

УДК 338.1

**Зиннуров Ильнур Ильдарович**

магистрант направления подготовки «бизнес-информатика в высокотехнологичных отраслях экономики»

Национальный исследовательский ядерный университет «МИФИ»

Россия, Москва

vip.zinnurov@mail.ru

**Котов Евгений Юрьевич**

магистрант направления подготовки «бизнес-информатика в высокотехнологичных отраслях экономики»

Национальный исследовательский ядерный университет «МИФИ»

Россия, Москва

zhek.a.k@yandex.ru

**Ilnur I. Zinnurov**

Master's student in the direction of training "Business Informatics in High-Tech Sectors of the Economy"

National Research Nuclear University MEPhI  
Russia, Moscow

**Evgeniy Ur. Kotov**

Master's student in the direction of training "Business Informatics in High-Tech Sectors of the Economy"

National Research Nuclear University MEPhI  
Russia, Moscow

zhek.a.k@yandex.ru

**ПРИМЕНЕНИЕ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ ДЛЯ РЕШЕНИЯ ЗАДАЧ ОНЛАЙН ПРИМЕРКИ ОДЕЖДЫ**

**APPLICATION OF MACHINE LEARNING TECHNOLOGIES TO SOLVE ONLINE APPARELING TASKS**

**Аннотация**

Технологии стремительно развиваются и с каждым годом технические возможности устройств лишь возрастают, что предоставляет множество новых возможностей для e-commerce fashion сегмента. Одной из наиболее перспективных технологий является создание виртуальной примерочной, которая позволит значительно повысить пользовательский опыт и получить прирост прибыли. Именно об этой технологии, её особенностях и существующих сегодня ограничениях, пойдёт речь в работе.

**Ключевые слова:**

нейронные сети, визуальный поиск, распознавание образов

**Abstract**

Technologies are rapidly developing and every year the technical capabilities of devices only increase, which provides many new opportunities for the e-commerce fashion segment. One of the most promising technologies is the creation of a virtual fitting room, which will significantly increase the user experience and gain profit. It is about this technology, its features and the limitations existing today that will be discussed in the work.

**Keywords:**

neural networks, visual search, pattern recognition

В последние годы электронная коммерция росла быстрыми темпами. Сегодня потребители с большей вероятностью будут делать покупки в Интернете, нежели посещать розничный магазин офлайн. Однако, с покупкой одежды ситуация намного сложнее. Людям необходимо знать, как одежда сидит на них, как она выглядит и как ощущается на ощупь. Цифровые системы примерки потенциально могут удовлетворить основные из этих потребностей, обеспечивая прямое визуальное проецирование интересующей модели через камеру, учитывающее индивидуальные параметры тела человека. Именно эти возможности вызывают огромный интерес

среди игроков в отрасли онлайн-продаж, так как они являются привлекательной альтернативой для улучшения пользовательского опыта и популяризации онлайн-покупок модной одежды.

Однако, к сожалению, технология все еще далека от практичной, простой в использовании и адекватной для замены физической примерки. В настоящее время большинство интеллектуальных систем примерки полагаются либо на редактирование изображений, копирование и вставку, либо на демонстрации шаблонов, в то время как конечная цель – это быстрая и реалистичная система примерки, адаптируемая к телу каждого покупателя. По-прежнему существует значительный технологический разрыв между моделированием и демонстрацией примерки одежды в цифровом и реальном мирах, включая быструю и реалистичную демонстрацию, точное моделирование человеческого тела и одежды, точное моделирование материала одежды и преобразование одежды из виртуального в физический мир без потерь качества.

В этой статье будет рассмотрен ряд важнейших проблем, которые необходимо решить отрасли для осуществления полного перехода на использование технологии онлайн-примерки:

- 1) точная оценка человеческих форм и размеров с помощью мобильных устройств;
- 2) точное восстановление материалов через анализ изображений в реальном времени;
- 3) простота конструирования и манипулирования выкройками и предметами одежды пользователями системы.

Несмотря на то, что традиционные методы добились значительного прогресса в решении этих незначительных проблем, подходы, основанные на машинном обучении, продемонстрировали огромный потенциал для совершения перехода к использованию технологии. По сравнению с традиционными методами алгоритмы машинного обучения обычно намного быстрее, поскольку обучение и оптимизация выполняются офлайн. Они также хороши для обобщения неявных образов без необходимости утомительной предварительной обработки данных. Несмотря на то, что существуют обширные исследования в области обучения на 2D-изображениях, машинное обучение сильно вариативных 3D-объектов человеческого тела все еще далеки от совершенства, поэтому открытые проблемы, описанные выше, остаются неуловимыми.

