

ОПРЕДЕЛЕНИЕ ПОДЛИННОСТИ ЦИФРОВЫХ ФОТОГРАФИЙ НА ОСНОВЕ ХАРАКТЕРИСТИК ЦИФРОВЫХ УСТРОЙСТВ И ГРАФИЧЕСКИХ РЕДАКТОРОВ

Кадан А. М., Каспер П. С., Лазарь А. И., Радевич Н. А., Сенько Д. Ю., Шишкин Е. А.
Кафедра системного программирования и компьютерной безопасности,

Гродненский государственный университет имени Янки Купалы

Гродно, Республика Беларусь

E-mail: {kadan, kasper_ps_14, lazar_ai_14, radevich_na_14, senko_dj_13, shishkin_en_14}@mf.grsu.by

Представлен метод подтверждения подлинности цифровых фотографий, основанный на учете особенностей реализации формата JPEG, определяемых программно-технической реализацией цифровых фотокамер различных брендов и моделей. Работа метода основана на применении алгоритмов машинного обучения и позволяет определить бренд и модель цифровой фотокамеры, которой была сделана цифровая фотография, или определить графический редактор, которым в изображение были внесены изменения.

ВВЕДЕНИЕ

Цифровые фотокамеры и полученные с их помощью фотографии зачастую являются носителями криминалистически значимой информации. В то же время, количество различных способов мошенничества в сфере ИТ постоянно растет. Поэтому актуальной, и не только для специалистов в области компьютерной технической экспертизы (КТЭ), является задача обеспечения возможности подтверждения подлинности цифровых изображений. Подобные задачи актуальны, к примеру, в финансовых сферах, страховом деле, информационной безопасности, защите информации и криминалистике.

Под «подтверждением подлинности» будем понимать возможность определения бренда цифровой камеры и ее модели либо определение класса программного средства, с помощью которого было изменено оригинальное изображение.

I. МЕТОДЫ ПОДТВЕРЖДЕНИЯ ПОДЛИННОСТИ JPEG-ИЗОБРАЖЕНИЙ

Традиционно в качестве атрибутов JPEG-изображений выделяются:

1. метаданные EXIF;
2. таблица Хаффмана, заранее записанная в устройство. Определяется производителем на основании характеристик устройства;
3. таблицы квантования, которые также записаны в устройство заранее и определяются производителем;
4. размеры эскиза характерные для устройств определенной марки и модели. При этом эскиз также имеет характерные для используемого устройства эскизные таблицы Хаффмана и квантования;
5. размер итогового изображения.

Если нужно решить, является ли цифровая фотография подлинной, проводится исследование предоставленных цифровых фотографий.

Традиционно, эксперты применяют такие методы как [1]:

- визуальный метод;
- анализ EXIF-данных;
- эффект двойного квантования (double quantization effect);
- анализ уровня ошибки (error level analysis);
- копирование-перемещение фона (copy-move forgery);
- определение сетки артефакта блока (block artifact grid detection);
- определение качества изображения (image quality detection);
- интерполяция матрицы фильтров цветов (color filter array interpolation);
- базовый метод [2].

II. РАЗЛИЧИЯ В СТРУКТУРЕ ФАЙЛОВ JPEG-ИЗОБРАЖЕНИЙ

Алгоритм JPEG в наибольшей степени пригоден для сжатия фотографий и изображений, содержащих реалистичные сцены с плавными переходами яркости и цвета. Необходимость аппаратной реализации алгоритма JPEG в цифровых фотокамерах привели к тому, что практически все его реализации имеют различия у различных производителей цифровых фотокамер.

Согласно требованиям стандарта ISO/IEC 10918-1 [3], файл JPEG содержит последовательность маркеров, каждый из которых начинается с байта 0xFF, свидетельствующего о начале маркера, и байта — идентификатора. Некоторые маркеры состоят только из этой пары байтов, другие же содержат дополнительные данные, состоящие из двухбайтового поля с длиной информационной части маркера (включая длину этого поля, но за вычетом двух байтов начала маркера т.е. 0xFF и идентификатора) и собственно данных.

Среди маркеров выделяют группу основных маркеров, которые присутствуют в реали-

зации JPEG-формата практически у всех разработчиков, и целый ряд дополнительных (не обязательных) маркеров.

Также в структуре JPEG-формата у различных производителей отличается типы используемых маркеров, количество вхождений маркеров одного типа, длина блока кода, связанного с маркером, порядок появления маркеров в файле и другие характеристики, также связанные с маркерами.

