

УДК 004.89

DOI: [10.26102/2310-6018/2024.46.3.012](https://doi.org/10.26102/2310-6018/2024.46.3.012)

Метод генерации контуров, сохраняющий характеристики распределения геометрических параметров, по обучающему набору с использованием полярного представления контуров

В.А. Калашников✉

*Финансовый университет при Правительстве Российской Федерации, Москва,
Российская Федерация*

Резюме. В статье представлен новый алгоритм аугментации визуальных данных на основе статистических методов. Метод включает в себя оригинальный способ кодирования контуров в виде одномерных векторов, хранящих информацию о расстояниях от центра тяжести до вершин под определенными углами. Предложен алгоритм генерации новых контуров, основанный на статистических характеристиках исходного набора данных и нормальном распределении. Ключевой особенностью метода является сохранение важных статистических свойств исходного набора данных, что подтверждается математическими доказательствами двух основных утверждений об инвариантности математического ожидания и дисперсии. Представлен визуальный пример, демонстрирующий работу метода на реальном контуре. Предложенный подход имеет потенциал для применения в различных областях, включая компьютерное зрение, медицинскую визуализацию и дистанционное зондирование, где генерация и аугментация данных о контурах объектов играют важную роль. Метод может быть особенно полезен в ситуациях, когда сбор реальных данных затруднен или ресурсоемок. Основные результаты получены аналитическим методом – разработанная математическая модель дополнена генератором случайных чисел из распределения с параметрами, рассчитанными на базе обучающего набора данных. Параметры подобраны таким образом, чтобы основные статистические характеристики обучающего набора данных сохранялись на синтетических данных, что позволяет эффективно применять предложенный алгоритм к широкому классу задач распознавания образов.

Ключевые слова: генерация контуров, полярное представление, аугментация данных, компьютерное зрение, статистические характеристики, машинное обучение.

Благодарности: Автор благодарит своего научного руководителя, доктора экономических наук В.И. Соловьева за консультирование в процессе разработки алгоритма и написания статьи.

Для цитирования: Калашников В.А. Метод генерации контуров, сохраняющий характеристики распределения геометрических параметров, по обучающему набору с использованием полярного представления контуров. *Моделирование, оптимизация и информационные технологии.* 2024;12(3). URL: <https://moitvvt.ru/ru/journal/pdf?id=1626> DOI: 10.26102/2310-6018/2024.46.3.012

A method for generating contours that preserve the distribution characteristics of geometric parameters from a training set using polar representation of contours

V.A. Kalashnikov✉

*Financial University under the Government of the Russian Federation, Moscow,
the Russian Federation*

Abstract. This article presents a new algorithm for visual data augmentation based on statistical methods. The method includes an original approach to encoding contours as one-dimensional vectors, storing information about distances from the center of gravity to vertices at specific angles. An algorithm for

generating new contours is proposed, based on the statistical characteristics of the original dataset and normal distribution. The key feature of the method is the preservation of important statistical properties of the original dataset, which is confirmed by mathematical proofs of two main statements about the invariance of mathematical expectation and variance. A visual example demonstrating the method's performance on a real contour is presented. The proposed approach has potential applications in various fields, including computer vision, medical imaging, and remote sensing, where generation and augmentation of object contour data play a crucial role. The method can be particularly useful in situations where collecting real data is difficult or resource-intensive. The main results were obtained through an analytical method – the developed mathematical model is supplemented by a random number generator from a distribution with parameters calculated based on the training dataset. The parameters are selected in such a way that the main statistical characteristics of the training dataset are preserved in the synthetic data, allowing for effective application of the proposed algorithm to a wide class of pattern recognition tasks.

Keywords: contour generation, polar representation, data augmentation, computer vision, statistical characteristics, machine learning.

Acknowledgements: The author expresses gratitude to his scientific advisor, Doctor of Economics V.I. Soloviev, for providing guidance during the algorithm development process and the writing of this article.

For citation: Kalashnikov V.A. A method for generating contours that preserve the distribution characteristics of geometric parameters from a training set using polar representation of contours. *Modeling, Optimization and Information Technology*. 2024;12(3). URL: <https://moitvvt.ru/ru/journal/pdf?id=1626> DOI: 10.26102/2310-6018/2024.46.3.012 (In Russ.).

