

Программные системы: теория и приложения

Двуязычный электронный научный журнал

№4  2024

Bilingual Online Scientific Journal

Program Systems: Theory and Applications

Том 15 Выпуск 4(63) 2024 г.

СОДЕРЖАНИЕ

Научная статья Программное и аппаратное обеспечение распределенных и суперкомпьютерных систем

СТЕЦЮРА Г. Г.[✉]. Синхронное взаимодействие распределенных неупорядоченных цифровых объектов 3–24, 25–26

Научная статья Методы оптимизации и теория управления

РАСИНА И. В.[✉], БЛИНОВ А. О.. Об одном способе поиска оптимального управления в неоднородной дискретной системе с запаздыванием по состоянию процессов 27–39, 40–41

Научная статья Методы оптимизации и теория управления

РАСИНА И. В.[✉], ГУСЕВА И. С.. Эвристический алгоритм для одной нелинейной задачи оптимального управления 43–52, 53–54

Научная статья Математическое моделирование

СТЕПАНОВ Д. Н.[✉], ТИЩЕНКО И. П.. Математическое моделирование с учётом ограничений и исследование оптимальной конфигурации оптической стереосистемы, состоящей из двух плоских зеркал и видеокамеры 55–73, 74–77

Научная статья Искусственный интеллект и машинное обучение

СМИРНОВ А. В.[✉], ПАРФЕНОВ Д. Д., ТИЩЕНКО И. П.. Нейросетевая классификация видеороликов по малому числу кадров ... 79–93, 94–96

Научная статья Программное и аппаратное обеспечение распределенных и суперкомпьютерных систем

БАГИРОВ Э.[✉]. Построение надёжной системы обнаружения вредоносного ПО с использованием генеративных состязательных сетей для увеличения данных (Англ.) 97–109, 110–110

Обзорная статья Искусственный интеллект и машинное обучение

ГРИЦЕНКО Г. Г.[✉], ФРАЛЕНКО В. П.. Аналитический обзор архитектур, моделей, методов и алгоритмов для локализации и трекинга негибких объектов 111–144, 145–151

Научная статья Медицинская информатика

СЕРДЮК Ю. П.[✉], ВЛАСОВА Н. А., МОМОТ С. Р.. Извлечение симптомов и автоматическое предсказание диагноза по медицинским клиническим записям 153–178, 179–181

Авторский указатель 185

Click the flag at a top corner of any page to switch the language, please!

Author index 187

Contents 189



Синхронное взаимодействие распределенных неупорядоченных цифровых объектов

Геннадий Георгиевич **Стецюра** 

Институт проблем управления имени В. А. Трапезникова РАН, Москва, Россия

 gstetsura@mail.ru

Аннотация. Предложены методы быстрой синхронизации взаимодействия неупорядоченных активных распределенных цифровых объектов, объединенных в группы. Неупорядоченные объекты (не использующие адреса или другие индивидуальные признаки) заменяют обращение к отдельным объектам по адресам обращением к кластерам объектов с указанием общих для таких объектов наборов признаков. Любому количеству объектов доступен одновременный обмен сигналами и сообщениями с любым количеством объектов. Перевод объектов в синхронное состояние выполняется однократно, посылкой объектами единственного сигнала синхронизации, и затем поддерживается в течение заданного времени. Основной вид связей между объектами – беспроводные каналы, с передачей по ним оптических или радиосигналов. Нарушение синхронизации объекты восстанавливают собственными действиями. Объекты могут быть стационарными и мобильными. Основные особенности структуры связей объектов – одновременная видимость состояния всех объектов любым объектом группы и одновременная доставка на вход любого объекта сообщений группы объектов с побитной синхронизацией.

Ключевые слова и фразы: реактивность, однократная синхронизация, распределенное управление, распределенная обратная связь, неупорядоченные цифровые объекты, безадресные операции, ассоциативное взаимодействие

Для цитирования: Стецюра Г. Г. *Синхронное взаимодействие распределенных неупорядоченных цифровых объектов* // Программные системы: теория и приложения. 2024. Т. 15. № 4(63). С. 3–26. https://psta.psir.ru/read/psta2024_4_3-26.pdf

Введение

В статье рассмотрено взаимодействие объединенных в группы цифровых объектов. Объекты неупорядоченные (не используют адреса) и взаимодействуют с указанием признаков, характерных для объекта или кластера объектов; требуют быстрой реакции на незапланированные события с одновременным совместным синхронным ответом на них всей группы объектов.

Такие характеристики востребованы в распределенных управляющих системах и тех вычислительных системах, где по характеру задачи отдельная операция выполняется с одновременным обращением к множеству объектов, выделяемому по их состоянию в текущий момент – частично для задач типа Dataflow, задач ассоциативного взаимодействия и многих других задач, применяющих эвристику. Отказ от применения адресов естественен также для взаимодействия простых устройств – датчиков, исполнительных механизмов, если их состав переменный и требуется получать сведения не о состоянии устройства, а о состоянии неизвестного в текущий момент места его расположения. Характерная для указанных выше задач непредвиденность очередных шагов процесса обработки данных и недопустимость его задержки – основные их отличия от чисто вычислительных задач, и в статье учтена внесением существенных изменений в структуры взаимодействия объектов и в способы управления взаимодействием объектов.

В статье рассмотрены два вида синхронизации – одноканальная синхронизация (ОС) и периодическая синхронизация (ПС). В ОС перевод объектов в синхронное состояние выполняется однократно, посылкой объектами единственного сигнала синхронизации, что существенно ускоряет переход группы асинхронных объектов в синхронное состояние.

Выполнение ОС запускает ПС, которая поддерживается в интервале времени, достаточном для выполнения небольших фрагментов задачи с последующим перезапуском ПС с помощью ОС. Сочетание двух видов синхронизации позволяет объектам уменьшить затраты времени на переход в синхронное состояние, сохранять синхронность и не нарушать ее при входе новых объектов в действующую систему.

В статье также приведены способы выполнения в системе распределенных групповых операций, позволяющих неупорядоченным объектам одновременно оценить и изменить состояние всей группы объектов (в указанных выше областях часто требуется взаимодействовать не с отдельными объектами, а с группой в целом).

Ранее автором в статьях [1, 2] были предложены методы быстрой синхронизации взаимодействия в группах объектов, но в них объекты в отличие от новой статьи упорядочены. В [1] структура связей объектов

неоднородна – добавлены специальные объекты-ретрансляторы сигналов, через которые обмениваются сигналами объекты группы. Для достижения высокой точности синхронизации объекты стационарные.

В [2] объекты упорядочены, как и в [1], но структура связей однородна – объекты обмениваются сигналами по прямым связям между собой без ретрансляторов. Структура связей намного проще, объекты могут быть мобильными, но точность синхронизации ниже.

В предлагаемой статье решения статей [1, 2] взяты за основу, но область применения решений расширена включением неупорядоченных объектов, что потребовало изменить способы взаимодействия объектов. Из [1] взята приведенная ниже на рисунке 1 структура связей, в которой каждый объект одновременно взаимодействует со всеми объектами, и во время передачи сообщений их содержание обрабатывается без задержки в простых средствах взаимодействия объектов без привлечения компьютеров. Время такой обработки для приведенных ниже операций не зависит от количества участвующих в ней объектов (см. раздел 6). Участие сетевых средств в обработке данных – основная причина желательного ограничения расстояний между объектами.

Предыдущий абзац объясняет, почему в статье вместо обычного термина «связь» используется «взаимодействие» – в процессе передачи сообщений данные в них обрабатываются.

В основной структуре связей (см. рисунок 1) гибко повышена отказоустойчивость – для устранения одновременных m отказов в каналах связи между любыми объектами достаточно в любом месте структуры иметь только m резервных каналов, так как структура позволяет в микросекундном диапазоне изменить все связи объектов.

Требуемые в статье технические средства известны, взяты из авторитетных публикаций в Интернете, подтверждены в них экспериментально, возможность получения высокой точности синхронизации подтверждает международный стандарт [6, 8]. Несколько необычно, что требуемые в статье технические средства используются во многих областях, но не обнаружено их применение в области компьютеринга.

В разделе 1 статьи приведена структура связей в группе объектов и процесс однократной синхронизации объектов; в разделе 2 приведены способы расширения набора средств синхронизации объектов; в разделе 3 – формирование команд управления группой объектов; в разделе 4 – периодическая синхронизация; в разделе 5 – синхронизация воздействия объектов на внешнюю среду, синхронизация объектов в однородных системах, синхронное взаимодействие простых неупорядоченных объектов; в разделе 6 рассмотрены распределенные групповые операции; в разделе 7 дан пример многоэтапного взаимодействия неупорядоченных

объектов; в разделе 8 рассмотрено отрицательное влияние закона Амдала на выполнение безадресного взаимодействия объектов и его уменьшение применением разработанных в статье способов взаимодействия объектов.

1. Структура связей в группе неупорядоченных объектов, процесс одноканальной синхронизации

1.1. Структура связей в группе объектов

В качестве основной структуры связей выбрана дающая наиболее точную синхронизацию неоднородная структура связей в группе объектов, показанная на рисунке 1.

В структуре каждый объект может одновременно получить двоичные сообщения о состоянии любого набора включенных в структуру объектов с побитной синхронизацией сообщений. Объекты объединяются через ретрансляторы сигналов, не содержащие логические элементы. Каждый ретранслятор одновременно объединяет произвольное количество объектов источников и приемников сообщений.

Для получения наибольшей точности синхронизации и, как следствие, повышения скорости взаимодействия объектов неоднородная структура содержит только стационарные объекты, и ретрансляторы, обменивающиеся оптическими сигналами. В отличие от объектов ретрансляторы упорядочены.

Для взаимодействия объекты посылают сигналы ретранслятору и получают от него сигналы, отличающиеся по частоте от отправленных к ретранслятору. Количество ретрансляторов может отличаться от количества объектов.

На рисунке 1 каждый объект O это компьютер или физический объект, содержащий компьютер. Здесь O_i и O_k два произвольных объекта




Рисунок 1. Структура взаимодействия объектов в сети ЖРВ

из N объектов структуры, RT_h и RT_q – произвольные ретрансляторы из группы ретрансляторов RT . (Далее, по возможности, будем опускать нижние индексы в обозначении ретранслятора из группы RT .)

Каждый объект может выполнять совместно функции объекта-источника (Os) и объекта-приемника (Or) оптических сигналов. В Os и Or имеются передатчик Ts и приемник Rs оптических сигналов. Если объект действует как Os , то его Ts передает в RT сигналы сообщения. Необязательно, но допускается возврат сигналов из RT в Rs данного Os . Если объект действует как Or , то его Ts передает в RT непрерывный сигнал, который RT возвратит в Rs модулированным сигналами источника, пославшего сообщение в RT .

Функции взаимодействия объектов достаточно просты, чтобы их выполняли интерфейсные карты (КИ). В каждой КИ вместе с Ts и Rs находится коммутатор сигналов, связывающий источник и приемник объекта с любыми ретрансляторами из группы RT . Коммутаторы кратко описаны ниже.

Рассмотрим детали функционирования ретранслятора. Ретранслятор содержит ретрорефлектор (катафот), который поступающий в него сигнал от любого объекта возвращает этому объекту. Входящий сигнал ориентирован на ретрорефлектор ретранслятора. Для приема сообщения приемник должен послать в ретрорефлектор выбранного им ретранслятора непрерывный сигнал на частоте $*f_1$ для приема единицы и $*f_0$ для приема нуля. Источник в этот ретранслятор посылает сообщение двоичными сигналами: единицу объект-источник передает оптическим сигналом на частоте f_1 , ноль – на частоте f_0 .

Ретранслятор принимает эти сигналы источника, переводит их в электрические сигналы и модулирует ими соответственно непрерывные сигналы $*f_1$, и $*f_0$, отправляя этим сообщение приемнику. Одновременно через ретранслятор может взаимодействовать группа источников и приемников. Разница в частотах f и $*f$ позволяет объектам Or принимать сигналы только от ретрансляторов без помех от источников Or .

Замена группы источников сигналов единственным вторичным источником – RT позволяет точно синхронизовать одновременный обмен сигналами между группой источников и группой приемников сигналов. Если одноименные разряды сообщений, посылаемых группой объектов-источников группы, поступят в RT одновременно, то так объединенное сообщение из RT поступит во все объекты-приемники как единое сообщение. Будет показано, что точность синхронизации разрядов объединяемых сообщений, не зависит от расположения объектов и RT и позволит создать ряд быстрых распределенных групповых операций.

Коммутаторы под управлением объектов выбирают ретрансляторы, в которые объекты в текущий момент должны передать сообщения и от которых приемники примут сообщения. При наличии нескольких Ts и Rs в объекте он может одновременно обмениваться сообщениями с группой RT .

Показанная в статье на рисунке 1 структура относится только к наиболее быстродействующим системам. Менее быстрые системы могут быть однородными и их объекты будут взаимодействовать без ретрансляторов. Необходимые в структуре оптические ретрансляторы с ретрорефлекторами и коммутаторы применяют в ряде областей, например, в средствах связи [3, 4], но не применяют в компьютерах. Поэтому кратко изложим принцип работы этих устройств.

Основное свойство ретрорефлектора – отражать приходящий световой сигнал к его источнику. Широко используются два вида ретрорефлекторов – на основе отражающей свет призмы и шаровой линзы («кошачий глаз»). Принцип работы ретранслятора с ретрорефлектором, содержащим отражатель-призму, иллюстрирует рисунок 2. На рисунке 2а объект-




Рисунок 2. Ретранслятор

источник, от которого объект-приемник должен получить сообщение содержит ретрорефлектор с призмой (2), возвращающей приходящие в нее от приемника непрерывный оптический сигнал опроса (1) к приемнику. Объект-источник электрическим сигналом (4) посылает сообщение на управляемый сигналом (4) светофильтр (3), покрывающий задние стенки призмы. Фильтр отражает сигнал приемника только при приходе на фильтр сигнала (4), соответствующего двоичной единице в возвращаемом ретрорефлектором приемнику сообщении.

На рисунке 2б к обычной конструкции добавлены только позиции 5 и 6. Здесь от произвольного приемника R_s поступают два непрерывных сигнала на частотах $*f_1$ и $*f_0$ для приема в сообщениях источника единицы и нуля соответственно. Но теперь ретранслятор – отдельное устройство, не связанное с объектом-источником. Источник расположен удаленно от ретранслятора и передает сообщение, в котором двоичная единица и ноль передаются оптическими сигналами на частотах f_1 и f_0 (позиция 5). Эти сигналы ретрорефлектор ретранслятора направит в фотоприемник (6), преобразующий их в электрические сигналы (4),

направленные на фильтр (3). Последний модулирует ими непрерывные сигналы приемника, превращая их в сообщении.

Ретранслятор будет полностью пассивным устройством, если приемники пошлют дополнительно световой сигнал для снабжения ретранслятора энергией.

В объектах можно применять два вида коммутаторов оптических сигналов с разным временем переключения направления передаваемых объектами сигналов.

Первый вид коммутатора применяет распространенные микроэлектромеханические системы (MEMS), содержащие большие группы микрозеркал. Каждое зеркало электрически управляемо, переходит в новое положение и сохраняет его до получения нового сигнала управления. В типичном MEMS зеркала имеют два положения, активное и пассивное. Световые сигналы от источника поступают на коммутатор, в нем активное зеркало направит сигналы на соответствующий ему ретранслятор, который, как показано выше, обеспечит связь с приемниками сигналов.

Аналогично действуя, коммутатор приемника направит его непрерывный сигнал в RT . Принятый коммутатором приемника от RT сигнал поступает в фотоприемник сигнала.

В основном, в разных реализациях переключение зеркал выполняется за интервал времени порядка микросекунды.

Второй вид коммутатора использует группы оптических микролазеров, сигналы каждого из них направляются в *фиксированном направлении* к требуемому ретранслятору. В коммутаторе также каждому ретранслятору соответствует фотоприемник. Выбор объектом требуемого ретранслятора выполняется в наносекундном диапазоне [5].

Описание структуры, связывающей скоростные объекты, завершено. Подчеркнем, структура позволяет любому объекту одновременно получать на свой единственный вход (возможно многоразрядный) данные от группы объектов. Результаты следующих [разделов 1.2 и 1.3](#) позволяют побитно синхронизовать приходящие сообщения.

Отметим наиболее важные особенности, приведенной в разделе структуры связей. Структура позволяет объекту одновременно и побитно синхронно получать сообщения от многих объектов. Структура связей может быть в микросекундном диапазоне полностью перестроена посылкой команды одновременно группе объектов. Объект-источник непосредственно не посылает сообщение объекту-приемнику – оба объекта в динамике выбирают ретранслятор для связи. Это позволяет экономно повышать отказоустойчивость системы: при наличии m одновременно отказов в произвольных каналах связи достаточно иметь только m произвольно расположенных резервных ретрансляторов. Отсутствие непосредственной

связи источников с приемниками необходимо, как будет показано, для быстрого сбора данных о состоянии совокупности объектов. Это существенно для распределенных многокомпонентных систем управления и систем с большой неопределенностью в продвижении обработки данных, например, при ассоциативном поиске, во многих задачах с эвристикой, при заранее неизвестном месте и времени получения промежуточных результатов вычисления. Детали приведены далее в статье.

Кратко рассмотрим процесс однократной синхронизации взаимодействия объектов.

1.2. Запуск процесса однократной синхронизации

Изложение следует статье [1], термин – однократная синхронизация (ОС) применен по следующей причине. Каждому объекту из п. 1.1 для синхронного взаимодействия через общий ретранслятор с другими объектами группы достаточно послать *единственный сигнал* s , длительности не менее T – времени переноса сигналов s между наиболее удаленными от RT объектами группы и RT , выбранным для взаимодействия объектов. Передача сигнала s разрешена, если объект не получает от других объектов группы любые сигналы в течение интервала времени T . Действия объектов иллюстрирует рисунок 3.




Рисунок 3. Формирование сигналов S и $*S$

Здесь группа из n объектов посылает в ретранслятор в разные моменты времени в пределах T импульсные сигналы s одинаковой длительности $T_0 \geq T$. Частично совмещаясь во времени, эти сигналы создают единственный общий сигнал S . Момент завершения импульсного сигнала S воспринимается объектами как сигнал $*S$ начала синхронных действий объектов. При выполнении условия $T_0 \geq T$ любые два сигнала s поступят к любому объекту, хотя бы частично совмещаясь во времени, и сигналы S и $*S$ будут единственными.

Каждый объект интервал времени от обнаружения начала сигнала S до его завершения $*S$ использует для подготовки к следующим действиям.

Получение сигнала $*S$ объекты в следующем разделе используют как общий сигнал перехода к синхронному выполнению совместных действий.

1.3. Завершение входа объектов в синхронное состояние

Получив сигнал $*S$, объекты должны определить удаленность от RT , что позволит им синхронизовать передачу сигналов так, чтобы сигналы, соответствующие одноименным двоичным разрядам сообщений, поступали в RT в точно контролируемые моменты времени. Удаленность от RT объекты могут определить с ошибкой менее пикосекунды, применяя новые известные методы измерения расстояний. Эти методы были разработаны усилиями многих коллективов для точной синхронизации физических экспериментов в ЦЕРН (CERN) и в 2019 оформлены в виде международного стандарта. Методы подробно изложены в статьях [6–8], и далее используются без изменений.

В стандарте [6–8] удаленность объектов определяется поочередно вне процесса выполнения текущей задачи. Объекты при отсутствии адресов будут выбирать очередной объект по его отличительным признакам операций $\max$ или $\min$ (см. раздел 3.1), добавляя к признаку случайные числа при неоднозначном результате выбора. Определив удаленность от RT объект определяет момент начала передачи сообщения в RT .

Вводится единственный фиктивный объект O^* , расположенный от RT дальше любого объекта системы. Для согласования отправки своих сигналов в RT любой объект O_i посылает сообщение или одиночный сигнал с задержкой $D = 2(T^* - T_i) + \alpha$, где

- T^* – интервал времени доставки сигнала в RT от объекта O^* ,
- T_i – интервал времени доставки сигнала в RT от любого объекта O_i ,
- α – произвольный сдвиг времени.

Вначале положим $\alpha = 0$. Задержка $D = 2(T^* - T_i)$ учитывает время, требуемое сигналам любых объектов поступить в RT одновременно – группой объектов в RT будет создано одно короткое сообщение с наложением сигналов от одноименных разрядов в сообщениях объектов.

Варьируя α , объект при необходимости вносит дополнительный сдвиг прихода сигнала в RT . В результате в RT будет создано общее сообщение, состоящее из упорядоченных во времени сообщений объектов. Порядок передачи сообщений определяют объекты. Приемники сигналов RT определяют свою удаленность во времени от RT , вычисляя D^* подобно D , что позволяет им, получив сообщение источников, выполнять требуемые действия одновременно. Если объекты-приемники должны инициировать действия других объектов, то приемники действуют как источники и пошлют свои сообщения другим объектам-приемникам и т.д.

Однотактная синхронизация (ОС) выполнена с точностью синхронизации, не зависящей от T . В однородных системах, не имеющих RT , разброс во времени начала синхронизации объектами достигает $T = L/c$, где

L – максимальное расстояние между объектами,
 c – скорость света.

Отметим, что группа источников имеет возможность одновременно синхронно послать сообщение группе приемников, только используя RT – единственный источник-посредник.

1.4. Области применения однократной синхронизации

Наиболее широко применяемый в многих областях вид синхронизации состоит в многократных малых взаимных воздействиях, завершающихся переходом объектов в длительно поддерживаемое синхронное состояние. Но в разделе 1.2 ОС запускается единственным сигналом, созданным без внешней поддержки множеством синхронизируемых объектов. Основная задача ОС – *однократный* запуск во всей группе объектов известного объектам однократного действия, не требующего длительного сохранения объектами периодической синхронизации (ПС). ОС используется для разных применений во всех разделах статьи. Синхронно выполнить группой объектов однократное действие требуется очень часто, в том числе в областях далеких от техники. В статье ОС достигается достаточно простыми средствами, что делает ее доступной и вне техники. В качестве примера приведем очень известную задачу синхронизации цепи стрелков [9].

Это вариант модели одновременного запуска всех частей самоорганизующейся системы, например, группы биологических объектов. Командир посылает в цепь стрелков одному из стрелков (граничному в цепи) команду всем выстрелить одновременно. Стрелок передает команду непосредственному соседу и т.д., т.е. здесь все объекты – вариант клеточных автоматов с близкими связями. В известных решениях после нескольких волн передачи команды по цепи (не меньше 9) объекты синхронизованы и одновременно стреляют. Опубликовано много вариантов решения этой актуальной для биологии задачи.

Применение ОС расширяет задачу и ускоряет ее решение: командира нет, стрелки расположены произвольно. Некоторые стрелки, обнаружив цель, посылают всем стрелкам, без посредников, приведенные выше сигналы s длительности, не меньшей T . Сигналы объединяются в общий сигнал S . В момент его завершения $*S$ стрелки стреляют. Затрачено время не больше $2T$. В однородной системе (без RT) возможен разброс в выстрелах не больше T , в неоднородной системе разброса нет.

Таким образом, не требующую вычислений ОС выполняют очень простые объекты.

В разделе 4 статьи показано применение ОС для часто востребованного запуска ПС, поддерживаемой в небольшом интервале времени, достаточном для выполнения сложных операций в скоростных системах. Как видно, ОС может быть использована широко.

2. Расширение набора средств синхронизации объектов

2.1. Создание сигнала о завершении объектами асинхронных действий

Синхронизация необходима не только в начале совместных действий объектов послылкой сигналов S и $*S$, но и для быстрого оповещения о завершении объектами совместной синхронной или асинхронной работы. Для этого используем модифицированный вариант формирования сигналов S и $*S$, показанный на рисунке 4.



РИСУНОК 4. Завершение асинхронных действий группой объектов

Объекты используют дополнительный канал и выполняют следующие два шага.

Шаг 1. Каждый объект, начиная совместные с другими объектами действия, посылает всем объектам сигнал U , подобный сигналу S . Передача его будет выполняться в отдельном канале (например, на выделенной частоте) и длится до завершения объектом его части совместных действий.

Будем считать, что, подобно сигналу S длительность U не может быть меньше T . Это обеспечивает, как и для S , единственность сигнала U . Завершив свою часть совместных действий, объект переходит к шагу 2.

Шаг 2. Объект прекращает передачу своего сигнала U и ожидает появления сигнала $*U$ – момента завершения сигналов U , посланных всеми источниками. Подобно сигналу $*S$ сигнал $*U$ единственный. Получив $*U$, объекты синхронно фиксируют завершение этапа совместных действий.

2.2. О выборе объектами каналов взаимодействия

В разделах 1.2 и 2.1 группы объектов в двух *известных заранее* каналах применили сигналы $*S$ и $*U$ для децентрализованной реакции на заранее не планируемые асинхронные действия объектов – синхронизацию действий источников сообщений и определение момента завершения асинхронных операций. Аналогично можно реагировать на другие виды непредвиденных событий при организации исходной структуры связей или в пределах выполняемого алгоритма.

Но в общем случае следует предоставить объектам возможность управлять выбором каналов взаимодействия – источнику для связи

с объектами-приемниками требуется посылать сообщения в ретранслятор, за которым следят приемники. Для этого при *исходном формировании системы* всем объектам сообщается адрес *системного RT*, за которым они должны следить, постоянно или в заданном интервале времени. При создании нового кластера объектов адрес кластерного *RT*, подобного адресу системного *RT*, объекты получают от системного *RT*, куда его направит объект, создающий кластер. Далее, при работе в пределах кластера общую для кластера информацию объекты получают от кластерного *RT*. Так как системный *RT* должен быть доступен всем объектам, то его сигналы для упрощения коммутаторов объектов могут быть ненаправленными.

Замечание к разделу 2.2. Если объекты не упорядочены, а позиции расположения *RT* нумерованы, то *RT*, связанный с кластером или отдельным объектом может во многих случаях служить их адресом.

2.3. Способ упорядочения действий объектов

Для объектов, имеющих порядковые номера (адреса) в [1, 2] применяются логические шкалы (или просто шкалы) – последовательности двоичных разрядов, каждый из которых соответствует одному из нумерованных объектов. Если объектам требуется передать сообщения в *RT* одно за другим, то вначале они синхронно с совмещением одноименных разрядов передают в *RT* свои шкалы, содержащие нули и только в одном разряде, соответствующем объекту, единицу. От *RT* объекты получают общую шкалу с группой единиц и, учитывая только единицы, упорядочат передачу сообщений.

При отсутствии адреса он заменяется набором из признака объекта с добавлением случайного числа с обработкой набора операцией $\max/\min$ (см. раздел 1.3).

3. Формирование команд управления группой объектов

В разделе рассмотрены идентификация объектов посредством шкал с набором признаков объекта и формирование команд управления группой объектов кластера.

3.1. Идентификация объекта логической шкалой с набором признаков

Рассмотрим взаимодействие группы объектов, в которой вместо адреса объекта используется набор характеризующих объект признаков. Набор признаков будет представлен логической шкалой (для краткости шкалой), частный случай которой введен в разделе 2.3. Шкала состоит из последовательности двоичных разрядов, каждому разряду поставлен в соответствие один из признаков, характеризующих объект, его текущее состояние или

состояние окружающей объект среды. Для взаимодействующих объектов признаки в разряде их шкал имеют одинаковое значение. В разряде шкалы объект отмечает наличие и отсутствие соответствующего разряда признака двоичной единицей и нулем и передается в структуре связи сигналом частоты f_1 и f_0 соответственно.

Требуется выделять из общей группы объектов отдельные объекты или их кластеры с идентичными запросу шкалами, что достигается следующим вариантом не требующей вычислений распределенной операции $\max$ из [1, 2]. Объекты передают свои шкалы признаков в RT синхронно побитно, начиная со старшего разряда. Каждый следующий разряд шкалы передают только объекты или объект, пославший единицу в предыдущем разряде. В результате будет выделен кластер объектов с одинаковым набором признаков. Аналогично, с заменой единицы на ноль выполняется операция $\min$. Приведенная операция входит в состав распределенных групповых операций из раздела 6. При использовании адресов аналогично выделяются максимальный и минимальный адреса (см. раздел 1.3).

Таким образом, здесь адресный обмен сообщениями заменяется безадресным обменом, который в разделе 3.2 применен для создания безадресных команд управления объектами.

3.2. Формирование безадресных команд управления группой объектов кластера

При выработке *группой* источников общей команды для задания действий *группе* приемников потребуется источникам предварительно, взаимодействуя между собой, сформировать такую команду, состоящую из трех блоков. В блоке (B_1) объектами будет указана наиболее значимая из команд. Во втором блоке (B_2) объекты указывают набор признаков объектов, которым направляется команда. В третьем блоке (B_3) подобно (B_2) формируется набор признаков коллектива источников сообщения.

Быстрое решение для создания первого блока (B_1) следующее. Имеется упорядоченный по уменьшению значимости согласованный список команд. Порядковые номера в списке возрастают. Цифры номеров, заданные в системе счисления с произвольным основанием, представлены шкалами. Каждый объект выбирает порядковый номер рекомендуемой им команды и синхронно с остальными объектами передает выбранный номер, выполняя при передаче операцию $\min$ (раздел 3.1). Тогда в B_1 будет объектами выбрана наиболее значимая команда.

(Увеличение основания системы счисления сокращает количество необходимых обменов сообщениями между объектами, а значит время наиболее затратной части операции $\min$.) Итак, первый блок (B_1) содержит код выбранной из списка команды. Считаем известными до отправки

команды объектам наборы признаков коллектива объектов, которому направляется команда. Этот набор помещается во втором блоке (B_2). В третьем блоке (B_3) подобно (B_2) формируется набор признаков коллектива источников сообщения. В результате совместного применения трех частей каждый объект-приемник в кластере выполнит реакцию на поступающую команду. В блоках B_2 и B_3 вместе с набором признаков, могут указываться адреса ретрансляторов.

Таким образом, в разделе 3.2 объекты заменили команды с неизвестными им адресами объектов командами с признаками и адресами ретрансляторов.

4. Периодическая синхронизация (ПС)

4.1. ПС с постоянным составом объектов и задач в цикле синхронизации

В этом разделе ПС выполняется для систем, имеющих RT . ПС запускается выполнением ОС и сохраняет синхронность взаимодействия объектов в течение заданного интервала времени, достаточного для выполнения последовательности операций, обычно небольшой.

Находящиеся в ПС объекты посылают другим объектам синхросигналы с эталонным циклом Θ длительности обычно значительно больше T ; имеют внутренний механизм поддержки синхронизации – таймер. Запуск ПС объекты выполняют в связке: действует ОС, которая запускает ПС, длящуюся в течение цикла Θ или до получения команды выхода из ПС. Находящийся в ПС объект передает синхросигнал в конце цикла Θ и для продолжения ПС запускает ОС.

Считается, что в пределах Θ таймеры сохраняют синхронность, действия объектов полностью согласованы, и объекты в пределах Θ взаимодействуют синхронно.

Возможен вариант, при котором в цикле Θ объекты выполняют асинхронную работу и должны передать другим объектам результат синхронно по битам в заданном интервале $\Delta\Theta$ перед завершением Θ . Результат может быть получен раньше этого интервала, но объекты-приемники, которые ожидают результат, должны его получить от RT с указанной синхронностью. Источники определяют момент получения результата самостоятельно, используя сигналы U из раздела 2, или посылая сигналы в заранее известный момент времени завершения объектами всех ожидаемых асинхронных работ.

Выше предполагалось, что в пределах цикла Θ состав объектов и задач не изменяется. Сделаем исключение для критического события, требующего срочной реакции объектов.

В этом случае выполнение объектами в ПС задачи немедленно прекращается, состояние объектов сохраняется, и начинается новый цикл Θ выполнения объектами поступившей новой задачи. После завершения внеочередной задачи прерванная задача продолжается. При большой разнице между T и Θ ускорение существенное.

4.2. ПС с переменным составом объектов и задач в цикле синхронизации

Предположим, что в пределах Θ может быть синхронно выполнено несколько задач с разным составом объектов. Для такой ситуации разделим цикл Θ на этапы Ψ меньшей длительности, известной участникам цикла заранее. Тогда объекты в пределах одного этапа Ψ будут действовать подобно их действиям в цикле Θ , но для перехода к следующему этапу Ψ не требуется выполнять ОС.

Подобно действиям в цикле объекты-приемники получают результаты от РТ синхронно до завершения этапа Ψ . Этот момент источники определяют по показаниям таймера. Затем начнется новый этап Ψ , будет сформирована новая группа участников, действующая подобно действиям объектов на предыдущем этапе, Отсутствие ОС ускорило смену Ψ .

Замечание к разделу 4. Рассмотренная в разделе периодическая синхронизация может рассматриваться как вариант только однократной синхронизации с включением в объекты таймеров. Таймерам задается ритм, поддерживаемый в небольшом интервале времени. Таймеры в объектах запускают сигналы s , которые объединяются в сигнал S и сигнал $*S$ запускает ОС, т.е. объектам дается разрешение взаимодействовать с учетом точности их средств синхронизации. Затем возникает пауза и новый цикл ОС.

5. Дополнительные виды взаимодействия объектов

5.1. Синхронизация воздействий объектов на внешнюю среду

Если система объектов действует как система управления, то от нее требуется быстрая реакция на непредвиденные внешние события, возможно с воздействием объектов-исполнителей на среду и источники событий. Исполнители часто не отличаются от рассмотренных выше обычных приемников сообщений и команд и применяют обратную связь с источниками для коррекции последовательности своих воздействий на среду.

Однако при взаимно удаленных группах объектов источников и исполнителей команды допустима форма связи источников команд с воздействующими на среду исполнителями.

Пусть первая из групп подключена к ретранслятору RT_1 , вторая – к RT_2 , удаленному от RT_1 и соединенному с RT_1 линией связи. Источники посылают в RT_1 команду для удаленных исполнителей. При удалении на произвольное расстояние исполнители, *не уменьшая точность взаимной синхронизации*, выполняют команды источников.

5.2. Синхронное взаимодействие объектов в однородных системах

В однородных системах ретранслятор отсутствует, и это снижает точность синхронизации объектов и скорость выполнения распределенных операций с одновременным участием в операции группы объектов. Замедление весьма существенное: интервал времени при передаче соседних битов *в операндах объектов-участников распределенной операции* не должен быть меньше $T = L/c$, где L – максимальное расстояние между объектами, c – скорость света. В остальных случаях отличия незначительные. Например, при обычной передаче сообщения после выделения источника сообщения он передает сообщение со скоростью, ограниченной только технологическими возможностями оборудования.

Устранить замедление в $T = L/c$ и при этом не использовать сложную неоднородную структуру из раздела 1 позволяет следующая упрощенная неоднородная структура. В ней применен единственный ретранслятор, который вместо ретрорефлектора содержит приемник и источник ненаправленных сигналов. Источники объектов посылают приемнику ретранслятора единицы и нули сообщений ненаправленными сигналами частот f_1 и f_0 , а ретранслятор передает без задержки эти сообщения всем объектам также ненаправленными сигналами частот $*f_1$ и $*f_0$. Разные диапазоны частот f и $*f$ исключают в объектах помехи принимаемым сигналам от передаваемых объектами сигналов.

Пропускная способность по сравнению с приведенной выше неоднородной системой много ниже, но распределенные операции выполняются без задержки, возникающей в полностью однородных системах. В рассмотренной упрощенной системе может применяться и единственный ретранслятор с ретрорефлектором, а источники и приемники сообщений будут обмениваться с ретрорефлектором ненаправленными сигналами.

5.3. Особенности взаимодействия простых неупорядоченных объектов

Простыми будем считать объекты с очень ограниченными вычислительными или управляющими средствами, например, датчики и исполнительные механизмы. Простые объекты часто объединены в группы большого, переменного и неизвестного заранее состава. Обращаться к группам таким объектам быстрее по набору параметров объектов, чем перечисляя их адреса.

Часто важны не адрес или текущее состояние параметров объекта, а параметры места его расположения. Также часто требуется определять количество объектов с идентичным набором параметров и имеющих предельные отклонения в этих параметрах. Решения статьи позволяют взаимодействовать объектам, указанным выше.

6. Распределенные групповые операции

В разделе приведены распределенные групповые операции, примененные ранее автором в [1, 2]. Основная их особенность состоит в одновременной, синхронной по разрядам обработке обрабатываемых операцией данных, поступающих от группы объектов. Приведены следующие операции: поразрядные логические операции, выделение в группе чисел с максимальным и минимальным значением, аналого-цифровые сложение и вычитание. Вся распределенная часть операций выполняется в RT , не содержащем логические элементы.

Поразрядные логические операции AND, OR, XOR, логическое «НЕ». Каждый объект-участник этих операций использует шкалу набора признаков. Разряды шкалы соответствуют логическим признакам, характеризующим состояние объекта. Если признак у объекта присутствует, то объект заносит в разряд шкалы единицу, иначе – ноль. Шкалы объекты синхронно по разрядам направляют в RT , представляя единицу сигналом частоты f_1 и ноль – сигналом f_0 . В RT одноименные двоичные сигналы смешиваются и направляются связанным с RT объектам. Если в группе поступающих в RT одноименных разрядов шкал присутствуют нули и единицы, то приемники в этом разряде получают от RT смесь сигналов f_1 и f_0 – третье состояние.

Над общей шкалой каждый объект-приемник выполнит логические групповую операцию. Если объект выполняет поразрядную операцию AND , то для конкретного разряда ее значение равно единице только если разряд содержит f_1 и не содержит f_0 , иначе результат ноль; для OR значение операции равно нулю, если разряд содержит только f_0 , иначе – единица; для XOR значение операции равно единице, если разряд содержит f_1 и f_0 , иначе – ноль. Значение логического «НЕ» при поступлении f_1 равно нулю, при f_0 – единице, при поступлении f_1 и f_0 не определено.

Поиск в массиве чисел максимального и минимального числа. Введем шкалами представление цифр в системе счисления с основанием больше двух: цифру представим шкалой с количеством двоичных разрядов, равным основанию системы. В ней содержится единица в разряде, равном значению цифры, и нули в остальных разрядах. Например, в десятичной системе совмещение шкал для цифр 7, 5, 4, 2 даст шкалу 001011010.

Из нее видно, что в совмещении участвовали наибольшая цифра 7 и наименьшая 2. Такое представление цифр ускоряет поиск $\max$ и $\min$ по сравнению с поиском в двоичной системе: потребуется пересылать меньшее количество более длинных шкал. Именно количество шкал, а не их разрядность в распределенной группе объектов замедляет операции. Каждую цифру-шкалу можно передать на высокой скорости, но до начала передачи следующей цифры чисел объекты должны получить общую шкалу для предыдущей цифры и определить, будут ли они участвовать в процессе дальнейшего определения $\max$ или $\min$.

Операции суммирования/вычитания многих чисел обычно требуют выполнить поочередно цепочку двухкомпонентных операций. Такие действия можно выполнить в структуре рисунок 1, формируя необходимую цепочку связей для объектов-участников операции. Небольшое ускорение дает при этом передача шкал для чисел, представленных в системе счисления с основанием больше двух. Однако во многих задачах распределенного управления и задачах с эвристикой операции суммирования/вычитания выполняются быстрее и проще при существенном ограничении: современные технологии позволяют одновременно участвовать в операции не более 10^4 объектам.

При допустимости указанного ограничения применим аналого-цифровые операции суммирования и вычитания к цифрам чисел, представленных шкалами [1, 2]. Для этого добавим в RT аналого-цифровой преобразователь (АЦП). Он переведет уровень энергии одновременно приходящих в RT сигналов в число. Способ создания требуемых выше стабильных по энергии сигналов показан в [10].

Рассмотрим пример: в RT приходят шкалы группы цифр одного из разрядов десятичных чисел, принятых от объектов. Каждая шкала содержит только одну единицу, остальные – нули, и в RT создается общая шкала, например, 010110010. Шкала показывает наличие цифр 8, 6, 5, 2 в разряде. Пусть поступило три экземпляра цифры 8, девять – цифры шесть, два – цифры 5 и семь – цифры 2. АЦП преобразует шкалу в последовательность цифр 030920070. Здесь цифры показывают: АЦП получил 3 сигнала для значения цифры 8, 9 сигналов для цифры 6, 2 для 5 и 7 для 2.

Локально каждый объект для суммы цифр в старшем десятичном разряде чисел одновременно выполнит подсчет: $3 \times 8 + 9 \times 6 + 2 \times 5 + 7 \times 2 = 102$. Действуя аналогично с другими цифрами числа, объект вычислит сумму полученных чисел. Передавать разряды чисел в RT объекты могут и в обратном порядке. Для вычитания следует отдельно выполнять в RT суммирование цифр для создания двух операндов и вычитание завершать локально в каждом приемнике.

7. Многоэтапное бездресное взаимодействие объектов (пример)

В разделе приведен пример формирования группой объектов последовательности бездресной обработки данных в системе с ретрансляторами RT . Расположение объектов и RT фиксировано. Ретрансляторам присвоены адреса и коммутаторы их используют, создавая взаимосвязи объектов. На рисунке 5 показана структура, отличающаяся от структуры рисунка 1 тем, что группа ретрансляторов RT и объектов разделена на кластеры с произвольным, изменяемым в субмикросекундном диапазоне времени составом объектов. Здесь RT_a , RT_b , RT_c – три кластера ретрансляторов, O_i , O_j , O_k , – три кластера объектов. Кластеры выделены из единых групп ретрансляторов и объектов, показанных на рисунке 1.




Рисунок 5. Структура многоэтапного бездресного взаимодействия объектов

В полученной структуре любой объект в любом кластере организует синхронную связь с произвольным ретранслятором из любого кластера ретрансляторов. Если коммутатор конкретного объекта позволяет одновременно поддерживать несколько соединений с разными кластерами, то они также реализуются. Всегда поддерживается постоянная связь с системным RT (см. раздел 2.2).

На рисунке 5 ретрансляторы кластера RT_a соединены с кластерами O_i и O_j . Ретрансляторы RT_c соединены с кластерами O_i , O_j и O_k , с O_k установлены два канала. Подобно рисунку 1 в новой структуре все межсоединения объектов могут быть одновременно изменены посылкой объектам общей команды. Взаимодействие объекты выполняют следующими шагами.

- (1) Объекты-источники кластера, создают сигналы S , затем $*S$, разрешая объектам-источникам кластера совместно формировать общую команду, сообщающую другим объектам о RT , выбранных источниками для связи с ними. Сформированная команда будет включать адреса RT для связи с объектами кластера-источника, набор параметров источников, канал барьерной синхронизации и другие служебные функции. Команда поступит к всем объектам во всех кластерах. Теперь приемники могут связываться с объектами кластера-источника через приведенные в команде адреса RT источников. Если адрес RT

источника остается приемнику неизвестным, то приемник выполнит запрос адреса через системный *RT*. Аналогично действуя, сообщат о себе кластеры-приемники.

Такова общая схема информирования объектов системы о способе связи с ними в текущей структуре связей. Она действительна и для структуры рисунк 1.

- (2) Связи, созданные на шаге 1 сохраняются неизменными в течение заданного интервала времени (этапа) и уточняются по этапам без обращения к объектам по адресам. Приведенные действия выполняются без привлечения адресов объектов.
- (3) После завершения в системе решаемой задачи создается приведенным способом новая структура. Структура не может быть создана внешним центром при задании новой задачи, если шаги выполнения задачи не детерминированы, что характерно для задач управления распределенными объектами, задач ассоциативного поиска, эвристических и частично в Dataflow при неизвестных в нем моментах времени появления требуемых промежуточных результатов задачи.

8. Уменьшение отрицательного влияния закона Амдала

Закон Амдала оценивает влияние доли последовательных операций (в частности, последовательного обмена через средства связи) на скорость выполнения задач в системах с многими взаимодействующими объектами. Закон выражается формулой $S = 1/(\alpha + (1 - \alpha)/N)$, где

α – доля последовательных (не распараллеливаемых) операций,
 N – количество параллельно обрабатывающих данные процессоров,
 S – ускорение времени обработки данных в зависимости от значений α и N .

Единица в числителе это время выполнения задачи при одном процессоре и отсутствии последовательных операций. В знаменателе $\alpha + (1 - \alpha)/N$ учитывает влияние α и N на величину S .

Если выбрать $\alpha = 0,1$, то $S = 5,263$ при $N = 10$; $S = 9,174$ при $N = 100$ и с ростом N значение S не достигнет 10. С ростом α значение S стремится к единице. Таким образом, на ускорение S в основном влияет α .

Уменьшать α существенно для любых распределенных систем и особенно для распределенных систем управления, в которых для принятия коллективных управляющих решений объекты должны собирать данные о состоянии групп объектов. Для ускорения реакции системы эти данные должен получать каждый объект системы одновременно, что в статье привело к использованию особой структуры связей объектов, быстрых способов управления взаимодействием объектов и к скоростным распределенным групповым операциям.

При отсутствии адресов, как в этой статье, растет неопределенность и, как следствие, нагрузка на средства связи. Поэтому возрастает отрицательное влияние закона Амдала, значительно компенсируемое результатами статьи.

Заключение

В статье предложены структуры связей и методы повышения скорости синхронизации и выполнения ряда видов взаимодействия для распределенных систем, содержащих группы технических объектов, не использующих адреса.

Применение таких структур и методов ориентировано на управляющие и вычислительные системы, решающие задачи управления в жестком реальном времени; задачи ассоциативного поиска; многие задачи с применением эвристики; некоторые задачи типа Dataflow. Второй областью применения методов служат простые датчики и исполнительные механизмы, объединенные в группы большого размера и переменного состава, в том числе с заранее неизвестным количеством объектов.

Предложенные решения во всех разделах применяют однократную синхронизацию, выполняемую посылкой объектами единственного сигнала синхронизации. Однократная синхронизация также запускает переход объектов в периодическую синхронизацию. Для синхронизованных объектов доступен ряд распределенных операций по оценке общего состояния всех объектов системы, которые выполняются в процессе передачи сообщений без его задержки.

Полученные в статье решения реализуются достаточно просто, что позволяет их применять в технических объектах с ограниченными возможностями.

В целом статья повышает скорость входа в синхронизм и реактивность широкого спектра цифровых систем, состоящих из групп неупорядоченных объектов, расширяя этим результаты статей [1, 2].

Список использованных источников

- [1] Стецюра Г. Г. *Синхронное выполнение групповых операций в распределенных компонентах суперкомпьютеров и компьютерных кластерах* // Программные системы: теория и приложения. – 2022. – Т. 13. – № 4(55). – С. 3–24.   ↑4, 5, 10, 14, 15, 19, 20, 23
- [2] Стецюра Г. Г. *Организация взаимодействия активных объектов однородных цифровых структур* // Программные системы: теория и приложения. – 2023. – Т. 14. – № 4(59). – С. 3–23.   ↑4, 5, 14, 15, 19, 20, 23


- [3] Rabinovich W. S., Goetz P. G., Mahon R., Swingen L. A., Murphy J. L., Ferraro M., Burris H. R., Moore Ch. I., Suite M. R., Gilbreath G. Ch., Binari S. C., Klotzkin D. J. *45-Mbit/s cat's-eye modulating retroreflectors* // Optical Engineering.– 2007.– Vol. **46**.– No. 10.– id. 104001.– 8 pp.  ↑8
- [4] Zhu Y., Wang G. *Research on retro-reflecting modulation in space optical communication system*, IOP Conference Series Earth and Environmental Science.– vol. **108**.– No. 3.– 2018.– id. 032060.  ↑8
- [5] Proceedings of the IEEE.– 2020.– Vol. **108**.– No. 5, Special Issue Active Nanophotonics.– Pp. 613–852.  ↑9
- [6] *IEEE standard for a precision clock synchronization protocol for networked measurement and control systems*, IEEE 1588-2019.– IEEE Instrumentation and Measurement Society.– 2020.  ↑5, 11
- [7] White Rabbit Official CERN website <http://white-rabbit.web.cern.ch/>. ↑11
- [8] Rösel K., Helm M., Zirngibl J., Stubbe H. *Current Developments of IEEE 1588 (Precision Time Protocol)*, Seminar IITM WS 20/21, Network Architectures and Services (May 2021).– Pp. 13–17.  ↑5, 11
- [9] Мур Э. *Задача о синхронизации цепи стрелков*, Кибернетический сборник. Новая серия.– т. **1**, М.: Мир.– 1965.– С. 76–77. ↑12
- [10] Bosiljevac M., Babić D., Sipus Z. *Temperature-stable LED-based light source without temperature control*, Photonic Instrumentation Engineering III (15 March 2016, San Francisco, CA, USA), Proc. SPIE.– vol. **9754**.– 2016.– id. 975416.– 6 pp.  ↑20

Поступила в редакцию	01.07.2024;
одобрена после рецензирования	28.07.2024;
принята к публикации	29.07.2024;
опубликована онлайн	17.10.2024.

