

Intelligent information systems

УДК 004. 932.2:004.93'1

doi: 10.20998/2522-9052.2020.1.17

В. О. Гороховатський¹, Д. В. Пупченко¹, Н. І. Стяглик²¹ Харківський національний університет радіоелектроніки, Харків, Україна² Харківський навчально-науковий інститут ДВНЗ Університет банківської справи, Україна

ДОСЛІДЖЕННЯ ТРАНСФОРМАЦІЙ ПРОСТОРУ ДАНИХ ПРИ НАВЧАННІ МЕРЕЖІ КОХОНЕНА У МЕТОДАХ СТРУКТУРНОЇ КЛАСИФІКАЦІЇ ЗОБРАЖЕНЬ

Анотація. Предметом досліджень статті є модифікація засобів навчання мережі Кохонена задля класифікації зображень у системах комп'ютерного зору. **Метою** є визначення нового простору даних для навчання мережі та створення ефективного методу класифікації на основі множини дескрипторів ключових точок. **Завдання:** застосування нейронної мережі Кохонена для навчання системи класифікації у визначеному просторі даних, трансформація простору даних навчання мережі, вивчення адаптаційних можливостей і оцінювання ефективності функціонування мережі засобами програмного моделювання. **Методами** є: інтелектуальний аналіз даних, апарат структурної класифікації зображень, детектор ORB для визначення дескрипторів ключових точок, засоби навчання мережі Кохонена, програмне моделювання. Отримані такі **результати**. Запропоновано моделі трансформації даних, які підвищують результативність навчання. Проведено порівняльний аналіз розроблених методів навчання та класифікації. Здійснена програмна реалізація системи класифікації, експериментально проведено дослідження її ефективності та оцінювання часу оброблення. **Висновки.** Наукова новизна дослідження полягає в удосконаленні методів структурної класифікації з використанням навчання мережі Кохонена шляхом впровадження нового простору даних на базі центрів описів еталонів та згортання даних, що сприяє забезпеченню високої результативності класифікації при достатній швидкодії та дає можливість використовувати модифіковані методи у застосунках реального часу. **Практичну значимість** роботи складають отримані моделі програмного забезпечення для оцінювання ефективності класифікаторів у системах комп'ютерного зору, підтверджена ефективність розробок на прикладах баз даних зображень.

Ключові слова: комп'ютерний зір; структурне розпізнавання зображень; ключові точки зображення; дескриптор; детектор ORB; мережа Кохонена; навчання мережі; простір даних; програмне моделювання; база зображень.

Вступ

У комп'ютерних системах розпізнавання візуальних об'єктів визначними показниками є результативність та час оброблення. У зв'язку з цим у прикладних задачах набули поширення методи структурної класифікації зображень, побудовані на вживанні нейронних мереж для виявлення закономірностей на множині ознак структурних описів бази зразків [1-3]. Останнім часом впроваджуються структурні методи, засновані на детектуванні ключових точок (КТ) зображень [3-6]. КТ – це числовий вектор (дескриптор), що координатно зафіксований у точці зображення і відображає властивості деякого околу. Основні переваги сучасних детекторів, таких як ORB, BRISK [5, 6], полягають в забезпеченні високої швидкодії при порівняльній або кращій точності, ніж у їх аналогів SIFT та SURF, за рахунок істотного спрощення процесу обробки впровадженням дескрипторів бінарного типу.

Цікавим для науки про дані є вивчення адаптаційних властивостей і параметричних характеристик нейронних мереж стосовно навчання в задачах класифікації зображень за множиною дескрипторів КТ [7-9], де спостерігається необмежена різноманітність аналізованих даних, важливим є також дослідження ефективності схем навчання мереж, які враховують ступінь близькості елементів різних класів у просторі ознак.

