

Министерство образования и науки Российской Федерации  
Федеральное государственное автономное образовательное учреждение  
высшего образования  
«Российский государственный профессионально-педагогический университет»

**ЭЛЕКТРОННОЕ УЧЕБНОЕ ПОСОБИЕ  
«ОСНОВЫ МАШИННОГО ОБУЧЕНИЯ  
В ОБЛАСТИ КИБЕРБЕЗОПАСНОСТИ»**

Выпускная квалификационная работа  
по направлению подготовки 44.03.04 Профессиональное обучение  
(по отраслям)  
профилю подготовки «Информатика и вычислительная техника»  
специализации «Информационная безопасность»

Идентификационный номер ВКР: 191

Екатеринбург 2018

Министерство образования и науки Российской Федерации  
Федеральное государственное автономное образовательное учреждение  
высшего образования  
«Российский государственный профессионально-педагогический университет»  
Институт инженерно-педагогического образования  
Кафедра информационных систем и технологий

К ЗАЩИТЕ ДОПУСКАЮ

Заведующая кафедрой ИС

\_\_\_\_\_ Н. С. Толстова

« \_\_\_\_ » \_\_\_\_\_ 2018 г.

**ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА**  
**ЭЛЕКТРОННОЕ УЧЕБНОЕ ПОСОБИЕ**  
**«ОСНОВЫ МАШИННОГО ОБУЧЕНИЯ**  
**В ОБЛАСТИ КИБЕРБЕЗОПАСНОСТИ»**

Исполнитель:

обучающаяся группы № ИБ-401

А. Н. Аюпова

Руководитель:

канд. пед. наук, доцент

И. А. Сулова

Нормоконтролер:

Т. В. Рыжкова

Екатеринбург 2018

## АННОТАЦИЯ

Выпускная квалификационная работа состоит из презентационного материала и пояснительной записки на 46 страницах, содержащей 41 рисунок, 1 таблицу, 30 источников литературы, а также 1 приложение на 2 страницах.

Ключевые слова: ЭЛЕКТРОННОЕ УЧЕБНОЕ ПОСОБИЕ, КИБЕРБЕЗОПАСНОСТЬ, МАШИННОЕ ОБУЧЕНИЕ, ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ, ПРЕЗЕНТАЦИЯ.

**Аюпова А. Н.**, Электронное учебное пособие «Основы машинного обучения в области кибербезопасности»: выпускная квалификационная работа / А. Н. Аюпова; Рос. гос. проф.-пед. ун-т, Ин-т инж.-пед. образования, Каф. информ. систем и технологий. — Екатеринбург, 2018. — 46 с.

Объектом исследования данной выпускной квалификационной работы является процесс обучения студентов дисциплине «Интеллектуальные средства защиты информации».

Предметом выпускной квалификационной работы — учебный материал для дисциплины «Интеллектуальные средств защиты информации» по теме «Основы машинного обучения в области кибербезопасности».

Цель работы — разработать электронное учебное пособие «Основы машинного обучения в области кибербезопасности».

Отличительной особенностью данного электронного учебного пособия является ориентирование на дисциплину «Интеллектуальные средств защиты информации» для направления подготовки 44.03.04 Профессиональное обучение (по отраслям) профиль «Информационные технологии», а также на раскрытие вопросов машинного обучения в сфере информационной безопасности.

# СОДЕРЖАНИЕ

Введение.....	4
1 Анализ литературы по проблеме исследования.....	6
1.1 Обзор литературных источников .....	6
1.2 Обзор интернет-источников.....	9
1.3 Обзор рабочей программы дисциплины.....	10
2 Описание электронного учебного пособия «Основы машинного обучения в кибербезопасности» .....	12
2.1 Описание тематики презентаций по теоретическому блоку .....	12
2.2 Представление презентационного материала .....	13
2.3 Описание лабораторных работ .....	30
2.4 Описание интерфейса программного продукта.....	36
Заключение .....	39
Список использованных источников .....	41
Приложение .....	45

## ВВЕДЕНИЕ

Основная задача науки и реальной жизни — получение правильных предсказаний о будущем поведении сложных систем на основании их прошлого поведения. Многие задачи, возникающие в практических приложениях, не могут быть решены заранее известными методами или алгоритмами. Это происходит по той причине, что нам заранее не известны механизмы порождения исходных данных или же известная нам информация недостаточна для построения модели источника, генерирующей поступающие к нам данные. Как говорят, мы получаем данные из «черного ящика». В этих условиях ничего не остается, как только изучать доступную нам последовательность исходных данных и пытаться строить предсказания совершенству нашу схему в процессе предсказания. Подход, при котором прошлые данные или примеры используются для первоначального формирования и совершенствования схемы предсказания, называется методом машинного обучения.

Машинное обучение — чрезвычайно широкая и динамически развивающаяся область исследований, использующая огромное число теоретических и практических методов. В данной курсовой работе ознакомимся с некоторыми современными математическими проблемами данной области и их решениями, основной из которых является проблема построения и оценка предсказаний будущих исходов. С данным подходом тесно связана задача универсального предсказания. В том случае, когда мы не имеем достаточной информации для того чтобы построить модель источника генерирующей наблюдаемые данные, нам приходится учитывать как можно более широкие классы таких моделей и строить методы, которые предсказывают «не хуже» чем любая модель из данного класса. Понятие универсального предсказания, которое первоначально возникло в теории предсказаний стационарных источников, в настоящее время вышло далеко за рамки этой теории.

Объектом исследования данной выпускной квалификационной работы является процесс обучения студентов дисциплине «Интеллектуальные средства защиты информации».

Предметом выпускной квалификационной работы — учебный материал для дисциплины «Интеллектуальные средств защиты информации» по теме «Основы машинного обучения в области кибербезопасности».

Цель работы — разработать электронное учебное пособие «Основы машинного обучения в области кибербезопасности».

Для реализации поставленной цели необходимо решить следующие задачи:

- проанализировать литературу и интернет-источники по машинному обучению, с целью систематизации и структурирования собранного материала;
- проанализировать рабочую программу;
- разработать презентационный материал и лабораторные работы по введению в машинное обучение;
- реализовать электронное учебное пособие.

# 1 АНАЛИЗ ЛИТЕРАТУРЫ ПО ПРОБЛЕМЕ ИССЛЕДОВАНИЯ

## 1.1 Обзор литературных источников

Для создания презентационного материала по теме «Основы машинного обучения» были отобраны источники литературы и интернет-источники, которые наиболее ясно, чётко и доступно раскрывают понятие и суть данной темы.

Особенно стоит отметить учебник Флах П. «Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных» [28], в котором рассматриваются задачи и проблемы, решаемые методами машинного обучения; этапы и применения разнообразных моделей обучения. Эти данные позволяют глубже понять смысл данной темы и разобраться в ней более конкретно.

В книге Вьюгина В. В. «Математические основы теории машинного обучения и прогнозирования» [7] дано конкретное определение понятия машинное обучение, помогает уяснить некоторые современные математические проблемы данной области и их решения. Первая часть книги — статистическая теория машинного обучения — использует методы теории вероятностей и математической статистики. В основе данного подхода лежит предположение о том, что наблюдаемые исходы генерируются вероятностным источником, возможно, с неизвестными параметрами.

Книга «Машинное обучение» [4] рассчитана на тех, кто хочет решать самые разнообразные задачи при помощи машинного обучения. Как правило, для этого нужен Python.

В курсе лекций Загинайлова Ю. Н. [10] изложены теоретические основы информационной безопасности технической системы. Приведены объекты обеспечения информационной безопасности, угрозы объектам, политики

и структуры систем обеспечения информационной безопасности. Рассмотрены понятия и классификации защищаемой информации, угроз безопасности информации, объектов, способов, средств и систем защиты информации.

В книге «Введение в машинное обучение с помощью Python. Руководство для специалистов по работе с данными» [22] рассказывается о том, что машинное обучение стало неотъемлемой частью различных коммерческих и исследовательских проектов, однако эта область не является прерогативой больших компаний с мощными аналитическими командами. Эта книга научит практическим способам построения систем машинного обучения, даже если пользователь еще новичок в этой области.

В учебном пособии Васильева В.И. «Интеллектуальные системы защиты информации» [5] рассмотрены основы построения интеллектуальных систем защиты информации в корпоративных информационных системах. Автор сделал акцент на построении биометрических систем идентификации личности, систем обнаружения и предотвращения вторжений, анализа и управления информационными рисками. Изложены современные подходы к созданию данного класса систем с использованием методов теории нейронных сетей, искусственных иммунных систем, нечетких когнитивных моделей.

В течение последнего десятилетия произошел взрыв в вычислительных и информационных технологиях. С его помощью поступают огромные объемы данных в различных областях, таких как медицина, биология, финансы и маркетинг. Задача понимания этих данных привела к разработке новых инструментов в области статистики и породила новые области, такие как интеллектуальный анализ данных, машинное обучение и биоинформатика. Многие из этих инструментов имеют общие основы, но часто выражаются с другой терминологией. В книге «The Elements of Statistical Learning: Data Mining, Inference, and Prediction» [29] описываются важные идеи в этих областях в общих концептуальных рамках. Хотя этот подход является статистическим, акцент делается на концепциях, а не на математике. Приводится



много примеров с либеральным использованием цветной графики. Это ценный ресурс для статистиков и всех, кто интересуется разработкой данных в науке или промышленности. Охват книги обширен: от контролируемого обучения (прогнозирования) до неконтролируемого обучения. Многие темы включают в себя нейронные сети, вспомогательные векторные машины, деревья классификации и повышение — первое всестороннее рассмотрение этой темы в любой книге. В этом крупном новом выпуске представлены многие темы, не затронутые в оригинале, включая графические модели, случайные леса, ансамблевые методы, алгоритмы наименьшей регрессии и пути для лассо, неотрицательной матричной факторизации и спектральной кластеризации.

В книге «Распознавание образов. Построение и обучение вероятностных моделей» [19] рассматриваются несколько практически важных примеров решения задач статистического обучения, в которых пространства признаков и ответов и обучающие наборы устроены слишком сложно и нерегулярно, так что стандартные методы статистического обучения в них нельзя применить буквально, но можно применять после построения адекватных вероятностных моделей. Значительная часть описываемых методов строго обоснована: простые технические детали доказательств сформулированы и предложены в качестве упражнений, более сложные, но не слишком громоздкие доказательства предьявлены.

Книга «Машинное обучение: новый искусственный интеллект» Этема Алпайдина [2] представляет собой краткое введение в машинное обучение. Книга дает общее представление о машинном обучении, описывает суть основных алгоритмов обучения без погружения в технические подробности и обсуждает некоторые примеры их применения на уровне, достаточном для понимания основ.

