

## Висновки

На основі виконаних досліджень можна зробити такі висновки:

1. Варіант 1 – така конструкція має найменшу чутливість до зміни прискорення через жорсткість кріплень електрода до основи. Застосування цієї конструкції рекомендується для визначення прискорень, більших, ніж  $1000 \text{ м/с}^2$ .

2. Варіант 2 – конструкція володіє більшою чутливістю, через зменшення жорсткості кріплень, а саме: товщина кріплень є тоншою, а довжина більшою. Застосування інтегрального приладу на основі цієї конструкції рекомендується для вимірювання прискорення, що не перевищує  $5000 \text{ м/с}^2$ .

3. Варіант 3 – така конструкція акселерометра порівняно з першою конструкцією найчутливіша до зміни прискорення, внаслідок зменшення жорсткості кріплень, та рівномірного розподілу навантажень.

4. У жодній з трьох конструкцій напруження у вузлах не перевищує максимально допустимого, тому ніяких обмежень на урахування напруження не накладається.

1. Волович А., Волович Г. *Интегральные акселерометры // Компоненты и технологии.* – 2000.
2. Amarasinghe R. et al *Design and fabrication of miniaturized six-degree of freedom piezoresistive accelerometer MEMS 2005: 18th IEEE International Conference on microelectromechanical systems.* – P. 351–354.
3. *A capacitive humidity sensor integrated with micro heater and ring oscillator circuit fabricated by CMOS–MEMS technique Sensors and Actuators B: Chemical.* – 2006. – 116, Issue 1.
4. Muller R.S. and K.Y. Lau, “Surface-Micromachined Microoptical Elements and Systems,” in *Integrated Sensors, Microactuators, Microsystems (MEMS), Vol.86, No. 8, Aug.1998.*

УДК 681.324

У.В. Поліщук<sup>1</sup>, Ю.В. Цимбал<sup>1</sup>, І.Ю. Юрчак<sup>2</sup>

Національний університет “Львівська політехніка”,

<sup>1</sup>кафедра автоматизованих систем управління,

<sup>2</sup>кафедра систем автоматизованого проектування

## МЕТОД КАСКАДНОГО ЗАСТОСУВАННЯ КОМПРЕСУЮЧОЇ НЕЙРОННОЇ МЕРЕЖІ ТА МЕТОДІВ КОНТЕКСТНОГО МОДЕЛЮВАННЯ

© Поліщук У.В., Цимбал Ю.В., Юрчак І.Ю., 2010

Розглянуто варіант послідовного застосування компресуючої нейронної мережі та методів контекстного моделювання для ефективного ущільнення даних, зокрема зображень та аудіосигналів. Запропонований метод оснований на поданні проміжного архіву зберігання даних у форматі чисел з фіксованою комою та забезпечує покращення характеристики щодо коефіцієнта компресування та якості відтворення первинних даних.

**Ключові слова:** нейронна мережа, компресія даних, відтворення первинних даних

**A variant of consistent application of the compressive neural network and context modeling techniques for efficient data compression, including images and audio signals is being viewed. The method is based on the representation of intermediate storage archive in a fixed-point format and provides improved performance of compression coefficient and quality of primary data reproduction.**

**Keywords:** neural network, data compression, primary data reproduction

### Вступ

Ущільнення даних належить до процедур перекодування, які здійснюють з метою зменшення об'єму даних та є необхідним для раціональнішого використання пристроїв зберігання інформації, а також передавання даних каналами зв'язку. Метою компресування може бути також ефективніше подання вхідної інформації для порівняння процедур її опрацювання, зокрема прогнозування, розпізнавання, порівняння.

