



19. Daneshmand B. Analysis and evaluation of the effectiveness of methods for ensuring the quality of service for software-defined networks of the standard 5G/IMT-2020. *Russian Technological Journal*. 2021, vol. 9, no. 5, pp. 14–25. DOI: 10.32362/2500-316X-2021-9-5-14-25. Available at: <https://www.rty-mirea.ru/jour/article/download/364/301> (accessed 13 December 2025).
20. Serag R. H., Abdalzaheer M. S., El Atty Elsayed H. A., Sobh M. Software Defined Network Traffic Classification for QoS Optimization Using Machine Learning. *Journal of Network and Systems Management*. 2025, vol. 33, art. 41. DOI: 10.1007/s10922-025-09911-6. Available at: <https://link.springer.com/article/10.1007/s10922-025-09911-6> (accessed 13 December 2025).
21. Alashjaee A. M., Kushwaha S., Alamro H., Hassan A. A., Alanazi F., Mohamed A. Optimizing 5G network performance with dynamic resource allocation, robust encryption and Quality of Service (QoS) enhancement. *PeerJ Computer Science*. 2024, vol. 10, article e2567. DOI: 10.7717/peerj-cs.2567. Available at: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11622846/> (accessed 13 December 2025).
22. Sharma A. A Novel Dynamic Controller Mapping Approach in Software-Defined Networking to Neutralise Traffic Burst. *SSRN Electronic Journal*. January 2022. DOI: 10.2139/ssrn.4305985. Available at: [https://www.researchgate.net/publication/366392424\\_A\\_Novel\\_Dynamic\\_Controller\\_Mapping\\_Approach\\_in\\_Software-Defined\\_Networking\\_to\\_Neutralise\\_Traffic\\_Burst](https://www.researchgate.net/publication/366392424_A_Novel_Dynamic_Controller_Mapping_Approach_in_Software-Defined_Networking_to_Neutralise_Traffic_Burst) (accessed 13 December 2025).
23. Strzeciwiłk D., Nakhla R., Zawiślak R. Performance Analysis of a QoS System with WFQ Queuing Using Temporal Petri Nets. *Lecture Notes in Computer Science*. 2021, vol. 12865, pp. 462–476. DOI: 10.1007/978-3-030-84340-3\_38. Available at: [https://www.researchgate.net/publication/354654181\\_Performance\\_Analysis\\_of\\_a\\_QoS\\_System\\_with\\_WFQ\\_Queueing\\_Using\\_Temporal\\_Petri\\_Nets](https://www.researchgate.net/publication/354654181_Performance_Analysis_of_a_QoS_System_with_WFQ_Queueing_Using_Temporal_Petri_Nets) (accessed 13 December 2025).
24. Xie Y., Kong Y., Huang L., Wang S. Resource allocation for network slicing in dynamic multi-tenant networks: A deep reinforcement learning approach. *Computer Communications*. 2022, vol. 195, no. 3. DOI: 10.1016/j.comcom.2022.09.015. Available at: [https://www.researchgate.net/publication/363592172\\_Resource\\_allocation\\_for\\_network\\_slicing\\_in\\_dynamic\\_multi-tenant\\_networks\\_A\\_deep\\_reinforcement\\_learning\\_approach](https://www.researchgate.net/publication/363592172_Resource_allocation_for_network_slicing_in_dynamic_multi-tenant_networks_A_deep_reinforcement_learning_approach) (accessed 13 December 2025).

© Л. Р. Тенешев, Н. С. Мальцева

**Ссылка для цитирования:**

Тенешев Л. Р., Мальцева Н. С. Разработка алгоритмов автоматического распределения ресурсов в сетях связи на основе анализа трафика и приоритетов обслуживания // Инженерно-строительный вестник Прикаспия : научно-технический журнал / Астраханский государственный архитектурно-строительный университет. Астрахань : ГАОУ АО ВО «АГАСУ», 2026. № 1 (55). С. 119–126.

УДК 004.932.2:004.931

DOI 10.52684/2312-3702-2026-55-1-126-134

**МАТЕМАТИЧЕСКАЯ МОДЕЛЬ И ПРОГРАММНЫЙ КОМПЛЕКС  
ДЛЯ СИСТЕМЫ ДЕТЕКТИРОВАНИЯ СИНТЕТИЧЕСКИХ ИЗОБРАЖЕНИЙ ЛИЦ  
В СРЕДЕ МЕССЕНДЖЕРА НА БАЗЕ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ EFFICIENTNETV3**

**И. А. Соловьева, И. Б. Муравьев, Д. С. Соловьев**

**Соловьева Инна Александровна**, кандидат технических наук, доцент кафедры математического моделирования и информационных технологий, Тамбовский государственный университет имени Г. Р. Державина, г. Тамбов, Российская Федерация, тел.: + 7 (4752) 72-34-34; e-mail: good.win32@yandex.ru;

**Муравьев Иван Борисович**, магистрант, Тамбовский государственный университет имени Г. Р. Державина, г. Тамбов, Российская Федерация, тел.: + 7 (4752) 72-34-34; e-mail: ivanmuravjov@gmail.com;

**Соловьев Денис Сергеевич**, доктор технических наук, профессор кафедры математического моделирования и информационных технологий, Тамбовский государственный университет имени Г. Р. Державина, г. Тамбов, Российская Федерация, тел.: + 7 (4752) 72-34-34; e-mail: solovjevdenis@mail.ru

Объектом исследования является система детектирования синтетических изображений лиц в условиях мессенджеров. Мотивация работы обусловлена рисками распространения фейковых аккаунтов и дезинформации, возникающими при использовании генеративных моделей. В основе метода лежит математическая модель бинарной классификации на архитектуре EfficientNetV3, интегрированная в полный конвейер обработки изображений с этапами детекции лиц, кадрирования и нормализации. При обучении применялись техники дообучения, агрессивной аугментации и регуляризации. В результате достигнута точность классификации 92,5 % и ROC-AUC 98 % на сбалансированной выборке. Система демонстрирует устойчивость к JPEG-сжатию до уровня качества 60 % с потерей точности менее 3 %. Разработанный Telegram-бот подтвердил работоспособность модели в условиях, имитирующих реальное применение.

**Ключевые слова:** синтетические изображения лиц, детектирование, математическая модель, EfficientNetV3, мессенджер, бинарная классификация, программный комплекс, обработка изображений, система, Telegram-бот.