Імплементация мереж Кохонена у процес класифікації дає можливість універсально і з успіхом на-

лаштуватися на довільні набори візуальних даних [2, 7]. Якість класифікації напряму залежить від результатів навчання мережі на множині описів навчальної вибірки. Провідним для класифікації є вивчення можливостей і властивостей процесу навчання нейронної мережі в плані найбільш ефективного використання чи трансформації простору даних, а також дослідження поглиблених схем навчання.

Метою роботи є створення високоєфективного методу класифікації в межах бази еталонів на основі детектування дескрипторів КТ та визначення нового простору даних для навчання мережі. Завданнями роботи є застосування нейронної мережі Кохонена для навчання системи класифікації у визначеному просторі даних, вивчення адаптаційних можливостей і оцінювання ефективності функціонування мережі засобами програмного моделювання.

Класифікація на основі навчання мережі Кохонена

Нехай $W = \{x | x \in R^n\}$, $W \subseteq R^n$ – простір структурних ознак (дескрипторів КТ) зображень. База описів еталонів $Z \subset W$ задана як множина $Z = \{Z^j\}_{j=1}^J$, $s_j = \text{card } Z^j$, $s = \text{card } Z$, $s = \sum_j s_j$. Кожна ознака $x_i^j \in Z^j$ асоціюється з деяким еталонем Z^j в плані належності до його складу, бо база зразків задана. Основною задачею навчання мережі є налагодження класифікатора на ефективне використання розміщеної в описах еталонної інформації.

Розглянемо навчання як послідовність етапів.

1. Виберемо елементи навчальної множини у вигляді сукупності $Z = \{Z^j\}_{j=1}^J$ описів усіх s елементів бази еталонів.

2. Ініціюємо матрицю $M = \{m_j\}_{j=1}^J$ ваг, рядками якої є сформовані вектора нейронів m_j – центрів класів так, що $m_j = x_i^j$, $x_i^j \in Z^j$, де i – номер довільного вектора із класу зразків Z^j .

3. Виберемо поточний елемент $z \in Z$, для кожного $j \in [1, 2, \dots, J]$ обчислимо відстань $q_j = \rho(z, m_j)$ і визначимо клас d нейрона-переможця: $d = \arg \min_j q_j$.

4. Обчислимо зміни ваг для нейронів вихідного шару мережі

$$\Delta m_j = h(j, d, t) \cdot \eta \cdot (z - m_j),$$

де η – коефіцієнт швидкості навчання; $h(j, d, t)$ – значення функції околиці для нейрона з номером j в момент часу навчання t ; зазвичай $h(j, d, t) = \exp[-\rho(j, d) / \sigma(t)]$ визначають у вигляді гаусової функції, а радіус $\sigma(t) = 1 / \exp(t^{-2})$ околиці зменшують зі збільшенням параметра t , $t = 1, \dots, s$.

5. Коректуємо матрицю ваг $M = M + \Delta M$ на кроці t .

6. Продовжуємо навчання (п. 3-5) до завершення списку Z .

7. Перевіряємо виконання умови припинення навчання. При невиконанні умови продовжуємо навчання, вибір даних із набору Z здійснюється у фіксованому або випадковому порядку.

Застосуємо поширений критерій зупинки навчання у вигляді фіксованої кількості ітерацій [7]. Цей вибір зроблено для оцінювання та порівняння часу навчання у сформованих просторах даних.

У результаті навчання отримуємо систему, адаптовану для розпізнавання довільних структурних описів на підставі навчальної вибірки бази еталонів. Вибір метрики у п. 3 визначається простором дескрипторів і способом формування центрів. Для здійснення навчання у експериментах використаємо квадрат евклідової метрики, зважаючи на те, для бінарних ознак значення метрики Хемінга та евклідової відстані співпадають.

Якість класифікації безпосередньо залежить від результатів навчання системи і від змісту структурних описів навчальної вибірки.

