

DOI:

## МОДЕЛИРОВАНИЕ ОБНАРУЖЕНИЯ И РАСПОЗНАВАНИЯ АНОМАЛЬНОГО ПОВЕДЕНИЯ ДИНАМИЧЕСКИХ СИСТЕМ<sup>1</sup>

Амосов О.С., Амосова С.Г.

*Институт проблем управления им. В.А. Трапезникова РАН,*

*Россия, г. Москва, ул. Профсоюзная д.65*

*osa18@yandex.ru, amosovasg@yandex.ru*

*Аннотация: Дана постановка задачи оценивания эмерджентных свойств системы, обнаружения и распознавания возникновения аномалий в поведении динамической системы. Для решения поставленных задач предлагается нечеткое когнитивное моделирование и набор глубоких нейронных сетей. Рассматривается пример распознавания аномалии в поведении процессов в инфраструктуре аэродрома.*

Ключевые слова: оценивание эмерджентных свойств системы, глубокая нейронная сеть, нечеткая когнитивная модель, распознавание аномальной ситуации, система безопасности аэродрома.

### Введение

Вопросам обнаружения и распознавания аномального поведения динамических систем уделено значительное внимание [1–5]. В основном работы направлены на поиск аномалий в информационных системах (сетевые атаки) [1], в системах контроля и управления доступом (пропуск объекта на территорию) [2], в промышленных системах (поломка оборудования, поиск отказов) [3], в дорожно-транспортных, поисковых системах [4, 5].

Под аномальным поведением системы понимается ее функционирование, отличающееся от нормального, штатного. Важность обнаружения аномалий обусловлена обеспечением, в первую очередь, безопасности людей, а затем оборудования и технических систем.

Становится актуальной необходимость разработки методов, способных на основе анализа поведения наблюдаемого процесса обнаруживать, распознавать и прогнозировать возникновение нештатных ситуаций в динамических системах. Ситуации могут быть как штатные, так и нештатные (аномальные), которые имеют определенные последствия на поведение процесса.

Стоит отметить, что нештатные ситуации могут очень сильно различаться по своей природе: отсутствие средств индивидуальной защиты при работе на высоте; отсутствие человека на рабочем месте; неправильная технология клепания; прорыв трубопровода; возгорание на производстве; наличие людей, транспорта на взлётно-посадочной полосе (ВПП) аэродрома, разлив топлива и так далее.

В настоящее время существует много методов и алгоритмов для выявления аномального поведения системы, например, такие как: метод опорных векторов, при котором возможно задать границу отсека для аномальных данных; метод изолирующего леса (Isolate forest), т.е. аномальные значения (выбросы) попадают в листья на ранних этапах, которые проще «изолировать»; статистические методы – построение распределения данных с выявлением выбросов и аномальных значений; метрические методы – нормальные значения расположены в заданной области многомерного пространства, и дистанция до аномалий будет больше, чем до разделяющей гиперплоскости; кластерные методы – значение удалено от центров кластеров более чем на определенную величину, значение можно считать аномальным; методы главных компонент; современные методы классификации и регрессии на основе искусственных нейронных сетей (НС) [6].

Для описания ситуаций с выделением взаимосвязей и зависимостей между факторами применяется когнитивное моделирование. Когнитивное моделирование становится все более популярным подходом в авиационной, военной и перерабатывающей промышленности за его вычислительную мощность для моделирования обработки информации и визуализацию. Например, в [7] разработана модель для вероятностного прогнозирования реакции экипажа АЭС на работу в аварийных условиях. Спектр реакции оператора включает когнитивные, психологические и физические действия в ходе аварии.

В данной статье для моделирования обнаружения и распознавания аномального поведения динамических систем с помощью видеонаблюдения предлагается использование глубоких нейронных сетей для оценивания состояния системы, ее эмерджентных свойств и классификации ситуаций. Для

---

<sup>1</sup> Данный файл удовлетворяет всем перечисленным требованиям

объяснимости решений и подготовки обучающих множеств предлагается создание нечеткой когнитивной модели системы и аннотирование наблюдаемых сцен видеопотока.

