

МИНИСТЕРСТВО ОБРАЗОВАНИЯ РЕСПУБЛИКИ БЕЛАРУСЬ

Учреждение образования

«Брестский государственный технический университет»

Кафедра «ЭВМ и системы»

МЕТОДИЧЕСКИЕ УКАЗАНИЯ

**по выполнению лабораторных работ по курсу
«Интеллектуальные системы принятия решений»
для студентов специальности 53 01 02**

ЧАСТЬ 2

Брест 2002

УДК 681.3

Методические указания предназначены для выполнения лабораторных работ по дисциплине "Интеллектуальные системы принятия решений" и содержат описание 7 лабораторных работ по изучению теоретических основ систем принятия решений, являются второй частью лабораторно-практического курса по изучению современных методов обработки реальных, неполных и противоречивых данных и способов автоматизированного принятия решений на их основе. Задания, требования к выполнению работ и содержанию отчетов разработаны с учетом имеющейся на кафедре «ЭВМ и системы» БГТУ аппаратно-технической базы.

Методические указания предназначены для студентов специальности 53 01 02 «Автоматизированные системы обработки информации».

Ил. 5, табл. 3, список лит. – I назв.

СОДЕРЖАНИЕ

РАЗДЕЛ 1. АРХИТЕКТУРА, ПРИНЦИПЫ ФУНКЦИОНИРОВАНИЯ И ОБУЧЕНИЯ ИНС ВЕКТОРНОГО КВАНТОВАТЕЛЯ	4
1. Архитектура векторного квантователя	4
1.1. Конкурентное обучение с одним победителем	5
1.2. Конкурентное обучение со многими победителями	6
1.3. Контролируемое конкурентное обучение	6
1.4. Порядок проведения лабораторных работ	6
Лабораторная работа №4. Исследование ИНС векторного квантователя, использующей метод конкурентного обучения с одним победителем	7
Лабораторная работа №5. Исследование ИНС векторного квантователя, использующей метод контролируемого конкурентного обучения	8
Лабораторная работа № 6. Исследование ИНС векторного квантователя, использующей метод обучения со многими победителями	9
РАЗДЕЛ 2. РЕЦИРКУЛЯЦИОННЫЕ НЕЙРОННЫЕ СЕТИ	10
2.1. Метод главных компонент	10
2.2. Архитектура рециркуляционной нейронной сети	14
2.3. Алгоритм обратного распространения ошибки	16
2.4. Кумулятивное дельта-правило	18
2.5. Метод послонного обучения	20
2.5.1. Теоретические основы метода	21
2.5.2. Алгоритм послонного обучения	25
2.6. Модифицированное правило Хебба	26
2.7. Порядок проведения лабораторных работ	28
Лабораторная работа №7. Исследование рециркуляционной ИНС, использующей метод правила Хебба для одиночного обучающего эталона ...	29
Лабораторная работа №8. Исследование рециркуляционной ИНС, использующей метод правила Хебба для серии обучающих эталонов	30
Лабораторная работа №9. Исследование рециркуляционной ИНС, использующей метод послонного обучения для одиночного обучающего эталона	31
Лабораторная работа №10. Исследование рециркуляционной ИНС, использующей метод послонного обучения для серии обучающих эталонов	32
СПИСОК ЛИТЕРАТУРЫ	32
ПРИЛОЖЕНИЕ	33

РАЗДЕЛ 1. АРХИТЕКТУРА, ПРИНЦИПЫ ФУНКЦИОНИРОВАНИЯ И ОБУЧЕНИЯ ИНС ВЕКТОРНОГО КВАНТОВАТЕЛЯ

1. Архитектура векторного квантователя

Искусственная нейронная сеть (ИНС) для векторного квантования была предложена в 1982 г. Кохоненом. Векторное квантование используется для сжатия данных и основано на идее сопоставления входного вектора с эталоном. Пусть имеется предварительно сформированное множество эталонных данных, каждое из которых называется кодовым вектором. Совокупность кодовых векторов называется кодовой книгой. При поступлении входного вектора происходит его сравнение с вектором из кодовой книги. В процессе этого выбирается такой кодовый вектор, который наилучшим образом аппроксимирует входной вектор и его номер используется в качестве кода (рис. 1.1). В качестве меры близости может использоваться евклидово расстояние D .

Нейронную сеть для векторного квантования принято называть *обучающимся векторным квантователем* (learning vector quantization). Она представляет собой двухслойную сеть с прямым распространением сигналов. В процессе поступления эталонных векторов на сеть она обучается так, что образуются кластеры различных эталонов, каждому из которых соответствует свой нейрон. При поступлении на вход такой нейронной сети неизвестного образа, он идентифицируется в соответствии с мерой близости к эталонным векторам и кодируется на выходе сети номером нейрона. Существует большое количество вариантов обучения векторного квантователя. Рассмотрим некоторые из них.




Рис. 1.1. Пример векторного квантования

1.1. Конкуреннтное обучение с одним победителем

Здесь в отдельный квант времени только один нейрон может быть победителем. Процедура обучения векторного квантователя состоит из следующих шагов.

- 1) Случайно инициализируются весовые коэффициенты нейронной сети в диапазоне $[0, 1]$.
- 2) Задается начальное значение момента времени $t = 1$.
- 3) Для всех входных образцов $x^l, l = \overline{1, L}$ последовательно вычисляется:

а) норма вектора

$$D_j^l = |X^l - W_j|,$$

где $j = \overline{1, m}$;

б) определяется нейрон победитель, обеспечивающий минимальное расстояние

$$D_k^l = \min_j D_j^l;$$

в) производится модификация весовых коэффициентов нейронных элементов

$$w_{ij}(t+1) = w_{ij}(t) + \gamma(t) \cdot (x_i - w_{ij}(t)), \text{ если } j = k$$

$$w_{ij}(t+1) = w_{ij}(t), \text{ если } j \neq k,$$

где $i = \overline{1, n}, j = \overline{1, m}$.

Величина $\gamma(t)$ характеризует скорость обучения в момент времени t . Она является постоянной величиной или уменьшается с течением времени по следующему закону:

$$\gamma(t) = \frac{1}{t}.$$

- 4) Изменяется значение времени $t = t + 1$, и процесс повторяется начиная с шага 3.

Обучение производится до получения желаемой степени согласования между входными и весовыми векторами, или до тех пор, пока не перестанут изменяться весовые коэффициенты. Рекомендуется выбирать общее количество итераций равным

$$t = (50 + 200)L,$$

где L - общее количество кодовых векторов.

1.2. Конкуреннтное обучение со многими победителями

При конкурентном обучении со многими победителями (Multiple Winner) вокруг нейрона- победителя формируются соседние нейроны, которые также входят в класс победителей V . В этом случае весовые коэффициенты изменяются для всех нейронов, принадлежащих области V . Тогда

$$\Delta w_{ij} = \begin{cases} \gamma(t) \cdot (x_i - w_{ij}), & \text{если } j \in V \\ 0, & j \notin V \end{cases} \quad (1.1)$$

1.3. Контролируемое конкурентное обучение

Если заранее известно соответствие эталонных векторов нейронным элементам, то используется *контролируемое конкурентное обучение* (Supervised Competitive learning). Для такого обучения весовые коэффициенты нейрона победителя усиливаются при корректной классификации и ослабляются в противном случае. Тогда

$$\Delta W_k = \gamma(X - W_k), \quad (1.2)$$

если X и W_k принадлежат к одному классу и

$$\Delta W_k = -\gamma(X - W_k), \quad (1.3)$$

если X и W_k принадлежат к различным классам. Весовые коэффициенты остальных нейронов при этом не изменяются.

