

УДК 004.932.72'1

С. Г. Антощук, д-р техн. наук,
Н. А. Годовиченко

УЧЕТ НЕОПРЕДЕЛЕННОСТИ ДАННЫХ ПРИ МОДЕЛИРОВАНИИ СОБЫТИЙ С ПОМОЩЬЮ СЕТИ ПЕТРИ

Аннотация. Проведен анализ задачи распознавания событий в видеопотоке, выявлены основные задачи, которые ставятся при разработке систем распознавания событий. Рассмотрено использование сети Петри в качестве модели для распознавания событий. Предложена вероятностная модель на основе сети Петри в виде байесовского рекурсивного фильтра с использованием фильтра частиц. Проведено тестирование на основе набора видеороликов и показана эффективность предложенной модели в условиях неопределенности входных данных при использовании реальных алгоритмов трекинга.

Ключевые слова: системы восприятия информации, модель событий, семантические сети, сеть Петри, вероятностная модель, байесовский подход, байесовский рекурсивный фильтр, динамическая модель, модель измерений

S. G. Antoshchuk, ScD.,
N. A. Godovichenko

ACCOUNTING DATA UNCERTAINTY IN MODELING EVENTS WITH PETRI NETS

Abstract. The analysis of the problem of recognition events in the video was conducted, identified the main tasks set in the development of systems of recognition events. The use of Petri nets as a model for recognition events was examined. The probabilistic model based on the Petri net in the form of the recursive Bayesian filter was proposed.. Testing conducted on a set of videos and shows the effectiveness of the proposed model under uncertainty of input data using real tracking algorithms.

Keywords: systems of information perception, event model, semantic networks, Petri nets, a probabilistic model, Bayesian approach, Bayesian recursive filter, the dynamic model, the measurement model, conditional independence

С. Г. Антощук, д-р.техн.наук,
М. А. Годовиченко

ВРАХУВАННЯ НЕВИЗНАЧЕНОСТІ ДАНИХ ПРИ МОДЕЛЮВАННІ ПОДІЙ ЗА ДОПОМОГОЮ МЕРЕЖІ ПЕТРІ

Анотація. Проведено аналіз задачі розпізнавання подій у відеопотоці, виявлені основні задачі, які виникають при розробці систем розпізнавання подій. Розглянуто використання мережі Петрі в якості моделі розпізнавання подій. Запропоновано імовірнісну модель на основі мережі Петрі у вигляді байесівського рекурсивного фільтру. Запропоновано динамічну модель та модель вимірювань на основі мережі Петрі. Проведено тестування на основі набору відеороликів та показано ефективність запропонованої моделі в умовах невизначеності вхідних даних при використанні реальних алгоритмів трекінгу.

Ключові слова: системи сприйняття інформації, модель подій, семантичні мережі, мережа Петрі, імовірнісна модель, байесівський підхід, байесівський рекурсивний фільтр, динамічна модель, модель вимірювань

Введение. Одним из важных направлений развития систем искусственного интеллекта является создание систем восприятия семантически значимой информации в видеопотоке.

Среди различных прикладных задач, связанных с созданием таких систем, можно выделить задачу распознавания событий, запечатленных на видео. Эта задача возникает при построении робототехнических систем, охранных систем нового поколения, систем интеллектуального видеонаблюдения и т.д.

События на видео являются высокоуровневыми семантическими концептами, которые воспринимает человек при просмотре видеопоследовательности. Восприятие и понимание этих событий компьютером является одной из основных задач, решаемых в настоящее время в области компьютерного зрения.

Разработка систем распознавания событий связана с решением двух ключевых задач [4]:

- 1) задача извлечения данных из видеопотока;
- 2) задача представления и распознавания значимых событий.

© Антощук С.Г., Годовиченко Н.А., 2013

Задача извлечения данных заключается в необходимости разработки комплекса методов и алгоритмов, предназначенных для преобразования видеoinформации в набор объектов, которые характеризуют видеопоследовательность.