## 1 Постановка задачи обнаружения и распознавания аномальных ситуаций в поведении динамической системы

Рассматривается стохастическая система  $S$ , поведение которой можно классифицировать как нормальное или аномальное. Введем конечное множество  $\mathbf{B} = \{\beta_1, \dots, \beta_\mu, \dots, \beta_\eta\}$ , содержащее  $\eta$  классов ситуаций. Его элементами являются класс штатных ситуаций, характеризующий нормальный режим работы системы и несколько классов нештатных ситуаций, характеризующих аномальное поведение системы.

Текущее состояние системы отвечает текущей ситуации  $Q_j$ , которая превращается в новую ситуацию  $Q_l$  при воздействии управления  $\mathbf{u}_k$  и/или возмущения  $\mathbf{w}_k$  на систему.

Пусть задан недоступный непосредственному наблюдению  $n$ -мерный случайный процесс с дискретным временем, характеризующий состояние динамической системы  $S$   $\mathbf{x}_i = [x_{i1}, \dots, x_{in}]^T, i = 0, 1, \dots$ . В распоряжении имеются связанные с  $\mathbf{x}_i$  значения  $m$ -мерного случайного процесса измерений с дискретным временем  $\mathbf{y}_j = [y_{1j}, \dots, y_{mj}]^T, j = \overline{1, k}$ . Считаем, что эмерджентные свойства системы  $S$  характеризуются известной функцией  $\varphi(\mathbf{X}_i)$  от составного вектора состояния  $\mathbf{X}_i = [\mathbf{x}_1^T, \dots, \mathbf{x}_{i-1}^T, \mathbf{x}_i^T]^T$ .

Требуется:

1) Найти оценку  $\varphi(\mathbf{X}_i)$  для некоторого заданного момента времени  $i$ , вычисляемую с использованием набора измерений, задаваемого составным вектором  $\mathbf{Y}_k = [\mathbf{y}_1^T, \dots, \mathbf{y}_{k-1}^T, \mathbf{y}_k^T]^T$  размерности  $k \cdot m$ . Обозначим оценку  $\varphi(\mathbf{X}_i)$ , полученную на основе измерений  $\mathbf{Y}_k$ , через  $\tilde{\varphi}(\mathbf{X}_{i/k})$  и определим ее как  $q$ -мерную вектор-функцию измерений [8, 9]:

$$(1) \quad \tilde{\varphi}(\mathbf{X}_{i/k}) = \mathbf{h}_i(\mathbf{Y}_k).$$

Заметим, что функция  $\varphi(\mathbf{x}_i)$  в частном случае может представлять собой сам вектор состояния  $\mathbf{x}_i$ :  $\varphi(\mathbf{x}_i) = \mathbf{x}_i$ .

В рамках традиционного байесовского подхода отыскиваемая оценка  $\tilde{\varphi}(\mathbf{X}_{i/k})$  минимизирует критерий [8, 9]:

$$(2) \quad J_{i/k} = M \|\varphi(\mathbf{X}_i) - \tilde{\varphi}(\mathbf{X}_{i/k})\|^2,$$

где  $M$  – знак математического ожидания.

2) Классифицировать состояние динамической системы, соответствующей штатной или нештатной ситуации из множества  $\mathbf{B}$ , с использованием отображения  $\mathbf{F}_2: \tilde{\varphi}(\mathbf{X}_{i/k}) \rightarrow \beta_\mu, \mu = \overline{1, \eta}$ , в соответствии с заданным критерием  $\mathbf{p}(\tilde{\varphi}(\mathbf{X}_{i/k}))$ , минимизирующим вероятность ошибки классификации.

В качестве дополнительных знаний (ограничений) могут быть использованы, при наличии, уравнения динамики системы и уравнения измерений.

## 2 Решение задачи обнаружения и распознавания аномального поведения динамической системы

Ограничимся классом динамических систем, в которых измерения поступают только с камер видеонаблюдения. Определим для такой задачи вектора состояний и измерений, представленные в разделе 1, и обучающие множества для нейронных сетей.

