
БИОМЕТРИЧЕСКИЕ ИСТОЧНИКИ ИНФОРМАЦИИ, ИХ АНАЛИЗ И ПРИМЕНЕНИЕ

УДК 004.032.26

ПРОБЛЕМЫ КОМПРЕССИИ ДАННЫХ БОЛЬШОГО ОБЪЕМА В УСЛОВИЯХ НЕОПРЕДЕЛЕННОСТИ С ЦЕЛЬЮ ВЫЯВЛЕНИЯ ЛОКАЛЬНЫХ ОСОБЕННОСТЕЙ

Е.А. ВИНОКУРОВА

Предложено архитектуру и алгоритм обучения всех параметров вэйвлет-нейро-компрессора данных большого объема в условиях неопределенности с целью выявления локальных особенностей данных. Вэйвлет-нейро-компрессор позволяет сжимать не только данные, поданные в виде 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.

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].

Выделим в качестве основных следующие типовые прикладные задачи снижения размерности анализируемого признакового пространства, которые рассматриваются в рамках многомерного анализа данных [6].

Первой задачей можно выделить отбор наиболее информативных признаков (включая выявление латентных факторов). Речь идет об отборе из исходного (априорного) множества признаков $X = (x_1, x_2, \dots, x_n)$, которые обладали бы свойством

наибольшей информативности в смысле, определенном, как правило, некоторым специально подобранным для каждого конкретного типа задач критерием информативности. Также критерий информативности может быть нацелен на максимальную автоинформативность новой системы показателей, т.е. на максимально точное воспроизведение всех исходных признаков по сравнительно небольшому числу вспомогательных переменных.

Второй задачей является сжатие массивов обрабатываемой и хранимой информации. Такой вид задач связан с рассмотренной выше и, в частности, требует в качестве одного из основных приемов решения построения экономной системы вспомогательных признаков, обладающих наивысшей автоинформативностью. В действительности при решении достаточно серьезных задач сжатия больших массивов информации используется сочетание методов классификации и снижения размерности. Методы классификации позволяют перейти от массива, содержащего информацию по всем n статистически обследованным объектам, к соответствующей информации только по k эталонным образцам $k \ll n$, где в качестве эталонных образцов берутся специальным образом отобраные наиболее типичные представители классов, полученных в результате операции разбиения исходного множества объектов на однородные группы. Методы же снижения размерности позволяют заменить исходную систему показателей набором вспомогательных (наиболее автоинформативных) переменных.

Третьей задачей можно выделить визуализацию данных. Данная задача дает ответ на вопрос еще на предварительной стадии анализа данных – распадается ли анализируемая выборка на четко выраженные кластеры в заданном пространстве, каково примерное число их и т.д. Так как

максимальный размер фактически воспринимаемого пространства равен трем, поэтому естественно, возникает проблема проецирования анализируемых многомерных данных из исходного пространства на прямую, плоскость, поверхность, в крайнем случае – в трехмерное пространство так, чтобы интересующие специфические особенности исследуемой совокупности, если они присутствовали в исходном пространстве, сохранились бы и после проецирования. Следовательно, и здесь идет речь о снижении размерности анализируемого признакового пространства, но снижении, во-первых, подчиненном некоторым специальным критериям и, во-вторых, оговоренном условием, что размерность редуцированного пространства должна не превышать трех.

Еще одной задачей является сжатие временных рядов. Задача такого рода позволяет проводить компрессию многомерных временных рядов, во-первых, с целью анализа, прогноза, эмуляции уже объединенного процесса, который объединит все локальные особенности, а во-вторых, с целью упрощения хранения больших объемов многомерных временных рядов, это могут быть однородные процессы, которые снимаются с нескольких датчиков (такие как кардиограммы, энцефалограммы, голосовые наборы данных) или разнородные процессы, анализ которых может показать их зависимость между собой. Данная задача менее всех исследована, чем выше описанные, что подтверждает актуальность исследований в данном направлении.

Для решения рассмотренных 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, предложено 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 для компрессии временных рядов.

В работе [20-22] была предпринята попытка синтеза метода сжатия временных рядов с целью их дальнейшего сегментирования, но такой метод основан на методе главных компонент и не применим в on-line режиме.

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

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

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.

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 синаптическими 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




Рис. 1. Архитектура вэйвлет-нейро-компрессора

обучения составного адаптивного вэйвлон, 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 .

3. АЛГОРИТМ ОБУЧЕНИЯ ВЭЙВЛЕТ-НЕЙРО-КОМПРЕССОРА

Базируясь на критерии обучения вида

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




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

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

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

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

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

где e^i – ошибка обучения.

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

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

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

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 таблицей "объект-свойство", так и нестационарных нелинейных временных рядов в on-line режиме, что дает преимущество по сравнению с существующими методами.

Результаты экспериментов подтверждают эффективность предложенного вэйвлет-нейро-компрессора в решении задач биомедицинских приложений, в биометрических методах

аутентификации пользователей методов, в анализе экономических показателей и других задачах.

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 таблице "объект-свойство", но и многомерных нестационарных временных рядов произвольной природы с целью дальнейшей обработки.

Имитационные эксперименты подтверждают эффективность развиваемого подхода.

