

Алгоритм выделения областей с нарушенной гребневидной структурой

М.А. Посыпкин, А.В. Туркин

Аннотация. Предложен алгоритм выделения областей с нарушенной гребневидной структурой. Рассмотрены некоторые применяемые на практике подходы, и проведен сравнительный анализ с оценкой надежности классификации и времени работы алгоритмов.

Ключевые слова: оценка качества изображения отпечатка пальца, EM-алгоритм, классификация блоков изображения, автоматическая дактилоскопическая идентификационная система.

Введение

Большинство автоматических дактилоскопических идентификационных систем используют так называемые особые точки (точки разветвлений и окончаний) изображения отпечатка пальца для вынесения решения о допуске лица, чей отпечаток был получен, на защищаемый этой системой периметр. При таком подходе можно выделить три основных этапа работы этой системы: получение изображения отпечатка пальца, его обработка с построением шаблона отпечатка пальца (который можно представить как список координат особых точек с их возможными атрибутами: тип точки, направление следования гребня и т.д.) и сравнение полученного шаблона с теми, которые хранятся в базе зарегистрированных в системе пользователей. В свою очередь, этап обработки отпечатка пальца обычно состоит из двух главных стадий: улучшения качества изображения и выделения локальных особенностей. Для улучшения качества изображения и получения четкой гребневидной структуры отпечатка применяются различные подходы с применением фильтров [1]. На практике возможно получение такого изображения, в некоторых сегментах которого нарушения гребневидной структуры носят столь необратимый характер,

что применение фильтра для них невозможно. В таких областях высок риск выделения ложных точек разветвлений и окончаний, поэтому часто в этап обработки включают стадию выделения областей с нарушенной гребневидной структурой. В этой работе рассмотрена только эта стадия и предлагается алгоритм выделения таких областей.

1. Постановка задачи

Рассмотрим полученное со считывателя отпечатков пальцев изображение I , которое имеет 256 уровней яркости и представляет собой матрицу размера M на N , $I_{i,j} \in \{0,1,\dots,255\}$, $1 \leq i \leq M$, $1 \leq j \leq N$. Помимо области отпечатка пальца, характеризующейся наличием структуры (далее определяемая как гребневидная) чередующихся светлых и темных полос с высокой и низкой интенсивностью пикселей соответственно, изображение содержит область фона. Область отпечатка пальца нами будет рассматриваться как объединение двух непересекающихся подобластей: с нарушенной и приемлемой для дальнейшей обработки гребневидной структурой.

Для выделения областей с нарушенной гребневидной структурой каждое из изображений

разбивается на ряд непересекающихся блоков ω ($\omega_{p,q} \in \{0,1,\dots,255\}$, $1 \leq p \leq P$, $1 \leq q \leq Q$). Ставится задача определения наличия или отсутствия четко выраженной гребневидной структуры в каждом блоке. Размеры блока были выбраны на основе следующих требований:

1) блок должен содержать пиксели хотя бы одного гребня и одной бороздки (как будет показано ниже, это необходимо для вынесения правильного решения по блоку изображения);

2) блок должен иметь минимально возможные размеры (в связи с необходимостью выделения четкой границы раздела областей с явно выраженной и нарушенной гребневидной структурой).

Исходя из этих требований на основе эксперимента значения P и Q были выбраны равными 16.

При проведении данной работы был использован считыватель отпечатков пальцев, основанный на температурном методе получения изображений компании ATMEL [2]. С помощью этого считывателя была сформирована база изображений отпечатков пальцев. На основании анализа большого количества этих изображений можно выделить пять основных классов блоков (Рис. 1). Если рассматривать блок изображения, где присутствует гребневидная структура, гистограмма распределения вероятностей интенсивностей пикселей, построенная по этому блоку, будет выглядеть как два соединенных между собой «колокола» (Рис. 1 (а)). Один из них соответствует области гребней, второй – области бороздок. В области, где гребневидная структура сильно нарушена или отсутствует (область фона), гистограмма блока

