

УДК 004.8+004.93

В.Н. Бондарев, доцент, канд. техн. наук

Севастопольский национальный технический университет

ул. Университетская 33, г. Севастополь, Украина, 99053

E-mail: vbondarev@sevntu.com.ua

ПРАВИЛО ОБУЧЕНИЯ КАСКАДНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ ВЫДЕЛЕНИЯ ОКРАШЕННЫХ ГАУССОВЫХ СИГНАЛОВ

Рассматривается искусственная нейронная сеть, обеспечивающая последовательное выделение окрашенных гауссовых сигналов из их смеси. Предложено правило обучения каскадной нейронной сети, основанное на критерии минимума среднего квадрата ошибки предсказания, упрощающее реализацию сети в реальном времени. Приводятся графики выделенных сигналов и значения индексов эффективности.

Ключевые слова: каскадная искусственная нейронная сеть, выделение окрашенных гауссовых сигналов, слепое разделение сигналов, средний квадрат ошибки предсказания

Выделение сигналов из смеси с другими сигналами или шумами находит широкое применение во многих областях науки и техники: обработке биомедицинских сигналов, анализе геофизических данных, обработке речи, анализе акустических шумов механизмов, беспроводной связи и др. При этом во многих случаях выделение сигналов осуществляют на основе метода независимого компонентного анализа (НКА), в соответствии с которым предполагается, что исходные сигналы-источники являются статистически независимыми и негауссовыми [1, 2]. В частности, в работе [3] предложено правило самообучения каскадной искусственной нейронной сети (ИНС) для слепого выделения сигналов, использующее критерий максимума абсолютного значения эксцесса выделяемого сигнала, т.е. повышающее его негауссовость.

Если выделяемые сигналы являются статистически зависимыми или характеризуются значениями эксцесса близкими к нулю (т.е. являются гауссовыми), то алгоритмы, основанные на принципах НКА, оказываются неэффективными [2].

Цель статьи состоит в разработке простого правила обучения каскадной ИНС для выделения окрашенных гауссовых сигналов, которые характеризуются специфической временной структурой.

Предположим, что специфическая временная структура исходных сигналов задаётся авторегрессионной (АР) моделью

$$s_i(k) = u_i(k) + \sum_{p=1}^P a_i(p)s_i(k-p), \quad (1)$$

где $s_i(k)$ — неизвестный i -ый сигнал-источник, $i=1...n$; $u_i(k)$ — белый шум с нормальным законом распределения; P — порядок модели; $a_i(p)$ — коэффициенты АР-модели, $p=1...P$; k — целочисленный индекс, соответствующий номеру отсчета.

Последовательное (поочерёдное) выделение сигналов из смеси может быть выполнено с помощью каскадной ИНС, общая схема применения которой изображена на рисунке 1 [2, 3]. Здесь наблюдаемый входной вектор $\mathbf{x} = [x_1, ..., x_m]^T$, компоненты которого представляют собой аддитивную смесь сигналов-источников $s_1, ..., s_n$, описывается выражением

$$\mathbf{x} = \mathbf{A}\mathbf{s},$$

где $\mathbf{A}_{m \times n}$ — неизвестная смешивающая матрица, $m \geq n$; $\mathbf{s} = [s_1, ..., s_n]^T$ — вектор ненаблюдаемых сигналов-источников.

Сеть функционирует в два этапа. На первом этапе вектор $\mathbf{x}$ преобразуется с помощью адаптивно вычисляемой матрицы $\mathbf{V}$ к вектору $\mathbf{x}_1 = [x_{11}, ..., x_{1m}]^T$, имеющему характеристики белого шума, что устраняет корреляционную зависимость между его компонентами. На втором этапе с помощью ИНС, содержащей чередующиеся каскады выделения очередного сигнала и удаления его из смеси, формируются выходные сигналы $y_i(k)$, являющиеся оценками сигналов-источников $s_i(k)$. Выделение очередного сигнала $y_i(k)$ из смеси выполняется адаптивным линейным элементом (АЛЭ) за счет подстройки его весовых коэффициентов в соответствии с выбранным правилом обучения ИНС. При этом правило обучения выводится исходя из предположения о том, что исходные сигналы являются статистически независимыми и негауссовыми. После выделения очередного сигнала он удаляется из смеси и далее процедура повторяется.




Рисунок 1 — Общая схема применения каскадной ИНС

В отличие от [2, 3] в рассматриваемом случае исходные сигналы могут быть статистически зависимыми и гауссовыми. Для выделения таких сигналов необходимо, чтобы рассматриваемая ИНС могла дополнительно восстанавливать параметры модели (1), т.е. контролировать временную структуру выделяемых сигналов. С этой целью в работе [2] предлагается последовательно АЛЭ включить фильтр линейного предсказания с передаточной функцией $B_1(z)$ (рисунок 2). Адаптивно вычисляемые коэффициенты этого фильтра будут обеспечивать восстановление АР-модели (1) очередного выделяемого сигнала, в соответствии с которой

$$A_i(z) = \sum_{p=1}^P a_i(p) z^{-p},$$

где $A_i(z)$ — передаточная функция рекурсивной составляющей АР-модели.