Для каждой проблемы, перечисленной выше, мы мотивируем ее важность, даем описание проблемы и представляем современные подходы с потенциалом для улучшения. Решение этих сложных проблем приведут к значительному прогрессу в области технологий цифровых примерочных, а также в других областях электронной коммерции.

### **Существующие проблемы**

Рассмотрим три основных проблемы, которые ограничивают широкое распространение и признание как покупателями, так и компаниями технологии цифровой примерки. Есть несколько причин, по которым покупатели по-прежнему предпочитают физическую примерку. Во-первых, потребители не уверены, подойдет ли им то, что они покупают в интернет-магазине. Хотя общие системы онлайн-примерки существуют, отсутствие единообразия в них и стандартизации для различных брендов и материалов одежды часто может затруднять онлайн-примерку одежды, особенно для людей с нестандартными формами тела и пропорциями. Точная оценка формы человеческого тела - залог успешной цифровой примерки. Во-вторых, ткань обычно является ключевым фактором при покупке одежды. Различные ткани влияют на то, как одежда выглядит и сидит, как потребители будут ее носить и купят ли они ту или иную модель товара. Однако соответствие между фактическим материалом и его цифровым представлением не совсем понятно и зачастую значительно различаются. Также сложно полностью в виде цифрового образа воссоздать товар, обучая систему из реальных примеров.

Для клиентов внешний вид так же важен, как и другие факторы. Существует два подхода к отображению одежды: на основе 2D-изображения и на основе 3D-сетки с фотореалистичной визуализацией. У них есть разные преимущества и недостатки, но для поддержки обоих требуется большая база данных, состоящая из предметов одежды. Хотя создание 3D моделей одежды требует значительных усилий, 2D-изображения часто имеют такой недостаток, как недостаток вариаций и их гораздо сложнее настроить. В любом случае система примерки нуждается в удобном для пользователя дизайне и бэкэнде для эффективных манипуляций. И последнее, но не менее важное: быстрая и реалистичная анимация движущихся предметов одежды вместе с движениями тела значительно улучшает пользовательский опыт. Хотя это не так критично, как другие факторы, это эффективно сократит разрыв в восприятии между реальным и цифровым миром покупок в Интернете. Ранее, исследователи

предлагали использовать облачные вычисления для повышения скорости анимации, но в силу множества различных факторов, всё ещё существует заметный технологический разрыв, не позволяющий создавать высококачественную интерактивную 3D-анимацию одежды.

### **Распознавание фигуры человека**

Как уже отмечалось, точная оценка формы человека является ключом к возможности реализации технологии цифровой примерки. Реконструкция человеческого тела, состоящая из оценки позы и формы, широко изучалась в различных областях, включая цифровое наблюдение, компьютерную анимацию, спец. эффекты, а также виртуальную и дополненную реальность. Тем не менее, это остается сложной и популярной темой, представляющей интерес у исследователей со всего мира. Хотя прямое 3D-сканирование тела может обеспечить отличные и точные результаты, его применение несколько ограничено необходимым специализированным оборудованием. RGB изображения широко доступны как входные данные для цифровой примерки и могут быть легко получены с помощью обычных мобильных устройств. Хотя были предложены методы примерки на основе исключительно изображений [1], оценка 3D модели тела на основе машинного обучения более широко применима в том смысле, что 3D модель тела может быть сформирована и таким образом, будет получена возможность изменять позу и направление модели. Неформально определить проблему реконструкции человеческого тела возможно исходя из одного или нескольких изображений RGB, что позволит оценить геометрию и размер человеческого тела и вывести трехмерную гуманоидную сетку. Традиционные алгоритмы часто формулируют ее как задачу оптимизации, в которой разница силуэтов является основной частью целевой функции распознавания [2]. Поэтому эти методы либо требуют, чтобы человек носил обтягивающую одежду, либо, в качестве альтернативы, ослабляют целевую функцию, которая должна быть односторонней на открытых частях тела [3], либо указывают соответствия [4]. Использование методов машинного обучения в этой проблеме привело к значительным успехам. Во-первых, он переместил алгоритм из оперативного режима в офлайн, что значительно сократило время отклика. Во-вторых, используя параметрическую модель человека [5], можно легко построить регрессионную сеть для параметров, в то время как необходимые потери также могут быть выведены из них. В то время как в ранних работах предлагались сетевые модели

только для 2D / 3D скелетов тела [6-8], в более поздних работах были представлены методы выполнения регрессии для всего человеческого тела – либо с использованием параметрической модели человека [9, 10], либо на основе представления, основанного на вокселях, являющихся аналогом пикселя для трёхмерного объекта [11-13]. Поскольку аннотации в большинстве реальных наборов данных содержат только совместные позиции, процесс обучения был усовершенствован различными способами [14-17]. Наиболее актуальная работа по представляемой тематике – это работа «Shape-aware human pose and shape reconstruction using multi-view images» [18]. В упомянутой работе делается акцент на изучении формы, в то время как многие другие работы часто фокусируются на потерях тела и суставов, но игнорируют влияние форм тела.

