

Инкрементное обучение алгоритма обнаружения нехарактерного поведения на основе главных компонент

Р.А. Шаталин¹, В.Р. Фидельман¹, П.Е. Овчинников¹

¹ Нижегородский государственный университет им. Н.И. Лобачевского, Нижний Новгород

Аннотация

Предложена схема инкрементного обучения алгоритма обнаружения нехарактерного поведения на основе главных компонент. Результаты экспериментов на наборе данных лаборатории университета Калифорнии в Сан-Диего и экспериментально полученных видео при разном количестве обучающих примеров свидетельствуют о достижении результатов, схожих с процедурой обычного обучения. При этом предложенная схема позволяет в несколько раз сократить время инкрементного обучения в сравнении с подходом на основе спектрального разложения.

Ключевые слова: инкрементное обучение, обработка видеоизображений, обнаружение нештатных ситуаций, метод главных компонент.

Цитирование: Шаталин, Р.А. Инкрементное обучение алгоритма обнаружения нехарактерного поведения на основе главных компонент / Р.А. Шаталин, В.Р. Фидельман, П.Е. Овчинников // Компьютерная оптика. – 2020. – Т. 44, № 3. – С. 476-481. – DOI: 10.18287/2412-6179-CO-624.

Citation: Shatalin RA, Fidelman VR, Ovchinnikov PE. Incremental learning for abnormal behaviour detection algorithm based on principal components. Computer Optics 2020; 44(3): 476-481. DOI: 10.18287/2412-6179-CO-624.

Введение

За последние годы для задач видеонаблюдения предложено и реализовано множество алгоритмов обнаружения конкретных нештатных ситуаций на основе строгих правил [1, 2]. Хотя данный подход позволяет с высокой надёжностью распознавать заранее известные типы нештатных ситуаций, модификация алгоритмов для выявления иного типа аномалий не тривиальна. Для устранения данного недостатка было предложено множество подходов к обнаружению аномалий в сцене [3]. Одним из них является поиск отклонений от модели, составленной на основе примеров нормального поведения. Для решения данной задачи часто используют оценки на основе метода главных компонент [4]. Ранее был предложен алгоритм обнаружения нештатных ситуаций на основе метода главных компонент [5]. Данный алгоритм обучается путём вычисления набора главных компонент для векторов характеристик нормального поведения. При поступлении нового примера нормального поведения требуется повторное вычисление главных компонент по старым и новым данным, но вычислительная сложность данной процедуры не позволяет применить её в реальном времени. Одним из способов устранения данного недостатка является инкрементное обучение [6], которое заключается в адаптации модели по новым данным.

В данной работе предложена схема инкрементного обучения алгоритма на новом векторе характеристик нормального поведения с существенно меньшей вычислительной сложностью и уровнем ошибок, сравнимым с обычным обучением алгоритма.

1. Метод

Предлагаемая схема инкрементного обучения была протестирована путём модификации алгоритма обнаружения нештатных ситуаций по последовательностям длин векторов смещения [5]. Полученный алгоритм состоит из следующих этапов.

Выделение фона

Для выделения фона использовалась самоорганизующаяся искусственная нейронная сеть, предложенная в работе [7]. Параметры сети подбирались на основе экспериментальных данных. Хотя предложенный ранее критерий качества выделения фона на основе морфологических операторов [8] позволяет получить некие оценки параметров самоорганизующейся сети, он не учитывает особенностей остальных этапов алгоритма. Например, ложные объекты мало влияют на оценку движения в сцене, но отнесение объекта к фону вносит существенное искажение в характеристики поведения.

Оценка движения

Для оценки движения пикселей объектов между двумя последовательными кадрами был использован пирамидальный метод Лукаса–Канаде [9]. Для компенсации влияния перспективной проекции методом плоской гомографии [10] рассчитывались векторы смещения – проекции векторов оптического потока на плоскость пола. Затем вычислялись значения длин векторов смещения, к которым применялся медианный фильтр.

