

ТРУДЫ  
ВСЕРОССИЙСКОЙ НАУЧНОЙ КОНФЕРЕНЦИИ  
«ПРОЕКТИРОВАНИЕ НАУЧНЫХ И ИНЖЕНЕРНЫХ  
ПРИЛОЖЕНИЙ В СРЕДЕ MATLAB»

***Часть 4. Нейронные сети и их  
приложения***

*Под общ. ред. М.Н. Рычагова*

## СОДЕРЖАНИЕ

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ДЕЯТЕЛЬНОСТИ ПРОИЗВОДСТВЕННОГО ПРЕДПРИЯТИЯ Кушнир О.А., Рудинский И.Д. ....	550
ИСКУССТВЕННАЯ НЕЙРОННАЯ СЕТЬ ДЛЯ ДИАГНОСТИКИ НЕФТЕПРОДУКТОВ Никифоров И.К., Кречка П.М. ....	552
АППРОКСИМАЦИЯ ЧАСТОТНЫХ ХАРАКТЕРИСТИК ЦИФРОВЫХ ФИЛЬТРОВ С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ Саутов Е.Ю., Гречин А.Н., Хрящев В.В., Приоров А.Л. ....	556
ИСПОЛЬЗОВАНИЕ ПАКЕТА NEURAL NETWORK TOOLBOX ДЛЯ РЕШЕНИЯ ЗАДАЧИ ОБНАРУЖЕНИЯ И ВЫДЕЛЕНИЯ ГРАНИЦ РАЗДЕЛА СЛУЧАЙНЫХ ПОЛЕЙ ПРИ ОБРАБОТКЕ ИЗОБРАЖЕНИЙ Сирота А.А., Маслов О.В. ....	561
УПРАВЛЕНИЕ ЦВЕТОМ ПРИ ПРОИЗВОДСТВЕ КРАСОК С ИСПОЛЬЗОВАНИЕМ МЕХАНИЗМА НЕЙРОННЫХ СЕТЕЙ Сокольчик П.Ю., Шумихин А.Г. ....	570
НЕЙРОСЕТЕВОЙ ПОДХОД К РЕШЕНИЮ ЗАДАЧИ ВОССТАНОВЛЕНИЯ АМПЛИТУДЫ ДИСКРЕТНОГО СИГНАЛА Хрящев В.В., Саутов Е.Ю., Соколенко Е.А. ....	580

УДК 519.6

## **ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ДЕЯТЕЛЬНОСТИ ПРОИЗВОДСТВЕННОГО ПРЕДПРИЯТИЯ**

Кушнир О.А., Рудинский И.Д.

*Калининградский государственный технический университет,*

*г. Калининград*

*e-mail: [scale@kcl.ru](mailto:scale@kcl.ru)*

Для производственного предприятия, занимающегося строительством, особую актуальность имеет прогноз финансовых показателей по конкретному заказу на этапе проектирования строительной сметы. В соответствии с содержанием и количеством работ в смете по номеру расценки и ценника указывается стоимость прямых затрат в виде материалов, заработной платы и эксплуатации машин в ценах СНиП вместе с ежемесячно уточняющимся коэффициентом пересчета в текущие цены. В бухгалтерском учете каждая строительная смета отражается в виде хозяйственных операций выполняемого заказа в течение периода, предусмотренного договором. Аналитика заказа ведется в разрезе статей затрат, число которых в зависимости от сложности строительных работ варьируется от 5 до 30. Требуется по проектируемой смете спрогнозировать бухгалтерские параметры заказа, а именно статьи затрат основного и вспомогательного производства, возможные общехозяйственные затраты и бухгалтерскую прибыль за указанный период выполнения заказа. Неопределенность задачи заключается в невозможности прямого расчета показателей только по данным сметы и ценников из-за постоянных несоответствий затрат, заложенных в смете к показателям бухгалтерского учета данного заказа.

Для решения поставленной задачи необходим анализ выполненных смет и соответствующих им бухгалтерских данных. Каждая работа, определенная в смете, содержит свои показатели, которые, в свою очередь, в бухгалтерии отражаются одной или несколькими статьями затрат. Фактически сетевой характер взаимосвязей исходных и результирующих показателей позволяет использовать в качестве метода анализа нейросетевое моделирование. Обучение нейронной сети может проводиться на

материалах сметной документации и бухгалтерской отчетности по фактически выполненным заказам.

Для решения задачи предлагается использовать трехслойную нейронную сеть с обратным распространением ошибки. С помощью сигмоидальной функции вычисляется активность каждой работы относительно учитываемых входных показателей. После того, как активности всех сигналов на выходе нейрона определены, вычисляется ошибка. Целевая функция нейронной сети рассчитывает градиент ошибок бухгалтерских показателей для разных работ в смете при прохождении каждого слоя сети. При обучении сети вычисляются отклонения значений показателей на выходах нейронов от реальных показателей и обратном прохождении этих отклонений до породивших их элементов с целью коррекции ошибки. Количество нейронов во входном слое – 50, в выходном – 30, что определяется множествами входных и выходных переменных моделируемой задачи. Скрытый слой с численностью нейронов, равной мощности входного слоя, используется для фильтрации работ в сметах по каждому бухгалтерскому показателю. При определении шага обучения сети предлагается использовать адаптивный алгоритм выбора шага, автоматически корректирующий размер шага в процессе обучения в зависимости от изменения ошибки.

Входные нейроны соответствуют входным параметрам смет по содержанию строительных работ, накладным расходам и плановым накоплениям. Выходные элементы сети соответствуют бухгалтерским статьям затрат по прямым, вспомогательным затратам производства и общехозяйственным затратам.

Реализация системы предполагается в среде MATLAB с использованием Neural Networks Toolbox. Применение предлагаемой нейросетевой модели на строительном предприятии позволит анализировать производственному отделу и бухгалтерии статьи затрат строительных заказов с возможностью прогноза таких бухгалтерских данных, как прибыль заказа и налогооблагаемые суммы. В перспективе возможна интеграция этой модели в систему управления предприятием, где она в качестве подсистемы прогнозирования позволит определять перспективность и целесообразность выполнения конкретных заказов.

УДК 519.6

## ИСКУССТВЕННАЯ НЕЙРОННАЯ СЕТЬ ДЛЯ ДИАГНОСТИКИ НЕФТЕПРОДУКТОВ

Никифоров И.К., Кречка П.М.

*Чувашский государственный университет имени И.Н. Ульянова,*

*г. Чебоксары*

*e-mail: [rrs@chtt.ru](mailto:rrs@chtt.ru)*

Искусственные нейронные сети (ИНС) широко применяются в различных прикладных областях. Возможности ИНС по моделированию сложных нелинейных систем используются при моделировании измерительных устройств. Из многочисленных описанных в литературе структур ИНС для применения в области измерений наиболее подходят сети прямого распространения, называемые *многослойным персептроном* (МСП), в котором нет обратных связей и обучающие алгоритмы обратного распространения ошибки (алгоритм Румельхарта-Хинтона-Вильямса) [1].

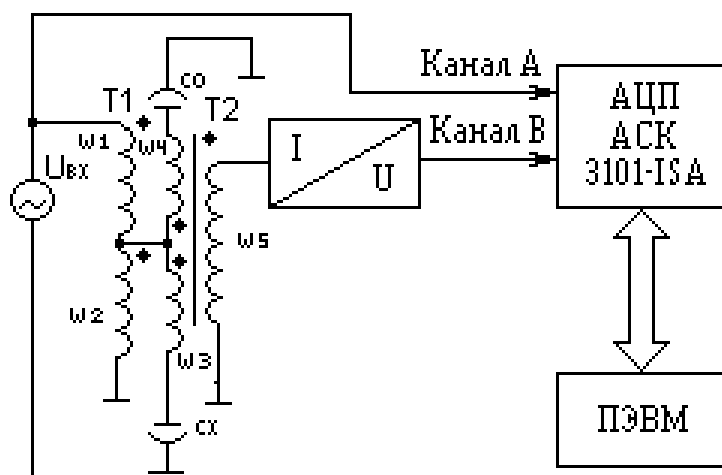


Рис. 1. Структурная схема измерительной установки.