Рисунок 2 — Каскадная ИНС с линейным предсказателем

Взаимосвязь входа-выхода ИНС и фильтра линейного предсказания, изображенного на рисунке 2, описывается формулами:

$$y_1(k) = \mathbf{w}_1^T \mathbf{x}_1(k), \quad (2)$$

$$\epsilon_1(k) = y_1(k) - \sum_{p=1}^P b_1(p) y_1(k-p) = \mathbf{w}_1^T \mathbf{x}_1(k) - \mathbf{b}_1^T \bar{\mathbf{y}}_1, \quad (3)$$

где $\mathbf{w}_1 = [w_{11}, w_{12}, \dots, w_{1m}]^T$ — вектор коэффициентов АЛЭ1; $\epsilon_1(k)$ — ошибка предсказания; $\mathbf{b}_1 = [b_1(1), b_1(2), \dots, b_1(P)]^T$ — вектор коэффициентов фильтра линейного предсказания с передаточной функцией $B_1(z) = \sum_{p=1}^P b_1(p) z^{-p}$; $\bar{\mathbf{y}}_1 = [y_1(k-1), y_1(k-2), \dots, y_1(k-P)]^T$ — вектор предыдущих значений выделяемого сигнала $y_1(k)$.

Таким образом, очередной каскад ИНС имеет два выхода: $y_1(k)$, который оценивает извлекаемый сигнал-источник и $\epsilon_1(k)$, который представляет ошибку предсказания. Задача заключается в оптимальном оценивании значений векторов $\mathbf{w}_1$ и $\mathbf{b}_1$, чтобы сеть выделяла только один сигнал из смеси. ИНС успешно выделит на выходе первого каскада i -ый сигнал-источник, если вектор весовых коэффициентов $\mathbf{w}_1$ удовлетворяет условию

$$\mathbf{w}_1^T \bar{\mathbf{A}}_1 = \mathbf{e}_i^T,$$

где $\bar{\mathbf{A}}_1 = \mathbf{V}\mathbf{A}$ и вектор $\mathbf{e}_i$ содержит только один ненулевой элемент в i -ой строке. В этом случае $y_1(k) = \mathbf{e}_i^T \mathbf{s} = c_1 s_i(k)$, где c_1 — произвольный ненулевой масштабный множитель.

Для достижения указанной цели осуществляется минимизация функции стоимости

$$J(\mathbf{w}_1, \mathbf{b}_1) = \frac{1}{2} E\{\epsilon_1^2\} + \frac{\beta}{4} (1 - E\{y_1^2\})^2, \quad (4)$$

где $\beta > 0$ — коэффициент штрафа. Первый член функции стоимости обеспечивает поиск минимума среднего квадрата ошибки предсказания $E\{\epsilon_1^2\}$. Ошибка предсказания будет минимальной, если $\epsilon_1(k) = c_1 u_i(k)$, а это возможно только в случае $y_1(k) = c_1 s_i(k)$. Таким образом, минимизируя средний квадрат ошибки предсказания, мы добиваемся того, чтобы на выходе ИНС выделялся один из исходных сигналов. Второй член функции стоимости исключает тривиальный случай $y_1(k) = 0$ и ограничивает дисперсию выхода $y_1(k)$ единичным значением.

Минимизация функции стоимости (4) позволяет получить следующее правило обучения [2]:

$$\mathbf{w}_1(k+1) = \mathbf{w}_1(k) - \eta_1(k)[\epsilon_1(k)\tilde{\mathbf{x}}_1(k) - \gamma(k)y_1(k)\mathbf{x}_1(k)], \quad (5)$$

$$\mathbf{b}_1(k+1) = \mathbf{b}_1(k) + \tilde{\eta}_1(k)\epsilon_1(k)\bar{\mathbf{y}}_1, \quad (6)$$

где $\gamma(k) = \beta[1 - m_2(y_1(k))]$ — коэффициент забывания; $m_2(y_1(k))$ — оценка второго момента выделяемого сигнала $y_1(k)$; $\tilde{\mathbf{x}}_1(k) = \mathbf{x}_1(k) - \sum_{p=1}^P b_1(p)\mathbf{x}_1(k-p)$ — вектор ошибок предсказания модифицированного вектора смеси $\mathbf{x}_1$; $\eta_1(k)$ и $\tilde{\eta}_1(k)$ — коэффициенты скорости обучения.