**MATHEMATICAL MODEL AND SOFTWARE COMPLEX FOR A SYNTHETIC FACE IMAGE DETECTION SYSTEM  
IN MESSENGER ENVIRONMENTS BASED ON EFFICIENTNETV3 CONVOLUTIONAL NEURAL NETWORK**

**I. A. Solovyeva, I. B. Muravyev, D. S. Solovyev**

**Solovyeva Inna Aleksandrovna**, Candidate of Technical Sciences, Associate Professor of Mathematical Modeling and Information Technologies Department, Derzhavin Tambov State University, Tambov, Russian Federation, phone: + 7 (4752) 72-34-34; e-mail: good.win32@yandex.ru;

**Muravyev Ivan Borisovich**, undergraduate student, Derzhavin Tambov State University, Russian Federation, phone: + 7 (4752) 72-34-34; e-mail: ivanmuravjov@gmail.com;

**Solovyev Denis Sergeyevich**, Doctor of Technical Sciences, Professor of Mathematical Modeling and Information Technologies Department, Derzhavin Tambov State University, Tambov, Russian Federation, phone: + 7 (4752) 72-34-34; e-mail: solovjevdenis@mail.ru

The study focuses on a system for detecting synthetic face images in messenger environments. The motivation arises from the risks of fake accounts and misinformation propagation due to generative models. The method is based on a binary classification mathematical model using the EfficientNetB3 architecture, integrated into a full image processing pipeline including face detection, cropping and normalization. Training techniques involved transfer learning, aggressive data augmentation and regularization. The model achieved a classification accuracy of 92,5 % and ROC-AUC of 98 % on a balanced test set. The system exhibits robustness to JPEG compression up to 60% quality with less than 3 % accuracy drop. The implemented Telegram bot confirmed the model's functionality in near-real-world conditions.

**Keywords:** *synthetic face images, detection, mathematical model, EfficientNetB3, messenger, binary classification, software complex, image processing, system, Telegram bot.*

## Введение

Быстрое развитие генеративных моделей глубокого обучения, таких как генеративно-состязательные сети и диффузионные модели [1], привело к созданию синтетических изображений лиц, практически неотличимых от фотографических [2]. Широкое распространение таких изображений в цифровой среде, включая мессенджеры, создает значительные риски для информационной безопасности, способствуя распространению фейковых аккаунтов, дезинформации и мошенничества с использованием социальной инженерии [3]. Задача автоматического детектирования синтетических изображений лиц является предметом активных исследований. Существующие подходы можно условно разделить на две группы. К первой относятся методы, основанные на анализе низкоуровневых статистических признаков и спектральных характеристик [4, 5], демонстрирующие ограниченную эффективность против современных генеративных моделей. Вторая группа основана на применении глубоких сверточных нейронных сетей (CNN), обученных на размеченных наборах данных [6]. Архитектуры, такие как ResNet и Xception, показывают высокую точность в контролируемых условиях. Однако, как показали работы [7, 8], их производительность и устойчивость критически снижаются в условиях, характерных для систем реального времени, таких как мессенджеры: при сильном сжатии и ресемплинге изображений, необходимости минимизации времени инференса и работе на оборудовании с ограниченными ресурсами. В частности, недостаточно изучены вопросы адаптации и оптимизации сложных CNN-архитектур для встраивания в клиент-серверные приложения с высокой нагрузкой. Таким образом, актуальной остается проблема разработки не только точного, но и эффективного с точки зрения вычислений метода детекции, ориентированного на работу в условиях реальных коммуникационных платформ.

Целью настоящего исследования является разработка математической модели и программного комплекса для детектирования синтетических изображений лиц в среде мессенджера, обеспечивающих баланс между высокой классификационной точностью и низкими вычислительными затратами.

Для достижения поставленной цели необходимо решить следующие задачи:

- 1) разработать полный конвейер обработки изображений для целевой среды (мессенджер), включающий этапы детекции лиц, их стандартизацию и подготовку датасета, устойчивого к артефактам сжатия;
- 2) построить, обучить и оптимизировать математическую модель бинарной классификации на основе архитектуры EfficientNetB3 для детекции синтетических лиц;
- 3) реализовать программный комплекс, интегрирующий обученную модель в среду мессенджера (Telegram-бот), и провести его всестороннее тестирование;
- 4) провести экспериментальную оценку точности, устойчивости к сжатию и общей работоспособности системы на смешанной выборке реальных и синтетических изображений.

## Метод

### 1. Постановка задачи

В рамках данного исследования решается задача бинарной классификации произвольного входного изображения по признаку происхождения лица, присутствующего на нем:

$$I \in \mathbb{R}^{H \times W \times 3}, \quad (1)$$

где  $H$  – высота;  $W$  – ширина; 3 – число цветовых каналов.

Формально, задача заключается в построении отображения:

$$F: I \rightarrow \{0,1\}, \quad (2)$$

где 1 – соответствует реальному (фотографическому) изображению лица; 0 – соответствует синтетическому, сгенерированному нейросетевой моделью, изображению лица.

Поскольку изображение (1) может содержать несколько объектов, фоновые помехи или не содержать лиц вовсе, полный конвейер обработки включает два последовательных этапа: 1) локализация и извлечение области лица; 2) классификация извлеченной области. Таким образом, модель представляет собой композицию:

$$F(I) = C(L(I)), \quad (3)$$

где  $L$  – оператор локализации лица;  $C$  – классификатор реалистичности лица.

### 2. Локализация лиц и предобработка данных

Конвейер обработки изображений начинается с детекции и извлечения областей лиц, что позволяет изолировать целевые объекты от фона и посторонних элементов, обеспечивая корректную работу последующего классификатора.

### 2.1. Выбор методов детекции лиц на разных этапах работы

В ходе исследования детекция лиц выполнялась на двух независимых этапах, что обусловило выбор разных методов, оптимальных для решения конкретных подзадач:

1) этап подготовки датасета. Для автоматического выделения и кадрирования лиц из обширных исходных коллекций изображений применялся каскадный классификатор на основе признаков Хаара, реализованный в библиотеке OpenCV [9]. Этот выбор был обусловлен высокой скоростью обработки, что критически важно для работы с большими объемами данных, и достаточной для данной задачи точностью при фронтальных ракурсах лиц;

2) этап работы финальной системы. В разработанном программном комплексе (Telegram-бот), предназначенном для детектирования в условиях, близких к реальным, используется нейросетевая модель Multi-task Cascaded Convolutional Networks (MTCNN) [10]. MTCNN была выбрана для финального внедрения благодаря своей превосходной точности локализации лиц при различных ракурсах, условиях освещения и частичных перекрытиях (окклюзиях), что обеспечивает надежность работы всего конвейера в неконтролируемой среде мессенджера.

