

## МЕТОД КЛАССИФИКАЦИИ ТЕКСТУР С ИСПОЛЬЗОВАНИЕМ СТРУКТУРНЫХ ХАРАКТЕРИСТИК ИЗОБРАЖЕНИЯ

Асатрян Д.Г.<sup>1,2</sup>, Куркчян В.В.<sup>2</sup>, Харатян Л.Р.<sup>2</sup>

<sup>1</sup> Институт проблем информатики и автоматизации  
Национальной Академии наук Республики Армения,

<sup>2</sup> Российско-Армянский (Славянский) университет

### Аннотация

В статье предлагается новая методика для анализа и классификации текстур, основанная на использовании структурных свойств изображения. Известно, что визуальная система человека успешно воспринимает содержание изображения по визуализированной совокупности краёв и границ, имеющихся в изображении. В данной работе в качестве характеристики структуры изображения предлагается использовать совокупность магнитуд градиента изображения. Магнитуда градиента считается случайной величиной, имеющей двухпараметрическое распределение Вейбулла, а в качестве характеристики близости двух изображений используется специальная мера близости оценок параметров соответствующих распределений. Классификация выполнена методом сравнения с эталоном на примере базы данных университета Гейдельберга (Германия), которая содержит 10 классов текстур. В качестве эталонов использован набор средних значений оценок параметров распределения Вейбулла, рассчитанных по совокупности магнитуд градиента текстур обучающей выборки, а сравнение выполнено по предложенной мере близости. В результате анализа выявлены два практически неразличимых класса, а для остальных 8 классов показано, что ошибка классификации в среднем составляет около 18 %.

**Ключевые слова:** классификация, текстура, магнитуда градиента, распределение Вейбулла, мера сходства.

### Введение

Классификация текстур является одной из важных областей обработки изображений, компьютерного зрения и их приложений, таких как анализ сцен, распознавание образов, дистанционное зондирование, поиск содержательной информации и т. д. Целью классификации является отнесение неизвестного образца изображения к одному из заранее заданных классов. Класс текстур обычно задаётся в виде некоторого множества изображений, выбранных по определённым содержательным или формальным признакам. Как известно, нет однозначного и чёткого определения понятия «текстура» (см., например, [1], в которой приведены наиболее часто встречаемые определения и даны соответствующие комментарии). Поэтому выбранные для классификации классы текстур, как правило, являются в определённой степени условными.

При решении задачи классификации текстур необходимо задать (или найти подходящее) описание (дескриптор) и меру близости изображений, соответствующую этому описанию. Как показывает даже беглый анализ научной литературы, предложено множество различных дескрипторов, применённых к одним и тем же типам, классам или базам текстур. При этом в каждый класс могут входить изображения одних и тех же реальных объектов, которые отличаются размерами, повернуты друг относительно друга, имеют различные цветовые характеристики, подвергнуты определённому геометрическому преобразованию и искажениям. Поэтому наибольший интерес представляют методы классификации, инвариантные относительно указанных факторов [2]. Многие предложенные в литературе инвариантные процедуры основаны на использовании определённых элементов структуры в изображении, например, отрезков прямых линий или линий фиксированной конфигурации, повторяющихся групп пикселей (элементов текстуры – тексе-

лов) и др., в соответствии с тем, как воспринимает структуру текстуры визуальная система человека (ВСЧ). В качестве наглядного примера укажем работу [3], в которой решена задача классификации типов кристаллических решёток по совокупности признаков структуры, обусловленных ориентировкой и распределением составных частей породы. Краткий обзор инвариантных методов классификации текстур можно найти в [4–8].

В настоящей работе мы ограничиваемся рассмотрением текстурных изображений, структура которых может быть охарактеризована совокупностью существующих в них краёв и границ. Большинство процедур, работающих со структурами подобного типа, применяют дескрипторы, использующие определённые свойства градиентного поля.