Извлечение признаков поведения

Вектор признаков поведения был выбран как последовательность отфильтрованных длин векторов смещения для всех пикселей на изображении. Пусть изображение имеет размеры $W \times H$, а $\vec{d}(x, y)$ – вектор смещения для пикселя с координатами (x, y) . Тогда вектор признаков поведения \vec{f} можно записать в следующем виде:

$$\vec{f} = \left\{ \left| \vec{d}(0, 0) \right|, \left| \vec{d}(1, 0) \right|, \dots, \left| \vec{d}(W, 0) \right|, \right. \\ \left. \left| \vec{d}(0, 1) \right|, \dots, \left| \vec{d}(W, 1) \right|, \dots, \left| \vec{d}(W, H) \right| \right\}. \quad (1)$$

Обнаружение нештатных ситуаций

Для оценки аномальности поведения в сцене по векторам признаков применялся метод на основе главных компонент [5], суть которого заключается в следующем. На стадии обучения для всех примеров «нормального» поведения извлекаются вектора признаков, и для получившегося набора векторов находят главные компоненты. Во время работы текущий вектор признаков поведения проецируется на набор векторов главных компонент и обратно. В общем случае набор векторов главных компонент не является базисом и некоторая составляющая вектора теряется при проецировании. Далее эта составляющая называется вектором невязки, и её можно вычислить из следующих выражений:

$$\vec{r} = \vec{f} - \vec{f}_r = \vec{f} - \vec{F} - \sum_i^q p_i \vec{v}_i, \quad (2) \\ p_i = (\vec{f} - \vec{F}, \vec{v}_i),$$

где \vec{r} – вектор невязки, \vec{f} – текущий вектор характеристик поведения, \vec{f}_r – результат прямого и обратного проецирования вектора \vec{f} , \vec{F} – среднее значение вектора характеристик поведения по обучающей выборке, \vec{v}_i – вектор i -й главной компоненты, p_i – проекция вектора \vec{f} на вектор \vec{v}_i , $(\vec{f} - \vec{F}, \vec{v}_i)$ – скалярное произведение векторов \vec{v}_i и $\vec{f} - \vec{F}$, q – общее количество главных компонент.

В качестве оценки аномальности использовалась максимальная невязка, которая представляет собой максимальное значение среди модулей компонент вектора невязки.

Инкрементное обучение данного метода сводится к задаче обновления главных компонент по новому значению вектора характеристик нормального поведения. Пусть n – размерность вектора характеристик поведения, а m – количество примеров в исходной обучающей выборке. Если пренебречь изменением среднего значения вектора характеристик \vec{F} , то ковариационную матрицу C' размером $n \times n$ для дополненной обучающей выборки можно записать в следующем виде:

$$C' = \frac{1}{m+1} \sum_k^{m+1} (\vec{f}_k - \vec{F})(\vec{f}_k - \vec{F})^T = \\ = \frac{1}{m+1} \sum_k^m (\vec{f}_k - \vec{F})(\vec{f}_k - \vec{F})^T + \\ + \frac{1}{m+1} (\vec{f}_{m+1} - \vec{F})(\vec{f}_{m+1} - \vec{F})^T = \\ = \frac{m}{m+1} C + \frac{1}{m+1} (\vec{f}_{m+1} - \vec{F})(\vec{f}_{m+1} - \vec{F})^T, \quad (3)$$

где C' – ковариационная матрица для дополненной обучающей выборки, \vec{f}_{m+1} – новое значение вектора характеристик нормального поведения, а C – ковариационная матрица для исходной обучающей выборки.

Если количество главных компонент q для исходной обучающей выборки совпадает с размерностью вектора характеристик n , то вектора главных компонент образуют базис и вектор невязки равен нулю. Рассмотрим случай, когда $q < n$. Составим ортонормированный базис из векторов главных компонент, нормализованного вектора невязки $\vec{r}_{m+1} / |\vec{r}_{m+1}|$ для нового примера нормального поведения и произвольных векторов $\{\vec{v}_{q+2} \dots \vec{v}_n\}$. С учётом выражения (2) новое значение вектора характеристик нормального поведения \vec{f}_{m+1} после вычитания среднего значения вектора характеристик \vec{F} можно записать в данном базисе следующим образом:

$$\vec{f}_{m+1} - \vec{F} = \vec{r}_{m+1} + \sum_i^q p_i \vec{v}_i = \sum_i^q p_i \vec{v}_i + \left| \vec{r}_{m+1} \right| \frac{\vec{r}_{m+1}}{\left| \vec{r}_{m+1} \right|}. \quad (4)$$

Определим ортогональную матрицу V размером $n \times n$ вида:

$$V = \left[\vec{v}_0 \quad \dots \quad \vec{v}_q \quad \vec{r}_{m+1} / \left| \vec{r}_{m+1} \right| \quad \vec{v}_{q+2} \quad \dots \quad \vec{v}_n \right]. \quad (5)$$

Тогда спектральное разложение ковариационной матрицы C для исходной обучающей выборки можно представить в следующем виде:

$$C = V \begin{bmatrix} \lambda_0 & \dots & 0 & 0 & \dots & 0 \\ \vdots & \ddots & \vdots & \vdots & \dots & \vdots \\ 0 & \dots & \lambda_q & 0 & \dots & 0 \\ 0 & \dots & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & 0 & \dots & 0 \end{bmatrix} V^T = V \Lambda V^T, \quad (6)$$

где λ_i – собственное значение i -й главной компоненты.

