

УДК 004.931:664

ОБ ОСОБЕННОСТЯХ ВЕЙВЛЕТ-СПЕКТРА ПЛОСКОГО ИЗОБРАЖЕНИЯ КАК ПРИЗНАКОВОГО ПРОСТРАНСТВА В СТАТИСТИЧЕСКИХ МЕТОДАХ РАСПОЗНАВАНИЯ¹

Горонков К. А.², Усатилов С. В.³

ABOUT THE FEATURES OF THE WAVELET SPECTRUM AS A FLAT IMAGE FEATURE SPACE FOR
STATISTICAL PATTERN RECOGNITION METHODS

Goronkov K. A., Usatikov S. V.

The methods of identification with a given accuracy of the mass of objects of natural origin, with high intraclass variability of the visual, the proximity of the classes themselves are considered. In particular, the problems of rapid diagnosis of latent infection of grain by insects in bulk grain and legumes. Theoretical and experimental studies with a variety of statistical classifier that uses pattern recognition algorithm to construct the ellipsoid scattering in the feature space (with a normal distribution), and the degeneracy of the covariance matrix characteristics and features of the spectrum of the wavelet feature space for expansion, were held. Proposed use of the degeneracy of the covariance matrix of the wavelet spectrum of a flat image to improve recognition.

Keywords: statistical methods for pattern recognition, wavelet spectrum, the diagnosis of hidden insect infestation of grains and legumes.

Анализ фото- и видеоинформации системами технического зрения (СТЗ) в пищевой и перерабатывающей промышленности необходим в таких задачах, как автоматическая классификация с высокой производительностью по параметрам формы, цвета, размеров плодов, семян и других объектов; экспресс-диагностика скрытой зараженности зерна насекомыми, в массе зерновых и бобовых. Для повышения эффективности функционирования СТЗ необходимо постоянно пополнять арсенал методов и средств предварительной обработки изображения и построения классификаторов, сочетающих требуемые показатели по быстродействию и достоверности идентификации. Статистические методы в сочетании с методами спектрального анализа обладают рядом достоинств для решения актуальной задачи массового распознавания с требуемой точностью плоских цифровых изображений объектов природного происхождения, с высо-

кой визуальной внутриклассовой вариабельностью, при близости самих классов [1–4].

В данной работе рассмотрены методы массовой идентификации с заданной точностью объектов природного происхождения. Проведены теоретические и экспериментальные исследования с разновидностью статистического классификатора, использующего в алгоритме распознавания построение эллипсоида рассеяния в признаковом пространстве (при нормальном распределении), а также вырожденности матрицы ковариации признаков и особенностей вейвлет-спектра для расширения признакового пространства. Предложено применение вырожденностей ковариационной матрицы вейвлет-спектра плоского изображения для повышения эффективности распознавания.

Разработанное программное обеспечение реализует следующий алгоритм оптического распознавания, включающий этапы (рис. 1, 2):

¹Работа выполнена при финансовой поддержке Российского Фонда фундаментальных исследований и администрации Краснодарского края (11-08-96519-р_юг_ц).

²Горонков Константин Александрович, аспирант кафедры общей математики Кубанского государственного технологического университета; e-mail: e_2.71828@mail.ru.

³Усатилов Сергей Васильевич, д-р физ.-мат. наук, профессор кафедры общей математики Кубанского государственного технологического университета; e-mail: sv@usatikov.com.




