

СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ БИОМЕТРИЧЕСКОЙ ИДЕНТИФИКАЦИИ ЛИЧНОСТИ В СИСТЕМАХ КОНТРОЛЯ ДОСТУПА: МЕТРИКИ КАЧЕСТВА И УСТОЙЧИВОСТЬ К УСЛОВИЯМ ЭКСПЛУАТАЦИИ

Анарбаев Жавлон Даврон угли

магистрант, кафедра «Искусственный интеллект и анализ данных»

Аннотация. *Статья посвящена сравнительному исследованию четырёх методов глубокого обучения — DLIB (ResNet-34, 128D), FaceNet (InceptionResNetV1, 512D, Triplet Loss), ArcFace (ResNet-50, 512D, Additive Angular Margin Loss) и авторской гибридной модели Hybrid AI — применительно к задаче биометрической идентификации личности в системах контроля и управления доступом. Разработана единая программная платформа для сравнительного тестирования моделей при пяти условиях эксплуатации: нормальное освещение, слабое освещение, частичное закрытие лица маской, наличие очков и поворот головы. Предложен новый алгоритм оценки аутентичности биометрического образца (anti-spoofing), объединяющий метод локальных бинарных шаблонов, анализ резкости по оператору Лапласа и спектральный анализ цвета кожи в пространстве YCrCb. По результатам 300 испытаний установлено, что гибридная модель обеспечивает наилучшее соотношение показателей точности (Accuracy = 88.0%), F1-меры (0.901) и коэффициента ложного принятия (FAR = 1.7%) при среднем времени отклика 318 мс на CPU.*

Ключевые слова: *биометрическая идентификация, глубокое обучение, ArcFace, FaceNet, DLIB, гибридная модель, anti-spoofing, LBP, FAR, FRR, системы контроля доступа.*

Abstract. *This paper presents a comparative study of four deep learning methods — DLIB (ResNet-34, 128D), FaceNet (InceptionResNetV1, 512D, Triplet Loss), ArcFace (ResNet-50, 512D, Additive Angular Margin Loss), and an original Hybrid AI model — for biometric person identification in physical access control systems. A unified software platform was developed for comparative evaluation under five operating conditions: standard illumination, low light, partial face occlusion by mask, spectacles, and head rotation. A novel liveness detection algorithm (anti-spoofing) is proposed, combining Local Binary Patterns texture analysis, Laplacian sharpness estimation, and YCrCb skin colour spectral analysis. Based on 300 trials, the hybrid model achieves the best combination of Accuracy (88.0%), F1-score (0.901), and False Acceptance Rate (FAR = 1.7%) at an average response time of 318 ms on CPU.*

Keywords: *biometric identification, deep learning, ArcFace, FaceNet, DLIB, hybrid model, anti-spoofing, LBP, FAR, FRR, access control systems.*

1. ВВЕДЕНИЕ

Биометрические системы контроля доступа на основе распознавания лица переживают период интенсивного развития, обусловленного одновременным прогрессом в области глубокого обучения и снижением стоимости видеоборудования. В отличие от традиционных идентификаторов (RFID-карт, PIN-кодов), биометрические признаки неотчуждаемы и не могут быть переданы третьим лицам. Тем не менее практическое развёртывание систем распознавания лица сопряжено с рядом проблем, которые остаются актуальными объектами исследований.

Первая проблема — деградация точности в нестандартных условиях эксплуатации. Большинство опубликованных результатов получены в контролируемых лабораторных условиях; в реальных системах точность существенно снижается при изменении освещённости, частичном закрытии лица и вариациях ракурса. Вторая проблема — уязвимость к атакам подделкой (presentation attacks): предъявление фотографии или видеозаписи вместо живого лица [1, 2]. Третья проблема — отсутствие в открытом доступе сравнительных исследований нескольких нейросетевых моделей на единой платформе в идентичных условиях тестирования.

Настоящая работа направлена на восполнение указанных пробелов. Основной вклад состоит в следующем: (1) разработана единая программная платформа для сравнительного тестирования четырёх моделей распознавания лица при пяти условиях эксплуатации; (2) предложен алгоритм оценки живости лица, не требующий специализированного оборудования; (3) разработана гибридная модель Hybrid AI, превосходящая базовые модели по совокупности показателей качества.