В одной из ранних работ предложен дескриптор, использующий магнитуду градиента и названный авторами «количество краёв в единице площади (Amount of edge per unit area)» [9]. Согласно этому дескриптору, каждому пикселу изображения ставится в соответствие магнитуда градиента, вычисленная по интенсивности пикселей из некоторой его окрестности. Далее определяется среднее значение магнитуды, приходящееся на единицу площади изображения, по которому и можно производить классификацию текстур. В дальнейшем этот метод был использован в других работах, однако в них непосредственно рассчитывались лишь некоторые числовые характеристики совокупности магнитуд. Между тем анализ работ с использованием градиентного поля изображения показывает необходимость изыскания достаточно общей математической модели, пригодной для анализа и классификации текстур без ограничения на наличие её конкретных свойств. Основой для такой модели может послужить предположение о случайном характере магнитуды градиента текстуры и типе распределения.

Важным является вопрос о распределении магнитуды градиента, которое существенным образом зависит от распределения интенсивностей пикселей самого изображения. Ввиду огромного разнообразия типов и содержания изображений отмечаем стремление отыскать универсальную модель распределения интенсивностей пикселей произвольного изображения и ограничиваемся рассмотрением лишь определённых классов изображений, для которых применение конкретной модели имеет теоретическое или хотя бы экспериментальное обоснование. Анализ научной литературы показывает, что удобным и распространённым типом изображения является текстура, а подходящим распределением для магнитуды градиента текстуры является двухпараметрическое распределение Вейбулла. Так, данное положение теоретически и экспериментальными исследованиями обосновано в [10]. Определённые теоретические обоснования приведены также в [11].

Следует отметить, что, применяя вейбуллиевскую модель, мы заменяем всё изображение текстуры (или её рассматриваемую часть) всего двумя параметрами, что в случае адекватности модели даёт огромное преимущество в задачах поиска информации и классификации в больших базах данных. Важность разработки быстрых методов поиска информации с применением текстурных признаков и других дескрипторов отмечается в литературе (см., например, [12]). Однако при применении вейбуллиевской модели для ускорения процедур поиска придётся столкнуться с некоторой потерей точности, что, впрочем, в каждом аналогичном случае может оцениваться и приводить к определённому компромиссу.

Основываясь на приведённых выше рекомендациях, один из авторов настоящей работы в статье [13] предложил меру близости двух изображений, которая основана на двухпараметрической вейбуллиевской модели с использованием структурной характеристики, определяемой совокупностью значений магнитуды градиента изображения. Конкретный вид данной меры зависит от статистических оценок параметров распределения Вейбулла по выборкам магнитуд градиента сравниваемых изображений. В работе показано существенное достоинство данной меры – её инвариантность относительно различных манипуляций с изображением (повороты, масштабирование и др.). А это свойство весьма важно при классификации изображений, т.к. набор текстур, отобранных для классификации по какому-либо принципу, например, путём визуального анализа, может содержать образцы, полученные от исходного путём преобразований указанного типа.

Модели, основанные на распределении Вейбулла, с успехом применялись в различных прикладных задачах [11, 14]. Так, вейбуллиевская модель для магнитуды градиента легла в основу алгоритма обнаружения дефектов текстур, описанного в работе [14]. Процедура классификации, предложенная в этой модели, основана на использовании метода опорных векторов в пространстве параметров распределения Вейбулла. Однако в случае, если число классов

больше двух, данная процедура классификации нуждается в соответствующем обобщении.

В настоящей работе предложена процедура классификации, основанная на методе сравнения с эталоном при использовании упомянутой меры близости изображений. На конкретном примере набора данных текстур показана эффективность предложенной процедуры.

### Мера сходства изображений текстур

Рассмотрим полутоновое 8-битовое изображение  $I = \{I(m,n)\}$  с размерами  $M \times N$ ,  $m = 0, 1, \dots, M-1$ ,  $n = 0, 1, \dots, N-1$ , где  $I(m,n)$  – интенсивность пикселя с координатами  $(m,n)$ .

Матрицы горизонтального и вертикального градиентов изображения обозначим через  $\|G_H(m,n)\|$  и  $\|G_V(m,n)\|$  соответственно, а матрицу магнитуды градиента – через  $\|M(m,n)\|$ , где

$$M(m,n) = \sqrt{G_H^2(m,n) + G_V^2(m,n)}. \quad (1)$$

В общем случае можно считать, что градиентное поле представляет собой двумерную случайную выборку вида

$$G(m,n) = [G_H(m,n), G_V(m,n)].$$

Магнитуда градиента (1) считается случайной величиной, имеющей распределение Вейбулла с плотностью распределения

$$f(x; \eta, \sigma) = \frac{\eta}{\sigma} \left(\frac{x}{\sigma}\right)^{\eta-1} \exp\left[-\left(\frac{x}{\sigma}\right)^\eta\right], \quad x \geq 0, \quad (2)$$

где  $\eta > 0$  – параметр формы, а  $\sigma > 0$  – параметр масштаба.

