

В. Д. ДМИТРИЕНКО, д-р техн. наук, проф., НТУ "ХПИ",
С. Ю. ЛЕОНОВ, д-р техн. наук, проф., НТУ "ХПИ"

НЕЙРОННАЯ СЕТЬ, ИСПОЛЬЗУЮЩАЯ СКАЛЯРНОЕ ПРОИЗВЕДЕНИЕ И ОПРЕДЕЛЯЮЩАЯ НЕСКОЛЬКО РЕШЕНИЙ

Нейронная сеть Хемминга является весьма эффективным инструментом для решения задач распознавания дискретных объектов, двоичные компоненты которых описываются с помощью биполярных компонент, а в качестве меры близости используется разность между числом одинаковых биполярных компонент векторов и расстоянием Хемминга между ними. Для более тонкой классификации двоичных объектов (векторов) применяется ряд расширений расстояния Хемминга, использующих различные функции аффинности (близости или взаимосвязи) между двоичными объектами. В статье предлагаются модификации нейронной сети Хемминга, в которых вместо расстояния Хемминга предлагаются другие функции аффинности между двоичными векторами. Ил.:7. Табл.: 2. Библиогр.: 8 назв.

Ключевые слова: нейронная сеть; расстояние Хемминга; функции аффинности между двоичными векторами; дискретные объекты.

Постановка проблемы и анализ литературы. Скалярное произведение векторов часто используется при решении разнообразных задач определения аффинности (близости или взаимосвязи) различных двоичных объектов. В частности, нейронная сеть Хемминга [1 – 3], в которой используется скалярное произведение DB двух биполярных n -разрядных векторов $D = (d_1, \dots, d_n)$, $B = (b_1, \dots, b_n)$

$$DB = \sum_{k=1}^n d_k b_k = a_{eq} - r = 2a_{eq} - n, \quad (1)$$

где a_{eq} – число одинаковых биполярных компонент у векторов D и B ; r – расстояние Хемминга между векторами D и B (число различных компонент у рассматриваемых векторов), $a_{eq} + r = n$,

применяется при распознавании черно-белых изображений по числу совпадающих биполярных компонент с учетом расстояния Хемминга

$$a_{eq} = n/2 + \frac{1}{2} \sum_{k=1}^n d_k b_k. \quad (2)$$

Число одинаковых биполярных компонент векторов можно

рассматривать как меру сходства этих векторов. Для одинаковых векторов эта мера сходства достигает максимального значения, равного числу двоичных разрядов у сравниваемых векторов. Минимальное значение, равное нулю, мера сходства принимает в том случае, когда у сравниваемых векторов нет ни одного двоичного разряда с одинаковыми компонентами.

Идея хеммингового расстояния и меры близости (2) базируется на числе несовпадающих или совпадающих разрядов у сравниваемых двоичных векторов. Однако в работах [4 – 7] отмечается, что может быть введена более тонкая классификация для сравниваемых двоичных векторов с помощью специальной табл. 1 при бинарном кодировании векторов, содержащих закодированные признаки некоторых сравниваемых объектов.

Таблица 1

Взаимосвязь признаков пары объектов (бинарных векторов)

$$D = (d_1, \dots, d_n), B = (b_1, \dots, b_n)$$

	<i>B</i>	
<i>D</i>	1	0
1	<i>a</i>	<i>e</i>
0	<i>f</i>	<i>b</i>

В табл. 1 переменная *a* введена для подсчета числа признаков (числа единичных компонент двоичных векторов), которые имеются одновременно у обоих объектов *D* и *B*. Она рассчитывается по соотношению

$$a = \sum_{v=1}^n d_v b_v. \quad (3)$$

Скалярное произведение (3) бинарных векторов *D* и *B* используется для вычисления параметра сходства (меры близости двоичных векторов) в дискретной нейронной сети АРТ-1 [1, 2]. Однако использование для оценки сходства двух бинарных векторов только единичных компонент заметно снижает возможности для более тонкого сравнения этих векторов. Для этого необходимо знание переменных *b*, *f* и *e* (табл. 1).