После обучения нейронная сеть может осуществлять функции векторного квантования. При этом на выходе в каждый квант времени будет активным только один нейрон (его выход равен 1), а остальные нейроны будут иметь нулевые выходные значения.

1.4. Порядок проведения лабораторных работ

Комплексная работа студентов по способам организации и обучения ИНС векторного квантователя разделена на 3 части и представлена в виде 3 самостоятельных лабораторных работ (№4, №5, №6), описания которых приведены ниже. Работы включают в себя изучение материалов раздела 1, разработку моделей ИНС векторных квантователей и проведении исследований с использованием наборов эталонов, приведенных в приложении.

ЛАБОРАТОРНАЯ РАБОТА №4

ИССЛЕДОВАНИЕ ИНС ВЕКТОРНОГО КВАНТОВАТЕЛЯ, ИСПОЛЬЗУЮЩЕЙ МЕТОД КОНКУРЕНТНОГО ОБУЧЕНИЯ С ОДНИМ ПОБЕДИТЕЛЕМ

Цель работы. Изучить основные принципы и алгоритмы обучения и функционирования ИНС векторного квантователя при решении задач распознавания образов.

1. Порядок проведения работы

- 1.1. Изучить теоретические сведения (раздел 1).
- 1.2. Написать на любом ЯВУ программу моделирования ИНС векторного квантователя для распознавания образов.
- 1.3. Провести исследование полученной модели. При этом на вход сети необходимо подавать искаженные образы, в которых инвертированы некоторые биты. Критерий эффективности процесса распознавания - максимальное кодовое расстояние (количество искаженных битов) между исходным и поданным образом. Исходные образы взять из таблиц П.1, П.2 приложения.
- 1.4. По результатам исследований оформить отчет, содержащий:
 - титульный лист;
 - цель работы;
 - задание;
 - описание результатов распознавания;
 - выводы по лабораторной работе.

2. Контрольные вопросы

- 2.1. Что такое кодовое расстояние?
- 2.2. Нарисуйте архитектуру ИНС, применявшейся в лабораторной работе с указанием числа входов и выходов.
- 2.3. Из каких шагов состоит алгоритм обучения ИНС?
- 2.4. Чему равно теоретическое значение нейрона победителя в применявшемся алгоритме?

ЛАБОРАТОРНАЯ РАБОТА №5

ИССЛЕДОВАНИЕ ИНС ВЕКТОРНОГО КВАНТОВАТЕЛЯ, ИСПОЛЬЗУЮЩЕЙ МЕТОД КОНТРОЛИРУЕМОГО КОНКУРЕНТНОГО ОБУЧЕНИЯ

Цель работы. Изучить основные принципы и алгоритмы обучения и функционирования ИНС векторного квантователя при решении задач распознавания образов.

1. Порядок проведения работы

- 1.1. Изучить теоретические сведения (раздел 1).
- 1.2. Написать на любом ЯВУ программу моделирования ИНС векторного квантователя для распознавания образов используя метод контролируемого конкурентного обучения.
- 1.3. Провести исследование полученной модели. При этом на вход сети необходимо подавать искаженные образы, в которых инвертированы некоторые биты. Критерий эффективности процесса распознавания - максимальное кодовое расстояние (количество искаженных битов) между исходным и поданным образом. Исходные образы взять из таблиц П.1, П.2 приложения.
- 1.4. По результатам исследований оформить отчет в соответствии с перечнем, представленным в п.1.4 лабораторной работы №4.

2. Контрольные вопросы

- 2.1. Нарисуйте архитектуру НС, применявшейся в лабораторной работе с указанием числа входов и выходов.
- 2.2. Из каких шагов состоит алгоритм обучения НС?
- 2.3. Чему равно теоретическое значение нейрона победителя в применявшемся алгоритме?

ЛАБОРАТОРНАЯ РАБОТА № 6
ИССЛЕДОВАНИЕ ИНС ВЕКТОРНОГО КВАНТОВАТЕЛЯ, ИСПОЛЬЗУЮЩЕЙ
МЕТОД ОБУЧЕНИЯ СО МНОГИМИ ПОБЕДИТЕЛЯМИ

Цель работы. Изучить основные принципы и алгоритмы обучения и функционирования ИНС векторного квантователя при решении задач распознавания образов.

1. Порядок проведения работы

- 1.1. Изучить теоретические сведения (раздел 1).
- 1.2. Написать на любом ЯВУ программу моделирования ИНС векторного квантователя для распознавания образов, используя метод с многими победителями.
- 1.3. Провести исследование полученной модели. При этом на вход сети необходимо подавать искаженные образы, в которых инвертированы некоторые биты. Критерий эффективности процесса распознавания - максимальное кодовое расстояние (количество искаженных битов) между исходным и поданным образом. Исходные образы взять из таблиц П.1, П.2 приложения.
- 1.4. По результатам исследований оформить отчет в соответствии с перечнем, представленным в п.1.4 лабораторной работы №4.

2. Контрольные вопросы

- 2.1. Нарисуйте архитектуру НС, применявшейся в лабораторной работе с указанием числа входов и выходов.
- 2.2. Из каких шагов состоит алгоритм обучения НС?
- 2.3. Чему равно теоретическое значение нейрона победителя в применявшемся алгоритме?
- 2.4. Приведите геометрическую интерпретацию понятия «Евклидово расстояние между векторами» для двумерного случая.

РАЗДЕЛ 2. РЕЦИРКУЛЯЦИОННЫЕ НЕЙРОННЫЕ СЕТИ

Рециркуляционные сети характеризуются как прямым $Y=f(X)$, так и обратным $X=f(Y)$ преобразованием информации. Задачей такого преобразования является достижение наилучшего автопрогноза или самовоспроизводимости вектора X . Рециркуляционные нейронные сети применяются для сжатия (прямое преобразование) и восстановления исходной (обратное преобразование) информации. Такие сети являются самоорганизующимися в процессе работы, где обучение производится без учителя. Теоретической основой рециркуляционных нейронных сетей является *анализ главных компонент* (principal component analysis).

2.1. Метод главных компонент

Метод главных компонент применяется в статистике для сжатия информации без существенных потерь ее информативности. Он состоит в линейном ортогональном преобразовании входного вектора X размерности n в выходной вектор Y размерности p , где $p < n$. При этом компоненты вектора Y являются некоррелированными и общая дисперсия после преобразования остается неизменной. Совокупность входных паттернов представим в виде матрицы:

$$X = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_n^1 \\ x_1^2 & x_2^2 & \dots & x_n^2 \\ \dots & \dots & \dots & \dots \\ x_1^L & x_2^L & \dots & x_n^L \end{bmatrix}$$

где $X^k = (x_1^k, x_2^k, \dots, x_n^k)$ соответствует k -му входному образу, L - общее количество образов.

