

## МЕТОДЫ ОБУЧЕНИЯ ПАРАЛЛЕЛЬНО-ИЕРАРХИЧЕСКОЙ СЕТИ И ИХ ПРИМЕНЕНИЕ ДЛЯ РАСПОЗНАВАНИЯ ОБРАЗОВ

**Ключевые слова:** *параллельно-иерархическая сеть, обучение, изображения, лазерные трассы, человеческие лица.*

### 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 базе входных данных, который формируется на этапе обучения.) Эти информационно-вычислительные свойства позволяют ПИ-сетям решать сложные задачи, для этого 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. Обучение можно определить 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 последующее выполнение 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 ней-

росетей, созданных из взаимосвязанных нейронов, является способ связи сети с окружающей средой. В этом контексте говорят о парадигме обучения, связанной с моделью окружающей среды.

Метод организации ПИ-сети описан в работе [16] и поэтому в данной статье не обсуждается.

#### РАЗРАБОТКА МАТЕМАТИЧЕСКИХ МОДЕЛЕЙ ОБУЧЕНИЯ ПАРАЛЛЕЛЬНО-ИЕРАРХИЧЕСКОЙ СЕТИ

Исходя из структуры ПИ-сети и анализа правил обучения [4], 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. 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 формируется сигнал ошибки  $e_k(n)$ . По определению

$$e_k(n) = d_k(n) - y_k(n). \quad (1)$$

Сигнал ошибки будет инициализировать механизм управления, цель которого — 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

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

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 [8]. 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

$$\Delta\sigma_j(n) = \eta e_k(n) x_j(n), \quad (3)$$

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:

$$\sigma_j(n+1) = \sigma_j(n) + \Delta\sigma_j(n). \quad (4)$$

Таким образом, их можно рассматривать как старое и новое значения параметров ПИ-сети, поэтому можно записать

$$\sigma_j(n) = z^{-1}[\sigma_j(n+1)], \quad (5)$$

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»:

$$\left\{ (x_i, d_i) \right\}_{i=1}^N, \quad (6)$$

где  $x_i$  — входной вектор,  $d_i$  — соответствующий ему желаемый исходный сигнал. Если необходимо классифицировать определенный неизвестный вектор  $x_j$ , то из базы данных выбирается исходный сигнал, отвечающий входному сигналу, близкому к  $x_j$ .

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

- критерий, использующийся для определения окружения вектора  $x_j$ ;
- правило обучения, применяющееся к образцу из окружения тестового вектора.

Согласно правилу ближайшего соседа [9] в соседние включается образец, ближайший тестовому. Рассмотрим вектор

$$x'_N \in \{x_1, x_2, \dots, x_N\}. \quad (7)$$

Он считается ближайшим соседом вектора  $x_j$ , если выполняется условие

$$\min d(x_j, x_i) = d(x'_N, x_i), \quad (8)$$

где  $d(x'_N, x_i)$  — евклидово расстояние между векторами  $x_i$  и  $x'_N$  [9]. 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, который описывается следующим образом.

Находим  $k$  классифицированных соседей, ближайших к входному тестовому вектору  $x_j$ , где  $k$  — некоторое целое число. Вектор  $x_j$  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 наблюдения, отличающиеся от номинальной модели), как показано на рис. 1.

На рис. 1 область в штриховом круге содержит две точки, принадлежащие классу 1, и одну, принадлежащую классу 0, а точка  $d$  отвечает тестовому вектору  $x_j$ . 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.



Рис. 1. Графическая интерпретация метода обучения ПИ-сети на основе использования памяти

#### РАЗРАБОТКА МЕТОДОВ ОБУЧЕНИЯ ПАРАЛЛЕЛЬНО-ИЕРАРХИЧЕСКОЙ СЕТИ

Из результатов корреляционного сравнения изображений разных лиц, проведенного в работах [10, 11], видно, что информативным показателем является коэффициент корреляции на нулевом уровне ПИ-сети. Его будем применять для верификации соответствия 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 [10] 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.

- Построение структуры ПИ-сети избранного изображения.
- Применение метода обучения, основанного на использовании памяти.

Классификатором на основе  $k$ -ближайших соседей, использующихся в данном методе, является число уровней ПИ-сети.

