

УДК 621.397: 004.032.26

**МЕТОДЫ РАСПОЗНАВАНИЯ ЭЛЕМЕНТОВ ЗЕРНОВЫХ СМЕСЕЙ
ПО РЕЗУЛЬТАТАМ ИЗМЕРЕНИЯ СПЕКТРАЛЬНЫХ
ХАРАКТЕРИСТИК В СИСТЕМАХ СЕПАРАЦИИ
РЕАЛЬНОГО ВРЕМЕНИ**

Э. К. Алгазинов, М. А. Дрюченко, Д. А. Минаков, А. А. Сирота, В. А. Шульгин

Воронежский государственный университет

Поступила в редакцию 5.05.2013 г.

Аннотация. Рассматривается задача распознавания элементов зерновых смесей на основе измерения спектров люминесценции в интересах повышения эффективности потоковых систем фотосепарации. Для реализации процедур распознавания предложено использовать нейросетевые алгоритмы, а также алгоритмы, реализованные на основе машины опорных векторов. Исследуются характеристики эффективности распознавания с использованием предложенных алгоритмов.

Ключевые слова: методы распознавания образов, системы фотосепарации, нейросетевые алгоритмы распознавания, характеристики спектров люминесценции.

Annotation. The article considers the problem of recognition of elements of grain mixtures on the basis of measurements of the spectra of luminescence in the interests of increasing the efficiency of flow systems fotoseparation. For the realization of procedures of recognition is proposed to use a neural network algorithms and algorithms implemented on the basis of support vector machines. Explores the characteristics of efficiency of recognition using the proposed algorithms.

Keywords: recognition techniques, the system fotoseparation, neural network algorithms to recognize the characteristics of the luminescence spectra.

Введение и постановка задачи. Решение задачи распознавания и сортировки элементов зерновых смесей в ходе обработки потока семян различного качества в системах сепарации реального времени возможно путем интеграции новейших достижений в области компьютерных технологий, электроники, высокоскоростной регистрации и обработки видеоизображений. Одним из перспективных подходов для решения указанной задачи является использование методов глубокого спектрального анализа в сочетании с современными методами обработки регистрируемых данных. Технология сепарации зерновых культур по их цветам реализована в так называемых «традиционных» фотосепара-

торах. Разделение объектов осуществляется на основе анализа отраженного от их поверхности излучения в одном, двух или трех цветовых диапазонах. Наибольшую эффективность сепарации дает анализ отраженного света в нескольких цветовых диапазонах. В этом плане перспективные технологии сепарации могут быть созданы при использовании оптического волокна для суммирования излучения различных лазерных источников. Заложенные в таком решении возможности управления спектральным составом зондирующего излучения существенно расширяет функциональные возможности фотосепараторов.

Вместе с тем, в ряде случаев удаление чужеродных объектов-примесей в общем обрабатываемом потоке зернового материала вызывает затруднения, поскольку их цвет совпадает с цветом объектов [1,2]. В этом случае можно расширить анализируемый спектральный диапазон либо в ИК область (преимущественно до 2,5 мкм), либо в рентгеновский диапазон элек-

© Алгазинов Э. К., Дрюченко М. А., Минаков Д. А., Сирота А. А., Шульгин В. А., 2013

Работа выполнена при поддержке гранта Минобрнауки РФ по программе «Развитие кооперации российских вузов и производственных предприятий» (Постановление Правительства № 218 от 09.04.2010 г. – 3 очередь, № 02. G25.31.0002)

ромагнитного излучения. Однако использование спектральных особенностей объектов в ИК или в рентгеновском диапазоне сопряжено с рядом трудностей, и, прежде всего, необходимостью привлечения существенно более дорогостоящей техники.

Поэтому в этих случаях, по нашему мнению, целесообразно применять метод люминесцентной спектроскопии. Действительно, например, в работах [3,4] показана возможность разделения здоровых семян сои от зараженных вирусом семян (вирусная мозаика сои). Оказалось, что интенсивность люминесценции белков, полифенолов и других веществ существенно зависит от их концентрации. А любое заболевание вызывает аномальное изменение структуры и биохимического состава органических веществ семян. Возможны перспективы применения этого метода и для других зерновых культур. Таким образом, исследование спектров люминесценции позволит в ряде случаев сформировать информативные признаки, на основе которых возможно будет осуществить распознавание элементов здоровых и пораженных зерновых культур в видимом диапазоне в случае, если цвет хороших и дефектных элементов зерновых смесей не отличается.

Целью работы является сравнительный анализ возможностей различных методов и алгоритмов распознавания элементов зерновых смесей на основе измерения характеристик спектров люминесценции. Для проведения сравнительного анализа в ходе исследования рассматривались нейросетевые алгоритмы распознавания и алгоритмы, реализующие метод машин опорных векторов, которые представляют два базовых подхода для построения распознающих систем на основе обучения с «учителем» по «прецедентам» (при отсутствии статистической модели данных).

Методика и результаты спектрального анализа. В качестве метода исследования объектов зерновых смесей в данной работе использован метод люминесцентной спектроскопии. Для управления спектральным комплексом использовалась лицензионная программа SpectraSuite, которая представляет собой модульную программную платформу для спектроскопии, основанную на технологии Java. В качестве объектов исследования были выбраны две группы зерновых смесей. В первой группе «хорошими» объектами были зерна пшеницы, а «плохими» – зер-

на ячменя. Во второй группе хорошими объектами были зерна обрубленного овса, а плохими – зерна необрубленного овса. При этом зерновки в каждой группе практически не отличаются по цвету.

Спектры люминесценции измерялись с использованием экспериментальной установки, созданной на базе волоконно-оптического спектрометра USB4000-VIS-NIR (350 – 1050 нм) фирмы Ocean Optics; схема экспериментальной установки приведена на рис. 1. Данная установка предназначена для регистрации люминесценции различных объектов (твердых тел, порошков, растворов), и в том числе семян и зерновых культур. Реализация данной оптической схемы [5,6] приводит к существенному снижению потерь при прохождении излучения от источника люминесценции до спектрометра.