Введение

Обогащение наборов данных для обучения сверточных нейронных сетей и иных алгоритмов компьютерного зрения является важной задачей в глубоком и машинном обучении [1]. Методы генерации контуров позволяют искусственно создавать дополнительные примеры изображений, значительно расширяя исходные наборы данных. Это особенно актуально для областей, где сбор реальных данных затруднен или является ресурсоемким, таких как медицинская визуализация [2], дистанционное зондирование Земли [3], подводные работы и др. [4]. Кроме того, синтезированные данные о контурах могут использоваться для тестирования и сравнительного анализа различных алгоритмов компьютерного зрения в контролируемых условиях [5]. Это позволяет оценивать робастность алгоритмов к различным искажениям и вариациям входных данных.

Методы генерации также помогают выявлять скрытые закономерности и взаимосвязи в имеющихся контурных данных. Это может привести к более глубокому пониманию природы данных и улучшению производительности алгоритмов, обученных на этих данных.

Наконец, генеративные модели для контуров потенциально могут использоваться в приложениях дополненной и виртуальной реальности, когда требуется синтезировать реалистичные контурные изображения в режиме реального времени на основе имеющихся данных [6]. Таким образом, исследования по генерации контуров являются актуальными и перспективными для дальнейшего развития областей компьютерного зрения и машинного обучения.

В научной литературе есть множество примеров симуляции и генерации контуров объектов. Ключевыми из них являются:

1) модели на основе деформации шаблонов (deformable templates) [7]. В них используется некий базовый контур-шаблон, который затем деформируется для получения новых контуров. Данный метод обладает большим количеством вариаций и

применяется в самых разных сферах, однако наиболее популярен в сфере распознавания лиц [8];

2) активные модели контуров (active shape/appearance models). Они обучаются на наборе размеченных контуров и могут генерировать новые статистически допустимые контуры [9];

3) генеративно-состязательные сети (GAN). Нейросети, в которых генератор учится создавать реалистичные контуры, а дискриминатор – отличать настоящие от сгенерированных [10];

4) вариационные автокодировщики (VAE). Позволяют обучить скрытое представление контуров в латентном пространстве и сэмплировать из него новые контуры [11];

5) грамматики для генерации контуров. Определяются набор примитивов и правила их комбинирования.

Таким образом, методы симуляции и генерации контуров – активно развивающаяся область, в последние годы особенно бурно развиваются подходы на основе глубокого обучения (GAN, VAE и др.). Конкретный выбор зависит от типов объектов, требований к реалистичности, разнообразию, контролируемости генерации и т. д.

Материалы и методы

Предлагаемый метод представления контуров

В данной работе предлагается следующий метод представления контуров из обучающего набора данных. Путем описанных далее преобразований исходный контур преобразуется в одномерный вектор, который хранит информацию о расстояниях от центра тяжести до вершин под определенными углами, количество которых зависит от выбранной степени дискретизации. Отметим, что перед дальнейшими шагами работы наши контуры предполагаются ориентированными таким образом, чтобы прямая, соединяющая наиболее удаленные точки по длине, проходила параллельно горизонтальной границе изображения, а прямая, соединяющая наиболее удаленные точки по ширине, была ориентирована по вертикальной границе изображения.

Рассчитывать координаты конкретных векторов предлагается по следующей схеме.

Входные данные:

Последовательность координат многоугольника контура, заданная в виде списка списков.

$$P = [[x_1; y_1]; [x_2; y_2] \dots [x_n; y_n]].$$

Степень дискретизации контура d – натуральное число.