В работе рассматривается программная реализация двухслойного МСП, выполненного с применением специализированного пакета по ИНС Neural Networks Toolbox, входящего в интегрированный математический пакет MATLAB 6.

Сеть имеет 60 входов и 60 выходов и способна идентифицировать бензопродукты с октановым числом (ОЧ) 70-100 с дискретностью 0.5 ОЧ.

Данные по АЧХ и ФЧХ, которые рассмотрены в [2], снимаются с измерительной установки, структурная схема которой представлена на рис. 1, и оформлены в виде матриц входных данных, которые подаются на вход ИНС.

Датчики СХ и С0 представляют собой два стальных цилиндра соосно вставленных один в другой, конструкция которых показана на рис.2. Для поддержания одинакового уровня исследуемой жидкости во внутреннем объеме датчика, на боковых стенках внешнего цилиндра обоих датчиков имеются сливные отверстия.




Рис. 2. Конструкция датчика.

В [3] был разработан и отлажен алгоритм обучения ИНС, работа которой описывается формулой:

$$y_{jl} = \sum_i w_{ijl} x_{ijl}, z_{jl} = F(y_{jl} - \Theta_{jl}), x_{ij(l+1)} = z_{jl},$$

где индексом  $i$  обозначают номер входа;  $j$  – номер ФН в слое;  $l$  – номер слоя;  $x_{ijl}$  –  $i$ -й входной сигнал  $j$ -го ФН в слое  $l$ ;  $y_{jl}$  – сигнал у  $j$ -го ФН в слое  $l$ ;  $z_{jl}$  – выходной сигнал ФН;  $\Theta_{jl}$  – пороговый уровень ФН  $j$  в слое  $l$ .

Структурная схема рассматриваемой ИНС показана на рис. 3. Выбор значений весов и порогов в МСП требует обучения, т.е. пошаговых изменений весовых коэффициентов и пороговых уровней. Задача формализации, т.е. выбора смысла, которым

наделяются компоненты входного и выходного векторов, решается человеком на основе практического опыта.

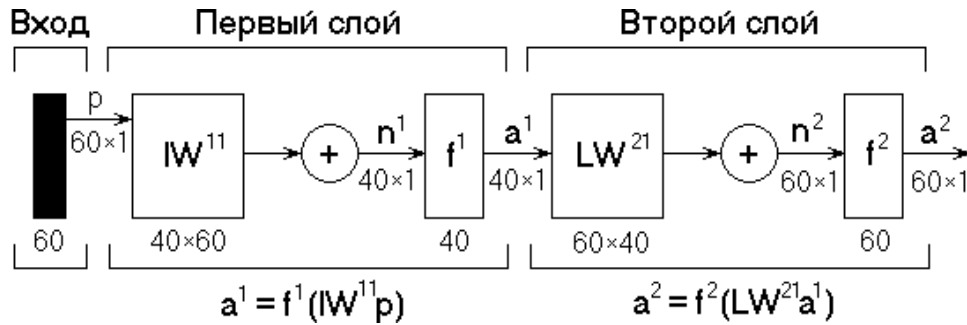


Рис. 3. Структурная схема ИНС.

Сеть задается набором весовых коэффициентов и пороговых уровней  $P = \begin{bmatrix} w \\ \Theta \end{bmatrix}$ . Так как обучающее множество задано, то ошибка сети зависит только от вектора параметров  $E = E(p)$ . При обучении на каждой итерации корректируют параметры в направлении антиградиента  $E$ :  $\Delta P = -\epsilon \nabla E(p)$ . В теории оптимизации доказано, что такой алгоритм обеспечивает сходимость к одному из локальных минимумов функции ошибки, при условии правильного выбора оптимального шага  $\epsilon > 0$  на каждой итерации. Значения производных  $\partial E / \partial w_{ijl}$  и  $\partial E / \partial \Theta_{jl}$  позволяют ввести коррекции  $\Delta w_{ijl}$  и  $\Delta \Theta_{jl}$  для нейронов последующего слоя.

Алгоритм обучения ИНС (согласно поставленной задаче):

1. Подать на входы сети один из возможных образов в режиме обычного функционирования ИНС и рассчитать выходной сигнал.
2. Рассчитать величину  $\delta^{(N)}$  для выходного слоя по формуле:  

$$\delta_j^{(N)} = (y_j^{(N)} - d_j) \cdot \frac{dy_j}{ds_j},$$
где  $y_j^{(N)}$  – реальное выходное состояние нейрона  $j$  выходного слоя  $N$  нейронной сети при подаче на ее входы образа;  $d_j$  – идеальное (желаемое) выходное состояние этого нейрона.
3. Рассчитать изменения весов  $\Delta w^{(N)}$  слоя  $N$ :  $\Delta w_{ij}^{(N)} = -\eta \cdot \delta_j^{(N)} \cdot y_i^{(N-1)}$ , где  $\eta$  – коэффициент скорости обучения,  $0 < \eta < 1$ .
4. Рассчитать соответственно  $\delta^{(n)}$  и  $\Delta w^{(n)}$  для остальных слоев,  $n = N-1, \dots, 1$ .

$$\delta_j^{(n)} = \left[ \sum_k \delta_k^{(n+1)} \cdot w_{jk}^{(n+1)} \right] \cdot \frac{dy_j}{ds_j}$$

$$\Delta w_{ij}^{(n)} = -\eta \cdot \delta_j^{(n)} \cdot y_i^{(n-1)}$$

5. Скорректировать все веса  $w_{ij}^{(n)}$  в ИНС:  $w_{ij}^{(n)}(t) = w_{ij}^{(n)}(t-1) + \Delta w_{ij}^{(n)}(t)$ .
6. Если ошибка больше допустимого значения, то перейти на шаг 1. В противном случае – конец. Средняя квадратичная ошибка вычисляется по следующей формуле:  $E(w) = \frac{1}{N} \sum_j (y_j^{(N)} - d_j)^2$ .

В результате получена ИНС, способная определять ОЧ бензопродуктов в пределах 70-100 с дискретностью 0.5, реализованная в среде *MATLAB* 6. Предполагается реализация информационно-измерительного канала в среде пакета LABView фирмы National Instruments с применением ранее полученных результатов по исследованию бензинов и моделированию ИНС с учетом поставленной задачи.

### *Литература*

1. *Дапонте П., Гримальди Д.* Искусственные нейронные сети в измерениях // Приборы и системы управления. 1999. №3. с. 49-64.
2. *Никифоров И.К.* Исследование частотных характеристик бензинов // Материалы VI школы-семинара «Актуальные проблемы физической и функциональной электроники». Ульяновск: Изд-во ульяновского гос. техн. ун-та, 2001, с. 42.
3. *Никифоров И.К., Михайлов М.В.* Экспертная система для определения октанового числа бензинов. Алгоритм обучения // Труды молодых ученых и специалистов / Изд-во Чуваш. Ун-та, Чебоксары: 2001. с. 175-179.



УДК 621.37

## **АППРОКСИМАЦИЯ ЧАСТОТНЫХ ХАРАКТЕРИСТИК ЦИФРОВЫХ ФИЛЬТРОВ С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ**

Саутов Е.Ю., Гречин А.Н., Хрящев В.В., Приоров А.Л.  
*Ярославский государственный университет им. П.Г. Демидова,*  
*г. Ярославль*  
*e-mail: [dcslab@uniyar.ac.ru](mailto:dcslab@uniyar.ac.ru)*

Выполняя, подобно аналоговым цепям, операцию частотной фильтрации, цифровые фильтры (ЦФ) обладают рядом существенных преимуществ. Сюда относятся, например, высокая стабильность параметров, возможность получать самые разнообразные формы амплитудно-частотных (АЧХ) и фазо-частотных характеристик (ФЧХ).