Практическое применение правила (5) предполагает значительные вычислительные затраты, обусловленные необходимостью m -кратного вычисления свертки $\sum_{p=1}^P b_1(p)\mathbf{x}_1(k-p)$. Это усложняет алгоритм обучения и затрудняет его реализацию в реальном времени. Кроме этого, требуется вычислять оценку $m_2(y_1)$ непосредственно в процессе выделения сигнала y_1 , что приводит к неустойчивости в работе ИНС.

С целью упрощения алгоритма обучения и повышения устойчивости выделения сигналов воспользуемся более простым критерием минимума среднего квадрата ошибки предсказания

$$J(\mathbf{w}_1, \mathbf{b}_1) = \frac{1}{2} E\{\epsilon_1^2\} \text{ при } \|\mathbf{w}_1\| = 1. \quad (7)$$

Для поиска оптимальных значений $\mathbf{w}_1$ в условиях простого ограничения $\|\mathbf{w}_1\| = 1$ будем использовать проекционный подход, в соответствии с которым на каждой итерации выполняется поиск оптимального вектора весов $\mathbf{w}_1$ без учета ограничений, например, с помощью метода нисходящего градиента, а затем осуществляется нормализация вектора $\mathbf{w}_1$ по отношению к его длине.

Применяя стандартный подход нисходящего градиента к минимизации (7) с учетом (2) и (3), получаем

$$\frac{d\mathbf{w}_1}{dt} = -\eta_1(t) \frac{\partial J(\mathbf{w}_1, \mathbf{b}_1)}{\partial \mathbf{w}_1} = -\eta_1(t) E\{\epsilon_1(t)\mathbf{x}_1(t)\}, \quad (8)$$

$$\frac{d\mathbf{b}_1}{dt} = -\tilde{\eta}_1(t) \frac{\partial J(\mathbf{w}_1, \mathbf{b}_1)}{\partial \mathbf{b}_1} = -\tilde{\eta}_1(t) E\{\epsilon_1(t)\bar{\mathbf{y}}_1(t)\}, \quad (9)$$

где t — время; E — символ математического ожидания.

Отсюда с помощью стохастической аппроксимации и дискретизации выражений (8) и (9) получим следующее простое правило обучения

$$\mathbf{w}_1^+(k+1) = \mathbf{w}_1(k) - \eta_1(k)\epsilon_1(k)\mathbf{x}_1(k), \quad (10)$$

$$\mathbf{b}_1(k+1) = \mathbf{b}_1(k) + \tilde{\eta}_1(k)\epsilon_1(k)\bar{\mathbf{y}}_1(k), \quad (11)$$

где

$$\mathbf{w}_1(k+1) = \mathbf{w}_1^+(k+1) / \|\mathbf{w}_1^+(k+1)\|.$$

Заметим, что формулы (6) и (11) совпадают, а формула (10) значительно проще формулы (5), так как не использует текущих оценок момента второго порядка и не требует m -кратного вычисления свертки.

В соответствии с рисунком 1 после выделения сигнала y_1 его удаляют из смеси x_1 , используя простое соотношение [2, 4]

$$x_2(k) = x_1(k) - w_1 y_1(k).$$

Выделение и удаление последующих сигналов из X_2 выполняется аналогично.

Ниже приведены результаты компьютерного моделирования каскадной ИНС, использующей предложенное правило обучения (10) – (11), в сопоставлении с ИНС, использующей правило обучения (5) – (6). При этом в качестве исходных использовались два окрашенных гауссовых сигнала s_1 и s_2 , каждый из которых получался в результате фильтрации случайной гауссовой последовательности нерекурсивным фильтром 20-го порядка. Коэффициенты фильтра выбирались случайно из диапазона $[-1 \ 1]$. Нормализованные значения эксцессов сигналов s_1 и s_2 были близки к нулю ($-0,0065$ и $-0,0176$, соответственно). Сигналы s_1 и s_2 смешивались с помощью матрицы A , строки которой имели значения $[0,82 \ -0,90]$ и $[-0,54 \ -0,84]$. Начальные значения весовых коэффициентов АЛЭ и фильтра предсказания задавались случайными числами в диапазоне от $-0,1$ до $0,1$. Порядок предсказывающего фильтра ИНС $P=5$. Коэффициенты скорости обучения $\eta_1(k)$ и $\tilde{\eta}_1(k)$ были равны $0,001$. Коэффициент $\beta = 4$. Вычисление выбеливающей матрицы V осуществлялось рекурсивно по формуле [1, 2]

$$V(k+1) = V(k) - \mu(k)[v(k)v^T(k) - I]V(k),$$

где $\mu(k)$ — коэффициент, определяющий скорость адаптации; I — единичная матрица.

