

Інфокомунікаційні системи

УДК 004.032.26

Е.А. Винокурова, Ю.Е. Татарінова, А.В. Асеев

Харьковский национальный университет радиоэлектроники, Харьков

ВЫЯВЛЕНИЕ ЛОКАЛЬНЫХ ХАРАКТЕРИСТИК БИОМЕТРИЧЕСКИХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ ВЭЙВЛЕТ-НЕЙРО-КОМПРЕССОРА

Предложены архитектура и алгоритм обучения всех параметров вэйвлет-нейро-компрессора данных большого объема с целью выявления локальных особенностей биометрических изображений. Вэйвлет-нейро-компрессор позволяет сжимать не только данные, поданные в виде изображений, таблиц "объект-свойство", но и нестационарные нелинейные временные ряды в on-line режиме. Предложенный подход может быть использован для решения задач интеллектуальной обработки сигналов произвольной природы и в задачах аутентификации пользователей по их биометрическому образу.

Ключевые слова: сжатие данных большого объема, вэйвлет-нейро-компрессор, нестационарные временные ряды, аутентификация, биометрия.

Введение

В настоящее время информация накапливается в огромные базы данных, объем которых измеряется в терабайтах. Фактически бесчисленное количество информации может получить кто угодно и где угодно через Интернет. Но для эффективного принятия решений полученную информацию необходимо обобщить и структурировать. Таким образом, когда количество данных, размерность и сложность скрытых зависимостей в них выше человеческих возможностей, на первый план выходят методы интеллектуального анализа данных, которые позволяют извлечь локальные особенности и полезные знания.

Наряду с задачами, так или иначе связанными с проблемой аппроксимации, такими как прогнозирование, эмуляция, идентификация, распознавание образов, достаточно часто приходится решать задачу компрессии информации (сокращение размерности входного пространства признаков).

Задача компрессии данных широко применяется в различных приложениях биомедицины, техники, экономики, а также в задачах биометрической аутентификации личности, где необходимо выделить локальные особенности биометрических образов пользователя с целью занесения их в базу данных и для дальнейшего проведения аутентификации личности [1 – 5].

В настоящее время биометрическая аутентификация не только является неотъемлемой процедурой для допуска к объектам повышенной секретности, но и входит в нашу повседневную жизнь, о чем свидетельствует множество фактов.

Огромный интерес к биометрии обусловлен рядом причин. В классических парольных системах,

а также в системах на основе карт доступа подглядывание или угадывание пароля, кража или изготовление дубликата карты приводит к компрометации всей системы. Более того, законный пользователь, потеряв или испортив карту, теряет возможность доступа к системе. Системы на основе биометрии практически лишены этих недостатков – идентификатор неразрывно связан с самим пользователем, поэтому потеря или изменение идентификатора возможны только в чрезвычайных происшествиях, а современные сканеры биометрических данных позволяют обнаруживать попытки использования муляжей.

Все биометрические характеристики человека можно разделить на два класса – статические и динамические. Статические – неизменяемые в течение продолжительного времени характеристики личности, данные ей от рождения. Примером статических характеристик могут быть рисунок радужной оболочки глаза, форма лица, форма уха, рисунок папиллярных узоров пальца. Динамические характеристики отражают особенности, характерные для подсознательных движений в процессе воспроизведения какого-либо действия. Примерами подобных характеристик могут служить голос, почерк человека.

В отличие от аутентификации пользователей по паролям или уникальным цифровым ключам, биометрические технологии всегда вероятностные, поскольку всегда есть шанс совпадения сравниваемых биологических характеристик у двух разных людей. В силу этого любая биометрическая система содержит следующие два параметра:

- ошибка первого рода (False Rejection Rate, FRR) – вероятность того, что легитимный пользователь может быть не распознан системой.

- ошибка второго рода (False Acceptance Rate, FAR) – вероятность ошибочной аутентификации (идентификации) нелегитимного пользователя.

Ошибки первого и второго рода, в первую очередь, связаны с технической невозможностью получения всегда одинаковых цифровых образов данной биометрической характеристики при каждом ее сканировании. Шумы в датчике, различное положение частей тела человека при сканировании, искажения самих характеристик (мимика, ожоги или порезы пальцев, световые блики и т.п.) – все это отражается на формируемом цифровом образе.