## 1.2 Обзор интернет-источников

При анализе интернет-источников хочется выделить статью «Машинное обучение для чайников» [16] размещенную на интернет-ресурсе «Newtonew.com». В данной статье рассказывается для чего собственно нужна эта технология и приведены грамотные примеры использования, которые помогут разобраться с нуля в данной теме.

Приведены классы задач машинного обучения:

- задача регрессии: на основании различных признаков предсказать вещественный ответ;
- задача классификации: на основании различных признаков предсказать категориальный ответ;
- задача кластеризации: разбиение данных на похожие категории;
- задача уменьшения размерности: научиться описывать данные не  $N$  признаками, а меньшим числом;
- задача выявления аномалий: на основании признаков научиться различать отличать аномалии от «не-аномалий».

Несмотря на множество преимуществ предыдущей статьи удалось найти видеолекции с полным курсом про машинное обучение, которые ведет Воронцов К. В. [6]. Он рассказывает про основные понятия машинного обучения: объект, ответ, признак, предсказательная модель, метод обучения, эмпирический риск, переобучение. И показывает всё на наглядных примерах, что очень помогает в понимании материала.

В статье «Машинное обучение» [15] рассказывается о том, что обширный подраздел искусственного интеллекта, изучающий методы построения алгоритмов, способен обучаться. Машинное обучение — не только математическая, но и практическая, инженерная дисциплина. Чистая теория, как правило, не приводит сразу к методам и алгоритмам, применимым на практике. Чтобы заставить их хорошо работать, приходится изобретать дополнительные эвристики, компенсирующие несоответствие сделанных в теории

предположений условиям реальных задач. Практически ни одно исследование в машинном обучении не обходится без эксперимента на модельных или реальных данных, подтверждающего практическую работоспособность метода.

В статье Генрихова И. Е. [8] одной из центральных задач распознавания образов является задача распознавания по прецедентам. Известным инструментом решения данной задачи являются деревья решений. Синтез классического решающего дерева представляет собой итерационный процесс. Как правило, для построения очередной внутренней вершины дерева выбирается признак, который наилучшим образом удовлетворяет некоторому критерию ветвления, т.е. наилучшим образом разделяет текущее множество обучающих объектов.

### **1.3 Обзор рабочей программы дисциплины**

Программа академического бакалавриата по направлению подготовки 44.03.04 Профессиональное обучение (по отраслям) профиль «Информатика и вычислительная техника» профилизация «Информационная безопасность» предполагает в 6 семестре изучение дисциплины «Интеллектуальные средства защиты информации». Среди дисциплин, на которые опирается дисциплина «Интеллектуальные средства защиты информации» в 5 семестре — «Защита сетевых информационных систем», «Обеспечение безопасности баз данных». Параллельно рассматриваются такие дисциплины, как «Криптографические методы защиты информации» и «Программные средства обеспечения информационной безопасности». В последующих семестрах дисциплина «Интеллектуальные средства защиты информации» станет базой для прохождения таких дисциплин, как: 7 семестр — «Средства защиты в среде Интернет»; 8 семестр — «Проектирование систем безопасности» или «Принципы проектирования защищенных информационных систем», а также «Аппаратные средства защиты информации» и «Политика безопасности предприя-

тия».

Общая трудоемкость дисциплины «Интеллектуальные средства защиты информации» составляет 3 зачетных единицы, что соответствует 108 часам. На аудиторные занятия отводится 48 часов, среди которых 16 — лекционных и 32 — на лабораторные работы.

Перечень решаемых дисциплиной задач:

1. Разработка концепции построения интеллектуальной системы защиты информации на основе системного подхода.
2. Разработка архитектуры интеллектуальной автоматизированной системы защиты информации.
3. Разработка алгоритма принятия решений по оперативному управлению средствами защиты информации на основе методов искусственного интеллекта.
4. Разработка методики проектирования интеллектуальной автоматизированной системы кибербезопасности.
5. Реализация разработанных алгоритмов и оценка эффективности предлагаемых подходов.

Результатами изучения дисциплины должны стать:

- разработка и исследование методологических основ проектирования интеллектуальных систем защиты информации (ИСЗИ) на базе системно-концептуального подхода;
- исследование методов машинного обучения для защиты информации от злоумышленников;
- разработка алгоритма реализации методов машинного обучения для реализации искусственного интеллекта в кибербезопасности.

## 2 ОПИСАНИЕ ЭЛЕКТРОННОГО УЧЕБНОГО ПОСОБИЯ «ОСНОВЫ МАШИННОГО ОБУЧЕНИЯ В КИБЕРБЕЗОПАСНОСТИ»

### 2.1 Описание тематики презентаций по теоретическому блоку

В соответствии с изученным материалом было принято решение разделить его на темы для более удобного восприятия информации и оформить в Microsoft PowerPoint.

В результате проведенного анализа была разработана структура презентационного материала, состоящая из 8 тем (таблица 1).

Таблица 1 — Тематика презентационного материала

Основная тема	Тематика презентаций по теоретическому блоку
1	2
Знакомство с анализом данных и машинным обучением	Основные понятия машинного обучения
	Примеры прикладных задач
	Проблема переобучения и методология решения задач машинного обучения
Решающие деревья	Определение бинарного решающего дерева. Пример решающего дерева
	Жадный алгоритм построения дерева ID3
	Недостатки алгоритма и способы их устранения
	Проблема переобучения. Усечение дерева
Линейные методы классификации	Линейная модель классификации метод стохастического градиента
	Линейная модель классификации эвристики стохастического градиента
Метрические методы	Метод ближайших соседей и его обобщения. Обобщённый метрический классификатор
	Метод потенциальных функций
	Непараметрическая регрессия. Формула Нада-рая-Ватсона
	Непараметрическая регрессия. Проблема выбросов и робастная непараметрическая регрессия. Алгоритм LOWESS

Окончание таблицы 1

1	2
Логистическая регрессия	Логистическая регрессия
Метод опорных векторов	Переход к линейно неразделимой выборке. Условия Каруша-Куна-Таккера.
	Функция ядра. Примеры ядер
Метрики качества	Вычисление качества алгоритмов классификации
	Две основные метрики качества: PR-кривая и ROC-кривая
	Многоклассовая классификация
Нейронные сети	От линейного классификатора к искусственной нейронной сети
	Обратное распространение ошибок
	Эвристики в методе обратного распространения ошибок

## 2.2 Представление презентационного материала

В рамках данной работы были разработаны 22 презентации по теме «Основы машинного обучения в кибербезопасности». В первой презентации рассмотрена подтема «Основные понятия машинного обучения». По сути дела, большая часть машинного обучения — это наука о том, как решать задачу восстановления функции по точкам. весь курс машинного обучения будет посвящен конкретизации следующих вопросов: каким образом задаются объекты, какими могут быть ответы, как строить эту функцию, аппроксимирующую нашу неизвестную зависимость, и в каком смысле мы должны добиваться хорошего качества аппроксимации? начнём с того, как задаются объекты. Самый распространённый способ задания объектов — это признаковое описание. Признаки чисто формально — это функции, которые объектам ставят в соответствие какие-то значения, как правило, числовые. На рисунках 1, 2 приведены примеры графического представления данной темы.

## Как задаются объекты.

### Признаковое описание

$f_j: X \rightarrow D_j, j = 1, \dots, n$  – признаки объектов (features).

Типы признаков:

- $D_j = \{0,1\}$  – бинарный признак  $f_j$ ;
- $|D_j| < \infty$  – номинальный признак  $f_j$ ;
- $|D_j| < \infty, D_j$  упорядочено – порядковый признак  $f_j$ ;
- $D_j = \mathbb{R}$  – количественный признак  $f_j$ .

Вектор  $(f_1(x), \dots, f_n(x))$  – признаковое описание объекта  $x$ . Матрица «объекты-признаки» (feature data)

$$F = \|\|f_j(x_i)\|\|_{\ell \times n} = \begin{pmatrix} f_1(x_1) & \dots & f_n(x_1) \\ \dots & \dots & \dots \\ f_1(x_\ell) & \dots & f_n(x_\ell) \end{pmatrix}$$

Рисунок 1 — Внешний вид слайда с описанием способов задания объектов

## Этапы обучения и применения модели

### Этап обучения (train):

Метод обучения (learning algorithm)  $\mu: (X \times Y)^\ell \rightarrow A$  по выборке  $X^\ell = (x_i, y_i)_{i=1}^\ell$  строит алгоритм  $a = \mu(X^\ell)$ :

$$\begin{pmatrix} f_1(x_1) & \dots & f_n(x_1) \\ \dots & \dots & \dots \\ f_1(x_\ell) & \dots & f_n(x_\ell) \end{pmatrix} \xrightarrow{y} \begin{pmatrix} y_1 \\ \dots \\ y_\ell \end{pmatrix} \xrightarrow{\mu} a$$

### Этап применения (test):

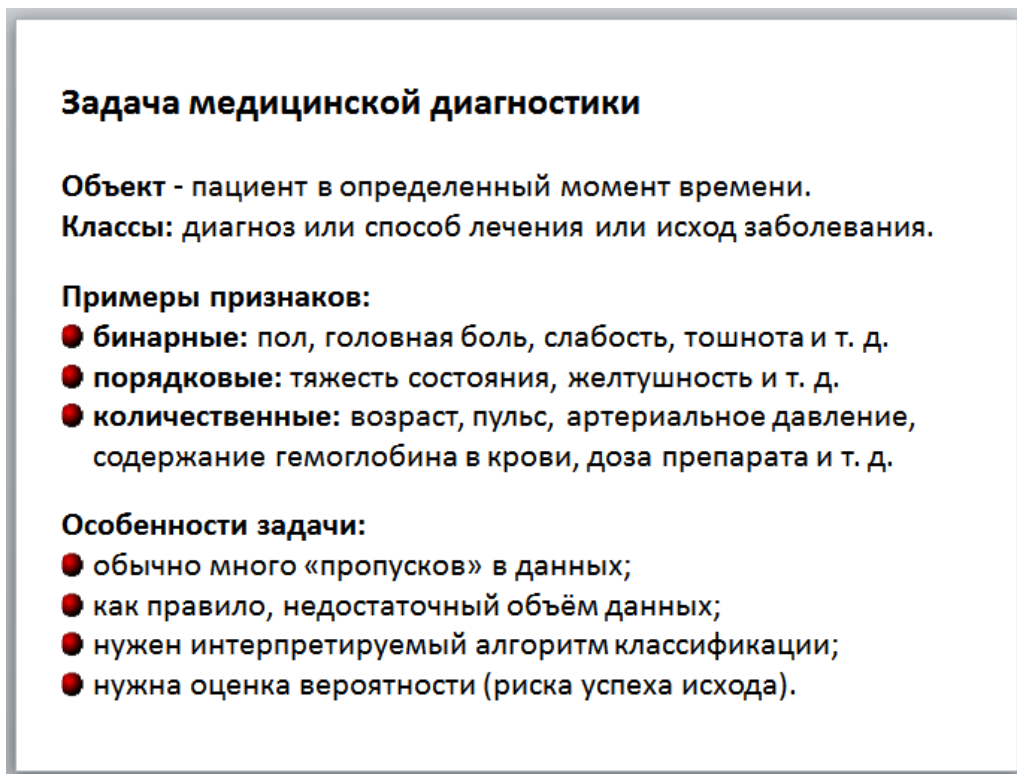
алгоритм  $a$  для новых объектов  $x'_1, \dots, x'_k$  выдаёт ответы  $a(x'_i)$ .