Розглянемо прикладні варіанти модифікації для визначення простору навчальних даних:

а) множини дескрипторів для кожного зразка;

б) множини дескрипторів зразків, для яких попередньо застосовано процедури формування центрів класів [2];

в) центри для кожного зразка класу; цей варіант відрізняється від б) тим, що центри кожного зразка вважаються самостійною одиницею у мережі, на якій проходить навчання і класифікація;

г) використання процедури згортки для множини дескрипторів кожного зразка.

Ефективність класифікації безпосередньо залежить від таких факторів: початкова база даних, простір даних для навчання, застосовані методи попередньої обробки (метод формування дескрипторів чи центрів), метрика для порівняння дескрипторів, кортеж адаптованих нейронів. Критерієм для оцінювання якості класифікації (значення помилки) виберемо величину, що підраховує частку елементів навчальної вибірки Z , що за результатом класифікації потрапили «не в свої» класи:

$$\beta = \sum_{j=1}^J (s_j - a_j) / s, \quad (1)$$

де a_j – кількість ознак із загальної їх кількості s_j в описі еталона Z^j , віднесених у процесі класифікації до класу j . Значення β відображає рівень помилкових рішень при класифікації множини Z . Чим ближче β до нуля, тим вище досягнуто якість класифікації на навчальній вибірці.

Способи трансформації простору для навчального процесу мережі

3 огляду на бінарне подання дескрипторів ORB, для кожного еталонного опису Z^i визначимо вектор центру класу на основі логічного правила, яке порівнює загальну кількість одиниць для кожного з 256 бітів усієї множини дескрипторів опису з половиною від їх числа [2, 3]:

$$m_i(b) = \begin{cases} 1, & \sum_{d=1}^{s(i)} x_d(b) \geq s(i) / 2; \\ 0, & \sum_{d=1}^{s(i)} x_d(b) < s(i) / 2; \end{cases} \quad (2)$$

$$x_d \in Z^i, \quad b = 1, \dots, 256,$$

де $x_d(b)$ – біт з номером b дескриптора з номером d в описі еталону.

Відповідно до (2) значення кожного з бітів центру m_i визначається значеннями бітів всіх дескрипторів, що належать еталону з номером i . Центр (2) відражає властивості еталона (класу).

Важливою характеристикою для варіантів а) та б) навчання мережі Кохонена є час навчання [8]. Потенційна необхідність збільшувати кількість КТ, через те що не всі КТ сприяють результативній класифікації, вносить необхідність розглянути альтернативи методу (2), з метою скорочення часу навчання та класифікації. Іншим варіантом є використання методів попередньої обробки для отримання опису зображення. Головний функціонал нейромереж – це узагальнення системи ознак. Наприклад у згорткових нейромережах обробленням досягається суттєве скорочення кількості параметрів моделі для мінімізації перенавчання [8, 13].

Інтерпретуємо карту характеристик зображення, що описана дескрипторами еталону Z^i , у вигляді вектору ймовірностей

$$p^i = \left[\sum_{d=1}^{s(i)} x_d(b) \right] / s(i), \quad (3)$$

у значеннях вектору p^i інтегрується просторова інформація опису Z^i шляхом додавання значень бітів дескрипторів для отримання скороченої моделі даних [12]. Вектор p^i узагальнює характеристики зображення через подання частоти появи одиниці в кожному з 256 бітів дескриптору ORB.

Подаємо нормовані вектори (3) на вхід нейронної мережі і тренуємо мережу тільки на них. Класифікація за варіантом г) також ґрунтується на значеннях (3). На рис. 1 наведено приклад фрагменту значень вектору (3) для зображення.




Рис. 1. Приклад фрагменту вектору p^i

Вектори p^i можна використовувати для довільних типів мереж, що загалом значно знижує час навчання за рахунок обробки одного вектору там, де традиційно оброблялися сотні векторів.

Результати експериментальних досліджень

Для реалізації методу класифікації обрано середовище VS Community 2019 і засоби бібліотеки OpenCV [18]. Бібліотека OpenCV має більше 2500 оптимізованих класичних та сучасних алгоритмів комп'ютерного зору і машинного навчання.