Современные системы биометрической аутентификации включают в себя, по крайней мере, два модуля – модуль регистрации и модель аутентификации (идентификации) пользователей. При регистрации происходит многократное считывание выбранной характеристики, вычисление некоторого среднего его значения и запись этого значения в базу данных системы. В дальнейшем, при прохождении процедуры аутентификации пользователь вновь предъявляет свои биометрические данные. Модуль аутентификации производит сравнение полученного образа с тем, что хранится в базе, и на основании сходства делает вывод об успешно/неуспешно пройденной процедуре.

В таких системах после выбора биометрической характеристики определяются функция расстояния между двумя образами и некоторый коэффициент сходства двух образов. Если расстояние между двумя образами не превышает этот коэффициент, то система рассматривает их, как образы, принадлежащие одному пользователю. В противном случае делается вывод о принадлежности образов разным пользователям.

Подобные системы имеют ряд существенных недостатков, связанных с тем, что сами образы хранятся в базе данных:

- две различные системы, использующие одну и ту же биометрическую характеристику, используют идентичную ключевую информацию о пользователе;
- в этих системах невозможна анонимная аутентификация пользователей;
- существует возможность похищения базы данных эталонов злоумышленником. Шифрование базы данных лишь увеличит время доступа к самим данным. Более того, злоумышленником может быть администратор этой базы данных.

Возможность применения хэш-функций к цифровым образам позволила бы решить указанные проблемы. Однако использование хэш-функций затрудняется нечеткостью самих биометрических данных.

Таким образом, одной из основных проблем, стоящих перед разработчиками биометрических систем, является проблема выработки уникальных фиксированных битовых строк из биометрических данных при каждой операции сканирования.

Для решения задач компрессии существует ряд разработанных методов, таких как метод главных компонент [7], линейный дискриминантный анализ [8], вэйвлет-анализ [9 – 11], однако такие методы не могут быть применены для решения задач компрессии в реальном времени, с другой стороны, предложен ряд методов на основе нейронных сетей, таких как нейронная сеть "Бутылочное горлышко" [12], нейронная сеть Хэбба-Сэнгера [13], нейронная сеть Оя-Карунена [14 – 17], нейронная сеть Рубнера-Шультена-Тэвена [18, 19], но все предложенные нейронные сети не могут применяться в реальном времени для компрессии данных.

Таким образом, самым ключевым блоком является блок выделения локальных особенностей из биометрического образа. Для решения этой задачи был предложен вэйвлет-нейро-компрессор и его метод обучения.

1. Архитектура вэйвлет-нейро-компрессора

В статье предлагается гибридная двуслойная вэйвлет-нейронная архитектура для решения задачи компрессии временных рядов и ее алгоритм обучения, сочетающие преимущества теории нейронных сетей и теории вэйвлетов, а именно способность обобщать и обучаться с возможностью выявления локальных особенностей. Введем в рассмотрение двуслойную вэйвлет-нейронную архитектуру, представленную на рис. 1. Строительным элементом такой структуры является вэйвлет-нейрон [23] с нелинейными вэйвлет-синапсами. При подаче на вход вэйвлет-нейро-компрессора многомерного временного ряда $X = \{x^1(k), x^2(k), \dots, x^n(k)\}$ на выходе сети получаем сигналы вида (так называемые главные компоненты)

$$y^m(k) = \sum_{i=1}^n \sum_{l=1}^{h_1} \varphi_{li}^{mi}(x^i(k)) w_{li}^{mi}(k), \quad (1)$$

а соответственно сигналы, получаемые на выходе второго слоя, имеют вид

$$\begin{aligned} \epsilon^i(k) &= \sum_{m=1}^h f_0^{im}(y^m(k)) = \\ &= \sum_{m=1}^h \sum_{j=1}^{h_2} \varphi_{j0}^{im}(y^m(k)) w_{j0}^{im}(k) = \\ &= \sum_{m=1}^h \sum_{j=1}^{h_2} \varphi_{j0}^{im} \left(\sum_{i=1}^n \sum_{l=1}^{h_1} \varphi_{li}^{mi}(x^i(k)) w_{li}^{mi}(k) \right) w_{j0}^{im}(k), \end{aligned} \quad (2)$$

где $\varphi_{li}^{mi}(\bullet)$, $\varphi_{j0}^{im}(\bullet)$ - вэйвлет-активационные функции первого и второго слоев соответственно, $w_{li}^{mi}(k)$, $w_{j0}^{im}(k)$ - синаптические веса первого и второго слоев соответственно, $y^m(k)$ - m-компонента сжатого многомерного временного ряда.




