

**ГОУ ВПО Российско-Армянский (Славянский)
университет**

Утверждено
Директор Института математики и информатики
Арамян Р.Г.



«21» мая 2025, протокол №9.1

УЧЕБНО-МЕТОДИЧЕСКИЙ КОМПЛЕКС ДИСЦИПЛИНЫ

**Наименование дисциплины: Специализация по компьютерной науке 1.1
(Машинное обучение)**

Автор: Хачатуров Н.А.

Направление подготовки: 01.03.02 Прикладная математика и информатика
**Наименование образовательной программы: 01.03.02 Прикладная
математика и информатика**

1. АННОТАЦИЯ

1.1. Краткое описание содержания данной дисциплины;

Курс предназначен для бакалавров. В рамках этого курса студенты изучат рассматриваются методы эффективной тонкой настройки больших моделей, включая адаптивные подходы и их практическую реализацию. Освещаются вариации функций активации и оптимизаторов обучения, а также их влияние на производительность моделей. Отдельное внимание уделяется инструментам обучения и версионирования, необходимым для управления экспериментами и воспроизводимости результатов. Кроме того, затрагиваются ключевые этапы подготовки данных: сбор, разметка и реализация алгоритмов предварительной обработки. Завершает блок введение в обработку речи как одного из прикладных направлений современной ИИ-разработки.

1.2. Трудоемкость в академических кредитах и часах, формы итогового контроля (экзамен/зачет);

Виды учебной работы	В акад. часах
Общее количество часов	64
Лекция	32
Практика	32
Итоговый контроль	Экзамен

1.3. Взаимосвязь дисциплины с другими дисциплинами учебного плана специальности (направления)

Данная дисциплина связана с дисциплиной «Вступление в большие языковые модели»

1.4. Результаты освоения программы дисциплины:

Код компетенции	Наименование компетенции	Код индикатора достижения компетенций	Наименование индикатора достижений компетенций
ПК-7	способностью к разработке и применению алгоритмических и программных решений в области системного и прикладного	1	Знать методы и технологии разработки и применения системного и прикладного программного обеспечения

	программного обеспечения	2	Разрабатывать и применять алгоритмические и программные решения в области системного и прикладного программного обеспечения
		3	Владеть способностью разрабатывать и применять алгоритмические и программные решения в области системного и прикладного программного обеспечения
ПК-1	способностью собирать, обрабатывать и интерпретировать данные современных научных исследований, необходимые для формирования выводов по соответствующим научным исследованиям	1	Знать принципы определения актуальности и практической значимости НИР на основе обобщения, анализа
		2	Уметь работать с научными источниками, проводить анализ и критически оценивать результаты научных исследований
		3	Владеть опытом выделять сильные и слабые стороны, определять значимость научных источников

2. УЧЕБНАЯ ПРОГРАММА

2.1. Цели и задачи дисциплины

Дать студентам системное представление о современных подходах к эффективной тонкой настройке нейросетевых моделей, разнообразии функций активации и оптимизаторов,

инструментах управления обучением, а также практических аспектах сбора и разметки данных. Дополнительно — ввести в основы обработки речи как важного направления в ИИ.

Задачи:

- Ознакомить студентов с методами тонкой настройки моделей, включая адаптивные и параметрически эффективные техники (Adapters, LoRA и др.).
- Изучить различные функции активации, их свойства и области применения.
- Рассмотреть современные оптимизаторы обучения, их преимущества и ограничения.
- Научить использовать инструменты отслеживания экспериментов и версионирования моделей (например, MLflow, Weights & Biases, DVC).
- Осветить процессы сбора и аннотирования данных, а также принципы построения пайплайнов для подготовки датасетов.
- Сформировать базовые знания по обработке речевых данных и применению ASR-систем.
- Развить практические навыки реализации и настройки компонентов ИИ-систем.