$$\begin{pmatrix} f_1(x'_1) & \dots & f_n(x'_1) \\ \dots & \dots & \dots \\ f_1(x'_k) & \dots & f_n(x'_k) \end{pmatrix} \xrightarrow{a} \begin{pmatrix} a(x'_1) \\ \dots \\ a(x'_k) \end{pmatrix}$$

Рисунок 2 — Внешний вид слайда с описанием этапов обучения

Вторая подтема посвящена примерам прикладных задач машинного обучения. В машинном обучении исходные данные, как правило, представ-

ляются в виде матрицы «объекты — признаки». Строки матрицы соответствуют объектам, столбцы — признакам, и есть еще один столбец — это ответы, правильные ответы на объектах обучающей выборки, и цель — научиться восстанавливать зависимость ответов от объектов, ну и далее потом эту зависимость использовать для того, чтобы делать прогнозы, решать задачи автоматизации принятия решений. На рисунке 3 приведен один из примеров — задача медицинской диагностики.



**Задача медицинской диагностики**

**Объект** - пациент в определенный момент времени.  
**Классы:** диагноз или способ лечения или исход заболевания.

**Примеры признаков:**

- **бинарные:** пол, головная боль, слабость, тошнота и т. д.
- **порядковые:** тяжесть состояния, желтушность и т. д.
- **количественные:** возраст, пульс, артериальное давление, содержание гемоглобина в крови, доза препарата и т. д.

**Особенности задачи:**

- обычно много «пропусков» в данных;
- как правило, недостаточный объём данных;
- нужен интерпретируемый алгоритм классификации;
- нужна оценка вероятности (риска успеха исхода).

Рисунок 3 — Внешний вид слайда с задачей медицинской диагностики

Также на рисунке 4 было рассмотрено предсказание оттока клиентов у определенного мобильного оператора, то есть требуется по этим частным данным сделать предсказания относительно других частных данных. В первом модуле рассказывается о задачах, которые решает машинное обучение, определен базовый набор понятий и введены необходимые обозначения. Также идет отсылка на основные библиотеки языка Python для работы с данными (NumPy, Pandas, Scikit-Learn), которые понадобятся для выполнения практических заданий на протяжении всей дисциплины.



## **Задача предсказания оттока клиентов**

**Объект** – абонент в определённый момент времени.

**Классы** – уйдёт или не уйдёт в следующем месяце.

### **Примеры признаков:**

- **бинарные:** корпоративный клиент, включение услуг, и т. д.
- **номинальные:** тарифный план, регион проживания, и т. д.
- **количественные:** длительность разговоров (входящих, исходящих, СМС, и т. д.), частота оплаты и т. д.

### **Особенности задачи:**

- нужно оценивать вероятность ухода;
- сверхбольшие выборки;
- не ясно, какие признаки вычислять по «сырым» данным.

Рисунок 4 — Внешний вид слайда с задачей предсказания оттока клиентов

Как итог к этой теме было составлено резюме, в котором выделены особенности данных в прикладных задачах. Резюме представлено на рисунке 5.

## **Резюме**

- **Прикладные задачи машинного обучения**  
встречаются во всех областях бизнеса, науки, производства
- **Особенности данных в прикладных задачах:**
  - разнородные (признаки измерены в разных шкалах);
  - неполные (измерены не все, имеются пропуски);
  - неточные (измерены с погрешностями);
  - противоречивые (объекты одинаковые, ответы разные);
  - избыточные (сверхбольшие, не помещаются в память);
  - недостаточные (объектов меньше, чем признаков);
  - неструктурированные (нет признаковых описаний);
  - нетривиальные критерии качества.

Рисунок 5 — Внешний вид слайда с резюме

В третьей презентации рассмотрена подтема «Проблема переобучения и методология решения задач машинного обучения».

Пример переобучения полиномиальной регрессии представлен на рисунке 6.



Рисунок 6 — Внешний вид слайда с примером

И также подведен итог данной темы, в котором представлены этапы решения задач машинного обучения, на рисунке 7.

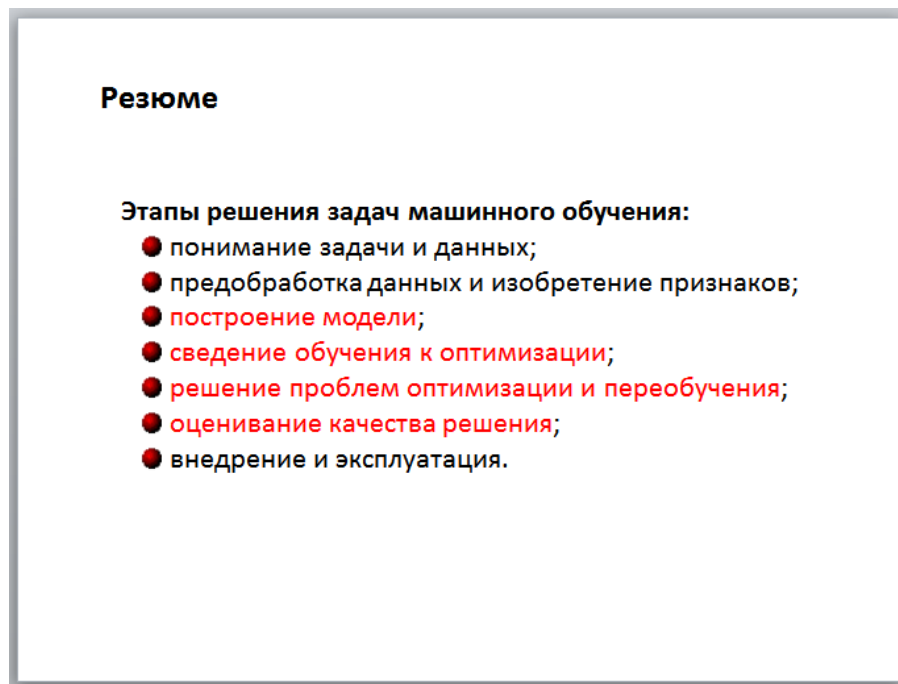


Рисунок 7 — Внешний вид слайда с резюме

Вторая тема посвящена решающим деревьям. В первой презентации представлена подтема «Определение бинарного решающего дерева» в которой рассказывается о бинарном решающем дереве и приведены несколько примеров для наглядности. На рисунке 8 представлен пример бинарного решающего дерева.

Бинарное решающее дерево – алгоритм классификации  $a(x)$ , задающийся бинарным деревом:

- 1)  $\forall v \in V_{\text{внутр}} \rightarrow$  предикат  $\beta_v: X \rightarrow \{0, 1\}, \beta_v \in \mathcal{B}$ ,
- 2)  $\forall v \in V_{\text{лист}} \rightarrow$  имя класса  $C_v \in Y$ , где  $\mathcal{B}$  - множество бинарных признаков или предикатов (например, вида  $\beta_{(x)} = [x^j \geq \theta_j], x^j \in \mathbb{R}$ )

- 1:  $v := v_0$ ;
- 2: пока  $v \in V_{\text{внутр}}$
- 3:   если  $\beta_v(x) = 1$  то
- 4:     переход вправо:  $v := R_v$ ;
- 5:   иначе
- 6:     переход влево  $v := L_v$ ;
- 7: вернуть  $C_v$ .

Рисунок 8 — Внешний вид слайда с описанием бинарного решающего дерева

Вторая подтема посвящена «Жадному алгоритму построения дерева ID3». На рисунке 9 представлен пример алгоритма построения дерева ID3.

**Жадный алгоритм построения дерева ID3**

- 1: ПРОЦЕДУРА LearnID3 ( $U \subseteq X^{\ell}$ );
- 2: если все объекты из  $U$  лежат в одном классе  $c \in Y$  то
- 3:   вернуть новый лист  $v, c_v := c$ ;
- 4: найти предикат с максимальной информативностью:  
 $\beta := \arg \max_{\beta \in \mathcal{B}} I(\beta, U)$ ;
- 5: разбить выборку на две части  $U = U_0 \sqcup U_1$  по предикату  $\beta$ :  
 $U_0 := \{x \in U: \beta(x) = 0\}$ ;  
 $U_1 := \{x \in U: \beta(x) = 1\}$ ;
- 6: если  $U_0 = \emptyset$  то
- 7:   вернуть новый лист  $v, c_v :=$  Мажоритарный класс ( $U$ );
- 8: создать новую внутреннюю вершину  $v: \beta_v := \beta$ ;  
 построить левое поддерево:  $L_v := \text{LearnID3}(U_0)$ ;  
 построить правое поддерево:  $R_v := \text{LearnID3}(U_1)$ ;
- 9: вернуть  $v$ ;

Рисунок 9 — Внешний вид слайда с примером алгоритма

Третья подтема посвящена «Недостаткам алгоритма и обработка пропусков». В данной теме рассказывается о достоинствах и недостатках решающих деревьях ID3 и обработке пропусков. Слайд из данной темы представлен на рисунке 10.

Решающие деревья ID3: достоинства и недостатки

Достоинства:

- Интерпретируемость и простота классификации.
- Гибкость: можно варьировать множество  $\mathcal{S}$ .
- Допустимы разнотипные данные и данные с пропусками.
- Трудоемкость линейна по длине выборки  $O(|\mathcal{S}|h\ell)$ .
- Не бывает отказов от классификации.

Недостатки:

- Жадный ID3 переусложняет структуру дерева, и, как следствие, сильно переобучается.
- Фрагментация выборки: чем дальше  $v$  от корня, тем меньше статистическая надёжность выбора  $\beta_v, c_v$ .
- Высокая чувствительность к шуму, к составу выборки, к критерию информативности.

Рисунок 10 — Внешний вид слайда с описанием достоинств и недостатков решающих деревьев

В четвертой подтеме рассказывается о «Проблеме переобучения. Усечение дерева». Усечение дерева и алгоритм представлены на рисунке 11.

Усечение дерева (pruning). Алгоритм C4.5

$X^k$  — независимая контрольная выборка,  $k \approx 0.5\ell$ .