Литература

- [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., Engeler, W., Frank, P.* 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 International Conference on Information Technology for Application (ICITA 2004). – 2005. – P. 210-220.
- [5] *Connie T.* Palmprint Recognition with PCA and ICA, Image and Vision Computing / Connie T., Teoh, A., Goh, M. // New Zealand 2003, Palmerston North, New Zealand, (2003) 232–227.
- [6] *Айвазян С.А.* Прикладная статистика. Классификация и снижение размерности / С.А. Айвазян. - Финансы и статистика. - 1989. - 608 с.
- [7] *Лоули Д.* Факторный анализ как статистический метод / Лоули Д., Максвелл А. – 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. – 215с.
- [9] *Chui C. K.* An Introduction to Wavelets / C. K. Chui. – New York: Academic, 1992. – 264 p.
- [10] *Szu H.* Wavelet transforms and neural networks for compression and recognition / H. Szu, 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 / Cichocki A., Unbehauen R. – Stuttgart: Teubner, 1993. – 526 p.

- [13] Sanger T. Optimal unsupervised learning in a single-layer linear feedforward neural network / Sanger T. // Neural Networks. — 1989. — 2. — P. 459-473.
- [14] Oja E. Neural networks, principal components, and subspaces / Oja E. // 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 / Oja E., Karhunen J. // J. Math. Anal. Appl. — 1983. — 91. — P.102-111.
- [16] Chen T. Global convergence of Oja's subspace algorithm for principal component extraction / Chen T., Hua Y., Yan W.-Y. // IEEE Trans. on Neural Networks. — 1998. — 9. — P.58-67.
- [17] Бодянский Е.В. Модифицированный нейрон Оя для анализа нестационарных данных / Бодянский Е.В., Плисс И.П., Тесленко Н.А. // Автоматизация: проблемы, идеи решения: Междунар. науч.-техн. конф.: тезисы докл. — Севастополь, 2006. — С.18-21.
- [18] Bishop C.M. Neural Networks for Pattern Recognition / Bishop C. M. — Oxford: Clarendon Press, 1995. — 482 p.
- [19] Haykin S. Neural Networks. A Comprehensive Foundation / Haykin S. — N.J.: Upper Saddle River, Prentice Hall, Inc., 1999. — 842 p.
- [20] Abonyi J, Feil B., Nemeth S.Z., Arva P. Fuzzy Clustering Based Segmentation of Time-Series / Abonyi J, Feil B., Nemeth S.Z., Arva P. // Proc. 5th International Symposium on Intelligent Data Analysis. — Berlin, Germany. — 2003. — P. 275-285.
- [21] Abonyi J. Introduction to Fuzzy Data Mining Methods. / Abonyi J, Feil B. // 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 / Abonyi J, Feil B. — Birkhauser. Verlag AG. — Basel-Boston-Berlin. — 2007. — 303 p.
- [23] Bodyanskiy Ye. An adaptive learning algorithm for a wavelet neural network / Bodyanskiy Ye., Lamonova N., Pliss I., Vynokurova O. // Blackwell Synergy: Expert Systems. — 22. — №5 — P. 235-240.
- [24] Бодянский Е.В. Адаптивный вэйвлон и алгоритм его обучения / Бодянский Е.В., Винокурова Е.А. // Управляющие системы и машины. — 2009. — 1 (219). — С.47-53.
- [25] Bodyanskiy Ye. Radial-basis-fuzzy-wavelet-neural network with adaptive activation-membership function / Bodyanskiy Ye., Vynokurova O., Yegorova E. // International Journal on Artificial Intelligence and Machine Learning. — 2008. — V.8. — II. — P. 9-15.

Поступила в редколлегию 15.03.2012

Винокурова Елена Анатольевна, кандидат технических наук, ведущий научный сотрудник Проблемной научно-исследовательской лаборатории АСУ, доцент кафедры Безопасности информационных технологий Харьковского национального университета радиоэлектроники. Область научных интересов: гибридные системы вычислительного интеллекта, вэйвлет-нейро-фаззи системы, прогнозирование, идентификация, компрессия, аутентификация на основе методов вычислительного интеллекта.



УДК 004.032.26

Проблеми стиснення даних великого обсягу за умов невизначеності з метою виявлення локальних особливостей / О. А. Винокурова // Прикладна радіоелектроніка: наук.-техн. журнал. — 2012. — Том 11. № 2. — С. 250–254.

Запропоновано архітектуру та алгоритм навчання усіх параметрів вейвлет-нейро-компресора даних великого обсягу за умов невизначеності з метою виявлення локальних особливостей даних. Вейвлет-нейро-компресор дозволяє стискати не тільки данні, що поданні у вигляді таблиці “об’єкт-властивість”, але і нестационарні нелінійні часові ряди у on-line режимі. Запропонований підхід може бути використано для вирішення різних задач інтелектуальної обробки сигналів довільної природи та в задачах автентифікації користувачів за їх біометричним образом.

Ключові слова: стиснення даних великого обсягу, вейвлет-нейро-компресор, нестационарні часові ряди, автентифікація

Рис. 02. Библиогр.: 25назв.

UDC 004.032.26

Problems of mass data compression for the purpose of detecting local features under uncertainty conditions / O.A. Vinokurova // Applied Radio Electronics: Sci. Journ. — 2012. Vol. 11. № 2. — P. 250–254.

An architecture and all parameters learning algorithm of a wavelet-neuro-compressor of mass data to detect local features under uncertainty conditions are proposed. The wavelet-neuro-compressor allows to compress not only data in an “object-property” table but non-stationary nonlinear time series in the on-line mode. The proposed approach can be used for solving of different problems of intelligent signal processing and in the tasks of authenticating users by their biometric image.

Keyword: mass data compression, wavelet-neuro-compressor, non-stationary time series, authentication.

Fig.: 02. Ref.: 25 items.