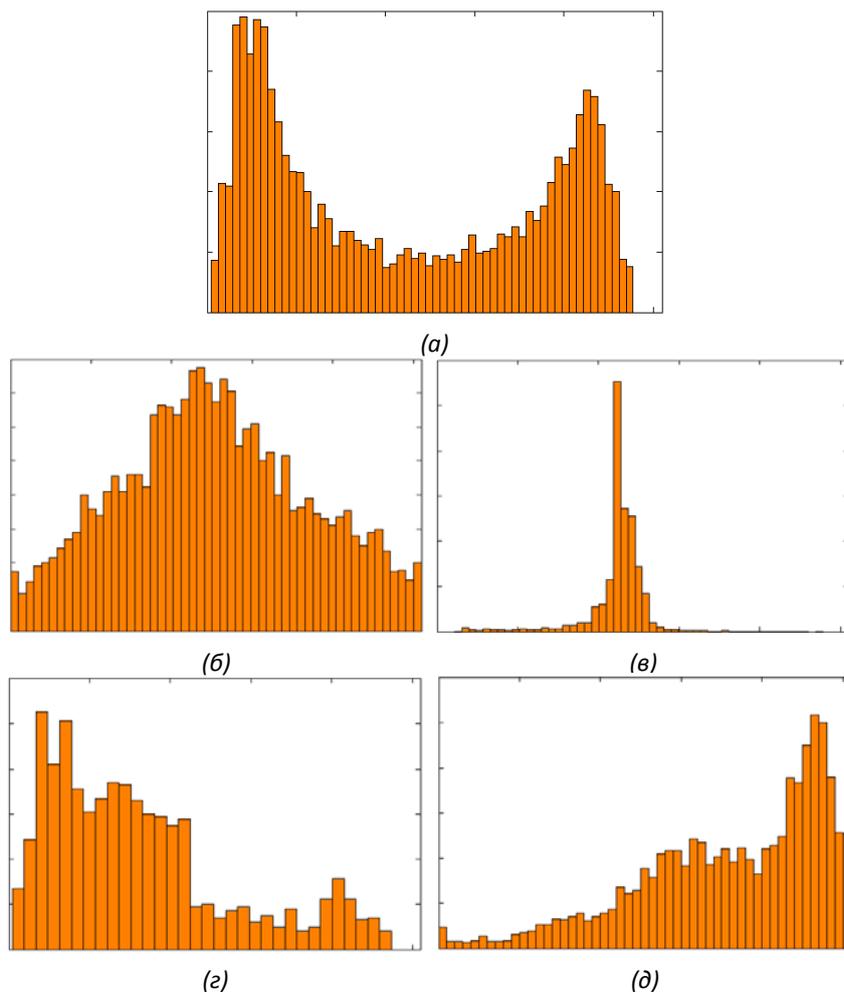


Рис. 1. Классы областей

будет иметь уплощенный (Рис. 1 (б)) или ярко выраженный унимодальный характер (Рис. 1 (в)) соответственно. Для таких областей можно также получить гистограммы блоков с двумя «колоколами», значения максимумов (мод) которых сильно отличаются друг от друга (Рис. 1(г) или Рис. 1(д)).

На основании приведенных наблюдений предложим следующий алгоритм определения наличия или отсутствия четко выраженной гребневидной структуры, использующий информацию об интенсивностях пикселей в некотором блоке изображения. В качестве критерия для построения решающего правила, по которому будет происходить классификация, был использован вид функции плотности распределения вероятностей интенсивностей пикселей отдельно взятого блока. Следовательно, решение задачи классификации того или иного блока изображения подразумевает решение задачи о восстановлении функций плотности, каждая из которых будет определять некоторый класс.

Общая схема работы алгоритма, при применении такого подхода, будет состоять из двух основных частей: обучения и классификации. *Этап обучения* включает оценку функций плотности каждого класса исходя из информации о принадлежности к некоторому классу ряда блоков изображения. На *этапе классификации* эта информация используется для вынесения решения о принадлежности того или иного блока к одному из приведенных выше классов путем применения решающего правила классификации.

Введем ряд понятий, необходимых для формального описания и анализа алгоритмов *обучения* и *классификации*. Пусть Ω – множество блоков изображения. Это множество будем считать разбитым на ряд непересекающихся областей: $\Omega = \Omega_1 \cup \dots \cup \Omega_5$. Каждое Ω_i будем называть классом. Первый класс (Ω_1) будет определять область, дальнейшая обработка которой возможна с целью обнаружения в ней локальных особенностей (Рис. 1 (а)); $\Omega_2, \Omega_3, \Omega_4$ – области изображения отпечатка пальца с нарушенной гребневидной структурой (Рис. 1(б, г, д)); последний, Ω_5 – область фона (Рис. 1(в)).