В качестве источников возбуждения люминесценции использовали лазерный диод, излучающий на длине волны 405 нм. Плотность мощности излучения не превышала 20 мВт/см², для того, чтобы исключить повреждение зерновок. Для доставки возбуждающего излучения и сбора сигнала люминесценции использовалось кварцевое оптоволокно диаметром 600 мкм (QP600, Ocean Optics). Возбуждающее люминесценцию излучение лазерного диода вводилось в волокно с помощью коллиматора, фокусирующей линзы и зеркальной поверхности 4 призмы 1. Конструкция призмы 1 выполнена таким образом, чтобы минимизировать потери при разделении возбуждающего излучения и излучения люминесценции. На передней части коллиматора устанавливались светофильтры Bandpass, вырезающие длинноволновую область излучения лазерных диодов. Коллимированное излучение лазерного диода, после прохождения фокусирующей линзы проходит через плоскую грань внутренней призмы 1 и отражается от зеркальной поверхности 4, нанесенной на ее светоотражающую поверхность, размещенную внутри призмы. Отраженное от зеркальной поверхности излучение выходит из призмы через плоскую грань и фокусируется на торце волновода 2.

Введенное в волновод 2 излучение распространяется по нему и на выходе поглощается исследуемой областью зерновки 3, контактирующей с торцом волновода. При этом излучение люминесценции зерновки вводится в тот же

самый волновод 2. Площадь облучения зерновки и, следовательно, исследуемая область определялась площадью сечения волновода и составляла 600 мкм. Геометрия оптической схемы экспериментальной установки выбрана таким образом, чтобы апертурный угол оптического волновода 2, и, соответственно, апертура пучка излучения люминесценции в области делительной призмы 1 была существенно больше апертурного угла и апертуры светового пучка в области призмы, вводимого в волновод стимулирующего люминесценцию излучения. При этом апертура зеркального покрытия 4, соответствующая апертуре пучка стимулирующего излучения, создана минимальной, что позволяет лишь незначительной части энергии пучка люминесценции отразиться от зеркальной поверхности и не попасть в спектрометр. В результате излучение люминесценции анализируемых областей объектов вводится в волновод с максимальной эффективностью и достигается минимизация потерь излучения люминесценции.

Наряду с излучением люминесценции, по волноводу 2 возвращается и часть стимулирующего излучения, отраженного от объекта 3. Эта составляющая излучения поглощается фильтрами Longpass, которые при этом пропускают излучение люминесценции исследуемых зерновок. Излучение люминесценции попадает на грань призмы, апертура которой согласована с апертурным углом волновода. Нами был выбран многомодовый оптический волновод

(QR600, Ocean Optics), для которого апертурный угол является относительно большим. Вследствие этого на грань призмы попадает широкоапертурный пучок излучения люминесценции, который затем вводится в волновод 5 с помощью линзы и почти без потерь поступает на вход спектрофотометра 6, сопряженного с компьютером 7. Часть излучения теряется вследствие отражения от зеркальной области 4, но поскольку ее площадь минимальна по отношению к площади, ограниченной апертурой пучка люминесценции, проходящего через призму, то эта составляющая незначительна. Таким образом, создана относительно простая, но в тоже время высокочувствительная компактная система, позволяющая регистрировать спектры люминесценции с очень малых областей в реальном масштабе времени.

Измерения проводились в темноте в отсутствие источников рассеянного света. По каждому экземпляру зерновки было зафиксировано около 200 спектров люминесценции. На рис. 2,а представлены усредненные спектры люминесценции зерен пшеницы и ячменя. Анализ всех спектров люминесценции свидетельствует о том, что интенсивность люминесценции зерен пшеницы варьируется в большем диапазоне по сравнению с зернами ячменя, что говорит о большей не однородности зерен пшеницы.

На рис. 2,б. представлены усредненные спектры люминесценции обрушенного и необрушенного овса. Из рисунка видно, что спектры люминесценции обрушенного (кривая 1) и






Рис. 1. Экспериментальная установка для изучения спектров люминесценции



а)



б)

Рис. 2. Спектры люминесценции пшеницы (кривая 1) и ячменя (кривая 2) – (а). Спектры люминесценции обрубленного овса (кривая 1) и необрубленного овса (кривая 2) и кончика обрубленного овса (кривая 3) – (б)

необрубленного овса (кривая 2) представляют собой также составные полосы. Анализ всех спектров люминесценции свидетельствует о том, что интенсивность люминесценции зерен обрубленного овса выше, чем необрубленных. Кроме того, для зерен необрубленного овса обнаружено, что люминесценция по всей площади зерна неоднородна.

Исследование нейросетевых алгоритмов распознавания. С учетом анализа возможных принципов применения нейронных сетей для построения алгоритмов распознавания объектов, во многих случаях можно говорить о возможности замены оптимальных статистических решающих правил их нейросетевыми эквивалентами. [7-12]. Для решения задачи распознавания объектов зерновых смесей в работе использовалась нейронная сеть (НС) класса

МЛР (многослойный перцептрон). Сеть имеет слой входных контактов, количество которых n соответствует количеству используемых признаков распознавания, формируемых на основе компонентов спектров люминесценции, полученных в ходе экспериментальных исследований. Использовалась сеть, имеющая два слоя нейронов, один из которых является скрытым и один – выходным слоем. Количество нейронов в скрытом слое m_1 выбиралось из диапазона значений $n \leq m_1 \leq 2n + 1$. Поскольку рассматривались двухальтернативные задачи распознавания объектов выходной (второй) слой состоит из одного нейрона $m_2 = 1$, который формирует решение в виде $rec = sign(y - 0.5)$, где значения переменной rec , равные +1, соответствуют первому классу объектов, а значения, равные -1, соответствуют второму классу объектов. Для обеспечения инвариантности обработки исходных данных – измеренных спектров люминесценции первоначально проводилась их нормировка по следующей формуле $s_t = s'_t \left(\sum_{i=1}^N s'_i \right)^{-1}$, $t = \overline{1, N}$, где s'_t – изначально регистрируемые значения спектральных компонентов; N – количество спектральных компонентов ($N \approx 3600$), получаемы на установке рис. 1.