Задача представления и распознавания событий заключается в поиске метода формального описания значимых событий с целью их дальнейшего анализа и распознавания. Как правило, формальное описание событий осуществляется с использованием определенной модели, которую называют модель событий [5].

Выбор подходящей модели для ее последующего использования в качестве модели событий является нетривиальной задачей, которой посвящено немало работ в области распознавания событий [1, 6 – 9]. Модель должна иметь достаточную выразительную мощность для моделирования сложных иерархических отношений и, в то же время, быть реализуемой на практике.

Еще одним важным требованием, предъявляемым к модели событий, является необходимость работать в условиях неопределенности данных, потому что информация о сцене, полученная на этапе извлечения данных, имеет вероятностный характер из-за шумов и ошибок распознавания.

Целью данной статьи является разработка модели представления событий, которая сочетает достаточную выразительную мощность для формального описания событий и возможность учитывать ошибки извлечения данных.

Наиболее предпочтительным является использование семантических моделей, среди которых можно выделить сеть Петри [1, 2, 10]. Механизм, заложенный в сети Петри, позволяет легко моделировать несквенциальные временные отношения, равно как и другие семантические отношения между событиями. Кроме того, представление модели обеспечивает ее компактность. Выразительная мощность сети Петри позволяет моделировать все временные интервальные отношения [11].

Моделирование событий с помощью сети Петри. Для моделирования событий с помощью сети Петри вводится понятие

«процесс», которое означает соединенные между собой события. Соединение осуществляется таким образом, чтобы определить временные и логические отношения между событиями.

Сеть Петри может быть представлена двудольным ориентированным графом (рис. 1) и формально определяется кортежем

$$\langle P, T, C, events, \delta, S, F \rangle,$$

где $P = \{P_1, P_2, \dots, P_n\}$ – множество позиций;

$T = \{T_1, T_2, \dots, T_n\}$ – множество переходов;

C – множество соединительных дуг;

$events$ – множество событий, которые составляют процесс;

$\delta : T \rightarrow events$ – функция маркировки, которая отображает события на переходы (например, $\delta(T_5) = \text{"Вошел_посетитель"}$);

S – стартовая позиция, которая представляет «начало» процесса;

F – конечная позиция, которая представляет «окончание» процесса.




Рис. 1. Представление сети Петри

Позиции представляют собой точки маршрута, которые определяют прогресс выполнения процесса. Специальные позиции определяют «старт» и «конец» процесса. «Стартовая» позиция содержит в себе метку, когда распознавание процесса находится в начальном состоянии. Метка в «конечной» позиции означает, что распознавание процесса было завершено. В другом случае, метка будет содержаться в одном или нескольких промежуточных позициях.

Наряду с большим количеством преимуществ, сеть Петри имеет недостатки, самым существенным из которых является детерминистическая природа сети. Использование сети Петри предполагает, что инфор-

мация, полученная на этапе извлечения данных, является безошибочной. Вследствие того, что информация о сцене, полученная на этапе извлечения данных, имеет вероятностный характер, детерминистическая модель на основе сети Петри будет работать неэффективно.

Решением данной проблемы может быть использование вероятностных моделей (например, байесовской сети), которые имеют механизмы для коррекции ошибок входных данных, однако такие модели не обладают достаточно выразительной мощностью для моделирования сложных процессов.

В качестве возможного варианта решения данной проблемы, авторами предлагается подход, который основан на преобразовании детерминистической модели на основе сети Петри в байесовский рекурсивный фильтр с использованием фильтра частиц, что позволяет делать вероятностный вывод о наступлении определенного события в условиях неопределенности входных данных.

Этот подход позволяет применять хорошо изученные методы работы с неопределенностью и, в то же время, использовать преимущества структуры сети Петри для моделирования событий.