Ключевой вклад автор упомянутой ранее работы заключается в том, что была разработана многопроекционная, многоступенчатая структура для устранения неоднозначности, вызванной проекцией камеры, показанная на рисунке 1.

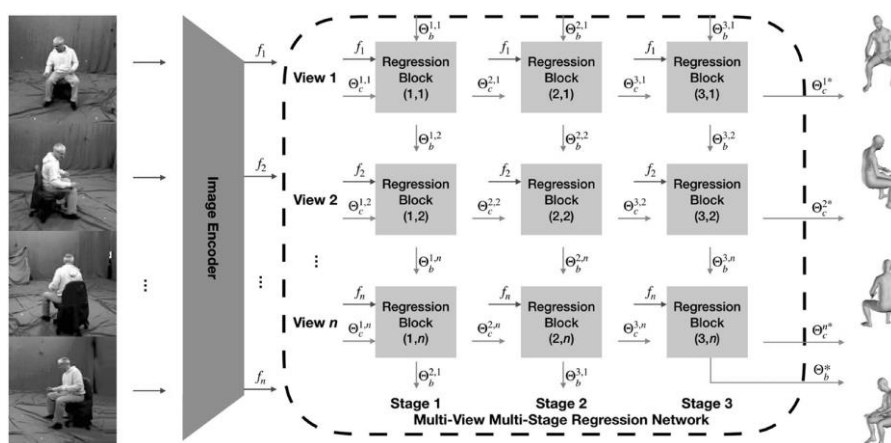


Рисунок 1 – Структура многоступенчатой, многопроекционной нейронной сети, представленной в работе [18]

Данная модель выполняет несколько этапов исправления ошибок. Каждое из входных изображений передается пошагово. На каждом этапе блок прогнозирования общих параметров вычисляет поправку на основе характеристики изображения и прогнозирования ввода. Параметры камеры и человеческого тела оцениваются одновременно, проецируя предсказанные 3D-суставы обратно в 2D для вычисления потерь. Предполагаемые параметры позы и формы являются общими для всех видов, в то время как каждый вид поддерживает собственную калибровку камеры и глобальную ориентацию. Предлагаемая структура использует рекуррентную структуру, что делает ее универсальной моделью, применимой к любому количеству представлений. В то же

время он объединяет совместно используемую информацию из разных представлений, чтобы поза и форма человеческого тела были оптимизированы с использованием функций изображения из всех представлений. В отличие от статических многоуровневых CNN, которые имеют фиксированное количество входов, они используют RNN-подобную структуру в циклической форме, чтобы принимать любое количество образов и предотвращать угасание градиента, предсказывая корректирующие значения вместо обновления параметров в каждой регрессии.

Эксперименты показали, что после обучения эта модель может формировать изображение с одним представлением, обеспечивать столь же хорошую оценку позы, как и современное искусство, и значительно улучшенную оценку позы при использовании многовидовых входных данных, что приводит к лучшей оценке формы во всех наборах данных. Пример показан на рисунке 2.

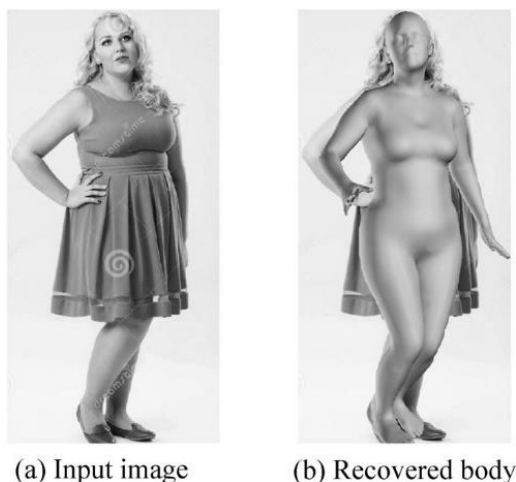


Рисунок 2 – Результаты прогнозов формы тела нейронной сети.

Модель фиксирует форму человеческого тела на основе синтетических данных.

Кроме того, для обогащения обучающих данных вводится потоковая генерация синтетических данных на физическом уровне, что очень полезно для оценки формы и регуляризации в тех случаях, когда традиционные датасеты недостаточно репрезентативны. В то время как синтетические данные улучшают разнообразие человеческих тел с достоверными параметрами, необходимы более крупные наборы данных об одежде и более удобный процесс регистрации, чтобы минимизировать разрыв в производительности между реальными изображениями и синтетическими данными. Кроме того, другие переменные, такие как волосы, цвет кожи и трехмерный фон, являются нестабильными элементами, которые могут влиять на воспринимаемую реалистичность синтетических данных за счет более высоких затрат на более сложный

процесс генерации данных. В связи с недавним прогрессом в передаче стилей изображений с использованием GAN многообещающим направлением является перенос синтетического результата на более реалистичные изображения для дальнейшего улучшения результата.