Рис. 1. Архитектура вэйвлет-нейро-компрессора

Двойной вэйвлет-нейрон состоит из двух слоев: скрытого слоя, в котором $2n$ вэйвлет-синапсов по h_1 вэйвлет-функций в каждом и выходного слоя, состоящего из $2n$ вэйвлет-синапса с h_2 вэйвлет-функциями.

В каждом вэйвлет-синапсе реализованы вэйвлеты, отличающиеся между собой параметрами центра и ширины, которые уточняются наряду с синептическими весами с помощью тех или иных алгоритмов обучения. С одной стороны, в качестве вэйвлет-активационных функций могут быть взяты различные семейства вэйвлетов, но с другой стороны, хорошо бы использовать адаптивную функцию принадлежности, параметры и форма, которой настраивалась бы в процессе обучения системы компрессии.

В данном случае предлагается использовать введенную нами [24, 25] настраиваемую активационную функцию, имеющую вид

$$\varphi_{li}^{mi}(x^i(k)) = (1 - \alpha_{li}^{mi} (\tau_{li}^{mi})^2) \exp\left(-\frac{(\tau_{li}^{mi})^2}{2}\right), \quad (3)$$

$$\varphi_{j0}^{im}(y^m(k)) = (1 - \alpha_{j0}^{im} (\tau_{j0}^{im})^2) \exp\left(-\frac{(\tau_{j0}^{im})^2}{2}\right), \quad (4)$$

где $\tau_{li}^{mi}(x^i(k)) = (x^i(k) - c_{li}^{mi}(k))(\sigma_{li}^{mi}(k))^{-1}$,
 $\tau_{j0}^{im}(y^m(k)) = (y^m(k) - c_{j0}^{im}(k))(\sigma_{j0}^{im}(k))^{-1}$,

α_{li}^{mi} , α_{j0}^{im} – настраиваемый параметр ($0 \leq \alpha \leq 1$).

Уточняемый параметр α позволяет настраивать форму активационной функции в процессе обучения составного адаптивного вэйвлонна, при этом при $\alpha = 0$ получаем Гауссову функцию активации, при $\alpha = 1$ получаем вэйвлет-функцию «Mexican Hat», а при $0 < \alpha < 1$ – гибридную функцию активации.

На рис. 2 приведены формы активационных функций в зависимости от параметра α .




Рис. 2. Адаптивная функция активации с различными параметрами α (точечная линия $\alpha = 0$, пунктирная линия $\alpha = 0.5$, сплошная линия $\alpha = 1$)

2. Алгоритм обучения вэйвлет-нейро-компрессора

Базируясь на критерии обучения вида

$$E^i(k) = \frac{1}{2} \left(x^i(k) - \sum_{m=1}^h f_0^{im}(y^m(k)) \right)^2, \quad (5)$$

можно записать алгоритм настройки синаптических весов и параметров вэйвлет-активационных функций первого слоя в виде

$$\begin{aligned} w_{li}^{mi}(k+1) &= w_{li}^{mi}(k) + \\ &+ \eta^w e^i(k) \left[f_0^{im}(y^m(k)) \right]' \varphi_{li}^{mi}(x^i(k)), \quad (6) \\ \left\{ \begin{aligned} c_{li}^{mi}(k+1) &= c_{li}^{mi}(k) + \\ &+ \eta^c e^i(k) \left[f_0^{im}(y^m(k)) \right]' w_{li}^{mi}(k) \frac{\partial \varphi_{li}^{mi}(x^i(k))}{\partial c_{li}^{mi}(k)}, \\ (\sigma_{li}^{mi})^{-1}(k+1) &= (\sigma_{li}^{mi})^{-1}(k) + \\ &+ \eta^\sigma e^i(k) \left[f_0^{im}(y^m(k)) \right]' w_{li}^{mi}(k) \frac{\partial \varphi_{li}^{mi}(x^i(k))}{\partial (\sigma_{li}^{mi})^{-1}(k)}, \\ \alpha_{li}^{mi}(k+1) &= \alpha_{li}^{mi}(k) + \\ &+ \eta^\alpha e^i(k) \left[f_0^{im}(y^m(k)) \right]' w_{li}^{mi}(k) \frac{\partial \varphi_{li}^{mi}(x^i(k))}{\partial \alpha_{li}^{mi}(k)}, \end{aligned} \right. \quad (7) \end{aligned}$$