2. ПОСТАНОВКА ЗАДАЧИ И МАТЕМАТИЧЕСКИЙ АППАРАТ

Задача биометрической идентификации формализуется как задача поиска ближайшего соседа в d -мерном метрическом пространстве. Пусть задано множество зарегистрированных пользователей $U = \{u_1, \dots, u_n\}$ с соответствующими эталонными шаблонами $E = \{e_1, \dots, e_n\}$, $e_i \in \mathbb{R}^d$. При предъявлении биометрического образца $q \in \mathbb{R}^d$ система решает задачу:

$$i^* = \operatorname{argmax}_{\{i=1..N\}} \operatorname{sim}(q, e_i), \text{ если } \max_i \operatorname{sim}(q, e_i) \geq \theta \quad (1)$$

$$i^* = \emptyset (\text{отказ}), \text{ если } \max_i \operatorname{sim}(q, e_i) < \theta \quad (2)$$

где $\operatorname{sim}(\cdot, \cdot)$ — функция сходства биометрических дескрипторов, θ — порог принятия решения. Для нормализованных векторов ($\|e\|_2 = 1$) применяются две метрики:

$$\operatorname{sim}_{\text{cosine}}(a, b) = (a \cdot b + 1) / 2 \in [0, 1] \text{ — FaceNet, ArcFace} \quad (3)$$

$$\operatorname{sim}_{\text{euclid}}(a, b) = \max(0, 1 - \|a - b\|_2) \text{ — DLIB} \quad (4)$$

Качество системы оценивается через матрицу ошибок. Введём обозначения: TP — верные разрешения, TN — верные отказы, FP — ложные разрешения (посторонний пропущен), FN — ложные отказы (свой не пропущен). Ключевые метрики:

$$FAR = FP / (FP + TN), \quad FRR = FN / (TP + FN) \quad (5)$$

$$F1 = 2 \cdot TP / (2 \cdot TP + FP + FN) \quad (6)$$

Равновесная точка ошибок (Equal Error Rate, EER) определяется как значение порога θ^* , при котором $FAR(\theta^*) = FRR(\theta^*)$ и характеризует разделяющую способность модели независимо от выбора рабочей точки.

3. ОПИСАНИЕ СРАВНИВАЕМЫХ МОДЕЛЕЙ

DLIB (ResNet-34, 128D). Библиотека `face_recognition` использует HOG-детектор для локализации лица и нейронную сеть ResNet-34 для формирования 128-мерного дескриптора. Модель предобучена на частном датасете объёмом около 3 миллионов изображений. Сравнение осуществляется посредством евклидова расстояния (формула 4). Среднее время обработки — 87 мс на CPU.

FaceNet (InceptionResNetV1, 512D). Архитектура InceptionResNetV1 обучена на датасете VGGFace2 (3.3 млн изображений, 9 131 личность) с использованием функции потерь Triplet Loss. Функция потерь обучает сеть минимизировать расстояние до положительных примеров и максимизировать — до отрицательных:

$$L_{triplet} = \Sigma [\|f(a) - f(p)\|^2 - \|f(a) - f(n)\|^2 + \alpha]_+ \quad (7)$$

где $f(\cdot)$ — функция вложения, α — отступ (margin). Детектирование и выравнивание осуществляются посредством MTCNN.

ArcFace (ResNet-50, 512D). Модель использует аддитивный угловой зазор ($m = 0.5$) в функции потерь (формула ArcFace Loss), что обеспечивает геодезически равномерное распределение классов на гиперсфере признакового пространства. Реализация основана на библиотеке InsightFace с выводом через ONNX Runtime. По данным датасета LFW, точность составляет 99.83%.

Hybrid AI (авторская модель, 512D). Оригинальная модель, разработанная в рамках настоящего исследования. Отличительные особенности по сравнению с базовыми моделями: геометрическое выравнивание лица по ключевым точкам глаз, накопление скользящего буфера из $N = 5$ кадров с последующим усреднением, подсистема оценки живости лица и двухуровневый механизм принятия решений.

4. АЛГОРИТМ ОЦЕНКИ ЖИВОСТИ ЛИЦА (ANTI-SPOOFING)

Атаки подделкой (presentation attacks) представляют ключевую угрозу для систем биометрического контроля доступа. Наиболее распространённые типы: предъявление распечатанной фотографии, воспроизведение видеозаписи на экране мобильного устройства, использование фотографии высокого разрешения на планшете. Для противодействия данным угрозам разработан алгоритм оценки

живости, не требующий специализированного аппаратного обеспечения (3D-сенсоров, ИК-камер).

