

УДК 658.012:681.32:621.38

*Л.И. Тимченко, В.В. Мельников, В.В. Шпакович, Н.И. Кокряцкая*

Государственный экономико-технологический университет транспорта, г. Киев, Украина  
timchen@list.ru

## Разработка методов обучения параллельно-иерархической сети для высокоэффективного распознавания образов

В статье рассмотрен метод параллельно-иерархического преобразования на основе популяционного кодирования и его применение для задач распознавания образов. Также рассмотрены положения, которые использованы для разработки методов обучения ПИ сети, использующих идею популяционного кодирования в искусственной нейронной сети. Разработаны математические модели обучения ПИ сети, а также комбинированный метод обучения ПИ сети для распознавания статических и динамических образов. Приведены теоретические сведения и экспериментальные исследования.

### Введение

В классической работе [1] Мак-Каллок и Питс описывают логику вычислений в нейронных сетях, основанную на математической логике и результатах, полученных в нейрофизиологии, при которой формализованная модель нейрона отвечает принципу «все или ничего». Сеть с такой парадигмой составлена из большого количества элементарных вычислительных единиц, соединенных правильно сконфигурированными и синхронно работающими синаптическими весами, и способна выполнять любые вычисления. Этот результат стал реальным прорывом в области моделирования нервной системы.

Одним из современных направлений в этой области являются параллельно-иерархические (ПИ) сети [2], обладающие хорошей вычислительной производительностью благодаря однородной организации параллельно-распределенной структуры, а также способностью к обучению и обобщению. (Обобщение – это выработка обоснованного результата на основе входных данных, который не формируется на этапе обучения.) Эти информационно-вычислительные свойства позволяют ПИ сетям решать сложные задачи, для чего их необходимо интегрировать в более сложные системы.

### Исходные положения для разработки методов обучения ПИ сети

Свойство, являющееся важнейшим для любой нейронной сети, – это способность сети обучаться, получая данные из окружающей среды, и совершенствовать свою эффективность в результате процесса обучения. Нейронная сеть обучается посредством интерактивного процесса настройки синаптических весов и порогов. В идеале нейронная сеть получает знание об окружающей среде после каждой итерации процесса обучения. Можно определить обучение как процесс, в котором свободные параметры сети адаптируются через процесс стимуляции окружающей средой, в которую встроена сама сеть. Тип обучения определяется применением способа обучения с изменяющимися параметрами.

Это определение процесса обучения означает следующее выполнение последовательности событий:

1. Нейронная сеть стимулируется окружающей средой.
2. В результате стимуляции происходят изменения свободных параметров нейронной сети.
3. Нейронная сеть отвечает по-новому на стимулы окружающей среды, поскольку имеются изменения внутренней структуры сети.

Заранее определенный набор четких правил решения проблемы обучения называется алгоритмом обучения. Известно, что универсального алгоритма обучения не существует, ведь все алгоритмы обучения отличаются способом настройки синаптических весов нейронов. Еще одним характерным отличием нейросетей, созданных из взаимосвязанных нейронов, является способ связи сети с окружающей средой. В этом контексте говорят о парадигме обучения, связанной с моделью окружающей среды.

## Описание метода организации ПИ сети

Анализ образа заключается в последовательном преобразовании совпадающих и выявлении (фильтрации) несовпадающих во времени составляющих образа при переходе элементов нейронной сети из текущих энергетических состояний с одними пространственными координатами в состояния с меньшей энергией и другими пространственными координатами. Условием перехода составляющих образа на следующий уровень является наличие динамики взаимного совпадения промежуточных результатов обработки во времени в одноименных каналах нижнего уровня. Результат анализа образа формируется из изолированных в пространственно-временной области составляющих образа [3].

Рассмотрим математическую модель параллельного разложения множества  $\mu = \{a_i\}$ ,  $i = \overline{1, n}$  [3], [4], применяемого в каждой ветви ПИ сети.

$$\sum_{i=1}^n a_i = \sum_{j=1}^R \left( n - \sum_{k=0}^{j-1} n_k \right) (a^j - a^{j-1}), \quad (1)$$

где  $a_i \neq 0$ ,  $R$  – размерность данного множества,  $a^k$ ,  $k = \overline{1, R}$ , – элементы подмножеств, состоящих из одинаковых элементов,  $n_k$  – число элементов в  $k$ -м подмножестве (то есть кратность числа  $a_i$ ),  $a^j$  – элемент множества  $\{a^k\}$ , выбранный на  $j$ -м шаге,  $j = \overline{1, R}$ ,  $a^0 = 0$ ,  $n_0 = 0$ .