Рис. 1. *а* — Примеры NIR-изображений скрытой заражённости пшеницы (*а*) размером 640×480 пикселей, при длине волны $1305,05$ нм: *1* — пшеница, заражённая долгоносиком, *2* — мукоедом, *3* — точильщиком, *4* — хрущак, *5* — здоровая пшеница; *б* — пример обработки фрагмента кадра (объекты отделены от фона, определены реальные размеры) для скрытой заражённости пшеницы

– получение кадра с изображением объектов;

– обработка кадра: *а* — определение границ объектов; *б* — поворот изображений объектов; *в* — режим «калибровки», сохранение в «обучающей» базе данных (БД) выборочных наблюдений;

– в режиме «калибровки» создание «эталонной» БД; *а* — отбор экспертом эталонной выборки; *б* — получение векторов признаков отобранных объектов; *в* — статистическая обработка: определение эллипсоида рассеивания (в случае нормального распределения), матрицы ковариации, маски признаков, списка линейных зависимостей; *г* — ассоциация эталона с классом объектов и сохранение в БД эталонов;

– идентификация неопределённых объектов: *а* — получение векторов признаков неустановленных объектов; *б* — сравнение полученных векторов с векторами признаков из «эталонной» БД.

Объекты природного происхождения могут быть несимметричными. Снятые на изображении с разных сторон, они меняют форму распределения: появляется бимодальность (рис. 2в), существенно искажая исходное распределение. В этом случае необходимо разделить эталонную выборку на две, и поскольку обе выборки по-прежнему описывают одну и ту же генеральную совокупность, попадание в любую из них означает принадлежность к данному классу. Обнаружить отклонение от унимодальности можно, применив к гистограмме исходной выборки метод Оцу и разделить её на две гистограммы; далее определить моду каждой из полученных гистограмм; проверить, совпадает ли мода хотя бы одной из полученных гистограмм с порогом

бинаризации. Если хотя бы одна совпадает с этим порогом, следует считать выборку унимодальной, в противном случае — не унимодальной.

В статье приняты следующие обозначения:

$a_{c,r}$ — аппроксимирующие коэффициенты вейвлет-спектра;

$d_{c,r}^H$ — горизонтальные детализирующие коэффициенты вейвлет-спектра;

$d_{c,r}^V$ — вертикальные детализирующие коэффициенты вейвлет-спектра;

$d_{c,r}^D$ — диагональные детализирующие коэффициенты вейвлет-спектра;

LL — фильтр-матрица аппроксимирующих коэффициентов;

LH — фильтр-матрица горизонтальных детализирующих коэффициентов;

HL — фильтр-матрица вертикальных детализирующих коэффициентов;

HH — фильтр-матрица диагональных детализирующих коэффициентов;

\mathbf{x} — точка пространства (вектор);

$\mu_{\mathbf{x}}$ — центр рассеяния (вектор мат. ожиданий);

V — ковариационная матрица;

E — единичная матрица размером $n \times n$;

F_{KP} — заданный процент выборки;

KP — коэффициент пропорциональности эллипсоида, охватывающего заданный процент выборки;

Et — эталонная выборка, S_{et} — её размер;

MD — максимальное расстояние между объектом обучающей выборки и центроидом обучающей выборки;

x_k^* — наблюдаемое значение признака;

x_k — расчётное значение признака;

l_{max} — максимальное отклонение наблюдаемого значения признака от расчётного.

