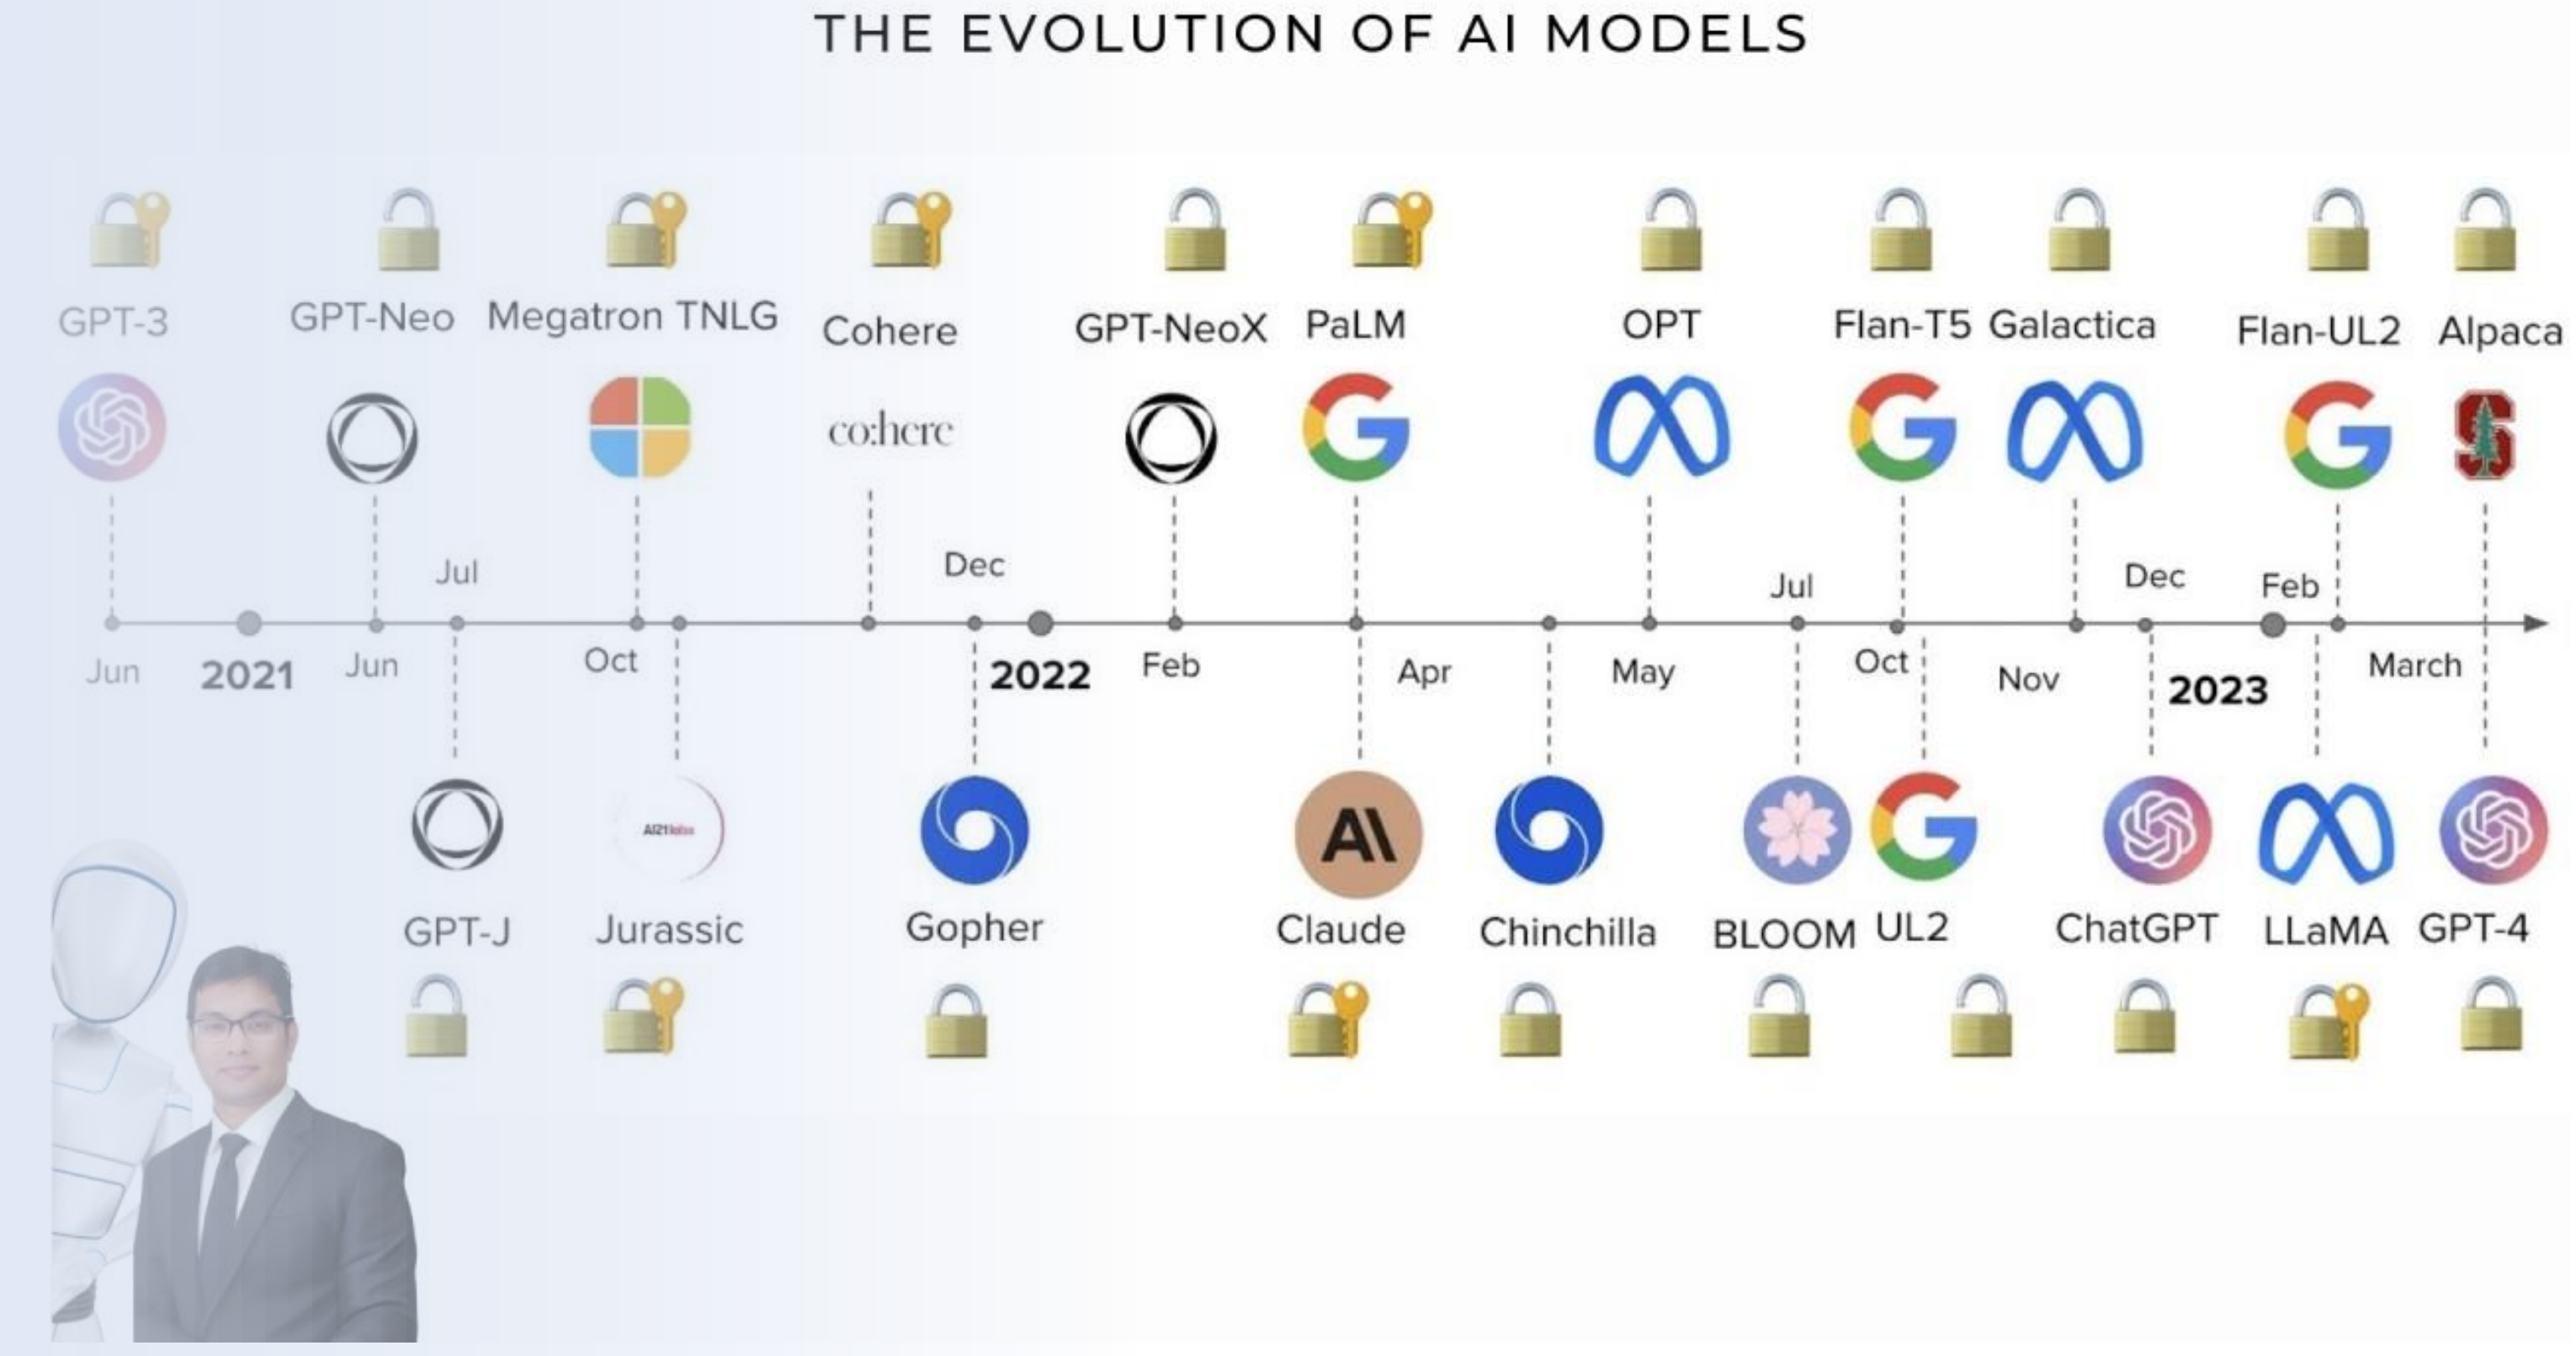


«Перспективы использования искусственного интеллекта в градостроительной деятельности»
Международная научная конференция
XV Академические чтения, посвященные памяти академика РААСН Г.Л.Осипова
 Москва, НИИСФ РААСН 2-3 июля 2024

Эволюция идей искусственного интеллекта: история развития и связь с практикой

Воронцов Константин Вячеславович
 д.ф.-м.н., профессор РАН,
 рук. лаб. машинного обучения и семантического анализа Института ИИ МГУ,
 зав. кафедрой математических методов прогнозирования ВМК МГУ,
 зав. кафедрой интеллектуальных систем МФТИ,
voron@mlsa-iai.ru



Information collected and poster designed by Danielle Williams, PhD | Washington University in St. Louis
daniellejwilliams.com

Методология эмпирической индукции

От дедуктивного метода познания к индуктивному:

«Не следует полагаться на сформулированные аксиомы и формальные базовые понятия, какими бы привлекательными и справедливыми они не казались. Законы природы нужно «расшифровывать» из фактов опыта. Следует искать правильный метод анализа и обобщения опытных данных; здесь логика Аристотеля не подходит в силу её абстрактности, оторванности от реальных процессов и явлений.»