Таким образом, метод Хаара применялся как инструмент предобработки для создания датасета, а MTCNN является ключевым компонентом детекции в итоговой рабочей системе.

### 2.2. Предобработка области лица

Первичная обработка направлена на выделение из исходного изображения  $I$  стандартизованного тензора  $X \in \mathbb{R}^{224 \times 224 \times 3}$ , содержащего только область лица. Для вычисления суммы яркостей в любой прямоугольной области алгоритм работает с интегральным представлением изображения:

$$I(x, y) = \sum_{x' \leq x, y' \leq y} I_{gs}(x', y'), \quad (4)$$

Где  $I_{gs}$  – изображение в градациях серого;  $x', y', x, y$  – координаты точки изображения.

Слабая классификация прямоугольной области  $R$  описывается функцией:

$$h_j(R) = \text{sign}[\sum_{p \in R_{white}} I_{gs}(p) - \sum_{p \in R_{black}} I_{gs}(p) - \theta_j], \quad (5)$$

где  $R_{white}$ ,  $R_{black}$  – смежные прямоугольники, образующие признак;  $\theta_j$  – порог;  $p$  – точка изображения;  $j$  – индекс признака в каскаде (номер слабого классификатора).

Итоговый сильный классификатор последовательно применяется в каскаде для быстрого отбрасывания негативных областей и вычисляется как:

$$H(R) = \text{sign}(\sum_{j=1}^J \alpha_j h_j(R) - \theta), \quad (6)$$

где  $\alpha_j$  – веса, обученные алгоритмом AdaBoost [11];  $J$  – общее количество слабых классификаторов в данном каскаде;  $\theta$  – порог принятия решения для сильного классификатора.

Для каждого обнаруженного ограничивающего прямоугольника  $(x, y, w, h)$  выполняется кадрирование:

$$X_{crop} = I[y: y + h, x: x + w]. \quad (7)$$

Полученный фрагмент масштабируется до фиксированного размера  $224 \times 224$  пикселя билинейной интерполяцией. Процесс завершается операцией нормализации:

$$X = X_{crop}^{resized} / 255, \quad (8)$$

которая переводит значения пикселей в диапазон  $[0; 1]$ .

Такая предобработка обеспечивает инвариантность к исходному разрешению и частичную устойчивость к аффинным искажениям.

### 3. Архитектура классификационной модели

В качестве базовой модели для классификатора  $C$  выбрана сверточная нейронная сеть EfficientNetB3 [12]. Данный выбор основан на проведенном анализе современных архитектур CNN (включая ResNet, Xception и Vision Transformer) с точки зрения их эффективности в задачах бинарной классификации изображений. Критериями сравнения являлись: точность на эталонных наборах данных (ImageNet), вычислительная сложность (количество параметров, FLOPs), время инференса и способность к извлечению высокоуровневых семантических признаков, необходимых для различения тонких артефактов генерации. EfficientNetB3 продемонстрировала оптимальное соотношение точности и производительности, что критически важно для работы в системах реального времени, таких как мессенджеры. Предварительное обучение на наборе ImageNet обеспечивает модель богатым набором начальных признаков [13], что позволяет эффективно применять технику дообучения на специализированном датасете.

Архитектура EfficientNetB3 построена на основе мобильного инвертированного бутылочного слоя (MBConv) с механизмом взаимодействия между каналами Squeeze-and-Excitation (SE). Основной блок MBConv для входного тензора  $U$  размерности  $h \times w \times k$  выполняет следующие преобразования:

1. Применяется свертка  $1 \times 1$  с коэффициентом расширения  $t$ , увеличивая число каналов до  $tk$ :

$$\tilde{U} = \text{Conv}_{1 \times 1}(U), \quad (9)$$

Где  $\text{Conv}$  – операция свертки.

2. Пространственные признаки извлекаются глубиной сверткой  $3 \times 3$ :

$$\tilde{\tilde{U}} = \text{DepthwiseConv}_{3 \times 3}(\tilde{U}), \quad (10)$$

где  $\text{Depthwise}$  – операция глубокой свертки.

3. Для адаптивного перевзвешивания каналов применяется SE-механизм, который глобальным средним пулингом преобразует  $\tilde{\tilde{U}}$  в вектор  $z \in \mathbb{R}^{tk}$ :

$$z_c = \frac{1}{h \times w} \sum_{i=1}^h \sum_{j=1}^w \tilde{\tilde{U}}_c(i, j), \quad (11)$$

Где  $c$  – индекс канала (от 1 до  $tk$ ).

Затем два полносвязных слоя формируют вектор внимания:

$$s = \sigma(W_2 \delta(W_1 z)), \quad (12)$$

где  $\delta$  – ReLU-активация;  $\sigma$  – сигмоида;  $W_1, W_2$  – обучаемые веса.

Итоговый тензор получается поэлементным умножением:

$$\tilde{\tilde{\tilde{U}}}_c = s_c \tilde{\tilde{U}}_c. \quad (13)$$

4. Свертка  $1 \times 1$  уменьшает число каналов обратно до  $k$ , и если размерности совпадают, применяется остаточное соединение:

$$V = Conv_{1 \times 1}(\bar{U}) + U. \quad (14)$$

Исходная модель была модифицирована для решения задачи бинарной классификации. Верхние полносвязные слои заменены на новую последовательность. На выход базовой модели (тензор размерности  $7 \times 7 \times 1536$ ) применяется слой глобального среднего пулинга вида:

$$g = \frac{1}{7 \times 7} \sum_{i=1}^7 \sum_{j=1}^7 V_{:,:,c}(i, j), \quad (15)$$

формируя вектор признаков  $g \in \mathbb{R}^{1536}$ . Далее следует полносвязный слой из 512 нейронов с активацией ReLU и L2-регуляризацией (метод борьбы с переобучением, штрафующий модель за слишком большие значения весов; коэффициент регуляризации  $\lambda = 0,01$ ), слой Dropout (метод регуляризации, который случайным образом "отключает" заданную долю нейронов во время обучения, что предотвращает ко-адаптацию признаков) с вероятностью 0,5 для борьбы с переобучением и финальный нейрон с сигмоидальной активацией.