- Построение структуры ПИ-сети эталонного изображения.
- Применение метода обучения, основанного на коррекции ошибок. Критерием верификации в данном методе является коэффициент корреляции на нулевом уровне ПИ-сети.

Коррекция ошибок для коэффициентов корреляции проводится на нулевом, первом, среднем, предпоследнем и третьем с конца уровнях ПИ-сети до тех пор, пока параметры сети не придут к абсолютно равносному состоянию (+1) или превысят его. Если значение параметров приводит к состоянию (-1) (или абсолютно неравносному состоянию), то делается вывод о непринаджности изображения данному образу.

Из результатов обработки динамических образов изображений пятен лазерных пучков [10, 12] следует, что информативным показателем является средний коэффициент корреляции по уровням ПИ-сети для формирования нижней границы туннеля.

Решения задачи формирования границ туннеля проводилось на основе туннелирования [13] по усредненным коэффициентам корреляции при сравнении эталонного образа с отдельным фрагментом трассы. Обучение ПИ-сети сводилось к выполнению следующих этапов:

- 1) найти для фрагмента трассы точку с максимальной яркостью  $T_{\max}$ ;
- 2) выбрать необходимое количество  $N$  значений яркости  $T_{\max-w}$ ,  $w=1, 2, \dots, N$ , начиная с максимальной (крайние точки с яркостями  $T_{\max-w}$  образуют  $N$  краевых линий);
- 3) определить для каждого краевого контура предварительные центры отдельно для каждой координаты:

$$x_c = \frac{1}{M} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} w(f(x, y)) x, \quad y_c = \frac{1}{M} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} w(f(x, y)) y,$$

$$M = \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} w(f(x, y)), \tag{9}$$

где  $w=1, 2, \dots, N$ ,  $f(x, y)$  — функция яркости изображения;

- 4) найти усредненные координаты для всего фрагмента трассы (данными для усреднения являются координаты центра каждого краевого контура) [14];
- 5) найти эталонный образ (усредненные значения яркостей элементов разложения, из которых состоит фрагмент трассы, для обучающей выборки находятся для каждого фрагмента трассы);

6) провести туннелирование по усредненным коэффициентам корреляции при сравнении эталонного образа с отдельным фрагментом трассы (в качестве верхней границы туннеля выбирается единица, а в качестве нижней — усредненный коэффициент корреляции);

7) определить «хорошие» или «плохие» изображения (фрагмент трассы считается «хорошим» при попадании среднего коэффициента корреляции в туннель эталонного образа, иначе — «плохим»);

8) провести оптимизацию весов для «хорошего» изображения:

$$x_{\text{эц}} = \frac{1}{M} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} w(f(x, y)) (x + \delta_X),$$

$$y_{\text{эц}} = \frac{1}{M} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} w(f(x, y)) (y + \delta_Y), \quad (10)$$

где  $w=1, 2, \dots, N$ ,  $f(x, y)$  — яркость,  $\delta_X, \delta_Y$  — смещение центров по осям  $X$  и  $Y$  соответственно.

Смещение центров по осям  $X$  и  $Y$  определяется по формулам (17) и (18):

$$\delta_X = \frac{1}{N} \sum_{i=0}^{N-1} (\bar{x} - x_i), \quad (11)$$

$$\delta_Y = \frac{1}{N} \sum_{i=0}^{N-1} (\bar{y} - y_i), \quad (12)$$

где  $\bar{x}, \bar{y}$  — средние значения центра выборки изображений по осям  $X$  и  $Y$  соответственно,  $x_i, y_i$  — координаты центра каждого  $i$ -го «хорошего» изображения.

Полученные значения  $x_{\text{эц}}, y_{\text{эц}}$  и есть окончательный результат измерения координат энергетических центров (эц) изображений пятен лазерных пучков. Этот показатель будем применять для верификации соответствия образов, а также для определения желаемого отклика в методе обучения, основанного на коррекции ошибок.

