



УДК 004.931

БЛОК РАСПОЗНАВАНИЯ РАСТИТЕЛЬНОГО СЫРЬЯ ЭКСПЕРТНОЙ СИСТЕМЫ МОНИТОРИНГА ПОКАЗАТЕЛЕЙ БЕЗОПАСНОСТИ И КАЧЕСТВА ПРИ ПРОИЗВОДСТВЕ КОНСЕРВОВ**Бородихин А.С., Горонков К.А., Руденко О.В., Троянова Т.Л., Усатиков С.В.***ГОУ ВПО «Кубанский государственный технологический университет»,**Краснодар, e-mail: adm@kgtu.kuban.ru;**ГНУ «Краснодарский научно-исследовательский институт хранения и переработки сельскохозяйственной продукции», Краснодар, e-mail: kisp@kubannet.ru*

Рассмотрены нейросетевая и статистическая реализации блока распознавания вычислительного ядра экспертной системы, обеспечивающей возможность принятия решений в системе непрерывного мониторинга показателей безопасности и качества в процессе производства консервов групп А, Б, В и Г. Видеоизображение семян и плодов, подвергнутое спектральному вейвлет-преобразованию, в нейросетевой реализации является входом многослойной нейронной сети, выходной нейрон которой принимает решение об отбраковке и др. В блоке на основе статистических методов распознавания образов вейвлет-спектр проверяется на принадлежность к эталонным эллипсоидам рассеивания.

Ключевые слова: база данных, вейвлет-преобразование, распознавание изображений, зерновые культуры, нейронная сеть

THE BLOCK OF RECOGNITION OF VEGETATIVE RAW MATERIALS OF EXPERT SYSTEM OF MONITORING OF INDICATORS OF SAFETY AND QUALITY BY MANUFACTURE OF CANNED FOOD**Borodihin A.S., Goronkov K.A., Rudenko O. V, Trojanova T.L., Usatikov S.V.***Kuban state technological university, Krasnodar, e-mail: adm@kgtu.kuban.ru);**Krasnodar scientific research institute of storage and processing agricultural production, Krasnodar, e-mail: kisp@kubannet.ru*

Are considered neural network and statistical realizations of the block of recognition of a computing kernel of the expert system providing possibility of decision-making in system of continuous monitoring of indicators of safety and quality in the course of manufacture of canned food of groups A, B, C and D. Video the image of seeds and the fruits, subjected to spectral wavelet -transformation, in neural network realizations is an input of a multilayered neural network, target neuron which the decision on rejection, etc. In the block on the basis of statistical methods of recognition of images makes, the wavelet -spectrum is checked on an accessory to reference ellipsoid dispersion.

Keywords: Database, wavelet-transformation, recognition of images, grain crop, neural network

Системы технического зрения решают задачи по дополнению или замене человека в областях деятельности, связанных со сбором и анализом зрительной информации. Уровень их использования в прикладных областях является одним из наглядных показателей уровня развития высоких технологий в различных отраслях промышленности. Применение систем технического зрения – автоматическая классификация с высокой производительностью по параметрам формы, цвета, размеров плодов, семян и других объектов. В условиях ужесточающейся конкуренции производители вынуждены беспокоиться о качестве используемого сырья и выпускаемой продукции, чтобы производимый продукт пользовался спросом. А на производствах малой и средней мощности, где качество сырья и тестовых заготовок на этапах технологического процесса оценивается «на глаз» и зависит от личного опыта технолога без объективных методов контроля, сложно добиться стабильного качества продукции.

На базе КНИИХП и КубГТУ разработано математическое и программное обе-

спечение производственного представления знаний ЭС, обеспечивающей возможность принятия решений в системе непрерывного мониторинга показателей безопасности и качества в процессе производства консервов групп А, Б, В и Г [1-3].

Решение ряда задач ЭС наиболее эффективно с помощью применения методов нейронных сетей. Как этап технологического процесса инспекция проводится с целью удаления непригодных для переработки семян и плодов, а также посторонних примесей и предметов. В данной работе рассмотрены нейросетевая и статистическая реализации блока распознавания вычислительного ядра указанной ЭС. В нейросетевом блоке видеоизображение семян и плодов, подвергнутое спектральному вейвлет-преобразованию, является входом многослойной нейронной сети, выходной нейрон которой принимает решение об отбраковке и др. В блоке на основе статистических методов распознавания образов, вейвлет-спектр проверяется на принадлежность к эталонным эллипсоидам рассеивания.

