

денко Л.Г., Горленко І.О., Шевченко Л.М., Барановський В.А. Еколого-географічні дослідження території України. – К.: Наукова думка, 1990. – 32 с. 4. Адаменко Я.О. Структура будови баз даних екологічної інформації / Нетрадиційні енергоресурси та екологія України. – К.: Манускрипт, 1996. – С. 111–123. 5. Ковальчук І.П. Регіональний еколого-геоморфологічний аналіз. – Львів: Вид-во ін-ту українознавства, 1997. – 440 с. 6. Волошин І.М. Ландшафтно-екологічні основи моніторингу. – Львів: Простір, 1998. – 356 с. 7. Малишева Л.Л. Ландшафтно-геохімічна оцінка екологічного стану території. – К.: РВЦ “Київський університет”, 1998. – 264 с. 8. Мельник А.В. Українські Карпати: еколого-ландшафтне дослідження. – Львів: Вид-во ЛНУ, 1999. – 286 с. 9. Гуцуляк В.М. Ландшафтна екологія. Геохімічний аспект. – Чернівці: Рута, 2002. – 272 с. 10. Міщенко Л.В. Гоекологічний аудит техногенного впливу на довкілля та здоров’я населення (на прикладі регіону Покуття): Автореф. дис. ... канд. геогр. наук. – Чернівці, 2003. – 21 с. 11. Адаменко О.М. Інформаційно-керуючі системи екологічного моніторингу на прикладі Карпатського регіону // Укр. географ. журн. – 1993. – №3. – С. 8–14. 12. Адаменко О.М., Рудько Г.І. Екологічна геологія. – К.: Манускрипт, 1998. – 349 с.

УДК 681.324

У. Поліщук, О. Ткаченко, Ю. Цимбал
Національний університет “Львівська політехніка”,
кафедра автоматизованих систем управління

УЩІЛЬНЕННЯ ЗОБРАЖЕНЬ ЗА ДОПОМОГОЮ НЕЙРОПОДІБНИХ СТРУКТУР МОДЕЛІ ГЕОМЕТРИЧНИХ ПЕРЕТВОРЕНЬ

© Поліщук У., Ткаченко О., Цимбал Ю., 2010

Подаються основи методу ущільнення напівтонових та кольорових зображень на основі нейроподібної структури моделі геометричних перетворень (МГП) в автоасоціативному режимі її застосування. Використовується властивість автоасоціативних мереж МГП виділяти на виході нейронних елементів (НЕ) прихованого шару Головні Компоненти (ГК) даних без використання принципу «звуженого горла», що забезпечує принципово нову здатність ущільнювати дані без втрат інформації.

This paper describes compression method of the color and gray-scale images. Method is based on the neurolike Geometrical Transformation Machine structure in the auto-associative application mode. The GTM neural network feature to extract Principal Components on the neural elements (NOT) output without using “bottle-neck principle” is being used. It provide the fundamental new ability to realize compression without information losses.

Засади нейромережного ущільнення зображень

Ущільнення даних залишається актуальною проблемою для інформаційних систем протягом тривалого часу. В останні роки розроблено високоефективні методи та підходи до компресії даних, що ґрунтуються на різноманітних властивостях і принципах, які обираються залежно від типів даних і характеру завдань. Серед подібних задач окреме місце посідає проблема ущільнення зображень, оскільки розмір графічних файлів високої якості зазвичай значно перевищує розмір файлів інших типів (текстові дані, виконавчі модулі невеличких програм), проте користувачеві часто доводиться мати з ними справу.

Графічний файл кольорового зображення представляється двовимірним образом, кожен піксель якого задається 24 бітами, де компоненти червоного, зеленого та блакитного займають по 8 бітів кожен, отже, загальна кількість можливих варіантів пікселів становить $2^{24} \approx 16.78$ мільйонів [1].

На відміну від ущільнення тексту, де немає можливості вилучити жоден відсоток інформації без втрати цілісності документа, ущільнювати зображення можна з певними втратами, оскільки частину зображення, що не сприймається людським оком, можливо вилучити.