«Таблица открытия»: множество объектов $\{x_1, \dots, x_m\}$:

- $f_j(x_i)$ – измеряемое значение j -го признака объекта x_i
- y_i – измеряемое значение целевого свойства x_i , либо $y_i \in \{0,1\}$ – отсутствие или наличие целевого свойства

Фрэнсис Бэкон. Новый органон. 1620.



Фрэнсис Бэкон (1561--1626)




Задача проведения функции через точки

Предсказание свойства $y(x)$ по признакам $f_j(x)$, (линейной) моделью $a(x, w)$ с параметрами w :

$$a(x, w) = \sum_j w_j f_j(x)$$

Метод наименьших квадратов (Гаусс, 1795):

$$\sum_{(x,y)} (a(x, w) - y)^2 \rightarrow \min_w$$



Карл Фридрих Гаусс (1777--1855)

«Our principle, which we have made use of since 1795, has lately been published by Legendre...»


C.F.Gauss. Theory of the motion of the heavenly bodies moving about the Sun in conic sections. 1809.

Задача восстановления регрессии

Исследование наследственности роста (Гальтон, 1886).

Δ — отклонение роста от среднего в популяции


Зависимость (линейная?) Δ взрослого сына от Δ отца:



Galton F. Regression towards mediocrity in hereditary stature. 1886.

Двойной смысл термина «регрессия»:

- регрессия (роста) к среднему в популяции
- необычный «обратный» ход исследования: сначала данные, потом модель



Фрэнсис Гальтон (1822--1911)

Задачи машинного обучения с учителем

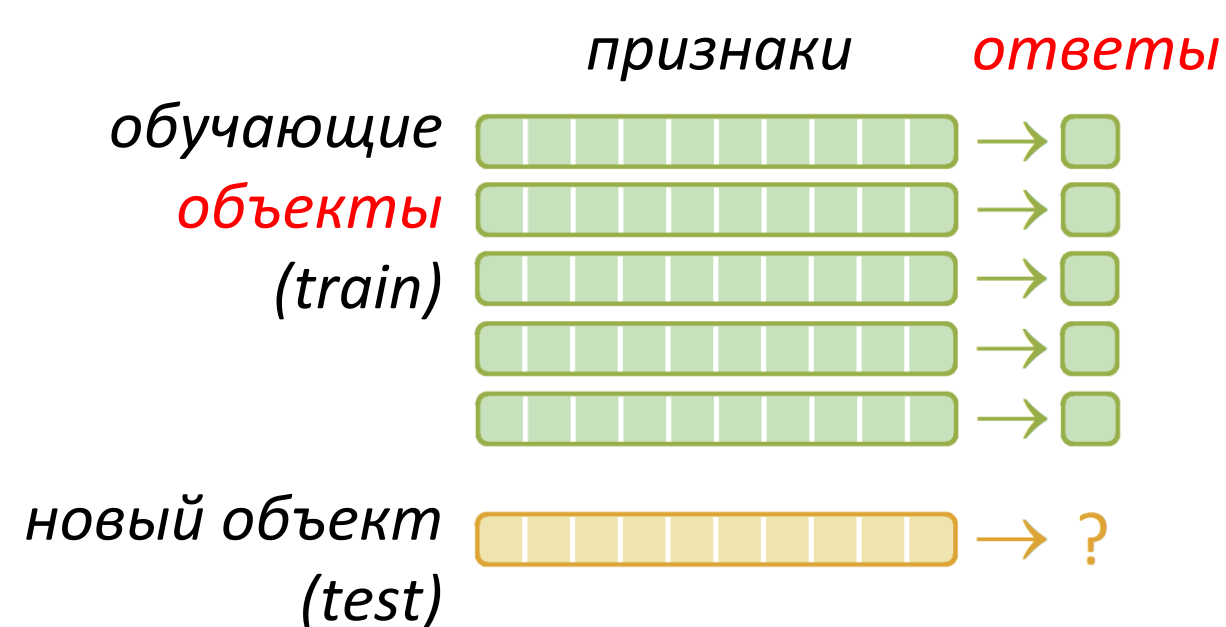
Этап №1 – обучение с учителем

- **На входе:**
данные – выборка прецедентов «**объект** → **ответ**»,
каждый объект описывается набором признаков
- **На выходе:**
модель, предсказывающая ответ по объекту

Если нет данных,
то нет
и машинного
обучения


Этап №2 – применение

- **На входе:**
данные – новый **объект**
- **На выходе:**
предсказание **ответа** на новом объекте



Примеры задач машинного обучения

- **Медицинская диагностика:**
объект – данные о пациенте на текущий момент
ответ – диагноз / лечение / риск исхода
- **Поиск месторождений полезных ископаемых:**
объект – данные о геологии района
ответ – есть/нет месторождение
- **Управление технологическими процессами:**
объект – данные о сырье и управляющих параметрах
ответ – количество/качество полезного продукта



Примеры задач ML в бизнесе


- **Кредитный скоринг:**
объект – данные о заёмщике
ответ – решение по кредиту & вероятность дефолта
- **Предсказание оттока клиентов:**
объект – данные о клиенте на момент времени t
ответ – уйдёт ли клиент к моменту времени $t + \Delta$
- **Прогнозирование объёмов продаж:**
объект – данные о продажах на момент времени t
ответ – объём спроса в интервале от t до $t + \Delta$



Задачи ML с данными сложной структуры

Вход: сложно структурированные «сырые» данные объектов

Выход: векторные признаковые представления объектов, затем ответы



Deep Learning – это всего лишь обучаемая векторизация сложных объектов

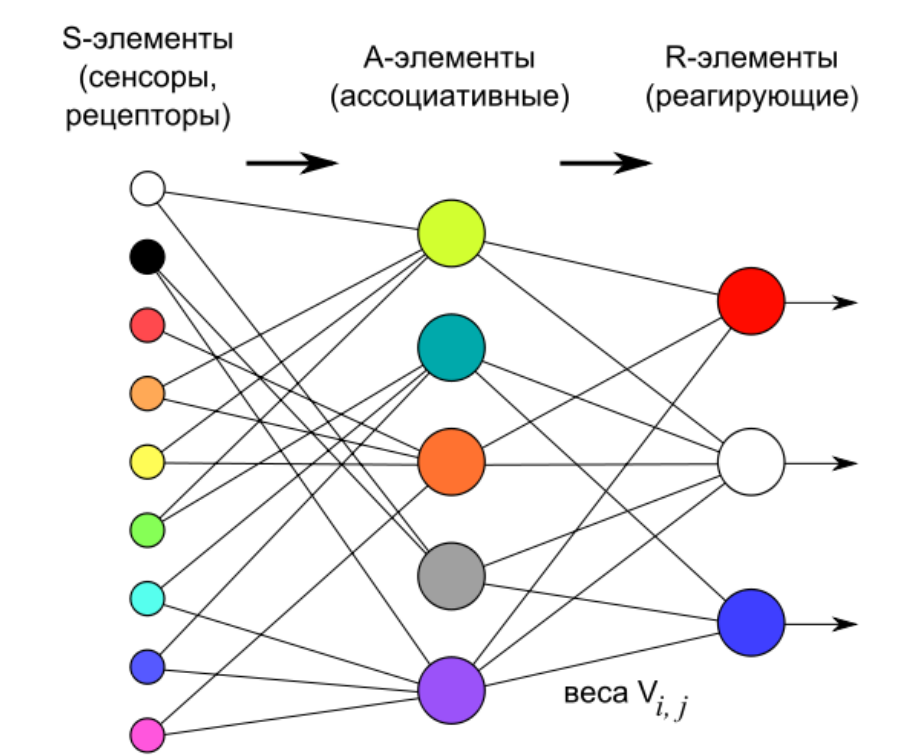
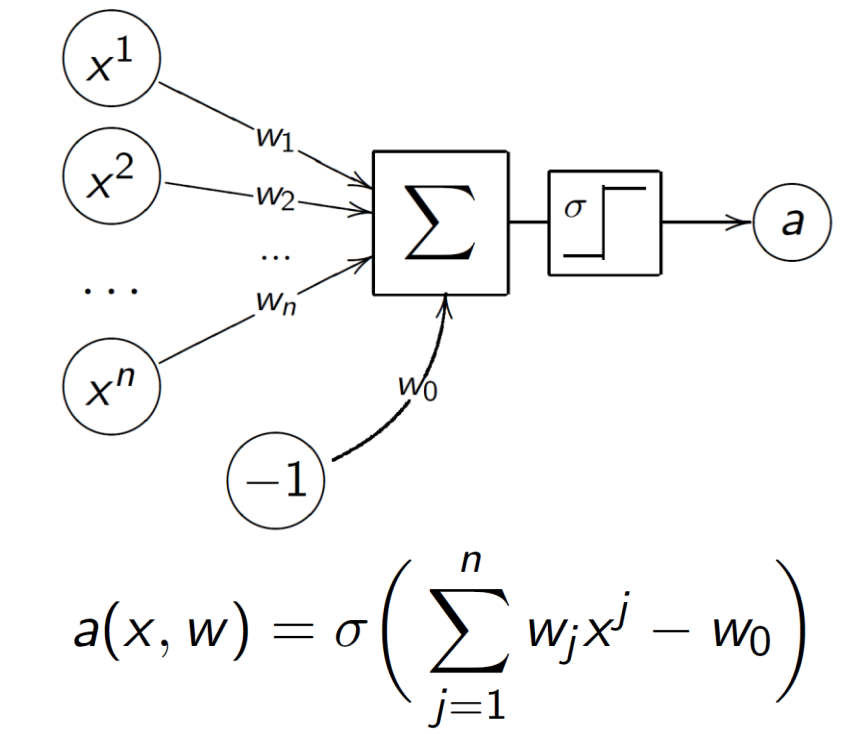


Примеры сложно структурированных объектов: изображения, видео, временные ряды, тексты, транзакции, графы, ...

Искусственные нейронные сети

Математическая модель нейрона (МакКаллок и Питтс, 1943)



Первый нейрокомпьютер Mark-1 (Фрэнк Розенблатт, 1960)