Воспользуемся идеей популяционного кодирования [5], построив модель какого-либо конечного действия, совершаемого по всем текущим действиям.

Для ПИ сети усредненными параметрами могут быть количество элементов в ветви каждого уровня, которые определяются на основе модели вида (1), и значения самого элемента. Очевидно, что на уровне ветвей нейронной сети данное конечное действие при реализации популяционного кодирования отвечает усредненным параметрам этой сети [2]. В этом случае текущий образ, который распознается, будет отображаться текущей ПИ сетью и сравниваться с эталонной ПИ сетью с усредненными параметрами:

$$\bar{a}_{i,j} = \frac{1}{NM} \sum_{ij} a_{i,j}. \quad (2)$$

Обозначив среднее значение произвольного элемента первого уровня через  $\bar{a}_{i,j}^1$ , второго уровня –  $\bar{a}_{i,j}^2$ , третьего уровня –  $\bar{a}_{i,j}^3$  и т.д.  $k$ -го последнего уровня –  $\bar{a}_{i,j}^k$ , а также среднее число элементов первого уровня –  $N_{\bar{a}_{i,j}^1}$ , второго уровня –  $N_{\bar{a}_{i,j}^2}$ , третьего уровня –  $N_{\bar{a}_{i,j}^3}$  и т.д.  $k$ -го уровня –  $N_{\bar{a}_{i,j}^k}$ , можно сформировать ПИ сеть с усредненными параметрами.

Синтезированная таким способом структура ПИ сети с усредненными параметрами показана на рис. 1:

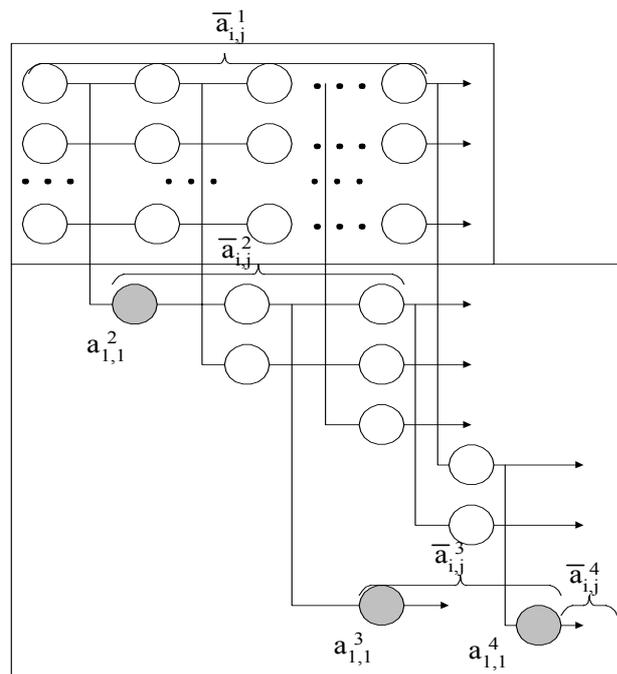


Рисунок 1 – Структура ПИ сети [3] с усредненными параметрами

Текущий образ или исследуемый образ, который обработан ПИ сетью с текущими параметрами  $a_{i,j}^1, a_{i,j}^2, a_{i,j}^3, \dots, a_{i,j}^k$  и соответствующим числом элементов в ветвях каждого уровня –  $N_{a_{i,j}^1}, N_{a_{i,j}^2}, N_{a_{i,j}^3}, \dots, N_{a_{i,j}^k}$ , сравнивается с эталонным обра-

зом, который обработан ПИ сетью с усредненными параметрами –  $\bar{a}_{i,j}^1, \bar{a}_{i,j}^2, \bar{a}_{i,j}^3, \dots, \bar{a}_{i,j}^k$  и средним числом элементов в ветвях соответствующего уровня –  $N_{\bar{a}_{i,j}^1}, N_{\bar{a}_{i,j}^2}, N_{\bar{a}_{i,j}^3}, \dots, N_{\bar{a}_{i,j}^k}$ .