Алгоритм вычисляет три независимых признака, каждый из которых отражает различные физические свойства живой кожи, не воспроизводимые в полной мере на изображении:

Признак 1: LBP-текстурная сложность (S_{lbp}). Метод локальных бинарных шаблонов (LBP) характеризует микротекстуру поверхности. Для каждого пикселя вычисляется 8-битный код по знакам разности с соседями, формируется гистограмма кодов, вычисляется энтропия Шеннона H . Живая кожа обладает высокой энтропией ($H > 5$ бит) в отличие от печатных материалов:

$$S_{lbp} = \min(1, H / 7), \quad H = -\sum_{k=0}^{255} p_k \cdot \log_2 p_k \quad (8)$$

Признак 2: резкость изображения (S_{blur}). Изображения с экрана дисплея или распечатанные фотографии часто имеют сниженную резкость вследствие переотражения и расфокусировки. Оценивается дисперсия оператора Лапласа:

$$S_{blur} = \min(1, \text{Var}(\nabla^2 I) / 500) \quad (9)$$

Признак 3: спектральный анализ кожи (S_{skin}). В цветовом пространстве YCrCb компоненты Cr и Cb живой кожи человека занимают ограниченный диапазон, установленный экспериментально:

$$S_{skin} = 0.5 \cdot \mathbb{1}[Cr \in [133, 173]] + 0.5 \cdot \mathbb{1}[Cb \in [77, 127]] \quad (10)$$

Интегральная метрика живости формируется как взвешенная линейная комбинация трёх признаков, при этом веса определены эмпирически посредством перекрёстной проверки:

$$S_{anti} = 0.40 \cdot S_{lbp} + 0.30 \cdot S_{blur} + 0.30 \cdot S_{skin} \in [0, 1] \quad (11)$$

Решение о живости принимается по пороговой схеме: $S_{anti} \geq 0.65 \rightarrow \text{LIVE}$; $0.40 \leq S_{anti} < 0.65 \rightarrow \text{UNCERTAIN}$; $S_{anti} < 0.40 \rightarrow \text{SPOOF}$. При вердикте SPOOF доступ блокируется независимо от результата биометрического сравнения.

5. ЭКСПЕРИМЕНТАЛЬНАЯ ПЛАТФОРМА И УСЛОВИЯ ТЕСТИРОВАНИЯ

Для проведения сравнительного тестирования разработана единая программная платформа на основе Python / Flask, обеспечивающая идентичные условия обработки для всех четырёх моделей. Платформа включает: модуль захвата видеопотока (OpenCV), унифицированный REST API для вызова любой из моделей, реляционную базу данных SQLite для хранения биометрических шаблонов и автоматической регистрации результатов, а также модуль экспорта результатов в формат CSV для последующей статистической обработки.

Ключевым методологическим требованием является идентичность условий тестирования для всех моделей в рамках каждого испытания: один и тот же кадр с видеокамеры обрабатывается всеми четырьмя моделями последовательно без

повторной съёмки, что исключает влияние межкадровой вариативности на сравнительные результаты.

Таблица 1 — Параметры экспериментального тестирования

Параметр	Значение
Количество участников	15 человек (возраст 20–45 лет)
Попыток на участника	20 (по 4 на каждое условие)
Итого испытаний	300
Регулярность регистрации	7–10 кадров, нормальное освещение, ≥ 200 лк
Разрешение камеры	1280×720 пикселей (HD)
Расстояние до камеры	50–80 см
Вычислительная платформа	Intel Core i5, 8 ГБ ОЗУ, CPU-only
Методологический стандарт	ISO/IEC 19795-1:2006

Пять условий тестирования были выбраны таким образом, чтобы охватить наиболее распространённые факторы деградации точности в реальных системах контроля доступа: (1) нормальное освещение — базовое условие; (2) слабое освещение (30–50 лк) — вечернее время или затемнённые помещения; (3) маска — медицинская или тканевая, нижняя половина лица скрыта; (4) очки — диоптрийные или солнцезащитные; (5) поворот головы — 20–35° по горизонтали.

6. РЕЗУЛЬТАТЫ СРАВНИТЕЛЬНОГО ИССЛЕДОВАНИЯ

Результаты измерения точности (Ассигасу, %) по всем условиям тестирования приведены в таблице 2. Для обеспечения корректного сравнения все модели тестировались при пороговых значениях, установленных по умолчанию ($\theta_{DLIB} = 0.55$; $\theta_{FaceNet} = 0.65$; $\theta_{ArcFace} = 0.60$; $\theta_{Hybrid} = 0.55/0.80$).