где $\eta^w, \eta^c, \eta^\sigma, \eta^\alpha$ - шаг алгоритма обучения,

$$\left[f_0^{im}(y^m(k)) \right]' = \sum_{j=1}^{h_2} w_{j0}^{im}(k) \frac{\partial \varphi_{j0}^{im}(y^m(k))}{\partial y^m(k)}.$$

Алгоритм обучения второго слоя основывается на критерии, записанном в виде

$$E^i(k) = \frac{1}{2} (x^i(k) - \xi^i(k))^2 = \frac{1}{2} (e^i)^2(k), \quad (8)$$

где e^i - ошибка обучения.

Таким образом, алгоритм обучения синаптических весов и параметров активационных вэйвлет-функций второго слоя имеет вид

$$w_{j0}^{im}(k+1) = w_{j0}^{im}(k) + \eta_0 e^i(k) \varphi_{j0}^{im}(y^m(k)), \quad (9)$$

$$\left\{ \begin{aligned} c_{j0}^{im}(k+1) &= c_{j0}^{im}(k) + \\ &+ \eta_0^c e^i(k) w_{j0}^{im}(k) \frac{\partial \varphi_{j0}^{im}(y^m(k))}{\partial c_{j0}^{im}(k)}, \\ (\sigma_{j0}^{im})^{-1}(k+1) &= (\sigma_{j0}^{im})^{-1}(k) + \\ &+ \eta_0^\sigma e^i(k) w_{j0}^{im}(k) \frac{\partial \varphi_{j0}^{im}(y^m(k))}{\partial (\sigma_{j0}^{im})^{-1}(k)}, \\ \alpha_{j0}^{im}(k+1) &= \alpha_{j0}^{im}(k) + \\ &+ \eta_0^\alpha e^i(k) w_{j0}^{im}(k) \frac{\partial \varphi_{j0}^{im}(y^m(k))}{\partial \alpha_{j0}^{im}(k)}, \end{aligned} \right. \quad (10)$$

где $\eta_0^w, \eta_0^c, \eta_0^\sigma, \eta_0^\alpha$ - шаг алгоритма обучения.

Таким образом, вэйвлет-нейро-компрессор позволяет реализовать сжатие и выявление локальных особенностей как данных, представленных в виде изображений, таблицы "объект-свойство", так и нестационарных нелинейных временных рядов в online режиме, что дает преимущество по сравнению с существующими методами.

3. Численный эксперимент

Для решения задачи выявления локальных особенностей из биометрических образов был взят набор изображений, который состоял из 10 изображений отпечатков пальцев размером 120×180 пикселей с 256 градациями серого (2 изображения отпечатка для 5 пользователей). Далее каждое изображение разбивалось на неперекрываемые фрагменты размерностью 5×5 пикселей, и подавалось на вэйвлет-нейро-компрессор, который состоял из 15 адаптивных вэйвлет-функций активации-принадлежности в каждом вэйвлет-синапсе. Начальные значения весовых коэффициентов были сгенерированы случайным образом. Далее вэйвлет-нейро-компрессор обучался предложенным методом в течение 3 эпох.

На рис. 3 представлено оригинальное изображение отпечатка пальца. Для восстановления изображения использовалось обратное преобразование на основе вэйвлет-нейро-компрессора.



Рис. 3. Оригинальное изображение отпечатка пальца

На рис. 4 представлены результаты восстановления изображения отпечатка пальца при различном количестве главных компонент.




Рис. 4. Результаты восстановления изображений: а – по одной главной компоненте; б – по 20 главным компонентам; в – по 60 главным компонентам; г – по 180 главным компонентам

В табл. 1 представлены значения кумулятивной информативности от 1 до 20 компоненты.