Таким образом, классификатор  $C$  реализует функцию:

$$f(X; \theta) = \sigma(\omega^T \phi(X) + b), \quad (16)$$

где  $\phi(X)$  – вектор признаков, извлеченный базовой сетью;  $\theta$  – параметры модели;  $\omega$  – веса добавленных полносвязных слоев (включая выходной нейрон);  $T$  – операция транспонирования;  $b$  – смещение.

Итоговое решающее правило имеет вид:

$$\hat{y} = I[f(X; \theta) > 0,5], \quad (17)$$

где  $I[\cdot]$  – индикаторная функция.

#### 4. Обучение модели и методы оптимизации

Модель обучалась методом минимизации бинарной кросс-энтропийной функции потерь:

$$L(\theta) = -\frac{1}{N} \sum_{i=1}^N [y_i \log(f(X_i; \theta)) + (1 - y_i) \log(1 - f(X_i; \theta))], \quad (18)$$

где  $N$  – количество обучающих примеров (батчей);  $y_i$  – истинная метка.

Для повышения обобщающей способности применялась агрессивная аугментация данных в режиме реального времени с использованием

ImageDataGenerator (Keras) [14]. Каждое изображение в обучающем батче подвергалось случайному преобразованию из набора: поворот в диапазоне  $\pm 50^\circ$ , сдвиги по ширине и высоте на 30 %, сдвиг на 40 %, масштабирование в диапазоне  $[0,6; 1,4]$ , горизонтальное отражение. Нормировка значений в диапазон  $[0,1]$  также являлась частью конвейера аугментации.

Использовалась стратегия дообучения с замороженными на начальных этапах весами первых 150 слоев базовой модели EfficientNetB3. Оптимизация проводилась алгоритмом Adam с начальной скоростью обучения  $\eta = 5 \times 10^{-5}$  [15]. Для адаптивного управления процессом обучения применялись callback-функции: ReduceLROnPlateau (уменьшение  $\eta$  в 2 раза при отсутствии улучшения метрики val\_loss в течение 5 эпох), EarlyStopping (остановка при отсутствии уменьшения (18) в течение 7 эпох) и ModelCheckpoint для сохранения лучшей по валидационной метрике версии модели. Обучение проводилось на графическом процессоре AMD Radeon RX 580 с использованием ROCm 3.5.1 и TensorFlow [16]. Для управления памятью GPU использовался механизм memory\_growth, а объем доступной видеопамяти был ограничен 7 Гб.

В рамках предложенного метода от постановки задачи в виде отображения (1), (2) и композиции модели (3) до процессов локализации лиц (4)–(8), описания архитектуры классификатора (9)–(17) и функции потерь (18) реализован полный конвейер обработки и классификации изображений.

#### 5. Программная реализация и интеграция

Программный комплекс реализован на языке Python и состоит из трех модулей: 1) подготовки датасета, 2) обучения модели, 3) Telegram-бота. Интеграция в мессенджер осуществлена через библиотеку python-telegram-bot. Обработка запроса от пользователя в виде диаграммы последовательности на языке UML представлена на рисунке 1.

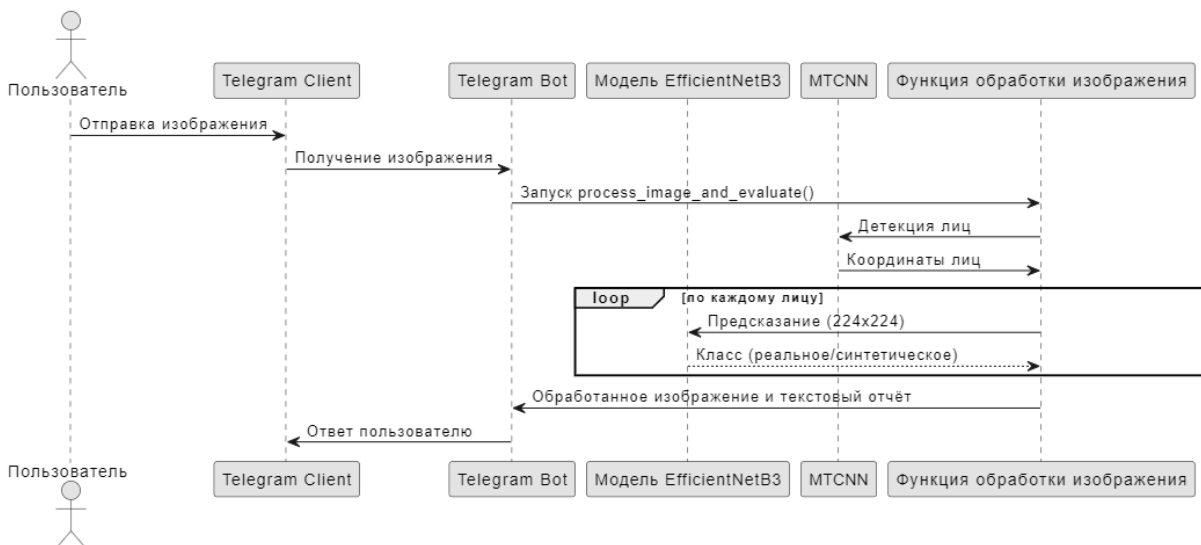


Рис. 1. Диаграмма последовательности обработки запроса от пользователя (иллюстрация авторов)

Fig. 1. Sequence diagram of user request processing (illustration by the authors)

Обработка запроса выполняется по следующему алгоритму:

- 1) пользователь отправляет изображение боту;
- 2) бот сохраняет файл и передает его в функцию `process_image_and_evaluate()`;
- 3) для детекции лиц используется нейросетевая модель MTCNN;
- 4) для устранения дубликатов применяется эвристика: два ограничивающих прямоугольника  $(x_1, y_1, w_1, h_1)$  и  $(x_2, y_2, w_2, h_2)$  считаются дубликами, если  $|x_1 - x_2| < \max(w_1, w_2) / 2$  и  $|y_1 - y_2| < \max(h_1, h_2) / 2$ ;
- 5) каждое уникальное лицо кадрируется, масштабируется, нормализуется и подается на вход обученной модели EfficientNetB3;
- 6) результат классификации (вероятность и метка) наносится на исходное изображение, которое вместе с текстовым отчетом возвращается пользователю.

## Результаты и обсуждение

В данном разделе представлены комплексные результаты тестирования системы, включающие качественный анализ работы конвейера, количественные метрики эффективности модели, оценку ее устойчивости к сжатию и сравнительный анализ с существующими подходами.