Предполагается, что существует истинный классификатор, который определяется как функция $\mathcal{F}_u : \Omega \rightarrow \{\Omega_1, \Omega_2, \Omega_3, \Omega_4, \Omega_5\}$. На практике данная функция обычно реализуется как экспертная оценка. Эксперт определяет набор ее значений $\{\mathcal{F}_u(\omega(t))\}$, $t=1, \dots, R$ на конечной исследуемой совокупности блоков $\omega(t)$, $t=1, \dots, R$, где каждый блок представляется как последовательность интенсивностей пикселей.

Вместе с \mathcal{F}_u определим функцию $\mathcal{F} : \Omega \rightarrow \{\Omega_1, \Omega_2, \Omega_3, \Omega_4, \Omega_5\}$, называемую классификатором или решающим правилом. Решается задача о построении в некотором смысле оптимального классификатора $\mathcal{F}(\omega)$, а именно такого, чтобы при предъявлении элементов $\omega \in \Omega$ в процессе классификации на практике равенство $\mathcal{F}(\omega) = \mathcal{F}_u(\omega)$ (правильная классификация) выполнялось всегда.

2. Этап обучения

2.1. Восстановление функций плотности классов

Решается задача определения вида функции плотности для определенных выше пяти классов $\Omega_1, \dots, \Omega_5$ исходя из информации о принадлежности к некоторому классу ряда блоков изображения. Пусть в результате анализа совокупности изображений были выделены T_i блоков, относящихся к некоторому классу Ω_i для некоторого фиксированного $i=1, \dots, 5$. Вектор, содержащий все интенсивности пикселей блока t , $1 < t < T_i$, обозначим через $\omega^{\Omega_i}(t)$. Рассмотрим совокупность следующих векторов для всех T_i блоков: $\bar{x}^{\Omega_i} = (\omega_{1,1}^{\Omega_i}(1), \dots, \omega_{16,16}^{\Omega_i}(1), \dots, \omega_{1,1}^{\Omega_i}(T), \dots, \omega_{16,16}^{\Omega_i}(T))$.

Для целей обучения необходимо иметь вектор, являющийся реализацией независимых одинаково распределенных случайных величин. Очевидно, что значения интенсивностей соседних пикселей в блоке сильно коррелированы. Сформируем обучающий вектор \bar{x}^{Ω_i} путем выбора случайным образом n элементов из вектора \bar{x}^{Ω_i} . Значение n было выбрано на основе эксперимента и равнялось 640, этого ко-

личества элементов в векторе вполне достаточно для задачи обучения. Так как местоположения элементов в векторе $\mathbf{x}^{-\Omega_i}$ для последующей записи в \mathbf{x}^{Ω_i} выбираются случайным образом, можно считать, что в результате описанной операции будет получен искомый вектор. Следует отметить, что в этом случае в векторе $\mathbf{x}^{-\Omega_i}$ было 2560 элементов, т.е. для формирования каждого вектора $\mathbf{x}^{-\Omega_i}$ было использовано по 10 блоков изображения.

Определим алгоритм для восстановления функции плотности $f_{\xi}(x)$ некоторого i -го класса с использованием вектора \mathbf{x}^{Ω_i} . Для простоты последующего изложения алгоритма определим вектор $\mathbf{x} = (x_1, \dots, x_n)$. Из теоремы Винера [3] следует, что плотность случайной величины ξ может быть представлена в виде смеси нормальных распределений с некоторым

общим σ : $f_{\theta}^{\xi}(x) = \sum_{i=1}^K p_i \psi_i(x; a_i, \sigma)$, где $K \geq 1$ –

натуральное число, $\psi_1 \dots \psi_k$ – нормальные

плотности: $\psi_i(x; a_i, \sigma) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left\{-\frac{(x-a_i)^2}{2\sigma^2}\right\}$,

$x \in \mathbb{R}$. Решается задача нахождения параметров этой смеси по известным реализациям случайной величины ξ – по вектору \mathbf{x} . Запишем эти параметры в виде вектора θ : $\theta = (p_1 \dots p_K, a_1 \dots a_K, \sigma)$, где $p_1 + p_2 + \dots + p_K = 1$, $p_i > 0$, $\sigma > 0$, $p_i, a_i, \sigma \in \mathbb{R}$, $i = 1 \dots K$.

