

Аппаратно-программный комплекс для анализа неоднородного потока объектов в системах фотосепарации реального времени

Э. К. АЛГАЗИНОВ, М. А. ДРЮЧЕНКО, Д. А. МИНАКОВ, А. А. СИРОТА,
В. А. ШУЛЬГИН

Воронежский государственный университет, Воронеж, Россия, e-mail: sir@cs.vsu.ru

Проанализирован неоднородный поток объектов на основе обработки изображений, синтезируемых по результатам построчного сканирования освещенного потока в системах фотосепарации. Описан аппаратно-программный комплекс, функционирующий в реальном времени одновременно с процессом сепарации при совмещенном режиме анализа изображений потока на основе предложенных алгоритмов предварительной обработки и распознавания. Приведены экспериментальные результаты указанных алгоритмов на примере анализа потока элементов зерновых смесей.

Ключевые слова: фотосепарация, распознавание объектов, обработка изображений, нейронные сети.

The nonuniform flow of objects analysis based on image processing is considered. The processed images are synthesized by the results of line-by-line scanning of illuminated flow in the optical sorting systems. The description of implemented hardware-software complex for objects flow analysis based on proposed image preliminary processing and recognition algorithms functioning simultaneously with the real-time separation process in combined mode is presented. The experimental results of proposed algorithms application by the example of grain mixture flow components analysis are described.

Key words: objects optical sorting, objects recognition, image processing, neural networks.

Повышение качества анализа неоднородного (смешанного) потока объектов в системах фотосепарации реального времени возможно в результате интеграции новейших достижений в область электроники, регистрации, обработки видеоизображений, а также с помощью современных компьютерных технологий. Подобные системы фотосепарации находят применение в самых различных областях, однако наиболее широко их используют для автоматического распознавания и сортировки зерновых смесей. В разрабатываемых в настоящее время фотосепараторах реализованы технологии сепарации элементов зерновых смесей (ЭЗС) [1, 2], основанные на разделении объектов в потоке на основе регистрации и анализе диффузно отраженного от их поверхности излучения в одном, двух или трех спектральных диапазонах. Для цифровой регистрации изображений используют линейки ПЗС-фотоприемников с системой воздушных клапанов, способных с высоким быстродействием принимать и исполнять решения об изъятии из потока некондиционных объектов. Учитывая существенные ограничения по быстродействию, для распознавания таких объектов используют правила принятия решений порогового типа, позволяющие в качестве определяющих признаков использовать такие характеристики ЭЗС, как их яркость и поперечные размеры. Новые технологии фотосепарации основаны на внедрении альтернативных спектральных методов анализа ЭЗС, например, формирования спектров люминесценции объектов [3, 4].

Еще одним важным направлением в совершенствовании подобных систем является совмещение режимов сепарации и анализа потока объектов на основе их синтезированных изображений, обработка которых дает возможность получить широкий набор признаков формы, цвета, текстуры объектов для их последующего распознавания. В итоге можно определить реальные характеристики смешанного потока, что позволит решить следующие задачи: оценить состав

исходного материала и настроить пороги принятия решений для одновременно выполняемой сортировки в режиме реального времени, в том числе, и в адаптивном режиме; провести контроль качества сепарации объектов на входе системы для произвольного количества обрабатываемого материала.

Цель данной работы — анализ неоднородного потока объектов на примере ЭЗС с помощью аппаратно-программного комплекса, а также обоснование и исследование алгоритмов обработки синтезированных изображений, обеспечивающих распознавание и определение компонентного состава смеси.

В качестве объектов исследования выбрали три группы ЭЗС с двумя типами объектов: зерна пшеницы продовольственного значения и в качестве примеси — зерна ячменя; ядра семечек подсолнечника и зерна сои; зерна гречихи и овса.

Методика первичной регистрации данных и структура аппаратно-программного комплекса. Первичную регистрацию данных, обработку и анализ изображений неоднородного потока ЭЗС осуществляли в рамках разработанного аппаратно-программного комплекса, интегрированного в состав фотосепаратора и являющегося оригинальной разработкой [5, 6]. Блок-схема аппаратно-программного комплекса представлена на рис. 1.