Аналогично спектральное разложение ковариационной матрицы C' для дополненной обучающей выборки можно представить в виде:

$$C' = V' \Lambda' V'^T = \frac{m}{m+1} V \Lambda V^T + \\ + \frac{1}{m+1} (\vec{f}_{m+1} - \vec{F})(\vec{f}_{m+1} - \vec{F})^T. \quad (7)$$

Из выражения (7) следует связь между главными компонентами исходной и дополненной обучающей выборки:

$$\begin{aligned}
 V' \Lambda' V'^T &= \frac{m}{m+1} V \Lambda V^T + \\
 &+ \frac{1}{m+1} V V^T (\vec{f}_{m+1} - \vec{F}) (\vec{f}_{m+1} - \vec{F})^T V V^T = \\
 &= \frac{1}{m+1} V [m \Lambda + V^T (\vec{f}_{m+1} - \vec{F}) (\vec{f}_{m+1} - \vec{F})^T V] V^T.
 \end{aligned} \tag{8}$$

Определим матрицу M размером $n \times n$ следующим образом:

$$M = m \Lambda + V^T (\vec{f}_{m+1} - \vec{F}) (\vec{f}_{m+1} - \vec{F})^T V, \tag{9}$$

тогда задачу обновления главных компонент можно свести к поиску спектрального разложения матрицы M следующим образом:

$$\begin{aligned}
 V' \Lambda' V'^T &= \frac{1}{m+1} V V_M \Lambda_M V_M^T V^T, \\
 V' &= V V_M, \quad \Lambda' = \frac{1}{m+1} \Lambda_M,
 \end{aligned} \tag{10}$$

где V_M – матрица из собственных векторов M , Λ_M – матрица из собственных чисел M .

Для анализа структуры матрицы M необходимо рассмотреть часть второго слагаемого с учётом выражений (4) и (5):

$$V^T (\vec{f}_{m+1} - \vec{F}) = \begin{bmatrix} \vec{v}_0 \\ \vdots \\ \vec{v}_q \\ \vec{r}_{m+1} / |\vec{r}_{m+1}| \\ \vec{v}_{q+2} \\ \vdots \\ \vec{v}_n \end{bmatrix} \left(\sum_i^q p_i \vec{v}_i + |\vec{r}_{m+1}| \frac{\vec{r}_{m+1}}{|\vec{r}_{m+1}|} \right). \tag{11}$$

Поскольку вектора $\{\vec{v}_{q+2} \dots \vec{v}_n\}$ вместе с векторами главных компонент \vec{v}_i и нормализованным вектором невязки $\vec{r}_{m+1} / |\vec{r}_{m+1}|$ образуют ортонормированный базис, то выражение (11) сводится к следующему:

$$V^T (\vec{f}_{m+1} - \vec{F}) = \begin{bmatrix} p_0 \\ \vdots \\ p_q \\ |\vec{r}_{m+1}| \\ 0 \\ \vdots \\ 0 \end{bmatrix}. \tag{12}$$

Тогда матрица M запишется в виде:

$$\begin{bmatrix} m\lambda_0 + p_0^2 & \dots & p_0 p_q & p_0 |\vec{r}_{m+1}| & 0 & \dots & 0 \\ \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ p_q p_0 & \dots & m\lambda_q + p_q^2 & p_q |\vec{r}_{m+1}| & 0 & \dots & 0 \\ |\vec{r}_{m+1}| p_0 & \dots & |\vec{r}_{m+1}| p_q & |\vec{r}_{m+1}|^2 & 0 & \dots & 0 \\ 0 & \dots & 0 & 0 & 0 & \dots & 0 \\ \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & 0 & 0 & \dots & 0 \end{bmatrix}. \tag{13}$$

Из (13) видно, что все столбцы и строки матрицы M с индексами больше $q+1$ равны нулю, что позволяет произвести спектральное разложение лишь для верхнего левого блока. Тем не менее, средняя вычислительная сложность данной операции составляет $O(q^3)$ [12], что при большом количестве главных компонент не позволяет применить её в реальном времени.

