

DOI <https://doi.org/10.15407/usim.2018.04.003>
УДК 004.8 + 004.032.26

А.Д. ГОЛЬЦЕВ, канд. техн. наук, ст. научн. сотр., и.о. зав. отделом,
Міжнародний науково-навчальний центр інформаційних технологій та систем
НАН та МОН України, просп. Глушкова, 40, Київ 03187, Україна,
root@adg.kiev.ua

В.И. ГРИЦЕНКО, член-кор. НАН України, директор,
Міжнародний науково-навчальний центр інформаційних технологій та систем
НАН та МОН України, просп. Глушкова, 40, Київ 03187, Україна,
vig@irtc.org.ua

НЕЙРОСЕТЕВЫЕ ТЕХНОЛОГИИ В ЗАДАЧЕ РАСПОЗНАВАНИЯ РУКОПИСНЫХ СИМВОЛОВ

Описаны структуры и механизмы работы классификатора LiRA и модульных нейронных сетей. Оба классификатора решают задачу распознавания изображений на основе поиска признаков в них. Эксперименты в сравнении двух классификаторов, показали, что последняя версия модульной нейронной сети обладает более высокой эффективностью (распознающей способностью), чем классификатор LiRA, хотя и несколько уступает ему в быстродействии.

Ключевые слова: нейроны, нейронные слои, обучаемые связи, LiRA—признаки, тормозные связи.

Введение

Отдел Нейросетевых технологий обработки информации Международного научно-учебного центра информационных технологий и систем образовался из Отдела биологической и медицинской кибернетики, организованного академиком Н.М. Амосовым в 1962 г. В начальный период разработки отдела управлялись прежде всего гипотезой о механизмах переработки информации мозгом человека, предложенной Н.М. Амосовым [1] и результатами моделирования этой исходной гипотезы [2]. Подробное описание работ в этот ранний период представлено в [3], а более поздних — в [4-5].

В настоящее время цель данного исследования — разработка эффективных нейросетевых технологий обработки информации на основе компьютерного моделирования нейронной ор-

ганизации мозга человека и механизмов его мышления. Разработанные нейросетевые технологии предназначены для использования в решении актуальных практических задач Искусственного Интеллекта:

- разработка нейросетевых векторных распределенных представлений данных разной природы;
- интеллектуальная обработка сигнальной информации;
- обработка и классификация изображений и звуков с использованием нейронных сетей;
- быстрая оценка сходства и поиск по сходству (с использованием нейросетевых методов).

В 80-х годах прошлого века Э.М. Куссулем была предложена теория ассоциативно-проективных нейронных сетей [6], которая может стать основой для построения нейросетевого искусственного интеллекта. Эта теория в значительной степени базируется на *распре-*

деленных представлениях (РП) различных типов данных. Распределенные представления — это форма векторного представления данных, к которой привели идеи распределенного или «голографического» представления информации в мозге. В распределенных векторных представлениях данных каждый объект (различной природы и сложности) представлен множеством компонентов вектора, и каждый из них может принадлежать представлениям многих объектов. В обычных векторных представлениях смысл каждого компонента определен, чего нельзя сказать о векторах РП, где каждый компонент вектора можно считать некоторым признаком, выделенным из исходного представления объекта. Сходство этих векторов отражает некоторую функцию сходства представляемых ими объектов. Использование РП позволяет эффективно оценивать сходство объектов и дает возможность решать задачи их поиска и классификации [7-11].

Распределенные представления тесно связаны с ассоциативной памятью [12-14]. Они используются не только для представления векторных объектов [4, 15-18], но и для сложно структурированных исходных данных [4, 19-22]. Распределенные представления применяются для решения различных задач, в частности, для регуляризации машинного обучения [23-25] и для моделирования рассуждений по аналогии [4, 21].

В рамках исследований, относящиеся к задаче распознавания, были разработаны несколько высокопроизводительных нейросетевых классификаторов на основе простых линейных перцептронов: *RTC* (*Random Threshold Classifier*), *RSC* (*Random Subspace Coding*), *LiRA* (*Limited Receptive Area*). Рассмотрим два нейронных классификатора: *LiRA* и модульные нейронные сети.

Оба классификатора моделируют в некоторой степени нейронную структуру мозга человека, и поэтому обладают определенной нейробиологической релевантностью. Кроме того, оба классификатора можно считать интеллектуальными информационными технологиями, предназначенными в первую

очередь для решения практических задач в области распознавания некоторых типов изображений.

Нейросетевой классификатор *LiRA*

Задача классификации состоит в назначении меток классов неизвестным объектам. Для нейронной сети наиболее распространенным способом обучения классификации является работа с учителем, т.е. формирование структуры межнейронных связей сети в учебном процессе с использованием заданного множества обучающих образцов объектов, для каждого из которых задана метка его класса.

Рассмотрим структуру и алгоритмы функционирования нейронного классификатора *LiRA*, разработанного прежде всего для классификации изображений [26-30].

Классификатор *LiRA*, фактически, — простой линейный перцептрон. Процедура распознавания осуществляется в нем поиском на изображении некоторого набора заранее сконструированных признаков. Это — специальные признаки, называемые *LiRA*-признаками.

Отметим, что высокая распознающая способность классификатора *LiRA* базируется именно на использовании множества (десятков и сотен тысяч) простых и эффективных *LiRA*-признаков.

Каждый признак представляет собой некоторую совокупность значений, которые принимает небольшое число (четыре—10) фиксированных пикселей изображения. Для бинарных изображений, часть этих пикселей должна принадлежать распознаваемому объекту (обычно это единичные пиксели), а другая часть принадлежит фону (нулевые пиксели). Обозначим количество используемых *LiRA*-признаков через N .

Алгоритм формирования каждого *LiRA*-признака для бинарных изображений заключается в следующем. Квадрат, размер которого составляет малую часть размера изображения, случайным образом располагается внутри изображения (растра). Все пиксели формируемого признака также случайно выбираются внутри

этого квадрата. Затем их координаты запоминаются вместе с информацией о том, являются ли эти пиксели единичными или нулевыми.

Классификатор *LiRA* состоит из трех слоев: *S*, *A* и *R*. Входное изображение подается на входной слой *S* — двумерную матрицу яркостей (растр). Промежуточный слой *A* состоит из *N* двоичных *A*-нейронов, каждый из которых есть представитель одного *LiRA*-признака.

Выходной слой *R* представляет классы распознаваемых объектов (изображений); обозначим количество классов через *M*. Введем целочисленный вектор (столбец) *R* из *M* компонент для представления активности выходных *R*-нейронов.

Когда на входной слой *S* классификатора подается некоторое изображение, в нем осуществляется поиск всех *N* *LiRA*-признаков. Признак считается найденным на изображении, если все его единичные и нулевые пиксели совпадают с единичными и нулевыми пикселями изображения соответственно.

Для представления всех признаков, обнаруженных на изображении, введем двоичный вектор *A* (нулевой изначально), состоящий из *N* компонент. Каждый компонент вектора *A* представляет соответствующий *LiRA*-признак, т.е. если некоторый *j*-й признак идентифицирован на изображении, то соответствующий *j*-й компонент двоичного вектора *A* устанавливается в единицу.

Таким образом, выходная активность всех *N* нейронов слоя *A* представляется распределением нулей и единиц вектора *A*[*N*]. Отметим, что, хотя на последующих рисунках вектор *A* изображается в виде линейки или горизонтальной колонки, определяем его вектором столбцом.

В процессе распознавания выход (двоичный) каждого нейрона слоя *A* (*A*-нейрона) передается на входы всех нейронов слоя *R* (*R*-нейронов) посредством *M* обучаемых связей. Введем целочисленную матрицу *W*[*M*][*N*] для представления весов обучаемых связей классификатора. Тогда элемент *w*[*m*][*j*] этой матрицы обозначает вес связи, передающей бинарный выход *A_j*-го нейрона на вход нейрона *R_m*, представляющего класс *m*. До начала

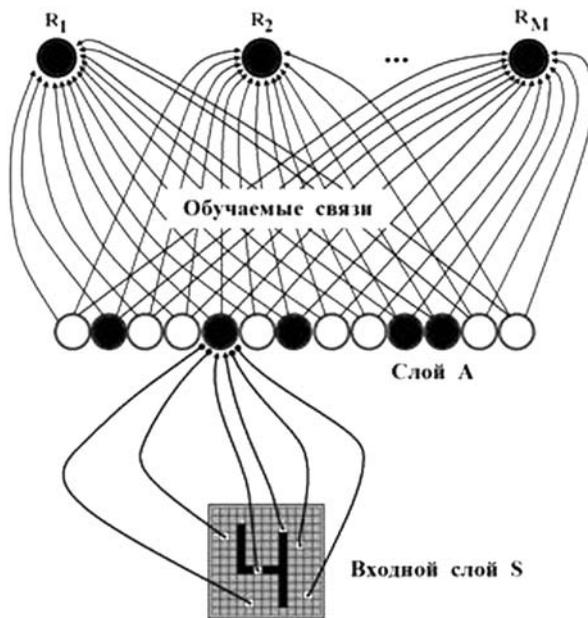


Рис. 1. Классификатор *LiRA*.

