

Документ подписан простой электронной подписью
Информация о владельце:
ФИО: Суворов Антон Дмитриевич
Должность: Ректор
Дата подписания: 31.08.2026 16:35:32
Уникальный идентификатор:
a39bdb15d680d3b0adbfc0a15c1efb14747dc0

Сколковский институт науки и технологий (Сколтех)

Рабочая программа дисциплины	Генеративные модели в искусственном интеллекте
Преподаватель	Коротин Александр

Аннотация

Описание курса

В курсе «Фундаментальные основы генеративного ИИ» рассказывается про одну из самых перспективных областей глубокого обучения - нейросетевое генеративное моделирование. За последнее десятилетие прогресс в этой области происходит крайне быстрыми темпами. Большие генеративные нейросети общего назначения (Kandinsky, DALL-E, MidJourney и пр.) уже активно используются на практике для генерации цифрового контента. Вместе с тем возрастает и потребность обучения генеративных моделей узкого назначения для решения конкретных прикладных задач в компьютерном зрении, медицине, геологии и других отраслях.

В рамках курса будут освещены основные современные подходы к построению генеративных моделей. Будут рассмотрены функции потерь, используемые для обучения генеративных моделей: дивергенция Кульбака-Лейблера, Фишера, Дженсена-Шеннона, метрика оптимального транспорта Монжа-Канторовича-Вассерштейна, и непосредственно способы их оптимизации, включая подходы на основе вариационных оценок (evidence lower bound), сопоставления скоров (score matching), состязательного обучения (adversarial learning) и др. В программе будут рассмотрены все основные парадигмы, используемые для построения генеративных моделей: генеративные состязательные нейросети (GANs), вариационные автокодировщики (VAE), диффузионные модели (DDPM) и пр.

1. Основная информация

Академический уровень курса	Магистратура Аспирантура
Количество кредитов	3

Предварительные требования к курсу / рекомендации

Студенты должны быть знакомы с основами математики (курсы по математическому анализу, линейной алгебре, теории вероятностей), программированием (на Python) и основами науки о данных (алгоритмы, статистика, машинное обучение, нейронные сети).

Тип оценки - дифференцированная

Отображение оценок в процентах

A:	86
B:	76
C:	66
D:	56
E:	46
F:	0

2. Содержание курса

Тема	Краткое содержание	Лекции (час)	Семинары (час)	Лабораторные занятия (час)	Самостоятельная работа (час)
Модели гауссовой смеси	Идеи явного и неявного моделирования распределения данных. Задачи выборки и оценки плотности. Кульбак-Дивергенция Лейблера (KL) и ее основные свойства. Принцип минимизации Расхождения KL и эквивалентность максимизации вероятности получения данных. Гауссова смешанная модель (GMM). Обучение GMM на основе градиента и связанные с ним проблемы. Нижняя граница доказательности (ELBO). Идея подхода со скрытыми переменными. Алгоритм максимизации математического ожидания (EM) для GMM.	2	2		5
Модели, основанные на использовании энергии	Модели, основанные на энергии Принцип моделирования распределения с использованием функции энергии. Методы выборки по ненормированной плотности (выборка по важности, выборка по отбраковке, динамика Ланжевена и т.д.). Градиент функционала дивергенции KL в случае моделирования энергетической функции (energy-based models, EBM), алгоритм обучения и выборки из EBM.	2	2		4
Нормализующие потоки	Моделирование распределений с использованием обратимых преобразований с помощью быстро вычисляемого Якобианца. Изменение переменных при применении преобразования для функции плотности вероятности. Нормализующие потоки, особенности их архитектуры (включая уровень аффинной связи)	2	2		4

