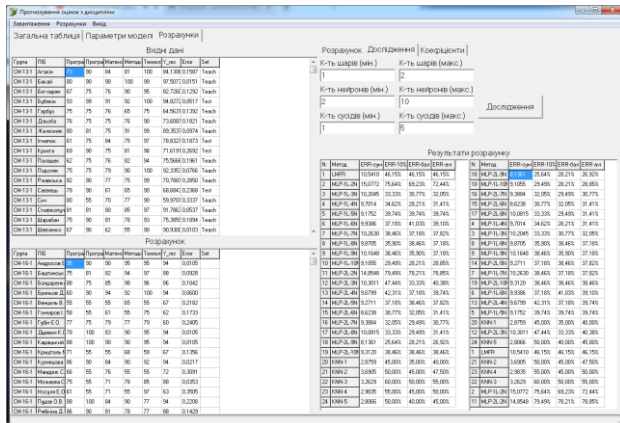


Рис. 19. Дослідження методів з MLP 4-(1..2)(2..10)

Користувач має можливість клацнути мишею на будь-якому рядку та обрати пункт у контекстному меню, потім або «Зберегти мережу у файлі», або «Застосувати до розрахунків», що дозволить отримати нові результати.

Далі проведемо ще декілька досліджень. Визначимо вплив дисциплін «Дискретна математика», «Алгоритми і структури даних», «Програмування та алгоритмічні мови» та «Математична логіка і теорія алгоритмів» на «Методи оптимізації та дослідження операцій». Розрахунок-дослідження за параметрами «один шар мережі – від двох до п'яти нейронів у кожному прихованому шарі» призводить до не дуже гарних результатів: найнижча похибка (35 %) – у методу найближчих сусідів. Розрахунок-дослідження за параметрами «один-два шарі мережі – від двох до десяти нейронів у кожному прихованому шарі» також не забезпечує гарних результатів: найнижча похибка – 34 %, одношаровий перцептрон з 10 нейронами у шарі. Однак застосування MLP-4-1-10-1 до нових даних з «МОДО» (СМ-16-1) показує тільки 20 % похибку.

Визначимо вплив дисциплін «Алгоритми і структури даних», «Програмування та алгоритмічні мови», «Математична логіка і теорія алгоритмів» та «Організація баз даних і знань» на «Проектування інформаційних систем». Розрахунок-дослідження за параметрами «один шар мережі – від двох до п'яти нейронів у кожному прихованому шарі» знову призводить до не дуже гарних результатів: найнижча похибка (35 %) – у

методу найближчого сусіда. Розрахунок-дослідження за параметрами «один-два шарі мережі – від двох до десяти нейронів у кожному прихованому шарі» також не забезпечує гарних результатів: найнижча похибка – 34 %, двошаровий перцептрон з 10 нейронами у шарі. Однак застосування MLP-4-10-10-1 до нових даних з «ПІС» (СМ-16-1) показує тільки 10 % похибку, що можна вважати гарним результатом.

Висновки. Проведені дослідження довели, що застосування низки математичних методів (лінійного регресійного аналізу, штучних нейронних мереж, найближчих сусідів) для прогнозування оцінок студентів з окремої дисципліни в залежності від якості засвоєння попереднього матеріалу призводить до задовільних результатів. Шляхом проведення серії числових експериментів підбрано оптимальну архітектуру нейронної мережі – перцептрон з трьома прихованими шарами з п'ятьма нейронами у кожному.

Отримані результати можна буде застосувати у роботі кафедри під час аналізу успішності студентів тощо.

