

МАШИННА ОЦІНКА ЗНАТЬ СТУДЕНТІВ У СИСТЕМІ КЕРУВАННЯ ДИСТАНЦІЙНИМ НАВЧАННЯМ

А.С. Довбиш, В.О. Любчак, С.О. Петров
Сумський державний університет

Пропонується класифікаційний алгоритм машинної оцінки знань студентів при тестовому контролі, який є складовою частиною алгоритму функціонування мультиагентної системи керування дистанційним навчанням, розробленим у рамках інформаційно-екстремальної інтелектуальної технології.

ВСТУП ТА ПОСТАВЛЕННЯ ЗАВДАННЯ

Навчальний процес будемо розглядати як органічне поєднання двох динамічних процедур – подання та виведення знань. Реалізація першої процедури шляхом транспортування інформації у рамках сучасного інформаційно-освітнього інформаційного середовища вищого навчального закладу не викликає ускладнень [1]. Реалізація другої процедури потребує розроблення інтелектуальної складової адаптивної системи керування дистанційним навчанням (СКДН), що пов'язано з моделюванням викладачем когнітивного процесу прийняття рішень. При цьому функціональна ефективність СКДН суттєво залежить від алгоритму персоніфікації знань студентів. На жаль, у переважній більшості відомих СКДН на етапі контролю знань використовуються математично не обґрунтовані системи тестування, що базуються, як правило, на однорівневій адитивній системі оцінок і не дозволяють об'єктивно відбивати знання студентів [2-5]. У праці [6] розглядається реалізація нелінійної оціночної функції тестів на базі багатопарових нейронних мереж з метою побудови вирішальних правил, що лінійно розділяються. Але при цьому питання оптимального генерування тестів не розглядається. Один із перспективних шляхів вирішення проблеми машинної оцінки знань студентів полягає у застосуванні для синтезу адаптивної СКДН ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІТ) [7,8], яка ґрунтується на прямій оцінці інформаційної спроможності системи за умов нечіткої компактності реалізації образу і обмеженого обсягу навчальної вибірки. Тому у статті задача оптимізації дидактичних параметрів генерування тестів розглядається у рамках ІЕІТ синтезу машинного агента “ВИКЛАДАЧ”, що відбувається в режимі навчання СКДН, а задача оцінки знань – у рамках синтезу агента “СТУДЕНТ”, що відбувається в режимі екзамену, тобто безпосередньої персоніфікації студента.

Розглянемо постановку задачі машинної оцінки знань студентів за результатами тестування у рамках ІЕІТ.

Нехай за результатами тестового контролю сформовано апріорно класифіковану навчальну матрицю типу «об'єкт-властивість» $\| y_{m,i}^{(j)} \mid m = \overline{1, M}; i = \overline{1, N}; j = \overline{1, n} \|$, де M – кількість класів розпізнавання (рівнів знань); N – кількість тестів за матеріалом поточного модуля дистанційного курсу; n – обсяг навчальної вибірки (кількість реалізацій образу). Сформовано структурований вектор просторово-часових параметрів функціонування СКДН $g = \langle d_m, x_m, \delta, k_B, k_3 \rangle$ з відповідними обмеженнями, де

d_m , x_m – фенотипні параметри, що визначають геометрію розбиття простору ознак на класи розпізнавання; δ – генотипний параметр поля контрольних допусків; k_B , k_Z – генотипні дидактичні параметри СКДН – коефіцієнти валідності та значущості тестів. Ефективність навчання СКДН будемо оцінювати інформаційним критерієм функціональної ефективності (КФЕ).

Треба у рамках ІЕІТ:

1) На етапі навчання СКДН, під яким розуміється проектування та супроводження дистанційного курсу, за результатами машинного тестування побудувати оптимальні вирішальні правила для гіперсферичного класифікатора шляхом цілеспрямованої оптимізації відповідних координат вектора g за умови, що усереднений за алфавітом класів інформаційний КФЕ навчання СКДН набуває глобального максимуму в робочій області визначення його функції

$$E^* = \frac{1}{M} \sum_{m=1}^M \max_G E_m,$$

де E_m – КФЕ навчання системи розпізнавати реалізації класу X_m^o ; G – область допустимих значень параметрів функціонування СКДН.