Рис. 2. Тестові зображення

Вибрані для експерименту категорії розпізнаваних зображень показано на прикладі бази Leeds Butterfly [14-16] (рис. 2). Рис. 3 містить приклад координат сформованих КТ.



Рис. 3. Приклад еталону з координатами КТ

Протестовані варіанти числа дескрипторів на кожному еталоні: 400 та 100 задля вивчення впливу на швидкодію. Також протестовані два варіанти для кількості епох мережі Кохонена 100 та 200 задля досягнення балансу швидкодії і точності. Апробоване збільшення числа ітерацій до 300 або 400 не сприяє зростанню результативності класифікації, але час навчання суттєво зростає.

Варіанти з підстроюванням нейрона переможця, чи трьох нейронів, найближчих за відстанню до нейрона переможця, дозволяють виконувати розпізнавання швидше або точніше [2].

Досліджено варіанти а) – г) методів навчання та класифікації за 4 класами з використанням 4-х категорій еталонів (рис. 2). Час навчання мережі залежить від факторів: кількість епох, число дескрипторів на кожний еталон та число нейронів, які змінюються у процесі навчання мережі. Кількість дескрипторів для кожного еталону коливалася у межах 375...400.

Результати дослідження варіанту а) для тестового прикладу показали, що цей підхід не дає можливості результативно класифікувати вибрані еталони. Значення $\beta = 0,65$, час роботи склав 14,94 с. Це аргументує застосування трансформації простору даних у вигляді підходів попереднього оброблення або побудови центрів з метою покращення ефективності.

Процедура навчання для варіанту б) проведена на двох різних зображеннях кожного із 4-х еталонів, число ітерацій – 200. Час класифікації склав 4.98 с.

Значення $\beta = 0,31$, за табл. 1 спостерігається висока ступінь розрізнення: максимуми значень знаходяться на діагоналях, перевищують інші елементи, усі еталони класифіковані вірно. Використання мережі при розрахунку центрів за (2) значно знижує похибку класифікації: з 0,65 для методу а) до 0,31 для методу б).

Проаналізуємо результативність класифікації на 15 тестових еталонах із застосуванням варіантів, різних за числом змінюваних нейронів, кількістю дескрипторів для кожного еталону та значеннями ітерацій мережі.

Для варіантів у 400 дескрипторів на еталон помилка класифікації коливалася у межах 0,33 – 0,28. Для варіантів зі 100 дескрипторами помилка природно збільшилась і становила 0,46 – 0,29.

Таблиця 1 – Результат класифікації за методом б)

Еталони	Класи			
	1	2	3	4
Z^1	279	33	27	61
Z^2	58	288	25	29
Z^3	36	91	228	23
Z^4	88	9	3	300

Основною залежністю є результативність від числа ітерацій мережі. Найкращі результати отримані для 400 дескрипторів, де навіть при незначному числі у 100 ітерацій мережі вдалося досягнути невисокого показника помилки 0,28.

Зміна кількості (1 чи 3) адаптованих нейронів майже не впливає на показники навчання, але впливає на помилку класифікації і на число помилково класифікованих даних. Модифікація одного нейрону практична тільки для ітерацій 200 та значному числі дескрипторів. Але навіть при цих умовах помилка класифікації на 10% більше ніж у відповідних варіантах з модифікацією 3-х нейронів, а кількість помилок зросла від 0 до 2. Найкращий результат отримано на кількості ітерацій 200 за 3-ма нейронами, при цьому коректно класифіковано всі класи еталонів з помилкою 0,23.

Час роботи для варіантів з 400 дескрипторами склав 13.7...16.21 с, для варіантів зі 100 дескрипторами 6.2...7.9 с. Метод б) показав найвищий рівень розрізнення у порівнянні з іншими, однак потребує значних обсягів часу.

