

$$\text{где } G(\alpha) = \left(I_{m_1} \alpha + S_{11}^T(\gamma_{11}) S_{11}(\gamma_{11}) \right)^{-1} S_{11}^T(\gamma_{11}), \quad S(\gamma) = \sum_{i=0}^{\gamma_{11}} S_{12}(i) \Delta^{\gamma_{11} + \gamma_{22} - i} S_{22}^+(\gamma_{22}).$$

С учетом (11), условиями структурной невырожденности системы (1) при локально-оптимальном управлении (8) являются

$$\text{rank}\left(I_{m_1} - G(\alpha)S(\gamma)D_{21}\right) = m_1, \quad \text{rank}\left(I_{m_1} \alpha + S_{11}^T(\gamma_{11}) S_{11}(\gamma_{11})\right) = m_1. \quad (12)$$

Таким образом, при выполнении условий (12) возможно получение в явном виде уравнений развязывающего компенсатора (11) в виде многомерной дискретной динамической системы авторегрессионного типа, порядок которой определяется запаздыванием по каналу измерений.

Выводы. В работе обоснована возможность применения метода локально-оптимального прогнозирующего управления в задачах компенсации неизмеряемых возмущений. Применение предложенного метода позволяет получить уравнения развязывающего компенсатора в явном виде и синтезировать физически реализуемый закон управления. Определенным недостатком метода внутренних моделей применительно к задаче оценивания возмущений является то, что структура и параметры наблюдателя возмущений (4), (5) с внутренней моделью полностью определяются уравнениями объекта, вследствие чего наблюдатель может иметь неудовлетворительные динамические свойства. Так, например, для неминимально-фазовых объектов по каналу управления наблюдатель оказывается неустойчивым. В этом случае синтез наблюдателя возмущения с заданными динамическими свойствами возможен на основе применения теории инвариантных наблюдателей и обратных динамических моделей [8].

Таким образом, метод локально-оптимального управления в сочетании с методом внутренних моделей обеспечивает возможность решения задачи управления выходом динамической системы с запаздыванием.

Список литературы: 1. Макаров И.М., Менский Б.М. Линейные автоматические системы. - М.: Машиностроение, 1982. - 504 с. 2. Емельянов С.В., Коровин С.К. Новые типы обратной связи: Управление при неопределенности. - М.: Наука. Физматлит, 1997. - 352 с. 3. Костенко Ю.Т., Любчик Л.М. Системы управления с динамическими моделями. - Харьков: Основа, 1996. - 212 с. 4. Tsypkin Ya. Z., Holmberg U. Robust stochastic control and internal model control // Int. J. of Control. 1995. - Vol. 61. - No 4. - P. 809 - 822. 5. Kelmans G.K., Roznyak A.S., Chernitsar A.V. Adaptive locally optimal control // Int. J. System Science. -1981. - Vol.12. - No 2.-P. 235-254. 6. Любчик Л.М., Малько М.Н. Структурный синтез регуляризованных обратных систем пониженного порядка // Системний аналіз, управління і інформаційні технології: Вісник Харківського державного політехнічного університету. Збірка наукових праць. - Харків: ХДПУ, 1999. - Випуск 72.- С. 165 - 168. 7. Lyubchik L.M., Mueller P.C. Robust disturbance decoupling in multivariable systems via the unknown-input observers // Proceedings of 16-th IFAC World Congress, Prague, July 4-8, 2005. - 6 р. 8. Любчик Л.М. Метод обратных динамических моделей в задачах синтеза многомерных комбинированных систем с наблюдателями возмущений // Радиоэлектронні і комп'ютерні системи.-№ 5 (24).- 2007.-С. 77- 83.

Поступила в редакцию 15.06.08

УДК 681.513

Ю.И. ДОРОФЕЕВ, канд. техн. наук,
А.А. ГЛУХОВА

ИССЛЕДОВАНИЕ КАЧЕСТВА КОМПРЕССИИ ДАННЫХ С ПОМОЩЬЮ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Розглядається розв'язання задачі стискування та відновлення дискретної інформації за допомогою штучних нейронних мереж. Аналізується вплив розміру та параметрів нейронної мережі на величину похибки декодування даних.