Шаг 1 (расчет центра тяжести контура)

Найдем центр тяжести контура на изображении по следующей формуле:

$$x_c = \frac{\sum_{i=1}^n x_i}{n},$$

$$y_c = \frac{\sum_{i=1}^n y_i}{n}.$$

Шаг 2 (задание системы координат)

Введем систему координат следующим образом. За начало отсчета возьмем найденный на первом шаге центр тяжести фигуры. Ось абсцисс и ординат проведем через крайние точки камня по x и y , то есть:

$$x_{min} = \min_i \{x_i\}; x_{max} = \max_i \{x_i\},$$

$$y_{min} = \min_i \{y_i\}; y_{max} = \max_i \{y_i\}.$$

Рассмотрим точки:

$$X_A = \{x_{min}; y_A\}; X_B = \{x_{max}; y_B\},$$

$$Y_A = \{x_A; y_{min}\}; Y_B = \{x_B; y_{max}\}.$$

Отметим, что вторая координата в каждой паре точек выбрана произвольным образом из пересечения контура и ограничивающего прямоугольника. В большинстве случаев, такая точка единственна, но если их несколько, то можно выбрать любую из них.

Теперь проведем прямые, проходящие через центр тяжести контура и параллельные $X_A X_B$ и $Y_A Y_B$ – эти прямые будут задавать систему координат.

Шаг 3 (задание угловых лучей)

И центра тяжести фигуры, от прямой $X_A X_B$ последовательно отложим d лучей, выходящих под равными углами: $\{0 * 360/d; 1 * 360/d \dots (d - 1) * 360 / d\}$.

Шаг 4 (расстояния до контура)

Найдем расстояния от начала координат до точки контура, расположенной на сегменте пересечения и запишем их в выходной вектор.

Выходные данные

Одномерный вектор из d чисел, характеризующих расстояния от начала координат до контура под каждым из d углов.

Предлагаемый метод генерации контуров

После проведения описанных выше преобразований мы получим обучающий набор данных в виде матрицы размеров d на m , где d – степень дискретизации контура, а m – количество элементов в обучающем наборе данных. Обозначим эту матрицу TD (training dataset). Таким образом,

$$TD = \{r_{ij}\}, i \in \{1, 2 \dots d\}, j \in \{1, 2 \dots m\}.$$

Далее рассмотрим каждый из столбцов матрицы TD как выборку из некоторого фиксированного распределения вероятностей. Поскольку контуры датасета могут иметь разные геометрические размеры, применим преобразования растяжения и сжатия по длине и ширине. Заметим, что эти параметры могут быть вычислены следующим образом:

$$l_j = r_{0j} - r_{\frac{d}{2}j},$$

$$w_j = r_{\frac{d}{4}j} - r_{\frac{3d}{4}j},$$

так как точки с индексами $0, d/2$ и $d/4$ и $3d/4$ являются диаметрально противоположными по длине и ширине относительно центра тяжести.

Координаты нормализованных точек контура будут связаны с исходными по следующим формулам.

$$\widehat{x}_{ij} \cdot l_j = r_{ij} \cos\left(i \cdot \frac{360}{d}\right),$$

$$\widehat{y}_{ij} \cdot w_j = r_{ij} \sin\left(i \cdot \frac{360}{d}\right).$$

Это является следствием того, что каждая из точек контура P_{ij} представляется с помощью описанного выше метода хранения информации в векторном виде:

$$\vec{P}_{ij} = r_j \left(\cos \left(i \cdot \frac{360}{d} \right) + \sin \left(i \cdot \frac{360}{d} \right) \right).$$

Для сокращения записей обозначим описанное выше преобразование $N(r)$.

Сформулируем следующий алгоритм генерации контуров.

Шаг 1 (нормализация набора данных)

Применим преобразование нормализации к каждой из строк матрицы тренировочного датасета TD, полученный в результате набор данных обозначим $N(TD)$.

Шаг 2 (вычисление модельного контура)

Найдем среднее значение каждого из столбцов набора $N(TD)$ и получим в результате усредненный нормализованный контур M_n . Далее умножим каждую из координат вектора M_n на среднее значение совокупности максимумов расстояний – для каждой строки TD выберем наибольшее значение. Полученный вектор назовем модельным и обозначим M .

Шаг 3 (генерация нового контура)

Для каждого исходного контура с фиксированным номером i вычислим отклонение от среднего контура путем нахождения модуля разности полярного представления контура и модельного контура, обозначим полученный вектор D . То есть:

$$D_i = |\{r_{ij}\} - M|.$$

Вычислим также и дисперсию по всем числам набора $\{D_i\}$ и обозначим ее $Var(D)$.