### 1. Качественный анализ работы системы

Верификация работы полного конвейера (детекция лица → классификация) проводилась на разнородной выборке изображений, включающей одиночные и групповые портреты, фотографии с животными и фоновыми объектами, а также синтетические изображения высокой степени реалистичности (рис. 2).



Рис. 2. Примеры входных данных для тестирования системы:  
 а) одиночный портрет; б) групповой портрет; в) сцена с человеком и животным;  
 г) мультипликационный персонаж (иллюстрация авторов)

Fig. 2. Examples of input data for system testing: a) single portrait; b) group portrait; c) scene with a human and an animal; d) cartoon character (illustration by the authors)

На рисунке 2а показана успешная классификация реального фотографического портрета разработанной системой. Модель отнесла его к классу «real» с вероятностью 99,83 %. Высокая уверенность обусловлена наличием естественных артефактов: неоднородной текстурой кожи с порами, асимметрией черт лица, физически корректным распределением света

и теней, а также детализированной проработкой волос и щетины. Система устойчиво работает со сложными сценами. На рисунке 2б протестирован случай с двумя лицами в кадре. Модель успешно детектировала оба лица, независимо проанализировала каждое и выдала индивидуальные оценки. Первое лицо было классифицировано как синтетическое (0,41 %

вероятности быть реальным), второе – с пограничной уверенностью (30,27 %). Такой результат демонстрирует способность системы выделять и оценивать множественные объекты, а также указывает на сложность задачи при работе с высококачественными генерациями, где признаки синтетичности могут быть выражены слабее.

Важным аспектом является специфичность работы алгоритма детекции лиц. Как видно на рис. 2в, на изображении, содержащем человека и животное, модель MTCNN корректно проигнорировала морду животного, идентифицировав только человеческое лицо, которое и было передано на классификацию. Это подтверждает корректность работы конвейера и его ориентацию исключительно на целевой объект исследования – челове-

ческое лицо. На рисунке 2г представлен предельный случай – изображение без человеческих лиц (мультипликационный персонаж). Система, верно, сообщила об отсутствии детектируемых объектов, что исключает ложные срабатывания классификатора на нерелевантных данных.

#### 2. Количественная оценка эффективности модели

Для количественной оценки обученной модели EfficientNetB3 был сформирован тестовый датасет, не участвовавший в обучении и валидации. Он содержал 200 изображений, сбалансированных по классам (100 реальных и 100 синтетических). Синтетические изображения были получены от различных современных генеративных моделей (StyleGAN2, StyleGAN3, Stable Diffusion) [17]. Результаты оценки показаны в таблице 1.

Таблица 1

Результаты классификации на тестовом наборе данных

№ п/п	Класс	Точность, %	Полнота, %	F1-мера, %	ROC-AUC, %
1	2	3	4	5	6
2	Реальные лица	94	92	93	98
3	Синтетические лица	91	93	92	98
4	Среднее	92,5	92,5	92,5	98

Общая точность модели составила 92,5 %, что свидетельствует о высокой эффективности выбранной архитектуры и методики обучения. Значение площади под ROC-кривой (AUC = 98 %) близко к максимальному, что указывает на отличную способность модели разделять два класса. Сбалансированные значения метрик для каждого из классов (полнота, F1-мера ~ 92 %) говорят об отсутствии существенного смещения модели в пользу одного из них.

#### 3. Анализ устойчивости к артефактам сжатия

Учитывая целевую среду применения (мессенджеры), была проведена серия экспериментов по оценке устойчивости модели к JPEG-сжатию. Исходные изображения из тестового набора последовательно сжимались с возрастающим уровнем компрессии (качество от 90 до 30 %). Результаты показывают, что точность модели остается стабильной

(снижение менее 3 %) при качестве сжатия вплоть до 60%, что соответствует типичным настройкам мессенджеров. Резкое падение точности наблюдается лишь при экстремальном сжатии (качество 30 %), которое приводит к появлению макро-артефактов, нарушающих как семантику изображения, так и низкоуровневые статистические паттерны, на которые опирается разработанная модель.

#### 4. Сравнение с известными подходами

Для контекстуализации полученных результатов проведено сравнение предложенного подхода на базе модифицированной EfficientNetB3 с другими методами и архитектурами, описанными в литературе. Сравнение проводилось по ключевым для прикладного внедрения параметрам: точности и относительному времени инференса на одном изображении. Результаты представлены в таблице 2.

Таблица 2

Сравнение предложенного метода с известными решениями

№ п/п	Архитектура / Метод	Точность, %	Относительное время инференса
1	2	3	4
2	EfficientNetB3	92,5	1,0x
3	ResNet50 [7]	89,1	1,4x
4	Xception [8]	90,3	1,8x
5	Vision Transformer (ViT-B/16) [18]	91,8	3,2x
6	Классический подход (HOG + SVM) [19]	74,2	0,3x
7	Метод на основе анализа Фурье-спектра [20]	81,5	0,7x

Результаты показывают, что предложенное решение превосходит по точности не только классические методы анализа признаков (HOG+SVM, частотный анализ), но и другие популярные глубокие архитектуры аналогичной сложности (ResNet50, Xception). Сравнение с Vision Transformer, показавшим близкую точность, демонстрирует ключевое практическое пре-

имущество EfficientNetB3 – существенно более высокую скорость работы (в 3,2 раза), что является критически важным для систем реального времени и массового использования в мессенджерах.

#### Заключение

В результате проведенного исследования была успешно решена задача создания эффективной си-

стемы для детектирования синтетических изображений лиц, адаптированной к условиям работы в среде мессенджера. Работа позволила достичь поставленной цели – разработать математическую модель и программный комплекс, обеспечивающие баланс между высокой классификационной точностью и приемлемыми вычислительными затратами. На основе решения сформулированных задач получены следующие основные выводы:

1. Разработанный полный конвейер обработки изображений, включающий операции кадрирования, масштабирования до размера  $224 \times 224$  пикселей и нормализацию, позволяет формировать однородный входной поток данных для нейросетевой модели. На этапе формирования датасета для автоматической разметки использовался каскадный классификатор Хаара. В финальную систему интегрирован нейросетевой детектор MTCNN.

2. Построенная математическая модель на базе архитектуры EfficientNetB3 продемонстрировала высокую эффективность в задаче бинарной классификации синтетических и реальных лиц. Использование стратегии дообучения с заморозкой начальных слоев, агрессивной аугментации данных и регуляризации (Dropout, L2) позволило достичь точности 92,5 % и значения ROC-AUC 98 % на независимой тестовой выборке. Модель показала оптимальное соотношение точности и скорости инференса по сравнению с альтернативными архитектурами (ResNet50, Xception, Vision Transformer).