	и принцип обучения модели. Расширения: непрерывные Нормализующие потоки, обучающий алгоритм. Ограничения нормализующих потоков.				
Вариационные автоэнкодеры	Ограничения моделей ЕВМ и нормализующего потока. Сложность обучения моделей с общими скрытыми переменными. Нижняя граница доказательности (ELBO). Трюк с параметризацией как возможность оптимизации ELBO. Вариационные автоэнкодеры (VAE). Расширения VAE: Иерархические VAE, VQ-VAE и т.д.	2	2		4
Ваниль Порождающие Противоборствующие сети	Вариационная оценка JS в задаче оптимизации дивергенции. Идея состязательного обучения. Ваниль Генерирующие состязательные сети (vanilla GAN). Ключевые компоненты состязательного обучения: оптимизаторы, архитектуры, регуляризации и т.д. Ненасыщающая функция потерь, архитектура StyleGAN. Переход от vanilla GAN к общему f-GAN через двойственную форму f-дивергенций. Условные GAN.	2	2		4
GANs для домена перевода проблем	Проблема перевода предметной области и ее ключевые формулировки. Парный (контролируемый) перевод предметной области и ограничения его простых решений (регрессия l2 и т.д.). Условные GAN для парных задач, определение потерь. Мотивация и объяснение снижения уровня шума в генераторе. Регуляризация с контролируемыми потерями. Непарный (неконтролируемый) перевод предметной области и его неоднозначности. Модель CycleGAN и объяснение ее потерь (состязательные термины, циклические термины, регуляризация дополнительного контента). Возможность одностороннего непарного обучения без потерь в циклах.	2	2		4
Вассерштейн порождающий состязательные сети	Задачи о метриках типа f-дивергенции. Оптимальная транспортная метрика Монжа-Канторовича и идея ее оптимизации. Двойственная форма для расстояния Вассерштейна-1. Алгоритм Вассерштейна ГАНА и его вариации (коррекция градиента, ограничение веса). Разрывы	2	2		4

	между теорией и практикой в моделях, подобных WGAN.				
Модели, основанные на оценке	Проблемы EBM. Идея сопоставления оценок (градиент логарифма плотности) распределений (сопоставление оценок) вместо самой плотности. Дивергенция Фишера как альтернатива Дивергенции KL и ее свойствам. Ключевые подходы к сопоставлению оценок (базовые модели, модели с уменьшенным уровнем шума, модели, основанные на распределенных оценках). Сети оценки с учетом уровня шума (NCSN).	2	2		4
Диффузия модели	Ограничения VAE. Обучение иерархическое VAE с ELBO и его несвободный от моделирования характер. Идея использования кодировщика как предопределенного стохастического процесса. Отказ от использования диффузионных вероятностных моделей (DDPM). Перспективный Марковский процесс в DDPM и его свойство не допускать моделирования. Представление потерь в DDPM, параметризация и другие аспекты обучения. Устранение шума в диффузионных неявных моделях (DDIM) и ускорение вывода.	2	2		4
Модели согласования потоков	Идея изучения векторных полей для выполнения переноса массы между вероятностными распределениями. Моделирование несвободного характера непрерывных нормализующих потоков. Идея построения интерполирующих кривых между распределениями и моделирования их как векторных полей. Потери при согласовании потоков (FM), их свойство не поддаваться моделированию. Оптимизация FM, зависимость от плана транспортировки. Выравнивание потоков с помощью minibatch optimal transport. Итеративная процедура согласования потоков (выпрямленные потоки) для выравнивания потоков, ее свойства и ограничения.	2	2		4

3. Результаты обучения

Результаты обучения в Сколтехе указаны в соответствии со структурой результатов обучения в Сколтехе

1. ФУНДАМЕНТАЛЬНЫЕ ЗНАНИЯ

- 1.1. Знание математики и естественных наук
- 1.2. Знание прикладных и инженерных наук, включая современные методы и инструменты