Переменная *b* в табл. 1 предназначена для подсчета числа признаков (числа нулевых компонент векторов), которыми рассматриваемые объекты одновременно не обладают

$$b = \sum_{v=1}^n (1-d_v)(1-b_v). \quad (4)$$

С помощью переменной f подсчитывается число признаков, которые есть у объекта (вектора) B , но нет у объекта D . Переменная e , наоборот, предназначена для учета признаков, которых нет у объекта B , но есть у второго объекта D :

$$f = \sum_{v=1}^n (1-d_v)b_v, \quad (5)$$

$$e = \sum_{v=1}^n d_v(1-b_v). \quad (6)$$

Из анализа соотношений (3) – (6) следует, что мера близости объектов D и B возрастает при увеличении функции аффинности a . Этого нельзя однозначно сказать о функции (4), поскольку только отсутствие одинаковых признаков у объектов может указывать как на сходство объектов, так и на их принадлежность к разным классам (когда общим является только это свойство). Относительно функций (5) и (6) можно сказать, что мера близости объектов D и B симметрична относительно этих функций.

Различные комбинации функций (3) – (6) позволяют получить целый ряд функций аффинности бинарных векторов (объектов, наличие или отсутствие признаков у которых кодируется бинарными компонентами) [4 – 7]. Приведем некоторые из них:

Функция аффинности Рассела и Рао

$$S_1 = \frac{a}{a+b+f+e} = \frac{a}{n}. \quad (7)$$

Функция аффинности Жаккара

$$S_2 = \frac{a}{a+f+e} = \frac{a}{n-b}. \quad (8)$$

Функция аффинности Сокаля и Мишера

$$S_3 = \frac{a+b}{n}. \quad (9)$$

Функции аффинности Кульчинского 1 и 2

$$S_4 = \frac{a}{f+e}, \quad (10)$$

$$S_5 = \frac{a}{2(a+e)} + \frac{a}{2(a+f)}. \quad (11)$$

Функция аффинности Дайса

$$S_6 = \frac{a}{2a+e+f}. \quad (12)$$

Функция аффинности Юла

$$S_7 = \frac{ab-ef}{ab+ef}. \quad (13)$$

Пример 1. Выполним с помощью функций аффинности (3) – (13) и расстояния r Хемминга сравнение трех пар векторов D и B :

$$D = (1\ 1\ 0\ 1\ 1\ 1\ 0\ 0\ 0\ 1);$$

$$B = (1\ 0\ 1\ 0\ 1\ 1\ 1\ 0\ 0\ 1);$$

$D = B = (1\ 1\ 0\ 1\ 1\ 1\ 0\ 0\ 0\ 1)$ и векторов D и $B_1 = (0\ 0\ 1\ 0\ 0\ 0\ 1\ 1\ 1\ 0)$. Результаты вычислений приведены в табл. 2.

Анализ табл. 2 показывает, что функции аффинности $S_1 - S_7$ ведут себя аналогично:

- минимальные значения принимают для векторов с противоположными бинарными компонентами;
- максимальные значения имеют для пары одинаковых бинарных векторов;
- если сравниваемые вектора не совпадают и не противоположны своими компонентами, то функции аффинности $S_1 - S_7$ принимают значения между своими максимальными и минимальными значениями.

Расстояние Хемминга ведет себя в каком-то смысле противоположно – принимает минимальное значение для одинаковых двоичных векторов и максимальное значение для векторов, которые не имеют на одного одинакового двоичного разряда.

Функции аффинности не исчерпываются соотношениями (3) – (13) [4 – 7]. Значительное число этих функций указывает на отсутствие одной универсальной функции, пригодной для сравнения любых двоичных векторов с бинарным кодированием компонент. Нет и общепризнанных рекомендаций по применению известных функций.