Таблица 1
Значения кумулятивной информативности для компонент

Количество главных компонент	Значение кумулятивной информативности компонент
1	0.1703
2	0.3345
...	...
10	0.8126
...	...
18	0.9575
19	0.9646
20	0.9708

Таким образом, после обработки изображения биометрического признака на основе вэйвлет-нейро-компрессора в скрытом слое генерируется вектор уникальных признаков, который будет характеризовать пользователя.

Выводы

Предложена архитектура вэйвлет-нейро-компрессора и алгоритм его обучения всех параметров, обладающий следящими и фильтрующими свойствами. Предложенный подход позволяет решать задачу сжатия данных не только в виде изображений, таблиц "объект-свойство", но и многомерных нестационарных временных рядов произвольной природы с целью дальнейшей обработки. Имитационные эксперименты подтверждают эффективность развиваемого подхода.

Список литературы

1. Fronthaler H. Local feature extraction in fingerprints by complex filtering / H. Fronthaler, K. Kollreider, J. Bigun // Proc. Intl. Workshop on Biometric Recognition Systems. – Dortmund: Gesundheit. – 2005. – P. 77-84.
2. Garcia-Salicetti S. BIOMET: A multimodal person authentication database including face, voice, fingerprint, hand and signature modalities / S. Garcia-Salicetti, C. Beumier, G. Chollet, B. Dorizzi, J. Lunter // Proc. International Conference on Audio- and Video-Based Biometric Person Authentication. – NY: Sears. – 2003. – P. 487-510.
3. Leung M. Fingerprint image processing using neural network / M. Leung, W. Engeler, P. Frank // Proc. IEEE Region 10 Conf. on Computer and Comm. Systems. – NY: Sears. – 1999. – P. 657-714.
4. Kyong W.N. A Feature Extraction Method for Binary Iris Code Construction / W.N. Kyong, L.Y. Kyong, S.B. Jun, S.Y. Woo // Proc. of the 2nd Int. Conf. on Information Technology for Application. – 2005. – P. 210-220.
5. Connie T. Palmprint Recognition with PCA and ICA, Image and Vision Computing / T. Connie, A. Teoh, M. Goh // New Zealand, 2003, Palmerston North. – 2003. – P. 232-227.
6. Айвазян С.А. Прикладная статистика. Классификация и снижение размерности / С.А. Айвазян. – М.: Финансы и статистика, 1989. – 608 с.
7. Лоули Д. Факторный анализ как статистический метод / Д. Лоули, А. Максвелл. – М.: Мир, 1967. – 144 с.
8. Ким Дж. Факторный, дискриминантный и кластерный анализ / Дж. Ким, Ч.У. Мьюллер и др. – М.: Финансы и статистика, 1989. – 215 с.
9. Chui C.K. An Introduction to Wavelets / C.K. Chui. – New York: Academic, 1992. – 264 p.
10. Su H. Wavelet transforms and neural networks for compression and recognition / H. Su, B. Telfer, J. Garcia // Neural Networks. – 1996. – 9. – P. 695-709.
11. Meyer Y. Wavelets: Algorithms and Applications / Y. Meyer. - Philadelphia, PA: SIAM., 1993. – 133 p.
12. Cichocki A. Neural Networks for Optimization and Signal Processing / A. Cichocki, R. Unbehauen. – Stuttgart: Teubner, 1993. – 526 p.
13. Sanger T. Optimal unsupervised learning in a single-layer linear feedforward neural network / T. Sanger // Neural Networks. – 1989. – 2. – P. 459-473.
14. Oja E. Neural networks, principal components, and subspaces / E. Oja // Int. J. of Neural Systems. – 1989. – 1. – P. 61-68.
15. Oja E. An analysis of convergence for a learning version of the subspace method / E. Oja, J. Karhunen // J. Math. Anal. Appl. – 1983. – 91. – P. 102-111.
16. Chen T. Global convergence of Oja's subspace algorithm for principal component extraction / T. Chen, Y. Hua, W.-Y. Yan // IEEE Trans. on Neural Networks. – 1998. – 9. – P. 58-67.
17. Бодянский Е.В. Модифицированный нейрон Оя для анализа нестационарных данных / Е.В. Бодянский, И.П. Плисс, Н.А. Тесленко // Автоматизация: проблемы, идеи решения: Междунар. науч.-техн. конф.: тезисы докл. – Севастополь, 2006. – С. 18-21.
18. Bishop C.M. Neural Networks for Pattern Recognition / C.M. Bishop. – Oxford: Clarendon Press, 1995. – 482 p.
19. Haykin S. Neural Networks. A Comprehensive Foundation / S. Haykin. – N.J.: Upper Saddle River, Prentice Hall, Inc., 1999. – 842 p.
20. Abonyi J. Fuzzy Clustering Based Segmentation of Time-Series / J. Abonyi, B. Feil, S.Z. Németh, P. Arva // Proc. 5th Int. Symp. on Intelligent Data Analysis. – Berlin, Germany. – 2003. – P. 275-285.