4. Задания и выставление оценок

Требование к физической посещаемости (% от числа занятий)	65
--	----

Тип назначения	Краткое содержание задания	% от итоговой оценки за курс
Домашние задания	Практическая часть (программирование в pytorch) домашнее задание, состоящее из нескольких задач, относящихся к первой части курса. Пример задачи: Реализация и обучение генеративной модели, основанной на вариационном автоэнкодере (VAE). Тестирование на низкоразмерных синтетических данных и реальных изображениях.	35
Домашние задания	Практические (кодирование в pytorch) домашнее задание состоящий из нескольких проблем связанные со второй частью конечно. Пример проблемы: Реализация условной диффузионная модель (DDPM) для образ супер-постановление CelebA лица.	35
Итоговый экзамен	Устный итоговый экзамен. Студентам будут даны 2 вопроса (из списка всех экзаменационных вопросов) о генеративных моделях и 15 минут на подготовку ответов на них. Студентам разрешается взять с собой 1 Лист формата А4 с любыми заметками на обеих сторонах и используйте его во время экзамена.	30

5. Критерии оценки

<u>Задание 1 Типа</u>	Домашние задания
-----------------------	------------------

Пример задания 1

Будет 2 домашних задания. Домашние задания в основном практические и состоят из нескольких задач, связанных с реализацией определенных генеративных моделей.

Пример задачи:

Реализация и обучение генеративной модели, основанной на вариационном автоэнкодере (VAE). Тестирование на низкоразмерных синтетических данных и реальных данных изображений MNIST.

Критерии оценки задания 1

Чтобы получить максимальную оценку за выполнение задания, представленные ответы должны работать без ошибок, быть воспроизводимыми и хорошо объясненными. Результаты обучения модели должны быть хорошо визуализированы, качественно и количественно оценены и обсуждены. В целом, каждая задача в задании будет разделена на множество подзадач (связанных с конкретными пунктами выше), поэтому учащиеся смогут получить неполные оценки, если не все подзадачи будут успешно выполнены.

<u>Задание 2 Типа</u>	Итоговый экзамен
------------------------------	------------------

Пример задания 2

Устный итоговый экзамен. Студентам будет предложено 2 вопроса (из списка всех экзаменационных вопросов) о генеративных моделях и 15 минут на подготовку ответов на них. Студентам разрешается взять с собой 1 лист формата A4 с любыми заметками на обеих сторонах и использовать его во время экзамена.

Основные критерии оценки:

Каждый вопрос будет оцениваться отдельно, и общая оценка за экзамен будет равна среднему баллу за каждый из вопросов.

6. Учебники и интернет-ресурсы

Необходимые учебники	ISBN-13 (or ISBN-10)
Tomczak, J. M. (2024). Deep generative modeling for neural compression. In Deep generative modeling (pp. 259-275). Cham: Springer International Publishing.	
Дополнительная литература	
Lipman, Y., Chen, R. T., Ben-Hamu, H., Nickel, M., & Le, M. Flow Matching for Generative Modeling. In The Eleventh International Conference on Learning Representations.	
Kingma, D. P., & Welling, M. Autoencoding variational {Bayes}. In Int. Conf. on Learning Representations.	
Isola, P., Zhu, J. Y., Zhou, T., & Efros, A. A. (2017). Image-to-image translation with conditional adversarial networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1125-1134).	
Rezende, D., & Mohamed, S. (2015, June). Variational	

inference with normalizing flows. In International conference on machine learning (pp. 1530-1538). PMLR.	
Song, Y., & Kingma, D. P. (2021). How to train your energy-based models. arXiv preprint arXiv:2101.03288.	
Song, Y., & Ermon, S. (2019). Generative modeling by estimating gradients of the data distribution. Advances in neural information processing systems, 32.	
Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial nets. Advances in neural information processing systems, 27.	
Arjovsky, M., Chintala, S., & Bottou, L. (2017, July). Wasserstein generative adversarial networks. In International conference on machine learning (pp. 214-223). PMLR.	
Zhu, J. Y., Park, T., Isola, P., & Efros, A. A. (2017). Unpaired image-to-image translation using cycle-consistent adversarial networks. In Proceedings of the IEEE international conference on computer vision (pp. 2223-2232).	

7. Оборудование

Программное обеспечение
Google Colab, GPU

Оборудование
Ноутбук со стабильным подключением к Интернету