Предлагаемая схема инкрементного обучения заключается в следующем. Если пренебречь взаимозависимостями между проекциями вектора характеристик \vec{f}_{m+1} на составленный базис, то обновление главных компонент можно производить по набору векторов следующего вида:

$$\left\{ \vec{F} + (\vec{f}_{m+1}, \vec{v}_0) \vec{v}_0, \dots, \vec{F} + (\vec{f}_{m+1}, \vec{v}_q) \vec{v}_q, \vec{F} + \vec{r}_{m+1} \right\}. \tag{14}$$

При проецировании таких векторов только одна из компонент вектора (12) отлична от нуля, и матрица M принимает диагональный вид. Введя шаг инкрементального обучения c , получаем следующую схему обновления собственных значений:

$$\lambda'_i = \begin{cases} (1-c)\lambda_i + c \cdot p_i^2, & i \leq q, \\ c \cdot |\vec{r}_{m+1}|^2, & i = q+1. \end{cases} \tag{15}$$

Таким образом, инкрементное обучение метода сводится к добавлению главной компоненты с вектором $\vec{r}_{m+1} / |\vec{r}_{m+1}|$ и обновлением собственных значений по формуле (15). Данный подход использует неточный способ определения главных компонент для дополненной обучающей выборки, но его вычислительная сложность составляет $O(q)$.

2. Результаты экспериментов

Предлагаемая схема инкрементного обучения алгоритма обнаружения нехарактерного поведения на основе главных компонент была реализована в качестве алгоритма обработки видеоизображений. Работа алгоритма была протестирована на наборе данных лаборатории университета Калифорнии в Сан-Диего (UCSD) [11] и экспериментально полученных видео. Видеозапись «Работа и ремонт» была сделана в компьютерном классе ННГУ. На ней в качестве нормального поведения была взята работа за компьютером, а в качестве нештатного – манипуляции с задней панелью системного блока. Видеозапись лаборатории UCSD содержит пешеходную улицу, обычная ходьба

по которой была взята за нормальное поведение, а проезд транспортных средств – за нештатное.

Из каждого видео бралось ограниченное число примеров нормального поведения. Часть примеров использовалась для обычного обучения алгоритма, а остальная часть – для инкрементного обучения. Затем вычислялись значения максимальной невязки для остальных кадров с нормальным и аномальным поведением из выбранного видео. На основе полученных значений рассчитывались равные уровни ошибок, которые представляют собой уровень ошибок при равной частоте ложных тревог и пропуска события [11]. При этом для уменьшения влияния шума и вычислительных погрешностей отбрасывались главные компоненты, которые описывали менее 0,1 % вариации характеристик нормального поведения. Для сравнения также рассматривался случай, когда все примеры нормального поведения использовались для обычного обучения алгоритма.

Параметры самоорганизующейся сети для извлечения фона [7] и размер медианного фильтра для длин векторов смещения подбирались из условия минимума равного уровня ошибок алгоритма на видеозаписях и приведены в табл. 1. Шаг инкрементного обучения s был задан равным 0,00001.

Табл. 1. Параметры извлечения характеристик поведения из видео «Работа и ремонт» и видео лаборатории UCSD

Параметр	Работа и ремонт	UCSD
Начальный порог сети для извлечения фона	1	1
Рабочий порог сети для извлечения фона	0,001	0,05
Начальная скорость обучения сети для извлечения фона	1	1
Рабочая скорость обучения сети для извлечения фона	0,001	0,001
Размер медианного фильтра, пиксели	3	5

В табл. 2 приведены равные уровни ошибок алгоритма при разном количестве примеров нормального поведения для обычного и инкрементного обучения. Из табл. 2 видно, что предложенная схема инкрементного обучения позволяет достичь результатов, аналогичных обычному обучению. При этом расхождение в равных уровнях ошибок объясняется неточностью определения главных компонент при инкрементном обучении. Для видео лаборатории UCSD полученные результаты близки к равному уровню ошибок в 23 %, который является минимальным среди всех методов, рассмотренных в работе [11].