Если воспользоваться препарированием элементов ПИ сети для каждого уровня [6], то от усредненных параметров  $\bar{a}_{i,j}^1, \bar{a}_{i,j}^2, \bar{a}_{i,j}^3, \dots, \bar{a}_{i,j}^k$  можно перейти на основе трехуровневого кодирования к их отображению бинаризованными препаратами (-1, 0, +1). Затем определяются массивы разностей элемента со средним значением

яркостей элементов разложения изображения (или его фрагмента), в котором находится элемент изображения:

$$R_{i,j} = a_{i,j} - \bar{a}_{i,j}. \quad (3)$$

Для препарирования начального изображения полученные разности сравниваются с порогом  $\delta$ , то есть

$$a_{i,j}^{(\delta)} = \begin{cases} 1, & \text{если } R_{i,j} > \delta \\ -1, & \text{если } R_{i,j} < -\delta \\ 0, & \text{если } |R_{i,j}| \leq \delta \end{cases}. \quad (4)$$

Причем, порог  $\delta$  вычисляется из условия (5):

$$N_t^{(1)} \times N_t^{(-1)} \times N_t^{(0)} = \text{Max}, \quad (5)$$

где  $N_t^{(1)}, N_t^{(-1)}, N_t^{(0)}$  – количества единичных, минус единичных и нулевых препаратов при каждом пороге  $t$  [7].

Для произвольного усредненного параметра трехуровневый переход может отображаться тремя видами препаратов: нулевым –  $a_{i,j}^0$ , положительным –  $a_{i,j}^1$ , отрицательным –  $a_{i,j}^{-1}$ . В этом случае ПИ сеть с числовыми отсчетами преобразуется в ПИ сеть с бинаризованными отсчетами  $a_{i,j}^0, a_{i,j}^1, a_{i,j}^{-1}$ . Тогда существенно упрощается процедура корреляционного сравнения бинаризованных отсчетов текущей и эталонной ПИ сетей.

Для формирования эталонов изображения необходимо провести обучение в пределах выборки. Для чего необходимо делать усреднение по элементам ветви каждого уровня, то есть формировать усредненные элементы  $\bar{a}_{i,j}^1, \bar{a}_{i,j}^2, \bar{a}_{i,j}^3, \dots, \bar{a}_{i,j}^k$ , переходя затем к бинаризованным препаратам  $a_{i,j}^0, a_{i,j}^1, a_{i,j}^{-1}$ . Выполнив вышеуказанные действия, можно сформировать ПИ сеть с эталонными параметрами для текущих изображений. После чего можно делать ее корреляционное сравнение с ПИ сетью, которая использует текущие параметры. (Под ПИ сетью с текущими параметрами понимается ПИ сеть с текущими значениями ее элементов  $a_{i,j}^1, a_{i,j}^2, a_{i,j}^3, \dots, a_{i,j}^k$  с переходом к бинаризованным препаратам  $a_{i,j}^0, a_{i,j}^1, a_{i,j}^{-1}$  и текущим числом элементов в ветвях каждого уровня  $N_{a_{i,j}^1}, N_{a_{i,j}^2}, N_{a_{i,j}^3}, \dots, N_{a_{i,j}^k}$ .)

Коэффициент корреляции  $p_{X,Y}$  между выборками двух случайных дискретных величин  $X, Y$  с математическими ожиданиями  $M_X, M_Y$  и среднеквадратичными отклонениями  $\sigma_X, \sigma_Y$  определялся как:

$$p_{X,Y} = \frac{COV(X,Y)}{\sigma_X \times \sigma_Y}, \quad (6)$$

где  $-1 \leq p_{X,Y} \leq 1$  и  $COV(X,Y) = \frac{1}{n} \sum_{i=1}^n (x_i - \mu_X)(y_i - \mu_Y)$ .

Очень важным обстоятельством является то, что коэффициент корреляции можно вычислять не только для каждой двух уровней, но и для двух ПИ сетей, что улучшает достоверность результата распознавания.