Важное практическое значение имеют методы синтеза ЦФ, обеспечивающие заранее заданные свойства, например, требуемый вид импульсной или частотной характеристики. Наиболее распространенными методами синтеза ЦФ с конечной импульсной характеристикой (КИХ-фильтров) являются [1]: метод «окна», метод частотной выборки, оптимальные методы. Эти методы имеют ряд преимуществ и недостатков. Например, метод «окна» прост для программирования, что позволяет успешно применять его для расчета фильтров больших порядков, а синтезированные оптимальными методами ЦФ имеют наименьшую (среднеквадратическую или максимальную) погрешность аппроксимации при заданном порядке фильтра или наименьший порядок при заданной (допустимой) погрешности аппроксимации.

В последнее время в широком круге задач цифровой обработки сигналов применяется аппарат нейронных сетей [2,3]. В работе предлагается использовать нейросетевой алгоритм для решения задачи синтеза цифровых КИХ-фильтров.

Для расчета коэффициентов ЦФ по заданной амплитудно-частотной характеристике (АЧХ) использовалась трехслойная нейронная сеть (НС) без обратных связей. В среде MATLAB 6.0 (R12) подобная НС может быть смоделирована при помощи функции [4]:

**net = newff(PR,[S1 S2...SNI],{TF1 TF2...TFNI},btf,blf,pf),**

\где PR – массив размера  $R \times 2$  минимальных и максимальных значений для  $R$  векторов входа;  $S_i$  – количество нейронов в слое  $i$ ;  $Tf_i$  – функция активации слоя  $i$ , по умолчанию `tansig`; `btf` – обучающая функция, реализующая метод обратного распространения, по умолчанию `trainlm`; `blf` – функция настройки, реализующая метод обратного распространения, по умолчанию `learngdm`; `pf` – критерий качества обучения, по умолчанию `mse`; `net` – объект класса `network object` – нейронная сеть.

В данном случае вызов функции `newff()` выглядит следующим образом:

**net=newff(minmax(P),[n,m,2],{'logsig' 'logsig' 'purelin'},'trainrp'),**

где  $P$  – множество входных векторов;  $n$  – количество входов НС;  $m$  – количество нейронов в скрытом слое.

Количество нейронов в выходном слое – 2, значения их выходов соответствуют значениям коэффициентов  $a_2$ ,  $a_3$ , ( $a_1=1$ ) нерекурсивного цифрового фильтра второго порядка (рис. 1). Значение  $n$  выбрано равным 30, этого количества точек достаточно для приемлемого представления АЧХ фильтра на интервале  $[0, \pi]$ . Количество нейронов в скрытом слое выбиралось из расчета:

$$\frac{N}{10} - n - l \leq m \leq \frac{N}{2} - n - l,$$

где  $l$  – количество выходов НС (в данном случае – 2);  $N$  – количество обучающих выборок.




Рис. 1. Нерекурсивный цифровой фильтр второго порядка.

НС обучалась на массиве из 200 выборок, в котором в равном объеме представлены все виды фильтров (верхних и нижних частот, полосовые, режекторные). Обучающую пару составляют отсчеты

АЧХ, как вход НС и значения коэффициентов фильтра на выходе. На обучающие выборки был наложен ряд ограничений, не влияющий на качество решения поставленной задачи, но заметно облегчающий процесс обучения НС:

1. Входные АЧХ отнормированы на единицу по амплитуде.
2. Значения коэффициентов фильтра  $a_2$ ,  $a_3$  брались в интервалах  $[-1, 1]$ .

Наиболее эффективно НС обучалась при использовании функции “**trainrp**”. Значение ошибки обучения рассчитывалось методом “наименьших квадратов” (SSE), и было задано равным 0.1. В результате сеть была обучена и при тестировании показывала неплохие результаты. Тестирование проводилось следующим образом: выбиралась пара коэффициентов  $a_2$ ,  $a_3$ , вычислялась АЧХ фильтра с этими коэффициентами, отсчеты этой АЧХ подавались на вход тестируемой НС. На выходе сети получали искомые коэффициенты, по которым синтезировался фильтр и строилась его АЧХ. На рис. 2, 3 представлены результаты тестирования НС.




Рис. 2. Значения коэффициентов: заданных –  $a_2 = -0.5$ ,  $a_3 = 0.45$ ;  
рассчитанных –  $a_2 = -0.4544$ ,  $a_3 = 0.4271$ .




Рис. 3. Значения коэффициентов: заданных –  $a_2 = 0.5$ ,  $a_3 = 0.18$ ;  
рассчитанных –  $a_2 = 0.5051$ ,  $a_3 = 0.1732$ .

Полученные результаты показывают принципиальную возможность применять аппарат нейронных сетей к указанному классу задач. Применение среды MATLAB для исследования решения задач синтеза нам кажется оптимальным по той причине, что результаты, полученные в Neural Network Toolbox легко можно сопоставить с соответствующими результатами из Signal Processing Toolbox и Filter Design Toolbox.

Развитием подобных исследований является разработка нейронных сетей для расчета коэффициентов КИХ-фильтров высших порядков, а также синтез коэффициентов фильтра по заданной идеальной АЧХ, для чего предполагается использовать дополнительный слой с радиально-базисными функциями активации.

Результаты работы могут найти применение при проектировании устройств обработки и передачи цифровых сигналов.

### *Литература*

1. *Рабинер Л., Гоулд Б.* Теория и применение цифровой обработки сигналов: Пер. с англ. – М.: Мир, 1978. 848 с.
2. *Галушкин А.И.* Теория нейронных сетей: М., Радиотехника, 2000. 416 с.
3. *Хрящев В.В., Приоров А.Л.* Цифровая фильтрация на базе клеточных нейронных сетей //Труды VIII Всероссийской конференции с международным участием «Нейрокомпьютеры и их применение» (НКП-2002), Москва 2002. С. 191-199.
4. *Медведев В.С., Потемкин В.Г.* Нейронные сети. MATLAB 6. М.: ДИАЛОГ-МИФИ, 2002. 496 с.

УДК 621.391:396

## **ИСПОЛЬЗОВАНИЕ ПАКЕТА NEURAL NETWORK TOOLBOX ДЛЯ РЕШЕНИЯ ЗАДАЧИ ОБНАРУЖЕНИЯ И ВЫДЕЛЕНИЯ ГРАНИЦ РАЗДЕЛА СЛУЧАЙНЫХ ПОЛЕЙ ПРИ ОБРАБОТКЕ ИЗОБРАЖЕНИЙ**

Сирота А.А., Маслов О.В.

*Воронежский государственный университет, г. Воронеж*

*e-mail: [mov20@mail.ru](mailto:mov20@mail.ru)*

В настоящее время известно множество машинных алгоритмов выделения границы раздела пространственно распределенных объектов на изображениях, описываемых разнородными случайными полями [1,2]. Большинство из них синтезированы в предположении о наличии некоей статистической модели полей и имеют достаточно сложную структуру [3,4]. Появление аппарата искусственных нейронных сетей и эффективных процедур их обучения позволило взглянуть на проблему выделения границы как на проблему обучения сети «с учителем» на сериях эталонных изображений, содержащих всевозможные варианты расположения границы. Это дало возможность избавиться от необходимости использования статистических моделей, не всегда отражающих реальные характеристики объектов, и синтезируемых на их основе оптимальных алгоритмов обработки, что во многих случаях является оправданным с позиции упрощения и повышения быстродействия обработки. Целью настоящей работы является анализ возможностей алгоритмов выделения границы с помощью различных нейросетевых типопредставителей в пакете Neural Network Toolbox(NNT) фирмы Mathworks.

Для эффективного сравнительного анализа различных нейросетевых типопредставителей потребовалось введение некоторой тестовой модели полей. Для этой цели были выбраны модели гауссовских марковских случайных полей, которые достаточно часто используются при описании изображений и для которых возможен синтез эталонных оптимальных в статистическом смысле алгоритмов, обеспечивающих анализ

потенциальной эффективности различных нейросетевых алгоритмов.




Рис. 1.