Рекомендовал к публикации

к.т.н. С. А. Романенко

Информация об авторе:



Геннадий Георгиевич Стецюра

д. т. н., профессор, гл. н. с. ИПУ РАН. Область интересов: информатика, computing. Основные работы в области распределенных многокомпонентных цифровых систем. Более 150 публикаций и более 20 патентов и авторских свидетельств на изобретения.



0000-0003-4606-4424

e-mail:

Декларация об отсутствии личной заинтересованности: *благополучие автора не зависит от результатов исследования.*



Synchronous interaction of distributed disordered digital objects

Gennady Georgievich **Stetsyura**

V. A. Trapeznikov Institute of Control Sciences of RAS, Moscow, Russia

 gstetsura@mail.ru

Abstract. Methods of fast synchronization of interaction of unordered active distributed digital objects grouped into clusters are proposed. Unordered objects (which do not use addresses or other individual attributes) replace addressing individual objects by addresses with addressing clusters of objects specifying sets of attributes common to such objects. This allows any number of objects to simultaneously exchange signals and messages with any number of objects. Transfer of objects into synchronous state is performed in a single-cycle manner, by sending a single synchronization signal by the objects, and then maintained for a specified time. The main type of communication between objects is wireless channels, with the transmission of optical or radio signals. Violation of synchronization is restored by the objects by their own actions. Objects can be stationary and mobile. The main features of the structure of object connections are simultaneous visibility of the state of all objects by any object of the group and simultaneous delivery of messages from a group of objects to the input of any object with bit synchronization. (*In Russian*).

Key words and phrases: reactivity, single-cycle synchronization, distributed control, distributed feedback, unordered digital objects, addressless operations, associative interaction

2020 *Mathematics Subject Classification:* 65Y05; 68Q10

For citation: Gennady G. Stetsyura. *Synchronous interaction of distributed disordered digital objects*. Program Systems: Theory and Applications, 2024, **15**:4(63), pp. 3–26. (*In Russ.*). https://psta.psiras.ru/read/psta2024_4_3-26.pdf

References

- [1] G. G. Stetsyura. “Synchronous execution of group operations in distributed supercomputer components and computer clusters”, *Program Systems: Theory and Applications*, **13**:4(55) (2022), pp. 25–46. 
- [2] G. G. Stetsyura. “The organization of interaction the active objects of homogeneous digital structures”, *Program Systems: Theory and Applications*, **14**:4(59) (2023), pp. 3–23 (In Russ.). 
- [3] W. S. Rabinovich, P. G. Goetz, R. Mahon, L. A. Swingen, J. L. Murphy, M. Ferraro, H. R. Burris, Ch. I. Moore, M. R. Suite, G. Ch. Gilbreath, S. C. Binari, D. J. Klotzkin. “45-Mbit/s cat’s-eye modulating retroreflectors”, *Optical Engineering*, **46**:10 (2007), id. 104001, 8 pp. 
- [4] Y. Zhu, G. Wang. “Research on retro-reflecting modulation in space optical communication system”, *IOP Conference Series Earth and Environmental Science*, vol. **108**, 3, 2018, id. 032060. 
- [5] *Proceedings of the IEEE*, **108**:5, Special Issue Active Nanophotonics (2020), pp. 613–852. 
- [6] *IEEE standard for a precision clock synchronization protocol for networked measurement and control systems*, IEEE 1588-2019, IEEE Instrumentation and Measurement Society, 2020. 
- [7] White Rabbit Official CERN website <http://white-rabbit.web.cern.ch/>.
- [8] K. Rösel, M. Helm, J. Zirngibl, H. Stubbe. “Current Developments of IEEE 1588 (Precision Time Protocol)”, Seminar IITM WS 20/21, Network Architectures and Services (May 2021), pp. 13–17. 
- [9] E. T. Moore. “The firing squad synchronization problem”, *Sequential Machines*, Addison-Wesley Publ. Co. Inc., Beading. Mass–Palo Alto–London, 1964, pp. 213–214.
- [10] M. Bosiljevac, D. Babić, Z. Sipus. “Temperature-stable LED-based light source without temperature control”, Photonic Instrumentation Engineering III (15 March 2016, San Francisco, CA, USA), *Proc. SPIE*, vol. **9754**, 2016, id. 975416, 6 pp. 

УДК 517.977.5

 10.25209/2079-3316-2024-15-4-27-41


Об одном способе поиска оптимального управления в неоднородной дискретной системе с запаздыванием по состоянию процессов

Ирина Викторовна **Расина**^{1✉}, Александр Олегович **Блинов**²

¹ Институт программных систем им. А. К. Айламазяна РАН, Вельское, Россия

² Российский государственный социальный университет, Москва, Россия

[✉] irinarasina@gmail.com

Аннотация. Рассматривается класс неоднородных дискретных систем (НДС) с промежуточными критериями, содержащих два уровня. Системы нижнего уровня включают в себя переменные состояния с запаздыванием. Такие НДС представлены на практике и получаются в процессе дискретизации непрерывных систем при решении задач оптимизации итерационными методами. Для указанного класса предлагается аналог достаточных условий оптимальности Кротова, на основе которого строится метод улучшения управления. Предлагаемый метод проиллюстрирован примером.

Ключевые слова и фразы: неоднородные дискретные системы, запаздывание по состоянию, промежуточные критерии, задача оптимального управления

Для цитирования: Расина И. В., Блинов А. О. *Об одном способе поиска оптимального управления в неоднородной дискретной системе с запаздыванием по состоянию процессов* // Программные системы: теория и приложения. 2024. Т. 15. № 4(63). С. 27–41. https://psta.psisras.ru/read/psta2024_4_27-41.pdf

Введение

Изучение процессов с запаздыванием имеет долгую историю. Первым на необходимость учета предшествующего состояния системы для ее полного описания, качественного исследования и прогнозирования поведения обратил внимание Вольтера [1] при анализе математических моделей численности биологических популяций. Позднее на этот же факт указали специалисты по технологиям и управлению в таких сферах как экономика, экология, диагностика технических устройств, химико-технологические процессы, передача информации, ядерные процессы, космонавтика и многих других. Отметим лишь некоторые из этих работ [3, 4, 10]. Традиционно поиски решения для задач оптимального управления в системах с запаздыванием начались с моделей, описываемых дифференциальными уравнениями. Позднее состоялось обращение к дискретным системам. Во всех этих случаях исследования были связаны с получением условий типа принципа максимума Понтрягина, перечислить все работы такого плана не представляется возможным. Примерами могут служить работы [13, 14]. В данной работе сделана попытка получения достаточных условий оптимальности типа Кротова для неоднородных дискретных систем (НДС) с промежуточными критериями, содержащих два уровня. Системы нижнего уровня включают в себя переменные состояния с запаздыванием. Найденные условия используются для построения метода улучшения первого порядка и формулирования его алгоритма. Алгоритм апробирован на иллюстративном примере.

1. Неоднородные дискретные процессы с запаздыванием по состоянию и промежуточными критериями

Будем рассматривать двухуровневую модель, в которой нижний уровень представлен дискретными динамическими системами однородной структуры с запаздыванием по соответствующему состоянию. На верхнем уровне действует дискретная модель общего вида

$$(1) \quad \begin{aligned} x(k+1) &= f(k, x(k), u(k)), \\ k &\in \mathbf{K} = \{k_I, k_I + 1, \dots, k_F\}, \quad u \in \mathbf{U}(k, x), \end{aligned}$$

где k – номер шага, k_I, k_F – соответственно начальный и конечные шаги; x и u – соответственно переменные состояния и управления произвольной природы (возможно различной) для различных k ; $\mathbf{U}(k, x)$ – заданное при каждом k и x множество.

Выделено подмножество $\mathbf{K}' \subset \mathbf{K}$, $k_F \notin \mathbf{K}'$, на котором $u(k)$ предстает в виде пары $(u^v(k), m^d(k))$, где u^v – управление верхнего уровня, а $m^d(k)$ – дискретный процесс $(x^d(k, t), u^d(k, t))$, $t \in \mathbf{T}(k, z(k))$, $m^d(k) \in \mathbf{D}^d(k, z(k))$. Под $\mathbf{D}^d$ понимается множество допустимых процессов m^d , удовлетворяющих системе

$$(2) \quad \begin{aligned} x^d(k, t+1) &= f^d(k, z, t, x^d(k, t), x^d(k, t - \tau^k), u^d(k, t)), \\ t &\in \mathbf{T} = \{t_I(z), t_I(z) + 1, \dots, t_F(z)\}, \\ x^d(k, t) &= \beta(k, t), \quad t < t_I(z). \end{aligned}$$

$$x^d \in \mathbf{X}^d(k, z, t), \quad u^d \in \mathbf{U}^d(k, z, t, x^d), \quad z = (k, x, u^v),$$

t – номер шага, $t_I(z)$, $t_F(z)$ – соответственно начальный и конечный шаги при каждом k , $\beta(k, t)$ – заданные функции. Для системы (2) на множестве $\mathbf{T}$ задана промежуточная цель в виде функционала, который необходимо минимизировать:

$$I^k = \sum_{\mathbf{T}(z) \setminus t_F(z)} f^k(t, x^d(k, t), x^d(k, t - \tau^k), u^d(k, t)) \rightarrow \inf.$$

Здесь $\mathbf{X}^d(k, z, t)$, $\mathbf{U}^d(k, z, t, x^d)$ – заданные при каждом t , z и x^d множества. Оператор правой части (1) на множестве $\mathbf{K}'$ сводится к следующему:

$$\begin{aligned} f(k, x, u) &= \theta(z, \gamma^d(z)), \quad \text{где} \quad \gamma^d = (t_I, x_I^d, t_F, x_F^d, y_I^T, y_F^T) \in \mathbf{\Gamma}^d(k, z), \\ \mathbf{\Gamma}^d(z) &= \{\gamma^d : t_I = \tau(k, z), t_F = \vartheta(k, z), x_I^d = \xi(k, z), x_F^d \in \mathbf{\Gamma}_F^d(k, z)\}. \end{aligned}$$

На множестве $\mathbf{D}$ процессов

$$m = (x(k), u(k), x^d(k, t), x^d(k, t - \tau^k), u^d(k, t)),$$

удовлетворяющих (1), (2), рассматривается задача оптимального управления о минимизации терминального функционала $I = F(x(k_F))$ при фиксированных $k_I = 0$, k_F , $x(k_I)$ и дополнительных ограничениях $x(k) \in \mathbf{X}(k)$. Подчеркнем, что на каждом дискретном шаге $k \in \mathbf{K}'$ модель рассматривает дискретный процесс $m(k)$, управление которым состоит из фиксированной на шаге дискретной части u и дискретно изменяемой части m^d .

ЗАМЕЧАНИЕ 1. Уравнение типа (2) нетрудно преобразовать к уравнению вида (1). Пусть $x(t+1) = f(t, x(t), x(t-q), u(t))$, $q > 1$. Положим $y^1(t) = x(t-1)$, $y^2(t) = x(t-2)$, ..., $y^q(t) = x(t-q)$. Тогда $y^1(t+1) = x(t)$, $y^2(t+1) = y^1(t)$, ..., $y^q(t+1) = y^{q-1}(t)$. Окончательно имеем следующую систему типа (1): $x(t+1) = f(t, x(t), y^1(t), y^2(t), \dots, y^q(t)), u(t)$, $y^1(t+1) = x(t)$, $y^2(t+1) = y^1(t)$, ..., $y^q(t+1) = y^{q-1}(t)$.

2. Достаточные условия оптимальности

За основу для получения достаточных условий оптимальности взят принцип расширения [7].

Прежде чем получить указанные условия для рассматриваемой задачи введем в рассмотрение новые переменные x^{0k} и преобразуем подзадачу нижнего уровня к виду:

$$\begin{aligned} x^d(k, t+1) &= f^d(k, z, t, x^d(k, t), u^d(k, t), y^\tau(k, t)), \\ x^{0k}(k, t+1) &= x^{0k}(k, t) + f^k(t, x^d(k, t), u^d(k, t), y^\tau(k, t)), \quad x^{0k}(t_I(z)) = 0, \\ I^k &= x^{0k}, \quad \tilde{x}^d = (x^d, x^{0k}), \quad \tilde{f}^d = (f^d, f^k). \end{aligned}$$

Далее вводится множество **Е** процессов m , в котором исключены дискретные цепочки, и обобщенный лагранжиан по аналогии с лагранжианом для НДС [12]:

$$\begin{aligned} L &= G(x(k_F)) - \sum_{\mathbf{K} \setminus \mathbf{K}' \setminus k_F} R(k, x(k), u(k)) + \\ &\quad + \sum_{\mathbf{K}'} \left(G^d(z) - \sum_{\mathbf{T}(z) \setminus t_F} R^d(z, t, x^d(k, t), u^d(k, t), y^\tau(k, t)) \right), \\ G(x) &= F(x(k_F)) + \varphi(k_F, x) - \varphi(k_I, x(k_I)), \\ R(k, x, u) &= \varphi(k+1, f(k, x, u)) - \varphi(k, x), \\ G^d(k, z, \gamma^d) &= -\varphi(k+1, \theta(k, z, \gamma^d)) + \varphi(k, x(k)) - x^{0k}(k, t_F) + \\ &\quad + \tilde{\varphi}^d(k, z, t_F, x_F^d, y_F^\tau) - \tilde{\varphi}^d(k, z, t_I, x_I^d, y_I^\tau), \\ R^d(k, z, t, x^d, u^d, y^\tau) &= \tilde{\varphi}^d(k, z, t+1, f^d(k, z, t, x^d, u^d, y^\tau)) - \\ &\quad - f^k(t, x^d, u^d, y^\tau) - \tilde{\varphi}^d(k, z, t, x^d, y^\tau), \\ \mu^d(k, z, t) &= \sup_{x^d \in \mathbf{X}^d(k, z, t), y^\tau \in \mathbf{X}^d} R^d(k, z, t, x^d, y^\tau, u^d), \\ u^d &\in \mathbf{U}^d(k, z, t, x^d), \\ l^d(k, z) &= \inf_{\gamma^d \in \Gamma^d(k, z), x^d \in \mathbf{X}^d(k, z, t_F)} G^d(k, z, \gamma^d), \\ \mu(k) &= \begin{cases} \sup_{x \in \mathbf{X}(k), u \in \mathbf{U}(k, x)} R(k, x, u), & t \in \mathbf{K} \setminus \mathbf{K}', \\ -\inf_{x \in \mathbf{X}(k), u^v \in \mathbf{U}^v(k, x)} l^d(z), & k \in \mathbf{K}', \end{cases} \\ l &= \inf_{x \in \Gamma \cap \mathbf{X}(k_F)} G(x). \end{aligned}$$

Здесь $\varphi(k, x)$ – произвольный функционал, $\tilde{\varphi}^d(k, z, t, x^d, y^\tau, x^{0k}) = \varphi^d(k, z, t, x^d, y^\tau) - x^{0k}$ – произвольное параметрическое семейство функционалов (с параметрами k, z).

Легко убедиться, что $L(m) = I(m)$ при $m \in \mathbf{D}$, т. е. при выполнении отброшенных связей $L(m)$ совпадает с $I(m)$. Действительно, при $m \in \mathbf{D}$, как видно,

$$\begin{aligned} R &= \varphi(k+1, x(k+1)) - \varphi(k, x), \\ R^d &= \varphi^d(k, z, t+1, x^d(t+1)) - \\ &\quad - f^k(t, x^d(k, t), u^d(k, t), y^\tau(k, t)) - \varphi^d(k, z, t, x^d, y^\tau), \\ G^d(k, z, \gamma^d) &= -\varphi(k+1, \theta(k, z, \gamma^d)) + \varphi(k, x(k)) + \\ &\quad + \varphi^d(k, z, t_F, x_F^d, y^\tau) - \varphi^d(k, z, t_I, x_I^d, y^\tau), \\ L &= F(x(k_F)) + \sum_{\mathbf{K} \setminus \mathbf{K}'} (\varphi(k, x) - \varphi(k, x)) + \\ &\quad + \sum_{\mathbf{K}'} \left(\sum_{\mathbf{T}(k, z)} (\varphi^d(k, z, t, x^d, y^\tau) - \varphi^d(k, z, t, x^d, y^\tau)) \right). \end{aligned}$$

Отсюда непосредственно следуют теоремы, аналогичные теоремам для НДС [12].

ТЕОРЕМА 1. Пусть даны последовательность процессов $\{m_s\} \subset \mathbf{D}$ и функционалы φ, φ^d , такие что:

- (1) $R(k, x_s(k), u_s(k)) \rightarrow \mu(k), \quad k \in \mathbf{K};$
- (2) $R^d(z_s, t, x_s^d(t), u_s^d(t), y_s^\tau) - \mu^d(z_s, t) \rightarrow 0, \quad k \in \mathbf{K}', t \in \mathbf{T}(z_s);$
- (3) $G^d(z_s, \gamma_s^d) - l^d(z_s) \rightarrow 0, \quad k \in \mathbf{K}';$
- (4) $G(x_s(t_F)) \rightarrow l.$

Тогда последовательность $\{m_s\}$ – минимизирующая для I на $\mathbf{D}$.

ТЕОРЕМА 2. Для любого элемента $m \in \mathbf{D}$ и любых функционалов φ, φ^d имеет место оценка

$$I(m) - \inf_{\mathbf{D}} I \leq \Delta = I(m) - l.$$

Пусть имеются два процесса $m^I \in \mathbf{D}$ и $m^II \in \mathbf{E}$ и функционалы φ и φ^d такие, что $L(m^II) < L(m^I) = I(m^I)$ и $m^II \in \mathbf{D}$. Тогда $I(m^II) < I(m^I)$.

Рассмотрим теперь доказательство этих теорем.

Итак, утверждение теоремы 2 становится очевидным поскольку элементы $m^I \in \mathbf{D}$, $m^II \in \mathbf{D}$, а на этом множестве функционалы L и I совпадают.

Далее из определения l , l^d , μ , μ^d следует, что для любых $m \in \mathbf{D}$ $I = L \geq l$. В силу условий 1)-4) существует последовательность $\{m_s\}$, на которой предел $L = I$ равен l . Отсюда следует утверждение теоремы 1.

3. Метод улучшения управления

Предположим, что $\mathbf{X}(k) = \mathbb{R}^{m(k)}$, $\mathbf{X}^d(z, t) = \mathbb{R}^{n(k)}$, $x_I^d = \xi(z)$, k_I , x_I , k_F , $t_I(k)$, $t_F(k)$, $\beta(k, t)$ – заданы, $x_F^d \in \mathbb{R}^{n(k)}$ и системы нижнего уровня не зависят от управления u^v .

Основу для построения метода составляют задача улучшения и принцип расширения [2, 7]. Задача улучшения состоит в построении некоторого оператора $\eta(m)$, $\eta : \mathbf{D} \rightarrow \mathbf{D}$, обладающего свойством $I(\eta(m)) \leq I(m)$. Если задан начальный элемент, то оператор генерирует улучшающую, в частности, минимизирующую последовательность $\{m_s\} : m_{s+1} = \eta(m_s)$.

Согласно указанному принципу расширения по заданному элементу $m^I \in \mathbf{D}$ требуется найти элемент $m^{II} \in \mathbf{D}$, на котором $I(m^{II}) = L(m^{II}) < I(m^I) = L(m^I)$. Иначе $L(m^{II}) - L(m^I) < 0$. Рассмотрим приращение функционала $L(m)$, которое представим в виде

$$\begin{aligned} \Delta L \approx & G_{x_F}^T \Delta x_F - \\ & - \sum_{\mathbf{K} \setminus \mathbf{K}' \setminus k_F} \left(R_x^T \Delta x + R_u^T \Delta u + \frac{1}{2} \Delta u^T R_{uu} \Delta u \right) + \\ & + \sum_{\mathbf{K}' \setminus k_F} \left(G_{x_F^d}^{dT} \Delta x_F^d + G_x^{dT} \Delta x \right) + \\ & + \sum_{\mathbf{K}' \setminus k_F} \left(G_{x_F^d}^{dT} \Delta x_F^d + G_x^{dT} \Delta x + G_{y_F^T}^{dT} \Delta y_F^T \right) - \\ & - \sum_{\mathbf{T}(z) \setminus t_F} \left(R_{x^d}^{dT} \Delta x^d + R_x^{dT} \Delta x + R_{y^T}^{dT} \Delta y^T + R_{u^d}^{dT} \Delta u^d + \frac{1}{2} \Delta u^{dT} R_{u^d u^d} \Delta u^d \right), \end{aligned}$$

где $\Delta u = u - u^I$, $\Delta x = x - x^I$, $\Delta u^d = u^d - u^{dI}$, $\Delta x^d = x^d - x^{dI}$, $\Delta y^T = y^T - y^{TI}$, $\Delta x_F^d = x_F^d - x_F^{dI}$, $x_F = x(k_F)$. Здесь производные функций R , G , R^d , G^d подсчитаны при $u = u^I(k)$, $x = x^I(k)$, $x^d = x^{dI}(k, t)$, $y^{TI}(k)$, $u^d = u^{dI}(k, t)$.

Предположим, что матрицы R_{uu} и $R_{u^d u^d}^d$ отрицательно определены. Найдем Δu , Δu^d доставляющие максимум выражениям, стоящим под знаками сумм $\sum_{\mathbf{K} \setminus \mathbf{K}' \setminus k_F}$, $\sum_{\mathbf{T}(z) \setminus t_F}$ соответственно. Нетрудно видеть, что

$$\Delta u = -(R_{uu})^{-1} R_u,$$

$$\Delta u^d = -(R_{u^d u^d}^d)^{-1} R_{u^d}^d.$$

Зададим функции φ, φ^d в виде:

$$\varphi = \psi^T(k)x(k),$$

$$\varphi^d = \lambda^T(k, t)x(k) + \psi^{dT}(k, t)x^d(k, t) + q^T(k, t)y^\tau(k, t),$$

где ψ, ψ^d, λ, q – вектор-функции, и таким образом, чтобы приращение функционала ΔL не зависело от $\Delta x, \Delta x_F, \Delta x^d, \Delta y^\tau, \Delta x_F^d$. Последнее требование будет достигнуто, если:

$$R_x = 0, \quad R_x^d = 0, \quad R_{x^d}^d = 0, \quad R_{y^\tau}^d = 0,$$

$$G_x = 0, \quad G_x^d = 0, \quad G_{x_F^d}^d = 0, \quad G_{y_F^\tau}^d = 0.$$

Расшифровка указанных условий приводит к задаче Коши для НДС относительно ψ, ψ^d, q, λ с начальными условиями на правом конце:

$$\psi(k_F) = -F_x, \quad \psi(k) = H_x, \quad k \in \mathbf{K} \setminus \mathbf{K}' \setminus k_F,$$

$$\psi(k) = H_x + \xi_x^T H_{x^d} + \xi_x^T \psi^d(k, t_I) + \lambda(t_I) - \lambda(t_F), \quad k \in \mathbf{K}',$$

$$\psi^d = H^d(k, t)_{x^d},$$

$$t = t_I + \tau + 1, \dots, t_F - 1,$$

$$\psi^d(k, t_F) = H_{x_F^d},$$

$$\lambda(k, t) = \lambda(k, t+1) + H_x^d, \quad \lambda(k, t_F) = 0,$$

где

$$H = \psi^T(k+1)f(k, x(k), u(k)), \quad k \in \mathbf{K} \setminus \mathbf{K}' \setminus k_F$$

и

$$q(k, t) = H_{y^\tau}^d, \quad q(k, t_F) = -\theta_{y_F^\tau}$$

$$H = \psi^T \theta(k, \gamma^d), \quad k \in \mathbf{K}',$$

$$H^d = \psi^{dT}(k, t+1)f^d(k, t, x(k), x^d, y^\tau(k), u^d) - f^k(t, x^d, y^\tau(k), u^d),$$

$$x(k_I) = x_I, \quad x(k_F) = x_F, \quad x^d(k, t_I) = x_I^d, \quad x^d(k, t_F) = x_F^d,$$

$$y^\tau(k, t_I) = y_I^\tau, \quad y^\tau(k, t_F) = y_F^\tau.$$

При этом

$$\Delta u(k) = -H_{uu}^{-1} H_u,$$

$$\Delta u^d(k, t) = -(H_{u^d u^d}^d)^{-1} H_{u^d}^d.$$

Следует отметить, что $\psi^{dT}(k, t) = 0, t > t_F(k)$. Это утверждение может быть получено по аналогии с обычными дискретными процессами с запаздыванием как и в [14].

4. Итерационная процедура

На основе полученных соотношений можно сформулировать следующую итерационную процедуру.

1. «Слева направо» просчитывается НДС (1), (2) при $u = u_s(k)$, $u^d = u_s^d(k, t)$ и заданных начальных условиях, получается соответствующие траектории $(x_s(k), x_s^d(k, t))$.

2. «Справа налево» разрешается НДС относительно $\psi(k)$, $\psi^d(k, t)$, $q(k, t)$, $\lambda(k, t)$.

3. Находятся Δu , Δu^d и новые управления $u = u_s(k) + \Delta u$, $u^d = u_s^d(k, t) + \Delta u^d$.

4. При найденных управлениях и начальном условии $x(k_I) = x_I$ просчитывается «слева направо» исходная НДС (1), (2). Тем самым определяется новый элемент m_{s+1} .

Процесс итераций заканчивается, когда $|I_{s+1} - I_s| \approx 0$ с заданной точностью.

5. Пример

Проиллюстрируем работу метода на примере. Пусть задана НДС, состоящая из двух этапов. Первый этап:

$$x^d(t+1) = -2x^d(t) + (u_1^d - 1)^2 + x^d(t-2),$$

$$x^d(0) = 1, \quad t = 0, 1, 2, 3, 4, 5,$$

$$\tau = 2, \quad y^\tau = x^d(t-2),$$

$$I^0 = \frac{1}{2}(x^d(t))^2 + \frac{1}{3}(u_1^d)^3.$$

Второй этап:

$$x^d(t+1) = (t - u_2^d)^2 - x^d(t-1), \quad t = 6, 7, 8,$$

$$I^1 = \frac{1}{2}(x^d)^2 + u_2^d,$$

$$\tau = 1, \quad y^\tau = x^d(t-1),$$

$$I = x^d(9) \rightarrow \min.$$

Здесь I^0 , I^1 — соответственно промежуточные функционалы первого и второго этапов.

Нетрудно видеть, что $K = 0, 1, 2$. Поскольку роль связующей переменной на двух рассматриваемых этапах играет x^d , то в терминах этой

переменной легко записать процесс верхнего уровня:

$$x(0) = x^d(0, 0), \quad x(1) = x^d(0, 5), \quad x(2) = x^d(1, 9), \quad x^d(1, 6) = x(1).$$

Тогда $\theta = x^d(0, 5)$, $\xi = x(1)$, $I = x(2)$.

Поскольку на обоих этапах процесс нижнего уровня не зависит от переменных состояния верхнего уровня, то $\lambda(0, t) = \lambda(1, t) = 0$.

Имеем:

$$\begin{aligned} \psi(2) &= -1, \quad \psi(1) = \psi(2) + \psi^d(1, 4), \\ H^d(0, t) &= \psi^d(0, t+1)(-2x^d(t) + (u_1^d - 1)^2 + y^\tau) - \frac{1}{2}(x^d(t))^2 - \frac{1}{3}(u_1^d)^3, \\ H^d(1, t) &= \psi^d(1, t+1)((t - u_2^d)^2 - y^\tau) - \frac{1}{2}(x^d)^2 - u_2^d, \\ \psi^d(0, t) &= -2\psi^d(0, t+1) - x^d, \quad q(0, t) = \psi^d(0, t + \tau + 1), \\ \psi^d(0, 5) &= \psi(2), \\ \psi^d(1, t) &= -x^d, \quad q(1, t) = -\psi^d(1, t + \tau + 1), \quad \psi^d(1, 10) = 0, \\ H_{u_1^d}^d(0, t) &= 2\psi^d(0, t+1)(u_1^d - 1) - (u_1^d)^2, \\ H_{u_1^d u_1^d}^d(0, t) &= 2(\psi^d(0, t+1) - u_1^d), \\ H_{u_2^d}^d(1, t) &= -2\psi^d(1, t+1)(t - u_2^d) - 1, \\ H_{u_2^d u_2^d}^d(1, t) &= 2\psi^d(1, t+1). \end{aligned}$$

Были проведены вычислительные эксперименты. В начале велся поиск решения примера при различных начальных управляющих воздействиях и одинаковой предыстории. Для расчетов потребовалось 5 итераций. Изменение функционала в обоих случаях представлено в таблице 1, из которой следует, что решения совпадают.

Таблица 1. Результаты расчетов примера 1

Итерация	$I = x^d(9) \rightarrow \min$	
	При начальном $u_{1,2}^d \equiv 1$	При начальном $u_{1,2}^d \equiv 0.5$
0	9	13
1	-14.637	-14.638
2	-14.658	-14.648
3	-14.699	-14.681
4	-14.914	-14.916
5	-14.915	-14.918

Графики переменных состояния и управления даны на рисунках 1, 2.




Рисунок 1. Состояние. Пример при начальном $u_{1,2}^d \equiv 1$




Рисунок 2. Управление. Пример при начальном $u_{1,2}^d \equiv 1$

Далее был осуществлен поиск решения при одном и том же начальном управлении, но с двумя разными предысториями. Результаты представлены в таблице 2 и на рисунках 3, 4.

Из полученных результатов видно, что предыстория оказывает существенное влияние на конечный результат: минимальные значения функционала резко отличаются, тоже происходит с управляющими воздействиями и состоянием процесса.

Кроме того, были выполнены расчеты еще для двух вариантов предысторий. Во всех случаях наблюдается существенная зависимость конечного результата от предыстории. Представление об этом дает таблица 3.

ТАБЛИЦА 2. Результаты расчетов примера

Итерация	$I = x^d(9) \rightarrow \min$	
	Предыстория 1, 1, 1	Предыстория -1, 0, 1
0	9	-8
1	-14.637	-31.743
2	-14.658	-31.864
3	-14.699	-31.871
4	-14.914	-31.876
5	-14.915	-31.877




Рисунок 3. Состояние. Пример




Рисунок 4. Управление. Пример

6. Заключение

Таким образом, в работе рассмотрены НДС с промежуточными критериями и запаздыванием по состоянию систем нижнего уровня. Получен

Таблица 3. Рассчитанные значения управления $I = x^d(9) \rightarrow \min$

Предыстория	1, 1, 1	-1, 0, 1	2, 1.5, 1	5, 2, 1	-3, 0, 1
Начальное	9.000	-8.000	17.500	50.000	-32
Конечное	-14.915	-31.877	-8.254	24.841	-55.846

аналог достаточных условий оптимальности Кротова, на основе которого построен метод улучшения управления, сформулирован его алгоритм. Предлагаемый метод проиллюстрирован примером, подтверждающим его работоспособность. Расчеты на иллюстративном примере подтвердили многочисленные рекомендации из разных областей науки о влиянии предыстории на развитие модели.

Список использованных источников

- [1] Вольтера В. *Математическая теория борьбы за существование*. – М.: Наука. – 1976. – 288 с.  ²⁸
- [2] Кротов В. Ф., Гурман В. И. *Методы и задачи оптимального управления*. – М.: Наука. – 1973. – 448 с.  ³²
- [3] Богомолов В. Л. *Автоматическое регулирование мощности гидростанций по водостоку* // Автоматика и телемеханика. – 1941. – № 4. – С. 103–129.  ²⁸
- [4] Горяченко В. Д. *Методы исследования устойчивости ядерных реакторов*. – М.: Атомиздат. – 1977. – 296 с.  ²⁸
- [5] Гурман В. И., Расина И. В. *Метод глобального улучшения управления для неоднородных дискретных систем* // Программные системы: теория и приложения. – 2016. – Т. 7. – № 1(28). – С. 171–186.  [↑]
- [6] Гурман В. И. *К теории оптимальных дискретных процессов* // Автоматика и телемеханика. – 1973. – № 7. – С. 53–58.  [↑]
- [7] Гурман В. И. *Абстрактные задачи оптимизации и улучшения* // Программные системы: теория и приложения. – 2011. – Т. 2. – № 5(9). – С. 21–29.  ^{↑30, 32}
- [8] Кротов В. Ф. *Достаточные условия оптимальности для дискретных управляемых систем* // ДАН СССР. – 1967. – Т. 172. – № 1. – С. 18–21.  [↑]
- [9] Расина И. В. *Дискретные неоднородные системы и достаточные условия оптимальности* // Известия Иркутского государственного университета. Серия Математика. – 2017. – Т. 19. – № 1. – С. 62–74.  [↑]
- [10] Марчук Г. И. *Математические модели в иммунологии*. – М.: Наука. – 1985. – 239 с.  ²⁸
- [11] Гурман В. И., Расина И. В. *О практических приложениях достаточных условий сильного относительного минимума* // Автоматика и телемеханика. – 1979. – № 10. – С. 12–18.  [↑]

- [12] Расина И. В., Гусева И. С. *Метод улучшения управления для неоднородных дискретных систем с промежуточными критериями* // Программные системы: теория и приложения.– 2018.– Т. 9.– № 2(37).– С. 23–38. ↑^{30, 31}
- [13] Боков Г. В. *Принцип максимума Понтрягина в задаче с временным запаздыванием* // Фундаментальная и прикладная математика.– 2009.– Т. 15.– № 5.– С. 3–19. ↑²⁸
- [14] Пропой А. И. *Элементы теории оптимальных дискретных процессов*.– М.: Наука.– 1973.– 256 с. ↑^{28, 33}

Поступила в редакцию 08.07.2024;
одобрена после рецензирования 22.10.2024;
принята к публикации 02.11.2024;
опубликована онлайн 08.11.2024.

Рекомендовал к публикации

д.т.н. А. М. Цирлин

Информация об авторах:



Ирина Викторовна Расина

д.ф.-м.н., г.н.с. Исследовательского центра системного анализа Института программных систем им. А. К. Айламазяна РАН, ГО Переславль-Залесский, Российская Федерация, специалист в области моделирования и управления гибридными системами, автор и соавтор более 130 статей и 5 монографий



0000-0001-8939-2968

e-mail:



Александр Олегович Блинов

к.т.н., доцент кафедры информационных технологий, искусственного интеллекта и общественно-социальных технологий цифрового общества факультета политических и социальных технологий ФГБОУ ВО «Российский государственный социальный университет», Москва, Российская Федерация



0000-0002-5713-2325

e-mail:

Авторы внесли равный вклад в подготовку публикации.

Декларация об отсутствии личной заинтересованности: благополучие авторов не зависит от результатов исследования.



One method of optimal control searching in a heterogeneous discrete systems with a delay in the state of processes

Irina Viktorovna **Rasina**¹, Alexander Olegovich **Blinov**²

¹ Ailamazyan Program Systems Institute of RAS, Ves'kovo, Russia

² Russian State Social University, Moscow, Russia

[✉] irinarasina@gmail.com

Abstract. It is considered a class of non-homogeneous discrete systems (DNS) with intermediate criteria containing two levels. Lower-level systems include delayed state variables. Such DNS are presented in practice and are obtained in the process of discretization of continuous systems when solving optimization problems using iterative methods. For this class, an analogue of Krotov's sufficient optimality conditions is proposed, on the basis of which a method for improving control is constructed. The proposed method is illustrated with an example. (*In Russian*).

Key words and phrases: non-homogeneous discrete systems, delay in the state of processes, intermediate criteria, optimal control problem

2020 *Mathematics Subject Classification:* 49M25; 49K21, 49N99

For citation: Irina V. Rasina, Alexander O. Blinov. *One method of optimal control searching in a heterogeneous discrete systems with a delay in the state of processes*. Program Systems: Theory and Applications, 2024, **15**:4(63), pp. 27–41. (*In Russ.*). https://psta.psir.ru/read/psta2024_4_27-41.pdf

References

- [1] V. Vol'tera. *Mathematical Theory of Struggle for Existence*, Nauka, M., 1976, 288 pp. (in Russian).
- [2] V. F. Krotov, V. I. Gurman. *Methods and Problems of Optimal Control*, Nauka, M., 1973, 448 pp. (in Russian).
- [3] V. L. Bogomolov. "Automatic control of the power of hydroelectric power stations along the drain", *Avtomatika i telemekhanika*, 1941, no. 4, pp. 103–129 (in Russian).
- [4] V. D. Goryachenko. *Methods for studying the stability of nuclear reactors*, Atomizdat, M., 1977, 296 pp. (in Russian).
- [5] V. I. Gurman, I. V. Rasina. "Global control improvement method for non-homogeneous discrete systems", *Program Systems: Theory and Applications*, **7**:1(28) (2016), pp. 171–186 (in Russian). 
- [6] V. I. Gurman. "Theory of optimum discrete processes", *Autom. Remote Control*, **34**:7 (1973), pp. 1082–1087.
- [7] V. I. Gurman. "Abstract problems of optimization and improvement", *Program Systems: Theory and Applications*, **2**:5(9) (2011), pp. 21–29 (in Russian). 
- [8] V. F. Krotov. "Sufficient conditions for the optimality of discrete control systems", *DAN SSSR*, **172**:1 (1967), pp. 18–21 (in Russian). 
- [9] I. V. Rasina. "Discrete nonuniform systems and sufficient conditions of optimality", *Izvestiya Irkutskogo gosudarstvennogo universiteta. Seriya Matematika*, **19**:1 (2017), pp. 62–74 (in Russian). 
- [10] G. I. Marchuk. *Mathematical Models in Immunology*, Nauka, M., 1985, 239 pp. (in Russian).
- [11] V. I. Gurman, I. V. Rasina. "On practical applications of conditions sufficient for a strong relative minimum", *Autom. Remote Control*, **40**:10 (1980), pp. 1410–1415.
- [12] I. V. Rasina, I. S. Guseva. "Control improvement method for non-homogeneous discrete systems with intermediate criterions", *Program Systems: Theory and Applications*, **9**:2(37) (2018), pp. 23–38 (in Russian).  
- [13] G. V. Bokov. "Pontryagin's maximum principle of optimal control problems with time-delay", *J. Math. Sci.*, **172**:5 (2011), pp. 623–634.
- [14] A. I. Propoj. *Elements of the theory of optimal discrete processes*, Nauka, M., 1973, 256 pp. (in Russian).

УДК 517.977.5

 10.25209/2079-3316-2024-15-4-43-54



Эвристический алгоритм для одной нелинейной задачи оптимального управления

*Нашему учителю, профессору В. И. Гурману
к 90-летию со дня рождения*

Ирина Викторовна **Расина**^{1✉}, Ирина Сергеевна **Гусева**²

¹ Институт программных систем им. А. К. Айламазяна РАН, Вельское, Россия

² Бурятский государственный университет, Улан-Удэ, Россия

[✉] irinarasina@gmail.com

Аннотация. Рассматривается задача оптимального управления для одного из вариантов квазилинейной системы. Для ее решения используется идея профессора В. И. Гурмана, предложившего сочетать два варианта принципа расширения. Один из них, традиционный подход Кротова, а второй - метод штрафных функций. Выбранный класс систем позволяет провести аналитическое исследование лагранжиана Кротова, что в свою очередь приводит к формулировке алгоритма. Полученный алгоритм апробирован на двух иллюстративных примерах, для которых построены минимизирующие последовательности. Трудоемкость расчетов сопоставима с методами, основанными на традиционном принципе расширения. Результаты расчетов проиллюстрированы таблицами и графиками.

Ключевые слова и фразы: достаточные условия оптимальности Кротова, принцип расширения, квазилинейные системы

Для цитирования: Расина И. В., Гусева И. С. *Эвристический алгоритм для одной нелинейной задачи оптимального управления* // Программные системы: теория и приложения. 2024. Т. 15. № 4(63). С. 43–54. https://psta.psiras.ru/read/psta2024_4_43-54.pdf

Введение

В самом общем виде задача оптимизации может быть сформулирована следующим образом. Пусть имеется некоторое множество $\mathbf{D}$ с элементами

z , которые будем называть допустимыми. На этом множестве задан функционал $I(z)$. Требуется найти последовательность элементов z_s из $\mathbf{D}$, на которой функционал $I(z)$ стремится к своей нижней грани на $\mathbf{D}$, т.е. $I(z_s) \rightarrow \inf I, z \in \mathbf{D}$. Другими словами, речь идёт о поиске минимизирующей последовательности. Саму задачу для краткости будем обозначать $(I, \mathbf{D})$. При конкретизации каждой составляющей этой задачи будет получаться определенный класс задач оптимизации, такой как линейное или нелинейное программирование, оптимальное управление непрерывными или дискретными системами и т.д.

Существуют самые разнообразные подходы к решению конкретной задачи $(I, \mathbf{D})$. Одним из таких подходов является принцип расширения. Его суть состоит в переходе от исходной задачи к эквивалентной $(L, \mathbf{E})$, где функционал L есть модификация функционала I , определённая на более широком множестве $\mathbf{E}$, включающем в себя $\mathbf{D}$. Идея принципа расширения и первая его реализация принадлежит Лагранжу при решении задачи на условный экстремум. В роли функционала I фигурировала функция многих переменных, а в роли множества $\mathbf{D}$ — система равенств, состоящая из функций многих переменных. Минимизирующая последовательность должна была состоять из элементов, удовлетворяющих этой системе равенств. Лагранж предложил заменить исходную функцию некой конструкцией L , включающей в себя дополнительные слагаемые. Каждое из них представляло собой произведение одного из равенств на некоторый множитель. Тогда множество $\mathbf{E}$ совпадало с областью определения заданной функции, и на исходном множестве I и L совпадали. Конструкция L в дальнейшем получила название функции Лагранжа, а дополнительные множители стали множителями Лагранжа [1].

Эта идея была реализована В. Ф. Кротовым для задач оптимального управления непрерывными и дискретными системами [2]. Как и у Лагранжа, производилось преобразование исходного функционала с помощью дополнительных конструкций, учитывающих ограничения на переменные состояния и управления. Вместо множителей Лагранжа фигурировала уже некая функция (функция Кротова). Позднее этот результат был распространен на дискретно-непрерывные системы и неоднородные дискретные системы [3, 4]. Все указанные преобразования задачи $(I, \mathbf{D})$ к задаче $(L, \mathbf{E})$ производились по алгоритму предложенному В. Ф. Кротовым. Однако позднее В. И. Гурман высказал идею иного преобразования I в L по аналогии с методом штрафов и реализовал её на простом примере [5].

В данной работе схема, предложенная в [5], использована для класса квазилинейных систем. Изложена методика преобразования, получаемый

при этом алгоритм и иллюстративный пример. Для рассматриваемой в статье задачи далее используется эвристический прием аналогичный подходу SDRE [6].

Ниже рассматривается комбинация двух вариантов принципа расширения: сочетание расширения, предложенного Кротовым с расширением с использованием штрафных функций. Изложенный подход успешно реализуем для частных случаев управляемых систем: систем, близких к линейным, билинейным, линейно-квадратическим с управляемыми коэффициентами и т.д., где возможны аналитические преобразования лагранжиана Кротова. Непосредственно в работе рассматриваются квазилинейные системы. В самом общем случае схема становится слишком громоздкой, трудно реализуемой и малоэффективной.

1. Постановка задачи

Будем рассматривать следующую задачу оптимального управления:

$$(1) \quad \dot{x} = \frac{dx}{dt} = A(x, \varepsilon)x + B(x, \varepsilon)u, \quad t \in \mathbf{T} = [t_I, t_F],$$

где A, B — матрицы размеров $n \times n$, $n \times r$ соответственно,

$$x(t) \in \mathbb{R}^n, \quad u(t) \in \mathbb{R}^r,$$

ε — параметр, $\varepsilon \in (0, 1]$. Для модели (1) ставится задача о поиске минимума на $\mathbf{D}$ функционала

$$(2) \quad I = \frac{1}{2} \int_{\mathbf{T}} (x^T Q(x, \varepsilon)x + u^T S(x, \varepsilon)u) dt + Nx_F + \frac{1}{2} x_F^T \Lambda x_F$$

при начальном состоянии $x(t_I) = x^0$. Здесь Q, S — заданные матрицы размера $n \times n$, $r \times r$ соответственно, $Q \geq 0$, $S > 0$, Λ — симметрическая, положительно определенная матрица размера $n \times n$, N — вектор размера n .

2. Преобразование задачи и поиск решения

Преобразуем задачу, используя вариант расширения класса допустимых, предложенный В. И. Гурманом в [5], при этом будем предполагать, что все объекты обладают необходимыми для преобразований свойствами. Всё дальнейшее исследование проводится в предположении, что матрицы A, B, Q, S не зависят от x , что и определяет эвристический характер получаемого алгоритма.

Введём в рассмотрение ещё одно уравнение $\dot{x} = v$, где v можно рассматривать как новое неограниченное управление. С учётом этого

функционал представим в виде:

$$L_\alpha = \alpha \int_{\mathbf{T}} (v - A(x, \varepsilon)x - B(x, \varepsilon)u)^T (v - A(x, \varepsilon)x - B(x, \varepsilon)u) dt + \\ + (1 - \alpha) \left(\frac{1}{2} \int_{\mathbf{T}} (x^T Q(x, \varepsilon)x + u^T S(x, \varepsilon)u) dt + Nx_F + \frac{1}{2} x_F^T \Lambda x_F \right).$$

Здесь α — весовой коэффициент, $\alpha \in [0, 1]$, а первое подынтегральное выражение — штраф за невыполнение уравнения связи. Следует заметить, что при α стремящемся к нулю все компоненты вектора v стремятся в бесконечность, т. е. по сути выполняют роль штрафных функций.

Воспользуемся далее конструкциями достаточных условий оптимальности Кротова [2]. Лагранжиан Кротова с использованием конструкций достаточных условий оптимальности этого же автора имеет вид:

$$\tilde{L}_\alpha = G - \int_{\mathbf{T}} R_\alpha dt,$$

где

$$G = (1 - \alpha)F(t_F, x_F) + \varphi(t_F, x_F) - \varphi(t_I, x_I), \quad x_F = x(t_F), \quad x_I = x(t_I),$$

$$R_\alpha = \varphi_x^T v - \alpha(v - A(x, \varepsilon)x - B(x, \varepsilon)u)^T (v - A(x, \varepsilon)x - B(x, \varepsilon)u) - \\ - \frac{1}{2}(1 - \alpha)(x^T Q(x, \varepsilon)x + u^T S(x, \varepsilon)u) + \varphi_t.$$

Здесь $\varphi(t, x)$ — функция Кротова; $F(t_F, x_F) = Nx_F + \frac{1}{2}x_F^T \Lambda x_F$. Заметим, что максимум функции R_α равен либо нулю, либо const и она зависит от управления v квадратичным образом, найдём её максимум по этой переменной. Имеем:

$$R_{\alpha v} = \varphi_x - 2\alpha(v - A(x, \varepsilon)x - B(x, \varepsilon)u) = 0.$$

Откуда

$$\bar{v} = \frac{1}{2\alpha}\varphi_x + A(x, \varepsilon)x + B(x, \varepsilon)u.$$

Подставим найденное выражение для v в функцию R_α и выполним необходимые преобразования, обозначим результат как P_α .

$$P_\alpha = \varphi_x(A(x, \varepsilon)x + B(x, \varepsilon)u) + \frac{1}{4\alpha}(\varphi_x)^2 - \\ - \frac{1}{2}(1 - \alpha)(x^T Q(x, \varepsilon)x + u^T S(x, \varepsilon)u) + \varphi_t = \text{const}.$$

В свою очередь, полученная конструкция зависит от управления u также квадратичным образом. Из необходимых условий экстремума следует, что

управление, доставляющее максимум функции P_α , имеет вид:

$$(3) \quad \bar{u} = \frac{1}{1-\alpha} S^{-1} B^T \varphi_x.$$

Подставив это выражение в функцию P_α и выполнив необходимые преобразования, будем иметь:

$$\begin{aligned} M_\alpha = P_\alpha(\bar{u}) &= A^T \varphi_x x + \frac{1}{2(1-\alpha)} \varphi_x^T B S^{-1} B^T \varphi_x + \\ &+ \frac{1}{4\alpha} (\varphi_x)^2 - \frac{1}{2} (1-\alpha) x^T Q x + \varphi_t = \text{const}. \end{aligned}$$

Зададим функцию $\varphi(t, x)$ в виде $\varphi(t, x) = \psi^T(t)x + \frac{1}{2}x^T \sigma(t)x$, где ψ — вектор размера n , а σ — симметрическая матрица размера $n \times n$.