обучения все компоненты матрицы *W* устанавливаются равными нулю. В процессе обучения веса связей матрицы *W* изменяются, как описано ниже. На рис. 1 показана общая структура классификатора *LiRA*.

В процессе распознавания некоторое тестовое изображение подается на слой *S* классификатора. Все *LiRA*-признаки, показанные на изображении, выделяются, как описано выше, и фиксируются в векторе *A* в виде его единичных компонент. Выходная активность всех *N* нейронов слоя *A* (вектор *A*) через матрицу связей *W* и передается на входы *R*-нейронов.

Реализуется алгоритм распознавания так.

Сначала, посредством умножения матрицы *W* на вектор (столбец) *A*, вычисляется вектор *R*:

$$R = WA. \quad (1)$$

Затем определяется *R*-нейрон максимальной активности. Номер этого *R*-нейрона соответствует классу распознанного входного изображения; обозначим номер распознанного класса через *z*:

$$z = \arg \max_{m=1}^M r_m. \quad (2)$$

В процессе обучения классификатора используется модифицированное правило обучения персептрона [26–30]. Все учебные образцы изображений подаются на слой S поочередно.

Пусть на вход подается изображение, принадлежащее классу c . Классификатор осуществляет распознавание этого изображения. Как описано ранее, в результате выполнения процедуры распознавания вычисляется вектор R с его компонентом $r[c]$, представляющим правильный класс c . После этого, уровень активности R_c -го нейрона искусственно снижается; новое значение активности R_c -го нейрона обозначим как $r^*[c]$: $r^*[c] = r[c] (1 - T)$, где T — «параметр защитной полосы», $0 \leq T < 1$.

Сниженный уровень активности $r^*[c]$ сравнивается с уровнями активности всех других R -нейронов, чтобы определить победителя согласно уравнению (2). Учебное изображение считается правильно распознанным, если сниженное значение $r^*[c]$ превышает уровни активности всех других R -нейронов. В этом случае никакой модификации весов связей не происходит. Если же оказывается, что какой-либо другой R -нейрон, соответствующий неправильному классу d ($d \neq c$), имеет максимальную активность, то веса связей матрицы W изменяются так:

$$w[c][j] = w[c][j] + \Delta w, \quad (3)$$

$$w[d][j] = w[d][j] - \Delta w, \quad (4)$$

где $j = 1, 2, 3, \dots, N$, а Δw — модификатор веса связи.

Из формул (3) и (4) следует, что веса связей матрицы W могут иметь как положительные, так и отрицательные значения.

Затем обрабатывается следующий учебный образец. Понятие эпохи, часто используется в области алгоритмов обучения. Эпоха — это один полный цикл последовательного рассмотрения всех образцов обучающего набора.

Последовательное рассмотрение всех учебных образцов продолжается многократно, эпоха за эпохой, до достижения сходимости, т.е. до отсутствия ошибочной классификации всех учебных образцов.

Сходимость достигается, когда персептрон способен образовывать достаточно сложные поверхности во входном пространстве S для разделения всех учебных образцов. Введение защитной полосы с параметром T направлено на отдаление разделительной поверхности от образцов учебного набора (опосредованно, через удаление разделительной гиперплоскости от соответствующих этим объектам векторов слоя A). Это можно рассматривать как некоторый аналог разделительной полосы SVM [31], но формируемый не офф-лайн, а в процессе он-лайн обучения. Это, в некоторой степени, аналогично идеям алгоритмов [32–34].

Введение защитной полосы обычно приводит к улучшению возможностей обобщения и повышению процента правильной классификации. Алгоритм обучения *LiRA* позволяет обрабатывать большие обучающие наборы в пространстве *LiRA*-признаков большой размерности N и не нуждается в решении задачи оптимизации квадратичного программирования в отличие, например, от *SVM*.

Классификатор *LiRA* успешно использовался во многих задачах, таких, например, как распознавание рукописных цифр, распознавание текстур поверхностей, границ объектов, в микромеханике и в сельском хозяйстве [26–30, 35, 36].

На основе классификатора *LiRA* разработаны нейросетевые технологии идентификации диктора по голосу и обработки речевых записей большой длительности [37]. В этой работе результаты многополосной фильтрации звуковых сигналов рассматривались как двумерные изображения. Индивидуальные особенности голосов фиксируются в структуре нейронной сети в процессе ее обучения. Сеть автоматически формирует индивидуальные портреты голосов как совокупности речевых признаков. Система работает как в режиме поиска в голосовых базах данных, так и в режиме реального времени. Обеспечивается достоверность идентификации микрофонных сигналов в пределах 94–98 процентов и телефонных сигналов в пределах 85–94 процентов. Технология ори-

ентирована на работу с фонотеками с произвольным количеством голосов разных людей, записанных по микрофонному и телефонному каналам связи. Реализована также возможность поиска определяемых пользователем голосов в многочасовых аудиозаписях (индексация аудиоданных).

Отметим, что результаты, достигнутые при решении перечисленных задач, свидетельствуют, что простой линейный перцептрон (которым, фактически, является классификатор *LiRA*) демонстрирует способность распознавания на уровне таких методов, как *Backpropagation* и *SVM*, в условиях использования им множества простых *LiRA*-признаков (десятков и сотен тысяч). При этом классификатор *LiRA* обладает следующими достоинствами: классификатор — простое линейное устройство, алгоритмы работы которого не сравнимы по сложности с перечисленными методами; благодаря простым алгоритмам функционирования, процедура распознавания выполняется классификатором очень быстро, что существенно для практических задач.

Модульные нейронные сети

Согласно гипотезе Хебба, функциональным элементом мышления человека и высших животных является не отдельный нейрон, а нейронный ансамбль, состоящий из многих нейронов, объединенных в некоторую функциональную структуру [38]. С целью моделирования мышления человека в соответствии с этой гипотезой, проведены исследования нейронных сетей с ансамблевой организацией. В результате этих исследований разработаны эффективные модульные нейронные сети [39–48].

Модульная нейронная сеть предназначена для распознавания объектов из ограниченного количества классов. Сеть имеет модульную предорганизацию, т.е. она изначально разделена на несколько одинаковых модулей, по одному на каждый распознаваемый класс. В процессе обучения в каждом модуле формируется собственная индивидуальная структура

связей между составляющими его нейронами. Эта структура межнейронных связей представляет собой обобщенное описание соответствующего класса. Поскольку каждому классу соответствует определенный модуль, структуры межнейронных связей в разных модулях (описания классов) не пересекаются, в результате чего каждая такая структура адекватно отражает характерные особенности соответствующего класса.

Описание первой версии модульной нейронной сети опубликовано в 1991 г. в [39]. Ранние версии модульных нейронных сетей (например, [39–44]) носили название ансамблевых нейронных сетей. В процессе обучения каждый образец обучающей выборки запоминался в сети в виде нейронного ансамбля. В результате, в каждом модуле сети формировалось множество пересекающихся нейронных ансамблей.

В процессе распознавания в сети происходил многократный пересчет нейронной активности, благодаря которому сеть сходилась к устойчивому состоянию. Ансамблевые сети с многократным пересчетом нейронной активности обладали высокой распознающей способностью, но нуждались для своего функционирования в больших вычислительных затратах.

В дальнейшем, для ускорения работы сети, многократный пересчет активности сети был сокращен до однократного. Поэтому в настоящее время, из названия рассматриваемых сетей изъят термин «ансамблевые», хотя и теперь процедуру обучения сети можно интерпретировать, как образование в ней нейронных ансамблей.

В процессе исследования модульных нейронных сетей разработано много различных их модификаций. Например, в 1998 г. была предложена модульная сеть с тормозными связями между модулями [41], а позднее была исследована модульная ансамблевая сеть с обучаемыми возбуждающими связями между модулями [46].