Теперь новый контур может быть получен путем преобразования исходного контура с помощью формулы:

$$N_{ij} = M + kD_i,$$

где число k – это сгенерированное с помощью языка программирования Python и модуля `numpy.random` действительное число из нормального распределения $N(0; P^2)$.

Параметр P будем рассчитывать по следующей формуле:

$$P = \frac{Var(D)}{Var_{\text{выб}}(D_i) + \left(\frac{\sum_{m=1}^d D_{im}}{d}\right)^2}.$$

Результаты

Инвариантные статистические характеристики предлагаемого метода

Пусть по каждому вектору из полярных представлений контуров мы сгенерировали представление N_{ij} .

Сформулируем и докажем далее следующие два утверждения:

(Утверждение 1)

Математическое ожидание i -ой компоненты сгенерированной совокупности векторов совпадает с i -ой компонентой вектора M .

Доказательство:

$$E(N_{ij}) = E(M + kD_i) = E(M) + E(kD_i) = M + D_i E(k) = M.$$

(Утверждение 2)

Дисперсия отклонений сгенерированной совокупности совпадает с рассчитанной дисперсией отклонений $Var(D)$.

Доказательство:

$$\begin{aligned} \text{Var}(N_{ij}) &= \text{Var}(M + kD_i) = \text{Var}(kD_i) \\ &= \text{Var}(k)\text{Var}(D_i) + E(k)^2\text{Var}(D_i) + E(D_i)^2\text{Var}(k) \\ &= \text{Var}(k)\text{Var}(D_i) + E(D_i)^2\text{Var}(k) = \text{Var}(k)[\text{Var}(D_i) + E(D_i)^2] \\ &= \text{Var}(D). \end{aligned}$$

Из написанного выше следует, что и дисперсия отклонений, и математическое ожидание реального и сгенерированного набора данных совпадают, это значит, что данные характеристики представляют собой инвариантные параметры для предлагаемого метода.

Пример исходного и сгенерированного контура приведен ниже на Рисунке 1 (реальный контур извлечен из изображения камня). На данном изображении можно наблюдать уменьшение длины и ширины замкнутого контура в результате применения описанного выше подхода. Из этого можно сделать вывод об отрицательности полученного генератором случайных чисел параметра k .

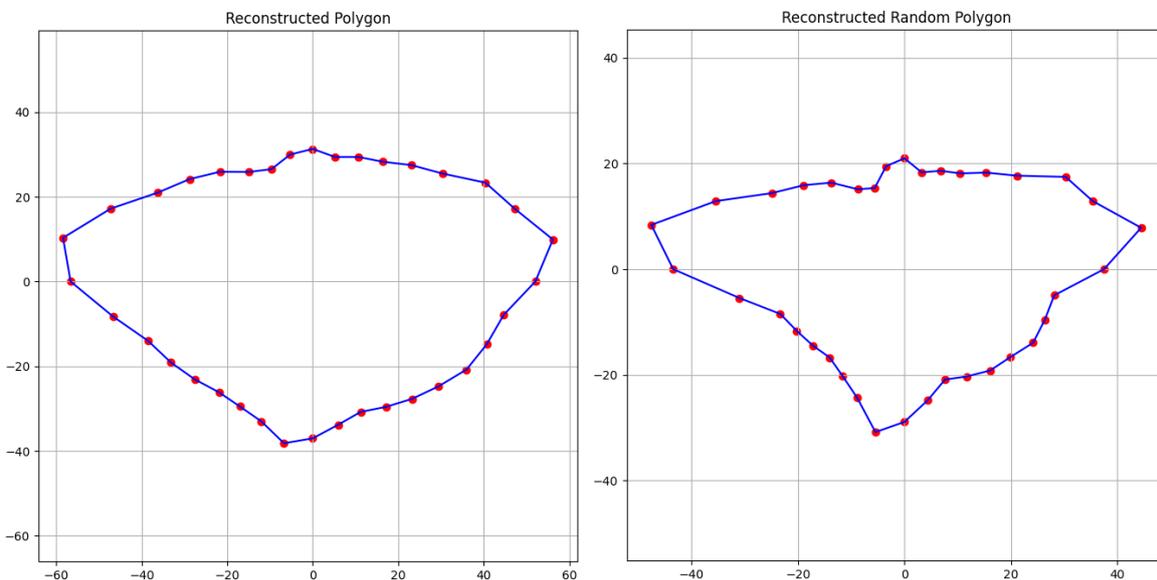


Рисунок 1 – Пример исходного и сгенерированного контура
 Figure 1 – Example of original and generated contour