Рассматривается решение задачи компрессии и восстановления дискретной информации с помощью искусственных нейронных сетей. Анализируется влияние размера и параметров нейронной сети на величину ошибки декодирования данных.

The problem of compression and restoration of discrete information using artificial neural networks is considered. The impact of the size and parameters of the neural network by the amount of errors decoding data is analyzed.

Введение. В связи с непрерывным увеличением объема информации, накапливаемой во всех областях человеческой деятельности, все большее значение приобретают технологии ее компактного представления. Способ получения компактного представления информации называют экономным кодированием или компрессией.

Отправной точкой развития технологий экономного кодирования принято считать 40-е годы XX века – период зарождения теории информации. Тогда основные результаты носили в большинстве своем чисто теоретический характер и почти не имели практической ценности. С появлением в конце 70-х годов эффективных практических схем компрессии данных интерес к этому разделу теории информации заметно вырос, однако невысокий уровень развития вычислительной техники препятствовал развитию этого направления. Многие вопросы были в полной мере исследованы только во второй половине 80-х годов.

В настоящее время раздел теории информации, касающийся методов компрессии и архивации, претерпевает серьезные изменения, что связано со значительным увеличением объемов теоретических и прикладных исследований.

Методы компрессии информации. Теория экономного кодирования объединяет несколько направлений. В рамках данной теории принято выделять методы компрессии информации без потерь и методы компрессии информации с потерями [1]. Методы второй группы применяются к информации, содержащей отдельные несущественные составляющие, не несущие значимой смысловой нагрузки. Примерами могут служить звуковая

информация, предназначенная для прослушивания, и графические изображения.

Методы компрессии без потерь используются для обработки дискретной информации. Любое дискретное информационное сообщение на языке теории информации представляется как некоторая конечная последовательность натуральных чисел. Настоящая работа посвящена исследованию качества компрессии дискретной информации с помощью искусственных нейронных сетей.

Любой метод компрессии данных так или иначе учитывает информационные закономерности, которые свойственны различным типам информации. Различие между методами состоит только в способе учета этих закономерностей.

Для осуществления эффективной компрессии сообщений, поступающих с выхода некоторого источника информации, требуется знание его характеристик. В случае, когда нет дополнительной информации об источнике, определить его характеристики можно только путем статистического анализа его информационной выборки.

В основе большинства существующих методик компрессии лежат два подхода. Первый называется вероятностным и позволяет учесть статистические особенности появления символов в информационном сообщении. Основная идея сокращения объема информации заключается в том, что часто встречающимся символам ставятся в соответствие короткие коды, а символам, встречающимся реже, – длинные коды. В настоящее время в большинстве коммерческих приложений для построения системы кодов переменной длины используется кодирование Хаффмена [2], являющееся лучшим с точки зрения качества информационного представления.

В основе другого подхода, называемого комбинаторным, лежит трактовка информационных закономерностей как присутствие в информации одних символьных комбинаций и полное отсутствие других. Кодирование основывается на построении кодовых систем, содержащих коды только тех информационных последовательностей, которые реально порождаются информационным источником. К данной категории, в частности, относятся методы словарной группы, впервые описанные в работах А.Лемпеля и Я.Зива [3].

Основу методов кодирования данной группы составляет информационная структура, называемая словарем. Методы отличаются друг от друга способом организации словаря и схемой поиска совпадений в информационной выборке. Разбиение дискретного информационного сообщения на кодируемые составляющие представляет собой трудноформализуемую задачу, от оптимальности решения которой в значительной степени зависит эффективность метода.

Экспериментальная оценка качества компрессии информации с помощью нейронных сетей. Несмотря на высокую популярность использования искусственных нейронных сетей для решения трудноформализуемых

задач, для целей экономного кодирования информации они применяются относительно недавно.

В данной работе исследуется качество компрессии дискретных данных с использованием сети Кохонена, которая представляет собой набор упорядоченных нейронов (называемых картой), обучение которых осуществляется "без учителя" путем самоорганизации. В картах Кохонена нейроны помещаются в узлах решетки, обычно одно- или двухмерной.