В рассматриваемой задаче распознавания использование всех 3600 спектральных составляющих, измеренных по каждому объекту является нецелесообразным. Более того, применение спектральных измерений для систем сепарации реального времени требует минимизации размерности используемого набора спектральных признаков. Поэтому для снижения размерности N выполнялось «прореживание» исходных данных путем усреднения соседних спектральных участков и формирование нового массива спектральных компонент \tilde{s}_p с использованием полученных средних значений:

$$\tilde{s}_p = \sum_{t=ind}^{\Delta} \frac{s_t}{\Delta}, p = \overline{1, n},$$

$$ind = floor\left(\frac{N}{n}\right)(p-1) + 1, \quad (1)$$

$$\Delta = floor\left(\frac{N}{n}\right)p,$$

где $n < N$ – итоговое количество спектральных участков; $floor()$ – операция округления в меньшую сторону.

Обучающие и тестовые множества для НС-классификатора формировались на основе полученных нормированных и усредненных наборов измерений спектров люминесценции для «хороших» и «дефектных» экземпляров зерновок, соответствующих двум классам исследуемых зерновых смесей. Наборы измерений для «хороших» и «дефектных» зерен обозначим как $A = \{A_1, A_2, \dots, A_m\}$ и $B = \{B_1, B_2, \dots, B_m\}$, где $A_i = (a_{i,1}, a_{i,2}, \dots, a_{i,K})^T$ и $B_i = (b_{i,1}, b_{i,2}, \dots, b_{i,K})^T$, $i = \overline{1, m}$ – векторы, каждый элемент которых $a_{i,j} = (\tilde{s}_{i,j,1}^{(a)}, \tilde{s}_{i,j,2}^{(a)}, \dots, \tilde{s}_{i,j,n}^{(a)})^T$, $b_{i,j} = (\tilde{s}_{i,j,1}^{(b)}, \tilde{s}_{i,j,2}^{(b)}, \dots, \tilde{s}_{i,j,n}^{(b)})^T$, $j = \overline{1, K}$ содержит последовательность значений нормированных и усредненных спектров люминесценции, измеренных для i -го образца каждого набора; K – количество измерений для одного образца (в рассматриваемой задаче $K = 300$).

Матрица обучающих данных НС определялась в виде $X = \{x_1^{(a)}, x_2^{(a)}, \dots, x_m^{(a)}, x_1^{(b)}, \dots, x_m^{(b)}\}$, где $x_i^{(a)} = (a_{i,1}, a_{i,2}, \dots, a_{i,\delta})$ и $x_i^{(b)} = (b_{i,1}, b_{i,2}, \dots, b_{i,\delta})$, $i = \overline{1, m}$; δ – длина вектора x_i (выбиралась равной $K/3$). Значения векторов x_i далее подавались на входы НС. Значения, ожидаемые на выходе сети, определялись компонентами целевой матрицы $Z = \{z_1^{(a)}, z_2^{(a)}, \dots, z_m^{(a)}, z_1^{(b)}, \dots, z_m^{(b)}\}$, где $z_i^{(a)} = (+1.0, \dots, +1.0)$, $z_i^{(b)} = (-1.0, \dots, -1.0)$, $i = \overline{1, m}$. Длина вектора z_i равна δ .

Входные и целевые данные для тестирования обученной НС формировались в виде

$\bar{X} = \{\bar{x}_1^{(a)}, \bar{x}_2^{(a)}, \dots, \bar{x}_m^{(a)}, \bar{x}_1^{(b)}, \dots, \bar{x}_m^{(b)}\}$ и $\bar{Z} = \{\bar{z}_1^{(a)}, \bar{z}_2^{(a)}, \dots, \bar{z}_m^{(a)}, \bar{z}_1^{(b)}, \dots, \bar{z}_m^{(b)}\}$, где $\bar{x}_i^{(a)} = (a_{i,\delta+1}, a_{i,\delta+2}, \dots, a_{i,K})$, $\bar{x}_i^{(b)} = (b_{i,\delta+1}, b_{i,\delta+2}, \dots, b_{i,K})$, $i = \overline{1, m}$; $\bar{z}_i^{(a)} = (+1.0, \dots, +1.0)$, $\bar{z}_i^{(b)} = (-1.0, \dots, -1.0)$, $i = \overline{1, m}$; $(K - \delta)$ – длина вектора \bar{x}_i и \bar{z}_i . Получаемые на выходе НС данные обозначались как $Y = \{y_1, y_2, \dots, y_m, y_{m+1}, \dots, y_{2m}\}$. Суммарная вероятность ошибки распознавания объектов зерновой смеси для всех измерений вычислялась путем сравнения значений $y_i = (y_{i,1}, y_{i,2}, \dots, y_{i,K-\delta})$, $i = \overline{1, 2m}$ с соответствующими значениями из целевого набора \bar{Z} по формуле

$$P_{\text{ош}} = \frac{\sum_{i=1}^Q P_i}{Q},$$

$$P_i = \begin{cases} 1, & |y_{i,j} - \bar{z}_{i,j}| < 1 \\ 0, & |y_{i,j} - \bar{z}_{i,j}| \geq 1 \end{cases},$$

$$i = \overline{1, 2m}; j = \overline{1, K - \delta},$$

$$Q = 2m(K - \delta).$$

На рис. 3а приведены зависимости вероятности ошибки распознавания объектов в зерновых смесях «обрушенный – необрушенный овес» и «пшеница – ячмень» от количества анализируемых спектральных участков n . С увеличением числа спектральных участков, участвующих в обучении НС, ошибка распознавания для смесей обоих типов значительно