Различия в использовании маркеров наблюдаются не только в файлах различных брендов, но также и для различных моделей одного и того же производителя, а также и для одних и тех же моделей при выборе различных режимов (настроек) фотосъемки. Использование графического редактора также вносит изменения в структуру исходного JPEG-файла, что, возможно, позволит идентифицировать программное средство, с помощью которого была нарушена подлинность исходного цифрового изображения.

III. ПОДГОТОВКА ОБУЧАЮЩЕЙ ВЫБОРКИ

База цифровых изображений была получена путем выгрузки изображений с сайта [4], на котором представлены различные бренды и модели фотоаппаратов вместе с примерами оригинальных фотографий.

Полученная с сайта база включала более 1500 различных примеров бренд-модель и более 25000 оригинальных цифровых фотографий. Для ее получения были разработаны специальные программные модули на языке Python, позволившие автоматизировать работу. Также были созданы таблицы брендов, моделей бренда, фотографий, связанных с моделью бренда.

На основании структуры JPEG-файлов этих цифровых фотографий были сформированы два множества признаков (data set'ов) для применения методов машинного обучения.

В первый data set на основании анализа каждой из фотографий были отобраны 12 признаков: (1-2) Название камеры (бренд), название модели; (3-4) количество всех маркеров, количество маркеров начала 0xFFD8; (5-6) длина и количество таблиц квантования 0xFFDB; (7-8) длина и количество начала кадра, базового метода Хаффмана 0xFFC4; (11-12) длина и количество начала закодированного изображения 0xFFDA.

Во второй data set были включены данные о 54 признаках на основе основных и дополнительных маркеров.

IV. ОБУЧЕНИЕ МОДЕЛЕЙ

Для построения автоматизированной системы подтверждения подлинности изображений на основе построенных обучающих выборок (решения задачи классификации) были обучены моде-

ли методов машинного обучения, построенные на основе алгоритмов наивного байесовского классификатора; решающих деревьев; k-ближайших соседей; случайного леса.

Качество обучения было протестировано методом кросс-валидации. Сами алгоритмы машинного обучения были заимствованы из библиотеки sklearn компании Google.

В результате было установлено, что наилучший уровень предсказания имеет модель, основанная на алгоритме случайного леса – 87%.

Такой результат позволяет найти практическое применение в области информационной безопасности и криминалистике. Однако исследования в этой области имеют дальнейшие пути развития. Например, пополнение базы данных оригинальных фотографий, расширение количества классов марок и моделей фотоаппаратов, поиск новых характеристик для классификации и дополнение базы изображениями, измененными в различных редакторах.

V. СЕРВИС ПРОВЕРКИ ПОДЛИННОСТИ ИЗОБРАЖЕНИЙ

Разработан и функционирует как клиент-серверное приложение прототип сервиса проверки подлинности цифровых изображений. Сервис является локальным на компьютере эксперта, так как передавать в локальную сеть, а тем более в Интернет, криминалистически значимую информацию недопустимо.

База признаков, используемых для прогнозирования результата, – для определения подлинности цифрового изображения путем подтверждения (или отрицания) наличия у него характеристик, присущих фотографиям, сделанных фотокамерой конкретных бренда и модели, – может пополняться экспертом самостоятельно. Особое внимание уделено фотографиям, сделанным камерами цифровых мобильных устройств, с учетом их очень широкого распространения и весьма большого разнообразия.

1. Как проверить фотографию на подлинность [Электронный ресурс]. – Режим доступа: <http://www.smtdp.com/ru/kak-proverit-fotografiyu-na-podlinnost/>. – Дата доступа: 21.08.2017.
2. Метаданные в цифровой фотографии [Электронный ресурс]. – Режим доступа: <http://www.ixbt.com/digimage/metadxp.shtml>. – Дата доступа: 20.02.2017.
3. ISO/IEC 10918-1: 1993(E). Information technology – digital compression and coding of continuous-tone still images – requirements and guidelines [Электронный ресурс]. – Метод доступа: <https://www.w3.org/Graphics/JPEG/itu-t81.pdf>. – Дата доступа: 22.08.2017.
4. Digital Camera Reviews, Canon Cameras, Nikon Cameras, DSLR and SLR Cameras - Steves Dificams [Электронный ресурс]. – Метод доступа: www.steves-dificams.com/camera-reviews/. – Дата доступа: 22.08.2017.