3. Реализованный программный комплекс в виде Telegram-бота подтвердил свою работоспособность в

условиях, имитирующих реальное применение. Система корректно обрабатывает входящие изображения, выполняет детекцию нескольких лиц, проводит их классификацию и возвращает пользователю наглядный результат с вероятностной оценкой. Интеграция модели в окружение мессенджера выполнена с использованием асинхронной обработки и эффективного управления памятью GPU.

4. Комплексное тестирование системы на сбалансированной выборке, содержащей 200 изображений (100 реальных и 100 синтетических), показало стабильно высокие метрики качества. Анализ устойчивости к сжатию выявил, что точность модели снижается менее чем на 3 % при качестве JPEG не ниже 60%, что соответствует требованиям эксплуатации в мессенджерах. Качественная оценка работы системы на разнородных данных (одиночные и групповые портреты, изображения с животными) подтвердила корректность работы всего конвейера.

Таким образом, в ходе исследования разработана и апробирована интегрированная система детектирования синтетических изображений лиц, сочетающая современные методы глубокого обучения, математического моделирования и программной инженерии. Дальнейшее развитие работы может быть направлено на адаптацию модели для мобильных устройств, повышение ее устойчивости к состязательным атакам и интеграцию методов объяснимого искусственного интеллекта для повышения доверия пользователей.

#### Список литературы

1. Peng Y. A Comparative Analysis Between GAN and Diffusion Models in Image Generation / Y. Peng // Transactions on Computer Science and Intelligent Systems Research. – 2024. – Vol. 5. – P. 189–195. – DOI 10.62051/0f1va465.
2. Boyd A. The Value of AI Guidance in Human Examination of Synthetically-Generated Faces / A. Boyd, P. Tinsley, K. Bowyer, A. Czajka // Proceedings of the AAAI Conference on Artificial Intelligence. – 2023. – Vol. 37, No. 5. – P. 5930–5938. – DOI 10.1609/aaai.v37i5.25734.
3. Жарова А. К. Технологии дипфейк: социально-правовые риски нарушения частной жизни лица и правовые решения / А. К. Жарова // Правопорядок: история, теория, практика. – 2025. – № 2 (45). – С. 63–68. – DOI 10.47475/2311-696X-2025-45-2-63-68.
4. Нгуен Т. Т. Метод распознавания фигур с использованием фурье-дескрипторов и нейронной сети / Т. Т. Нгуен // Проблемы информатики. – 2011. – № S2. – С. 64–69.
5. Хасан А. А. Анализ текстурных признаков на изображениях / А. А. Хасан, В. С. Панищев, В. П. Решетникова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. – 2014. – № 2. – С. 102–107.
6. Куликов С. В. Исследование возможности совместного применения нейросетевого преобразователя биометрия-код и глубокой сверточной нейронной сети в распознавании лиц / С. В. Куликов, О. С. Захаров, Д. Ю. Андреев // Информационные технологии. – 2018. – Т. 24, № 2. – С. 116–120.
7. Sowmya M. Human Behavior Classification using 2D - Convolutional Neural Network, VGG16 and ResNet50 / M. Sowmya, M. Balasubramanian, K. Vaidehi // Indian Journal of Science and Technology. – 2023. – Vol. 16, № 16. – P. 1221–1229. – DOI 10.17485/ijst/v16i16.199.
8. Wang B. Two-Stream Xception Structure Based on Feature Fusion for DeepFake Detection / B. Wang, L. Huang, T. Huang, F. Ye // International Journal of Computational Intelligence Systems. – 2023. – Vol. 16, № 1. – P. 134. – DOI 10.1007/s44196-023-00312-8.
9. Kaur G. Comparative analysis of Haar Cascade, OpenCV, and you only look once algorithms for vehicle detection / G. Kaur, S. Pawar, R. Patil, A. Patil, A. Yenikar, N. Bhandari, K. Kadam // Bulletin of Electrical Engineering and Informatics. – 2025. – Vol. 14. – P. 4758–4768. – DOI 10.11591/eei.v14i6.10554.
10. Ku H. Face recognition based on mtcnn and convolutional neural network / H. Ku, W. Dong // Frontiers in Signal Processing. – 2020. – Vol. 4. – P. 37–42. – DOI 10.22606/fsp.2020.41006.
11. Гуцин Р. И. Анализ параллельной нейронной сети Adaboost для классификации больших наборов изображений / Р. И. Гуцин, Ю. А. Орлова, В. Л. Розалиев // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. – 2020. – Т. 10, № 1. – С. 78–93.

12. Adnan F. EfficientNetB3-Adaptive Augmented Deep Learning (AADL) for Multi-Class Plant Disease Classification / F. Adnan, M. Awan, A. Mahmoud, H. Nobanee, A. Yasin, A. Zain // IEEE Access. – 2023. – Vol. 11. – P. 85426–85440. – DOI 10.1109/ACCESS.2023.3303131.
13. Deng J. ImageNet: a Large-Scale Hierarchical Image Database / J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, F.-F. Li // IEEE Conference on Computer Vision and Pattern Recognition. – 2009. – P. 248–255. – DOI 10.1109/CVPR.2009.5206848.
14. Гушин Н. С. Сравнительный анализ методов аугментации, используемых в библиотеках Keras и Albumentations / Н. С. Гушин // Тинчуринские чтения - 2025 «Энергетика и цифровая трансформация»: статьи по материалам Международной молодежной научной конференции, Казань, 23–25 апреля 2025 года : в 4 т. – Казань : Казанский государственный энергетический университет, 2025. – С. 43–46.
15. Казаков М. А. Робастный оптимизатор Adam на основе усредняющих агрегирующих функций / М. А. Казаков // Известия Кабардино-Балкарского научного центра РАН. – 2025. – Т. 27, № 5. – С. 159–167. – DOI 10.35330/1991-6639-2025-27-5-159-167.
16. Жигулин В. И. Анализ скорости работы и рекомендации при работе с нейронными сетями / В. И. Жигулин, К. А. Шумилов, В. А. Алфимов // Инженерно-строительный вестник Прикаспия. – 2023. – № 4 (46). – С. 92–95. – DOI 10.52684/2312-3702-2023-46-4-92-95.
17. Sadek M. G. Advancing Text-to-Image Generation: A Comparative Study of StyleGAN-T and Stable Diffusion 3 under Neutrosophic Sets / M. G. Sadek, A. Y. Hassan, T. O. Diab, A. Abdelhafeez // Neutrosophic Sets and Systems. – 2025. – Vol. 85. – P. 784–800. – DOI 10.5281/zenodo.15380944.
18. Zhang X. A high-precision facial recognition method for small-tailed Han sheep based on an optimised Vision Transformer / X. Zhang, Ch. Xuan, Ya. Ma, He. Su // Animal. – 2023. – Vol. 17, № 8. – P. 100886. – DOI 10.1016/j.animal.2023.100886.
19. Patil S. Face Expression Recognition Using SVM and KNN Classifier with HOG Features / S. Patil, Y. M. Patil // Smart Innovation, Systems and Technologies. – 2022. – Vol. 303 SIST. – P. 416–424. – DOI 10.1007/978-981-19-2719-5\_39.
20. Колючкин В. Я. Выбор рабочего словаря признаков в алгоритмах распознавания изображений на основе фурье-дескрипторов / В. Я. Колючкин, К. М. Нгуен // Наука и образование: научное издание МГТУ им. Н. Э. Баумана. – 2014. – № 3. – С. 188–199. – DOI 10.7463/0314.0699817.