Определим модели состояния случайных полей, заполняющих некоторый фрагмент изображения и разделенных общей границей [5]. Пусть имеется два случайных поля  $y_1(i, j) = m_1 + \lambda_1(i, j), i = \overline{1, i_j}, j = \overline{1, M}, y_2(i, j) = m_2 + \lambda_2(i, j), i = \overline{i_j + 1, N}, j = \overline{1, M}$ , где  $m_{1,2}$  - неизвестные значения постоянных составляющих ( $M[m_{1,2}] = m_{1,2}^0, D[m_{1,2}] = \sigma_{m,2}^2$ );  $\lambda_{1,2}(i, j)$  - реализации марковских разделимых случайных полей ( $M[\lambda_{1,2}(i, j)] = 0, M[\lambda_{1,2}^2(i, j)] = \sigma_{\lambda,2}^2$ ), описывающие стохастические составляющие полей  $y_{1,2}(i, j)$ ;  $i$  - номер элемента строки;  $j$  - номер строки изображения, заданного на двумерной сетке размером  $N \times M$ . Поля  $y_{1,2}(i, j)$  разделены границей случайной формы  $i_j = f(j)$ , описываемой марковской цепью с переходными вероятностями  $P_\Gamma(i_j | i_{j-1}), j = \overline{2, M}$  и вероятностями начальных состояний  $P_\Gamma(i_1) = 1/N$ . Корреляционная функция стохастических составляющих полей имеет вид  $M[\lambda_{1,2}(i, j)\lambda_{1,2}(k, m)] = \sigma_{\lambda,2}^2 \rho_{1,2}^{\Delta x_1 |i-k| + \Delta x_2 |j-m|}$ , где  $\rho_{1,2}$  - коэффициенты пространственной корреляции;  $\Delta x_1, \Delta x_2$  - дискреты задания координатной сетки. Поля могут отличаться уровнями постоянных

составляющих (граница типа «перепад») и/или значениями коэффициентов пространственной корреляции. Кроме того, может рассматриваться граница между полями одинаковой структуры, но имеющими «разрыв» в области расположения границы. Представленная модель является достаточно общей и позволяет описывать различные варианты задания границы раздела пространственно распределенных объектов на изображениях. Пример реализации таких полей, разделенных границей типа "перепад", представлен на рис. 1.

Как показано в [5], для рассмотренной модели уравнения состояний и построчных наблюдений совокупного изображения в присутствии шумов могут быть записаны в виде

$$x_j = F_j(\beta)x_{j-1} + G_j(\beta)u_j, \quad z_j = H_j(\beta)x_j + v_j, \quad (1)$$

где  $x_j = (\lambda_1(1, j), \dots, \lambda_1(i_j, j), \lambda_2(i_j + 1, j), \dots, \lambda_2(N, j), m_1, m_2)^T$  - расширенный вектор состояний;  $u_j = (u(1, j), \dots, u(N, j))^T$  - вектор шума возмущения с независимыми от точки к точке значениями ( $M[u(i, j)] = 0, M[u^2(i, j)] = 1$ );  $z_j = (z(1, j), \dots, z(N, j))^T$  - вектор наблюдений, получаемый при сканировании строки общего изображения;  $v_j = (v(1, j), \dots, v(N, j))^T$  - вектор шума наблюдений с независимыми от точки к точке значениями ( $M[v(i, j)] = 0, M[v^2(i, j)] = \sigma_z^2$ );  $F_j(\beta), G_j(\beta), H_j(\beta)$  - преобразующие матрицы соответствующей размерности, известные с точностью до параметра  $\beta$ , определяемого парой чисел  $\beta = \{n = i_{j-1}, m = i_j\}$ , описывающих положение границы в предыдущей и последующей строке изображения (точный вид матриц приведен в [5]). Оптимальный алгоритм обработки (ОАО) для этих моделей, обеспечивающий оценку вектора состояний с минимальной дисперсией и определение положения границы, определяется соотношениями

$$\begin{aligned} \hat{x}_{j|j} &= \sum_{k=1}^{N_j} \tilde{x}_{j|j}(\theta_k) P(\theta_k | z^j), \quad \tilde{x}_{j|j}(\theta_k) = \int x_j P(x_j | z^j, \theta_k) dx_j, \\ l &= \arg \max_k P(\theta_k | z^j), \quad P(\theta_k | z^j) = P(i_1^{(k)}, \dots, i_j^{(k)} | z^j) = \\ &= P(z_j | i_1^{(k)}, \dots, i_j^{(k)}, z^{j-1}) P_\Gamma(i_j^{(k)} | i_{j-1}^{(k)}) P(i_1^{(k)}, \dots, i_{j-1}^{(k)} | z^{j-1}) / C(z^j), \end{aligned} \quad (2)$$

где  $\theta_k$  - гипотезы о конкретном местоположении границы, каждая из которых определяется набором  $\theta_k = \{i_1^{(k)}, \dots, i_j^{(k)}\}, k = \overline{1, N_j}$ ,  $N_j$  - количество сформированных к данному шагу гипотез;  $\tilde{x}_{j|j}(\theta_k)$  - условная оптимальная в среднеквадратичном оценка вектора



состояний  $x_j$  по совокупности  $z^j = (z_1, \dots, z_j)$  предшествующих наблюдений при фиксированной форме границы;  $C(z^j)$  - нормирующая величина. Положение границы находится по максимуму апостериорной вероятности гипотез  $P(\theta_k | z^j)$ .

Кроме того, может рассматриваться задача обнаружения границы в рамках которой реализуется принятие решения о наличии неоднородности в пределах некоторого прямоугольного фрагмента изображения, что дает возможность определить находится ли в этой области однородное поле, пригодное для дальнейшей машинной обработки (например, классификации), или в ее пределах находится граница раздела двух полей, которую следует уточнить. Синтезированное оптимальное решающее правило (ОРП) в данном случае имеет вид

$$p_{\vartheta_2} \sum_{k=1}^{N_j} P(z^j | \theta_k) P(\theta_k) \underset{\vartheta_1}{\overset{\vartheta_2}{>}} p_{\lambda_1} P_{\lambda_1}(z^j) + p_{\lambda_2} P_{\lambda_2}(z^j), \quad (3)$$

где  $\vartheta_{1,2}$  - гипотезы об отсутствии и наличии границы соответственно,  $p_{\vartheta_1} = p_{\lambda_1} + p_{\lambda_2}$ ,  $p_{\vartheta_2}$  - априорные вероятности заполнения фрагмента изображения однородным полем и полями с границей между ними.

С помощью встроенного языка системы MATLAB описанные выше алгоритмы были эффективно реализованы в виде набора М-функций, интенсивно использующих широкие возможности системы MATLAB по оперированию матрицами.

Для решения выше описанных задач выделения и обнаружения границы в рамках нейросетевого подхода и их сравнительного анализа реализованы варианты построения НС, основанные на использовании возможностей пакета Neural Network Toolbox среды MATLAB. Для задачи построения выделения границы рассматривались три вида сетей.

### **Многослойный персептрон (МСП)**

Для нахождения положения границы использовался двухслойный МСП со скрытым нелинейным слоем (10 нейронов) и линейным выходным слоем. Предложенная структура сети представлена на рис. 2. Активационная функция нелинейных элементов скрытого слоя задавалась в виде логистического

сигмоида:  $\log \text{sig}(x) = \frac{1}{1 + e^{-x}}$ . С помощью функции newff генерировалась соответствующая топология сети.




Рис. 2.

На вход МСП подавался вектор  $x^{(1)}$ , содержащий  $N \times M_s$  элементов наблюдаемого изображения, где  $M_s$  - количество строк ( $M_s \leq M$ ). На выходе сети определялось положение элемента границы в последней строке из числа строк, подаваемых на вход. При таком задании архитектуры сети по аналогии с ОАО обеспечивается (если  $M_s > 1$ ) учет влияния предыстории на результат определения границы в текущей строке. Выход сети содержал  $N$  нейронов, представляющих положение границы как дельта-вектор  $b_j = \delta(i - i_j), i = \overline{1, N}$ , где  $i$  - номер нейрона,  $i_j$  - номер граничного элемента в строке. Множество содержащихся в пакете NNT процедур обучения, основанных на реализации метода обратного распространения, позволило сделать эффективный выбор процедуры обучения. Оптимальной по соотношению ошибка/время оказалась процедура обучения методом адаптивного спуска по градиенту функции среднеквадратичной ошибки обучающей выборки в пакетном режиме `traingda` (веса корректировались после представления всей обучающей выборки)[6]. При ее использовании время обучения снизилось в несколько раз по сравнению со временем обучения стандартной процедурой обратного распространения. Для оценки качества обучения была применена так называемая проверочная выборка (validation set), состоящая из 100 реализаций, сгенерированных независимо от обучающей выборки. Это позволило снизить объем обучающей выборки без потери общности, и соответственно сократить время обучения.