Использование байесовского рекурсивного фильтра и фильтра частиц. Байесовский рекурсивный фильтр позволяет вычислить апостериорное распределение $P(x_t | y_{1:t})$ системы x_t в момент времени t путем получения апостериорного распределения $P(x_{t-1} | y_{1:t-1})$ в момент времени $t-1$, которое рекурсивно используется для получения обновленного измерения с каждым новым наблюдением.

Структура байесовского рекурсивного фильтра состоит из двух основных моделей. Динамическая модель $P(x_t | x_{t-1})$ описывает изменение состояний с течением времени. Модель измерений $P(y_t | x_t)$ определяет отношение между переменными состояния и наблюдения.

После инициализации, работа байесовского рекурсивного фильтра состоит из двух этапов: предсказание и коррекция.

Для представления и оценки апостериорного распределения используется фильтр

частиц, с помощью которого апостериорная функция плотности вероятности представляется в виде множества случайных частиц с ассоциированными весами.

Фильтр частиц поддерживает множество N гипотез о текущем состоянии, которое называется частицами и обозначается как $X_t = \{x_t^{(1)}, x_t^{(2)}, \dots, x_t^{(N)}\}$. Каждой частице $x_t^{(i)}$ ставится в соответствие вес w_t^i . Веса используются для аппроксимации апостериорного распределения следующим образом:

$$P(x_t | y_{1:t}) \approx \sum_{i=1}^N w_t^i \delta(x_t, x_t^{(i)}),$$

где δ – дельта-функция Дирака.

Построение байесовского рекурсивного фильтра с помощью сети Петри. Чтобы применить байесовский рекурсивный фильтр для решения задачи моделирования и распознавания событий, необходимо представить модель событий, выраженную с помощью сети Петри в терминах байесовского рекурсивного фильтра.

Строго говоря, необходимо определить пространство возможных состояний, которые может принимать система в определенный момент времени, а также пространство возможных наблюдений в этот момент времени.

На следующем этапе необходимо определить динамическую модель $P(x_t | x_{t-1})$, которая описывает изменение состояний системы во времени, а также модель измерений $P(y_t | x_t)$, которая определяет достоверность определенного наблюдения, когда система находится в определенном состоянии.

Кроме того, необходимо определить условную независимость переменных, чтобы отобразить природу сети Петри, а также определить априорную вероятность для инициализации работы фильтра.

Определение пространства состояний. Байесовская парадигма требует, чтобы в динамической модели текущее состояние полностью определялось предыдущими состояниями. Вследствие этого для моделирования динамики сети Петри необходимо предположить, что множество

событий, которые происходят на каждом кадре, являются компонентами состояния.

Таким образом, переменная $x_t = \langle x_{t(m)}, x_{t(e)} \rangle$ является кортежем из двух компонентов. Первый компонент $x_{t(m)} \in \mathcal{S}$ означает маркировку сети Петри в момент времени t . Второй компонент $x_{t(e)} \in \mathcal{M}$ определяет события (если есть таковые), которые происходят в момент времени t .

Определение пространства наблюдений. На каждом кадре будет наблюдаться определенное значение достоверности для соответствующего релевантного события из множества O . Таким образом, наблюдение будет являться вектором $y_t \in [0,1]^{|O|}$, i -ый компонент $y_{t(i)}$ вектора y_t представляет достоверность наблюдения $O(i)$, i -го события в O .

Определение условной независимости. В дополнение к определению переменных состояния и наблюдения, также предполагается некоторая условная независимость среди переменных, чтобы отобразить природу сети Петри.

Прежде всего, пространство состояний факторизуется с использованием марковского предположения первого порядка, которое утверждает, что состояние в момент времени t не зависит от состояния всех предыдущих моментов, а только от момента времени $t-1$. Таким образом, необходимо поддерживать аппроксимацию зависимости только между состояниями в моменты времени t и $t-1$.

Дополнительно, делается предположение, что события, которые случаются в конкретном кадре, могут соотноситься только с открытыми переходами сети Петри. Кроме того, при данном событии, которое происходит в момент времени t , переменная наблюдения независима от текущей маркировки.