#### References

1. Peng Y. A Comparative Analysis Between GAN and Diffusion Models in Image Generation. *Transactions on Computer Science and Intelligent Systems Research*. 2024 vol. 56, pp. 189–195. DOI 10.62051/0f1va465.
2. Boyd A., Tinsley P., Bowyer K., Czajka A. The Value of AI Guidance in Human Examination of Synthetically-Generated Faces. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2023, vol. 37, no. 5, pp. 5930–5938. DOI 10.1609/aaai.v37i5.25734.
3. Zharova A. K. Tekhnologii dipfeik: sotsialno-pravovie riski narusheniya chastnoi zhizni litsa i pravovie resheniya [Dipfake technologies: socio-legal risks of violation of individual's privacy and legal solutions]. *Pravoporyadok: istoriya, teoriya, praktika* [Legal and Order: History, Theory, Practice]. 2025, no. 2 (45), pp. 63–68. DOI 10.47475/2311-696X-2025-45-2-63-68.
4. Nguen T. T. Metod raspoznavaniya figur s ispolzovaniem fure-deskriptorov i neironnoi seti [Method of shape recognition using Fourier descriptors and neural network]. *Problemi informatiki* [Problems of Informatics]. 2011, no. S2, pp. 64–69.
5. Hasan A. A., Panishchev V. S., Reshetnikova V. P. Analiz teksturnikh priznakov na izobrazheniyakh [Analysis on the pictures textural features]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vichislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie* [Proceedings of the Southwest State University. Series: IT Management, Computer Science, Computer Engineering, Medical Equipment Engineering]. 2014, no. 2, pp. 102–107.
6. Kulikov S. V., Zakharov O. S., Andreev D. Yu. Issledovanie vozmozhnosti sovmestnogo primeneniya neirosetevogo preobrazovatela biometriya-kod i glubokoi svertochnoi neironnoi seti v raspoznavanii lits [Exploring the possibility of using deep convolutional neural network paired with neural "biometric image to code" converter in face recognition]. *Informatsionnie tekhnologii* [Information technology]. 2018, vol. 24, no. 2, pp. 116–120.
7. Sowmya M., Balasubramanian M., Vaidehi K. Human Behavior Classification using 2D – Convolutional Neural Network, VGG16 and ResNet50. *Indian Journal of Science and Technology*. 2023, vol. 16, no. 16, pp. 1221–1229. DOI 10.17485/ijst/v16i16.199.
8. Wang B., Huang L., Huang T., Ye F. Two-Stream Xception Structure Based on Feature Fusion for DeepFake Detection. *International Journal of Computational Intelligence Systems*. 2023, vol. 16, no. 1, pp. 134. DOI 10.1007/s44196-023-00312-8.
9. Kaur G., Pawar S., Patil R., Patil A., Yenikar A., Bhandari N., Kadam K. Comparative analysis of Haar Cascade, OpenCV, and you only look once algorithms for vehicle detection. *Bulletin of Electrical Engineering and Informatics*. 2025, vol. 14, pp. 4758–4768. DOI 10.11591/eei.v14i6.10554.
10. Ku H., Dong W. Face recognition based on mtcnn and convolutional neural network. *Frontiers in Signal Processing*. 2020, vol. 4, pp. 37–42. DOI 10.22606/fsp.2020.41006.
11. Guschin R. I., Orlova Yu. A., Rozaliev V. L. Analiz parallelnoi neironnoi seti Adaboost dlya klassifikatsii bolshikh naborov izobrazhenii [Parallel Neural Network Analysis of Topics for Classifying Large Sets of Images]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vichislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie* [Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering]. 2020, vol. 10, no. 1, pp. 78–93.
12. Adnan F., Awan M., Mahmoud A., Nobanee H., Yasin A., Zain A. EfficientNetB3-Adaptive Augmented Deep Learning (AADL) for Multi-Class Plant Disease Classification. *IEEE Access*. 2023, vol. 11, pp. 85426–85440. DOI 10.1109/ACCESS.2023.3303131.
13. Deng J., Dong W., Socher R., Li L.-J., Li K., Li F.-F. ImageNet: a Large-Scale Hierarchical Image Database. *IEEE Conference on Computer Vision and Pattern Recognition*. 2009, pp. 248–255. DOI 10.1109/CVPR.2009.5206848.
14. Gushchin N. S. Sravnitel'nyi analiz metodov augmentatsii, ispolzuemikh v bibliotekakh Keras i Albumentations [Comparative analysis of augmentation methods used in keras and albumentations]. *Tinchurinskie chteniya – 2025 «Energetika i tsifrovaya transformatsiya» : stati po materialam Mezhdunarodnoi molodezhnoi nauchnoi konferentsii. V chetirekh tomakh, Kazan, 23–25 aprelya 2025 goda* [Tinchurin Readings – 2025 «Energy and Digital Transformation»: articles based on the proceedings of the International Youth Scientific Conference. In four volumes, Kazan, April 23–25, 2025.]. Kazan: Kazanskiy gosudarstvennii energeticheskiy universitet; 2025, pp. 43–46.