Заключение

В данной работе был представлен новый метод генерации контуров на основе обучающего набора данных с использованием полярного представления контуров. Ключевые аспекты и результаты исследования включают:

1. Разработан эффективный способ представления контуров в виде одномерных векторов, хранящих информацию о расстояниях от центра тяжести до вершин под определенными углами.
2. Предложен алгоритм генерации новых контуров, основанный на статистических характеристиках обучающего набора данных и нормальном распределении.
3. Доказаны два важных утверждения об инвариантных статистических характеристиках метода:
 - а) математическое ожидание компонент сгенерированных векторов совпадает с компонентами модельного вектора;

б) дисперсия отклонений сгенерированной совокупности совпадает с дисперсией отклонений исходного набора данных.

4. Представлен визуальный пример, демонстрирующий работу метода на реальном контуре.

Предложенный метод имеет потенциал для применения в различных областях, где требуется генерация или аугментация данных о контурах объектов. Он может быть особенно полезен в задачах компьютерного зрения, медицинской визуализации, дистанционного зондирования и других сферах, где сбор реальных данных затруднен или ресурсоемок.

Дальнейшие исследования могут быть направлены на:

- оптимизацию параметров метода для различных типов контуров;
- расширение метода для работы с трехмерными объектами;
- интеграцию предложенного подхода с современными методами машинного обучения, такими как генеративно-сопоставительные сети (GAN) или вариационные автокодировщики (VAE);
- проведение сравнительного анализа с существующими методами генерации контуров.

В целом, представленный метод открывает новые возможности для генерации и анализа контуров, что может способствовать развитию алгоритмов компьютерного зрения и машинного обучения в различных прикладных областях.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Калашников В.А. Исследование методов аугментации в задаче сегментации камней на конвейере предприятия горной промышленности. *Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки*. 2024;(1):69–71.
Kalashnikov V.A. Study of augmentation methods in the problem of stone segmentation on a conveyor belt of a mining enterprise. *Sovremennaya nauka: aktual'nye problemy teorii i praktiki. Seriya: Estestvennyye i tekhnicheskie nauki = Modern Science: actual problems of theory and practice. Series: Natural and Technical Sciences*. 2024;(1):69–71. (In Russ.).
2. Веселов Д.И., Андриянов Н.А. Сегментация медицинских изображений с использованием методов компьютерного зрения. В сборнике: *Радиолокация, навигация, связь: Сборник трудов XXX Международной научно-технической конференции: Том 2, 16–18 апреля 2024 года, Воронеж, Россия*. Воронеж: Издательский дом ВГУ; 2024. С. 75–80.
Veselov D.I., Andriyanov N.A. Medical image segmentation using computer vision methods. In: *Radiolokatsiya, navigatsiya, svyaz': Sbornik trudov XXX Mezhdunarodnoi nauchno-tekhnicheskoi konferentsii: Volume 2, 16–18 April 2024, Voronezh, Russia*. Voronezh: Izdatel'skii dom VGU; 2024. pp. 75–80. (In Russ.).
3. Шелепов Л.К., Поляков А.Н. Оптимизация формирования набора данных для обучения модели YOLO с использованием данных ДЗЗ. В сборнике: *Far East Math – 2023: Материалы национальной научной конференции, 04–09 декабря 2023 года, Хабаровск, Россия*. Хабаровск: Тихоокеанский государственный университет; 2024. С. 146–150.
Shelepov L.K., Polyakov A.N. Optimization of dataset creation for YOLO model training using remote sensing data. In: *Far East Math – 2023: Materialy natsional'noi nauchnoi konferentsii, 04–09 December 2023, Khabarovsk, Russia*. Khabarovsk: Pacific National University; 2024. pp. 146–150. (In Russ.).