Певною специфікою вирізняються методи компресії зображень на основі застосування штучних нейронних мереж. На відміну від більш традиційних методів ущільнення – математичних перетворень і видалення надлишковості – нейронні мережі розв’язують задачі ущільнення шляхом побудови структури мережі мінімальної складності за умови врахування необхідних обмежень. Відомі методики застосування нейронних мереж (автоасоціативні нейромережі та карти Когонена) забезпечують здійснення компресії за рахунок властивостей узагальнення (генералізації), що дає можливість отримувати значні коефіцієнти компресії, однак передбачає обов’язкові при цьому втрати. Очевидно, що парадигма карт Когонена за визначенням передбачає обов’язкову наявність втрат, однак для автоасоціативних структур подібні обмеження не є такими очевидними.

Відомо, що автоасоціативна мережа – це багат шаровий перцептрон, вхідні дані для якого відтворюються (найчастіше зі спотвореннями) на виході.

На рис. 1 зображено структуру автоасоціативної мережі з одним прихованим шаром нейронних елементів і т.зв. «вузьким горлом», що являє собою найпоширеніший приклад застосування нейронних мереж до розв’язання задач ущільнення зображень [2].




Рис. 1. Автоасоціативна нейронна мережа

Вхідний та прихований шари цієї структури виконують власне компресію даних [2, 3], 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 $q < n$, тобто реалізується так званий ефект «вузького горла».

Сигнали на виходах нейронних елементів у «вузькому горлі» прихованого шару зазвичай містять меншу кількість інформації, ніж сигнали на вхідних елементах, 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 більше нейронів q в прихованому шарі – тим більший об’єм інформації, що в них зберігається, і, відповідно, якісніше її відновлення в процесі декомпресії.

Основою методики використання як Самоорганізаційних Карт Особливостей Когонена (SOFM), так і автоасоціативних нейронних мереж є їх навчання без супервізора (самонавчання) – тобто тип навчання, коли мережа самостійно формує свої виходи, адаптуючись лише до сигналів, що надходять на її входи. Отже, автоасоціативна мережа навчається лише на закономірностях, що закладені в самих даних. Лише реально існуюча надлишковість дає змогу знаходити компактніший

опис даних. Оскільки обсяг опису даних пропорційний до двох величин: розрядності даних b (кількості бітів), що визначає різноманіття значень, яких вони набувають, та кількості компонент вхідних векторів x^a , відповідно до цього розрізняють два типи відмінних між собою нейромережних способів ущільнення [5]:

- **зниження розмірності даних** при мінімальній втраті інформації: автоасоціативні мережі, що здійснюють *аналіз головних компонент* даних, виділяють набори незалежних ознак;
- **зменшення різноманітності даних** шляхом виділення скінченного набору прототипів та віднесення даних до одного з таких типів: кластеризація даних, квантування неперервної вхідної інформації здійснюється за допомогою Самоорганізаційних Карт Особливостей Когонена (SOFM).

Ущільнення зображень за допомогою автоасоціативної мережі на основі Моделі Геометричних перетворень

У цій роботі розроблено новий ефективний метод застосування нейроподібних структур для задач компресії кольорових та напівтонових зображень без втрат або з можливістю регулювання ступеня втрат інформації. Метод ґрунтується на використанні нейроподібної структури моделі геометричних перетворень (МГП) в автоасоціативному режимі її застосування [6].

Нейроподібні структури МГП загалом виконують функції універсальних апроксиматорів, реалізують принципи навчання та самонавчання, будуються на підставі алгоритмічних або апаратних варіантів виконання з використанням принципів просторового та часового розпаралелювання [7, 8].

Одна з відмінностей нейроподібних автоасоціативних мереж МГП від багатопаралельних перцептронів в автоасоціативному варіанті їх застосування, що є важливою для здійснення компресії даних, полягає в тому, що режим „звуженого горла“ не є обов’язковим для реалізації подібних структур, отже, існує можливість точного (з нульовою методичною похибкою) відображення векторів вхідних сигналів у вектори вихідних, одночасно виділяючи на виходах нейронних елементів прихованого шару сигнали всіх ортогональних, незалежних компонент інформаційного об’єкта. Причому перша компонента задає напрямок, вздовж якого дисперсія максимальна, наступна компонента проводиться так, що вздовж неї максимізується залишкова варіація і т.д.

Процедура ущільнення

На вхід нейронної мережі подаються дані про зображення, розділені на блоки розміром $h \times v$ пікселів. Блоки зображення подаються послідовно.