Тестирование предлагаемого алгоритма было проведено на компьютере с четырёхъядерным CPU Intel Core i7 4,2 ГГц и 16 GB RAM. В табл. 3 приведено среднее время инкрементного обучения на одном примере нормального поведения на основе спектрального разложения матрицы M и по предложенной

схеме при разном количестве главных компонент. Из табл. 3 видно существенное сокращение времени инкрементного обучения при использовании предложенной схемы вместо подхода на основе спектрального разложения.

Табл. 2. Равный уровень ошибок максимальной невязки для видео «Работа и ремонт» и видео лаборатории UCSD при разном количестве примеров нормального поведения для обычного и инкрементного обучения. Знак «+» обозначает инкрементное обучение и разделяет количество примеров для обычного и инкрементного обучения

Название видео	Количество примеров	Максимальная невязка
Работа и ремонт	3+2	5,72 %
Работа и ремонт	3+4	7,02 %
Работа и ремонт	3+6	1,47 %
Работа и ремонт	5	5,72 %
Работа и ремонт	7	1,58 %
Работа и ремонт	9	1,47 %
UCSD	5+5	28,56 %
UCSD	5+10	26,20 %
UCSD	5+15	27,95 %
UCSD	5+20	26,57 %
UCSD	10	28,85 %
UCSD	15	26,63 %
UCSD	20	28,60 %
UCSD	25	27,41 %

Табл. 3. Среднее время инкрементного обучения на одном примере нормального поведения для кадров из видео «Работа и ремонт» и видео лаборатории UCSD на основе спектрального разложения и предложенной схемы при разном количестве главных компонент

Название видео	Количество главных компонент	Обучение на основе спектрального разложения, мс	Предложенная схема, мс
Работа и ремонт	205	199,68	14,74
UCSD	624	5438,52	68,58

В табл. 4 приведено среднее время извлечения вектора характеристик и расчёта значений невязок для него. Видно, что инкрементное обучение не приводит к увеличению количества главных компонент и времени вычисления невязок.

Заключение

В данной работе предложена схема инкрементного обучения алгоритма обнаружения нехарактерного поведения на основе метода главных компонент. Для тестирования схемы был реализован алгоритм оценки аномальности поведения в сцене. Результаты экспериментов на наборе данных лаборатории университета Калифорнии в Сан-Диего (UCSD) и экспериментально полученных видео при разном количестве обучающих примеров свидетельствуют о достижении результатов, схожих с процедурой обычного обучения. При этом предложенная схема позволяет в не-

сколько раз сократить время инкрементного обучения в сравнении с подходом на основе спектрального разложения.

Табл. 4. Среднее время извлечения вектора характеристик и расчета невязок для кадров из видео «Работа и ремонт» и видео лаборатории UCSD при разном количестве примеров нормального поведения для обычного и инкрементного обучения. Знак «+» обозначает инкрементное обучение и разделяет количество примеров для обычного и инкрементного обучения

Название видео	Количество примеров	Количество главных компонент	Извлечение характеристик, мс	Вычисление невязок, мс
Работа и ремонт	3	205	98,9	13,9
Работа и ремонт	5	227	99,2	15,2
Работа и ремонт	7	257	98,5	17,2
Работа и ремонт	9	265	99,4	17,7
Работа и ремонт	3+2	220	99,2	14,8
Работа и ремонт	3+4	202	99,7	13,7
Работа и ремонт	3+6	265	98,9	17,8
UCSD	5	624	13,3	32,7
UCSD	10	1353	13,3	69,4
UCSD	15	1161	13,7	59,9
UCSD	20	1614	13,7	83,8
UCSD	25	1815	13,6	93,7
UCSD	5+5	703	13,7	36,8
UCSD	5+10	366	13,4	19,3
UCSD	5+15	456	13,6	24,0
UCSD	5+20	593	13,2	30,5

Литература

1. **Popoola, O.** Video-based abnormal human behavior recognition – A review / O. Popoola, K. Wang. // IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews. – 2012. – Vol. 42, Issue 6. – P. 865-878.

2. **Елифанцев, Б.Н.** Мультисенсорные системы мониторинга территорий ограниченного доступа: возможности видеоаналитического канала обнаружения вторжений / Б.Н. Елифанцев, А.А. Пятков, С.А. Копейкин // Компьютерная оптика. – 2016. – Т. 40, № 1. – С. 121-129. – DOI: 10.18287/2412-6179-2016-40-1-121-129.

