

УДК 004.032 26



НЕЙРОННАЯ СЕТЬ И АЛГОРИТМ ЕЕ ОБУЧЕНИЯ ДЛЯ АНАЛИЗА НЕЗАВИСИМЫХ КОМПОНЕНТ В ЗАДАЧАХ ОБРАБОТКИ ИЗОБРАЖЕНИЙ

А.Г. Ведмедь¹, В.П. Машталир², Е.С. Сакало³

^{1,2,3}ХНУРЭ, г. Харьков, Украина, mashtalir@kture.kharkov.ua

Для решения задачи восстановления изображений предложена нейронная сеть для реконструкции входных сигналов в предположении их взаимной статической независимости. Введенные алгоритмы вычислительно просты и предназначены для обработки информации в последовательном режиме по мере ее поступления.

НЕЙРОННАЯ СЕТЬ, АНАЛИЗ НЕЗАВИСИМЫХ КОМПОНЕНТ, ОБРАБОТКА ИЗОБРАЖЕНИЙ

Введение

Анализ независимых компонент [1] в общем случае связан с проблемой разделения смесей сигналов с априори неизвестными характеристиками, поступающих из различных источников, и в настоящее время достаточно широко используется в задачах обработки биомедицинской информации, данных, получаемых от линейных полей, диагностирования и тестирования сложных электронных систем и, что особенно интересно, при обработке (прежде всего восстановления) изображений, искаженных возмущениями неизвестной природы.

Особенно эффективно анализ независимых компонент может быть реализован на основе нейросетевого подхода [2-7], что создает предпосылки для обработки поступающих данных в реальном времени.

В анализе независимых компонент априори предполагается, что исходный n -мерный сигнал $x(t) = (x_1(t), x_2(t), \dots, x_n(t))^T$ (здесь t – непрерывное время) воспринимается датчиками не в «чистом» виде, а в форме линейной комбинации так, что

$$y_i(t) = \sum_{j=1}^n a_{ij} x_j(t), i = 1, 2, \dots, n$$

или в векторной форме

$$y(t) = Ax(t),$$

где $A \in R^{n \times n}$; $\det A \neq 0$; $y(t) = (y_1(t); y_2(t); \dots; y_n(t))^T$. При этом полагается, что как сигналы $x_j(t)$, так и матрица A неизвестны. Задача состоит в разделении (реконструкции) входных сигналов в предположении их взаимной статической независимости и существования матрицы A^{-1} , обратной к неизвестной смешивающей матрице A . Что касается обработки изображений, то достаточно часто возникает задача не только их «очистки» – фильтрации от различного рода искажений и изменений, но и разделения смеси различных изображений, когда разные образы накладываются один на другой.

Именно в такой форме проблема впервые рассмотрена и решена Дж. Херольтом и К. Джуттенном

[8-10], хотя введенная ими рекуррентная разделяющая нейронная сеть на сегодня считается недостаточно эффективной.

Рассматривая данную задачу с позиций нейросетевого подхода, можно говорить о синтезе архитектур и модернизированных алгоритмов обучения, обеспечивающих преобразование наблюдаемого векторного сигнала $y(t) = (y_1(t), y_2(t), \dots, y_n(t))^T$ в некий новый вектор $s(t) = (s_1(t), s_2(t), \dots, s_n(t))^T$ с независимыми компонентами $s_i(t)$, при этом статистически независимая от других компонент $s_i(t)$ должна быть связана в некотором смысле с соответствующей компонентой $x(t)$.

На рис. 1 приведена обобщенная схема нейросетевой реализации анализа независимых компонент.




Рис. 1. Нейросетевая реализация анализа независимых компонент

Элементарные нейронные структуры, рассмотренные выше, могут быть обобщены на случай многомерного сигнала произвольной размерности n , при этом основные соотношения, описывающие данную ситуацию, могут быть записаны в виде

$$s(t) = Wy(t),$$

$$y(t) = Ax(t),$$

где $W = \{w_{ij}\} \in R^{n \times n}$ – матрица настраиваемых синтаксических весов и приведена на рис. 2.

Как видно, данная архитектура полностью совпадает с конструкцией самоорганизующейся карты Т. Кохонена с одинаковым числом входов и выходов.