- 1: для всех  $v \in V_{\text{внутр}}$
- 2:  $S_v :=$  подмножество объектов  $X^k$ , дошедших до  $v$ ;
- 3: если  $S_v = \emptyset$  то
- 4: вернуть новый лист  $v$ ,  $c_v :=$  Мажоритарный класс ( $U$ );
- 5: число ошибок при классификации  $S_v$  четырьмя способами:
  - $r(v)$  — поддеревом, растущим из вершины  $v$ ;
  - $r_L(v)$  — поддеревом левой дочерней вершины  $L_v$ ;
  - $r_R(v)$  — поддеревом правой дочерней вершины  $R_v$ ;
  - $r_c(v)$  — к классу  $c \in Y$ .
- 6: в зависимости от того, какое из них минимально:
  - сохранить поддерево  $v$ ;
  - заменить поддерево  $v$  поддеревом  $L_v$ ;
  - заменить поддерево  $v$  поддеревом  $R_v$ ;
  - заменить поддерево  $v$  листом,  $c_v := \arg \min_{c \in Y} r_c(v)$ .

Рисунок 11 — Внешний вид слайда с описанием усечения дерева

Третья тема посвящена «Линейным методам классификации». Линейные модели широко используются в машинном обучении благодаря их относительной простоте, в некоторых случаях хорошей интерпретируемости и наличию глубоко проработанных численных методов. Данная тема делится на 2 подтемы. В первой подтеме рассказывается о линейной модели классификации, методе стохастического градиента, на рисунке 11.

Обучение классификации – тоже оптимизация

Обучающая выборка:  $X^\ell = (x_i, y_i)_{i=1}^\ell$ ,  $x_i \in \mathbb{R}^n$ ,  $y_i \in \{-1, +1\}$

- Модель классификации – *линейная*:  

$$a(x, w) = \text{sign}\langle x, w \rangle$$
- **Непрерывная аппроксимация бинарной функции потерь:**  

$$\mathcal{L}(a, y) = [\langle x_i, w \rangle y_i < 0] \leq \mathcal{L}(\langle x_i, w \rangle y_i),$$
 где  $M_i(w) = \langle x_i, w \rangle y_i$  – отступ (margin) объекта  $x_i$
- Метод обучения – *минимизация эмпирического риска*:  

$$Q(w) = \sum_{i=1}^{\ell} [\langle x_i, w \rangle y_i < 0] \leq \sum_{i=1}^{\ell} \mathcal{L}(\langle x_i, w \rangle y_i) \rightarrow \min_w$$
- Проверка по тестовой выборке  $X^k = (\tilde{x}_i, \tilde{y}_i)_{i=1}^k$ :  

$$\bar{Q}(w) = \frac{1}{k} \sum_{i=1}^k [\langle \tilde{x}_i, w \rangle \tilde{y}_i < 0]$$

Рисунок 12 — Внешний вид слайда с описанием непрерывной аппроксимации бинарной функции потерь

Метод стохастического среднего градиента SAG рассмотрен также в первой подтеме. И представлен на рисунке 13.

Алгоритм SAG (Stochastic Average Gradient)

**Вход:** выборка  $X^\ell$ , темп обучения  $h$ , темп забывания  $\lambda$ ;  
**Выход:** вектор весов  $w$ ;

- 1 инициализировать веса  $w_j, j = 1, \dots, n$ ;
- 2 инициализировать градиенты:  $G_i := \nabla \mathcal{L}_i(w), i = 1, \dots, \ell$ ;
- 3 инициализировать оценку функционала:  $\bar{Q} := \frac{1}{\ell} \sum_{i=1}^{\ell} \mathcal{L}_i(w)$ ;
- 4 **повторять**
- 5 выбрать объект  $x_i$  из  $X^\ell$  случайным образом;
- 6 вычислить потерю:  $\mathcal{E}_i := \mathcal{L}_i(w)$ ;
- 7 вычислить градиент:  $G_i := \nabla \mathcal{L}_i(w)$ ;
- 7 сделать градиентный шаг:  $w := w - h \sum_{i=1}^{\ell} G_i$ ;
- 8 оценить функционал:  $\bar{Q} := (1 - \lambda)\bar{Q} + \lambda \mathcal{E}_i$ ;
- 9 **пока** значение  $\bar{Q}$  и/или веса  $w$  не сойдутся;

Рисунок 13 — Внешний вид слайда с описанием алгоритма SAG

Диагональный метод Левенберга-Марквардта рассмотрен в следующей подтеме. В этой же подтеме рассказывается о преимуществах и недостатках метода стохастического градиента, вариантах инициализации весов, вариантах выбора градиентного шага. Метод Левенберга-Марквардта представлен на рисунке 14.

Диагональный метод Левенберга-Марквардта

Метод Ньютона-Рафсона,  $\mathcal{L}_i(w) = \mathcal{L}((w, x_i)y_i)$ :

$$w := w - h(\mathcal{L}_i''(w))^{-1} \nabla \mathcal{L}_i(w),$$

где  $\mathcal{L}_i''(w) = \left( \frac{\partial^2 \mathcal{L}_i(w)}{\partial w_j \partial w_j} \right)$  – гессиан,  $n \times n$ -матрица

Эвристика: считаем, что гессиан диагонален. Тогда

$$w_j := w_j - h \left( \frac{\partial^2 \mathcal{L}_i(w)}{\partial w_j^2} + \mu \right)^{-1} \frac{\partial \mathcal{L}_i(w)}{\partial w_j}.$$

$h$  – темп обучения, можно полагать  $h = 1$   
 $\mu$  – параметр, предотвращающий обнуление знаменателя.  
 Отношение  $h/\mu$  есть темп обучения на ровных участках функционала  $\mathcal{L}_i(w)$ , где вторая производная обнуляется.

Рисунок 14 — Внешний вид слайда с описанием метода Левенберга-Марквардта

В следующей теме рассказывается о «Метрических методах классификации». Метрический классификатор — алгоритм классификации, основанный на вычислении оценок сходства между объектами. Простейшим метрическим классификатором является метод ближайших соседей, в котором классифицируемый объект относится к тому классу, которому принадлежит большинство схожих с ним объектов. Метод ближайших соседей рассматривается в первой подтеме и представлен на рисунке 16.

Метрические методы проводят классификацию на основе сходства, благодаря чему могут работать на данных со сложной структурой — главное, чтобы между объектами можно было измерить расстояние. В работе рассмотрен метод  $k$  ближайших соседей, а также способ его обобщения на задачи регрессии с помощью ядерного сглаживания.

### Метод k ближайших соседей (k nearest neighbors, kNN)

$$w(i, k) = [i \leq k].$$

$w(i, k) = [i \leq 1]$  – метод ближайшего соседа.

#### Преимущества:

- простота реализации (lazy learning);
- параметр k можно оптимизировать по критерию скользящего контроля (leave-one-out);

$$LOO(k, X^\ell) = \sum_{i=1}^{\ell} [a(x_i, X^\ell \setminus \{x_i\}, k) \neq y_i] \rightarrow \min_k.$$

#### Проблемы:

- возможны ситуации, когда классификация не однозначна:  $\Gamma_y(x) = \Gamma_s(x)$  для пары классов  $y \neq s$
- учитываются не значения расстояний, а только их ранги

Рисунок 15 — Внешний вид слайда с описанием метода ближайших соседей

В следующей презентации представлена тема «Метод окна Парзена. Метод потенциальных функций». В этом файле рассмотрены методы парзеновского окна переменной и фиксированной ширины. Также приведен пример парзеновского окна фиксированной ширины  $h$  на двумерной выборке на рисунках 16, 17.

### Метод окна Парзена

$$w(i, x) = K\left(\frac{\rho(x, x^{(i)})}{h}\right), \text{ где } h \text{ – ширина окна,}$$

$K(r)$  – ядро, не возрастает и положительно на  $[0, 1]$ .

#### Метод парзеновского окна *фиксированной ширины*:

$$a(x; X^\ell, h, K) = \arg \max_{y \in Y} \sum_{i=1}^{\ell} [y_i = y] K\left(\frac{\rho(x, x_i)}{h}\right)$$

#### Метод парзеновского окна *переменной ширины*:

$$a(x; X^\ell, k, K) = \arg \max_{y \in Y} \sum_{i=1}^{\ell} [y_i = y] K\left(\frac{\rho(x, x_i)}{\rho(x, x^{(k+1)})}\right)$$

#### Оптимизация параметров – по критерию LOO:

- выбор ширины окна  $h$  или числа соседей  $k$
- выбор ядра  $K$  слабо влияет на качество классификации

Рисунок 16 — Внешний вид слайда с описанием метода окна Парзена

Парзеновское окно фиксированной ширины  $h$

**Пример:** двумерная выборка, два класса  $Y = \{-1, +1\}$ .

$$a(x) = \arg \max_{y \in Y} \Gamma_y(x) = \text{sign} (\Gamma_{+1}(x) - \Gamma_{-1}(x))$$

$h = 0.05$




Рисунок 17 — Внешний вид слайда с описанием примера на двумерной выборке

Третья подтема посвящена непараметрической регрессии, формуле Надарая-Ватсона. Сама формула представлена на рисунке 18.

Непараметрическая регрессия. Формула Надарая-Ватсона

Приближение константой  $f(x, \alpha) = \alpha$  в окрестности  $x \in X$ :

$$Q(\alpha; X^\ell) = \sum_{i=1}^{\ell} w_i(x) (\alpha - y_i)^2 \rightarrow \min_{\alpha \in \mathbb{R}}$$

где  $w_i(x) = K\left(\frac{\rho(x, x_i)}{h}\right)$  – веса объектов  $x_i$  относительно  $x$ ;

$K(r)$  – ядро, невозрастающее, ограниченное, гладкое;

$h$  – ширина окна сглаживания.

**Формула ядерного сглаживания Надарая-Ватсона**

$$a_h(x; X^\ell) = \frac{\sum_{i=1}^{\ell} y_i w_i(x)}{\sum_{i=1}^{\ell} w_i(x)} = \frac{\sum_{i=1}^{\ell} y_i K\left(\frac{\rho(x, x_i)}{h}\right)}{\sum_{i=1}^{\ell} K\left(\frac{\rho(x, x_i)}{h}\right)}$$

Рисунок 18 — Внешний вид слайда с формулой Надарая-Ватсона

В четвертой, последней подтеме данной теме рассказывается о проблеме выбросов и алгоритме LOWESS. На рисунке 19 представлена проблема выбросов.