Таблиця 2

Значения функций аффинности для различных пар векторов

	a	b	e	f	S_1	S_2	S_3	S_4	S_5	S_6	S_7	r
Значения функций сходства для векторов D и B .	4	2	2	2	0,4	0,5	0,6	1	2/3	1/3	0,5	4
Значения функций сходства для одинаковых векторов $D = B = (1101110001)$.	6	4	0	0	0,6	0,75	1	∞	1	0,5	1	0
Значения функций сходства для векторов D и B_1 с противоположными компонентами.	0	0	6	4	0	0	0	0	0	0	-1	10

Выбор функции аффинности обычно выполняется путем анализа результатов компьютерного моделирования в пространстве признаков, закодированных бинарными компонентами.

Целью статьи является разработка модификаций нейронной сети Хемминга, позволяющих решать задачи распознавания дискретных объектов, двоичные компоненты которых описываются с помощью бинарных компонент, а в качестве меры близости используются функции аффинности вида (7) – (13).

Нейронная сеть Хемминга [1 – 3]. Имеет n входных нейронов S_1, \dots, S_n (рис. 1), которые воспринимают информацию о биполярных компонентах входных изображений $D^q = (d_1^q, \dots, d_n^q)$, $q = \overline{1, L}$. Выходные сигналы S -элементов повторяют их входные сигналы: $U_{\text{вых}S_i} = U_{\text{вх}S_i} = d_i^q$, $i = \overline{1, n}$. Каждый элемент S -слоя связан с каждым нейроном Z -слоя (рис. 1). Веса $(w_{1p}^1, w_{2p}^1, \dots, w_{np}^1)$ связей нейрона Z_p ($p = \overline{1, m}$) содержат информацию о p -ом эталонном изображении $B^p = (b_1^p, \dots, b_n^p)$: $w_{1p}^1 = b_1^p / 2, \dots, w_{np}^1 = b_n^p / 2$, где верхний индекс в весах связей указывает на слой Z -нейронов.

Функции активации элементов Z -слоя имеют вид:

$$g_z(U_{ex}) = \begin{cases} 0, & \text{если } U_{ex} \leq 0, \\ k_1 U_{ex}, & \text{если } 0 \leq U_{ex} \leq U_n, \\ U_n, & \text{если } U_{ex} > U_n, \end{cases} \quad (14)$$

где U_{ex} – входной сигнал нейрона Z-слоя; k_1 , U_n – константы.




Рис. 1. Нейронная сеть Хемминга

При подаче на вход нейронной сети изображения $D^* = (d_1^*, \dots, d_n^*)$ каждый Z-элемент определяет свои входные и выходные сигналы в соответствии с выражениями вида (2) и (14):

$$U_{exZp} = n/2 + \frac{n}{2} \sum_{i=1}^n w_{ip} d_i^*,$$

$$U_{выхZp} = g_z(U_{exZp}) = a_p, \quad p = \overline{1, m}.$$

Выходные сигналы нейронов Z -слоя поступают на соответствующие входы элементов A -слоя (рис. 1), которые имеют функции активации, описываемые соотношением

$$U_{выхAp} = g(U_{exp}) = \begin{cases} U_{exp}, & \text{если } U_{exp} > 0, \\ 0, & \text{если } U_{exp} \leq 0, \quad p = \overline{1, m}. \end{cases}$$

Веса связей нейронов A -слоя задаются соотношением

$$w_{ij}^2 = \begin{cases} 1, & \text{если } i = j, \\ -\varepsilon, & \text{если } i \neq j, \quad i, j = \overline{1, m}, \end{cases}$$

где ε – постоянная, удовлетворяющая выражению $0 < \varepsilon \leq 1/m$.