2) На етапі екзамену визначити належність вектора-реалізації рівня знань слухача до відповідного класу із заданого алфавіту $\{X_m^o\}$.

МАТЕМАТИЧНА МОДЕЛЬ СКДН

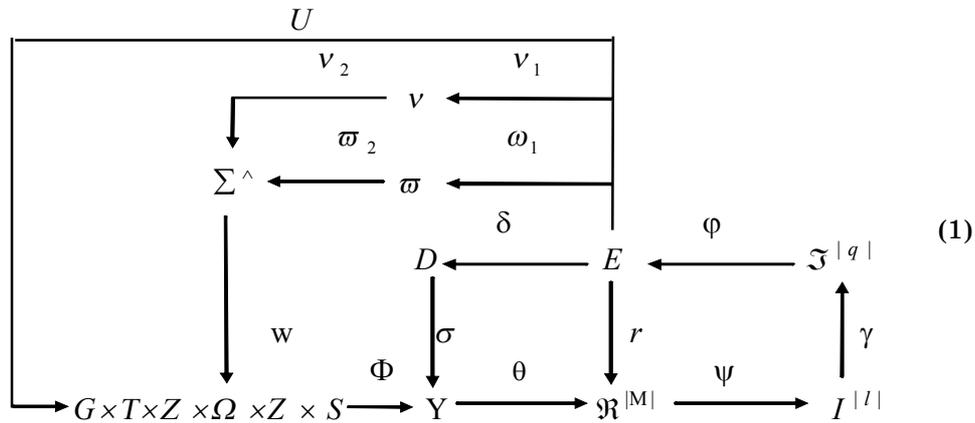
Математичний вхідний опис СКДН, що оптимізує параметри генерування тестів, подамо у вигляді теоретико-множинної структури

$$\Delta_B < G, T, \Omega, Z, S, Y, \Phi > ,$$

де G – множина вхідних сигналів (множина тестів); T – множина моментів зняття даних (результатів тестування); Ω – простір ознак розпізнавання (окремі відповіді на запитання); Z – множина функціональних станів системи (рівнів знань слухача); S – множина оцінок знань; Y – вибіркова множина (апріорно класифікована навчальна матриця); $\Phi : G \times T \times \Omega \times Z \times S \times Y$ – оператор виходу, який формує навчальну матрицю.

Категорійну модель СКДН подамо у вигляді діаграми відображення множин, що застосовуються в процесі оптимізації дидактичних параметрів генерування тестів.

У діаграмі (1) оператор $\theta : Y \rightarrow \tilde{\mathfrak{R}}^{|M|}$ будує нечітке розбиття $\tilde{\mathfrak{R}}^{|M|}$, яке в загальному випадку допускає перетин класів розпізнавання, а оператор $\Psi : \mathfrak{R}^{|M|} \rightarrow I^{|l|}$ перевіряє основну статистичну гіпотезу $\gamma_1 : y_{m,i}^{(j)} \in X_m^o$, де $I^{|l|}$ – множина гіпотез, яка для $M = 2$, крім основної, включає альтернативну гіпотезу $\gamma_2 : y_{m,i}^{(j)} \notin X_m^o$. Оператор γ визначає множину точнісних характеристик $\mathfrak{Z}^{|q|}$, де $q = l^2$, а оператор ϕ обчислює значення інформаційного критерію оптимізації, які є елементами терм-множини E .



Оператор r коригує у рамках базового алгоритму навчання LEARNING [8] розбиття $\mathfrak{R}^{|M|}$ в процесі оптимізації геометричних параметрів контейнерів класів розпізнавання, що відновлюються в радіальному базисі дискретного простору ознак розпізнавання. Крім контура базового алгоритму навчання, діаграма (1) містить так само контури оптимізації контрольних допусків, в якому терм-множина D – значення системи контрольних допусків на ознаки розпізнавання, і оптимізації дидактичних параметрів генерування тестів, в яких ω і v – множини значень коефіцієнтів валідності k_B і значущості k_3 відповідно. Тут Σ^\wedge – відкрита послідовність тестів, що генерується. Оператор U регламентує процес навчання СКДН.