## Разработка математических моделей обучения параллельно-иерархической сети

Исходя из структуры ПИ сети и анализа правил обучения [8], можно сделать вывод, что наиболее оптимальным для обучения ПИ сети будет применение двух методов обучения с учителем: обучение на основе коррекции ошибок и обучение с использованием памяти.

Кратко опишем эти методы обучения ПИ сети.

Входным сигналом ПИ сети является вектор сигнала  $x(n)$ . Под  $n$  понимают дискретное время, или номер шага интерактивного процесса обучения ПИ сети. Выходной сигнал ПИ сети –  $y_k(n)$  сравнивается с желаемым выходом  $d_k(n)$ , в результате чего формируется сигнал ошибки  $e_k(n)$ . По определению:

$$e_k(n) = d_k(n) - y_k(n). \quad (7)$$

Сигнал ошибки будет инициализировать механизм управления, целью которого является применение последовательности коррекций сигнала ошибки ПИ сети. Эти изменения направлены на пошаговое приближение исходного сигнала  $y_k(n)$  к желаемому  $d_k(n)$ . Это достигается за счет минимизации функции стоимости или индекса производительности  $E(n)$ , значение которой вычисляется по формуле (8):

$$E(n) = \frac{e_k^2(n)}{2}, \quad (8)$$

где  $E(n)$  – текущее значение энергии ошибки.

Пошаговая коррекция параметров ПИ сети происходит до тех пор, пока параметры системы не достигнут абсолютно равновесного состояния (+1) в случае корректного распознавания, или абсолютно неравновесного состояния (-1) – в случае некорректного распознавания. В этой точке процесс обучения прекращается.

Минимизация функции стоимости  $E(n)$  происходит по дельта-правилу или правилу Видроу-Хофа [2]. Обозначим текущее значение параметра ПИ сети, отвечающее входному вектору  $x(n)$ ,  $j$ -му уровню ПИ сети на шаге дискретизации  $n$ . В соответствии с дельта-правилом изменение параметра  $\Delta\sigma_j(n)$  на этом шаге дискретизации определяется соотношением (9):

$$\Delta\sigma_j(n) = \eta e_k(n) x_j(n), \quad (9)$$

где  $\eta$  – положительная константа, определяющая скорость процесса обучения и используемая при переходе от одного шага к другому.

Вычислив величину изменения параметра  $\Delta\sigma_j(n)$  ПИ сети, можно определить его новое значение для следующего шага дискретизации:

$$\sigma_j(n+1) = \sigma_j(n) + \Delta\sigma_j(n). \quad (10)$$

Таким образом, их можно рассматривать как старое и новое значения параметров ПИ сети. Поэтому можно записать:

$$\sigma_j(n) = z^{-1}[\sigma_j(n+1)], \quad (11)$$

где  $z$  – оператор единичной задержки. Этот элемент представляет собой ячейку памяти.

При обучении, основанном на использовании памяти, весь предыдущий опыт накапливается в большом объеме правильно классифицированных образцов вида

«ВХОД-ВЫХОД» (12):

$$\{(x_i, d_i)\}_{i=1}^N, \quad (12)$$

где  $x_i$  – входной вектор,  $d_i$  – соответствующий ему желаемый исходный сигнал.

Если необходимо классифицировать определенный неизвестный вектор  $x_i$ , то из базы данных выбирается исходный сигнал, отвечающий входному сигналу, близкому к  $x_i$ .

Алгоритм обучения ПИ сети на основе использования памяти включает две основные составляющие:

- критерий, использующий для определения окружения вектора  $x_i$ ;
- правила обучения, применяющегося к образцу из окружения тестового вектора.

Согласно правилу ближайшего соседа [7] в соседние включается образец, ближайший к тестовому. Рассмотрим вектор (13):

$$x'_N \in \{x_1, x_2, \dots, x_N\}. \quad (13)$$

Данный вектор считается ближайшим соседом вектора  $x_i$ , если выполняется условие (14):

$$\min d(x_j, x_i) = d(x'_N, x_i), \quad (14)$$

где  $d(x'_N, x_i)$  – Эвклидово расстояние между векторами  $x_i$  и  $x_j$  [7]. Данное правило обучения не зависит от закона распределения, использующегося при генерировании образцов при обучении.

