

Прокопович Г.А., Сычѳв В.А.

Объединѳнный институт проблем информатики НАН Беларуси

Лаборатория моделирования самоорганизующихся систем

{rprakovich, vsychyov}@robotics.by

ПРЕДОБРАБОТКА СИГНАЛОВ ДЛЯ ИНВАРИАНТНОГО РАСПОЗНАВАНИЯ ИЗОБРАЖЕНИЙ

Введение

К настоящему времени проведено множество исследований [1], посвящённых применению искусственных нейронных сетей (ИНС) в обработке сложных сигналов различной природы. Однако можно отметить, что в данных работах не уделялось должного внимания проблеме подготовки входных данных для нейросети, предполагая, что данные для обучения и корректного функционирования уже имеются и представлены в виде, доступном для конкретной ИНС. Тем не менее, как показала практика [2], предобработка данных может стать одним из наиболее трудоёмких элементов нейросетевого анализа. Причём иногда знание основных принципов и приемов предобработки исходных данных является более важным, чем знание собственно нейросетевых алгоритмов.

Для решения конкретной задачи недостаточно знать архитектуру и алгоритм работы ИНС. Даже при наличии действующего нейроэмулятора сам процесс решения прикладной задачи, в том числе и подготовка входных данных, целиком ложится на плечи пользователя.

Рассмотрим необходимые этапы нейросетевого анализа:

1) *кодирование входов-выходов*: программно реализованные ИНС могут работать только с числами, поэтому любой сигнал должен подвергаться цифровому преобразованию, т.е. получить количественную оценку;

2) *нормирование данных*: конечный результат работы ИНС не должен зависеть от выбора единиц измерения, для чего входные данные должны быть нормированными и безразмерными;

3) *предобработка данных* заключается в удалении (фильтрации) очевидных регулярностей из входных данных, что облегчает ИНС выявлять нетривиальные закономерности;

4) *обучение нескольких нейросетей* осуществляется для определения оптимальной архитектуры ИНС по производительности, так как конечный результат обучения зависит не только от её размеров (количества нейронов и самих слоёв), но и от её начальной конфигурации;

5) *отбор оптимальных сетей*: процесс выбора таких структур ИНС, которые дадут наименьшую ошибку предсказания на известных данных;

б) *оценка значимости предсказаний*: ошибки производимых ИНС-вычислений не должны превышать допустимых задачей ограничений, чтобы не потерять смысл (ценность) предсказанных значений.

Можно заметить, что этапы процесса предобработки входных данных, указанные в пп. 1-3, не связаны непосредственно с ИНС, но, тем не менее, они являются одним из ключевых элементов данной информационной технологии. Результат обучения и функционирования ИНС может решающим образом зависеть от того, в каком виде была представлена информация для её обучения.

1. Кодирование входов-выходов

По типу входной информации ИНС подразделяются на аналоговые и двоичные. Если первые используют информацию в форме действительных чисел, то вторые оперируют с информацией, представленной в двоичном виде. Аналоговые ИНС, в частности многослойные персептроны, часто используются для распознавания образов и обработки цветных либо полутоновых изображений. Однако современная вычислительная техника основана на цифровой элементной базе, поэтому большинство разработчиков, с целью дальнейшей аппаратной реализации проектируемых ИНС, стремится входные и выходные данные представлять в двоичных кодах. К тому же существуют целые классы ИНС, которые работают только с бинарными либо биполярными кодами. В частности, к ним относятся ИНС типа сетей Хемминга и Хопфилда.

Следующий немаловажный вопрос представления входов-выходов для ИНС заключается в том, что практически все нейросети способны обрабатывать только одномерные массивы, т.е. данные, представленные в виде векторов. Исключением является лишь ограниченное число нейросетей, например, когнитрон или свёрточные ИНС, которые способны обрабатывать двумерные образы как единое целое [1, 2]. Для обработки многомерных данных с помощью остальных архитектур первые требуется преобразовать в одномерные массивы данных. Например, для записи монохромного изображения в ассоциативную сеть Хопфилда его необходимо представить в виде одномерного массива, так как весовую матрицу можно получить лишь с помощью внешнего (матричного) произведения векторов из обучаемой выборки [3].