В качестве меры структурной близости двух изображений, у которых распределения вероятностей магнитуды градиента описываются функциями  $f_1(x; \eta_1, \sigma_1)$  и  $f_2(x; \eta_2, \sigma_2)$  соответственно, в работе [13] предложена

$$W^2 = \frac{\min(\eta_1, \eta_2) \min(\sigma_1, \sigma_2)}{\max(\eta_1, \eta_2) \max(\sigma_1, \sigma_2)}, \quad 0 < W^2 \leq 1. \quad (3)$$

При выполнении численных расчётов производится статистическое оценивание параметров распределения (2) методом моментов применительно к матрице (1), элементы которой находятся при помощи оператора Собела.

Небольшая модификация процедуры оценивания близости и классификации, описанной в настоящей работе, позволяет применять её и в случае цветных изображений.

В работе [13] приведены примеры, показывающие инвариантность меры (3) относительно различных преобразований изображений, в том числе поворотов и масштабирования.

Приведём пример, иллюстрирующий инвариантность предложенной меры сходства изображений текстур.

*Пример.* На рис. 1 приведён фрагмент изображения некоторой текстуры (рис. 1а) и результаты двух транс-

формаций этого фрагмента: поворота на  $45^\circ$  (рис. 1б) и увеличения размеров в 1,5 раза (рис. 1в).




Рис. 1. Примеры трансформированных текстур

В табл. 1 приведены соответствующие значения  $W^2$ , указывающие на значительное сходство этих изображений, несмотря на поворот и масштабирование исходного изображения. Расчёт PSNR возможен только для первых двух изображений и даёт результат сходства в 12,5 дБ, что никак нельзя считать удовлетворительным.

Таблица 1. Мера близости трансформированных текстур

Изображения	(а) и (б)	(а) и (в)	(б) и (в)
$W^2$	0,97	0,94	0,96

### Методика классификации текстур

Предполагается, что заданы классы текстур, выбранные по некоторому принципу, отвечающему задачам определённого исследования, а также некоторое множество текстур, которые необходимо классифицировать. Предлагаемая процедура классификации основана на методе сравнения с эталонами и включает следующие шаги:

Шаг 1. Для каждого изображения текстуры из обучающей и тестируемой выборок оцениваются параметры распределения Вейбулла  $\eta$  и  $\sigma$ .

Шаг 2. Определяются средние значения  $\bar{\eta}_i$  и  $\bar{\sigma}_i$  оценок параметров  $\hat{\eta}_i$  и  $\hat{\sigma}_i$  для  $i = 1, 2, \dots, 10$  по соответствующим образцам обучающей выборки. Эти значения запоминаются в качестве эталонных для последующего сравнения с ними тестовых образцов. Определяются также среднее значение  $\bar{W}^2$  и среднеквадратическое отклонение  $S_i$  меры близости  $W^2$  по

всем парам образцов каждого класса с номером  $i = 1, 2, \dots, 10$ .

Эти значения используются при оценивании степени сходства текстур внутри классов из обучающей выборки.

Шаг 3. Для каждого тестируемого образца текстуры по формуле (3) рассчитывается мера его близости с каждым эталоном. Принадлежность образца к какому-нибудь классу определяется по максимальному значению меры близости.

### Результаты экспериментов

Для проверки эффективности предлагаемого метода классификации нам представлялось целесообразным найти в сети Интернет готовые классы текстур, отказываясь от более простого и довольно распространённого метода искусственного создания обучающей выборки, получаемой в результате поворотов или иных преобразований одних и тех же образцов текстур. Типичным является подход, при котором из некоторого набора текстур (например, из известного набора Brodatz) выбираются отдельные образцы, каждый из них делится на определённое количество непесекающихся частей. Затем часть полученных таким образом изображений используется как обучающая выборка, а остальная часть – как тестовая (укажем в качестве примера работу [15]). Основанием для отказа от подобного подхода служит ожидаемый низкий процент ошибок классификации ввиду того, что при подобных преобразованиях структура текстуры в принятом выше смысле практически не меняется (что иллюстрируется рассмотренным выше примером).