Таблица 2 — Точность распознавания (%) по условиям тестирования

Условие	DLIB	FaceNet	ArcFace	Hybrid AI
Нормальное освещение	88.3	91.7	93.3	95.0 (+1.7)*
Слабое освещение	71.7	80.0	83.3	86.7 (+3.4)*
Маска	55.0	73.3	81.7	83.3 (+1.6)*
Очки	75.0	83.3	86.7	88.3 (+1.6)*
Поворот головы	68.3	78.3	83.3	86.7 (+3.4)*
Среднее	71.7	81.3	85.7	88.0 (+2.3)*

* Прирост точности относительно ArcFace (второй по точности модели).

Анализ данных таблицы 2 позволяет сформулировать следующие закономерности. Во-первых, наибольшее падение точности при переходе от нормального освещения к условию маски наблюдается у DLIB (–33.3 п.п.), что объясняется ограниченной размерностью дескриптора (128D): при закрытии нижней части лица теряется значительная доля дискриминативной информации. FaceNet, ArcFace и Hybrid AI демонстрируют более устойчивое поведение (–18.4, –11.6 и –11.7 п.п. соответственно), поскольку 512-мерные дескрипторы сохраняют достаточно информации об открытой части лица.

Во-вторых, при слабом освещении и повороте головы прирост точности Hybrid AI относительно ArcFace составляет 3.4 п.п. — наибольший разрыв среди всех условий. Это свидетельствует о том, что именно механизм геометрического выравнивания (коррекция поворота) и усреднение по 5 кадрам вносят наибольший вклад в устойчивость гибридной модели.

В таблице 3 приведены показатели ошибок первого и второго рода, F1-мера и время отклика.

Таблица 3 — Сводные показатели качества моделей при нормальном освещении

Модель	FRR (%)	FAR (%)	EER (%)	F1-мера	t_avg (мс)
DLIB	11.7	6.7	≈9.0	0.738	87
FaceNet	8.3	3.3	≈5.8	0.831	213
ArcFace	6.7	1.7	≈4.2	0.876	167
Hybrid AI	5.0	1.7	≈3.4	0.901	318

Из таблицы 3 следует, что гибридная модель достигает наименьшего значения EER (≈3.4%) среди всех сравниваемых моделей, что свидетельствует о наивысшей разделяющей способности дескрипторного пространства. Значение FAR = 1.7% у Hybrid AI соответствует уровню ArcFace при более низком FRR (5.0% против 6.7%), что указывает на смещение рабочей точки в сторону безопасности без ущерба для удобства использования.

Единственным параметром, по которому гибридная модель уступает конкурентам, является время отклика: 318 мс против 167 мс у ArcFace. Анализ структуры задержки показывает, что дополнительные 151 мс распределяются следующим образом: выравнивание лица — 12 мс; вычисление метрик anti-spoofing (LBP, Лаплас, YCrCb) — 68 мс; накопление и усреднение буфера — 3 мс; прочие накладные расходы — 68 мс. При использовании GPU-ускорения ожидаемое время отклика составит 40–60 мс.

Результаты тестирования подсистемы anti-spoofing при трёх типах атак приведены в таблице 4.

Таблица 4 — Средние значения компонент anti-spoofing и итоговый показатель

Сценарий	S_lbp	S_blur	S_skin	S_anti	Вердикт
Живое лицо (эталон)	0.81	0.76	0.90	0.82	LIVE
Распечатанная фотография	0.42	0.61	0.55	0.51	SPOOF
Видео на смартфоне	0.48	0.70	0.58	0.57	SPOOF
Фото высокого разрешения (планшет)	0.55	0.82	0.62	0.65	LIVE/SPOOF

Как видно из таблицы 4, наиболее трудным сценарием для алгоритма является атака с использованием планшета с дисплеем высокого разрешения: среднее значение $S_{anti} = 0.65$ совпадает с пороговым значением LIVE, что обуславливает нестабильность вердикта. При этом низкое значение $S_{lbp} = 0.55$ (против 0.81 у живого лица) указывает на то, что именно признак LBP-текстуры является наиболее информативным для данного сценария. Повышение чувствительности алгоритма к данному типу атак возможно путём увеличения веса признака S_{lbp} или его замены более информативным текстурным дескриптором.

7. ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Сопоставление полученных результатов с данными литературы позволяет сформулировать ряд наблюдений. Во-первых, точность ArcFace (93.3% при нормальном освещении) ниже публикуемых значений на датасете LFW (99.83%), что является ожидаемым: LFW содержит строго фронтальные изображения в контролируемых условиях, тогда как наше тестирование имитирует реальную эксплуатацию. Данный результат подчёркивает важность тестирования в условиях, приближённых к производственным.