### **Моделирование материала одежды. Введение в моделирование одежды**

Материал одежды играет важную роль в системах онлайн примерки одежды. Физическое воссоздание ткани не только позволяет достаточно точно визуализировать поведение ткани, но также влияет на то, как одежда ощущается и сидит на теле. Однако моделирование ткани – сложная задача: внешний вид и физические свойства одежды определяются не только типом материала, из которого она изготовлена, но также кроем. Таким образом, исследователи часто сосредотачиваются на физическом поведении, а не на основных семантических примитивах.

Таким образом, формулируется задача моделирования материала одежды следующим образом. При наличии достаточного количества данных моделируется физическое поведение и физические свойства материала, чтобы визуальные эффекты были максимально схожи с эффектами реального материала, что позволит воспроизвести материал с помощью компьютера. Данная задача состоит из двух этапов: это создание физической модели материала, а во-вторую очередь оценка параметров модели.

Существует множество способов моделирования одежды, включая системы с пружинной массой и конечные элементы. Последняя является самой популярной моделью, так как может давать более реалистичные результаты. Хотя можно использовать изотропные свойства, такие как модуль Юнга и коэффициент Пуассона, анизотропная модель – лучший выбор, поскольку она может поддерживать различное поведение, вызванное переплетением материала.

### **Оценка на основе обучения**

В то время как традиционные методы оптимизации [19] часто занимают много времени для вычисления параметров материала, методы машинного обучения могут проводить прогнозирование в реальном времени с помощью простой операции с прямой связью, что является крайне актуальным приложениях, требующих быстрого отклика, такими как системы онлайн примерочных. Современная модель от Янга и др.

[20] использует CNN в сочетании с LSTM для воссоздания свойств материала из видео. Чтобы ограничить пространство ввода и решения, они выбирают один из материалов в качестве основы. Материальное подпространство строится путем умножения этой материальной основы на положительный коэффициент. Чтобы построить оптимальное подпространство параметров материала, проводится анализ чувствительности параметров материала, чтобы исследовать чувствительность параметров материала к по отношению к величине деформации  $D(k)$ . Моделирование ткани, основанное на физических свойствах, используется для генерации гораздо большего количества выборок данных в этих подпространствах, сбор которых в противном случае был бы затруднительным. Сетки ткани генерируются посредством физического моделирования, а затем визуализируются как 2D-изображения с произвольно назначаемой текстурой. Используя образцы данных, они комбинируют метод извлечения признаков сигнала изображения, CNN, с методом обучения временной последовательности, LSTM, чтобы изучить сопоставление видимого визуального отображения и материала. Как показано на рисунке 3, слой CNN используется для извлечения визуальных характеристик как нижнего, так и высшего порядка, в то время как слой LSTM фокусируется на изучении взаимосвязи между свойствами материала ткани и ее поведением при изменении формы.

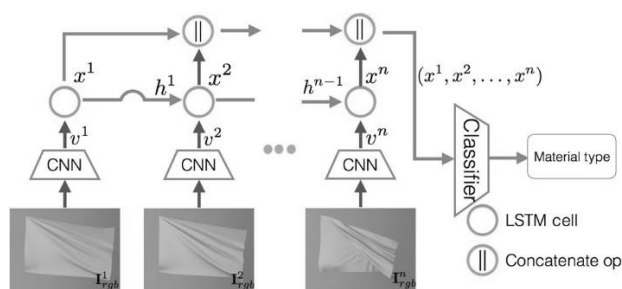


Рисунок 3 – Моделирование материала путём изучения паттернов движения объектов изображения, предоставленных СНС

Они продемонстрировали предложенный фреймворк с применением «клонирования материала». Обученная модель СНС способна клонировать поведение материалов и улавливать движение ткани, что наглядно продемонстрировано на рисунке 4. Тип материала можно определить из видеозаписи движения ткани за довольно небольшой промежуток времени. Восстановленный тип материала можно «клонировать» на другой кусок ткани или одежды, как показано на рисунке 5. При этом сеть понимает, где находится невидимый в данный момент участок объекта.






Рисунок 4 – Прогресс обучения СНС клонированию материалов




Рисунок 5 – Моделирование поведение материала на основе видео(слева) и перенос свойств в реальный мир (на примере юбки)

В этой работе видеоролики содержат только один кусок ткани, который не взаимодействует с другими объектами. Несмотря на то, что в реальной жизни это не применимо, этот метод позволяет по-новому взглянуть на решение поставленной проблемы. Логичным развитием обучения было бы изучение СНС поведения объекта на реальном человеческом теле при различных условиях освещения и частичной окклюзии.