Слой A -нейронов функционирует циклически, при этом выходные сигналы элементов описываются соотношением

$$U_{выхAj}(t+1) = g(U_{выхAj}(t) - \varepsilon \sum_{p=1, p \neq j}^m U_{выхAp}(t)), \quad j = \overline{1, m}$$

при начальных условиях $U_{выхAj}(0) = a_j, \quad j = \overline{1, m}$.

Если среди входных сигналов a_p ($p = \overline{1, m}$) есть один наибольший, то в результате итерационного процесса только один нейрон A_j будет иметь выходной сигнал, больший нуля. Поскольку выходные сигналы элементов A -слоя поступают на входы нейронов Y -слоя, которые имеют функции активации вида

$$g_Y(U_{ex}) = \begin{cases} 1, & \text{если } U_{ex} > 0, \\ 0, & \text{если } U_{ex} \leq 0, \end{cases}$$

то на выходе сети Хемминга будет только один нейрон Y_j с единичным выходным сигналом. Этот сигнал указывает на то, что входное изображение $D^* = (d_1^*, \dots, d_n^*)$ по мере сходства изображений (2) наиболее близок к эталонному изображению $B^j = (b_1^j, \dots, b_n^j)$.

Новые нейронные сети, вычисляющие функции аффинности между двоичными объектами с бинарными компонентами.

Нейронную сеть Хемминга можно представить и в более общем виде (рис. 2).

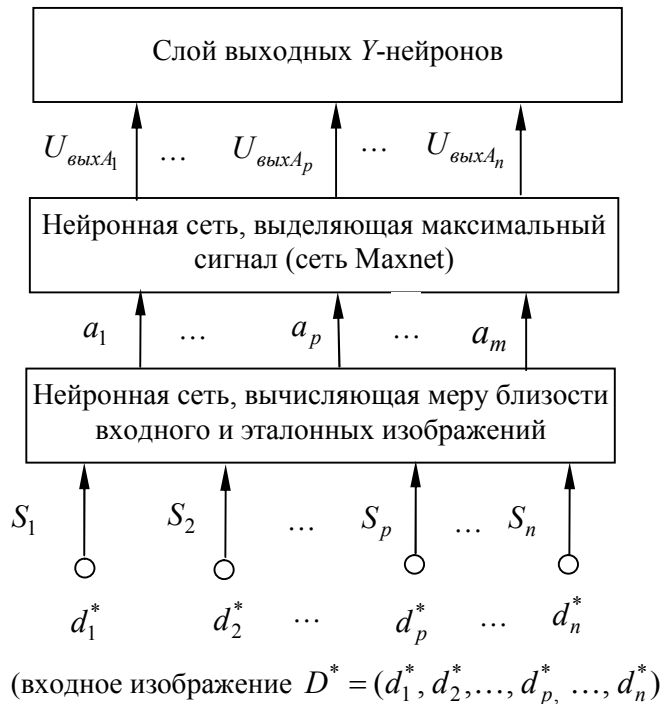


Рис. 2. Блок-схема нейронной сети Хемминга

Такое представление нейронной сети Хемминга позволяет увидеть, что два основных блока сети могут изменяться независимо друг от друга. В частности, вместо сети Махнет может использоваться нейронная сеть, выделяющая несколько одинаковых максимальных сигналов. Это позволяет находить эталонные изображения, которые могут находиться на одинаковом минимальном расстоянии от входного [3, 8]. Из архитектуры сети (рис. 2) следует и то, что блок, вычисляющий меру близости входного и эталонных изображений, может вычислять различные меры близости. Относительная независимость основных блоков нейронной сети Хемминга позволяет предложить нейронные сети и для работы с бинарными изображениями (векторами) и использующие разнообразные функции аффинности вида (7) – (13) между входными и эталонными бинарными изображениями.