2.2. Трудоемкость дисциплины и виды учебной работы (в академических часах и зачетных единицах)

Виды учебной работы	Всего, в акад. часах	Распределение по семестрам					
		7 сем	— сем	— сем	— сем.	— сем	— сем.
1	2	3	4	5	6	7	8
1. Общая трудоемкость изучения дисциплины по семестрам, в т. ч.:							
1.1. Аудиторные занятия, в т. ч.:	64	64					
1.1.1. Лекции	32	32					
1.1.2. Практические занятия, в т. ч.	32	32					
1.2. Самостоятельная работа, в т. ч.:	62	62					
Итоговый контроль (Экзамен, Зачет, диф. зачет - указать)		Экзам ен					

2.3. Содержание дисциплины

2.3.1. Тематический план и трудоемкость аудиторных занятий (модули, разделы дисциплины и виды занятий) по рабочему учебному плану

Разделы и темы дисциплины	Всего (ак. часов)	Лекции (ак. часов)	Практ. Занятия (ак. часов)	Семинары (ак. часов)	Лабор. (ак. часов)
1	2=3+4+5+6 +7	3	4	5	6
Тема 1. Линейная и логистическая регрессия	4	2	2		
Тема 2. Классификация и регрессия как задачи обучения с учителем	4	2	2		
Тема 3. Кластеризация и обучение без учителя. Понижение размерности: PCA, t-SNE, UMAP	4	2	2		
Тема 4. Понижение размерности: PCA, t-SNE, UMAP	4	2	2		
Тема 5. Полносвязные нейросети и функции активации	4	2	2		
Тема 6. Градиентный спуск, backpropagation и регуляризация	4	2	2		
Тема 7. Свёрточные нейронные сети	4	2	2		
Тема 8. Современные CNN: ResNet и DenseNet	4	2	2		
Тема 9. Генеративные состязательные сети: GAN, StyleGAN, CycleGAN	4	2	2		
Тема 10. Рекуррентные нейронные сети: RNN, LSTM, GRU	4	2	2		
Тема 11. Attention и переход к трансформерам	4	2	2		

Тема 12. Архитектура трансформеров	4	2	2		
Тема 13. Эмбединги и позиционное кодирование	4	2	2		
Тема 14. Языковые модели: BERT и GPT	4	2	2		
Тема 15. Архитектуры компьютерного зрения: YOLO, ViT	8	4	4		
ИТОГО	64	32	32		

2.3.2. Краткое содержание разделов дисциплины в виде тематического плана

Тема 1. Линейная и логистическая регрессия

Рассматриваются основные принципы линейной и логистической регрессии как базовых алгоритмов машинного обучения. Объясняется постановка задачи, модель, функция потерь и способы оценки качества предсказаний.

Тема 2. Классификация и регрессия как задачи обучения с учителем

Изучаются задачи предсказания непрерывных и категориальных переменных.

Рассматриваются принципы разбиения выборки, метрики качества, проблемы переобучения и обобщающей способности моделей.

Тема 3. Кластеризация и обучение без учителя

Рассматриваются методы поиска скрытых структур в данных без использования меток.

Изучаются алгоритмы кластеризации, включая k-means и DBSCAN, а также способы оценки качества кластеров.

Тема 4. Понижение размерности: PCA, t-SNE, UMAP

Изучаются методы уменьшения размерности для визуализации и ускорения обучения моделей. Объясняются принципы работы PCA, t-SNE и UMAP, а также особенности их применения к различным типам данных.

Тема 5. Полносвязные нейросети и функции активации

Рассматривается архитектура полносвязных нейронных сетей, принципы их построения и роль нелинейных функций активации. Изучаются ReLU, Sigmoid, Tanh и их влияние на обучение.

Тема 6. Градиентный спуск, backpropagation и регуляризация

Объясняются методы оптимизации нейронных сетей: градиентный спуск и обратное распространение ошибки. Изучаются техники регуляризации, включая L2 и L1 для предотвращения переобучения.

Тема 7. Свёрточные нейронные сети

Изучается архитектура сверточных сетей, используемых для обработки изображений. Рассматриваются свёртки, pooling-операции, глубина фильтров и параметры, влияющие на извлечение признаков.

Тема 8. Современные CNN: ResNet и DenseNet

Рассматриваются современные архитектуры свёрточных сетей. Изучаются остаточные связи в ResNet и плотные связи в DenseNet. Анализируются преимущества каждой модели.