Вариацией классификатора на основе ближайшего соседа является классификатор  $k$ -ближайших соседей, описывающийся следующим образом.

Находим  $k$  классифицированных соседей, ближайших к входному тестовому вектору  $x_i$ , где  $k$  – некоторое целое число. Вектор  $x_i$  относим к классу, чаще других встречающийся среди  $k$ -ближайших соседей.

Таким образом, классификатор на основе  $k$ -ближайших соседей работает подобно устройству усреднения. Например, он может не учесть единичные выбросы (выбросы – это наблюдение, отличающееся от номинальной модели), как показано на рис. 2:

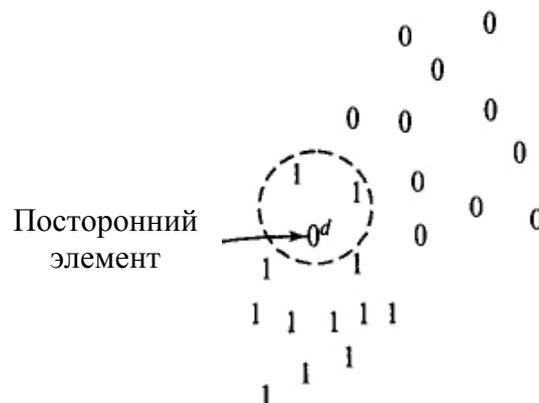


Рисунок 2 – Графическая интерпретация метода обучения ПИ сети на основе использования памяти

На рис. 2 область в штриховом круге содержит две точки, принадлежащие к классу 1, и одну, принадлежащую к классу 0, а точка  $d$  отвечает тестовому вектору  $x_i$ . При  $k = 3$  классификатор на основе  $k$ -ближайших соседей отнесет точку  $d$  к классу 1 несмотря на то, что она лежит ближе к выбросам, относящимся к классу 0.

## Разработка методов обучения параллельно-иерархической сети

Из результатов корреляционного сравнения изображений разных лиц, проведенного в работах [8], [9], видно, что информативным показателем является коэффициент корреляции на нулевом уровне ПИ сети. Его будем применять для верификации соответствию образов, а также для определения желаемого ответа в методе обучения, основанного на коррекции ошибок.

Из результатов корреляционного сравнения по уровням ПИ сети изображений разных лиц [8] видно, что информативными показателями для распознавания лиц являются коэффициенты корреляции на первом, среднем, предпоследнем и третьем с конца уровнях. Эти показатели будут вспомогательными при использовании метода обучения ПИ сети для распознавания статических образов.

Для обучения ПИ сети при распознавании статических образов будем использовать комбинированный метод, содержащий методы обучения, основанные на технологии «*sed learning*». Детальное описание комбинированного метода обучения приведено ниже.

Последовательность комбинированного метода основана на коррекции ошибок и на использовании памяти ПИ сети при распознавании статических образов:

1. Построение структуры ПИ сети избранного изображения.
2. Применение метода обучения, основанного на использовании памяти. Классификатором на основе  $k$ -ближайших соседей, используемых в данном методе, является число уровней ПИ сети.
3. Построение структуры ПИ сети эталонного изображения.
4. Применение метода обучения, основанного на коррекции ошибок. Критерием, используемым для верификации в данном методе, является коэффициент корреляции на нулевом уровне ПИ сети.
5. Проведение коррекции ошибок для коэффициентов корреляции производится на нулевом, первом, среднем, предпоследнем и третьем с конца уровнях ПИ сети. Коррекция проводится до тех пор, пока параметры сети придут к абсолютно равновесному состоянию (+1), или превысят его. Если значение параметров приводит к состоянию (-1) (или абсолютно неравновесному состоянию), то делается вывод о непринадлежности изображения к данному образу.

## Результаты экспериментальных исследований обучения параллельно-иерархической сети при распознавании статических и динамических образов

При обучении ПИ сети для распознавания статических образов для тестового примера использовано изображение AGJ-02 из Манчестерской базы человеческих лиц [10].

При распознавании тестового образа AGJ-02 и выборе из базы образа №1 AL-01 параметры ПИ сети пришли к неравновесному состоянию на третьем шаге. Поэтому делается вывод о непринадлежности изображения AGJ-02 к образу AL-01.