21. Abonyi J. *Introduction to Fuzzy Data Mining Methods*. / J. Abonyi, B. Feil // *Handbook of Research on Fuzzy Information Processing in Databases* / J. Galindo (Ed.) – 2008. – P. 55-95.

22. Abonyi J. *Cluster analysis for data mining and systems identification* / J. Abonyi, B. Feil. – Birkhäuser. Verlag AG. – Basel-Boston-Berlin. – 2007. – 303 p.

23. Bodyanskiy Ye. *An adaptive learning algorithm for a wavelet neural network* / Ye. B. Bodyanskiy, N. Lamonova, I. Pliss, O. Vynokurova // *Blackwell Synergy: Expert Systems*. – 22. – №5. – P. 235-240.

24. Бодянский Е.В. *Адаптивный вейвлон и алгоритм*

его обучения / Е.В. Бодянский, Е.А. Винокурова // *Управляющие системы и машины*. – 2009. – 1 (219). – С. 47-53.

25. B. Bodyanskiy Ye. *Radial-basis-fuzzy-wavelet-neural network with adaptive activation-membership function* / Ye. B. Bodyanskiy, O. Vynokurova, E. Yegorova // *Int. J. on Artificial Intelligence and Machine Learning*. – 2008. – V.8. – II. – P. 9-15.

Поступила в редколлегию 2.07.2013

Рецензент: д-р техн. наук, проф. Е.В. Бодянский, Харьковский национальный университет радиоэлектроники, Харьков.

ВИЯВЛЕННЯ ЛОКАЛЬНИХ ХАРАКТЕРИСТИК БІОМЕТРИЧНИХ ЗОБРАЖЕНЬ НА ОСНОВІ ВЕЙВЛЕТ-НЕЙРО-КОМПРЕСОРА

О.А. Винокурова, Ю.Є. Татарінова, О.В. Асєєв

Запропоновано архітектуру та алгоритм навчання всіх параметрів вейвлет-нейро-компресора даних великого обсягу з метою виявлення локальних особливостей біометричних зображень. Вейвлет-нейро-компресор дозволяє скискати не тільки дані, подані у вигляді зображень, таблиць "об'єкт-властивість", але й нестационарні нелінійні часові ряди в on-line режимі. Запропонований підхід може бути використаний для вирішення задач інтелектуальної обробки сигналів довільної природи та в задачах автентифікації користувачів по їх біометричному образу.

Ключові слова: стиснення даних великого обсягу, вейвлет-нейро-компресор, біометричний образ, автентифікація, біометрія.

LOCAL CHARACTERISTICS DETECTION OF BIOMETRIC IMAGES BASED ON WAVELET-NEURO-COMPRESSOR

O.A. Vynokurova, Yu.Ye. Tatarinova, O.V. Asieiev

In this paper architecture and all parameters learning algorithm of wavelet-neuro-compressor of large size data for the purpose of detection local features biometric images are proposed. Wavelet-neuro-compressor allows to compress not only images, data in the "object-property" table but and non-stationary nonlinear time series in on-line mode. Proposed approach can be used for solving of the different problems in the intelligent signal processing and the tasks of user authentication with biometrics pattern.

Keywords: data compression of large size, wavelet-neuro-compressor, biometric pattern, authentication, biometrics.