С учётом этого,

$$\begin{aligned} M_\alpha &= A^T \psi x + \frac{1}{2} x^T \sigma A x + \frac{1}{2} x^T A^T \sigma x + \frac{1}{2(1-\alpha)} (\psi^T B S^{-1} B^T \psi + \\ &+ \psi^T B S^{-1} B^T \sigma x + x^T \sigma B S^{-1} B^T \psi + x^T \sigma B S^{-1} B^T \sigma x) + \\ &+ \frac{1}{4\alpha} (\psi^T \psi + \psi^T \sigma x + x^T \sigma \psi + x^T \sigma E \sigma x) - \\ &- \frac{1}{2} (1-\alpha) x^T Q x + \dot{\psi}^T x + \frac{1}{2} x^T \dot{\sigma} x = \text{const}. \end{aligned}$$

Потребуем теперь, чтобы последнее выражение не зависело от состояния процесса. В итоге получим уравнения для нахождения вектора ψ и матрицы σ . Итак,

$$(4) \quad \begin{aligned} \dot{\psi} &= -A^T \psi - \frac{1}{2(1-\alpha)} (\psi^T B S^{-1} B^T \sigma + \sigma B S^{-1} B^T \psi) - \\ &- \frac{1}{4\alpha} (\psi^T \sigma + \sigma \psi), \end{aligned}$$

$$(5) \quad \begin{aligned} \dot{\sigma} &= -\sigma A - A^T \sigma - \frac{1}{2\alpha(1-\alpha)} \sigma (2\alpha B S^{-1} B^T + \\ &+ (1-\alpha)E) \sigma + (1-\alpha)Q. \end{aligned}$$

Значения $\psi(t_F) = -(1-\alpha)N$, $\sigma(t_F) = -(1-\alpha)\Lambda$. Следует заметить, что для матрицы σ получено дифференциальное уравнение типа Риккати. С учётом полученных для ψ и σ уравнений, выражение для M_α принимает вид:

$$M_\alpha = \frac{1}{4\alpha(1-\alpha)} \psi^T (2\alpha B S^{-1} B^T + (1-\alpha)E) \psi.$$

В последнем выражении от параметра ε зависят матрицы B и S^{-1} . Максимум этого выражения даст новое значение параметра.

Для поиска параметра ε может быть использован градиентный метод и его разнообразные модификации. В частных случаях возможно аналитическое исследование выражения M_α и получение формулы для нового значения параметра.

3. Алгоритм

- (1) Задаются начальное управление u^I и значение параметра ε^I .
- (2) Решается исходная система уравнений (1), в результате находится траектория x^I .
- (3) Справа налево интегрируется система (4) для вектора ψ и система (5) для матрицы σ .
- (4) Находится новое управление $\bar{u}$ по формуле (3) и параметр ε .
- (5) Переход к пункту 2.

Критерий окончания расчётов: разность между значениями функционала на соседних итерациях меньше заранее заданной точности вычислений.

4. Пример 1

Рассмотрим следующую задачу:

$$\dot{x} = (\varepsilon x)^2 - \varepsilon \sqrt{x} u, \quad x(0) = 1, \quad I = \frac{1}{2} \int_0^1 \varepsilon^2 (x^2 + x u^2) dt + x(1).$$

Здесь $A = \varepsilon^2 x$, $B = -\varepsilon \sqrt{x}$, $Q = \varepsilon^2$, $S = \varepsilon^2 x$, $N = 1$, $\Lambda = 0$. Основные формулы алгоритма имеют вид:

$$\begin{aligned} \bar{u} &= \frac{1}{(\alpha - 1)\varepsilon\sqrt{x}}(\psi + \sigma x), \\ \dot{\psi} &= -\varepsilon^2 x \psi - \frac{1 + \alpha}{2\alpha(1 - \alpha)} \psi \sigma, & \psi(1) &= \alpha - 1, \\ \dot{\sigma} &= -2\varepsilon^2 x \sigma - \frac{1 + \alpha}{2\alpha(1 - \alpha)} \sigma^2 + (1 - \alpha)\varepsilon^2, & \sigma(1) &= 0, \\ M_\alpha &= \frac{1 + \alpha}{4\alpha(1 - \alpha)} \psi^2. \end{aligned}$$

На начальной итерации $\varepsilon^I = 1$, $u^I = 2$.

В таблице 1 представлено изменение функционала по итерациям при различных значениях параметра α .

На решение примера потребовалось 6 итераций. При этом значение функционала с $I^0 = 1.1044$ уменьшилось до $I^6 = 0.8590; 0.5366; 0.5020$ при

Таблица 1. Изменение значений функционала при различных значениях α по итерациям, $R^k = |I^k - I^{k-1}|$

k	$\alpha = 0.3$			$\alpha = 0.6$			$\alpha = 0.9$		
	ε^k	I^k	R^k	ε^k	I^k	R^k	ε^k	I^k	R^k
0	1	1.1044		1	1.1044		1	1.1044	
1	0.7588	0.9422	0.1622	0.2669	0.6944	0.4100	0.0528	0.8925	0.2119
2	0.7695	0.8637	0.0785	0.2738	0.5626	0.1318	0.0529	0.5392	0.3533
3	0.7644	0.8626	0.0011	0.2675	0.5429	0.0197	0.0528	0.5107	0.0285
4	0.7628	0.8599	0.0027	0.2668	0.5386	0.0043	0.0528	0.5046	0.0061
5	0.7624	0.8592	0.0007	0.2667	0.5372	0.0014	0.0528	0.5027	0.0019
6	0.7622	0.8590	0.0002	0.2666	0.5366	0.0006	0.0528	0.5020	0.0007

$\alpha = 0.3; 0.6; 0.9$ соответственно. Графики управляющего воздействия и состояния процесса на первой и последней итерациях при $\alpha = 0.6$ даны на рисунке 1.




Рисунок 1. Графики состояния $x(t)$ и управляющего воздействия $u(t)$ по итерациям при $\alpha = 0.6$

5. Пример 2

Рассмотрим следующую задачу:

$$\dot{x} = (\varepsilon x)^2 - \varepsilon \sin(x)u, \quad x(0) = 0.5,$$

$$I = \frac{1}{2} \int_0^1 \varepsilon^2 (x^2 \sqrt{x} + (xu)^2) dt - x(1).$$

Здесь $A = \varepsilon^2 x$, $B = -\varepsilon \sin x$, $Q = \varepsilon^2 \sqrt{x}$, $S = (\varepsilon x)^2$, $N = -1$, $\Lambda = 0$. Основные формулы алгоритма имеют вид:

$$\bar{u} = \frac{\sin x}{(\alpha - 1)\varepsilon x^2}(\psi + \sigma x),$$

$$\dot{\psi} = -\varepsilon^2 x \psi - \left(\frac{\sin^2 x}{(1 - \alpha)x^2} + \frac{1}{2\alpha} \right) \psi \sigma, \quad \psi(1) = 1 - \alpha,$$

$$\dot{\sigma} = -2\varepsilon^2 x \sigma - \left(\frac{\sin^2 x}{(1 - \alpha)x^2} + \frac{1}{2\alpha} \right) \sigma^2 + (1 - \alpha)\varepsilon^2 \sqrt{x}, \quad \sigma(1) = 0,$$

$$M_\alpha = \frac{1}{4\alpha(1 - \alpha)} \left(2\alpha \frac{\sin^2 x}{x^2} + 1 - \alpha \right) \psi^2.$$

На начальной итерации $\varepsilon^I = 0.7$, $u^I = -0.5$. В таблице 2 обозначим $R^k = |I^k - I^{k-1}|$. В этой таблице представлено изменение функционала

Таблица 2. Изменение значений функционала по итерациям при различных значениях α

	$\alpha = 0.4$			$\alpha = 0.6$		
k	ε^k	I^k	R^k	ε^k	I^k	R^k
0	0.7	-0.8328		0.7	-0.8328	
1	0.5888	-0.9632	0.1304	0.2583	-0.8668	0.0340
2	0.6022	-1.0268	0.0636	0.2621	-0.8973	0.0305
3	0.5998	-1.0272	0.0004	0.2624	-0.9018	0.0045
4	0.6004	-1.0273	0.0001	0.2620	-0.9007	0.0011
5				0.2619	-0.9006	0.0001

по итерациям с $I^0 = -0.8328$ до $I^4 = -1.0273$ и $I^5 = -0.9006$ при значениях параметра $\alpha = 0.4$ и 0.6 соответственно. Графики управляющего воздействия и состояния процесса на первой и последней итерациях при $\alpha = 0.4$ даны на рисунке 2.

Заметим, что минимум функционала в обоих примерах существенно зависит от выбора весового коэффициента α .




Рисунок 2. Графики состояния $x(t)$ и управляющего воздействия $u(t)$ по итерациям при $\alpha = 0.4$

Заключение

На классе квазилинейных систем рассмотрен еще один вариант реализации принципа расширения, предложенный В. И. Гурманом в [5], сочетающий традиционный подход Кротова [2] и идею использования штрафных функций [1]. Полученный алгоритм апробирован на двух иллюстративных примерах. В результате расчетов построены минимизирующие последовательности. Его трудоемкость по количеству итераций практически не отличается от алгоритма, основанного на традиционном варианте принципа расширения [7], что подтверждает его работоспособность. Область его применения отмечена во введении.

Список использованных источников

- [1] Фихтенгольц Г. М. *Курс дифференциального и интегрального исчисления*, учебник для вузов, в 3-х томах. – Т. 1. – СПб: Лань. – 2024. – 608 с. [↑]_{44, 51}
- [2] Кротов В. Ф., Гурман В. И. *Методы и задачи оптимального управления*. – М.: Наука. – 1973. – 448 с. [↑]_{44, 46, 51}

- [3] Гурман В. И. *К теории оптимальных дискретных процессов* // Автоматика и телемеханика. – 1973. – № 7. – С. 53–58.  ↑44
- [4] Расина И. В. *Иерархические модели управления системами неоднородной структуры*. – М.: Физматлит. – 2014. – 160 с. ↑44
- [5] Гурман В. И., Расина И. В., Гусева И. С., Фесько О. В. *Методы приближенного решения задач оптимального управления* // Программные системы: теория и приложения. – 2015. – Т. 6. – № 4(27). – С. 113–137.  ↑44, 45, 51
- [6] Çimen T. *Systematic and effective design of nonlinear feedback controllers via the state-dependent Riccati equation (SDRE) method* // Annu. Rev. Control.. – 2010. – Vol. 34. – No. 1. – Pp. 32–51.   ↑45
- [7] Расина И. В., Гусева И. С. *Об одном классе дискретно-непрерывных систем с параметрами* // Программные системы: теория и приложения. – 2023. – Т. 14. – № 1(56). – С. 125–148.    ↑51

Поступила в редакцию 11.09.2024;
 одобрена после рецензирования 24.09.2024;
 принята к публикации 02.11.2024;
 опубликована онлайн 08.11.2024.

Рекомендовал к публикации

д.т.н. А. М. Цирлин

Информация об авторах:



Ирина Викторовна Расина

д.ф.-м.н., гл. научн. сотр. Исследовательского центра системного анализа Института программных систем имени А. К. Айламазяна РАН. Специалист в области моделирования и управления гибридными системами, автор и соавтор более 130 статей и 5 монографий



0000-0001-8939-2968

e-mail:



Ирина Сергеевна Гусева

к.ф.-м.н., ст.преп. Бурятского государственного университета имени Доржи Банзарова, РФ, респ. Бурятия, г. Улан-Удэ; автор и соавтор более 20 публикаций; область интересов – оптимальное управление, численные методы



0000-0001-8720-3676

e-mail:

Авторы внесли равный вклад в подготовку публикации.

Декларация об отсутствии личной заинтересованности: благополучие авторов не зависит от результатов исследования.



A heuristic algorithm for one nonlinear optimal control problem

*dedicated to our teacher, Professor V. I. Gurman
on the 90th anniversary of his birth*

Irina Viktorovna **Rasina**¹, Irina Sergeevna **Guseva**²

¹ Ailamazyan Program Systems Institute of RAS, Ves'kovo, Russia

² Buryat State University, Ulan-Ude, Russia

 irinarasina@gmail.com

Abstract. The optimal control problem for one of the variants of a quasilinear system is considered. To solve it, the idea of Professor V. I. Gurman is used, who proposed to combine two variants of the expansion principle. One of them is the traditional Krotov approach, and the second is the penalty function method. The selected class of systems allows for an analytical study of the Krotov Lagrangian, which in turn leads to the formulation of the algorithm. The resulting algorithm is tested on two illustrative examples, for which minimizing sequences are constructed. The complexity of the calculations is comparable with methods based on the traditional expansion principle. The calculation results are illustrated by tables and graphs. (*In Russian*).

Key words and phrases: sufficient Krotov optimality conditions, the expansion principle, quasi-linear systems

2020 *Mathematics Subject Classification:* 49M25; 49K21, 49N99

For citation: Irina V. Rasina, Irina S. Guseva. *A heuristic algorithm for one nonlinear optimal control problem.* Program Systems: Theory and Applications, 2024, **15**:4(63), pp. 43–54. (*In Russ.*). https://psta.pspiras.ru/read/psta2024_4_43-54.pdf

References

- [1] G. M. Fikhtengol'ts. *The Course of Differential and Integral Calculus*, uchebnik dlya vuzov, v 3-x tomax. V. 1, Lan', SPb, 2024, 608 pp. (in Russian).
- [2] V. F. Krotov, V. I. Gurman. *Methods and Problems of Optimal Control*, Nauka, M., 1973, 448 pp. (in Russian).
- [3] V. I. Gurman. "Theory of optimum discrete processes", *Autom. Remote Control*, **34**:7 (1973), pp. 1082–1087.
- [4] I. V. Rasina. *Hierarchical Control Models of Heterogeneous Structure Systems*, Fizmatlit, M., 2014, 160 pp. (in Russian).
- [5] V. I. Gurman, I. V. Rasina, I. S. Guseva, O. V. Fes'ko. "Methods for approximate solution of optimal control problems", *Program Systems: Theory and Applications*, **6**:4(27) (2015), pp. 113–137 (in Russian). 
- [6] T. Çimen. "Systematic and effective design of nonlinear feedback controllers via the state-dependent Riccati equation (SDRE) method", *Annu. Rev. Control.*, **34**:1 (2010), pp. 32–51. 
- [7] I. V. Rasina, I. S. Guseva. "About one class of discrete-continuous systems with parameters", *Program Systems: Theory and Applications*, **14**:1(56) (2023), pp. 125–148 (in Russian).  



Математическое моделирование с учётом ограничений и исследование оптимальной конфигурации оптической стереосистемы, состоящей из двух плоских зеркал и видеокамеры

Дмитрий Николаевич Степанов^{1✉}, Игорь Петрович Тищенко²

^{1,2} Институт программных систем им. А. К. Айламазяна РАН, Вельского, Россия

[✉] mitek1989@mail.ru

Аннотация. Статья продолжает серию исследований, посвященных математическому моделированию и оптимизации конфигурации оптической стереосистемы, состоящей из видеокамеры и двух плоских зеркал. В предыдущей работе мы разработали модель, которая учитывает различные ограничения на конфигурацию подобной системы: величина стереобазы, размеры зеркал, общие габариты оптической системы, отсутствие двойного отражения световых лучей, недопущение ситуации, когда видеокамера отражается в зеркалах. Выполнена постановка задачи условной оптимизации, в качестве целевой функции выбран периметр прямоугольника, ограничивающий оптическую систему.

В рамках данной работы мы добавили в модель набор ограничений, которые задают конфигурацию рабочей зоны, она образована пересечением полей зрения двух виртуальных камер. Соответствующие изменения были внесены в программу для численного решения задачи условной оптимизации с использованием пакета SciPy. Продемонстрированы примеры решения задачи для различных исходных данных. Полученные результаты расширяют теорию компьютерного зрения и могут быть использованы в создании и исследовании систем компьютерного зрения для робототехнических комплексов и систем неразрушающего контроля.

Ключевые слова и фразы: машинное зрение, оптические приборы, математическое моделирование, стереозрение, оптимизация, катоптрическая система

Для цитирования: Степанов Д. Н., Тищенко И. П. Математическое моделирование с учётом ограничений и исследование оптимальной конфигурации оптической стереосистемы, состоящей из двух плоских зеркал и видеокамеры // Программные системы: теория и приложения. 2024. Т. 15. № 4(63). С. 55–77. https://psta.pstiras.ru/read/psta2024_4_55-77.pdf

Введение

Системы технического зрения в настоящее время широко применяются для решения многих практических задач: неразрушающий контроль качества деталей и материалов, создание 3D-моделей реальных объектов, биометрические системы распознавания, автономные роботы и др. Существует несколько способов восстановления 3D-структуры наблюдаемой сцены.

Первый способ — использование источников лазерного излучения (лидаров) и времяпролетных (ToF-) камер. Принцип их работы основан на измерении времени движения световых лучей. Важнейшее преимущество лидаров и ToF-камер — они позволяют восстановить 3D-структуру наблюдаемой сцены без дополнительных сложных алгоритмов калибровки сенсоров и анализа сенсорных данных. Недостаток: информация о текстуре и цвете объектов сцены недоступна, если дополнительно не используются обычные видеокамеры. Кроме того, стоимость лидаров может быть достаточно высокой.

Второй способ — использование структурированной подсветки: излучатель проецирует на объекты некоторый паттерн известной конфигурации, а видеокамера выполняет съемку подсвеченных объектов. Поскольку конфигурация паттерна и взаимное расположение видеокамеры и излучателя известны, то можно восстановить 3D-координаты точек, на которые попадает паттерн. Подобные решения значительно дешевле лидаров, но требуют наличие алгоритмов детектирования на изображении тех пикселей, на которые попала подсветка. В условиях неконтролируемого освещения эта задача может быть нетривиальной. Кроме того, могут быть восстановлены 3D-координаты только тех точек, на которые попала подсветка, т.е. получить так называемое плотное стерео (dense stereo) становится затруднительным.

Если первые два способа относятся к так называемому активному стереозрению, то третий способ — к пассивному. Он основан на съемке сцены несколькими фото- или видеокамерами с разных ракурсов. Если объекты неподвижны, то также может использоваться вариант, когда одна камера выполняет снимки с разных ракурсов (англ. *structure from motion* — структура из движения). Подобные решения дешевле лидаров, сохраняют информацию о текстуре и цвете объектов, менее требовательны к освещению, по сравнению с решениями на основе

структурированной подсветки. Пассивное стереозрение более скрытно, поскольку использование активных систем может быть обнаружено сторонним наблюдателем. Кроме того, видеокамеры имеют обычно более высокое быстродействие (FPS, Frames per Second — количество кадров в секунду), чем лидары и ToF-камеры.

Работа многокамерных систем основана на решении задачи стереосопоставления (stereo correspondence problem): поиск соответствия между пикселями изображений, выполненных с разных ракурсов. И здесь, конечно, следует заметить, что данная задача является одной из самых сложных в компьютерном зрении и не имеет универсального алгоритма ее решения.

Для восстановления 3D-структуры сцены также используются катадиоптрические системы, в состав которых входят видеокамера и комбинация преломляющих и отражающих элементов. На одной светочувствительной матрице создается сразу несколько изображений. Проблема стереосопоставления остается актуальной, но для получения стереоснимков достаточно одной видеокамеры. Следствие этого факта: уменьшение общей стоимости элементов оптической системы и отсутствие в необходимости синхронизации камер.

Пример задачи, в которой использование подобных оптических систем являются фактически единственным возможным вариантом: измерение уровня вибрации на рабочих поверхностях приборов для воспроизведения звука. Такая задача исследуется, к примеру, в статье [1]. В этой задаче необходимо построить 3D-модель вибрирующей поверхности, и стереозрение имеет ряд преимуществ перед другими способами решения задачи: возможность проводить измерения по всему рабочему полю и низкая чувствительность к окружающему акустическому шуму. Но возникает необходимость использования высокоскоростных камер, которые достаточно дороги. Однако, при использовании системы зеркал и единственной камеры общая стоимость всей системы радикально уменьшается.

Если присутствуют только преломляющие элементы, то такая система называется диоптрической, а если только отражающие элементы, то катоптрической. Диоптрические системы исследуются, к примеру, в работах [2, 3], в данном случае используются призмы. Катоптрические системы разделяются по типу используемых зеркал, плоских или криволинейных.

С криволинейными зеркалами можно добиться более широких углов обзора, но более заметными становятся геометрические искажения, особенно по краям зеркал. Данная работа является продолжением наших исследований катоптрических систем с плоскими зеркалами, результаты предыдущих исследований изложены в статьях [4–6]. В статье [6] изложен аналитический обзор публикаций подобных оптических систем, здесь мы ограничимся его краткой версией.

Системы, в которых только одно плоское зеркало, наиболее простые [7], но имеют малый угол обзора, для решения этой проблемы зеркало делают подвижным [8–10]. В работе [11] предложена математическая модель формирования изображений в системе из камеры и одного зеркала (плоского, конического, сферического, параболического, эллиптического или гиперболического), авторы выполнили оценку пространственного разрешения оптических систем и оценку уровня размытия, вызванного расфокусировкой. В качестве примеров работ по математическому моделированию трехзеркальных систем можно привести статьи [7, 12–14].

В трехзеркальных системах на одну часть фотоматрицы проецируются лучи, отразившиеся от одного зеркала, а на другую часть матрицы — отразившиеся от двух других зеркал. На таком принципе основана и оптическая система, которая исследовалась, например, в статьях [15, 16]: 9 зеркал организованы в виде двух пирамид, расположенных друг напротив друга. Четырехзеркальные системы исследовались, к примеру, в статьях [17–22]. Отдельно можно выделить работы, посвященные созданию панорамных стереоизображений с использованием множества зеркал [23, 24]. Наконец, имеются работы (например, [25]), в которых описываются катадиоптрические системы, содержащие и зеркала, и преломляющие элементы: например, два плоских зеркала и дихроичный фильтр.

Данная работа посвящена двухзеркальным системам. Хотя имеется достаточно много статей по таким системам, нужно заметить, что в части работ принимается ряд допущений, сужающих область применения предложенных математических моделей. Например, в работе [26] одно из зеркал располагается параллельно плоскости изображения камеры, а в работе [27] зеркала располагаются симметрично относительно оптической оси камеры.

Однако рассматриваются и более общие случаи. Так в статьях [28, 29] выведены уравнения эллипсоидных ограничений, предложен алгоритм

вычисления фокальной длины системы линз, вычислен угол обзора стереосистемы. В работе [30] описана система из двух плоских зеркал и RGB-D камеры, два зеркала позволяют следить за обстановкой перед мобильным роботом и за ним. В статье [31] предложен алгоритм вычисления угла между зеркалами и вычисления фундаментальных матриц, связывающих положения и ориентации камеры относительно зеркал. На основе двух или трех зеркал можно построить калейдоскопическую систему, таким системам посвящены, к примеру, работы [32, 33].

Обзор показал, что в существующих математических моделях катоптрических систем с плоскими зеркалами используется небольшое количество параметров: в частности, для двухзеркальных — чаще всего только угол обзора и размер стереобазы. Но практически не затрагиваются следующие аспекты:

- реальные образцы оптических систем имеют определенные габариты и массу, и могут быть ограничения на максимально возможные размеры оптической системы. Например, на беспилотный летательный аппарат или на подвижный робототехнический комплекс невозможно поставить слишком большую катоптрическую систему.
- может иметь место проблема двойного отражения. Если в одном зеркале отражается другое зеркало, то в результате на изображении появятся неинформативные области.
- в зеркалах могут отражаться области, наблюдение которых следует избегать. Например, в зеркалах может отражаться видеокамера или элементы конструкции, которые входят в оптическую систему.
- рабочая зона двухзеркальной оптической системы образована пересечением полей зрения двух виртуальных камер. Восстановить 3D-координаты можно только для тех объектов, которые попали в эту зону. В наиболее простых случаях рабочая зона имеет форму треугольника, один из его углов и будет углом обзора оптической системы. Но какова будет конфигурация рабочей зоны при различных расположениях зеркал относительно видеокамеры — эта проблема своего всестороннего анализа пока не получила.

В нашей предыдущей работе [6] была предложена математическая модель катоптрической системы с двумя плоскими зеркалами, в которую входит величина стереобазы, размеры зеркал, учитывается возможность двойного отражения, возможность отражения в зеркалах видеокамеры, а также учитываются общие габариты оптической системы. Выполнена

постановка задачи условной оптимизации, которая позволяет найти конфигурацию оптической системы с заданными характеристиками и минимальными размерами.

В настоящей работе мы исследуем конфигурацию рабочей зоны оптической системы в зависимости от положения зеркал и дополним оптимизационную задачу еще одним набором ограничений, которые задают размеры этой зоны.

1. Полученные ранее результаты

На рисунке 1 приведена иллюстрация модели оптической стереосистемы




Рисунок 1. Модель оптической стереосистемы из видеокамеры и двух плоских зеркал

из двух плоских зеркал, подробное ее описание доступно в работах [5, 6]. Используется вид сверху, начало координат (точка O) расположено в оптическом центре камеры, ось OX направлена вправо от камеры, ось OZ — вперед (оптическая ось), а ось OY направлена вниз. Центр объектива камеры совпадает с началом координат, объектив изображен в виде тонкой линзы.

В реальных камерах чаще всего линз несколько, но здесь мы используем математическую модель «камера-обскура» и перспективную проекцию. Фокальная длина линзы равна f , отрезок F_1F_2 соответствует фотоматрице видеокamеры, плоскости обоих зеркал параллельны оси OY . Отрезки AB и BC соответствуют плоскостям зеркал, вместе они перекрывают все поле зрения камеры и соединяются в точке B , которая лежит на оси OZ . Отрезки AB и BC лежат на прямых с уравнениями $z = \tan(\phi_1)x + b_1$ и $z = \tan(\phi_2)x + b_2$, здесь ϕ_1 и ϕ_2 — углы между прямыми и положительным направлением оси OX , $\phi_{1,2} \in [0, \pi]$.

Пусть ось OZ делит угол обзора камеры пополам, т.е. центр фотоприемника (точка F_0) лежит на оси OZ , или же близко к оси: для большинства современных камер это условие выполняется. Если угол обзора обозначить как 2α , то $\angle AOB = \angle BOC = \alpha$. Положения левой и правой виртуальных камер обозначены точками T_1 и T_2 , расчет их координат представлен в статье [6]. Нетрудно убедиться, что эти точки являются отражением точки O относительно зеркал. Поле зрения левой виртуальной камеры образовано лучами l_{31} и l_{32} , и правой виртуальной камеры — лучами l_{41} и l_{42} .

Сделаем три замечания относительно разработанной математической модели.

- (1) Все параметры видеокamеры фиксированы и не входят в состав оптимизируемых параметров. В данной задаче требуется знать только один параметр камеры — ее горизонтальный угол обзора 2α . Разработка и проектирование собственной видеокamеры — намного более трудная задача, по сравнению со случаем, когда используется готовая видеокamera, и требуется рассчитать только конфигурацию отражающих и/или преломляющих элементов.
- (2) дисторсия на снимках либо незначительна, либо устранена программными методами (камера при этом должна быть заранее откалибрована).
- (3) $\alpha \leq \pi/2$, в противном случае мы имеем дело со сверхширокоугольными камерами, которые в данном исследовании не рассматриваются.

Опишем постановку оптимизационной задачи, которая была ранее

исследована и численно решена в статье [6]:

$$(1) \quad \phi_1 > \pi/2 + \alpha, \phi_1 > \phi_2, \phi_{1,2} \in (\pi/2, \pi],$$

$$(2) \quad \text{base}(\phi_1, \phi_2, b) := 2b \sin(\phi_1 - \phi_2) \geq T_{\min},$$

$$(3) \quad L_1(\phi_1, b) := \frac{b \sin \alpha}{-\cos(\phi_1 - \alpha)} \leq L_{10},$$

$$(4) \quad L_2(\phi_2, b) := \frac{b \sin \alpha}{-\cos(\phi_2 + \alpha)} \leq L_{20},$$

$$(5) \quad \phi_1 < 2\phi_2 - \pi/2,$$

$$(6) \quad (X_C - X_A) \leq \text{wbox}, Z_A \leq \text{hbox},$$

$$(7) \quad \left(\phi_1 < 3\pi/4 \right) \text{OR} \left(\left(\phi_1 \geq 3\pi/4 \right) \text{AND} (u_{41} < -s_1) \right),$$

$$(8) \quad \left(\phi_2 < \left(3\pi/4 - \alpha/2 \right) \right) \text{OR} \left(\left(\phi_2 \geq \left(3\pi/4 - \alpha/2 \right) \right) \text{AND} (u_{32} < -s_1) \right),$$

$$(9) \quad F(\phi_1, \phi_2, b) = 2((X_C(\phi_1, b) - X_A(\phi_2, b)) + Z_A(\phi_2, b)) \rightarrow \min.$$

Поясним (1): если $\phi_1 \leq \pi/2 + \alpha$, то прямая AB не будет пересекаться с лучом OA ; если $\phi_1 \leq \phi_2$, то поля зрения виртуальных камер не будут пересекаться (обнаружено экспериментально); если $\phi_{1,2} \leq \pi/2$, то камера будет наблюдать заднюю поверхность зеркала. Условие (2) задает ограничение на величину стереобазы: она должна быть не менее заданного значения $T_{\min}$. Условия (3) и (4) задают ограничения на ширины зеркал: ширина левого зеркала не превосходит величину L_{10} , а ширина правого зеркала — величину L_{20} . При условии (5) не наблюдается двойное отражение. Выражение (6) задает ограничения на размеры габаритного прямоугольника $AA_1A_2A_3$, который ограничивает оптическую систему; ширина прямоугольника не превосходит значения wbox , а высота — значения hbox . При условиях (7) и (8) в зеркалах не отражается конструкция видеокамеры. Здесь через u_{ij} обозначена абсцисса точки пересечения луча l_{ij} и оси OX , а s_1 — длина отрезка G_1O , здесь G_1G_2 — отрезок, который в предыдущей статье был определен как «запрещенная зона» — область, которая не должна отражаться в зеркалах, она соответствует габаритам конструкции видеокамеры. Выражение (9) определяет функцию, которую необходимо минимизировать: периметр прямоугольника $AA_1A_2A_3$.

2. Случай $\Delta\phi < \alpha/2$

Было проведено моделирование различных конфигураций двухзеркальной системы в среде Maple. В итоге было обнаружено, что конфигурация рабочей зоны зависит от значения $\Delta\phi = \phi_1 - \phi_2$ и угла обзора видеокамеры 2α . Оказалось, что при $\Delta\phi < \alpha/2$ рабочая зона (см. рисунок 2) имеет наиболее простой вид, она заключена между лучами l_{31} и l_{41} .




РИСУНОК 2. Расчет рабочей зоны в случае $\Delta\phi < \alpha/2$

Поскольку $T_1B = T_2B = b$, то $\triangle T_1BT_2$ — равнобедренный. Тогда если точка T — середина T_1T_2 , то TB — высота и медиана $\triangle T_1BT_2$. Поскольку величина стереобазы $T_1T_2 = 2b \sin \Delta\phi$, то $\sin \angle TBT_2 = TT_2/BT_2 = \sin \Delta\phi$, откуда $\angle TBT_2 = \angle TBT_1 = \Delta\phi$, а $TB = b \cos \Delta\phi$.

Таким образом, угол обзора оптической стереосистемы, который расположен между лучами l_{31} и l_{41} , равен $\Delta\phi$. На наш взгляд, угол обзора не является здесь достаточно информативной характеристикой оптической системы, поскольку не содержит полной информации о размерах рабочей зоны. Пусть от оптической системы требуется, чтобы рабочая зона простиралась на расстояние Z_0 от пары виртуальных камер (рисунок 2). И также требуется, чтобы ширина рабочей зоны (отрезок PQ) на этом расстоянии составляла не менее чем H_0 . Конкретные значения Z_0 и H_0 могут быть выбраны, исходя из особенностей задачи и особенностей детектируемых объектов. Такой задачей может быть, например, автономная навигация подвижного робота, детектирующего препятствия и целевые объекты с помощью стереозрения, или восстановление 3D-структуры сцены в задаче стереомикроскопии или неразрушающего контроля. Расстояние Z_0 назовем эффективной дальностью.

Введем функцию f_1 , которая определяет длину отрезка PQ (используем тот факт, что $\angle UBQ = \angle T_1BT$):

$$(10) \quad \begin{aligned} f_1(\Delta\phi, b) &= 2(UT - TB) \cdot \tan \angle UBQ = \\ &= 2(Z_0 - b \cos \Delta\phi) \cdot \tan \Delta\phi = 2Z_0 \cdot \tan \Delta\phi - 2b \cdot \sin \Delta\phi. \end{aligned}$$

В итоге мы можем записать следующее условие на размеры рабочей зоны (здесь и далее для более компактной записи опустим аргументы функций f_i , поскольку у всех функций они совпадают и равны $\Delta\phi$ и b):

$$(11) \quad (\Delta\phi < \alpha/2) \text{ AND } (f_1 \geq H_0).$$

Моделирование также показало, что при $\Delta\phi < \alpha/2$ прямые, на которых лежат лучи l_{31} и l_{42} , пересекаются за виртуальными камерами. Рассмотрим, в каком случае эти прямые будут параллельны. Если они параллельны, то $\angle BT_1T_2 = \pi - \angle T_1T_2G = \pi - (\angle T_1T_2B + \angle BT_2G)$, откуда $\Delta\phi = \alpha/2$. Аналогичный результат можно получить, если рассмотреть лучи l_{32} и l_{41} .

3. Случай $\Delta\phi \in [\alpha/2, \alpha]$

В случаях, когда значение $\Delta\phi$ превосходит $\alpha/2$, но не превосходит α , конфигурация рабочей зоны имеет более сложный вид, представленный на рисунке 3. Она состоит из треугольника BB_1B_2 и области, расположенной выше отрезка B_1B_2 между лучами l_{32} и l_{42} . В точке B_1 пересекаются




РИСУНОК 3. Расчет рабочей зоны в случае $\Delta\phi \in [\alpha/2, \alpha]$

лучи l_{32} и l_{41} , а в точке B_2 — лучи l_{31} и l_{42} . В точке B_4 пересекаются прямые B_1B_2 и TB .

Нетрудно убедиться, что расчет ширины рабочей зоны будет выпол-

няться по разному для эффективных расстояний, больших либо меньших чем длина отрезка TB_4 . Вначале выведем формулу для вычисления его длины, воспользовавшись теоремой синусов и свойствами вертикальных углов:

$$\begin{aligned}
 TB_4 &= TB + BB_4 = b \cos \Delta\phi + BB_1 \cdot \cos \angle B_4BB_1 = \\
 &= (b + BB_1) \cdot \cos \Delta\phi, \\
 \angle B_1BT_1 &= \pi - \angle T_1BT_2 = \pi - 2\Delta\phi, \\
 \angle BB_1T_1 &= \pi - \angle B_1BT_1 - \angle BT_1B_1 = 2\Delta\phi - \alpha, \\
 (12) \quad \frac{BB_1}{\sin \angle BT_1B_1} &= \frac{BT_1}{\sin \angle BB_1T_1} \Rightarrow BB_1 = \frac{b \sin \alpha}{\sin (2\Delta\phi - \alpha)}, \\
 f_2(\Delta\phi, \alpha) &= TB_4 = b \cos \Delta\phi \left(1 + \frac{\sin \alpha}{\sin (2\Delta\phi - \alpha)} \right).
 \end{aligned}$$

Пусть эффективное расстояние $Z_0 = Z_{01}$ не превосходит длину отрезка TB_4 , тогда ширина рабочей зоны (отрезок J_1K_1) вычисляется по формулам из предыдущего раздела. Получаем следующее условие:

$$(13) \quad (\alpha/2 \leq \Delta\phi \leq \alpha) \text{ AND } (Z_0 \leq f_2) \text{ AND } (f_1 \geq H_0).$$

Если же $Z_0 = Z_{02}$ больше чем TB_4 , то ширина рабочей зоны (отрезок J_2K_2) зависит от длины отрезка U_2B_3 :

$$\begin{aligned}
 U_2B_3 &= U_2T + TB_3 = Z_0 + TT_2 \cdot \cot \angle TB_3T_2 = \\
 &= Z_0 + b \sin \Delta\phi \cdot \cot \angle TB_3T_2, \\
 \angle TT_2B &= \pi/2 - \angle TBT_2 = \pi/2 - \Delta\phi, \\
 (14) \quad \angle TT_2B_3 &= \pi - \angle TT_2B - \angle BT_2B_2 = \pi/2 + \Delta\phi - \alpha, \\
 \angle TB_3T_2 &= \pi/2 - \angle TT_2B_3 = \alpha - \Delta\phi, \\
 f_3(\Delta\phi, b) &= J_2K_2 = 2U_2B_3 \cdot \tan \angle TB_3T_2 = \\
 &= 2Z_0 \cdot \tan (\alpha - \Delta\phi) + 2b \cdot \sin \Delta\phi.
 \end{aligned}$$

В результате получаем следующее логическое выражение

$$(15) \quad (\alpha/2 \leq \Delta\phi \leq \alpha) \text{ AND } (Z_0 \geq f_2) \text{ AND } (f_3 \geq H_0).$$

Результаты моделирования показали, что при увеличении угла $\Delta\phi$ точка B_3 все дальше удаляется от виртуальных видеокамер и в какой-то момент уходит в бесконечность: прямые l_{32} и l_{42} становятся параллельными. Условие параллельности можно записать в виде выражения $\angle B_2T_2B_1 + \angle BB_1K_1 = \pi$. Поскольку $\angle BB_1T_1 = 2\Delta\phi - \alpha$, то несложно убедиться, что параллельность возникает при $\Delta\phi = \alpha$.

4. Случай $\Delta\phi \in (\alpha, \pi/2)$

При дальнейшем увеличении угла $\Delta\phi$ точка пересечения прямых l_{32} и l_{42} находится уже перед виртуальными камерами (точка B_5 на рисунке 4),




Рисунок 4. Расчет рабочей зоны в случае $\Delta\phi \in (\alpha, \pi/2)$

а рабочая область оптической системы теперь становится областью ограниченного размера — четырехугольник $BB_1B_5B_2$.

Как и в предыдущем разделе, ширина рабочей зоны зависит от того, превосходит ли расстояние Z_0 длину отрезка TB_4 . Если не превосходит, то этот вариант уже был рассмотрен ранее, и мы получаем следующее логическое выражение:

$$(16) \quad (\alpha < \Delta\phi < \pi/2) \text{ AND } (Z_0 \leq f_2) \text{ AND } (f_1 \geq H_0).$$

В противном случае (расстояние $Z_0 = Z_{03}$ на рисунке 4) необходимо,

чтобы обеспечивалось условие $Z_0 \leq TB_5$. Вычислим длину отрезка TB_5

$$\begin{aligned} \angle TT_2B_5 &= \angle TT_2B + \angle BT_2B_5 = \pi/2 - \Delta\phi + \alpha, \\ (17) \quad TB_5 &= TT_2 \cdot \tan \angle TT_2B_5, \\ f_4(\Delta\phi, b) &= TB_5 = b \cdot \sin \Delta\phi \cdot \cot(\Delta\phi - \alpha). \end{aligned}$$

а затем определим ширину рабочей зоны J_3K_3 :

$$\begin{aligned} T_1T_2 \parallel B_1B_2 &\Rightarrow \angle U_3K_3B_5 = \angle TT_2B_5, \\ (18) \quad J_3K_3 &= 2(TB_5 - U_3T) \cdot \cot \angle U_3K_3B_5, \\ f_{31}(\Delta\phi, b) &= 2Z_0 \cdot \tan(\alpha - \Delta\phi) + 2b \cdot \sin \Delta\phi \equiv f_3(\Delta\phi, b). \end{aligned}$$

В итоге получаем следующее логическое выражение:

$$(19) \quad (\alpha < \Delta\phi < \pi/2) \text{ AND } (Z_0 \geq f_2) \text{ AND } (f_4 \geq Z_0) \text{ AND } (f_3 \geq H_0).$$

5. Постановка и решение задачи условной оптимизации для поиска оптимальной конфигурации оптической системы

Мы получили ограничения на размеры рабочей зоны оптической системы в виде набора выражений (11), (13), (15), (16), (19). Эти выражения добавляются в модель (1)–(9), которая разработана в предыдущей статье. Соответствующие изменения были внесены в разработанную ранее программу для численного решения задачи условной оптимизации с использованием программного пакета *SciPy*^{URL}. Использовался метод *differential_evolution* из модуля *optimize* для поиска глобального минимума скалярной функции вида $F(\vec{X})$ при заданном наборе ограничений вида $\vec{b}_l \leq \vec{F}(\vec{X}) \leq \vec{b}_u$. Этот программный метод базируется на эвристическом алгоритме дифференциальной эволюции.

Программа доступна в *github-репозитории*^{URL}. Отметим особенность программной реализации обновленной модели. Пять логических выражений (11), (13), (15), (16), (19) не могут все одновременно быть истинными (например, не может быть оба истинными выражение $(\Delta\phi < \alpha/2)$ и выражение $(\alpha \leq \Delta\phi \leq \pi/2)$), поэтому оптимизационная задача фактически разбивается на пять отдельных независимых подзадач, в каждую из которых входят выражения (1)–(9) и по одному из пяти новых выражений. В процессе работы программы какие-то из пяти подзадач могут не иметь решения (соответствующие системы неравенств окажутся несовместными), а среди решения остальных подзадач выбирается то решение, при котором значение целевой функции будет наименьшим.

В таблице 1 приведены примеры расчета конфигурации оптической системы для различных значений параметра H_0 .

Таблица 1. Расчет конфигурации оптической системы при различных значениях параметра H_0

H_0 (см)	F (см)	ϕ_1 (рад)	ϕ_2 (рад)	$b_{1,2}$ (см)	AB (см)	AC (см)	AA_1 (см)	A_1A_2 (см)	$\Delta\phi$ (рад)
—	20,6	3,00	2,29	5,3	3,0	2,6	4,6	5,7	0,72
20	35,9	3,00	2,60	8,9	4,9	4,0	8,3	9,7	0,40
30	41,6	2,95	2,60	10,1	5,7	4,6	9,6	11,2	0,35
40	49,0	2,92	2,62	11,7	6,8	5,3	11,2	13,2	0,30
50	—	—	—	—	—	—	—	—	—

Здесь F — минимум целевой функции (периметр $AA_1A_2A_3$), AB и BC — размеры левого и правого зеркал, $w \times h$ — размеры короба $AA_1A_2A_3$. Значения остальных параметров были взяты из предыдущей статьи, а именно: угол $\alpha = 26,75^\circ = 0,467$ рад., расстояние $Z_0 = 100$ см минимальное значение стереобазы $T_{\min} = 7$ см, максимально возможная ширина обоих зеркал $L_{10} = L_{20} = 10$ см, максимально допустимые размеры короба $AA_1A_2A_3$ равны $w_{\text{box}} \times h_{\text{box}} = 15 \times 15$ см, а длина отрезка $G_1O = s_1 = 1,5$ см. Вторая строка таблицы демонстрирует расчеты для случая, когда параметр H_0 не учитывается. Для случая $H_0 = 50$ см решение не было найдено.

По таблице видно, что если необходимо увеличить ширину рабочей зоны, то угол между зеркалами будет уменьшаться, а габариты оптической системы — увеличиваться (при условии, что все остальные параметры остаются неизменными). Например, если необходимо рассчитать конфигурацию двухзеркальной оптической системы для ее установке на подвижном роботе (летающем или едущем), то потребуются найти баланс между габаритами оптической системы (слишком большую систему зеркал разместить не получится) и требуемой шириной рабочей зоны. А ширина зависит от особенностей той задачи, для решения которой планируется использовать возможности стереозрения: например, от размера наблюдаемых целевых объектов, трехмерную структуру которых требуется восстановить.

Заключение

Выполнена модификация ранее разработанной математической модели катоптрической системы, состоящей из двух плоских зеркал и обеспечи-

вающей получение стереопар изображений с помощью единственной видеокамеры. Модель учитывает практические аспекты, возникающие при проектировании подобных систем: ограничения на размер зеркал, проблема двойного отражения, наблюдение запрещенных областей, общие габариты оптической системы. В рамках данной работы в модель добавлены ограничения, которые учитывают конфигурацию рабочей зоны оптической системы, рабочая зона образована пересечением полей зрения двух виртуальных камер. Алгоритм численного решения задачи условной оптимизации был написан с использованием возможностей программного пакета SciPy.

Полученные результаты могут быть использованы для проектирования катоптрических стереосистем различного назначения: например, для их установки на подвижных автономных роботах, для визуального контроля качества изготовленных деталей на конвейере или для анализа характеристик рабочих поверхностей акустических систем. Во всех трех случаях критична синхронизация полученной стереопары снимков, что и обеспечивается подобными катоптрическими системами. В дальнейшем планируется использовать предложенный подход к исследованию трехзеркальных и четырехзеркальных катоптрических стереосистем.

Список использованных источников

- [1] Durand-Texte T., Melon M., Simonetto E., Durand S., Moulet M.-H. *3D vision method applied to measure the vibrations of non-flat items with a two-mirror adapter* // Journal of Physics Conference Series.– 2018.– Vol. **1149**.– No. 1.– id. 012008. doi ↑57
- [2] Gorevoy A. V., Machikhin A. S. *Optimal calibration of a prism-based videoendoscopic system for precise 3D measurements* // Computer Optics.– 2017.– Vol. **41**.– No. 4.– Pp. 535–544. doi ↑57
- [3] Zhou F., Chen Y., Zhou M., Li X. *Effect of catadioptric component postposition on lens focal length and imaging surface in a mirror binocular system* // Sensors.– 2019.– Vol. **19**.– No. 23.– id. 5309. doi ↑57
- [4] Степанов Д. Н., Смирнов А. В. *Исследование процесса калибровки и оптических характеристик стереонасадки 3Dberry* // Программные системы: теория и приложения.– 2018.– Т. **9**.– № 3(38).– С. 11–28. doi ↑58
- [5] Степанов Д. Н. *Математические модели получения стереоизображений с двухзеркальных катадиоптрических систем с учетом дисторсии объективов* // Компьютерная оптика.– 2019.– Т. **43**.– № 1.– С. 105–114. doi ↑58, 60
- [6] Степанов Д. Н., Тищенко И. П. *Математическое моделирование и исследование оптимальной конфигурации оптической стереосистемы, состоящей из двух плоских зеркал* // Программные системы: теория и приложения.– 2024.– Т. **62**.– № 3(62).– С. 23–52. doi ↑58, 59, 60, 61, 62

- [7] Gluckman J., Nayar S.K. *Rectified catadioptric stereo sensors* // IEEE Transactions on Pattern Analysis and Machine Intelligence.– 2002.– Vol. **24**.– No. 2.– Pp. 224–236.  
- [8] Clark A. F., Chan S. W. *Single-camera computational stereo using a rotating mirror* // *Proceedings of the British Machine Vision Conference*.– V. 2 (13-16 September 1994, University of York, York, UK), ed. Hancock E. R.– BMVA Press.– 1994.– ISBN 952-1898-1-X.– Pp. 761–770.  
- [9] Nakao T., Kashitani A. *Panoramic camera using a mirror rotation mechanism and a fast image mosaicing* // *Proceedings 2001 International Conference on Image Processing*.– V. 2 (07-10 October 2001, Thessaloniki, Greece).– IEEE.– 2001.– ISBN 0-7803-6725-1.– Pp. 1045–1048.  
- [10] Hu S., Dong H., Shimasaki K., Jiang M., Senoo T., Ishii I. *Omnidirectional panoramic video system with frame-by-frame ultrafast viewpoint control* // IEEE Robotics and Automation Letters.– 2022.– Vol. **7**.– No. 2.– Pp. 4086–4093.  
- [11] Baker S., Nayar S. K. *A theory of single-viewpoint catadioptric image formation* // International Journal of Computer Vision.– 1999.– Vol. **35**.– No. 2.– Pp. 175–196.  
- [12] Pachidis T., Lygouras J. *A pseudo stereo vision system as a sensor for real time path control of a robot* // *Proceedings of the 19th IEEE Instrumentation and Measurement Technology Conference*.– V. 2, IMTC 2002 (21-23 May 2002, Anchorage, AK, USA).– IEEE.– 2002.– ISBN 0-7803-7218-2.– Pp. 1589–1594.  
- [13] Vernon D. *An optical device for computation of binocular stereo disparity with a single static camera*, Opto-Ireland 2002: Optical Metrology, Imaging, and Machine Vision (5-6 September 2002, Galway, Ireland), Proc. SPIE.– vol. **4877**.– 2003.– Pp. 38–46.  
- [14] Chai X., Zhou F., Chen X. *Epipolar constraint of single camera mirror binocular stereo vision systems* // Optical Engineering.– 2017.– Vol. **56**.– No. 8.– id. 084103.– 8 pp.  
- [15] Zhou F., Chai X., Chen X., Song Y. *Omnidirectional stereo vision sensor based on single camera and catoptric system* // Applied Optics.– 2016.– Vol. **55**.– No. 25.– Pp. 6813–6820.  
- [16] Liu Y., Zhou F., Guo Z., Tan H., Zhang W. *Design and optimization of a quad-directional stereo vision sensor with wide field of view based on single camera* // Measurement.– 2022.– Vol. **203**.– No. 7.– id. 111915.  
- [17] Wang R., Li X., Zhang Y. *Analysis and optimization of the stereo-system with a four-mirror adapter* // Journal of the European Optical Society Rapid Publications.– 2008.– Vol. **3**.– id. 08033.– 7 pp.  
- [18] Yu L., Pan B. *Structure parameter analysis and uncertainty evaluation for single-camera stereo-digital image correlation with a four-mirror adapter* // Applied Optics.– 2016.– Vol. **55**.– No. 25.– Pp. 6936–6946.  
- [19] Luo H., Yu L., Pan B. *Design and validation of a demand-oriented single-camera stereo-DIC system with a four-mirror adapter* // Measurement.– 2021.– Vol. **186**.– No. 5.– Pp. 110083.  