Для момента времени  $i$  система будет представлять собой множество взаимосвязанных объектов  $\omega \in \Omega$ , каждый из которых определяется вектором признаков  $\mathbf{x}_{pi} = [x_{pi}(\omega), \dots, x_{pi}(\omega)]^T, i = 0, 1, \dots$ . Признаки в явном виде задать сложно, но их можно извлечь из двумерного изображения объекта с помощью нейронной сети. Тогда динамика системы из  $n$ -объектов определяется вектором состояния  $\mathbf{x}_i = [\mathbf{x}_{i1}^T, \dots, \mathbf{x}_{in}^T]^T, i = 0, 1, \dots$ .

В случае камер видеонаблюдения в качестве вектора измерений  $\mathbf{y}_j$  в момент времени  $j$ ,  $j = \overline{1, k}$  будут использоваться кадры  $\mathbf{I}_j$ ,  $\mathbf{y}_j = \mathbf{I}_j$  непрерывного видеопотока  $\mathbf{V}_k = [\mathbf{I}_1, \dots, \mathbf{I}_{k-1}, \mathbf{I}_k]$ . При этом составной вектор измерений  $\mathbf{Y}_k = \mathbf{V}_k$ .

Для обучения нейронной сети априорная информация об объекте  $\omega \in \Omega$  представлена обучающим множеством (датасетом)  $D_\omega = \{(\mathbf{I}_\omega^j, \beta_\mu^j)\}, j = \overline{1, L_\omega}$ , заданным таблицей, каждая строка  $j$  которой содержит матричное описание (2D изображение) образа  $\omega \in \Omega$  и метку класса, к которому принадлежит объект  $\beta_{\omega\mu}$ ,  $\mu = \overline{1, \mu_\omega}$ . Априорная информация о ситуациях  $Q \in \Omega_Q$  представлена обучающим множеством (датасетом)  $D_Q = \{(\mathbf{I}_Q^j, \beta_\mu^j)\}, j = \overline{1, L_Q}$ , заданным таблицей, каждая строка  $j$  которой содержит тензорное описание (совокупность 2D изображений) ситуации  $Q \in \Omega_Q$  и метку класса, к которому принадлежит ситуация  $\beta_{Q\mu}$ ,  $\mu = \overline{1, \mu_Q}$ .

Предлагаемый для решения подход состоит из следующих этапов:

1. Синтез когнитивной модели системы для создания множества классов ситуаций  $\mathbf{V} = \{\beta_{Q1}, \dots, \beta_{Q\mu}, \dots, \beta_{Q\mu_Q}\}$  ( $\mu_Q$  – количество классов ситуаций) и их описания. На этом этапе разрабатывается когнитивная карта системы в целом. Для этого выявляется группа факторов, влияющих на эмерджентные свойства системы, приводящих к аномальным ситуациям. Этап завершается созданием базы знаний об объектах и ситуациях, двух датасетов:  $D_\omega = \{(\mathbf{I}_\omega^j, \beta_\mu^j)\}, j = \overline{1, L_\omega}$ ,  $\mu = \overline{1, \mu_\omega}$  и  $D_Q = \{(\mathbf{I}_Q^j, \beta_\mu^j)\}, j = \overline{1, L_Q}$ ,  $\mu = \overline{1, \mu_Q}$  для обучения нейронных сетей.
2. Строится когнитивный образ ситуаций в виде лепестковой диаграммы, которая отражает эволюцию ситуации во времени. Ее коэффициенты постоянно обновляются и отражают степень изменения факторов ситуации.
3. Оценивание эмерджентных свойств динамической системы и признаков ситуаций  $\tilde{\varphi}(\mathbf{X}_{i/k})$  с использованием современных нейросетевых методов.

Решается задача видеонаблюдения и анализа текущей ситуации по имеющимся кадрам  $\mathbf{y}_j = \mathbf{I}_j$  непрерывного видеопотока  $\mathbf{Y}_k = \mathbf{V}_k$  и априорной информации  $D_\omega$  и  $D_Q$  для глубокого обучения НС с учителем. Дается оценка признаков  $\tilde{\mathbf{x}}_i$  объектов  $\omega$  и признаков  $\tilde{\varphi}(\mathbf{X}_i)$  ситуаций  $Q$  с помощью НС, реализующих отображения  $\mathbf{F}_{1\omega} : \mathbf{I}_j \rightarrow \tilde{\mathbf{x}}_i$  и  $\mathbf{F}_{1Q} : \mathbf{Y}_k \rightarrow \tilde{\varphi}(\mathbf{X}_i)$ .