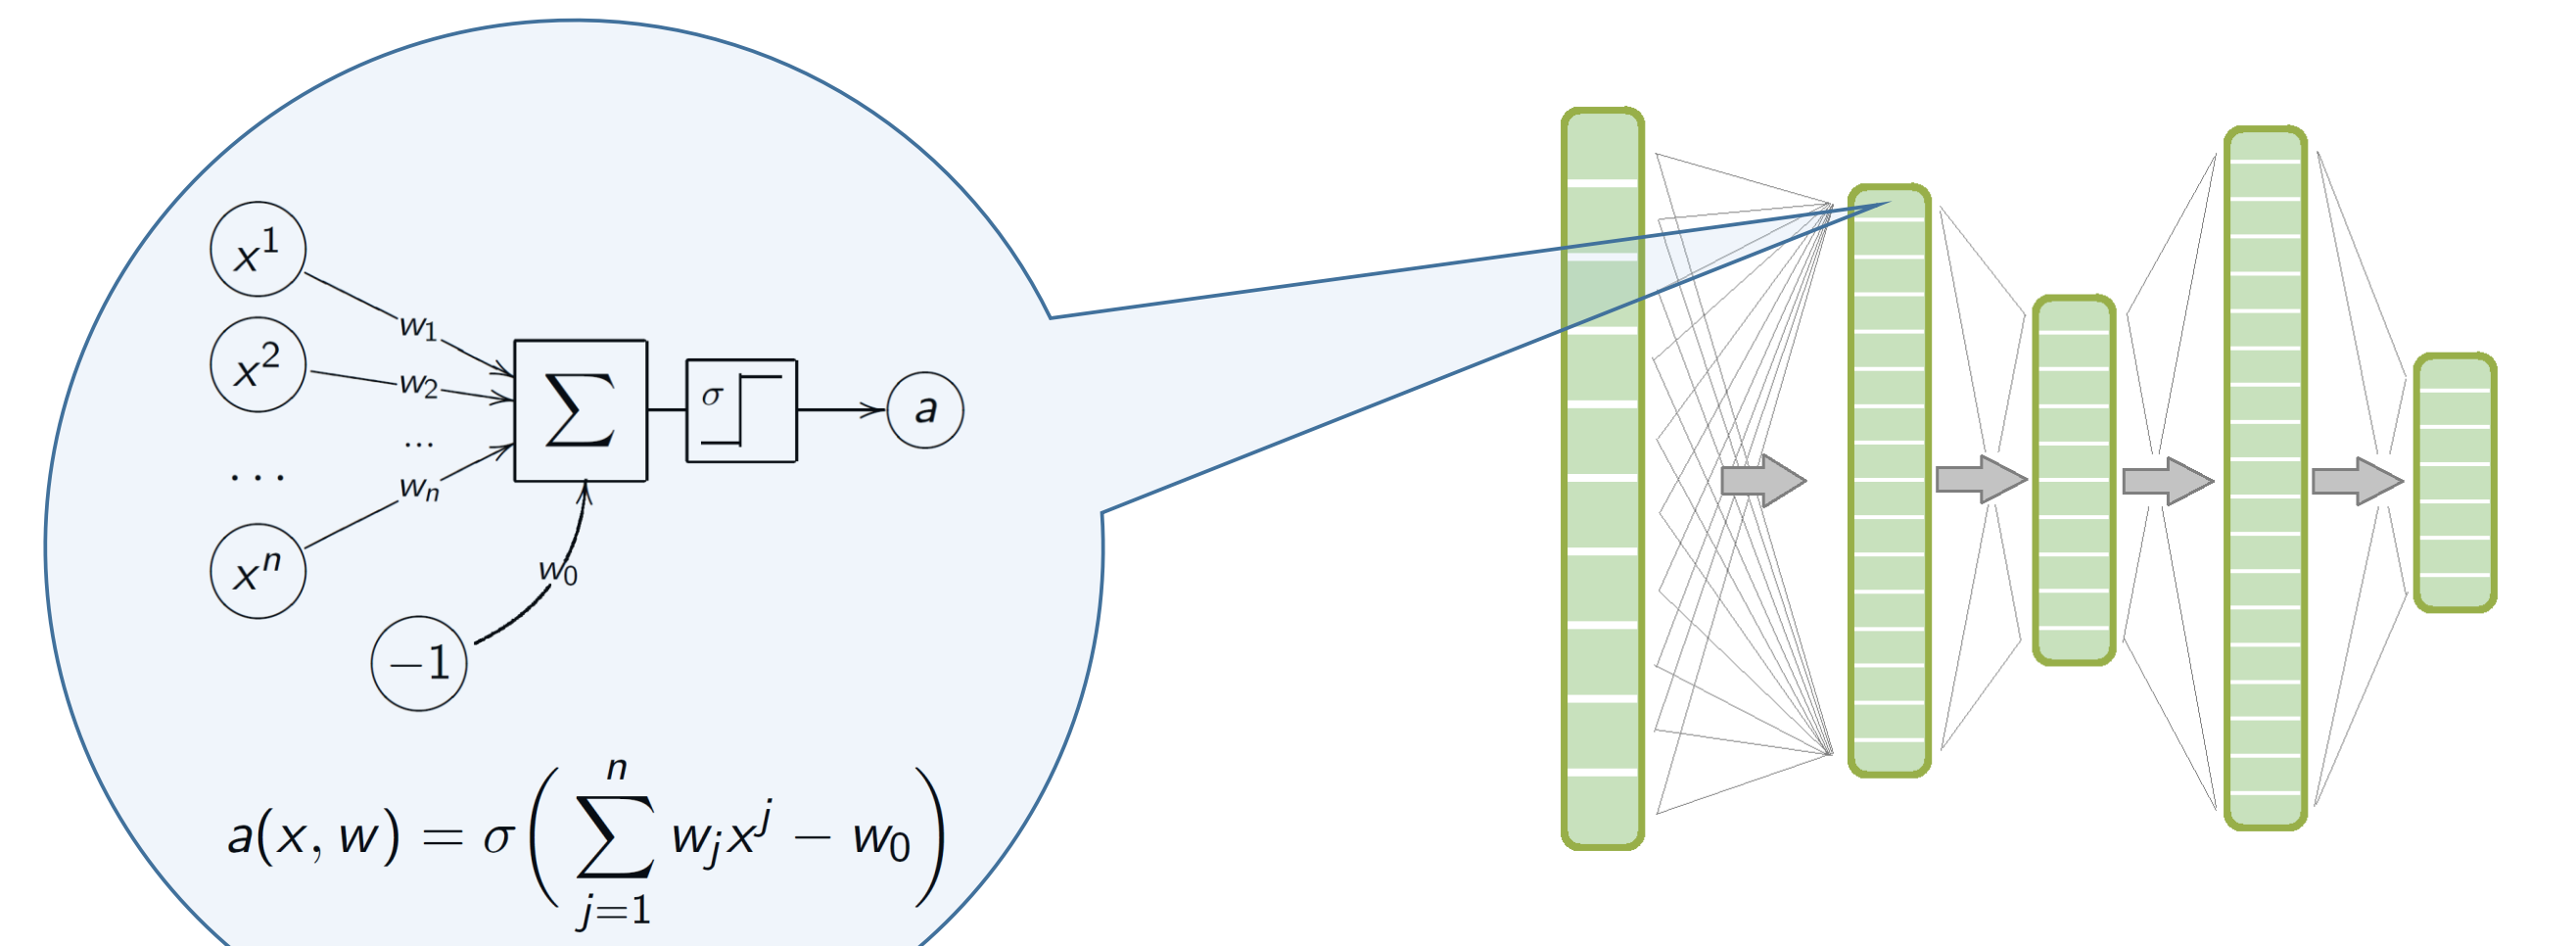


Многослойные нейронные сети

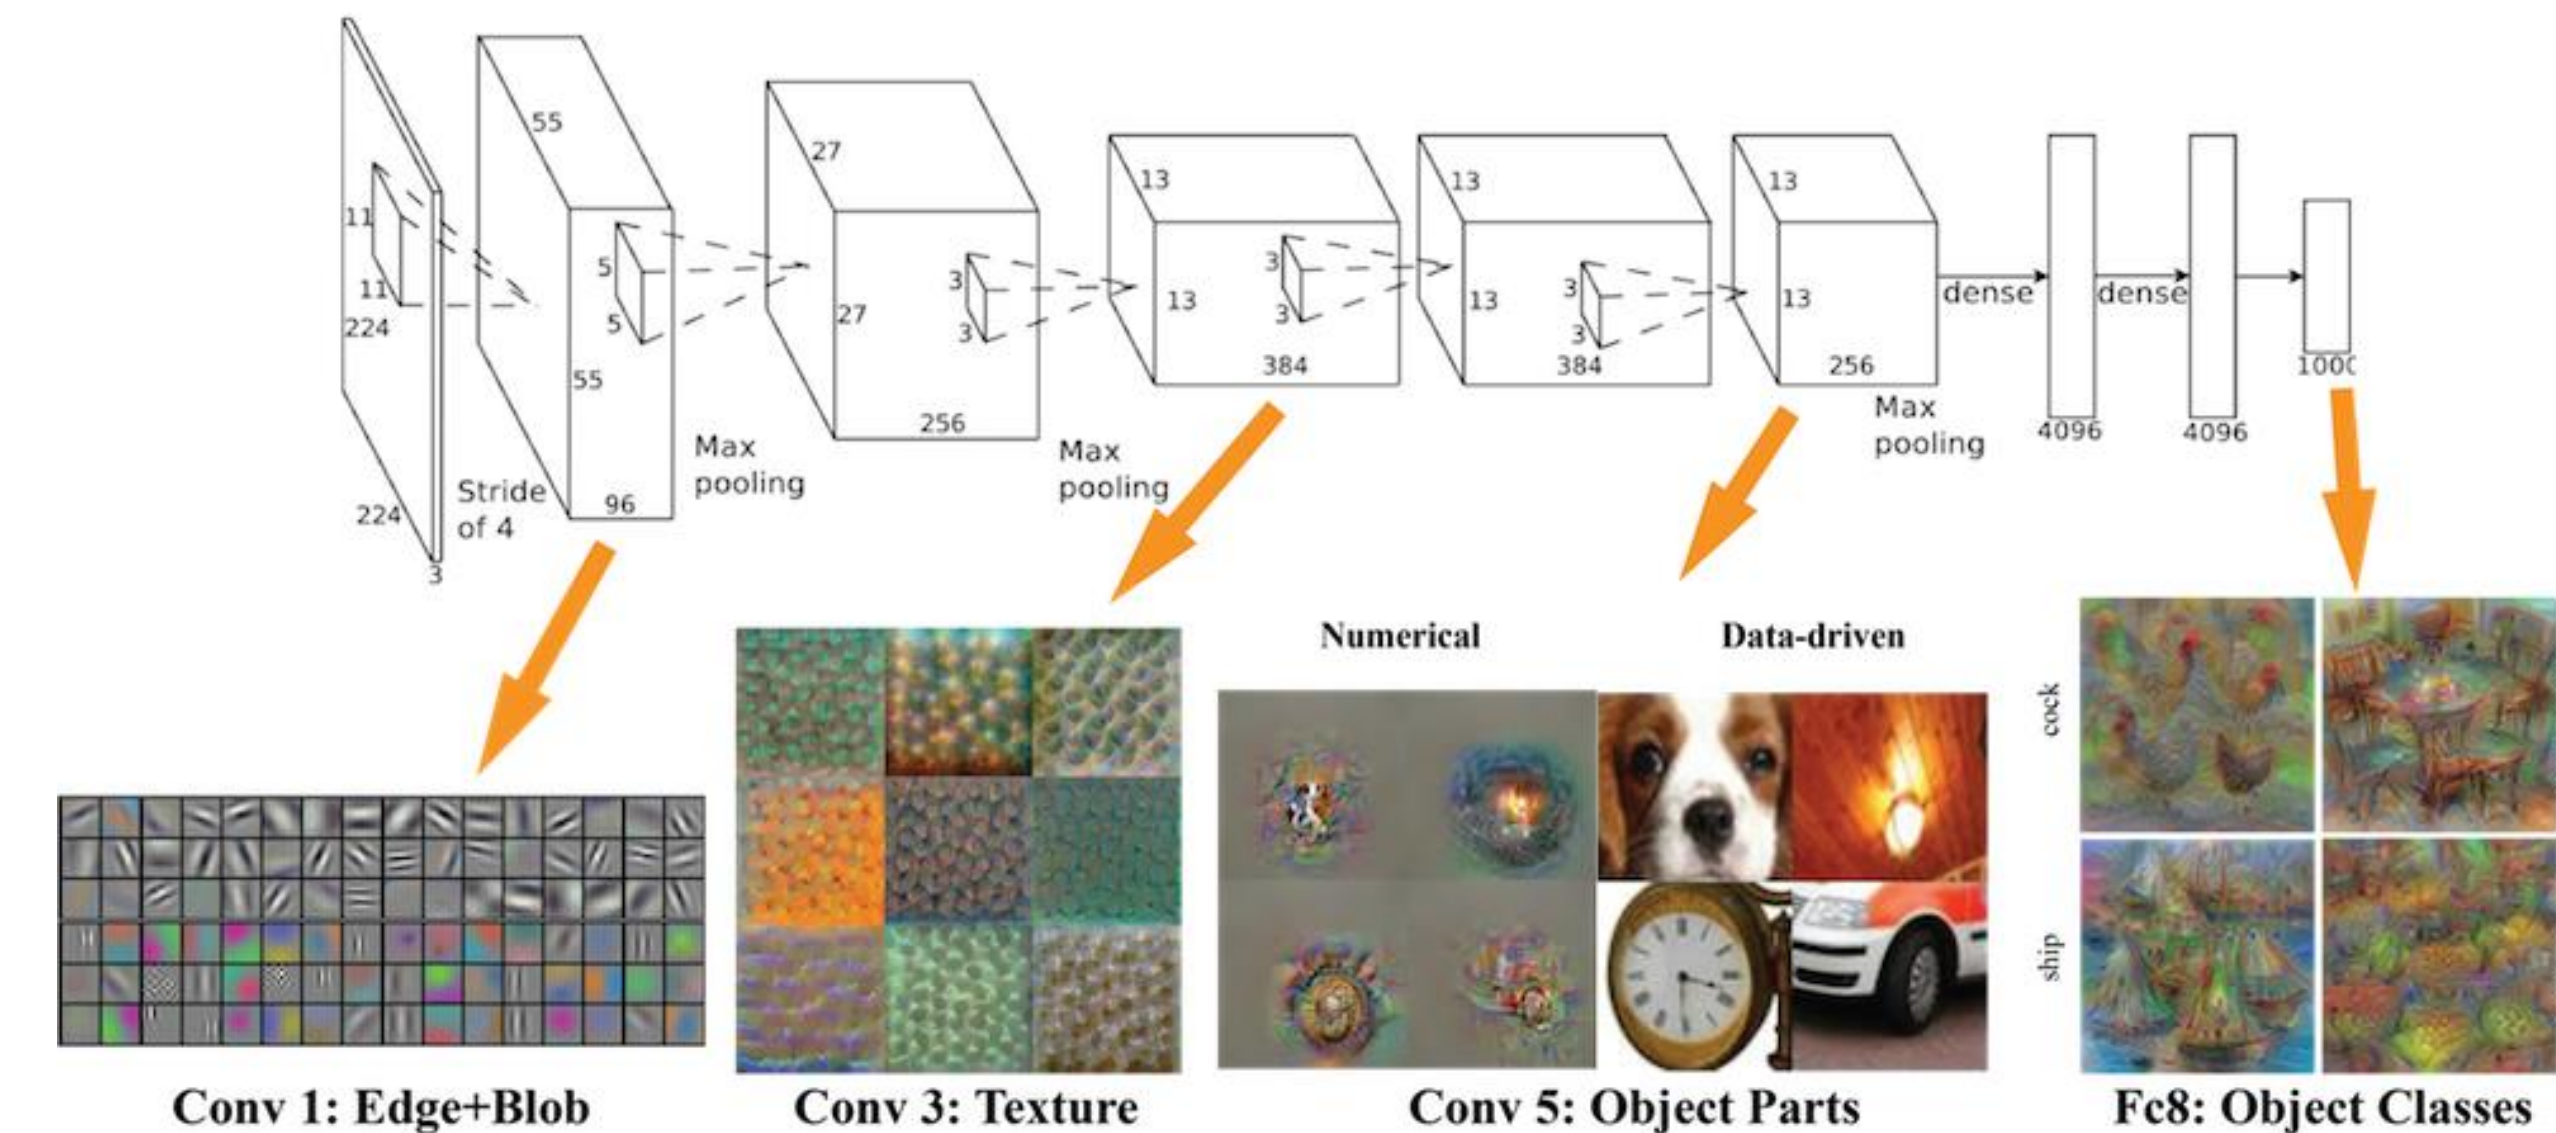
На каждом слое сети вектор объекта преобразуется в новый вектор