Для разработки ЭС непрерывного мониторинга показателей качества и безопасности на консервных предприятиях в данной работе использована оболочка COM-P[ascal], поддерживающая продукционное представление знаний и различные методы аргументации логического вывода – прямой, обратный и смешанный [4]. COM-системы предоставляют разработчикам возможность встраивания компоненты работы со знаниями в виде библиотеки функций

языков Object Pascal Delphi и C++ Microsoft Visual и Borland C++ Builder. Проанализировав и тщательно изучив технологию производства четырёх групп консервной продукции в соответствии с системой НАССР, были выбраны параметры, которые необходимо контролировать для получения качественной и безопасной продукции [2–3]. Параметры ввели в экспертную систему в качестве переменных с заранее заданными диапазонами (рис. 1).

Процент нулей в детализирующем вейвлет-спектре	Горох	Кукуруза	Подсолнечник
Оригинал			
20			
40			
80			
85			
90			
95			
97			
99			
100			

Рис. 1. Влияние количества сохранённых гармоник вейвлет-спектра на качество восстановленного по спектру изображения

Блок распознавания в ЭС включает следующие этапы создания «обучающей» базы данных (БД) для спектрального анализа плоского изображения плодов и последующего распознавания изображений:

1) фотосъёмка плодов на однотонном фоне; для «обучающей» БД – известного сорта, для рабочего режима – сортосмеси, подлежащей распознаванию;

2) применение алгоритмов отделения фона и выделения пиксельных изображений отдельных единичных плодов;

3) установить центр масс объекта, угол поворота относительно начальной системы координат и размеры каждого изображения, перенести начало координат в центр масс объекта и произвести поворот осей координат таким образом, чтобы ось абсцисс проходила вдоль максимального удлинения объекта;

4) нормализовать размеры объекта таким образом, чтобы вне зависимости от разрешения анализируемого изображения геометрические размеры всех объектов совпадали;

5) провести дискретное вейвлет-преобразование цветовых составляющих всех точек (пикселей), принадлежащих выделенной в предыдущих пунктах области; упорядочить полученные коэффициенты; отбросить незначимые элементы полученного упорядоченного массива;

6) для «обучающей» БД – сохранить полученные данные в БД единичных вейвлет-спектров;

7) для нейросетевых (НС) методов распознавания БД единичных вейвлет-спектров является обучающей выборкой. Разработать топологию и провести обучение НС;

8) для рабочего режима вейвлет-спектр элементов сортосмеси, подлежащей распознаванию, подаётся на вход разработанной НС. Выход НС идентифицирует элементы сортосмеси;

9) для статистических методов распознавания построение БД эталонных для каждого сорта эллипсоидов рассеивания;

10) для рабочего режима блока на основе статистических методов распознавания


образов, вейвлет- спектр элементов сортосмеси, подлежащей распознаванию, проверяется на принадлежность к эталонным эллипсоидам рассеивания и определяется вероятность идентификации элементов сортосмеси.

Этапы 1–6, 9 описаны в работах [5–7] и далее не рассматриваются.

На этапе 5 в БД сохраняется изображение объекта размером 64×64 пикселя (см. рис. 1). Для получения спектра применяется алгоритм Малла 5-го уровня. В качестве материнского вейвлета выбран вейвлет Хаара. При расчёте вейвлет-спектра создаются аппроксимация и вертикальные, горизонтальные и диагональные коэффициенты. На пятом уровне разложения ширина и высота аппроксимации становятся равными двум пикселям. Как видно из рис. 2 (100% нулевых коэффициентов детализации в спектре), в этих коэффициентах содержится информация о среднем цвете соответствующих участков исходного изображения. Добавление 1% (99% нулевых коэффициентов) детализирующих коэффициентов позволяет восстановить приблизительную форму исходного изображения. Также проявляются основные цвета участков окраски исходного изображения. Последующее добавление коэффициентов вейвлет-спектра ведёт к уточнению границ объекта и детализации окраски. Детализирующие коэффициенты содержат информацию о разнице цветов соседних участков изображения. Чем выше уровень разложения, тем большие участки изображения описываются соответствующими коэффициентами. Наибольшие различия в цвете наблюдаются на границе объекта, где цвет резко изменяется. Как следствие, коэффициенты, отвечающие за участки изображения, захватывающие границу объекта, имеют более высокие значения, чем вейвлет-коэффициенты, описывающие окраску объекта. По этой причине при последовательном добавлении детализирующих коэффициентов в отфильтрованный спектр в первую очередь восстанавливается форма объекта.



а



б

Рис. 2. а – вариабельность контуров сорта Мастер; б – вариабельность контуров сорта Сур

Рассмотрим результаты нейросетевой реализации блока распознавания вычислительного ядра ЭС.