При распознавании тестового образа AGJ-02 и выборе из базы образа №1 AGJ-01 параметры ПИ сети пришли к равновесному состоянию на четвертом шаге. Поэтому делается вывод о принадлежности изображения AGJ-02 к образу AGJ-01.

При обучении ПИ сети для распознавания динамических образов тестовым примером являлся фрагмент трассы TV-029.

Таблица 1 – Результаты обучения ПИ сети при распознавании статических образов



Тестовое изображение AGJ-02:



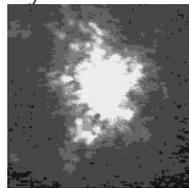
Выбранные образы: 1) AL-01 , 2) AGJ-01

№ шага обучения $n$	Изображение	$\sigma_0(n)$	$\sigma_1(n)$	$\sigma_{AVR}(n)$	$\sigma_{L-1}(n)$	$\sigma_{L-2}(n)$
1	AGJ-02	0,61	0,8	0,57	0,5	0,7
2	AGJ-02	0,75	0,82	0,77	<b>1</b>	0,9
3	AGJ-02	0,89	0,84	0,97	–	<b>1</b>
4	AGJ-02	<b>1,03</b>	0,86	<b>1,17</b>	–	–

Координаты фрагмента трассы TV-029, избранного на основе метода использования памяти, – (57.00; 34.00).

В табл. 1 и 2 выделенные цифровые значения жирным шрифтом означают, что процесс обучения для этого параметра на данном шаге обучения завершается, т.е. параметр достиг своего равновесного состояния.

Таблица 2 – Результаты обучения ПИ сети при распознавании динамических образов



Тестовый фрагмент TV-029:

№ шага обучения $n$	Фрагмент трассы	$X$	$Y$	$\sigma_0(n)$	$\sigma_1(n)$	$\sigma_{AVR}(n)$	$\sigma_{L-1}(n)$	$\sigma_{L-2}(n)$
1	TV-029	55,5	35,5	0,72	0,81	0,5	0,69	0,59
2	TV-029	56,63	34,38	0,77	0,83	<b>1,05</b>	0,77	<b>1,59</b>
3	TV-029	56,7	34,31	0,82	0,85	–	0,85	–
4	TV-029	56,75	34,36	0,87	0,87	–	0,93	–
5	TV-029	56,78	34,23	0,92	0,89	–	<b>1,01</b>	–
6	TV-029	56,8	34,2	0,97	0,91	–	–	–
7	TV-029	56,82	34,18	<b>1,02</b>	0,93	–	–	–
8	TV-029	56,84	34,16	–	0,95	–	–	–
9	TV-029	56,86	34,14	–	0,97	–	–	–
10	TV-029	56,88	34,12	–	0,99	–	–	–
11	TV-029	56,9	34,1	–	<b>1,01</b>	–	–	–
12	TV-029	56,92	34,08	–	–	–	–	–
13	TV-029	56,94	34,06	–	–	–	–	–
14	TV-029	56,96	34,04	–	–	–	–	–
15	TV-029	56,98	34,02	–	–	–	–	–
16	TV-029	<b>57,00</b>	<b>34,00</b>	–	–	–	–	–

При распознавании тестового фрагмента TV-029 и выборе из базы образа корреляционные параметры ПИ сети пришли к равновесному состоянию на одиннадцатом шаге, а координатные параметры ПИ сети – на шестнадцатом шаге. Точность измерения после коррекции энергетических центров фрагментов трасс составила 0,01 элемента разложения.

Определяем «хорошие» фрагменты трассы № 1 и для них проводим оптимизацию весов, тем самым вычисляя координаты энергетических центров изображений пятен лазерных пучков (рис. 3).