Для оценки параметров смеси применим подход, известный как метод максимального правдоподобия [4]. В соответствии с этим методом оценка $\hat{\theta}$ неизвестного параметра θ по вектору \mathbf{x} – наблюдениям случайной величины ξ – определяется из условия:

$L(\mathbf{x}; \hat{\theta}) = \max_{\theta} L(\mathbf{x}; \theta)$, где L – функция правдоподобия, $L(\mathbf{x}; \theta) = f_{\xi}(x_1; \theta) f_{\xi}(x_2; \theta) \dots f_{\xi}(x_n; \theta)$.

Таким образом, оценка максимального правдоподобия $\hat{\theta}$ параметра θ по независимым наблюдениям x_1, \dots, x_n может быть представлена в виде задачи оптимизации:

$\hat{\theta} = \operatorname{argmax}_{\theta} \prod_{i=1}^n f_{\theta}^{\xi}(x_i)$. Эквивалентное определение

оценки максимального правдоподобия можно дать с использованием логарифмической функции правдоподобия $\hat{\theta} = \operatorname{argmax}_{\theta} \sum_{i=1}^n \ln f_{\theta}^{\xi}(x_i)$.

[5]. Логарифмическая функция правдоподобия является наиболее часто используемой, в том числе и в данной статье.

Прежде чем определять параметры смеси, необходимо оценить количество ее компонентов. Практически при решении этой задачи очень важно подойти к ней с точки зрения оценки наименьшего количества компонентов смеси, при которых модель согласуется с данными [6].

2.2. Оценка параметров функций плотности классов

Определим процедуру, позволяющую находить максимум (по параметру θ и при фиксированном K – количестве компонентов смеси) логарифмической функции правдоподобия, т.е. решим оптимизационную задачу вида:

$$\sum_{j=1}^n \ln \left(\sum_{i=1}^K p_i \psi_i(x; a_i, \sigma) \right) \rightarrow \max_{p_i, a_i, \sigma}.$$

Для решения поставленной задачи был применен EM-алгоритм [5, 6]. Применяя этот алгоритм к рассматриваемой задаче, получим следующие расчетные формулы. Положим, что значение параметра θ на m -ой итерации EM-алгоритма

известно: $\theta^{(m)} = (p_1^{(m)} \dots p_K^{(m)}, a_1^{(m)} \dots a_K^{(m)}, \sigma^{(m)})$. Запишем отношение

$$g_{ij}^{(m)} = \frac{\frac{p_i^{(m)}}{\sqrt{2\pi\sigma^{(m)}}} \exp\left\{-\frac{1}{2}(x_j - a_i^{(m)})^2\right\}}{\sum_{r=1}^k \frac{p_r^{(m)}}{\sqrt{2\pi\sigma^{(m)}}} \exp\left\{-\frac{1}{2}(x_j - a_r^{(m)})^2\right\}},$$

тогда уточненные значения параметров p_i , a_i и σ на $(m+1)$ -ой итерации EM-алгоритма имеют вид:

$$p_i^{(m+1)} = \frac{1}{n} \sum_{j=1}^n g_{ij}^{(m)}; \quad a_i^{(m+1)} = \frac{1}{\sum_{j=1}^n g_{ij}^{(m)}} \sum_{j=1}^n g_{ij}^{(m)} x_j;$$

$$\sigma^{(m+1)} = \left[\frac{1}{n} \sum_{i=1}^K \sum_{j=1}^n g_{ij}^{(m)} (x_j - a_i^{(m+1)})^2 \right]^{1/2};$$

$$i = 1, \dots, K.$$

В результате применения EM-алгоритма вычисляется последовательность значений $\{\theta^{(m)}\}_{m>1}$ параметра θ . На каждом последующем шаге EM-алгоритма вычисленное значение функции правдоподобия больше значения функции правдоподобия на предыдущем шаге работы алгоритма. Достижение стационарной точки (локального максимума) алгоритмом определяется исходя из следующего соотношения: $L(x; \theta^{(m+1)}) - L(x; \theta^{(m)}) < \varepsilon$. Параметр был выбран экспериментально, $\varepsilon = 10^{-6}$.