В основі ущільнення лежить усунення *надлишковості інформації*, що міститься у вхідних даних. Як приклад надлишковості можна навести повторення у тексті певних фрагментів (напр., слів природної або машинної мови) [1]. Таку надлишковість усувають, замінюючи послідовності символів, що часто повторюються, коротшими значеннями (кодом), а тих, що рідше, – довгими. Проте для випадку статичних растрових зображень, що подаються двовимірним масивом значень яскравостей пікселів (елементів зображення), йдеться про *два типи надлишковості*, перший з яких схожий на надлишковість у текстових даних (однобітні чорно-білі зображення та зображення із невеликою кількістю кольорів та великими чіткими областями, заповнені одним кольором). У таких зображеннях певні кольори (кольорові гами) можуть переважати, а інші трапляються доволі рідко, тому надлишковість усувається за допомогою присвоєння різним пікселам кодів змінної довжини, так само, як і при ущільненні текстових даних.

Інший тип надлишковості, що характерний для повноколірних неперервно-тонових зображень (природні зображення, відскановані чи отримані під час знімання цифровою камерою), пов'язаний із тим, що зображення містять в собі надлишкову інформацію, яка утворюється за рахунок сильної кореляції між пікселами та не сприймається людським зором, тобто деякі деталі зображення можуть бути опущені без помітного порушення інформаційного змісту.

Одним із основних підходів, що використовується для ущільнення багаторівневих (напівтонових, неперервно-тонових кольорових) зображень, є перетворення первинного масиву даних (пікселів) та кодування перетворених значень [2]. Перетворення зображень дає змогу здійснити декореляцію, одночасно видаляючи надлишковість. Відомо декілька способів перетворень, переважна більшість яких, окрім вейвлетних методів та фрактального кодування, ґрунтуються на двовимірних ортогональних перетвореннях: дискретно-косинусне перетворення, перетворення Уолша–Адамара, Карунена–Лоєва.

У [2] стверджується про значні переваги над іншими методами в задачах ущільнення зображень методу, оснований на перетворенні Карунена–Лоєва, де на перший базисний вектор у середньому припадає найбільша кількість інформації про зображення, на другий – максимум із тієї, що залишилась, і т.д., інакше кажучи, здійснюється лінійний аналіз головних компонент. Проте, враховуючи, що базисні вектори перетворення Карунена–Лоєва обчислюються на основі статистичних властивостей зображень, що перетворюються, виникає необхідність записувати ці вектори в ущільнений файл для використання декодером. Окрім того, не існує швидкого алгоритму їх обчислення, що робить метод КЛ суто теоретичним. У зв'язку з цим виникає завдання пошуку методу, що володів би невеликою обчислювальною складністю та властивостями, схожими до перетворення Карунена–Лоєва. Розв'язок поставленого завдання потрібно шукати на основі застосування нових нейроподібних засобів та методів їх навчання та використання.

### Автоасоціативні нейронні мережі в задачах ущільнення зображень

Розглянемо структуру автоасоціативної нейронної мережі із одним прихованим шаром нейронних елементів (рис. 1) і т. зв. “вузьким горлом”, що є найпоширенішим прикладом застосування нейронних мереж до розв'язання задач ущільнення зображень [3].




Рис. 1. Автоасоціативна нейронна мережа з “вузьким горлом”

Вхідний та прихований шари цієї структури виконують власне компресію даних [3, 4], тоді як прихований та вихідний здійснюють декомпресію. Кількість нейронів вихідного шару дорівнює  $n$  та кількості нейронів у вхідному шарі. Прихований шар містить  $q$  нейронів, так що  $q \ll n$ , тобто реалізується так званий ефект “вузького горла”. Тобто в таких структурах відбуваються послідовні перетворення: з простору великої розмірності  $\rightarrow$  у простір зменшеної розмірності  $\rightarrow$  в простір початкової розмірності. Сигнали на виходах нейронних елементів у “вузькому горлі” прихованого шару зазвичай містять меншу кількість інформації, ніж сигнали на вхідних елементах, ущільнення даних відбувається принципово з втратами, однак існує можливість наперед задати точність відтворення даних на виході так, щоб втрати не були надто істотними. Сигнали на виходах нейронних елементів прихованого шару відповідають головним компонентам перетворення (Principal Components Analysis – PCA), тобто саме вони формують інформаційне ядро. Чим більша кількість нейронів  $q$  у прихованому шарі – тим більший об’єм інформації, що в них зберігається, і, відповідно, якісніше її відновлення в процесі декомпресії.

