

МОДЕЛИРОВАНИЕ НЕЙРОСЕТЕВОГО ВЫДЕЛЕНИЯ ЭТАЛОННЫХ СИГНАЛОВ ВРЕМЕНИ ИЗ ВЕЙВЛЕТ-СПЕКТРА ИЗОБРАЖЕНИЙ, ТРАНСЛИРУЕМЫХ ПО КАНАЛАМ ЦИФРОВОГО ТЕЛЕВИДЕНИЯ

М.Л. Троцко

(Научный метрологический центр (военных эталонов), Харьков)

В статье представлены результаты моделирования нейросетевого выделения эталонных сигналов времени из вейвлет-спектра изображений, транслируемых по каналам цифрового телевидения.

моделирование нейросетевого выделения, вейвлет-спектр изображений

Постановка проблемы. В то время как концепция развития информационного пространства Украины устанавливает окончательный переход от аналогового телевизионного вещания к цифровому до 2012-2015 г.г. [1, 2], проблема передачи эталонных сигналов времени (ЭСВ) по каналам цифрового телевидения не решена и предполагает применение новых подходов к преобразованию и выделению кодированной информации, передаваемой в компрессированном формате, подходов, основанных на применении нейросетевых и вейвлет-технологий [3 – 8].

Анализ литературы. В работе [9] представлена постановка задачи исследования многослойных нейронных сетей (МНС) для выделения спектрального образа ЭСВ из вейвлет-спектра изображений, транслируемых по каналам цифрового телевидения.

Цель статьи – провести моделирование нейросетевого выделения спектрального образа ЭСВ из вейвлет-спектров изображений, транслируемых по каналам цифрового телевидения.

Основной материал исследования. Выделение эталонного сигнала времени, содержащегося в составе изображения, представим как процесс выделения неперекрывающегося участка вейвлет-спектра изображения, в пределах которых скачкообразно изменяется яркость изображения с присвоением ему соответствующего идентификатора.

Моделирование проведено при помощи системы компьютерной математики MATLAB 6.5 средствами приложения Neural Network Toolbox [10, 11]. Оно содержало два этапа, соответствующих построению и обу-

чению классификации предъявляемых спектральных образов двух МНС различной архитектуры.

Случайным образом из массива тестовых фрагментов выделяются векторы-фрагменты фонового изображения Fg^{image} , которым присваивается идентификатор «1». Выделенный фрагмент спектра, соответствующий ЭСВ – $Fg^{timestamp}$, включается в тестовую выборку с идентификатором «2».

Тестовая выборка состоит из девяти фрагментов матрицы аппроксимирующих вейвлет-коэффициентов, представляющих собой вектор, содержащий 10 элементов, соответствующих обычному изображению, и одного фрагмента, содержащего вейвлет-коэффициенты ЭСВ. На рис. 1 представлены соответственно тестовые векторы-фрагменты массива аппроксимирующих вейвлет-коэффициентов изображения и рамкой в нижнем правом углу выделен фрагмент, содержащий вейвлет-коэффициенты ЭСВ.




Рис. 1. Тестовые векторы-фрагменты массива аппроксимирующих вейвлет-коэффициентов изображения

Первый этап моделирования. Создается двухслойная МНС, имеющая сигмоидные функции активации в скрытом и выходном слоях. Количество нейронов скрытого слоя равно количеству отсчетов во фрагменте, предъявляемом для классификации, $n_{k-1}=10$. Выходной слой составляют два нейрона с сигмоидной функцией активации (по количеству разделяемых классов). Обучающая выборка формируется данной МНС в виде последовательности фрагментов вейвлет-спектра фонового изображения и ЭСВ. Обучение МНС проводится по алгоритму обратного распространения ошибки [12]. Чередувание фрагментов, принадлежащих разным классам, предпринимается для закрепления навыков распознавания.

На рис. 2 – 4 пунктирной линией обозначены целевые векторы, представляющие собой чередование идентификаторов каждого из клас-

сов. Значению ординаты 1 соответствует класс 1 – идентификатор «1». Аналогично значению ординаты 2 соответствует класс 2 – идентификатор «2». По оси абсцисс отложены отсчеты чередующихся фрагментов, представляемых на вход МНС.