Чтобы запустить итерационный процесс EM-алгоритма, необходимо указать начальное значение параметра $\theta^{(0)}$, которое выбиралось исходя из гистограммы, построенной по выборке x так, чтобы уже с начальным значением параметра смесь наиболее близко аппроксимировала полученную функцию плотности.

2.3. Оценка количества параметров функций плотности классов

Определив процедуру для нахождения параметров смеси нормальных с общим σ , оценим оптимальное количество параметров K_{opt} . Предположим, что имеется набор функций плотности $f_{\theta_1}^{\xi}(x), \dots, f_{\theta_{K_{max}}}^{\xi}(x)$, каждая из которых представляет собой смесь с соответствующими параметрами: $K = 1, \dots, K_{max}$. Значение K_{max} – количество компонентов смеси, которое было выбрано на основе опыта: $K_{max} = 10$. Ставится задача определения того оптимального значения количества компонентов смеси, при котором помимо того, что исходные данные согласуются с выбранным видом функции плотности, эта функция имеет наименьшее число параметров.

Выполним последовательный поиск оптимального количества параметров смеси, рассматривая две гипотезы: гипотеза H_1 определяет согласие заранее найденной функции плотности с выборкой x при $2K$ параметрах

смеси, а гипотеза H_2 определяет согласие с выборкой при $2(K+1)$ параметрах смеси, где $K = 1, \dots, K_{max} - 1$. Для проверки этих гипотез был применен байесовский информационный критерий, описанный в работе [7]. В соответствии с этим критерием решение задачи об оптимальном значении числа компонентов смеси имеет вид: $K_{opt} = \arg \min_K \{-2 \log L(x; \hat{\theta}_K) + (2K) \log n\}$, где $\hat{\theta}_K$ – оценка максимального правдоподобия параметра θ для некоторого значения K компонентов смеси, построенная с применением вышеописанного алгоритма по вектору $x = (x_1, \dots, x_n)$. Схема оценивания неизвестных параметров смеси будет строиться следующим образом: вначале строится оценка параметра $\hat{\theta}_K$ и $\hat{\theta}_{K+1}$ для последовательности фиксированных значений $K = 1, \dots, K_{max} - 1$. Затем, с использованием байесовского информационного критерия на основе этих оценок выносится решение о продолжении или прекращении процесса оценивания параметров с выбором оптимального значения K_{opt} в качестве оценки для неизвестного числа компонентов смеси.

3. Этап классификации

Все изображение разбивается на блоки размера 16 на 16 пикселей. Из каждого блока случайным образом выбираются 128 элементов. Таким образом, мы располагаем исходными статистическими данными – выборкой $x = (x_1, x_2, \dots, x_{128})$, где x_i независимые и одинаково распределенные случайные величины с функцией распределения $F_{\xi}(t)$. Стоит отметить, что относительно выборки x будем допускать двойственное толкование этого обозначения и объекта: как случайного вектора и как вектора реальных числовых данных, полученных в фактически осуществленных экспериментах.

Рассмотрим следующую задачу классификации. Выборку x из 128 фиксированных наблюдений необходимо отнести к одному из классов $\Omega_1, \Omega_2, \Omega_3, \Omega_4$ или Ω_5 . Данная задача является статистической задачей

проверки следующих гипотез: H_1 – выборка \mathbf{x} принадлежит классу Ω_1 , H_2 – выборка \mathbf{x} принадлежит классу Ω_2 и т.д.

Положим, что гипотезы равновероятны (постулат Байеса-Лапласа), и по формуле Байеса найдем вероятность принадлежности \mathbf{x} к классу Ω_i , $i=1, \dots, 5$, т.е. апостериорные вероятности гипотез H_1, \dots, H_5 , если в результате наблюдения получена выборка \mathbf{x} :

$$P(H_i | \mathbf{x}) = \frac{f_\xi(\mathbf{x} | H_i)}{\sum_{k=1}^5 f_\xi(\mathbf{x} | H_k)}, \text{ где } f_\xi(\mathbf{x} | H_i) - \text{со-}$$