Будем считать, что матрица X является центрированной, то есть вектор математических ожиданий $\mu=0$. Этому добиваются при помощи следующих преобразований:

$$x_j = x_j^i - \mu^j, \quad (2.1)$$

$$\mu^j = \sum_{i=1}^L x_j^i / L. \quad (2.2)$$

Матрица ковариаций входных данных X определяется как

$$K = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2n} \\ \dots & \dots & \dots & \dots \\ \sigma_{n1} & \sigma_{n2} & \dots & \sigma_{nn} \end{bmatrix},$$

где σ_{ij} - ковариация между i -ой и j -ой компонентой входных образов.

Элементы матрицы ковариаций можно вычислить следующим образом:

$$\sigma_{ij} = \frac{1}{L} \sum_{k=1}^L (x_i^k - \mu^i)(x_j^k - \mu^j), \quad (2.3)$$

где $i, j = \overline{1, n}$.

Таким образом, на основе матрицы входных образов можно определить выборочную ковариационную матрицу. В дальнейшем изложении будем оперировать с входной информацией, представленной в виде вектора $X = (x_1, x_2, \dots, x_n)$.

Метод главных компонент состоит в нахождении таких линейных комбинаций исходных переменных

$$y_1 = w_{11}x_1 + w_{21}x_2 + \dots + w_{n1}x_n$$

$$y_2 = w_{12}x_1 + w_{22}x_2 + \dots + w_{n2}x_n$$

.....

$$y_p = w_{1p}x_1 + w_{2p}x_2 + \dots + w_{np}x_n$$

что

$$\sigma(y_i, y_j) = 0; \quad i, j = \overline{1, n};$$

$$\sigma(y_1) > \sigma(y_2) > \dots > \sigma(y_p);$$

$$\sum_{i=1}^p \sigma_{ii} = \sum_{i=1}^n \sigma(y_i).$$

Из последних выражений следует, что переменные y_i некоррелированы, упорядочены по возрастанию дисперсии и сумма дисперсий входных образов остается без изменений. Тогда подмножество первых p переменных y характеризует большую часть общей дисперсии. В результате получается сжатое представление входной информации.

Переменные $y_i, i = \overline{1, p}$ называются главными компонентами. В матричной форме преобразование главных компонент можно представить как

$$Y = W^T X, \quad (2.4)$$

где строки матрицы W^T должны удовлетворять условию ортогональности, т.е.

$$\begin{aligned} W_i W_j^T &= 1, \forall i = j \\ W_i W_j^T &= 0, \forall i \neq j \end{aligned} \quad (2.5)$$

При этом вектор W_i определяется как

$$W_i = (w_{i1} \ w_{i2} \ \dots \ w_{in}).$$

Для определения главных компонент необходимо определить весовые коэффициенты W_i , $i = 1, p$.

Можно показать, что каждая главная компонента получается как линейная комбинация $y_k = W_k X$, где W_k - собственный вектор ковариационной матрицы K , соответствующий k -му по величине собственному значению β_k этой матрицы. Для определения собственных значений β ковариационной матрицы, необходимо решить характеристическое уравнение:

$$\det(K - \beta I) = 0, \quad (2.6)$$

где I - единичная матрица.

Так как ковариационная матрица K является симметричной, то уравнение (2.6) имеет n вещественных корней:

$$\beta_1 > \beta_2 > \dots > \beta_n > 0. \quad (2.7)$$

Для определения первой главной компоненты, необходимо выбрать из n собственных значений матрицы K наибольшее (β_1) и решить следующую систему уравнений:

$$(K - \beta_1 I) W_1^T = 0, \quad (2.8)$$

где W_1^T - вектор столбец.

Из системы уравнений (2.8) определяется собственный вектор W_1 .

Как известно, собственные векторы действительной симметрической матрицы являются ортогональными. Для получения ортонормированного вектора W_1 необходимо пронормировать его:

$$W_1 = \left(\frac{w_{11}}{|W_1|}, \frac{w_{21}}{|W_1|}, \dots, \frac{w_{n1}}{|W_1|} \right), \quad (2.9)$$

$$\text{где } |W_1| = \sqrt{w_{11}^2 + w_{21}^2 + \dots + w_{n1}^2}.$$

В результате проведенных вычислений получается первая главная компонен-

та $y_1 = W_1 X$, которая имеет максимальную дисперсию $\sigma(y_1)$. Аналогичным образом определяются остальные главные компоненты. При этом вторая компонента будет иметь следующую по величине дисперсию и так далее. Получаемая матрица весовых коэффициентов является ортогональной, т.е.

$$W W^T = I. \quad (2.10)$$

Собственные числа β матрицы K характеризуют дисперсию главных компонент. При этом сумма дисперсий в пространстве исходных признаков равняется сумме дисперсий в пространстве выходных признаков:

$$\sum_{i=1}^n \sigma_{y_i}(x) = \sum_{i=1}^n \beta_i. \quad (2.11)$$

Можно показать, что метод главных компонент имеет следующий критерий информативности [1]:

$$J = \frac{\beta_1 + \beta_2 + \dots + \beta_p}{\beta_1 + \beta_2 + \dots + \beta_n}. \quad (2.12)$$

Данный критерий позволяет ориентировочно определить число главных компонент p . Так, анализируя при помощи выражения (2.12) изменение J в зависимости от числа p , можно подобрать необходимое количество компонент без существенной потери информативности J .

Рассмотрим отображение выходного вектора Y во входной вектор X . Такое отображение называется автопрогнозом. Пусть

$$X = QY + e, \quad (2.13)$$

где e - дисперсия остатка, Q - матрица размерности $n \times p$.

В [1] приводится теорема, определяющая матрицу Q .

Теорема 2.1. Минимальное значение дисперсии остатка в выражении (2.13) достигается, когда столбцы матрицы Q равняются собственным векторам W_i , вычисленных в соответствии с методом главных компонент.

Таким образом

$$Q = W = \begin{bmatrix} W_{11} & W_{12} & \dots & W_{1p} \\ W_{21} & W_{22} & \dots & W_{2p} \\ \dots & \dots & \dots & \dots \\ W_{n1} & W_{n2} & \dots & W_{np} \end{bmatrix}.$$

Тогда наилучший автопрогноз достигается, когда

$$X=WY. \quad (2.14)$$

Величина абсолютной ошибки прогноза выражается через собственные числа ковариационной матрицы

$$\Delta = \sum_{i=1}^{n-p} \beta_{p+i}. \quad (2.15)$$

Относительная ошибка определяется, как

$$\delta = \frac{\Delta}{\sum_{i=1}^n \beta_i} \cdot 100\%. \quad (2.16)$$

Метод главных компонент является эффективным средством для сжатия и восстановления данных.

2.2. Архитектура рециркуляционной нейронной сети

Рециркуляционная нейронная сеть представляет собой совокупность двух слоев нейронных элементов, которые соединены между собой двунаправленными связями (рис. 2.1).

Каждый из слоев нейронных элементов может использоваться в качестве входного или выходного. Если слой нейронных элементов служит в качестве входного, то он выполняет распределительные функции.

В противном случае нейронные элементы слоя являются обрабатывающими. Весовые коэффициенты соответствующие прямым и обратным связям характеризуются матрицей весовых коэффициентов W и W' . Для наглядности рециркуляционную сеть можно представить в развернутом виде, как показано на рис. 2.2.