Для того чтобы монохромное графическое изображение размером $(m \times n)$ привести к необходимому для функционирования ИНС виду, требуется исходный двумерный массив преобразовать в вектор длиной $(m \cdot n)$ при помощи одного из приведённых способов (рисунок 1а и б).




Рисунок 1 – Пример развёртки двумерных массивов в одномерные

На рисунке 1в показан пример, как с помощью двумерного массива, состоящего из 0 и 1, возможно закодировать монохромное изображение буквы «А». На рисунке 1г показан пример развёртки изображённого на рис. 1в двумерного массива указанным в б способом. Таким образом, полученный вектор отождествляет собой изображение буквы «А», и теперь он может являться входной информацией для ИНС.

2. Нормирование

В связи с тем, что чаще всего ИНС являются промежуточным звеном в АСУ либо системах принятия решений, то входные и выходные данные ИНС могут быть совершенно разнородными величинами. Поэтому становится очевидным, что результаты нейросетевого моделирования не должны зависеть от единиц измерения этих величин, т.е. чтобы сеть трактовала их значения единообразно, все входные и выходные величины должны быть приведены к единому масштабу.

Как правило, нормирование данных часто применяется для того, чтобы уравнивать отрицательный вклад, вносимый в модель исследуемого объекта, от различных переменных, а также чтобы обрабатывать совместно разные блоки данных. В результате, нормирование влияет на точность прогнозирования ИНС. Однако неправильный подход к нормированию данных может перечеркнуть все другие меры, принимаемые для увеличения точности работы ИНС.

Нормирование данных необходимо для того, чтобы каждое значение, подаваемое на вход ИНС, находилось в интервале $[0, 1]$. Расчеты показали, что погрешность прогноза существенно зависит от способа нормирования входных данных. Этому вопросу уделяется внимание во многих работах, например [1, 4], посвященных как прогнозированию нагрузки, так и использованию ИНС в других задачах, где данные по модулю превышают единицу.

Простейшее решение вопроса – это нормирование данных по формуле

$$P_i^H = \frac{P_i}{P_{\max}}, \quad (1)$$

где P_i – значение входного сигнала ИНС, подаваемое на i -й входной нейрон; P_{\max} – максимальное значение входного сигнала в рассматриваемой выборке; P_i^H – нормированное значение. В этом случае для нашей задачи все данные после нормирования находятся, как правило, в интервале $[P_{\min} / P_{\max}; 1]$, где P_{\min} – минимальное значение сигнала в каждой выборке. Однако величина может сильно P_{\min} / P_{\max} ограничивать диапазон снизу.

Следующая формула нормирования лишена этого недостатка и позволяет растянуть данные, подаваемые на вход ИНС, от 0 до 1:

$$P_i^H = \frac{P_i - P_{\min}}{P_{\max} - P_{\min}}. \quad (2)$$

3. Предобработка

Процесс предобработки входных данных для ИНС предполагает использование знаний специалиста из конкретной предметной области для того, чтобы от исходной информации перейти к некоторому минимальному набору признаков. Это позволит принципиально упростить реализацию и уменьшить сложность (и время) обучения ИНС, что, следовательно, приведёт к увеличению производительности и надежности получаемых решений. Основная задача предобработки входных данных для обучения ИНС заключается в следующем:

- 1) фильтрация искажений;
- 2) снижение размерности входных данных;
- 3) инвариантность к смещению.

Для решения перечисленных задач обычно используют разработанные и хорошо зарекомендовавшие себя методы из теории обработки сигналов в цифровой и радиотехнике. Однако на практике чаще требуется обрабатывать не только одномерные, но и многомерные сигналы, в частности, такие как графические изображения.