Первыми объектами исследований являлись сорта подсолнечника. Одним из этапов технологического процесса является разделение масличных культур на сорта и выделение неочищенных зёрен из общей массы. Решение такой задачи классификации осуществлено методами НС. Выбор топологии и обучение НС проведено с помощью известного нейроимитатора STATISTICA Neural Networks (SNN) v.6.0. Данный нейроимитатор позволяет конвертировать построенную сеть в язык C++ и легко интегрировать с экспертной системой. Следует отметить, что противоречивость требований высокой точности распознавания и возможностью настройки на практически любую культуру, существенна только при использовании нейропроцессоров вместо универсальных ЭВМ, т.к. накладываются ограничения на выбор топологии НС. Применение нейроимитаторов, ценой потери скорости распознавания, позволяет оперативно и гибко менять топологию НС.

Для разделения использовались сорта Сур и Мастер, которые относятся к гибридным сортам подсолнечника. Подсолнечник

сорта Сур – это ультраранний сорт подсолнечника с масличностью до 49%, сорт Мастер – высокопродуктивный среднеспелый сорт подсолнечника с масличностью до 54%.

Архитектура сети: многослойный персептрон с 48 входами, одним промежуточным слоем и двумя выходами. Алгоритмом обучения был BFGS 25 (квази-ньютоновский метод), функция активации нейронов – логистическая $f(s) = \frac{1}{1 + e^{-s}}$ (0,1), функция ошибок SOS (равна сумме (взятой по всем наблюдениям) квадратов разностей целевых и фактических значений).

Таблица 1


Матрица классификации для двух сортов

	Мастер	Сур
Всего	46	34
Правильно	46	32
Не правильно	0	2
Правильно %	100	95
Не правильно %	0	5

Наличие ошибки распознавания обосновано высокой вариабельностью сортов, особенно у сорта Сур, (рис. 3).



а



б

Рис. 3. а – вариабельность контуров пригодных зёрен; б – отбракованных зёрен

Отделение очищенного зерна подсолнечника дает 100% распознавание. Архитектура сети – персептрон MLP-100-28-2, алгоритм обучения BFGS 7 (квази-ньютоновский метод), функция активации нейронов – радиальная базисная (гауссова) $f(s) = \exp(-s^2)$ (0,1). Квази-ньютоновский метод – это современный метод обучения многослойных персептронов (Bishop, 1995; Shepherd, 1997). Он подходит для сетей небольшого размера и основывается на предположении о том, что по квадратичной (т.е. имеющей параболическую форму) поверхности ошибок можно двигаться непосредственно в направлении минимума, вычисляя шаг с помощью матрицы Гессе

(матрицы вторых частных производных поверхности ошибок).

Таблица 2

	Сур	Сур очищенный
Всего	48	34
Правильно	48	34
Не правильно	0	0
Правильно %	100	100
Не правильно %	0	0

Следующим объектом исследования были зерна кукурузы (см. рис. 3), которые очень часто используются для консервирования и замораживания. Архитектура сети – многослойный персептрон с 54 входны-

ми нейронами, промежуточный слой из 34 нейронов и один нейрон на выходе. Функция активации нейронов – логистическая $f(s) = \frac{1}{1+e^{-s}}$ (0,1), функция ошибок SOS (равна сумме, взятой по всем наблюдениям, квадратов разностей целевых и фактических значений). Контрольная производительность равна 1, тестовая – 0,928, ошибка обучения – 0,000110.

Таблица 3

	Годные	Не годные
Всего	14	42
Правильно	14	41
Ошибочно	0	1
% правильных	100	97,62
% ошибочных	0	2,38



а



б

Рис. 4. а – вариабельность контуров пригодных зёрен; б – отбракованных зёрен

Таблица 4

	Годные	Не годные
Всего	43	22
Правильно	42	21
Ошибочно	1	1
% правильных	97,67	95,45
% ошибочных	2,33	4,54

Алгоритмы обучения: первый этап – алгоритм обратного распространения в 100 эпох, второй этап – метод сопряженных градиентов. Для обоих этапов применялась затухающая регуляризация весов с параметром 0,01.

Для сравнения рассмотрим результаты статистической реализации блока распознавания вычислительного ядра ЭС. В блоке на основе статистических методов распознавания образов вейвлет-спектр проверяется на принадлежность к эталонным эллипсоидам рассеивания [7]. Проведено распознавание культур гороха, кукурузы и подсолнечника и отделения примесей в тестовых смесях зёрен.

Обучение – алгоритм обратного распространения на 100 эпох и метод сопряженных градиентов с восстановлением сети с наименьшей контрольной ошибкой.