Исходя из задачи контроля параметров пучка лазерного излучения, будем использовать координаты  $X$  и  $Y$  энергетических центров фрагментов трасс в качестве основных показателей для распознавания изображений пятен лазерных пучков. Коэффициенты корреляции на первом, среднем, предпоследнем и третьем с конца уровнях будут вспомогательными при использовании метода обучения ПИ-сети для распознавания динамических образов.

Для обучения ПИ-сети при распознавании динамических образов будем использовать комбинированный метод, содержащий методы обучения, основанные на коррекции ошибок и на использовании памяти. Последовательность применения комбинированного метода обучения ПИ-сети для распознавания динамических образов состоит в следующем.

- Построение структуры ПИ сети избранного фрагмента лазерной трассы.
- Применение метода обучения, основанного на использовании памяти.

Классификатором данного метода на основе  $k$ -ближайших соседей является число общих уровней ПИ-сети.

- Построение структуры ПИ-сети эталонного образа.
- Применение метода обучения, основанного на коррекции ошибок. Критерием верификации данного метода является средний коэффициент корреляции по уровням ПИ-сети.

- Проведение коррекции ошибок для координат  $X$  и  $Y$  энергетических центров фрагментов трасс и коэффициентов корреляции на первом, среднем, предпоследнем и третьем с конца уровнях ПИ-сети. Коррекция проводится до тех пор, пока параметры сети не придут к абсолютно равновесному состоянию. Если значение параметров приводит к абсолютно неравновесному состоянию, то делается вывод о непринадлежности фрагмента лазерной трассы 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 [15].

При распознавании тестового образа AGJ-02 (рис. 2, *а*) и выборе из базы образа № 1 AL-01 (рис. 2, *б*) параметры ПИ-сети пришли к неравновесному состоянию на третьем шаге. Поэтому делается вывод о непринадлежности изображения AGJ-02 образу AL-01.

При распознавании тестового образа AGJ-02 и выборе из базы образа № 1 AGJ-01 (рис. 2, *в*) параметры ПИ-сети пришли к равновесному состоянию на чет-

вертом шаге. Поэтому делается вывод о принадлежности изображения AGJ-02 образу AGJ-01.

При обучении ПИ-сети для распознавания динамических образов тестовым примером являлся фрагмент трассы TV-029. Координаты фрагмента трассы TV-029, избранного на основе метода использования памяти, — (57.00; 34.00).




Рис. 2. Тестовое изображение AGJ-02 (*а*); выбранные образы: AL-01 (*б*) и AGJ-01 (*в*)



Рис. 3. Тестовый фрагмент трассы TV-029

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

При распознавании тестового фрагмента TV-029 (рис. 3) и выборе из базы образа корреляционные параметры ПИ-сети пришли к равновесному состоянию на 11-м шаге, а координатные параметры ПИ сети — на 16-м шаге. Точность измерения после коррекции энергетических центров фрагментов трасс составила 0,01 элемента разложения.


**Таблица 1.** Результаты обучения ПИ-сети при распознавании статических образов

Номер шага обучения, $n$	$\sigma_0(n)$	$\sigma_1(n)$	$\sigma_{AVR}(n)$	$\sigma_{L-1}(n)$	$\sigma_{L-2}(n)$
1	0,61	0,8	0,57	0,5	0,7
2	0,75	0,82	0,77	<b>1</b>	0,9
3	0,89	0,84	0,97	–	<b>1</b>
4	<b>1,03</b>	0,86	<b>1,17</b>	–	–