Рис. 2.1. Архитектура рециркуляционной нейронной сети




Рис. 2.2. Эквивалентное представление рециркуляционной сети

Такое представление сети является эквивалентным и характеризует полный цикл преобразования информации. При этом промежуточный слой нейронных элементов производит кодирование (сжатие) входных данных X , а последний слой осуществляет восстановление сжатой информации Y . Назовем слой нейронной сети, соответствующий матрице связи W прямым, а соответствующий матрице связей W' - обратным.

Рециркуляционная сеть предназначена как для сжатия данных, так и для восстановления сжатой информации. Сжатие данных осуществляется при прямом преобразовании информации в соответствии с выражением:

$$Y = F(W^T X). \quad (2.17)$$

Восстановление или реконструкция данных происходит при обратном преобразовании информации:

$$\bar{X} = F(W' Y). \quad (2.18)$$

В качестве функции активации нейронных элементов F может использоваться как линейная, так и нелинейная функции. При использовании линейной функции активации:

$$Y = W^T X, \quad (2.19)$$

$$\bar{X} = W' Y. \quad (2.20)$$

В предыдущем разделе отмечалось, что наилучший автопрогноз достигается тогда, когда матрица весовых коэффициентов сформирована в соответствии с методом главных компонент. При этом столбцы матрицы W' равняются собственным векторам ковариационной матрицы. Тогда:

$$W' = W.$$

Таким образом весовые коэффициенты линейной рециркуляционной нейронной сети можно определить при помощи метода главных компонент. В этом

случае матрица W является ортогональной и

$$WW^T = 1.$$

Линейные рециркуляционные сети, в которых весовые коэффициенты определяются в соответствии с методом главных компонент, называются PCA сетями. Рассмотрим другие методы обучения рециркуляционных нейронных сетей.

2.3. Алгоритм обратного распространения ошибки

Рециркуляционные нейронные сети должны обеспечивать такое преобразование информации, чтобы достигалась минимальная суммарная среднеквадратичная ошибка между входными и реконструированными образами:

$$E_s = \frac{1}{2} \sum_{k=1}^L \sum_{i=1}^n (\bar{x}_i^k - x_i^k)^2, \quad (2.21)$$

где \bar{x}_i^k - i -ая компонента k -го выходного образа сети; x_i^k - i -ая компонента k -го входного образа сети; L - общее количество образов.

Можно показать [1], что функция (2.21) достигает минимума, если в качестве y_j ($j = \overline{1, p}$) использовать первые p главные компоненты вектора X . Это является теоретической основой для использования алгоритма обратного распространения ошибки, который минимизирует суммарную среднеквадратичную ошибку сети методом градиентного спуска.

Пусть среднеквадратичная ошибка сети для одного образа равняется

$$E = \frac{1}{2} \sum_{i=1}^n (\bar{x}_i - x_i)^2.$$

Тогда в соответствии с методом градиентного спуска

$$w_{ij}(t+1) = w_{ij}(t) - \alpha \frac{\partial E}{\partial w_{ij}(t)},$$

$$w'_{ji}(t+1) = w'_{ji}(t) - \alpha \frac{\partial E}{\partial w'_{ji}(t)}.$$

Рассмотрим правило модификации весовых коэффициентов нейронной сети в случае использования произвольной функции активации нейронных элементов. Тогда взвешенная сумма и выходное значение j -го нейрона скрытого слоя определяется соответственно следующим образом:

$$S_j = \sum_{i=1}^n w_{ij} x_i,$$

$$y_j = F(S_j).$$

Аналогично для i -го нейрона выходного слоя

$$S_i = \sum_{j=1}^p w'_{ji} y_j,$$

$$\bar{x}_i = F(S_i).$$

Тогда

$$\frac{\partial E}{\partial w'_{ji}} = \frac{\partial E}{\partial \bar{x}_i} \frac{\partial \bar{x}_i}{\partial S_i} \frac{\partial S_i}{\partial w'_{ji}} = (\bar{x}_i - x_i) F'(S_i) y_j,$$

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial x_i} \frac{\partial x_i}{\partial S_j} \frac{\partial S_j}{\partial w_{ij}} \frac{\partial y_j}{\partial S_j} \frac{\partial S_j}{\partial w_{ij}} = F'(S_j) x_i \gamma_j.$$

Здесь γ_j - ошибка j -го нейрона скрытого слоя. Она равняется

$$\gamma_j = \sum_{i=1}^n (\bar{x}_i - x_i) F'(S_i) w'_{ji}.$$

В соответствии с этим правило модификация весовых коэффициентов прямого и обратного слоя можно представить, как

$$w_{ij}(t+1) = w_{ij}(t) - \alpha F'(S_j) x_i \gamma_j, \quad (2.22)$$

$$w'_{ji}(t+1) = w'_{ji}(t) - \alpha F'(S_i) y_j (\bar{x}_i - x_i). \quad (2.23)$$

Подставляя в (2.22) и (2.23) производные используемой функции активации $F'(S_j)$ и $F'(S_i)$ можно получить конкретные выражения для модификации весовых коэффициентов рекуррентной нейронной сети. Данный подход можно использовать для сжатия изображения.

Для модификации весовых коэффициентов можно использовать в приведённых выше выражениях адаптивный шаг обучения. Так, при использовании линейной рекуррентной сети значение адаптивного шага при модификации весовых коэффициентов обратного слоя w' равняется:

$$\alpha(w) = \frac{1}{\sum_{j=1}^p y_j^2}.$$

Аналогичным образом определяется значение адаптивного шага обучения для модификации весовых коэффициентов прямого слоя или при использовании нелинейной функции активации нейронных элементов.

2.4. Кумулятивное дельта-правило

Кумулятивное дельта-правило представляет собой незначительную модификацию стандартного backpropagation. Рассмотрим применение данного правила для обучения линейных рециркуляционных нейронных сетей.

В процессе обучения рециркуляционной сети для каждого входного образа производится три цикла распространения информации: прямое, обратное и прямое. После этого производится настройка весовых коэффициентов сети. Для наглядности процесса распространения информации введем обозначения. Пусть $x_i(0)$ - входной вектор, поступающий на вход сети в начальный момент времени. Тогда выходной вектор сети в момент $t = 1$ определяется в результате прямого преобразования информации:

$$y_j(1) = \sum_{i=1}^n w_{ji} x_i(0), \quad (2.24)$$

где $j = \overline{1, p}$.

Вектор получается в результате обратного преобразования вектора $Y(1)$:

$$\bar{x}_i(2) = \sum_{j=1}^p w_{ji} y_j(1), \quad (2.25)$$

где $j = \overline{1, n}$.

На третьем этапе распространения информации определяется вектор $\bar{Y}(3)$:

$$\bar{y}_j(3) = \sum_{i=1}^n w_{ji} \bar{x}_i(2), \quad (2.26)$$

где $j = \overline{1, p}$.

Такое преобразование информации можно представить в виде цепочки, изображенной на рис. 2.3.