Теперь коротко опишем технические преимущества рассмотренных методов обучения ПИ сети, исходя из результатов экспериментальных исследований (табл. 3):

Таблица 3 – Сравнительная характеристика информационных технологий обучения ПИ сети

№ п/п	Параметры, использованные в ПИ сети	Информационная технология [2], [3], [6], [9], [11], [12]	Разработанная информационная технология
Распознавание статических образов изображений человеческих лиц			
	Используемый метод обучения	Метод обучения ПИ сети на основе $Q$ -разложения [2], [12]	Метод обучения ПИ сети на основе популяционного кодирования [12] со сравнением масок [13]
а)	средний процент корректного распознавания статических образов на нулевом уровне ПИ сети, %	80	93,75
б)	средний процент корректного распознавания статических образов при построении поуровневых корреляционных кривых, %	5	84
в)	среднее время распознавания, с	10,73	В зависимости от уровня при обучении ПИ сети (от 0,5 до 12)
Распознавание динамических образов изображений пятен лазерных пучков			
	Используемый метод обучения	Метод обучения ПИ сети на основе моментных признаков с оптимизацией весов [3], [6], [11]	Метод обучения ПИ сети на основе коррекции энергетических центров фрагментов лазерных трасс
а)	средний процент «хороших» фрагментов трасс, %	50	38,4
б)	средний процент корректного распознавания, %	84,8	92,5
в)	точность определения точки привязки, не более, элементов разложения	1,2	0,01
г)	среднее время распознавания, с	30	В зависимости от уровня при обучении ПИ сети (от 0,5 до 60)

## Выводы

В статье рассмотрены положения, необходимые для разработки методов обучения ПИ сети. В отличие от известных структур искусственных нейронных сетей, в которых для сравнения используются не нормируемые (абсолютные) критерии подобия, в рассмотренном методе организации ПИ сети [16] используется нормируемый критерий. На основе анализа правил обучения сделан вывод, что наиболее оптимальным для обучения ПИ сети является применение двух методов обучения с учителем: обучение на основе коррекции ошибок и обучение с использованием памяти. Разработаны математические модели обучения ПИ сети, а также комбинированный метод обучения ПИ сети для распознавания статических и динамических образов.

Из результатов экспериментальных исследований обучения ПИ сети при распознавании тестового образа AGJ-02 и выборе из базы образа № 1 AL-01 параметры ПИ сети пришли к неравновесному состоянию на третьем шаге. При распознавании тестового образа AGJ-02 и выборе из базы образа № 1 AGJ-01 параметры ПИ сети пришли к равновесному состоянию на четвертом шаге. Поэтому делается вывод о принадлежности изображения AGJ-02 к образу AGJ-01. То есть распознаваемый образ правильно классифицирован.

При распознавании тестового фрагмента TV-029 и выборе из базы образа корреляционные параметры ПИ сети пришли к равновесному состоянию на одиннадцатом шаге, а координатные параметры ПИ сети – на шестнадцатом шаге.

Наиважнейшие технические преимущества предложенного комбинированного метода обучения ПИ сети, которые реализованы в новом программном средстве по сравнению с предыдущими программными средствами и методами, заложенными в нем, следующие: точность измерения после коррекции энергетических центров фрагментов трасс определения составила 0,01 элемента разложения (по сравнению с 1,2 элемента разложения). При этом процент «хороших» изображений составил 38,4% (по сравнению с 50%), что повышает общий процент корректного распознавания до 92,5% (84,8%). Однако показатель «среднее время распознавания» на начальном уровне для обучения ПИ сети составляет: 60 с (30 с).

При распознавании статических образов средний процент корректного распознавания на нулевом уровне ПИ сети повысился: 93,75% (80%). Также отмечаем значительный рост среднего процента корректного распознавания статических образов при построении поуровневых корреляционных кривых: 84% (по сравнению с 5%). Показатель «среднее время распознавания» на начальном уровне при обучении ПИ сети составляет: 10,73 с (12 с).

## Литература

1. McCulloch W.S. A logical calculus of the ideas immanent in nervous activity / McCulloch W.S., W. Pitts // *Bulletin of Mathematical Biophysics*. – 1943. – Vol. 5. – P. 115-133.
2. Тимченко Л.И. Многоэтапная параллельно-иерархическая сеть как модель нейроподобной схемы вычислений / Л.И. Тимченко // *Кибернетика и системный анализ*. – 2000. – № 2. – С. 114-134.
3. Свечников С.В. Квазиимпульсно-потенциальные оптоэлектронные элементы и устройства логико-временного типа / Свечников С.В., Кожемяко В.П., Тимченко Л.И. – К. : Наукова думка, 1987. – 256 с.
4. Рабинович З.Л. Представление и обработка знаний во взаимодействии сенсорной и языковой нейросистем человека / З.Л. Рабинович, Г.С. Воронков // *Кибернетика и системный анализ*. – 1998. – № 2. – С. 3-11.
5. Хьюбел Д. Глаз, мозг, зрение / Хьюбел Д. – М. : Мир, 1990. – 239 с.
6. Method for Training of a Parallel-Hierarchical Network, Based on Population Coding for Processing of Extended Laser Paths Images / Leonid I. Timchenko, Yuriy F. Kutaev, Volodymyr P. Kozhemyako [and oth.] // *Proceedings of SPIE*. – 2002. – Vol. 4790. – P. 465-479.