До недоліків цього методу, окрім згаданої вище можливості здійснювати ущільнення лише з втратами інформації та значних часових затримок на виконання процедури навчання мережі, також належить багато неточностей, пов’язаних із оцінкою коефіцієнта компресії. Під час визначення останнього зазвичай не враховуються реальні затрати на зберігання та передавання вагових коефіцієнтів навченої ШНМ, що дає спотворене уявлення про ступінь ущільнення [7–10], тобто результати щодо застосування автоасоціативних штучних нейронних мереж, описані передусім, становлять теоретичний інтерес для дослідників у цій галузі.

## 1. Ущільнення зображень на основі моделі геометричних перетворень

Зображення, що пройшло первинну обробку (зафіксоване цифровою фотокамерою, відскановане зображення), – це двовимірний масив двійкових чисел, кожне з яких відповідає конкретному пікселю. На вхід нейронної мережі послідовно подаються вектори даних, що відповідають блокам зображення розміром  $n \times n$  пікселів (напр.,  $8 \times 8$ ,  $N=64$ ). У випадку кольорового зображення, де кожен піксел подається 24-бітовим числом, по 8 бітів на кожному компоненту, використовується 192 ( $64 \times 3$ ) відповідно входів та виходів мережі. Кожен піксел зображення подано трьома компонентами вектора.

Використання нейронної мережі для розв’язання будь-яких задач передбачає виконання послідовно двох етапів навчання та, відповідно, використання мережі.

### 1.1. Етап навчання нейронної мережі

Навчання мережі (покрокові перетворення вхідної матриці) ґрунтується на геометричній моделі та представленні тіла інформаційного об’єкта [5, 6]. Кожен вхідний вектор розглядається як точка у  $n$ -вимірному просторі, де  $n$  – кількість компонент вектора. Множина точок-реалізацій формує тіло інформаційного об’єкта (у цьому випадку зображення), що моделюється за допомогою нейромережі. Навчання мережі здійснюється покроковим проектуванням точок на нормальну гіперплощину, вимірність якої на одиницю менша, аніж вимірність початкового гіпертіла.

Форма подання векторів-реалізацій вхідної матриці, елементами якої є значення пікселів  $x_{ij}$ , задана (1):

$$x_{ij} = \left\{ \begin{matrix} x_1 & x_2 & \dots & x_N \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \end{matrix} \right\}, \text{ де } i = \overline{1, M}, \quad j = \overline{1, N}; \quad (1)$$

Процедура навчання кожної з них поділяється на такі кроки:

1. Обчислюємо центр ваги початкового масиву даних  $x_{i,j}$ , що являє собою зображення

$$\tilde{x}_{cj} = \frac{\sum_{i=1}^m x_{ij}}{M}, \text{ для } j = \overline{1, n}; \quad (2)$$

2. Знаходимо рядок  $x_{cj}$ , за Евклідом, найближчий до центра ваги, та виконуємо центрування елементів масиву (3–4):

$$x_{cj} \approx \min \left\{ \sum_{j=1}^n (\%_j - x_{i,j})^2 \right\}, \text{ для } i = \overline{1, M}, \quad j = \overline{1, n}; \quad (3)$$

$$x1_{i,j}^{(k)} = x_{i,j} - xc_j, \text{ для } k=0; \quad (4)$$

3. Знаходимо базовий рядок (найвіддаленіша точка від початку координат):

$$xB_j^{(k)} \approx \max \left\{ \sum_{j=1}^n (x1_{i,j}^{(k)})^2 \right\}; \quad (5)$$

4. Обчислюємо коефіцієнт  $z_i^{(k)}$  – віддаль від  $i$ -ї точки до нормальної гіперплощини на  $k$ -му кроці ортогональних перетворень:

$$z_i^{(k)} = \frac{\sum_{j=1}^n (x1_{i,j}^k \times xB_j^k)}{D^{(k)}}, \quad (6)$$

де  $D^{(k)}$  – віддаль від початку координат до базової точки.