Рассмотрим нелинейное преобразование, которое отображает непрерывное входное пространство X в дискретное выходное пространство A . Вектор $x \in X$, который случайно выбирается из входного пространства, имеет размерность n и обозначается $x = [x_1, x_2, \dots, x_n]^T$. Вектор синаптических весов нейрона i , входящего в карту Кохонена, имеет ту же размерность и обозначается $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$, $i = 1, 2, \dots, l$, где l – общее количество нейронов сети.

Сущность алгоритма самоорганизации, предложенного Кохоненом, состоит в отыскании того нейрона, который лучше всего соответствует входному вектору x и перемещении вектора синаптических весов этого нейрона и нейронов, которые лежат в его топологической окрестности, в сторону вектора x . В ходе конкурентного процесса нейроны решетки избирательно настраиваются на различные входные векторы и, в результате, группы входных векторов, образующие кластер, представляются единственным вектором весов нейрона-“победителя”. Таким образом, модель нейронной сети Кохонена реализует топологическое отображение, которое оптимально размещает фиксированное количество векторов синаптических весов нейронов (т.е. кодовых слов, составляющих словарь) во входное пространство более высокой размерности.

Настроенная карта Кохонена, представленная множеством векторов синаптических весов $\{w_i\}$, $i = 1, 2, \dots, l$, реализует аппроксимацию входного пространства X в выходном пространстве A . Тем самым она осуществляет сжатие информации путем хранения большого объема векторов $x \in X$ с помощью нахождения небольшого набора прототипов $\{w_i\}$.

В процессе моделирования кодирование информации осуществлялось путем замены 16-разрядной битовой цепочки, состоящей из 0 и 1, на номер нейрона-“победителя”, вектор весов которого после обучения сети оказался наиболее близок к значениям входной цепочки. Декодирование выполнялось путем округления значений весов нейрона-“победителя” до 0 или 1.

Целью моделирования является проверка возможности применения сети Кохонена для компрессии информации и ее восстановления без потерь, а также исследование зависимости количества ошибочно восстановленных бит от размера карты. Для обучения использовались 3 массива бинарных данных по 2000 примеров в каждом с различными вероятностями появления 1 (50%,

70% и 90%). Моделирование выполнено для карт Кохонена размерностью 2x2, 2x3, 3x3, 3x4, нейроны которых расположены в узлах двумерной прямоугольной решетки. Результаты приведены на рис. 1. Очевидно, что с помощью карт Кохонена не удается добиться сжатия и декодирования данных без потерь. Минимальное количество ошибочных бит (1.3 бит) получено при использовании карты наибольшего размера для данных, содержащих 90% единиц. Полученные результаты также позволяют сделать вывод, что увеличение количества нейронов в три раза не приводит к существенному улучшению качества компрессии и восстановления данных.

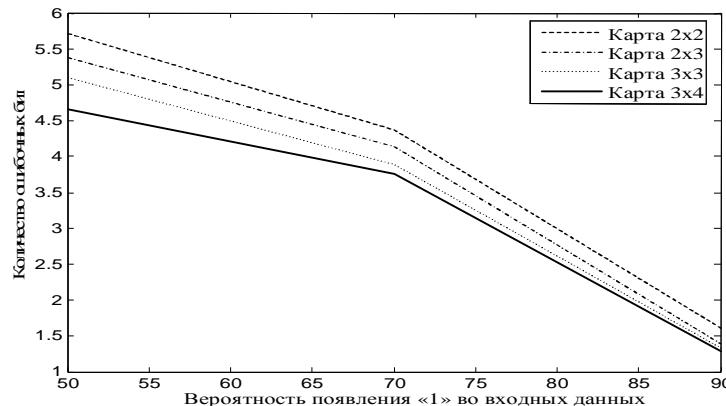


Рис.1. Зависимость величины ошибки декодирования от размера карты Кохонена

Так как для дискретной информации кодирование с потерями недопустимо, для дальнейшего исследования выбрана трехслойная нейронная сеть прямой передачи сигналов. Входной слой из 16 нейронов и скрытый слой меньшего размера N (количество нейронов определяется в процессе экспериментов) осуществляют компрессию данных. Закодированная версия входного вектора x является выходным сигналом скрытого слоя. Для того, чтобы восстановить исходный вектор, закодированный сигнал передается выходному слою из 16 нейронов, который выполняет роль декодера. Чем меньше размер скрытого слоя N по сравнению с n , тем более эффективна сеть в качестве средства компрессии данных.