7. [Электронный ресурс]. – Режим доступа : <http://www.korrespondent.net>.
8. Хинтон Д.Е. Как обучаются нейронные сети / Д.Е. Хинтон // В мире науки. – 1992. – № 11-12. – С. 103-110.
9. Тимченко Л.І. Конвергентні та дивергентні процеси в реальних та штучних нейронних мережах / Л.І. Тимченко // Вісник ВПШ. – 1997. – № 1. – С. 5-10.
10. Система координатної привязки для нестационарних сигналів / Л.І. Тимченко, Ю.Ф. Кутаєв, А.А. Герций [и др.] // Известия РАН. Сер. физическая. – 2001. – № 6. – С. 886-890.
11. Железняк А.Л. Сегментація напівтонових зображень за ознакою зв'язаності : монографія / [Железняк А.Л., Тимченко Л.І., Стасюк О.І. и др.]. – К. : ДЕДУТ, 2008. – 144 с.
12. Режим доступа : <http://peira.essex.ac.uk/ira/pix/faces/manchester>.
13. Метод паралельно-ієрархічного розпізнавання зображень / Л.І. Тимченко, В.В. Мельников, Н.І. Кокряцька [и др.] // Искусственный интеллект. – 2009. – № 3. – С. 606-617.
14. Паралельно-ієрархічне перетворення як системна модель для розпізнавання зображень / Л.І. Тимченко, В.В. Мельников, Н.І. Кокряцька [та ін.] // Искусственный интеллект. – 2008. – № 3. – С. 353-363.
15. Применение паралельно-ієрархічного метода розпізнавання зображень п'ятих лазерних пучків / Л.І. Тимченко, В.В. Мельников, Н.І. Кокряцька [и др.] // Материалы Международной научно-технической конференции «Многопроцессорные вычислительные и управляющие системы – 2009». – Таганрог. – С. 147-150.
16. Метод знаходження енергетичних центрів фрагментів лазерних протяжних трас в реальному масштабі часу для розпізнавання образів / Л.І. Тимченко, В.В. Мельников, Н.І. Кокряцька [та ін.] // Праці 9-ї всеукраїнської міжнародної конференції «Оброблення сигналів і зображень та розпізнавання образів». – Київ, 2008. – С. 213-216.

**Л.І. Тимченко, В.В. Мельников, В.В. Шпакович, Н.І. Кокряцька**

**Розробка методів навчання паралельно-ієрархічної мережі для високоефективного розпізнавання образів**

У статті розглянутий метод паралельно-ієрархічного перетворення на основі популяційного кодування та його застосування для задач розпізнавання образів. Також розглянуті положення, які використані для розробки методів навчання ПМ мережі, що використовують ідею популяційного кодування в штучній нейронній мережі. Розроблені математичні моделі вчення ПМ мережі, а також комбінований метод навчання ПМ мережі для розпізнавання статичних і динамічних образів. Наведені теоретичні відомості і експериментальні дослідження.

**L.I. Tymchenko, V.V. Melnikov, V.V. Shpakovich, N.I. Kokryatskaya**

**Parallel-hierarchical Network Learning Methods Creation for High-efficient Images Recognition**

In this article parallel-hierarchical transformation method based on popular coding and its using for images recognition tasks are considered. Some postulates has been researched for parallel-hierarchical network learning methods creation using the idea of popular coding in the artificial neural network. The learning mathematical models and also combine learning method for statical and dynamical images recognition have been created. Theoretical information and experimental researching are presented.

*Стаття поступила в редакцію 01.06.2010.*