В данной работе проведены численные эксперименты по классификации текстур на примере базы данных университета Гейдельберга [16], в которой представлены 10 классов текстур с 7475 образцами. Изображения, включённые в каждый из классов, получены авторами [16] методом моделирования, визуально аналогичны изображениям реальных текстур. На рис. 2 для наглядности приведены образцы текстур из рассматриваемой базы данных.




Рис. 2. Образцы текстур из базы данных [16]

Следует отметить, что принцип, согласно которому авторы [16] создали именно эти классы, нам неизвестен. Поэтому вопрос о том, насколько заданные

классы различимы по тому или иному дескриптору, можно решить лишь экспериментальным путём. Каждый класс нами был разбит на два подкласса с при-

мерно одинаковым количеством образцов, один из которых используется в качестве обучающего класса, а другой – в качестве тестового.

В табл. 2 приведены эталонные значения  $\bar{\eta}_i$  и  $\bar{\sigma}_i$  для обучающей выборки с 10 классами, а также средние  $\bar{W}^2$  и среднеквадратические отклонения  $S_i$  значений меры близости внутри каждого класса.

Анализируя данные табл. 2, можно обнаружить достаточно высокие значения меры сходства текстур внутри каждого класса. Можно также заметить близость эталонных параметров классов с номерами 3 и 9 ( $W^2 = 0,983$ ), что может служить основанием для объединения этих классов или выполнения других действий по усмотрению персоны, проводящей исследование. В данном контексте важно лишь то, что предложенная методика позволяет обнаруживать плохо различимые классы текстур из числа заданных.

Табл. 2. Параметры обучающей выборки

Номер класса	N	$\bar{\eta}_i$	$\bar{\sigma}_i$	$\bar{W}^2$	$S_i$
1	288	132,56	1,849	0,858	0,091
2	288	293,01	1,515	0,908	0,060
3	288	79,92	1,992	0,950	0,034
4	288	55,08	1,062	0,951	0,029
5	288	119,68	1,979	0,953	0,031
6	288	286,58	1,657	0,931	0,051
7	575	49,53	1,169	0,858	0,074
8	575	69,18	1,973	0,960	0,026
9	575	78,63	1,990	0,946	0,036
10	288	93,12	1,255	0,950	0,030

По описанной выше методике проведена классификация тестовой выборки, состоящей из половинок классов. Результаты классификации приведены в табл. 3.

В строке с номером  $i$  расположены данные о количестве тестируемых текстур  $i$ -го класса, отнесенных процедурой классификации к каждому из 10 классов. Все числа каждой строки, кроме числа, размещённого в столбце с тем же номером  $i$ , представляют количество ошибочно классифицированных текстур, процентные отношения которых приведены в последнем столбце.

Как и следовало ожидать, максимальное число ошибок классификации приходится на классы с номерами 3 и 9 и составляет примерно 50 % от объёма подкласса. Для остальных классов процент ошибок находится в пределах от нуля до 23 % (в среднем около 18 %), что свидетельствует о достаточной различимости остальных восьми классов.

Таким образом, предложенная методика классификации позволяет различать классы текстур, используя предложенную меру сходства изображений, рассчитываемой по значениям оценок параметров распределения Вейбулла. Сравнительно высокий процент ошибок классификации в рассмотренном примере окупается инвариантностью предложенной процедуры к размерам, поворотам и другим характеристикам текстурных изображений.

В заключение отметим, что приведённые результаты в основном не противоречат выводам визуального анализа классов текстур.

