

## РАЗРАБОТКА АЛГОРИТМА ВЕРИФИКАЦИИ СОСТОЯНИЯ ГЛАЗ ДЛЯ СИСТЕМ LIVENESS DETECTION НА ИЗОБРАЖЕНИЯХ НИЗКОГО КАЧЕСТВА

Боцман А.Е.<sup>1</sup>

Научный руководитель - Кованцев А.Н.<sup>1</sup>

<sup>1</sup>Университет ИТМО

botsman\_artem@mail.ru

Работа выполнена в рамках научно-исследовательской работы магистратуры Университета ИТМО.

### Введение

Liveness Detection нужен, чтобы защищать биометрию от подделок (фото, видео, повторное воспроизведение) [3] и снижать риск ложного допуска. В практике один из самых понятных индикаторов связан с глазами: открыт ли глаз в момент проверки, есть ли естественные изменения вроде моргания. Но в реальных данных качество часто низкое: маленькие фрагменты глаза порядка 24x24 пикселя, шум, размытие, падение разрешения. Из-за этого простые решения начинают ошибаться, поэтому задача верификации состояния глаз на низком качестве остается актуальной.

### Основная часть

В работе собран единый экспериментальный пайплайн для задачи open/closed на серых изображениях 24x24. Датасет организован в два класса (opened и closed). Чтобы оценка была честной и воспроизводимой, выполнено стратифицированное разделение train/val 80/20 с фиксированным seed = 42. Далее обученная модель используется как модуль, который на вход получает патч глаза и возвращает вероятность открытого состояния.

В качестве базовой модели выбрана компактная сверточная сеть MediumEyeCNN. Она рассчитана на маленький вход и быстрый расчет: три сверточных блока (свертка, нормализация, ReLU, pooling), затем выпрямление признаков, Dropout(p = 0.5) и два полносвязных слоя. На выходе получается score от 0 до 1, который интерпретируется как вероятность открытого глаза. Решение принимается сравнением с порогом.

Архитектура MediumEyeCNN построена специально под маленький вход и низкое качество. Вход: один канал, 24x24. Далее идут три сверточных слоя с увеличением числа каналов (32, 64 и 128). После каждой свертки применяются BatchNorm и ReLU, затем MaxPool, чтобы уменьшать пространственное разрешение и повышать устойчивость. После сверточных блоков признаки выпрямляются (Flatten), затем используется Dropout(p = 0.5) для снижения переобучения. Классификация выполняется двумя полносвязными слоями (с промежуточным размером 96) и Sigmoid на выходе, который дает вероятность "глаз открыт".

Обучение проводилось с контролем переобучения на валидации: отслеживались loss и метрики верификации. Для выбора лучшей версии модели использовался критерий качества на val, ориентированный на задачу верификации (в частности, EER). Это важно для Liveness Detection, так как в реальной системе решение принимается по порогу, а не только по максимальной точности

Обучение проводилось с контролем переобучения на валидации: отслеживались loss и метрики верификации. Для выбора лучшей версии модели использовался критерий качества на val, ориентированный на задачу верификации (в частности, EER).

Это важно для Liveness Detection, так как в реальной системе решение принимается по порогу, а не только по максимальной точности.

Шаги исследования:

- 1) подготовка данных и проверка баланса классов.
- 2) обучение модели и контроль переобучения по валидации.
- 3) оценка качества как верификации (ROC-AUC и EER) вместе с F1.
- 4) анализ ошибок на сложных и сомнительных примерах.
- 5) проверка устойчивости к деградациям blur и downscale/upscale

На валидационной выборке получены следующие итоговые значения: accuracy = 0.9763, F1 = 0.9767, ROC-AUC = 0.9908, EER = 0.0213. По матрице ошибок видно, что модель уверенно работает по двум классам: 366 правильных ответов для closed и 377 для opened, при 9 ошибках в каждом направлении. Это важно для liveness, потому что позволяет настраивать порог и заранее понимать баланс ложных допусков и отказов.

Сопоставление с известными подходами показывает, что предлагаемое решение соответствует практическим ограничениям задачи. Методы на лицевых ключевых точках и показателе открытости (например, EAR по Soukupova, 2016) [1] обычно работают быстро, но их качество сильно зависит от точности детекции landmarks и заметно проседает на шуме и низком разрешении. С другой стороны, глубокие CNN-подходы (например, Kim, Hong, 2017) [2] демонстрируют высокую точность, но в описаниях чаще предполагают более качественный вход и более тяжелые модели. В данной работе акцент сделан на малый вход 24x24 и низкое качество: компактная CNN дает высокий результат на валидации и при этом остается вычислительно легкой, поэтому по критериям применимости и скорости для edge/мобильных сценариев она выглядит не хуже альтернатив, описанных в литературе.

Отдельно проверена устойчивость к ухудшению качества. При легком размытии качество почти не меняется, но при усилении blur и при снижении разрешения качество падает заметно сильнее. Практический вывод простой: в liveness-сценарии помимо самой модели нужен контроль качества кадра и, при необходимости, отказ от решения (reject) при низкой уверенности.

Размытие: k3 sigma 0.5, F1=0.9754, EER=0.024

Размытие: k5 sigma 1.0, F1=0.9432, EER=0.0427

Размытие: k7 sigma 1.5, F1=0.7464, EER=0.0853

Снижение разрешения: 18px, F1=0.9643, EER=0.032

Снижение разрешения: 12px, F1=0.8542, EER=0.0613

Снижение разрешения: 8px, F1=0.6203, EER=0.1333

## Выводы

Собран и проверен алгоритм верификации состояния глаз для сценариев Liveness Detection на изображениях низкого качества. Показано, что компактная CNN на входе 24x24 может давать высокое качество на валидации и удобна для работы в режиме пороговой верификации, где критичны ROC и EER. Тесты устойчивости подтверждают границы применимости при blur и downscale, поэтому для практического использования необходимы контроль качества входа и обработка низкоуверенных кадров.

## Литература

1. Soukupova T., Cech J. Eye Blink Detection Using Facial Landmarks. Czech Technical University in Prague, 2016
2. Kim K. W., Hong H. G. A Study of Deep CNN-Based Classification of Open and Closed Eyes Using a Visible Light Camera Sensor. Neurocomputing, 2017.
3. Antil A., Dhiman C. Unmasking Deception: A Comprehensive Survey on the Evolution of Face Anti-spoofing Methods. Neurocomputing, 2025.