Рис. 2.3. Последовательное преобразование информации в рециркуляционной сети

Тогда ошибка восстановления информации в первом слое нейронной сети определяется как:

$$E = \frac{1}{2} \sum_i (\bar{x}_i(2) - x_i(0))^2. \quad (2.27)$$

Ошибку воспроизведения информации во втором слое нейронной сети можно представить следующим образом:

$$E' = \frac{1}{2} \sum_j (\bar{y}_j(3) - y_j(1))^2. \quad (2.28)$$

Обучение рециркуляционной нейронной сети производится как с целью минимизации ошибки E , так и E' . При этом значение $y_j(1)$ в выражение (2.28) принимается за эталонное. Тогда в соответствии с методом градиентного спуска в пространстве весовых коэффициентов:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha \frac{\partial E'}{\partial w_{ij}(t)}, \quad (2.29)$$

$$w_{ji}(t+1) = w_{ji}(t) - \alpha \frac{\partial E}{\partial w_{ji}(t)}. \quad (2.30)$$

Определим производные для линейной рециркуляционной сети. Тогда:

$$\frac{\partial E'}{\partial w_{ij}(t)} = (\bar{y}_j(3) - y_j(1)) \bar{x}_i(2), \quad (2.31)$$

$$\frac{\partial E}{\partial w'_{ji}(t)} = (\bar{x}_i(2) - x_i(0)) y_j(1). \quad (2.32)$$

В результате, выражения для настройки весовых коэффициентов рециркуляционной нейронной сети примут следующий вид:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha x_i(2)(\bar{y}_j(3) - y_j(1)), \quad (2.33)$$

$$w'_{ji}(t+1) = w'_{ji}(t) - \alpha y_j(1)(\bar{x}_i(2) - x_i(0)). \quad (2.34)$$

Для получения ортонормированных весовых векторов w_k для каждого нейрона необходимо ввести нормированное правило обучения. Пусть $W_k = (w_{1k}, w_{2k}, \dots, w_{pk})$ - весовой вектор k -го нейронного элемента. Тогда длина его в момент времени $t+1$ равняется:

$$|W_k(t+1)| = \sqrt{w_{1k}^2(t+1) + w_{2k}^2(t+1) + \dots + w_{pk}^2(t+1)}. \quad (2.35)$$

В соответствии с этим нормированное правило обучения для весовых коэффициентов k -го нейрона можно представить следующим образом:

$$w_{ik}(t+1) = \frac{w_{ik}(t) - \alpha x_i(2)(\bar{y}_k(3) - y_k(1))}{|W_k(t+1)|}. \quad (2.36)$$

Аналогично производится формирование весовых коэффициентов W' . Как уже отмечалось в процессе обучения рециркуляционной сети для каждого входного образа происходит три цикла распространения информации. После этого осуществляется модификация весовых коэффициентов сети. Процедура обучения осуществляется до тех пор, пока суммарная среднеквадратичная ошибка сети не станет меньше заданной.

В начальный момент времени производится случайная инициализация весовых коэффициентов. Рекомендуется инициализировать веса с нулевым средним [1]. При этом желательно обеспечивать симметричность весовых коэффициентов прямого и обратного слоя ($w_{ij} = w'_{ji}$). Точно такие же выражения, (2.33) и (2.34), Хинтон использовал для модификации синаптических связей нелинейных рециркуляционных сетей, хотя с формальной точки зрения это является неверным.

2.5. Метод послыпоного обучения

Характеризуется последовательной модификацией весовых коэффициентов различных слоёв нейронной сети и состоит из двух отдельных фаз обучения. На первом этапе осуществляется определение весовой матрицы $W' = [w'_{ji}]$, $j = \overline{1, p}$, $i = \overline{1, l}$ и матрицы выходных значений скрытого слоя $\bar{y} = [\bar{y}_j^k]$, $j = \overline{1, p}$, $k = \overline{1, L}$ для осуществления наилучшего автопрогноза. Для этого необходимо минимизировать суммарную среднеквадратичную ошибку между восста-

новленными данными \bar{X} и входными данными X :

$$E_S = \frac{1}{2} \sum_{k=1}^L \sum_{i=1}^{n_i} (x_i^k - \bar{x}_i)^2, \quad (2.37)$$

где L – общее количество тренировочных образцов.

На втором этапе алгоритма определяется весовая матрица прямого слоя $W = [w_{ij}]$, $i = \overline{1, n}$, $j = \overline{1, p}$. При этом в качестве эталонных выходов используются значения \bar{y} , полученные на предыдущем этапе алгоритма. Тогда обучение на втором этапе происходит с целью минимизации следующего выражения:

$$E'_S = \frac{1}{2} \sum_{k=1}^L \sum_{j=1}^p (y_j^k - \bar{y}_j)^2. \quad (2.38)$$

Рассмотрим теоретические основы метода послынного обучения.

2.5.1. Теоретические основы метода

Определим правила обучения в случае использования в слоях рециркуляционной сети нелинейной функции активации. Тогда на первом этапе алгоритма необходимо определить весовые коэффициенты обратного слоя W' , а также для каждого входного вектора X определить такой вектор Y , чтобы обеспечить минимизацию суммарной среднеквадратичной ошибки (2.37).

Рассмотрим определение матрицы выходных значений скрытого слоя \bar{Y} для минимизации выражения (2.37). В соответствии с методом градиентного спуска компоненты вектора Y должны изменяться с течением времени, как:

$$y_j(t+1) = y_j(t) - \alpha_1 \frac{\partial E}{\partial y_j(t)}. \quad (2.39)$$

Ошибка E определяется следующим образом:

$$E = \frac{1}{2} \sum_{i=1}^n (\bar{x}_i - x_i)^2, \quad (2.40)$$

где

$$\bar{x}_i = F(S_i) = F\left(\sum_{j=1}^p w_{ji} y_j\right). \quad (2.41)$$

Дифференцируя выражение (2.40) по переменной y_j получим:

$$\gamma_j = \frac{\partial E}{\partial y_j} = \sum_i \frac{\partial E}{\partial x_i} \frac{\partial x_i}{\partial S_j} \frac{\partial S_j}{\partial y_j} = \sum_{i=1}^n (\bar{x}_i - x_i) F'(S_j) w'_{ji}. \quad (2.42)$$

Тогда

$$y_j(t+1) = y_j(t) - \alpha_1 \gamma_j. \quad (2.43)$$

Для нахождения адаптивного шага обучения α_1 будем использовать метод наискорейшего спуска.

Теорема 2.2: При использовании линейной рециркуляционной сети значение адаптивного шага обучения α_1 для модификации выходных значений скрытого слоя с целью минимизации среднеквадратичной ошибки определяется на основе следующего выражения:

$$\alpha_1(t) = \frac{\sum_i (\bar{x}_i - x_i) \sum_j \gamma_j w'_{ji}}{\sum_i (\sum_j \gamma_j w'_{ji})^2}. \quad (2.44)$$

Доказательство. В соответствии с методом наискорейшего спуска

$$\alpha_1(t) = \min \{E(y_j(t) - \alpha_1(t) \gamma_j)\}.$$

Выходное значение j -го нейрона последнего слоя в момент времени $t+1$ можно представить следующим образом

$$\bar{x}_i(t+1) = \sum_{j=1}^p w'_{ji} y_j(t+1).$$

После преобразования последнего выражения получим:

$$\bar{x}_i(t+1) = \bar{x}_i(t) - \alpha_1 \sum_{j=1}^p \gamma_j w'_{ji}.$$

Определим среднеквадратичную ошибку сети, как

$$E = \frac{1}{2} \sum_{i=1}^n (\bar{x}_i(t+1) - x_i)^2.$$

Находим такое α_1 при котором среднеквадратичная ошибка сети является минимальной:

$$\frac{\partial E}{\partial \alpha_1} = \sum_{i=1}^n (\bar{x}_i(t+1) - x_i) \left(- \sum_{j=1}^p \gamma_j w'_{ji} \right) = 0.$$

Преобразуя последнее выражение, получим значение адаптивного шага обу-

чения:

$$\alpha_1 = \frac{\sum_i (\bar{x}_i - x_i) \sum_j \gamma_j w'_{ji}}{\sum_i (\sum_j \gamma_j w'_{ji})^2}$$

Так как $\frac{\partial^2 E}{\partial \alpha_1^2} > 0$, то при данном значении α_1 обеспечивается минимум средне-квадратичной ошибки. Теорема доказана.