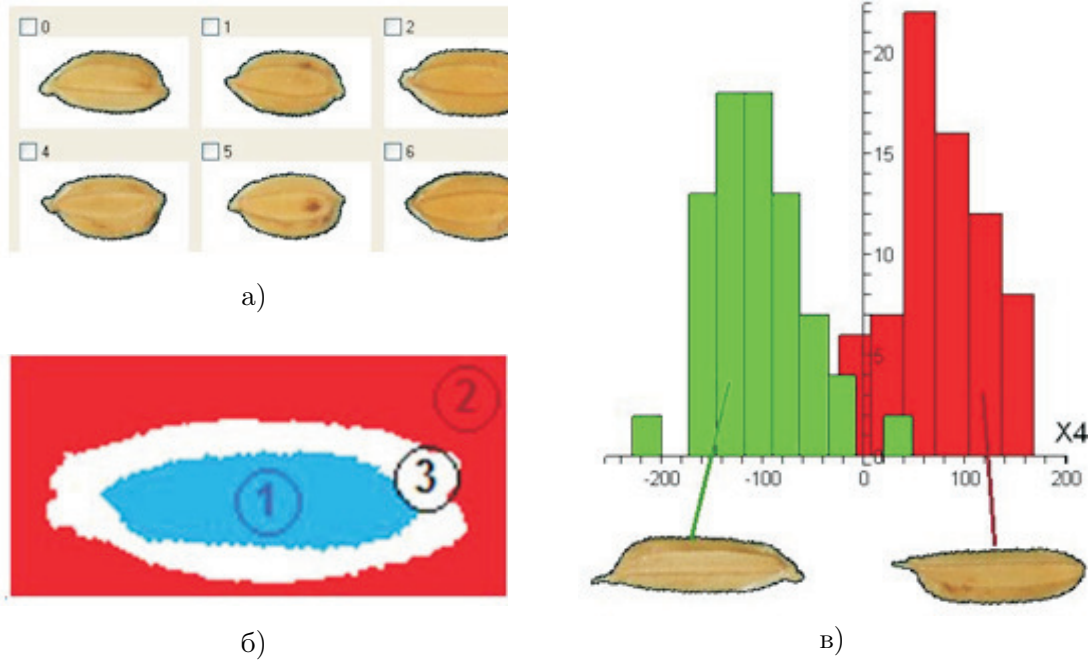


Рис. 2. а — «обучающая» БД дискретных вейвлет-спектров единичных зёрен риса; б — статистические свойства изображения сорта Изумруд культуры риса: область 1 — захватывается всеми объектами обучающей выборки, область 2 — не захватывается ни одним объектом, 3 — попадание случайно; в — пример бимодального распределения 4-й гармоники

После отбора «обучающих» образцов для каждого наблюдения вычисляется вектор признаков, состоящий из гармоник спектра вейвлет-преобразования плоского изображения

$$a_{c,r} = \sum_{h=0}^{PH} l(2r-h) \sum_{w=0}^{PW} l(2c-w) f_{w,h},$$

$$d_{c,r}^H = \sum_{h=0}^{PH} l(2r-h) \sum_{w=0}^{PW} h(2c-w) f_{w,h},$$

$$d_{c,r}^V = \sum_{h=0}^{PH} h(2r-h) \sum_{w=0}^{PW} l(2c-w) f_{w,h}, \quad (1)$$

$$d_{c,r}^D = \sum_{h=0}^{PH} h(2r-h) \sum_{w=0}^{PW} h(2c-w) f_{w,h},$$

$$c = 0 \dots \frac{PW}{2} - 1, \quad r = 0 \dots \frac{PH}{2} - 1.$$

Применяется вейвлет Хаара. Комбинации фильтров, которые используются при вычислении коэффициентов, представляются в виде фильтров-матриц (рис. 3):

Как видно из (1) и рис. 3, коэффициенты вейвлет-спектра представляют собой линейные комбинации значений пикселей. На

границе объекта фильтр-матрица может захватит лишь часть изображения объекта. Например, в случае с верхней границей объекта, $X_0 = 0$, $X_1 = 0$. Тогда измерения становятся зависимыми: $a = d^H$, $d^V = -d^D$ — а форма распределения искажается. Анализ таких распределений сильно затруднён, поэтому при создании эталона не учитываются коэффициенты вейвлет-спектра, полученные на границе объекта. В качестве критерия принадлежности к какому-либо классу используется проверка на попадание вектора признаков объекта в доверительную (99% и выше) область пространства признаков:

$$\int_{G_{1,a}(x_1, \dots, x_n)} \dots \int_{G_{n,b}(x_1, \dots, x_n)} f(x_1, \dots, x_n) \times dx_1 \dots dx_n = F_{KP}, \quad (2)$$