Особливістю цього підходу є те, що віддаль від  $i$ -ї точки до нормальної гіперплощини не є нормованою, отже, максимально можливе значення змінної дорівнює  $z_i^{(0)} = 255 \times \sqrt{n}$ , де  $n$  – вимірність вектора-реалізації, а мінімальне значення, відмінне від нуля, становить 1. На кожному кроці перетворень діапазон змінних  $z_i^{(k)}$  зменшується. Це дає змогу здійснювати перетворення у форматі чисел з фіксованою комою.

5. Виконуємо  $k$ -й крок ортогональних перетворень (проектування точок-реалізацій на нормальну гіперплощину):

$$x_{i,j}^{(k+1)} = XB_j^{(k)} \times z_i^{(k)}, \text{ для } i = \overline{1, M}, j = \overline{1, n}, \quad (7)$$

де  $XB_j^{(k)}$  – базовий рядок, нормований до одиничного радіуса.

Після кожного кроку ортогональних перетворень вимірність гіперповерхні зменшується на одиницю, а характеристики самого перетворення (коефіцієнти  $z_i^{(k)}$  та елементи базових рядків перетворень) зберігаються у пам'яті як параметри мережі.

Навчання мережі вважається завершеним, якщо виконується умова  $x_{ij}^{(k+1)} = 0$ . Це означає, що усі точки-реалізації спроектовані у початок координат; в іншому разі здійснюємо наступний крок ортогоналізації:  $k=k+1$ .

## 1.2. Етап використання нейронної мережі

Процедура використання мережі (відтворення первинних даних) здійснюється у зворотній до алгоритму навчання послідовності, починаючи із останнього кроку ортогоналізації, в результаті чого на виходах мережі отримуємо масив чисел  $x_{ij}$ , які відповідають значенням елементів відновленого зображення:

$$x1_{ij}^{(k)} = x1_{ij}^{(k+1)} \times XB_{ij}^{(k)} \times z_i^{(k)}, \quad (8)$$

де  $k=k_{max}$ ,  $i = \overline{1, M}$ ,  $j = \overline{1, n}$ ;

$$x_{i,j} = x1_{i,j}^{(0)} = xc_j \quad (9)$$

Тобто інформація, яка забезпечує формування компресуючої нейромережі для відтворення первинних даних на основі архіву, представлена елементами базових рядків у форматі чисел з фіксованою комою і займає незначний об'єм.

Оскільки всі дані архіву подаються у форматі чисел з фіксованою комою, виникає можливість додатково застосувати як наступний крок контекстні методи компресії без втрат інформації, як зазвичай роблять для ущільнення звичайних текстових даних.

## 2. Апробація методу та програми компресії зображень

На рис. 2–5 подаються результати виконання програми “Bitmap\_coder” на тестових зображеннях “Louvre”, “Flower”, “Renoir”, “X-ray” при показниках компресії 6.8, 4.19, 10.039 та 8.5 відповідно.



Рис. 2.1. Тестове зображення "Louvre"



Рис. 2.2. 8 нейронів, PSNR=35,226, cr=6,8



Рис. 3.1. Тестове зображення "Flower"



Рис. 3.2. 11 нейронів, PSNR=30,621, cr=4,19



Рис. 4.1. Тестове зображення "Repoir"



Рис. 4.2. 7 нейронів, -4 біти,  
PSNR=30,471, SSIM= 0,982, cr=10,039



Рис. 5.1. Тестове зображення "X-ray"



Рис. 5.2. 6 нейронів – 3 біти,  
PSNR= 37,45, SSIM=0,998, cr=11,1

**Результати застосування розробленого програмного комплексу ущільнення зображень  
“Bitmap\_coder” з використанням різних параметрів та режимів ущільнення**