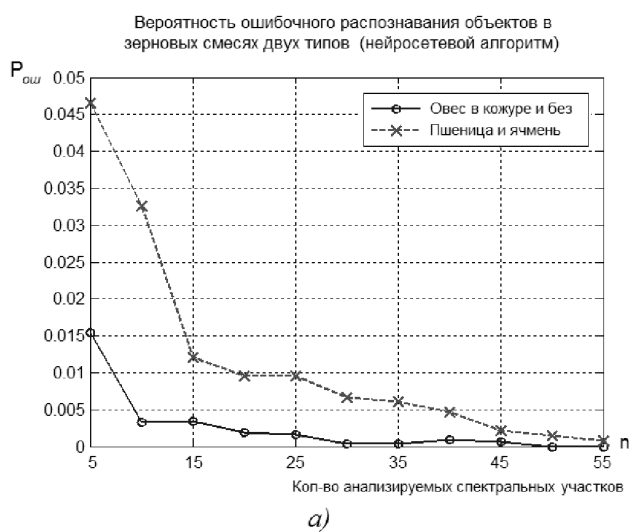


Рис. 3. Зависимость вероятности ошибочного распознавания объектов в зерновых смесях двух типов от количества анализируемых спектральных участков: а) – алгоритм на основе MLP; б) – алгоритм на основе SVM

уменьшается. Однако при этом возрастает количество используемых спектральных признаков, что может отрицательно отразиться на пропускной способности системы распознавания. Приемлемые значения количества анализируемых спектральных участков должны определяться на компромиссной основе с учетом практической реализуемости датчика и обеспечения требуемой вероятности ошибки распознавания.

Для исследования устойчивости нейросетевого алгоритма распознавания к возможному искажению входных данных проводилось искусственное «зашумление» тестовых наборов спектральных участков \bar{X} путем добавления к ним гауссовских возмущений с заданной СКО σ .

На рис. 4 а,б представлены зависимости вероятности ошибочного распознавания объектов в смесях двух типов от количества анализируемых спектральных участков n и СКО искусственно вносимых гауссовских искажений σ . С увеличением СКО искажения σ возрастает процент ошибочно распознанных объектов – в большей степени для смеси «обрушенный – необрушенный овес» (с 0.0025 до 0.034 при $n = 10$), и в меньшей для смеси «пшеница – ячмень» (с 0.033 до 0.086 при $n = 10$). В рамках предложенного подхода к распознаванию уменьшить влияние возмущений можно путем увеличения количества анализируемых спек-

тральных участков. Так, для $n = 50$ НС, обученная для распознавания объектов в смеси «обрушенный – необрушенный овес», позволяет обеспечить вероятность распознавания объектов в присутствии искажений (СКО $\sigma = 0.1$) с ошибкой менее 0.25 %. В то же время, для смеси «пшеница – ячмень» существенного снижения вероятности ошибки при увеличении числа спектральных участков не наблюдается, что связано с худшей сепарабельностью исходных данных соответствующей зерновой смеси. На рис. 4,б вероятность ошибки для пшеницы в несколько раз больше чем для овса на не зашумленных данных, так как форма усредненных спектров люминесценции пшеницы-ячменя практически идентичная (на рис. 2 они различаются в основном по уровню). Однако для разных образцов зерна эти уровни меняются достаточно существенно. В этих условиях выполняемая предварительная нормировка может даже несколько ухудшить результат распознавания. Поэтому можно предложить рассмотреть возможность использования в качестве обучающих и тестовых данных данные, получаемые в поддиапазоне заданной ширины, например, для смеси «пшеница-ячмень» $\lambda = 480 \dots 580$, для смеси «овес» $\lambda = 480 \dots 630$.

Анализ полученных результатов позволяет сделать вывод о том, что нейросетевые алгоритмы позволяют потенциально обеспечить достаточно высокую достоверность распознавания с

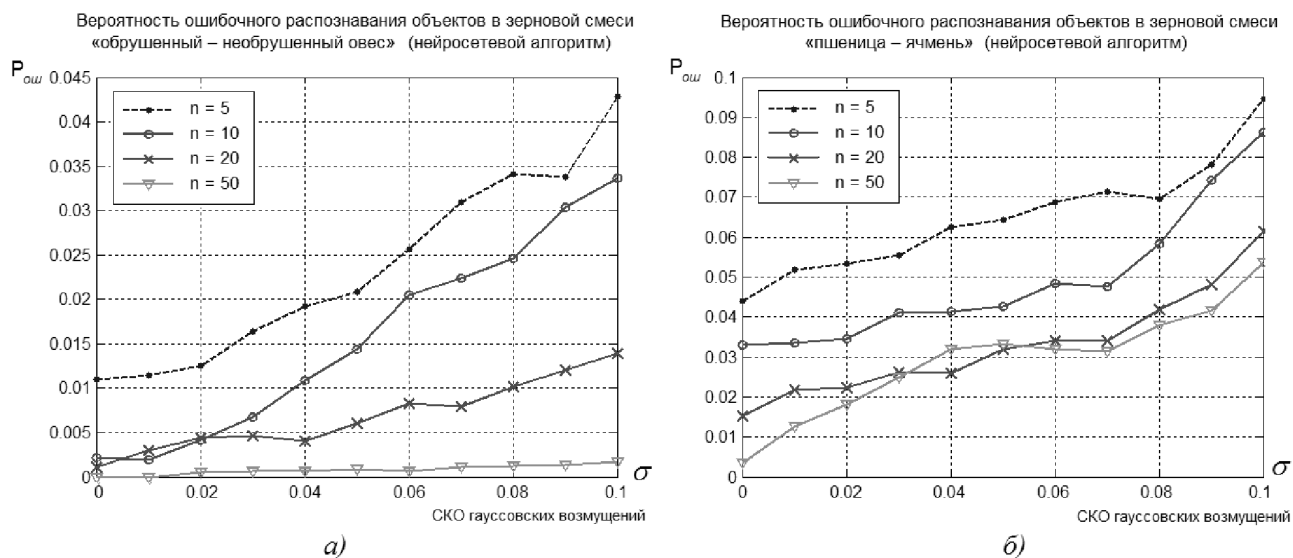


Рис. 4. Зависимость вероятности ошибочной распознавания объектов в зерновых смесях «обрушенный – необрушенный овес» (а) и «пшеница – ячмень» (б) от количества анализируемых спектральных участков и СКО вносимых возмущений