вместная функция плотности, характеризующая класс Ω_i [8]. Таким образом, может быть получен оптимальный по критерию максимальной апостериорной вероятности алгоритм принятия некоторой гипотезы. Приведем это решающее правило: принимается гипотеза H_i , если

$$f_\xi(\mathbf{x} | H_i) = \max_{1 \leq k \leq 5} f_\xi(\mathbf{x} | H_k) \quad [4].$$

Таким образом, на *этапе классификации* решение о принадлежности того или иного блока отпечатка пальца к одному из приведенных выше классов принимается путем вычисления значения функции $\mathcal{F}(\omega)$ для некоторого блока ω : $\mathcal{F}(\omega) = S_k$, если $f_\xi(\mathbf{x} | H_k) = \max_{1 \leq k \leq 5} f_\xi(\mathbf{x} | H_k)$.

4. Оценка надежности алгоритма классификации

Необходимо количественно оценить степень уверенности ν (которую можно назвать надежностью классификации) в справедливости равенства $\mathcal{F}(\omega) = \mathcal{F}_u(\omega)$ для произвольного $\omega \in \Omega$. Очевидно, что указанная оценка напрямую определяет качество решения поставленной задачи и, следовательно, дает возможность производить сравнение нескольких алгоритмов классификации, результаты которой приведены ниже. Задача оценки надежности классификации состоит в определении ν , в том случае когда в распоряжении имеются лишь наборы значений на прецедентах истинного и построенного классификаторов.

Пусть на пространстве образов Ω задано распределение вероятностей $P(X)$, $X \subseteq \Omega$, и любой рассматриваемый набор образов

$\omega(1), \dots, \omega(G)$ является реализацией независимой выборки G случайных величин из генеральной совокупности с распределением $P(X)$. Положим Ω разбитым на две подобласти – правильных X_n и неправильных (ошибочных) X_o классификаций – и пусть $\nu = P(X_n)$. Обозначим через m_n количество прецедентов, попавших в область X_n , а через m_o – количество прецедентов, попавших в область X_o ($m_n + m_o = m_{no}$). Тогда, как описано в [9], оценками вероятностей вынесения классификатором правильного $p_n = P(X_n)$ и ошибочного $p_o = P(X_o)$ ($p_n + p_o = 1$) решений (по методу максимального правдоподобия) будут относительные частоты числа прецедентов m_n и m_o в областях X_n и X_o соответственно: $\frac{m_n}{m_{no}}$ и $\frac{m_o}{m_{no}}$.

Следует отметить, что элементы $\omega(1), \dots, \omega(G)$, составляющие экзаменационную выборку (которая используется для оценки качества алгоритмов) не присутствуют в обучающей выборке, т.е. в той, что используется для построения решающего правила. Таким образом, обучающая и экзаменационная выборки не имеют общих элементов, что гарантирует корректность применения результатов классификации на экзаменационной последовательности к задаче оценки качества классификации.

5. Сравнение предложенного метода с некоторыми применяемыми на практике

В работе [10] предлагается моделировать чередующиеся гребни и бороздки изображения отпечатка пальца синусоидальной волной, построенной путем проекции пикселей некоторого блока изображения на направление чередования гребней и бороздок, и вычислять амплитуду, частоту и среднеквадратическое отклонение по полученной волне. Отбираются несколько обычных изображений отпечатков пальцев и разбиваются на блоки с вычислением этих характеристик. С получившейся совокупностью трехмерных шаблонов производится операция кластеризации с выделением значе-

ний центров кластеров. Эти значения применяются для классификации блоков изображения отпечатка пальца.

В работе [11] рассмотрен метод, основанный на применении фильтра Габора для получения характеристик отдельного блока изображения. С каждым блоком осуществляется операция свертки с ядром фильтра Габора (действительная часть функции Габора, которая получена модуляцией косинусной волны функцией Гаусса), настроенным на восемь различных направлений. Для каждого блока изображения отпечатка пальца получаются восемь характеристик, каждая из которых соответствует некоторому направлению фильтра Габора. Эти характеристики блока затем участвуют в вычислении значения среднеквадратического отклонения для блока. Для блоков изображения хорошего качества, где присутствует гребневидная структура с некоторым локальным направлением следования гребней и бороздок, одна или несколько характеристик блока, полученных с применением фильтра Габора, будут иметь намного большее значение, чем остальные. Для блоков, где гребневидная структура отсутствует или сильно нарушена и нельзя выделить локальное направление следования гребней и бороздок, значения характеристик блока будут незначительно отличаться друг от друга.