## Проблема выбросов и локально взвешенное сглаживание

**Проблема выбросов:** большие случайные ошибки в значениях  $y_i$  сильно искажают оценку Надарая Ватсона

$$a_h(x; X^\ell) = \frac{\sum_{i=1}^{\ell} y_i w_i(x)}{\sum_{i=1}^{\ell} w_i(x)}, \quad w_i(x) = K\left(\frac{\rho(x, x_i)}{h}\right).$$

### Идея:

чем больше величина невязки  $\varepsilon_i = |a_h(x_i; X^\ell \setminus \{x_i\}) - y_i|$ , тем меньше должен быть вес  $i$ -го объекта  $w_i(x)$ .

### Эвристика:

домножить веса  $w_i(x)$  на коэффициенты  $\gamma_i = \tilde{K}(\varepsilon_i)$ , где  $\tilde{K}(\varepsilon)$  – ещё одно ядро, вообще говоря, отличное от  $K(r)$ .

### Рекомендация:

использовать квадратическое ядро  $\tilde{K}(\varepsilon) = K_Q\left(\frac{\varepsilon}{6\text{med}\{\varepsilon_i\}}\right)$ , где  $\text{med}\{\varepsilon_i\}$  – медиана множества значений  $\varepsilon_i$ .

Рисунок 19 — Внешний вид слайда с описанием проблемы выбросов

На рисунке 20 описан алгоритм LOWESS.

## Алгоритм LOWESS (LOcally WEighted Scatter plot Smoothing)

**Вход:**  $X^\ell$  – обучающая выборка;

**Выход:** коэффициенты  $\gamma_i, i = 1, \dots, \ell$ ;

1: инициализация:  $\gamma_i, i = 1, \dots, \ell$ ;

2: **повторять**

3: **для всех** объектов  $i = 1, \dots, \ell$

4: **вычислить** оценки скользящего контроля:

$$a_i := a_h(x_i; X^\ell \setminus \{x_i\}) = \frac{\sum_{j=1, j \neq i}^{\ell} y_j \gamma_j K\left(\frac{\rho(x_i, x_j)}{h(x_i)}\right)}{\sum_{j=1, j \neq i}^{\ell} \gamma_j K\left(\frac{\rho(x_i, x_j)}{h(x_i)}\right)};$$

5: **для всех** объектов  $i = 1, \dots, \ell$

6:  $\gamma_i := \tilde{K}(|a_i - y_i|)$ ;

7: **пока** коэффициенты  $\gamma_i$  не стабилизируются;

Рисунок 20 — Внешний вид слайда с описанием алгоритма LOWESS

Пятая тема посвящена «Логистической регрессии», в которую входят такие темы как: «Логистическая регрессия», «Пример прикладной задачи»,

«Регуляризованная логистическая регрессия». Первая подтема представлена на рисунке 21.

Обоснование логарифмической функции потерь

$(x_i, y_i)_{i=1}^{\ell} \sim p(x, y; w)$  — выборка независимых наблюдений.  
 Принцип максимума правдоподобия:

$$L(w) = \log \prod_{i=1}^{\ell} p(x_i, y_i; w) = \sum_{i=1}^{\ell} \log P(y_i | x_i; w) p(x_i) \rightarrow \max_w$$

Вероятностная модель порождения данных с параметром  $w$ :

- $p(x)$  не зависит от параметра модели  $w$ ,
- $p(y|x; w)$  описывается линейной моделью классификации:

$$P(y_i | x_i; w) = \frac{1}{1 + \exp(-\langle x_i, w \rangle y_i)} = \sigma(\langle x_i, w \rangle y_i),$$

где  $\sigma(M) = \frac{1}{1 + e^{-M}}$  — сигмоидная функция.  
 Тогда задачи  $Q(w) \rightarrow \min$  и  $L(w) \rightarrow \max$  эквивалентны:

$$Q(w) = \sum_{i=1}^{\ell} \log(1 + \exp(-\langle w, x_i \rangle y_i)) \rightarrow \min_w$$

Рисунок 21 — Внешний вид слайда с обоснованием логарифмической функции потерь

На рисунке 22 показан пример прикладной задачи.

Пример. Бинаризация признаков и скоринговая карта

Задача кредитного скоринга:

- $x_i$  — заёмщики
- $y_i \in \{-1(\text{bad}), +1(\text{good})\}$

Бинаризация признаков  $f_j(x)$ :

$$b_{jk}(x) = [f_j(x) \in D_{jk}]$$

Возраст	до 25	5
	25 - 40	10
	40 - 50	15
	50 и больше	10
Собственность	владелец	20
	совладелец	15
	съемщик	10
	другое	5
Работа	руководитель	15
	менеджер среднего звена	10
	служащий	5
	другое	0
Стаж	1/безработный	0
	1-3	5
	3-10	10
	10 и больше	15
Работа_мужа/жены	нет/домохозяйка	0
	руководитель	10
	менеджер среднего звена	5
	служащий	1

Рисунок 22 — Внешний вид слайда с примером задачи

Про регуляризованную логистическую регрессию рассказывается в последней презентации, на рисунке 23.

### Регуляризованная логистическая регрессия

- $L_2$  – регуляризация решает проблему мультиколлинеарности (сокращает веса линейно зависимых признаков):

$$Q(w) = \sum_{i=1}^{\ell} \log(1 + \exp(-\langle w, x_i \rangle y_i)) + \tau \sum_{j=1}^n w_j^2 \rightarrow \min_w.$$

- $L_1$  – регуляризация имеет эффект отбора признаков (обнуляет веса  $w_j$  неинформативных признаков):

$$Q(w) = \sum_{i=1}^{\ell} \log(1 + \exp(-\langle w, x_i \rangle y_i)) + \tau \sum_{j=1}^n |w_j| \rightarrow \min_w.$$

- Используется также их комбинация – ElasticNet.

Коэффициент регуляризации  $\tau$  подбирается по скользящему контролю.

Рисунок 23 — Внешний вид слайда с описанием регуляризованной логистической регрессии

Шестая тема в данной работе «Метод опорных векторов». Первая под-тема «Переход к линейно неразделимой выборке. Условия Каруша-Куна-Таккера» представлена на рисунке 24.

### Переход к линейно неразделимой выборке

Постановка задачи в случае линейно разделимой выборки:

$$\begin{cases} \frac{1}{2} \|w\|^2 \rightarrow \min_{w, w_0}; \\ M_i(w, w_0) \geq 1, i = 1, \dots, \ell. \end{cases}$$

Общий случай – линейно неразделимая выборка:

$$\begin{cases} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^{\ell} \xi_i \rightarrow \min_{w, w_0, \xi}; \\ M_i(w, w_0) \geq 1 - \xi_i, i = 1, \dots, \ell \\ \xi_i \geq 0, i = 1, \dots, \ell \end{cases}$$

Исключая  $\xi_i$ , получаем задачу безусловной минимизации:

$$C \sum_{i=1}^{\ell} (1 - M_i(w, w_0))_+ + \frac{1}{2} \|w\|^2 \rightarrow \min_{w, w_0}.$$

Рисунок 24 — Внешний вид слайда с описанием перехода к линейно неразделимой выборке

Тема «Условия Каруша-Куна-Таккера» описаны на рисунке 25.

Условия Каруша-Куна-Таккера

Задача математического программирования:

$$\begin{cases} f(x) \rightarrow \min_x; \\ g_i(x) \leq 0, i = 1, \dots, m; \\ h_j(x) = 0, j = 1, \dots, k. \end{cases}$$

Необходимые условия. Если  $x$  – точка локального минимума, то существуют множители  $\mu_i, i = 1, \dots, m, \lambda_j, j = 1, \dots, k$ :

$$\begin{cases} \frac{\partial \mathcal{L}}{\partial x} = 0, \mathcal{L}(x; \mu, \lambda) = f(x) + \sum_{i=1}^m \mu_i g_i(x) + \sum_{j=1}^k \lambda_j h_j(x); \\ g_i(x) \leq 0; h_j(x) = 0; \text{(исходные ограничения)} \\ \mu_i \geq 0; \text{(двойственные ограничения)} \\ \mu_i g_i(x) = 0; \text{(условие дополняющей нежёсткости)} \end{cases}$$

Рисунок 25 — Внешний вид слайда с описанием условия Каруша-Куна-Таккера

Во второй подтеме «Функция ядра. Примеры ядер» приведено определение ядра, примеры ядер, классификации с различными ядрами, которые помогают разобраться в этой теме. На рисунке 26 наглядно показаны примеры ядер.

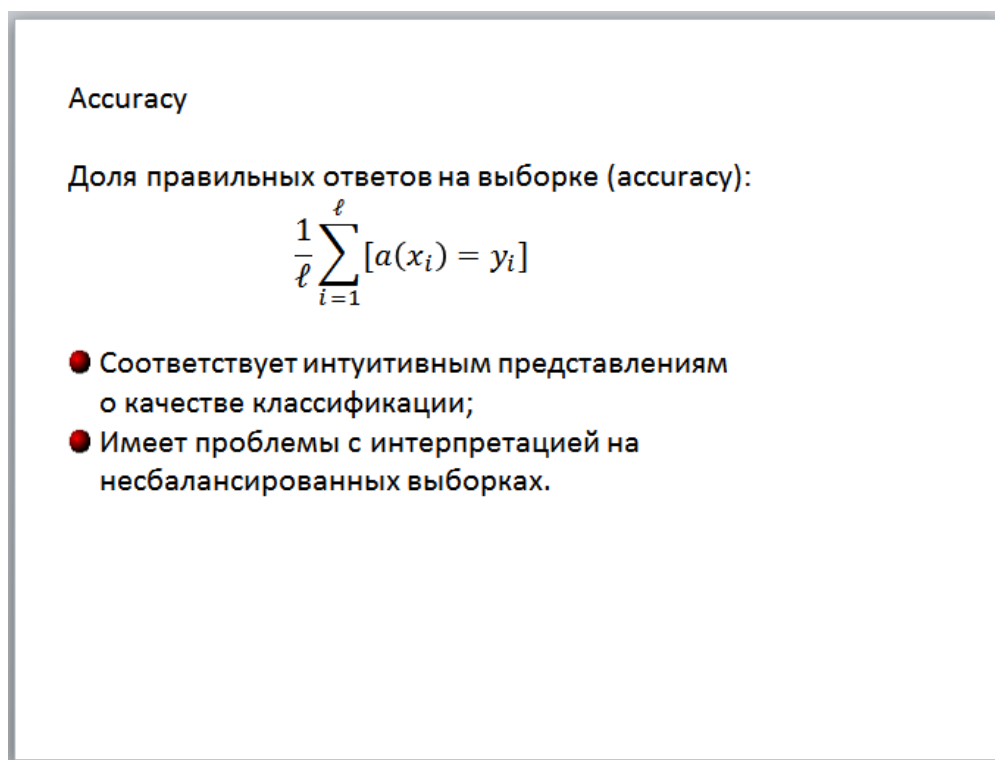
Примеры ядер

Ядра в SVM расширяют линейную модель классификации:

- $K(x, x') = (\langle x, x' \rangle + 1)^d$   
– полиномиальная разделяющая поверхность степени  $\leq d$ ;
- $K(x, x') = \langle \sigma(z), \sigma(z) \rangle$   
– нейронная сеть с заданной функцией активации  $\sigma(z)$   
( $K$  не при всех  $\sigma$  является ядром);
- $K(x, x') = \text{th}(k_1 \langle x, x' \rangle + k_0), k_0, k_1 \geq 0$   
– нейросеть с сигмоидными функциями активации;
- $K(x, x') = \exp(-\gamma \|x - x'\|^2)$   
– сеть радиальных базисных функций (RBF ядро);

Рисунок 26 — Внешний вид слайда с примерами ядер

В седьмой теме данной работы рассказывается о «Метриках качества». В машинном обучении существует большое количество метрик качества, каждая из которых имеет свою прикладную интерпретацию и направлена на измерение конкретного свойства решения. В первой презентации рассмотрена подтема «Вычисление качества алгоритмов классификации». В простейшем случае метрикой может быть Ассигасу, доля документов по которым классификатор принял правильное решение. На рисунке 27 представлена метрика, о которой говорилось выше.