В нейронной сети Хемминга (рис. 1) вычисление скалярного произведения двух бинарных векторов $D = (d_1, \dots, d_n)$, $B = (b_1, \dots, b_n)$ выполняется следующим образом

$$DB = \sum_{i=1}^n d_i b_i = (a + b) - (f + e), \quad (15)$$

где a, b, f, e – переменные, определяемые соотношениями (3) – (6), при этом вектор D является входным вектором, а вектор B – вектором весов связей нейрона, с помощью которого вычисляется скалярное произведение. Поскольку $(a + b) + (f + e) = n$, то из (15) можно получить

$$\sum_{i=1}^n d_i b_i = 2(a + b) - n$$

или

$$(a + b) = \frac{n}{2} + \frac{1}{2} \sum_{i=1}^n d_i b_i.$$

В нейронной сети Хемминга величина выражения $(a + b)$ вычисляется с помощью одного нейрона (рис. 3). В случае бинарного кодирования признаков объектов или двоичных бинарных векторов воспользоваться сетью Хемминга для вычисления скалярного произведения двух векторов не удастся. Нельзя вычислить с помощью одного нейрона и большинство функций аффинности (7) – (13). Для вычисления этих функций необходимо вначале с помощью отдельных нейронов определить функции (3) – (6), а затем с их помощью вычислять функции аффинности (7) – (13).




Рис. 3. Нейрон для вычисления скалярного произведения двух биполярных векторов в нейронной сети Хемминга;

$n/2, b_1/2, b_2/2, \dots, b_n/2$ – веса связей нейрона; d_1, d_2, \dots, d_n – компоненты входного вектора

На рис. 4 приведен нейрон для вычисления переменной a . При этом входные сигналы нейрона G_1 определяются компонентами бинарного вектора D , а веса связей – компонентами бинарного вектора $B = (b_1, \dots, b_n)$. На рис. 5 приведен блок для вычисления переменной b

(соотношение (4)). В этом блоке с помощью суммирующих элементов $\Sigma_1, \dots, \Sigma_n$ вначале вычисляются входные сигналы $(1-d_1), (1-d_2), \dots, (1-d_n)$ нейрона G_2 , которые затем умножаются на соответствующие весовые коэффициенты $(1-b_1), (1-b_2), \dots, (1-b_n)$, а после этого суммируются элементом G_2 . Это и приводит к вычислению соотношения (4). Если на рис. 5 на входы нейрона G_2 подать входные сигналы d_1, d_2, \dots, d_n вместо вычисляемых суммирующими элементами сигналов $(1-d_1), (1-d_2), \dots, (1-d_n)$, то нейрон G_2 будет вычислять переменную e (соотношение (6)). Для вычисления переменной f (соотношение (5)) в рис. 5 достаточно весовые коэффициенты $(1-b_1), (1-b_2), \dots, (1-b_n)$ заменить на соответствующие весовые коэффициенты (b_1, \dots, b_n) .




Рис. 4. Нейрон для вычисления переменной a ; b_1, b_2, \dots, b_n – веса связей нейрона; d_1, d_2, \dots, d_n – компоненты входного вектора

Имея нейроны или нейронные компоненты для вычисления переменных a, b, f, e несложно получить и нейронные сети для вычисления любой функции аффинности (7) – (13). Возьмем наиболее сложную из них – функцию аффинности Кульчинского 2. Нейронная сеть для вычисления меры близости входного и эталонного изображения приведена на рис. 6.

Аналогичным образом может быть синтезирована нейронная сеть для вычисления любой другой функции аффинности из приведенного списка. В частности, на рис. 7 приведена нейронная сеть для вычисления функции аффинности Юла (соотношение (13)).