### Сеть Элмана (СЭ)

Ограничением рассмотренного варианта построения МСП в задаче построчного выделения границы является отсутствие обратной связи, что не позволяет на каждом шаге учитывать предыдущий результат. Использование информации о ранее принятом решении по предыдущей строке позволяет реализовать сеть Элмана [6], содержащую обратную связь и имеющую структуру, представленную на рис. 2 (функция создания топологии СЭ – **newelm**). СЭ позволяет избавиться от необходимости введения нескольких строк исходного изображения, поэтому входом сети являлась одна текущая строка изображения, а вклад предыдущего наблюдения учитывался через введенную обратную связь. Для обучения данной сети используется стандартный алгоритм обратного распространения, но при этом ошибка обучения через обратную связь не распространяется. Для учета характеристик изменения границы в СЭ требуется, чтобы элементы обучающей выборки были последовательно связаны между собой. Поэтому была сформирована общая реализация случайного поля из 1000 строк с непрерывным изменением границы, которая при обучении сети предъявлялась последовательно. Следует отметить, что в случае линейного входного слоя, топология сети соответствует рекуррентному фильтру Калмана.

### Вероятностная сеть (ВС)

Данная сеть [7] является, по сути, классификатором гипотез о местоположении границы. Предложенная топология сети представлена на рис. 3. Соответствующая функция создания топологии сети – **newpnn**.




Рис. 3.

В данном случае эталоны классов определялись наборами из  $M_s$  строк изображения с идеальным перепадом между средними значениями полей  $m_1^0$ ,  $m_2^0$  и со всеми возможными вариантами расположения границы. Согласно стандартному правилу обучение первого слоя производится путем приравнивания векторов весов первого слоя центрам классов, а матрица весов второго слоя назначается равной матрице соответствия подклассов классам, состоящей из единиц и нулей.

Для сравнительной оценки качества алгоритмов определения границы использовалась среднеквадратичная ошибка определения границы  $\varepsilon^2$  и вероятность точного определения положения элемента границы  $P_g$ . В эксперименте исследовалась зависимость эффективности рассмотренных алгоритмов от уровня аддитивного гауссовского белого шума наблюдения  $\sigma_z$  при уровне полезного сигнала, задаваемого разностью постоянных составляющих полей (граница типа “перепад”). Для оценки влияния предыстории проводился также анализ характеристик оптимального (ОАО1) и нейросетевого алгоритма (МСП1) при использовании в качестве входной информации только одной текущей строки исходного изображения. Полученные зависимости для величины  $\varepsilon^2$  при  $N = 20$ ,  $M_s = 3$  (рис. 4) показывают достаточно устойчивое функционирование алгоритмов, реализующих ВС, а также СЭ с учетом того, что последняя использует на входе только одну текущую строку изображения.

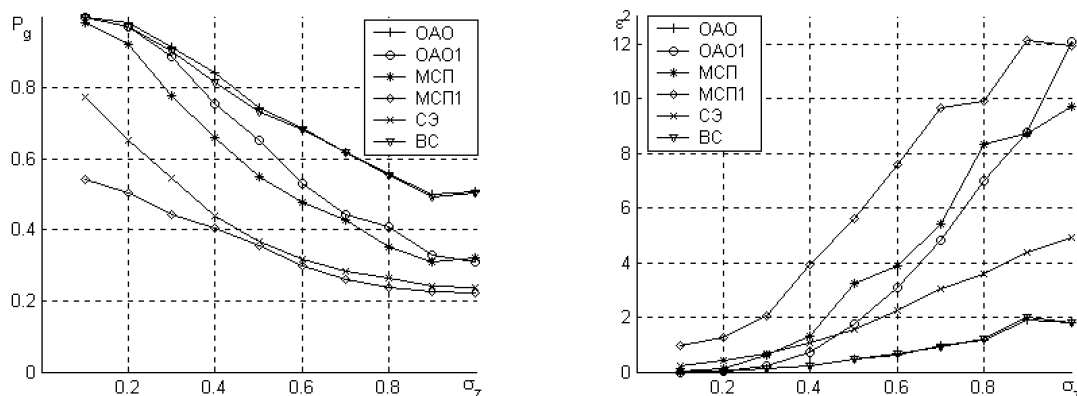


Рис. 4.

Для решения задачи обнаружения границы был применен двухслойный персептрон, содержащий 10 нейронов в скрытом слое и один выходной нейрон, играющий роль порогового элемента, сигнализирующего о наличии границы. Входом явились все элементы рассматриваемой области, подаваемые одновременно. В

таким виде МСП представляет собой аналог ОРП с обучением.

Для оценки качества нейросетевого алгоритма обнаружения границы были получены зависимости от  $\sigma_z$  вероятностей ошибок первого и второго рода при обнаружении (рис. 5), где МСП демонстрирует сравнительно неплохое качество работы по сравнению с ОРП даже при достаточно больших значениях  $\sigma_z$ .

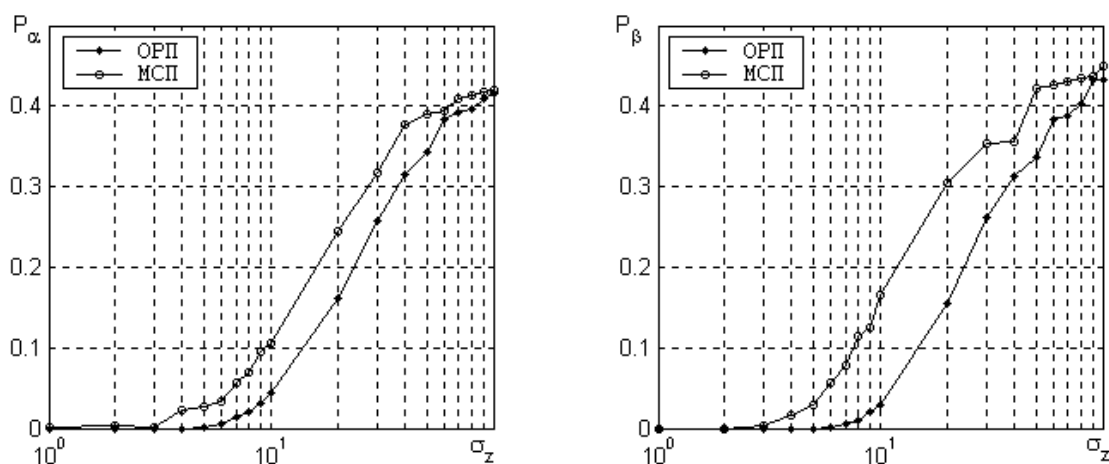


Рис. 5.

Применение программного продукта MATLAB позволило решать целый класс задач по обработке изображений в пределах единой интегрированной среды, что значительно сократило время разработки программной (машинно-зависимой) части проекта. Применение пакета Neural Networks Toolbox позволило сосредоточиться на процессе выбора подходящей топологии сети среди множества реализованных в нем вариантов и остановиться на МСП, СЭ и ВС. Благодаря реализации быстрых алгоритмов обучения, основанных на алгоритме «обратного распространения», время обучения сети сократилось в несколько раз по сравнению с традиционным алгоритмом обучения методом обратного распространения. Это позволило обоснованно подойти к генерации обучающих изображений и сконцентрировать усилия на оптимальном подборе параметров обучения без временных затрат на реализацию известных алгоритмов функционирования и обучения сетей. Совместно с пакетом Image Processing Toolbox обученные сети применялись для обработки реальных изображений поверхности Земли, полученных методами дистанционного зондирования, что свидетельствует о возможности проведения не только научных экспериментов, но и реализации на базе MATLAB единого практического комплекса обработки изображений

применительно к условиям сложной сигнально-помеховой обстановки.