Ассигасу

Доля правильных ответов на выборке (ассигасу):

$$\frac{1}{\ell} \sum_{i=1}^{\ell} [a(x_i) = y_i]$$

- Соответствует интуитивным представлениям о качестве классификации;
- Имеет проблемы с интерпретацией на несбалансированных выборках.

Рисунок 27 — Внешний вид слайда с описанием метрики ассигасу

Точность и полнота являются метриками, которые используются при оценке большей части алгоритмов извлечения информации. На рисунке 28 представлена точность.

В машинном обучении существует большое количество метрик качества, каждая из которых имеет свою прикладную интерпретацию и направлена на измерение конкретного свойства решения. В этой работе рассмотрено, какие бывают метрики качества бинарной и многоклассовой классификации, а также рассмотрим способы сведения многоклассовых задач к двухклассовым.

Точность и полнота

Точность (precision) – насколько можно доверять классификатору:

$$\text{precision} = \frac{TP}{TP + FP}$$

	$y = 1$	$y = 0$
$a(x) = 1$	20	50
$a(x) = 0$	5	1000

Точность классификатора: 28.6%

Точность константного классификатора: 0%

Рисунок 28 — Внешний вид слайда с описанием точности

На рисунке 29 представлена полнота.

Точность и полнота

Полнота (recall) – как много объектов класса 1 находит классификатор:

$$\text{recall} = \frac{TP}{TP + FN}$$

	$y = 1$	$y = 0$
$a(x) = 1$	20	50
$a(x) = 0$	5	1000

Точность классификатора: 80%

Точность константного классификатора: 0%

Рисунок 29 — Внешний вид слайда с описанием полноты

## 2.3 Описание лабораторных работ

При создании электронного учебного пособия были реализованы 8 лабораторных работ по следующим темам:

1. Логические методы классификации.
2. Метрические методы классификации: выбор числа соседей.
3. Метрические методы классификации: выбор метрики.
4. Линейные методы классификации.
5. Метод опорных векторов: опорные объекты.
6. Метод опорных векторов: анализ текстов.
7. Логистическая регрессия.
8. Метрики качества.

Лабораторная работа 1 (рисунок 30) основана на материалах лекций по логическим методам и направлено на знакомство с решающими деревьями.

**Примечание¶**

Реализация в Scikit-Learn: в библиотеке `scikit-learn` решающие деревья реализованы в классах `sklearn.tree.DecisionTreeClassifier` (для классификации) и `sklearn.tree.DecisionTreeRegressor` (для регрессии). Обучение модели производится с помощью функции `fit`.¶

Пример использования приведен на рисунке 1.¶

```
1 import numpy as np
2 from sklearn.tree import
  DecisionTreeClassifier
3 X = np.array([[1, 2], [3, 4], [5, 6]])
4 y = np.array([0, 1, 0])
5 clf = DecisionTreeClassifier()
6 clf.fit(X, y)
```

Рисунок 1¶

В этом задании потребуется находить важность признаков. Это можно сделать, имея уже обученный классификатор (рисунок 2).¶

Рисунок 30 — Внешний вид фрагмента лабораторной работы «Логические методы классификации»

Решающие деревья относятся к классу логических методов. Их основная идея состоит в объединении определенного количества простых решаю-

щих правил, благодаря чему итоговый алгоритм является интерпретируемым. Как следует из названия, решающее дерево представляет собой бинарное дерево, в котором каждой вершине сопоставлено некоторое правило вида « $j$ -й признак имеет значение меньше  $b$ ». В листьях этого дерева записаны числа-предсказания. Чтобы получить ответ, нужно стартовать из корня и делать переходы либо в левое, либо в правое поддерево в зависимости от того, выполняется правило из текущей вершины или нет.

Одна из особенностей решающих деревьев заключается в том, что они позволяют получать важности всех используемых признаков. Важность признака можно оценить на основе того, как сильно улучшился критерий качества благодаря использованию этого признака в вершинах дерева.

Лабораторные работы 2 и 3 «Выбор числа соседей» и «Выбор метрики» (рисунки 31 и 32) основаны на материалах лекций по метрическим методам.

**Лабораторная работа 2**

**Выбор числа соседей**

Цель: изучить метод  $k$ -ближайших соседей.

Задачи:

- → научиться работать с методом  $k$ -ближайших соседей;
- → научиться выбирать в нем параметр  $k$ ;
- → научиться правильно готовить данные к использованию в методе  $k$ NN;
- → изучить способ обобщения метода  $k$ -ближайших соседей на задачи регрессии с помощью ядерного сглаживания.

¶

Данное задание основано на материалах лекций по метрическим методам и посвящено подбору числа соседей в методе  $k$ NN.

**Теоретический материал**

Рисунок 31 — Внешний вид фрагмента лабораторной работы «Метрические методы классификации: выбор числа соседей»



Главным параметром любого метрического алгоритма является функция расстояния (или метрика), используемая для измерения сходства между объектами. Можно использовать стандартный вариант (например, евклидову метрику), но гораздо более эффективным вариантом является подбор метрики под конкретную задачу. Один из подходов — использование той же евклидовой метрики, но с весами: каждой координате ставится в соответствие определенный коэффициент; чем он больше, тем выше вклад признака в итоговое расстояние. Веса настраиваются с целью оптимизации качества на отложенной выборке. Другой подход, о котором и пойдет речь в данном задании — выбор метрики из некоторого класса метрик. Мы возьмем за основу метрику Минковского:¶

$$\rho_p(x, z) = \left( \sum_{j=1}^d |x_j - z_j|^p \right)^{\frac{1}{p}} \quad \text{¶}$$

Рисунок 32 — Внешний вид фрагмента лабораторной работы «Метрические методы классификации: выбор метрики»

Метрические методы основаны на гипотезе компактности, суть которой состоит в том, что объекты с похожими признаковыми описаниями имеют похожие значения целевой переменной. Если эта гипотеза верна, то строить прогноз для нового объекта можно на основе близких к нему объектов из обучающей выборки — например, путем усреднения их ответов (для регрессии) или путем выбора наиболее популярного среди них класса (для классификации). Методы такого типа и называются метрическими.

Лабораторная работа 4 (рисунок 33) основана на материалах лекции по линейным методам классификации.

Линейные алгоритмы — распространенный класс моделей, которые отличается своей простотой и скоростью работы. Их можно обучать за разумное время на очень больших объемах данных, и при этом они могут работать с любыми типами признаков — вещественными, категориальными, разреженными. В этом задании мы предлагаем вам воспользоваться перцептроном — одним из простейших вариантов линейных моделей.

Пример-использования-приведен-на-рисунке-5.

```

1 from sklearn.preprocessing import
  StandardScaler
2 scaler = StandardScaler()
3 X_train = np.array([[100.0, 2.0], [50.0, 4.0]
  , [70.0, 6.0]])
4 X_test = np.array([[90.0, 1], [40.0, 3], [60
  .0, 4]])
5 X_train_scaled = scaler.fit_transform(X_train
  )
6 X_test_scaled = scaler.transform(X_test)
7

```

Рисунок-5

**Ход-работы**

- Загрузите обучающую и тестовую выборки из файлов `perceptron-train.csv` и `perceptron-test.csv`. Целевая переменная записана в первом столбце, признаки — во втором и третьем.
- Обучите перцептрон со стандартными параметрами и `random_state=241`.

Рисунок 33 — Внешний вид фрагмента лабораторной работы «Линейные методы классификации»

Лабораторные работы 5 и 6 «Метод опорных векторов»: «Опорные объекты» и «Анализ текстов» (рисунки 34 и 35) основаны на материалах лекций по методам опорных векторов.

Метод опорных векторов (Support Vector Machine, SVM) — один из видов линейных классификаторов. Функционал, который он оптимизирует, направлен на максимизацию ширины разделяющей полосы между классами. Из теории статистического обучения известно, что эта ширина тесно связана с обобщающей способностью алгоритма, а ее максимизация позволяет бороться с переобучением.

Метод опорных векторов имеет еще одну особенность. Если преобразовать его оптимизационную задачу, то окажется, что итоговый классификатор можно представить, как взвешенную сумму скалярных произведений данного объекта на объекты обучающей выборки:

$$a(x) = \sum_{i=1}^{\ell} \lambda_i y_i \langle x, x_i \rangle - w_0$$

По сути, алгоритм делает предсказания на основе сходства нового объекта с объектами обучающей выборки. При этом, как

Рисунок 34 — Внешний вид фрагмента лабораторной работы «Метод опорных векторов: опорные объекты»

TfidfVectorizer (рисунок 7).

```
1 feature_mapping = vectorizer
  .get_feature_names()
2 print feature_mapping[i]
```

Рисунок 7

Подбор параметров удобно делать с помощью класса `sklearn.grid_search.GridSearchCV` (При использовании библиотеки `scikit-learn` версии 18.0.1 `sklearn.model_selection.GridSearchCV`). Пример использования (рисунок 8).

```
1 grid = {'C': np.power(10.0, np.arange(-5, 6
  ))}
2 cv = KFold(y.size, n_folds=5, shuffle=True,
  random_state=241)
3 clf = svm.SVC(kernel='linear', random_state
  =241)
4 gs = GridSearchCV(clf, grid, scoring
  = 'accuracy', cv=cv)
5 gs.fit(X, y)
```

Рисунок 8

Рисунок 35 — Внешний вид фрагмента лабораторной работы «Метод опорных векторов: анализ текстов»

Метод опорных векторов — один из видов линейных классификаторов. Функционал, который он оптимизирует, направлен на максимизацию ширины разделяющей полосы между классами. Из теории статистического обучения известно, что эта ширина тесно связана с обобщающей способностью алгоритма, а ее максимизация позволяет бороться с переобучением.