Експерименти показали, що час оброблення у методі в) вдалося значно знизити у порівнянні з іншими методами, він склав 2.27...2.77 с. Помилка коливалась у межах 0,20...0,34.

Основний вплив на результативність та час класифікації має кількість дескрипторів у еталоні та число ітерацій. Найкращі результати отримані при 200 ітераціях, причому навіть при використанні 100 дескрипторів помилка склала 0,2. Змінення кількості адаптованих нейронів майже не впливає ні на показники часу роботи мережі, ні на результативність класифікації. Недоліком цього методу є те, що така мережа працює з прямим віднесенням до класу і немає можливості оцінювати кількість класифікованих дескрипторів еталону як ймовірність належності класу.

У варіанті г) застосуємо визначення (3) і обчислимо для дескрипторів кожного еталону вектор ймовірностей появи одиниці в кожному біті. Помилка для найліпших варіантів мережі (400 дескрипторів та 200 ітерацій) суттєво знизилася – до 0,06, невірно класифікований тільки один еталон. При зниженні числа дескрипторів помилка зростає до 0,34. Зниження числа ітерацій до 100 призводить до помилки 0,20.

Отримані результати показали чітку залежність між коректною класифікацією та кількістю дескрипторів у еталоні. Число ітерацій також є важливим

параметром, що посилює класифікаційні можливості мережі, а кількість адаптованих нейронів майже не впливає на результат.

Метод г) значно скорочує час роботи нейронної мережі в порівнянні з другими методами без погіршення якості. Якість класифікації для варіантів б) та г) майже співпадає. Час оброблення знизився майже у 8 раз (з 16.21 до 2.82 с для варіантів з аналогічною якістю), що дозволяє потенційно використовувати підхід г) для об'ємних баз зображень, у застосунках реального часу, при обробленні відеосигналів, тощо. Зазначений час потенційно дозволяє обробляти кожен десятий кадр відео з частотою оновлення у 60 кадрів в секунду.

Висновки

Стаття містить результати порівняльного аналізу розроблених методів навчання та класифікації для експериментальних зображень бази Leeds Butterfly при різних параметрах функціонування класифікаційної мережі Кохонена. Дослідження підтвердило здатність універсально адаптувати параметри мережі для довільних візуальних даних, особливо результативними є трансформації з використанням центрів класів та згортання даних на етапі попереднього оброблення.

Найкращу результативність показали методи із формуванням системи центрів для кожного зразка класу та використанням згортки для системи центрів, причому застосування згортки суттєво збільшує швидкість оброблення даних у порівнянні з іншими варіантами.

Наукова новизна дослідження полягає в удосконаленні методів структурної класифікації з використанням навчання мережі Кохонена шляхом впровадження нового простору даних на базі центрів описів еталонів та згортання даних, що сприяє забезпеченню високої результативності класифікації при достатній швидкості та дає можливість використовувати модифіковані методи у застосунках реального часу. Практичну значимість роботи складають отримані моделі програмного забезпечення для оцінювання ефективності класифікаторів у системах комп'ютерного зору, підтверджена ефективність розробок у прикладах баз даних зображень.

Подальше поліпшення продуктивності може бути досягнуто за рахунок підходів навчання з учителем, оскільки класи дескрипторів бази даних відомі. Однак, модернізація потенційно ускладнює оброблення, що впливає на швидкість.

