

УДК 612.087.1:004.032.26

ПРОГРАММНАЯ БИОМЕТРИЯ



А.А. Навроцкий

Заведующий кафедрой информационных технологий автоматизированных систем БГУИР, кандидат физико-математических наук, доцент



М.Д. Коробан

Магистрант кафедры информационных технологий автоматизированных систем БГУИР

*Белорусский государственный университет информатики и радиоэлектроники, Республика Беларусь
E-mail: navrotsky@bsuir.by, maxnorsemen@gmail.com*

Аннотация. Обсуждаются методологические вопросы применения технологии мягкой биометрии.

Ключевые слова: нейронная сеть, сверточная нейронная сеть, архитектура нейронной сети, переобучение в нейронных сетях, гиперпараметр.

Концепция программной биометрии появилась в начале 2000-х годов для описания подхода, в котором биометрические признаки (этническая принадлежность, пол, возраст, высота, сложность тела, цвет волос, цвет глаз и т.д.) используются в качестве входных данных при использовании методов нечеткой логики, машинном обучении и эволюционные вычисления. Основная идея заключается в использовании групп недостаточно информативных функций для уверенного решения задач идентификации.

Биометрические признаки могут характеризоваться различными параметрами, такими как характер ценности и отличительность. В работе [1] рассмотрена сравнительная эффективность черт лица для идентификации людей. Однако, если полученные данные не обладают достаточной полнотой, необходимо использование других биометрических признаков.

Из имеющихся подходов к установлению точной переидентификации в настоящее время в чаще всего используются CNN (convolutional neural network – сверточная нейронная сеть) и так ID-дискриминантные вложения (ID - идентификатор), основная идея которых – получение таких отображений изображений, которые улучшают идентификацию.

Для изучения использовались открытые наборы данных и репозитории из различных источников. Использовалась предварительно подготовленную модель для извлечения IDE из собранных видеоклипов видеонаблюдения, с последующим анализом вложений.

На первом этапе были обучены две сети на базе данных Market-1501 – ResNet-v1-50 и ResNet-v1-101. Необходимо было не только собрать и обработать набор изображений, но и выполнить их переквалификацию в пользовательском наборе данных. Набор данных был собран из кадров, полученных всех трех камер наблюдения. Общее количество ограничивающих полей – 7 365. Все ящики были аннотированы вручную. Ящики, содержащие размытые или удаленные изображения, были аннотированы как «неизвестные» и использовались для обучения. После отброса некачественных коробок, осталось 6248 ящиков. Для обеспечения правильного разделения, идентификаторы, имеющие менее 10 вхождений, были отмечены как неизвестные. В результате осталось 6 181 изображений. Недостатком рассмотренных сетей является их невысокая производительность.

Семейство сетей MobileNet по сравнению с ResNet-v1-101 тратит на вычисления на 30 процентов меньше времени и имеет сопоставимую точность. MobileNet-v1-224 был выбран для дальнейшей разработки и прошел обучение как для чистого пользовательского набора данных, так и для пользовательского набора данных, смешанного с набором данных Market-1501. Установлено, что обучение пользовательскому набору данных приводит к значительному повышению производительности. Чистый набор данных дает лучшие результаты обучения, чем смешанные.

Из-за характера обучения триплетной потери, классификаторы, которые расположены в модуле `sklearn.neighbors` и используют эвклидовое расстояние, выглядят как наиболее полезные.

Метод `NearestCentroid` сталкивается с проблемами, когда изображения одного и того же класса группируются в нескольких разных регионах (это может иметь место для изображений с разных камер или для изображений с наружной одеждой и без нее).

`KNeighborsClassifier` оспаривается выбросами, то есть изображениями, имеющими некоторое большое расстояние даже до ближайших соседей.

`RadiusNeighborsClassifier` учитывает все изображения, которые достаточно близки, а также автоматически делает выводы из того факта, что для определенного изображения нет близких соседей, обозначая его как «неизвестный».

Схема классификатора представлена на рисунке 1.