### **Оптимизация с использованием дифференцируемой физики**

Другой подход к моделированию ткани — это измерение геометрических различий непосредственно во время оптимизации параметров. Предполагая, что

окружающая среда известна системе, вычисление предполагаемого движения и его градиента по отношению к параметрам материала может быть достигнуто с помощью дифференцируемого моделирования. Типичным использованием дифференцируемого моделирования является управление движением, показанное на рисунке 6, где проводится анализ отличий от цели, а потери передаются обратно в НС.

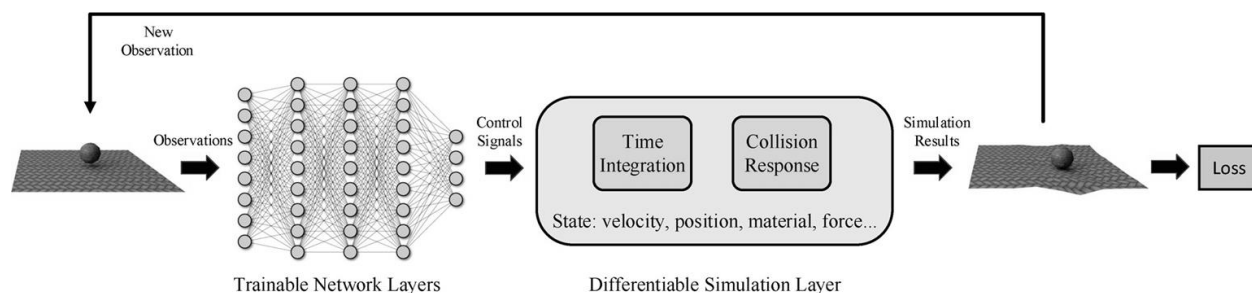


Рисунок 6 – Пример использования дифференцируемого моделирования

Аналогичные процессы могут быть применены и к оценке параметров материала. Измеряя расстояние до цели как потерю и вычисляя соответствующие градиенты, либо в пространстве пикселей, либо в трехмерном пространстве, параметры материала могут быть изучены или оптимизированы для достижения желаемого поведения движения ткани или визуального эффекта. Недавние научные работы по физике объектов, связанные с описанием моделирования тканей охватывают область твёрдых тел [22, 23], тканей [24] и системы кристаллических решёток [25, 26]. Самым современным является работа [24], в которой предлагается метод дифференцируемой симуляции тканей. Это первая работа, посвященная решению задачи моделирования с высокой размерностью и предложению общего дифференциального алгоритма обработки коллизий. Позже последующая работа [21] расширила алгоритм, применив его к связанной динамике с твердыми телами. В целом подход к логике построения вычислений моделирования тканей в описанных работах схож: производится дискретизация с использованием метода конечных элементов, далее интегрирование с использованием неявного метода Эйлера и реакция на столкновение в зонах коллизий. Они используют неявное разграничение в линейном вычислителе и оптимизацию для вычисления градиента по входным параметрам. Разрыв, возникающий в результате реакции на соударение, пренебрежимо мал, поскольку такие разрывные состояния представляют собой набор нуль-мер. Во время обратного распространения ошибки в оптимизации значения градиента могут быть

непосредственно вычислены матрицы ограничений после qr-разложения. Этот подход содержит несколько методов, которые могут быть использованы в других дифференцируемых симуляциях. В современных алгоритмах моделирования часто используется неявный метод Эйлера для получения стабильных результатов интегрирования. Таким образом, матрица масс  $M$  часто включает якобиан сил и обозначается как  $\hat{M}$ , чтобы указать на различия. Для вычисления ускорения необходима система решений линейных уравнений, поскольку вычисление  $\hat{M}^{-1}$  занимает много времени. Неявное дифференцирование используется для вычисления градиентов линейного решения. Для уравнения  $\hat{M} a = f$  с решением  $z$  и распространенным градиентом  $\partial L / \partial a | a=z$ , где  $L$  – функция потерь для конкретной задачи, неявное дифференцирование используется для получения градиентов. Более подробно эта механика описана в статье [24].

Был предложен общий подход, использующий LCP для объединения границ столкновения в физическом моделировании, но построение статического LCP часто нецелесообразно при моделировании ткани из-за высокой размерности. Коллизии и контакты, которые происходят на каждом шаге, очень разрежены по отношению к полным данным. Поэтому используется динамический подход, который включает обнаружение коллизий и реагирование на них.