вероятностями ошибки порядка 0.1 % и 0.5 % для зерновых смесей первого и второго типа соответственно. Для учета возможных неспецифических особенностей, возникающих в измеренных спектрах люминесценции, связанных с естественной изменчивостью объектов в рамках одной или нескольких выборок, возможно осуществить процедуру дообучения НС с использованием новых данных или обучить другую НС без принципиального изменения схемы работы самого алгоритма распознавания.

Исследование алгоритмов распознавания на основе машин опорных векторов. Альтернативным подходом к распознаванию объектов, который рассматривался в рамках данного исследования, является использование метода машин опорных векторов (SVM, support vector machine). Метод SVM часто позволяет обеспечить хорошее качество распознавания, работая с абстрактной векторной моделью представления данных [13].

Будем рассматривать задачу распознавания элементов зерновых смесей как бинарную: т.е. каждый распознаваемый объект принадлежит только одному из двух классов – «нормальных» и «дефектных» зерновок. Объекты, как и ранее, описываются измеренными спектрами люминесценции и представляются как векторы (точки) в n -мерном пространстве. В простейшем случае задача разделения векторов по принадлежности к одному из двух классов сводится к задаче поиска разделяющей гиперплоскости (размерности $n - 1$). Очевидно, что вариантов таких гиперплоскостей может быть много, поэтому при реализации метода SVM полагают, что максимизация зазора между классами способствует более уверенной классификации. Такая гиперплоскость называется оптимальной разделяющей гиперплоскостью. Обозначим обучающие данные в виде $\{\tilde{s}_i, k_i\}$, $i = 1, n$, $k_i \in \{-1, +1\}$, \tilde{s}_i – элементы массива усредненных спектральных компонент из (1). Предположим, что имеется гиперплоскость, разделяющая данные двух классов (положительные и отрицательные). Точки \tilde{s}_i , лежащие на гиперплоскости, удовлетворяют условию

$$\langle w, \tilde{s} \rangle + b_0 = 0, \quad (2)$$

где w – перпендикуляр к разделяющей гиперплоскости, $\langle \cdot, \cdot \rangle$ – скалярное произведение, b_0 – вспомогательный параметр, $|b_0| / \|w\|$ – перпендикуляр к гиперплоскости, опущенный из начала координат. Метод опорных векторов

строит классифицирующую функцию F в виде $F(\tilde{s}) = \text{sign}(\langle w, \tilde{s} \rangle + b_0)$. Объекты, для которых $F(\tilde{s}) = 1$ попадают в один класс, а объекты с $F(\tilde{s}) = -1$ – в другой.

Пусть \tilde{s}^- и \tilde{s}^+ – две точки из различных классов, имеющие наименьшее расстояние от разделяющей гиперплоскости до ближайшей точки соответствующего одноименного класса. Считается, что \tilde{s}^- и \tilde{s}^+ лежат на границе «разделяющей» полосы, ширина которой определяется как $(\tilde{s}^- + \tilde{s}^+)$. Задача оптимального разделения в этом случае сводится к поиску «опорных» векторов и гиперплоскостей, ближайших к опорным векторам двух классов и параллельных оптимальной разделяющей гиперплоскости. Несложно показать, что эти гиперплоскости могут быть описаны уравнениями:

$$\langle w, \tilde{s}_i \rangle + b_0 = 1 \quad (3)$$

для $k_i = +1$ и $\langle w, \tilde{s}_i \rangle + b_0 = -1$ для $k_i = -1$.

В случае если обучающая выборка линейно разделима, то гиперплоскости выбираются таким образом, чтобы между ними не лежала ни одна точка обучающей выборки, а затем расстояние между гиперплоскостями (разделяющая полоса M на рис. 5) максимизируется. Для векторов принадлежащих различным классам справедливы следующие ограничения:

$$\langle w, \tilde{s}_i \rangle + b_0 \geq +1 \quad (4)$$

для $k_i = +1$, $\langle w, \tilde{s}_i \rangle + b_0 \leq -1$ для $k_i = -1$

Точки, удовлетворяющие неравенству (4), лежат на границе полосы H_1 с нормалью w и перпендикуляром из начала координат $|1 - b_0| / \|w\|$, а точки, удовлетворяющие неравенству (5), лежат на границе полосы H_2 с противоположной нормалью w и перпендикуляром из начала координат $|-1 - b_0| / \|w\|$. Таким образом, $\tilde{s}^- = \tilde{s}^+ = 1 / \|w\|$ и ширина полосы разделения равна $2 / \|w\|$ [13]. Построение оптимальной разделяющей гиперплоскости сводится к задаче квадратичного программирования, т.е. минимизации квадратичной формы при n ограничениях-неравенствах относительно переменных w, b_0 :

$$\begin{cases} \langle w, w \rangle \rightarrow \min \\ k_i (\langle w, \tilde{s}_i \rangle - b_0) \geq 1, i = \overline{1, n}. \end{cases} \quad (5)$$

По теореме Куна–Таккера [14] эта задача эквивалентна двойственной задаче поиска седловой точки функции Лагранжа:




Рис. 5.

$$\left\{ \begin{aligned} L(w, b_0, \lambda) &= 0.5 \langle w, w \rangle + \\ &+ \sum_{i=1}^n \lambda_i \left(k_i \left(\langle w, \tilde{s}_i \rangle - b_0 \right) - 1 \right) \rightarrow \min_{w, b_0} \max_{\lambda} \\ &\lambda_i \geq 0, \quad i = \overline{1, n}, \\ \lambda_i &= 0 \text{ ; } 8 k_i \left(\langle w, \tilde{s}_i \rangle - b_0 \right) = 1, \quad i = \overline{1, n}, \end{aligned} \right. \quad (6)$$

где $\lambda = (\lambda_1, \dots, \lambda_n)$ – вектор двойственных переменных [14].