СПИСОК ЛІТЕРАТУРИ

1. Гороховатський В.А. () Структурний аналіз і інтелектуальна обробка даних в комп'ютерному зренні. Харьков: СМІТ, 2014. 316 с.
2. Гороховатський В.А., Пупченко Д.В. Классификация изображений визуальных объектов по множеству дескрипторов особенных точек на основе нейронной сети Кохонена. *Системи управління, навігації та зв'язку*. 2018. №2 (48). – С. 68-72.
3. Гороховатський В.О., Пупченко Д.В., Солодченко К.Г. Аналіз властивостей, характеристик та результатів застосування новітніх детекторів для визначення особливих точок зображення. *Системи управління, навігації та зв'язку*. 2018. №1 (47), С. 93-98.
4. Gorokhovatskyi V.A. Image Classification Methods in the Space of Descriptions in the Form of a Set of the Key Point Descriptors. *Telecommunications and Radio Engineering*. 2018. 77 (9). P. 787-797.
5. Leutenegger, S., Chli, M., Siegwart, R.Y. BRISK: Binary Robust Invariant Scalable Keypoints. *Computer Vision (ICCV)*. 2011. P. 2548-2555.
6. Ethan Rublee, Vincent Rabaud, Kurt Konolige, Gary Bradski. ORB: an efficient alternative to SIFT or SURF. *Computer Vision (ICCV)*, IEEE International Conference on IEEE. 2011. P. 2564-2571.
7. Кохонен Т. Самоорганизующиеся карты. Москва : БИНОМ. Лаборатория знаний, 2013. 655 с.
8. Осовский С. Нейронные сети для обработки информации. М.: Финансы и статистика, 2002. 344 с.
9. Борисов Е. Кластеризатор на основе нейронной сети Кохонена [Электронный ресурс]. Режим доступа к материалу: <http://mechanoid.kiev.ua/neural-net-kohonen-clusterization.html>
10. Mousavi S.M.H., Lyashenko V. Extracting old Persian cuneiform font out of noisy images (handwritten or inscription). *10th Iranian Conference on Machine Vision and Image Processing (MVIP)*, 2017. P. 241-246.
11. Han J., Kamber, M. Data Mining: Concepts and Techniques. Amsterdam: Morgan Kaufmann Publishers, 2006. 754 p.
12. Gadetska S.V., Gorokhovatsky V.O. Statistical measures for computation of the image relevance of visual objects in the structural image classification methods. *Telecommunications and Radio Engineering*. 2018. 77 (12), P. 1041-1053.
13. Lin M., Chen Q., Yan S. Network in network. *arXiv preprint arXiv:1312.4400*. 2013.
14. Josiah Wang, Katja Markert, Mark Everingham. Learning Models for Object Recognition from Natural Language Descriptions. *Proceedings of the 20th British Machine Vision Conference (BMVC-2009)*. 2009.
15. Wang J., Markert K., Everingham M. Learning Models for Object Recognition from Natural Language Descriptions. *Proceedings of the 20th British Machine Vision Conference – BMVC*. 2009. Vol. 1, P. 2.
16. Gorokhovatskyi O., Gorokhovatskyi V., Peredrii O. Analysis of Application of Cluster Descriptions in Space of Characteristic Image Features. *Data*. 2018. 3(4), P. 52. DOI: <http://doi.org/10.3390/data3040052>.
17. Calonder M., Lepetit V., Strecha C., Fua P. Brief: Binary robust independent elementary features. *European conference on computer vision*. Springer, Berlin. 2010. P. 778-792
18. OpenCV foundation. OpenCV: Image Thresholding. 2017. Available at: https://docs.opencv.org/3.3.0/d7/d4d/tutorial_py_thresholding.html