4. Производится классификация текущей ситуации с использованием отображения  $\mathbf{F}_2 : \tilde{\varphi}(\mathbf{X}_i) \rightarrow \beta_{Q\mu}$ ,  $\mu = \overline{1, \mu_Q}$  в соответствии с заданным критерием  $\mathbf{p}(\tilde{\varphi}(\mathbf{X}_i))$ , минимизирующим вероятность ошибки классификации.

5. Для подкрепления классификации ситуаций производится аннотирование сцен видеопотока.

### 3 Иллюстрирующий пример для системы безопасности на аэродроме

Задача контроля безопасности аэродрома является наиболее важной для сохранения жизни людей и инфраструктуры аэродрома.

Для создания когнитивной модели ситуаций опишем основные факторы, влияющие на состояние безопасности и степень готовности инфраструктуры на аэродроме (табл. 1).

Таблица 1. Основные факторы, влияющие на степень готовности инфраструктуры аэродрома С<sub>5</sub>

Факторы	Ситуации	Причины возникновения
С <sub>1</sub> Человеческий	<ul style="list-style-type: none"> <li>– несанкционированное появление людей на ВПП;</li> <li>– ситуации из-за недостаточной квалификации персонала;</li> <li>– розлив топлива;</li> <li>– пожар.</li> </ul>	<ul style="list-style-type: none"> <li>– нарушение правил передвижения людей по ВПП;</li> <li>– невнимательность диспетчера;</li> <li>– невыполнение должностных инструкций, нарушение правил;</li> <li>– поджог;</li> <li>– халатность.</li> </ul>
С <sub>2</sub> Технико-механический	<ul style="list-style-type: none"> <li>– наличие транспортных средств на ВПП;</li> <li>– наличие дронов;</li> <li>– возможность столкновения транспортных средств или транспортного средства со вспомогательным оборудованием ВПП или на стоянке;</li> <li>– возможность столкновения воздушного судна с транспортным средством или другим наземным оборудованием на ВПП и стоянке;</li> <li>– ненадлежащее освещение вдоль рулежной дорожки.</li> </ul>	<ul style="list-style-type: none"> <li>– нарушение правил вождения транспортных средств в контролируемой зоне, повлекшее возникновение опасности для воздушного судна;</li> <li>– отказ навигационных / посадочных средств ВПП;</li> <li>– отказ системы светосигнального оборудования ВПП;</li> <li>– слишком большая загруженность аэропортов;</li> <li>– не соответствующее ситуации координирование экипажей диспетчерами;</li> <li>– строительные работы.</li> </ul>
С <sub>3</sub> Животный и растительный	<ul style="list-style-type: none"> <li>– опасное скопление птиц над ВПП;</li> <li>– наличие любых диких животных в зоне выполнения полетов;</li> <li>– сухая трава;</li> <li>– загущенная растительность.</li> </ul>	<ul style="list-style-type: none"> <li>– не эффективное использование биоакустических установок;</li> <li>– не проводятся мероприятия по устранению мест скопления птиц и зверей;</li> <li>– нет в наличии отпугивающих средств;</li> <li>– несвоевременная обработка растительности аэродрома.</li> </ul>
С <sub>4</sub> Природные	<ul style="list-style-type: none"> <li>– пожар;</li> <li>– обледенение;</li> <li>– снег;</li> <li>– ограниченная видимость или туман;</li> <li>– сильный дождь (ВПП покрыта слоем воды или скользкая от дождя);</li> <li>– постоянный или порывистый боковой, или попутный ветер.</li> </ul>	<ul style="list-style-type: none"> <li>– гроза;</li> <li>– низкие температуры (ВПП покрыта слоем слякоти или льда);</li> <li>– не учитываются климатические условия.</li> </ul>

Для определения типа ситуации экспертным путем сформирована когнитивная модель ситуаций, которая отражает штатные и нештатные ситуации. По выделенным основным факторам на основании экспертных оценок строится когнитивная карта ситуации в целом для мониторинга глобальных показателей безопасности аэродрома (рис. 1,а).