### *Литература*

1. Бакут П.А., Колмогоров Г.С. Сегментация изображений: методы выделения границ областей // Зарубежная электроника. 1987. № 10. С. 25-47.
2. Бакут П.А., Колмогоров Г.С., Ворновицкий И.Э. Сегментация изображений: методы пороговой обработки // Зарубежная электроника. 1987. № 10. С. 6-24.
3. Абду И.Э., Прэтт У.К. Количественный расчет детекторов контуров, основанных на полчеркивании перепадов яркости с последующим пороговым ограничением // ТИИЭР. 1979. Т. 67, № 5. С. 59-70.
4. Розенфельд А., Дэйвис Л.С. Сегментация и модели изображений // ТИИЭР, 1979. Т. 67, № 5. С. 71-81.
5. Попело В.Д., Сирота А.А. Оценивание случайных полей изображений совместно с определением границ между ними при построчных наблюдениях // Радиотехника (журнал в журнале), 2000. № 10. С. 65-73.
6. Уоссерман Ф. Нейрокомпьютерная техника: теория и практика. М.: Мир, 1992. 183 с.

УДК 519.6

## УПРАВЛЕНИЕ ЦВЕТОМ ПРИ ПРОИЗВОДСТВЕ КРАСОК С ИСПОЛЬЗОВАНИЕМ МЕХАНИЗМА НЕЙРОННЫХ СЕТЕЙ

Сокольчик П.Ю., Шумихин А.Г.

*Пермский государственный технический университет, г. Пермь*

*e-mail: [psokol@cpl.pstu.ac.ru](mailto:psokol@cpl.pstu.ac.ru)*

Производство лаков и красок относится к гибким производственным системам, в которых в зависимости от условий в данном наборе аппаратов возможно получение одного или нескольких продуктов одновременно. Для лакокрасочного производства характерны непрерывно-дискретный характер производства, нестационарность процессов, субъективность восприятия характеристик продукции (цвет, блеск), сложность построения математических моделей, имеющих физический смысл, вызванная большим количеством протекающих процессов и большим количеством параметров состояния, что обуславливает целесообразность применения аппарата нейронных сетей.

Одной из основных проблем при производстве красок является правильная дозировка пигментов, подбор требуемого соотношения пигментов.

Существуют следующие проблемы при определении состава пигментов. При равных массах пигментов в разных производственных циклах цвет готовой краски может отличаться. Цвет готовой краски определяется экспертом, что, в свою очередь, вносит субъективность в оценки. Создание новой рецептуры краски определенного цвета при переходе от лабораторных исследований к производству сопровождается большим количеством брака при постановке цвета. Необходимо прогнозировать цвет краски по исходной рецептуре до проведения технологического процесса (прямая задача). Для протекающего технологического процесса необходимо управлять дозировкой пигментов (обратная задача). Прямая задача формулируется в виде  $\bar{c} = F(\bar{x})$ , где  $\bar{x}$  - вектор, характеризующий концентрации пигментов в краске;  $\bar{c}$  - вектор параметров, характеризующих цвет краски. Обратная задача имеет вид  $\bar{x} = F^{-1}(\bar{c})$ . Так как процессы, связанные с

цветопередачей, сложны и требуют знания эксперта (человек с правильным цветовосприятием), функции  $F$  и  $F^{-1}$  представлены в виде нейронных сетей.

Для этих целей использовались нейронные сети с алгоритмом обучения обратного распространения ошибки, каждый нейрон которой имеет вид:

$$\begin{cases} S_{jk} = \sum_{i=1}^n x_i w_{ijk}; \\ N_{jk} = f(S_{jk}), \end{cases}$$

где  $x_i$  – входы формального нейрона  $i = \overline{1, n}$ ;  $w_{ijk}$  – весовой коэффициент  $i$ -го входа  $k$ -го нейрона в слое  $k = \overline{1, n_l}$  ( $n_l$  – количество слоев нейронной сети);  $f$  – функция активации нейрона;  $N_{jk}$  – выход  $j$ -го нейрона  $k$ -го слоя. В качестве функции активации использовалась логистическая функция (сигмоида)  $f(x) = 1/(1 + e^{-ax})$ .

Исходные данные для обучения нейронных сетей получены при смешении краски содержащей три группы пигментов: белый (Б), красный (К) и зеленый (З). Нормированные значения объемных концентраций:  $X_c^* = X_c/V$ , где  $X_c$  – объем компонента  $C$ , мл;  $V$  – полный объем замеса, мл;  $X_c^*$  – приведенная концентрация,  $X^* \in [0, 1]$ . Числовые характеристики цвета получены с помощью светочувствительного сканирования. В качестве цветовой модели применена аддитивная RGB модель с 24-разрядами представления цвета. Цвет разлагается на 3 составляющих Red, Green и Blue. Для обучения и использования составляющие представлены в нормированном виде:  $C_i^* = C_i/N$  где  $C_i^*$  – нормативный уровень  $i$ -й цветовой составляющей;  $C_i$  – представление цветовой составляющей в виде одного из 256 возможных уровней;  $N=255$  – максимально возможное числовое значение уровня цветового представления.

Исходные данные представлены в таблице 1.

Обработка данных проводилась с использованием пакета MATLAB и его библиотеки Neural Network Toolbox. На рис. 1–3 представлены графики изменения ошибки при обучении сети для прямой задачи, на рис. 4 – 6 – для обратной. Графики получены в среде MATLAB.



Таблица 1.

N образца	Относительная объемная концентрация пигментов, об. доли			Приведенные составляющие RGB-вектора		
	$C_B^*$	$C_K^*$	$C_3^*$	$R^*$	$G^*$	$B^*$
1	0.00	0.00	1.00	0.149	0.275	0.141
2	0.00	1.00	0.00	0.698	0.169	0.126
3	0.00	0.50	0.50	0.184	0.180	0.127
4	1.00	0.00	0.00	1.000	1.000	0.969
5	0.33	0.67	0.00	0.831	0.290	0.247
6	0.25	0.50	0.25	0.327	0.196	0.157
7	0.20	0.40	0.40	0.243	0.224	0.157
8	0.50	0.50	0.00	0.831	0.294	0.259
9	0.40	0.40	0.20	0.345	0.263	0.200
10	0.33	0.33	0.33	0.263	0.267	0.184




Рис 1. Изменение ошибки при использовании «упругого» алгоритма обучения.




Рис. 2. Изменение ошибки прогноза при использовании алгоритма обучения с использованием метода секущих.




Рис. 3. Изменение ошибки прогноза при использовании алгоритма обучения с оптимизацией Левенберга - Марквардта




Рис. 4. Изменение ошибки при использовании «упругого» алгоритма обучения.




Рис. 5. Изменение ошибки прогноза при использовании алгоритма обучения с использованием метода секущих




Рис. 6. Изменение ошибки прогноза при использовании алгоритма обучения с оптимизацией Левенберга – Марквардта.

Рис. 1 - 6 показывают, что наиболее удовлетворительные результаты отвечают методу обучения с оптимизацией Левенберга - Марквардта и в дальнейшем применялся именно этот метод.

Результаты прогноза для прямой задачи на тестовой выборке приведены на рис. 7 - 9. На рис. 10 - 12 представлены результаты прогноза для обратной задачи.

Номер образца

Рис. 7. Прогноз R-составляющей цвета.




Рис. 8. Прогноз G-составляющей цвета.

Номер образца

Рис. 9. Прогноз В-составляющей цвета.




Рис. 10. К определению требуемой концентрации белого пигмента.

Номер образца

*Рис. 11. К определению требуемой концентрации красного пигмента.*

Номер образца

*Рис. 12. К определению требуемой концентрации зеленого пигмента.*

Полученный результат удовлетворяет точности, с которой необходимо проводить дозировку пигментов. Таким образом, лабораторные эксперименты по подбору пигментного состава можно проводить с невысокой точностью и неквалифицированному сотруднику. Затем по результатам экспериментов обучается нейронная сеть для обратной задачи. На вход сети подается вектор цветовой составляющей требуемого цвета и рассчитывается требуемый состав. Обученная сеть в дальнейшем применима для дозировки пигментов в производстве. Для каждой новой рецептуры используется новая нейронная сеть.