Третьим объектом исследования был консервированный зелёный горошек (рис. 4). Архитектура сети – многослойный перцептрон с 250 нейронами на входе, два промежуточных слоя по 127 нейронов и один на выходе. Функция активации нейронов – логистическая $f(s) = \frac{1}{1+e^{-s}}$ (0,1), функция

ошибок SOS (равна сумме, взятой по всем наблюдениям, квадратов разностей целевых и фактических значений). Контрольная производительность равна 0,937, тестовая – 0,9937, ошибка обучения – 0,00199.

ошибок SOS (равна сумме, взятой по всем наблюдениям, квадратов разностей целевых и фактических значений). Контрольная производительность равна 0,937, тестовая – 0,9937, ошибка обучения – 0,00199.

Таблица 5

	Мастер	Сур
Всего	46	34
Правильно	42	31
Не правильно	4	3
Правильно %	91,3	91,1
Не правильно %	8,7	8,9

Очищенные зёрна подсолнечника показали лучшие результаты:

Таблица 6

Матрица классификации

	Сур	Сур очищенный
Всего	48	34
Правильно	45	32
Не правильно	3	2
Правильно %	93,8	94,1
Не правильно %	6,2	5,9

Результаты распознавания зёрен кукурузы и горошка:



Таблица 7
Матрица классификации

	Кукуруза	Горох
Всего	77	83
Хороших	45	59
Плохих	28	24
Признано хорошими	39 (86,7% хороших зёрен)	52(88,1% хороших зёрен)
Пропущено примесей	1 (3,6% примесей)	0 (0% примесей)
Процент ошибок	9,1	8,4

Таким образом, применение стандартной топологии нейронной сети – многослойного персептрона, без изменения функции активации и функции ошибки, с использованием градиентных методов обучения первого и второго порядка позволило провести достаточно точную оценку качества входной продукции для разных видов овощных и масличных культур. Блок на основе статистических методов распознавания образов показал худшие результаты.

Данная работа выполнена при финансовой поддержке Российского Фонда фундаментальных исследований и администрации Краснодарского края, грант №08-07-99033-р_офи.

Список литературы

1. Шаззо А.Ю. Вопросы разработки вычислительного ядра экспертных систем высокоточного распознавания компонентов и прогнозирования качества при хранении зерновой массы // Юг России: сб. тезисов конф. по-

лучателей грантов регион. конкурса РФФИ и адм. Краснодар. края. – Краснодар: НП ИТЦ «Кубань-Юг», 2008. – С. 177–178.

2. Троянова Т.Л., Усатиков С.В., Михайлюта Л.В. Нейросетевые блоки экспертной системы мониторинга показателей безопасности и качества при производстве соков // Гибридный интеллект: сб. матер.межд.научно-практич. конф. (11 мая 2009г.) – Воронеж: РИО МОУ ВПО ВИЭСУ, 2009. – С. 202–205.

3. Прототип экспертной системы мониторинга показателей безопасности и качества при производстве соков / Т.Л. Троянова, С.В. Усатиков, Л.В. Михайлюта, М.К. Кравцова // Олимпиада-2014: технологические и экологические аспекты производства продуктов питания: сб. матер. межд. научно-практич. конф. – Краснодар: КНИИХП, КубГУ, 2009. – С. 313–314.

4. Иванов Ю.К. Инструментарий для построения мультиплатформенных экспертных систем // Науч. сессия МИФИ-2006: Сб. науч. тр.: в 13 т. – М.: МИФИ, 2006. – Т.3.

5. Усатиков С.В., Руденко О.В., Горонков К.А. О точности распознавания по контуру изображений злаковых культур с помощью нейронных сетей // Обзор. прикл. и пром. математики. – 2009. – Т. 16, Вып. 3 – С. 567–569.

6. Усатиков С.В., Горонков К.А. База данных спектров плоских изображений для высокоточного распознавания сортов зерновых культур // Автоматизир. информ. и электро-энергетич. системы: материалы. I межвуз. научно-практич. конфер. – Краснодар: Изд. Дом-Юг, 2010. – С. 144–146.

7. Горонков К.А., Руденко О.В., Усатиков С.В. База данных обучающей выборки для высокоточного распознавания плоских изображений сортов злаковых и масличных культур // Фундаментальные исследования. – 2011. – №8. – Ч. 2.

Рецензенты:

Камалян Р.З., д.т.н., зав. кафедрой общей и прикладной математики Академии маркетинга и социально-информационных технологий, г. Краснодар;

Семенчин Е.А., д.ф.-м.н., зав. кафедрой Высшей алгебры и геометрии Кубанского государственного университета, МО РФ, г. Краснодар.

Работа поступила в редакцию 12.04.2011.