REFERENCES

1. Gorokhovatsky, V.O. (2014), *Structural analysis and data mining in computer vision*, SMIT, Kharkiv, 316 p.
2. Gorokhovatsky, V.O. and Pupchenko, D.V. (2018), "Classification of images of visual objects according to the set of descriptors of singular points based on the Kohonen neural network", *Control, navigation and communication systems*, No. 2 (48), pp. 68-72.
3. Gorokhovatsky, V.O., Pupchenko, D.V. and Solodchenko, K.G. (2018), "Analysis of the properties, characteristics and results of using the latest detectors to determine specific points of the image", *Control, navigation and communication systems*, No. 1 (47), pp. 93-98.
4. Gorokhovatsky, V.A. (2018), "Image Classification Methods in the Space of Descriptions in the Form of a Set of the Key Point Descriptors", *Telecommunications and Radio Engineering*, 77 (9), pp. 787-797.
5. Leutenegger, S., Chli, M. and Siegwart, R.Y. (2011), "BRISK: Binary Robust Invariant Scalable Keypoints", *Computer Vision (ICCV)*, pp. 2548-2555.
6. Ethan, Rublee, Vincent, Rabaud, Kurt, Konolige and Gary, Bradski (2011), "ORB: an efficient alternative to SIFT or SURF", *Computer Vision (ICCV)*, *IEEE International Conference on IEEE*, pp. 2564-2571.
7. Kohonen, T. (2013), *Self-organizing maps*, BINOM. Laboratory of Knowledge, Moscow, 655 p.
8. Osovsky, S. (2002), *Neural networks for information processing*, Finance and statistics, Moscow, 344 p.
9. Borisov, E. (2014), *Cluster based on the Kohonen neural network*, available at: <http://mechanoid.kiev.ua/neural-net-kohonen-clusterization.html>
10. Mousavi, S.M.H. and Lyashenko, V. (2017), "Extracting old persian cuneiform font out of noisy images (handwritten or inscription)", *10th Iranian Conference on Machine Vision and Image Processing (MVIP)*, pp. 241-246.
11. Han, J. and Kamber, M., (2006), *Data Mining: Concepts and Techniques*, Morgan Kaufmann Publishers, Amsterdam, 754 p.
12. Gadetska, S.V. and Gorokhovatsky, V.O. (2018), "Statistical Measures for Computation of the Image Relevance of Visual Objects in the Structural Image Classification Methods", *Telecommunications and Radio Engineering*, 77 (12), pp. 1041-1053.
13. Lin, M., Chen, Q., and Yan, S. (2013), "Network in network", *arXiv preprint arXiv:1312.4400*.
14. Josiah, Wang, Katja Markert, and Mark, Everingham (2009), "Learning Models for Object Recognition from Natural Language Descriptions", *Proceedings of the 20th British Machine Vision Conference (BMVC2009)*, September 2009.
15. Wang, J., Markert, K., and Everingham, M. (2009), "Learning Models for Object Recognition from Natural Language Descriptions", *BMVC*, Vol. 1, p. 2.
16. Gorokhovatsky, O., Gorokhovatskyi, V. and Peredrii, O. (2018), "Analysis of Application of Cluster Descriptions in Space of Characteristic Image Features", *Data*, 3(4), 52, DOI: <http://doi.org/10.3390/data3040052>
17. Calonder, M., Lepetit, V., Strecha, C. and Fua, P. (2010), "Brief: Binary robust independent elementary features", *European conference on computer vision*, Springer, Berlin, pp. 778-792.

18. OpenCV foundation (2017), *OpenCV: Image Thresholding*, available at:
https://docs.opencv.org/3.3.0/d7/d4d/tutorial_py_thresholding.html

Надійшла (received) 12.11.2019

Прийнята до друку (accepted for publication) 22.01.2020

ВІДОМОСТІ ПРО АВТОРІВ / ABOUT THE AUTHORS

- Гороховатський Володимир Олексійович** – доктор технічних наук, професор, професор кафедри інформатики, Харківський національний університет радіоелектроніки, Харків, Україна;
Volodymyr Gorokhovatsky – Doctor of Technical Sciences, Professor, Professor of Computer Science Department, Kharkiv National University of RadioElectronics, Kharkiv, Ukraine;
 e-mail: gorohovatsky.vl@gmail.com; ORCID ID: <http://orcid.org/0000-0002-7839-6223>.
- Пупченко Дмитро Вікторович** – магістрант кафедри інформатики, Харківський національний університет радіоелектроніки, Харків, Україна;
Dmytro Pupchenko – Undergraduate of Computer Science Department, Kharkiv National University of RadioElectronics, Kharkiv, Ukraine;
 e-mail: dmytro.pupchenko@nure.ua; ORCID ID: <http://orcid.org/0000-0002-7438-1382>.
- Стяглик Наталя Іванівна** – кандидат педагогічних наук, завідувач кафедри інформаційних технологій, Харківський навчально-науковий інститут ДВНЗ Університет банківської справи, Харків, Україна;
Natalia Stiahlyk – Candidate of Pedagogical Sciences, Head of information technology Department, Kharkiv educational and scientific institute of SHEI “Banking University”, Kharkiv, Ukraine;
 e-mail: natastyaglick@gmail.com; ORCID ID: <http://orcid.org/0000-0001-5938-2013>.