УДК 621.391

## НЕЙРОСЕТЕВОЙ ПОДХОД К РЕШЕНИЮ ЗАДАЧИ ВОССТАНОВЛЕНИЯ АМПЛИТУДЫ ДИСКРЕТНОГО СИГНАЛА

Хрящев В.В., Саутов Е.Ю., Соколенко Е.А.

*Ярославский государственный университет им. П.Г. Демидова,*

*г. Ярославль*

*e-mail: [vhr@yandex.ru](mailto:vhr@yandex.ru)*

Как в дискретном, так и в аналоговом случае амплитуда и фаза преобразования Фурье (ПФ) сигнала являются независимыми функциями. Следовательно, сигнал не может быть восстановлен без знания хотя бы одной из них. Однако при определённых условиях между этими компонентами существует связь. Например, когда сигнал каузальный и является сигналом минимальной фазы, т.е. все нули его  $z$ -преобразования находятся внутри единичного круга, логарифмическая амплитуда и фаза связаны между собой преобразованием Гильберта.

Одномерная задача восстановления амплитуды заключается в том, чтобы восстановить ограниченный дискретный сигнал по фазе его ДПФ. Если не наложено никаких условий на временной сигнал, то существует бесконечно много решений такой задачи. Это следует хотя бы из того, что если  $x(n)$  есть решение задачи восстановления амплитуды, то сигнал  $w(n)$ , представляющий собой свёртку  $x(n)$  и любого сигнала нулевой фазы  $y(n)$ , определённый как

$$w(n) = x(n) * y(n) = \sum_{k=-\infty}^{\infty} x(k)y(n-k), \quad (1)$$

также является решением проблемы восстановления амплитуды. Мы подразумеваем под сигналом нулевой фазы сигнал, фаза ПФ которого равна нулю или  $\pi$  для всех  $\omega \in [0, 2\pi]$ . Поскольку  $y(n)$  – сигнал нулевой фазы, то на основании (1) можно легко убедиться, что фазы ПФ  $w(n)$  и  $x(n)$  одинаковы т.е.

$$\arg(W(e^{j\omega})) = \arg(X(e^{j\omega})).$$

С практической точки зрения наиболее интересны случаи, когда длина временного сигнала ограничена и известна. В этом случае выражение для восстановления сигнала по отсчетам его

дискретного преобразования Фурье (ДПФ), имеет вид [1]

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{j(2\pi/N)kn}, \quad n = 0, 1, \dots, M-1,$$

где  $M$  – длина сигнала,  $N$  – количество отсчетов ДПФ.

Очевидно, что для точного воспроизведения  $M$ -точечного сигнала необходимо выбрать  $N \geq M$ . ДПФ реального сигнала в общем случае является комплексным сигналом, т.е. как и ПФ имеет амплитуду и фазу. Можно показать, что ограниченный непериодический сигнал, имеющий  $z$ -преобразование без обратно сопряженных нулей (под обратно сопряжёнными нулями понимается то, что если  $z_0$  – нуль  $z$ -преобразования, то и  $1/z_0$  также нуль  $z$ -преобразования) однозначно определяется (с точностью до постоянного коэффициента) фазой его преобразования Фурье.

Наиболее часто используемый для решения данной задачи метод имеет ряд недостатков, главный среди которых – большой объем вычислений при вычислении прямого и обратного ДПФ [2].

Мы рассматриваем задачу восстановления сигнала по фазе его ДПФ как задачу аппроксимации, когда на входное воздействие (фаза ДПФ) требуется получить отклик (временной сигнал). Для такой задачи логично использовать нейронные сети (НС), которые позволяют аппроксимировать функции без использования их аналитического или близкого математического вида.

Задача восстановления амплитуды принадлежит к классу задач глобальной аппроксимации, и лучшей нейросетевой структурой для решения подобных задач является, как известно, многослойный персептрон (МП). Из выражений для прямого и обратного ДПФ можно заметить, что для восстановления любого отсчёта сигнала используются все коэффициенты ДПФ (то же самое, разумеется, имеет место и для фазового спектра). Поэтому для решения поставленной задачи нужно использовать полносвязный МП. В предлагаемом варианте использовался полносвязный МП прямого распространения, имеющий входной, выходной и один скрытый слой. Эта сеть приведена на рис.1.




Рис.1. Структура полносвязной сети прямого распространения для решения задачи восстановления амплитуды.

Для каждого нейрона в качестве нелинейной функции активации используется сигмоидная функция, в качестве алгоритма обучения – алгоритм обратного распространения, который, как доказано, устойчив [3].

В среде MATLAB 6.0 (R12) подобная НС может быть смоделирована при помощи функции [4] –

**net = newff(PR,[S1 S2...SNI],{TF1 TF2...TFNI},btf,blf,pf),**

где PR – массив размера  $R \times 2$  минимальных и максимальных значений для  $R$  векторов входа;  $S_i$  – количество нейронов в слое  $i$ ;  $Tf_i$  – функция активации слоя  $i$ , по умолчанию tansig; btf – обучающая функция, реализующая метод обратного распространения, по умолчанию trainlm; blf – функция настройки, реализующая метод обратного распространения, по умолчанию learnqdm; pf – критерий качества обучения, по умолчанию mse; net – объект класса network object – нейронная сеть.

В рассматриваемом случае вызов функции **newff()** выглядит следующим образом:

```
min_max = zeros(16,2);
min_max(:,1) = -pi;
min_max(:,2) = pi;
net = newff(min_max,[16 6],{'logsig','logsig'},'trainbr');
```

при этом нами исследуется случай  $M = 6, N = 32$ .

Поясним ещё раз назначение передаваемых функции **newff()**

параметров. Поскольку входными векторами сети являются вектора, состоящие из первых  $N/2$  отсчётов фазы  $N$ -точечного ДПФ сигнала, который нужно восстановить, то массив `min_max` содержит 16 строк. Так как значения отсчётов фазовых характеристик любого сигнала лежат в интервале  $[-\pi, \pi]$ , то всем элементам первого столбца `min_max` присваиваются значения  $-\pi$ , а второго  $\pi$ . Два числа «16» и «6» (числа могут быть разделены как пробелами, так и запятыми) в квадратных скобках означают, что кроме первого слоя (который выполняет лишь функцию передачи сигналов со всех входов на выходы каждого нейрона следующего слоя) должен присутствовать скрытый слой с 16 нейронами и выходной слой с 6 нейронами. Далее в фигурных скобках указаны функции активации для этих слоёв (название функции – «`logsig`» – взято в одинарные кавычки, разделитель – вновь пробел или запятая) и в конце – алгоритм обучения сети.

Далее для обучения НС (обучение проводилось групповым способом) были сформированы 2 массива, один – массив желаемых выходов – состоящий из 100 сигналов (составляющих столбцы массива) длительностью  $M=6$ , второй – массив входов – состоящий из первых 16 отсчётов фазовых характеристик соответствующих сигналов. Сигналы должны были удовлетворять следующим ограничениям:

- Во-первых, выбирались только неотрицательные сигналы.
- Во-вторых, из случайно генерируемых сигналов отбирались только те, для которых было выполнено условие отсутствия у функции  $z$ -преобразования обратно сопряжённых нулей.

При решении задачи восстановления амплитуды моделируется зависимость между входным воздействием (фаза ПФ сигнала) и откликом (временной сигнал) при помощи нейронной сети. Эта зависимость в общем случае не является гладкой и не может быть хорошо аппроксимирована при помощи МСП. Поэтому необходимо ограничить область рассматриваемых сигналов теми, для которых зависимость между самим сигналом и фазой его ДПФ является гладкой. Такому условию, как раз и удовлетворяет класс сигналов без обратно сопряжённых нулей.