Лабораторная работа 7 «Логистическая регрессия» (рисунок 36) основана на материалах лекций по логистической регрессии.

Логистическая регрессия — один из видов линейных классификаторов. Одной из ее особенностей является возможность оценивания вероятностей классов, тогда как большинство линейных классификаторов могут выдавать только номера классов.

$$\frac{1}{\ell} \sum_{i=1}^{\ell} \log(1 + \exp(-y_i(w_1 x_{i1} + w_2 x_{i2}))) + \frac{1}{2} C \|w\|^2 \rightarrow \min_{w_1, w_2}$$

Здесь  $x_{i1}$  и  $x_{i2}$  — значение первого и второго признаков соответственно на объекте  $x_i$ . В этом задании мы будем рассматривать алгоритмы без свободного члена, чтобы упростить работу.

Градиентный шаг для весов будет заключаться в одновременном обновлении весов  $w_1$  и  $w_2$  по следующим формулам (проверьте сами, что здесь действительно выписана производная нашего функционала):

$$w_1 := w_1 + k \frac{1}{\ell} \sum_{i=1}^{\ell} y_i x_{i1} \left( 1 - \frac{1}{1 + \exp(-y_i(w_1 x_{i1} + w_2 x_{i2}))} \right) - k C w_1$$

$$w_2 := w_2 + k \frac{1}{\ell} \sum_{i=1}^{\ell} y_i x_{i2} \left( 1 - \frac{1}{1 + \exp(-y_i(w_1 x_{i1} + w_2 x_{i2}))} \right) - k C w_2$$

Здесь  $k$  — размер шага.

Рисунок 36 — Внешний вид фрагмента лабораторной работы «Логистическая регрессия»

Лабораторная работа 8 «Метрические качества классификации» (рисунок 37) основана на материалах лекций по метрикам качества классификации.

### Ход работы

- Загрузите файл `classification.csv`. В нем записаны истинные классы объектов выборки (колонок `true`) и ответы некоторого классификатора (колонок `pred`).
- Заполните таблицу ошибок классификации.
 

	Actual Positive	Actual Negative
Predicted Positive	TP	FP
Predicted Negative	FN	TN

Для этого подсчитайте величины TP, FP, FN и TN согласно их определениям. Например, FP — это количество объектов, имеющих класс 0, но отнесенных алгоритмом к классу 1. Ответ в данном вопросе — четыре числа через пробел.
- Посчитайте основные метрики качества классификатора.
  - Accuracy (доля верно угаданных) — `sklearn.metrics.accuracy_score`

Рисунок 37 — Внешний вид фрагмента лабораторной работы «Метрические качества классификации»

В задачах классификации может быть много особенностей, влияющих на подсчет качества: различные цены ошибок, несбалансированность классов и т.д. Из-за этого существует большое количество метрик качества — каждая из них рассчитана на определенное сочетание свойств задачи и требований к ее решению.

Меры качества классификации можно разбить на две большие группы: предназначенные для алгоритмов, выдающих номера классов, и для алгоритмов, выдающих оценки принадлежности к классам.

## 2.4 Описание интерфейса программного продукта

Главная страница (рисунок 38) содержит навигационные кнопки, для подробного ознакомления с полной информацией.




Рисунок 38 — Внешний вид титульной страницы

На рисунке изображен снимок экрана (рисунок 39) раскрывающегося навигационного меню.

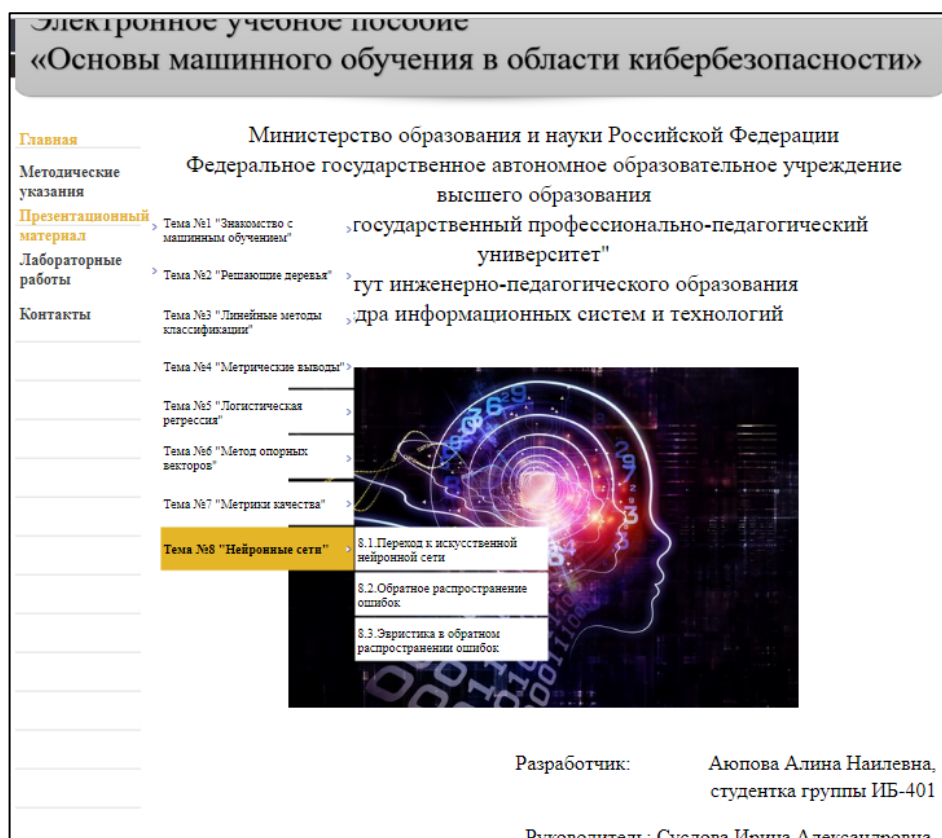


Рисунок 39 — Внешний вид навигационного меню

На изображении (рисунок 40) показан результат перехода по навигационной кнопке на страницу с презентацией.

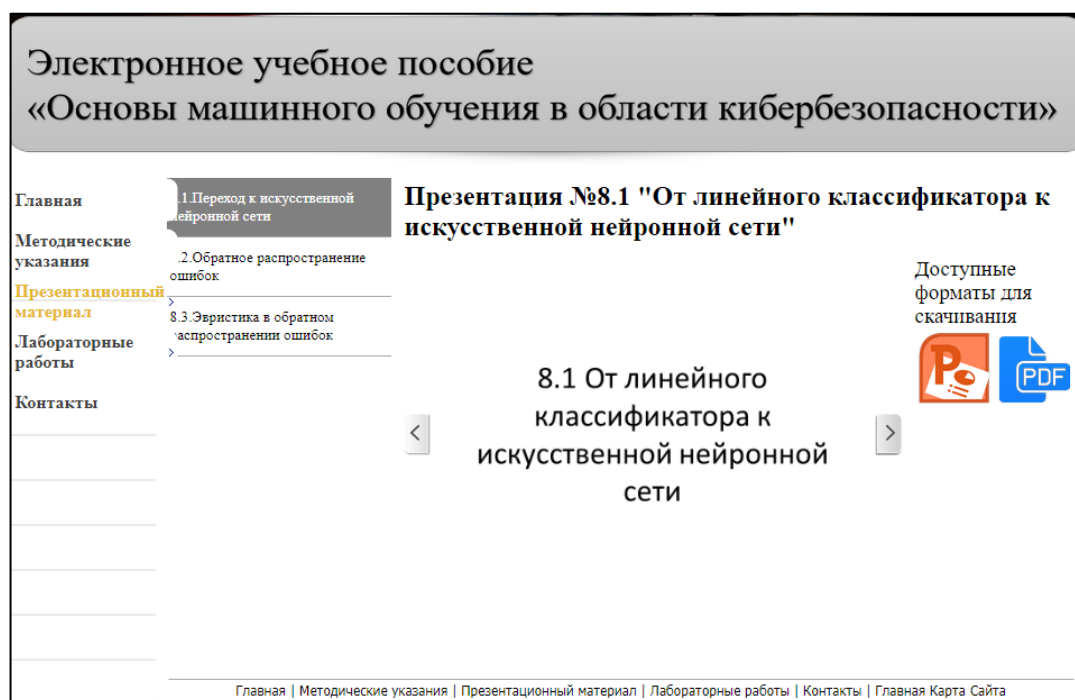


Рисунок 40 — Результат действия перехода на теоретический раздел

На рисунке изображен подраздел «Лабораторная работа» (рисунок 41).

# Электронное учебное пособие «Основы машинного обучения в области кибербезопасности»



<b>Главная</b>	Лабораторная работа №1 "Логические методы классификации"	<b>Лабораторная работа №1 "Решающие деревья"</b>  <b>Лабораторная работа 1 "Решающие деревья"</b>  Цель: изучить основной класс логических алгоритмов — решающие деревья.  Задачи: <ul style="list-style-type: none"><li>· научиться обучать решающие деревья;</li><li>· научиться находить наиболее важные для решающих деревьев признаки;</li><li>· ознакомиться с объединением деревьев в композицию, называемую случайным лесом.</li></ul> Данное задание основано на материалах лекций по логическим методам и направлено на знакомство с решающими деревьями (Decision Trees). Логические методы делают классификацию объектов на основе простых правил, благодаря чему являются интерпретируемыми и легкими в реализации. При объединении в композицию логические модели позволяют решать многие задачи с высоким качеством.  <b>Теоретический материал</b>  Решающие деревья относятся к классу логических методов. Их основная идея состоит в объединении определенного количества простых	Доступные файлы для скачивания  
Методические указания	Лабораторная работа №2 "Метрические методы классификации"		
Презентационный материал	Лабораторная работа №3 "Метрические методы классификации"		
Лабораторные работы	Лабораторная работа №4 "Линейные методы классификации"		
Контакты	Лабораторная работа №5 "Метод опорных векторов"		
	Лабораторная работа №6 "Метод опорных векторов"		
	Лабораторная работа №7 "Логистическая регрессия"		
	Лабораторная работа №8 "Метрики качества"		

Рисунок 41 — Внешний вид лабораторной работы

## ЗАКЛЮЧЕНИЕ

Машинное обучение — это направление в науке, а с недавних пор и в технологиях, которое решает задачу обучения компьютера. Сразу хочу отметить, что не предполагается никакого полноценного обучения, которое можно было бы сравнить с обучением человека. Машинное знание, которое сформировалось в процессе обучения, не может принимать по-настоящему интеллектуальных решений, как это может сделать человек. И, несмотря на это, в последнее время потребность в машинном обучении резко выросла. Машинное обучение выходит из сферы только математиков и алгоритмистов, и все глубже проникает в мир IT-бизнесменов, а затем и в мир простых обывателей. С одной стороны, это приносит человеку огромную пользу, а с другой — может в скором времени бросить вызов каждому из нас.