Обработка коллизий и их реализации основана на оптимизации зоны воздействия. Алгоритм находит все конфликтующие экземпляры, используя непрерывное обнаружение коллизий, и устанавливает ограничения для всех коллизий. Чтобы внести минимальное изменение в исходное состояние сети, разработана задача QR для определения ограничений. Поскольку функция расстояния со знаком линейна по  $x$ , оптимизация принимает квадратичную форму, как было первоначально показано в работе [24], что отражает формула (1)

$$\begin{cases} \frac{1}{2}(z-x)^T W(z-x), z \rightarrow minimize \\ Gz + h \leq 0 \end{cases} \quad (1)$$

где  $W$  – постоянная диагональная матрица веса, связанная с массой каждой вершины,  $G$  и  $h$  – это ограничительные параметры.

Величины переменных и ограничений равны  $n$  и  $m$ , т.е.  $x \in \mathbb{R}^n$ ,  $h \in \mathbb{R}^m$  и  $G \in \mathbb{R}^{n \times m}$ . Важно заметить, что эта задача оптимизации получает на вход параметры  $x$ ,  $G$  и

$h$ , а на выход параметр  $z$ , который минимизируется. Задача оптимизации заключается в том, чтобы вывести  $\partial L/\partial X$ ,  $\partial L/\partial G$  и  $\partial l/\partial h$  для заданной  $\partial L/\partial Z$ , где  $L$  является функцией потерь. При вычислении градиента с использованием неявного дифференцирования размерность линейной системы может быть очень высокой. Важная особенность состоит в том, что  $n \gg m > \text{rank}(G)$ , поскольку одна коллизия часто включает 4 вершины (таким образом, получается 12 переменных), а некоторые коллизии могут быть линейно зависимы (например, несколько соседних пар коллизий). Они минимизируют размер линейного уравнения на основе QR-разложения  $G$ , что является ключом к ускорению обратного распространения ошибки QP большой размерности.

Тестирование описанного алгоритма показало его способность оптимизировать параметры материала путём проведения наблюдений. К примеру, на сцене изображен кусок ткани, висящий под действием силы тяжести и подвергающийся постоянной силе ветра. Модель материала состоит из трех составляющих: плотности  $d$ , жесткости при растяжении  $S$  и жесткости при сжатии  $B$ . Жесткость при растяжении определяет величину реакции материала при растяжении ткани; жесткость на сжатие показывает, насколько легко ткань можно сжимать и складывать. В таблице 1 представлены результаты работы описываемого алгоритма.

Таблица 1 – Результаты работы предиктивного алгоритма

Метод	Время работы (сек)	Ошибка измерения (%)	Ошибка при растяжении (%)	Ошибка при сжатии (%)	Ошибка моделирования (%)
Базовый	–	68 ± 46	160 ± 119	70 ± 42	12 ± 3.0
L-BFGS	2.89 ± 0.02	4.2 ± 5.6	72 ± 90	70 ± 43	4.9 ± 3.3
Метод, представленный в работе [24]	2.03 ± 0.06	1.8 ± 2.0	45 ± 41	77 ± 36	1.6 ± 1.4

Результаты показывают, что описанный подход позволяет достичь гораздо меньшей ошибки в большинстве наблюдений по сравнению с базовыми подходами. С помощью вычисленного градиента с использованием модели возможно эффективно оптимизировать неизвестные параметры, которые доминируют в движении ткани, чтобы соответствовать наблюдаемым данным. Предложенный в работе метод работает быстрее, чем L-BFGS. Значения параметров материала – это нормы разности

Научный журнал «Бизнес и общество» №3 (31), 2021  
ISSN 2409-6040

Фробениуса, нормированные на норму Фробениуса целевого объекта. Значения моделируемого результата представляют собой средние попарные расстояния до вершин, нормированные на размер ткани. Метод, основанный на градиенте, дает гораздо меньшие ошибки, чем базисный метод.

### **Моделирование и дизайн одежды**

Создание реалистичных моделей одежды становится все более популярным в связи с быстрыми изменениями модных тенденций и растущей потребностью в виртуальных моделях одежды в различных приложениях, таких как приложения виртуальной примерки. На сегодняшний день такие модели применяются для современных интерактивных систем дизайна одежды [27]. Моделирующие приложения требуют наличие общей модели ткани, которая может представлять собой разнообразные наборы предметов одежды. Тем не менее, существует много проблем в автоматическом создании моделей одежды. Во-первых, одежда обычно имеет различные типы топологии, особенно эта проблема актуальна для модной одежды, что затрудняет разработку универсального автоматизированного редактора. Кроме того, не менее актуальной остаётся проблема, связанная с тем, что часто бывает непросто перенастроить общий дизайн одежды на другую форму тела, что затрудняет подгонку.