где $F_{KP} \in (0; 1)$ — заданная доля выборки; $G_{i,a}(x_1, \dots, x_n)$ и $G_{i,b}(x_1, \dots, x_n)$ — искомые функции пределов интегрирования, а $f(x_1, \dots, x_n)$ — функция плотности вероятности произвольного распределения. При гипотезе о нормальности распределения вектора признаков \mathbf{x}

$$f(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^n |\mathbf{B}|}} e^{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu}_x)^T \mathbf{B}^{-1}(\mathbf{x}-\boldsymbol{\mu}_x)}. \quad (3)$$

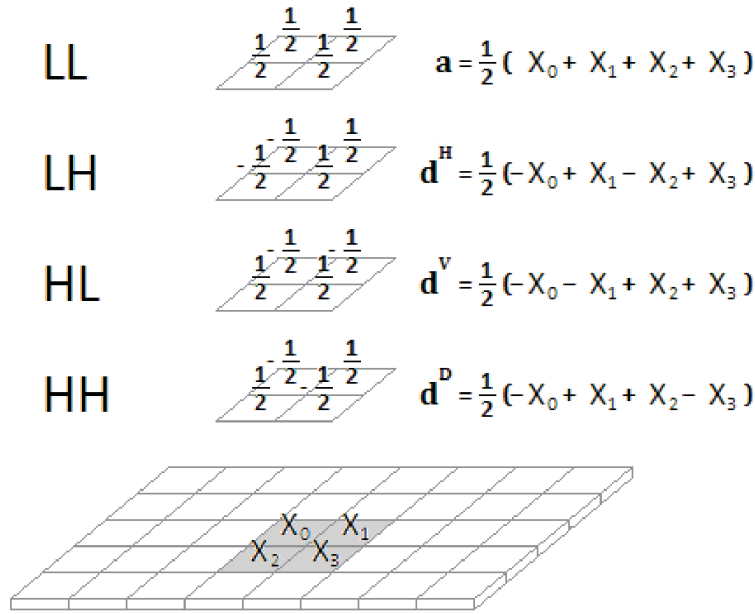


Рис. 3. Схема применения фильтров-матриц

Между признаками, оставшимися после их отсеивания на границе объекта, могут существовать множественные линейные зависимости. Мультиколлинеарность признаков делает матрицу ковариации \mathbf{B} вырожденной (в вычислениях — плохо обусловленной). Для выявления этих множественных зависимостей \mathbf{B} преобразуется к диагональному виду с помощью элементарных преобразований над строками по методу Якоби

$$b_{k,i} = cb_{k,i} + sb_{l,i},$$

$$b_{l,i} = -sb_{k,i} + cb_{l,i},$$

где

$$c = \frac{b_{k,k}}{\sqrt{b_{k,k}^2 + b_{l,k}^2}}, \quad s = \frac{b_{l,k}}{\sqrt{b_{k,k}^2 + b_{l,k}^2}},$$

$$k = 1 \dots (n-1), \quad l = (k+1) \dots n,$$

$$i = k \dots n.$$

Использование метода Якоби более оправдано, поскольку он не вызывает лавинообразного увеличения модулей коэффициентов, характерного для метода Гаусса.

Если представить матрицу \mathbf{B} в виде вектор-столбца $\mathbf{B} = (\mathbf{B}_1, \dots, \mathbf{B}_n)^T$, где $B_i = (b_{i,1}, \dots, b_{i,n})$, то после первого шага преобразований Якоби она изменится следующим образом:

$$\mathbf{B}^{(1)} = (c_{1,2}B_1 + s_{1,2}B_2, -s_{1,2}B_1 + c_{1,2}B_2, B_3, \dots, B_n)^T,$$

что эквивалентно умножению слева на матрицу

$$\begin{pmatrix} c_{1,2} & s_{1,2} & 0 & \dots & 0 \\ -s_{1,2} & c_{1,2} & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{pmatrix}$$

размером $n \times n$, которую обозначим $\mathbf{D}^{(1)}$. Таким образом,

$$\mathbf{B}^{(i)} = \mathbf{P}^{(i)} \times (\mathbf{B}_1, \dots, \mathbf{B}_n)^T,$$