Говоря строго, можно сказать, что $x_{t(e)}$ не зависит от $x_{t-1(m)}$, а $x_{t-1(e)}$ не зависит от $x_{t(m)}$. Также y_t не зависит от $x_{t(m)}$ и $x_{t(e)}$ (рис. 2).




Рис. 2. Отношения условной независимости между переменными состояния и наблюдения

Определение динамической модели. Динамическую модель $P(x_t | x_{t-1})$ можно представить следующим образом:

$$P(x_t | x_{t-1}) = P(x_{t(m)}, x_{t(e)} | x_{t-1(m)}, x_{t-1(e)}) = P(x_{t(m)} | x_{t-1(m)}, x_{t-1(e)}) \cdot P(x_{t(e)} | x_{t(m)}),$$

где второе равенство получается согласно условной независимости $x_{t(e)}$ от $x_{t-1(m)}$ и $x_{t-1(e)}$ от $x_{t(m)}$. Таким образом, это позволяет найти $P(x_{t(m)} | x_{t-1(m)}, x_{t-1(e)})$ и $P(x_{t(e)} | x_{t(m)})$ исходя из структуры сети Петри. Формула $P(x_{t(e)} | x_{t(m)})$ образуется путем назначения равной вероятности всем включенным переходам в структуре сети Петри следующим образом: $\hat{P}(x_{t(e)} | x_{t(m)}) = 1$, если все переходы в $x_{t(e)}$ открыты в маркировке $x_{t(m)}$ и $\hat{P}(x_{t(e)} | x_{t(m)}) = 0$ в ином случае. Пустое множество $x_{t(e)} = \emptyset$ считается включенным во всех маркировках.

Если произвести нормализацию, будет получено следующее выражение:

$$P(x_{t(e)} | x_{t(m)}) = \frac{\hat{P}(x_{t(e)} | x_{t(m)})}{\sum_{x' \in \mathcal{M}} \hat{P}(x' | x_{t(m)})}.$$

Аналогично $P(x_{t(m)} | x_{t-1(m)}, x_{t-1(e)})$ получается следующим образом: $\hat{P}(x_{t(m)} | x_{t-1(m)}, x_{t-1(e)}) = 1$, в том случае, если $x_{t(m)} \leftarrow x_{t-1(m)} | x_{t-1(e)}$ и $\hat{P}(x_{t(m)} | x_{t-1(m)}, x_{t-1(e)}) = 0$ в ином случае. В конкретном случае

$x_{t(m)} \leftarrow x_{t-1(m)} | x_{t-1(e)}$ означает, что существует путь из состояния $x_{t-1(m)}$ в состояние $x_{t(m)}$ через переход, связанный с событием $x_{t-1(e)}$. После осуществления нормализации будет получено следующее выражение:

$$P(x_{t(m)} | x_{t-1(m)}, x_{t-1(e)}) = \frac{\hat{P}(x_{t(m)} | x_{t-1(m)}, x_{t-1(e)})}{\sum_{x' \in S} \hat{P}(x' | x_{t-1(m)}, x_{t-1(e)})}$$

Получение модели измерений. Для получения модели измерения $P(y_t | x_t)$ необходимо, чтобы все компоненты вектора наблюдений были независимы по отношению друг к другу. Это предположение приводит к следующему выражению:

$$P(y_t | x_t) = \prod_{i=1}^{|O|} P(y_{t(i)} | x_t)$$

где $y_{t(i)}$ указывает на i -й компонент вектора наблюдения. Кроме того, используя предположение, что y_t является условно независимым по отношению к $x_{t(m)}$ данного $x_{t(e)}$, можно получить:

$$P(y_t | x_t) = \prod_{i=1}^{|O|} P(y_{t(i)} | x_t) = \prod_{i=1}^{|O|} P(y_{t(i)} | x_{t(m)}, x_{t(e)}) = \prod_{i=1}^{|O|} P(y_{t(i)} | x_{t(e)})$$

Этого достаточно чтобы записать $P(y_{t(i)} | x_{t(e)})$ из структуры сети Петри, что позволяет получить модель измерения.