15. Kazakov M. A. Robastnii optimizator Adam na osnove usrednyayushchikh agregiruyushchikh funktsii [Robust adam optimizer based on averaging aggregation functions]. *Izvestiya Kabardino-Balkarskogo nauchnogo tsentra RAN* [News of the Kabardino-Balkarian Scientific Center of RAS]. 2025, vol. 27, no. 5, pp. 159–167. DOI 10.35330/1991-6639-2025-27-5-159-167.
16. Zhigulin V. I., Shumilov K. A., Alfimov V. A. Analiz skorosti raboti i rekomendatsii pri rabote s neironnimi setyami [Speed analysis and recommendations for working with neural networks]. *Inzhenerno-stroitelnyi vestnik Prikaspiya* [Engineering and Construction Bulletin of the Caspian Region]. 2023, no. 4 (46), pp. 92–95. DOI 10.52684/2312-3702-2023-46-4-92-95.
17. Sadek M. G., Hassan A. Y., Diab T. O., Abdelhafeez A. Advancing Text-to-Image Generation: A Comparative Study of Style-GAN-T and Stable Diffusion 3 under Neutrosophic Sets. *Neutrosophic Sets and Systems*. 2025, vol. 85, pp. 784–800. DOI 10.5281/zenodo.15380944.
18. Zhang X., Xuan Ch., Ma Ya., Su He. A high-precision facial recognition method for small-tailed Han sheep based on an optimised Vision Transformer. *Animal*. 2023, vol. 17, no. 8, pp. 100886. DOI 10.1016/j.animal.2023.100886.
19. Patil S., Patil Y. M. Face Expression Recognition Using SVM and KNN Classifier with HOG Features. *Smart Innovation, Systems and Technologies*. 2022, vol. 303 SIST, pp. 416–424. DOI 10.1007/978-981-19-2719-5\_39.
20. Kolyuchkin V. Ya., Nguen K. M. Vibor rabocheho slovarya priznakov v algoritmakh raspoznavaniya izobrazhenii na osnove fure-deskriptorov [Selecting an informative features vocabulary for recognition algorithms based on Fourier-descriptors]. *Nauka i obrazovanie: nauchnoe izdanie MGTU im. N. E. Baumana* [Science and Education of the Bauman MSTU]. 2014, no. 3, pp. 188–199. DOI 10.7463/0314.0699817.

© И. А. Соловьева, И. Б. Муравьев, Д. С. Соловьев

**Ссылка для цитирования:**

Соловьева И. А., Муравьев И. Б., Соловьев Д. С. Математическая модель и программный комплекс для системы детектирования синтетических изображений лиц в среде мессенджера на базе сверточной нейронной сети efficientnetb3 // Инженерно-строительный вестник Прикаспия : научно-технический журнал / Астраханский государственный архитектурно-строительный университет. Астрахань : ГАОУ АО ВО «АГАСУ», 2026. № 1 (55). С. 126–134.

УДК 531.3:629.3.015:519.6

DOI 10.52684/2312-3702-2026-55-1-134-141

**РАЗРАБОТКА МЕТОДИКИ ЧИСЛЕННОГО МОДЕЛИРОВАНИЯ  
ДЛЯ АНАЛИЗА СКОРОСТНЫХ ПАРАМЕТРОВ  
ТРАНСПОРТНОГО СРЕДСТВА ПО ДАЛЬНОСТИ СВОБОДНОГО ПОЛЕТА  
АНТРОПОМЕТРИЧЕСКОГО ОБЪЕКТА**

*А. В. Синельщиков, Е. В. Пономарева, Е. Д. Пономарева*

**Синельщиков Алексей Владимирович**, кандидат технических наук, доцент кафедры промышленного и гражданского строительства, Астраханский государственный архитектурно-строительный университет, г. Астрахань, Российская Федерация, тел.: + 7 (927) 282-62-11; e-mail: laex@bk.ru;

**Пономарева Елена Владимировна**, кандидат физико-математических наук, доцент кафедры «Общественные дисциплины и наземный транспорт», Астраханский государственный технический университет, г. Астрахань, Российская Федерация, тел.: + 7 (927) 566-50-32; e-mail: acmpax@rambler.ru;

**Пономарева Елена Дмитриевна**, студент, Астраханский государственный технический университет, г. Астрахань, Российская Федерация, тел.: + 7 (917) 182-47-33; e-mail: acmpax@rambler.ru

В статье представлена методика анализа скоростных параметров транспортных средств при столкновениях, основанная на кинематике свободного полета антропометрического объекта. Исследование направлено на повышение точности инженерных расчетов при ударе легких моторных средств о массивные препятствия. Научная новизна заключается в интеграции дифференциальных уравнений динамики твердого тела с учетом односторонних связей и импульсных воздействий, описываемых аппаратом обобщенных функций. Рассмотрен механизм трансформации поступательной энергии системы во вращательное движение («эффект катапульты») при блокировке передней оси. Разработанная математическая модель учитывает горизонтальную проекцию скорости и вертикальную составляющую, возникающую за счет угловой скорости тангажа. Модель верифицирована путем сопоставления расчетных траекторий с координатами падения объекта. Моделирование показало высокую чувствительность результатов к антропометрии водителя и геометрии транспортного средства.

**Ключевые слова:** математическое моделирование, динамика столкновений, закон сохранения импульса, свободный полет, антропометрические данные, эффект катапульты, неупругое столкновение, численное моделирование, односторонние связи, обобщенные функции.

**DEVELOPMENT OF A COMPUTATIONAL MODELING METHODOLOGY  
FOR ANALYZING VEHICLE VELOCITY PARAMETERS BASED ON THE FREE-FLIGHT DISTANCE  
OF AN ANTHROPOMETRIC OBJECT**

*A. V. Sinelshchikov, Ye. V. Ponomareva, Ye. D. Ponomareva*

**Sinelshchikov Aleksey Vladimirovich**, Candidate of Technical Sciences, Associate Professor of Industrial and Civil Engineering Department, Astrakhan State University of Architecture and Civil Engineering, Astrakhan, Russian Federation, phone: + 7 (927) 282-62-11; e-mail: laex@bk.ru;

**Ponomareva Yelena Vladimirovna**, Candidate of Physical and Mathematical Sciences, Associate Professor of General Engineering Disciplines and Land Transport Department, Astrakhan State Technical University, Astrakhan, Russian Federation, phone: + 7 (927) 566-50-32; e-mail: acmpax@rambler.ru;

**Ponomareva Yelena Dmitriyevna**, student, Astrakhan State Technical University, Astrakhan, Russian Federation, phone: + 7 (917) 182-47-33; e-mail: acmpax@rambler.ru