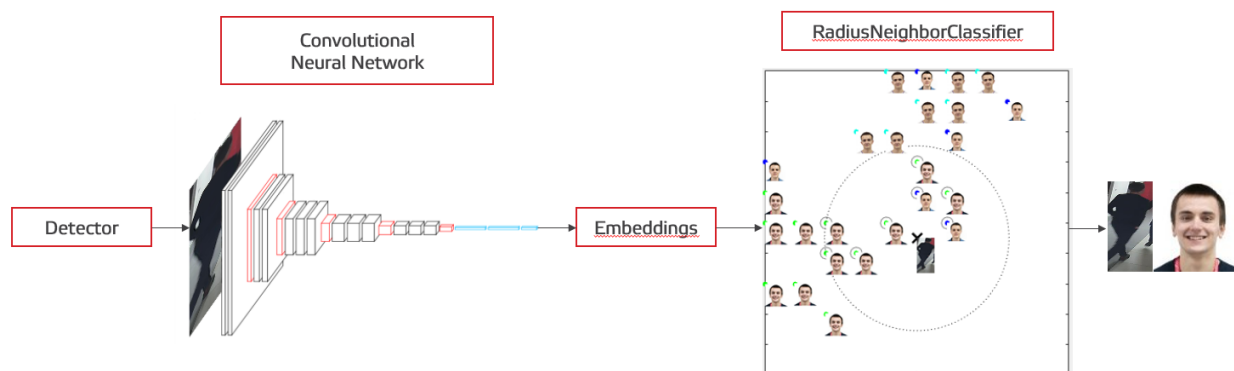


Рисунок 1. Схема классификатора

Классификатор изображения человека обучался с использованием различных значений радиуса для `RadiusNeighborClassifier`. Были рассчитаны и построены значения многоклассовой точности, точности неизвестного обнаружения и отзыва неизвестного обнаружения.

ResNet-v1-101, обученный на базе данных Market-1501, обеспечивает сравнительный тест, который в лучшем случае является умеренным (рисунок 2). ResNet-v1-101, обученный по смешанному набору данных, обеспечивает вложения, которые намного плотнее и намного лучше разделены (рисунок 3).

MobileNet-v1-224, обученный по смешанному набору данных, обеспечивает достаточно хорошие результаты, что дает около 0,6 для точности в 0,9 для отзыва. Все ведет к уменьшению количества ложных срабатываний.

MobileNet-v1-224, обученный по чистому пользовательскому набору данных, обеспечивает очень хорошие результаты, сочетая высокую точность с почти конкурирующим отзывом. Для классификации в приложении был выбран радиус 11,5, что дает более 0,97 отзыва и более 0,94 точности.

Производительность приложения при использовании модели MobileNet-v1-224 сильно зависит от согласования одежды и условий освещения. Другим фактором снижения производительности является нестабильность ограничивающих прямоугольников. Для увеличения

точности можно выполнить следующее:

- изменение насыщенности и оттенка цвета;
- добавление шумов (Шум - вкрапление разноцветных точек или повышается зернистость фотографии.);
- отбор лучших изображений на основе области сбора (сбор статистики классификации в зависимости от местоположения ограничительной рамки, предполагающая коррекцию области сбора или взвешивание изображений на основе их местоположения);
- увеличивая порог для фильтрации низкочастотных тождеств (исключая обучение тождеств, имеющих менее 20/50 изображений вместо 10);
- взвешивание изображений по времени (введение распада веса для наблюдений);
- использование потока высокого разрешения для распознавания с использованием ранней остановки.

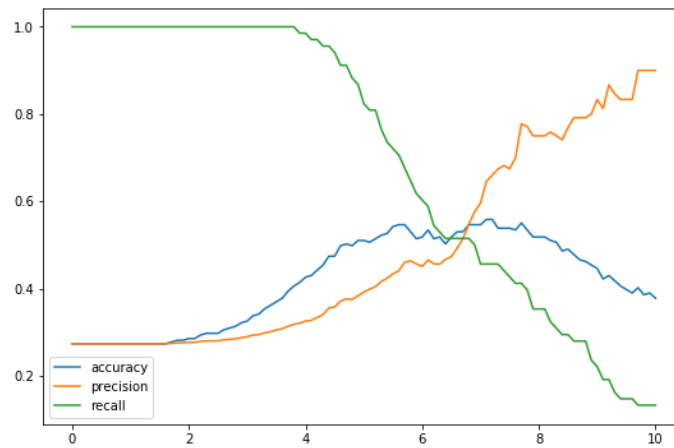


Рисунок 2. Точность классификации после обучения модели ResNet-v1- 101 на базе данных Market-1501




Рисунок 3. Точность классификации после обучения модели ResNet-v1- 101 на смешанном наборе данных

При подготовке изображения использовались следующие методы:

- цветовая аугментация. В связи с тем, что оттенок изображения меняется в зависимости от типа освещения, используется «градиентная карта» для выполнения операции смешивания мягкого света с исходным изображением для получения взвешенной суммы изображений;
- шумовая аугментация. В результате получаются изображения с теплым и холодным

оттенками и изображение в оттенках серого. Для шумоподавления используется наложение аддитивного гауссовского шума. Для регуляризации используется монохроматический шум (имеющий одинаковое значение для всех каналов);

– масштабирование. Изображения с низкой контрастностью необходимо корректировать. Один из подходов к коррекции – масштабирование интенсивности, которое представляет собой расширение спектра интенсивности на весь диапазон возможных значений интенсивности.

Для получения наибольшей точности распознавания было исследовано влияние гиперпараметров, используемых при обучении модели повторной идентификации человека был проведен ряд экспериментов.

Гиперпараметры — это значения, которые нужно подбирать вручную. Среди таких значений можно выделить:

- момент и скорость обучения;
- количество скрытых слоев;
- количество нейронов в каждом слое;
- наличие или отсутствие нейронов смещения

Для исследования использовались наборы данных с различными временными метками. Для получения оценки влияния гиперпараметров использовались различные их наборы.