Каждое преобразование (нейрон) – линейная модель $a(x, w)$

Веса w являются обучаемыми параметрами модели



Глубокие свёрточные нейронные сети для классификации объектов на изображениях



Krizhevsky A., Sutskever I., Hinton G. ImageNet classification with deep convolutional neural networks. 2012.

Решающая роль больших данных (big data)

ImageNet: открытая выборка 14М изображений, 20К категорий


IMAGENET



Старт в 2009 г. Человеческий уровень ошибок 5% пройден в 2015 г.


Li Fei-Fei et al. ImageNet: A large-scale hierarchical image database. 2009.

Li Fei-Fei et al. Construction and analysis of a large scale image ontology. 2009.




Три составляющих успеха Deep Learning

- Повсеместное применение компьютерных технологий
→ *накопление больших выборок данных*
в частности, ImageNet
- Развитие математических методов и алгоритмов
→ *накопление критической массы опыта*
методы оптимизации для больших размерностей
- Достижения микроэлектроники
→ *рост вычислительных мощностей, закон Мура*
в частности, графические ускорители (GPU)



Машинное обучение – это оптимизация

x – вектор объекта обучающей выборки
 $a(x, w)$ – предсказательная модель
 w – параметры модели
 $Loss(x, w)$ – функция потерь
 $Q(w)$ – критерий качества модели




Задача обучения параметров модели:

$$Q(w) = \sum_x Loss(x, w) \rightarrow \min$$

Способ решения – численные методы оптимизации

Обучение с учителем (supervised learning): восстановление регрессии (regression)


x – вектор объекта обучающей выборки, y – числовой ответ
 $a(x, w)$ – модель регрессии с параметрами w
Например, $a(x, w) = \sum_j w_j x_j$ – линейная модель регрессии
 $Loss(x, w) = (a(x, w) - y)^2$ – квадратичная функция потерь



невязка (error)

Обучение с учителем (supervised learning): классификация (classification)

x – вектор объекта обучающей выборки, y – ответ (+1 или -1)
 $a(x, w)$ – модель классификации с параметрами w
Например, $a(x, w) = \text{sign}(\sum_j w_j x_j)$ – линейная модель
 $Loss(x, w) = \max(0, 1 - y \sum_j w_j x_j)$ – функция потерь SVM hinge



отступ (margin)

Машинное обучение – это оптимизация


x – вектор объекта обучающей выборки

$a(x, w)$ – предсказательная модель

w – параметры модели

$Loss(x, w)$ – функция потерь

$Q(w)$ – критерий качества модели



Задача обучения параметров модели:

$$Q(w) = \sum_x Loss(x, w) \rightarrow \min$$

Способ решения – численные методы оптимизации


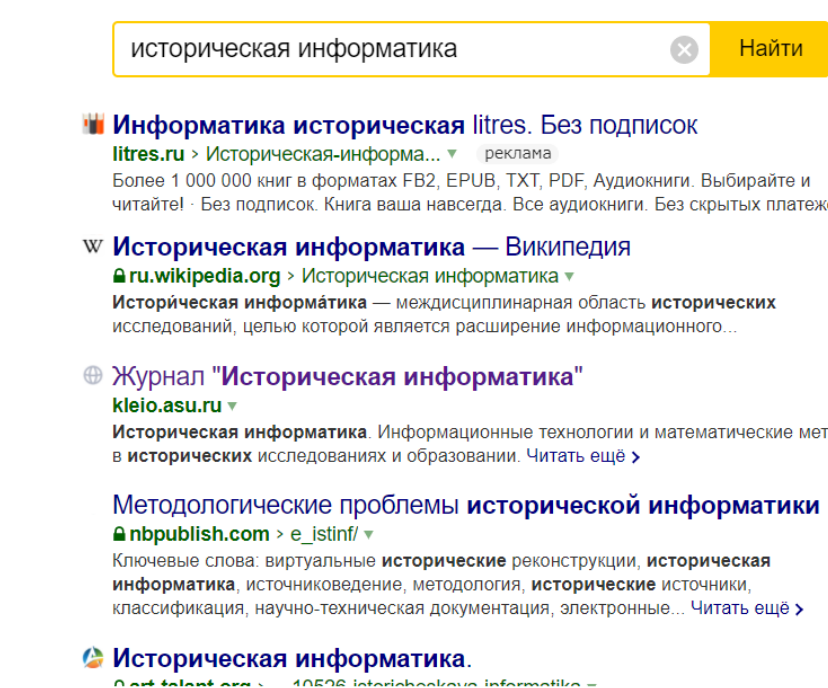
Обучение с учителем (supervised learning): обучение ранжированию (learning to rank)

x – вектор пары «запрос-документ», y – оценка релевантности

$a(x, w)$ – модель ранжирования документов по запросу, параметр w

Например, $a(x, w) = \sum_j w_j x_j$ – линейная модель

$$Loss(x, x', w) = \max(0, 1 - [y > y'](a(x, w) - a(x', w)))$$



$$\text{Precision} = \frac{\text{true positives}}{\text{true positives} + \text{false positives}}$$

$$\text{Recall} = \frac{\text{true positives}}{\text{true positives} + \text{false negatives}}$$

*не только поиск,
но и любые задачи, где
человеку удобно
принимать решения,
выбирая один из вариантов*

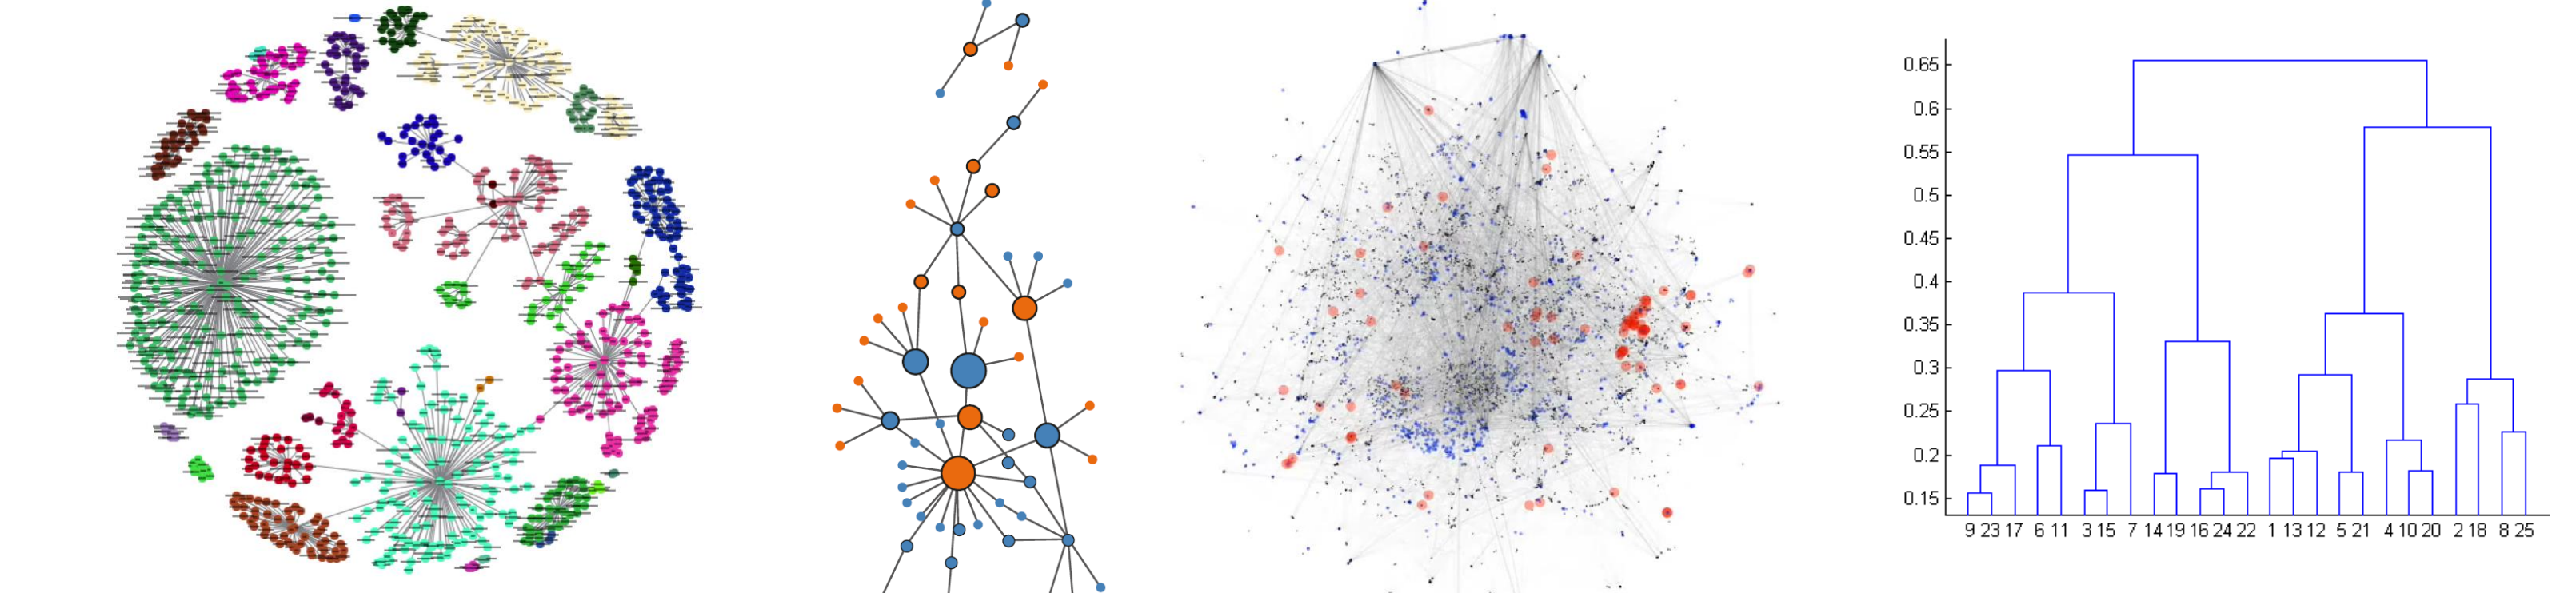
Обучение без учителя (unsupervised learning): кластеризация (clustering)

x – вектор объекта обучающей выборки, ответы не задаются

$a(x, w)$ – кластер, ближайший к x

$w = \{c_1, \dots, c_K\}$ – векторы центров всех кластеров

$$Loss(x, w) = \min_k \|x - c_k\|$$
 – расстояние до ближайшего кластера




Машинное обучение – это оптимизация

x – вектор объекта обучающей выборки
 $a(x, w)$ – предсказательная модель
 w – параметры модели
 $Loss(x, w)$ – функция потерь
 $Q(w)$ – критерий качества модели