Исследование трансформаций пространства данных при обучении сети Кохонена в методах структурной классификации изображений

V. A. Gorokhovatsky, D. V. Pupchenko, N. I. Stiahlyk

Аннотация. Предметом исследований статьи есть модификация средств обучения сети Кохонена для классификации изображений в системах компьютерного зрения. **Цель** – определение нового пространства данных для обучения сети и создания эффективного метода классификации на основе множества дескрипторов ключевых точек. **Задания:** применение нейронной сети Кохонена для обучения системы классификации в определенном пространстве данных, трансформация пространства данных для обучения сети, изучение адаптационных возможностей и оценивание эффективности функционирования сети средствами программного моделирования. **Методы:** интеллектуальный анализ данных, аппарат структурной классификации изображений, детектор ORB для определения дескрипторов ключевых точек, средства обучения сети Кохонена, программное моделирование. Получены такие **результаты.** Предложены модели трансформации данных, которые повышают результативность обучения. Проведен сравнительный анализ разработанных методов обучения и классификации. Осуществлена программная реализация системы классификации, экспериментально проведено исследование её эффективности и оценивание времени обработки. **Выводы.** Научная новизна исследования состоит в усовершенствовании методов структурной классификации с использованием обучения сети Кохонена путем внедрения нового пространства данных на основе центров описаний эталонов и свертки данных, что обеспечивает высокую результативность классификации при достаточном быстродействии и дает возможность применить модифицированные методы в приложениях реального времени. **Практическая значимость** работы состоит в получении моделей программного обеспечения для оценивания эффективности классификаторов в системах компьютерного зрения, подтверждена эффективность разработок на примерах баз данных изображений.

Ключевые слова: компьютерное зрение; структурное распознавание изображений; ключевые точки изображения; дескриптор; детектор ORB; сеть Кохонена; обучение сети; пространство данных; программное моделирование; база изображений.

Research of data space transformation in Kohonen network training for methods of structural classification of images

V. Gorokhovatsky, D. Pupchenko, N. Stiahlyk

Abstract. The subject of the article's research is the modification of Kohonen neural network training for image classification. The purpose is to define a new data space for network learning and to create an effective classification method based on a set of key point descriptors. **Task:** use of the Kohonen neural network to train the classification system in a certain data space, transform the data space of the training network, study adaptive capabilities and evaluate the effectiveness of the network by means of software modeling. **The methods** are: data mining, structural classification of images, ORB detector for determining key point descriptors, Kohonen network learning tools, software modeling. The following **results** were obtained: data transformation models that enhance learning performance are proposed. The comparative analysis of the developed methods of training and classification is made. A software implementation of the classification system has been carried out, its efficiency has been experimentally investigated and the processing time has been evaluated. **Conclusions.** The scientific novelty of the study is refining structural classification methods using Kohonen network by introducing a new center based clustering approach and a method for collapsing descriptor data, which contributes to high classification performance at sufficient speed and enables the use of these modified methods in real-time applications. The practical importance of the work is created by the models of software used to evaluate the performance of the classifiers in computer vision systems, and the proven effectiveness of the development on the specified image databases.

Keywords: computer vision; structural image recognition; key image points; descriptor; ORB detector; Kohonen network; network learning; data space; software modeling; image database.