Проблема подгонки одежды в некоторой степени решалась работой, описанной выше. Несмотря на то, что в работе [28] был предложен эффективный алгоритм создания трехмерной одежды, основанный на эскизах лицевых и оборотных изображений, алгоритм имеет некоторые сложности с оптимизацией, сгенерированной предметы одежды на другие формы тела. В то же время, в работе [29] предложен алгоритм, который позволяет эффективно выполнять подстройку изображений под форму тела, но допускает ограниченную топологию предметов одежды, такую как футболки или юбки. Ещё нет работ в открытом доступе, в которых рассматривалось бы решение этих две проблемы одновременно.

В данной работе представлено описание основанной на глубоком обучении параметрической генеративной модели НС для преодоления вышеуказанных трудностей. Если учитывать в качестве входных данных выкройки одежды и формы человеческого тела, то потенциально можно было бы решить проблему. Одним из возможных подходов было бы вычисление изображения смещения в  $U-V$  пространстве человеческого тела как единого представления сетки одежды. Различная топология и

размеры одежды представлены на изображении разными значениями. Двумерное изображение смещения, как представление данных трехмерной сетки одежды, затем может быть передано в условную состязательную сеть (сGAN) для обучения скрытому пространству. 2D-представление матрицы одежды может передавать нерегулярные данные 3D матрицы в обычные типы изображений, в которых традиционная CNN может легко обучаться. Также, возможно извлечение относительной геометрической информации относительно человеческого тела, что позволит переформатировать одежду на другого человека.

### **Заключение**

Хотя виртуальная реальность и цифровая примерка имеют отличный потенциал и быстро развиваются, остаются нерешенными многие проблемы, что не позволяет на данный момент системам онлайн-примерки получить широкое распространение. В работе перечислены три основные проблемы, каждая из которых может быть решена или улучшена с помощью алгоритмов машинного обучения. Для прогнозирования материала одежды современные методы все еще достаточно ограничены, поскольку данные исходные данные для обучения сильно ограничены. В большинстве случаев можно найти датасеты с развевающимися от потоков ветра тканями, но не более. Чтобы улучшить применимость обученных моделей к повседневным задачам, необходимо сосредоточиться на решении проблемы с помощью более разнообразного набора входных данных. Прогнозирование материала одежды на неподвижном человеческом теле может быть хорошим началом, после которого должно будет последовать обобщение произвольных движений человека и обучение распознавания наличия нескольких предметов одежды на одном теле. В области оценки формы человека необходимы исследования того, как внешние ограничения могут повысить точность оценки. Например, можно искусственно ограничить форму или размер одежды при оценке анализа тела по видео или изображениям, что повысит шансы точно определить форму тела. Хотя методы, основанные на оптимизации, могут довольно легко интегрировать эти ограничения, такая задача остается труднодостижимой для подходов, основанных на машинном обучении. Один из вариантов реализации состоит в том, чтобы совместно оценивать тело и одежду вместе и вносить потери при пересечении двух оценок. Этот подход потребует нового подхода к представлению одежды при обучении НС, так как в противном случае будет

необходимо обучать одну модель для каждого типа одежды, что будет крайне труднодостижимо.

### Список использованных источников

1. Zhao-Heng, Zheng Система смены одежды на основе изображений / Zheng Zhao-Heng, Hao-Tian. – Текст : непосредственный // Computational Visual Media. – 2020.
2. HS-Nets: Estimating human body shape from silhouettes with convolutional neural networks. / E. Dibra, H. Jain, z. C. O", R. Ziegler. – Текст : непосредственный // Proceedings of the 4th International Conference on 3D Vision. – 2016. – С. 108-117.
3. Bařlan, A. The naked truth: Estimating body shape under clothing. / A. Bařlan, M. Black. — Текст : непосредственный // Computer Vision – ECCV 2008. Lecture Notes in Computer Science. – 2008. – № 5303. – С. 15-29.
4. Unite the people: Closing the loop between 3D and 2D human representations. / C. Lassner, J. Romero, M. Kiefel, F. Bogo. – Текст : непосредственный // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2017.
5. SMPL: A skinned multi-person linear model. / M. Loper, N. Mahmood, J. Romero [и др.]. – Текст : непосредственный // ACM Transactions on Graphic. – 2015. – № 34.
6. Convolutional pose machines / S. Wei, V. Ramakrishna, T. Kanade, Y. Sheikh. – Текст : непосредственный // Proceedings of the IEEE conference on Computer Vision and Pattern Recognition. – 2016. – С. 4724-4732.
7. Realtime multi- person 2D pose estimation using part affinity fields / Z. Cao, T. Simon, S. Wei, Y. Sheikh. – Текст : непосредственный // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2017. – С. 1302- 1310.
8. VNect: Realtime 3D human pose estimation with a single RGB camera / D. Mehta, S. Sridhar, O. Sotnychenko, H. Rhodin. – Текст : непосредственный // ACM Transactions on Graphics. – 2017. – № 36.
9. Video based reconstruction of 3D people models / T. Alldieck, M. Magnor, W. Xu, C. Theobalt. – Текст : непосредственный // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2018. – С. 8387–8397.
10. End-to-end recovery of human shape and pose / A. Kanazawa, M. Black, D. Jacobs, J. Malik. – Текст : непосредственный // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2018. – С. 7122–7131.