Рис. 2. Нейросетевая идентификация спектральных образов тестового изображения по выборке из чередующихся тестовых и эталонных образов




Рис. 3. Нейросетевая идентификация спектральных образов тестового изображения по выборке из чередующихся тестовых и эталонных образов (2 тестовых, 1 эталонный)

Непрерывной линией на рис. 2 – 4 представлены результаты распознавания МНС спектральных образов фрагментов тестовой выборки.

Качество обучения проверялось при симуляции функционирования МНС, т.е. при достижении установленного уровня среднего квадратического значения (СКЗ) погрешности обучения на вход МНС подавалась новая тестовая выборка

$$\sigma_i = \sqrt{\frac{1}{N} \sum_{i=0}^{N-1} (y_i^{\text{МНСГС}} - y_i^*)^2} = 0,001,$$

где N – количество нейронов выходного слоя; $y_i^{\text{МНСГС}}$ – выходной сигнал МНС ГС (идентификатор класса, к которому принадлежит фраг-




Рис. 4. Нейросетевая идентификация спектральных образов тестового изображения по выборке из чередующихся тестовых и эталонных образов (неупорядоченное чередование)

мент); y_i^* – эталонное значение выходного сигнала МНС ГС. Результаты нейросетевого распознавания спектральных образов тестового изображения, полученные после обучения МНС на выборке из чередующихся тестовых и эталонных образов, при различном порядке следования фрагментов разных классов являются неудовлетворительными, так как представляемые на вход МНС тестовые фрагменты идентифицировались со СКЗ погрешности σ_i , превышающей в несколько раз заданное СКЗ погрешности обучения $\sigma_i = 0,001$.

Чередование фрагментов вейвлет-спектра ЭСВ и фонового изображения показало наличие сбоя идентификации при переходе от фрагмента к фрагменту. Данный сбой характерен для любого порядка чередования тестовых фрагментов и проявляется на участках, соответствующих примерно половине длины фрагмента, т.е. МНС продолжает идентифицировать вновь поступивший на ее вход фрагмент как предыдущий, присваивая ему ложный идентификатор. Данный факт, вероятно, обусловлен сложностью формы разделяющей поверхности, для формирования которой не достаточно возможностей МНС с сигмоидными функциями активации.

Второй этап моделирования. Создается двухслойная МНС гибридной структуры (МНС ГС), первый слой которой состоит из радиально-базисных нейронов, а второй из нейронов с «соревновательной (competitive)» функцией активации. Количество РБФ-нейронов в скрытом слое и нейронов выходного слоя Кохонена определяется в процессе обучения.

Результаты моделирования нейросетевой классификации спектральных образов тестового изображения, полученные после обучения МНС ГС на выборке из тестовых и эталонных образов приведены на рис. 5 в виде идентификаторов классов, присвоенных МНС ГС фрагментам тестовой выборки.

Каждому фрагменту, состоящему из 10 вейвлет-коэффициентов, значение которых представлено цветом в градации от «черного» к «белому», были поставлены в соответствие идентификаторы «1» для фрагментов с №№ 1, 3 – 10, соответствующих фрагментам вейвлет-спектра фонового изображения, и идентификатор «2» – для фрагмента тестовой выборки с № 2, представляющего вейвлет-спектр ЭСВ (на рис. 5 приведен в рамке).

На рис. 6 приведены результаты проверки обобщающих свойств МНС ГС, полученных ею при обучении. На вход МНС ГС был представлен фрагмент вейвлет-спектра фонового изображения, отсутствовавший в тестовой выборке и не имевший установленного идентификатора клас-

са. Выходной сигнал МНС ГС, т.е. идентификатор нового входного фрагмента соответствует его классу, следовательно, МНС ГС, обобщая знания, полученные при обучении, правильно идентифицирует неизвестный фрагмент вейвлет-спектра.

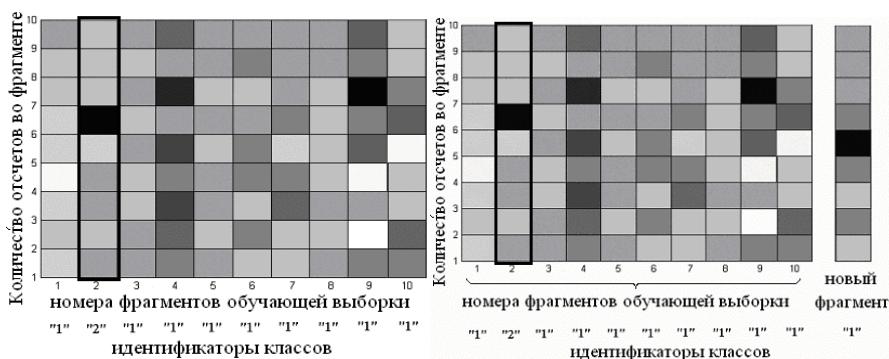


Рис. 5. Нейросетевая классификация спектральных образов тестового изображения, полученные после обучения МНС ГС по выборке из тестовых и эталонного образов