- [20] López-Alba E., Felipe-Sesé L., Schmeer S., Díaz F. A. *Optical low-cost and portable arrangement for full field 3D displacement measurement using a single camera* // Measurement Science and Technology.– 2016.– Vol. **27**.– No. 11.– id. 115901. doi ↑⁵⁸
- [21] Yu Z., Ma K., Wang Z., Wu J., Wang T., Zhuge J. *Surface modeling method for aircraft engine blades by using speckle patterns based on the virtual stereo vision system* // Optics Communications.– 2018.– Vol. **411**.– Pp. 33–39. doi ↑⁵⁸
- [22] Bartol K., Bojanić D., Petković T., Pribanić T. *Catadioptric stereo on a smartphone* // 2021 12th International Symposium on Image and Signal Processing and Analysis, ISPA 2021 (13–15 September 2021, Zagreb, Croatia).– IEEE.– 2021.– ISBN 1-66542-639-X.– Pp. 189–194. doi ↑⁵⁸
- [23] Aggarwal R., Vohra A., Namboodiri A. M. *Panoramic stereo videos with a single camera* // 2016 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2016 (27–30 June 2016, Las Vegas, NV, USA).– IEEE.– 2016.– ISBN 978-1-4673-8850-4.– Pp. 3755–3763. doi ↑⁵⁸
- [24] Zhu L., Wang W., Liu Y., Lai S., Li J. *A virtual reality video stitching system based on mirror pyramids* // 2017 International Conference on Virtual Reality and Visualization, ICVRV 2017 (21–22 October 2017, Zhengzhou, China).– IEEE.– 2017.– ISBN 978-1-5386-2636-8.– Pp. 288–293. doi ↑⁵⁸
- [25] Zhong F., Quan C. *A single color camera stereo vision system* // IEEE Sensors Journal.– 2018.– Vol. **18**.– No. 4.– Pp. 1474–1482. doi ↑⁵⁸
- [26] Nene S. A., Nayar S. K. *Stereo with mirrors* // Sixth International Conference on Computer Vision (07 January 1998, Bombay, India).– IEEE.– 2002.– ISBN 81-7319-221-9.– Pp. 1087–1094. doi ↑⁵⁸
- [27] Goshtasby A., Gruver W. A. *Design of a single-lens stereo camera system* // Pattern Recognition.– 1993.– Vol. **26**.– No. 6.– Pp. 923–937. doi ↑⁵⁸
- [28] Gluckman J., Nayar S. K. *Planar catadioptric stereo: geometry and calibration* // Proceedings IEEE Computer Society Conference on Computer Vision and Pattern Recognition.– V. 1 (23–25 June 1999, Fort Collins, CO, USA).– IEEE.– 1999.– ISBN 0-7695-0149-4.– Pp. 22–28. doi ↑⁵⁸
- [29] Gluckman J., Nayar S. K. *Catadioptric stereo using planar mirrors* // International Journal of Computer Vision.– 2001.– Vol. **44**.– No. 1.– Pp. 65–79. doi ↑⁵⁸
- [30] Endres F., Sprunk C., Kümmerle R., Burgard W. *A catadioptric extension for RGB-D cameras* // 2014 IEEE/RSJ International Conference on Intelligent Robots and Systems (14–18 September 2014, Chicago, IL, USA).– IEEE.– 2014.– ISBN 9781479969357.– Pp. 466–471. doi ↑⁵⁹
- [31] Mariottini G. L., Scheggi S., Morbidi F., Prattichizzo D. *Catadioptric stereo with planar mirrors: multiple-view geometry and camera localization* // Visual Servoing via Advanced Numerical Methods, Lecture Notes in Control and Information Sciences.– vol. **401**, eds. Chesi G., Hashimoto K., London: Springer.– 2010.– ISBN 978-1-84996-088-5.– Pp. 3–21. doi ↑⁵⁹
- [32] Takahashi K., Nobuhara S. *Structure of multiple mirror system from kaleidoscopic projections of single 3D point* // IEEE Transactions on Pattern Analysis and Machine Intelligence.– 2022.– Vol. **44**.– No. 9.– Pp. 5602–5617. doi ↑⁵⁹

- [33] Zhao Y., Chen Y., Yang L. *Calibration of double-plane-mirror catadioptric camera based on coaxial parallel circles* // Journal of Sensors.– 2022.– Vol. **2022**.– No. 12.– id. 7145400.– 15 pp. doi ↑59

Поступила в редакцию 18.10.2024;
одобрена после рецензирования 29.10.2024;
принята к публикации 02.11.2024;
опубликована онлайн 17.11.2024.

Рекомендовал к публикации

д.ф.-м.н. Ю. Л. Сачков

Информация об авторах:



Дмитрий Николаевич Степанов

к.т.н., научн. сотр. Исследовательского центра мультипроцессорных систем ИПС им. А.К. Айламазяна РАН. Область научных интересов: математическое моделирование, численные методы, компьютерное зрение, распознавание образов, параллельное программирование, визуальная навигация, анализ данных



0000-0003-2582-5757

e-mail:



Игорь Петрович Тищенко

к.т.н., и.о. директора ИПС им. А.К. Айламазяна РАН. Область научных интересов: распознавание образов, параллельное программирование, искусственные нейронные сети, беспилотные летательные аппараты



0000-0002-0369-0524

e-mail:

Вклад авторов: Д. Н. Степанов – 95% (идея, методология, программное обеспечение, валидация, формальный анализ, расследование, сбор материала, курирование данных, написание черновой версии, доработка и редактирование, визуализация); И. П. Тищенко – 5% (наставничество, администрирование).

Декларация об отсутствии личной заинтересованности: *благополучие авторов не зависит от результатов исследования.*



Mathematical modeling with constraints and research of the optimal configuration of an optical stereo system consisting of two flat mirrors and videocamera

Dmitry Nikolaevich **Stepanov**¹, Igor Petrovich **Tishchenko**²

^{1,2} Ailamazyan Program Systems Institute of RAS, Ves'kovo, Russia

¹  mitek1989@mail.ru

Abstract. The paper continues a series of studies devoted to mathematical modeling and optimization of optical stereo system configuration, consists of video camera and two flat mirrors. In previous work, we developed a model that takes into account various constraints on the configuration of such a system: the size of the stereo base, the size of the mirrors, overall dimensions of the optical system, the absence of double reflection of light rays, preventing the situation when the video camera is reflected in the mirrors. A conditional optimization problem is formulated, the perimeter of the rectangle that bounds the optical system is chosen as the objective function.

In this work we added a set of constraints to the model that define the configuration of the working area, which is formed by the intersection of the fields of view of two virtual cameras. The corresponding changes were made to the program for the numerical solution of the constrained optimization problem using the SciPy package. The results obtained expand the theory of computer vision and can be used in the creation and research of computer vision systems for robotic systems and non-destructive testing systems. (*In Russian*).

Key words and phrases: machine vision, optical devices, mathematical modeling, stereovision, optimization, catoptric system

2020 *Mathematics Subject Classification:* 78M50; 78A05, 68T45

For citation: Dmitry N. Stepanov, Igor P. Tishchenko. *Mathematical modeling with constraints and research of the optimal configuration of an optical stereo system consisting of two flat mirrors and videocamera*. Program Systems: Theory and Applications, 2024, **15**:4(63), pp. 55–77. (*In Russ.*). https://psta.psiras.ru/read/psta2024_4_55-77.pdf

References

- [1] T. Durand-Texte, M. Melon, E. Simonetto, S. Durand, M. -H. Moulet. “3D vision method applied to measure the vibrations of non-flat items with a two-mirror adapter”, *Journal of Physics Conference Series*, **1149**:1 (2018), id. 012008. 
- [2] A. V. Gorevoy, A. S. Machikhin. “Optimal calibration of a prism-based videoendoscopic system for precise 3D measurements”, *Computer Optics*, **41**:4 (2017), pp. 535–544. 
- [3] F. Zhou, Y. Chen, M. Zhou, X. Li. “Effect of catadioptric component postposition on lens focal length and imaging surface in a mirror binocular system”, *Sensors*, **19**:23 (2019), id. 5309. 
- [4] D. N. Stepanov, A. V. Smirnov. “Research of calibration process and optical characteristics of 3Dberry stereo nozzle”, *Program Systems: Theory and Applications*, **9**:3(38) (2018), pp. 11–28 (in Russian). 
- [5] D. N. Stepanov. “Mathematical models of obtaining stereo images from two-mirror catadioptric systems with regard to lens distortion”, *Komp'yuternaya optika*, **43**:1 (2019), pp. 105–114 (in Russian). 
- [6] D. N. Stepanov, I. P. Tishhenko. “Mathematical modeling and research of the optimal configuration of an optical stereo system consisting of two flat mirrors”, *Program Systems: Theory and Applications*, **62**:3(62) (2024), pp. 23–52 (in Russian). 
- [7] J. Gluckman, S. K. Nayar. “Rectified catadioptric stereo sensors”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **24**:2 (2002), pp. 224–236. 
- [8] A. F. Clark, S. W. Chan. “Single-camera computational stereo using a rotating mirror”, *Proceedings of the British Machine Vision Conference*. V. 2 (13-16 September 1994, University of York, York, UK), ed. Hancock E. R., BMVA Press, 1994, ISBN 952-1898-1-X, pp. 761–770. 
- [9] T. Nakao, A. Kashitani. “Panoramic camera using a mirror rotation mechanism and a fast image mosaicing”, *Proceedings 2001 International Conference on Image Processing*. V. 2 (07-10 October 2001, Thessaloniki, Greece), IEEE, 2001, ISBN 0-7803-6725-1, pp. 1045–1048. 
- [10] S. Hu, H. Dong, K. Shimasaki, M. Jiang, T. Senoo, I. Ishii. “Omnidirectional panoramic video system with frame-by-frame ultrafast viewpoint control”, *IEEE Robotics and Automation Letters*, **7**:2 (2022), pp. 4086–4093. 
- [11] S. Baker, S. K. Nayar. “A theory of single-viewpoint catadioptric image formation”, *International Journal of Computer Vision*, **35**:2 (1999), pp. 175–196. 
- [12] T. Pachidis, J. Lygouras. “A pseudo stereo vision system as a sensor for real time path control of a robot”, *Proceedings of the 19th IEEE Instrumentation and Measurement Technology Conference*. V. 2, IMTC 2002 (21-23 May 2002, Anchorage, AK, USA), IEEE, 2002, ISBN 0-7803-7218-2, pp. 1589–1594. 

- [13] D. Vernon. “An optical device for computation of binocular stereo disparity with a single static camera”, Opto-Ireland 2002: Optical Metrology, Imaging, and Machine Vision (5-6 September 2002, Galway, Ireland), Proc. SPIE, vol. **4877**, 2003, pp. 38–46. [doi](#)
- [14] X. Chai, F. Zhou, X. Chen. “Epipolar constraint of single camera mirror binocular stereo vision systems”, *Optical Engineering*, **56**:8 (2017), id. 084103, 8 pp. [doi](#)
- [15] F. Zhou, X. Chai, X. Chen, Y. Song. “Omnidirectional stereo vision sensor based on single camera and catoptric system”, *Applied Optics*, **55**:25 (2016), pp. 6813–6820. [doi](#)
- [16] Y. Liu, F. Zhou, Z. Guo, H. Tan, W. Zhang. “Design and optimization of a quad-directional stereo vision sensor with wide field of view based on single camera”, *Measurement*, **203**:7 (2022), id. 111915. [doi](#)
- [17] R. Wang, X. Li, Y. Zhang. “Analysis and optimization of the stereo-system with a four-mirror adapter”, *Journal of the European Optical Society Rapid Publications*, **3** (2008), id. 08033, 7 pp. [doi](#)
- [18] L. Yu, B. Pan. “Structure parameter analysis and uncertainty evaluation for single-camera stereo-digital image correlation with a four-mirror adapter”, *Applied Optics*, **55**:25 (2016), pp. 6936–6946. [doi](#)
- [19] H. Luo, L. Yu, B. Pan. “Design and validation of a demand-oriented single-camera stereo-DIC system with a four-mirror adapter”, *Measurement*, **186**:5 (2021), pp. 110083. [doi](#)
- [20] E. López-Alba, L. Felipe-Sesé, S. Schmeer, F. A. Díaz. “Optical low-cost and portable arrangement for full field 3D displacement measurement using a single camera”, *Measurement Science and Technology*, **27**:11 (2016), id. 115901. [doi](#)
- [21] Z. Yu, K. Ma, Z. Wang, J. Wu, T. Wang, J. Zhu. “Surface modeling method for aircraft engine blades by using speckle patterns based on the virtual stereo vision system”, *Optics Communications*, **411** (2018), pp. 33–39. [doi](#)
- [22] K. Bartol, D. Bojanić, T. Petković, T. Pribanić. “Catadioptric stereo on a smartphone”, *2021 12th International Symposium on Image and Signal Processing and Analysis, ISPA 2021* (13-15 September 2021, Zagreb, Croatia), IEEE, 2021, ISBN 1-66542-639-X, pp. 189–194. [doi](#)
- [23] R. Aggarwal, A. Vohra, A. M. Namboodiri. “Panoramic stereo videos with a single camera”, *2016 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2016* (27-30 June 2016, Las Vegas, NV, USA), IEEE, 2016, ISBN 978-1-4673-8850-4, pp. 3755–3763. [doi](#)
- [24] L. Zhu, W. Wang, Y. Liu, S. Lai, J. Li. “A virtual reality video stitching system based on mirror pyramids”, *2017 International Conference on Virtual Reality and Visualization, ICVRV 2017* (21-22 October 2017, Zhengzhou, China), IEEE, 2017, ISBN 978-1-5386-2636-8, pp. 288–293. [doi](#)
- [25] F. Zhong, C. Quan. “A single color camera stereo vision system”, *IEEE Sensors Journal*, **18**:4 (2018), pp. 1474–1482. [doi](#)

- [26] S. A. Nene, S. K. Nayar. “Stereo with mirrors”, *Sixth International Conference on Computer Vision* (07 January 1998, Bombay, India), IEEE, 2002, ISBN 81-7319-221-9, pp. 1087–1094. 
- [27] A. Goshtasby, W. A. Gruver. “Design of a single-lens stereo camera system”, *Pattern Recognition*, **26**:6 (1993), pp. 923–937. 
- [28] J. Gluckman, S. K. Nayar. “Planar catadioptric stereo: geometry and calibration”, *Proceedings IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. V. 1 (23–25 June 1999, Fort Collins, CO, USA), IEEE, 1999, ISBN 0-7695-0149-4, pp. 22–28. 
- [29] J. Gluckman, S. K. Nayar. “Catadioptric stereo using planar mirrors”, *International Journal of Computer Vision*, **44**:1 (2001), pp. 65–79. 
- [30] F. Endres, C. Sprunk, R. Kümmerle, W. Burgard. “A catadioptric extension for RGB-D cameras”, *2014 IEEE/RSJ International Conference on Intelligent Robots and Systems* (14–18 September 2014, Chicago, IL, USA), IEEE, 2014, ISBN 9781479969357, pp. 466–471. 
- [31] G. L. Mariottini, S. Scheggi, F. Morbidi, D. Prattichizzo. “Catadioptric stereo with planar mirrors: multiple-view geometry and camera localization”, *Visual Servoing via Advanced Numerical Methods*, Lecture Notes in Control and Information Sciences, vol. **401**, eds. Chesi G., Hashimoto K., Springer, London, 2010, ISBN 978-1-84996-088-5, pp. 3–21. 
- [32] K. Takahashi, S. Nobuhara. “Structure of multiple mirror system from kaleidoscopic projections of single 3D point”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **44**:9 (2022), pp. 5602–5617. 
- [33] Y. Zhao, Y. Chen, L. Yang. “Calibration of double-plane-mirror catadioptric camera based on coaxial parallel circles”, *Journal of Sensors*, **2022**:12 (2022), id. 7145400, 15 pp. 



Нейросетевая классификация видеороликов по малому числу кадров

Александр Владимирович **Смирнов**¹, Дмитрий Денисович **Парфенов**²,
Игорь Петрович **Тищенко**³

^{1,3} Институт программных систем им. А. К. Айламазяна РАН, Вельское, Россия

² ГУМРФ имени адмирала С.О. Макарова, Санкт-Петербург, Россия

Аннотация. В статье предложен метод нейросетевой классификации коротких видеороликов. Задача классификации рассматривается с точки зрения уменьшения числа требуемых операций для категоризации видеороликов. Предлагаемое решение заключается в использовании небольшого числа кадров (не более 10) для выполнения классификации при помощи самой лёгкой нейросетевой архитектуры семейства моделей ResNet. В ходе исследования создан собственный набор данных для обучения, состоящий из трёх классов: «animals», «cars» и «people». В результате получена точность классификации, равная 79%, а также сформирована база данных классифицируемых видеороликов и разработано приложение с элементами GUI для взаимодействия с классификатором и просмотра результатов.

Ключевые слова и фразы: Классификация видео, набор данных, нейронные сети, графический интерфейс пользователя

Для цитирования: Смирнов А.В., Парфенов Д.Д., Тищенко И.П. *Нейросетевая классификация видеороликов по малому числу кадров* // Программные системы: теория и приложения. 2024. Т. 15. № 4(63). С. 79–96.
https://psta.psiras.ru/read/psta2024_4_79-96.pdf

Введение

В настоящее время большую роль в обработке информации различного типа и происхождения играют нейронные сети. Одной из наиболее востребованных областей применения нейросетевых моделей является обработка графических данных, в частности изображений или видео.

Так, например, в работе [1] задача классификации видео рассматривается как операция присвоения некоторого индекса или метки конкретному видеоролику. Авторы используют собственную модель свёрточной нейронной сети (CNN), а также набор данных UCF11¹, состоящий из видеороликов с различными действиями людей. В результате была получена точность классификации действий, сравнимая с другими нейросетевыми моделями.

В другой работе [2] основное внимание уделялось поиску ключевых кадров на видео, что в последствии повышало точность классификации. Здесь авторы используют гибридную модель состоящую из свёрточной нейронной сети, технологии кластеризации пиков плотности временных сегментов (TSDPC)² и сети с долговременной краткосрочной памятью (LSTM)³. В итоге им удалось получить точность на наборах данных HMDB51⁴ и UCF101⁵ в 82.94% и 91.43% соответственно.

Статья [3] также посвящена поиску ключевых кадров. Разработанный метод основан на использовании шаблонов действий путем определения информативной области каждого кадра. Данный метод был протестирован на наборе данных UCF101 с использованием моделей ConvLSTM⁶ и VGG16⁷. В результате была получена точность классификации видео более 80%.

Достаточно важным фактором в задаче классификации видео может стать используемый для обучения набор данных. Именно от используемого набора данных зависит итоговая цель классификации. В статье [4] рассматривается создание набора данных из видеороликов, содержащих действия с разжиганием ненависти. Авторы отмечают, что подобные наборы данных существуют, но содержат в основном текстовую информацию, а

¹UCF11 - Action Recognition^{[URL](#)}

²Кластеризация на основе плотности (Пространственная статистика)^{[URL](#)}

³LSTM – сети долгой краткосрочной памяти^{[URL](#)}

⁴HMDB51^{[URL](#)}

⁵UCF101 - Action Recognition^{[URL](#)}

⁶ConvLSTM^{[URL](#)}

⁷VGG16 — нейросеть для выделения признаков изображений^{[URL](#)}

изображения и видео представлены очень редко. Вследствие чего, авторы вручную отобрали 43 часа видео для создания своего набора данных, на котором протестировали нейронную сеть и получили точность около 79%.

В работе [5] решается задача поиска признаков ненормального поведения пассажиров лифта. Эксперименты проводились на наборе видеоданных, содержащем четыре вида ненормального поведения: открывание двери, прыжки, пинки и блокировка двери. При использовании модифицированной модели PP-TSM удалось достичь точности классификации в 95%, что на 10% больше, чем было получено на стандартной модели PP-TSM⁸.

Статья [6] описывает метод обнаружения аномального поведения на видео. В данном случае под таким поведением подразумевается проявление жестокости с использованием оружия. Для обнаружения аномалий поведения авторы используют собственную модель нейронной сети J.QCNN, основанную на квантовой свёрточной нейронной сети (QCNN) [7] и глубокой свёрточной нейронной сети Javeria (DCNN). В результате была получена точность обнаружения более 90% по метрике F1-score⁹.

Следующая работа [8] посвящена распознаванию действий на видео с последующим расставлением временных меток. Здесь предлагается модель на основе метода двухпоточкового слияния информации с механизмами внимания (DSIFAM). При тестировании разработанной модели на наборах данных UCF11 и UCF50¹⁰ была получена точность в 91.2% и 89.1% соответственно.

Помимо анализа готовых видеофайлов, также ведутся работы по обработке потокового видео. Такой подход следует использовать, когда необходимо оперативно принять решение, например, быстро идентифицировать потенциально критические или опасные ситуации. Так в статье [9] рассматривается унифицированная и теоретически обоснованная адаптационная система для решения проблемы онлайн-классификации видеоданных, которая основана на математической модели теории классификации. Благодаря этому авторам удалось получать результат от нейронной сети гораздо быстрее без значительного ущерба для точности по сравнению с классическим подходом.

⁸High performance recognition 2D architecture PP-TSM^[URL]

⁹Что такое F-score и для чего он используется?^[URL]

¹⁰UCF50 - Action Recognition Data Set^[URL]

В статье [10] представлено исследование на тему классификации спортивных видео. Ключевой проблемой является природа данных видеороликов, которая заключается в присутствии большого количества динамических сцен. Для решения поставленных задач, авторы разрабатывают собственную нейросетевую модель, основанную на извлечении ключевых кадров и использующую принципы сиамских сетей¹¹. В результате новая модель продемонстрировала точность в 97% на наборе видеоданных высокого разрешения и 87% на наборе видеоданных низкого разрешения.

Анализ мультипликационных видеороликов представлен в работе [11]. Здесь авторы поставили задачу отфильтровать нежелательный контент, содержащий жестокие и откровенно сексуальные сцены. Они использовали предварительно обученную на наборе данных ImageNet¹² сверточную сеть в сочетании с сетью двунаправленной долговременной краткосрочной памяти на основе внимания (BiLSTM¹³). Эксперименты показали, что разработанная модель работает относительно лучше других сетей, достигая точности в 95.3%.

Нейросетевая обработка видеоданных находит применение в различных сферах. Благодаря высокой точности такого анализа некоторые результаты исследований можно применять уже сейчас в различных видеохостингах в качестве инструмента фильтрации и автоматизированной категоризации контента.

В настоящей работе предложен метод нейросетевой классификации коротких видеороликов по небольшому числу кадров. В рамках данной работы был создан собственный обучающий набор данных, состоящий из 3 классов: «animals», «cars» и «people». В результате была получена точность классификации, равная 79% по метрике F1-score, что немного ниже, чем в представленных выше работах. Однако прямое сравнение точности классификации нецелесообразно, так как использовались не только разные нейросетевые модели, но и разные наборы данных.

1. Цель и задачи исследования

Классификация изображений или объектов на изображениях предполагает отнесение целевого объекта к одному из рассматриваемых

¹¹ A Friendly Introduction to Siamese Networks^{URL}

¹² ImageNet^{URL}

¹³ Bidirectional LSTM^{URL}

классов. При классификации видеороликов задача классификации сводится к определению категории/класса видео. Однако видеоролик по сути является набором изображений/кадров, которые постепенно сменяют друг друга. В таком случае требуется определить класс большого множества отдельно взятых кадров, что может быть ресурсозатратно, так как в одной секунде стандартного видеоролика может быть от 30 кадров. Очевидным выходом из данной ситуации может быть использование лишь части кадров видеоролика.

Отличительной особенностью настоящего исследования является использование малого числа кадров видеоролика для выполнения его классификации. Тесты нейросетевого анализа показали, что для достижения удовлетворительной точности достаточно использовать около 10 ± 1 кадров видео.

Основной целью настоящего исследования является экспериментальная проверка метода нейросетевой классификации/категоризации видеороликов, который основан на анализе малого числа кадров без предварительной обработки. Метод считается условно работоспособным, если точность классификации видеороликов превышает 70%.

2. Используемая нейросетевая модель-классификатор

В качестве классификатора рассматривались следующие нейросетевые решения: ResNet [12], Faster R-CNN [13] и EfficientNet [14]. Среди представленных моделей была выбрана 18-слойная¹⁴ нейросетевая архитектура ResNet (рисунок 1), так как она предлагает баланс между глубиной, сложностью и производительностью.

Вероятно, для будущих итераций настоящего исследования будет использована 50-слойная¹⁵ архитектура ResNet. Такое решение было продиктовано тем, что 50-слойная архитектура показывает более высокие результаты точности, но также требует больше времени на обучение и классификацию. Тем не менее, 18-слойная архитектура ResNet способна показывать сопоставимые значения точности¹⁶. Реализация архитектуры ResNet-18 была выполнена на ЯП Python с использованием инструментария PyTorch¹⁷.

¹⁴[resnet18](#)^{URL}

¹⁵[resnet50](#)^{URL}

¹⁶[Image Classification on ImageNet](#)^{URL}

¹⁷[PyTorch documentation](#)^{URL}




Рисунок 1. Оригинальная архитектура ResNet18

3. Создание набора обучающих данных

Несмотря на наличие готовых наборов данных, для решения поставленных задач был создан собственный обучающий набор данных, состоящий из кадров видео с изображением неудач. Так называемое «видео с неудачей» обычно длится менее 10 секунд и содержит не более двух действий-неудач.

По мнению авторов настоящей статьи такой видеоролик с большой долей вероятности может быть успешно классифицирован, так как его содержание достаточно однозначно определено типом отображаемой неудачи. Однако из-за короткой продолжительности «видео с неудачей» часто собирают в тематические подборки, что, с одной стороны, упрощает поиск достаточного количества данных, а с другой стороны, затрудняет извлечение и обработку конкретного ролика.

3.1. Критерии определения классов

Для классификации видеоданных было сформировано три основных класса: «animals», «cars» и «people». Каждый класс определялся наличием на видео объекта конкретного типа, который непосредственно совершал неудачное действие или становился причиной неудач, а именно:

animals — класс включал сцены, где причиной неудачи было животное.

Сюда входили различные виды животных, от домашних до диких, которые по своей природе создавали ситуации, подходящие под определение «видео с неудачей»;

cars — класс включал сцены, в которых основной причиной возникновения неудачи являлся автомобиль. Подобные видеофрагменты охватывали инциденты с участием автомобилей, такие как аварии, неудачные маневры и другие события, связанные с транспортными средствами;

people — класс содержал видеоматериалы, где неудачные ситуации происходил исключительно с участием людей, без присутствия животных или автомобилей. Сцены данного типа включали падения, ошибки и другие инциденты, произошедшие с людьми.

3.2. Формирование набора данных

В первую очередь был осуществлён сбор исходного видеоматериала, сгруппированного по трем ранее описанным категориям. Видеоконтент был извлечён с популярного видеохостинга¹⁸ при помощи специально

¹⁸Видеохостинги: обзор самых популярных площадок^{url}

написанного скрипта на ЯП Python, который позволяет загружать видеофайлы различного формата и качества.

Процесс формирования набора данных состоял из следующих этапов:

Предварительная обработка видео. После получения исходных видеофайлов была проведена их предварительная обработка в программе Adobe Premiere Pro¹⁹. С помощью функции «определение сцен» (Scene Detection) видео было автоматически разделено на отдельные сцены. Этот шаг был необходим, так как скачанный видеоматериал представлял собой подборки «видео с неудачами», которые были смонтированы в единый видеоролик.

Разделение сцен на кадры. Полученные ранее сцены были разделены на кадры. В рамках данного процесса из каждой сцены были извлечены последовательности по 10 случайных кадров.

Верификация и очистка данных. На этом этапе был проведён тщательный анализ полученных кадров. Кадры проверялись на корректность и соответствие выбранным критериям категорий. Нерелевантные кадры (размытый кадр, чёрный экран и т.п.) были удалены из набора данных.

Расширение и балансировка набора данных. Завершающим этапом было расширение и балансировка набора данных. Поскольку изначально количество данных в каждой из категорий могло отличаться, были приняты меры по балансировке классов. Для этого использовались методы дополнения данных, включая операции поворота, изменения масштаба, а также другие трансформации, что позволило создать равномерно распределённый набор данных для последующего обучения нейронной сети.

Таким образом, процесс создания набора данных был тщательно структурирован и включал в себя этапы сбора, обработки, верификации и балансировки данных, что обеспечило получение качественного и надежного материала для дальнейшего обучения модели. Сформированный набор данных содержал по 2939 изображений/кадров для каждого из трёх классов.

4. Обучение нейронной сети

Обучение нейронной сети происходило при помощи трансферного метода. Трансферное обучение (TL)²⁰ — это метод машинного обучения, при котором модель, предварительно обученная выполнению одной

¹⁹ Professional video editing software | Adobe Premiere Pro[®]

²⁰ Что такое трансферное обучение?^{URL}

задачи, перенастраивается для выполнения другой, похожей на предыдущую. Обучение новой модели – это трудоемкий и длительный процесс, требующий большого количества данных, достаточной вычислительной мощности и прохождения нескольких итераций, прежде чем модель будет готова к запуску. Вместо этого применяется метод TL для переобучения существующих моделей, подготавливая их к решению смежных задач с использованием новых данных.

Метод TL был использован на предварительно обученной модели ResNet-18. Переобучение модели выполнялось в течении 25, 35 и 50 эпох. В таблице 1 представлены характеристики модели после обучения.

Таблица 1. Характеристики модели после обучения

Кол-во эпох	Точность на тренировочной выборке, %	Точность на валидационной выборке, %	Ошибка на тренировочной выборке	Ошибка на валидационной выборке
25	78.0	89.7	0.538	0.266
35	77.3	90.4	0.546	0.262
50	81.4	93.6	0.458	0.172

На рисунках 2 и 3 представлены графики точности и ошибки для обучения модели в течение 50 эпох.




Рисунок 2. График изменения значения точности, полученной на тренировочной и валидационной выборках в процессе обучения




Рисунок 3. График изменения значения ошибки, полученной на тренировочной и валидационной выборках в процессе обучения

5. Тестирование нейросети и подсчёт точности

Для тестирования обученной нейронной сети использовалось 35 видеороликов класса «animals», 39 видеороликов класса «cars» и 42 видеоролика класса «people». Из каждого видеоролика извлекалось 10 ± 1 кадров с равными временными промежутками. Принадлежность ролика к какому-либо классу определялась классом большинства его кадров, то есть, если более 50% кадров ролика имели некоторый класс, то и сам видеоролик относился к этому же классу.

Точность рассчитывалась по метрике F1-score с помощью функции `MulticlassF1Score`²¹ библиотеки `PyTorch Lightning`²². Также были подсчитаны значения Precision (точность)²³ и Recall (полнота)²⁴ для видеороликов и их кадров. В таблицах 2 и 3 представлены данные, полученные в ходе тестирования нейросети.

²¹[MulticlassF1Score^{URL}](#)

²²[Turn ideas into AI, Lightning fast^{URL}](#)

²³[MulticlassPrecision^{URL}](#)

²⁴[MulticlassRecall^{URL}](#)

Таблица 2. Данные о количестве используемых кадров и результирующей точности

Класс	Кол-во кадров	Precision	Recall	F1-score
animals	378	0.754	0.576	0.653
cars	427	0.899	0.733	0.807
people	456	0.602	0.824	0.696
Общее	1261	0.752	0.711	0.719

Таблица 3. Данные о количестве используемых видеороликов и результирующей точности

Класс	Кол-во видео	Precision	Recall	F1-score
animals	35	0.884	0.657	0.754
cars	39	0.916	0.846	0.880
people	42	0.666	0.857	0.750
Общее	116	0.822	0.786	0.794

6. Приложение для взаимодействия с классификатором и просмотра результатов

В рамках исследования, описанного в настоящей статье, было разработано приложение с графическим интерфейсом пользователя (GUI) для взаимодействия с классификатором, хранения и просмотра результатов классификации видеороликов. На рисунке 4 изображены основные окна приложения.

Разработанное приложение имеет следующий функционал:

Выбор видеофайла. Данная операция позволяет пользователю выбрать один или несколько видеофайлов с локального диска для их классификации. При нажатии на соответствующий элемент GUI открывается диалоговое окно для выбора файлов с расширениями .mp4, .avi и .mov. После завершения выбора выполняется анализ каждого файла. Результатом анализа является определённый класс/категория видео («animals», «cars» или «people»).

Взаимодействие с базой данных. При нажатии на соответствующий элемент GUI открывается новое окно, в котором отображается список видеофайлов, ранее классифицированных и сохранённых в базе данных. Далее отправляется запрос к базе данных для извлечения видео на основе выбранного фильтра. Пользователь может выбрать категорию для фильтрации или оставить фильтр на значении «All» для отображения всех видео. В окне предпросмотра отображается список видеофайлов с указанием их пути и категории.

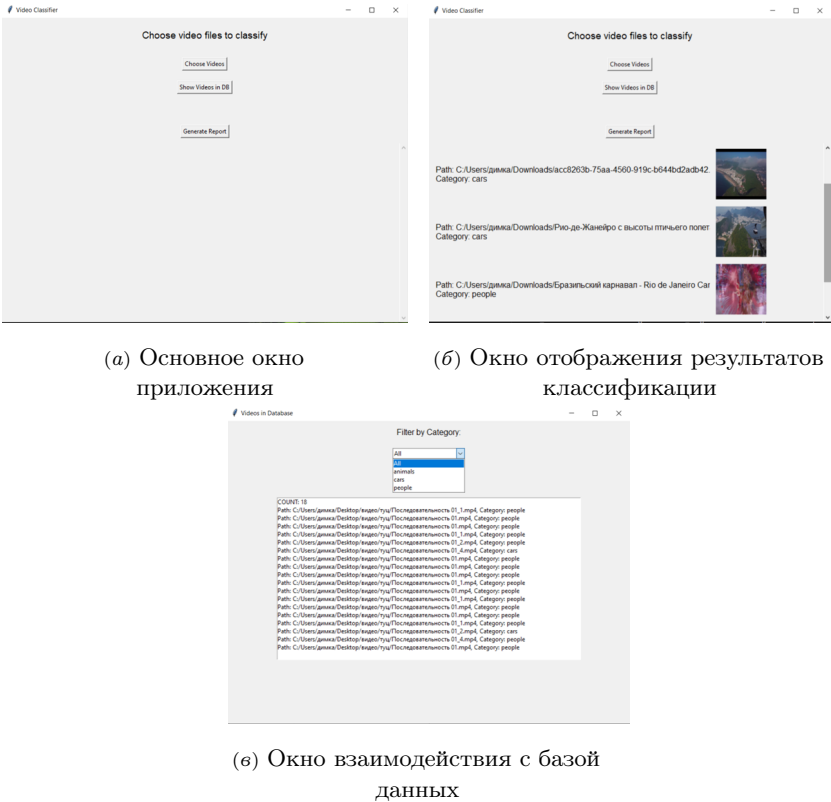


Рисунок 4. Приложение для взаимодействия с классификатором

Создание отчёта. При нажатии на на соответствующий элемент GUI приложение генерирует текстовый файл, который содержит сводку о количестве видео в каждой категории и полный список видео с указанием их категорий.

7. Анализ полученных результатов

В процессе тестирования нейронной сети была достигнута точность классификации более 79% (0.794), при этом точность классификации отдельного класса «cars» составила 88% (0.880). Данные показатели выше, чем заявленный порог в 70%, при достижении которого предложенный метод считается успешно проверенным и условно работоспособным.

Тем не менее, полученное значение точности меньше, чем в аналогичных работах, рассмотренных ранее. Это может указывать на наличие некоторых недостатков представленного метода классификации. Однако проводить прямое сравнение некорректно, так как использовались не только разные нейросетевые модели, но и разные наборы данных.

Стоит отметить, что в предложенном методе не используются какие-либо алгоритмы предобработки видео/кадров видео. Помимо этого, классификатором выступает относительно простая и лёгкая нейросетевая модель. Основная идея предложенного метода как раз и заключалась в том, чтобы выполнить классификацию/категоризацию видеороликов с использованием минимально возможных инструментария и данных.

Вывод

В результате проведённого исследования была достигнута точность классификации/категоризации видео более 79%, что доказывает жизнеспособность выбранного метода. Однако следует учесть тот факт, что при анализе видео сложной композиции или при классификации на более конкретные классы, вероятно, потребуются прибегнуть к дополнительным методам извлечения признаков или ключевых кадров, которые были описаны в рассмотренных статьях.

Список использованных источников

- [1] Duvvuri K., Kanisettypalli H., Jaswanth K., Murali K. *Video classification using CNN and ensemble learning* // 2023 9th International Conference on Advanced Computing and Communication Systems.– V. 1, ICACCS 2023 (17-18 March 2023, Coimbatore, India).– IEEE.– 2023.– ISBN 9798350397383.– Pp. 66–70.  ^{↑80}
- [2] Tang H., Ding L., Wu S., Ren B., Sebe N., Rota P. *Deep unsupervised key frame extraction for efficient video classification* // ACM Transactions on Multimedia Computing, Communications and Applications.– 2023.– Vol. 19.– No. 3.– id. 119.– 17 pp.  ^{↑80}
- [3] Savran K. R., Gan J. Q., Escobar J. J. *A novel keyframe extraction method for video classification using deep neural networks* // Neural Computing and Applications.– 2023.– Vol. 35.– No. 34.– Pp. 24513–24524.  ^{↑80}
- [4] Das M., Raj R., Saha P., Mathew B., Gupta M., Mukherjee A. *HateMM: a multi-modal dataset for hate video classification* // Proceedings of the International AAAI Conference on Web and Social Media.– 2023.– Vol. 17, Proceedings of the Seventeenth International AAAI Conference on Web and Social Media (ICWSM 2023).– Pp. 1014–1023.  ^{↑80}


- [5] Lei J., Sun W., Fang Y., Ye N., Yang S., Wu J. *A model for detecting abnormal elevator passenger behavior based on video classification* // Electronics.– 2024.– Vol. **13**.– No. 13.– id. 2472.– 15 pp.  ^{↑81}
- [6] Amin J., Anjum M. A., Ibrar K., Sharif M., Kadry S., Crespo R. G. *Detection of anomaly in surveillance videos using quantum convolutional neural networks* // Image and Vision Computing.– 2023.– Vol. **135**.– id. 104710.  ^{↑81}
- [7] Cong I., Choi S., Lukin M. D. *Quantum convolutional neural networks* // Nature Physics.– 2019.– Vol. **15**.– Pp. 1273–1278.  ^{↑81}
- [8] Jianmin H., Jie L. *A video action recognition method via dual-stream feature fusion neural network with attention* // International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems.– 2024.– Vol. **32**.– No. 04.– Pp. 673–694.  ^{↑81}
- [9] Trędowicz M., Struski Ł., Mazur M., Janusz S., Lewicki A., Tabor J. *PrAViC: probabilistic adaptation framework for real-time video classification*.– 2024.– 12 pp.  arXiv:  2406.11443 [cs.CV] ^{↑81}
- [10] Gao T., Zhang M., Zhu Y., Zhang Y., Pang X., Ying J., Liu W. *Sports video classification method based on improved deep learning* // Applied Sciences.– 2024.– Vol. **14**.– No. 2.– id. 948.– 13 pp.  ^{↑82}
- [11] Kanwal Y., Tabassam N. *An attention mechanism-based CNN-BiLSTM classification model for detection of inappropriate content in cartoon videos* // Multimedia Tools and Applications.– 2024.– Vol. **83**.– No. 11.– Pp. 31317–31340.  ^{↑82}
- [12] He K., Zhang X., Ren S., Sun J. *Deep residual learning for image recognition* // 2016 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2016 (27–30 June 2016, Las Vegas, NV, USA).– IEEE.– 2016.– ISBN 978-1-4673-8850-4.– Pp. 770–778. ^{↑83}
- [13] Ren S., He K., Girshick R., Sun J. *Faster R-CNN: towards real-time object detection with region proposal networks* // Proceedings of the 28th International Conference on Neural Information Processing Systems.– V. 1, NIPS'15 (December 7–12, 2015, Montreal, Canada), Cambridge: MIT Press.– 2015.– ISBN 9781510825024.– Pp. 91–99.  ^{↑83}
- [14] Tan M., Le Q. V. *EfficientNet: rethinking model scaling for convolutional neural networks* // Proceedings of the 36th International Conference on Machine Learning, ICML 2019 (9–15 June 2019, Long Beach, California, USA), Proceedings of Machine Learning Research.– vol. **97**.– ICML.– 2019.– ISBN 9781510886988.– Pp. 6105–6114. ^{↑83}

Поступила в редакцию	01.10.2024;
одобрена после рецензирования	23.10.2024;
принята к публикации	04.11.2024;
опубликована онлайн	20.11.2024.

Рекомендовал к публикации

к.т.н. Е. П. Куршев

Информация об авторах:



Александр Владимирович Смирнов

Младший научный сотрудник Лаборатории методов обработки и анализа изображений, Институт Программных Систем имени А. К. Айламазяна РАН. Научные интересы: компьютерное зрение; нейронные сети; робототехника; автоматизация и управление



0000-0002-7104-1462

e-mail:



Дмитрий Денисович Парфенов

Студент 3 курса по специальности «Прикладная информатика в экономике». Научные интересы: компьютерное зрение; нейронные сети



0000-0002-0369-0524

e-mail:



Игорь Петрович Тищенко

Кандидат технических наук, ИО директора, Институт Программных Систем имени А. К. Айламазяна РАН. Научные интересы: компьютерное зрение; нейронные сети; робототехника; автоматизация и управление



0000-0002-0369-0524

e-mail:

Вклад авторов: *А. В. Смирнов* – 55% (идея, методология, программное обеспечение, валидация, формальный анализ, расследование, написание черновой версии, доработка и редактирование, визуализация, наставничество, администрирование); *Д. Д. Парфенов* – 35% (сбор материала, курирование данных, написание черновой версии, доработка и редактирование, визуализация); *И. П. Тищенко* – 10% (администрирование, финансирование).

Декларация об отсутствии личной заинтересованности: *благополучие авторов не зависит от результатов исследования.*



Neural network classification of videos based on a small number of frames

Alexander Vladimirovich **Smirnov**¹, Dmitry Denisovich **Parfenov**²,
Igor Petrovich **Tishchenko**³

^{1,3} Ailamazyan Program Systems Institute of RAS, Ves'kovo, Russia

² Admiral Makarov State University of Maritime and Inland Shipping, St. Petersburg, Russia

Abstract. The article proposes a method for neural network classification of short videos. The classification problem is considered from the point of view of reducing the number of operations required to categorize videos. The proposed solution consists of using a small number of frames (no more than 10) to perform classification using the lightest neural network architecture of the ResNet family of models. As part of the work, a proprietary training dataset was created, consisting of three classes: “animals”, “cars” and “people”. As a result, a classification accuracy of 79% was obtained, a database of classified videos was formed, and an application with GUI elements was developed for interacting with the classifier and viewing the results. (*In Russian*).

Key words and phrases: Video classification, dataset, neural networks, graphical user interface

2020 *Mathematics Subject Classification:* 68T10; 68T45

For citation: Alexander V. Smirnov, Dmitry D. Parfenov, Igor P. Tishchenko. *Neural network classification of videos based on a small number of frames.* Program Systems: Theory and Applications, 2024, **15**:4(63), pp. 79–96. (*In Russ.*). https://psta.psiras.ru/read/psta2024_4_79-96.pdf

References

- [1] K. Duvvuri, H. Kanisettypalli, K. Jaswanth, K. Murali. “Video classification using CNN and ensemble learning”, *2023 9th International Conference on Advanced Computing and Communication Systems*. V. 1, ICACCS 2023 (17-18 March 2023, Coimbatore, India), IEEE, 2023, ISBN 9798350397383, pp. 66–70. [doi](#)
- [2] H. Tang, L. Ding, S. Wu, B. Ren, N. Sebe, P. Rota. “Deep unsupervised key frame extraction for efficient video classification”, *ACM Transactions on Multimedia Computing, Communications and Applications*, **19**:3 (2023), id. 119, 17 pp. [doi](#)
- [3] K. R. Savran, J. Q. Gan, J. J. Escobar. “A novel keyframe extraction method for video classification using deep neural networks”, *Neural Computing and Applications*, **35**:34 (2023), pp. 24513–24524. [doi](#)
- [4] M. Das, R. Raj, P. Saha, B. Mathew, M. Gupta, A. Mukherjee. “HateMM: a multi-modal dataset for hate video classification”, *Proceedings of the International AAAI Conference on Web and Social Media*, **17**, Proceedings of the Seventeenth International AAAI Conference on Web and Social Media (ICWSM 2023) (2023), pp. 1014–1023. [doi](#)
- [5] J. Lei, W. Sun, Y. Fang, N. Ye, S. Yang, J. Wu. “A model for detecting abnormal elevator passenger behavior based on video classification”, *Electronics*, **13**:13 (2024), id. 2472, 15 pp. [doi](#)
- [6] J. Amin, M. A. Anjum, K. Ibrar, M. Sharif, S. Kadry, R. G. Crespo. “Detection of anomaly in surveillance videos using quantum convolutional neural networks”, *Image and Vision Computing*, **135** (2023), id. 104710. [doi](#)
- [7] I. Cong, S. Choi, M. D. Lukin. “Quantum convolutional neural networks”, *Nature Physics*, **15** (2019), pp. 1273–1278. [doi](#)
- [8] H. Jianmin, L. Jie. “A video action recognition method via dual-stream feature fusion neural network with attention”, *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, **32**:04 (2024), pp. 673–694. [doi](#)
- [9] M. Trędowicz, Ł. Struski, M. Mazur, S. Janusz, A. Lewicki, J. Tabor. *PRaViC: probabilistic adaptation framework for real-time video classification*, 2024, 12 pp. [doi](#) [arXiv:2406.11443 \[cs.CV\]](#)
- [10] T. Gao, M. Zhang, Y. Zhu, Y. Zhang, X. Pang, J. Ying, W. Liu. “Sports video classification method based on improved deep learning”, *Applied Sciences*, **14**:2 (2024), id. 948, 13 pp. [doi](#)
- [11] Y. Kanwal, N. Tabassam. “An attention mechanism-based CNN-BiLSTM classification model for detection of inappropriate content in cartoon videos”, *Multimedia Tools and Applications*, **83**:11 (2024), pp. 31317–31340. [doi](#)
- [12] K. He, X. Zhang, S. Ren, J. Sun. “Deep residual learning for image recognition”, *2016 IEEE Conference on Computer Vision and Pattern Recognition*, CVPR 2016 (27-30 June 2016, Las Vegas, NV, USA), IEEE, 2016, ISBN 978-1-4673-8850-4, pp. 770–778.

- [13] S. Ren, K. He, R. Girshick, J. Sun. “Faster R-CNN: towards real-time object detection with region proposal networks”, *Proceedings of the 28th International Conference on Neural Information Processing Systems*. V. 1, NIPS’15 (December 7–12, 2015, Montreal, Canada), MIT Press, Cambridge, 2015, ISBN 9781510825024, pp. 91–99. 
- [14] M. Tan, Q. V. Le. “EfficientNet: rethinking model scaling for convolutional neural networks”, *Proceedings of the 36th International Conference on Machine Learning*, ICML 2019 (9-15 June 2019, Long Beach, California, USA), Proceedings of Machine Learning Research, vol. **97**, ICML, 2019, ISBN 9781510886988, pp. 6105–6114.