Як критерій функціональної ефективності навчання СКДН розглянемо модифікацію інформаційної міри Кульбака для рівноймовірних гіпотез, що характеризує найбільш важкий у статистичному розумінні випадок прийняття рішень [7]:

$$\begin{aligned}
 E_m^{(k)} &= \frac{1}{2} \log_2 \left(\frac{D_1^{(k)} + D_2^{(k)}}{\alpha^{(k)} + \beta^{(k)}} \right) \left[(D_1^{(k)} + D_2^{(k)}) - (\alpha^{(k)} + \beta^{(k)}) \right] = \\
 &= \log_2 \left(\frac{2 - (\alpha^{(k)} + \beta^{(k)})}{\alpha^{(k)} + \beta^{(k)}} \right) \left[2 - (\alpha^{(k)} + \beta^{(k)}) \right],
 \end{aligned}
 \tag{2}$$

де $D_1^{(k)}$, $D_2^{(k)}$, $\alpha^{(k)}$, $\beta^{(k)}$ – одержані на k -му кроці навчання СКДН точнісні характеристики процесу навчання: перша та друга достовірності, помилки першого та другого роду відповідно.

Таким чином, критерій (2) є нелінійним функціоналом від точнісних характеристик процесу навчання. Крім того, його функція є неоднозначною, що потребує знання робочої (допустимої) області її визначення. Оскільки навчальна вибірка є обмеженою за обсягом, то замість помилок першого та другого роду на практиці розглядаються їх оцінки: $\alpha^{(k)} = K_1^{(k)} / n$, $\beta = K_2 / n$, де K_1 – кількість реалізацій класу X_1^0 , які не знаходяться в k -му контейнері цього класу, що відновлюється на k -му кроці навчання; $K_2^{(k)}$ – кількість “чужих” реалізацій, які

знаходяться в k -му контейнері класу X_m^o . Після підстановки цих оцінок у (2) отримуємо робочу формулу КФЕ за Кульбаком

$$E_m = \frac{1}{n} \log_2 \left\{ \frac{2n + 10^{-r} - [K_1^{(k)} + K_2^{(k)}]}{[K_1^{(k)} + K_2^{(k)}] + 10^{-r}} \right\} * [2n - (K_1^{(k)} + K_2^{(k)})], \quad (3)$$

де 10^{-r} – будь-яке мале додатне число, яке дозволяє уникнути появи нуля в знаменнику дробу.

АЛГОРИТМ ОПТИМІЗАЦІЇ

Алгоритм оптимізації дидактичних параметрів генерування тестів у рамках ІЕІТ подамо у вигляді ітераційної процедури наближення глобального максимуму інформаційного КФЕ навчання СКДН до його граничного значення

$$k_3^* = \arg \max_{G_1} \{ \max_{G_2} \{ \max_{G_3} \{ \max_{G_4} \{ \max_{G_5} E_m \} \} \} \} \}, \quad (4)$$

де G_1, G_2, G_3, G_4, G_5 – допустимі області значень параметрів функціонування $k_3, k_B, \delta, x_m, d_m$ відповідно.

Вхідними даними алгоритму оптимізації є апріорно класифікована навчальна матриця $\| y_{m,i}^{(j)} \mid m=1, M; i=1, N; j=1, n \|$, а вихідними – оптимальні параметри функціонування СКДН. Розглянемо схему алгоритму оптимізації.

Крок 1 Формування лічильника значень коефіцієнта значущості

$$K_3 : s = 0.$$

Крок 2

$$s := s + 1.$$

Крок 3 Формування лічильника значень коефіцієнта валідності

$$K_B : b = 0.$$

Крок 4

$$b := b + 1.$$

Крок 5 Обнулюється лічильник кроків зміни параметра $\delta : l := 0$.