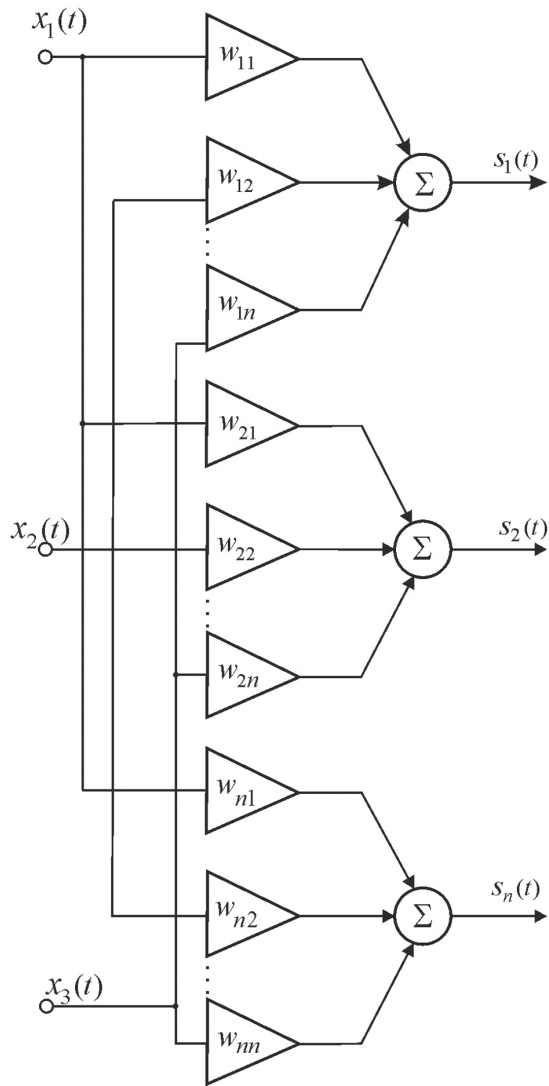


Рис. 2. Нейронная сеть для анализа независимых компонент

1. Элементарная нейронная сеть для анализа независимых компонент и алгоритмы ее обучения

В качестве базового элемента нейросетевой системы для анализа независимых компонент рассмотрим элементарную двухвходовую подсистему, предназначенную для разделения ненаблюдаемых сигналов $x_1(t)$ и $x_2(t)$. В настоящее время для решения этой задачи используются две основные архитектуры [2,7], приведенные на рис. 3 (а, б).

Пунктиром обведена часть, недоступная наблюдению, при этом неизвестные веса смешивающей матрицы $a_{11}, a_{12}, a_{21}, a_{22}$ должны быть оценены с помощью настраиваемых синаптических весов w_{12} и w_{21} путем соответствующей обработки сигналов $y_1(t), y_2(t), s_1(t), s_2(t)$.

Обучение структур, приведенных на рис. 3, сводится к нахождению в процессе настройки значений синаптических весов w_{12} и w_{21} , а в его основе лежит хеббовское правило [11] в непрерывном времени, модифицированное Джуттенем-Херольдом [9] с учетом статической независимости сигналов $s_1(t)$ и $s_2(t)$.

Поскольку задачи обработки изображений решаются в цифровом виде, следует ввести дискретные алгоритмы обучения, получаемые с помощью цифрового квантования [12]:

$$\begin{cases} w_{12}(k+1) = w_{12}(k) + \eta(k)\varphi(s_1(k))\psi(s_2(k)), \\ w_{21}(k+1) = w_{21}(k) + \eta(k)\varphi(s_2(k))\psi(s_1(k)), \end{cases}$$

где $k = 1, 2, \dots, N$ – текущее дискретное время; $\eta(k)$ – параметр шага алгоритма обучения, выбираемого по аналогии с параметром шага в градиентных алгоритмах оптимизации.




Рис. 3. Элементарная нейронная сеть для анализа независимых компонент

2. Искусственная нейронная сеть для анализа главных компонент и ее обучение

К настоящему времени известно достаточно большое число правил обучения такой сети в непрерывном времени [2, 5, 6, 10, 11], среди которых можно отметить:

– модифицированное правило Чихотского

$$\frac{dW}{dt} = \eta(t)W(I - \varphi(s(t))\psi^T(s(t)))W,$$

где $W(0) = I$; $\varphi(s(t)) = (\varphi(s_1(t)); \varphi(s_2(t)); \dots; \varphi(s_n(t)))^T$, $\psi^T(s(t)) = (\psi(s_1(t)); \psi(s_2(t)); \dots; \psi(s_n(t)))$; $I - (n \times n)$ единичная матрица;