Building robust malware detection through conditional Generative Adversarial Network-based data augmentation

Elshan Baghirov^{1✉}

¹Institute of Information Technology, Baku, Azerbaijan

✉ elsenbagirov1995@gmail.com

Abstract. Malware detection is essential in cybersecurity, yet its accuracy is often compromised by class imbalance and limited labeled data. This study leverages conditional Generative Adversarial Networks (cGANs) to generate synthetic malware samples, addressing these challenges by augmenting the minority class.

The cGAN model generates realistic malware samples conditioned on class labels, balancing the dataset without altering the benign class. Applied to the CICMalDroid2020 dataset, the augmented data is used to train a LightGBM model, leading to improved detection accuracy, particularly for underrepresented malware classes.

The results demonstrate the efficacy of cGANs as a robust data augmentation tool, enhancing the performance and reliability of machine learning-based malware detection systems.

Key words and phrases: malware detection, Generative Adversarial Networks, machine learning, cybersecurity, data augmentation

2020 *Mathematics Subject Classification:* 68T10; 68T45

For citation: Elshan Baghirov. *Building robust malware detection through conditional Generative Adversarial Network-based data augmentation*. Program Systems: Theory and Applications, 2024, **15**:4(63), pp. 97–110.
https://psta.psiras.ru/read/psta2024_4_97-110.pdf

Introduction

Malware refers to malicious software intended to disrupt operations, deny access to services, collect personal data without the user's consent, gain unauthorized access to system resources, or engage in other harmful activities. The rapid advancement of information technology has led to an exponential rise in malware, making it one of the primary threats to computer security [1–3].

Malware detection methods can be broadly categorized into two main types: signature-based detection and behavior-based detection [4]. Signature-based detection relies on known malware patterns or signatures, making it highly effective at identifying previously encountered threats.

However, it struggles to detect novel or evolving malware variants. On the other hand, behavior-based detection analyzes the actions and behaviors of programs to identify malicious intent, even in unknown or zero-day threats. While behavior-based methods provide more robust protection against new threats, they often come with higher computational costs and the potential for false positives [4].

As malware continues to evolve and adapt, traditional detection methods face significant limitations. Signature-based methods cannot keep up with the sheer volume of new malware variants, while behavior-based methods, although more adaptive, can be resource-intensive and prone to inaccuracies in complex environments.

Moreover, the challenge of class imbalance—where benign files vastly outnumber malware samples—further complicates the development of effective detection models. This imbalance can lead to poor generalization, causing machine learning models to misclassify malware or fail to detect it altogether.

To address these issues, recent advancements have explored machine learning and data augmentation techniques, particularly Generative Adversarial Networks (GANs), to enhance malware detection [4–6]. By generating synthetic malware samples, GANs help balance the dataset and improve model performance in detecting underrepresented malware classes.

Our study focuses on employing cGANs to augment malware datasets, addressing the class imbalance problem and enhancing the detection capabilities of machine learning models.

This paper presents the following key contributions:

- **cGAN for Malware Data Augmentation:** conditional GANs are applied to generate synthetic malware samples, addressing the class imbalance issue in malware detection datasets.
- **Comparative Evaluation:** a thorough evaluation of machine learning models on imbalanced and augmented datasets is conducted, highlighting the benefits of cGAN-generated data in improving model performance.
- **Reproducible Methodology:** a detailed, reproducible experimental design for applying cGANs in cybersecurity is outlined to improve detection accuracy and reliability.

These contributions help advance malware detection by addressing class imbalance and improving model performance against diverse threats.

The paper is organized as follows:

Section 1 reviews existing malware detection techniques and the application of GANs for data augmentation.

Section 2 provides background on GANs and cGANs, explaining their structure and usage in data generation tasks.

Section 3 covers the experiments and results, including a description of the dataset, environmental setup, experimental design, and detailed results of the experiments.

Section 4 concludes the paper, summarizing key findings and proposing future research directions.

1. Related works

The paper by Nguyen et al. [6] explores the use of GANs for image-based malware classification. The study compares the performance of GANs with various other machine learning models, such as support vector machines (SVM) and random forest (RF). They focus on using the GAN model to classify different malware families and evaluate its efficacy for adversarial attacks.

The results show that GANs are effective at generating realistic images for classification but are less useful for adversarial attacks, as the generated images are easily distinguishable from real ones. The paper also highlights the strengths of auxiliary-classifier GANs (AC-GANs) in achieving competitive classification results when compared with other machine learning techniques.

Li et al. [7] introduce GMADV, a framework for Android malware classification and adversarial training, addressing challenges posed by anti-reverse engineering techniques and limited malware sample diversity. GMADV converts APK files into RGB Markov images and utilizes a VGG13 model for feature extraction and classification. Additionally, a GMM-GAN is employed to increase malware variant diversity by blending content and style features.

Experimental results show significant improvements in classification performance, with F1-scores exceeding 95%, demonstrating the framework's effectiveness in generating diverse malware variants and enhancing adversarial training.

Reilly et al. [5] explore the use of deep learning, specifically GANs, to enhance the robustness of image-based malware classification models against adversarial attacks. The study evaluates two image conversion techniques — byteplot and space-filling curves — using a ResNet-50 model to classify malware samples.

The results show that models trained with GAN-generated data exhibit significantly better resistance to adversarial attacks compared to those trained without GANs. The paper underscores how adversarial training, particularly with GANs, improves classification performance and robustness in malware detection tasks, highlighting the potential of GANs to bolster the security and accuracy of such systems despite certain limitations.

The provided papers present several limitations in the use of GANs for malware detection and classification. In the GMADV framework, while diverse malware variants are generated, the method still produces samples with similarities to the originals, limiting the creation of entirely novel behaviors, and the GMM-GAN may struggle with scalability for larger datasets.

The image-based malware classification model trained with GANs, as discussed by Li et al. [7], shows improved robustness against adversarial attacks but is limited to image-based transformations, leaving potential gaps in detecting more dynamic malware types, and the results are specific to the ResNet-50 model. Nguyen et al.'s work [6] also faces challenges, particularly with the computational expense and instability of GANs during training on large datasets, and the generated samples, while useful for classification, are less effective in adversarial settings where real and synthetic data are more easily distinguished.




FIGURE 1. General structure of GANs

These studies highlight the constraints of GAN-based approaches in scaling, sample diversity, and generalization across various malware types.

2. Background

2.1. Generative Adversarial Networks

First introduced by Ian Goodfellow and colleagues in 2014, GANs have swiftly evolved into a pivotal technique within machine learning and artificial intelligence [8]. Originally created for image generation tasks, GANs feature two neural networks in competition: a generator, which produces data resembling real-world examples, and a discriminator, which works to differentiate between real and generated data. This adversarial dynamic pushes both networks to improve iteratively.

The overall structure of GANs is depicted in Figure 1. Since their inception, GANs have been applied to a wide range of areas, such as data augmentation, artistic generation, and more recently, in cybersecurity for generating synthetic datasets that strengthen machine learning models against threats like malware. Despite their versatility, training GANs can be difficult, with issues like mode collapse and high computational demands being common challenges [9]. Nevertheless, their ability to generate highly realistic synthetic data marks GANs as a transformative tool in modern machine learning.




FIGURE 2. The architecture of cGAN [11]

2.2. Conditional Generative Adversarial Networks

CGANs represent a refined architecture of the standard Generative Adversarial Network, designed to generate synthetic data closely aligned with conditioned constraints. This architecture incorporates both a generator and a discriminator, functioning through an adversarial process to improve the realism and specificity of generated outputs [10, 11].

The interaction between G and D is depicted in Figure 2. Here, the generator aims to fool the discriminator by creating data indistinguishable from real data, while the discriminator learns to better differentiate real data from forgeries. This adversarial training not only enhances the generator's ability to mimic real data but also sharpens the discriminator's analytical skills.

The generator, denoted by G , takes as input a noise vector Z , typically sampled from a standard normal distribution, along with conditional labels Y . These labels ensure that the generated data, $G(X, Z)$, conforms to specific attributes required by the application, such as class characteristics in classification tasks. This approach allows the generator to produce not only realistic but also conditionally relevant data.

Simultaneously, the discriminator, D , evaluates the authenticity of both the data produced by G and the actual data samples from the training set. Each set of data, real or synthetic, is presented to D along with its corresponding labels Y , which helps D make more informed judgments.

TABLE 1. Original CICMalDroid2020 dataset size with categories

Category	Count
Adware	1,253
Banking	2,100
SMS malware	3,904
Riskware	2,546
Benign	1,795

The discriminator’s task is to distinguish between ‘real’ and ‘fake’ data, effectively identifying the synthetic outputs of the generator.

CGANs are particularly valuable for applications requiring data augmentation in imbalanced datasets, significantly contributing to the diversity and volume of training data. This makes them ideal for improving model performance and robustness in various domains, including cybersecurity and healthcare.

3. Experiments and results

3.1. Dataset description

The experiments in this study utilize the CICMalDroid2020 dataset [12, 13], which contains a balanced distribution of benign and malware samples. Distribution of file categories in this dataset has been shown in Table 1. However, to simulate a more challenging, imbalanced scenario that is common in real-world malware detection, we intentionally reduced the number of malware samples to 10% of their original count, ensuring that the percentage distribution of different malware categories was maintained to preserve sample diversity. This resulted in 980 malware samples and 1,795 benign samples. Using cGAN, we generated additional synthetic malware samples to increase the total malware count to 1,795, thereby balancing the dataset while preserving the diversity of malware categories for improved detection performance.

3.2. Experimental design

In this study, the cGAN was employed to address class imbalance by generating synthetic malware samples. The cGAN architecture used for

malware data augmentation is outlined in Algorithm 1. This algorithm consists of several key steps, which involve training both the generator and discriminator in a competitive setting.

Algorithm 1 cGAN for Malware Data Augmentation

- 1: **Input:** Real dataset X_{real} with class labels y_{real} , latent space dimension z , total number of epochs $epochs$, batch size m
- 2: **Output:** Trained generator G , trained discriminator D , generated synthetic malware samples X_{fake}
- 3: **Initialize** generator G and discriminator D with random weights
- 4: Set optimizer and hyperparameters
- 5: **for** each epoch t from 1 to $epochs$ **do**
- 6: **Step 1: Train the Discriminator D :**
- 7: Sample a batch of real data X_{real} and labels y_{real}
- 8: Sample a batch of random noise vectors z and malware labels y_{fake}
- 9: Generate synthetic samples $X_{fake} = G(z, y_{fake})$
- 10: Compute discriminator loss:

$$L_{real} = D(X_{real}, y_{real}), \quad L_{fake} = D(X_{fake}, y_{fake})$$

- 11: Update D by minimizing combined loss:

$$L_D = \frac{1}{2}(L_{real} + L_{fake})$$

- 12: **Step 2: Train the Generator G :**
- 13: Sample new batch of random noise vectors z and malware labels y_{fake}
- 14: Generate synthetic samples $X_{fake} = G(z, y_{fake})$
- 15: Compute generator loss:

$$L_G = D(G(z, y_{fake}), y_{fake})$$

- 16: Update G by maximizing L_G
 - 17: **end for**
 - 18: **Step 3: Generate new malware samples:**
 - 19: Sample random noise z and malware labels $y_{fake} = 1$
 - 20: Generate synthetic malware samples $X_{synthetic} = G(z, y_{fake})$
 - 21: Combine $X_{synthetic}$ with the original dataset
-

The process begins by initializing the generator G and the discriminator D with random weights. In each epoch, the discriminator is trained first by sampling batches of real data, along with the corresponding class labels, and comparing them with synthetic data generated by the generator.

The discriminator's loss is calculated based on its ability to distinguish between real and fake samples, and the model is updated by minimizing the combined loss from both real and synthetic data, as outlined in Step 1 of Algorithm 1.

Following this, the generator is trained to improve the realism of the synthetic data. It does this by generating new samples from random noise vectors, conditioned on malware labels, and receiving feedback from the discriminator. The generator's loss is calculated based on how well it can "fool" the discriminator into classifying synthetic data as real, and it is updated by maximizing its loss function, as described in Step 2.

The final step, Step 3 of Algorithm 1, involves generating new synthetic malware samples by sampling random noise and malware labels. These newly generated samples are combined with the original dataset to balance the distribution of benign and malware samples.

The iterative adversarial process between the generator and discriminator allows the model to refine the quality of the synthetic malware samples over multiple epochs, ultimately creating a balanced dataset that enhances the performance of the machine learning models trained on it. This approach effectively addresses the issue of class imbalance in malware detection tasks, enabling models to better detect minority class malware instances.

3.3. Enviromental setup

The experiments in this study were conducted on the Kaggle platform, leveraging its computational resources for efficient model training and evaluation. Various configurations were used, including CPU (4 cores, 30 GB RAM) for data processing, and GPU (Nvidia Tesla P100 or T4) with up to 2 GPUs, 4 CPU cores, and 29 GB RAM for deep learning tasks. The TPU 1VM setup, with 96 CPU cores and 330 GB RAM, provided the highest computational power, ensuring efficient handling of large-scale deep learning workloads and producing reliable results.

3.4. Results and discussions

The initial experiments conducted on the imbalanced dataset and the subsequent trials on the augmented dataset using LightGBM and other machine learning models yielded significant insights, presented in Table 2 and Table 3. Corresponding confusion matrices for LightGBM's

TABLE 2. Comparison of the models on the imbalanced dataset

Model	Accuracy	Precision	Recall	F1-Score
LightGBM	0.9153	0.8958	0.8643	0.8798
Random Forest	0.9189	0.9096	0.8593	0.8837
KNN	0.8559	0.8083	0.7839	0.7959
Logistic Regression	0.7532	0.7460	0.4724	0.5785

TABLE 3. Comparison of the models on the augmented dataset

Model	Accuracy	Precision	Recall	F1-Score
LightGBM	0.9568	0.9619	0.9541	0.9579
Random Forest	0.9513	0.9666	0.9378	0.9520
KNN	0.8955	0.9041	0.8919	0.8980
Logistic Regression	0.8078	0.8816	0.7243	0.7953

TABLE 4. Confusion matrix for the imbalanced dataset using LightGBM

		Predicted	
		Negative	Positive
Actual	Negative	335	21
	Positive	16	183

TABLE 5. Confusion matrix for the augmented dataset using LightGBM

		Predicted	
		Negative	Positive
Actual	Negative	335	13
	Positive	16	354

performance on both datasets are detailed in Table 4 and Table 5.

In the comparative analysis of machine learning models trained on both imbalanced and augmented datasets, LightGBM consistently emerged as the standout performer. Initially, on the imbalanced dataset, LightGBM demonstrated a strong capability with an accuracy of 91.53%, precision of 89.58%, and an F1-score of 87.98%. This performance indicates a robust ability to handle class imbalances effectively, particularly in identifying the

minority class malware samples.

Upon augmenting the dataset to mitigate class imbalance, LightGBM's performance further excelled, leading to even higher metrics with an accuracy of 95.68%, precision of 96.19%, and an outstanding F1-score of 95.79%. The most notable improvement was observed in its recall, which reached 95.41%, underscoring the model's enhanced ability to correctly identify almost all malware samples in the augmented dataset.

4. Conclusions and future works

In this study, we utilized cGAN to address the challenge of class imbalance in malware detection. By intentionally reducing the number of malware samples to 10% of their original count, we simulated a real-world imbalanced scenario. Using cGAN, we augmented the minority class and balanced the dataset.

The results showed that after balancing the dataset, the LightGBM model achieved a high accuracy of 95.68%, with improvements in precision (96.19%), recall (95.41%), and F1-score (95.79%). These metrics indicate that LightGBM is highly effective when paired with cGAN-generated synthetic data, outperforming other models in terms of detecting underrepresented malware samples. This demonstrates the strength of LightGBM in handling large-scale, imbalanced datasets when supplemented with generative techniques like cGAN.

There are several key directions for future research based on the results of this study. First, optimizing the models with more advanced data augmentation techniques, such as Variational Autoencoders (VAEs) or Generative Pretrained Transformers (GPT), could further enhance the detection of complex malware patterns. Additionally, implementing these augmented models in real-time malware detection systems would provide valuable insights into their performance in dynamic and evolving environments.

Another important area is cross-dataset validation, where the models could be tested across different malware datasets to assess their generalizability and robustness in varied attack scenarios. Furthermore, investigating hybrid approaches, such as combining multiple machine learning models or ensemble methods, could further improve detection accuracy while reducing false positives and negatives.

Finally, it is essential to evaluate the resilience of these models against adversarial attacks, ensuring that the augmented data not only improves detection rates but also enhances the security and reliability of the entire detection system. Addressing these areas will contribute to the advancement of more robust and effective malware detection frameworks.

References

- [1] D. O. Won, Y. N. Jang, S. W. Lee. “PlausMal-GAN: Plausible malware training based on generative adversarial networks for analogous zero-day malware detection”, *IEEE Transactions on Emerging Topics in Computing*, **11**:1 (2023), pp. 82–94.  [↑98](#)
- [2] E. Baghirov. “A comprehensive investigation into robust malware detection with explainable AI”, *Cyber Security and Applications*, **3** (December 2025), id. 100072.  [↑98](#)
- [3] E. Baghirov. “Techniques of malware detection: Research review”, *2021 IEEE 15th International Conference on Application of Information and Communication Technologies*, AICT 2021 (13–15 October 2021, Baku, Azerbaijan), IEEE, 2021, ISBN 978-1-6654-3641-0/21, pp. 1–6.  [↑98](#)
- [4] S. Jang, S. Li, Y. Sung. “Generative adversarial network for global image-based local image to improve malware classification using convolutional neural network”, *Applied Sciences*, **10**:21 (2020), id. 7585, 14 pp.  [↑98](#)
- [5] C. Reilly, S. O Shaughnessy, C. Thorpe. “Robustness of image-based malware classification models trained with generative adversarial networks”, *EICC’23: Proceedings of the 2023 European Interdisciplinary Cybersecurity Conference* (14–15 June 2023, Stavanger, Norway), ACM, New York, 2023, ISBN 978-1-4503-9829-9, pp. 92–99.  [↑98, 100](#)
- [6] H. Nguyen, F. Di Troia, G. Ishigaki, M. Stamp. “Generative adversarial networks and image-based malware classification”, *Journal of Computer Virology and Hacking Techniques*, **19** (2023), pp. 579–595.  [↑98, 99, 100](#)
- [7] S. Li, Z. Tang, H. Li, J. Zhang, H. Wang, J. Wang. “GMADV: An android malware variant generation and classification adversarial training framework”, *Journal of Information Security and Applications*, **84** (August 2024), id. 103800.  [↑100](#)
- [8] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio. “Generative adversarial nets”, *Advances in Neural Information Processing Systems 27*, NIPS 2014 (8–13 December 2014, Montreal, Canada), 2014, ISBN 9781510800410, 9 pp.  [↑101](#)
- [9] R. Yuwana, F. Fauziah, A. Heryana, D. Krisnandi, R. S. Kusumo, H. F. Pardede. “Data augmentation using adversarial networks for tea diseases detection”, *Jurnal Elektronika dan Telekomunikasi*, **20**:1 (2020), pp. 29–35.  [↑101](#)

- [10] M. Mirza, S. Osindero. *Conditional generative adversarial nets*, 2014, 7 pp. arXiv:1411.1784~[cs.LG] ↑¹⁰²
- [11] M. Iwayama, S. Wu, C. Liu, R. Yoshida. “Functional output regression for machine learning in materials science”, *Journal of chemical information and modeling*, **62**:20 (2022), pp. 4837–4851. doi ↑¹⁰²
- [12] S. Mahdavifar, A. F. A. Kadir, R. Fatemi, D. Alhadidi, A. A. Ghorbani. “Dynamic android malware category classification using semi-supervised deep learning”, *2020 IEEE Intl Conf on Dependable, Autonomic and Secure Computing, Intl Conf on Pervasive Intelligence and Computing, Intl Conf on Cloud and Big Data Computing, Intl Conf on Cyber Science and Technology Congress, DASC/PiCom/CBDCOM/CyberSciTech* (17–22 August 2020, Calgary, AB, Canada), 2020, ISBN 978-1-7281-6609-4, pp. 515–522. doi ↑¹⁰³
- [13] S. Mahdavifar, D. Alhadidi, A. A. Ghorbani. “Effective and efficient hybrid android malware classification using pseudo-label stacked auto-encoder”, *Journal of Network and Systems Management*, **30** (2022), id. 22, 34 pp. doi ↑¹⁰³

Received	05.12.2024;
approved after reviewing	07.12.2024;
accepted for publication	07.12.2024;
published online	10.12.2024.

Recommended by

prof. S. M. Abramov

Information about the author:

Elshan Baghirov



Elshan Baghirov is a PhD candidate at the Institute of Information Technology, Baku, Azerbaijan. His research focuses on machine learning, and cybersecurity, with a particular emphasis on malware detection. He is also a data scientist at Kapital Bank OJSC, where he applies advanced analytics and predictive modeling to real-world business problems. His scientific interests include artificial intelligence, deep learning, and cybersecurity.



0000-0002-5940-4136

e-mail:

The author declare no conflicts of interests.



Построение надёжной системы обнаружения вредоносного ПО с использованием генеративных состязательных сетей для увеличения данных

Эльшан Багиров¹

¹ Институт Информационных Технологий, Баку, Азербайджан

[✉] elsenbagirov1995@gmail.com

Аннотация. Обнаружение вредоносного ПО является важным аспектом кибербезопасности, однако его точность часто снижается из-за дисбаланса классов и ограниченного количества размеченных данных. В данном исследовании используются генеративные состязательные сети с условными данными (conditional Generative Adversarial Networks, cGAN) для генерации синтетических образцов вредоносного ПО, что позволяет решить эти проблемы за счёт увеличения объёма данных в классе меньшинства.

Модель cGAN генерирует реалистичные образцы вредоносного ПО, основываясь на метках классов, балансируя набор данных без изменения класса безопасных образцов. Применённый к набору данных CICMalDroid2020, увеличенный объём данных используется для обучения модели LightGBM, что приводит к повышению точности обнаружения, особенно для слабо представленных классов вредоносного ПО.

Результаты демонстрируют эффективность использования cGAN в качестве надёжного инструмента для увеличения объёма данных, что улучшает производительность и надёжность систем обнаружения вредоносного ПО на основе машинного обучения.

Ключевые слова и фразы: Обнаружение вредоносного ПО, Генеративные Состязательные Сети, Машинное Обучение, Кибербезопасность, Увеличение Объёма Данных

Для цитирования: Багиров Э. *Построение надёжной системы обнаружения вредоносного ПО с использованием генеративных состязательных сетей для увеличения данных* // Программные системы: теория и приложения. 2024. Т. 15. № 4(63). С. 97–110. https://psta.psisras.ru/read/psta2024_4_97-110.pdf



Аналитический обзор архитектур, моделей, методов и алгоритмов для локализации и трекинга неригидных объектов

Григорий Глебович **Гриценко**¹, Виталий Петрович **Фраленко**²

^{1,2}Институт программных систем им. А. К. Айламазяна РАН, Веськово, Россия

Аннотация. Компьютерное зрение требует анализа видеопотока, включающего извлечение информации из кадров, обнаружение определенных объектов и сбор данных о них. После обнаружения часто требуется выполнять *трекинг* или слежение за объектами в видеопотоке. *Неригидность* или изменчивость формы препятствует анализу объектов, усложняет их обнаружение и трекинг и ухудшает локализацию.

В обзоре рассмотрены архитектуры, модели, методы и алгоритмы, применяемые на практике при обнаружении и отслеживании неригидных объектов, и выделены перспективные решения.

Ключевые слова и фразы: неригидный объект, искусственная нейронная сеть, глубокое обучение, локализация объектов, трекинг объектов, обнаружение пожаров и задымлений, анализ медицинских изображений

Благодарности: Исследование выполнено за счет *гранта Российского научного фонда № 22-11-20001*  и гранта в форме субсидии из областного бюджета организациям Ярославской области.

Для цитирования: Гриценко Г. Г., Фраленко В. П. Аналитический обзор архитектур, моделей, методов и алгоритмов для локализации и трекинга неригидных объектов // Программные системы: теория и приложения. 2024. Т. 15. № 4(63). С. 111–151. https://psta.psir.ru/read/psta2024_4_111-151.pdf

Введение

Обнаружение объектов – фундаментальная задача компьютерного зрения, направленная на выделение конкретных элементов из изображений или видеопотоков, таких как люди, транспортные средства и здания. Эта технология находит широкое применение в различных сферах, включая автономное вождение, медицинскую диагностику, системы безопасности и развлекательные приложения.

Ключевым элементом обнаружения объектов является классификация, то есть определение типа объекта на основе его визуальных характеристик. Алгоритмы машинного обучения анализируют пиксели изображения, распознавая формы, цвета, текстуры и другие особенности, чтобы, например, выделить пешехода на фоне или отличить автомобиль от велосипеда. Однако обнаружение объектов является лишь первым шагом. В динамике, когда объекты движутся, изменяют форму или исчезают из поля зрения, требуется более сложная технология – трекинг.

Трекинг – задача отслеживания объектов в видеопотоке с течением времени. Требуется не только определить местоположение объекта в каждом кадре, но и проследить его траекторию, скорость и направление движения. Точность трекинга напрямую зависит от уровня ригидности объекта, то есть его способности сохранять форму и геометрию.

Ригидные объекты, такие как автомобили или здания, легко отслеживаются, поскольку их внешние изменения незначительны. Неригидные объекты представляют собой более сложную задачу для алгоритмов трекинга. Эти объекты могут изменять форму, распадаться на части, сливаться с фоном или полностью исчезать из поля зрения. Например, облака, туман и дым, которые кажутся статичными, но на самом деле постоянно меняют свою форму и структуру. Огонь, пожары и взрывы – примеры неригидных объектов, которые сложно отследить из-за динамичного характера пламени, дыма и взрывной волны.

Алгоритмы трекинга должны учитывать деформацию объекта, его взаимодействие с окружающей средой, изменение освещения и множество других факторов, влияющих на его внешний вид. Решение этих задач имеет ключевое значение для совершенствования систем автономного вождения, прогнозирования стихийных бедствий, мониторинга окружающей среды и многих других областей. Дополнительные трудности включают изменение размера объекта, перекрытия объектов, появление и исчезновение объектов из поля зрения. Новые технологии, такие как глубокое обучение и 3D-трекинг, позволяют повысить точность и информативность трекинга неригидных объектов.

Цель настоящей работы заключается в сравнительном анализе архитектур, моделей, методов и алгоритмов обнаружения и трекинга неригидных объектов с выделением наиболее перспективных из них.

1. Способы повышения эффективности локализации неригидных объектов в кадре

1.1. Применение метода выравнивания гистограмм, модулей СВМ и алгоритма CAPAN

Высокая влажность в морской среде ухудшает видимость. Поэтому для улучшения обнаружения пожара на судне с помощью камер в работе [1] предложен метод выравнивания гистограмм. Он позволяет повысить точность идентификации и локализации опасных неригидных объектов, таких как огонь и дым. Метод заключается в регулировании яркости изображений путем равномерного распределения значений по каналам RGB. При увеличении масштаба изображения его идентичность сохраняется. Анализ яркости изображений в исследовании [1] проводился с использованием функции кумулятивной плотности (*cumulative density*). Модель, обученная на обширном наборе данных, включающем более 25 тысяч изображений судов, достигла впечатляющей точности, превышающей 99%; для сравнения – 94% получено в ранней работе тех же авторов [2].

Авторы статьи [3] предлагают вариант усовершенствования архитектуры YOLOv5 путем добавления трех модулей сверточного блочного анализа (СВМ, Convolutional Block Attention Modules) [4]. Для сбора детальной информации о градиентном потоке и повышения точности обнаружения небольших объектов использован модуль C2f ^{URL} вместо стандартного модуля C2. Модуль C2f реализуется двумя сегментационными головками (от англ «segmentation heads»), которые обучаются предсказывать семантические сегментационные маски для входного изображения. По своей природе модуль C2f является более быстрой реализацией модуля C2.

Эксперименты показали, что алгоритм достиг 82.36% mAP50 для обнаружения пожаров. Использование данных с маркировкой объектов, похожих на огонь, снизило количество ложных срабатываний. Модуль СВМ улучшил mAP50 на 2.09%, а модуль C2f – на 1.35%. Объединение обоих модулей привело к увеличению mAP50 на 2.72%. В свою очередь, эксперименты по маркировке данных, подобных огню, показали, что возможно снизить количество ложных срабатываний на 3.7% для выбросов из дымовых труб и на 2.45% для облаков. Интеграция модулей СВМ и C2f улучшает способность сети различать объекты, связанные с пожарами.

В статье [5] предложен алгоритм CAPAN (Channel Attention Path Aggregation Network), который позволяет искусственной нейронной

сети (ИНС) фокусироваться на особенностях канала с информацией о переднем плане. SARAN предлагает более эффективное объединение функций, используя механизм внимания к каналу (ECA, Efficient Channel Attention). Алгоритм, предложенный в статье, показал лучшую среднюю точность обнаружения и распознавания по сравнению с другими методами. Результаты тестирования показали улучшение точности распознавания на 8.3% для датасета Flame и на 2.1% для датасета Smoke по сравнению с базовой моделью.

1.2. Искусственная нейронная сеть со слоем Fire-RPG

В работе [6] представлен комбинированный подход к решению задачи раннего обнаружения возгораний в условиях городской среды. В рамках подхода рассматриваются ИНС Fire-RPG, метрика Wise-IoU, блоки для построения сетей CBAM [4], RepVGG [7] и GhostV2 [8]. В качестве основы Fire-RPG взята ИНС YOLOv8. Она состоит из трех основных частей: «позвоночника» (*backbone*), «шей» (*neck*) и «головной части» (*head*), каждая из которых включает модули для локализации ключевых объектов.

Модули «позвоночника» и «шей» содержат такие части как C2f, CBS и SPPF, которые обеспечивают эффективное представление объектов. CBS является базовым сверточным модулем, а C2f использует поэтапный метод повышения обучаемости и упрощения модели. SPPF (Spatial Pyramid Pooling Fast), в свою очередь, представляет собой специальный модуль для объединения знаний об объектах разного размера, оптимизированный для снижения вычислительных затрат.

«Шея» построена на структурах FPN (Feature Pyramid Network) и PAN (Path Aggregation Network), которые генерируют карты объектов разного масштаба с семантической и функциональной информацией. Эти структуры расширяют возможности обнаружения объектов разного размера. «Головная» часть состоит из трех слоев обнаружения объектов, которые выполняют операции вывода на основе информации, полученной от «шей». Эти слои определяют местоположение объектов и их категории.

Для раннего обнаружения пожаров добавлен дополнительный слой обнаружения сверхмалых объектов – Fire-RPG, переход к обнаружению таких объектов снижает эффект от того, что целевые объекты неригидны. Этот слой увеличивает вычислительные затраты, что может повлиять на способность обнаружения в реальном времени. Пять высокочувствительных по используемым ресурсам модулей C2f заменены модулями GhostV2C2f (предложены авторами этой же работы).

Модули CBS заменены высокопроизводительными блоками RepVGG для более эффективного извлечения характеристик. В магистраль добавлены три блока СВМ, использующие пространственную информацию для выделения средних и мелких объектов. RepVGG применяет метод структурной репараметризации для трансформации сложных нейронных сетей в более простые и эффективные эквивалентные структуры. В работе приводится оптимизированная структура GhostNet и внедрен механизм внимания (*attention mechanism*) DFC (Decoupled Fully Connected). Полностью подключенные слои генерируют карты внимания с глобальным полем восприятия. Механизм внимания DFC и модуль Ghost работают в параллельных ветвях ИНС. Механизм DFC использует понижающую дискретизацию для сжатия карты объектов.

Авторами работы предложена функция потерь Wise-IoU (WIoU) для решения задачи обнаружения пожаров. Эта функция потерь направлена на снижение влияния низкокачественных данных и имеет три версии, каждая из которых ориентирована на различные типы якорных прямоугольников (*anchor boxes*). WIoU использует механизм внимания на расстоянии (*distance attention mechanism*). Второй важный фактор WIoU – коэффициент усиления по немонотонному градиенту (*non-monotonic gradient gain coefficient*), который определяет как функция потерь реагирует на низкокачественные и высококачественные якорные прямоугольники. Сравнение различных функций потерь приведено в таблице 1.

Таблица 1. Сравнение функций потери (в процентах)

Модель	Точность	Полнота	mAP50	mAP50-95
YOLOv8s-CIoU	84.8	70.9	79.1	47.7
YOLOv8s-GIoU	85.1	70.4	79.6	47.6
YOLOv8s-DIoU	82.3	71.6	79.8	47.5
YOLOv8s-SIoU	82.6	71.4	79.1	47.2
YOLOv8s-EIoU	82.5	71.9	79.2	47.4
YOLOv8s-WIoUv1	85.1	70.3	79.0	47.0
YOLOv8s-WIoUv2	84.7	70.7	79.6	47.6
YOLOv8s-WIoUv3	84.2	71.4	80.0	47.3

Механизмы внимания в нейронных сетях позволяют выделять ключевые функции на картах объектов и создавать карты внимания. Эти карты внимания затем умножаются на исходные карты объектов, что позволяет усилить информацию об этих объектах. Существует несколько типов механизмов внимания, каждый из которых имеет свои особенности. Например, SE Attention (Squeeze-and-Excitation Attention) фокусируется на канале, но не учитывает пространственную информацию. Это делает

его простым в вычислениях, но менее эффективным для задач, требующих учета пространственной информации. CA Attention (Channel and Spatial Attention), напротив, учитывает как канал, так и пространственную информацию, но может быть сложным в вычислениях и замедлять процесс обнаружения объектов. Канальное внимание фокусируется на том, *что* важно в данных, а пространственное внимание – на том, *где* эта информация находится.

СВАМ, который ранее уже упоминался в настоящем исследовании, сочетает преимущества обоих подходов, обеспечивая баланс между канальным и пространственным вниманием. Он имеет простую структуру и низкие затраты на вычисления, что делает его эффективным для широкого спектра задач.

Результаты работы показывают, что СВАМ значительно повышает mAP50 до 80.0% и mAP50-95 до 48.0%, по сравнению с базовой моделью YOLOv8s, имеющей показатели mAP50 и mAP50-95, равные соответственно 79.1% и 47.7%. Значения показателей эффективности работы механизмов внимания представлены в таблице 2.

Таблица 2. Сравнение механизмов внимания (в процентах)

Модель	Точность	Полнота	mAP50	mAP50-95
YOLOv8s	84.8	70.9	79.1	47.7
YOLOv8s-SE	82.7	71.7	79.6	47.9
YOLOv8s-SA [9]	84.6	70.4	79.4	48.0
YOLOv8s-ECA [10]	82.1	71.1	79.2	47.4
YOLOv8s-CA	83.5	71.5	79.8	48.0
YOLOv8s-SimAM [11]	82.0	71.1	79.3	47.8
YOLOv8s-CBAM	83.2	72.9	80.0	48.0

Fire-RPG демонстрирует высокую точность обнаружения малых и трудноразличимых объектов, таких как слабое пламя и тонкий дым. YOLOv8s пропускает эти объекты и имеет более низкие показатели достоверности. Для оценки способностей моделей YOLOv8s и Fire-RPG к обобщению, они проверены на трех наборах данных.

Набор данных D-Fire включает изображения дикой природы с двумя видами объектов: дымом и пламенем. Набор данных ForestFire сосредоточен на лесных сценах и усовершенствован с помощью методов аугментации данных. Набор данных DFS содержит изображения пожаров из различных сцен с тремя метками: пламя, дым и «другое».

Результаты испытаний показали, что модель Fire-RPG продемонстрировала лучшие результаты по сравнению с YOLOv8s на всех трех наборах данных. В частности, Fire-RPG улучшила показатель mAP50 более чем

на 1% на всех наборах данных. На наборе данных DFS улучшение показателя mAP50-95 составило 0.8%, что свидетельствует о высокой способности модели к обобщению. Кроме того, модель Fire-RPG показала лучшую эффективность обнаружения по сравнению с обычными сверточными нейронными сетями (СНС), достигнув показателя mAP50 79.2%.

Модель Fire-RPG подходит для использования в городских системах пожарной сигнализации, где она может быть применена для раннего обнаружения пожаров, что способствует повышению скорости реагирования и безопасности. Результаты работы СНС представлены в таблице 3.

Таблица 3. Результаты работы СНС (в процентах)

Набор данных	Модель	Точность	Полнота	mAP50	mAP50-95
D-Fire	Fire-RPG	78.7	71.7	79.2	46.1
	YOLOv8s	76.6	72.9	78.0	45.6
ForestFire	Fire-RPG	63.2	60.0	63.1	27.8
	YOLOv8s	63.0	58.5	61.8	27.5
DFS	Fire-RPG	61.2	49.2	54.9	28.1
	YOLOv8s	60.7	48.8	53.8	27.3

1.3. Дистилляция знаний для улучшения обнаружения пожаров

В работе [12] представлен подход ILKDG (Intermediate Layer Knowledge Distillation with Gram Matrix-based Feature Flow) к извлечению знаний, основанный на распространении знаний (*knowledge propagation*) между слоями. Для этого используется матрица потока процедур решения (FSP, Flow of Solution Procedure), основанная на матрице Грама и коэффициенте корреляции Пирсона, что позволяет дистиллировать знания. Авторы предлагают интегрировать YOLOv7 с методами дистилляции знаний и использовать новый подход для улучшения обнаружения пожаров. При дистилляции знаний модель меньшего размера, обученная повторять поведение тяжелой и точной модели-учителя, достигает схожих с ней показателей, существенно выигрывая в размере и скорости за счет упрощенной архитектуры.

В отличие от предыдущих работ, в предлагаемом подходе для построения матрицы Грама используются признаки из разных слоев. ILKDG сопоставлен с классическими и современными подходами на специально созданном наборе данных. Обнаружено, что ILKDG существенно повышает точность и скорость обнаружения пожаров: значение mAP50 улучшено на 2.9%, а mAP50-95 – на 2.7% без необходимости изменения параметров сети. Дополнительные данные представлены в таблице 4.

Таблица 4. Результаты оценки на тестовом наборе данных (в процентах)

Модель/Подход	Точность	Полнота	mAP50	mAP50-95
Teacher (YOLOv7x)	88.1	84.2	89.5	63.7
Student (YOLOv7)	83.3	81.9	84.6	60.4
KD	84.4	82.4	85.9	61.8
FitNet	84.7	82.2	86.0	61.1
FGD	85.0	82.1	85.4	62.1
KD++	84.6	82.3	85.8	62.2
ILKDG	86.2	83.1	87.0	63.1

1.4. Архитектуры DMCNN, SqueezeNet, Light-FireNet, DCN_Fire, AFSNet, SE-EFFNet, EFDNet и GLCT

В работе [13] авторы рассмотрели основанные на глубоком обучении подходы к обнаружению пожаров. Далее перечислены наиболее перспективные варианты.

В исследовании [14] предложена архитектура DMCNN (Deep Multi-scale CNN). Она включает многомасштабную сверточную структуру Inception для достижения масштабной инвариантности и использует многомасштабные аддитивные слои слияния для снижения вычислительных затрат при сохранении более динамичных и статичных характеристик задымления.

В методе, описанном в [15], в качестве магистральной сети использована облегченная нейронная сеть *SqueezeNet*^{URL} [16], сделана тонкая настройка архитектуры, в том числе применены сверточные ядра меньшего размера и исключены полностью подключенные плотные слои (*dense*).

Рассматривались архитектура Light-FireNet [17], сочетающая в себе легкий механизм свертки и новый архитектурный дизайн для уменьшения размера модели, и модель DCN_Fire [18] для оценки риска лесных пожаров с использованием PCA (Principal Component Analysis) для улучшения межклассовой различимости.

Адаптивная сеть выбора кадров AFSNet [19] автоматически выбирает наиболее полезные видеок cadры для уменьшения избыточности функций и обеспечивает улучшенную расширенную свертку для уменьшения потери критически важной информации. Сеть изучает дискриминационные представления путем рассмотрения многомасштабной, контекстной и пространственно-временной информации.

В архитектуре SE-EFFNet [20] используется нейросеть EfficientNet-B3 в качестве магистральной сети извлечения полезных функций. В ней применяются комплексные автоэнкодеры для достижения эффективного выбора функций. EfficientNet обеспечивает баланс между разрешением входа, глубиной и шириной сети, одновременно внедряя сеть плотного

подключения (DenseNet) для обеспечения эффективного распознавания места пожара. Результаты эксперимента продемонстрировали, что по сравнению с базовой моделью SE-EFFNet достигла более низкого уровня ложноположительных и ложноотрицательных срабатываний, обладает более высокой точностью. Однако эта архитектура может страдать от переобучения, а ее производительность при обработке в реальном времени на устройствах с ограниченными ресурсами является средней.

Также, в исследовании [13] рассмотрены методы определения цвета и угла для предварительной обработки областей пламени и оптического потока для обнаружения дыма. Ху и др. [21] попытались объединить сети с глубокой сверточной долговременной памятью (LSTM, Long Short-Term Memory) и оптическими потоковыми методами для обнаружения пожара в режиме реального времени. Предложен метод, который сочетает использование канала со смешанным вниманием и слиянием функций. Метод протестирован на данных с туманной средой. Результаты эксперимента показали, что метод достиг точности 96.73% и оценки F1 87.22%.

Анализировалась применимость EFDNet [22], задействующей много-масштабный механизм выделения признаков (*multiscale feature extraction*) для улучшения пространственных деталей на этапе выделения признаков более низкого уровня с целью улучшения способности различать объекты, похожие на огонь. Неявный механизм глубокого контроля с помощью плотных пропускных соединений улучшает взаимодействие между информационными потоками, преобразуя мелкие пространственные объекты в семантическую информацию высокого уровня. Подход позволил достичь точности в 95.3% при компактном размере модели – всего 4.80 МБ.

В работе [23] предложена нейронная сеть для обнаружения пожаров под названием GLCT. Модель основывается на блоке-трансформере *MobileViT^{URL}*, что позволяет извлекать как глобальную, так и локальную информацию. Благодаря сочетанию SPP (Spatial Pyramid Pooling) с BiFPN (Bi-directional Feature Pyramid Network) для объединения признаков и включению в архитектуру YOLO-головки, построена целостная архитектура GLCT. Экспериментальные результаты показали, что GLCT достигла mAP 80.71%, обеспечив баланс между скоростью и точностью.

1.5. Искусственная нейронная сеть CAGSA-YOLO

Новая архитектура CAGSA-YOLO [24] отличается использованием модуля CARAFE (Content-Aware ReAssembly of FEatures) для повышения дискретизации, добавлением нового уровня обнаружения масштаба для объектов порядка 4x4 и использованием облегченной конструкции Sampling Ghost, в которой C3-модуль заменяется модулем C3Ghost. Модель CAGSA-YOLO разработана на основе оригинальной архитектуры YOLOv5s.

В отличие от традиционных трехуровневых архитектур, CAGSA-YOLO использует четырехуровневую, что достигается заменой традиционной повышающей дискретизации на CARAFE. Механизм SA (Self-Attention Mechanism) повышает интерес к целевым объектам и подавляет ненужные функции. Изменения позволили улучшить производительность модели и повысить ее эффективность при обнаружении объектов. CAGSA-YOLO обнаруживает больше деталей и имеет более высокую точность по сравнению с традиционным YOLOv5. Значения показателей проведенных экспериментов представлены в таблице 5.

Таблица 5. Сравнительная таблица экспериментов (в процентах)

Модель	Точность	Полнота	mAP50
YOLOv5s	93.7	78.5	83.4
YOLOv5s+CARAFE	92.3	79.5	84.1
YOLOv5s+CARAFE+scale	89.7	79.7	84.5
YOLOv5s+CARAFE+scale+Ghost	87.7	81.4	84.5
CAGSA-YOLO (YOLOv5s+CARAFE+scale+Ghost+SA)	89.7	80.1	85.1

1.6. Двухуровневые СНС с пространственно-временным вниманием

В статье [25] представлена двухуровневая СНС STCNNsmoke для сегментации областей с дымом, основанная на механизме пространственно-временного внимания. В пространственной части сети извлекаются характеристики объектов переднего плана с использованием модели ранжирования с частичным контролем. Во временной (или темпоральной) части характеристики оптического потока используются для представления динамических характеристик дыма, таких как рассеивание и развевание.

Эксперименты показали, что полученное среднее значение IoU составляет 83.52%, а среднее значение F1-меры – 85.75%. Это на 3.34% и 2.72% выше, чем у трех сравниваемых моделей соответственно. Для видеороликов, содержащих большое количество легкого и разреженного дыма, значения метрик IoU и F1 предлагаемой СНС немного улучшены по сравнению с другими СНС. Результаты экспериментов на тестовом наборе данных представлены в таблице 6.

В работе [26] рассмотрена пространственно-временная нейросеть *STCNet^{UR}* (Spatio-Temporal Cross Network). Предложена архитектура для обнаружения дыма, включающая обработку как пространственной, так и временной информации. Пространственная часть обрабатывает кадры как отдельные объекты, извлекая многомасштабную пространственную

Таблица 6. Средние значения IoU и F1-меры для тестовых примеров (в процентах)

Модель	IoU	F1-мера
FCN	75.25	79.97
Deeplab V3+	78.83	81.92
RANet	80.18	83.03
STCNNsmoke	83.52	85.75

пирамиду признаков. Остаточные кадры выделяются путем вычитания соседних кадров.

RGB-кадры используются для временного контура, ограничивая максимальное значение остаточного пикселя. Остаточные кадры фокусируются на движущихся объектах, подавляя помехи. Временная часть сети извлекает особенности движения из различий в кадрах, она имеет такую же архитектуру, как и пространственная, но весовые коэффициенты иные. Модель создает карты объектов с разной глубиной и размером.

Функциональная пирамидальная сеть (FPN, Feature Pyramid Network) улучшает представление признаков. Для многоуровневой структуры используются карты объектов от разных остаточных блоков. Пространственно-временная двойная пирамида улучшает способность распознавания признаков дыма. Карты пространственной и временной частей ИНС суммируются для участия в выводе модели. Суммирование карт объектов выполняется поэлементно. Для оптимизации весов модели использовался стохастический градиентный спуск.

Проведено сравнение с другими базовыми моделями, в том числе с MobileNetV2. Результаты сравнения с первичными методами распознавания видео показали, что SEResNeXt-50 обеспечивает лучшую производительность. Рассмотрены три варианта STCNet: STCNet-A, STCNet-B и STCNet-C. STCNet-A представляет собой типичную двухпоточную сеть, STCNet-B использует однонаправленное слияние элементов, а STCNet-C применяет пространственно-временное слияние объектов.

Результаты проведенных экспериментов показали эффективность многомасштабного слияния функций в STCNet. Для визуализации активных областей в кадрах применялся метод Grad-CAM. Продемонстрировано, что STCNet способна фокусироваться на области задымления, игнорируя помехи от пара. STCNet показывает значительные улучшения значений F-меры в обнаружении промышленного дыма по сравнению с конкурентами (до 6.20%).

1.7. Алгоритмическая модель «MS Transformer»

В статье [27] предложена алгоритмическая модель «MS Transformer», которая использует подход самоконтролируемого обучения (*self-supervised learning*) для применения случайной маски к входному изображению с целью восстановления входных признаков, получения более полного вектора признаков и фильтрации избыточного шума. Скользящее окно (*sliding window*) с механизмом локального самоанализа используется для повышения оценки внимания к обнаруживаемым небольшим объектам. Модель «MS Transformer» учитывает особенности медицинских изображений, включая низкое разрешение и общую зашумленность.

Процесс обработки изображений заключается в разделении входного изображения на части и выполнении операции маскирования, кодировании немаскированных патчей для получения признаков изображения, после чего происходит обучение модели с использованием декодера, восстанавливающего пиксели. Каждое медицинское изображение сегментируется на регулярные участки, затем они случайным образом выбираются и маскируются. Случайная маска способствует устранению избыточности и изучению признаков на глубоком уровне.

Архитектура «MS Transformer» включает слой реконструкции изображения, «Swin Transformer»^{URL} и фрагменты архитектуры YOLOv5. Иерархический трансформер состоит из двух последовательных трансформерных блоков, предсказывающих класс поражения и ограничивающую рамку.

Без механизма маскирования точность модели снижается на 8.6%, а mAP – на 9.0%. Эффект иерархического трансформера на модель выше, чем у механизма маски. Использование только маскирования для задачи обнаружения объектов снижает точность модели на 15.6% и уменьшает значение mAP на 16.1%.