Комплекс состоит из двух видеомодулей (ВМ), сопряженных с персональным компьютером (ПК). Основным элементом каждого ВМ является приемник изображений, объединенный с вычислительным блоком на основе двухядерного процессора. Приемник представлен высокочувствительным линейным CMOS-сенсором S11108 (Hamamatsu Photonics Co., Япония), содержащим 2048 пикселей размером 14×14 мкм. Максимальная частота строк при выводе всех пикселей линейного сенсора 4,67 кГц. При выводе половины от общего

числа пикселей из средней части сенсора частота строк может достигать 9,3 кГц.

Аналоговые выходные данные от сенсора оцифровываются аналого-цифровым преобразователем и направляются в специализированный процессор обработки сигналов — в двухъядерный процессор BF561 серии Blackfin (Analog Devices Inc., США) [7, 8]. Для разработки программного обеспечения ВМ с данным процессором выбрали интегрированную среду Visual DSP++5.0 с пакетом улучшений Update 9.1. Программное обеспечение для двухъядерного процессора работает в режиме реального времени и осуществляет связь с ПК, управление линейным сенсором изображения, анализ и обработку изображений от линейного сенсора, связь с другими модулями фотосепаратора.

В режиме фотосепарации ВМ предназначен для построчной видеосъемки освещенного потока объектов, падающих со скатного лотка сепаратора, оцифровки видеоданных, обработки кадров-строк изображений по специализированным алгоритмам и выдачи решения о типе годности объектов для их последующего изъятия из потока. Оба ВМ расположены симметрично по отношению к плоскости изображений. Видеомодули фиксируют изображения объектов с противоположных сторон. В качестве коммуникации между ПК и ВМ использован промышленный интерфейс стандарта RS485, а протоколом коммуникации служит Modbus RTU-протокол, в котором компьютер оператора выступает как ведущее устройство, а ВМ — как ведомые.

Одновременно по результатам первичной регистрации в комплексе синтезируются двумерные изображения падающих потоков объектов. Для этого линейный монохроматический сенсор формирует кадры-строки изображений, где каждая строка представляет массив 2048 значений интенсивности (яркости) в оттенках серого цвета каждого пикселя. Диапазон значений яркости имеет 16384 градаций. По параллельному порту кадры-строки один за другим поступают в двухъядерный процессор. По команде от компьютера процессор начинает захватывать и накапливать в специальном буфере памяти SDRAM последовательные кадры, поступающие по параллельному порту. Буфером служит двумерный массив 1024×2048 . После приема всех 1024 строк в определенном Modbus-регистре процессора устанавливается флаг готовности кадра двумерного изображения. Далее ПК может построчно считать это изображение по тому же протоколу. После того, как изображение считано целиком, его можно обрабатывать автономно с помощью описываемых далее программных средств.

Основные этапы обработки изображений неоднородного потока объектов. Реализованный подход к обработке синтезированных цифровых изображений предполагает выполнение следующих этапов:

предварительной обработки и улучшения качества растровых изображений с последующей бинарной сегментацией




Рис. 1. Блок-схема аппаратно-программного комплекса

и локализацией интересующих объектов на основе морфологических преобразований;

определения признаков, описывающих геометрические характеристики формы локализованных объектов, а также статистические характеристики распределения яркости изображений объектов с изъятным сложным фоном;

настройку, обучение и использование в рабочем режиме классификатора многомерных данных, реализованного на основе многослойной искусственной нейронной сети прямого распространения.

Укрупненная блок-схема, отражающая основные этапы процесса обработки, приведена на рис. 2. Рассмотрим каждый из этапов более подробно.

Предварительная обработка и сегментация. С учетом особенностей получения цифровых изображений для приведения присутствующих на них объектов к естественным пропорциям сначала осуществляют вертикальное растяжение кадров в 2—2,5 раза. Далее к изображениям в новом масштабе опционально применяют различные алгоритмы первичной обработки растровых изображений, включающие яркостную коррекцию (нормализацию, эквализацию гистограммы, инвертирование) и подавление шума (Despeckle-удаление пятен, гауссову, медианную, билатеральную фильтрацию, усиление резкости) [9]. Применение данных алгоритмов позволяет устранить мелкие включения, появляющиеся при формировании изображений потока объектов, а также улучшить их качество для визуального контроля результатов распознавания.