Список літератури

1. Положення про внутрішню систему забезпечення якості освіти. URL: http://www.dgma.donetsk.ua/docs/acts/Положення_про_внутр_сист_т_заб_якості_ДДМА_2020_Сайт.pdf. (дата звернення: 21.11.2021).
2. Освітньо-професійна програма «Інтелектуальні системи прийняття рішень» першого рівня вищої освіти за спеціальністю № 124 «Системний аналіз» салузі знань № 12 «Інформаційні технології». URL: http://www.dgma.donetsk.ua/docs/kafedry/ispr/opp/Системний_аналіз_бакалавр.pdf (дата звернення: 21.11.2021).
3. Мельников О. Ю., Бобрик А. В. Постановка задачі дослідження впливу якості засвоєння попереднього матеріалу на прогнозування оцінок студентів з окремої дисципліни. *Сучасна освіта – доступність, якість, визнання: збірник наукових праць XIII Міжнародної науково-методичної конференції, 16–18 листопада 2021 року*. Краматорськ: ДДМА, 2021. С. 199–201.
4. Мельников О. Ю. *Об'єктно-орієнтований аналіз і проектування інформаційних систем: посібник для студентів спеціальностей «Системний аналіз» та «Інформаційні системи та технології» Вид. 3-є, перероб. та доп.* Краматорськ: ДДМА, 2020. 208 с.
5. *Deductor – продвинутая аналитика без программирования*. URL: <https://basegroup.ru/deductor/description> (дата звернення: 21.11.2021).
6. Мельников О. Ю. Прогнозування оцінок студентів з окремої дисципліни залежно від якості засвоєння попереднього матеріалу. *Сучасні інформаційні технології, засоби автоматизації та електропривод: матеріали V Всеукраїнської науково-технічної конференції*. Краматорськ: ДДМА, 2021. С. 297–300. <http://dspace.dgma.donetsk.ua/handle/DSEA/802> (дата звернення: 21.11.2021).
7. Галушкін А. І. *Нейрокомпьютеры. Кн.3: Учебное пособие для вузов*. Москва: ИПРЖР, 2000. 528 с.
8. Widrow B., Lehr M. A. 30 years of adaptive neural networks: perceptron, madaline and backpropagation. *Proceedings of the IEEE*. 1990. Vol. 78, №. 9. P. 1415–1442.
9. Горбань А. Н. и др. *Нейроинформатика*. Новосибирск: Наука, Сибирская издательская фирма РАН, 1998. 296 с.
10. Миркес Е. М. *Нейроинформатика: учеб. пособ.* Красноярск: КГТУ, 2002. 120 с.
11. Гітис В. Б. *Нейромережні технології: навчальний посібник*. Краматорськ: ДДМА, 2021. 248 с.
12. Wynne-Jones M. Node splitting: A constructive algorithm for feed-forward neural networks. *Neural Computing and Applications*. 1993. Vol. 1, №. 1. P. 17–22.

13. Мельников А. Ю. Прогнозирование изменения вклада преподавателя в работу кафедры и использованием методов интеллектуального анализа данных. *Информационные технологии и средства обучения*. 2018. № 1 (63). С. 266–287.

References (transliterated)