Вид вероятности наблюдения $P(y_{t(i)} | x_{t(e)})$ моделирует представление о том, что если происходит определенное событие, наблюдаемая достоверность этого события будет высокой. Сигмоидальная функция, центрированная на значении 0,5, прекрасно подходит для моделирования этого предположения. С другой стороны, если событие не происходит, наблюдаемая достоверность этого события должна быть низкой. Таким образом, i -й компонент $y_{t(i)}$ представляет достоверность i -го события

$O(i)$ во множестве O . Так как $x_{t(e)} \in M \subseteq 2^O$, то можно проверить принадлежность $O(i)$ во множестве $x_{t(e)}$.

$$P(y_{t(i)} | x_{t(e)}) = \begin{cases} \varphi(y_{t(i)}) & \text{если } O(i) \in x_{t(e)} \\ 1 - \varphi(y_{t(i)}) & \text{иначе} \end{cases}$$

где $\varphi(z)$ – сигмоидальная функция с центром в 0,5:

$$\varphi(z) = \frac{1}{1 + e^{-k*(z-0.5)}}$$

Определение априорной вероятности. Априорная вероятность $P(x_0)$ определяется изначальной разметкой сети Петри следующим образом: $P(x_0) = P(x_{0(m)}, x_{0(e)}) = 1$, если $x_{0(m)}$ – изначальная разметка, а $x_{0(e)} = \emptyset$, и $P(x_0) = P(x_{0(m)}, x_{0(e)}) = 0$ в другом случае.

Работа байесовского рекурсивного фильтра. Из-за того, что для представления апостериорного распределения применяется фильтр частиц, работа байесовского рекурсивного фильтра сводится к вычислению весов w_t^i частиц, которые используются для аппроксимации апостериорного распределения $P(x_t | y_{1:t})$.

Первым шагом является инициализация фильтра, которая состоит в генерации множества частиц. Предполагаемое распределение, по которому происходит генерация частиц, эквивалентно динамической модели, которая определяется с помощью сети Петри.

На этапе обновления фильтра в каждый момент времени происходит пересчет весов частиц. Суммирование весов этих частиц, где $x_{t(m)} \in R$, позволяет определить вероятность того, что событие было распознано.

Работу фильтра можно представить в виде следующих этапов.

Этап 1. Инициализация фильтра. Для генерации частиц используется метод сэмпирования. Соответствующие веса инициализируются как $1/N$, где N – параметр, который указывает на количество частиц. Для $i = 1 \dots N$:

$$x_0^{(i)} \sim P(x_0), w_0^N = 1/N.$$

Этап 2. Обновление фильтра. На каждом кадре t от 1 до T определяется вектор наблюдений y_t . Этот вектор принадлежит $[0,1]^{|O|}$, где каждый элемент $y_{t(i)}$ представляет вероятность наблюдения i -го события во множестве O . Для каждого кадра t выполняется алгоритм из трёх шагов:

на первом шаге происходит выборка нового множества частиц из предполагаемой вероятности, используя частицы, полученные на предыдущем кадре (этап предсказания байесовского рекурсивного фильтра). Для $i = 1 \dots N$:

$$x_t^{(i)} \sim P(x_t | x_{t-1}^{(i)}).$$

На втором шаге веса каждой частицы обновляются, используя наблюдения (этап коррекции байесовского рекурсивного фильтра). Так, для $i = 1 \dots N$

$$\hat{w}_t^{(i)} = w_{t-1}^{(i)} * P(y_t | x_t^{(i)}).$$

На третьем шаге веса нормализуются. Для $i = 1 \dots N$

$$w_t^{(i)} = \frac{\hat{w}_t^{(i)}}{\sum_i \hat{w}_t^{(i)}}.$$

Экспериментальные исследования

Для проверки работоспособности предложенной модели в качестве обучающей выборки использованы видеоролики из базы данных VIRAT Video Dataset, которые были объединены в сценарий «Парковочная стоянка». В качестве моделей для сравнения использовалась детерминистическая сеть Петри, предложенная вероятностная модель и простая детерминистическая модель STRS, предложенная в работе [12], которая работает по пороговому принципу.