На практике случаи линейной разделимости данных гиперплоскостью достаточно редки. Чаще приходится классифицировать линейно неразделимые объекты, (и анализируемые зерновые объекты здесь не являются исключением). Для обобщения алгоритма SVM на случай линейной неразделимости, вводится допущение появления незначительного количества ошибок на обучающих объектах, что позволяет смягчить ограничения (4,5). Задается набор дополнительных переменных $\xi_i \geq 0$, характеризующих величину ошибки на классифицируемых объектах \tilde{s}_i , $i = \overline{1, n}$. Если $\xi_i = 0$, то на \tilde{s}_i ошибки нет, если $0 < \xi_i < 1$, значит объект \tilde{s}_i попадает внутрь разделяющей полосы но корректно классифицируется машиной опорных векторов, если же $\xi_i > 1$, то считается, что на объекте \tilde{s}_i допускается ошибка [15]. С введенными допущениями система (7) переписывается в виде:

$$\left\{ \begin{aligned} 0.5 \langle w, w \rangle + C \sum_{i=1}^n \xi_i &\rightarrow \min_{w, b_0, \xi} \\ k_i \left(\langle w, \tilde{s}_i \rangle - b_0 \right) &\geq 1 - \xi_i, \quad i = \overline{1, n}, \\ \xi_i &\geq 0, \quad i = \overline{1, n} \end{aligned} \right.$$

где C – «управляющий» параметр метода, который позволяет находить компромисс между максимизацией разделяющей полосы и мини-

мизацией суммарной ошибки. Функция Лагранжа для данной задачи имеет вид

$$\begin{aligned} L(w, b_0, \xi, \lambda, \eta) &= 0.5 \langle w, w \rangle - \\ &- \sum_{i=1}^n \lambda_i \left(k_i \left(\langle w, \tilde{s}_i \rangle - b_0 \right) - 1 \right) - \\ &- \sum_{i=1}^n \xi_i \left(\lambda_i + \eta_i - C \right), \end{aligned}$$

где $\eta = (\eta_1, \dots, \eta_n)$ – вектор переменных, двойственных к $\xi = (\xi_1, \dots, \xi_n)$.

Еще один путь решения линейно неразделимых задач заключается в следующем. Все элементы обучающей выборки вкладываются в пространство H более высокой размерности с помощью специального отображения $\varphi : R^n \rightarrow H$. Если пространство H имеет достаточно высокую размерность, то высока вероятность, что в нем выборка окажется линейно разделима. В пространстве H вектора признакового описания объектов \tilde{s}_i заменяются на вектора $\varphi(\tilde{s}_i)$, а само построение машины опорных векторов проводится аналогично описанному выше [15]. Классифицирующая функция F при этом принимает вид $F(\tilde{s}) = \text{sign}(\langle w, \varphi(\tilde{s}) \rangle + b_0)$. В выражении $\text{kernel}(\tilde{s}, \tilde{s}') = \langle \varphi(\tilde{s}), \varphi(\tilde{s}') \rangle$ называется ядром классификатора. С математической точки зрения ядром может служить любая положительно определенная симметричная функция двух переменных. Положительная определенность необходима для того, чтобы соответствующая функция Лагранжа в задаче оптимизации была ограничена снизу, т.е. задача оптимизации была бы корректно определена. От выбора ядра зависит точность классификатора. На практике чаще всего используют следующие ядра: $\text{kernel}(\tilde{s}, \tilde{s}') = \left(\langle \tilde{s}, \tilde{s}' \rangle + \text{const} \right)^d$ – полиномиальные и $\text{kernel}(\tilde{s}, \tilde{s}') = e^{-\|\tilde{s} - \tilde{s}'\|^2 / 2\sigma_{rbf}^2}$, $\sigma_{rbf} > 0$ – радиальные базисные функции.

При проведении экспериментальных исследований алгоритмов распознавания элементов в зерновых смесях двух типов по алгоритму SVM использовались встроенные функции пакета технических вычислений Matlab R2010 `svmtrain()` и `svmclassify()`. На рис. 3б приведены зависимости вероятности ошибочного распознавания объектов методом опорных векторов в смесях «обрушенный – необрушенный овес» и «пшеница – ячмень» от количества анализируемых спектральных участков n . Измерения были выполнены по «прореженным» спектрам люминесценции. На данном графике приведены по две кривые для зерновой смеси каждого типа, полученные при различных значениях параметра функции ядра – σ_{rbf} . Сразу следует отметить, что изменение данного параметра оказывает непосредственное влияние на сложность формы получаемой разделяющей границы. В общем случае увеличение σ_{rbf} сопровождается уменьшением числа опорных векторов и упрощением модели, уменьшение же σ_{rbf} увеличивает количество опорных векторов и усложняет модель. Работа с реальными данными спектров зерновых объектов разной степени однородности предполагает некоторый компромисс между сложностью модели и качеством классификации данных. Слишком простые

модели с большим σ_{rbf} будут плохо распознавать объекты даже по обучающей выборке, в то время как слишком сложные модели, хорошо распознающие обучающие данные, будут с большими ошибками обрабатывать на тестовых выборках. Характер приведенных на рис. 3б зависимостей для метода SVM существенно отличается от зависимостей, полученных для нейросетевого алгоритма.