Важным этапом, предвещающим применение высокоуровневых алгоритмов обработки изображений и упрощающим их дальнейший анализ, является бинарная сегментация. Для отделения объектов от сложного фона применяют алгоритмы глобальной и локальной бинарной сегментации, в результате работы которых исходные полутоновые изображения, имеющие $N = 256$ уровней яркости, преобразуются в черно-белые. В качестве основного алгоритма глобальной пороговой обработки используют алгоритм бинариза-




Рис. 2. Укрупненная блок-схема процесса обработки изображения потока объектов при реализации нейросетевого классификатора

ции с оптимальным нижним порогом, определяемым методом Otsu [10]. Являясь наиболее простым в вычислительном отношении, данный алгоритм позволяет эффективно отделять распознаваемые объекты от фона. Определенные сложности могут возникнуть при использовании алгоритмов глобальной пороговой сегментации для изображений, гистограммы которых не бимодальны. В таких случаях целесообразно применять алгоритмы локального определения порога бинаризации, при выполнении которых порог вычисляется методом среднего значения в задаваемой окрестности каждого пиксела изображения. При обработке цифровых изображений потока зерновых объектов в качестве основного алгоритма локальной бинаризации используют алгоритм адаптивной сегментации [9].

Предварительный анализ полученных бинаризованных цифровых изображений потока ЭЗС показал, что достаточно распространенным фактом, влияющим на точность результатов распознавания, является появление склеенных объектов. Подобного рода проблемы возникают вследствие наложения контуров объектов в процессе первичной регистрации. При увеличении плотности потока объектов частота их появления возрастает. Для решения задачи разделения склеенных объектов используют итеративный алгоритм, основанный на комбинации двух алгоритмов: морфологичес-

кого предельной эрозии и морфологической дилатации [9]. Алгоритм предельной эрозии применяют для формирования внутренних маркеров, определяющих множество связанных компонентов, принадлежащих отдельным составным частям склеенных объектов. Принцип его работы заключается в итерационной эрозии бинарных изображений объектов с отслеживанием момента, когда объект исчезнет полностью. Маркерами служат те объекты, которые исчезнут в ходе следующей итерации. После определения всех маркеров к каждому из них итерационно применяют обратную операцию — морфологическую дилатацию. Дилатация граничных точек объектов продолжается до тех пор, пока не будут достигнуты границы исходных контуров объектов бинарного раstra, или не возникнет соприкосновение границ соседних объектов. В результате, при корректном определении внутренних маркеров сложный бинарный объект сегментируется на несколько частей. Как показали эксперименты, описанный алгоритм позволяет эффективно разделять склеенные объекты, имеющие незначительную площадь перекрытия. Пример выполнения итерации алгоритма приведен на рис. 3, а.

На заключительном этапе предварительной обработки бинаризованного изображения фильтруют представленные на нем объекты по площади и компактности. Малоразмерные фрагменты (пыль, шумовые пиксели), а также крупные склеенные объекты, которые не удалось разделить, исключают из бинарного раstra, если их площадь

$s_i < \delta^{-1} \bar{s}$, или $s_i > \delta \bar{s}$, где $\bar{s}$ — рассчитанная средняя площадь всех объектов; $\delta = 3$ — коэффициент, определяющий допуск для площади. Из дальнейшего рассмотрения также исключают объекты, обладающие малой компактностью — вытянутые

включения неправильной формы естественного или искусственного (ошибки бинаризации) происхождения.

Далее выполняют наложение и поэлементное перемножение полученной «маски» бинарного изображения и одномасштабного исходного изображения в градациях серого. В результате формируется новое изображение в градациях серого, в котором фактически изымается сложный мешающий фон. Это изображение используют в дальнейшем при формировании окончательного набора признаков распознавания объектов.

Следует отметить, что разнотипный характер потоков объектов, различная производительность устройств первичной регистрации обуславливают неоднозначность выбора перечня используемых алгоритмов предварительной обработки. Эту неоднозначность можно устранить проведением предварительных экспериментов для типовых изображений, содержащих характерные или нехарактерные объекты, в результате чего из реализованного комплекса алгоритмов могут быть выбраны необходимые опции, и на этой основе сформирован индивидуальный сценарий предварительной обработки.