– правило Чихотского-Амари-Янга

$$\frac{dW}{dt} = \eta(t)(I - \varphi(s(t))\psi^T(s(t)))W^{-1},$$

– правило, основанное на естественном градиенте Амари

$$\frac{dW}{dt} = \eta(t)(I - \varphi(s(t))\psi^T(s(t)))W,$$

– правило Кардоссо

$$\frac{dW}{dt} = \eta(t)(I - s(t)s^T(t) - \alpha\varphi(s(t))\psi^T(s(t)) + \beta\psi(s(t))\varphi^T(s(t)))W,$$

$$\frac{dW}{dt} = \eta(t)(I - \varphi(s(t))s^T(t))W,$$

где α и β – некоторые параметры, заданные на интервале $[0, 1]$ и выбираемые обычно из эмпирических соображений.

Введем в рассмотрение алгоритмы дискретного времени, соответствующие указанным выше непрерывным правилам. При этом модифицированному правилу Чихотского соответствует алгоритм

$$W(k+1) = W(k) + \eta(k)W(k)(I - \varphi(s(k))\psi^T(s(k)))W(k),$$

правилу Чихотского-Амари-Янга –

$$W(k+1) = W(k) + \eta(k)(I - \varphi(s(k))\psi^T(s(k)))W^{-1}(k),$$

правилу на базе градиента Амари –

$$W(k+1) = W(k) + \eta(k)(I - \varphi(s(k))\psi^T(s(k)))W(k),$$

правилу Кардоссо –

$$W(k+1) = W(k) + \eta(k)(I - s(k)s^T(k) - \alpha\varphi(s(k)) \times \psi^T(s(k)) + \beta\psi(s(k))\varphi^T(s(k)))W(k)$$

и, наконец,

$$W(k+1) = W(k) + \eta(k)(I - \varphi(s(k))s^T(k))W(k).$$

В классе непрерывных нейронных сетей для анализа независимых компонент весьма эффек-

тивной показала себя сеть Чихотского-Унбехауэна [2], содержащая кроме фильтров высоких частот (ФВЧ) для исключения постоянной компоненты дополнительные фильтры низких частот (ФНЧ) для подавления нежелательных колебаний в выходном сигнале в процессе обучения. Данная сеть описывается правилами обучения вида

$$\frac{d\tilde{w}_{ij}(t)}{dt} = \eta(\beta(t)\varphi(s_i(t))\psi(s_j(t)*h(t)) - \alpha\tilde{w}_{ij}), \quad (1)$$

$$\frac{dw_{ij}(t)}{dt} = \mu\tilde{w}_{ij}, \quad i, j = 1, 2, \dots, n, \quad (2)$$

где $\eta = \frac{1}{\tau_1}$; $\mu = \frac{1}{\tau}$; $\alpha > 0$; $\beta(t) \geq 0$; $\lim_{t \rightarrow \infty} \beta(t) = 0$.

Для решения задач обработки изображений вместо (1) и (2) целесообразно ввести их дискретные аналоги

$$\tilde{w}_{ij}(k+1) = \tilde{w}_{ij}(k) + \eta(k)(\beta(k)\varphi(s_i(k))\psi(s_j(k)) - \bar{s}_j(k)) - \lambda\tilde{w}_{ij}(k), \quad (3)$$

$$\bar{s}_j(k+1) = \bar{s}_j(k) + \eta_s(k)(s_j(k+1) - s_j(k)), \quad (4)$$

$$w_{ij}(k+1) = (1 - \mu)w_{ij}(k) + \mu\tilde{w}_{ij}(k+1), \quad (5)$$

отличающиеся тем, что вместо операции высокочастотной фильтрации в (1) используется операция исключения среднего, вычисляемого с помощью соотношения (4), и реализуемая с помощью блока исключения среднего (БИС), а вместо низкочастотной фильтрации (2) – операция экспоненциального сглаживания (5) с параметром забывания μ , реализуемая с помощью блока экспоненциального сглаживания (БЭС). На рис. 4 приведена схема БИС, а на рис. 5 – БЭС.