Одним из широко используемых способов предварительной обработки измерительных сигналов является метод преобразования Фурье, который весьма хорошо себя зарекомендовал даже для фильтрации и сжатия цифровых изображений [5]. Например, в [1] предложен метод описания входных образов для перцептронной ИНС с помощью преобразования Фурье, благодаря чему она способна распознавать и классифицировать двумерные образы в независимости от их возможного перемещения, ротации и масштабирования. Однако описанный метод предварительной подготовки использует не всю информацию об образе, а только множество координат (x, y) его контура. Координатное описание контура представляется комплексным числом

$$z(i) = x(i) + j \cdot y(i). \quad (3)$$

Для некоторых классов объектов данный подход значительно упрощает их представление, не уменьшая их информативности (рис. 2а). Однако существуют классы объектов, которые нельзя качественно представить в виде единого замкнутого контура (рис. 2б). В этом случае для распознавания сложных объектов, по-видимому, потребуется использовать лингвистический подход, который будет учитывать иерархию составляющих элементов (рис. 2в). А это приведёт к значительному усложнению архитектуры и увеличению вычислительных затрат самого нейросетевого классификатора.

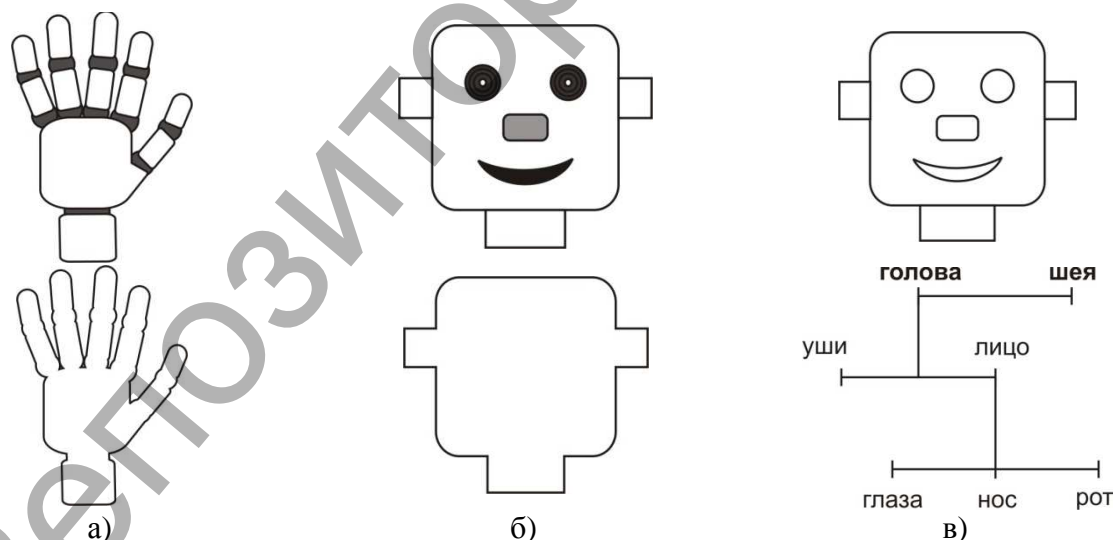


Рисунок 2

Однако для решения некоторых задач требуются более простые способы для инвариантного распознавания изображений.

4. Декорреляция бинарных изображений

Поскольку изображения содержат большой объём информации, важную роль играют вопросы её представления. Чёрно-белые (бинарные) изображения проще получать, хранить и обрабатывать, чем изображения, в которых имеется много уровней яркости. Несмотря на то, что в бинарных изображениях кодиру-

ется информация лишь о силуэте объекта, методы обработки бинарных изображений широко используются при распознавании графических образов, а также в системах технического зрения для пространственного ориентирования роботов. Из проекций бинарных изображений можно извлечь такие простые геометрические характеристики объектов, как площадь, ориентация и положение.

Тем не менее, в явном виде бинарные изображения очень сложно обрабатываются с помощью ИНС. Это связано с тем, что при решении реальных задачах корреляция эталонных векторов существенно снижает надежность идентификации ИНС. Так, например, среди букв латинского алфавита, изображённых на рис. 3а, присутствует корреляция от 36.23 до 85.64% (см. табл. 1). На рис. 3б изображены области пересечения графических образов, причём, чем больше пересечений, тем светлее каждая область.

Для решения описанной проблемы предлагается оригинальный метод декорреляции бинарных векторов, частным случаем которого могут быть чёрно-белые изображения. Данный способ заключается в отображении исходного бинарного вектора $\bar{Y} \in B^N$ в целочисленный вектор $\bar{X} \in Z^n$ меньшей размерности.