Табл. 3. Распределение ошибок классификации по классам

Классы	1	2	3	4	5	6	7	8	9	10	Процент ошибок
1	222	0	7	0	54	0	0	1	3	0	22,6
2	0	227	0	0	0	60	0	0	0	0	20,9
3	0	0	144	0	0	0	0	13	130	0	49,8
4	0	0	0	277	0	0	10	0	0	0	3,5
5	4	0	0	0	283	0	0	0	0	0	1,4
6	0	10	0	0	0	277	0	0	0	0	3,5
7	0	0	0	96	0	0	479	0	0	0	16,7
8	0	0	0	0	0	0	0	571	4	0	0,7
9	0	0	227	0	0	0	0	61	287	0	50,1
10	0	0	0	0	0	0	0	0	0	288	0

### Выводы

В статье предложена новая методика для анализа и классификации текстур, основанная на использовании структурных свойств изображения. В качестве характеристики структуры рассматривается совокупность магнитуд градиента изображения, для распределения которого принята двухпараметрическая вейбуллиевская модель. Для классификации текстур предложено использовать меру близости изображений, характеризующую близость значений статистической оценки параметров распределения Вейбулла, рассчитанной по соответствующим матрицам магнитуды градиента. Классификация выполнена мето-

дом сравнения с эталонами на примере базы данных университета Гейдельберга (Германия), которая содержит 10 классов текстур. В качестве эталонов использованы средние значения оценок параметров распределения Вейбулла по текстурам обучающей выборки, а сравнение выполнено по предложенной мере близости. В результате анализа выявлено, что два класса практически неразличимы, а для остальных 8 классов ошибка классификации в среднем составляет около 18 %. Предложенная методика классификации может быть использована также при поиске изображения с определёнными структурными свойствами в больших базах данных.

*Литература*

1. **Tuceryan, M.** Texture Analysis / M. Tuceryan, A.K. Jain // Handbook of Pattern Recognition and Computer Vision. – 2nd ed. – 1998. – P. 207-248.
2. **Mellor, M.** Locally Rotation, Contrast, and Scale Invariant Descriptors for Texture Analysis / Mellor Matthew, Byung-Woo Hong and Michael Brady // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2008. – Vol. 30(1) – P. 52-61.
3. **Куприянов, А.В.** Анализ текстур и определение типа кристаллической решётки на наномасштабных изображениях / А.В. Куприянов // Компьютерная оптика – 2011. – Т. 35, № 2. – С. 151-157.
4. **Bongkyu, L.** A New Method for Classification of Structural Textures / Lee Bongkyu // International Journal of Control, Automation, and Systems. – 2004. – Vol. 2(1) – P. 125-133.
5. **Jianguo, Zh.** Brief review of invariant texture analysis methods / Zhang Jianguo, Tan Tieniu // Pattern Recognition. – 2002. – Vol. 35. – P. 735-747.
6. **Lu, D.** A survey of image classification methods and techniques for improving classification performance / D. Lu, and Q. Weng // International Journal of Remote Sensing. – 2007. – Vol. 28(5). – P. 823-870.
7. **Thakare, V.S.** Survey On Image Texture Classification Techniques / Vishal S. Thakare, Nitin N. Patil and Jayshri S. Sonawane // International Journal of Advancements in Technology. – 2013. – Vol. 4(1). – P. 97-104.
8. **Jing, Y.T.** Recent Trends in Texture Classification. A Review / Y.T. Jing, H.T. Yong, Ye.L. Phooi // Symposium on Progress in Information & Communication Technology. – 2009 – P. 63-68.
9. **Rosenfeld, A.** Edge and curve detection for visual scene analysis / A. Rosenfeld and M. Thurston // IEEE Transaction on Computers. – 1971. – Vol. C-20 – P. 562-569.
10. **Geusebroek, J.** A six-stimulus theory for stochastic texture / J. Geusebroek and A. Smeulders // International Journal of Computer Vision. – 2005. – Vol. 62(1). – P. 7-16.
11. **Yanulevskaya, V.** Significance of the weibull distribution and its sub-models in natural image statistics / V. Yanulevskaya, J. Geusebroek // Proceedings of the Fourth International Conference on Computer Vision Theory and Applications (VISAPP). – 2009. – Vol. 1. – P. 355-362.
12. **Десятников, И.Е.** Алгоритмы поиска изображений в базах видеоданных / И.Е. Десятников, В.А. Утробин // Компьютерная оптика. – 2011. – Т. 35, №3. – С. 416-422.
13. **Asatryan, D.** Quality Assessment Measure Based on Image Structural Properties / D. Asatryan, K. Egiazarian // Proceedings of the International Workshop on Local and Non-Local Approximation in Image Processing, Finland, Helsinki. – 2009. – P. 70-73.
14. **Timma, F.** Non-parametric texture defect detection using Weibull features / F. Timma and E. Barth // Image Processing. Machine Vision Applications IV. Proceedings of SPIE. SPIE-IS&T. – 2011. – V. 7877.
15. **Soottitantawat, S.** Texture Classification Using an Invariant Texture Representation and a Tree Matching Kernel / Somkid Soottitantawat and Surapong Auwatanamongkol // IJCSI International Journal of Computer Science Issues. – 2011. – Vol. 8(1). – P. 98-106.
16. <http://hci.iwr.uni-heidelberg.de/Benchmarks/document/weakly-supervised-learning-industrial-optical-insp/>