где

$$\mathbf{P}^{(i)} = \mathbf{D}^{(i)} \times \mathbf{P}^{(i-1)}, \quad \mathbf{P}^{(0)} = \mathbf{E},$$

а $\mathbf{D}^{(i)}$ строится для каждого шага по следующему алгоритму. Если на i -ом шаге используются строки k и l , то матрицу $\mathbf{D}^{(i)}$ можно получить из единичной матрицы, заменив

$$\mathbf{D}_{k,k}^{(i)} = c_{k,l}; \quad \mathbf{D}_{k,l}^{(i)} = s_{k,l};$$

$$\mathbf{D}_{l,k}^{(i)} = -s_{k,l}; \quad \mathbf{D}_{l,l}^{(i)} = c_{k,l};$$

где коэффициенты

$$c_{k,l} = \frac{\mathbf{B}_{k,k}^{(i-1)}}{\sqrt{(\mathbf{B}_{k,k}^{(i-1)})^2 + (\mathbf{B}_{l,k}^{(i-1)})^2}},$$

$$s_{k,l} = \frac{\mathbf{B}_{l,k}^{(i-1)}}{\sqrt{\left(\mathbf{B}_{k,k}^{(i-1)}\right)^2 + \left(\mathbf{B}_{l,k}^{(i-1)}\right)^2}}$$

получены из матрицы $\mathbf{B}^{(i-1)}$.

Матрица $\mathbf{P}^{(i)}$ хранит в себе коэффициенты линейных комбинаций, позволяющие получить матрицу $\mathbf{B}^{(i)}$ из исходной. Преобразования над строками производятся, пока на каком-то шаге m не окажется, что последние $n - t$ строк матрицы $\mathbf{B}^{(m)}$ содержат нулевые элементы.

В этом случае $n - t$ строк матрицы $\mathbf{P}^{(m)}$ содержат коэффициенты линейной комбинации строк исходной матрицы, позволяющие получить нулевые строки

$$\left\{ \begin{array}{l} \sum_{i=1}^n P_{t,i}^{[m]} A_i = 0, \sum_{i=1}^n P_{t+1,i}^{[m]} A_i = 0, \dots, \\ \dots, \sum_{i=1}^n P_{n,i}^{[m]} A_i = 0 \end{array} \right\}^T.$$

Из этой системы выражаются $n - t$ зависимостей между строками. Для каждого из зависимых признаков вычисляется максимальная разница между наблюдаемым и расчётным значением $l_{\max} = \max(|\dot{\mathbf{x}}_k - \mathbf{x}_k|, \forall \mathbf{x} \in Et)$, где Et — эталонная выборка, а \mathbf{x}_k и $\dot{\mathbf{x}}_k$ — наблюдаемое и расчётное значения признака. При распознавании проверяется, что отклонение наблюдаемого значения зависимого признака от его расчетного значения не превышает эталонной величины: $|\dot{\mathbf{x}}_k - \mathbf{x}_k| \leq l_{\max}$. Так, результаты распознавания с использованием только линейных зависимостей на примере ИК-фото пшеницы, здоровой и заражённой различными вредителями (рис. 1), показывают 100% точность на имеющейся в [5, 6] выборке.

Для дальнейших вычислений требуется выполнить проверку нормальности распределения (например, методом χ^2). В случае принятия гипотезы о согласии распределений, возможны два способа вычисления размера доверительной области в пространстве признаков. Первый опирается на тот факт, что многомерные поверхности уровня для (3) задаются уравнением второго порядка

$$(\mathbf{x} - \boldsymbol{\mu}_x)^T \mathbf{B}^{-1} (\mathbf{x} - \boldsymbol{\mu}_x) = \text{const} \quad (4)$$

и являются эллипсоидами рассеяния. Константу в правой части (4) можно определить через кратный интеграл от (3), что при