Проведены эксперименты с коэффициентом маски в диапазоне от 10% до 80%. Когда коэффициент находится в диапазоне 10–30%, точность распознавания модели на эталонных наборах данных BCDD и DeepLesion составляет 86% и 82% соответственно. При коэффициенте маски 40% точность распознавания модели значительно улучшается, достигая 94.3% и 87.1% на тех же наборах данных.

1.8. Нейросетевой алгоритм GSSD⁺⁺

В работе [28] представлен алгоритм GSSD⁺⁺^{URL} для выявления пораженных участков печени на изображениях. Он использует динамическое

межфазное (*dynamic interphase*) извлечение пространственной салиентности (*spatial saliency*) из многопоточковых признаков (*multistream features*) для обнаружения очагов поражения печени.

Разработка базируется на автоматической сегментации паренхимы печени и сосудов на КТ с использованием глубокого обучения [29]. Для лучшего обнаружения повреждений предложен механизм многофазного пространственного управления вниманием, основанный на деформируемом ядре свертки. Этот механизм учитывает основные фазы многофазных входных данных, что повышает точность обнаружения повреждений и снижает вероятность ложных срабатываний.

Чтобы точнее обнаруживать повреждения, ядра свертки с обучаемыми и динамичными смещениями прогнозируют геометрические смещения для многофазных функций, а дополнительную визуальную подсказку для многофазного выравнивания дает карта врат самовнимания (*self-attention gate map*). Совместное использование карты врат самовнимания и модулей деформируемой свертки значительно улучшает эффективность обнаружения ошибочно зарегистрированных многофазных наборов данных и снижает вероятность ложных срабатываний.

Алгоритм GSSD⁺⁺ продемонстрировал точное и надежное обнаружение поражений печени, особенно при высоком пороге перекрытия. Показатели представлены в таблице 7.

Таблица 7. Анализ эффективности алгоритма GSSD⁺⁺ (в процентах)

Алгоритм	mAP для IoU50	mAP для IoBB50
GSSD ⁺⁺	67.87	77.22
GSSD ⁺⁺ без Phase-wise Offsets	61.50	74.08
GSSD ⁺⁺ без DC Module	61.60	71.89
GSSD ⁺⁺ без SA Modules@Base	62.59	74.40
GSSD ⁺⁺ без SA Modules@Fusion	64.03	76.49
GSSD ⁺⁺ без Interphase Attention	63.82	73.56

1.9. Искусственная нейронная сеть DEGPR

В статье [30] представлена ИНС *DEGPR*^{UR} (Deep Guided Posterior Regularization), предназначенная для подсчета и обнаружения клеток разных классов на медицинских изображениях. Модель DEGPR помогает в обнаружении объектов, акцентируя внимание на уникальных особенностях клеток, которые могут быть предоставлены патологоанатомами или извлечены из визуальных данных.

Дискриминация классов клеток базируется на пострегистрационной регуляризации (PR, Posterior Regularization) для двух типов признаков:

явных и неявных. Явные признаки вводятся под непосредственным руководством экспертов-патологоанатомов. Неявные признаки – вкрапления признаков для каждого класса, исследуемые с помощью супервизорного метода контрастных потерь (*contrastive loss*).

Векторы различий признаков используются для формирования Gaussian Mixture Model (GMM), применяемой при сравнении истинных и прогнозных ограничивающих рамок. Она запоминает базовое распределение объектов с помощью оценки плотности. Для каждого класса готовятся две отдельные GMM, моделирующие истинные и предсказанные ограничивающие рамки.

Чтобы выровнять распределения признаков, минимизируется KL-расхождение (*Kullback-Leibler divergence*) между истинными и прогнозируемыми GMM. Метод Монте-Карло, аппроксимирующий интеграл с помощью выборок, оценивает KL-расхождения. Потери для каждой пары классов вычисляются и нормализуются по количеству пар. Итоговая величина потерь рассчитывается как среднее значение потерь по всем парам классов.

Преобразование изображений в неявные векторы признаков реализует нейросеть ResNet18. Уменьшение размерности признаков осуществляет PCA, сохраняя при этом 90% дисперсии.

Модель протестирована на наборах данных CoNSeP, MoNuSAC и MuCeD и обеспечивает до 9% абсолютного прироста точности в обнаружении объектов, улучшает эффективность обнаружения и подсчета клеток на наборах данных. В случае набора MuCeD она повышает mAP на 3–9% и снижает среднюю абсолютную ошибку на 10–35%. Эффективность в улучшении производительности систем обнаружения объектов характеризует увеличение F1-меры модели для прогнозирования целиакии с 77% до 90%.

1.10. Искусственная нейронная сеть RCS-YOLO

В работе [31] предложена перепараметризованная СНС *RCS-YOLO^{UR}*, в которой объединены архитектура ShuffleNet и блоки RepVGG/RepConv. Новый модуль RCS-OSA извлекает семантическую информацию.

RCS опирается на структурную перепараметризацию для улучшения свертки, разделяет входной тензор на два канальных тензора и применяет для каждого свои операции обработки данных. Модуль одношаговой агрегации (OSA, One-Shot Aggregation) для объединения объектов в DenseNet переключает каналы в случайном порядке для повышения информативности представления. В свою очередь, перетасовка каналов улучшает объединение информации между тензорами, снижает

вычислительную сложность. Она обеспечивает полную взаимосвязь между функциями ввода и вывода, которые иначе ограничены внутри групп сверток. Проведены эксперименты, показавшие, что RCS-YOLO превосходит YOLOv6, YOLOv7 и YOLOv8: точность – на 1%; скорость вывода – на 60%.

1.11. Искусственная нейронная сеть BGF-YOLO

В статье [32] рассмотрена архитектура BGF-YOLO на основе YOLOv8. BGF-YOLO объединяет двухуровневую систему маршрутизации внимания (BRA, Bi-level Routing Attention) и сети с обобщенными функциональными возможностями (GFPN, Generalized Feature Pyramid Networks), в отличие от YOLOv8 добавлена четвертая детекторная головка.

Произведена оценка модели *BGF-YOLO*^{[URL](#)}, результаты отображены в таблице 8. В частности, BGF-YOLO показала абсолютное повышение на 1.2%, 4.5%, 4.7% и 0.7% по сравнению с YOLOv8x в показателях точности, полноты, mAP50 и mAP50-95 соответственно. BGF-YOLO превзошла DAMO-YOLO-L [33], RCS-YOLO [34] и другие высокоточные детекторы.

Таблица 8. Результаты сравнения показателей моделей (в процентах)

Модель	Точность	Полнота	mAP50	mAP50-95
YOLOv8	90.7	88.1	92.7	64.6
DAMO-YOLO-L	–	–	90.0	61.0
RCS-YOLO	90.8	88.5	87.8	68.0
BGF-YOLO	91.9	92.6	97.4	65.3

1.12. Искусственные нейронные сети FireNet и FireNet-v2

Авторами статьи [35] предложена архитектура нейронной сети *FireNet*^{[URL](#)}. Данная архитектура оптимизирована для мобильных и встроенных приложений, обеспечивает высокую производительность и более 24 кадров в секунду на Raspberry Pi 3B. Сеть состоит из 14 слоев, включая слои «объединения» (*pooling*), «выбывания» (*dropout*) и выходной слой Softmax. FireNet имеет три уровня свертки с ReLU (Rectified Linear Unit) в качестве функции активации, за исключением последнего слоя с Softmax. Сеть имеет следующие параметры входных данных и размеров слоев. Первый слой принимает на вход тензоры с полноцветными изображениями размером (64×64×3). Входной сигнал может быть увеличен до (128×128×3) без значительного снижения частоты кадров. В каждом из двух последующих слоев свертки удваиваются входные признаки, сохраняя размер ядра неизменным. Последующие слои включают плотный слой (*Dense layer*)

с 256 нейронами и два плотных слоя с 128 нейронами. Последний – плотный слой с двумя нейронами для предсказания. Используется «выбывание» со слоями свертки наряду с плотными слоями. Для слоев свертки выбрано стандартное значение «выбывания», равное 0.5. Для последующего плотного слоя выбрано значение, равное 0.2.

В работе [36] представлена ИНС FireNet-v2, превосходящая предыдущую версию в оптимизации и качестве обнаружения. Она имеет значительно меньшее количество параметров по сравнению с FireNet, сохраняя при этом эффективность обнаружения пожаров и производительность. Конкретные модификации в работе по сравнению с FireNet заключаются в том, что количество фильтров в первом, втором и третьем конволюционных слоях составляет 15, 20 и 30 соответственно, в то время как в FireNet – 16, 32 и 64, что привело к значительному уменьшению числа обучаемых параметров. Функция активации, используемая в последнем конволюционном слое и обоих внутренних плотных слоях, – сигмоидальная. В FireNet использовалась функция ReLU. Вместо разделения на тренировочные и тестовые наборы в соотношении 70 к 30, выбрано разделение 90 к 10, что позволило предлагаемой модели FireNet-v2 обучаться на большем количестве данных о пожарах. В модели в качестве входа используется тензоры с изображениями размером $64 \times 64 \times 3$. Промежуточные слои включают каскад сверток, слои отсева и усреднения, а функции активации – ReLU и сигмоид. Все три конволюционных слоя соединены с объединением средних значений. После сверточных слоев появляется выравнивающий слой (*Flatten layer*) и два плотных слоя с 256 и 128 нейронами каждый. После начального плотного слоя используется «выбывание» со значением 0.2. Полностью связанный плотный слой с выходом Softmax имеет два нейрона и является слоем предсказания, выводящим сигналы «пожар» и «не пожар». FireNet-v2 имеет точность 98.43%, используя всего 0.32 млн. параметров, по сравнению с 96.53% точности FireNet, использующей 0.65 млн. параметров. Результаты тестирования моделей представлены в таблицах 9–10.

ТАБЛИЦА 9. Сравнение точности при тестировании FireNet-v2 (на наборе данных Foggia)

Модель	Точность, %	Количество параметров, млн.
FireNet	96.53	0.65
FireNet-v2	98.43	0.32
Muhammad 1 [15]	94.50	0.42
Abdullah [37]	97.50	0.51
Yakhyokhuja [38]	99.53	9.08
Muhammad 2 [39]	94.43	7.00

Таблица 10. Сравнение точности при тестировании модели FireNet-v2 (на наборе данных, используемом в работе [35])

Модель	Точность, %	Количество параметров, тыс.
FireNet	93.91	646.820
FireNet-v2	94.95	318.460
Saponara [40]	96.58	171.296
Ayala [41]	96.33	956.226
Elhanashi [42]	93.60	23.482

1.13. Искусственные нейронные сети NASNet-A-OnFire и ShuffleNetV2-OnFire

В статье [43] предложены две компактные ЧНС с пониженной сложностью архитектуры для повышения эффективности – *NASNet-A-OnFire* и *ShuffleNetV2-OnFire*^{URL}. NASNet-A-Mobile [44] и ShuffleNetV2 [45] экспериментально оптимизированы с помощью специальных фильтров, предложенных в работе [46]. В результате NASNet-A-OnFire и ShuffleNetV2-OnFire обеспечили точность локализации 95% и 97% соответственно. Для локализации пожаров на изображениях использовалась суперпиксельная сегментация.

Сети NASNet-A-Mobile и ShuffleNetV2 выбраны за их компактность и высокую производительность в ImageNet-классификации. Обе архитектуры имеют модульную структуру, позволяющую легко изменять или удалять отдельные ячейки. NASNet-A-Mobile содержит последовательность из нормальных и восстановленных ячеек, повторяющуюся три раза. Нормальная ячейка состоит из трех 3×3 сверток и двух 5×5 , в то время как восстановленная ячейка имеет одну 3×3 , две 5×5 и две 7×7 свертки. Остальные слои в NASNet-A-Mobile включают усреднение или максимальное объединение. ShuffleNetV2 состоит из начального слоя свертки 3×3 , слоя объединения и трех типов ячеек: нормальной, уменьшающей и восстанавливающей. Нормальная ячейка разделяется на две половинки, каждая из которых взаимодействует с тремя ядрами с различными типами сверток. Уменьшающая ячейка объединяет все входные данные, в то время как восстановленная ячейка похожа на нормальную, но с шагом 2 в глубине свертки.

Авторами исследования [43] проведены эксперименты с упрощением описанных выше архитектур ЧНС. Упрощенные архитектуры включают удаление последнего полностью подключенного слоя и создание нового линейного слоя для бинарной классификации. Базовая модель NASNet-A-Mobile была предварительно обучена для классификации ImageNet, далее весовые коэффициенты замораживались за исключением последнего слоя. Выполнено сокращение количества фильтров в NASNet-A-Mobile и

ShuffleNetV2 для улучшения обобщения (с 1056 до 480). Архитектура ShuffleNetV2 содержит 340 тысяч параметров. Как и в экспериментах с моделью NASNet-A-Mobile, проведено замораживание параметров на первую половину обучения, удаление фильтров с низкими значениями L2-нормы и последующее переобучение модели.

1.14. Искусственная нейронная сеть MVMNet

В статье [47] предложен метод мультиориентированного обнаружения целевых объектов, основанный на модуле VAM (Value conversion-Attention Mechanism) и смешанной NMS (Non-Maximum Suppression). Используется softpool-объединение пространственных пирамид для сохранения информации о характеристиках; рассматриваемые мини-блоки изображения делятся на части в разных масштабах, далее над этими частями производятся операции свертки. Изображение конвертируется методом главных компонент, далее результат конвертации считывается как по строкам, так и по столбцам. Применяется комбинация гибридных не максимальных методов DIoU-NMS и Skew-NMS с двумя порогами для расстояний и углов для предотвращения ложного и пропущенного обнаружения. MVMNet превосходит другие методы, такие как D-RFCN+SNIP и RDD, по точности и скорости.

Архитектура MVMNet успешно справляется с задачами обнаружения дыма в сложных условиях, таких как наличие облаков и тумана. На тестовом наборе данных *Forest_Fire_Smoke_DATA*^{URL} mAP50 достигла 88.05%.

1.15. 3D-сверточная нейронная сеть с расширенным региональным контекстом

В статье [48] представлена ИНС *3DCE*^{URL} (3D-СНС с расширенным региональным контекстом), которая объединяет информативные признаки из нескольких двумерных изображений для эффективного использования контекстной информации. ИНС выполняет агрегацию карт объектов для окончательного прогнозирования. 3DCE объединяет M трехканальных изображений в M двумерных канальных карт объектов. Центральный срез содержит ограничивающую рамку «исходная истина», а другие фрагменты обеспечивают трехмерный контекст.

Результаты экспериментов показали, что доработанная R-FCN с ключевым фрагментом обеспечивает низкую точность из-за важности трехмерного контекста; даже при работе с 11 срезами RCNN не удается превзойти 3DCE, которая показала лучшие результаты для небольших (<10 мм) поражений. Показатели чувствительности СНС представлены в таблицах 11–12.

Таблица 11. Чувствительность (%) при различных FP (False Positive) на изображении на тестовом наборе DeepLesion; в качестве критерия расчета перекрытия используется IoU

FP на изображение	0.5	1	2	4	8	16
Без 3D-контекста	48.60	60.57	71.19	79.15	84.77	88.42
Faster RCNN, 3 среза	56.90	67.26	75.57	81.62	85.83	88.74
Оригинальная R-FCN, 3 среза	55.70	67.26	75.37	82.21	86.26	89.19
Доработанная R-FCN, 3 среза	56.49	67.65	76.89	82.76	87.03	89.82
Data-level fusion, 11 срезов	58.49	70.03	77.89	83.02	86.71	89.19
3DCE, 9 срезов	59.32	70.68	79.09	84.34	87.81	89.62
3DCE, 27 срезов	62.48	73.37	80.70	85.65	89.09	91.06

Таблица 12. Чувствительность (%) при четырех ложных срабатываниях на изображении на тестовом наборе DeepLesion

	Тип поражения								Диаметр поражения, мм			Интервал между срезами, мм	
	LU	ME	LV	ST	PV	AB	KD	BN	<10	10~30	>30	<2.5	>2.5
RCNN	86	83	88	70	80	79	79	65	75	84	81	81	82
3DCE	89	88	90	74	84	84	82	75	80	87	84	86	86

2. Способы трекинга неригидных объектов

2.1. Трекинг с помощью многомасштабных пространственно-временных дискриминантных карт салиентности

В статье [49] представлен метод отслеживания объектов, основанный на принципе пространственно-временной согласованности и идентификации характерных признаков. Разработана специальная глубокая полностью конволюционная нейронная сеть (TFCN, Tailored Fully Convolutional Neural network) для моделирования локального приоритета салиентности (*local saliency prior*) для заданного региона изображения, которая не только обеспечивает попиксельный вывод, но и объединяет семантическую информацию. Предложен многомасштабный мультирегиональный механизм для генерации карт локальной салиентности региона, который эффективно учитывает визуальное восприятие с различными пространственными схемами и вариациями масштаба. Карты салиентности объединяются с помощью метода взвешенной энтропии, что позволяет получить окончательную дискриминационную карту салиентности. Отмечается алгоритм слежения, основанный на предложенной пространственно-временной согласованной карте салиентности (STCSM, Spatial-Temporal Consistent Saliency Map). Алгоритм используется для классификации по фону и онлайн-обновлений. TFCN обеспечивает попиксельные выходные данные

и интегрирует семантическую информацию о целях. TFCN обучается с помощью стохастического градиентного спуска и адаптируется к онлайн-визуальному отслеживанию.

Эксперименты и результаты показали, что предлагаемый метод превосходит другие по точности и F-мере, в том числе проведено сравнение с методами LEGS, MDF и DRFI. Предлагаемый трекер показывает точность 84.2% и коэффициент успешности 56.1%. В бенчмарке OTB-50 трекер работает лучше, чем второй лучший трекер неригидных объектов – OGBT [51]. Производительность трекера OGBT: точность 74.8%, коэффициент успешности 52.4%. Отмечается, что разработанный трекер может генерировать попиксельные карты салиентности, что полезнее, чем результаты отслеживания по ограничительным рамкам. Детали реализации имеются в репозитории [*tracker_benchmark_v1.0*](https://github.com/zhengyu1992/tracker_benchmark_v1.0)^{URL}.

2.2. Трекинг с помощью деформируемых патчей

В работе [52] была предложена структура для отслеживания объектов с использованием деформируемых патчей и ядерного корреляционного фильтра с сохранением формы (SP-KCF, Shape-Preserved Kernelized Correlation Filter) для учета формы цели. Адаптация деформируемых патчей к сложной топологии и изменениям целей обеспечивается за счет фотометрической дискриминации (*photometric discrimination*) и вариативности формы патчей. Это позволяет отслеживать отдельные области и вычислять контуры объектов на основе информации о форме патчей. KCF-трекер учитывает неригидную форму патчей, что обеспечивает надежное отслеживание. Обучение классификатора происходит в области Фурье с использованием участков изображения вокруг мишени. Результаты сравнения методов представлены в таблице 13.

Таблица 13. Результаты оценки сравниваемых методов (F-мера в %)

Pix [53]	DF [54]	HT [55]	SLSM [56]	RPT [57]	SP-KCF
40.33	42.06	45.73	47.84	54.02	56.76

2.3. Трекинг с использованием параметрического активного контура и модели распределения точек

В работе [58] исследуется метод отслеживания неригидных объектов на изображениях с загроможденным фоном в многолюдных сценах. Авторы предлагают комбинированное использование параметрических активных контуров (PAC, Parametric Active Contours) и модели распределения точек (PDM, Point Distribution Model). PAC и PDM дополняют друг друга,

повышая устойчивость системы к окклюзии и изменениям внешнего вида объекта. Трекер состоит из этих двух частей и уровня управления, обеспечивающего обмен информацией между частями трекера, что позволяет продолжить работу в случае отказа одного из трекеров.

При рассмотрении частей трекера по отдельности стоит выделить, что PDM-трекер вычисляет вектор признаков и генерирует вектор формы, а PAC-трекер инициализируется на основе PDM и точно определяет область с целевым объектом. Уровень управления объединяет результаты PAC- и PDM-трекеров для обновления PDM. Неотъемлемой частью трекера является алгоритм обмена данными между его компонентами. Алгоритм использует ROI (Region-Of-Interest) для извлечения точек интереса и сопоставления с предыдущими кадрами. PAC инициализируется на основе точечной модели или контура предыдущего кадра. С целью повышения точности отслеживания применяется конвергенция PAC и обновление PDM. Стоит отметить, что априорная модель PDM используется для отслеживания работы системы и инициализации контура при окклюзиях. Для повышения надежности работы трекера обновления PDM отключены в моментах перекрытий.

2.4. Трекер на основе многообразий распределения точек

В работе [59] рассматривается модель трекинга неригидных объектов, разработанная для обработки текстурированных объектов в многолюдных сценах. Модель опирается на отслеживание характерных точек на изображениях и их сопоставлении. Модель представляет собой набор геометрических фигур, которые могут быть адаптированы к изменениям в объекте. Порог стробирования θ используется для фильтрации расстояний между объектами в разных кадрах, превышающих θ . Изображение центрируется и масштабируется для соответствия модели. Преобразование подобия T используется для отображения формы из системы отсчета изображения. Параметры сходства модели с изображением отсеиваются с помощью фильтра Калмана. Фильтр настраивается для различных типов движений.

Особенностью предложенной модели является ее универсальность: помимо людей она может успешно применяться для отслеживания других объектов, например, автомобилей. Важным отличием является сохранение меток объектов даже при частичных перекрытиях, что особенно актуально в условиях динамичной сцены.

2.5. Алгоритм трехмерной реконструкции неригидных объектов с использованием камеры глубины

В статье [60] рассматривается алгоритм выделения особых точек, предназначенный для создания трехмерных моделей объектов реального мира с использованием RGB-D-камеры Microsoft Kinect. Входные данные для алгоритма включают RGB-изображение, карту глубины и облако точек, полученные с помощью камеры Kinect. Отметим, что на этапе выделения признаков алгоритм находит общие точки между двумя объектами, используя для этого вычисляемые дескрипторы.

В процессе поиска подходящих ключевых точек исследованы четыре детектора: Harris [61], ISS [62], SUSAN [63] и SIFT [64]. Для описания признаков протестированы пять дескрипторов: PFH [65], SHOT [66], SC [67], RIFT [68] и RSD [69]. Для сравнения эффективности комбинаций детектор-дескриптор использован набор данных «freiburg1_teddy» из бенчмарка [70]. На этапе сопоставления признаков алгоритм находит соответствия между облаками точек с использованием модифицированного RANSAC (Random Sample Consensus). Для выравнивания совпадений используется алгоритм Kabsch, на этапе неригидной регистрации этот алгоритм находит преобразования для выравнивания облаков точек между собой. Итеративный алгоритм ближайших точек ICP используется для согласования выровненных поверхностей. На заключительном этапе строится трехмерная модель объекта на основе выровненных облаков точек. Сравнение работы различных модификаций ICP сделано с использованием среднего квадратического отклонения (СКВО), результаты тестирования алгоритмов представлены в таблице 14.

Таблица 14. Сравнение эффективности работы различных модификаций ICP

Алгоритм регистрации	СКВО, мм
ICP-R	4.7
ICP-nR	3.4
ICP-nRC	3.2

3. Оценка и выбор наиболее перспективных решений

С целью формирования более предметного обоснования выбора наиболее перспективных решений для работы с неригидными объектами составлены сводные таблицы 15–16 для каждого из основных разделов настоящего аналитического обзора. В них представлены показатели эффективности и общая характеристика обнаруженных в результате проведения аналитического обзора решений.

Таблица 15. Сводная таблица решений, рассмотренных в разделе «Способы повышения эффективности локализации неригидных объектов в кадре»

№	Решение	Эффективность	Комментарий
1	Применение метода выравнивания гистограмм [1], модулей СВМ [3] и алгоритма CAPAN [5]	Метод выравнивания гистограмм обеспечил рост точности с 94 до 99%; СВМ улучшил mAP50 на 2.09%; CAPAN улучшил mAP50 на 2.1–8.3%	Метод выравнивания гистограмм регулирует яркость изображений, равномерно распределяя значения по каналам RGB. Предложен ряд усовершенствований архитектуры YOLOv5, в том числе – использование модуля сверточного блочного анализа СВМ и алгоритма CAPAN, позволяющего ИНС фокусироваться на особенностях переднего плана.
2	Fire-RPG [6]	Рост mAP50 на 1.1–1.3%	Слой Fire-RPG для обнаружения сверхмалых объектов позволяет снизить негативный эффект неригидности целевых объектов. Слой увеличивает вычислительные затраты и может повлиять на способность обнаружения в реальном времени. Используется функция потерь Wise-IoU.
3	Дистилляция знаний на основе потока процедур решения [12]	Рост mAP50 на 2.9%, рост mAP50-95 на 2.7%	Предлагается интегрировать YOLOv7 с методами дистилляции знаний и использовать метод ILKDG.
4	DMCNN [14]	–	Используется многомасштабная сверточная структура Inception для достижения масштабной инвариантности, применяются аддитивные слои слияния для снижения вычислительных затрат при сохранении характеристик задымления.
5	<i>SqueezeNet</i> ^(m) [16]	–	Тонкая настройка архитектуры, в том числе осуществляется использование сверточных ядер меньшего размера и исключение плотных полностью подключенных слоев.
6	Light-FireNet [17]	–	Облегченные свертки и методы минимизации размера модели.

7	DCN_Fire [18]	—	Использование PCA для улучшения межклассовой различимости.
8	AFSNet [19]	—	Реализуется автоматический выбор полезных видеок кадров для уменьшения избыточности функций и улучшение свертки для минимизации потери важной информации. Сеть изучает дискриминационные представления, используя многомасштабную, контекстную и пространственно-временную информацию.
9	SE-EFFNet [20]	—	EfficientNet-B3 используется как магистральная сеть для извлечения полезных функций, применяя комплексные автоэнкодеры для эффективного выбора функций. Сеть балансирует разрешение входа, глубину и ширину сети.
10	Методы определения цвета и угла для предварительной обработки областей пламени и оптического потока, LSTM-сеть [21]	Точность 96.73%, F1-мера 87.22%	Объединение LSTM-сети с оптическими потоковыми методами.
11	EFDNet [22]	Точность 95.3%	Используется многомасштабный механизм выделения признаков для улучшения способности различать объекты, похожие на огонь. Применяется неявный механизм глубокого контроля с плотными пропускными соединениями для улучшения взаимодействия между информационными потоками, преобразуя мелкие пространственные объекты в семантическую информацию высокого уровня.
12	GLCT [23]	mAP 80.71%	Нейронная сеть на основе блока-трансформера MobileViT. Модель извлекает глобальную и локальную информацию, сочетая SPP и BiFPN для объединения признаков.
13	CAGSA-YOLO [24]	Рост mAP50 на 1.7%	Используется модуль CARAFE для повышения дискретизации, новый уровень обнаружения масштаба для объектов 4x4, облегченная конструкция Sampling Ghost с заменой C3-модуля на C3Ghost.

14	Двухуровневые СНС с пространственно-временным вниманием [25]	Рост F-меры на 2.72–6.20%	В пространственной части извлекаются характеристики объектов переднего плана с использованием модели ранжирования с частичным контролем. Во временной части используются характеристики оптического потока для представления динамических характеристик дыма, таких как рассеивание и разветвление.
15	MSTransformer [27]	Точность 87.1–94.3%	Используется самоконтролируемое обучение для применения случайной маски к входному изображению для восстановления признаков, получения полного вектора признаков и фильтрации шума. Скользящее окно с локальным самоанализом повышает внимание к небольшим объектам.
16	Нейросетевой алгоритм GSSD++ [28]	mAP 67.87–77.22%	Используется динамическое межфазное извлечение пространственной салиентности из многопоточковых признаков для обнаружения очагов поражения. Механизм многофазного пространственного управления вниманием на основе деформируемого ядра свертки повышает точность обнаружения повреждений и снижает вероятность ложных срабатываний.
17	DEGPR [30]	Рост точности на 9%, рост полноты на 4.5%, рост mAP на 3–9%, рост F1–меры на 13%	Модель акцентирует внимание на уникальных особенностях клеток, опираясь на пострегистрационную регуляризацию для явных и неявных признаков.
18	RCS-YOLO [31]	Рост точности на 1%	Используется структурная перепараметризация модели, входной тензор разделяется на два канальных тензора, для каждого нового тензора применяются свои операции обработки данных. Перетасовка каналов улучшает объединение информации и снижает вычислительную сложность.
19	BGF-YOLO [32]	Рост точности на 1.2%, рост mAP50 на 4.7%, рост mAP50-95 на 0.7%	Объединены двухуровневая система маршрутизации внимания и нейросеть с обобщенными функциональными возможностями. Добавлена четвертая детекторная головка для фокусировки на важных объектах.
20	FireNet [35]	Точность 93.91–96.53%	Сеть состоит из 14 слоев, включая слой свертки с ReLU и выходной слой Softmax. Первый слой принимает на вход тензоры размером $(64 \times 64 \times 3)$, которые могут быть увеличены до $(128 \times 128 \times 3)$ без снижения частоты кадров. Последующие слои включают плотный слой с 256 нейронами и два плотных слоя с 128 нейронами.

21	FireNet-v2 [36]	Точность 94.95–98.43%	Модификация FireNet, в том числе уменьшение количества фильтров в первых трех конволюционных слоях до 15, 20 и 30 соответственно (в FireNet – 16, 32 и 64), что значительно уменьшает число обучаемых параметров. Функция активации в последнем конволюционном и обоих внутренних плотных слоях – сигмоидальная.
22	NASNet-A-OnFire [43] и ShuffleNetV2-OnFire [45]	Точность 95–97%	Используются специальные фильтры, предложенные в работе [46].
23	MVMNet [47]	mAP50 88.05%	Метод мультиориентированного обнаружения объектов на основе модуля VAM и смешанной NMS. Используется softpool-объединение пространственных пирамид для сохранения характеристик. Применяется комбинация гибридных не максимальных методов DIoU-NMS и Skew-NMS с двумя порогами для расстояний и углов для предотвращения ложного и пропущенного обнаружения.
24	3D-CHC с расширенным региональным контекстом [48]	См. таблицы 11–12	Объединяет информативные признаки из нескольких двумерных изображений для эффективного использования контекстной информации.

Таблица 16. Сводная таблица решений, рассмотренных в разделе «Способы трекинга неригидных объектов»

№	Решение	Эффективность	Комментарий
1	Трекинг с помощью глубоких многомасштабных пространственно-временных дискриминантных карт салиентности [49]	Точность 84.2%	Используется мультирегиональный механизм для генерации карт локальной салиентности, учитывающий визуальное восприятие с различными пространственными схемами и вариациями масштаба.
2	Трекинг с помощью деформируемых патчей [52]	F-мера 56.76%	Предлагается структура для отслеживания объектов с использованием деформируемых патчей и ядерного корреляционного фильтра с сохранением формы для учета формы цели. Адаптация патчей к сложной топологии и изменениям целей обеспечивается за счет фотометрической дискриминации и вариативности формы.
3	Трекинг с использованием параметрического активного контура и модели распределения точек [58]	—	Метод отслеживания неригидных объектов на изображениях с загроможденным фоном в многолюдных сценах. Предлагается использовать параметрические активные контуры (PAC) и модели распределения точек (PDM).
4	Трекер на основе многообразий распределения точек [59]	—	Модель опирается на набор геометрических фигур, которые могут быть адаптированы к изменениям в целевых объектах.
5	Алгоритм трехмерной реконструкции с использованием камеры глубины [60]	—	Входные данные: RGB-изображение, карта глубины и облако точек. Алгоритм находит общие точки между объектами, используя вычисляемые дескрипторы.

Выбор представленных решений при написании аналитического обзора обусловлен наличием качественных улучшений в области исследуемой задачи. Главный критерий, по которому то или иное решение можно назвать перспективным, – рост показателей эффективности от добавления новых слоев, модификации существующих или в целом от применения совершенно новой архитектуры. Другой критерий – высокое абсолютное значение ключевых показателей качества.

Исходя из данных, приведенных в обзоре, и тех же данных, структурированных в таблицах 15–16, следует отметить, что все архитектуры, модели, методы и алгоритмы, рассмотренные в данном аналитическом обзоре, в целом можно считать перспективными для использования. В представленных обобщающих таблицах имеются решения, для которых отсутствуют данные о четком числовом значении эффективности. Несмотря на это, включение их в настоящую работу целесообразно, так как в дальнейшем предлагается провести для этих решений дополнительные исследования на собственных наборах данных. К таким работам относятся решения из таблицы 15 – строки 4–9; из таблицы 16 – строки 3–5.

Заключение

По результатам проведенной работы над аналитическим обзором, для создания эффективных инструментов, позволяющих осуществлять обнаружение неригидных объектов в видеопотоке, потребуется объединение ряда решений из рассмотренных научных работ.

Перспективным для локализации неригидных объектов, на наш взгляд, выглядит следующий ряд архитектур, моделей, методов и алгоритмов: архитектура Fire-RPG [6]; нейросетевой алгоритм GSSD⁺⁺ [28]; модель DEGPR [30]; архитектура RCS-YOLO [31]; архитектура BGF-YOLO [32]; архитектура FireNet-v2 [36]; архитектуры NASNet-A-OnFire и ShuffleNetV2-OnFire [43]. Наиболее перспективные решения для трекинга: метод на основе многомасштабных пространственно-временных дискриминантных карт салиентности [49] и метод, базирующийся на применении деформируемых патчей [52].

Список использованных источников

- [1] Ergasheva A., Akhmedov F., Abdusalomov A., Kim W. *Advancing maritime safety: early detection of ship fires through computer vision, deep learning approaches, and histogram equalization techniques* // Fire. – 2024. – Vol. 7. – No. 3. – id. 84. – 15 pp.  ↑115, 135
- [2] Farkhod A., Abdusalomov A., Makhmudov F., Cho Y. I. *LDA-based topic modeling sentiment analysis using topic/document/sentence (TDS)* // Applied Sciences. – 2021. – Vol. 11. – No. 23. – id. 11091. – 15 pp.  ↑115

- [3] Xu F., Zhang X., Deng T., Xu W. *An image-based fire monitoring algorithm resistant to fire-like objects* // Fire.– 2024.– Vol. 7.– No. 1.– id. 3.– 12 pp. doi ↑115, 135
- [4] Woo S., Park J., Lee J.-Y. *CBAM: convolutional block attention module*.– 2018.– 17 c. arXiv:1807.06521v2[cs.CV] doi ↑115, 116
- [5] Li G., Chen P., Xu C., Sun C., Ma Y. *Anchor-free smoke and flame recognition algorithm with multi-loss* // Fire.– 2023.– Vol. 6.– No. 6.– id. 225.– 16 pp. doi ↑115, 135
- [6] Li X., Liang Y. *Fire-RPG: an urban fire detection network providing warnings in advance* // Fire.– 2024.– Vol. 7.– No. 7.– id. 214.– 22 pp. doi ↑116, 135, 140
- [7] Ding X., Zhang X., Ma N., Han J., Ding G., Sun J. *RepVGG: Making VGG-style ConvNets great again*.– 2021.– 10 pp. arXiv:2101.03697[cs.CV] doi ↑116
- [8] Tang Y., Han K., Guo J., Xu C., Xu C., Wang Y. *GhostNetV2: enhance cheap operation with long-range attention*.– 2022.– 12 pp. arXiv:2211.12905[cs.CV] doi ↑116
- [9] Zhang Q. L., Yang Y. B. *SA-Net: shuffle attention for deep convolutional neural networks*.– 2021.– 9 pp. arXiv:2102.00240[cs.CV] doi ↑118
- [10] Wang Q., Wu B., P. Zhu, P. Li, W. Zuo, Hu Q. *ECA-Net: efficient channel attention for deep convolutional neural Networks*.– 2020.– 12 pp. arXiv:1910.03151v4[cs.CV] doi ↑118
- [11] Yang L., Zhang R. Y., Li L., Xie X. *Simple attention module based speaker verification with iterative noisy label detection*.– 2021.– 5 pp. arXiv:2110.06534[cs.CV] doi ↑118
- [12] Xie J., Zhao H. *Forest fire object detection analysis based on knowledge distillation* // Fire.– 2023.– Vol. 6.– No. 12.– id. 446.– 15 pp. doi ↑119, 135
- [13] Jin C., Wang T., Alhusaini N., Zhao S., Liu H., Xu K., Zhang J. *Video fire detection methods based on deep learning: datasets, methods, and future directions* // Fire.– 2023.– Vol. 6.– No. 8.– id. 315.– 27 pp. doi ↑120, 121
- [14] Yuan F., Zhang L., Wan B., Xia X., Shi J. *Convolutional neural networks based on multi-scale additive merging layers for visual smoke recognition* // Machine Vision and Applications.– 2019.– Vol. 30.– Pp. 345–358. doi ↑120, 135
- [15] Muhammad K., Ahmad J., Lv Z., Bellavista P., Yang P., Baik S. W. *Efficient deep CNN-based fire detection and localization in video surveillance applications* // IEEE Transactions on Systems, Man, and Cybernetics: Systems.– 2019.– Vol. 49.– No. 7.– Pp. 1419–1434. doi ↑120, 128
- [16] Iandola F. N., Han S., Moskewicz M. W., Ashraf K., Dally W. J., Keutzer K. *SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size*.– 2016.– 13 pp. arXiv:1602.07360[cs.CV] doi ↑120, 135
- [17] Khudayberdiev O., Zhang J., Abdullahi S. M., Zhang S. *Light-FireNet: an efficient lightweight network for fire detection in diverse environments* // Multimedia Tools and Applications.– 2022.– Vol. 81.– Pp. 24553–24572. doi ↑120, 135
- [18] Zheng S., Gao P., Wang W., Zou X. *A highly accurate forest fire prediction model based on an improved dynamic convolutional neural network* // Applied Sciences.– 2022.– Vol. 12.– No. 13.– id. 6721.– 15 pp. doi ↑120, 136
- [19] Tao H., Duan Q. *An adaptive frame selection network with enhanced dilated convolution for video smoke recognition* // Expert Systems with Applications.– 2023.– Vol. 215.– id. 119371.– 11 pp. doi ↑120, 136

- [20] Khan Z. A., Hussain T., Ullah F. U. M., Gupta S. K., Lee M. Y., Baik S. W. *Randomly initialized CNN with densely connected stacked autoencoder for efficient fire detection* // Engineering Applications of Artificial Intelligence.– 2022.– Vol. **116**.– id. 105403.– 11 pp. doi ↑^{120, 136}
- [21] Hu C., Tang P., Jin W., He Z., Li W. *Real-time fire detection based on deep convolutional long-recurrent networks and optical flow method* // Proceedings of the 2018 37th Chinese Control Conference (CCC), CCC 2018 (Wuhan, China, 25–27 July, 2018).– IEEE.– 2018.– ISBN 978-1-538-64968-8.– Pp. 9061–9066. doi ↑^{121, 136}
- [22] Li S., Yan Q., Liu P. *An efficient fire detection method based on multiscale feature extraction, implicit deep supervision and channel attention mechanism* // IEEE Transactions on Image Processing.– 2020.– Vol. **29**.– Pp. 8467–8475. doi ↑^{121, 136}
- [23] Yang C., Pan Y., Cao Y., Lu X. *CNN-transformer hybrid architecture for early fire detection* // Proceedings of the Artificial Neural Networks and Machine Learning.– V. IV, ICANN 2022: 31st International Conference on Artificial Neural Networks (Bristol, UK, 6–9 September, 2022), Lecture Notes in Computer Science.– vol. **13532**, Berlin: Springer.– 2022.– ISBN 978-3-031-15936-7.– Pp. 570–581. doi ↑^{121, 136}
- [24] Wang X., Cai L., Zhou S., Jin Y., Tang L., Zhao Y. *Fire safety detection based on CAGSA-YOLO network* // Fire.– 2023.– Vol. **6**.– No. 8.– id. 297.– 19 pp. doi ↑^{121, 136}
- [25] Ding Z., Zhao Y., Li A., Zheng Z. *Spatial-temporal attention two-stream convolution neural network for smoke region detection* // Fire.– 2021.– Vol. **4**.– No. 4.– id. 66.– 12 pp. doi ↑^{122, 137}
- [26] Cao Y., Tang Q., Lu X., Li F., Cao J. *STCNet: spatio-temporal cross network for industrial smoke detection*.– 2020.– 10 c. arXiv:2011.04863v1[cs.CV] doi ↑¹²²
- [27] Shou Y., Meng T., Ai W., Xie C., Liu H., Wang Y. *Object detection in medical images based on hierarchical transformer and mask mechanism* // Computational Intelligence and Neuroscience.– 2022.– Vol. **2022**.– id. 5863782.– 12 pp. doi ↑^{124, 137}
- [28] Lee S.-G., Kim E., Bae J. S., Kim J. H., Yoon S. *Robust end-to-end focal liver lesion detection using unregistered multiphase computed tomography images* // IEEE Transactions on Emerging Topics in Computational Intelligence.– 2023.– Vol. **7**.– No. 2.– Pp. 319–329. doi ↑^{124, 137, 140}
- [29] De Frutos J. P., Pedersen A., Pelanis E., Bouget D., Survarachakan S., Langø T., Elle O.-J., Lindseth F. *Learning deep abdominal CT registration through adaptive loss weighting and synthetic data generation* // PLOS ONE.– 2023.– Vol. **18**.– No. 2.– Pp. 1–14. doi ↑¹²⁵
- [30] Tyagi A. K., Mohapatra C., Das P., Makharia G., Mehra L., AP P., Mausam *DeGPR: deep guided posterior regularization for multi-class cell detection and counting*.– 2023.– 11 c. arXiv:2304.00741v1[cs.CV] doi ↑^{125, 137, 140}
- [31] Kang M., Ting C.-M., Ting F. F., Phan R. C.-W. *RCS-YOLO: a fast and high-accuracy object detector for brain tumor detection*.– 2023.– 11 c. arXiv:2307.16412v2[cs.CV] doi ↑^{126, 137, 140}
- [32] Kang M., Ting C.-M., Ting F. F., Phan R. C.-W. *BGF-YOLO: enhanced YOLOv8 with multiscale attentional feature fusion for brain tumor detection*.– 2023.– 5 c. arXiv:2309.12585v2[cs.CV] doi ↑^{127, 137, 140}

- [33] Xu X., Jiang Y., Chen W., Huang Y., Zhang Y., Sun X. *DAMO-YOLO : a report on real-time object detection design.*— 2023.— 10 с. arXiv:2211.15444v4[cs.CV] doi ↑127
- [34] Kang M., Ting C.-M., Ting F. F., Phan R. C.-W. *RCS-YOLO: a fast and high-accuracy object detector for brain tumor detection.*— 2023.— 11 pp. arXiv:2307.16412v2[cs.CV] doi ↑127
- [35] Jadon A., Omama M., Varshney A., Ansari M. S., Sharma R. *FireNet: a specialized lightweight fire & smoke detection model for real-time IoT applications.*— 2019.— 6 pp. arXiv:1905.11922v2[cs.CV] doi ↑127, 129, 137
- [36] Shees A., Ansari M. S., Varshney A., Asghar M. N., Kanwal N. *FireNet-v2: improved lightweight fire detection model for real-time IoT applications* // *Procedia Computer Science.*— 2023.— Vol. **218.**— Pp. 2233–2242. doi ↑128, 138, 140
- [37] Altowaijri A. H., Alfaifi M. S., Alshawi T. A., Ibrahim A. B., Alshebeili S. A. *A privacy-preserving IoT-Based fire detector* // *IEEE Access.*— 2021.— Vol. **9.**— Pp. 51393–51402. doi ↑128
- [38] Valikhujaev Y., Abdusalomov A., Cho Y. I. *Automatic fire and smoke detection method for surveillance systems based on dilated CNNs* // *Atmosphere.*— 2020.— Vol. **11.**— No. 11.— id. 1241.— 15 pp. doi ↑128
- [39] Muhammad K., Ahmad J., Mehmood I., Rho S., Baik S. W. *Convolutional neural networks based fire detection in surveillance videos* // *IEEE Access.*— 2018.— Vol. **6.**— Pp. 18174–18183. doi ↑128
- [40] Saponara S., Elhanashi A., Gagliardi A. *Real-time video fire/smoke detection based on CNN in antifire surveillance systems* // *Journal of Real-Time Image Processing.*— 2021.— Vol. **18.**— Pp. 889–900. doi ↑129
- [41] Ayala A., Lima E., Fernandes B., Bezerra B. L., Cruz F. *Lightweight and efficient octave convolutional neural network for fire recognition* // *Proceedings of the 2019 IEEE Latin American Conference on Computational Intelligence, LA-CCI'2019* (Guayaquil, Ecuador, 11–15 November, 2019).— IEEE.— 2019.— ISBN 978-1-7281-5666-8.— 6 pp. doi ↑129
- [42] Saponara S., Elhanashi A., Gagliardi A. *Exploiting R-CNN for video smoke/fire sensing in antifire surveillance indoor and outdoor systems for smart cities* // *Proceedings of the 2020 IEEE International Conference on Smart Computing, SMARTCOMP'2020* (Bologna, Italy, 14–17 September, 2020).— IEEE.— 2020.— ISBN 978-1-7281-6997-2.— Pp. 392–397. doi ↑129
- [43] Thomson W., Bhowmik N., Breckon T. P. *Efficient and compact convolutional neural network architectures for non-temporal real-time fire detection.*— 2020.— 6 pp. arXiv:2010.08833[cs.CV] doi ↑129, 138, 140
- [44] Zoph B., Vasudevan V., Shlens J., Le Q. V. *Learning transferable architectures for scalable image recognition* // *Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), CVPR'18* (Salt Lake City, Utah, 18–22 June, 2018).— IEEE.— 2018.— ISBN 978-1-728-13294-5.— Pp. 8697–8710. doi ↑129

- [45] Ma N., Zhang X., Zheng H.-T., Sun J. *Shufflenet v2: practical guidelines for efficient CNN architecture design* // *Proceedings of the 2018 European Conference on Computer Vision (ECCV)*, ECCV'18 (Munich, Germany, 8–14 September, 2018), Lecture Notes in Computer Science.– vol. **11218**, Cham: Springer.– 2018.– ISBN 978-3-030-01263-2.– Pp. 122–138.  [↑129, 138](#)
- [46] Li H., Kadav A., Durdanovic I., Samet H., Graf H. P. *Pruning filters for efficient ConvNets*.– 2017.– 13 pp. arXiv: 1608.08710v3[cs.CV]  [↑129, 138](#)
- [47] Hu Y., Zhan J., Zhou G., Chen A., Cai W., Guo K., Hu Y., Li L. *Fast forest fire smoke detection using MVMNet* // *Knowledge-Based Systems*.– 2022.– Vol. **241**.– 20 pp.  [↑130, 138](#)
- [48] Yan K., Bagheri M., Summers R. M. *3D context enhanced region-based convolutional neural network for end-to-end lesion detection*.– 2018.– 11 pp. arXiv: 1806.09648v2[cs.CV]  [↑130, 138](#)
- [49] Zhang P., Liu W., Wang D., Lei Y., Wang H., Shen C., Lu H. *Non-rigid object tracking via deep multi-scale spatial-temporal discriminative saliency maps*.– 2019.– 12 pp. arXiv: 1802.07957v2[cs.CV]  [↑131, 139, 140](#)
- [50] Hong S., You T., Kwak S., Han B. *Online tracking by learning discriminative saliency map with convolutional neural network* // *Proceedings of the 32nd International Conference on Machine Learning, ICML'15* (Lille, France, 6–11 July, 2015), PMLR.– vol. **37**.– 2015.– ISBN 978-1-510-81058-7.– Pp. 597–606.  [↑](#)
- [51] Son J., Jung I., Park K., Han B. *Tracking-by-segmentation with online gradient boosting decision tree* // *Proceedings of the 2015 IEEE International Conference on Computer Vision, ICCV'15* (Santiago, Chile, 07–13 December, 2015).– IEEE.– 2015.– ISBN 978-1-4673-8391-2.– Pp. 3056–3064.  [↑132](#)
- [52] Sun X., Cheung N.-M., Yao H., Guo Y. *Non-rigid object tracking via deformable patches using shape-preserved KCF and level sets* // *Proceedings of the 2017 IEEE International Conference on Computer Vision, ICCV'17* (Venice, Italy, 22–29 October, 2017).– IEEE.– 2017.– ISBN 978-1-5386-1032-9.– Pp. 5496–5504.  [↑132, 139, 140](#)
- [53] Duffner S., Garcia C. *PixelTrack: a fast adaptive algorithm for tracking non-rigid objects* // *Proceedings of the 2013 IEEE International Conference on Computer Vision, ICCV'13* (Sydney, NSW, Australia, 1–8 December, 2013).– IEEE.– 2013.– ISBN 978-1-4799-2840-8.– Pp. 2480–2487.  [↑132](#)
- [54] Sevilla-Lara L., Learned-Miller E. *Distribution fields for tracking* // *Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition, CVPR'12* (Providence, RI, USA, 16–21 June, 2012).– 2012.– ISBN 978-1-4673-1226-4.– Pp. 1910–1917.  [↑132](#)
- [55] Godec M., Roth P. M., Bischof H. *Hough-based tracking of non-rigid objects* // *Proceedings of the 2011 IEEE International Conference on Computer Vision, ICCV'11* (Barcelona, Spain, 06–13 November, 2011).– 2011.– ISBN 978-1-4577-1101-5.– Pp. 81–88.  [↑132](#)
- [56] Sun X., Yao H., Zhang S., Li D. *Non-rigid object contour tracking via a novel supervised level set model* // *IEEE Transactions on Image Processing*.– 2015.– Vol. **24**.– No. 11.– Pp. 3386–3399.  [↑132](#)

- [57] Li Y., Zhu J., Hoi S. *Reliable Patch Trackers: Robust visual tracking by exploiting reliable patches* // *Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition*, CVPR'15 (Boston, MA, USA, 07–12 June, 2015).– IEEE.– 2015.– ISBN 978-1-4673-6964-0.– Pp. 353–361. doi ↑132
- [58] Olszewska J. I., Mathes T., Vleeschouwer C. D., Piater J., Macq B. *Non-rigid object tracker based on a robust combination of parametric active contour and point distribution model*, Visual Communications and Image Processing 2007 (San Jose, CA, USA, 28 January–1 February, 2007), Proc. SPIE.– vol. **6508**.– 2007.– ISBN 978-0-8194-6621-1.– id. 65082A.– 8 pp. doi URL ↑132, 139
- [59] Mathes T., Piater J. *Robust non-rigid object tracking using point distribution manifolds* // *Pattern Recognition*, Lecture Notes in Computer Science.– vol. **4174**, Berlin–Heidelberg: Springer.– 2006.– ISBN 978-3-540-44414-5.– Pp. 515–524. doi ↑133, 139
- [60] Руиз-Родригез М., Кобер В. И., Карнаухов В. Н., Мозеров М. Г. *Алгоритм трехмерной реконструкции нежестких объектов с использованием камеры глубины* // *Информационные процессы*.– 2019.– Т. **19**.– № 4.– С. 388–398. URL ↑134, 139
- [61] Sipiran I., Bustos B. H. *Harris 3D: a robust extension of the harris operator for interest point detection on 3D meshes* // *The Visual Computer*.– 2011.– Vol. **27**.– No. 11.– Pp. 963–976. doi ↑134
- [62] Zhong Y. *Intrinsic shape signatures: A shape descriptor for 3D object recognition* // *Proceedings of the 2009 IEEE Conference on Computer Vision Workshops, ICCVW'09* (Kyoto, Japan, 27 September–4 October, 2009).– IEEE.– 2009.– ISBN 978-1-4244-4442-7.– Pp. 689–696. doi ↑134
- [63] Smith S. M., Brady J. M. *SUSAN — a new approach to low level image processing* // *International Journal of Computer Vision*.– 1997.– Vol. **23**.– No. 1.– Pp. 45–78. doi ↑134
- [64] Lowe D. G. *Distinctive image features from scale-invariant keypoints* // *International Journal of Computer Vision*.– 2004.– Vol. **60**.– No. 2.– Pp. 91–110. doi ↑134
- [65] Rusu R. B., Marton Z. C., Blodow N., Beetz M. *Persistent point feature histograms for 3D point clouds* // *Proceedings of the 10th International Conference on Intelligent Autonomous Systems, IAS-10* (Baden-Baden, Germany, 23–25 July, 2008).– IOS Press.– 2008.– ISBN 978-1-58603-887-8.– Pp. 119–128. doi ↑134
- [66] Tombari F., Salti S., Stefano L. D. *Unique signatures of histograms for local surface description* // *Proceedings of the 2010 European Conference on Computer Vision, ECCV'10* (Crete, Greece, 5–11 September, 2010), Lecture Notes in Computer Science.– vol. **6313**, Berlin–Heidelberg: Springer.– 2010.– ISBN 978-3-642-15557-4.– Pp. 356–369. doi ↑134
- [67] Frome A., Huber D., Kolluri R., Bulow T., Malik J. *Recognizing objects in range data using regional point descriptors* // *Proceedings of the 2004 European Conference on Computer Vision, ECCV'04* (Prague, Czech Republic, 11–14 May, 2004), Berlin–Heidelberg: Springer.– 2004.– ISBN 978-3-540-21982-8.– Pp. 224–237. doi ↑134


- [68] Lazebnik S., Schmid C., Ponce J. *A sparse texture representation using local affine regions* // IEEE Transactions on Pattern Analysis and Machine Intelligence.– 2005.– Vol. **27**.– No. 8.– Pp. 1265–1278.  ^{↑134}
- [69] Marton Z. C., Pangercic D., Blodow N., Kleinhellefort J., Beetz M. *General 3D modelling of novel objects from a single view* // *Proceedings of the 2010 IEEE/RSJ Conference on Intelligent Robots and Systems, IROS'10* (Taipei, Taiwan, 18–22 October, 2010).– IEEE.– 2010.– ISBN 978-1-4244-6674-0.– Pp. 3700–3705.  ^{↑134}
- [70] Sturm J., Engelhard N., Endres F., Burgard W., Cremers D. *A Benchmark for the evaluation of RGB-D SLAM systems* // *Proceedings of the 2012 IEEE/RSJ Conference on Intelligent Robots and Systems (IROS)*, IROS'12 (Vilamoura-Algarve, Portugal, 7–12 October, 2012).– IEEE.– 2012.– ISBN 978-1-4673-1737-5.– Pp. 573–580.  ^{↑134}

Поступила в редакцию 08.10.2024;
 одобрена после рецензирования 22.12.2024;
 принята к публикации 22.12.2024;
 опубликована онлайн 26.12.2024.