Формирование системы признаков распознавания. Несмотря на естественную фенотипическую изменчивость объектов очевидно, что ЭЗС каждого класса обладают опре-

деленным подобием по форме, яркости, контрастности. Это сходство заложено в основу формирования системы признаков, состав которой в рамках реализованного программного обеспечения может варьироваться, исходя из специфики решаемой задачи. Общий перечень используемых свойств распознавания объектов складывался на основе анализа и обобщения известных подходов, используемых в различных системах анализа изображений. В итоге сформировали набор, состоящий из двух групп: признаков формы, инвариантных к сдвигу, масштабу, повороту и основанных на характеристиках яркости локализованных объектов, которые определяют распределением серых тонов для изображений зерновых культур разных классов. Отметим, что предложенные признаки зависимы и, во многих случаях, избыточны. Однако, поскольку описываемый далее алгоритм распознавания реализован на основе нейронной сети, в процессе ее обучения каждый признак взвешивают и учитывают его влияние на общее качество решения задачи.

Важной информативной характеристикой распознаваемых зерен является их форма. Типовые образцы рассмотренных ЭЗС имеют свои специфические особенности. Так, зерна пшеницы обладают слегка продолговатой, реже продолговато-сфероидальной формой, зерна ячменя эллиптические, заостренные по краям, семена подсолнечника продолговатые, заостренные на одном конце, зерна сои имеют правильную овальную или округлую форму, зерна гречихи — округло-ромбическую, а зерна овса — сильно продолговатую, заостренную по краям форму. Примеры фрагментов синтезированных изображений потока ЭЗС трех типов приведены на рис. 3, б.

В задачах Computervision для распознавания образов двумерных объектов на основе анализа их формы часто применяют нормализованные моменты-инварианты [11]:

$$\eta_{p,q} = \left[\sum_{i=1}^s I(x,y)(x-x_c)^p (y-y_c)^q \right] / \mu_{0,0}^{(p+q)/2+1},$$

$$\mu_{p,q} = \sum_{i=1}^s I(x,y)x^p y^q,$$

где x, y — координаты точки; $I(x, y)$ — вес точки (яркость пиксела); s — число пикселей в пределах границ объекта; $x_c = \mu_{1,0}/\mu_{0,0}$, $y_c = \mu_{0,1}/\mu_{0,0}$ — координаты центра тяжести объекта. При формировании признакового пространства в качестве инвариантных числовых характеристик классифицируемых объектов рассматривали линейные комбинации нормализованных центральных моментов, известные как Ну-моменты [9]. Набор из семи Ну-моментов позволяет получить инвариантное представление контуров, не зависящее от масштаба, вращения и переноса:

$$hu_0 = \eta_{2,0} + \eta_{0,2}; hu_1 = (\eta_{2,0} - \eta_{0,2})^2 + 4(\eta_{1,1})^2;$$

$$hu_2 = (\eta_{3,0} - 3\eta_{1,2})^2 + (3\eta_{2,1} - \eta_{0,3})^2;$$

$$hu_3 = (\eta_{3,0} + \eta_{1,2})^2 + (\eta_{2,1} + \eta_{0,3})^2;$$




Рис. 3. Пример обработки фрагмента изображения, содержащего склеенные объекты, — а и фрагменты синтезированных изображений потока ЭЗС различных типов — б

$$hu_4 = (\eta_{3,0} - 3\eta_{1,2})(\eta_{3,0} + \eta_{1,2})[(\eta_{3,0} + \eta_{1,2})^2 - 3(\eta_{2,1} + \eta_{0,3})^2] + (3\eta_{2,1} - \eta_{0,3})(\eta_{2,1} + \eta_{0,3})[3(\eta_{3,0} + \eta_{1,2})^2 - (\eta_{2,1} + \eta_{0,3})^2];$$

$$hu_5 = (\eta_{2,0} - \eta_{0,2})[(\eta_{3,0} + \eta_{1,2})^2 - (\eta_{2,1} + \eta_{0,3})^2] + 4\eta_{1,1}(\eta_{3,0} + \eta_{1,2})(\eta_{2,1} + \eta_{0,3});$$

$$hu_6 = (3\eta_{2,1} - \eta_{0,3})(\eta_{2,1} + \eta_{0,3})[3(\eta_{3,0} + \eta_{1,2})^2 - (\eta_{2,1} + \eta_{0,3})^2] - (\eta_{3,0} - 3\eta_{1,2})(\eta_{2,1} + \eta_{0,3})[3(\eta_{3,0} + \eta_{1,2})^2 - (\eta_{2,1} + \eta_{0,3})^2].$$

Очевидно, что Ну-моменты можно вычислять как для бинарных изображений, так и для изображений в градациях серого с изъятым сложным фоном. В этом случае яркость отдельных пикселей объектов также будет оказывать влияние на итоговые значения инвариантов. В состав признаков формы ЭЗС дополнительно включались следующие характеристики.