Задача обучения параметров модели:

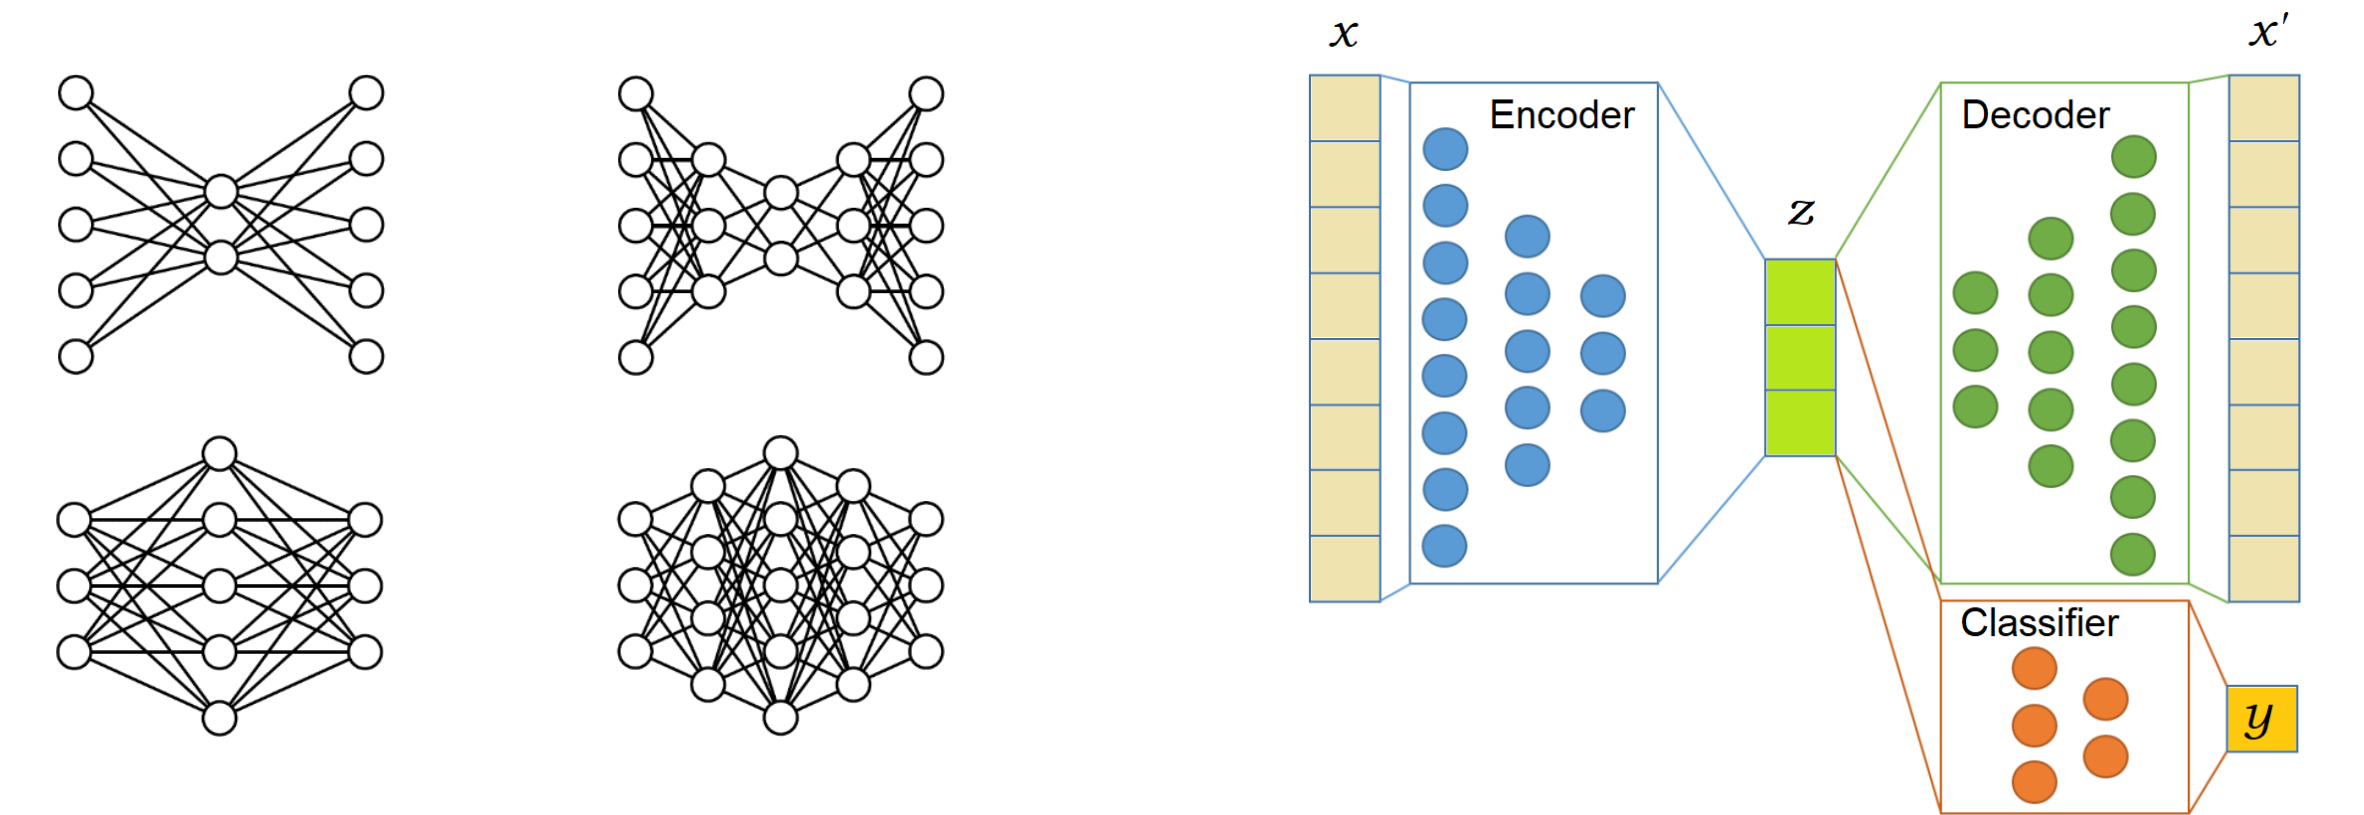
$$Q(w) = \sum_x Loss(x, w) \rightarrow \min$$

Способ решения – численные методы оптимизации



Обучение без учителя (unsupervised learning): векторизация, автокодировка (autoencoder)

x — описание объекта обучающей выборки, ответов не дано
 $z = f(x, w)$ — модель кодирования x в векторное представление z
 $x' = g(z, w')$ — модель декодирования z в реконструкцию x'
 $Loss(x, w) = \|g(f(x, w), w') - x\|$ — точность реконструкции объекта



обучаемая
векторизация
сложных
объектов

Перенос обучения (transfer learning), предобучение модели векторизации

$z = f(x, w)$ — модель векторизации, универсальная для многих задач
 $y = g(z, w')$ — часть модели, специфичная для своей задачи
 $\min_{w, w'} \sum_x Loss_1(g_1(f(x, w), w'))$ — обучение по большим данным
 $\min_{w'} \sum_{x'} Loss_2(g_2(f(x', w), w'))$ — обучение по своим данным



Sinno Jialin Pan, Qiang Yang. A Survey on Transfer Learning. 2009

Машинное обучение – это оптимизация

x – вектор объекта обучающей выборки

$a(x, w)$ – предсказательная модель

w – параметры модели


$Loss(x, w)$ – функция потерь

$Q(w)$ – критерий качества модели

Задача обучения параметров модели:

$$Q(w) = \sum_x Loss(x, w) \rightarrow \min$$

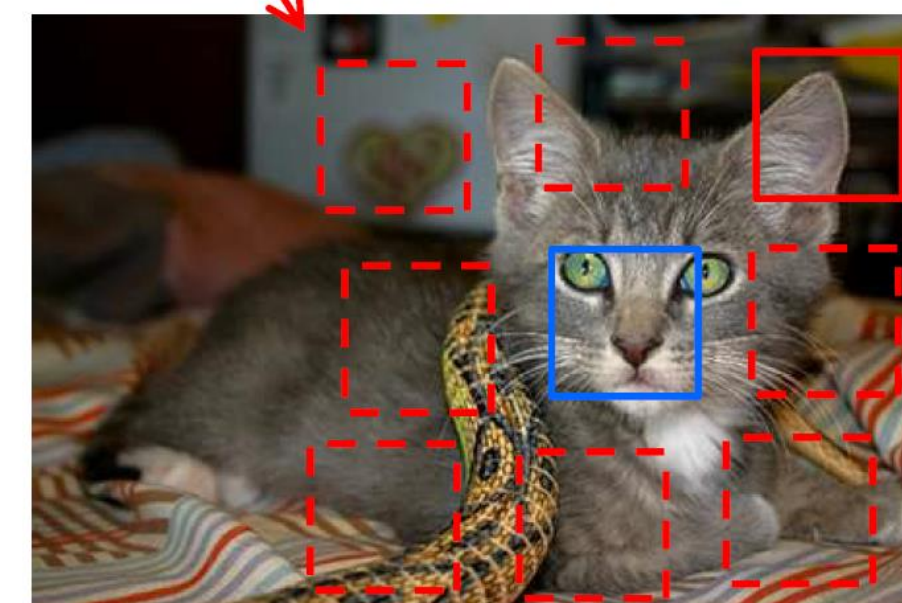
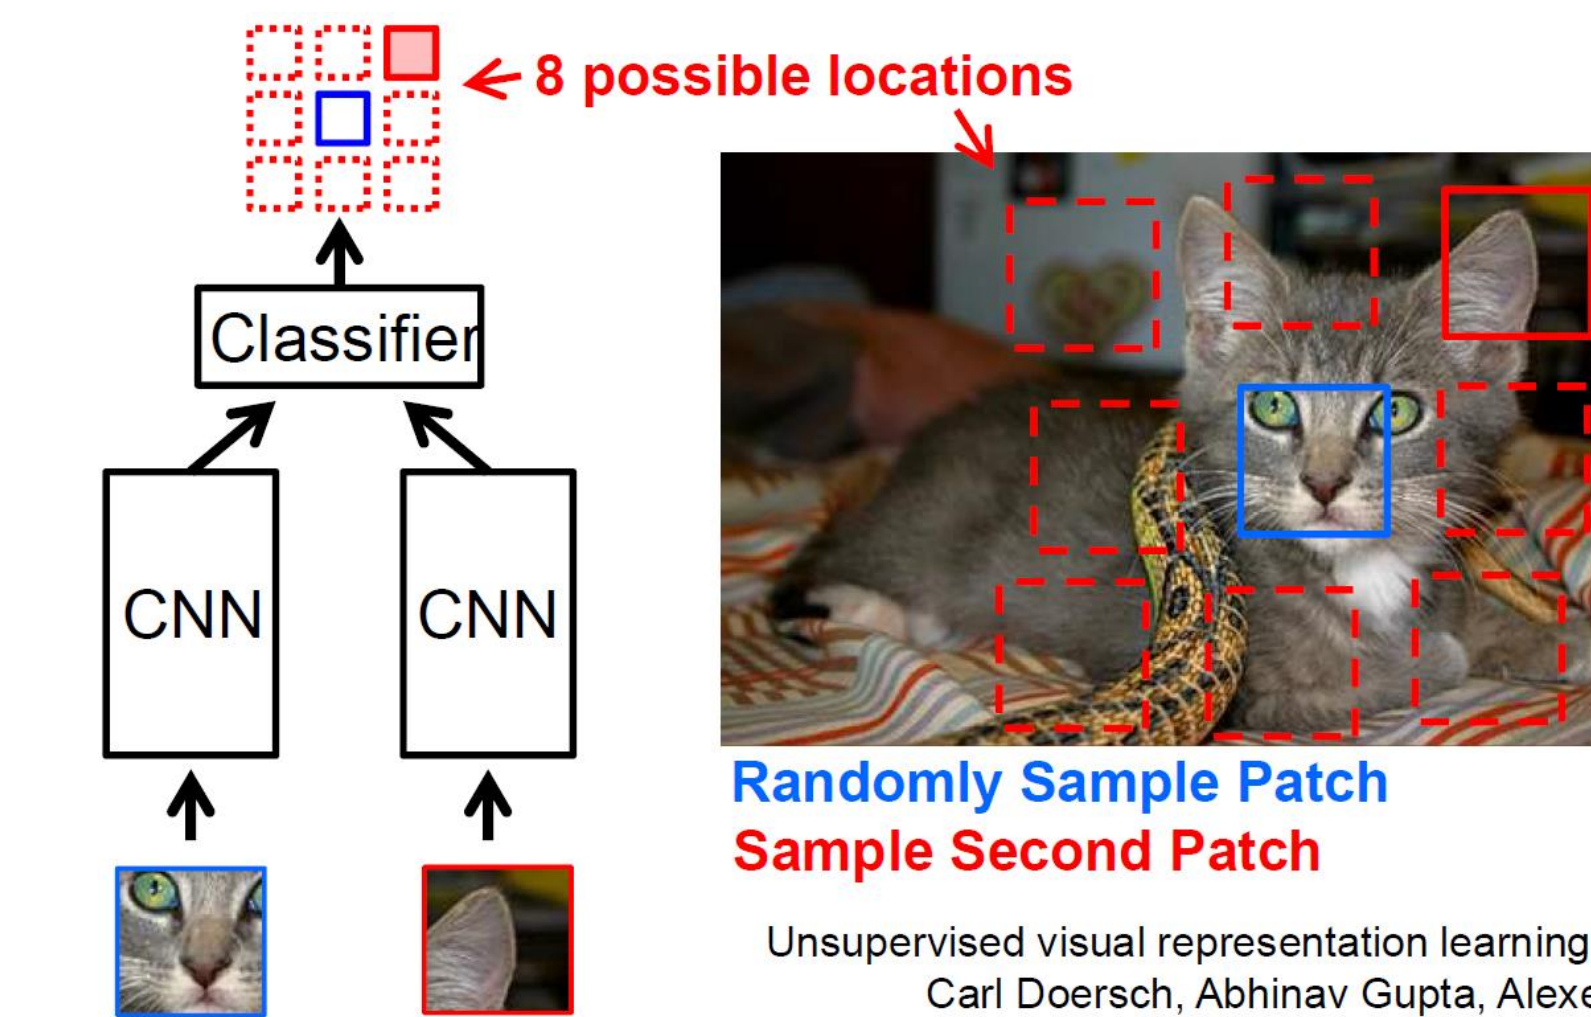
Способ решения – численные методы оптимизации