*References*

1. **Tuceryan, M.** Texture Analysis / M. Tuceryan, A.K. Jain // Handbook of Pattern Recognition and Computer Vision. – 2nd ed. – 1998. – P. 207-248.
2. **Mellor, M.** Locally Rotation, Contrast, and Scale Invariant Descriptors for Texture Analysis / Mellor Matthew, Byung-Woo Hong and Michael Brady // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2008. – Vol. 30(1) – P. 52-61.
3. **Kupriyanov, A.V.** Texture Analysis and Identification of the Crystal Lattice Type upon the Nanoscale Images / A.V. Kupriyanov // Computer Optics. – 2011. – Vol. 35(2). – P. 151-157. – (In Russian).
4. **Bongkyu, L.** A New Method for Classification of Structural Textures / Lee Bongkyu // International Journal of Control, Automation, and Systems. – 2004. – Vol. 2(1) – P. 125-133.
5. **Jianguo, Zh.** Brief review of invariant texture analysis methods / Zhang Jianguo, Tan Tieniu // Pattern Recognition. – 2002. – Vol. 35. – P. 735-747.
6. **Lu, D.** A survey of image classification methods and techniques for improving classification performance / D. Lu, and Q. Weng // International Journal of Remote Sensing. – 2007. – Vol. 28(5). – P. 823-870.
7. **Thakare, V.S.** Survey On Image Texture Classification Techniques / Vishal S. Thakare, Nitin N. Patil and Jayshri S. Sonawane // International Journal of Advancements in Technology. – 2013. – Vol. 4(1). – P. 97-104.
8. **Jing, Y.T.** Recent Trends in Texture Classification. A Review / Y.T. Jing, H.T. Yong, Ye.L. Phooi // Symposium on Progress in Information & Communication Technology. – 2009 – P. 63-68.
9. **Rosenfeld, A.** Edge and curve detection for visual scene analysis / A. Rosenfeld and M. Thurston // IEEE Transaction on Computers. – 1971. – Vol. C-20 – P. 562-569.
10. **Geusebroek, J.** A six-stimulus theory for stochastic texture / J. Geusebroek and A. Smeulders // International Journal of Computer Vision. – 2005. – Vol. 62(1). – P. 7-16.
11. **Yanulevskaya, V.** Significance of the weibull distribution and its sub-models in natural image statistics / V. Yanulevskaya, J. Geusebroek // Proceedings of the Fourth International Conference on Computer Vision Theory and Applications (VISAPP). – 2009. – Vol. 1. – P. 355-362.
12. **Desyatnikov, I.E.** The Search Algorithm for Image in Databases / I.E. Desyatnikov, V.A. Utrobin // Computer Optics. – 2011. – Vol. 35(3) – P. 416-422. – (In Russian).
13. **Asatryan, D.** Quality Assessment Measure Based on Image Structural Properties / D. Asatryan, K. Egiazarian // Proceedings of the International Workshop on Local and Non-Local Approximation in Image Processing, Finland, Helsinki. – 2009. – P. 70-73.
14. **Timma, F.** Non-parametric texture defect detection using Weibull features / F. Timma and E. Barth // Image Processing. Machine Vision Applications IV. Proceedings of SPIE. SPIE-IS&T. – 2011. – V. 7877.
15. **Soottitantawat, S.** Texture Classification Using an Invariant Texture Representation and a Tree Matching Kernel / Somkid Soottitantawat and Surapong Auwatanamongkol // IJCSI International Journal of Computer Science Issues. – 2011. – Vol. 8(1). – P. 98-106.
16. <http://hci.iwr.uni-heidelberg.de/Benchmarks/document/weakly-supervised-learning-industrial-optical-insp/>