В первом случае в качестве входных данных использовались вручную размеченные данные (ground truth), что соответствует ситуации «идеального» трекинга (рис. 3).




Рис. 3. Сценарий «Парковочная стоянка» («идеальный» трекинг)

Во втором случае для извлечения данных использовались реальные алгоритмы трекинга, что соответствует ситуации «реального» трекинга (рис. 4).

Результаты исследований представлены в виде ROC-кривой. Ввиду того, что в каждом тестовом видеоролике происходит небольшое количество событий, количество положительных оценок будет гораздо меньше, чем количество отрицательных. Это справедливо и применительно к реальным системам наблюдения. Поэтому при осуществлении эксперимента было важно выявить соотношение между истинно-положительной и ложноположительной оценками.




Рис. 4. Сценарий «Парковочная стоянка» («реальный» трекинг)

Количественную интерпретацию полученных результатов можно получить путем вычисления площади под ROC-кривой (чем выше показатель, тем качественней работа модели). Количественная интерпретация результатов представлена в табл. 1

1. Количественная интерпретация полученных ROC-кривых

Модель	Идеальный трекинг	Реальный трекинг
БРФ	0,91032	0,81725
сеть Петри	0,90005	0,74282
Модель STRS	0,8425	0,72270

Результаты экспериментального исследования показали, что в случае «идеального» трекинга сеть Петри и предложенная модель показывают похожие результаты. Однако при использовании реальных алгоритмов трекинга эффективность сети Петри снижается.

Это объясняется тем, что если какой-то компонент события (например, определенный объект на сцене) распознается с вероятностью ниже порогового уровня или не распознается, модели основанные на детерминистическом подходе не распознают событие. Вероятностная модель, в свою очередь, позволяет распознать событие, несмотря на возможную отсутствующую информацию.

Выводы. В данной работе была предложена модель на основе сети Петри и байесовского рекурсивного фильтра, которая позволяет сочетать достаточную выразительную мощь, присущую семантическим моделям, и механизм учета неопределенности данных, которым обладают вероятностные модели.

Изначально происходит построение сети Петри, которая представляет распознаваемые события, после чего разметка сети используется при построении динамической модели байесовского рекурсивного фильтра. Использование фильтра частиц позволяет проводить вероятностный вывод о наступлении события с учетом неопределенности данных.

Экспериментальные исследования показали, что полученная модель позволяет

улучшить качество распознавания событий по сравнению с детерминистическими моделями.

Список использованной литературы

1. Антощук С. Г. Модели представления событий при анализе видеопотока / С. Г. Антощук, Н. А. Годовиченко // *Электротехнические и компьютерные системы*. – К. : – 2013. – № 11. – С. 142 – 149.

2. Коваленко Н. В. Модель системы семантического анализа видеопотока для выявления девиантного поведения объектов интереса / Н. В. Коваленко, Н. А. Годовиченко // *Искусственный интеллект*. – Донецк : – 2012. – № 4. – С. 124 – 132.

3. Антощук С. Г. Моделирование событий в видеопотоке с помощью стохастических сетей Петри / С. Г. Антощук, Н. А. Годовиченко // *Оптико-електронні інформаційно-енергетичні технології*. Винниця :– 2013. – № 1. – С. 5 – 12.