1. *Polozhennja pro vnutrishnju systemu zabezpečennja jakosti osvity* [Regulations on the internal system for ensuring the quality of education]. URL: http://www.dgma.donetsk.ua/docs/acts/Положення_про_внутр_сист_заб_якості_ДДМА_2020_Сайт.pdf. (accessed 21.11.2021).
2. *Osvitin'o-profesijna programa «Intelektual'ni systemy pryjnattja rishen'» pershogo rivnja vyshhoi' osvity za special'nistju № 124 «Systemnyj analiz» galuzi znan' № 12 «Informacijni tehnologii'»*. [Educational and professional program "Intelligent Decision Making Systems" of the first level of higher education in the specialty No. 124 "System Analysis" of the branch of knowledge No. 12 "Information Technologies"]. URL: http://www.dgma.donetsk.ua/docs/kafedry/ispr/opp/Системний_аналіз_бакалавр.pdf (accessed 21.11.2021).
3. Melnykov O. Ju., Bobryk A. V. Postanovka zadachi doslidzhennja vplyvu jakosti zasvojennja poperedn'ogo materialu na prognozuvannja ocinok studentiv z okremoi' dyscypliny. [Statement of the problem of studying the influence of the quality of assimilation of the previous material on the prediction of students' grades in a particular discipline]. *Suchasna osvita – dostupnist', jakist', vyznannja: zbirnyk naukovyh prac' XIII Mizhnarodnoi' naukovo-metodychnoi' konferencii, 16–18 lystopada 2021 roku*. [Proc. of the Int. Conf. "Modern education - accessibility, quality, recognition"]. Kramators'k, DDMA Publ., 2021, pp. 199–201.
4. Melnykov O. Ju. *Ob'jektivno-orijentovanyj analiz i projektuvannja informacijnyh system: posibnyk dlja studentiv special'nostej «Systemnyj analiz» ta «Informacijni systemy ta tehnologii'»*. Vyd. 3-je, pererob. ta dop. [Object-oriented analysis and design of information systems: a manual for students of the specialties "System Analysis" and "Information Systems and Technologies"]. Kramators'k, DDMA Publ., 2020. 208 p.
5. *Deductor – prodivnutaja analitika bez programmirovannja* [Deductor – advanced analytics without programming]. URL: <https://basegroup.ru/deductor/description> (accessed 21.11.2021).
6. Melnykov O. Ju. Prognozuvannja ocinok studentiv z okremoi' dyscypliny zalezho vid jakosti zasvojennja poperedn'ogo materialu. [Prediction of students' grades in a separate discipline, depending on the quality of mastering the previous material]. *Suchasni informacijni tehnologii', zasoby avtomatyzacii ta elektropryvod: materialy V Vseukrai'ns'koi' naukovo-tehnicnoi' konferencii'*. [Proc. of the Int. Conf. "Modern information technologies, automation equipment and electric drive"]. Kramators'k, DDMA Publ., 2021, pp. 297–300. <http://dSPACE.dgma.donetsk.ua/handle/DSEA/802> (accessed 21.11.2021).
7. Galushkyn A. Y. *Nejrokomputeri. Kn.3: Uchebnoe posobie dlja vuzov*. [Neurocomputers]. Moscow, YPRZhR Publ., 2000. 528 p.
8. Widrow B., Lehr M. A. 30 years of adaptive neural networks: perceptron, madaline and backpropagation. *Proceedings of the IEEE*. 1990, vol. 78, №. 9, pp. 1415–1442.
9. Gorban' A. N. at al. *Nejroinformatika*. [Neuroinformatics]. Novosibirsk, Nauka, Sibirskaja izdatel'skaja firma RAN Publ., 1998. 296 p.
10. Mirkes E. M. *Nejroinformatika: ucheb. posob.* [Neuroinformatics]. Krasnojarsk, KGTU Publ., 2002. 120 p.
11. Gitis V. B. *Nejromerezhni tehnologii': navchal'nyj posibnyk*. [Neural network technologies]. Kramators'k, DDMA Publ., 2021. 248 p.
12. Wynne-Jones M. Node splitting: A constructive algorithm for feed-forward neural networks. *Neural Computing and Applications*. 1993, vol. 1, №. 1, pp. 17–22.
13. Melnikov A. Ju. Prognozirovanie izmenenija vклада преподавателя в работу кафедры и использованием методов интеллектуального анализа данных. [Predicting the change in the teacher's contribution to the work of the department and the use of data mining methods]. *Informacijnye tehnologii i sredstva obuchenija*. [Information technology and learning tools]. 2018, № 1 (63), pp. 266–287.

Надійшла (received) 05.05.2022

Відомості про авторів / About the Authors

Мельников Александр Юрійович – кандидат технічних наук, доцент, Донбаська державна машинобудівна академія, доцент кафедри інтелектуальних систем прийняття рішень; м. Краматорськ, Україна; ORCID: <https://orcid.org/0000-0003-2701-8051>; e-mail: alexandr@melnikov.in.ua

Гітис Веніамін Борисович – кандидат технічних наук, доцент, Донбаська державна машинобудівна академія, доцент кафедри інтелектуальних систем прийняття рішень; м. Краматорськ, Україна; ORCID: <https://orcid.org/0000-0002-7434-8259>; e-mail: veniamin.gitis@gmail.com

Melnykov Oleksandr Yuriyovych – Candidate of Technical Sciences (PhD), docent, Donbas State Engineering Academy, Associate Professor of the Department of Intelligent Decision Making Systems; Kramatorsk, Ukraine; ORCID: <https://orcid.org/0000-0003-2701-8051>; e-mail: alexandr@melnikov.in.ua

Gitis Veniamin Borisovych – Candidate of Technical Sciences (PhD), docent, Donbas State Engineering Academy, Associate Professor of the Department of Intelligent Decision Making Systems; Kramatorsk, Ukraine; ORCID: <https://orcid.org/0000-0002-7434-8259>; e-mail: veniamin.gitis@gmail.com