Поэтому, посчитали, что эта тема достаточно актуальна в наше время. Также очень интересной, потому что, эта тема новая, но за короткий отрезок времени проникла во многие сферы жизни. Про машинное обучение говорят уже в:

1. IT-сфере: разработка приложений.
2. Рекламных компаниях.
3. Маркетинговых исследованиях.
4. Медицинской диагностике.
5. Технической диагностике.
6. Биоинформатике и во многих других сферах.

Один из первых алгоритмов машинного обучения, искусственная нейронная сеть, был изобретен в 1950-х годах. Тогда казалось, что с помощью этого алгоритма можно будет вот-вот создать «сильный» искусственный интеллект, т.е. такой, который в состоянии мыслить, осознавать себя и решать не только те задачи, на которые запрограммирован. В противовес ему есть «слабый» искусственный интеллект — он может решать некоторые



творческие задачи: распознавать образы, предсказывать погоду, играть в шахматы и т.п. Теперь, спустя 60 лет гораздо лучше понимается, что до создания настоящего искусственного интеллекта ещё долго, а то, что сегодня называют искусственным интеллектом, является машинным обучением.

Для реализации поставленной цели были решены следующие задачи:

- проанализирована литература и интернет-источники по машинному обучению, с целью систематизации и структурирования собранного материала;
- проанализирована рабочая программа;
- разработан презентационный материал и лабораторные работы по введению в машинное обучение;
- реализовано электронное учебное пособие.

Таким образом, задачи решены, цель работы — разработать электронное учебное пособие «Основы машинного обучения в области кибербезопасности» — достигнута.

## СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Алгоритмы создания дерева принятия решений [Электронный ресурс]. — Режим доступа: <http://econf.rae.ru/pdf/2014/03/3245.pdf> (дата обращения: 20.04.2018).
2. Алпайдин Э. Машинное обучение: новый искусственный интеллект [Текст]/Э. Алпайдин — Москва: Издательская группа «Точка», 2017. — 208 с.
3. Баргесян А. А. Технологии анализа данных: Data Mining, Visual Mining, Text Mining, OLAP [Текст] /А. А. Баргесян, М. С. Куприянов, В. В. Степаненко, и т. д. — 2-е изд., перераб. и доп. — Санкт-Петербург: БХВ-Петербург, 2007. — 384 с.
4. Бринк Х. Машинное обучение [Текст] / Х. Бринк, Дж. Ричардс, М. Феверолф. — пер. с англ. И. Рузмайкина — Санкт-Петербург: Питер, 2017. — 336 с.
5. Васильев В. И. Интеллектуальные системы защиты информации [Текст]: учебное пособие / В. И. Васильев — Изд. 2-е, испр. — Москва: Машиностроение, 2012. — 171 с.
6. Видеолекции курса «Машинное обучение» [Электронный ресурс]. — Режим доступа: <https://yandexdataschool.ru/edu-process/courses/machine-learning#item-1> (дата обращения: 24.04.2018).
7. Вьюгин В. В. Математические основы теории машинного обучения и прогнозирования [Текст]/В. В. Вьюгин. — Москва: Издательство Московского центра непрерывного математического образования (МЦНМО) 2013. — 305 с.
8. Генрихов И. В. Построение и исследование полных решающих деревьев для задач классификации по прецедентам [Электронный ресурс]. — Режим доступа: <http://www.ccas.ru/avtorefe/101avtor.pdf> (дата обращения: 20.04.2018).

9. Деревья решений — общие принципы работы [Электронный ресурс]. — Режим доступа: <https://basegroup.ru/community/articles/description> (дата обращения: 15.04.2018).
10. Загинайлов Ю. Н. Теория информационной безопасности и методология защиты информации. Курс лекций. [Текст] / Ю. Н. Загинайлов. — Барнаул: Алтайский государственный технический университет им. И.И. Ползунова, 2010. — 104 с.
11. Знакомство с машинным обучением [Электронный ресурс]. — Режим доступа: <https://www.google.ru/about/main/machine-learning-qa/> (дата обращения: 08.04.2018).
12. Искусство анализа данных: взгляд изнутри [Электронный ресурс]. — Режим доступа: <https://www.osp.ru/cio/2018/02/13054071/> (дата обращения: 08.04.2018).
13. Логистическая регрессия и ROC-анализ — математический аппарат [Электронный ресурс]. — Режим доступа: <https://basegroup.ru/community/articles/logistic> (дата обращения: 01.04.2018).
14. Машинное обучение — это легко [Электронный ресурс]. Режим доступа: <https://habr.com/post/319288/> (дата обращения: 08.03.2018).
15. Машинное обучение [Электронный ресурс]. — Режим доступа: [http://www.machinelearning.ru/wiki/index.php?title=Машинное\\_обучение](http://www.machinelearning.ru/wiki/index.php?title=Машинное_обучение) (дата обращения: 24.03.2018).
16. Машинное обучение для чайников [Электронный ресурс]. — Режим доступа: <https://newtonew.com/tech/machine-learning-novice> (дата обращения: 20.03.2018).
17. Машинное обучение и анализ данных [Электронный ресурс]. — Режим доступа: <http://www.uic.unn.ru/~zny/ml/> (дата обращения: 04.04.2018).
18. Машинное обучение и анализ данных [Электронный ресурс]. — Режим доступа: [https://elibrary.ru/title\\_about.asp?id=32828](https://elibrary.ru/title_about.asp?id=32828) (дата обращения: 09.03.2018).

19. Мерков А. Б. Распознавание образов. Построение и обучение вероятностных моделей [Текст]/А. Б. Мерков — Москва: Ленанд, 2014. — 240 с.
20. Методы построения деревьев решений в задачах классификации в Data Mining [Электронный ресурс]. — Режим доступа: [https://ami.nstu.ru/~vms/lecture/data\\_mining/trees.htm](https://ami.nstu.ru/~vms/lecture/data_mining/trees.htm) (дата обращения: 05.04.2018).
21. Метрики в задачах машинного обучения [Электронный ресурс]. — Режим доступа: <https://habr.com/company/ods/blog/328372/> (дата обращения: 08.04.2018).
22. Мюллер А. Введение в машинное обучение с помощью Python. Руководство для специалистов по работе с данными [Текст]/ А. Мюллер, С. Гвидо. — пер. А. Груздев. — Москва: Альфа-книга, 2017. — 480 с.
23. Нестеров С. А. Основы информационной безопасности [Электронный ресурс] — Режим доступа: <https://e.lanbook.com/book/90153> (дата обращения: 04.03.2018).
24. Основные принципы подготовки презентаций [Электронный ресурс]. — Режим доступа: [https://studme.org/50391/menedzhment/osnovnye\\_printsipy\\_podgotovki\\_prezentatsiy](https://studme.org/50391/menedzhment/osnovnye_printsipy_podgotovki_prezentatsiy) (дата обращения: 24.03.2018).
25. Простыми словами: как работает машинное обучение [Электронный ресурс]. — Режим доступа: <https://www.kaspersky.ru/blog/machine-learning-explained/13605/> (дата обращения: 24.04.2018).
26. Советы по изучению машинного обучения [Электронный ресурс]. — Режим доступа: <https://www.youtube.com/watch?v=IiDmp-O2Yok> (дата обращения: 12.04.2018).
27. Тархов Д. А. Нейросетевые модели и алгоритмы [Текст]/ Д. А. Тархов — Москва: Радиотехника, 2014. — 352 с.
28. Флах П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных [Текст]/П. Флах. — пер. с англ. А. А. Слинкина. — Москва: ДМКПресс, 2015. — 400 с.

29. Хэсти Т. The Elements of Statistical Learning: Data Mining, Inference, and Prediction [Текст] / Т. Hastie, R. Tibshirani, J. Friedman — Springer, 2003, — 552 с.

30. SVM регрессия [Электронный ресурс]. — Режим доступа: [http://www.machinelearning.ru/wiki/index.php?title=SVM\\_%D1%80%D0%B5%D0%B3%D1%80%D0%B5%D1%81%D1%81%D0%B8%D1%8F\\_%28%D0%BF%D1%80%D0%B8%D0%BC%D0%B5%D1%80%29](http://www.machinelearning.ru/wiki/index.php?title=SVM_%D1%80%D0%B5%D0%B3%D1%80%D0%B5%D1%81%D1%81%D0%B8%D1%8F_%28%D0%BF%D1%80%D0%B8%D0%BC%D0%B5%D1%80%29) (дата обращения: 08.03.2018).

# ПРИЛОЖЕНИЕ

**Министерство образования и науки Российской Федерации  
Федеральное государственное автономное образовательное учреждение  
высшего образования**

**«Российский государственный профессионально-педагогический университет»**

Институт инженерно-педагогического образования  
Кафедра информационных систем и технологий  
направление 44.03.04 Профессиональное обучение (по отраслям)  
профиль «Информатика и вычислительная техника»  
профилизация «Информационная безопасность»

УТВЕРЖДАЮ  
Заведующий кафедрой  
\_\_\_\_\_ Н. С. Толстова

«25» декабря 2017 г.

## ЗАДАНИЕ

### на выполнение выпускной квалификационной работы бакалавра

студента 4 курса, группы ИБ-401 **Аюповой Алины Наилевной**

1. Тема «Электронное учебное пособие “Основы машинного обучения в области кибербезопасности”» утверждена распоряжением по институту от 25.12.2017 г. № \_\_\_\_.
2. Руководитель **Сулова Ирина Александровна**, доцент, кандидат педагогических наук.
3. Место преддипломной практики **ФГАОУ ВО «Российский государственный профессионально-педагогический университет»**.
4. Исходные данные к ВКР:
  - Вьюгин В. В. Математические основы теории машинного обучения и прогнозирования [Текст]/В. В. Вьюгин. — Москва: Издательство Московского центра непрерывного математического образования (МЦНМО) 2013. — 305 с.;
  - Флах П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных [Текст]/П. Флах. — пер. с англ. А. А. Слинкина. — Москва: ДМКПресс, 2015. — 400 с.;
  - Алпайдин Э. Машинное обучение: новый искусственный интеллект [Текст]/Э. Алпайдин — Москва: Издательская группа «Точка», 2017. — 208 с.
5. Содержание текстовой части ВКР (перечень подлежащих разработке вопросов):
  - проанализировать литературу и интернет-источники;
  - проанализировать рабочую программу;
  - разработать презентационный материал и лабораторные работы;
  - разработать электронное учебное пособие.