Рис. 5. Нейрон для вычисления переменной b . На рис. приняты следующие обозначения: $(1-b_1), (1-b_2), \dots, (1-b_n)$ – веса связей нейрона G_2 ; $\Sigma_1, \dots, \Sigma_n$ – суммирующие элементы для вычисления входных сигналов нейрона G_2

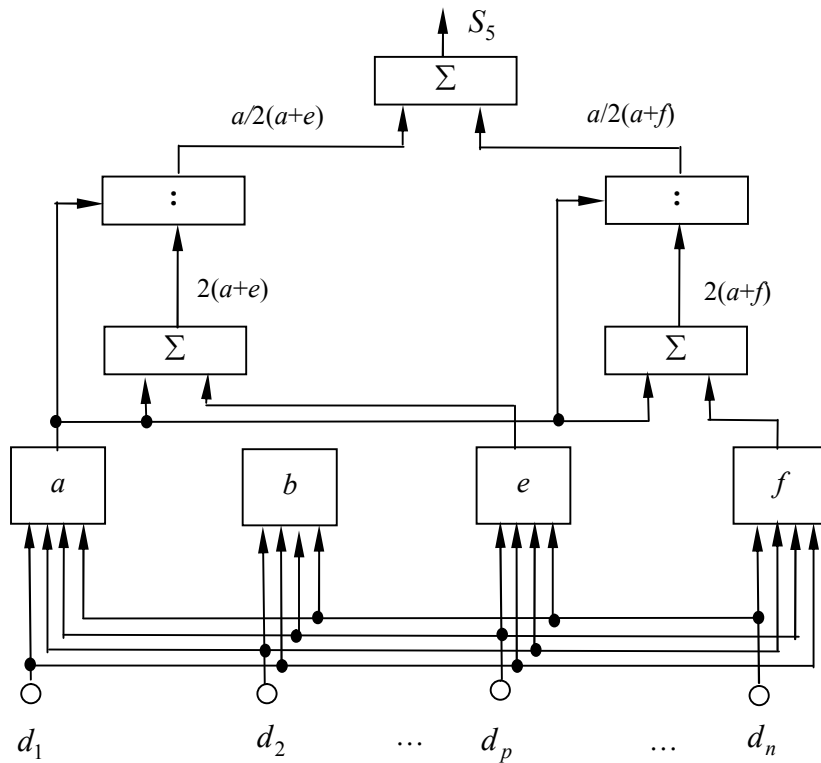


Рис. 6. Нейронная сеть, вычисляющая функцию Кульчинского 2




Рис. 7. Нейронная сеть, вычисляющая функцию аффинности Юла

Аналогичным образом могут быть синтезированы нейронные сети для вычисления любых функций близости для признаков объектов, закодированных с помощью бинарных признаков или бинарных векторов.

Выводы: Нейронная сеть Хемминга является эффективным инструментом для решения задач распознавания и классификации дискретных объектов, компоненты которых кодируются с помощью двоичного биполярного алфавита, а в качестве меры близости объектов используется разность между числом одинаковых биполярных компонент у сравниваемых объектов (векторов) и расстоянием Хемминга между ними. Однако нейронную сеть Хемминга нельзя использовать для решения указанных задач в случае, если компоненты сравниваемых объектов (векторов) кодируются с помощью бинарного алфавита. Нельзя

ее использовать и для оценки аффинности (близости) объектов (бинарных векторов) с помощью функций Жаккара, Сокала и Мишера, Кульчинского и т.д. В связи с этим разработан метод синтеза нейронных сетей, использующих для оценки близости бинарных векторов (объектов с бинарным кодированием компонент) вышеуказанные расстояния. Это расширяет область применения нейронных сетей для решения задач распознавания и классификации с помощью функций близости, использующих более тонкие признаки близости дискретных объектов с бинарным кодированием. При этом, как отмечалось при описании общей архитектуры нейронной сети Хемминга, сеть Махнет может заменяться нейронной сетью, которая позволяет определять несколько решений (если они существуют). Это позволяет, при необходимости, синтезировать нейронные сети, позволяющие получать наперед заданное число решений.