Обозначим матрицу весов скрытого слоя сети $W^{(1)}$, а матрицу весов выходного слоя $W^{(2)}$. Тогда с учетом одностороннего распространения сигналов вектор выхода скрытого слоя равен (сжатая информация):

$$h = W^{(1)}x,$$

а вектор выхода сети равен (информация, восстановленная в результате декомпрессии):

$$\hat{x} = W^{(2)}h = W^{(2)}W^{(1)}x.$$

Обучение сети, состоящее в оптимальном подборе весов, образующих матрицы $W^{(1)}$ и $W^{(2)}$, направлено на то, чтобы разность между $x_i^{(q)}$ и $\hat{x}_i^{(q)}$ для всех n составляющих вектора x_i при $q = 1, 2, \dots, Q$ (где Q обозначено количество векторов) была минимальной. Вследствие прямоугольности обеих матриц $W^{(1)}$ и $W^{(2)}$ аналитического решения этой задачи не существует.

Для обучения сети использовались те же массивы бинарных данных, что и для карты Кохонена. Обучение выполнено с помощью порогового алгоритма обратного распространения [4], критерием останова является достижение на выходе сети величины средней суммарной квадратичной ошибки 0,1.

Результаты экспериментов приведены на рис. 2. Очевидно, что для данных с вероятностью появления 1, равной 90%, сжатие без потерь (количество ошибок менее 1 бит) достигнуто уже при 3 нейронах в скрытом слое. Таким образом, достигнуто значение коэффициента компрессии, вычисленного как отношение количества нейронов во входном слое к количеству нейронов скрытого слоя, равное 5,33. Кроме того, сделан вывод, что наименьшая ошибка декодирования достигается, когда в первом слое сети в качестве активационной функции нейронов используется линейная функция, а в скрытом и выходном слое – сигмоидальная функция.

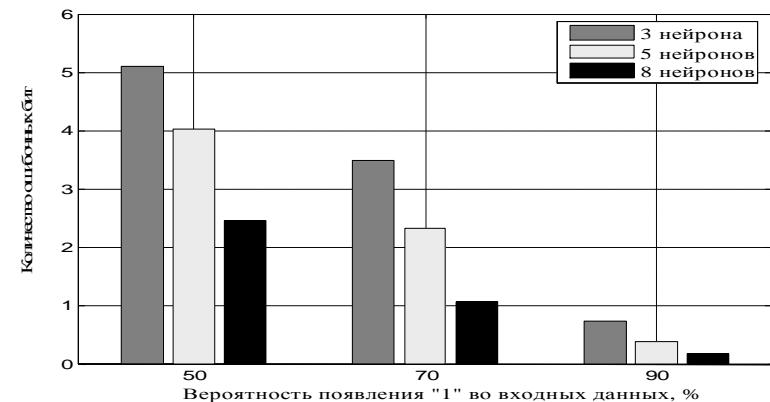


Рис.2. Зависимость ошибки декодирования от количества нейронов в скрытом слое

Список литературы: 1. Ватолин Д.К., Ратушняк А.А. Методы сжатия данных. Устройство архиваторов, сжатие изображений.– М.: ДИАЛОГ-МИФИ, 2002.– 384 с. 2. Хаффмен Д.А. Метод построения кодов с минимальной избыточностью: Пер. с англ. // Кибернетический сборник.– М.: ИЛ, 1961.– Вып. 3.– С. 79–87. 3. Ziv J., Lempel A. Compression of Individual Sequences via Variable-Rate Coding // IEEE Trans. Inform. Theory.– 1978.– Vol. 24, N5.– P. 530–536. 4. Хайкин С. Нейронные сети: полный курс.: Пер. с англ.– М.: Издательский дом "Вильямс", 2006.– 1104 с.

Поступила в редакцию 09.06.08