Рис. 4. Блок исключения среднего (БИС)




Рис. 5. Блок экспоненциального сглаживания (БЭС)

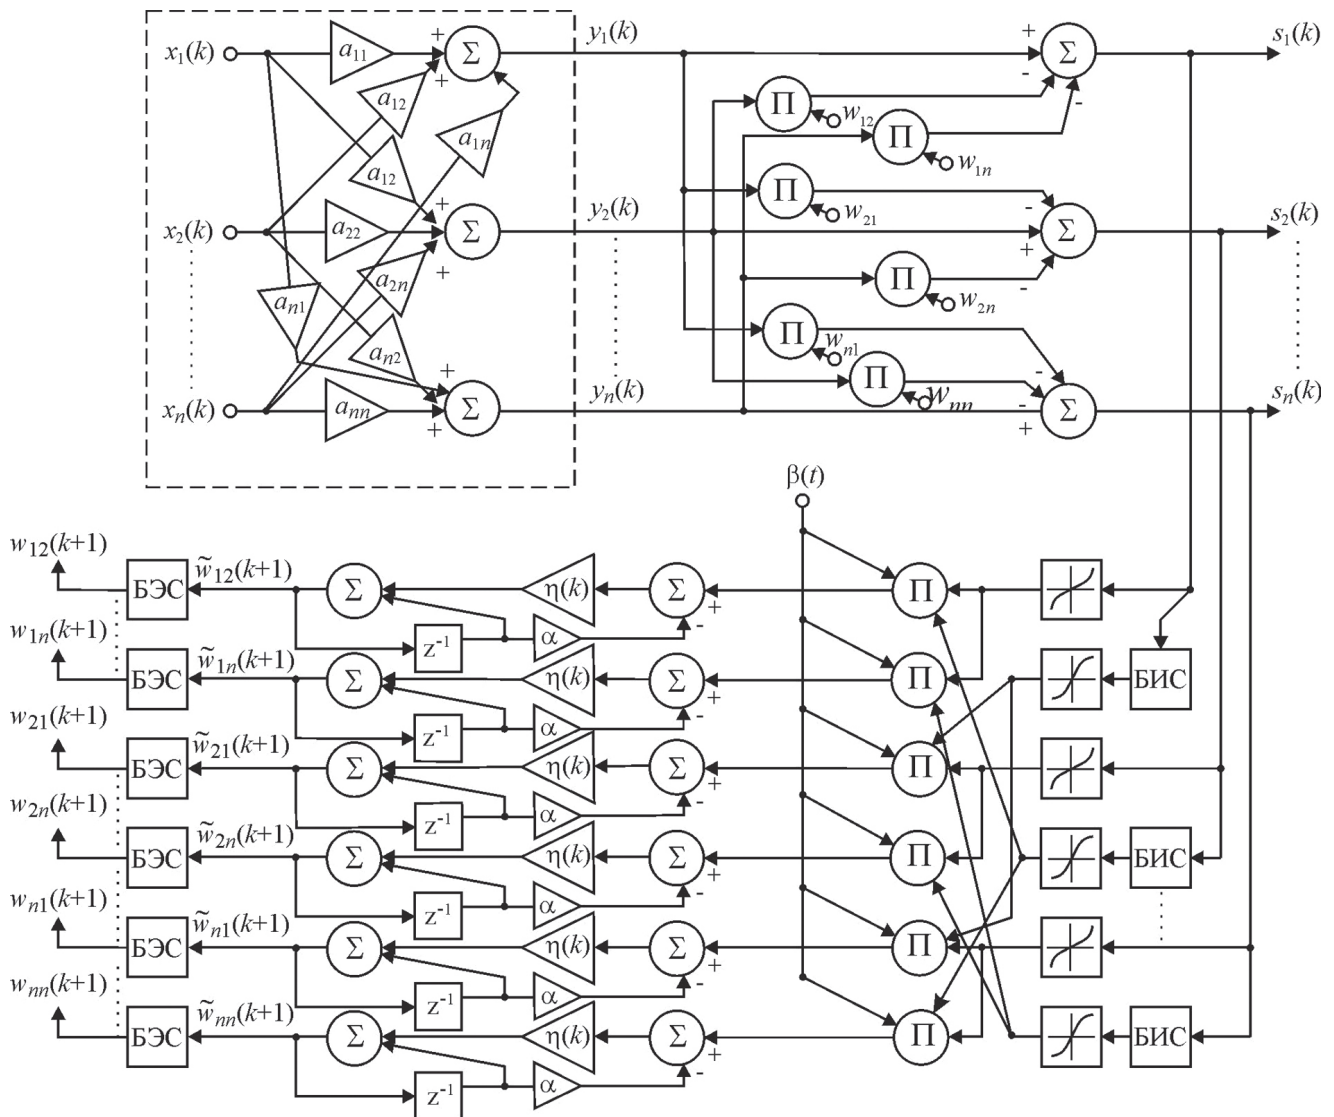


Рис. 6. Нейронная сеть для анализа независимых компонент в дискретном времени

На рис. 6 приведена архитектура нейронной сети для анализа независимых компонент на основе соотношений (3)-(5).