Зображення	Розмір зображення, пікселів	К-ть нейронів	К-ть видалених бітів	PSNR	SSIM	Розмір .рас файла, КБ	Розмір .7z файла, КБ	CR
Gaudi_col	1024 x 1024	12	3	32,111	0,994	595	334	5,22
Gaudi_col	1024 x 1024	9	4	30,306	0,991	407	226	7,64
Barbara_gray	512 x 512	31	4	33,191	0,994	102	75,9	2,94
Lena_gray	512 x 512	14	1	35,002	0,995	73,2	60,0	3,88
Lena_gray	512 x 512	64	3	41,620	0,999	199	125	1,53
Flower_col	1024 x 1024	12	4	31,092	0,993	523	302	5,95
Flower_col	1024 x 1024	32	1	40,187	0,999	1773	1126	1,8
Renoir	1024 x 1024	7	4	30,471	0,982	309	228	10,039
X-Ray	512 x 512	8	3	37,224	0,998	94	37	8,5

У таблиці подано порівняльні результати застосування розробленого програмного комплексу ущільнення зображень “Bitmap\_coder” з використанням різних параметрів та режимів ущільнення. Обчислення коефіцієнта компресії виконано без урахування додаткового застосування файлового архіватора 7-Zip у режимі використання алгоритму контекстного моделювання PPMd, що, як показано у таблиці, дає змогу збільшити отриманий коефіцієнт компресії ще на 20–30 %.

Отже, запропонований метод навчання та застосування ШНМ ГП з представленням сигналів проміжного перетворення та елементів базових рядків покрокових перетворень для відтворення параметрів нейромережі у форматі чисел з фіксованою комою забезпечує формування архівів скомпресованих даних мінімального об’єму та можливість регулювати поріг втрат інформації у широкому діапазоні.

#### **Висновки**

Розроблений метод навчання та застосування ШНМ ГП із представленням вихідних сигналів НЕ проміжного шару у форматі чисел з фіксованою комою забезпечує:

- ущільнення та відтворення даних без втрат або з плавним регулюванням порогу втрат інформації відкиданням молодших компонент ортогонального перетворення та скорочення довжини розрядної сітки, що представляє компоненти;
- можливість використання двоступеневого методу компресії зображень: почерговим застосуванням компресуючої автоасоціативної мережі та додатковим ущільненням створеного архіву методами кодування без втрат інформації;
- нейроподібні структури геометричних перетворень реалізують швидкі алгоритми навчання та застосування, що забезпечує компресування зображень великих об’ємів.

1. Сергеев В.С., Барин В.В. Сжатие данных, речи, звука и изображений в телекоммуникационных системах. – М.: Издательское предприятие РадиоСофт, 2009. – С.33–40. 2. Сэлмон Д. Сжатие данных, изображений и звука. – М.: Техносфера, 2004. 3. Osovski S. Sieci neuronowe dla przetwarzania informacji. Oficyna wydawnicza Politechniki Warszawskiej. – Warszawa, 2000. 4. Christopher M. Bishop. Neural Networks for Pattern Recognition. Oxford University Press (1999). 5. Ткаченко Р.О. Нова парадигма штучних нейронних мереж прямого поширення // Вісник Держ. ун-ту “Львівська політехніка”: Комп’ютерна інженерія та інформаційні технології. – 1999. – № 86. – С.43–54. 6. Грицик В.В., Ткаченко Р.О. Нові підходи до навчання штучних нейромереж // Доповіді Національної академії наук України. – 2002. – № 11. – С.59–65. 7. Verma B., Blumenstein M., Kulkarni S. A New Compression Technique Using an Artificial Neural Network // Journal of Intelligent Systems, 1999, vol. 9, № 1. – P.39–54. 8. Verma B., Blumenstein M., Kulkarni S. A Neural Network Based Technique for Data Compression // Proceedings of the IASTED International Conference on Modelling and Simulation, MSO '97, Singapore. – P.12–16. 9. Vilovic I. An Experience in Image Compression Using Neural Networks // 48th International Symposium ELMAR-2006, 07-09 June 2006, Zadar, Croatia. – P.95–98. 10. Durai A.S, Saro A.E., Phil M. An Improved Image Compression approach with Self-Organizing Feature Maps using Cumulative Distribution Function // GVIP Journal, Volume 6, Issue 2, September, 2006. – P.122–128.