Самостоятельное обучение (self-supervised)

x – изображение

$z = f(x, w)$ – модель векторизации, обучается предсказывать взаимное расположение пар фрагментов одного изображения



Randomly Sample Patch
Sample Second Patch

Unsupervised visual representation learning by context prediction,
Carl Doersch, Abhinav Gupta, Alexei A. Efros, ICCV 2015

Преимущество:
сеть выучивает векторные представления объектов без размеченной обучающей выборки

Многозадачное обучение (multi-task learning)

$z = f(x, w)$ – модель векторизации, универсальная для всех задач


$y = g_t(z, w'_t)$ – часть модели, специфичная для t -й задачи

$\min_{w, w'_t} \sum_t \sum_x Loss_t(g_t(f(x, w), w'_t))$ – обучение по всем задачам

few-shot learning – обучение по малому числу примеров

M. Crawshaw. Multi-task learning with deep neural networks: a survey. 2020

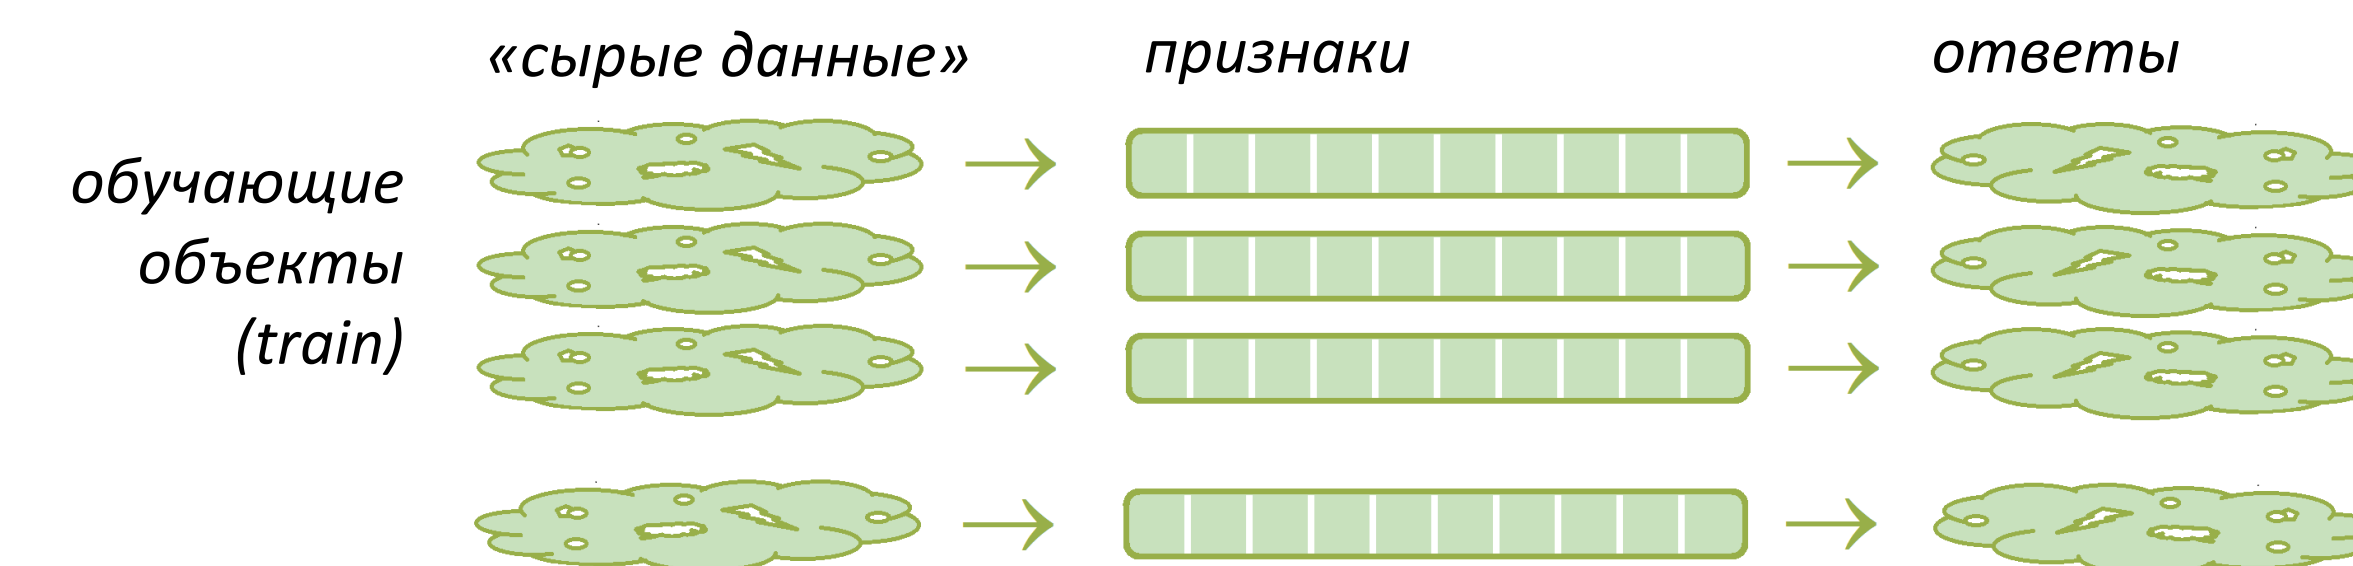
Y. Wang et al. Generalizing from a few examples: a survey on few-shot learning. 2020



Нейронные сети для синтеза объектов

Вход: сложно структурированные объекты

Выход: сложно структурированные ответы



Примеры: синтез изображений, перенос стиля, распознавание речи, машинный перевод, суммаризация текстов, диалог с пользователем

Модели: seq2seq, CNN, RNN, LSTM, GAN, BERT, GPT и др.

Генеративная состязательная сеть (GAN)

$x = g(z, w)$ — модель генерации реалистичного объекта x из шума z

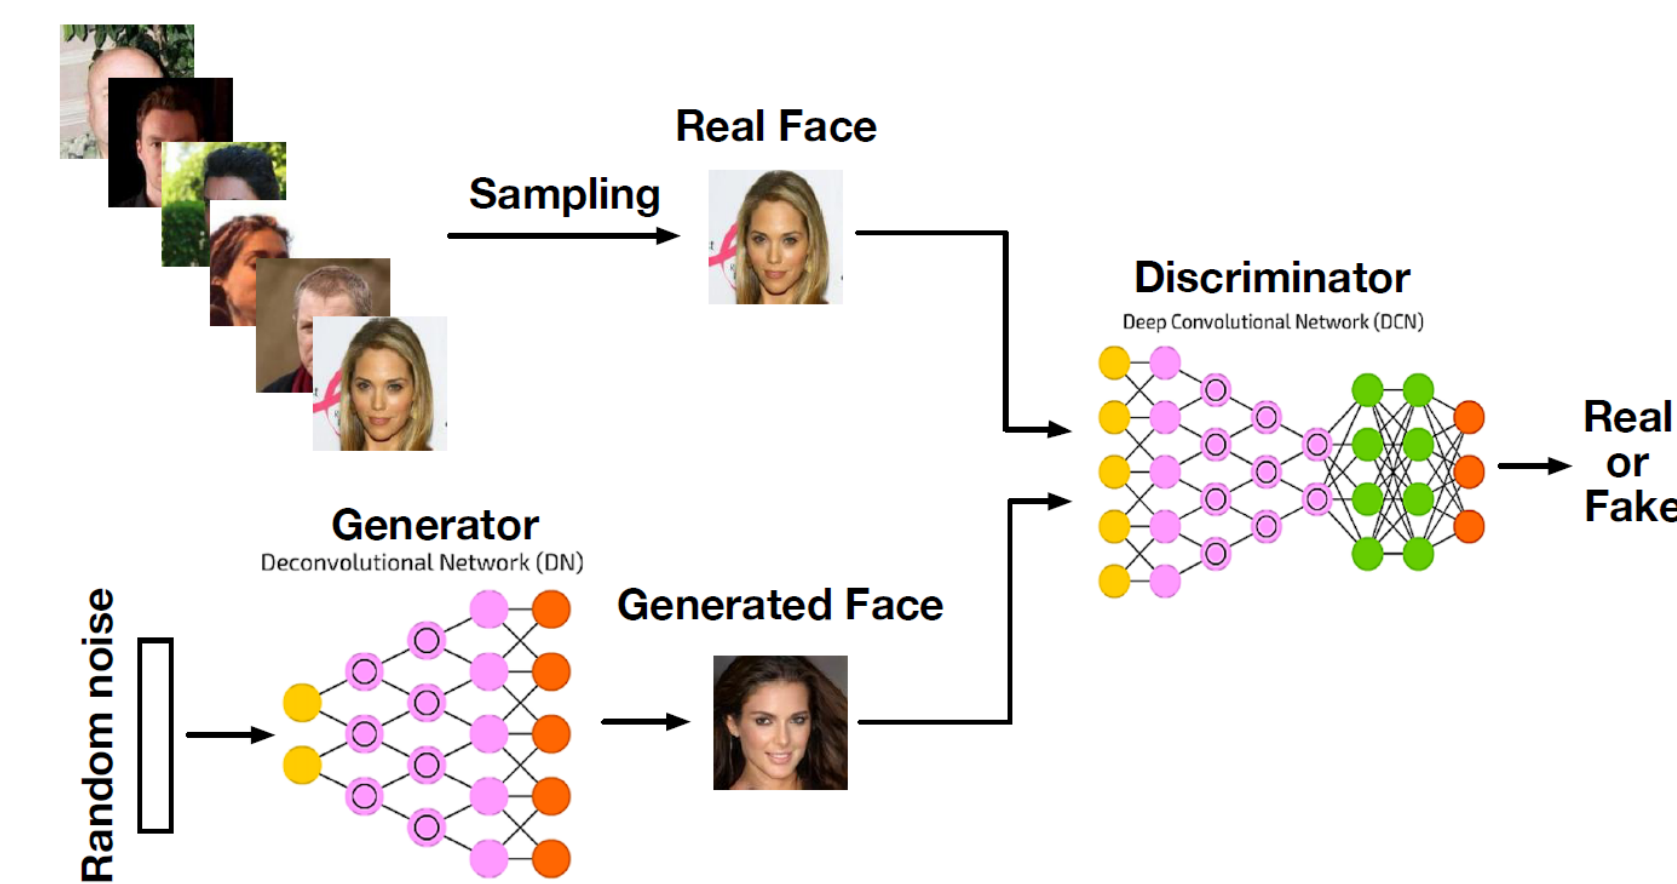
$f(x, w')$ — модель классификации x «реальный/сгенерированный»