Рис. 6. Нейросетевая классификация МНС ГС спектрального образа тестового изображения, не содержащегося в тестовой выборке спектральных образов

Выводы. Из-за сложности формы гиперповерхности, разделяющей классы, применение МНС с сигмоидными функциями активации не обеспечивает требуемого уровня точности распознавания спектральных образов.

Использование МНС ГС в качестве классификатора фрагментов вейвлет-спектра позволяет совмещать в одном алгоритме обучения выделение спектрального образа ЭСВ из спектра изображений, транслируемых по каналам цифрового телевидения, и формирование классификатора в автоматическом режиме. В процессе обучения МНС ГС учитывает статистические свойства выборки и исключает незначимые признаки, основываясь на обучающей выборке спектральных образов при отсутствии какой-либо априорной статистической информации. Таким образом, обученная МНС ГС способна выделять фрагменты, соответствующие ЭСВ, из новых массивов вейвлет-коэффициентов вновь поступающих изображений.

Основным направлением дальнейших исследований является исследование точности синхронизации системных шкал времени по ЭСВ, передаваемых по каналам цифрового телевидения.

ЛИТЕРАТУРА

1. ДСТУ 4214:2003. Цифрове телевізійне мовлення (DVB). Структура кадрів, кодування каналу та методи модуляції в кабельних розподільчих системах. Загальні технічні вимоги (EN 300 429:1998,MOD). – К.: Держспоживстандарт України, 2005. – 17 с.
2. ДСТУ 4215:2003. Цифрове телевізійне мовлення. Передавання інформації телетексту в цифрових потоках DVB. Загальні технічні вимоги (EN 300 472:1996, MOD). – К.: Держспоживстандарт України, 2005. – 6 с.
3. Дьяконов В.П. Вейвлеты. От теории к практике. – М.: СОЛОН-Р, 2002. – 448 с.
4. Lewis A.S., Knowles G. Image Compression Using the 2-D Wavelet Transform // IEEE Trans. Image Proc. – 1992. – Vol. 1, № 2. – P. 224-250.
5. Xziong Z., Ramchadran K., Orchard M.T. Space-frequency Quantization for Wavelet Image Coding // IEEE Trans. Image Proc. – 1997. – Vol. 6, № 2. – P. 677-693.
6. Саблин В.Н., Чапурский В.В., Шейко А.П. Нейросетевое распознавание спектральных портретов воздушных объектов при наблюдении методом теневого инверсного радиолокационного синтезирования апертуры // Радиотехника и электроника. – 2004 – Т. 49, № 2. – С. 184-195.
7. Сирота А.А., Попело В.Д., Маслов О.В. Нейросетевые и оптимальные алгоритмы обнаружения локально-неоднородных участков изображений // Радиоэлектроника. – 2003 – № 9. – С. 66-74.
8. Ососков Г.А., Полянский А., Пузынин И.В. Современные методы обработки экспериментальных данных в физике высоких энергий // Физика высоких энергий. – 2002. – Т. 33, Вып. 3. – С. 676-745.
9. Чинков В.Н., Троцко М.Л. Применение нейронной сети для выделения эталонных сигналов времени из вейвлет-спектра изображений, транслируемых по каналам цифрового телевидения // 36. наук. праць. – Х.: ХУ ПС. – 2006. – Вип. 1 (7). – С. 99-102.
10. Дьяконов В.П. MATLAB 6/6.1/6.5+Simulink4/5 в математике и моделировании. Полное руководство пользователя. – М.: СОЛОН-Пресс, 2003. – 576 с.
11. Demuth H., Beale M. Neural Network Toolbox User's Guide. – Natick: Math-Works, 1997. – 700 p.
12. Нейросетевые системы управления: Учебное пособие для вузов / В.А. Терехов, Д.В. Ефимов, И.Ю. Тюкин. – М.: Высш. шк., 2002. – 183 с.

Поступила 20.03.2006

Рецензент: доктор технических наук, профессор В.Н. Чинков,
Харьковский университет Воздушных сил им. И. Кожедуба.