3. **Sodemann, A.** A Review of Anomaly Detection in Automated Surveillance / A. Sodemann, M. Ross, B. Borghetti // IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews. – 2012. – Vol. 42, Issue 6. – P. 1257-1272.

4. **Jolliffe, I.T.** Principal component analysis / I.T. Jolliffe. – 2nd ed. – New York: Springer, 2002. – 488 p.

5. **Шаталин, Р.А.** Обнаружение нехарактерного поведения в задачах видеонаблюдения / Р.А. Шаталин, В.Р. Фидельман, П.Е. Овчинников // Компьютерная оптика. – 2017. – Т. 41, № 1. – С. 37-45. – DOI: 10.18287/2412-6179-2017-41-1-37-45.

6. **Losing, V.** Incremental on-line learning: A review and comparison of state of the art algorithms / V. Losing, B. Hammer, H. Wersing // Neurocomputing. – 2018. – Vol. 275. – P. 1261-1274.

7. **Maddalena, L.** A self-organizing approach to background subtraction for visual surveillance application / L. Maddalena, A. Petrosino // IEEE Transactions on Image Processing. – 2008. – Vol. 17, Issue 7. – P. 1168-1177.

8. **Шаталин, Р.А.** Критерий качества выделения фона с использованием морфологических операторов для задач обнаружения нештатных ситуаций / Р.А. Шаталин, П.Е. Овчинников // Системы управления и информационные технологии. – 2014. – Т. 56(2). – С. 190-194.

9. **Bouguet, J.** Pyramidal implementation of the Lucas Kanade feature tracker / J. Bouguet // Intel Corporation, Microprocessor Research Labs. – 2000. – 9 p.

10. **Antonakaki P.** Detecting abnormal human behavior using multiple cameras / P. Antonakaki, D. Kosmopoulos, S. Perantonis // Signal Processing. – 2009. – Vol. 89, Issue 9. – P. 1723-1738.

11. **Mahadevan, V.** Anomaly detection and localization in crowded scenes / V. Mahadevan, W. Li, V. Bhalodia, N. Vasconcelos // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2014. – Vol. 36, Issue 1 – P. 18-31.

12. **Press, W.H.** Numerical recipes: The art of scientific computing / W.H. Press, S.A. Teukolsky, W.T. Vetterling, B.P. Flannery. – 3rd ed. – New York: Cambridge University Press, 2007. – 1256 p.

Сведения об авторах

Шаталин Роман Андреевич, 1992 года рождения, в 2015 году окончил Нижегородский государственный университет по направлению подготовки 09.04.02 «Информационные системы и технологии» и поступил в аспирантуру ННГУ по направлению подготовки 03.06.01 «Физика и астрономия», работает программистом на кафедре информационных технологий в физических исследованиях физического факультета ННГУ. Область научных интересов: обработка видеоизображений, компьютерное зрение и машинное обучение. E-mail: shatalinra@nifti.unn.ru.

Фидельман Владимир Романович, 1950 года рождения, в 1974 году окончил физический факультет ГГУ по специальности «Физика» со специализацией «Математическое обеспечение ЭВМ и АСУ». В 1997 году защитил диссертацию на соискание ученой степени доктора технических наук по специальности «Применение вычислительной техники, математического моделирования и математических методов в научных исследованиях». С 1998 года – заведующий кафедрой информационных технологий в физических исследованиях физического факультета ННГУ. Область научных интересов: методы цифровой обработки сигналов и изображе-

ний, методы моделирования открытых самоорганизующихся систем, системы автоматизации научных исследований. E-mail: fidelman@nifti.unn.ru.

Овчинников Павел Евгеньевич, 1983 года рождения, в 2005 году окончил физический факультет ННГУ по специальности «Информационные системы (в физике)». В 2009 году защитил диссертацию на соискание ученой степени кандидата физико-математических наук, с 2013 года – старший научный сотрудник НИФТИ ННГУ. Область научных интересов: методы цифровой обработки сигналов и изображений, машинное обучение. E-mail: ope@nifti.unn.ru.

ГРНТИ: 28.23.15

Поступила в редакцию 27 августа 2019 г. Окончательный вариант – 10 декабря 2019 г.