4. Hu W., Tan T., Wang L., and Maybank S. A Survey on Visual Surveillance of Object Motion and Behaviors, (2004), *Systems, Man and Cybernetics, Part C*, No. 4, pp. 334 –352, doi: 10.1109/TSMCC.2004.829274, url : <http://vc.cs.nthu.edu.tw/home/paper/codfiles/yzchen/200812041421/A%20Survey%20on%20Visual%20Surveillance%20of%20Object%20Motion%20and%20Behaviors.pdf>.

5. Aggarwal J. K., and Cai Q. Human Motion Analysis: A Review, (1999), *Computer Vision and Image Understanding*, No. 3, pp. 428 – 440, doi:10.1006/cviu.1998.0744 url: <http://cvrc.ece.utexas.edu/aggarwaljk/Publications/Q.%20Cai,%20Human%20Motion%20Analysis%20A%20Review.pdf>.

6. Hongeng S., and Nevatia R. Multi-agent Event Recognition, (2001), *International Conference on Computer Vision*, pp. 84 – 93, doi:10.1109/ICCV.2001.937608 URL:<http://www.jianmeiauto.com/uploadfile/file/2013020222243062401.pdf>.

7. Cohn A. G., Magee D. R., Galata A., Hogg D., and Hazarika S. M. Towards an Architecture for Cognitive Vision Using Spatial-temporal Representations and Abduction, (2003), *In Spatial Cognition*, No. 2, pp. 232 – 248, doi: 10.1.1.15.1821.

8. Medioni G.G., Cohen I., Bremond F., Hongeng S., and Nevatia R. Event detection and analysis from video streams, (2001), *IEEE Transactions on Pattern Analysis and Machine Intelligence*, No. 8, pp. 873 – 889.

9. Buxton H. Generative Models for Learning and Understanding Dynamic Scene Activity, (2002), *ECCV Workshop on Generative Model Based Vision*, pp. 154 – 169, doi: 10.1.1.13.5001 url: ftp://ftp.cordis.europa.eu/pub/ist/docs/dir_e/cognition/eccv02.pdf.

10. Ghanem N., DeMenthon D., Doermann D., and Davis L. Representation and Recognition of Events in Surveillance Video Using Petri Nets, (2004), *Computer Vision and Pattern Recognition Workshop*, No. 1, pp. 112 – 132 doi:10.1109/CVPR.2004.156, url: <http://lampsrv02.umiacs.umd.edu/pubs/Papers/nghanem-04/nghanem-04.pdf>.

11. Allen F. J., and Ferguson G. Actions and Events in Interval Temporal Logic, 1994, *Journal of Logic and Computation*, No. 4(5), pp. 531 – 579, doi:10.1093/logcom/4.5.531, url: <http://web.mit.edu/larsb/Public/16.412/pset%204/allen94actions.pdf>.

12. Vu V., Bremond F., and Thonnat M. Automatic Video Interpretation: a Novel Algorithm for Temporal Scenario Recognition, (2003), *International Joint Conference on Artificial Intelligence*, No. 1, pp. 1295 – 1300 url: <http://www.sop.inria.fr/orion/Publications/Articles/ijcai2003.pdf>.

Получено 05.11.2013

References

1. Antoshchuk S.G., and Godovychenko N.A. Modeli predstavleniya sobytiy pri analize videopotoka [Events Representation Models for Videostream Analysis], (2013), *Elektrotechnic and Computer Systems*, Kiev, Ukraine, No. 11, pp. 142 – 149 (In Russian).

2. Kovalenko N.V., and Godovychenko N.A. Model' sistemy semanticheskogo analiza videopotoka dlya vyyavleniya deviantnogo povedeniya ob"ektov interesa [The Model of Video Semantic Analysis System for Objects of

Interest Deviant Behavior Detection], (2012), *Artificial Intelligence*, Donetsk, Ukraine, No. 4, pp. 124 – 132 (In Russian).