Рекомендовал к публикации

д.т.н. В. М. Хачумов

Информация об авторах:



Григорий Глебович Гриценко

Аспирант ИПС им. А.К. Айламазяна РАН. Область научных интересов: локализация и трекинг неригидных объектов.



0009-0006-6838-9632

e-mail:



Виталий Петрович Фраленко

Кандидат технических наук, ведущий научный сотрудник ИЦМС ИПС им. А.К. Айламазяна РАН. Область научных интересов: интеллектуальный анализ данных и распознавание образов, искусственный интеллект и принятие решений, параллельно-конвейерные вычисления, сетевая безопасность, диагностика сложных технических систем, графические интерфейсы.



0000-0003-0123-3773

e-mail:

Авторы внесли равный вклад в подготовку публикации.

Декларация об отсутствии личной заинтересованности: благополучие авторов не зависит от результатов исследования.



An analytical review of architectures, models, methods and algorithms for localization and tracking of non-rigid objects

Grigory Glebovich **Gricenko**¹, Vitaly Petrovich **Fralenko**²

^{1,2} Ailamazyan Program Systems Institute of RAS, Ves'kovo, Russia

Abstract. Computer vision requires video stream analysis, including extracting information from frames, detecting specific objects, and collecting data about them. After detection, *tracking* or following objects in the video stream is often required. *Non-rigidity* or shape variability hinders object analysis, complicates their detection and tracking, and worsens localization.

The review considers architectures, models, methods, and algorithms used in practice for detection and tracking of non-rigid objects, and highlights promising solutions. (*In Russian*).

Key words and phrases: non-rigid object, artificial neural network, deep learning, object localization, object tracking, fire and smoke detection, medical image analysis

2020 *Mathematics Subject Classification:* 68T45; 68T07

Acknowledgments: This work was financially supported by the *Russian Science Foundation*, project № 21-71-10056^{URU} and a grant in the form of a subsidy from the regional budget to organizations of the Yaroslavl region.

For citation: Grigory G. Gricenko, Vitaly P. Fralenko. *An analytical review of architectures, models, methods and algorithms for localization and tracking of non-rigid objects*. Program Systems: Theory and Applications, 2024, 15:4(63), pp. 111–151. (*In Russ.*). https://psta.psiras.ru/read/psta2024_4_111-151.pdf

References

- [1] A. Ergasheva, F. Akhmedov, A. Abdusalomov, W. Kim. “Advancing maritime safety: early detection of ship fires through computer vision, deep learning approaches, and histogram equalization techniques”, *Fire*, **7**:3 (2024), id. 84, 15 pp. 
- [2] A. Farkhod, A. Abdusalomov, F. Makhmudov, Y. I. Cho. “LDA-based topic modeling sentiment analysis using topic/document/sentence (TDS)”, *Applied Sciences*, **11**:23 (2021), id. 11091, 15 pp. 
- [3] F. Xu, X. Zhang, T. Deng, W. Xu. “An image-based fire monitoring algorithm resistant to fire-like objects”, *Fire*, **7**:1 (2024), id. 3, 12 pp. 
- [4] S. Woo, J. Park, J.-Y. Lee. *CBAM: convolutional block attention module*, 2018, 17 pp.  1807.06521v2 [cs.CV] 
- [5] G. Li, P. Chen, C. Xu, C. Sun, Y. Ma. “Anchor-free smoke and flame recognition algorithm with multi-loss”, *Fire*, **6**:6 (2023), id. 225, 16 pp. 
- [6] X. Li, Y. Liang. “Fire-RPG: an urban fire detection network providing warnings in advance”, *Fire*, **7**:7 (2024), id. 214, 22 pp. 
- [7] X. Ding, X. Zhang, N. Ma, J. Han, G. Ding, J. Sun. *RepVGG: Making VGG-style ConvNets great again*, 2021, 10 pp.  2101.03697 [cs.CV] 
- [8] Y. Tang, K. Han, J. Guo, C. Xu, C. Xu, Y. Wang. *GhostNetV2: enhance cheap operation with long-range attention*, 2022, 12 pp.  2211.12905 [cs.CV] 
- [9] Q. L. Zhang, Y. B. Yang. *SA-Net: shuffle attention for deep convolutional neural networks*, 2021, 9 pp.  2102.00240 [cs.CV] 
- [10] Q. Wang, B. Wu, P. Zhu, P. Li, W. Zuo, Q. Hu. *ECA-Net: efficient channel attention for deep convolutional neural Networks*, 2020, 12 pp.  1910.03151v4 [cs.CV] 
- [11] L. Yang, R. Y. Zhang, L. Li, X. Xie. *Simple attention module based speaker verification with iterative noisy label detection*, 2021, 5 pp.  2110.06534 [cs.CV] 
- [12] J. Xie, H. Zhao. “Forest fire object detection analysis based on knowledge distillation”, *Fire*, **6**:12 (2023), id. 446, 15 pp. 
- [13] C. Jin, T. Wang, N. Alhusaini, S. Zhao, H. Liu, K. Xu, J. Zhang. “Video fire detection methods based on deep learning: datasets, methods, and future directions”, *Fire*, **6**:8 (2023), id. 315, 27 pp. 
- [14] F. Yuan, L. Zhang, B. Wan, X. Xia, J. Shi. “Convolutional neural networks based on multi-scale additive merging layers for visual smoke recognition”, *Machine Vision and Applications*, **30** (2019), pp. 345–358. 
- [15] K. Muhammad, J. Ahmad, Z. Lv, P. Bellavista, P. Yang, S. W. Baik. “Efficient deep CNN-based fire detection and localization in video surveillance applications”, *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, **49**:7 (2019), pp. 1419–1434. 
- [16] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, K. Keutzer. *SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size*, 2016, 13 pp.  1602.07360 [cs.CV] 
- [17] O. Khudayberdiev, J. Zhang, S. M. Abdullahi, S. Zhang. “Light-FireNet:

- an efficient lightweight network for fire detection in diverse environments”, *Multimedia Tools and Applications*, **81** (2022), pp. 24553–24572. [doi](#)
- [18] S. Zheng, P. Gao, W. Wang, X. Zou. “A highly accurate forest fire prediction model based on an improved dynamic convolutional neural network”, *Applied Sciences*, **12**:13 (2022), id. 6721, 15 pp. [doi](#)
 - [19] H. Tao, Q. Duan. “An adaptive frame selection network with enhanced dilated convolution for video smoke recognition”, *Expert Systems with Applications*, **215** (2023), id. 119371, 11 pp. [doi](#)
 - [20] Z. A. Khan, T. Hussain, F. U. M. Ullah, S. K. Gupta, M. Y. Lee, S. W. Baik. “Randomly initialized CNN with densely connected stacked autoencoder for efficient fire detection”, *Engineering Applications of Artificial Intelligence*, **116** (2022), id. 105403, 11 pp. [doi](#)
 - [21] C. Hu, P. Tang, W. Jin, Z. He, W. Li. “Real-time fire detection based on deep convolutional long-recurrent networks and optical flow method”, *Proceedings of the 2018 37th Chinese Control Conference (CCC)*, CCC 2018 (Wuhan, China, 25–27 July, 2018), IEEE, 2018, ISBN 978-1-538-64968-8, pp. 9061–9066. [doi](#)
 - [22] S. Li, Q. Yan, P. Liu. “An efficient fire detection method based on multiscale feature extraction, implicit deep supervision and channel attention mechanism”, *IEEE Transactions on Image Processing*, **29** (2020), pp. 8467–8475. [doi](#)
 - [23] C. Yang, Y. Pan, Y. Cao, X. Lu. “CNN-transformer hybrid architecture for early fire detection”, *Proceedings of the Artificial Neural Networks and Machine Learning. V. IV, ICANN 2022: 31st International Conference on Artificial Neural Networks* (Bristol, UK, 6–9 September, 2022), Lecture Notes in Computer Science, vol. **13532**, Springer, Berlin, 2022, ISBN 978-3-031-15936-7, pp. 570–581. [doi](#)
 - [24] X. Wang, L. Cai, S. Zhou, Y. Jin, L. Tang, Y. Zhao. “Fire safety detection based on CAGSA-YOLO network”, *Fire*, **6**:8 (2023), id. 297, 19 pp. [doi](#)
 - [25] Z. Ding, Y. Zhao, A. Li, Z. Zheng. “Spatial-temporal attention two-stream convolution neural network for smoke region detection”, *Fire*, **4**:4 (2021), id. 66, 12 pp. [doi](#)
 - [26] Y. Cao, Q. Tang, X. Lu, F. Li, J. Cao. *STCNet: spatio-temporal cross network for industrial smoke detection*, 2020, 10 pp. [arXiv:2011.04863 \[cs.CV\]](#) [doi](#)
 - [27] Y. Shou, T. Meng, W. Ai, C. Xie, H. Liu, Y. Wang. “Object detection in medical images based on hierarchical transformer and mask mechanism”, *Computational Intelligence and Neuroscience*, **2022** (2022), id. 5863782, 12 pp. [doi](#)
 - [28] S.-G. Lee, E. Kim, J. S. Bae, J. H. Kim, S. Yoon. “Robust end-to-end focal liver lesion detection using unregistered multiphase computed tomography images”, *IEEE Transactions on Emerging Topics in Computational Intelligence*, **7**:2 (2023), pp. 319–329. [doi](#)
 - [29] de Frutos J. P., A. Pedersen, E. Pelanis, D. Bouget, S. Survarachakan, S. Survarachakan, O.-J. Elle, F. Lindseth. “Learning deep abdominal CT registration through adaptive loss weighting and synthetic data generation”, *PLOS ONE*, **18**:2 (2023), pp. 1–14. [doi](#)

- [30] A. K. Tyagi, C. Mohapatra, P. Das, G. Makharia, L. Mehra, P. AP, P. AP. *DeGPR: deep guided posterior regularization for multi-class cell detection and counting*, 2023, 11 pp. [arXiv:2304.00741](#) [cs.CV] [doi](#)
- [31] M. Kang, C.-M. Ting, F. F. Ting, R. C.-W. Phan. *RCS-YOLO: a fast and high-accuracy object detector for brain tumor detection*, 2023, 11 pp. [arXiv:2307.16412v2](#) [cs.CV] [doi](#)
- [32] M. Kang, C.-M. Ting, F. F. Ting, R. C.-W. Phan. *BGF-YOLO: enhanced YOLOv8 with multiscale attentional feature fusion for brain tumor detection*, 2023, 5 pp. [arXiv:2309.12585v2](#) [cs.CV] [doi](#)
- [33] X. Xu, Y. Jiang, W. Chen, Y. Huang, Y. Zhang, X. Sun. *DAMO-YOLO: a report on real-time object detection design*, 2023, 10 pp. [arXiv:2211.15444v4](#) [cs.CV] [doi](#)
- [34] M. Kang, C.-M. Ting, F. F. Ting, R. C.-W. Phan. *RCS-YOLO: a fast and high-accuracy object detector for brain tumor detection*, 2023, 11 pp. [arXiv:2307.16412v2](#) [cs.CV] [doi](#)
- [35] A. Jadon, M. Omama, A. Varshney, M. S. Ansari, R. Sharma. *FireNet: a specialized lightweight fire & smoke detection model for real-time IoT applications*, 2019, 6 pp. [arXiv:1905.11922v2](#) [cs.CV] [doi](#)
- [36] A. Shees, M. S. Ansari, A. Varshney, M. N. Asghar, N. Kanwal. “FireNet-v2: improved lightweight fire detection model for real-time IoT applications”, *Procedia Computer Science*, **218** (2023), pp. 2233–2242. [doi](#)
- [37] A. H. Altowaijri, M. S. Alfaifi, T. A. Alshawi, A. B. Ibrahim, S. A. Alshebeili. “A privacy-preserving IoT-Based fire detector”, *IEEE Access*, **9** (2021), pp. 51393–51402. [doi](#)
- [38] Y. Valikhujaev, A. Abdusalomov, Y. I. Cho. “Automatic fire and smoke detection method for surveillance systems based on dilated CNNs”, *Atmosphere*, **11**:11 (2020), id. 1241, 15 pp. [doi](#)
- [39] K. Muhammad, J. Ahmad, I. Mehmood, S. Rho, S. W. Baik. “Convolutional neural networks based fire detection in surveillance videos”, *IEEE Access*, **6** (2018), pp. 18174–18183. [doi](#)
- [40] S. Saponara, A. Elhanashi, A. Gagliardi. “Real-time video fire/smoke detection based on CNN in antifire surveillance systems”, *Journal of Real-Time Image Processing*, **18** (2021), pp. 889–900. [doi](#)
- [41] A. Ayala, E. Lima, B. Fernandes, B. L. Bezerra, F. Cruz. “Lightweight and efficient octave convolutional neural network for fire recognition”, *Proceedings of the 2019 IEEE Latin American Conference on Computational Intelligence*, LA-CCI’2019 (Guayaquil, Ecuador, 11–15 November, 2019), IEEE, 2019, ISBN 978-1-7281-5666-8, 6 pp. [doi](#)
- [42] S. Saponara, A. Elhanashi, A. Gagliardi. “Exploiting R-CNN for video smoke/fire sensing in antifire surveillance indoor and outdoor systems for smart cities”, *Proceedings of the 2020 IEEE International Conference on Smart Computing*, SMARTCOMP’2020 (Bologna, Italy, 14–17 September, 2020), IEEE, 2020, ISBN 978-1-7281-6997-2, pp. 392–397. [doi](#)
- [43] W. Thomson, N. Bhowmik, T. P. Breckon. *Efficient and compact convolutional neural network architectures for non-temporal real-time fire detection*, 2020, 6 pp. [arXiv:2010.08833](#) [cs.CV] [doi](#)

- [44] B. Zoph, V. Vasudevan, J. Shlens, Q. V. Le. “Learning transferable architectures for scalable image recognition”, *Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, CVPR’18 (Salt Lake City, Utah, 18–22 June, 2018), IEEE, 2018, ISBN 978-1-728-13294-5, pp. 8697–8710. 
- [45] N. Ma, X. Zhang, H.-T. Zheng, J. Sun. “Shufflenet v2: practical guidelines for efficient CNN architecture design”, *Proceedings of the 2018 European Conference on Computer Vision (ECCV)*, ECCV’18 (Munich, Germany, 8–14 September, 2018), Lecture Notes in Computer Science, vol. **11218**, Springer, Cham, 2018, ISBN 978-3-030-01263-2, pp. 122–138. 
- [46] H. Li, A. Kadav, I. Durdanovic, H. Samet, H. P. Graf. *Pruning filters for efficient ConvNets*, 2017, 13 pp. [arXiv:1608.08710v3](https://arxiv.org/abs/1608.08710v3) [cs.CV] 
- [47] Y. Hu, J. Zhan, G. Zhou, A. Chen, W. Cai, K. Guo, Y. Hu, L. Li. “Fast forest fire smoke detection using MVMNet”, *Knowledge-Based Systems*, **241** (2022), 20 pp. 
- [48] K. Yan, M. Bagheri, R. M. Summers. *3D context enhanced region-based convolutional neural network for end-to-end lesion detection*, 2018, 11 pp. [arXiv:1806.09648v2](https://arxiv.org/abs/1806.09648v2) [cs.CV] 
- [49] P. Zhang, W. Liu, D. Wang, Y. Lei, H. Wang, C. Shen, H. Lu. *Non-rigid object tracking via deep multi-scale spatial-temporal discriminative saliency maps*, 2019, 12 pp. [arXiv:1802.07957v2](https://arxiv.org/abs/1802.07957v2) [cs.CV] 
- [50] S. Hong, T. You, S. Kwak, B. Han. “Online tracking by learning discriminative saliency map with convolutional neural network”, *Proceedings of the 32nd International Conference on Machine Learning, ICML’15* (Lille, France, 6–11 July, 2015), PMLR, vol. **37**, 2015, ISBN 978-1-510-81058-7, pp. 597–606. 
- [51] J. Son, I. Jung, K. Park, B. Han. “Tracking-by-segmentation with online gradient boosting decision tree”, *Proceedings of the 2015 IEEE International Conference on Computer Vision, ICCV’15* (Santiago, Chile, 07–13 December, 2015), IEEE, 2015, ISBN 978-1-4673-8391-2, pp. 3056–3064. 
- [52] X. Sun, N.-M. Cheung, H. Yao, Y. Guo. “Non-rigid object tracking via deformable patches using shape-preserved KCF and level sets”, *Proceedings of the 2017 IEEE International Conference on Computer Vision, ICCV’17* (Venice, Italy, 22–29 October, 2017), IEEE, 2017, ISBN 978-1-5386-1032-9, pp. 5496–5504. 
- [53] S. Duffner, C. Garcia. “PixelTrack: a fast adaptive algorithm for tracking non-rigid objects”, *Proceedings of the 2013 IEEE International Conference on Computer Vision, ICCV’13* (Sydney, NSW, Australia, 1–8 December, 2013), IEEE, 2013, ISBN 978-1-4799-2840-8, pp. 2480–2487. 
- [54] L. Sevilla-Lara, E. Learned-Miller. “Distribution fields for tracking”, *Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition, CVPR’12* (Providence, RI, USA, 16–21 June, 2012), 2012, ISBN 978-1-4673-1226-4, pp. 1910–1917. 
- [55] M. Godec, P. M. Roth, H. Bischof. “Hough-based tracking of non-rigid objects”, *Proceedings of the 2011 IEEE International Conference on Computer*

- Vision*, ICCV'11 (Barcelona, Spain, 06–13 November, 2011), 2011, ISBN 978-1-4577-1101-5, pp. 81–88. [doi](#)
- [56] X. Sun, H. Yao, S. Zhang, D. Li. “Non-rigid object contour tracking via a novel supervised level set model”, *IEEE Transactions on Image Processing*, **24**:11 (2015), pp. 3386–3399. [doi](#)
- [57] Y. Li, J. Zhu, S. Hoi. “Reliable Patch Trackers: Robust visual tracking by exploiting reliable patches”, *Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition*, CVPR'15 (Boston, MA, USA, 07–12 June, 2015), IEEE, 2015, ISBN 978-1-4673-6964-0, pp. 353–361. [doi](#)
- [58] J. I. Olszewska, T. Mathes, C. D. Vleeschouwer, J. Piater, B. Macq. “Non-rigid object tracker based on a robust combination of parametric active contour and point distribution model”, *Visual Communications and Image Processing 2007* (San Jose, CA, USA, 28 January–1 February, 2007), *Proc. SPIE*, vol. **6508**, 2007, ISBN 978-0-8194-6621-1, id. 65082A, 8 pp. [doi](#) [URL](#)
- [59] T. Mathes, J. Piater. “Robust non-rigid object tracking using point distribution manifolds”, *Pattern Recognition*, *Lecture Notes in Computer Science*, vol. **4174**, Springer, Berlin–Heidelberg, 2006, ISBN 978-3-540-44414-5, pp. 515–524. [doi](#)
- [60] M. Ruiz-Rodríguez, V. I. Kober, V. N. Karnauxov, M. G. Mozerov. “Algorithm for three-dimensional reconstruction of non-rigid objects using a depth camera”, *Informacionnye processy*, **19**:4 (2019), pp. 388–398 (in Russian). [URL](#)
- [61] I. Sipiran, B. H. Bustos. “Harris 3D: a robust extension of the harris operator for interest point detection on 3D meshes”, *The Visual Computer*, **27**:11 (2011), pp. 963–976. [doi](#)
- [62] Y. Zhong. “Intrinsic shape signatures: A shape descriptor for 3D object recognition”, *Proceedings of the 2009 IEEE Conference on Computer Vision Workshops*, ICCVW'09 (Kyoto, Japan, 27 September–4 October, 2009), IEEE, 2009, ISBN 978-1-4244-4442-7, pp. 689–696. [doi](#)
- [63] S. M. Smith, J. M. Brady. “SUSAN — a new approach to low level image processing”, *International Journal of Computer Vision*, **23**:1 (1997), pp. 45–78. [doi](#)
- [64] D. G. Lowe. “Distinctive image features from scale-invariant keypoints”, *International Journal of Computer Vision*, **60**:2 (2004), pp. 91–110. [doi](#)
- [65] R. B. Rusu, Z. C. Marton, N. Blodow, M. Beetz. “Persistent point feature histograms for 3D point clouds”, *Proceedings of the 10th International Conference on Intelligent Autonomous Systems*, IAS-10 (Baden-Baden, Germany, 23–25 July, 2008), IOS Press, 2008, ISBN 978-1-58603-887-8, pp. 119–128. [doi](#)
- [66] F. Tombari, S. Salti, L. D. Stefano. “Unique signatures of histograms for local surface description”, *Proceedings of the 2010 European Conference on Computer Vision*, ECCV'10 (Crete, Greece, 5–11 September, 2010), *Lecture Notes in Computer Science*, vol. **6313**, Springer, Berlin–Heidelberg, 2010, ISBN 978-3-642-15557-4, pp. 356–369. [doi](#)
- [67] A. Frome, D. Huber, R. Kolluri, T. Bulow, J. Malik. “Recognizing objects in range data using regional point descriptors”, *Proceedings of the 2004 European Conference on Computer Vision*, ECCV'04 (Prague, Czech Republic, 11–14

- May, 2004), Springer, Berlin–Heidelberg, 2004, ISBN 978-3-540-21982-8, pp. 224–237. 
- [68] S. Lazebnik, C. Schmid, J. Ponce. “A sparse texture representation using local affine regions”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **27**:8 (2005), pp. 1265–1278. 
- [69] Z.C. Marton, D. Pangercic, N. Blodow, J. Kleinhellefort, M. Beetz. “General 3D modelling of novel objects from a single view”, *Proceedings of the 2010 IEEE/RSJ Conference on Intelligent Robots and Systems*, IROS’10 (Taipei, Taiwan, 18–22 October, 2010), IEEE, 2010, ISBN 978-1-4244-6674-0, pp. 3700–3705. 
- [70] J. Sturm, N. Engelhard, F. Endres, W. Burgard, D. Cremers. “A Benchmark for the evaluation of RGB-D SLAM systems”, *Proceedings of the 2012 IEEE/RSJ Conference on Intelligent Robots and Systems (IROS)*, IROS’12 (Vilamoura-Algarve, Portugal, 7–12 October, 2012), IEEE, 2012, ISBN 978-1-4673-1737-5, pp. 573–580. 



Извлечение симптомов и автоматическое предсказание диагноза по медицинским клиническим записям

Юрий Петрович **Сердюк**¹, Наталья Александровна **Власова**²,
Сева Рубеновна **Момот**³

¹⁻³Институт программных систем им. А. К. Айламазяна РАН, Веськово, Россия

Аннотация. В статье представлена система, которая извлекает симптомы заболеваний из медицинских клинических записей (текстов на естественном русском языке) и автоматически предсказывает по ним диагноз в виде наименования заболевания и его кода в соответствии со справочником МКБ-10. Система ограничена предметной областью из 6 пульмонологических заболеваний (хроническая обструктивная болезнь легких, пневмония, бронхиальная астма и др.) и COVID-19.

Извлечение симптомов реализовано с помощью нескольких нейронных сетей, выделяющих отдельные медицинские сущности и связи между ними. Предсказание диагноза также реализовано в виде классификатора на основе нейронной сети. Для обучения извлечению симптомов создан аннотированный корпус предложений. Описаны принципы и правила разметки симптомов. Представлен корпус текстов для обучения классификатора предсказанию диагнозов.

Приведены оценки точности при тестировании обеих подсистем. Точность предсказания диагноза на данной предметной области составила 88,5%. Даны сравнения с аналогичными работами по извлечению симптомов из текстов на различных языках, а также по автоматическому предсказанию диагнозов, включая системы типа ChatGPT.

Ключевые слова и фразы: системы поддержки принятия врачебных решений, извлечение симптомов, автоматическое предсказание диагнозов, BERT-модели, системы на основе ChatGPT

Для цитирования: Сердюк Ю. П., Власова Н. А., Момот С. Р. *Извлечение симптомов и автоматическое предсказание диагноза по медицинским клиническим записям* // Программные системы: теория и приложения. 2024. Т. 15. № 4(63). С. 153–181. https://psta.psisras.ru/read/psta2024_4_153-181.pdf

Введение

Одним из главных трендов развития современных систем здравоохранения является применение высокотехнологичных решений с использованием искусственного интеллекта (ИИ). В первую очередь методы ИИ находят свое применение в так называемых системах поддержки принятия клинических (врачебных) решений (СППКР/СППВР) [1]. Эти системы прошли долгий путь развития начиная с 1990-х годов, когда они строились на основе различного рода экспертных систем, базировавшихся, в свою очередь, на знаниях в виде правил или семантических сетей (фреймов), логических языках программирования типа PROLOG и других средствах [2].

На настоящий момент подавляющее число систем, работающих в области здравоохранения и использующих элементы ИИ, ориентировано на обработку медицинских изображений. Однако в последние годы существенный прогресс в области ИИ связан с применением нейронных сетей для обработки текстовой медицинской информации, включая «большие языковые модели» (Large Language Models — LLM), а также системы типа ChatGPT, которые позволяют намного более эффективно, чем ранее, решать задачи обработки (медицинских) текстов на естественном языке (ЕЯ) [3–5].

Существует несколько способов использования нейронных сетей и, в частности, LLM для обработки медицинских текстов. Часто нейронные сети обучают для извлечения значимой информации из текстов — в первую очередь симптомов и всего, что с ними связано [6, 7]. С другой стороны, системы на базе LLM применяют для прямой постановки диагноза по записям в (электронной) медицинской карте пациента [4, 8]. Также нейронные модели используются, например, для извлечения отзывов пациентов на применение тех или иных лекарств [9].

Упомянутые выше системы обладают рядом недостатков (подробный сравнительный обзор этих систем дан в разделе 3 «Обзор смежных работ»). В частности, в работе [7] симптомы извлекаются не в структурированном виде (см. раздел 1), а в форме «упоминаний симптомов», и дальнейшая постановка диагноза осуществляется на основе множества решающих правил. Семейства решающих правил обладают теми известными недостатками, что они трудоемки в разработке, у них обычно отсутствует полнота охвата возможных симптомов и их комбинаций, а при увеличении количества таких правил становится трудно следить за их непротиворечивостью.

С другой стороны, доказано, что нейронные сети способны смоделировать (вычислить) любую (предсказательную) функцию [21, Гл. 4].

В работе [4] предлагается подход к обучению нейронной сети простой классификации текстов (электронных записей о пациенте) на 265 классов, соответствующих заболеваниям из Международной классификации болезней версии 10 (МКБ-10). В данной системе отсутствует извлечение симптомов как таковое, что, в частности, делает невозможным какое-либо объяснение поставленного диагноза.

Системы типа ChatGPT вообще оказались практически непригодными в задачах автоматической постановки диагноза — диагностическая система на базе GPT-3.5 допустила ошибки в 83% педиатрических случаев, а система на базе GPT-4 правильно диагностировала только 39% сложных медицинских случаев у взрослых и детей [10].

В данной статье описывается система, в которой предпринята попытка устранения недостатков, присутствующих в упомянутых подходах. Постановка диагноза врачом является сложным многоэтапным процессом, в результате которого формируется ответ обычно состоящий из нескольких структурных частей:

- (1) основного диагноза,
- (2) осложнений основного заболевания,
- (3) сопутствующих заболеваний.

В настоящей работе моделируются два этапа процесса постановки диагноза:

- (1) извлечения симптомов из (электронной) медицинской карты пациента,
- (2) формулировки гипотезы о заболевании в виде его наименования и кода МКБ-10.

Хотя в современных медицинских информационных системах (МИС) информация о пациенте вводится через заранее подготовленные шаблоны, что делает ее частично структурированной, некоторая ее часть (иногда значительная и включающая в себя важные диагностические признаки) остается в свободном неструктурированном виде. Представляемая система способна извлекать симптомы из любого текста (структурированного и неструктурированного), представляя их в едином формате.

В первую очередь извлекаются те симптомы заболевания, которые наиболее важны и специфичны для заданной группы заболеваний. Кроме того, развитые подсистемы извлечения симптомов из неструктурированного текста позволят уменьшить трудоемкость разработки и сопровождения МИС, в частности, программирования и перепрограммирования входных шаблонов, оставив только стандартные шаблоны для всех или определенных групп заболеваний.

Шаг извлечения симптомов из имеющихся медицинских документов, относящихся к данному пациенту, и предъявление их врачу можно рассматривать как частичное объяснение выставленного впоследствии диагноза. Для получения максимально значимых практических результатов представляемая система ограничена предметной областью из шести пульмонологических заболеваний и COVID-19.

Результатом работы системы являются

- (1) список симптомов в структурированном виде — симптом и его значение,
- (2) гипотеза о диагнозе в виде названия заболевания, его кода по классификации МКБ-10, процента вероятности данного диагноза.

В случае, когда система не может с достаточной степенью уверенности предсказать заболевание, об этом выдается специальное сообщение.

Таким образом, предлагаемую систему можно использовать в качестве помощника врача, систематизирующего и представляющего в едином формате информацию, собранную о пациенте, и предлагающего гипотезу о вероятном заболевании.

Статья построена следующим образом:

В разделе 1 «Извлечение диагностических признаков» описан этап извлечения симптомов, которые мы расширяем до более общего понятия «диагностические признаки». Представлен аннотированный корпус предложений для обучения нейронной сети извлечению диагностических признаков, описаны принципы и правила их разметки.

В разделе 2 «Постановка диагноза» описан классификатор на основе нейронной сети, который осуществляет постановку диагноза по извлеченным диагностическим признакам. Представлен корпус из 140 документов, использованных для обучения классификатора.

В разделе 3 даны сравнения представляемой работы с аналогичными работами по извлечению симптомов, как с отечественными, так и с зарубежными, включая системы по извлечению симптомов COVID-19. Аналогично, приведены сравнительные сведения о системах автоматической постановки диагнозов, включая системы, разработанные в СберМедИИ, и системы на основе ChatGPT.

В заключительном разделе 4 сделаны краткие выводы о проделанной работе и обозначены пути дальнейшего совершенствования представленной системы.

1. Извлечение диагностических признаков

В рамках описываемого в данной статье подхода одним из этапов процесса диагностики является извлечение из (электронной) медицинской карты пациента, включающей обычно неструктурированную часть, всей необходимой для этого информации. Соответственно, ниже мы применяем термин «диагностический признак», понимая под ним не только отклонения и нарушения работы организма пациента (симптомы заболевания), но и любую другую информацию, которая может быть использована врачом (а также автоматической системой) для постановки диагноза. Иногда для краткости изложения мы будем использовать термин «симптом», понимая под ним диагностический признак.

В качестве диагностических признаков обычно рассматриваются

- (1) симптомы определенных заболеваний (малопродуктивный кашель, дизурия, менингеальные знаки) — такие симптомы мы называем симптомами-отклонениями,
- (2) описание состояния и характеристики органов или частей тела (кожные покровы бледно-розовые, сердечные тоны ясные, зев спокоен) — такие описания мы называем симптомами-характеристиками,
- (3) выражения с числовыми данными (температура $38,6^{\circ}\text{C}$, частота дыхательных движений 21–22 в минуту, сатурация 98%) — такие выражения называются показателями,
- (4) сведения об анамнезах пациента и его общем состоянии.

К результату работы подсистемы извлечения диагностических признаков предъявляются два основных требования:

- (1) понятность, наглядность и естественность представления выделенных из документа признаков (возможно, с ориентацией на определенную группу заболеваний),
- (2) возможность их эффективного использования при постановке диагноза автоматической системой.

В частности, первое требование позволяет использовать выделенные признаки как часть объяснения поставленного системой диагноза.

Возможны несколько подходов к аннотированию симптомов/диагностических признаков со структурной точки зрения:

- (1) неструктурное аннотирование, когда выделяются выражения, представляющие собой «упоминания симптомов»:
 - «малопродуктивный кашель»,
 - «миндалины гиперемированы, гипертрофированы»,

«грудная клетка правильной формы»,
«одышка при повышении физической нагрузки»;

- (2) разбивка диагностического признака на две части — непосредственно на признак и на его значение:

[кашель; *малопродуктивный*]
[миндалины; *гиперемированы, гипертрофированы*]
[грудная клетка; *правильной формы*]
[одышка; *при повышении физической нагрузки*]

- (3) выделение семантических медицинских сущностей с последующим конструированием из них диагностических признаков.

Первый подход [11] обладает тем недостатком, что различных упоминаний симптомов имеется очень большое количество, и потому для них трудно построить систему, прогнозирующую диагноз. В этом случае иногда прибегают к упрощению понятия «симптом/диагностический признак», выбрасывая из упоминания симптома некоторые его части, например, в выражении «одышка при повышении физической нагрузки» оставляют только слово «одышка» [7], что, естественно, намного снижает возможности системы по постановке правильного диагноза.

Третий подход состоит в том, что первоначально в тексте выделяются такие сущности как «заболевание (нарушение)», «симптом», «часть тела», «физиологический процесс», «степень тяжести (интенсивность)», «характеристика» и некоторые другие ¹, а далее из них собираются более крупные структурные единицы — диагностические признаки, на основе которых уже ставится диагноз. Недостаток этого подхода состоит в том, что очень трудно сформулировать достаточно точные правила относящие слова и словосочетания к той или иной семантической категории — примером является выражение «затруднение носового дыхания», что делает процесс аннотирования неоднозначным и очень сложным.

В нашей работе мы применяем второй подход, в котором диагностический признак считается состоящим из двух частей — непосредственно признака и его значения. Этот подход моделирует медицинскую практику врачей, когда в качестве результата обследования пациента перед этапом постановки диагноза формируется карта извлеченных симптомов (признаков). На рисунке 1 показан пример фрагмента карты обследования пациента, формируемой в одной из МИС с использованием шаблонов.

¹см., например, описание схем разметки на странице *аннотированного корпуса клинических текстов, созданного совместно ИСА РАН и НЦЗД*.^(url)

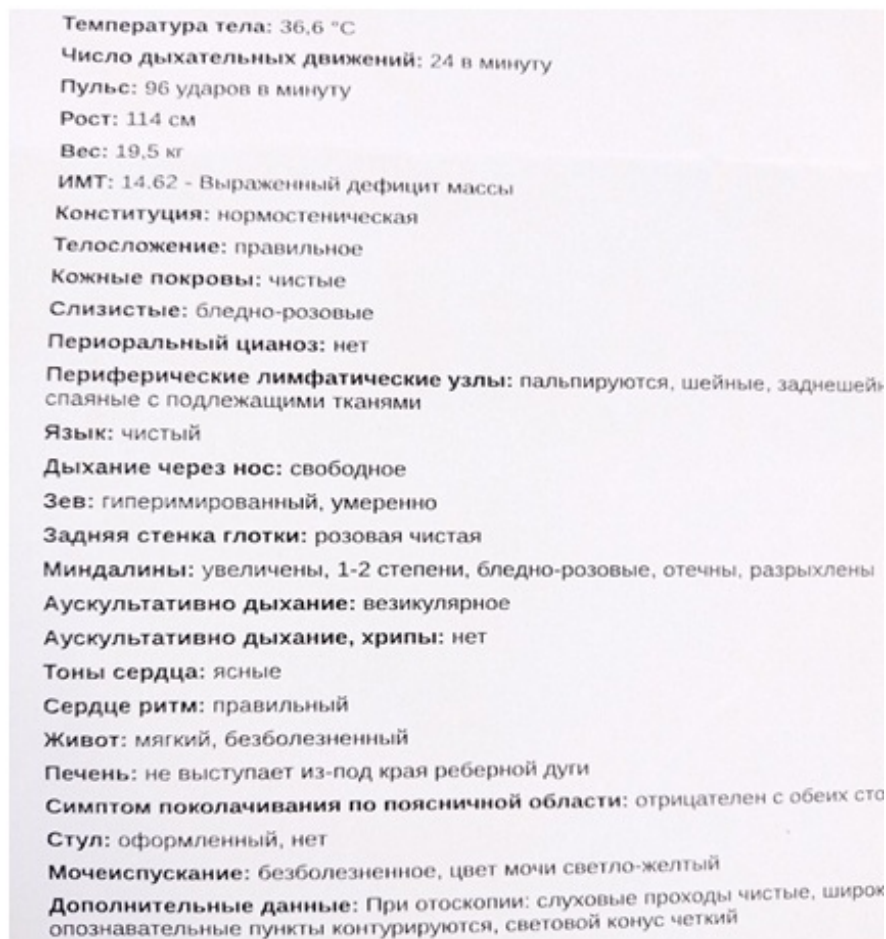


Рисунок 1. Пример результирующей карты обследования пациента.

Представляемая система позволяет строить аналогичную карту из любого свободного, неструктурированного текста. Кроме того, сама разметка признаков и их значений более проста по сравнению с другими подходами к аннотированию медицинских сущностей (см. Принцип I ниже).

Далее выделенные признаки оформляются в виде входов классификатора, на которые подаются соответствующие им значения. Общая схема

разметки, выработанная еще в работе [11], состоит из

- (1) **принципов разметки**, относящихся ко всем аннотируемым выражениям,
- (2) **правил разметки**, относящихся к большим группам выражений, объединенных некоторым общим свойством и
- (3) **специальных случаев** — правил разметки, относящихся обычно к небольшим по размеру, специальным группам выражений.

Ниже дается сокращенное описание схемы разметки, включающее в себя принципы и основные правила разметки, а также несколько специальных случаев.

Отметим, что базовой единицей аннотированного корпуса для извлечения диагностических признаков является предложение, т.е. признаки и соответствующие им значения выделяются человеком-аннотатором в рамках одного предложения.

Поскольку признак и его значение могут находиться в разных местах предложения, то для их связывания используют специальные программные средства (визуальные средства аннотирования, в нашем случае это система BRAT, <https://brat.nlplab.org/>), которые позволяют соединять различные сущности (в нашем случае признаки и их значения) с помощью направленных стрелок, см. рисунок 2.



Рисунок 2. Признак со значением.

1.1. Принципы разметки

Поскольку аннотированием медицинских документов занимаются врачи, то основными критериями, предъявляемыми к принципам разметки, являются их простота, понятность, наглядность и естественность представления признаков и их значений как результата аннотирования.

Подход к выделению из выражения признака и его значения основан на **двух принципах**, представляемых ниже.

Далее, в примерах разметки полученный результат представляется в виде пары

[признак; значение]

возможно, с указанием типа связи между компонентами пары и дополнительными комментариями.

В такой паре выделенные признак и значение представляются в той лексической форме, в которой они встречаются в конкретном аннотируемом тексте.

«Перенес несколько эпизодов ОРИ с малопродуктивным кашлем.» — [кашлем; малопродуктивным].

Принцип I (базовый). *В качестве признака (первого члена пары) выделяется структурно главная часть выражения, а в качестве значения — его зависимая (подчиненная) часть.*

Обычно главной частью выражения является некоторое нарушение/отклонение или указание на часть тела, или физиологический процесс (выраженные одним или несколькими словами), а подчиненной частью — характеристики этого нарушения или части тела.

«Ярко выраженная гиперемия на щеках и шее.» — [гиперемия; ярко выраженная на щеках и шее]

«Ребенок поступил в отделение с жалобами на отеки Квинке при погрешности в диете.» — [отеки Квинке; при погрешности в диете]

«При поступлении: кожные покровы бледно-розовые, суховатые.» — [кожные покровы; бледно-розовые, суховатые]

«В лёгких дыхание везикулярное, равномерно проводится во все отделы.» — [дыхание; везикулярное, равномерно проводится во все отделы]

В некоторых случаях признаки могут не иметь характеристик. Правила разметки таких выражений представлены ниже в разделе 1.2.1.

Принцип II. *В описаниях клинических осмотров и анамнезов некоторые признаки являются часто встречающимися, стандартными и играющими особую роль при постановке диагноза.*

Такие признаки врачи обычно хотят видеть в каждой выдаче подсистемы извлечения диагностических признаков. Обычно состав такой группы признаков является специфичным для определенной группы заболеваний, и чаще всего в нее входят некоторые части тела и физиологические процессы. Например, состав группы выделенных признаков, связанных с аллергическими и пульмонологическими заболеваниями, может быть таким:

- (1) дыхание,
- (2) кожа (кожные покровы),
- (3) живот,
- (4) язык,

(5) слизистые оболочки.

Принцип разметки выражений, включающих такого рода признаки состоит в том, что независимо от того, в виде какой части выражения они находятся — главной или зависимой, эти признаки всегда отмечаются в виде первого члена пары.

«С возраста 5-6 лет отмечается сухость кожи.» — [кожи; сухость с возраста 5-6 лет].

Следует отметить, что возможны случаи, когда в одно выражение могут входить несколько признаков из выделенной группы. В такой ситуации в качестве первого члена пары может быть выбран любой такой признак.

1.2. Правила разметки

Правила разметки уточняют принципы аннотирования I и II главных групп диагностических признаков:

- (1) признаков без характеристик,
- (2) признаков с характеристиками,
- (3) показателей,
- (4) анамнезов и сведений об общем состоянии пациента.

Ниже описываются основные правила разметки этих групп выражений с комментариями об их технической реализации в системе BRAT.

1.2.1. Признаки без характеристик

Одиночные, без дополнительных характеристик диагностические признаки являются простейшими признаками, встречающимися в медицинских текстах.

«У нее были типичные для коронавируса симптомы — одышка, слабость. С возраста 3-х лет у мальчика проявления полиноза: затруднение носового дыхания, симптомы конъюнктивита, отеки Квинке.»

Если в предложении говорится о наличии такого признака, то значением такого признака считается логическая константа **true**, если же об отсутствии — константа **false**. По этой причине такого рода признаки носят название булевских признаков. Для их представления ниже используются пары вида [признак; булевское значение].

«У нее были типичные для коронавируса симптомы — одышка, слабость.» — [одышка; true], [слабость; true]

«Аускультативно дыхание с жестким оттенком, хрипов нет.» — [хрипов; false]

Технически при разметке в системе BRAT булевские признаки отмечаются в виде сущностей типа Feature дополнительной установкой атрибута Negation для признаков со значением **false**.

Чаще всего такого рода признаки состоят из одного слова. Однако возможны случаи, когда они состоят из нескольких слов, обычно являющихся так называемыми «устойчивыми словосочетаниями» — часто встречающимися в медицинских текстах фразами, используемыми в качестве шаблонов. Примерами таких фраз являются «отеки Квинке», «сотрясение головного мозга», «вздутие живота» и т.п.

«*Менингеальных знаков на момент осмотра нет.*» — [менингеальных знаков; false]

«*Ведущий симптом в такой ситуации — диарея, затем по распространенности следуют вздутие живота, спастические боли, тошнота и рвота.*» — [вздутие живота; true], [спастические боли; true]

В последнем предложении выражение «спастические боли» потенциально могло бы быть разбито на признак и значение, но, тем не менее, оно должно быть отнесено к булевским признакам. В данном и аналогичных случаях, включая случаи для признаков с характеристиками, аннотация проводится согласно следующим правилам.