Список литературы:

1. Ямпольский Л.С. Нейротехнології та нейросистеми / Л.С. Ямпольский. – К.: Монографія. – "Дорадо-Друк", 2015. – 508 с.
2. Fausett L. Fundamentals of Neural Networks: Architectures, Algorithms and Applications / L. Fausett, New Jersey: Prentice Hall. Int., 2006. – 483 p.
3. Дмитриенко В.Д. Нейронная сеть Хемминга для решения задач с несколькими решениями / В.Д. Дмитриенко, А.Ю. Заковоротный, С.Ю. Леонов. – Вісник НТУ "ХПІ". Серія: Інформатика та моделювання. – Харків: НТУ "ХПІ". – 2017. – № 50 (1271). – С. 119-129.
4. Бабичев С.А. Теоретичні та практичні засади інформаційної технології обробки профілів експресій генів для реконструкції генних мереж. Дисертація на здобуття наукового ступеня доктора технічних наук по спеціальності 05.13.06 – інформаційні технології. – Херсон: Херсонський національний технічний університет. – 2018. – 382 с.
5. Дмитриенко В.Д. Методы и алгоритмы систем искусственного интеллекта / В.Д. Дмитриенко, И.П. Хавина, А.Ю. Заковоротный, М.В. Липчанский, Н.В. Мезенцев. – Киев: Кафедра, 2014. – 282 с.
6. Фор А. Восприятие и распознавание образов / А. Фор. – М.: Машиностроение, 1989. – 272 с.
7. Michalski R.S. A recent advance in data analysis / R.S. Michalski, E. Diday. – North Holland Edit, 1984. – P. 9-11.
8. Дмитриенко В.Д. Нейронные сети, использующие расстояние Хемминга для распознавания изображений на границах нескольких классов / В.Д. Дмитриенко, А.Ю. Заковоротный // Вісник НТУ "ХПІ". Серія Інформатика та моделювання. – Харків: НТУ "ХПІ". – 2013. – № 39 (1012). – С. 57-67.

References:

1. Yampolsky, L.S. (2015), *Neurotechnology and neurosystems*, Kiev, Monograph, "Dorado-Printing", 508 p.
2. Fausett, L. (2006), *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*, New Jersey: Prentice Hall. Int., 483 p.
3. Dmitrienko, V.D., Zakovorotny, A.Yu., and Leonov, S.Yu. (2017), "Hamming neural network for solving problems with several solutions", *Bulletin of NTU "KPI", Series: Informatics and Modeling*, Kharkiv, NTU "KPI", No. 50 (1271), P. 119-129.

4. Babichev, S.A. (2018), Theoretical and practical principles of information technology for processing gene expression profiles for gene network reconstruction. Dissertation for the degree of Doctor of Technical Sciences in specialty 05.13.06 – Information Technology, Kherson, Kherson National Technical University, 382 p.
5. Dmitrienko, V.D., Khavina, I.P., Zakovorotny, A.Yu., Lipchansky, M.V., and Mezentsev, N.V. (2014), *Methods and algorithms of artificial intelligence systems*, Kiev, Kafedra, 282 p.
6. For, A. (1989), *Perception and pattern recognition*, Moscow, Engineering, 272 p.
7. Michalski, R.S., and Diday, E. (1984), *A recent advance in data analysis*, North Holland Edit, P. 9-11.
8. Dmitrienko, V.D., Zakovorotny, A.Yu. (2013), Neural networks using Hamming distance to recognize images at the boundaries of several classes, *Bulletin of NTU "KPI", Series: Informatics and Modeling*, Kharkiv, NTU "KPI", No. 39 (1012), P. 57-67.

Статью представил доктор тех. наук, проф., зав. кафедри "Высшая математика" Ташкентского института инженеров ирригации и механизации сельского хозяйства Б.А. Худаяров.