Крок 6 Запускається лічильник $l := l + 1$ і обчислюються нижні та верхні контрольні допуски для всіх ознак

$$\{A_{HK,i}[l] := y_{m,i} - \delta [l]\} \quad \text{і} \quad \{A_{BK,i}[l] := y_{m,i} + \delta [l]\}, \\ i = \overline{1, N} \quad \text{відповідно.}$$

Крок 7 Реалізується базовий алгоритм навчання [7].

Крок 8 Якщо $E_1^*[l] \geq E_1^*[l-1]$, то виконується крок 9, інакше – крок 10.

Крок 9 Якщо $\delta \leq \delta_H / 2$, то виконується крок 6, інакше – крок 10.

Крок 10

$$\{A_{HK,i}^* := A_{HK,i}[l-1]\}; \{A_{BK,i}^* := A_{BK,i}[l-1]\}, \quad i = \overline{1, N};$$
$$E_1^* := E_1^*[l-1] \text{ і крок 4.}$$

Крок 11 Обчислюється $E[b]$ і виконується крок 4.

Крок 12 Якщо $K_B[b] \in G_{K_B}$, то $\max_{\{b\}}\{K_B[b]\}$ і виконується крок 2.

Крок 13 Обчислюється $E[s]$ і виконується крок 2

Крок 14 Якщо $K_3[s] \in G_{K_3}$, то $\max_{\{s\}}\{K_3[s]\}$ і ЗУПИН.

ПРИКЛАД РЕАЛІЗАЦІЇ АЛГОРИТМУ ОПТИМІЗАЦІЇ

Розглянемо оптимізацію параметрів генерування тестів на прикладі оцінки знань студентів за навчальною дисципліною «Інтелектуальні системи», що викладається студентам спеціальності «Інформатика» в Сумському державному університеті. За результатами тестування знань студентів за навчальний модуль «Методи подання знань» було сформовано вхідну апріорно класифіковану навчальну матрицю $\|y_{m,i}^{(j)}\|$ з параметрами: $m = \overline{1, 4}$; $i = \overline{1, 24}$; $j = \overline{1, 40}$. У процесі реалізації алгоритму (4) за критерієм (3) було побудовано оптимальні контейнери для чотирьох класів розпізнавання: X_1^o – “відмінно”, X_2^o – “добре”, X_3^o – “задовільно” і X_4^o – “незадовільно”. На рис. 1-4 показано результати оптимізації контейнерів цих класів, де заштрихована ділянка свідчить про робочу (допустиму) область визначення функції критерію оптимізації (3).

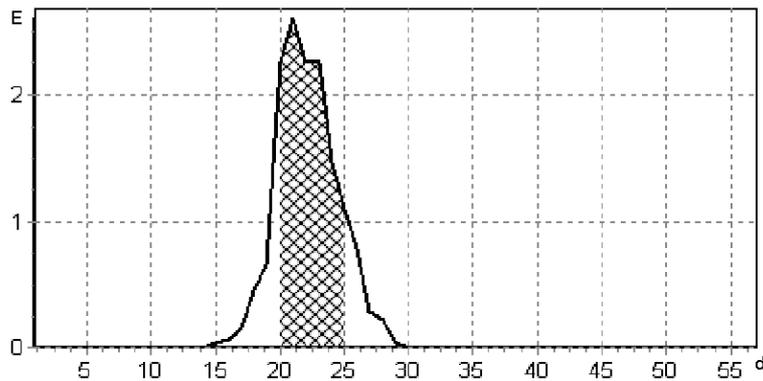


Рисунок 1– Залежність критерію оптимізації від радіуса контейнера класу X_1^o

Згідно з рис. 1 оптимальний радіус гіперсферичного контейнера, який дорівнює $d_1^* = 21$ у кодових одиницях Хеммінга, визначається як екстремальне значення глобального максимуму функції критерію оптимізації ($E_1^* = 2,45$) в робочій області її визначення.