Следствие 2.1. При использовании нелинейной рециркуляционной сети значение адаптивного шага обучения α_1 для модификации выходных значений скрытого слоя равняется

$$\alpha_1 = \frac{\sum_i (\bar{x}_i - x_i) \sum_j \gamma_j w'_{ji}}{F'(0) \sum_i (\sum_j \gamma_j w'_{ji})^2} \quad (2.45)$$

где $F'(0) = \frac{\partial F}{\partial S_i}$ при $S_i = 0$.

Доказательство данного следствия производится аналогично теореме с использованием разложения в ряд Тейлора.

Определим теперь выражение для настройки весовых коэффициентов w'_{ji} обратного слоя. Тогда в соответствии с методом градиентного спуска

$$w'_{ji}(t+1) = w'_{ji}(t) - \alpha_2 \frac{\partial E}{\partial w'_{ji}(t)} \quad (4.46)$$

Производная среднеквадратичной ошибки определяется как:

$$\frac{\partial E}{\partial w'_{ji}} = \frac{\partial E}{\partial \bar{x}_i} \frac{\partial \bar{x}_i}{\partial S_i} \frac{\partial S_i}{\partial w'_{ji}} = (\bar{x}_i - x_i) F'(S_i) \gamma_j \quad (2.47)$$

Отсюда следует, что модификация весовых коэффициентов обратного слоя должна производиться следующим образом:

$$w'_{ji}(t+1) = w'_{ji}(t) - \alpha_2 (\bar{x}_i - x_i) F'(S_i) \gamma_j \quad (2.48)$$

Адаптивный шаг обучения α_2 можно получить в виде:

$$\alpha_2 = \frac{\sum_i (\bar{x}_i - x_i)^2 F'(S_i)}{F'(0) \left(\sum_j y_j^2 \right) \sum_i (\bar{x}_i - x_i)^2 (F'(S_i))^2}. \quad (2.49)$$

Таким образом в результате выполнения первого этапа алгоритма происходит определение весовых коэффициентов обратного слоя w'_{ji} и эталонных выходов \bar{y}_j , $j = \overline{1, p}$, $k = \overline{1, L}$ скрытого слоя. Следует отметить, что значения эталонных выходов скрытого слоя \bar{y}_j могут не принадлежать диапазону от -1 до 1 . Поэтому необходимо проводить нормализацию эталонных выходов в соответствии с используемой функцией активации.

На втором этапе метода послонного обучения происходит определение весовых коэффициентов w_{ij} прямого слоя, где в качестве эталонных выходов \bar{y}_j используются значения полученные на предыдущем этапе. Для этого необходимо минимизировать выражение (2.37). Тогда

$$w_{ij}(t+1) = w_{ij}(t) - \alpha_3 \frac{\partial E'}{\partial w_{ij}(t)}, \quad (2.50)$$

где

$$E' = \frac{1}{2} \sum_{j=1}^p (y_j - \bar{y}_j)^2. \quad (2.51)$$

Определим производную среднеквадратичной ошибки:

$$\frac{\partial E'}{\partial w_{ij}} = \frac{\partial E'}{\partial y_j} \frac{\partial y_j}{\partial S_j} \frac{\partial S_j}{\partial w_{ij}} = (y_j - \bar{y}_j) F'(S_j) x_i, \quad (2.52)$$

где S_j - взвешенная сумма j -го нейрона скрытого слоя:

$$S_j = \sum_i w_{ij} x_i. \quad (2.53)$$

Тогда

$$w_{ij}(t+1) = w_{ij}(t) - \alpha_3 (y_j - \bar{y}_j) F'(S_j) x_i. \quad (2.54)$$

Значение адаптивного шага обучения α_3 определяется при этом следующим образом:

$$\alpha_3 = \frac{\sum_j (y_j - \bar{y}_j)^2 F'(S_j)}{F'(0) \left(\sum_j x_j^2 \right) \sum_j (y_j - \bar{y}_j)^2 (F'(S_j))^2} \quad (2.55)$$

Подставляя в приведённые выше выражения значения соответствующие используемой функции активации можно получить конкретные правила обучения для рециркуляционных сетей.

2.5.2. Алгоритм послонного обучения

Алгоритм послонного обучения состоит из следующих шагов.

- 1) Случайная инициализация весовых коэффициентов и задание суммарной среднеквадратичной ошибки сети E_m .
- 2) Последовательно подаются L образов на нейронную сеть. При этом для каждого образа происходит только прямое распространение информации. В результате данного этапа определяется базовый набор сжатых образов Y , которые будут использоваться на следующем этапе алгоритма.
- 3) Рассматривается только обратный слой сети. В качестве входной информации используются значения Y , определенные на предыдущем шаге алгоритма. В качестве эталонных значений выходов обратного слоя принимается вектор исходных данных X . При этом, производится следующая последовательность действий.
 - 3.1) Для L входных образов производится настройка весовых коэффициентов обратного слоя W' по выражению (2.46).
 - 3.2) Для L входных образов производится настройка желаемых выходов прямого слоя Y согласно выражению (2.43).
 - 3.3) Шаги 3.1 и 3.2 повторяются, пока суммарная среднеквадратичная ошибка обратного слоя не станет меньше заданной E_m .
- 4) Производится модификация весовых коэффициентов прямого слоя в соответствии с выражением (2.54). Для этого входные образы последовательно подаются на сеть и для каждого образа происходит только прямое распространение информации. В качестве эталонных данных используются значения \bar{Y} , полученные на предыдущем шаге алгоритма.

Пункт 4 продолжается до тех пор, пока суммарная среднеквадратичная ошибка прямого слоя не станет меньше заданной.

Существуют также другие варианты этого алгоритма. Так, например, после

выполнения шага 5 можно перейти к шагу 2 и повторить алгоритм до тех пор, пока не достигнется лучшее решение.

2.6. Модифицированное правило Хебба

Рассмотрим анализ стандартного правила Хебба с точки зрения минимизации ошибки нейронного элемента. Пусть имеются два нейронных элемента, соединённых синаптической связью w (рис. 2.4).




Рис. 2.4. Правило обучения Хебба

Тогда математически правило обучения Хебба можно представить, как

$$w(t+1) = w(t) + xy, \quad (2.56)$$

где $y = xw$.