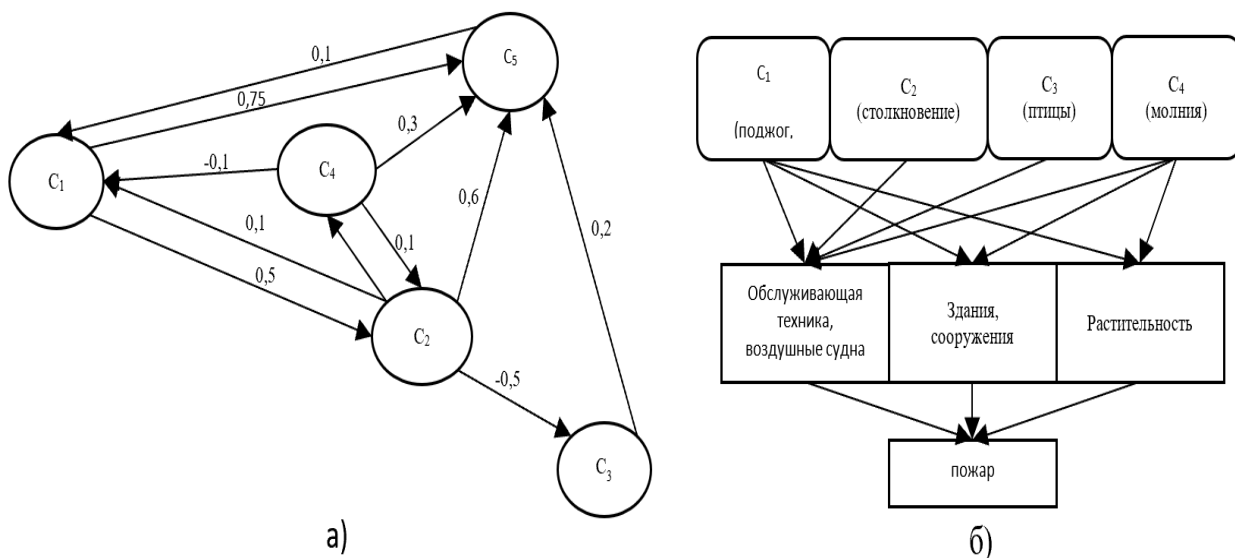


Рис. 1. Когнитивные карты: а) степень готовности инфраструктуры аэродрома; б) влияние факторов на возгорание

Когнитивная карта ситуации представлена ориентированным знаковым графом, в котором вершинами являются (входные и выходные переменные) основные факторы, а дугами между факторами – причинно-следственные связи (сила влияния), отражающие основные закономерности наблюдаемой ситуации. В когнитивной модели выделяют два типа причинно-следственных связей: положительные и отрицательные. При положительной связи увеличение значения фактора-причины приводит к увеличению значения фактора-следствия, а при отрицательной связи увеличение значения фактора-причины приводит к уменьшению значения фактора-следствия. На рис. 1,б построена когнитивная карта, которая отражает класс ситуации и уровень связи между факторами при пожаре.

Выделенным основным факторам соответствуют входные лингвистические переменные  $C_1$  – «Человеческий»,  $C_2$  – «Технико-механический»,  $C_3$  – «Животный, растительный»,  $C_4$  – «Природный» и выходные  $C_5$  – «Степень готовности», которые характеризуются нечеткими множествами с функциями принадлежности  $\mu_{\text{очень сильное}}(C_i)$ ,  $\mu_{\text{сильное}}(C_i)$ ,  $\mu_{\text{среднее}}(C_i)$ ,  $\mu_{\text{слабое}}(C_i)$  и принимают отрицательное или положительное значение в диапазоне от  $[-1, 1]$ . Связи между факторами состоят из набора нечетких «If-then» правил.