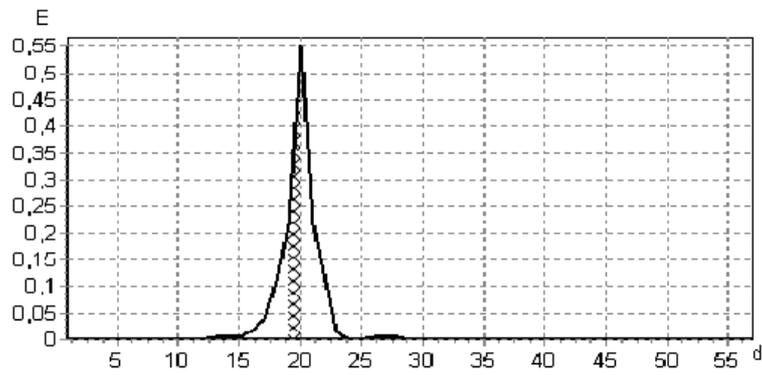


Рисунок 2– Залежність критерію оптимізації (3)
від радіуса контейнера класу X_2^0

Аналіз рис.2 показує, що радіус оптимального контейнера дорівнює $d_2^* = 20$ кодовим одиницям Хеммінга при максимальному значенні КФЕ навчання СКДН $E_2^* = 0,55$.

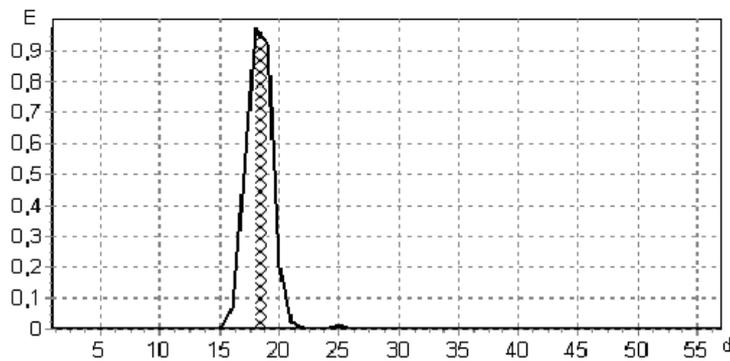


Рисунок 3– Залежність критерію оптимізації (3)
від радіуса контейнера класу X_3^0

Аналіз рис. 3 показує, що радіус оптимального контейнера дорівнює $d_3^* = 17$ кодовим одиницям Хеммінга при значенні КФЕ навчання СКДН $E_3^* = 0,95$.

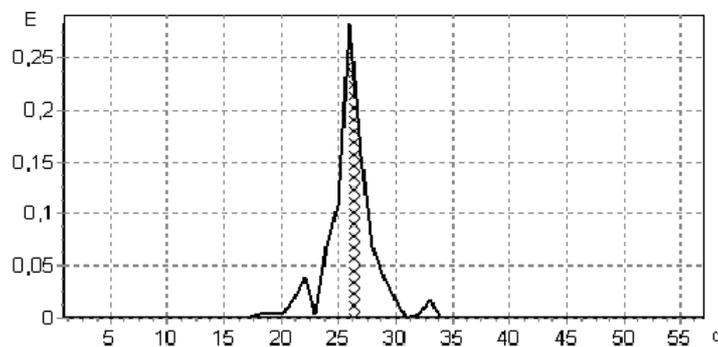


Рисунок 4– Залежність критерію оптимізації (3)
від радіуса контейнера класу X_4^0

Як видно з рис. 4, при оптимізації контейнера класу X_4^o одержано $d_4^* = 26$ при відповідному значенні КФЕ навчання СКДН $E_4^* = 0,28$.

Таким чином, експериментально підтверджено можливість відновлення в процесі навчання агента «ВИКЛАДАЧ» оптимального в інформаційному розумінні класифікатора. З іншого боку, аналіз значень глобальних максимумів КФЕ навчання (рис. 1-4) показує, що вони в робочій області їх визначення не є граничними, тобто оптимальний класифікатор не є безпомилковим за навчальною матрицею. Це потребує оптимізації інших просторово-часових параметрів функціонування СКДН, які впливають на її асимптотичні точнісні характеристики.