непосредственном интегрировании встречает значительные трудности, но допускает сведение к алгебраическому уравнению следующим образом. В системе координат с началом в центре рассеяния $\boldsymbol{\mu}_x$ и преобразованной к каноническому виду уравнение (4) имеет вид

$$\sum_{i=1}^n \frac{z_i^2}{-2 \ln \left(f_{el} \sqrt{(2\pi)^n |\mathbf{B}|} \right) a_i^2} = 1, \quad (5)$$

где

$$k^2 = -2 \ln \left(f_{el} \sqrt{(2\pi)^n |\mathbf{B}|} \right)$$

является коэффициентом подобия полуосей a_i эллипсоида, а константа

$$f_{el} \in \left(0; \frac{1}{\sqrt{(2\pi)^n |\mathbf{B}|}} \right)$$

регулирует вероятность попадания спектра в эллипсоид рассеяния. Если произвести в кратном интеграле от (3) замену на каноническую систему переменных, то якобиан

$$J = \frac{nb(n) \prod_{i=1}^n a_i}{\sqrt{(2\pi)^n |\mathbf{B}|}},$$

где

$$b(n) = \begin{cases} 2, & n = 1, \\ 2b(n-1) \int (1 - \delta^2)^{\frac{n-1}{2}} d\delta, & n \geq 2, \end{cases}$$

Для вычисления коэффициента подобия эллипсоида, охватывающего заданный процент выборки, необходимо решить следующее уравнение относительно KP :

$$\frac{nb(n) \prod_{i=1}^n a_i}{\sqrt{(2\pi)^n |\mathbf{B}|}} \int_0^{KP} e^{-\frac{k^2}{2}} k^{n-1} dk = F_{KP}. \quad (6)$$



















Для сокращения вычислений может быть применён второй метод, направленный на получение максимального значения функционала, вычисленного для каждого из объектов эталонной выборки

$$MD = \max (D(\mathbf{x}_i), \mathbf{x}_i \in Et, \quad i = 1 \dots S_{et}), \quad (7)$$

на

$$D(\mathbf{x}) = (\mathbf{x} - \boldsymbol{\mu}_x)^T \mathbf{B}^{-1} (\mathbf{x} - \boldsymbol{\mu}_x), \quad (8)$$

Влияние количества отфильтрованных гармоник вейвлет-спектра на качество восстановленного по спектру изображения

% нулей в детализирующем вейвлет-спектре	Горох	Кукуруза	Подсолнечник
Оригинал			
40			
80			
95			
99			
100			

Для определения попадания вектора \mathbf{x} в эллипсоид рассеивания в 1-м способе расчёта его размера — через (6) — необходимо сначала выполнить переход в систему координат проверяемого эллипсоида: $\mathbf{z} = (\mathbf{x} - \mu_x) \times \mathbf{RM}$, где \mathbf{RM} — матрица поворота; \mathbf{z} — вектор характеристик объекта в канонической системе координат проверяемого эллипсоида, и проверить неравенство

$$\sum_{i=1}^n \left(\frac{z_i}{KP \cdot a_i} \right) \leq 1. \quad (9)$$

Во 2-м способе — через (7) — необходимо проверить выполнение неравенства

$$D(\mathbf{x}) \leq MD. \quad (10)$$

Признаки плоских изображений, как видно из таблицы, при 100% нулевых коэффициентов детализации в спектре содержит информацию о среднем цвете соответствующих участков исходного изображения.

Добавление 1% (99% нулей) детализирующих коэффициентов позволяет восстановить приблизительную форму исходного изображения. С увеличением количества используемых коэффициентов форма и окраска объектов восстанавливаются всё точнее, а облака рассеивания всё сильнее отдаляются друг от друга в пространстве характеристик.

Данное свойство показано на рис. 4 и является основополагающим для выбранного подхода распознавания.