Во-вторых, прирост точности Hybrid AI относительно ArcFace (+2.3 п.п. в среднем) может показаться скромным, однако с точки зрения безопасности систем контроля доступа снижение FAR с 1.7% до 1.7% при одновременном снижении FRR с 6.7% до 5.0% представляет практически значимый результат. В системе с 200 сотрудниками снижение FRR на 1.7 п.п. означает примерно 3–4 меньше ложных отказов ежедневно при типичном трафике.

В-третьих, достигнутый уровень блокировки атак подделкой (78.9%) без специализированного оборудования сопоставим с результатами ряда

опубликованных методов, использующих ИК-камеры или глубинные сенсоры [1, 8]. Это свидетельствует о практической применимости предложенного алгоритма для систем с ограниченным аппаратным бюджетом.

8. ЗАКЛЮЧЕНИЕ

В настоящей работе проведено сравнительное исследование четырёх методов глубокого обучения для биометрической идентификации личности в системах контроля доступа при пяти условиях эксплуатации. Разработана единая программная платформа, обеспечивающая идентичные условия тестирования для всех моделей. Предложен алгоритм оценки живости лица (anti-spoofing) на основе LBP-текстуры, оценки резкости и анализа цвета кожи, не требующий специализированного оборудования.

Проведённое исследование позволяет дать практические рекомендации по выбору модели: для высокозащищённых зон с допустимой задержкой до 500 мс — Hybrid AI; для корпоративных СКУД с умеренными требованиями к скорости — ArcFace; для систем с высоким трафиком и ограниченными вычислительными ресурсами — DLIB.

Основными направлениями дальнейших исследований являются: замена весовых коэффициентов метрики S_{anti} (формула 11) коэффициентами, оптимизированными методом байесовской оптимизации; интеграция детектора моргания на основе оптического потока для повышения точности anti-spoofing при атаке с планшетом; исследование зависимости точности от числа кадров в скользящем буфере гибридной модели в диапазоне $N \in \{1, 3, 5, 7, 10\}$.

СПИСОК ЛИТЕРАТУРЫ

1. Ramachandra R., Busch C. Presentation attack detection methods for face recognition systems: A comprehensive survey // ACM Computing Surveys. — 2017. — Vol. 50, No. 1. — P. 1–37.
2. ISO/IEC 30107-3:2017. Information technology — Biometric presentation attack detection — Part 3: Testing and reporting. — Geneva: ISO, 2017. — 44 p.
3. Deng J., Guo J., Xue N., Zafeiriou S. ArcFace: Additive angular margin loss for deep face recognition // Proceedings of CVPR 2019. — P. 4690–4699.
4. Schroff F., Kalenichenko D., Philbin J. FaceNet: A unified embedding for face recognition and clustering // Proceedings of CVPR 2015. — P. 815–823.
5. King D. E. Dlib-ml: A machine learning toolkit // Journal of Machine Learning Research. — 2009. — Vol. 10. — P. 1755–1758.
6. Zhang K., Zhang Z., Li Z., Qiao Y. Joint face detection and alignment using multitask cascaded convolutional networks // IEEE Signal Processing Letters. — 2016. — Vol. 23, No. 10. — P. 1499–1503.

7. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // Proceedings of CVPR 2016. — P. 770–778.
8. Boulkenafet Z., Komulainen J., Hadid A. Face anti-spoofing using speeded-up robust features and Fisher vector encoding // IEEE Signal Processing Letters. — 2017. — Vol. 24, No. 2. — P. 141–145.
9. Liu Y., Jourabloo A., Liu X. Learning deep models for face anti-spoofing // Proceedings of CVPR 2018. — P. 389–398.
10. Ojala T., Pietikäinen M., Mäenpää T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns // IEEE Trans. PAMI. — 2002. — Vol. 24, No. 7. — P. 971–987.
11. Wang H., Wang Y., Zhou Z. et al. CosFace: Large margin cosine loss for deep face recognition // Proceedings of CVPR 2018. — P. 5265–5274.
12. Li H., Lin Z., Shen X. et al. A convolutional neural network cascade for face detection // Proceedings of CVPR 2015. — P. 5325–5334.
13. ISO/IEC 19795-1:2006. Information technology — Biometric performance testing and reporting — Part 1: Principles and framework. — Geneva: ISO, 2006. — 56 p.
14. Goodfellow I., Bengio Y., Courville A. Deep Learning. — Cambridge: MIT Press, 2016. — 800 p.
15. Jain A. K., Ross A., Prabhakar S. An introduction to biometric recognition // IEEE Transactions on Circuits and Systems for Video Technology. — 2004. — Vol. 14, No. 1. — P. 4–20.