Все сигналы нормировались по энергии. Это не является ограничением, поскольку масштабированием сигнала всегда можно добиться конкретного значения его энергии. Очевидно, что фаза ПФ любого отрезка  $x(n)$  и фаза ПФ любого кратного этому отрезку последовательности  $ax(n)$ ,  $a > 0$ , одинаковы. Таким образом, любая положительно кратная решению задачи восстановления амплитуды последовательность также является решением этой задачи. Чтобы

существовало взаимно однозначное соответствие между фазой ДПФ временного сигнала и самим сигналом, среди всех положительно кратных решений нужно выбрать сигнал единичной энергии и обучать нейронную сеть при помощи сигналов с единичной энергией. Другими словами, для сигналов длительностью  $M$  должно выполняться

$$\sum_{n=0}^{M-1} |x(n)|^2 = 1.$$

Для того, чтобы понять, как целесообразнее выполнять проверку условия, наложенного на функцию  $z$ -преобразования, обратимся к виду последней для сигнала  $x(n)$  длительности  $M$ .

$$X(z) = \frac{x(0) * z^{M-1} + x(1) * z^{M-2} + \dots + x(M-2) * z + x(M-1)}{z^{M-1}} \quad (2)$$

Очевидно, что нули  $X(z)$  совпадают с нулями многочлена, стоящего в числителе (2). Для их вычисления можно воспользоваться стандартной функцией **roots()**. При этом не требуется никакая модификация: если передать функции в качестве аргумента вектор  $x(n)$ , то она возвратит вектор-столбец, состоящий из нулей  $X(z)$ .

После того, как массивы обучающих и целевых векторов были сформированы, проводилось обучение сети. При этом важное значение имеет то, насколько проявится явление переобучения. Наилучшие результаты были получены при использовании функции **trainbr**. Эта функция использует квазиньютоновский алгоритм Левенберга - Марквардта, дополненный методом регуляризации с автоматическим выбором параметра на основе правила Байеса (Bayesian Regularization backpropagation). Функция **trainbr** является одной из наиболее эффективных для устранения явления переобучения в процессе обучения сети. Рассмотрим это явление более подробно.

Явление переобучения заключается в том, что в ряде случаев в процессе обучения мы минимизируем не ту ошибку, которую на самом деле нужно минимизировать; требуется минимизировать ошибку, которая появляется в сети, когда на неё подаются совершенно новые наблюдения. Весьма важно, чтобы НС обладала способностью приспосабливаться к этим новым наблюдениям. Реально сеть обучается минимизировать ошибку на некотором ограниченном обучающем множестве. И это не соответствует той реальной ситуации, когда надо минимизировать конкретную функцию ошибок для заранее неизвестной модели.

При работе с нейронными сетями возникает проблема выбора уровня сложности сети. Сети с большим количеством

настраиваемых весов позволяют воспроизводить очень сложные функции, и в этом смысле они склонны к переобучению. Сеть же с небольшим количеством весов может оказаться недостаточно гибкой, чтобы смоделировать имеющуюся зависимость.

Переобучение проявляется в том, что ошибки обучения на элементах обучающего множества могут оказаться очень малыми, но когда сети предъявляются новые данные, то погрешность существенно возрастает. Это означает, что сеть заучила примеры, но не научилась решать задачу, т.е. приспосабливаться к новым данным.

Для того, чтобы избежать явления переобучения, используют несколько методов. Один из которых – метод регуляризации. Суть его заключается в том, чтобы видоизменять в процессе обучения минимизируемый функционал качества так, чтобы он всегда имел минимум и положение этого минимума непрерывно зависело от параметра регуляризации.

Подобная модификация классического алгоритма обратного распространения позволяет снизить переобучение, но сложность состоит в том, что очень трудно определить оптимальное значение параметра регуляризации. Существует, однако, метод, позволяющий автоматически устанавливать значение этого параметра.

Автоматический выбор параметра регуляризации может быть реализован на основе правила Байеса. Этот подход был предложен Д. МакКейем (D. MacKay) и состоит в том, что веса и смещения сети рассматриваются, как случайные величины с известным законом распределения. Параметр регуляризации связан с дисперсией этого распределения и может быть оценен с использованием статистических методов. Соответствующая процедура регуляризации с использованием правила Байеса и алгоритма Левенберга – Марквардта реализована в виде *M*-функции **trainbr**.

На основании приведённой характеристики легко понять, почему при решении задачи восстановления амплитуды этот алгоритм дал наилучшие результаты. Когда необходимо аппроксимировать подобную зависимость со многими переменными на принципиально бесконечном множестве при помощи НС, то переобучение является серьёзной проблемой, которая может неожиданно проявиться при попытке усложнить структуру сети. Экспериментально было установлено, что увеличение числа нейронов в скрытом слое рассматриваемой сети приводит к снижению ошибки обучения (контролировалась ошибка SSE) и к ухудшению обобщающих свойств сети (эффективность

сети контролировалась по среднему и максимальному значениям среднеквадратичного отклонения сигнала, сгенерированного сетью по фазе ДПФ тестового сигнала от самого этого сигнала), если применяется алгоритм, не использующий регуляризацию; и практически не сказывается на результатах при использовании **trainbr**. Очевидно, мы столкнулись с переобучением. При этом тестировались следующие алгоритмы:

- алгоритмы на основе алгоритма обратного распространения (АОР), или алгоритма градиентного спуска, «классический» алгоритм обратного распространения **traingd**, алгоритм градиентного спуска с возмущением **traingdm**, алгоритм с выбором параметра скорости настройки **traingda**, «упругий» АОР **trainrp**;
- алгоритмы метода сопряжённых градиентов: алгоритм на основе метода Флетчера – Ривса **traincgf**, алгоритм на основе метода Polak – Ribiere **traincgp**, алгоритм на основе метода Powell – Beale **traincgb**;
- одношаговый алгоритм метода секущих **trainoss**, алгоритм Левенберга – Марквардта **trainlm**, алгоритм на основе метода масштабируемых сопряженных градиентов **trainscg**.

При использовании алгоритма **trainbr** ошибка обучения уменьшалась медленно, оставаясь довольно большой, но свойства сети к воспроизведению сигнала, не входящего в обучающее множество после обучения оказывались наилучшими. Ниже приводятся некоторые параметры и результаты тестирования обученной сети:

1. количество проведённых эпох (циклов обучения) – 25;
2. ошибка обучения (SSE) – 0,65;

На рис. 2 приведён результат тестирования сети случайным неотрицательным сигналом единичной энергии без обратно сопряжённых нулей. Приведены тестовый сигнал (этот сигнал не входил в обучающее множество) и сигнал, восстановленный нейронной сетью по фазе ДПФ тестового сигнала. Энергия ошибки вычислялась, как сумма квадратов отклонений двух сигналов

$$E = \sum_{i=0}^{M-1} e_i^2 = \sum_{i=0}^{M-1} (x1(i) - x2(i))^2.$$

На рис. 3 приведён результат тестирования сети 400 сигналами, не входящими в обучающее множество (сигналы неотрицательны, не имеют обратно-сопряжённых нулей и нормированы по энергии). Приведены минимальное, среднее и максимальное значения энергии ошибки. Энергия ошибки вычислялась так же как и в предыдущем случае.




Рис. 2. Соотношение тестового сигнала и сигнала, выдаваемого нейронной сетью.




Рис. 3. Энергия ошибки для 400 сигналов.



Практической ценностью решения данной проблемы является возможность восстановления полезного сигнала из сигнала, представляющего собой свертку полезного сигнала и неизвестного шума.

Это задача может быть решена в случае, когда сигнал помехи имеет преобразование Фурье с нулевой фазой, т.к. в этом случае фазовый спектр полезного сигнала не искажен. Такие ситуации встречаются, например, в случае если изображения, представленные в цифровой форме, размыты известным образом расфокусированными линзами.

### *Литература*

1. *Рабинер Л., Гоулд Б.* Теория и применение цифровой обработки сигналов. М.: Мир, 1978. 848 с.
2. *Olfat A., Soltanian-Zadeh H.* A neural network approach to magnitude retrieval //Signal Processing, V. 81, 2001, P. 1879-1888.
3. *Головкин В.А.* Нейронные сети: обучение, организация и применение. М.: ИПРЖР, 2001. 256 с.
4. *Медведев В.С., Потемкин В.Г.* Нейронные сети. MATLAB 6. М.: Диалог-МИФИ. 2002. 496 с.