Тема 9. Генеративные состязательные сети: GAN, StyleGAN, CycleGAN

Изучаются архитектура и принципы генеративных состязательных сетей. Объясняется работа генератора и дискриминатора. Рассматриваются применения и отличия моделей StyleGAN и CycleGAN.

Тема 10. Рекуррентные нейронные сети: RNN, LSTM, GRU

Рассматриваются архитектуры для работы с последовательными данными. Изучаются принципы работы RNN, их недостатки и способы их преодоления с помощью LSTM и GRU.

Тема 11. Attention и переход к трансформерам

Изучается механизм внимания как альтернатива рекуррентным структурам. Объясняется идея взвешивания значимости входных элементов и подготовка к архитектуре трансформеров.

Тема 12. Архитектура трансформеров

Рассматриваются ключевые компоненты трансформеров: self-attention, нормализация, позиционное кодирование и слоистая структура encoder–decoder. Объясняется масштабируемость и эффективность модели.

Тема 13. Эмбединги и позиционное кодирование

Изучаются методы представления слов и других объектов в виде плотных векторов.

Рассматриваются word2vec, контекстные эмбединги, позиционное кодирование и их роль в понимании структуры входных данных.

Тема 14. Языковые модели: BERT и GPT

Рассматриваются архитектуры языковых моделей BERT и GPT. Изучаются отличия autoencoding и autoregressive подходов, а также задачи, на которых обучаются эти модели и области их применения.

Тема 15. Архитектуры компьютерного зрения: YOLO, ViT

Изучаются современные архитектуры в задачах компьютерного зрения. Объясняются основные принципы детекции объектов в YOLO и использование трансформеров в Vision Transformer (ViT).

2.3.3. Краткое содержание семинарских/практических занятий/лабораторного практикума

Семинарские занятия проводятся в практико-ориентированной форме. Студентам предоставляется набор задач, соответствующих тематике занятия. Часть задач решается непосредственно в аудитории под руководством преподавателя, с пошаговым разбором решений и обсуждением используемых подходов. Оставшиеся задачи выдаются студентам в качестве домашнего задания для самостоятельного выполнения.

2.3.4. Материально-техническое обеспечение дисциплины

Необходим компьютер с проектором.

2.4. Модульная структура дисциплины с распределением весов по формам контролей

Формы контролей	Вес формы (форм) текущего контроля в результирующей оценке текущего контроля (по модулям)		Вес формы промежуточного контроля в итоговой оценке промежуточного контроля		Вес итоговой оценки промежуточного контроля в результирующей оценке промежуточных контролей		Вес итоговой оценки промежуточного контроля в результирующей оценке промежуточных контролей (семестровой оценке)		Веса результирующей оценки промежуточных контролей и оценки итогового контроля в результирующей оценке итогового контроля	
	M1 ¹	M2	M1	M2	M1	M2				
Вид учебной работы/контроля										
Контрольная работа <i>(при наличии)</i>										
Устный опрос <i>(при наличии)</i>										
Тест <i>(при наличии)</i>										
Лабораторные работы <i>(при наличии)</i>										
Письменные домашние задания <i>(при наличии)</i>										
Реферат <i>(при наличии)</i>										
Эссе <i>(при наличии)</i>										
Проект <i>(при наличии)</i>										
Другие формы <i>(при наличии)</i>										

¹ Учебный Модуль

Веса результирующих оценок текущих контролей в итоговых оценках промежуточных контролей						0.4		
Веса оценок промежуточных контролей в итоговых оценках промежуточных контролей						0.6		
Вес итоговой оценки 1-го промежуточного контроля в результирующей оценке промежуточных контролей								
Вес итоговой оценки 2-го промежуточного контроля в результирующей оценке промежуточных контролей								
Вес результирующей оценки промежуточных контролей в результирующей оценке итогового контроля								0.4
Вес итогового контроля (Экзамен/зачет) в результирующей оценке итогового контроля								0.6
	$\Sigma = 1$	$\Sigma = 1$	$\Sigma = 1$	$\Sigma = 1$	$\Sigma = 1$	$\Sigma = 1$	$\Sigma = 1$	$\Sigma = 1$

3. Теоретический блок

3.1. Материалы по теоретической части курса

3.2.1. Coursera – Machine Learning by Andrew Ng

3.2.2. Google's Machine Learning Crash Course

3.2.3. Книга «Введение в машинное обучение с помощью Python» — Андреас Мюллер, Сара Гвидо

4. Фонды оценочных средств.