Как и классификатор *LiRA*, модульная нейронная сеть распознает объекты с использо-

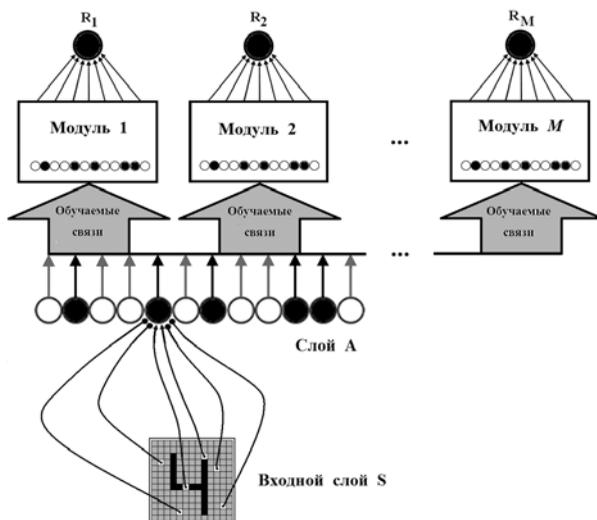


Рис. 2. Схематическое изображение общей структуры модульной нейронной сети

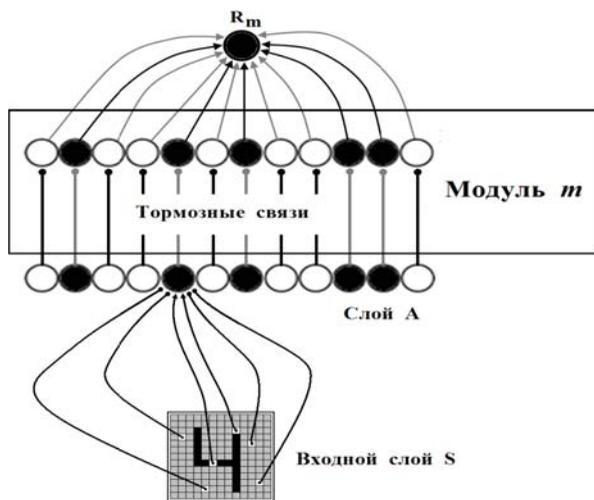


Рис. 3. Тормозные связи одного пучка (m-го) модульной нейронной сети

ванием некоторого заданного набора заранее сконструированных признаков; обозначим размер этого набора через N .

Эффективность модульных ансамблевых сетей тестировалась на различных задачах распознавания с различными типами признаков: текстурными [40-41], поплавковыми [43], двоичными и многозначными. В сравнительно недавних работах, с целью сравнения модуль-

ной сети с классификатором *LiRA* использовались описанные *LiRA*-признаки.

Модульная нейронная сеть также является линейным перцептроном, но состоит из четырех слоев: S , A , E и R . Как и в классификаторе *LiRA*, в модульной нейронной сети выходной слой R с его R -нейронами представляет классы объектов (изображений).

Как и в классификаторе *LiRA*, в процессе распознавания, некоторое тестовое изображение подается на S слой сети. Выделяются все признаки на изображении и фиксируются в двоичном векторе $A[N]$ в виде его единичных компонент.

В отличие от классификатора *LiRA*, выходная активность нейронов слоя A передается на промежуточный слой E , состоящий из $M \times N$ нейронов. Слой E разделен на M частей — модулей так, что каждый модуль содержит N нейронов. Каждый E -нейрон представляет один из N признаков. Все нейроны слоя E пронумерованы индексами j , отдельно в каждом модуле ($j = 1, 2, 3, \dots, N$) так, что нейроны, представляющие одинаковые признаки, но представленные в разных модулях, имеют одинаковые индексы j в последующих формулах.

Все E -нейроны имеют линейную, беспороговую выходную характеристику. Таким образом, выходная активность E -нейронов измеряется целыми числами. Введем целочисленную матрицу $E[M][N]$ для представления нейронной активности всего слоя E . Выходы всех N нейронов каждого модуля представлены m -й строкой матрицы E или, в другом обозначении, вектором-строкой $E[m]$.

Рассмотрим связи нейронов слоя A со слоем E на примере некоторого m -го модуля. Каждый нейрон слоя A имеет обучаемые связи, направленные на входы всех E -нейронов m -го модуля через m -й пучок связей. Для представления весов обучаемых связей m -го пучка введем отдельную целочисленную матрицу $W_m[N][N]$. Таким образом, в общем случае, матрица обучаемых связей каждого пучка содержит N^2 элементов. Такая модульная сеть называется *полностьюсвязной*, в отличие от сети с меньшим количеством связей.

Общая структура модульной нейронной сети показана на рис. 2. На этом рисунке все горизонтальные нейронные колонки сети изображены как состоящие из $N = 12$ нейронов.

В дополнение к обучаемым связям, каждый их пучок, направленный от слоя A к каждому модулю сети, содержит еще и N необучаемых проективных тормозных связей. Каждая такая связь соединяет j -й нейрон слоя A с соответствующим, т.е. с тем же порядковым номером j , нейроном модуля. Система тормозных связей вводится в сеть во избежание активации нейронов всех модулей, соответствующих нулевым компонентам вектора A .

Отметим, что эта система тормозных связей работает инверсным образом, т.е. торможение передается от неактивных нейронов слоя A , в то время, как его активные нейроны не оказывают тормозного воздействия на соответствующие нейроны модулей.

Таким образом, система тормозных связей передает всем модулям сети информацию о распределении нулей в векторе A , т.е. информацию об отсутствии данных признаков на входном изображении. Рис. 3 иллюстрирует это описание — только один (m -тый) модуль сети. Тормозные связи, фактически подавляющие активацию нейронов m -го модуля, обозначены черным цветом, неактивные тормозные связи — серым.

Рассмотрим процедуру распознавания в модульной сети. Двоичная нейронная активность нейронов слоя A (вектор A) передается обученными связями каждого m -го пучка (матрица $W_m[N][N]$) на входы всех E -нейронов каждого m -го модуля.

В результате передачи связями с разными весами в нейронах всех M модулей (в слое E) создается некоторое распределение вторичной градуальной (целочисленной) нейронной активности.

Вследствие наличия системы тормозных связей в составе всех M пучков, только такие нейроны модулей, которые не подавляются проективными тормозными связями, будут иметь ненулевую активность.

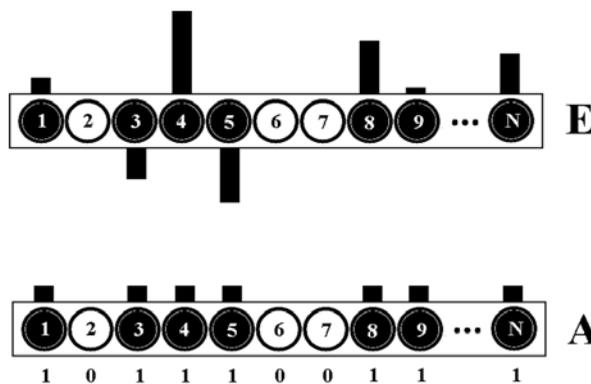


Рис. 4. Различия между активностью соответствующих нейронов в слоях A и E (векторы A и $E[m]$)

Распределение вторичной градуальной нейронной активности в нейронах каждого m -го модуля представляется m -й строкой матрицы E или вектором $E[m]$. Это распределение определяется формулой

$$e[m][j] = a[j] \sum_{i=1}^N a[i] w_m[i][j], \quad (5)$$

где $i = 1, 2, 3, \dots, N; j = 1, 2, 3, \dots, N; m = 1, 2, 3, \dots, M$.

Эквивалентное матричное уравнение выглядит так:

$$E[m] = [W_m A]^T. \quad (6)$$

Операция транспонирования в формуле (6) применена для превращения результата умножения в вектор-строку $E[m]$, т.е. в строку матрицы E .

Разница между активностью соответствующих нейронов в слоях A и E (векторы A и $E[m]$) показана на рис. 4. В отличие от нейронов слоя A , активность E -нейронов может иметь как положительные, так и отрицательные значения.