С точки зрения метода градиентного спуска:

$$w(t+1) = w(t) - \frac{\partial E}{\partial w}. \quad (2.57)$$

Тогда функция ошибки E , которая приводит к правилу Хебба, равняется

$$E = -\frac{1}{2}y^2 = -\frac{1}{2}xwy. \quad (2.58)$$

Подставляя (2.58) в (2.57), можно получить стандартное правило Хебба. Из (2.58) следует, что правило Хебба максимизирует амплитуду выходного сигнала. Поэтому было предложено модифицированное правило Хебба, в котором вводится ограничение на возрастание амплитуды выходного сигнала. Для обратного слоя линейной рециркуляционной сети модифицированное правило Хебба можно представить следующим образом:

$$w'_{ji}(t+1) = w'_{ji} + \alpha y_j (x_i - \sum_{j=1}^p w'_{ji} y_j). \quad (2.59)$$

Данное правило обучения называется Ойя (Оја) правилом [1]. Последнее слагаемое в выражении (2.59) препятствует неограниченному возрастанию весовых коэффициентов. Теоретически доказано, что Ойя-правило эквивалентно методу

главных компонент. Тогда матрица весовых коэффициентов прямого слоя рециркуляционной сети определяется как:

$$W = (W')^T.$$

В случае обучения нейронных элементов прямого слоя весовые коэффициенты будут изменяться в соответствии со следующим выражением:

$$w_y(t+1) = w_y(t) + \alpha y_j (x_i - \sum_{j=1}^p w_{ij} y_j). \quad (2.60)$$

Проведём анализ изменения весовых коэффициентов нейронной сети, которая обучается согласно выражению (2.60). Для j -го нейронного элемента весовые коэффициенты изменяются с течением времени, как

$$\Delta W_j = \alpha y_j (X - WY),$$

где:

$$X = [x_1 \ x_2 \ \dots \ x_n]^T,$$

$$Y = [y_1 \ y_2 \ \dots \ y_n]^T,$$

$$\Delta W_j = [\Delta w_{1j}, \Delta w_{2j}, \dots, \Delta w_{nj}]^T,$$

$$W = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1p} \\ w_{21} & w_{22} & \dots & w_{2p} \\ \dots & \dots & \dots & \dots \\ w_{n1} & w_{n2} & \dots & w_{np} \end{bmatrix}.$$

Рассмотрим весовые коэффициенты нейронной сети в состоянии равновесия, т.е.

$$\Delta W_j = \alpha y_j (X - WY) = 0.$$

Умножим обе части последнего выражения на W^T . Тогда получим

$$W^T X - W^T W Y = 0.$$

Так как $W^T X = Y$, то

$$W^T W = I, \quad (2.61)$$

где I - единичная матрица.

Как известно равенство (2.61) определяет необходимое и достаточное условие ортогональности матрицы W . Отсюда следует, что столбцы матрицы W являются ортонормированными, т.е.

$$\sum_{i=1}^n w_{ij} w_{ik} = \begin{cases} 1, & j = k \\ 0, & j \neq k \end{cases}$$

для любых j, k .

Таким образом Ойя-правило эквивалентно методу главных компонент.

Проанализируем правило Ойя для линейной сети с точки зрения метода градиентного спуска. Тогда среднеквадратичная ошибка и выходное значение рециркуляционной сети равняется

$$E = \frac{1}{2} \sum_{i=1}^p (\bar{x}_i - x_i)^2,$$

$$\bar{x}_i = \sum_{j=1}^p w'_{ji} y_j.$$

В соответствии с методом градиентного спуска

$$\frac{\partial E}{\partial w'_{ji}} = \frac{\partial E}{\partial x_i} \frac{\partial x_i}{\partial w'_{ji}} = -(x_i - \bar{x}_i) y_j = -y_j (x_i - \sum_{l=1}^p w'_{li} y_l).$$

Последнее выражение эквивалентно (2.59). Отсюда следует, что метод градиентного спуска приводит к Ойя-правилу для рециркуляционной сети.

2.7. Порядок проведения лабораторных работ

Исследовательская работа студентов по способам организации, обучения и применения рециркуляционных нейронных сетей разделена на 4 части и представлена в виде 4 самостоятельных лабораторных работ (№7, №8, №9, №10), описания которых приведены ниже. Работы включают в себя изучение материалов раздела 2, разработку моделей рециркуляционных нейронных сетей, алгоритмов обучения, проведение исследований по сжатию данных с использованием различных способов организации обучающих множеств на основе эталонов, приведенных в приложении.

ЛАБОРАТОРНАЯ РАБОТА №7

ИССЛЕДОВАНИЕ РЕЦИРКУЛЯЦИОННОЙ ИНС, ИСПОЛЬЗУЮЩЕЙ МЕТОД ПРАВИЛА ХЕББА ДЛЯ ОДИНОЧНОГО ОБУЧАЮЩЕГО ЭТАЛОНА

Цель работы. Изучить основные принципы функционирования рециркуляционной ИНС при решении задач сжатия образов, исследовать метод правила Хебба для обучения ИНС при использовании одиночного обучающего эталона.

1. Порядок проведения работы

- 1.1. Изучить теоретические сведения (раздел 2).
- 1.2. Написать на лобом ЯВУ программу моделирования рециркуляционной ИНС для сжатия образов, используя метод правила Хебба. Сжатие производить в матрицу 2×4 . Сеть состоит из 4 входов и двух выходов. В качестве обучающих образов необходимо использовать фрагменты матрицы размером 2×2 . Исходные образы взять из таблицы П.3 приложения. Для организации обучения использовать один эталон (16-разрядную последовательность битов, из которых состоит исходный образ).
- 1.3. Провести исследование полученной модели.
- 1.4. Оформить отчет, содержащий:
 - титульный лист;
 - цель работы;
 - задание;
 - описание результатов обучения и сжатия образов;
 - выводы по лабораторной работе.

2. Контрольные вопросы

- 2.1. Нарисуйте архитектуру НС, применявшейся в лабораторной работе с указанием числа входов и выходов.
- 2.2. Из каких шагов состоит алгоритм обучения НС?
- 2.3. Сравните результаты обоих случаев сжатия и объясните разницу в результатах.
- 2.4. Какая функция активации использовалась в архитектуре НС?

ЛАБОРАТОРНАЯ РАБОТА №8

ИССЛЕДОВАНИЕ РЕЦИРКУЛЯЦИОННОЙ ИНС, ИСПОЛЬЗУЮЩЕЙ МЕТОД ПРАВИЛА ХЕББА ДЛЯ СЕРИИ ОБУЧАЮЩИХ ЭТАЛОНОВ

Цель работы. Изучить основные принципы функционирования рециркуляционной ИНС при решении задач сжатия образов, исследовать метод правила Хебба для обучения ИНС при использовании серии обучающих эталонов.

1. Порядок проведения работы

- 1.1. Изучить теоретические сведения (раздел 2).
- 1.2. Написать на любом ЯВУ программу моделирования рециркуляционной ИНС для сжатия образов, используя метод правила Хебба. Сжатие производить в матрицу 2×4 . Сеть состоит из 4 входов и двух выходов. В качестве обучающих образов необходимо использовать фрагменты матрицы размером 2×2 . Исходные образы взять из таблицы П.3 приложения. Для организации обучения использовать серию из 4 эталонов (4 4-разрядные последовательности битов, из которых состоит исходный образ).
- 1.3. Провести исследование полученной модели.
- 1.4. По результатам исследований оформить отчет в соответствии с перечнем, представленным в п. 1.4 лабораторной работы №7.