Рисунок 3 – Пример пересечения двумерных графических образов

Алгоритм отображения, при котором происходит декорреляция бинарных векторов, заключается в следующем. Пусть имеется некий N -мерный бинарный вектор $\bar{Y} = [y_1, y_2, \dots, y_N]$. Далее разделим его на n равных частей, содержащих $k+1$ элементов каждый, т.е. $N = n(k+1)$ или $\text{mod}(N, n) = 0$. Таким образом, исходный бинарный вектор $Y \in B^N$ отображается в набор q -мерных векторов, т.е. образ $\bar{X}' = [x_1, x_2, \dots, x_n]$. Тогда каждую из n -х частей исходного бинарного вектора можно рассматривать как некое целое число $\pm q$, записанное в двоичном коде, причём, первый элемент определяет знак: 0 – «минус», 1 – «плюс», а остальные k элементов – величину q . Например, вектор $Y = [101011110011]$ можно разбить на три фрагмента по четыре элемента в каждом $x_1 = [1010]$, $x_2 = [1111]$ и $x_3 = [0011]$. Первому фрагменту соответствует число 2, второму – 7, а третьему – 3, т.е. при $k=3$ отображение примет вид $\bar{Y} \rightarrow \bar{X} = [2, 7, -3]$, при $k=2$: $\bar{Y} \rightarrow \bar{X} = [1, -3, 2, -3]$.

Одним из главных достоинств предложенного метода является то, что он подавляет имеющиеся корреляции. Рассмотрим два бинарных вектора $\bar{Y}_1 = [01000010]$ и $\bar{Y}_2 = [01011010]$, у которых совпадают 75% значений элемен-

тов. Если воспользоваться процедурой отображения с параметром $k=1$ (отображение в пространство $q=2$), при котором каждый вектор следует разбить на четыре фрагмента, получим два целочисленных вектора $\overline{X}_1 = [-1, 0, 0, 0]$ и $\overline{X}_2 = [-1, -1, 0, 0]$. В итоге указанные вектора коррелируют уже на 50%. Если использовать указанную процедуру с параметром $k=3$, то получим два совершенно не коррелирующих отображения $\overline{X}_1 = [-4, -2]$ и $\overline{X}_2 = [-5, 2]$.

Таблица 1 – Корреляция изображений букв латинского алфавита

Хемминг %	А	В	С	Д	Е	Ф	Г	Н	К
А		49.61	46.09	36.23	42.19	44.43	43.95	37.01	51.37
В	516		57.03	78.61	75.78	67.87	65.82	61.43	55.47
С	552	440		58.50	66.99	58.11	67.77	45.02	49.41
Д	653	219	425		69.24	63.28	72.36	62.30	51.46
Е	592	248	338	315		85.64	57.03	65.92	65.63
Ф	569	329	429	376	147		52.64	70.51	66.89
Г	574	350	330	283	440	485		44.82	44.92
Н	645	395	563	386	349	302	565		56.93
К	498	456	518	497	352	339	564	441	

Так же немаловажным свойством описанного отображения является то, что оно взаимно однозначно, т.е. по известному \overline{X} всегда можно совершенно точно восстановить его бинарный прообраз \overline{Y} .

Далее рассмотрим, как предложенный метод способен декоррелировать монохромные изображения, приведённые на рис. 3. Для начала с помощью одного из указанных на рис. 1а и 1б способов следует разложить двумерные графические образы размером 32×32 пикселей в вектора. Затем полученные бинарные вектора длиной $N=1024$ элементов следует отобразить в целочисленные вектора со следующими параметрами: $k=8$ и $n=N/k=1024/8=128$ пикселей. Для наглядности было принято, что $k=q$, т.е. все элементы векторов являются положительными числами в диапазоне от 0 до 255, так как $q_{\max} = 2^8 - 1 = 255$. Результат проведённой декорреляции приведён в таблице 2, а на рис. 4 отображены значения элементов декоррелированных векторов трёх первых букв латинского алфавита. Для наглядности на оси абсцисс обозначена только половина точек.