Выходы всех E -нейронов каждого модуля передаются на соответствующий R -нейрон (идентификатор класса) по необучаемым связям с единичным весом (аналогично тому, как это реализовано в классификаторе $LiRA$). Таким образом в процессе распознавания каждый R_m -нейрон суммирует выходную активность всех E -нейронов m -го модуля в соответствии с уравнением

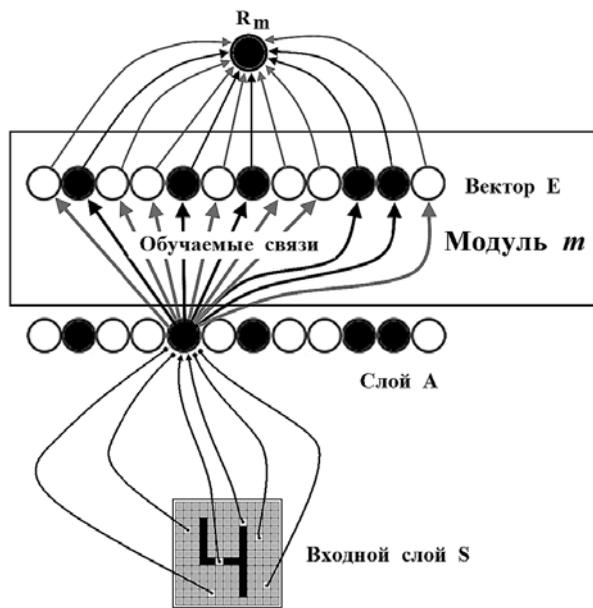


Рис. 5. Структура обучаемых связей одного из модулей (m -го) модульной нейронной сети

$$r[m] = \sum_{j=1}^N a[j] e[m][j]. \quad (7)$$

Эта же формула в виде матричного уравнения имеет следующий вид:

$$R = EA. \quad (8)$$

Как и в случае классификатора *LiRA*, при распознавании некоторого изображения, R -нейрон с максимальной активностью, определяет его класс в соответствии с уравнением (2).

Как и при обучении классификатора *LiRA*, в процессе обучения модульной нейронной сети, все образцы обучающего набора подаются на вход сети последовательно и многократно, эпоха за эпохой, до достижения сетью сходимости. Для обучения весов связей сети также используется правило Хебба. В начале обучения все компоненты матриц $W_m[N][N]$ ($m = 1, 2, 3, \dots, M$) устанавливаются равными нулю. Алгоритм обучения также предусматривает использование защитной полосы. Так, обучение ансамблевой сети происходит аналогично процедуре обучения классификатора *LiRA* со следующими изменениями.

Если на вход подается изображение, при-

надлежащее классу c , и, оказывается, что некоторый R_d -нейрон, соответствующий неправильному классу d ($d \neq c$), имеет максимальную активность, т.е. $r[d] > r^*[c]$, то веса связей в матрицах W_c и W_d (в модулях c и d) изменяются следующим образом

$$W_c[i][j] = w_c[i][j] + \Delta W (a[i] \wedge a[j]), \quad (9)$$

$$W_d[i][j] = w_d[i][j] - \Delta W (a[i] \wedge a[j]), \quad (10)$$

где $i = 1, 2, 3, \dots, N, j = 1, 2, 3, \dots, N, \wedge$ — знак конъюнкции, Δw — модификатор веса связи.

В формулах (9), (10) сомножитель $a \wedge a_j$ описывает действие системы тормозных связей в процессе обучения. Наличие этого сомножителя означает, что модификация весов связей в матрицах W_c и W_d осуществляется только между теми нейронами векторов A и E , которые соответствуют единичным компонентам вектора A .

Это описание иллюстрируется на рис. 5, где показана структура обучаемых связей правильного m -го модуля (т.е. модуля, соответствующего классу обучающего образца) ансамблевой сети в процессе обучения. На рисунке показаны связи, идущие от одного активного A -нейрона ко всем E -нейронам m -го модуля. Связи, в которых происходит увеличение их весов, изображены черным цветом, в отличие от связей, существующих в сети, но не участвующих в процессе модификации весов — серым цветом.

Как упомянуто ранее, в общем случае матрица связей каждого модуля сети содержит N^2 обучаемых связей. Это означает, что суммарное количество обучаемых связей в модульной сети достигает значения $M \times N^2$, которое в N раз превышает соответствующее количество обучаемых связей классификатора *LiRA* ($M \times N$).

Такая значительная разница в количестве связей приводит к следующим двум различиям между рассматриваемыми устройствами. Скорость распознавания тестовых задач у классификатора *LiRA* намного превосходит скорость работы модульной ансамблевой сети.

С другой стороны, модульная сеть, как имеющая больше возможностей для обучения, об-

ладает более высокой распознающей способностью, чем классификатор *LiRA*, при условии использования обоими устройствами одинакового количества одинаковых признаков. Этот результат получен в экспериментах, проведенных с целью прямого сравнения указанных устройств. Эксперименты проводились на базе рукописных цифр *MNIST* [49].

В базе *MNIST* размер каждого изображения равен $S=28 \times 28$ пикселей. *LiRA*-признаки формировались посредством квадрата, состоящего из 10×10 пикселей, в котором для каждого признака случайным образом выбирались два единичных пикселя и четыре нулевых. В этих экспериментах оба устройства использовали $N=7$ тыс. одинаковых *LiRA*-признаков, отобранных специальной процедурой из исходных 60 тыс. признаков, с целью выделить среди них наиболее информативные.

Графики зависимостей процента ошибок, допущенных классификатором *LiRA* и модульной сетью, от размера защитной полосы (параметр T) показаны на рис. 6. Число, расположенное возле каждой точки графиков, указывает количество эпох обучения, необходимых для достижения сходимости при соответствующем значении параметра T . Как видно на рис. 5, модульной сети необходимо значительно меньше циклов обучения в сравнении с классификатором *LiRA*, что свидетельствует о ее лучшей способности образовывать разделительные гиперплоскости в пространстве *LiRA*-признаков.

Уменьшение количества обучаемых связей в модульной нейронной сети

Как следует из приведенного описания модульной сети, ее основная проблема — это большое количество связей, следствием чего является ее сравнительно невысокое быстродействие в режиме распознавания. Решение этой проблемы посредством значительного уменьшения количества обучаемых связей сети предложено в [39].

В редуцированной версии модульной ней-

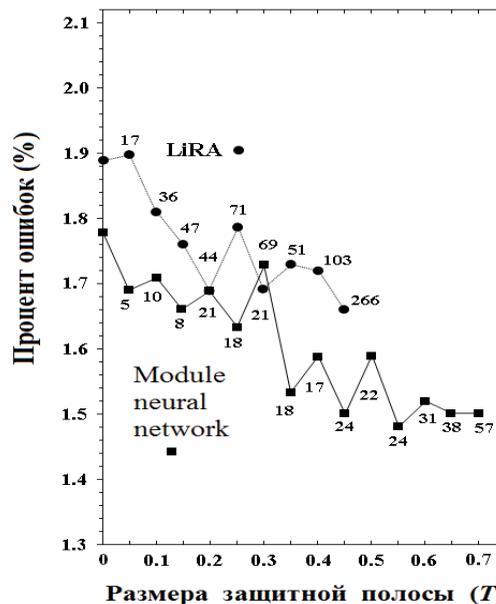


Рис. 6. Графики зависимостей процента ошибок, допущенных классификатором *LiRA* и модульной сетью, от размера защитной полосы (параметр T)

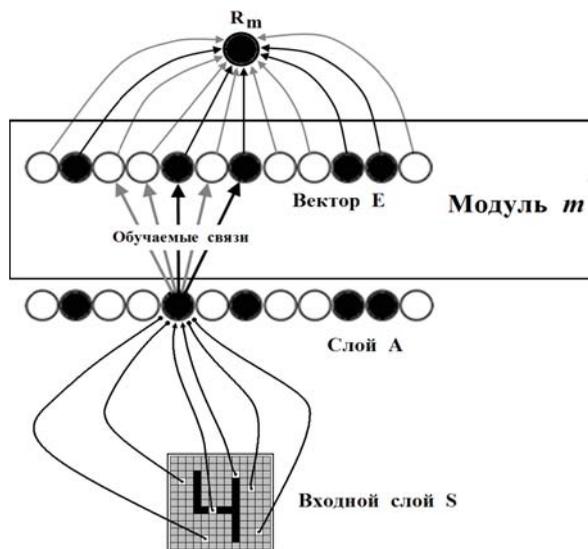


Рис. 7. Веер обучаемых связей одного нейрона m -го модуля модульной нейронной сети.