Incremental learning of an abnormal behavior detection algorithm based on principal components

R.A. Shatalin¹, V.R. Fidelman¹, P.E. Ovchinnikov¹

¹Lobachevsky State University of Nizhny Novgorod, Nizny Novgorod, Russia

Abstract

In this paper, we propose an incremental learning scheme for the abnormal behavior detection algorithm based on principal component. The results obtained on a UCSD dataset and our experimental videos at a different number of training samples show that error rates are similar to conventional learning. Moreover, the proposed scheme allows the incremental learning time to be significantly reduced in comparison with a method based on matrix eigendecomposition.

Keywords: incremental learning, video analysis, anomaly detection, principal component analysis.

Citation: Shatalin RA, Fidelman VR, Ovchinnikov PE. Incremental learning for abnormal behaviour detection algorithm based on principal components. *Computer Optics* 2020; 44(3): 476-481. DOI: 10.18287/2412-6179-CO-624.

References

- | | |
|--|---|
| <p>[1] Popoola O, Wang K. Video-based abnormal human behavior recognition – A review. <i>IEEE Trans Syst Man Cybern C</i> 2012; 42(6): 865-878.</p> <p>[2] Epifancev BN, Pyatkov AA, Kopeykin SA. Multi-sensor systems for monitoring access to restricted areas: capabilities of the intrusion detection video analytical channel. <i>Computer Optics</i> 2016; 40(1): 121-129. DOI: 10.18287/2412-6179-2016-40-1-121-129.</p> <p>[3] Sodemann A, Ross M, Borghetti B. A review of anomaly detection in automated surveillance. <i>IEEE Trans Syst Man Cybern C</i> 2012; 42(6): 1257-1272.</p> <p>[4] Jolliffe IT. <i>Principal component analysis</i>. 2nd ed. New York: Springer; 2002.</p> <p>[5] Shatalin RA, Fidelman VR, Ovchinnikov PE. Abnormal behaviour detection method for video surveillance applications. <i>Computer Optics</i> 2017; 41(1): 37-45. DOI: 10.18287/2412-6179-2017-41-1-37-45.</p> <p>[6] Losing V, Hammer B, Wersing H. Incremental on-line</p> | <p>learning: A review and comparison of state of the art algorithms. <i>Neurocomputing</i>, 2018, 275: 1261-1274.</p> <p>[7] Maddalena L, Petrosino A. a self-organizing approach to background subtraction for visual surveillance application. <i>IEEE Trans Image Proces</i> 2008; 17(7): 1168-1177.</p> <p>[8] Shatalin R, Ovchinnikov P. Background subtraction quality criterion based on morphological operations for behaviour anomaly detection [In Russian]. <i>Control Syst Inform Technol</i> 2014, 56(2):190-4.</p> <p>[9] Bouguet JY. Pyramidal implementation of the Lucas Kanade feature tracker. Intel Corp 2000.</p> <p>[10] Antonakaki P, Kosmopoulos D, Perantonis S. Detecting abnormal human behavior using multiple cameras. <i>Signal Proces</i> 2009, 89(9): 1723-1738.</p> <p>[11] Mahadevan V, Li W, Bhalodia V, Vasconcelos N. Anomaly detection and localization in crowded scenes. <i>IEEE Trans Pattern Anal Machine Intell</i>, 2014, 36(1): 18-31.</p> <p>[12] Press WH, Teukolsky SA, Vetterling WT, Flannery BP. <i>Numerical recipes: The Art of scientific computing</i>. 3rd ed. New York: Cambridge University Press; 2007.</p> |
|--|---|

Authors' information

Roman Andreevich Shatalin (b. 1992) received master degree in Computer Science from Lobachevsky State University, Nizhny Novgorod, Russian Federation in 2013 and currently is working towards PhD. His research interests primarily include computer vision and machine learning, with specific focus on visual analysis of human behavior. E-mail: shatalinra@nifti.unn.ru.

Vladimir Romanovich Fidelman (b. 1950) graduated from Faculty of Physics of Lobachevsky State University in 1974, majoring in Computer Software and Automation. Currently he is working as Head of Information Technology department in Physics research. Research interests are signal and image processing, models of open self-organizing systems, research automation systems. E-mail: fidelman@nifti.unn.ru.

Pavel Evgenyevich Ovchinnikov (b. 1983) graduated from Physics Faculty of Lobachevsky State University in 2005, majoring in Information Technologies in Physics. Currently he is working as Senior Researcher at Research Institute of Technical Physics at Lobachevsky State University. Research interests are signal and image processing, machine learning. E-mail: ope@nifti.unn.ru.

Received August 27, 2019. The final version – December 10, 2019.