Таблица 2 – Результат декорреляции изображений букв латинского алфавита

Расстояние Эйлера	А	В	С	Д	Е	Ф	Г	Н	К
А		1.0586	0.9696	1.1308	1.2610	1.6088	1.6471	1.0458	1.5328
В	2.9501		0.8136	0.5724	1.0905	1.3165	0.9682	1.0542	0.7220
С	2.7681	2.0128		0.7557	1.1655	0.8976	1.0146	1.0742	0.9898
Д	3.6845	4.1347	4.0645		1.1469	1.3253	0.8792	1.1493	0.7892
Е	5.5235	6.4267	5.5765	5.2376		1.5305	1.0752	0.4924	1.0487
Ф	6.5472	7.8325	6.7742	6.1168	2.5134		1.2379	1.4803	1.2208
Г	2.5918	2.9243	2.4515	4.3204	5.5242	6.6384		1.1382	0.6568
Н	3.0083	3.3943	3.4643	2.9428	5.5020	6.5546	3.7440		1.1394
К	3.8653	5.1055	4.6321	3.6540	5.3526	5.6539	4.5813	2.4406	

Далее необходимо рассмотреть вопрос о том, в какой степени предложенный метод декорреляции будет влиять на схожие образы, относящиеся к одному классу. Главная задача предобработки данных заключается в снижении существующей избыточности во входных данных. Однако необходимо следить за тем, чтобы это не снизило информативность примеров и, тем самым, качество нейропредсказаний.




Рисунок 4

На рис. 5 представлены декоррелированные вектора, содержащие информацию о монохромных изображениях латинской буквы "А", выполненной с помощью различных шрифтов. На приведённом графике визуально видна сохранившаяся корреляция между близкими образами. Это происходит благодаря удачно выбранному способу отображения, который при переводе векторов из бинарных в целочисленные увеличивает их евклидово расстояние по экспоненциальному закону.




Рисунок 5

На рис. 6 изображён график роста евклидова расстояния по мере увеличения параметра k от 1 до 16. На графике красными и синими линиями отображены евклидовы меры между похожими образами (буква «А» с различным написанием), а зелёными – между буквой «А» и «В». Таким образом, с ростом пространства k растёт и расстояние между образами, причём, чем больше разница между исходными образами была изначально, тем больше будет расстояние между соответствующими отображениями. Это заметно на представленных графиках: на начальном этапе евклидово расстояние между различными образами («А» и «В») было меньше, чем между образами из одного класса. Однако с ростом k расстояние между последними значительно сократилось по отношению к образу «В».