ронной сети каждый нейрон слоя A имеет обучаемые связи только с ограниченным количеством нейронов каждого модуля. Обозначим это количество через F , причем $1 < F < N$. Во всех M пучках, соединяющих нейроны слоя A с

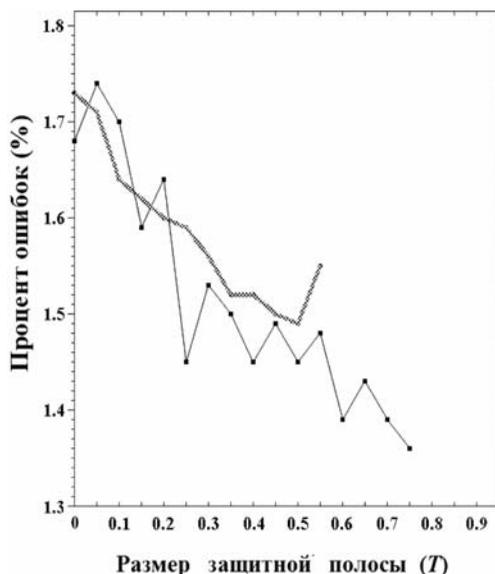


Рис 8. Зависимость процента ошибок модульной нейронной сети с $F = 51$ (тонкая черная линия) и процента ошибок классификатора *LiRA* (широкая пунктирная линия) от значений защитной полосы (параметр T) с использованием одного и того же набора из 60 тыс. *LiRA*-признаков

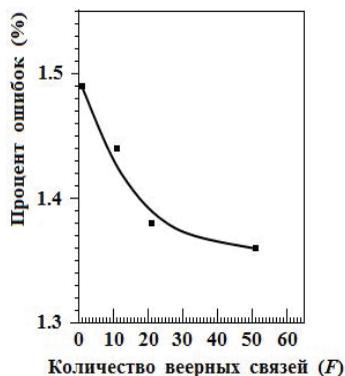


Рис. 9. Зависимость минимального процента ошибок модульной нейронной сети от значения параметра F

нейронами модулей, создается такая структура обучаемых связей, в которой каждый нейрон слоя A соединяется с F случайно выбранными нейронами каждого модуля.

В экспериментах, представленных далее, случайный выбор связей реализуется следующим образом. Одинаковый веер, состоящий из F связей, идет от каждого нейрона слоя A к F соседних нейронов каждого модуля. Поскольку все N признаков распределены случайным образом в векторе $A[N]$, постольку такая веерная

структура связей к смежным F нейронам фактически реализует случайное распределение связей внутри каждого пучка.

Структура обучаемых связей, описанная ранее, показана на рис. 7, где изображен только один веер, состоящий из $F = 5$ связей, направленный от одного нейрона слоя A к нейронам m -го модуля.

Черным цветом отмечены связи, в процессе распознавания изменяющие активность нейронов m -го модуля. Связи данного веера, существующие в сети, но не изменяющие активность нейронов m -го модуля в процессе распознавания (поскольку нейроны, на вход которых они поступают, заторможены) — серым.

Процедуры обучения и распознавания в редуцированной модульной сети выполняются в полном соответствии приведенным описаниям. Однако, теперь, каждая матрица W_m становится матрицей, содержащей не N^2 , а только $N \times F$ весов связей каждая.

Таким образом, общее количество обучаемых связей в редуцированной версии модульной сети равно $M \times N \times F$. В связи с сокращением количества связей в сравнении с полносвязной сетью ($M \times N^2$), время обработки каждого изображения существенно снижается (но остается в F раз больше, чем у классификатора *LiRA*). Однако, вследствие наличия большего числа обучаемых связей, чем в классификаторе *LiRA*, данная версия модульной нейронной сети должна иметь более высокую распознающую способность. Это предположение было проверено в следующих экспериментах.

Чтобы оценить зависимость распознающей способности модульных нейронных сетей с разным количеством обучаемых связей при изменении размера веера F , были проведены четыре серии экспериментов с $F = 1$, $F = 11$, $F = 21$ и $F = 51$.

Отметим, что модульная нейронная сеть с $F = 1$ является эквивалентом классификатора *LiRA*. Таким образом, результаты первой серии экспериментов с $F = 1$ позволяют провести сравнение между классификатором *LiRA* и модульными нейронными сетями с различным числом обучаемых связей.

Эксперименты проведены на базе рукописных цифр *MNIST* с использованием одинакового набора из 60 тыс. *LiRA*-признаков, сформированных в соответствии с описанием предыдущего раздела.

Результаты первой и четвертой серий экспериментов, а именно, зависимость процента ошибок классификатора *LiRA* (широкая пунктирная линия) и модульной нейронной сети с $F = 51$ (тонкая черная линия) от значений параметра T показаны на рис. 8. Наилучший результат этой версии модульной сети составляет 1,36 процентов (136 ошибок) и достигается при $T = 0,75$.

Как видно из рисунка, в задаче распознавания рукописных чисел базы *MNIST*, распознающая способность редуцированной модульной нейронной сети значительно превышает способность классификатора *LiRA*.

Зависимость минимального процента ошибок модульной нейронной сети с разным количеством обучающих связей (параметр F), полученные в результате четырех серий экспериментов показана на рис 9.

Кривая на рис. 9 показывает, что процент ошибок редуцированной модульной сети экспоненциально уменьшается с ростом F , т.е. абсолютное снижение процента ошибок экспоненциально замедляется с ростом F . Это существенный результат; основываясь на нем, можно экстраполировать кривую (рис. 9) на $F = 60$ тыс., т.е. на случай полносвязной сети.

Как видно из рис. 9, при такой экстраполяции, минимальный процент ошибок едва ли достигнет значения 1,33 процента. Однако лучший результат модульной сети с $F = 51$ составляет 1,36 процента. Очевидно, что разница между значениями 1,36 процента и 1,33 процента невелика. Следовательно, сеть с $F = 50$, т.е. с $M \times N \times F = 30$ млн связей, имеет лишь незначительно меньшую распознающую способность, чем полносвязная сеть с $M \times N^2 = 36$ млрд связей.

Итак, можно сделать вывод, что полносвязная модульная нейронная сеть — крайне избыточное устройство исходя из количества обучаемых связей.

Отметим, что результат распознавания рукописных чисел базы *MNIST*, составляющий 1,36 процента ошибок, достигнутый модульной сетью с $F = 51$, находится на уровне лучших современных результатов среди классификаторов, не использующих искусственное расширение набора обучающих примеров посредством различных имеющихся в базе деформаций цифр.

Таким образом, эксперименты показывают, что модульная нейронная сеть с уменьшенным числом связей обладает более высокой эффективностью (распознающей способностью), чем классификатор *LiRA*. Причем, эта версия модульной сети имеет более высокую скорость обработки изображений, приближающуюся к скорости классификатора *LiRA*. Итак, что скорость работы классификатора *LiRA* — его важнейшее преимущество.

Заключение

В статье рассмотрены два типа нейронных классификаторов, а именно, нейронный классификатор *LiRA* и модульные нейронные сети. Оба классификатора предназначены для решения практических задач по распознаванию некоторых типов изображений. Оба классификатора решают задачу распознавания изображений на основе поиска в изображениях некоторого набора заранее сконструированных признаков. В данной статье функционирование обоих классификаторов рассмотрено на примере использования *LiRA*-признаков. Отметим, что высокая распознающая способность классификаторов базируется именно на использовании очень большого количества (десятков и сотен тысяч) простых и эффективных *LiRA*-признаков.

Рассмотрены структуры и механизмы работы обоих классификаторов. Отмечено, что классификатор *LiRA* обладает следующими достоинствами: классификатор — это простое линейное устройство; благодаря своим простым алгоритмам функционирования, процедура распознавания выполняется клас-

сификатором быстро, что существенно для практических задач.

Модульная нейронная сеть — несколько более сложное устройство. В частности, такая сеть содержит большее количество обучаемых связей. В статье отражена эволюция модульных нейронных сетей, изначально задуманных как нейронная сеть, моделирующая нейронные ансамбли Хебба, и названные, соответственно — модульные нейронные сети с ансамблевой организацией.

В начале ансамблевые сети функционировали посредством многократного пересчета нейронной активности сети, вплоть до достижения ею устойчивого состояния. Вследствие этого, такие сети нуждались для своего функционирования в очень больших вычислительных и временных затратах. В дальнейшем, для ускорения работы сети, многократный пересчет нейрон-

ной активности был сокращен до однократного. Следующим шагом совершенствования модульной нейронной сети явилось уменьшение количества обучаемых связей сети. В результате таких изменений, модульная нейронная сеть превратилась в эффективное и достаточно быстрое устройство.

На основе результатов ряда экспериментов в сравнении двух классификаторов показано, что последняя версия модульной нейронной сети обладает более высокой эффективностью (распознающей способностью), чем классификатор *LiRA*, хотя и несколько уступает ему в быстродействии.