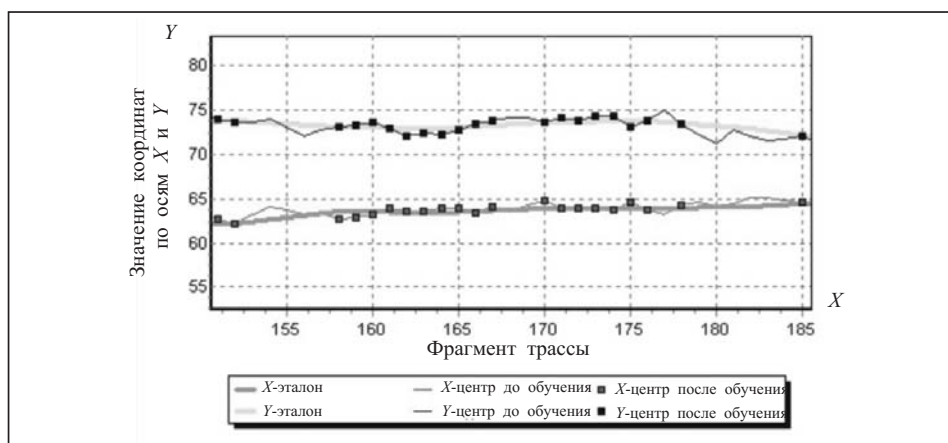


**Таблица 2.** Результаты обучения ПИ-сети при распознавании динамических образов

Номер шага обучения, $n$	$X$	$Y$	$\sigma_0(n)$	$\sigma_1(n)$	$\sigma_{AVR}(n)$	$\sigma_{L-1}(n)$	$\sigma_{L-2}(n)$
1	55,5	35,5	0,72	0,81	0,5	0,69	0,59
2	56,63	34,38	0,77	0,83	<b>1,05</b>	0,77	<b>1,59</b>
3	56,7	34,31	0,82	0,85	–	0,85	–
4	56,75	34,36	0,87	0,87	–	0,93	–
5	56,78	34,23	0,92	0,89	–	<b>1,01</b>	–
6	56,8	34,2	0,97	0,91	–	–	–
7	56,82	34,18	<b>1,02</b>	0,93	–	–	–
8	56,84	34,16	–	0,95	–	–	–
9	56,86	34,14	–	0,97	–	–	–
10	56,88	34,12	–	0,99	–	–	–
11	56,9	34,1	–	<b>1,01</b>	–	–	–
12	56,92	34,08	–	–	–	–	–
13	56,94	34,06	–	–	–	–	–
14	56,96	34,04	–	–	–	–	–
015	56,98	34,02	–	–	–	–	–
16	<b>57,00</b>	34,00	–	–	–	–	–



*Рис. 4.* График определения координат энергетических центров изображений пятен лазерных пучков до и после обучения ПИ-сети



*Рис. 5.* Увеличенный фрагмент графика рис. 4

Определяем «хорошие» фрагменты трассы № 1 и проводим для них оптимизацию весов, тем самым вычисляя координаты энергетических центров изображений пятен лазерных пучков (рис. 4, 5).

Технические преимущества рассмотренных методов обучения ПИ-сети, выявленные в результате экспериментальных исследований, представлены в табл. 3.

**Таблица 3.** Сравнительная характеристика информационных технологий обучения ПИ-сети

<b>Распознавание статических образов изображений человеческих лиц</b>		
<b>Параметры, использованные в ПИ-сети</b>	<b>Используемые методы обучения ПИ-сети</b>	
	на основе $Q$ -разложения [2, 16]	на основе популяционного кодирования [16] со сравнением масок [17]
Средний процент корректного распознавания статических образов на нулевом уровне ПИ-сети	80	93,75
Средний процент корректного распознавания статических образов при построении поуровневых корреляционных кривых	5	84
Среднее время распознавания, с	10,73	В зависимости от уровня при обучении ПИ-сети (от 0,5 до 12)
<b>Распознавание динамических образов изображений пятен лазерных пучков</b>		
<b>Параметры, использованные в ПИ-сети</b>	<b>Используемые методы обучения ПИ-сети</b>	
	На основе моментных признаков с оптимизацией весов [11–14]	На основе коррекции энергетических центров фрагментов лазерных трасс
Средний процент «хороших» фрагментов трасс	50	38,4
Средний процент корректного распознавания	84,8	92,5
Точность определения точки привязки, не более элементов разложения	1,2	0,01
Среднее время распознавания, с	30	В зависимости от уровня при обучении ПИ-сети (от 0,5 до 60)

## ЗАКЛЮЧЕНИЕ

В настоящей статье рассмотрены положения, необходимые для разработки методов обучения ПИ-сети. В отличие от известных структур искусственных нейронных сетей, в которых для сравнения используются ненормируемые (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 коррек-



ции 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 образу AGJ-01, т.е. распознаваемый образ правильно классифицирован.