3. Antoshchuk S.G., and Godovychenko N.A. Modelirovanie sobytiy v videopotoke s pomoschyu stohasticheskikh setey Petri [Modeling Events in Videostream With Stochastic Petri Nets], (2013), *Optoelectronic Information-energy Technologies*, Vinnitsa, Ukraine, No. 1, pp. 5 – 12 (In Russian).

4. Hu W., Tan T., Wang L., and others. A Survey on Visual Surveillance of Object Motion and Behaviors, *Systems, Man and Cybernetics, Part C*, (2004), No. 4, pp. 334 – 352 (In English), doi: 10.1109/TSMCC.2004.829274, url: <http://vc.cs.nthu.edu.tw/home/paper/codfiles/yzchen/200812041421/A%20Survey%20on%20Visual%20Surveillance%20of%20Object%20Motion%20and%20Behaviors.pdf>.

5. Aggarwal J.K., and Cai Q. Human Motion Analysis: A Review, *Computer Vision and Image Understanding*, (1999), No. 3, pp. 428 – 440 (In English), doi:10.1006/cviu.1998.0744, url: <http://cvrc.ece.utexas.edu/agggarwaljk/Publications/Q.%20Cai,%20Human%20Motion%20Analysis%20A%20Review.pdf>.

6. Hongenhg S., and Nevatia R. MultiAgent Event Recognition, *International Conference on Computer Vision*, (2001), pp. 84 – 93 (In English), doi: 10.1109/ICCV.2001.937608, url: <http://www.jianmeiauto.com/uploadfile/file/2013020222243062401.pdf>.

7. Cohn A.G., Magee D.R., Galata A., and others. Towards an Architecture for Cognitive Vision Using Spatio-Temporal Representations and Abduction, *In Spatial Cognition*, (2003), No. 2, pp. 232 – 248 (In English), doi: 10.1.1.15.1821.

8. Medioni G.G., Cohen I., Bremond F., and others. Event Detection and Analysis from Video Streams, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, (2001), No. 8, pp. 873 – 889 (In English), doi: 10.1109/34.946990, url: <http://iris.usc.edu/outlines/papers/1998/iuwevent98.pdf>.

9. Buxton H. Generative Models for Learning and Understanding Dynamic Scene Activity, *ECCV Workshop on Generative Model*

Based Vision, (2002), pp. 154 – 169 (In English), doi: =10.1.1.13.5001, url: ftp://ftp.cordis.europa.eu/pub/ist/docs/dir_e/cognition/eccv02.pdf.

10. Ghanem N., DeMenthon D., Doermann D., and others. Representation and Recognition of Events in Surveillance Video Using Petri Nets, *Computer Vision and Pattern Recognition Workshop*, (2004), No. 1, pp. 112 – 132 (In English), doi: 10.1109/CVPR.2004.156, url: <http://lampsrv02.umiacs.umd.edu/pubs/Papers/nghanem-04/nghanem-04.pdf>.

11. Allen F. J., and Ferguson G. Actions and Events in Interval Temporal Logic, (1994), *Journal of Logic and Computation*, No. 4, pp. 531 – 579 (In English), doi: 10.1093/logcom/4.5.531, url: <http://web.mit.edu/larsb/Public/16.412/pset%204/allen94actions.pdf>

12. Vu V., Bremond F., and Thonnat M. Automatic Video Interpretation: a Novel Algorithm for Temporal Scenario Recognition, (2003), *International Joint Conference on Artificial Intelligence*, No. 1, pp. 1295 – 1300 (In English), url: <http://www.sop.inria.fr/orion/Publications/Articles/ijcai2003.pdf>.



Антощук
Светлана Григорьевна,
д-р техн. наук, проф.,
директор ин-та
компьютерных систем,
зав. каф. информацион-
ных систем Одесского
нац. политехн. ун-та.
Тел.: +38048-7348-584.
E-mail: asg@ics.opu.ua



Годовиченко
Николай Анатольевич,
аспирант каф. информа-
ционных систем Одес-
ского нац. политехн. ун-
та,
м/т: +3(068)2619923