Нейробиологическая релевантность обоих нейронных классификаторов открывает возможности создания на их базе интеллектуальных информационных технологий, функционирующих аналогично человеческому мозгу.

СПИСОК ЛИТЕРАТУРЫ

1. Amosov N.M. Modelling of Thinking and the Mind. New York: Spartan Books, 1967.
2. Амосов Н.М., Байдык Т.Н., Гольцев А.Д., Касаткин А.М., Касаткина Л.М., Рачковский Д.А. Нейрокомпьютеры и интеллектуальные роботы. Киев: Наукова думка. 1991. 269 с.
3. Касаткина Л.М., Касаткин А.М., Гольцев А.Д., Рачковский Д.А. Реализация идей акад. Н.М. Амосова в нейросетевых информационных технологиях. Кибернетика и вычислительная техника. 2013. Вып. 174. С. 18—29.
4. Гриценко В.И., Рачковский Д.А., Гольцев А.Д., Лукович В.В., Мисуно И.С., Ревунова Е.Г., Слипченко С.В., Соколов А.М. Нейросетевые распределенные представления для интеллектуальных информационных технологий и моделирования мышления. Кибернетика и вычислительная техника. 2013. Вып. 173. С. 7—24.
5. Gritsenko V.I., Rachkovskij D.A., Revunova E.G. Neural distributed representations of vector data in intelligent information technologies. Cybernetics and Computer Engineering. 2018. N 4(194).
6. Куусуль Э.М. Ассоциативные нейроподобные структуры. Киев: Наукова думка. 1992. 144 с.
7. Мисуно И.С., Рачковский Д.А., Слипченко С.В., Соколов А.М. Поиск текстовой информации с помощью векторных представлений. Проблемы программирования. 2005. N 4. С. 50—59.
8. Kleyko D., Rahimi A., Rachkovskij D., Osipov E., Rabaey J. Classification and recall with binary hyperdimensional computing: Tradeoffs in choice of density and mapping characteristics. IEEE Transactions on Neural Networks and Learning Systems. 2018. DOI 10.1109/TNNLS.2018.2814400
9. Kussul E.M., Baidyk T.N., Lukovich V.V., Rachkovskij D.A. Adaptive neural network classifier with multfloat input coding. The 6th International Conference Neural Networks & their Industrial & Cognitive Applications “NeuroNimes’93”. Nîmes, France. 1993 (October 25—29). P. 209—216.
10. Lukovich V.V., Goltsev A.D., Rachkovskij D.A. Neural network classifiers for micromechanical equipment diagnostics and micromechanical product quality inspection. The 5th European Congress on Intelligent Techniques and Soft Computing “EUFIT’97”. Aachen, Germany. 1997 (September 8—11). P. 534—536.

11. Kussul E.M., Kasatkina L.M., Rachkovskij D.A., Wunsch D.C. Application of random threshold neural networks for diagnostics of micro machine tool condition. IEEE International Joint Conference on Neural Networks “IJCNN’01”. Anchorage, Alaska, USA. 1998 (May 4—9). P. 241—244.
12. Frolov A.A., Husek D., Rachkovskij D.A. Time of searching for similar binary vectors in associative memory. Cybernetics and Systems Analysis. 2006. Vol. 42, N 5. P. 615—623.
13. Gritsenko V.I., Rachkovskij D.A., Frolov A.A., Gayler R., Kleyko D., Osipov E. Neural distributed autoassociative memories: A survey. Cybernetics and Computer Engineering. 2017. N 2 (188). P. 5—35.
14. Frady E. P., Kleyko D., Sommer F. T. A theory of sequence indexing and working memory in recurrent neural networks. Neural Computation. 2018. Vol. 30, N 6. P. 1449—1513.
15. Rachkovskij D.A. Vector data transformation using random binary matrices. Cybernetics and Systems Analysis. 2014. Vol. 50, N 6. P. 960—968.
16. Rachkovskij D.A. Formation of similarity-reflecting binary vectors with random binary projections. Cybernetics and Systems Analysis. 2015. Vol. 51, N 2. P. 313—323.
17. Ferdowsi S., Voloshynovskiy S., Kostadinov D., Holotyak T. Fast content identification in highdimensional feature spaces using sparse ternary codes. The 8th IEEE International Workshop on Information Forensics and Security (WIFS’16). Abu Dhabi, UAE. 2016 (December 4—7). P. 1—6.
18. Kleyko D., Osipov E., Rachkovskij D.A. Modification of holographic graph neuron using sparse distributed representations. Procedia Computer Science. 2016. Vol. 88. P. 39—45.
19. Sokolov A., Rachkovskij D. Approaches to sequence similarity representation. Information Theories and Applications. 2005. Vol.13, N 3. P. 272—278.
20. Kanerva P. Hyperdimensional computing: An introduction to computing in distributed representation with high-dimensional random vectors. Cognitive Computation. 2009. Vol. 1, N 2. P. 139—159.
21. Slipchenko S. V., Rachkovskij D.A. Analogical mapping using similarity of binary distributed representations. Information Theories and Applications. 2009. Vol. 16, N 3. P. 269—290.
22. Gallant S. I., Okaywe T.W. Representing objects, relations, and sequences. Neural Computation. 2013. Vol. 25, N 8. P. 2038—2078.
23. Revunova E.G., Rachkovskij D.A. Using randomized algorithms for solving discrete ill-posed problems. Information Theories and Applications. 2009. Vol. 16, N 2. P. 176—192.
24. Rachkovskij D.A., Revunova E.G. Randomized method for solving discrete ill-posed problems. Cybernetics and Systems Analysis. 2012. Vol. 48, N 4. P. 621—635.
25. Revunova E.G., Rachkovskij D.A. Random projection and truncated SVD for estimating direction of arrival in antenna array. Cybernetics and Computer Engineering. 2018. N 3(193). P. 5—26.
26. Kussul E., Baidyk T., Kasatkina L., Lukovich V. Rosenblatt perceptrons for handwritten digit recognition. International Joint Conference on Neural Networks “IJCNN’01”. Washington, USA, 2001. P. 1516—1521.
27. Kussul E., Baidyk T. Improved method of handwritten digit recognition tested on MNIST database. Image and Vision Computing. 2004. Vol. 22. P. 971—981.
28. Kussul E., Baidyk T. LIRA neural classifier for handwritten digit recognition and visual controlled microassembly. Neurocomputing. 2006. Vol. 69(16—18). P. 2227—2235.
29. Makeyev O., Sazonov E., Baidyk T., Martin A. Limited receptive area neural classifier for texture recognition of mechanically treated metal surfaces. Neurocomputing. 2008. Vol. 71, N 7—9. P. 1413—1421.
30. Kussul E., Baidyk T., Wunsch D. Neural Networks and Micro Mechanics. Springer. 2010. 221 p.
31. Cristianini N., Shawe-Taylor J. An Introduction to Support Vector Machines (and other Kernel-Based Learning Methods). Cambridge University Press New York, NY, USA. 2000.
32. Шлезингер М.И., Калмыков И.Г., Сухоруков А.А. Сравнительный анализ алгоритмов, синтезирующих линейное решение для анализа сложных гипотез. Автоматика. 1981. 1. С. 3—9.
33. Schlesinger M.I., Hlavac V., Ten Lectures on Statistical and Structural Pattern Recognition. Dordrecht: Kluwer Academic Publishers. 2002.