Построен когнитивный образ ситуации в виде лепестковой диаграммы (рис. 2), который возможно использовать на диспетчерских пунктах «Руления», «Старта» и «Посадки». Когнитивный образ ситуации необходим для поддержки принятия решений и ориентирован на то, чтобы помочь активизировать внимание оператора и выделить проблемные факторы ситуации.




Рис. 2. Когнитивный образ ситуации

Экспертные оценки для когнитивной карты и лепестковой диаграммы определены на шкалах:  $\{-1$  (отрицательное очень сильное),  $-0.75$  (отрицательное сильное),  $-0.5$  (отрицательное среднее),  $-0.25$  (отрицательное слабое),  $0$  (отсутствует),  $0.25$  (положительное слабое),  $0.5$  (положительное среднее),  $0.75$  (положительное сильное),  $1$  (положительное очень сильное) $\}$ , что соответствует термам нечеткой логики «очень сильное», «сильное», «среднее», «слабое».

Для обновления коэффициентов лепестковой диаграммы используется динамическая нечеткая когнитивная модель, генерируемая в соответствии с алгоритмом, предложенным в [10]. С помощью этого алгоритма определяются регрессионные зависимости между факторами и выявляются качественные факторы, от которых зависит развитие ситуации.

Нами для компьютерного моделирования нештатной ситуации на аэродроме, имевшее место в аэропорту Шереметьево в мае 2019 г. [11], использовалось предложенное в работах [12, 13] программное обеспечение на языке Python 3.5 [14] для систем контроля и управления доступом.

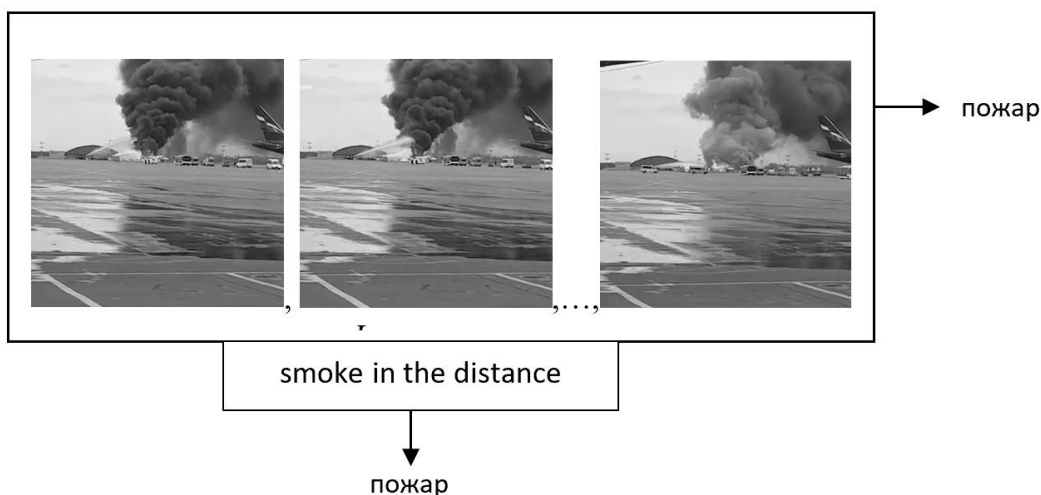
Для оценивания эмерджентных свойств наблюдаемой сцены и выделения ее признаков используется предобученная сверточная НС Inception v3 [15]. На последнем слое подвыборки операцией GlobalAveragePooling получается оценка каждого кадра, которая представляет собой вектор-столбец размером  $2048 \times 1$ . Признаковое описание видеофрагмента получается за счет операции конкатенации (склеивания) оценок всех кадров в виде матрицы размером  $690 \times 2048$ , столбцами которой являются оценки признаков для всех кадров видеофрагмента.

Множество классов ситуаций **В** сформировано нами из видеофрагментов штатных и нештатных ситуаций продолжительностью от 7 до 900 с. Видеофрагменты отбирались в соответствии с построенными когнитивными картами ситуаций, распределенных на классы. Выбраны видеоролики с проявлением всех качественных факторов и объектов, определенных когнитивными картами ситуаций.