Компактность — характеристика, определяемая отношением площади контура объекта к квадрату его периметра: $d = s/p^2$, где $s = \mu_{0,0}$ — площадь контура, т. е. количество пикселей с яркостью, отличной от фоновой $I(x, y) > 0$; p — количество пикселей, принадлежащих границе области. Объекты с наибольшей компактностью характеризуются достаточно малым количеством граничных точек.

Удлиненность, нецентрированность (эксцентриситет) — характеристика конического сечения контура объекта, показывающая степень отклонения его формы от окружности. Значение эксцентриситета вычисляли по формуле

$$e = \sqrt{1 - r_{\min}^2 / r_{\max}^2}, \text{ где } r_{\min} = \sqrt{(a+c - \sqrt{b^2 - (a-c)^2})/2},$$

$$r_{\max} = \sqrt{(a+c + \sqrt{b^2 - (a-c)^2})/2} \text{ — значения малой и больш-}$$

шой полуосей контура; $a = \mu_{2,0}/\mu_{0,0} - x_c^2$; $c = \mu_{0,2}/\mu_{0,0} - y_c^2$; $b = \mu_{1,1}/\mu_{0,0} - x_c y_c$; $\mu_{0,2}$, $\mu_{2,0}$ — осевые моменты инерции; $\mu_{1,1}$ — центральный момент инерции; x_c , y_c — координаты центра масс контура.

Дисперсионная характеристика контура — характеристика, определяющая степень «изрезанности» контура локализованного объекта, вычисляемая по формуле




Рис. 4. Архитектура нейросетового классификатора

$$\sigma_r = \sqrt{k^{-1} \sum_{i=1}^k (r_i - m_r)^2}, \text{ где } r_i = \sqrt{(x_c - x_i)^2 + (y_c - y_i)^2}, \quad i=1, k —$$

расстояния от центра масс объекта до граничных точек;

x_i, y_i — координаты каждой точки контура; $m_r = k^{-1} \sum_{i=1}^k r_i$.

Для распознавания ЭЗС, обладающих естественной изменчивостью, в большинстве случаев простым анализом формы ограничиться нельзя. Поэтому к перечню приведенных характеристик формы добавили признаки, учитывающие яркостные свойства распознаваемых объектов. В простейшем случае в качестве таких признаков рассматривали статистические моменты интегрального распределения яркости, вычисляемые по одномерной гистограмме значений яркости изображений локализованного объекта F . Вычисляли такие числовые характеристики как энтропия L_1 , «энергия» L_2 , вариация L_3 [12]:

$$L_1 = - \sum_{i=0}^{N-1} F(i) \lg F(i);$$

$$L_2 = \sum_{i=0}^{N-1} [F(i)]^2;$$

$$L_3 = \sum_{i=0}^{N-1} (i - m_F)^2 F(i),$$

где N — количество градаций яркости изображения локализованного объекта; m_F — среднее арифметическое по гистограмме.

Признаки L_1, L_2, L_3 позволяют оценивать лишь интегральные свойства пикселей, входящих в состав изображения. Для учета тонкой структуры изображения использовали статистики, вычисляемые по матрице смежности или матрице распределения градиентов [13, 14]. Матрица смежности V содержит относительные частоты v_{ij} присутствия на изображении соседних элементов, расположенных на расстоянии d друг от друга под углами 0 и 90° (горизонтально-вертикальные) или 45 и 135° (диагональные пары), с яркостями $i, j \in G, G = \{0, 1, \dots, N-1\}$. Признаки, основанные на характеристиках, вычисленных с использованием матриц смежности, рассматриваются в [12, 14]. Для решения задачи

распознавания классов ЭЗС использовали такие статистики на основе матрицы смежности, как «энергия» L_4 , вариация L_5 , однородность L_6 , контраст L_7 , энтропия L_8 :

$$L_4 = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} [V(i, j)]^2;$$

$$L_5 = \sum_{i=0}^{N-1} \left[(i - m_V)^2 \sum_{j=0}^{N-1} V(i, j) \right];$$

$$L_6 = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} [V(i, j)/(1+|i-j|)];$$

$$L_7 = \sum_{k=0}^{N-1} k^2 \left[\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} V(i, j)/U \right];$$

$$L_8 = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (V(i, j)/U) \lg(V(i, j)/U),$$

где m_V — среднее арифметическое матрицы V ; U — общее количество пар, примыкающих друг к другу элементов.