ПЕРСПЕКТИВИ УДОСКОНАЛЕННЯ ЗАПРОПОНОВАНОГО МЕТОДУ СИНТЕЗУ СКДН

Подальше удосконалення запропонованого методу синтезу адаптивної мультиагентної СКДН у рамках ІЕІТ полягає в побудові безпомилкового за навчальною матрицею класифікатора шляхом оптимізації інших функційних і технологічних просторово-часових параметрів функціонування, які впливають на асимптотичні (екстремальні) точнісні характеристики процесу навчання системи. При цьому збільшення кількості параметрів оптимізації за ітераційною процедурою (4) призведе до зменшення оперативності реалізації алгоритму навчання СКДН. Це потребує розроблення гібридних алгоритмів навчання СКДН, що, наприклад, базуються на генетичних алгоритмах[9]. Іншою задачею, що потребує свого розв'язання, є машинна кластеризація вхідних векторів-реалізацій образу (результатів тестування) з метою формування апріорно класифікованої вхідної навчальної матриці, що до теперішнього часу залишається виключно функцією викладача. Крім того, для вирішення проблеми оптимального генерування тестів, яка є ключовою при автоматизації створення навчально-методичного забезпечення навчального процесу, важливого значення набуває задача конструювання універсальної оціночної функції.

ВИСНОВКИ

1 Сформовано і розв'язано в рамках ІЕІТ задачу оптимізації дидактичних параметрів функціонування мультиагентної СКДН, що дозволяє розробнику дистанційного курсу обґрунтовано визначати вагові коефіцієнти значущості та валідності тестів для машинного контролю знань слухачів.

2 Результати фізичного моделювання алгоритму оптимізації дидактичних параметрів генерування тестів показують, що для побудови чіткого розбиття простору ознак на класи розпізнавання (рівні знань) необхідно здійснювати у рамках ІЕІТ оптимізацію за інформаційним КФЕ інших просторово-часових параметрів функціонування СКДН, що впливають на асимптотичні (екстремальні) точнісні характеристики процесу навчання машинного агента «Викладач».

SUMMARY

There is offered a classification algorithm of machine examination of students under test control, which is a component of algorithm functioning of multi-agent control system of e-Learning, which has been developed in the context information-extreme intellectual technology.

СПИСОК ЛІТЕРАТУРИ

1. Гриценко В.И., Кудрявцева С.П. Колос В.В., Веренич Е.В. Дистанционное обучение: Теория и практика. – Киев: Наукова думка, 2004. – 376 с.
2. Евтюхин Н.В. и др. Современное состояние методов тестирования знаний и умений за рубежом и в России // Инновации в образовании. – 2004. – № 1. – С. 27–38.

3. Попов Д.И. Оценка знаний в дистанционном обучении // Материалы Восьмой международной конференции «Открытое образование в России XXI века». – Москва: МЭСИ, 2000. – 188 с.
4. Похолков Ю.П. Проблемы и основные направления совершенствования инженерного образования // Alma Mater. Вестник высшей школы. – 2003. – №10. – С. 3 – 8.
5. Аванесов В.С. Научные основы тестового контроля знаний. – М.: Исследовательский центр, 1994. – 135 с.
6. Мухамедиев Р.И. Ограниченность одноуровневых аддитивных моделей оценивания // Вісник Сумського державного університету. – 2006. – №4(88). – С. 17-23.
7. Краснопопосовський А.С. Інформаційний синтез інтелектуальних систем керування: Підхід, що ґрунтується на методі функціонально-статистичних випробувань. – Суми: Видавництво СумДУ, 2004. – 261с.
8. Гриценко В.И., Довбыш А.С., Любчак В.А. Информационный синтез адаптивной мультиагентной системы управления дистанционным обучением. – УсиМ. – 2006. – №6. – С. 4-6, 25.
9. Рідкокаша А.А., Голдер К.К. Основы систем штучного інтелекту: Навчальний посібник. – Черкаси: Відлуння-Плюс, 2002. – 240с.

А.С. Довбиш, д-р техн. наук, проф.
Сумський державний університет

В.О. Любчак, канд. фіз.-мат. наук, доцент
Сумський державний університет

С.О. Петров, аспірант
Сумський державний університет

Надійшла до редакції 6 квітня 2007 р