34. Franc V., Hlavác V. An iterative algorithm learning the maximal margin classifier. *Pattern Recognition*. 2003. Vol. 36, N 9. P. 1985—1996.
35. Baidyk T, Kussul E., Makeyev O., Vega A., Limited receptive area neural classifier based image recognition in micromechanics and agriculture. *International Journal of Applied Mathematics and Informatics*. 2008. Vol. 2, N 3. P. 96—103.
36. Baydyk T., Kussul E., Hernández Acosta M. New Application of LIRA neural network. *The 16th WSEAS International Conference on Circuits*. Greece, Kos Island, 2012. P. 115—119.
37. Касаткина Л.М., Лукович В.В., Пилипенко В.В. Распознавание личности по голосу с помощью классификатора LIRA. *Управляющие системы и машины*. 2006. № 3. С. 67—73.
38. Hebb D.O. *The Organization of Behavior*. New York, USA: John Wiley & Sons Inc. 1949.
39. Gol'tsev A.D. Structured neural networks with learning for texture segmentation in images. *Cybernetics and Systems Analysis*. Plenum Publishing Corporation. New York, USA. 1991. Vol. 27, N 6. P. 927—936.
40. Goltsev A. An assembly neural network for texture segmentation. *Neural Networks*. 1996. Vol. 9, N 4. P. 643—653.
41. Goltsev A., Wunsch D.C. Inhibitory connections in the assembly network for texture segmentation. *Neural Networks*. 1998. Vol. 11, N 5. P. 951—962.
42. Goltsev A., Wunsch D.C. Generalization of features in the assembly neural networks. *International Journal of Neural Systems (IJNS)*. 2004. Vol. 14, N 1. P. 39—56.
43. Goltsev A. Secondary learning in the assembly neural network. *Neurocomputing*. 2004. Vol. 62. P. 405—426.
44. Goltsev A., Rachkovskij D. Combination of the assembly neural network with a perceptron for recognition of handwritten digits arranged in numeral strings. *Pattern Recognition*. 2005. Vol. 38, N 3. P. 315—322.
45. Гольцев А.Д. Нейронные сети с ансамблевой организацией. Киев: Наукова думка. 2005. 200 с.
46. Goltsev A., Gritsenko V. Modular neural networks with Hebbian learning rule. *Neurocomputing*. 2009. Vol. 72, N 10—12. P. 2477—2482.
47. Goltsev A., Gritsenko V. Investigation of efficient features for image recognition by neural networks. *Neural Networks*. 2012. Vol. 28. P. 15—23.
48. Goltsev A., Gritsenko V. Modular neural networks with radial neural columnar architecture. *Biologically Inspired Cognitive Architectures*. 2015. Vol. 13. P. 63—74.
49. LeCun Y. The MNIST database of handwritten digits. <http://yann.lecun.com/exdb/mnist/>

Поступила 22.10.2018

REFERENCES

1. Amosov, M., 1967. *Modelling of Thinking and the Mind*. New York: Spartan Books, 192 p.
2. Amosov, N.M., Baidyk, T.N., Goltsev, A.D., Kasatkin, A.M., Kasatkina, L.M., Rachkovsky, D.A., 1991. *Neurocomputers and intelligent robots*. Kiev: Naukova Dumka, 269 p. (In Russian).
3. Kasatkina L.M., Kasatkin A.M., Goltsev A.D., Rachkovsky D.A. Implementation of the ideas of Acad. N.M. Amosova in neural network information technologies. *Kibernetika i vychislitelnaa tehnika*. 2013, 174. pp. 18—29. (In Russian).
4. Gritsenko, V.I., Rachkovskij, D.A., Goltsev, A.D., Lukovych, V.V., Misuno, I.S., Revunova, E.G., Slipchenko, S.V., Sokolov, A.M., Talayev, S.A., 2013. “Neural distributed representation for intelligent information technologies and modeling of thinking”. *Cybernetics and Computer Engineering*, V. 173, pp. 7—24. (in Russian).
5. Gritsenko V.I., Rachkovskij D.A., Revunova E.G. Neural distributed representations of vector data in intelligent information technologies. *Cybernetics and Computer Engineering*. 2018. N 4(194).
6. Kussul, E.M., 1992. *Associative neural-like structures*. Kiev: Naukova Dumka, 144 p. (In Russian).
7. Misuno I.S., Rachkovskij D.A., Slipchenko S.V., Sokolov A.M. Searching for text information with the help of vector representations. *Problems of Programming*. 2005. N. 4. P. 50—59. (in Russian).
8. Kleyko, D., Rahimi, A., Rachkovskij, D., Osipov, E., Rabaey, J., 2018. “Classification and recall with binary hyperdimensional computing: Tradeoffs in choice of density and mapping characteristics”. *IEEE Transactions on Neural Networks and Learning Systems*, DOI 10.1109/TNNLS.2018.2814400.

9. Kussul, E.M., Baidyk, T.N., Lukovich, V.V., Rachkovskij, D.A., 1993. "Adaptive neural network classifier with multi-float input coding". The 6th International Conference Neural Networks & their Industrial & Cognitive Applications "Neuro-Nimes'93", Nîmes, France, October 25—29, pp. 209—216.
10. Lukovich, V.V., Goltsev, A.D., Rachkovskij, D.A., 1997. "Neural network classifiers for micromechanical equipment diagnostics and micromechanical product quality inspection". The 5th European Congress on Intelligent Techniques and Soft Computing "EUFIT'97". Aachen, Germany, September 8—11, pp. 534—536.
11. Kussul, E.M., Kasatkina, L.M., Rachkovskij, D.A., Wunsch, D.C., 1998. "Application of random threshold neural networks for diagnostics of micro machine tool condition". IEEE International Joint Conference on Neural Networks "IJCNN'01". Anchorage, Alaska, USA, May 4—9, pp. 241—244.
12. Frolov, A.A., Husek, D., Rachkovskij, D.A., 2006. "Time of searching for similar binary vectors in associative memory". Cybernetics and Systems Analysis, 42 (5), pp. 615—623.
13. Gritsenko V.I., Rachkovskij D.A., Frolov A.A., Gayler R., Kleyko, D., Osipov, E., 2017. "Neural distributed autoassociative memories: A survey". Cybernetics and Computer Engineering, 2(188), pp. 5—35.
14. Frady, E. P., Kleyko, D., Sommer, F.T., 2018. "A theory of sequence indexing and working memory in recurrent neural networks". Neural Computation, 30 (6), pp. 1449—1513.
15. Rachkovskij, D.A., 2014. "Vector data transformation using random binary matrices". Cybernetics and Systems Analysis, 50 (6), pp. 960—967.
16. Rachkovskij, D.A., 2015. "Formation of similarity-reflecting binary vectors with random binary projections". Cybernetics and Systems Analysis, 51 (2), pp. 313—323.
17. Ferdowsi, S., Voloshynovskiy, S., Kostadinov, D., Holotyak, T., 2016. "Fast content identification in highdimensional feature spaces using sparse ternary codes". The 8th IEEE International Workshop on Information Forensics and Security (WIFS'16). Abu Dhabi, UAE, December 4—7, pp. 1—6.
18. Kleyko, D., Osipov, E., Rachkovskij, D.A., 2016. "Modification of holographic graph neuron using sparse distributed representations". Procedia Computer Science, 88, pp. 39—45.
19. Sokolov, A., Rachkovskij, D., 2005. "Approaches to sequence similarity representation". Information Theories and Applications, 13 (3), pp. 272—278.
20. Kanerva, P., 2009. "Hyperdimensional computing: An introduction to computing in distributed representation with high-dimensional random vectors". Cognitive Computation, 1 (2), pp. 139—159.
21. Slipchenko, S. V., Rachkovskij, D.A., 2009. "Analogical mapping using similarity of binary distributed representations". Information Theories and Applications, 16 (3), pp. 269—290.
22. Gallant, S. I., Okaywe, T.W., 2013. "Representing objects, relations, and sequences". Neural Computation, 25 (8), pp. 2038—2078.
23. Revunova, E.G., Rachkovskij, D.A., 2009. "Using randomized algorithms for solving discrete ill-posed problems". Information Theories and Applications, 16 (2), pp. 176—192.
24. Rachkovskij, D.A., Revunova, E.G., 2012. "Randomized method for solving discrete ill-posed problems". Cybernetics and Systems Analysis, 48 (4), pp. 621—635.
25. Revunova, E.G., Rachkovskij, D.A., 2018. "Random projection and truncated SVD for estimating direction of arrival in antenna array". Cybernetics and Computer Engineering, 3 (193), pp. 5—26.
26. Kussul, E., Baidyk, T., Kasatkina, L. Lukovich, V., 2001. "Rosenblatt perceptrons for handwritten digit recognition". International Joint Conference on Neural Networks "IJCNN'01". Washington, USA, pp. 1516—1521.
27. Kussul, E., Baidyk, T., 2004. "Improved method of handwritten digit recognition tested on MNIST database". Image and Vision Computing, 22, pp. 971—981.
28. Kussul, E., Baidyk, T., 2006. "LIRA neural classifier for handwritten digit recognition and visual controlled microassembly". Neurocomputing, 69(16—18), pp. 2227—2235.
29. Makeyev, O., Sazonov, E., Baidyk, T., Martin, A., 2008. "Limited receptive area neural classifier for texture recognition of mechanically treated metal surfaces". Neurocomputing, 71 (7—9), pp. 1413.
30. Kussul, E., Baidyk, T., Wunsch, D., 2010. Neural Networks and Micro Mechanics. Springer, 221 p.