Для $\sigma_{rbf} = 0.5$ минимальные вероятности ошибки распознавания (порядка 0.3 % для обеих зерновых смесей) наблюдаются при $n = 5$. Увеличение n приводит к резкому увеличению процента ошибок распознавания. Так, при $n = 30$ вероятность ошибочного распознавания элементов в смеси «обрушенный – необрушенный овес» превышает 3 %, а для смеси «пшеница – ячмень» – 4 %. Для SVM модели с меньшим числом опорных векторов ($\sigma_{rbf} = 1$) при $n \leq 30$ средняя вероятность ошибочного распознавания составляет порядка 0.3 % и 0.2 % для смесей «обрушенный – необрушенный овес» и «пшеница – ячмень» соответственно. Дальнейшее увеличение размерности признакового описания снижает общую достоверность распознавания. Сравнение точности распознавания объектов при различных значениях n для НС и SVM дает следующие резуль-

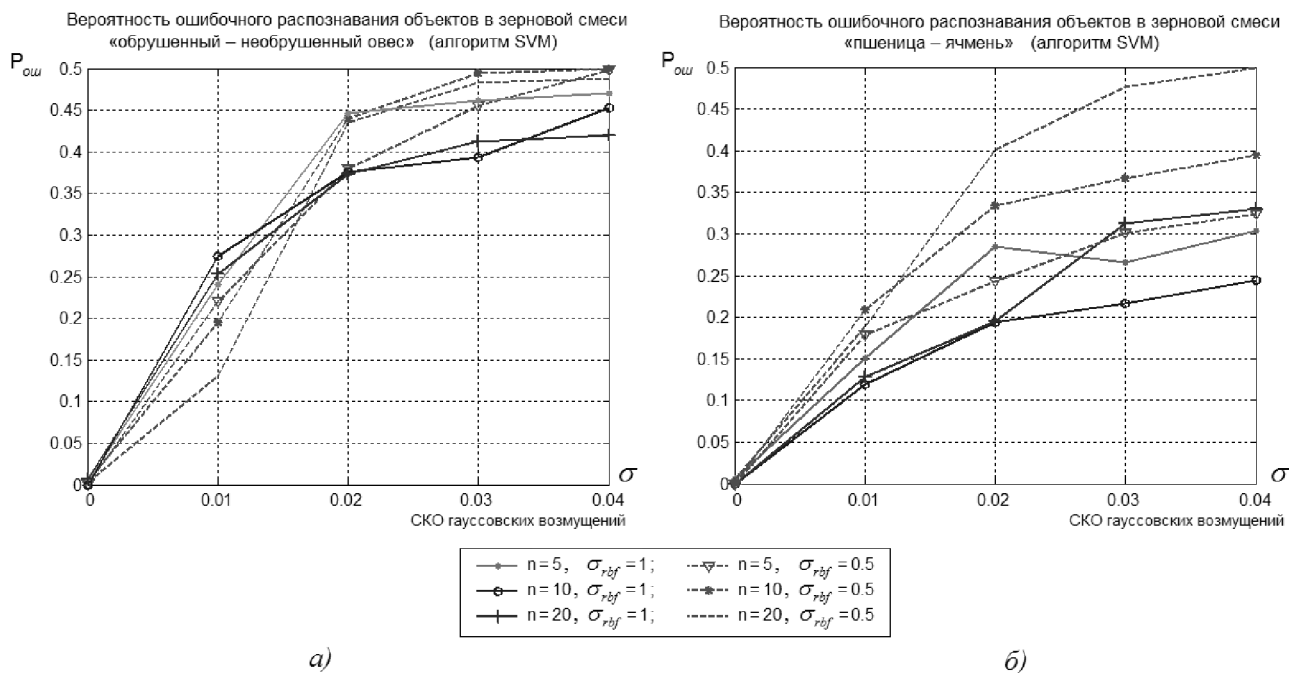


Рис. 6. Зависимости вероятности ошибочного распознавания объектов в зерновых смесях «обрушенный – необрушенный овес» (а) и «пшеница – ячмень» (б) от количества анализируемых спектральных участков, СКО вносимых гауссовских возмущений и параметра функции ядра σ_{rbf}

таты. Для смеси «обрушенный – необрушенный овес» при $n \leq 20$ метод опорных векторов ($\sigma_{rbf} = 1$) оказывается эффективнее с $P_{\text{ош}} \approx 0.2\%$, при $n > 20$ лучшую эффективность показывает нейросетевой алгоритм с $P_{\text{ош}} < 0.1\%$. Для смеси «пшеница – ячмень» при $n \leq 35$ метод опорных векторов ($\sigma_{rbf} = 1$) оказывается эффективнее с $P_{\text{ош}} \approx 0.25\%$, при $n > 35$ лучшую эффективность показывает нейросетевой алгоритм с $P_{\text{ош}} < 0.3\%$.

Для исследования устойчивости алгоритма распознавания на основе метода опорных векторов к возможному искажению входных данных, аналогично проводилось искусственное «зашумление» тестовых наборов спектральных участков. Результаты оценки вероятности ошибки распознавания объектов в смесях двух типов в присутствии гауссовских искажений приведены на рис. 6. С увеличением количества анализируемых спектральных участков в присутствии искусственных искажений наблюдается неприемлемый рост процента ошибок распознавания (при $\sigma = 0.01$ $P_{\text{ош}} > 20\%$ для смеси «обрушенный – необрушенный овес» и $P_{\text{ош}} > 15\%$ для смеси «пшеница – ячмень»), обуславливаемый прежде всего характером исходных данных (схожестью признаков описаний для объектов различных классов, полученных по усредненным спектрам люминесценции).