Работа алгоритма распознавания опробована на разрешениях изображений объектов: 64×64 , 32×32 , 16×16 и 8×8 пикселей, на зёрнах риса 5-ти сортов: Изумруд, Краснодарский, Кулон, Лиман и Регул. В качестве контрольной выборки использовалась смесь из объектов искусственного происхождения, добавленных при помощи графического редактора и зёрен одного из сортов риса. Для эталонов, созданных на основе изображений объектов 32×32 пикселя, показано гарантированное выделение объектов-участников обучающей выборки из смеси других объектов. Кроме того, удалось различить сорта зёрен риса, участвовавших в создании эталонов.

Работа алгоритма была опробована также на имеющихся в [5,6] ИК-фото зёрен пшеницы со скрытой заражённостью (рис. 1), заражённых следующими вредителями: хрущак, мукоед, зерновой точильщик и рисовый долгоносик.

При разрешении 8×8 пикселей метод позволяет различить только самые общие приметы объекта — средние цвета участков изображения. Проверка на контрольной группе показала, что зёрна риса легко отличаются алгоритмом распознавания от объектов ис-




Рис. 4. Распределения признаков сортов риса: а — для одной 13-й гармоники, б — двух, 13 и 19-й; в — трёх, 13, 19 и 15-й гармоник. Символами обозначены разные сорта риса: \square — Изумруд; $+$ — Краснодарский; \circ — Кулон; \diamond — Лиман; \circ — Регул

кусственного происхождения: ни один из таких объектов не был причислен к какому-либо из сортов риса и наоборот, однако сорта различить не удалось, что говорит о недостаточной для распознавания сортов культур детализации изображений на разрешении 8×8 .

Таким образом, на основе статистических методов и вейвлет-анализа построен алгоритм распознавания объектов природного происхождения по их изображениям с теоретически предсказуемой вероятностной точностью. Проведены эксперименты по распознаванию образцов: в частности, на имеющейся в [5, 6] выборке, по отделению на БИК-фотографиях здоровой пшеницы от пшеницы со скрытой заражённостью насекомыми. Повышение эффективности методики и технологии для распознавания с заданной точностью объектов природного происхождения

с сильной визуальной внутриклассовой вариативностью, при близости классов, достигнуто путём применения вероятностных областей рассеяния в признаковом пространстве (эллипсоида рассеяния при нормальном распределении), вырожденности матрицы ковариации признаков и особенностей вейвлет-спектра.

Литература

1. Choudhary R., Paliwal J., Jayas D.S., Ridgway C., Chambers J. Classification of cereal grains using wavelet, morphological, colour, and textural features of non-touching kernel images // Biosystems Engineering. 2008. Vol. 99. Issue 3 (March). P. 330–337.
2. Choudhary R., Mahesh S., Paliwal J., Jayas D.S. Identification of wheat classes using wavelet features from near infrared hyperspectral images

- of bulk samples // *Biosystems Engineering*. 2009. Vol. 102. Issue 2 (February). P. 115–127.
3. Горонков К. А., Руденко О. В., Усатиков С. В. О точности распознавания по контуру изображений злаковых культур при помощи нейронных сетей // *Обзорные прикладной и промышленной математики*. 2009. Т. 16. Вып. 3. С. 567–569.
 4. 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. Вып. 8. Ч. 2. С. 342–346.
 5. Singh C. B., Jayas D. S., Paliwal J., White N. D. G. Detection of insect-damaged wheat kernels using near-infrared hyperspectral imaging // *Journal of Stored Products Research*. 2009. Vol. 45. Issue 3 (July). P. 151–158.
 6. Chandra B. Singh, Digvir S. Jayas, Jitendra Paliwal, Noel D. G. White Identification of insect-damaged wheat kernels using short-wave near-infrared hyperspectral and digital colour imaging // *Computers and Electronics in Agriculture*. Vol. 73. Issue 2 (August). 2010. P. 118–125.

Ключевые слова: статистические методы распознавания образов, вейвлет-спектр, диагностика скрытой заражённости насекомыми зерновых и бобовых.

Статья поступила 17 июня 2012 г.

Кубанский государственный технологический университет, г. Краснодар

© Горонков К. А., Усатиков С. В., 2013