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

$$\left\{ \begin{matrix} x_1 & x_2 & x_3 \\ \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots \end{matrix} \right\} \text{ де } i = \overline{1, M}, j = \overline{1, N} \quad (1)$$

Кожен вектор одночасно може розглядатися як точка в просторі, вимірність якого дорівнює кількості компонент вектора n , а кількість рядків-векторів дорівнює кількості блоків зображення. Елементи першого стовпця вхідної матриці відповідають першим пікселям кожного з блоків, другі – другим і т.д. Наприклад, якщо вхідне зображення має розмірність 512x512 пікселів, розбите на блоки розміром 8x8 із загальною кількістю пікселів, що дорівнює 64 відповідно, то на вхід нейронної мережі ми подаємо матрицю, кількість стовпців якої дорівнює кількості елементів у блоці, а кількість рядків – кількості блоків, тобто 64x64 відповідно.

Компресія загалом відбувається за рахунок проміжного представлення векторів вхідних сигналів у сигнали в новій системі координат z_1 і z_2 , (на виходах нейронних елементів прихованого шару), які ми отримуємо, послідовно здійснивши ряд перетворень (рис. 2):

1. Обчислення центру ваги векторів-рядків початкової матриці-кластера $\bar{x}_j$;
2. Центрування матриці, x_{ij} ;
3. Обчислення базових рядків x_{ij} ;

4. Визначення віддалі від початку координат до базової точки-рядка та нормування базового рядка, D та XB_j відповідно;

5. Виділення Головних Компонент (віддалі від $i - \bar{i}$ точки до нормальної площини), z_i .

Основа процедури полягає у перетворенні з первинної системи координат у проміжну шляхом послідовного проектування тіла на нормальну площину, що проходить через початок координат. Нова система координат будується так, що вздовж кожної осі послідовно забезпечується максимально можлива для цього кроку дисперсія. Одночасно зберігається можливість перетворення точок-реалізацій з проміжної на первинну систему координат з нульовою методичною похибкою. Для проміжної системи вздовж окремих координатних осей (напр., z_3) отримуємо нульову дисперсію, тоді зменшуємо вимірність представлення шляхом відкидання відповідних компонентів, а вздовж інших – представлення забезпечується зі зменшеним числом бітів розрядної сітки із фіксованою комою (z_2). Тобто, координати (z_3) настільки малі, що ними можна знехтувати або без втрати точності представити меншим числом бітів. Отже, нова система координат є економнішою.




Рис. 2. Розміщення точок у просторі.
Представлення векторів у новій системі координат z_1 та z_2

На виході знову відбувається перетворення на первинну систему координат.

Моделювання і результати

Дослідження проводились для напівтонових чорно-білих та кольорових зображень. Рівень декомпресійних спотворень визначається коефіцієнтом RSNR (3) (англ.: peak signal to noise ratio). Це інженерний термін, який визначає співвідношення між максимумом можливого значення сигналу та потужністю шуму, що спотворює значення сигналу. Зазвичай вимірюється в логарифмічній шкалі у децибелах. Найпростіше обчислюється через середньоквадратичне відхилення (MSE):

$$MSE = \frac{\sum_{i=1}^m \sum_{j=1}^n (x_{ij} - \tilde{x}_{ij})^2}{mn}, \quad (2)$$

де m та n – розмір зображення по вертикалі та горизонталі відповідно; x_{ij} та $\tilde{x}_{ij}$ вхідне та декомпресоване зображення.

PSNR обчислюється у вигляді:

$$PSNR = 10 \lg \frac{(2^k - 1)^2}{MSE}, \quad (3)$$

де k – кількість бітів, що використовується для кодування градацій інтенсивності зображення.

Результати роботи алгоритму

На рис. 3 зображено результат виконання програми на тестовому зображенні „Lena” розміром 512x512 при 5 нейронах у прихованому шарі; коеф. компресії близько 13; PSNR=30.1697.




Рис. 3. „Lena” 512x512, 5 нейронів, $K_r \approx 13$, PSNR=30.1697




Рис. 4. „Lena_color”, 24 градації, 512x512, 5 нейронів, $K_r \approx 13$, PSNR=29,2196




Рис. 5. „Baboo” 512x512, 5 нейронів, $K_r \approx 13$, PSNR=21,2398




Рис. 6. „Baboo_color”, 24 градації, 512x512, 5 нейронів, $K_r \approx 13$, PSNR= 20,70478

Таблиця 1

Результати порівняння ефективності розробленої програми та інших експериментальних і комерційних програм на базі нейронних мереж