Классификатор ситуаций построен на основе глубоких НС из двух частей с независимыми входами [12]: 1) левая часть с независимыми рекуррентными слоями IndRNN [16] с функцией активации ReLU. 2) правая часть состоит из слоя подвыборки с операцией GlobalMaxPooling и полносвязного слоя с функцией активации ReLU.

Далее части объединяются слоем конкатенации и двумя последовательно идущими полносвязными слоями с функциями активации ReLU и Softmax соответственно. Результатом классификатора является вектор вероятностей  $\mathbf{p}(\tilde{\varphi}(\mathbf{X}_i))$ .

Для подкрепления классификации предлагается автоматическая аннотация кадра, построенная с использованием глубокой нейронной сети из слоев полносвязных, встраивания и IndRNN [12]. Для ее обучения применен датасет MS COCO [17], доработанный, как указано в [12]. Результаты классификации и аннотирования сцен видеопотока представлены на рис. 3.



*Рис. 3. Классификация и аннотирование видеофрагмента*

На рис. 3 приведен пример возгорания двигателя самолета [11]. Результатом работы подкрепления является увеличение вероятностной оценки классификации или вывод об ошибке работы алгоритма, если ни один из элементов вектора  $\mathbf{p}(\tilde{\varphi}(\mathbf{X}_i))$  так и не превысил порога 0.7. При выполнении алгоритма подкрепления итоговая точность алгоритма ( $M^{AC}$ , Accuracy) обнаружения и распознавания штатных и нештатных ситуаций достигла 80%.

Моделирование проводилось в среде Python на следующей конфигурации ПК: ЦПУ Intel Core i5-9600KF, ГПУ GeForce 1080 Ti. Время классификации видеофрагмента в 18 с (414 кадров) составило 0.5 с. Время аннотации одного кадра составило 0.015 с.

Авторы выражают благодарность младшему научному сотруднику Жиганову С.В. за оказанную помощь при проведении численных экспериментов с глубокими нейронными сетями для иллюстрирующего примера.

## Заключение

Дана постановка задачи оценивания эмерджентных свойств системы, обнаружения и распознавания возникновения аномалий в поведении динамической системы.

Для решения задачи оценивания состояния системы, ее эмерджентных свойств и классификации ситуаций предложен подход, состоящий из 5 этапов. Его особенностью является использование набора глубоких нейронных сетей со сверточными и рекуррентными слоями для поиска, выделения и оценки признаков объектов, выявления закономерностей в последовательности векторов признаков кадров видеопотока для классификации ситуаций.

Для объяснимости решений и подготовки обучающих множеств предложено создание нечеткой когнитивной модели системы и аннотирование наблюдаемых сцен видеопотока с помощью глубокой НС со сверточными и рекуррентными слоями.

Рассмотрен пример когнитивного моделирования аномалий в поведении процессов в инфраструктуре аэродрома. Рассмотрен пример распознавания пожара по видеоролику возгорания двигателя самолета на аэродроме Шереметьево в мае 2019 г. после экстренной посадки.

Компьютерный эксперимент показал эффективность и возможность применения предлагаемого подхода для распознавания нештатных ситуаций в режиме реального времени.

## Литература

1. Song X., Wu M., Jermaine C., Ranka S. Conditional Anomaly Detection // IEEE Transactions on Knowledge and Data Engineering. Vol. 19. 2007, № 5. – P. 631-645.
2. Амосов О.С., Баена С.Г., Иванов Ю.С., Со Х. Система автоматического управления шлагбаумом с использованием технологий нечеткого вывода и компьютерного зрения // Интернет-журнал Науковедение. 2017. Т. 9. № 1. – С. 42.
3. Акимов Н.Н., Андриянычева С.Б., Анисимов А.И., Бухвалов И.Р., Евсеев С.В., Лотов В.Н. Способ обнаружения нештатной ситуации на многониточном магистральном трубопроводе /ФГУП «РФЯЦ-ВНИИЭФ», Патент на изобретение RU 2700491 С1, от 17.09.2019 Бюл. № 26.