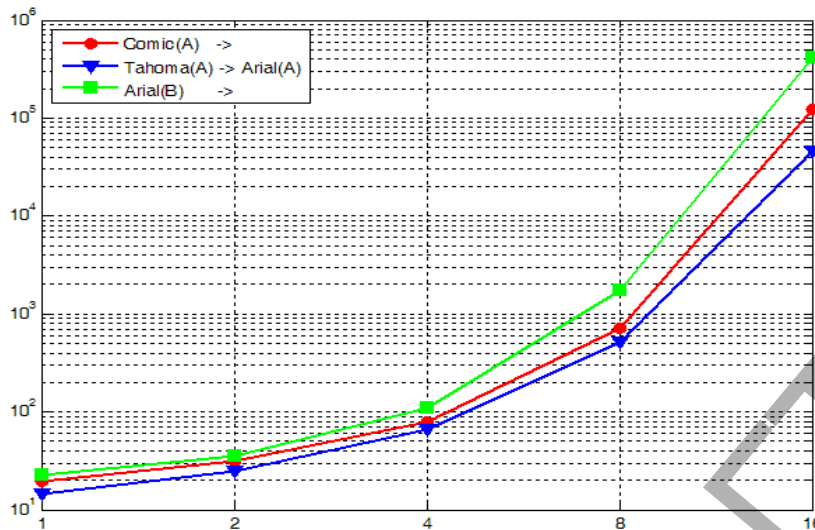


Рисунок 6 – Процесс экспоненциального роста евклидовой меры с ростом параметра k

Чтобы выявить способность сохранять близость между подобными образами в предложенном методе декорреляции, найдём среднюю ошибку распознавания. Допустим, что имеется два близких бинарных образа \bar{Y}_1 и \bar{Y}_2 , отличающихся только на один бит. В качестве примера, рассмотрим случай, когда $N = 8$. Если $\bar{Y}_1 = [0\ 0\ 0\ 0\ 0\ 0\ 0\ 0]$, то по нашему предположению \bar{Y}_2 может принять один из 8 возможных вариантов. Однако так как бинарный код является позиционным, то в зависимости от расположения каждой единицы в бинарном слове меняется и значение всего слова. Поэтому рассмотрим все случаи:

$$\begin{aligned} \bar{Y}_2^1 = [0\ 0\ 0\ 0\ 0\ 0\ 0\ 1] &\rightarrow X_2^1 = 1; & \bar{Y}_2^5 = [0\ 0\ 0\ 1\ 0\ 0\ 0\ 0] &\rightarrow X_2^5 = 16; \\ \bar{Y}_2^2 = [0\ 0\ 0\ 0\ 0\ 0\ 1\ 0] &\rightarrow X_2^2 = 2; & \bar{Y}_2^6 = [0\ 0\ 1\ 0\ 0\ 0\ 0\ 0] &\rightarrow X_2^6 = 32; \\ \bar{Y}_2^3 = [0\ 0\ 0\ 0\ 0\ 1\ 0\ 0] &\rightarrow X_2^3 = 4; & \bar{Y}_2^7 = [0\ 1\ 0\ 0\ 0\ 0\ 0\ 0] &\rightarrow X_2^7 = 64; \\ \bar{Y}_2^4 = [0\ 0\ 0\ 0\ 1\ 0\ 0\ 0] &\rightarrow X_2^4 = 8; & \bar{Y}_2^8 = [1\ 0\ 0\ 0\ 0\ 0\ 0\ 0] &\rightarrow X_2^8 = 128. \end{aligned}$$

Тогда среднее арифметическое значение будет равно

$$\langle X_2 \rangle = \frac{1}{N} \sum_{i=1}^N X_2^i = 31.875,$$

а учитывая, что $N_2^{\max} = 128$, средняя относительная погрешность предложенного метода декорреляции будет равна

$$\langle \varepsilon \rangle = \frac{\langle X_2 \rangle}{X_2^{\max}} \cdot 100\% = 24.9\%.$$

Несмотря на то, что ошибка на конкретном участке образа оказывается достаточно большой, на практике образы состоят из значительного числа составных элементов, большая часть из которых для близких образов одинакова. В результате, близкие образы и после декорреляции остаются в одном классе.

5. Инвариантность к искажениям

Несмотря на то, что предложенный метод отображения сохраняет корреляцию между подобными образами, он не способен противостоять таким искаже-

ниям, как масштабирование, ротация и смещение. Так, при повороте графических изображений корреляция между образами практически полностью пропадает (рис. 7). Однако, как было показано ранее, после проведения декорреляции бинарных образов они отображаются в новом целочисленном пространстве и могут рассматриваться как последовательности значений неких непрерывных функций. Другими словами, предложенное отображение можно рассматривать, в некотором роде, как цифро-аналоговое преобразование. Поэтому к полученным данным может быть применено большинство из известных методов обработки сигналов.




Рисунок 7 – Пример отрицательного влияния искажений типа «поворот»

Например, в работе [6] приведено описание многослойной перцептронной сети, которая производит классификацию сильно искажённых образов. Ключевым элементом описанного классификатора является препроцессор, выходные сигналы которого представляют собой последовательность компонентов дескрипторов Фурье. Однако единственным препятствием для использования указанного метода является различие способов представления начальных данных: поставленные в начале статьи требования не позволяют представлять графические образы в виде их контуров, так как за этим последует потеря семантической информации.