$\min_w \max_{w'} \sum_x \ln f(x, w') + \ln (1 - f(g(z, w), w'))$ — совместное обучение


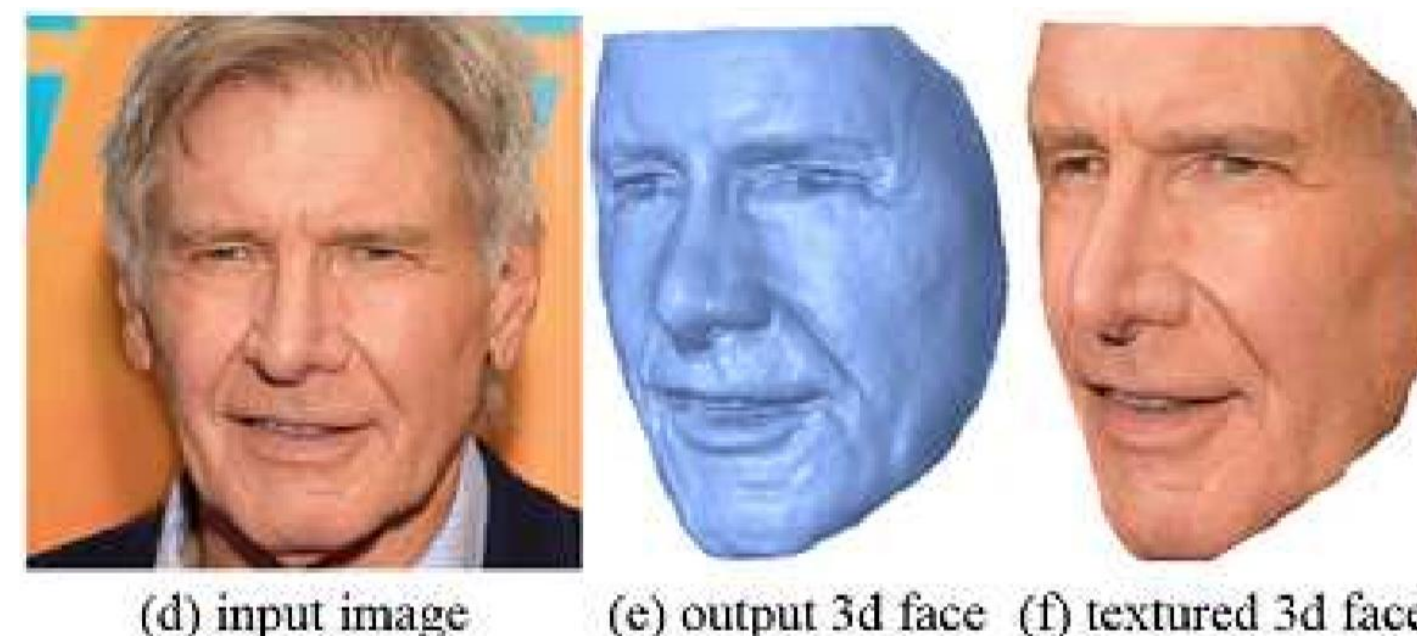
Antonia Creswell et al. Generative Adversarial Networks: an overview. 2017.

Zhengwei Wang et al. Generative Adversarial Networks: a survey and taxonomy. 2019.

Chris Nicholson. A Beginner's Guide to Generative Adversarial Networks. 2019.



Синтез изображений и видео



Caroline Chan, Shiry Ginosar, Tinghui Zhou, Alexei A. Efros. Everybody Dance Now. ICCV-2019.

Эволюция подходов в обработке текстов

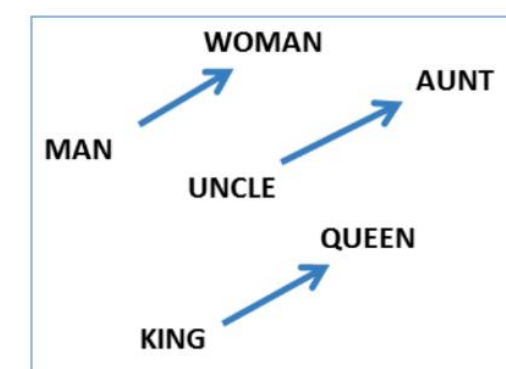
Декомпозиция задач по уровням «пирамиды NLP»

- морфологический анализ, лемматизация, опечатки, ...
- синтаксический анализ, выделение терминов, NER, ...
- семантический анализ, выделение фактов, тем, ...



Модели векторизации слов (эмбедингов)

- модели дистрибутивной семантики: word2vec [Mikolov, 2013], FastText [Bojanowski, 2016], ...
- тематические модели LDA [Blei, 2003], ARTM [2014], ...




Нейросетевые модели контекстной векторизации

- рекуррентные нейронные сети: LSTM, GRU, ...
- «end-to-end» модели внимания и трансформеры: машинный перевод [2017], BERT [2018], GPT-4 [2023], ...

$$\text{softmax} \left(\frac{Q \times K^T}{\sqrt{d}} \right) \cdot V$$

Модели внимания: машинный перевод



Интерпретация моделей внимания: матрица семантического сходства $A[t,i]$ показывает, на какие слова $x[i]$ входного текста модель обращает внимание, когда генерирует слово перевода $y[t]$

Bahdanau et al. Neural machine translation by jointly learning to align and translate. 2015

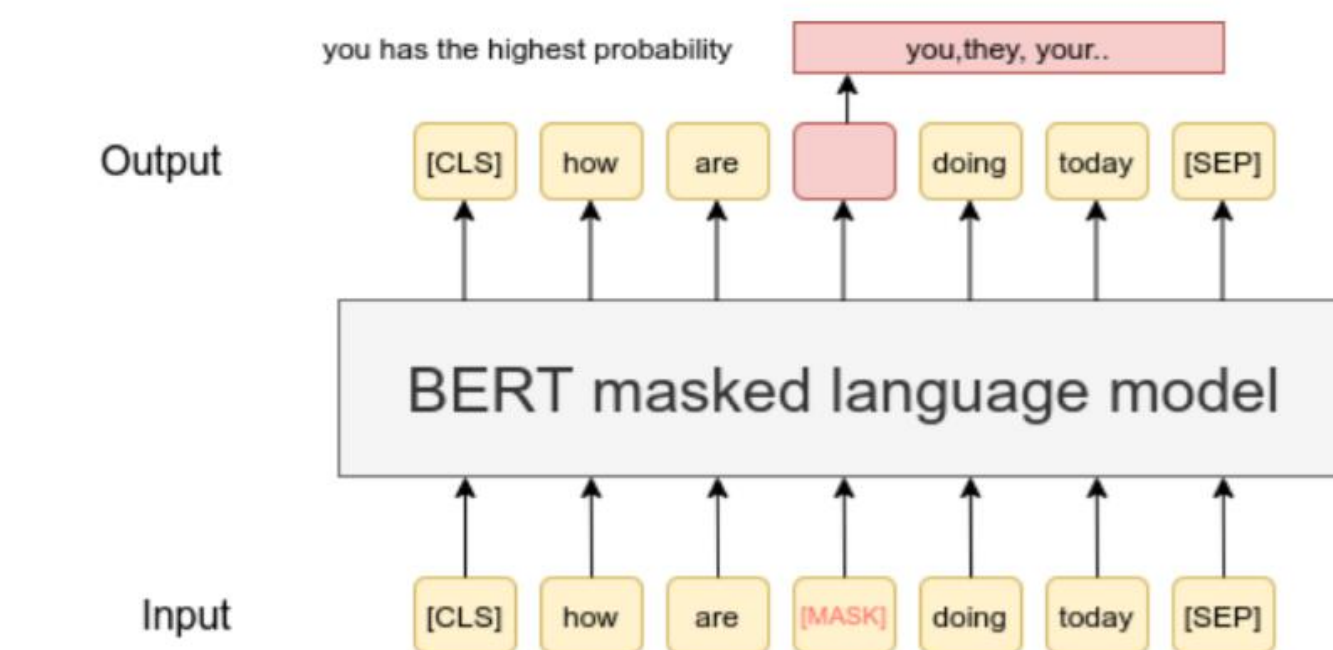
Обучение контекстной векторизации слов

x_i — слово на i -й позиции в коллекции текстовых документов

$z_i = f(x_i, C_i, w)$ — модель векторизации слова x_i по контексту C_i

$p(x|i, z, w')$ — вероятностная модель предсказания слова по вектору z

$\text{Loss}(x_i, w) = -\ln p(x_i|i, f(x_i, C_i, w), w')$ — потеря от предсказания слова на i -й позиции по его контексту (Masked Language Model)