Во время итоговой проверки знаний студенту будет предложена **практическая задача по машинному обучению**, направленная на оценку способности применять теоретические знания на практике, понимать этапы построения ML-моделей и обосновывать сделанные решения.

Как проходит оценка:

1. Выдача задачи

Студент получает задание, связанное с обучением и оценкой модели на реальном датасете. Ожидается, что студент самостоятельно выполнит полный ML-пайплайн: от предобработки данных до анализа результатов.

2. Пример задачи

*"Используя датасет **Kannada-MNIST**, обучите модель для распознавания рукописных цифр. Вы можете использовать фреймворки `scikit-learn` или `PyTorch` по выбору. Опишите этапы предобработки данных, выберите и обоснуйте модель (например, простая CNN), обучите её и оцените качество (accuracy, confusion matrix). При необходимости визуализируйте результаты и ошибки классификации."*

3. Проверка корректности решения

Представленное решение будет оцениваться по следующим критериям:

- правильность и полнота выполнения всех этапов пайплайна (предобработка, обучение, оценка);
- адекватность выбранных методов и обоснование решений;
- читаемость и структурированность кода;
- качество итоговой модели.

4. Устные вопросы по решению

После сдачи задачи студенту будет задано **несколько вопросов**, направленных на проверку глубины понимания:

- Почему вы выбрали именно такую модель? Какие альтернативы рассматривали?
- Как работает слой свёртки и что делает функция активации ReLU?
- Как влияет увеличение числа эпох/слоёв на модель? Что такое overfitting и как с ним бороться?
- Почему вы использовали именно такой learning rate? А что будет, если его уменьшить?

Такой формат оценки позволяет не только проверить знание инструментов и методов машинного обучения, но и убедиться в том, что студент понимает **причинно-следственные связи** в построении моделей и способен применять знания на практике.

5. Методический блок

Преподавание данной учебной дисциплины строится на сочетании лекционных занятий, практических семинаров и различных форм самостоятельной работы студентов.

На лекциях рассматриваются ключевые темы курса, охватывающие как базовые алгоритмы, так и современные подходы в машинном обучении и глубоком обучении. Особое внимание уделяется интуитивному пониманию методов, математическим основам, а также практическим сценариям применения. Сложные темы, такие как нейросетевые архитектуры, трансформеры или генеративные модели, подаются с акцентом на связь теории с реальными задачами.

На практических занятиях особый упор делается на:

- закрепление теоретических знаний через программную реализацию моделей;

- работу с библиотеками `scikit-learn`, `pandas`, `numpy`, `PyTorch`;
- интерпретацию результатов моделей и визуализацию;
- освоение пайплайна машинного обучения: от предобработки до оценки качества.

При проведении практических и семинарских занятий отдельное внимание уделяется:

- развитию навыков анализа и постановки ML-задач;
- умению выбирать подходящие модели и техники под конкретные данные;
- формированию навыков чтения научных статей и документации к фреймворкам.

Рабочей программой дисциплины предусмотрена самостоятельная работа студентов, направленная на закрепление и углубление знаний. Она включает:

- изучение и повторение лекционного материала;
- выполнение домашних заданий по следующим темам:
- выполнение мини-проектов и кейс-заданий;
- участие в командных и индивидуальных хакатонах;
- исследование современных публикаций и реализация state-of-the-art подходов;
- подготовку к тестированию, зачётам и итоговой проектной работе.

Такой формат преподавания формирует у студентов как прочные фундаментальные знания, так и прикладные навыки, необходимые для успешной работы в сфере машинного обучения и искусственного интеллекта.