Таким образом, в состав системы признакового описания ЭЗС вошли десять статистических характеристик описания формы и восемь статистических характеристик описания яркости объектов. Известно, что не все из выбранных признаков имеют одинаковую информативность. Разнообразие и неоднородность зерновых смесей не позволили строго формализовать процесс отбора оптимальных признаков, поэтому при проведении экспериментальных исследований использовали либо полную систему признаков, либо набор, сформированный на эмпирической основе. Использование на практике расширенной системы признаков не всегда оправдано, поскольку при малом количестве обучающих примеров снижается качество обучения классификатора.

Обучение и тестирование классификатора. В качестве классификатора при решении задачи распознавания классов ЭЗС, описываемых системой признаков, использовали искусственную нейронную сеть, реализующую двухальтернативное решающее правило: каждый объект может принадлежать только одному из двух классов — «хорошему» или «дефектному». Задачу решали с помощью двухслойной нейронной сети (НС) класса «многослойный персептрон», представленной на рис. 4 [15]. Количество n входных контактов сети определяли числом используемых признаков распознавания, для полной системы признаков $n = 18$. Количество нейронов скрытого слоя m_1 выбирали в диапазоне значений $n \leq m_1 \leq 2n + 1$. Выходной слой сети состоял из одного нейрона, на выходе которого формировалось решение в виде $\text{res} = \text{sign}(y - 0,5)$, где значения $+1, -1$ переменной res соответствуют первому и второму классам объектов.

Матрицу обучающих данных НС определяли в виде $X = \{ \mathbf{x}_1^{(a)}, \mathbf{x}_2^{(a)}, \dots, \mathbf{x}_k^{(a)}, \mathbf{x}_1^{(b)}, \mathbf{x}_2^{(b)}, \dots, \mathbf{x}_{m-k}^{(b)} \}$, где $\mathbf{x}_i^{(a)}, \mathbf{x}_j^{(b)}$ — векторы измеренных значений признаков для распознаваемых объектов первого и второго класса, $i=1, k; j=1, m-k$; k — количество векторов признаков для объектов первого класса; m — объем обучающей выборки. До подачи данных на

НС проводили дополнительное масштабирование обучающих данных по следующему правилу:

$$x_i^{(a)} = 2(x_i^{(a)} - x_{\min}) / (x_{\max} - x_{\min}) - 1, i = \overline{1, k};$$

$$x_j^{(b)} = 2(x_j^{(b)} - x_{\min}) / (x_{\max} - x_{\min}) - 1, j = \overline{1, m-k},$$

где $x_{\min}$, $x_{\max}$ — минимальный и максимальный элементы матрицы X .

Компоненты матрицы X далее подавали на входы НС. Ожидаемые на выходе сети значения определялись компонентами целевой матрицы

$$Z = \{z_1^{(a)}, z_2^{(a)}, \dots, z_k^{(a)}, z_1^{(b)}, z_2^{(b)}, \dots, z_{m-k}^{(b)}\}, i = \overline{1, k},$$

где $z_i^{(a)} = (+1, +1, \dots, +1)$;

$$z_j^{(b)} = (-1, -1, \dots, -1), j = \overline{1, m-k}.$$

Матрицу входных данных для тестирования обученной НС формировали в виде $\bar{X} = \{\bar{x}_1, \bar{x}_2, \dots, \bar{x}_m\}$, где $\bar{x}_i$ — вектор вычисленных значений признаков распознаваемого объекта, $i = \overline{1, m}$. Матрицу $\bar{X}$ нормировали аналогично X . Получаемые на выходе НС данные обозначали как $Y = (y_1, y_2, \dots, y_m)$.