Вне зависимости от числа анализируемых спектральных участков и значения параметра функции ядра σ_{rbf} , приемлемые вероятности ошибки распознавания фиксируются алгоритмом лишь в отсутствие искусственно вносимых возмущений, из чего можно сделать вывод о нецелесообразности использования данного алгоритма распознавания возможности появления существенных помеховых искажений данных спектральных измерений.

В целом анализ полученных результатов позволяет сделать вывод о том, что рассмотренные алгоритмы позволяют потенциально обеспечить достаточно высокую достоверность распознавания элементов в исследованных зерновых смесях. Достоинством нейросетевого алгоритма является его большая устойчивость к возможным неспецифичным изменениям характера входных данных спектров люминесценции и отражения, связанных с естественной изменчивостью объектов в рамках одной или нескольких выборок. При использовании искусственных

нейронных сетей всегда существует возможность осуществления процедуры их дообучения с использованием новых данных или обучения новой сети без принципиального изменения схемы работы самого алгоритма распознавания. Также следует отметить возможность повышения качества распознавания объектов по измеренным спектрам за счет увеличения размерности представления входных данных.

При исследовании применимости метода SVM в качестве его преимущества по сравнению с нейросетевым подходом является возможность достижения малых ошибок при небольшой размерности исходного признакового пространства. В то же время следует отметить относительно более существенное снижение достоверности распознавания на основе SVM при возникновении шумовых искажений.

СПИСОК ЛИТЕРАТУРЫ

1. Satake S., Ito T., Ikeda N. Cereal grain color sorting apparatus // US Patent 5,638,961. Jun. 17, 1997.
2. Satake S., Ito T., Ikeda N. Color sorting apparatus for grains // US Patent 5,779,058. Jul. 14, 1998.
3. Трубицын А.Г. Способ выделения здоровых семян сои // Патент RU №1205330. 1994 г.
3. Трубицын А.Г. Устройство для отбора здоровых семян сои // Патент RU №1695840.
5. Сарычева И.Н., Янушевич О.О., Минаков Д.А. и др. // Российская стоматология. – 2012. – № 3. – С. 50–56.
6. Сарычева И.Н., Янушевич О.О., Минаков Д.А. и др. // РФ Патент №: 2464549. – 2011. – С. 1–6.
7. Ефименко В.С. Применение нейронных сетей в задачах оптимальной фильтрации / В.С. Ефименко, В.Н. Харисов, Е.Г. Стребков // Радиотехника. – 2000, № 7. – С. 56–61.
8. Сирота А.А. Нейросетевые и статистически оптимальные алгоритмы принятия решений в задачах высокоточной координатометрии и обработки изображений / А.А. Сирота, Э.А. Кирсанов, О.В. Маслов // Сборник трудов III Международной конференции «Идентификация систем и задачи управления» – М.: Институт проблем управления им. В.А. Трапезникова РАН, 2004. – С. 1629–1652.
9. Кирсанов Э.А. Обработка информации в пространственно-распределенных системах радиомониторинга: статистические и нейросетевые подходы / Э. А. Кирсанов, А.А. Сирота. – М.: ФИЗМАТЛИТ, 2012, 344 с.
10. Татузов А.Л. Нейронные сети в задачах радиолокации / А.Л. Татузов. – М.: Радиотехника, 2009. – 432 с.
11. Перов А.И. Особенности синтеза устройств обнаружения и оценки параметров сигнала нейро-

сетевыми методами / А.И. Перов, Г.Г. Соколов // Радиотехника. – 2001, № 7. – С. 22–29.

12. Фролов И.И. Построение классификатора на основе машины опорных векторов для распознавания символов / И.И. Фролов, Р.Х. Садыхов. // Доклады БГУИР. – 2008, № 1. – С. 103–108.

Алгазинов Э. К. – д. ф.-м. н., профессор, заведующий кафедрой Информационных систем, факультета компьютерных наук, Воронежский государственный университет. Тел. (4732)208-724. Тел. (4732)208-724. Email: algazinov@cs.vsu.ru

Дрюченко М. А. – к. т. н., ассистент кафедры технологий обработки и защиты информации ВГУ. Email: m_dryuchenko@mail.ru

Минаков Д. А. – к. ф.-м. н., доцент кафедры физики и химии, Военный учебно-научный центр Военно-воздушных сил «Военно-воздушная академия имени профессора Н.Е. Жуковского и Ю.А. Гагарина» (г. Воронеж).

Сирота Александр Анатольевич – д. т. н., профессор, заведующий кафедрой Технологий обработки и защиты информации, факультета компьютерных наук, Воронежский государственный университет. E-mail: sir@cs.vsu.ru

Шульгин В. А. – к. т. н., старший научный сотрудник кафедры информационных систем ВГУ.

13. Ларин Р.М. Методы оптимизации. Примеры и задачи / Р.М. Ларин, А.В. Плясунов, А.В. Пяткин // Учеб. пособие. Новосиб. ун-т., 2003, – 115 с.

14. Scholkopf B. Advances in Kernel Methods. Support Vector Learning / B. Scholkopf, C.J.C. Burges, A.J. Smola // MIT Press, Cambridge, USA, 1998, – 376 p.

Algazinov E. K. – doctor of Physics-math. Sciences, Professor of the dept. of the Information Systems, Voronezh State University, Tel. (4732)208-724. Email: algazinov@cs.vsu.ru

Dryuchenko M. A. – Candidat of Technical Sciences, Assistant Professor, Chair of Information Processing and Security Technologies, Voronezh State University. Email: m_dryuchenko@mail.ru

Minakov D. A. – Candidat of Physics-math. Sciences, Associate Professor, Department of Physics and Chemistry, MESC of the Air Force «Force Academy named after Professor Zhukovsky and Gagarin».

Sirota A. A. – Doctor of Technical Sciences, Professor, Department of Processing technology and information security, Voronezh State University. E-mail:sir@cs.vsu.ru

Shulgin V. A. - Senior Researcher, Chair of Information Systems, Voronezh State University.