11. Volumetric inference of 3D human body shapes. / G. Varol, D. Ceylan, B. Russell, J. Yang. – Текст : непосредственный // Proceedings of the European Conference on Computer Vision. – 2018. – С. 20–36.
12. Deephuman: 3D human reconstruction from a single image / Z. Zheng, T. Yu, Y. Wei [и др.]. – Текст : непосредственный // Proceedings of the IEEE International Conference on Computer Vision. – 2019. – С. 7739–7749.
13. PIFu: Pixel-aligned implicit function for high-resolution clothed human digitization / S. Saito, Z. Huang, R. Natsume [и др.]. – Текст : непосредственный // Proceedings of the IEEE International Conference on Computer Vision. – 2019. – С. 2304–2314.
14. Xu, Y. Denserac: Joint 3D pose and shape estimation by dense render-and-compare / Y. Xu, S. Zhu, T. Tung. – Текст : непосредственный // Proceedings of the IEEE International Conference on Computer Vision. – 2019. – С. 7760–7770.
15. FACSIMILE: Fast and accurate scans from an image in less than a second / D. Smith, M. Loper, X. Hu [и др.]. – Текст : непосредственный // Proceedings of the IEEE International Conference on Computer Vision. – 2019. – С. 5329– 5338.
16. Learning to reconstruct people in clothing from a single RGB camera / T. Alldieck, M. Magnor, B. L. Bhatnagar, C. Theobalt. – Текст : непосредственный // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2019. – С. 1175–1186.
17. Kolotouros, N. Learning to reconstruct 3D human pose and shape via model fitting in the loop / N. Kolotouros, G. Pavlakos, M. J. Black. – Текст : непосредственный // Proceedings of the IEEE International Conference on Computer Vision. – 2019. – С. 2252–2261.
18. Liang, J. Shape-aware human pose and shape reconstruction using multi-view images / J. Liang, M. C. Lin. – Текст : непосредственный // Proceedings of the IEEE International Conference on Computer Vision. – 2019. – С. 4352–4362.
19. Physics-inspired garment recovery from a single-view image / S. Yang, Z. R. Pan, T. Amert [и др.]. – Текст : непосредственный // ACM Transactions on Graphics. – 2018. – № 37.
20. Learning-based cloth material recovery from video / Yang, S., Liang [и др.]. – Текст : непосредственный // Proceedings of the IEEE International Conference on Computer Vision. – 2017. – С. 4383–4393.
21. Scalable differentiable physics for learning and control / Qiao, L. Y, J. B. Liang [и др.]. – Текст : непосредственный // arXiv preprint. – 2020.



22. End-to-end differentiable physics for learning and control / K. A. Smith, K. Allen, J. Tenenbaum, J. Z. Kolter. – Текст : непосредственный // Proceedings of the Advances in Neural Information Processing Systems. – 2018.
23. A differentiable physics engine for deep learning in robotics / J. Degraeve, M. Hermans, J. Dambre, F. Wyffels. – Текст : непосредственный // Frontiers in Neurorobotics. – 2019. – № 13.
24. Liang, J. Differentiable cloth simulation for inverse problems / J. Liang, M. Lin, V. Koltun. — Текст : непосредственный // Proceedings of the 33rd Conference on Neural Information Processing Systems. – 2019.
25. ChainQueen: A real-time differentiable physical simulator for soft robotics / Y. Hu, J. Liu, A. Spielberg [и др.]. – Текст : непосредственный // Proceedings of the International Conference on Robotics and Automation. – 2019. – С. 6265–6271.
26. DiffTaichi: Differentiable programming for physical simulation / Y. M. Hu, L. Anderson, T. M. Li [и др.]. – Текст : непосредственный // arXiv preprint arXiv:1910.00935. – 2019.
27. 3D interactive garment patternmaking technology / K. X. Liu, X. Y. Zeng, P. Bruniaux, X. Y. Tao. — Текст : непосредственный // у. Computer-Aided Design. – 2018. – № 104. – С. 113-124.
28. Huang, P. Automatic realistic 3D garment generation based on two images / P. Huang, J. Yao, H. Zhao. – Текст : непосредственный // Proceedings of the International Conference on Virtual Reality and Visualization. – 2016. – С. 250-257.
29. Изучение общего пространства формы для мультимодального дизайна одежды / Т. Я. Янг, Д. Цейлан, Я. Попович, Н. Я. Митра. – Текст : непосредственный // ACM Transactions on Graphics. – 2018. – № 37.