**METHOD FOR TEXTURE CLASSIFICATION USING IMAGE STRUCTURAL FEATURES***D.G. Asatryan<sup>1,2</sup>, V.V. Kurkchiyan<sup>2</sup>, L.R. Kharatyan<sup>2</sup>*<sup>1</sup> *Institute for Informatics and Automation Problems of the National Academy of Sciences,*<sup>2</sup> *Russian-Armenian (Slavonic) University***Abstract**

In this paper, novel method for texture analysis and classification based on using image structural properties is proposed. It is known that the Human Visual System successfully perceives an image content by visualized collection of existing edges. In this paper, we propose to use the collection of gradient magnitudes as the characteristics of the structure of an image. Gradient magnitude is assumed to be a random variable with two-parameter Weibull distribution, and as a characteristic of the proximity of the two images we use a special measure of proximity of the parameter estimates of the corresponding distributions. Classification is made by method of comparison with the etalon using the database of the University of Heidelberg (Germany) which contains 10 texture classes. As an etalon is used the set of average values of the parameters estimates of the Weibull distribution, calculated by the magnitude gradients of training set of texture, and comparison is performed using the proposed proximity measure. The analysis revealed two virtually indistinguishable classes, and for the remaining eight classes it is shown that the classification error on the average is about 18%.

**Key words:** classification, texture, gradient magnitude, Weibull distribution, similarity measure.

**Сведения об авторах**

**Асатрян Давид Гегамович**, родился в 1940 году, доктор технических наук, профессор. Руководитель научно-исследовательского центра критических технологий Российско-Армянского (Славянского) университета, ведущий научный сотрудник Института проблем информатики и автоматизации Национальной Академии наук Армении. Область научных интересов: обработка цифровых сигналов и изображений. Имеет научные публикации по проблемам анализа, регистрации, сегментации, оценивания качества, восстановления, ЦВЗ-защиты изображения.

E-mail: [dasat@ipia.sci.am](mailto:dasat@ipia.sci.am).



**David Gegamovich Asatryan**, (b. 1940), Doctor of Sciences (Engineering), Professor. Head of Research Center for Critical Technologies of Russian-Armenian (Slavonic) University, Leading Scientist of the Institute for Informatics and Automation Problems of National Academy of Sciences of Armenia. Field of scientific interests: digital signal and image processing. He has scientific publications on problems of image processing, registration, segmentation, quality assessment, restoration, watermarking.

**Куркчиан Вардан Вардгесович**, родился в 1987 году, кандидат технических наук, работает в Научно-исследовательском центре критических технологий Российско-Армянского (Славянского) университета. Область научных интересов: цифровая обработка изображений. Имеет научные публикации по вопросам анализа, регистрации и оценивания качества изображений.

E-mail: [vakur87@gmail.com](mailto:vakur87@gmail.com).

**Vardan Vardgesovich Kurkchiyan**, (b. 1987), PhD on Engineering, collaborator of Research Center for Critical Technologies of Russian-Armenian (Slavonic) University. Field of scientific interests: digital image processing. He has scientific publications on Image Analysis, Registration and quality assessment.



**Харатян Луиза Рафаэловна**, 1990 года рождения. Аспирант Российско-Армянского (Славянского) университета по специальности «Математическое и программное обеспечение вычислительных машин, комплексов и компьютерных сетей». Область научных интересов: обработка цифровых изображений.

E-mail: [luiza.kharatyan@gmail.com](mailto:luiza.kharatyan@gmail.com).

**Luiza Rafaelovna Kharatyan**, (b. 1990), is a graduate student of the Russian-Armenian (Slavonic) University with major in Mathematical and Software Support of Computing Machinery, Suites and Computer Network. Field of scientific interests: digital image processing, software engineering.

*Поступила в редакцию 20 марта 2014 г.*