Выводы

Итак, в общем случае задача слепой сепарации может решаться на основе однослойных архитектур, содержащих в качестве нейронов адаптивные линейные ассоциаторы и предназначенных изначально для решения задач анализа главных компонент. Модифицированы алгоритмы обучения, позволяющие в реальном времени настраивать матрицу синаптических весов и обладающие высоким быстродействием и простотой численной реализации. В итоге предложена архитектура сети слепой сепарации и рекуррентная процедура ее обучения, позволяющие обрабатывать сильно “зашумленные” нестационарные сигналы. Предложенная нейронная сеть в процессе своего функционирования реализует лишь три элементарные операции сло-

жения, умножения и сдвига назад, что делает ее реализацию крайне простой. Особенно актуальным это становится в случаях, когда обработка производится в последовательном on-line режиме.

Список литературы: 1. Comon P. Independent component analysis. A new concept? // Signal Processing. – 1994. – Vol. 36. – P. 287-314. 2. Cichocki A., Unbehauen R. Neural networks for optimisation and signal processing. – Stuttgart: Teubner, 1993. – 526p. 3. Karhunen J., Oja E., Wang I., Vigarito R., Joutsensablo J. A class of neural network for independent component analysis // IEEE Trans. on Neural Networks. – 1995. – No 8 – P.487-504. 4. Girolami M., Cichocki A. Amari S.I. A common neural network model for exploratory data analysis and independent component analysis // IEEE Trans. on Neural Networks. – 1997. – No 9. – P.1495 – 1501. 5. Cardoso J.-F. Blind signal separation: Statistical principles // Proc. IEEE – 1998. – Vol. 86. – P.2009-2025. 6. Amari S., Cichocki A. Adaptive blind signal processing – neural network approaches // Proc. IEEE – 1998. – Vol. 86. – P.2026-2048. 7. Girolami M. Self-organizing mental networks. Independent component analysis and blind source

separation. — Berlin: Springer Verlag, 1999. — 271p. **8. Jutten C., Herault J.** Independent component analysis (INCA) versus principal component analysis // J.L. Lacoume (Ed.). — “Signal Processing 4”. — Amsterdam: Elsevier, 1988. — P.643-646. **9. Jutten C., Herault J.** Blind separation of sources. Part I: An adaptive algorithm based on neuromimetic architecture // Signal Processing. — 1991. — Vol. 24. — P.1-10. **10. Осовский, С.** Нейронные сети для обработки информации [Текст] / С. Осовский. — Москва: Финансы и статистика, 2002. — 314с. **11. Haykin S.** Neural networks. A comprehensive foundation. —N.J.: Prentice Hall, Inc., 1999. — 842 p. **12. Изерман, Р.** Цифровые системы управления [Текст] / Р. Изерман. — Москва: Мир, 1984. — 541 с. **13. Yip K.-H., Guan L., Liu W.** A recursive soft-decision approach to blind image deconvolution // IEEE Trans. on Signal Processing. — 2003. — Vol. 51. — P. 515-526.

Поступила в редколлегию 24.02.2010 г.

УДК 004.032 26

Нейрона мережа та алгоритм її навчання для аналізу незалежних компонент в задачах обробки зображень / В.П. Машталір, А. Е. Ведмідь, Е.С. Сакало // Біоніка інтелекту: наук.-техн. журнал. — 2010. — № 1 (72). — С. 33–37.

Для вирішення задачі відновлення зображень в роботі запропонована та проаналізована нейронна мережа для реконструкції вхідних сигналів в припущенні їх взаємної статичної незалежності.

Л. 6. Бібліогр.: 13 найм.

UDC 004.032 26

Neural network and learning algorithm for independent component analysis in processing of images / A.G. Vedmed V.P. Mashtalir, E.S. Sakalo // Bionics of Intelligence: Sci. Mag. — 2010. — № 1 (72). — P. 33–37.

For the decision of task of proceeding in images in process offered and analysed a neuron network is for the reconstruction of entrance signals in supposition them mutual static independence.

Fig. 6. Ref.: 13 items.