4. Ахмад А., Андриянов Н.А., Соловьев В.И., Соломатин Д.А. Применение глубокого обучения для аугментации и генерации подводного набора данных с промышленными объектами. *Вестник Южно-Уральского государственного университета. Серия: Компьютерные технологии, управление, радиоэлектроника*. 2023;23(2):5–16. <https://doi.org/10.14529/ctcr230201>
Ahmad A., Andriyanov N.A., Soloviev V.I., Solomatin D.A. Application of deep learning for augmentation and generation of an underwater data set with industrial facilities. *Vestnik Yuzhno-Ural'skogo gosudarstvennogo universiteta. Seriya: Komp'yuternye tekhnologii, upravlenie, radioelektronika = Bulletin of the South Ural State University. Series: Computer Technologies, Automatic Control, Radio Electronics*. 2023;23(2):5–16. (In Russ.). <https://doi.org/10.14529/ctcr230201>
5. Трубин А.Е., Морозов А.А., Зубанова А.Е., Ожередов В.А., Корепанова В.С. Методика предобработки данных машинного обучения для решения задач компьютерного зрения. *Прикладная информатика*. 2022;17(4):47–56. <https://doi.org/10.37791/2687-0649-2022-17-4-47-56>
Trubin A.E., Morozov A.A., Zubanova A.E., Ozheredov V.A., Korepanova V.S. The method of preprocessing machine learning data for solving computer vision problems. *Prikladnaya informatika = Journal of Applied Informatics*. 2022;17(4):47–56. (In Russ.). <https://doi.org/10.37791/2687-0649-2022-17-4-47-56>
6. Гибадуллин А.А. Генерация виртуальной реальности. *Академическая публицистика*. 2023;(12-2):231–233.
Gibadullin A.A. Generation of virtual reality. *Akademicheskaya publitsistika*. 2023;(12-2):231–233. (In Russ.).
7. Cheong Hou Y., Sahari K.S.M. Self-Generated Dataset for Category and Pose Estimation of Deformable Object. *Journal of Robotics, Networking and Artificial Life*. 2019;5(4):217–222. <https://doi.org/10.2991/jrnal.k.190220.001>
8. Gao X., Nguyen M., Yan W.Q. A High-Accuracy Deformable Model for Human Face Mask Detection. In: *Image and Video Technology: 11th Pacific-Rim Symposium (PSIVT 2023): Proceedings, 22–24 November 2023, Auckland, New Zealand*. Singapore: Springer; 2024. pp. 96–109. https://doi.org/10.1007/978-981-97-0376-0_8
9. Kramer D., Van der Merwe J., Lüthi M. A combined active shape and mean appearance model for the reconstruction of segmental bone loss. *Medical Engineering & Physics*. 2022;110. <https://doi.org/10.1016/j.medengphy.2022.103841>
10. Yuan H., Yanai K. Multi-Style Shape Matching GAN for Text Images. *IEICE Transactions on Information and Systems*. 2024;E107.D(4):505–514. <https://doi.org/10.1587/transinf.2023IHP0010>
11. Ribeiro T.F.R., Silva F., de C. Costa R.L. Reconstructing Spatiotemporal Data with C-VAEs. In: *Advances in Databases and Information Systems: 27th European Conference (ADBIS 2023): Proceedings, 04–07 September 2023, Barcelona, Spain*. Cham: Springer; 2023. pp. 59–73. https://doi.org/10.1007/978-3-031-42914-9_5

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Калашников Владимир Андреевич, Vladimir A. Kalashnikov, assistant, Financial ассистент, Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация.
University under the Government of the Russian Federation, Moscow, the Russian Federation.
e-mail: komb14@ya.ru
ORCID: [0000-0001-9701-9872](https://orcid.org/0000-0001-9701-9872)

*Статья поступила в редакцию 10.07.2024; одобрена после рецензирования 17.07.2024;
принята к публикации 24.07.2024.*

*The article was submitted 10.07.2024; approved after reviewing 17.07.2024;
accepted for publication 24.07.2024.*