Надійшла (received) 11.10.2019

Dmitrienko Valerii, Dr. Tech. Sci., Professor
National Technical University "Kharkiv Polytechnic Institute"
Str. Kirpicheva, 2, Kharkiv, Ukraine, 61002
Tel.: +38 (057) 707-61-98, e-mail: valdmitrienko@gmail.com
ORCID ID: 0000-0003-2523-595X

Leonov Sergey, Dr. Tech. Sci., Professor
National Technical University "Kharkiv Politechnical Institute"
Str. Kirpichova, 2, Kharkov, Ukraine, 61002
Tel.: (099) 911-911-3, e-mail: serleomail@gmail.com
ORCID ID 0000-0001-8139-0458

УДК 004.89

Дмитрієнко В.Д. Нейронна мережа, що використовує скалярний добуток і визначає кілька рішень / В.Д. Дмитрієнко, С.Ю. Леонов // Вісник НТУ "ХПІ". Серія: Інформатика та моделювання. – Харків: НТУ "ХПІ". – 2019. – № 28 (1353). – С. 68 – 82.

Нейронна мережа Хеммінга є досить ефективним інструментом для вирішення завдань розпізнавання дискретних об'єктів, двійкові компоненти яких описуються за допомогою біполярних компонент, а в якості міри близькості використовується різниця між числом однакових біполярних компонент векторів і відстанню Хеммінга між ними. Для більш тонкої класифікації двійкових об'єктів (векторів) застосовується ряд розширень відстані Хеммінга, що використовують різні функції афінності (близькості або взаємозв'язку) між двійковими об'єктами. У статті пропонуються модифікації нейронної мережі Хеммінга, в яких замість відстані Хеммінга пропонуються інші функції афінності між двійковими векторами. Іл.:7. Табл.: 2. Бібліогр.: 8 назв.

Ключові слова: нейронна мережа; відстань Хеммінга; функції афінності між двійковими векторами; дискретні об'єкти.

УДК 004.89

Дмитриенко В.Д. Нейронная сеть, использующая скалярное произведение и определяющая несколько решений / В.Д. Дмитриенко, С.Ю. Леонов // Вестник НТУ "ХПИ". Серія: Информатика и моделирование. – Харьков: НТУ "ХПИ". – 2019. – № 28 (1353). – С. 68 – 82.

Нейронная сеть Хемминга является весьма эффективным инструментом для решения задач распознавания дискретных объектов, двоичные компоненты которых описываются с помощью биполярных компонент, а в качестве меры близости используется разность между числом одинаковых биполярных компонент векторов и расстоянием Хемминга между ними. Для более тонкой классификации двоичных объектов (векторов) применяется ряд расширений расстояния Хемминга, использующих различные функции аффинности (близости или взаимосвязи) между двоичными объектами. В статье предлагаются модификации нейронной сети Хемминга, в которых вместо расстояния Хемминга предлагаются другие функции аффинности между двоичными векторами. Ил.:7. Табл.: 2. Библиогр.: 8 назв.

Ключевые слова: нейронная сеть; расстояние Хемминга; функции аффинности между двоичными векторами; дискретные объекты.

Dmitrienko V.D. A neural network using a scalar product and defining several solutions / V.D. Dmitrienko, S.Yu. Leonov // Herald of the National Technical University "KhPI". Series of "Informatics and Modeling". – Kharkov: NTU "KhPI". – 2019. – № 28 (1353). – P. 68 – 82.

The Hamming neural network is a very effective tool for solving discrete object recognition problems, the binary components of which are described using bipolar components, and the difference between the number of identical bipolar components of the vectors and the Hamming distance between them is used as a proximity measure. For a finer classification of binary objects (vectors), a number of Hamming distance extensions are used, using various affinity functions (proximity or interconnection) between binary objects. The article proposes modifications of the Hamming neural network, in which instead of the Hamming distance, other affinity functions between binary vectors are proposed. Figs.: 7. Tabl.: 2. Refs.: 8 titles.

Keywords: neural network; Hamming distance; affinity functions between binary vectors; discrete objects.