Решением данного противоречия может служить то, что предложенный в п. 4. метод декорреляции производит отображение всего образа, не разделяя его на какие-либо функциональные части. Поэтому с целью создания нового классификатора, устойчивого к искажениям во входных образах, было предложено в качестве препроцессора использовать предложенный метод декорреляции, а полученные сигналы подвергнуть дальнейшему кодированию с помощью дискретного преобразования Фурье. С этой целью исходный целочисленный вектор \bar{X}_n следует разбить на две равные части $a = [x_1, x_2, \dots, x_{n/2}]$ и $b = [x_{n/2+1}, x_{n/2+2}, \dots, x_n]$, где $\text{mod}(n, 2) = 0$, и представить его в виде следующего комплексного числа:

$$z(i) = a(i) + j \cdot b(i), \quad (4)$$

где i – номер очередной пары измерительных данных, описывающих образ. Далее воспользуемся дискретным преобразованием Фурье:

$$F_i = \sum_{k=0}^{m-1} z(i) \exp\left(-j \frac{2\pi}{m} ik\right), \quad (5)$$

где $m = n / 2$ – количество точек описания структуры.

В результате кодирования будет получен вектор $\vec{F} = [F_0, F_1, F_2, \dots, F_{m-1}]$, элементы которого представляют отдельные дескрипторы Фурье-преобразования. Данный вектор будет способен определять уникальность структуры первоначального образа, но в совершенно другом пространстве параметров, в котором путём простых преобразований можно добиться инвариантности к масштабу, ротации и смещению исходных образов. Полученное свойство положительным образом скажется на процессе распознавания образов.

Таблица 3 – Результат декорреляции изображений букв латинского алфавита

Расстояние Эйлера	А	В	С	Д	Е	Ф	Г	Н	К
А		0.8042	0.9312	1.1180	1.4706	1.3469	1.1739	1.0058	0.9428
В	3.7452		0.8288	0.8907	1.0912	1.2994	1.0274	0.5783	0.8841
С	3.7501	3.7983		1.0038	1.3236	0.9328	0.8786	0.9186	0.6975
Д	6.4267	6.1613	6.4399		1.1671	1.3213	1.2368	1.0907	1.0172
Е	5.5215	4.3699	4.6121	3.6919		1.5274	1.2318	0.9642	1.3660
Ф	4.0846	3.9866	3.4590	4.9804	3.5631		0.9991	1.3410	1.0764
Г	3.3943	4.4287	3.4020	5.5020	4.3784	3.0222		1.0530	0.9501
Н	3.2106	3.9793	3.2601	5.4340	4.0729	2.5655	1.5448		0.8988
К	3.8060	3.3751	3.2957	6.6215	4.9729	3.4618	4.0730	3.5903	

Заключение

В работе рассматривается проблема предобработки входных данных для искусственных нейронных сетей, необходимой для эффективного распознавания данных с помощью ИНС. Предлагается метод декорреляции бинарных изображений, позволяющий понизить корреляцию между образами различных классов и уменьшить объём информации, подаваемой на вход ИНС при распознавании данных образов без потери информативности.

Достоинством данного метода является сохранение корреляции между подобными образами и её снижение между образами разных классов. К недостаткам можно отнести недостаточно высокую устойчивость к таким искажениям, как масштабирование, ротация и смещение входных образов.

Полученные в работе результаты могут быть использованы в системах предобработки классификаторов и систем принятия решений.

Литература

1. Осовский, С. Нейронные сети для обработки информации / С. Осовский. – М.: Финансы и статистика, 2004. – 342 с.
2. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. – 2-е изд. – М.: Издательский дом «Вильямс», 2006. – 1104 с.
3. Головкин, В.А. Нейронные сети: обучение, организация и применение. Кн. 4: учеб. пособие для вузов / Общ. ред. Л.И. Галушкина. – М.: ИПРЖР, 2001. – 256 с.
4. Барский, А.Б. Нейронные сети: распознавание, управление, принятие решений / А.Б. Барский. – М.: Финансы и статистика, 2004. – 176 с.
5. Крот, А.М. Быстрые алгоритмы и программы цифровой спектральной обработки сигналов и изображений / А.М. Крот, Е.Б. Минервина. – Минск: Навука і тэхніка, 1995. – 407 с.
6. Dinh Nghia Do, Osowski, S. Shape recognition using FFT preprocessing and neural network // Compel, 1998. – Vol. 17, No.5/6. – P. 658-656.