Правило 1.2.1 (а). В выражениях, в которых симптомы-отклонения выражены в абстрактной форме и требуют уточнения места их проявления — *боль, искривление, деформация, стеснение, изменение* и т.п., эти симптомы вместе с указанием на место проявления отмечаются как булевские.

«*Изменений в легких нет.*» — [изменений в легких; false]

Правило 1.2.1 (б). Симптомы-отклонения, однозначно связанные с определенной частью тела или органом, также аннотируются в виде булевского признака со включением части тела или органа в сам признак («*першение в горле*», «*першение по задней части глотки*»).

Специфика разметки выражений, в которых говорится об отсутствии какого-либо признака, имеющего некоторые характеристики, отражена в правилах следующего раздела.

1.2.2. Признаки с характеристиками

Признаки с характеристиками являются самой многочисленной группой размечаемых выражений. Структурно такие выражения состоят из двух частей, где первая часть представляет собой либо

- (1) нарушение/отклонение в работе организма, либо
- (2) указание на часть тела или
- (3) физиологический процесс,

а вторая часть содержит одну или несколько характеристик того, что указано в первой части.

«С этого времени у ребенка одышка появилась и на фоне физической нагрузки.» — [одышка; на фоне физической нагрузки]

«Живот мягкий, доступен глубокой пальпации.» — [живот; мягкий, доступен глубокой пальпации]

«Стул оформленный, склонен к запорам.» — [стул; оформленный, склонен к запорам]

К характеристикам относятся те части выражения, которые, по мнению аннотатора, описывают

- степень выраженности нарушения/отклонения («*сильная головная боль*»),
- время проявления («*заложенность носа в ночной период*», «*покашливание в утреннее время*»),
- условие проявления («*риноконъюнктивальный синдром при контакте с бытовыми аллергенами*»),
- состояние части тела («*кожные покровы чистые, бледные, периорбитальные тени*») и др.

Поскольку для признака может быть указано в тексте несколько характеристик, расположенных в разных частях предложения, то в системе визуальной разметки BRAT от одного признака может быть проведено несколько стрелок к этим характеристикам.

Аналогично, в выражении может быть перечислено несколько признаков, имеющих одно и то же значение. В этом случае, в системе BRAT проводятся стрелки от каждого признака к этому значению. В частности, для выражения «*стул, диурез не нарушены*» результатом разметки будут пары [стул; не нарушены], [диурез; не нарушены].

Аналогично случаю отсутствия (отрицания) признаков без характеристик, в медицинских текстах могут встречаться выражения об отсутствии признаков с характеристиками (выражения с отрицанием) — «*сухого кашля не наблюдается*». В таких ситуациях действует правило согласно которому характеристики считаются принадлежащими главной части выражения, которая становится булевским признаком со значением **false** — [сухого кашля; false].

1.2.3. Показатели

Под показателями понимаются результаты простейших инструментальных исследований, которые проводятся при первичном и последующем осмотрах пациента — температура тела, частота дыхательных движений, частота сердечных сокращений (пульс), уровень оксигенации (сатурации)

и др. Обычно, такие признаки имеют числовые значения и размечаются как признаки с характеристиками (см. рисунок 2):

[частота дыхательных движений; 21–22]

[SpO₂; 98]

[артериальное давление; 110/80]

В эту категорию попадают и другие результаты инструментальных исследований и анализов — количество эритроцитов в крови, размеры и характеристики внутренних органов, определяемые при ультразвуковом или рентгенологическом исследованиях и т.д. Единицы измерения значения того или иного показателя в саму разметку в нашем случае не включаются.

1.2.4. Анамнезы и общие сведения о пациенте

Выражения, которые описывают анамнез, эпидемиологический статус и общее состояние пациента, рассматриваются в качестве отдельных групп признаков и размечаются с помощью специальных атрибутов в системе BRAT.

Примерами таких выражений являются: *«хронические болезни отрицает»*, *«вернулся из командировки в Германию 3 дня назад»*, *«состояние средней тяжести»*.

В текущей разметке такого рода выражения разбиты на 3 группы:

- (1) данные анамнезов жизни и болезни,
- (2) эпидемиологический статус (анамнез),
- (3) сведения об общем состоянии пациента.

Такие выражения отмечаются целиком, и им присваиваются атрибуты AofL (anamnesis of life), EpA (epidemiological anamnesis), CS (common state), соответственно, в системе BRAT.

В данные группы выражений могут входить разные сведения соответствующей направленности. В частности, в группу анамнеза могут входить сведения о наследственности пациента, хронических и перенесенных заболеваниях и др. Далее, в классификаторе болезней для такого рода выражений предусмотрены три вида входов — AofL, EpA и CS, на которые подаются извлеченные выражения соответствующих типов.

1.3. Специальные случаи

В данном разделе рассматриваются несколько специальных групп выражений и правила их разметки.

1.3.1. Заболевание как симптом

Иногда встречаются выражения, в которых упоминаются заболевания в качестве симптомов других заболеваний. Так, например, выявлено,

что вирус COVID-19 может вызывать конъюнктивит разного вида. Поэтому в соответствующих текстах он должен отмечаться в виде признака. Такого рода упоминания заболеваний аннотируются стандартным способом с разбивкой на признак и значение (если последнее присутствует в выражении). Так, отдельное слово "конъюнктивит" может отмечаться в виде, как обычно, булевского признака, а в предложении «У пациента наблюдалась выраженная диарея, плохо поддающаяся лечению» разметка соответствующего фрагмента будет иметь вид — [диарея; *выраженная*].

1.3.2. Выражения со словами «симптомы», «проявления», «случаи», «эпизоды», «приступы»

В медицинских текстах часто встречаются выражения вида «*симптомы бронхиальной астмы*», «*эпизоды малопродуктивного кашля*», «*кожные проявления аллергии*» и т.п. Для таких выражений применяются следующие два правила разметки:

- (1) если слова «симптомы», «проявления» и аналогичные стоят в начале выражения и не имеют дополнительных характеристик, то они не включаются в разметку:

«*симптомы бронхиальной астмы*» — [бронхиальной астмы; true]

«*эпизоды малопродуктивного кашля*» — [кашля; малопродуктивно-го]

- (2) если у таких слов есть дополнительные характеристики, то эти слова с их характеристиками включаются в значение признака:

«*кожные проявления аллергии*» — [аллергии; кожные проявления]

«*кожные проявления пищевой аллергии*» — [аллергии; пищевой],
[аллергии; кожные проявления]

«*редкие эпизоды малопродуктивного кашля*» — [кашля; малопродуктивного], [кашля; редкие эпизоды]

1.3.3. Выражения вида «потеря обоняния», «отсутствие аппетита»

Выражения вида «*отсутствие обоняния*», «*потеря вкуса*», «*снижение аппетита*» и им подобные размечаются в виде булевских признаков со значением true: «*жалобы на отсутствие аппетита*» — [отсутствие аппетита; true]

1.4. Техническая реализация

Аннотированный текст представляет собой «двумерную» структуру:

- (1) отмеченные сущности типа «признак» и «значение»,
- (2) связи нескольких типов между выделенными сущностями.

Соответственно, чтобы по чистому, неразмеченному тексту получить аналогичную структуру, требуется обучить нейронную сеть извлекать

- (1) сущности заданного типа и
- (2) отношения между ними.

Хотя существуют подходы к обучению нейросети одновременному извлечению сущностей и отношений между ними [12], они носят в основном исследовательский характер. В предлагаемой технической реализации для решения данной задачи используется две различные нейронные сети — одна для извлечения сущностей, вторая — для извлечения отношений. Обе сети реализованы на основе хорошо зарекомендовавших себя для практических целей приложений от компаний Deeppravlov и Facebook, соответственно.

Для обучения нейронных сетей обоих видов использовался один и тот же корпус из примерно 1500 предложений, аннотированных вручную в системе BRAT. В качестве сущностей в предложениях корпуса отмечались сущности

- (1) Feature (признак),
- (2) Value (значение),

где среди признаков специальными атрибутами отмечались (булевские) признаки с отрицанием, а также признаки, представляющие собой анамнез, эпидемиологический статус и общее состояние пациента. Общее количество отмеченных признаков и их значений составило около 5200.

Между сущностями отмечались три вида отношений:

- (1) отношение `has_String` между признаком и значением, отмечающее, что признак имеет символьную характеристику,
- (2) отношение `has_Numerical` между признаком и значением, отмечающее, что признак имеет числовую характеристику,
- (3) отношение `continue` между компонентами признака или между компонентами значения, отмечающее, что второй компонент является продолжением первого.

Данные виды отношений в технической реализации были дополнены отрицательными примерами — парами сущностей, соединенных связью типа «no-relation». Введение отрицательных примеров существенно улучшает результаты обучения нейронной сети извлечению действительных отношений между сущностями. Общее количество положительных примеров (реальных отношений) в корпусе составило около 2400, отрицательных примеров — около 9800. Как обычно, при обучении нейросети извлечению отношений все примеры разбивались на три части — примеры непосредственно для обучения, для проверки во время обучения (валидации) и для тестирования.

Для извлечения сущностей использовалась *предобученная BERT-модель per_rus_bert от компании DeepPavlov^{URL}*. Соответственно, размеченный корпус в BRAT-формате переводился предварительно в стандартный BIO-формат (beginning-inside-outside) для возможности использования этой модели. Точность работы нейронной сети на указанном выше корпусе составила 81,35% (F1-мера).

Аналогично, для извлечения отношений использовалась предобученная BERT-модель SpanBERT [13], предназначенная для предсказания заданных отношений между отдельными (непрерывными) фрагментами текста (спанами). В качестве технической реализации была выбрана *модель от компании Facebook^{URL}*. Далее

- (1) размеченный в BRAT-формате корпус предварительно преобразовывался в *стандартизованный формат TACRED^{URL}* — общепринятый в международном сообществе компьютерной лингвистики формат представления данных для извлечения отношений;
- (2) на основе корпуса в TACRED-формате порождались отрицательные примеры и проходило разбиение всех примеров на обучающую/валидационную/тестовую части (в отношении 75%, 12,5%, 12,5%).

Точность работы обученной нейронной сети по извлечению отношений составила 89,61% (F1-мера).

2. Постановка диагноза

Представляемая система извлечения симптомов и предсказания по ним диагнозов ограничена шестью пульмонологическими заболеваниями (в скобках приведены коды болезней по МКБ-10):

- (1) хроническая обструктивная болезнь легких (J44),
- (2) рак легких и бронхов (C34),
- (3) острый бронхит (J20),
- (4) пневмония (J18),
- (5) бронхит хронический (J41),
- (6) бронхиальная астма (J45),
- (7) COVID-19 (U07.1).

Для обучения классификатора предсказанию диагнозов был создан корпус из 140 текстов (по 20 текстов на каждое заболевание). Каждый текст представляет собой описание конкретного клинического случая с соответствующим диагнозом. Корпус составлен из (неструктурированных) текстов, взятых из материалов, имеющих в открытом доступе в Сети —

медицинских журналов (например, «Инфекционные болезни»), сборников ситуационных (клинических) задач для студентов медицинских вузов и др.

Предварительная обработка этих текстов состояла из двух этапов:

- (1) извлечение диагностических признаков и их значений из каждого текста (с сохранением их в формате json),
- (2) создание обучающего и тестового наборов данных для классификатора болезней.

Классификатор болезней представляет собой простую трехслойную сеть прямого распространения, на которую подаются значения извлеченных из текста описания болезни (медицинской карты пациента) диагностических признаков. Поскольку любая нейронная сеть, в том числе указанного вида, может иметь только фиксированное количество входов, то на основе анализа описаний пульмонологических заболеваний и COVID-19 вручную были отобраны наиболее важные симптомы для заболеваний этого типа. В этот список диагностических признаков вошли:

- (1) **стандартные (выделенные) признаки для данной группы заболеваний** (см. раздел 1.1, принцип II) — «*дыхание*», «*кожные покровы (кожа)*», «*язык*», «*слизистые оболочки*», «*живот*»;
- (2) **показатели** — «*температура*», «*пульс*», «*артериальное давление*», «*частота дыхания*», «*сатурация*»;
- (3) **булевские признаки** — «*чувство нехватки воздуха*», «*ощущение сдавленности в грудной клетке*», «*хрипы*», «*лихорадка*», «*слабость*», «*одышка*» и др.;
- (4) **признаки со значениями** — «*кашель*», «*рвота*», «*головная боль*», «*периферические лимфатические узлы*», «*задняя стенка глотки*» и др.;
- (5) **сведения об анамнезах и общем состоянии пациента** — «*общее состояние*», «*эпидемиологический анамнез*», «*анамнез жизни*».

Некоторые из перечисленных признаков могут иметь значения различных типов. Например, признак «*температура*» может иметь как числовое значение (39,6°C), так и символьное («*повышенная*»).

В соответствии с этим общее количество входов-признаков классификатора составило 34 плюс специальный вход «*Others*», на который подаются признаки с их значениями, которые выделены из исходного текста, но для которых отсутствуют отдельные входы из перечисленных выше. В последнем случае из всех таких признаков с соответствующими им значениями формируется единая строка, которая и подается на вход «*Others*» классификатора. Хотя эти признаки будут вносить меньший вклад в результирующий диагноз, это позволяет не потерять и учесть всю

диагностическую информацию, которую удалось извлечь из входного документа.

Поскольку входными значениями для классификатора, кроме булевских и числовых, являются символьные выражения (например, для признака «температура» значением может быть выражение «периодически субфебрильная»), то все значения перед подачей на вход классификатора переводятся в числовую форму стандартным способом — с помощью дистрибутивной модели русского языка, а именно, с помощью *BERT-модели rubert-base-cased от компании DeepPavlov*^{[URL](#)}. Данная модель переводит каждое выражение в список из 768 вещественных чисел. Для сохранения разумных размеров нейронной сети-классификатора и повышения скорости обучения использовались только 25 чисел из этого списка. Тем самым, общее количество входов нейронной сети составило $35 \times 25 = 875$. (Эксперименты с использованием большего количества чисел оставлены для дальнейших исследований).

Сама нейронная сеть состоит из 12 нейронов первого слоя, 8 нейронов второго слоя и 7 нейронов (по количеству болезней) выходного слоя. Все слои являются полносвязными (dense-слоями). В качестве функции активации первые два слоя используют кусочно-линейную функцию *relu* (rectified linear unit), а выходной слой — функцию *softmax*, переводящую выходные значения в значения вероятности. Параметры обучения классификатора были стандартными для такого рода сетей, количество итераций обучения — 150.

Кроме перевода символьных значений признаков в числовые, BERT-модель *rubert-base-cased* использовалась для связывания выделенных из текста признаков с конкретными входами классификатора болезней. Например, у классификатора есть вход «частота дыхания», а в текстах соответствующий признак может формулироваться как «число дыханий», или «частота дыхательных движений», или в виде других (грамматических) форм такого рода выражений. Эта проблема решалась переводом выражений, представляющих признаки, в числовую форму и применением функции, вычисляющей семантическую близость между парами выражений, а именно стандартной функции косинусного сходства. Порог сходства был выбран равным 0.99 — выделенный из текста признак связывался с тем признаком, являющимся входом классификатора, для которого синусное сходство было максимальным и не меньшим 0.99.

Обучение классификатора проводилось на корпусе из 140 текстов с его разбивкой 120 на обучение, 20 — на тестирование. Оценка точности работы классификатора осуществлялась путем кросс-валидации — проводилась 10-кратная случайная разбивка корпуса на обучающую и тестовую части, и подсчитывалось число правильных ответов. Ответ классификатора

считался правильным, если он совпадал с эталонным и степень уверенности (вероятность) его, вычисленная классификатором, превышала 90%. Если хотя бы одно из этих условий нарушалось, ответ классификатора считался неправильным. Точность работы классификатора при кросс-валидационной проверке составила 88,5% (23 случая неправильного диагноза из 200 тестовых). Наиболее трудной для автоматической диагностики оказалась хроническая обструктивная болезнь легких (ХОБЛ) — 7 случаев неправильного диагноза из 23. На следующих местах идут хронический бронхит и пневмония — по 4 случая. На диагностике COVID-19 классификатор не допустил ни одной ошибки.

3. Обзор смежных работ

В данном разделе мы даем обзор наиболее важных работ, посвященных автоматическому прогнозированию диагнозов по анамнезам пациентов, записанных в свободном неструктурированном виде. Специально отмечаются вопросы извлечения диагностических признаков (симптомов) в этих работах. Анализируются методы использования извлеченных симптомов для постановки диагноза. Дается сравнение с аналогичными решениями, принятыми в нашей системе.

В работе [7] заявлено создание алгоритма выявления подозрения на COVID-19. Исходными данными для алгоритма являются симптомы и их значения, извлекаемые из протоколов врачебных осмотров. Количество таких протоколов составило около 11 тыс., однако, установленными диагнозами для них являлись ОРВИ и пневмония, т.е. данные документы не относились непосредственно к COVID-19. Общее количество извлекаемых симптомов составило 14. Они извлекались из текста двумя способами — с помощью методов распознавания именованных сущностей и с помощью специально сконструированных правил. Точность извлечения симптомов составила от 82,6% до 97,43% в зависимости от конкретного симптома. В статье не приводятся сведения о способе извлечения значений таких симптомов как «температура», «частота дыхания», «частота сердечных сокращений» и некоторых других. Сама процедура постановки диагноза базируется на «решающих правилах», построенных на основе мнений врачей-экспертов о правилах взаимодействия симптомов. Результат представляет собой одно из трех значений «уровня подозрения на COVID-19»:

- (1) отсутствует подозрение на COVID-19,
- (2) подозрение на COVID-19,
- (3) вероятен COVID-19.

Количественных оценок точности работы такого алгоритма формирования подозрения на COVID-19 не приведено. Отличие нашей работы от данной состоит в использовании в нашей системе гораздо большего количества анализируемых симптомов, а также в постановке конкретного диагноза заболевания, а не значения «уровня подозрения» на него.

В работе [14] представлена система извлечения симптомов из неструктурированных текстов на английском языке и предсказания наличия COVID-19 по ним. В частности, эта система включает в себя аннотированный корпус из 1472 текстов, содержащих около 30 тыс. упоминаний диагнозов, результатов тестов и симптомов. В силу сходства задачи извлечения симптомов с их значениями с задачей извлечения событий с их аргументами, в данной системе выделение симптомов реализовано как извлечений событий с помощью дообученной Bio+Clinical BERT-модели для решения этой задачи. Точность извлечения симптомов составила 81%, а их значений — от 45% до 78% в зависимости от конкретного значения. Предсказание наличия COVID-19 было реализовано на основе метода случайного леса (random forest classifier) — использовании большого ансамбля решающих деревьев. Данные для обучения такого классификатора включали в себя, кроме симптомов, извлеченных из неструктурированных текстов, 24 структурированных признака. Среди них были

- (1) демографические показатели (пол, возраст),
- (2) жизненно важные показатели (vital signs), такие как температура, частота дыхания и др.,
- (3) результаты лабораторных исследований.

Кроме того, использовалась такая информация как

- (1) сведения, полученные в результате телефонного общения с пациентом (telephone encounters),
- (2) ход амбулаторного лечения (outpatient progress notes),
- (3) обращения к службе скорой помощи (emergency department notes).

Точность предсказания наличия COVID-19 только по структурированным данным составила 61–72%, по симптомам, извлеченным из неструктурированных текстов — 59–67%, по данным обоого типа — 65–78%. Преимущества нашей работы по сравнению с данной системой состоят в том, что наша система имеет возможность предсказывать одно из нескольких заболеваний, обладающих схожими симптомами, что существенно усложняет постановку корректного диагноза. Такое предсказание обеспечивается применением классификатора на основе нейронной сети, которая, в общем случае, является более мощным средством, чем классификатор на основе метода случайного леса.

В работе [4] представлена система принятия диагностических решений на основе данных электронной медицинской карты (ЭМК) пациента, собранных за последние 2 года. Эти данные включают в себя жалобы и анамнез, историю болезни, результаты первичного осмотра, а также лабораторных и инструментальных исследований. Система реализована в научном подразделении SberMedAI Сбербанка России и первоначально носила название «Умный помощник врача TOP-3». Позднее она была преобразована в систему AIDA (AI Diagnostic Assistant) — сервис ИИ для постановки окончательного диагноза на основании данных ЭМК пациента. По информации пресс-службы Сбербанк системы внедрены во всех поликлиниках для взрослых г. Москвы. Общее количество использованных для обучения документов для системы TOP-3 составило первоначально 4 млн., а позднее доведено до 12 млн. Для обучения системы AIDA было использовано 30 млн. записей визитов.

Система TOP-3 выдает результат в виде одного из 265 кодов заболеваний, выбранных из Международной классификации болезней МКБ-10. Система AIDA ограничена 94 наиболее важными диагнозами. Результат работы каждой из систем — выданный диагноз — оценивался врачом. Было использовано два основных вида оценки: по одному и трем выданным возможным диагнозам. В последнем случае, если хотя бы один из трех диагнозов, выданных нейросетью, совпадал с диагнозом врача, то такой ответ засчитывался за правильный. Точность выдачи одного диагноза в системе TOP-3 составила 47,5%, а по трем диагнозам — 68%. (Точность работы диагностических систем на базе ChatGPT также находится в этих пределах — см. об этом ниже). Данные о точности работы системы AIDA отсутствуют.

В качестве модели нейронной сети в обеих системах использовалась незначительно модифицированная стандартная BERT-модель для русского языка. Размер входных текстов ограничивался 128 словами (или, более точно, токенами). Использование такой модели означает, что задача постановки диагноза была сведена к простой задаче классификации текстов на 265 (или 94) категорий. Соответственно, системы такого рода не анализируют медицинские документы на выявление в них таких содержательных единиц как заболевания, симптомы, названия диагностических и лечебных процедур, лекарства и др., а также не определяют отношения между ними. Поэтому данные системы поставят «диагноз» по любому тексту, в том числе и по такому, в котором отсутствуют упоминания симптомов, или вообще не являющемуся медицинским. Кроме того, низкая точность работы таких систем не позволяет их рассматривать в качестве серьезной компоненты систем поддержки клинических решений. Еще одним серьезным их недостатком является отсутствие выдачи

какой-либо информации, объясняющей, почему был поставлен тот или иной диагноз. В нашей системе таблица извлеченных симптомов может служить частичным обоснованием и объяснением выданного диагноза. Кроме того, наша система предоставляет также числовой показатель степени уверенности принятого решения.

В последнее время появилось большое количество работ, описывающих попытки применения больших языковых моделей, в частности, систем типа ChatGPT, для решения задачи постановки медицинских диагнозов. Общий недостаток всех таких систем состоит в том, что их обучение проводится на всей массе данных, имеющихся в Интернете, которые очень часто оказываются неточными и неполными, что критически неприемлемо в задачах медицинской диагностики. Кроме того, такие системы в силу принципов своего построения принципиально не могут рассуждать, проводить простейшие логические умозаключения, которые являются неотъемлемой частью любого процесса постановки диагноза (принятия решения) в любой области. Много работ про тестирование систем на базе ChatGPT в конкретных областях медицины только подтверждают такие выводы.

В работе [10] проверялись возможности постановки диагнозов системой ChatGPT-3.5 в области педиатрии. Для такой оценки были выбраны 100 описаний болезней с подтвержденными диагнозами. Тексты были взяты из архива журнала JAMA Pediatrics и из архива Массачусетского госпиталя общего назначения (Massachusetts General Hospital). Результат, выдаваемый системой ChatGPT, оценивался двумя квалифицированными врачами по трехзначной шкале:

- (1) правильный,
- (2) неправильный,
- (3) не полностью описывает диагноз.

Общее количество ошибочных диагнозов составило 83%, среди них 72% были некорректны, а 11% клинически относящиеся к рассматриваемому случаю, но слишком общие, чтобы их рассматривать в качестве корректного диагноза.

В статье [18] изучались возможности трех систем — GPT-4, Gemini Pro и GPT-4, интегрированной с онтологией фенотипа человека (Human Phenotype Ontology) для постановки диагноза в 61 редком случае педиатрических заболеваний. Система GPT-4 оказалась способной предсказать корректный диагноз в 13,1% случаев, тогда как точность работы систем Gemini Pro и GPT-4 НРО составила только 8,2%.

В работе [19] изучалась точность работы системы GPT-4 в задачах комплексной медицинской диагностики. Исследование проводилось на

70 описаниях историй болезней, взятых из архива журнала New England Journal of Medicine. От системы требовалось два вида ответов:

- (1) наиболее вероятный диагноз,
- (2) дифференциальный диагноз — список возможных диагнозов, ранжированных по степени вероятности.

Во втором случае, если правильный диагноз попадал в данный список, то ответ засчитывался как правильный. Точность работы системы по определению единственного правильного диагноза составила 39% (27 случаев из 70), а в 45 случаях из 70 (64%) правильный ответ присутствовал в списке возможных диагнозов. Средняя длина такого списка для всех случаев составила 9.0.

В статье [20] сообщается о довольно успешных результатах тестирования больших языковых моделей в решении задач диагностики психических расстройств. В этой работе тестировались системы GPT-3.5 Turbo, GPT-4, Aya-101 и Nemotron. Системы тестировались на 20 клинических случаях, взятых из DSM-5 (Diagnostic and Statistical Manual of mental disorders, fifth edition) — нозологической системе психических расстройств. Ответ систем оценивался по трехзначной шкале:

- (1) правильный,
- (2) частично правильный,
- (3) неправильный.

В результате тестирования, 15 из 20 случаев были диагностированы корректно, по меньшей мере, одной из рассматриваемых систем. Системы GPT-3.5 и Chat GPT-4.0 дали правильный ответ в 13 из 20 случаев, а системы Aya и Nemotron — в 6–7 случаях из 20. Авторы статьи отмечают, что большое разнообразие психических заболеваний требует создания больших, но, в тоже время, хорошо проработанных датасетов, используемых для обучения моделей.

4. Выводы и направления дальнейшей работы

В данной работе была представлена система для извлечения симптомов заболеваний из медицинских клинических записей и автоматическому прогнозированию по ним диагноза. Система ограничена 6 пульмонологическими заболеваниями и COVID-19. Подход, реализованный в данной системе, отличается от подхода, принятого в системах TOP-3 и AIDA, разработанных в SberMedAI, и в которых реализована простая классификация текстов. Это позволило существенно повысить точность постановки диагноза, которая составила на указанной группе заболеваний 88.5%. Кроме того, список извлеченных симптомов, на основе которых был поставлен диагноз, можно рассматривать в качестве части его объяснения.

Дальнейшими направлениями совершенствования системы являются:

- (1) повышение точности работы подсистемы извлечения диагностических признаков путем увеличения объема и улучшения качества обучающего множества,
- (2) оценка использования модели RuBioBERT (RuBioRoBERTa) [3] для улучшения связывания выхода подсистемы извлечения симптомов со входом классификатора болезней,
- (3) повышение точности работы классификатора болезней путем более точного подбора симптомов, по которым производится классификация и усовершенствования его внутренней структуры,
- (4) разработка общедоступного Web-варианта системы с использованием из браузера.

Список использованных источников

- [1] Романов Н. А., Сачек М. М. *Системы поддержки принятия клинических решений: современное состояние и проблемы* // Вопросы организации и информатизации здравоохранения.– 2018.– № 3.– С. 18–25.   ↑156
- [2] Osheroff J. A. *Improving medication use and outcomes with clinical decision support: a step-by-step guide.*– HIMSS Publishing.– 2009.– ISBN 9780980069730.– 300 pp. ↑156
- [3] Yalunin A., Nestrov A., Umerenkov D. *RuBioRoBERTa: a pre-trained biomedical language model for Russian language biomedical text mining.*– 2022.– 5 pp.   2204.03951 ↑156, 178
- [4] Blinov P., Avetisian M., Kokh V., Umerenkov D., Tuzhilin A. *Predicting clinical diagnosis from patients electronic health records using BERT-based neural networks*, Artificial Intelligence in Medicine: 18th Int. Conf. on Art. Intel. In Medicine, AIME 2020 (Minneapolis, MN, USA, August 25–28, 2020), Lecture Notes in Computer Science.– vol. **12299**, Cham: Springer.– 2020.– ISBN 978-3-030-59136-6.– Pp. 111–121.  ↑156, 157, 175
- [5] Garg R. K., Urs V. L., Agarwal A. A., Chaudhary S. K., Paliwal V., Kar S. K. *Exploring the role ChatGPT in patient care (diagnosis and treatment) and medical research: a systematic review* // Health Promotion Perspectives.– 2023.– Vol. **13**.– No. 3.– Pp. 183–191.  ↑156
- [6] Steinkamp J. M., Bala W., Sharma A., Kantrowitz J. J. *Task definition, annotated dataset, and supervised natural language processing models for symptom extraction from unstructured clinical notes* // Journal of Biomedical Informatics.– 2020.– Vol. **102**.– id. 103354.– 9 pp.  ↑156
- [7] Гаврилов Д. В., Кирилкина А. В., Серова Л. М. *Алгоритм формирования подозрения на новую коронавирусную инфекцию на основе анализа симптомов для использования в системах поддержки принятия врачебных решений* // Врачи и информационные технологии.– 2020.– № 4.– С. 51–58.    ↑156, 160,

- [8] Umerenkov D., Zubkova G., Nesterov A. *Deciphering diagnosis: how large language models explanations influence clinical decision making.*– 2023.– 11 pp. arXiv:2310.01708  ↑156
- [9] Tutubalina E., Alimova I., Miftahutdinov Z., Sakhovskiy A., Malykh V., Nikolenko S. *The Russian Drug Reaction Corpus and neural models for drug reactions and effectiveness detection in user reviews* // *Bioinformatics.*– 2021.– Vol. **37.**– No. 2.– Pp. 243–249.  ↑156
- [10] Barile J., Margolis A., Cason G., Kim R., Kalash S., Tchaconas A., Milanaik R. *Diagnostic accuracy of a large language model in pediatric case studies* // *JAMA Pediatrics.*– 2024.– Vol. **178.**– No. 3.– Pp. 313–315.  ↑157, 176
- [11] Сердюк Ю. П., Власова Н. А., Момот С. Р. *Система извлечения упоминаний симптомов из текстов на естественном языке с помощью нейронных сетей* // Программные системы: теория и приложения.– 2023.– Т. **14.**– № 1(56).– С. 95–123.   ↑160, 162
- [12] Shang Yu-M., Huang H., Mao X. L. *OneRel: Joint entity and relation extraction with one module in one step* // *The Thirty-Sixth AAAI Conference on Artificial Intelligence (AAAI-22)* (February 22–March 1, 2022, online).– Curran Associates, Inc.– 2022.– ISBN 9781713855743.– Pp. 11285–11293.   ↑169
- [13] Joshi M., Chen D., Liu Y., Weld D. S., Zettlemoyer L., Levy O. *SpanBERT: improving pre-training by representing and predicting spans* // *Transactions of the Association for Computational Linguistics.*– 2020.– Vol. **8.**– Pp. 64–77.  ↑170
- [14] Lybarger K., Ostendorf M., Thompson M., Yetisgen M. *Extracting COVID-19 diagnoses and symptoms from clinical text: A new annotated corpus and neural event extraction framework* // *Journal of Biomedical Informatics.*– 2021.– Vol. **117.**– id. 103761.– 13 pp.  ↑174
- [15] Thirunavukarasu A. J., Ting D. S. J., Elangovan K., Gutierrez L., Tan T. F., Ting D. S. W. *Large language models in medicine* // *Nat. Med.*– 2023.– Vol. **29.**– No. 8.– Pp. 1930–1940.  ↑
- [16] Shah N. H., Entwistle D., Pfeffer M. A. *Creation and adoption of large language models in medicine* // *JAMA.*– 2023.– Vol. **330.**– No. 9.– Pp. 866–869.  ↑
- [17] Singhal K., Azizi S., Tu T., Mahdavi S. S., Wei J., Chung H. W., Scales N., Tanwani A., Cole-Lewis H., Pfohl S., Payne P., Seneviratne M., Gamble P., Kelly Ch., Babiker A., Schärli N., Chowdhery A., Mansfield Ph., Demner-Fushman D., Agüera y Arcas B., Webster D., Corrado G. S., Matias Y., Chou K., Gottweis J., Tomasev N., Liu Y., Rajkomar A., Barral J., Sementur Ch., Karthikesalingam A., Natarajan V. *Large language models encode clinical knowledge* // *Nature.*– 2023.– Vol. **620.**– No. 7972.– Pp. 172–180.  ↑
- [18] Young C. C., Enichen E., Rivera Ch., Auger C. A., Grant N., Rao A., Succi M. D. *Diagnostic accuracy of a custom large language model on rare pediatric disease case reports* // *American Journal of Medical Genetics, Part A.*– 2024.– id. e63878.  ↑176
- [19] Kanjee Z., Crowe B., Rodman A. *Accuracy of generative artificial intelligence model in a complex diagnostic challenge* // *JAMA.*– 2023.– Vol. **330.**– No. 1.– Pp. 78–80.  ↑176

- [20] Gargari G. K., Fatehi F., Mohammadi I., Firouzabadi S. R., Shafiee A., Habibi Gh. *Diagnostic accuracy of large language models in psychiatry* // Asian Journal of Psychiatry. – 2024. – Vol. **100**. – id. 104168.  ↑177
- [21] Nielsen M. *Neural networks and deep learning*, free online book. – 2016.  ↑156

Поступила в редакцию 03.12.2024;
одобрена после рецензирования 27.12.2024;
принята к публикации 28.12.2024;
опубликована онлайн 28.12.2024.

Рекомендовал к публикации

к.т.н. Я. И. Гулиев

Информация об авторах:



Юрий Петрович Сердюк

старший научный сотрудник Исследовательского центра искусственного интеллекта ИПС им. А. К. Айламазяна, научные интересы: параллельное программирование, формальные исчисления процессов, системы типов.



0000-0003-2916-2102

e-mail:




Наталья Александровна Власова

младший научный сотрудник Исследовательского центра искусственного интеллекта ИПС им. А. К. Айламазяна, научные интересы: компьютерная лингвистика, автоматическая обработка естественного языка, корпусная лингвистика



0000-0003-2916-2102

e-mail:



Седа Рубеновна Момот

инженер Исследовательского центра искусственного интеллекта ИПС им. А. К. Айламазяна, научные интересы: компьютерная лингвистика, автоматическая обработка естественного языка



0000-0003-2916-2102

e-mail:

Авторы внесли равный вклад в подготовку публикации.

Декларация об отсутствии личной заинтересованности: благополучие авторов не зависит от результатов исследования.



Symptoms extraction and automatic diagnosis prediction from medical clinical records

Yuri Serdyuk¹, Natalia Vlasova², Seda Momot³

¹⁻³ Ailamazyan Program Systems Institute of RAS, Ves'kovo, Russia

Abstract. The paper introduces a system for symptoms extraction from medical clinical records (texts in natural Russian language) and automatic prediction of a diagnosis in the form of the disease title and its ICD-10 code. The system is designed for a restricted domain of 6 pulmonary diseases (chronic obstructive pulmonary disease, pneumonia, bronchial asthma etc) and COVID-19.

Different neural networks are employed for the symptoms extraction by recognizing certain medical entities and relations between them. A classifier based on a neural network is responsible for the automatic diagnosis. An annotated corpus of sentences is created for the training of the neural networks. The principles and rules of the annotation are described. A corpus of texts is used for the training of the classifier.

Both subsystems were tested, the resulting accuracy estimates are provided. The accuracy of diagnosis in the given domain is 88.5%. We also compare our system with similar works on symptom extraction from texts in various languages, as well as on automatic diagnosis, including systems such as ChatGPT.

(*In Russian*).

Key words and phrases: clinical decision support systems, symptom extraction, automatic diagnosis prediction, BERT models, ChatGPT-based systems

2020 Mathematics Subject Classification: 68T50; 92C50

For citation: Yuri Serdyuk, Natalia Vlasova, Seda Momot. *Symptoms extraction and automatic diagnosis prediction from medical clinical records*. Program Systems: Theory and Applications, 2024, **15**:4(63), pp. 153–181. (*In Russ.*). https://psta.psir.ru/read/psta2024_4_153-181.pdf

References

- [1] N. A. Romanov, M. M. Sachek. “Clinical decision support systems: current state and problems”, *Voprosy organizatsii i informatizatsii zdravooohraneniya*, 2018, no. 3, pp. 18–25 (in Russian). 
- [2] Osheroff J. A.. *Improving medication use and outcomes with clinical decision support: a step-by-step guide*, HIMSS Publishing, 2009, ISBN 9780980069730, 300 pp.
- [3] A. Yalunin, A. Nestrov, D. Umerenkov. *RuBioRoBERTa: a pre-trained biomedical language model for Russian language biomedical text mining*, 2022, 5 pp.  2204.03951 
- [4] P. Blinov, M. Avetisian, V. Kokh, D. Umerenkov, A. Tuzhilin. “Predicting clinical diagnosis from patients electronic health records usin BERT-based neural networks”, *Artificial Intelligence in Medicine: 18th Int. Conf. on Art. Intel. In Medicine, AIME 2020 (Minneapolis, MN, USA, August 25-28, 2020)*, *Lecture Notes in Computer Science*, vol. **12299**, Springer, Cham, 2020, ISBN 978-3-030-59136-6, pp. 111–121. 
- [5] R. K. Garg, V. L. Urs, A. A. Agarwal, S. K. Chaudhary, V. Paliwal, Kar S. K.. “Exploring the role ChatGPT in patient care (diagnosis and treatment) and medical research: a systematic review”, *Health Promotion Perspectives*, **13**:3 (2023), pp. 183–191. 
- [6] J. M. Steinkamp, W. Bala, A. Sharma, Kantrowitz J. J.. “Task definition, annotated dataset, and supervised natural language processing models for symptom extraction from unstructured clinical notes”, *Journal of Biomedical Informatics*, **102** (2020), id. 103354, 9 pp. 
- [7] D. V. Gavrilov, A. V. Kirilkina, Serova L. M.. “Algorithm for forming a suspicion of a new coronavirus infection based on the analysis of symptoms for use in medical decision support systems”, *Vrach i informatzionnye tehnologii*, 2020, no. 4, pp. 51–58 (in Russian).  
- [8] D. Umerenkov, G. Zubkova, A. Nesterov. *Deciphering diagnosis: how large language models explanations influence clinical decision making*, 2023, 11 pp.  2310.01708 
- [9] E. Tutubalina, I. Alimova, Z. Miftahutdinov, A. Sakhovskiy, V. Malykh, S. Nikolenko. “The Russian Drug Reaction Corpus and neural models for drug reactions and effectiveness detection in user reviews”, *Bioinformatics*, **37**:2 (2021), pp. 243–249. 
- [10] J. Barile, A. Margolis, G. Cason, R. Kim, S. Kalash, A. Tchaconas, R. Milanaik. “Diagnostic accuracy of a large language model in pediatric case studies”, *JAMA Pediatrics*, **178**:3 (2024), pp. 313–315. 
- [11] Yu. P. Serdyuk, N. A. Vlasova, Momot S. R.. “A system for extracting symptom mentions from texts by means of neural networks”, *Program Systems: Theory and Applications*, **14**:1(56) (2023), pp. 95–123 (in Russian).  

- [12] Yu-M. Shang, H. Huang, X. L. Mao. “OneRel: Joint entity and relation extraction with one module in one step”, *The Thirty-Sixth AAAI Conference on Artificial Intelligence (AAAI-22)* (February 22–March 1, 2022, online), Curran Associates, Inc., 2022, ISBN 9781713855743, pp. 11285–11293. [URL](#) [doi](#)
- [13] M. Joshi, D. Chen, Y. Liu, D. S. Weld, L. Zettlemoyer, O. Levy. “SpanBERT: improving pre-training by representing and predicting spans”, *Transactions of the Association for Computational Linguistics*, **8** (2020), pp. 64–77. [doi](#)
- [14] K. Lybarger, M. Ostendorf, M. Thompson, M. Yetisgen. “Extracting COVID-19 diagnoses and symptoms from clinical text: A new annotated corpus and neural event extraction framework”, *Journal of Biomedical Informatics*, **117** (2021), id. 103761, 13 pp. [doi](#)
- [15] A. J. Thirunavukarasu, D. S. J. Ting, K. Elangovan, L. Gutierrez, T. F. Tan, Ting D. S. W.. “Large language models in medicine”, *Nat. Med.*, **29**:8 (2023), pp. 1930–1940. [doi](#)
- [16] N. H. Shah, D. Entwistle, M. A. Pfeffer. “Creation and adoption of large language models in medicine”, *JAMA*, **330**:9 (2023), pp. 866–869. [doi](#)
- [17] K. Singhal, S. Azizi, T. Tu, S. S. Mahdavi, J. Wei, H. W. Chung, N. Scales, A. Tanwani, H. Cole-Lewis, S. Pfohl, P. Payne, M. Seneviratne, P. Gamble, Ch. Kelly, A. Babiker, N. Schärli, A. Chowdhery, Ph. Mansfield, D. Demner-Fushman, Agüera y Arcas B., D. Webster, G. S. Corrado, Y. Matias, K. Chou, J. Gottweis, N. Tomasev, Y. Liu, A. Rajkomar, J. Barral, Ch. Semturs, A. Karthikesalingam, V. Natarajan. “Large language models encode clinical knowledge”, *Nature*, **620**:7972 (2023), pp. 172–180. [doi](#)
- [18] C. C. Young, E. Enichen, Ch. Rivera, C. A. Auger, N. Grant, A. Rao, M. D. Succi. “Diagnostic accuracy of a custom large language model on rare pediatric disease case reports”, *American Journal of Medical Genetics, Part A*, 2024, id. e63878. [doi](#)
- [19] Z. Kanjee, B. Crowe, A. Rodman. “Accuracy of generative artificial intelligence model in a complex diagnostic challenge”, *JAMA*, **330**:1 (2023), pp. 78–80. [doi](#)
- [20] G. K. Gargari, F. Fatehi, I. Mohammadi, S. R. Firouzabadi, A. Shafiee, Gh. Habibi. “Diagnostic accuracy of large language models in psychiatry”, *Asian Journal of Psychiatry*, **100** (2024), id. 104168. [doi](#)
- [21] M. Nielsen. *Neural networks and deep learning*, free online book, 2016. [URL](#)

АВТОРСКИЙ УКАЗАТЕЛЬ

Багиров Эльшан

Построение надёжной системы обнаружения вредоносного ПО с использованием генеративных состязательных сетей для увеличения данных **97, 110**

Блинов Александр Олегович

Об одном способе поиска оптимального управления в неоднородной дискретной системе с запаздыванием по состоянию процессов **27, 39**

Власова Наталья Александровна

Извлечение симптомов и автоматическое предсказание диагноза по медицинским клиническим записям **153, 180**

Гриценко Григорий Глебович

Аналитический обзор архитектур, моделей, методов и алгоритмов для локализации и трекинга неригидных объектов **111, 146**

Гусева Ирина Сергеевна

Эвристический алгоритм для одной нелинейной задачи оптимального управления **43, 52**

Момот Седа Рубеновна

Извлечение симптомов и автоматическое предсказание диагноза по медицинским клиническим записям **153, 180**

Парфенов Дмитрий Денисович

Нейросетевая классификация видеороликов по малому числу кадров ... **79, 93**

Расина Ирина Викторовна

Об одном способе поиска оптимального управления в неоднородной дискретной системе с запаздыванием по состоянию процессов **27, 39**

Эвристический алгоритм для одной нелинейной задачи оптимального управления **43, 52**

Сердюк Юрий Петрович

Извлечение симптомов и автоматическое предсказание диагноза по медицинским клиническим записям **153, 180**

Смирнов Александр Владимирович

Нейросетевая классификация видеороликов по малому числу кадров ... **79, 93**

Степанов Дмитрий Николаевич

Математическое моделирование с учётом ограничений и исследование оптимальной конфигурации оптической стереосистемы, состоящей из двух плоских зеркал и видеокамеры **55, 73**

Стецюра Геннадий Георгиевич

Синхронное взаимодействие распределенных неупорядоченных цифровых объектов **3**, 24

Тищенко Игорь Петрович

Математическое моделирование с учётом ограничений и исследование оптимальной конфигурации оптической стереосистемы, состоящей из двух плоских зеркал и видеокамеры **55**, 73

Нейросетевая классификация видеороликов по малому числу кадров ... **79**, 93

Фраленко Виталий Петрович

Аналитический обзор архитектур, моделей, методов и алгоритмов для локализации и трекинга неригидных объектов **111**, 146

VOL. 15 ISSUE 4(63) 2024

AUTHOR INDEX

Baghirov Elshan

Building robust malware detection through conditional Generative Adversarial Network-based data augmentation **97**, 110

Blinov Alexander Olegovich

One method of optimal control searching in a heterogeneous discrete systems with a delay in the state of processes **27**, 39

Fralenko Vitaly Petrovich

An analytical review of architectures, models, methods and algorithms for localization and tracking of non-rigid objects **111**, 146

Gricenko Grigory Glebovich

An analytical review of architectures, models, methods and algorithms for localization and tracking of non-rigid objects **111**, 146

Guseva Irina Sergeevna

A heuristic algorithm for one nonlinear optimal control problem **43**, 52

Momot Seda

Symptoms extraction and automatic diagnosis prediction from medical clinical records **153**, 180

Parfenov Dmitry Denisovich

Neural network classification of videos based on a small number of frames .. **79**, 93

Rasina Irina Viktorovna

One method of optimal control searching in a heterogeneous discrete systems with a delay in the state of processes **27**, 39

A heuristic algorithm for one nonlinear optimal control problem **43**, 52

Serdyuk Yuri

Symptoms extraction and automatic diagnosis prediction from medical clinical records **153**, 180

Smirnov Alexander Vladimirovich

Neural network classification of videos based on a small number of frames .. **79**, 93

Stepanov Dmitry Nikolaevich

Mathematical modeling with constraints and research of the optimal configuration of an optical stereo system consisting of two flat mirrors and videocamera .. **55**, 73

Stetsyura Gennady Georgievich

Synchronous interaction of distributed disordered digital objects **3**, 24

Tishchenko Igor Petrovich

Mathematical modeling with constraints and research of the optimal configuration of an optical stereo system consisting of two flat mirrors and videocamera . . 55, 73

Neural network classification of videos based on a small number of frames . . 79, 93

Vlasova Natalia

Symptoms extraction and automatic diagnosis prediction from medical clinical records153, 180

VOL. 15 ISSUE 4(63) 2024

CONTENTS

Research Article

HARDWARE AND SOFTWARE FOR DISTRIBUTED AND SUPERCOMPUTER SYSTEMS

GENNADY G. STETSYURA[✉]. *Synchronous interaction of distributed disordered digital objects (In Russ.)* 3–24, **25–26**

Research Article

OPTIMIZATION METHODS AND CONTROL THEORY

IRINA V. RASINA[✉], ALEXANDER O. BLINOV. *One method of optimal control searching in a heterogeneous discrete systems with a delay in the state of processes (In Russ.)* 27–39, **40–41**

Research Article

OPTIMIZATION METHODS AND CONTROL THEORY

IRINA V. RASINA[✉], IRINA S. GUSEVA. *A heuristic algorithm for one nonlinear optimal control problem (In Russ.)* 43–52, **53–54**

Research Article

COMPUTATIONAL SCIENCE

DMITRY N. STEPANOV[✉], IGOR P. TISHCHENKO. *Mathematical modeling with constraints and research of the optimal configuration of an optical stereo system consisting of two flat mirrors and videocamera (In Russ.)* 55–73, **74–77**

Research Article

ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING

ALEXANDER V. SMIRNOV[✉], DMITRY D. PARFENOV, IGOR P. TISHCHENKO. *Neural network classification of videos based on a small number of frames (In Russ.)* 79–93, **94–96**

Research Article

HARDWARE AND SOFTWARE FOR DISTRIBUTED AND SUPERCOMPUTER SYSTEMS

ELSHAN BAGHIROV[✉]. *Building robust malware detection through conditional Generative Adversarial Network-based data augmentation* **97–109, 110–110**

Review Article

ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING

GRIGORY G. GRICENKO[✉], VITALY P. FRALENKO. *An analytical review of architectures, models, methods and algorithms for localization and tracking of non-rigid objects (In Russ.)* 111–144, **145–151**

Research Article

MEDICAL INFORMATICS

YURI SERDYUK[✉], NATALIA VLASOVA, SEDA MOMOT. *Symptoms extraction and automatic diagnosis prediction from medical clinical records (In Russ.)* 153–178, **179–181**

Author index **187**

Чтобы сменить язык страницы, кликните, пожалуйста, флаг в верхнем углу
Авторский указатель 185

Содержание 2