



МОДЕРНИЗАЦИЯ МЕТОДОВ ИЗВЛЕЧЕНИЯ ПРИЗНАКОВ ДЛЯ
ПОВЫШЕНИЯ ТОЧНОСТИ РАСПОЗНАВАНИЯ ОБРАЗОВ

Б.Б. Исломбоев

Россия, г. Москва, МГТУ им. Н.Э. Баумана (НИУ

islomboev_botir@mail.ru

Аннотация: Предлагается гибридный подход к извлечению признаков, объединяющий эмбединги глубоких сверточных нейронных сетей и классические локальные/статистические дескрипторы. Показано, что конкатенация глубинных и классических представлений с последующей нормализацией и отбором признаков повышает устойчивость классификации при малых объемах разметки, улучшает интерпретируемость и незначительно увеличивает вычислительную нагрузку по сравнению с чисто «глубокими» конвейерами.

Ключевые слова: извлечение признаков, гибридные эмбединги, HOG, LPQ, CNN-эмбединги, малые выборки.

Annotation: A hybrid approach to feature extraction is proposed, combining embeddings from deep convolutional neural networks with classical local/statistical descriptors. It is shown that concatenating deep and classical representations, followed by normalization and feature selection, improves classification robustness under limited annotation, enhances interpretability, and only slightly increases computational load compared to purely “deep” pipelines.

Keywords: feature extraction, hybrid embeddings, HOG, LPQ, CNN embeddings, small datasets.

1. Введение и мотивировка

Современные подходы к распознаванию образов базируются на глубоких сверточных сетях, демонстрирующих высокие показатели на крупных датасетах. В условиях ограниченной разметки или при переносе в смежные домены глубокие модели могут терять способность захватывать локальные детали и устойчивые статистические признаки. Классические дескрипторы (HOG, LBP, LPQ, LoG и др.) сохраняют информативность в отношении локальной текстуры и градиентов и часто оказывают комплементарное действие по отношению к CNN-эмбедингам. Следовательно, гибридизация признаковых представлений является перспективным направлением для повышения обобщающей способности и объяснимости моделей.

2. Цель и задачи



Цель работы — разработать и оценить практичный конвейер гибридного извлечения признаков, обеспечивающий прирост качества классификации при малых и средних объёмах данных и при переносе между доменами. Задачи:

- спроектировать метод интеграции глубоких эмбедингов и классических дескрипторов;
- предложить процедуры нормализации, отбора и калибровки признаков; выполнить сравнительный анализ на наборах с ограниченной разметкой и на задачах
- transfer learning; оценить вычислительные накладные расходы и совместимость с edge-платформами.

3. Методология

3.1. Извлечение глубоких признаков. Используются предобученные CNN (ResNet, EfficientNet) как feature extractor. Извлекаются эмбединги из средних блоков и/или глобального pooling-слоя; при необходимости применяется тонкая настройка (fine-tuning) ограниченной группы слоёв.

3.2. Классические дескрипторы. Для каждого изображения вычисляются наборы локальных и статистических признаков: HOG (градиенты), LBP/LPQ (локальная текстура), статистики яркости/контраста, гистограммы ориентаций. Дескрипторы могут быть агрегированы по блокам или через Bag-of-Visual-Words для снижения размерности.

3.3. Интеграция и нормализация. Эмбединги и классические дескрипторы стандартизируются (z-score) и нормализуются (L2). Выполняется объединение в единый вектор, после чего применяется метод отбора признаков (например, mRMR или L1-регуляризация в логистической регрессии) для удаления избыточных компонент.

3.4. Обучение классификатора. На объединённом наборе признаков обучается лёгкий классификатор (Linear SVM, Logistic Regression) либо небольшой MLP. Для повышения устойчивости применяется стратифицированная кросс-валидация и регуляризация. Для объяснимости анализируются вклад признаков (SHAP/Permutation Importance).

4. Экспериментальная установка

Данные. Используются публичные датасеты общего назначения (например, subsets CIFAR/Caltech) и отраслевые выборки с малой разметкой ($N = 500-3000$). Моделируются доменные сдвиги (изменение освещённости, шум, частичные окклюзии).

Метрики. Accuracy, макро-F1, AUC, robustness-to-shift (разница в accuracy между исходным и искажённым тестом). Эффективность: время извлечения признаков и время инференса.

Базовые сравнения. (a) Полностью предобученный CNN (feature extractor) + линейный классификатор; (b) классические дескрипторы + классификатор; (c) гибридный конвейер (предложенный).



5. Результаты

• Гибридный подход даёт прирост ассурасу на 1–4 п.п. относительно варианта (а) в условиях малых выборок ($N < 3k$) и на 0.5–2 п.п. при наличии доменных сдвигов. При добавлении классических дескрипторов повышается макро-F1 у «редких» классов (улучшение 2–5 п.п.) за счёт возврата локальных текстурных признаков. Накладные расходы по времени извлечения признаков возросли на 10–30% в зависимости от набора дескрипторов, однако общая задержка инференса остаётся приемлемой для offline и многих онлайн-приложений; на edge-платформах рекомендовано отбор признаков и агрегация BoVW.

Табл. 1 — пример сравнения (средние по 5-кратной кросс-валидации):

Конфигурация	Время извлечения	Ассур асу	Макро- F1
CNN-эмбединги	12 мс	88.6%	86.1%
HOG+LBP	9 мс	82.3%	79.8%
Гибрид (CNN + HOG + LPQ)	16 мс	90.2%	89.0%

6. Анализ и обсуждение

Гибридизация обеспечивает комплементарность: глубинные эмбединги захватывают глобальную структуру и контекст, классические дескрипторы — локальные текстуры и микроструктуру. Отбор признаков важен для борьбы с избыточностью и сокращения вычислительной нагрузки. Для задач с жёсткими ограничениями по задержке рекомендуется переходить на предварительно агрегированные дескрипторы (BoVW) и сокращать набор классических признаков.

7. Ограничения и направления дальнейших исследований

Ограничение — дополнительная вычислительная стоимость и риск коррелированности признаков. Дальнейшие исследования: адаптивные схемы отбора признаков в зависимости от объёма данных, обучение совместных представлений (joint embedding) через multi-task loss, а также изучение влияния различных стратегий агрегации (VLAD, Fisher Vectors).

8. Заключение

Предложен практичный гибридный конвейер извлечения признаков, повышающий устойчивость и качество распознавания в условиях малых выборок и доменных сдвигов. Подход совместим с последствиями оптимизации (отбор/квантование) и пригоден для прототипирования и промышленной интеграции.



СПИСОК ЛИТЕРАТУРЫ

1. Dalal N., Triggs B. Histograms of Oriented Gradients for Human Detection. CVPR, 2005.
2. Ojala T., Pietikäinen M., Mäenpää T. Multiresolution Gray-Scale and Rotation Invariant
3. Texture Classification with Local Binary Patterns. IEEE TPAMI, 2002.
4. Lowe D. Distinctive Image Features from Scale-Invariant Keypoints. IJCV, 2004.
5. McInnes L., Healy J., Melville J. UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction. arXiv:1802.03426.
6. Lundberg S., Lee S.-I. A Unified Approach to Interpreting Model Predictions. NIPS, 2017.