Штучную засоренность зерновой смеси определяли как $G_{\text{экс}} = m^{(b)}/m$, где $m^{(b)}$ — число «дефектных» объектов, m — общее число объектов на изображении. Качество распознавания объектов определяли с помощью оценки вероятности суммарной ошибки распознавания, вычисляемой как $P_{\text{ош}} = m_{\text{ош}}/m$, где $m_{\text{ош}}$ — визуально оцененное число ошибочно классифицированных объектов. Заметим, что при визуальном анализе изображений для оценки $m_{\text{ош}}$ возможны погрешности, поэтому для более точной оценки результатов работы алгоритма распознавания проводили контрольную оценку штучной засоренности физическим подсчетом объектов в каждой тестовой смеси. В таблице приведены результаты оценки процентного состава смешанного потока объектов и вероятности ошибочного распознавания для трех типов зерновых смесей. Результаты получили, анализируя тестовые изображения, синтезированные при двух режимах работы фотосепаратора, обеспечивающие низкую и высокую плотность размещения объектов в кадре. Для первоначального обучения классификатора использовали цифровые изображения каждого класса ЭЗС без примесей. В среднем обучающая выборка включала по 300—500 реализаций векторов признаков для зерновых объектов каждого класса в рассматриваемых смесях. При обучении и тестировании НС использовали полную систему описанных признаков. При изменении характера анализируемых смесей классификатор можно дообучить или переобучить на новых данных без изменения общей схемы организации процесса распознавания.

Наибольшая погрешность (порядка 5—6 %), обусловленная значительной схожестью анализируемых объектов разных классов по форме и распределению яркости, наблюдается для смеси пшеница — ячмень. Для зерновых смесей подсолнечник — соя и гречиха — овес характерно более ярко выраженное визуальное отличие объектов. Расхождения в значениях вычисленной и контрольной штучной засоренности для данных двух групп ЭЗС не превышают 2—3 % даже при высокой плотности размещения сепарируемых объектов, при этом визуально оцененная $P_{\text{ош}} = 1,8—2,5$ %.

Результаты экспериментов показали, что увеличение плотности потока объектов сопровождается ростом частоты появления примесей, связанных с наложением контуров падающих объектов. Это негативно отражается на результате оценки засоренности, увеличивая вероятность ошибочного распознавания объектов в среднем в 1,25 раза. В смесях подсолнечник — соя и гречиха — овес в подавляющем большинстве случаев ошибочное распознавание объектов фиксировали лишь для склеенных объектов, которые не удалось разделить на этапе предварительной обработки.

Практическую реализацию описанных алгоритмов анализа изображений потока объектов выполнили в рамках программного модуля, реализованного на языке C++ с использованием библиотек Qt-4.7.0 и OpenCV-2.2. Функциональные возможности разработанного экспериментального программного модуля позволяют решать следующие задачи: реализовывать комплекс алгоритмов предварительной обработки и бинарной сегментации анализируемых изображений в соответствии с формируемым пользователем сценарием; определять необходимый набор признаков формы и яркости объектов для их последующего распознавания; задавать архитектуру; обучать, тестировать нейросетевой классификатор объектов; сохранять обученную сеть в структурированный файл для последующего ее использования в рабочем режиме; осуществлять детальную настройку параметров реализованных алгоритмов и изменять состав набора признаков описаний, что позволяет оценить влияние отдельных параметров на точность анализа состава смешанного потока объектов; проводить визуализацию результатов предварительной обработки и распознавания объектов.

Программный модуль можно эффективно использовать для проведения полноценного анализа синтезированных изображений смешанного потока объектов и оценки состава сепарируемых смесей с высокой производительностью. Так, на ЭВМ архитектуры x64, 64-bit, CPU: Intel Core i5-2500 3.30 GHz 3.60 GHz, RAM: 4 Gb время выполнения типового сценария предварительной обработки для кадра размером 1024×2048 точек в среднем составляет

Результаты экспериментальной проверки алгоритмов анализа смешанного потока объектов для ЭЗС разных типов

Плотность размещения объектов на синтезированном кадре, m	$G_{\text{экс}}$, %	Контрольные значения штучной засоренности, %	$P_{\text{ош}}$, %
Пшеница — ячмень			
<450	20,24	13,10	5,24
>650	22,54	13,10	6,30
Подсолнечник — соя			
<120	19,63	21,80	1,87
>150	21,26	21,80	2,29
Гречиха — овес			
<150	19,81	17,90	1,80
>400	20,69	17,90	2,42

1600—1700 мс; среднее время формирования полной системы признаков описателей (18 штук) для 500 объектов — 120 мс; тестирование обученного НС-классификатора с определением состава смеси в среднем занимает менее 2 мс для кадра, содержащего 500 объектов.