2. Контрольные вопросы

- 2.1. Нарисуйте архитектуру НС, применявшейся в лабораторной работе с указанием числа входов и выходов.
- 2.2. Из каких шагов состоит алгоритм обучения НС?
- 2.3. Сравните результаты данной работы с предыдущей.
- 2.4. Приведите эквивалентное представление рециркуляционной НС для вашего варианта архитектуры НС.

ЛАБОРАТОРНАЯ РАБОТА №9

ИССЛЕДОВАНИЕ РЕЦИРКУЛЯЦИОННОЙ ИНС, ИСПОЛЬЗУЮЩЕЙ МЕТОД ПОСЛОЙНОГО ОБУЧЕНИЯ ДЛЯ ОДИНОЧНОГО ОБУЧАЮЩЕГО ЭТАЛОНА

Цель работы. Изучить основные принципы функционирования рециркуляционной ИНС при решении задач сжатия образов, исследовать алгоритм послойного обучения ИНС при использовании одиночного обучающего эталона.

1. Порядок проведения работы

- 1.1. Изучить теоретические сведения (раздел 2).
- 1.2. Написать на любом ЯВУ программу моделирования рециркуляционной ИНС для сжатия образов, используя метод послойного обучения. Сжатие производить с коэффициентом 75% (в матрицу 3x3) и 50% (в матрицу 2x2). Исходные образы взять из таблицы П.3 приложения. Для организации обучения использовать один эталон (16-разрядную последовательность битов, из которых состоит исходный образ).
- 1.3. Провести исследование полученной модели.
- 1.4. По результатам исследований оформить отчет в соответствии с перечнем, представленным в п. 1.4 лабораторной работы №7.

2. Контрольные вопросы

- 2.1. Нарисуйте архитектуру ИНС, применявшейся в лабораторной работе с указанием числа входов и выходов.
- 2.2. Из каких шагов состоит алгоритм обучения ИНС?
- 2.3. Сравните результаты данной работы с предыдущей.
- 2.4. Сравните скорость обучения ИНС в данной работе с ИНС в предыдущей работе.

ЛАБОРАТОРНАЯ РАБОТА №10

ИССЛЕДОВАНИЕ РЕЦИРКУЛЯЦИОННОЙ ИНС, ИСПОЛЬЗУЮЩЕЙ МЕТОД ПОСЛОЙНОГО ОБУЧЕНИЯ ДЛЯ СЕРИИ ОБУЧАЮЩИХ ЭТАЛОНОВ

Цель работы. Изучить основные принципы функционирования рециркуляционной ИНС при решении задач сжатия образов, исследовать алгоритм послойного обучения ИНС при использовании серии обучающих эталонов.

1. Порядок проведения работы

- 1.1. Изучить теоретические сведения (раздел 2).
- 1.2. Написать на лобом ЯВУ программу моделирования рециркуляционной ИНС для сжатия образов, используя метод послойного обучения. Сжатие производить с коэффициентом 75% (в матрицу 3x3) и 50% (в матрицу 2x2). Исходные образы взять из таблицы П.3 приложения. Для организации обучения использовать серию из 4 эталонов (4 4-разрядные последовательности битов, из которых состоит исходный образ).
- 1.3. Провести исследование полученной модели.
- 1.4. По результатам исследований оформить отчет в соответствии с перечнем, представленным в п. 1.4 лабораторной работы №7.

2. Контрольные вопросы

- 2.1. Нарисуйте архитектуру НС, применявшейся в лабораторной работе с указанием числа входов и выходов.
- 2.2. Из каких шагов состоит алгоритм обучения НС?
- 2.3. Сравните результаты данной работы с предыдущей.
- 2.4. Расскажите алгоритм функционирования НС.
- 2.5. Какая функция активации использовалась в архитектуре НС?

СПИСОК ЛИТЕРАТУРЫ

1. Головкин В.А. Нейронные сети: обучение, организация и применение. Кн. 4: учебное пособие для вузов. – М.: ИПРЖР, 2001. – 256 с

ПРИЛОЖЕНИЕ

Варианты заданий к лабораторным работам №4-№6

Таблица II.1

Вариант	Эталон 1	Эталон 2	Эталон 3
1	1	6	8
2	2	1	8
3	3	2	8
4	4	3	8
5	5	4	8
6	6	5	8
7	7	6	8
8	1	3	8
9	2	4	8
10	3	5	8

Таблица II.2

№	Данные эталона																			
	0	1	0	0	1	1	0	1	0	0	0	0	1	0	1	0	1	0	0	0
1	0	1	0	0	1	1	1	0	1	0	0	0	1	0	1	0	1	0	0	0
2	0	0	0	0	1	1	1	1	0	0	0	0	1	1	1	1	0	0	0	0
3	1	1	1	1	0	0	0	0	1	1	1	1	0	0	0	1	1	1	1	1
4	1	1	0	0	1	1	0	0	1	1	0	0	1	1	0	0	1	1	0	0
5	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0	1	0
6	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1
8	1	1	1	0	0	0	1	1	1	0	0	0	1	1	1	0	0	0	1	1

Варианты заданий к лабораторным работам №7- №10

Таблица II.3

№	Образы	№	Образы
1	[1, 0, 0, 0]	6	[0, 0, 0, 1]
	[0, 1, 0, 0]		[0, 0, 1, 1]
	[0, 0, 1, 0]		[0, 1, 1, 1]
2	[0, 0, 0, 1]	7	[1, 1, 1, 1]
	[1, 1, 0, 0]		[1, 1, 0, 0]
	[0, 1, 1, 0]		[0, 0, 1, 1]
3	[0, 0, 1, 1]	8	[0, 0, 0, 0]
	[1, 0, 0, 1]		[1, 1, 1, 1]
	[1, 1, 1, 0]		[1, 1, 1, 0]
4	[1, 1, 0, 1]	9	[1, 1, 0, 1]
	[1, 0, 1, 1]		[1, 0, 1, 1]
	[0, 1, 1, 1]		[0, 1, 1, 1]
5	[1, 1, 1, 1]	10	[1, 0, 0, 1]
	[0, 0, 0, 0]		[1, 1, 0, 0]
	[1, 1, 0, 0]		[0, 1, 1, 0]
5	[0, 0, 1, 1]	10	[0, 0, 1, 1]
	[1, 0, 0, 0]		[0, 0, 0, 1]
	[1, 1, 0, 0]		[0, 0, 1, 0]
5	[1, 1, 1, 0]	10	[0, 1, 0, 0]
	[1, 1, 1, 1]		[1, 0, 0, 0]

Учебное издание

Составители: Головки Владимир Адамович
Дунец Андрей Петрович
Савицкий Юрий Викторович

МЕТОДИЧЕСКИЕ УКАЗАНИЯ к выполнению лабораторных работ по курсу «Интеллектуальные системы принятия решений» для студентов специальности 53 01 02

ЧАСТЬ 2

Ответственный за выпуск: Дунец А.П.
Редактор: Строкач Т. В.
Технический редактор: Никитчик А.Д.
Корректор: Никитчик Е.В.

Подписано к печати 6.07.02г.

Формат 60x84/16 Бумага «Чайка»

Усл. п.л. 2,1. Уч. изд. л. 2,25 Тираж 120 экз. Заказ № 645

Отпечатано на ризографе Учреждения образования
«Брестский государственный технический университет»
224017, Брест, ул. Московская, 267.