Было проведено сравнение предложенного алгоритма с описанными выше. Из базы отпечатков пальцев были выбраны несколько изображений для этапа обучения, а остальные использовались для классификации. С использованием экспертной оценки был сформирован набор прецедентов истинного классификатора, и произведено обучение. Была осуществлена классификация с определением ее надежности для каждого из отпечатков пальцев, как с применением предложенного метода, так и с использованием алгоритмов, представленных в работах [10, 11]. Результаты такого сравнения представлены в Табл. 1.

Из таблицы видно, что предложенный алгоритм более стабильно справляется с задачей классификации, чем алгоритмы Хонга [10] или алгоритм Шена [11], хотя и имеет чуть меньшее значение надежности классификации на небольшом количестве изображений.

Табл. 1.

Параметр оценки	Средняя	Максимальная	Минимальная
Надежность классификации предложенного алгоритма	0.8824	0.9123	0.8264
Надежность классификации алгоритма Хонга	0.8102	0.9185	0.6239
Надежность классификации алгоритма Шена	0.8119	0.9052	0.6939

Одновременно была произведена оценка времени работы алгоритмов. Результаты этой оценки приводятся в Табл. 2, в которой показано, во сколько раз предложенный алгоритм превосходит по быстродействию те алгоритмы с которыми проводилось сравнение.

Табл. 2.

Параметр оценки	Алгоритм Хонга	Алгоритм Шена
Среднее ускорение процесса классификации	2.30	5.96
Максимальное ускорение процесса классификации	2.31	6.0
Минимальное ускорение процесса классификации	2.27	5.91

Заключение

В работе предложен метод выделения областей с нарушенной гребневидной структурой. Алгоритм превосходит по быстродействию методы, применяемые на практике, имея при этом высокую надежность классификации.

Литература

1. Maltoni D., Maio D., Jain A.K., Prabhakar S. Handbook of Fingerprint Recognition 2nd ed., 2009.
2. Atmel FingerChip Thermal Fingerprint Sweep Sensor Hardware Based, Navigation and Click Function, SPI Interface [http://www.atmel.com/dyn/resources/prod_documents/doc5347.pdf], 2008.
3. Винер Н. Интеграл Фурье и некоторые его приложения. М., Физматгиз, 1963.
4. Левин Б.Р. Теоретические основы статистической радиотехники. 3-е изд. – М.: Радио и связь, 1989.
5. Titterington D.M., Smith A.F.M., Makov U.E. Statistical analysis of finite mixture distributions. 1985.
6. McLachlan G. Peel D. Finite Mixture Models. 2000.

7. G. Schwartz. Estimating the dimension of a model. – The Annals of Statistics, 1978, vol. 6.
8. Чистяков В.П. Курс теории вероятностей. 5-е изд. – М.: Агар, 2000.
9. Гуров С.И. Оценка надежности классифицирующих алгоритмов. Издательский отдел факультета Вычислительной математики и кибернетики МГУ им. М.В. Ломоносова, 2002.
10. Hong L., Wan Y., Jain A. Fingerprint Image Enhancement: Algorithm and Performance Evaluation. IEEE Transactions on PAMI, Vol. 20, No. 8, pp.777-789, 1998
11. Shen L., Kot A., Koo W. Quality Measures of Fingerprint Images. 3rd International Conference AVBPA 2001, p182-271, 2001.

Посыпкин Михаил Анатольевич. Ведущий научный сотрудник Институт системного анализа РАН. Окончил Московский государственный университет имени М.В.Ломоносова в 1996 году. Кандидат физико-математических наук. Автор 98 печатных работ. Область научных интересов: дискретная математика, распределенные вычисления, оптимизация.
E-mail: mposypkin@mail.ru

Туркин Андрей Владимирович. Инженер-электроник НИИ ВС и СУ Национального исследовательского университета МИЭТ. Окончил Московский государственный институт электронной техники (технический университет) в 2005 году. Автор 6 печатных работ. Область научных интересов: цифровая обработка изображений, распознавание образов.
E-mail: turkin@olvs.miee.ru