Програма	Зображення	Розмірність	Коефіцієнт компресії	PSNR	Час навчання
Bitmap coder	Lena_gray	512 x 512	10.6	30,1697	45 сек
Image Compression With Neural Networks 1.0 - Matlab source code (http://www.advancedsourcecode.com)	Lena_gray	512 x 512	10.6	28.3182	18000 сек
Bitmap coder	Pepper_gray	256 x 256	4	30,3529	3 сек
Результат, отриманий за матеріалами статті S. Anna Durai, and E. Anna Saro «Image Compression with Back-Propagation Neural Network using Cumulative Distribution Function», World Academy of Science, Engineering and Technology 17 2006	Pepper_gray	256 x 256	4	29.04	188 сек
Bitmap coder	Lena_gray	256 x 256	4	30,8081	5 сек
Результат, отриманий за матеріалами статті S. Anna Durai, and E. Anna Saro «Image Compression with Back-Propagation Neural Network using Cumulative Distribution Function», World Academy of Science, Engineering and Technology 17 2006	Lena_gray	256 x 256	4	28.91	182

Отже, аналіз наведених результатів показує, що використання мереж Моделі Геометричних Перетворень до ущільнення зображень дає покращені результати (співвідношення *якість/час навчання*) порівняно з існуючими методами, причому результати компресії чорно-білих та кольорових зображень виявилися співвимірними між собою при однакових початкових умовах.

Висновки

1. Розроблений метод, що ґрунтується на засадах навчання нейроподібних структур МГП з використанням представлення чисел з фіксованою комою, забезпечує ефективне ущільнення даних, зокрема без втрат інформації і може розглядатися як подальший крок у розвитку парадигми МГП.

2. Застосування формату чисел з фіксованою комою полегшує апаратну реалізацію нейромереж МГП високої продуктивності і швидкодії.

1. Сэломон Д. Сжатие данных, изображений и звука. – М.: Техносфера, 2004. 2. Osovski S. Sieci neuronowe dla przetwarzania informacji. Oficyna wydawnicza Politechniki Warszawskiej. Warszawa 2000. 3. Christopher M. Bishop. Neural Networks for Pattern Recognition. Oxford University Press (1999). 4. Kramer M. A. Autoassociative neural networks. Massachusetts inst. technology, dep. chemical eng., lab. intelligent systems process eng., Cambridge MA 02139, ETATS-UNIS. 5. A. Jerzov, A. Shumsky. Neurocomputing and its application in economic and business. MIFI 1998. 6. Ткаченко Р.О., Дорошенко А.В. Вдосконалення нейромережних методів класифікації в завданнях інтелектуального аналізу даних за допомогою методу імітації відпалу металу // Вісник Нац. ун-ту “Львівська політехніка”: Комп’ютерні системи проектування. Теорія і практика. – 2007. – № 591. – С. 33–37. 7. Tkachenko R., Tkachenko P., Tkachenko O., Schmitz-Lenders J. Geometrical transformation machine // Computer sciences and information technologies: Materials of the international conference CSIT’2007. – Lviv, 2007. – Pp. 52–53. 8. Ткаченко Р.О., Дорошенко А.В. База моделей на основі моделі геометричних перетворень для систем підтримки прийняття рішень // Комп’ютерні технології друкарства. – 2007. – № 17. – С. 21–28.

УДК 004.942

М. Медиковський, О. Шуневич

Національний університет “Львівська політехніка”,
кафедра автоматизованих систем управління

МЕТОД ЗАСТОСУВАННЯ СТАНДАРТУ OPC ДЛЯ СИНТЕЗУ СИСТЕМ УПРАВЛІННЯ

© Медиковський М., Шуневич О., 2010

Розглянуто способи взаємодії вбудованих систем з програмним забезпеченням комп’ютера, встановлено переваги застосування стандарту OPC, проаналізовано способи взаємодії OPC-клієнтів із OPC-серверами. Досліджено OPC-сервери і здійснено системний аналіз можливостей щодо симуляції отримання/передачі даних.

Some ways of interactions between embedded systems and software of PC, defined benefits of using OPC-standard, analyzed the ways of interactions between OPC-servers and OPC-clients. Investigated OPC-servers and implemented the system analysis of simulation mode for a receiving/sending data.

Вступ

Більшість автоматизованих систем управління будуються на базі промислових контролерів. Контролери регулюють технологічні параметри, аварійні сигнали; вони є засобом захисту і блокування (нижній рівень системи). Оброблена контролерами інформація передається до комп’ю-