При распознавании тестового фрагмента TV-029 и выборе из базы образа корреляционные параметры ПИ-сети пришли к равновесному состоянию на 11-м шаге, а координатные параметры ПИ сети — на 16-м 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 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 значительно вырос средний процент 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).

#### СПИСОК ЛИТЕРАТУРЫ

1. McCulloch W.S., Pitts W. A logical calculus of the ideas immanent in nervous activity // *Bul. of Mathem. Biophysics.* — 1943. — 5. — P. 115–133.
2. Тимченко Л.И. Многоэтапная параллельно-иерархическая сеть как модель нейроподобной схемы вычислений // *Кибернетика и системный анализ.* — 2000 — № 2. — С. 114–134.
3. Свечников С.В., Кожемяко В.П., Тимченко Л.И. Квазиимпульсно-потенциальные оптоэлектронные элементы и устройства логико-временного типа. — Киев: Наук. думка, 1987. — 256 с.
4. Хинтон Д.Е. Как обучаются нейронные сети // *В мире науки.* — 1992. — № 11–12. — С. 103–110.
5. Method for training of a parallel-hierarchical network, based on population coding for processing of extended laser paths images / L.I. Timchenko, Yu.F. Kutaev, V.P. Kozhemyako et al. // *Proc. of SPIE.* — 2002. — 4790. — P. 465–479.
6. Тимченко Л.И. Конвергентні та дивергентні процеси в реальних та штучних нейронних мережах // *Вісн. ВПІ.* — 1997. — № 1. — С. 5–10.
7. Сегментація напівтонових зображень за ознакою зв'язаності: Монографія / А.Л. Железняк, Л.І. Тимченко, О.І. Стасюк та ін. — Київ: ДЕДУТ, 2008. — 144 с.
8. Widrow B., Hoff M.E., Jr. Adaptive switching circuits // *IRE WESCON Convention Record.* — 1960. — P. 96–104.
9. Cover T.M., Hart P.E. Nearest neighbor pattern classification // *IEEE Transactions on Information Theory.* — 1976. — IT-13. — P. 21–27.

10. Метод параллельно-иерархического распознавания изображений: / Л.И. Тимченко, В.В. Мельников, Н.И. Кокряцкая и др. // Искусственный интеллект. — 2009. — № 3. — С. 606–617.
11. Параллельно-ієрархічне перетворення як системна модель для розпізнавання зображень / Л.І. Тимченко, В.В. Мельніков, Н.І. Кокряцька та ін. // Там же. — 2008. — № 3. — С. 353–363.
12. Применение параллельно-иерархического метода распознавания изображений пятен лазерных пучков // Материалы Междунар. науч.-техн. конф. «Многопроцессорные вычислительные и управляющие системы–2009» / Л.И.Тимченко, В.В.Мельников, Н.И.Кокряцкая и др. — Таганрог, 2009. — С. 147–150.
13. Метод знаходження енергетичних центрів фрагментів лазерних протяжних трас в реальному масштабі часу для розпізнавання образів / Л.І. Тимченко, В.В. Мельніков, Н.І. Кокряцька та ін. // Пр. 9-ї всеукр. міжнар. конф. «Оброблення сигналів і зображень та розпізнавання образів». — Київ, 2008. — С. 213–216.
14. Система координатной привязки для нестационарных сигналов / Л.И.Тимченко, Ю.Ф. Кутаев, А.А. Герций и др. // Изв. РАН. Сер. физическая. — 2001. — № 6. — С. 886–890.
15. Електронний ресурс манчестерської бази людських обличчя. — <http://peipa.essex.ac.uk/ipa/pix/faces/manchester>.
16. Метод организации параллельно-иерархической сети для распознавания образов / Л.И. Тимченко, В.В. Мельников, Н.И. Кокряцкая и др. // Кибернетика и системный анализ. — 2011. — № 1. — С. 152–163.
17. Вступ в алгоритмічну теорію ієрархії і паралелізму нейроподібних обчислювальних середовищ та її застосування до перетворення зображень: Основи теорії пірамідально-сітьового перетворення зображень / В.П. Кожем'яко, Л.І. Тимченко, Ю.Ф. Кутаєв, І.Д. Івасюк. — Київ: УМК ВО, 1994. — 272 с.

*Поступила 02.03.2010*