В результате было установлено:

– для большинства наборов влияние гиперпараметров на точность модели незначительное;

– наблюдается достаточно высокая (до 4%) дисперсия производительности модели, вызванная случайными изменениями в процессе стохастического градиентного спуска. Для уменьшения дисперсии необходима более длительная тренировка или использование другой модели.

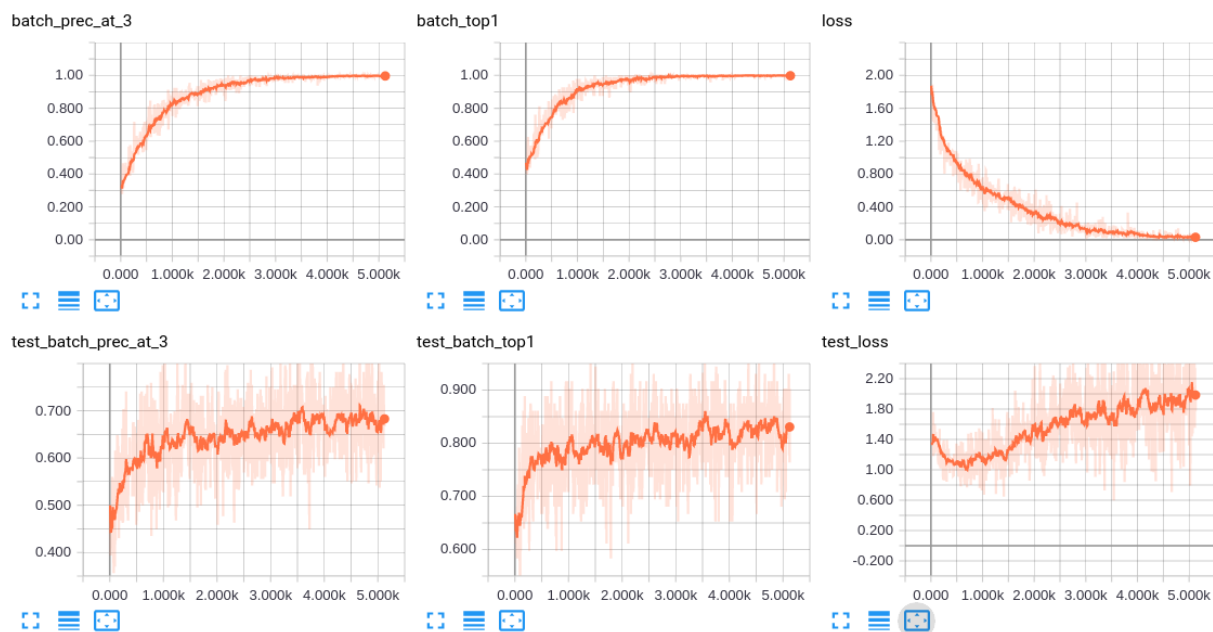


Рисунок 4. Графики опеределений точности классификации на обученных наборах данных и тестовых наборах данных

Для решения вышеизложенных проблем были проведены исследования, которые пока-

зали, что тренировка измеренных точности (верхняя строка) уже достигла максимума, а точность тестовых наборов (нижняя строка) все еще увеличивается (рисунок 4).

Резкость размерности вложений, создаваемых нейронной сетью в два раза от 128 до 64 незначительно уменьшала точность. Это совпадает с PCA вложений, полученных при более ранней оценке модели, которая сообщила только о 8% необъяснимой дисперсии после уменьшения размерности от 128 до 40.

Различные улучшения, выполненные с данными обучения (добавление шума, цветовых сдвигов, посевов, зеркальное отображение и масштабирование интенсивности), дают небольшое улучшение (несколько процентов) на производительность обученных моделей.

Dropout – метод решения проблемы переобучения в нейронных сетях [2] и уменьшение весов (регуляция l2) не оказали существенного влияния на точность, что, связано с тем, что используемая архитектура нейронной сети (MobileNet) проще, чем у более новых моделей [3].

Список литературы

- [1]. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3418766/>
- [2]. <https://pgaleone.eu/deep-learning/regularization/2017/01/10/analysis-of-dropout/#fnref:1>
- [3]. Howard et al., 2017

SOFT BIOMETRICS

A.A. NAUROTSKY, PhD

*Head of the Department of Information
Technologies of Automated Systems of
BSUIR, Associate Professor*

M.D. KOROBAN

*Master of Information
Technologies of Auto-
mated Systems of BSUIR*

*Belarusian State University of Informatics and Radioelectronics, Republic of Belarus
E-mail: navrotsky@bsuir. maxnorsemen@gmail.com*

Abstract. Methodological issues of using soft biometrics technology are discussed.

Key words: Neural network, convolutional neural network, MobileNet, Dropout, hyperparameter.