4. Попович В.В., Прокаев А.Н., Сорокин Р.П., Смирнова О.В. О распознавании ситуации на основе технологии искусственного интеллекта // Тр. СПИИРАН. 2008. №7. – С. 93-104.
5. Чиров Д.С., Хрипунов С.П. Интеллектуальные методы распознавания тактических ситуаций в условиях автономного применения робототехнических комплексов военного назначения // Вопросы безопасности. 2017. № 1. – С. 22-34.
6. Гаранин О.И. Методы и алгоритмы анализа статических и динамических зрительных сцен на основе сверточных нейронных сетей: дис. ... канд. тех. наук: 05.13.01 / Гаранин Олег Игоревич. - М., 2019. - 131 с. - Библиогр.: с.132-144.
7. Chang Y. H. J., Mosleh A. Cognitive modeling and dynamic probabilistic simulation of operating crew response to complex system accidents - Part 1: Overview of the IDAC Model // Reliability Engineering and System Safety. 92(8). 2007. – P. 997-1013.
8. Амосов О.С., Амосова Л.Н., Магола Д.С. Оценивание случайных последовательностей с использованием регрессии и вейвлетов // Информатика и системы управления. 2009. № 3 (21). С. 101-109.
9. Stepanov O.A., Amosov O.S. The Comparison of the Monte-Carlo Method and Neural Networks Algorithms in Nonlinear Estimation Problems // В сборнике: IFAC Proceedings Volumes (IFAC-PapersOnline) 9th IFAC Workshop "Adaptation and Learning in Control and Signal Processing", ALCOSP'2007. Сеп. "9th IFAC Workshop "Adaptation and Learning in Control and Signal Processing", ALCOSP'2007 - Final Program and Abstracts" sponsors: IFAC-TC on Adaptive and Learning Systems, Russian National Committee on Automatic Control (RNKAU), Saint Petersburg Regional Group of RNKAU, (Russ. Acad. Sci.) Inst. Probl. Mech. Eng., Saint Petersburg State University. Saint Petersburg, 2007. С. 392-397.
10. Curia L., Lavalle A. Decision Strategies in Dynamic Systems Using Fuzzy Cognitive Maps. Application to a Socio-Economic Example // Journal of Information Systems and Technology Management. Vol. 8. 2011, № 3. – P. 663-680.
11. Видеоролик новости телеканала Москва 24 [электронный ресурс] URL: <https://youtu.be/e11LbTuj01o> (дата обращения: 26.04.2020).
12. Амосов О.С., Амосова С.Г., Жиганов С.В., Иванов Ю.С., Пащенко Ф.Ф. Вычислительный метод распознавания ситуаций и объектов в кадрах непрерывного видеопотока с использованием глубоких нейронных сетей для систем контроля и управления доступом // Изв. РАН. ТиСУ. 2020. № 5.
13. Amosov O. S., Amosova S.G., Ivanov Y.S., Zhiganov S.V. Using the ensemble of deep neural networks for normal and abnormal situations detection and recognition in the continuous video stream of the security system // XIIIth International Symposium «Intelligent Systems» (INTELS'18). St. Petersburg, Russia. 2018. Procedia Computer Science, 2019, Vol. 150. – P. 532–539.
14. Амосов О.С., Иванов Ю.С., Амосова С.Г., Жиганов С.В. Программа для классификации и аннотирования ситуаций в непрерывном видеопотоке / Свидетельство о регистрации программы для ЭВМ RU 2019610487, 11.01.2019. Заявка № 2018665291 от 24.12.2018.
15. Szegedy C., Vanhoucke V., Ioffe S., Shlens J., Wojna Z. Rethinking the Inception Architecture for Computer Vision // IEEE Conf. on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA. 2016. – P. 2818-2826.
16. Li S., Li W., Cook C., Zhu C., Gao Y. Independently Recurrent Neural Network (IndRNN): Building A Longer and Deeper RNN // IEEE Conf. on Computer Vision and Pattern Recognition (CVPR). Salt Lake City, Utah, USA. 2018. – P. 5457-5466.
17. COCO dataset [электронный ресурс] URL: <http://mscoco.org/> (дата обращения: 10.01.2020).