На рисунке 3 изображены графики исходных колебаний s_1 и s_2 , графики, представляющие вектор смеси $x=[x_1, x_2]$, и графики выделенных сигналов y_1 и y_2 . Визуальное сравнение выделенных сигналов показывает, что предложенное правило обучения сети обеспечивает успешное решение задачи. При этом $y_1 \approx c_1 s_2$ и $y_2 \approx c_2 s_1$, где c_1 и c_2 — масштабные множители.




Рисунок 3 — Графики сигналов ИНС

Для количественной оценки полученных результатов можно воспользоваться индексом эффективности выделения сигналов на выходе j -го каскада ИНС [4]

$$PI_j = \frac{1}{n} \left(\sum_{i=1}^n \frac{e_{ji}^2}{e_{ji*}^2} - 1 \right),$$

где $e_j = [e_{j1}, e_{j2}, \dots, e_{jn}]$, $\bar{A}_j = (I - w_{j-1} w_{j-1}^T) \bar{A}_{j-1}$, $e_{ji*} = \max\{|e_{ji}|\}$, $i = 1, \dots, n$.

Чем меньше значение этого индекса, тем ближе выделенный сигнал на выходе соответствующего каскада ИНС к одному из исходных сигналов. Значения индексов эффективности для рассматриваемого примера сведены в таблицу 1.

Таблица 1 — Значения индексов эффективности

Правило обучения	Индекс эффективности	
	PI_1	PI_2
(5) — (6)	0,000416	0,000496
(10) — (11)	0,000247	0,000019

Из таблицы следует, что индекс PI_1 для предложенного правила (10)–(11) сопоставим по значению с соответствующим индексом для правила (5)–(6), а индекс PI_2 оказался существенно меньше. При этом правило (10)–(11) значительно проще правила (5)–(6).

Таким образом, правило (10)–(11) может успешно использоваться для обучения каскадной ИНС при выделении гауссовых сигналов, временная структура которых задаётся АР-моделью. Применение этого правила позволяет существенно упростить реализацию каскадной ИНС, что весьма важно для работы в реальном времени. Кроме этого, проведенные многочисленные эксперименты показали, что в ряде случаев правило (5)–(6) дает неустойчивые результаты, так как приводит к выделению одного и того же сигнала на выходе каждого из каскадов ИНС.

Так как реальные сигналы в ходе их передачи от источников сигналов к первичным измерительным преобразователям подвергаются свертке с импульсными характеристиками каналов передачи, то *задачей дальнейших исследований* можно считать выделение окрашенных гауссовых сигналов с учетом динамических свойств указанных каналов.

Библиографический список использованной литературы

1. Hyvarinen A. Independent component analysis / A. Hyvarinen, J. Karhunen, E. Oja. — NY: John Wiley & Sons Inc., 2001. — 479 p.
2. Cichocki A. Adaptive blind signal and image processing / A. Cichocki, S. Amari. — NY: John Wiley & Sons Inc., 2002. — 534 p.
3. Бондарева О.В. Каскадная нейронная сеть для выделения акустического сигнала утечки водопровода / О.В. Бондарева, В.Н. Бондарев, В.С. Чернега // Вестник СевГТУ. Сер. Информатика, электроника, связь: сб. науч. тр. — Севастополь, 2008. — Вып. 93 — С. 53–56.
4. Thawonmas R. A cascade neural network for blind signal extraction without spurious equilibria / R. Thawonmas, A. Cichocki, S. Amari // IEICE Trans. on Fundamentals of Electronics, Communications and Computer Sciences. — 1998. — Vol. E81-A. — № 9. — P. 1833–1846.

Поступила в редакцию 20.12.2010 г.

Бондарев В.М. Правило навчання каскадної нейронної мережі для виділення забарвлених гауссових сигналів

Розглядається штучна нейронна мережа, що забезпечує послідовне виділення забарвлених гауссових сигналів з їх суміші. Запропоновано правило навчання каскадної нейронної мережі, засноване на критерії мінімуму середнього квадрата помилки прогнозу, що спрощує реалізацію мережі у реальному часі. Приводяться графіки виділених сигналів і значення індексів ефективності.

Ключові слова: каскадна штучна нейронна мережа, виділення забарвлених гауссових сигналів, сліпе розділення сигналів, середній квадрат помилки прогнозу.

Bondarev V.N. A learning rule of the cascade neural network for colored Gaussian signal extraction

Artificial neural network for consecutive colored Gaussian signal extraction from its mixture is considered. Proposed is the cascade neural network learning rule based on criteria of the minimum average square of predictive error, which allows ease the on-line realization of the network. Plots of extracted signals and the performance indexes are demonstrated.

Keywords: cascade neural network, colored Gaussian signal extraction, blind signal separation, mean square predictive error.