31. Cristianini, N., Shawe-Taylor, J., 2000. *An Introduction to Support Vector Machines (and other Kernel-Based Learning Methods)*. Cambridge University Press New York, NY, USA.
32. Schlesinger, M.I., Kalmykov, V.G., Sukhorukov, A.A., 1981. "Comparative analysis of algorithms that synthesize a linear solution for the analysis of complex hypotheses." *Automation*. 1981. pp. 3–9.
33. Schlesinger, M.I., Hlavac, V., 2002. *Ten Lectures on Statistical and Structural Pattern Recognition*. Dordrecht: Kluwer Academic Publishers, 522 p.
34. Franc, V., Hlavác, V., 2003. "An iterative algorithm learning the maximal margin classifier". *Pattern Recognition*, 36 (9), pp. 1985–1996.
35. Baidyk, T, Kussul, E., Makeyev, O., Vega, A., 2008. "Limited receptive area neural classifier based image recognition in micromechanics and agriculture". *International Journal of Applied Mathematics and Informatics*, 2 (3), pp. 96–103.
35. Baydyk, T, Kussul, E., Hernández Acosta, M., 2012. "New Application of LIRA neural network". *The 16th WSEAS International Conference on Circuits*. Greece, Kos Island, pp. 115–119.
37. Kasatkina, L.M., Lukovich, V.V., Pilipenko, V.V., 2006. "Personality recognition by voice using the LIRA classifier". *Upravlausie sistemy i masiny*, 3, pp. 67–73. (In Russian).
38. Hebb, D.O., 1949. *The Organization of Behavior*. New York, USA: John Wiley & Sons Inc., 335 p.
39. Goltsev, A.D., 1991. "Structured neural networks with learning for texture segmentation in images". *Cybernetics and Systems Analysis*. Plenum Publishing Corporation. New York, USA, 27 (6), pp. 927–936.
40. Goltsev, A., 1996. "An assembly neural network for texture segmentation". *Neural Networks*, 9 (4), pp. 643–653.
41. Goltsev, A., Wunsch, D.C., 1998. "Inhibitory connections in the assembly network for texture segmentation". *Neural Networks*, 11 (5), pp. 951–962.
42. Goltsev, A., Wunsch, D.C., 2004. "Generalization of features in the assembly neural networks". *International Journal of Neural Systems (IJNS)*, 14 (1), pp. 39–56.
43. Goltsev, A., 2004. "Secondary learning in the assembly neural network". *Neurocomputing*, 62, pp. 405–426.
44. Goltsev, A., Rachkovskij, D., 2005. "Combination of the assembly neural network with a perceptron for recognition of handwritten digits arranged in numeral strings". *Pattern Recognition*, 38 (3), pp. 315–322.
45. Goltsev, AD, 2005. *Neural networks with ensemble organization*. Kiev: Naukova Dumka, 200 p. (In Russian).
46. Goltsev, A., Gritsenko, V., 2009. "Modular neural networks with Hebbian learning rule". *Neurocomputing*, 72 (10–12), pp. 2477–2482.
47. Goltsev, A., Gritsenko, V., 2009. "Investigation of efficient features for image recognition by neural networks". *Neural Networks*, 28, pp. 15–23.
48. Goltsev, A., Gritsenko, V., 2015. "Modular neural networks with radial neural columnar architecture". *Biologically Inspired Cognitive Architectures*, 13, pp. 63–74.
49. LeCun The MNIST database of handwritten digits. [online] Available at: <<http://yann.lecun.com/exdb/mnist/>> [Accessed 16 Oct. 2018].

Received 22.10.2018

A.D. Goltsev, канд. техн. наук, ст. научн. сотр., и.о. зав. отделом,
Міжнародний науково—навчальний центр інформаційних технологій та систем
НАН та МОН України, просп. Глушкова, 40, Київ 03187, Україна,
root@adg.kiev.ua

V.I. Gritsenko член—кор. НАН України, директор,
Міжнародний науково—навчальний центр інформаційних технологій та систем
НАН та МОН України, просп. Глушкова, 40, Київ 03187, Україна,
vig@irtc.org.ua

NEURAL NETWORK TECHNOLOGIES IN THE TASK OF RECOGNIZING HANDWRITING CHARACTERS

Introduction. Department of Neural Network Information Processing Technologies of the International Research and Training Center for Information Technologies and Systems is the successor to the Department of Biological and Medical Cybernetics, which was organized by Academician Amosov in 1962. Currently, the research goal is to develop the effective neural network information processing technologies based on computer simulation of the neural human brain organization and the mechanisms of its thinking. The developed neural network technologies are intended for solving the actual practical problems related to the field of Artificial Intelligence.

The purpose is to describe some of the department's work related to the field of image recognition and classification, in particular, the task of character image recognition.

Methods are: basic definitions, recommendations and conclusions grounded on the analysis of the research results.

Results the article considers two types of neural classifiers: *LiRA* neural classifier and modular neural networks. Both classifiers are designed to solve practical problems of image recognition. Both classifiers solve the problem by searching a certain set of pre-constructed features in the images. Both classifiers use the so-called *LiRA*-features. The ability of classifiers to effectively recognize visual images is largely based on the use of a very large number (tens and hundreds of thousands) of simple and effective *LiRA* functions. A series of experiments is conducted comparing the *LiRA* classifier and the modular neural network. The experiments show that the latest version of the modular neural network has a higher efficiency (recognition ability) than the *LiRA* classifier, although it is slightly inferior in speed.

Conclusion. The neurobiological relevance of the *LiRA* classifier and the modular neural network opens up the possibility of creating on their basis intelligent information technologies that function similarly to the human brain.

Keywords: *neurons, neural layers, trained connections, LiRA-features, inhibitory connections.*

А.Д. ГОЛЬЦЕВ, канд. техн. наук, ст. наук. співр., в.о. зав. віділом,
Міжнародний науково—навчальний центр інформаційних технологій та систем
НАН та МОН України, просп. Глушкова, 40, Київ 03187, Україна,
root@adg.kiev.ua

В.И. ГРИЦЕНКО, член—кор. НАН України, директор,
Міжнародний науково—навчальний центр інформаційних технологій та систем
НАН та МОН України, просп. Глушкова, 40, Київ 03187, Україна,
vig@irtc.org.ua

НЕЙРОМЕРЕЖЕВІ ТЕХНОЛОГІЇ В ЗАДАЧІ РОЗПІЗНАВАННЯ РУКОПИСНИХ СИМВОЛІВ

Вступ. Відділ нейромережових технологій обробки інформації Міжнародного науково-навчального центру інформаційних технологій і систем виокремився з відділу біологічної і медичної кібернетики, організованого академіком М.М. Амосовим у 1962 р. На даний час метою досліджень є розробка ефективних нейромережових технологій обробки інформації на основі комп'ютерного моделювання нейронної організації мозку людини і механізмів його мислення. Розроблені нейромережові технології призначені для використання у вирішенні актуальних практичних завдань, що належать до області штучного інтелекту.

Мета статті – описати частину робіт відділу, що стосуються розпізнавання і класифікації зображень, зокрема розпізнавання символічних зображень.

Методи - базові означення, рекомендації та висновки ґрунтуються на аналізі результатів власних досліджень.

Результат - в статті розглянуті два типи нейронних класифікаторів: нейронний класифікатор *LiRA* і модульні нейронні мережі. Обидва класифікатора призначені для вирішення практичних завдань з розпізнавання зображень. Обидва класифікатора вирішують задачу на основі пошуку в зображеннях деякого набору заздалегідь сконструйованих ознак. Функціонування обох класифікаторів розглянуто на прикладі використання так званих *LiRA*-ознак. Здатність класифікаторів ефективно розпізнавати зображення базується саме на використанні дуже великої кількості (десятків і сотень тисяч) простих і ефективних *LiRA*-ознак. На основі результатів ряду експериментів в порівнянні класифікатора *LiRA* і модульної нейронної мережі, показано, що остання версія модульної нейронної мережі володіє більш високою ефективністю ніж класифікатор *LiRA*, хоча і дещо поступається йому за швидкодією.

Висновок. Нейробіологічна релевантність класифікатора *LiRA* і модульної нейронної мережі відкриває можливості створення на їх базі інтелектуальних інформаційних технологій, які функціонують аналогічно людському мозку.

Ключові слова: нейрони, нейронні шари, зв'язку яких навчають зв'язку (обучаемые связи), *LiRA*-ознаки, гальмівні зв'язку.