Работа выполнена при поддержке Министерства образования и науки РФ по программе «Развитие кооперации российских вузов и производственных предприятий» (Постановление Правительства № 218 от 09.04.2010 г., грант № 02.G25.31.002).

Литература

1. **Pat. 5638961 US.** Cereal grain color sorting apparatus / S. Satake, T. Ito, N. Ikeda. 1997.
2. **Pat. 5779058 US.** Color sorting apparatus for grains / S. Satake, T. Ito, N. Ikeda. 1998.
3. **Алгазинов Э. К. и др.** Методы распознавания элементов зерновых смесей по результатам измерения спектральных характеристик в системах сепарации реального времени // Вестник ВГУ. Серия: Системный анализ и информационные технологии. 2013. № 2. С. 9—19.
4. **Алгазинов Э. К. и др.** Методы измерения спектральных характеристик и распознавания элементов зерновых смесей в системах сепарации реального времени // Измерительная техника. 2014. № 1. С. 36—41.
5. **Pat. 8343627 РФ.** Устройство для сортировки зерна по цвету / Г. В. Чуйко и др. // Изобретения. Полезные модели. 2009. № 16.

6. **Pat. 2489215 РФ.** Лазерный сортировщик / Э. М. Бабишев и др. // Изобретения. Полезные модели. 2013. № 22.
7. **Blackfin Embedded Symmetric Multiprocessor.** ADSP-BF561 / Analog Devices. Rev. E. 2009.
8. **Blackfin Processor Hardware Reference.** ADSP-BF561 / Analog Devices. Rev. 1.1. 2007.
9. **Гонсалес Р.** Цифровая обработка изображений / Под ред. Р. Гонсалес, М. Вудс. М.: Техносфера, 2005.
10. **Otsu N.** A threshold selection method from gray-level histograms / N. Otsu. IEEE Trans. Sys. Man. Cyber, 1979.
11. **Dudani S. A., Breeding K. J., McGhee R. B.** Aircraft identification by moment invariants // IEEE Trans. Comput. 1983. V. 1. N. 26. P. 39—45.
12. **Напряушкин А. А.** Алгоритмическое и программное обеспечение системы интерпретации аэрокосмических изображений для решения задач картирования ландшафтных объектов: Автореф. дис. на соиск. учен. степ. канд. техн. наук. Томск, 2002.
13. **Обиралов А. И.** Дешифрование снимков для целей сельского хозяйства. М.: Недра, 1982.
14. **Потапов А. А.** Новые информационные технологии на основе вероятностных текстурных и фрактальных признаков в радиолокационном обнаружении малоконтрастных целей // Радиотехника и электроника. 2003. Т. 48. № 9. С. 1101—1119.
15. **Осовский С.** Нейронные сети для обработки информации. М.: Финансы и статистика, 2002.

Дата принятия 07.03.2014 г.

ИЗМЕРЕНИЯ ВРЕМЕНИ И ЧАСТОТЫ

681.3:529.7

Повышение устойчивости оценок состояния эталонов времени и частоты

Ю. П. ХРУСТАЛЕВ, И. А. СЕРЫШЕВА

Иркутский государственный технический университет, Иркутск, Россия,
e-mail: khrustalev@istu.irk.ru

Рассмотрены причины возникновения неустойчивости оценок состояния эталонов времени и частоты по результатам измерений. Представлены методы повышения устойчивости статистических оценок, полученных на основе использования адаптивных прогнозирующих моделей, а также в режимах статической и динамической обработки данных.

Ключевые слова: эталон времени и частоты, модели авторегрессии, робастность в статистике.

The causes of originations of instability of time and frequency standards estimations by results of measurements carried out in the standards are revealed. The methods of statistics robustness increase in static and dynamic data processing modes and of estimations based on the use of adaptive prognostic models are presented.

Key words: time and frequency standard, autoregression models, robustness in statistics.

Для повышения точности и надежности воспроизведения единиц физических величин создаются их групповые эталоны, функционирующие как единое целое и представляющие сложные аппаратно-программные комплексы. Типич-

ными представителями групповых эталонов являются эталоны времени и частоты. В процессе формирования шкалы времени в них регулярно проводят измерения разностей частот, воспроизводимых элементами группового эталона —