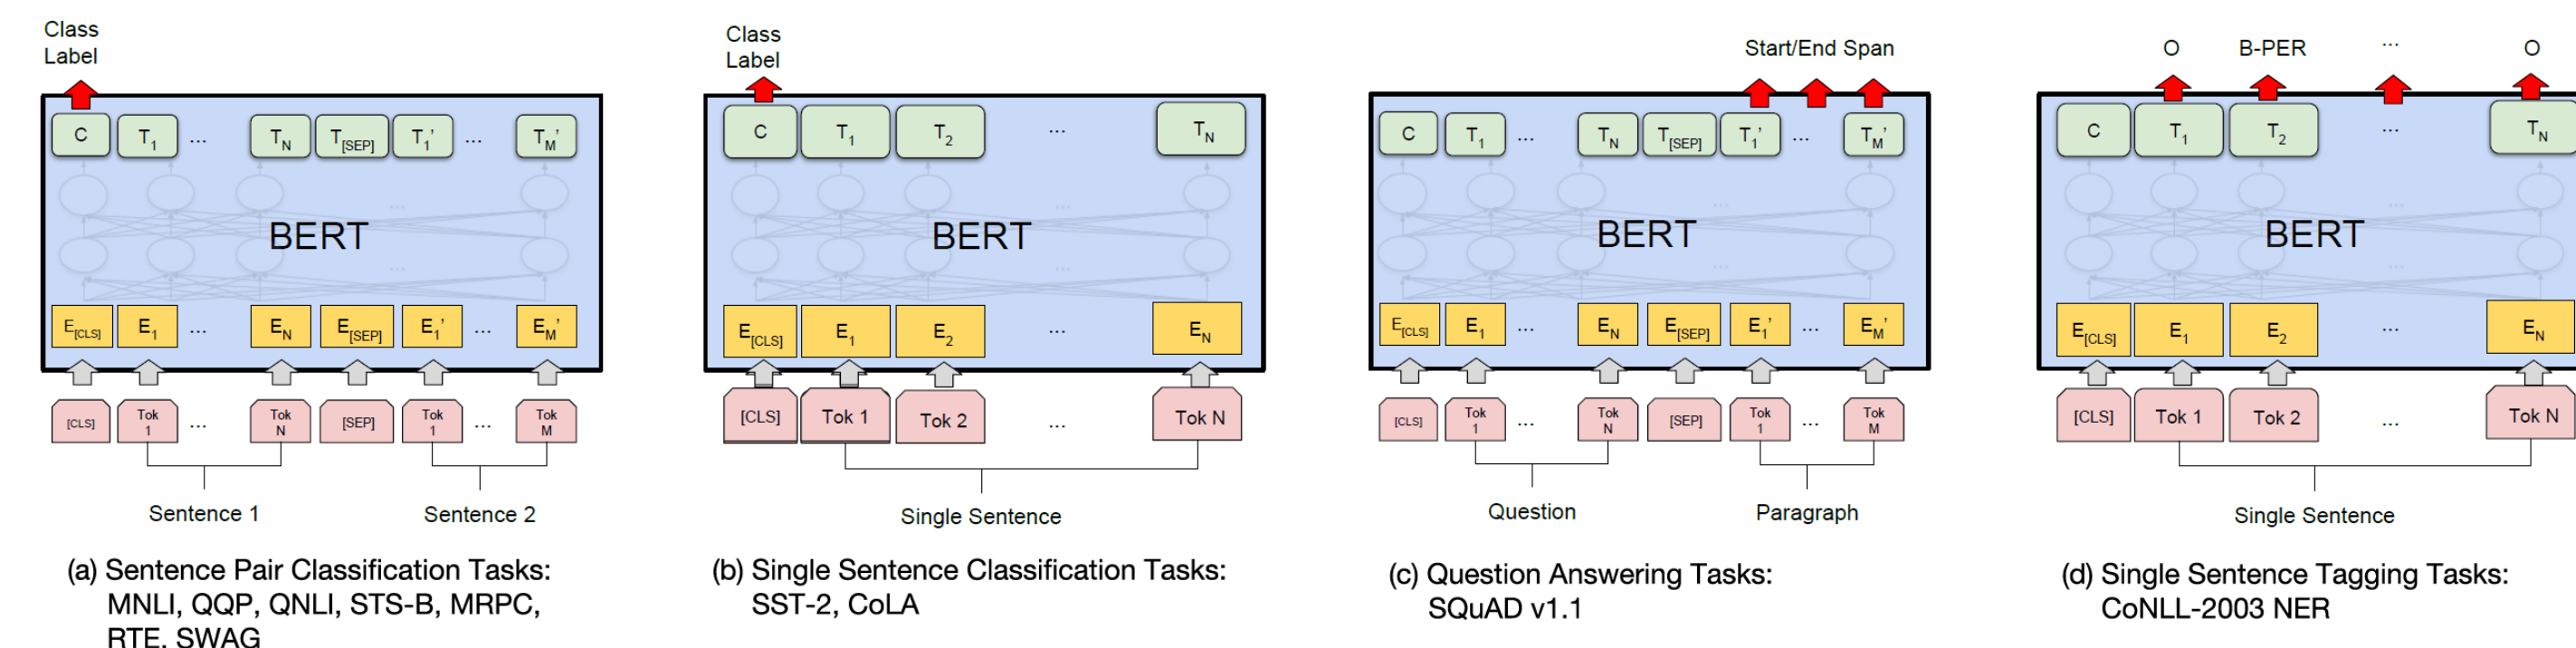


Vaswani et al. (Google) Attention is all you need. 2017.

Jacob Devlin et al. (Google AI Language) BERT: pre-training of deep bidirectional transformers for language understanding. 2019.

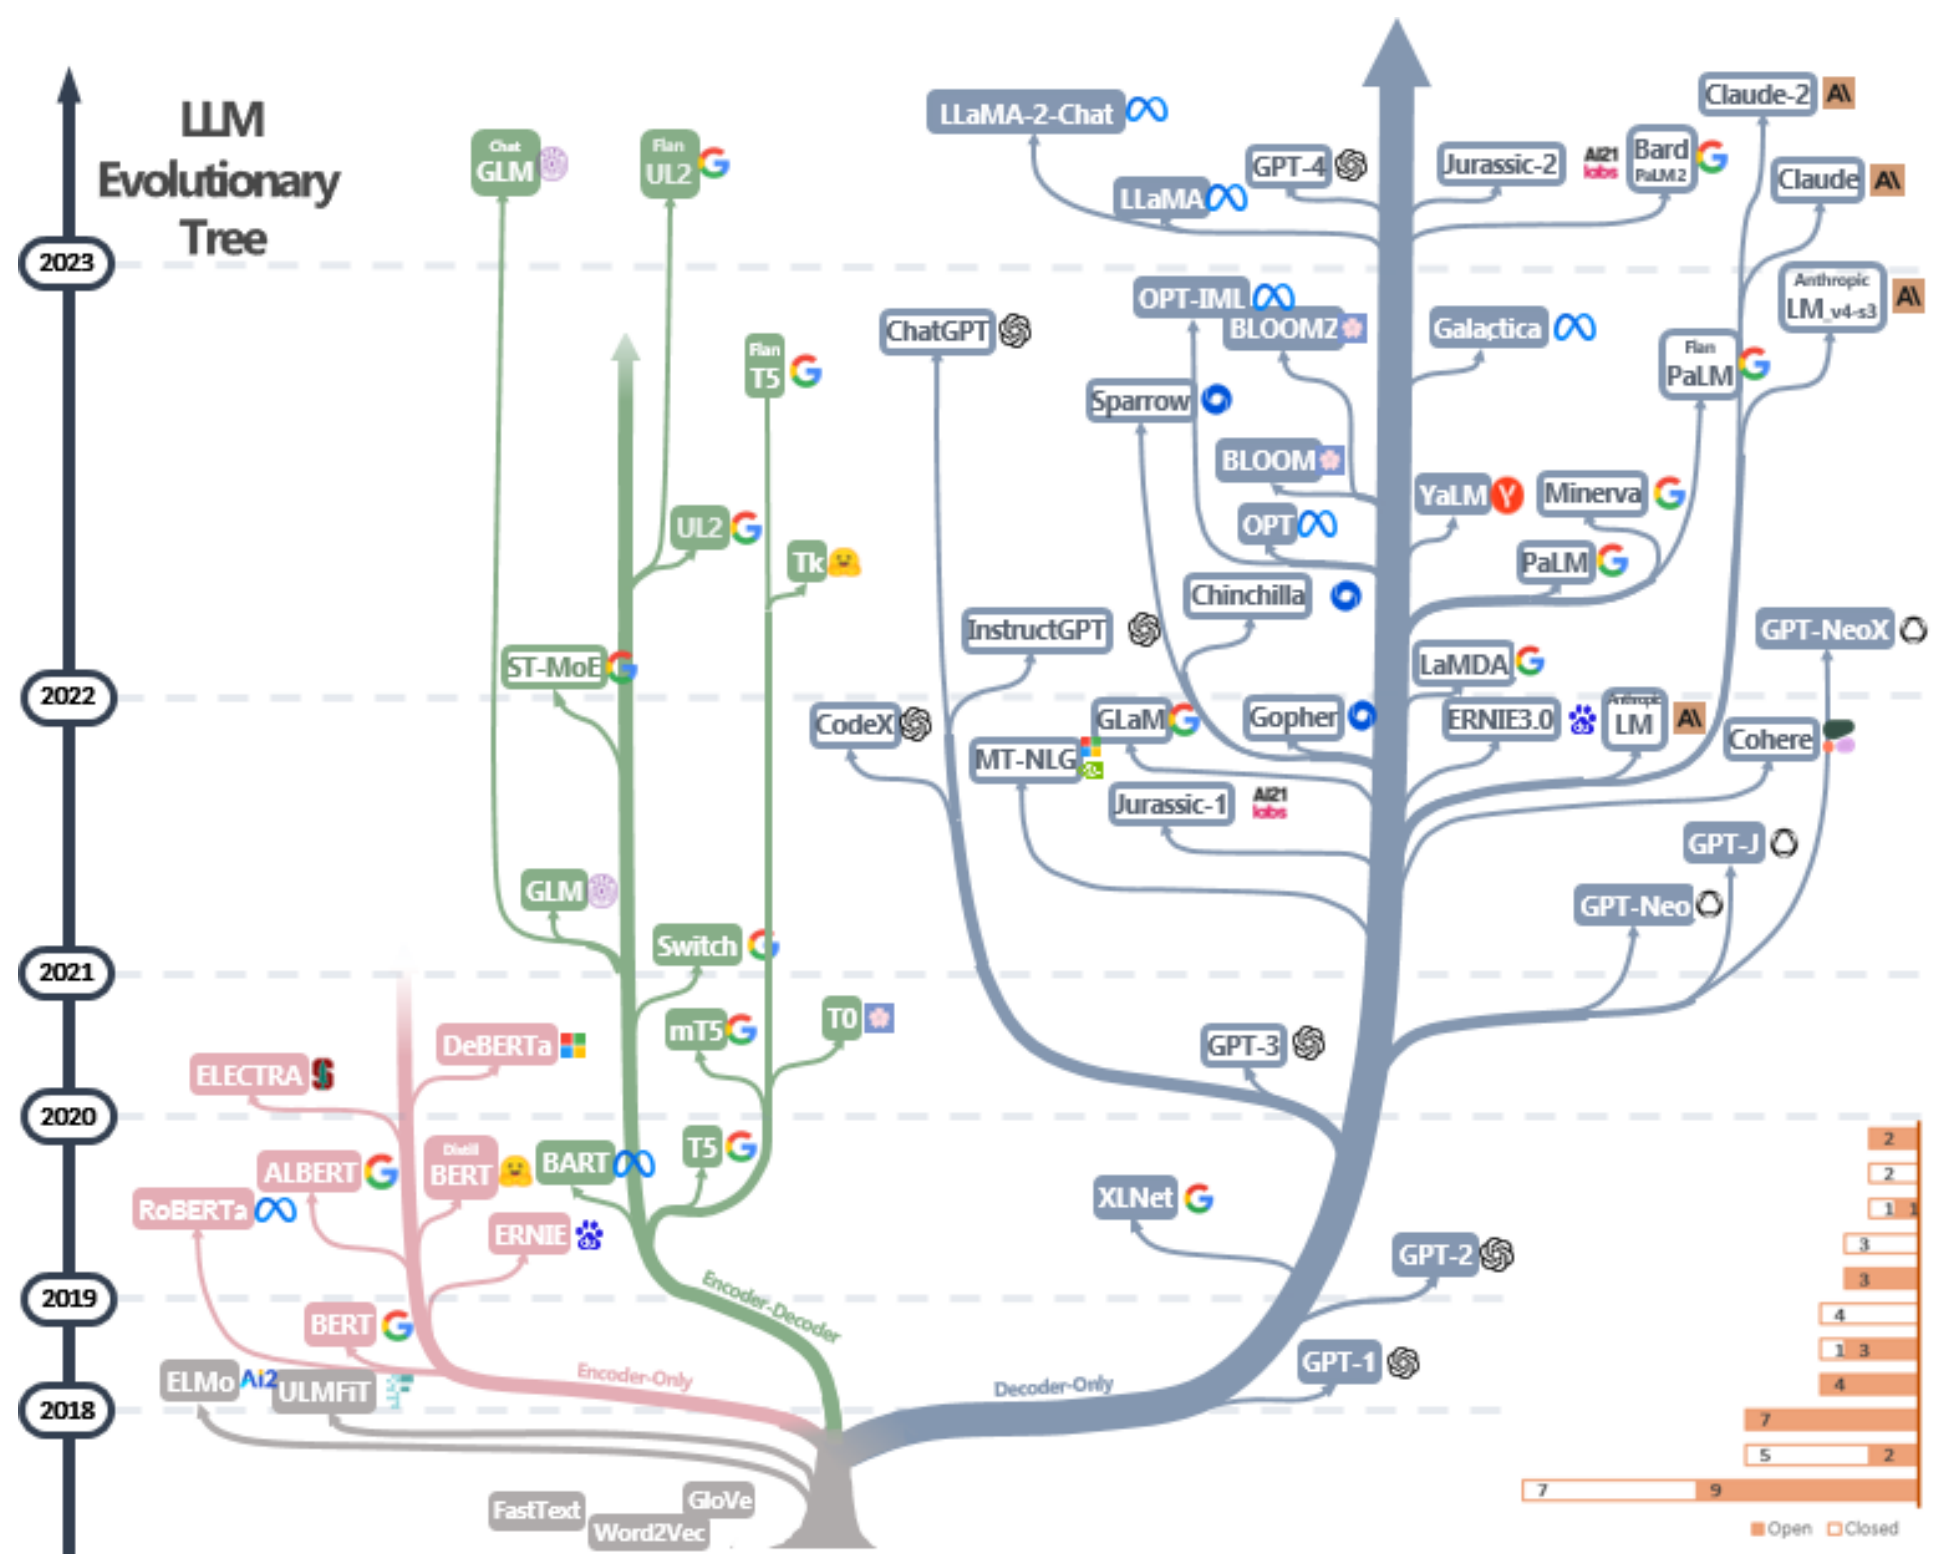

Трансформеры: большие языковые модели

- Обучаются векторизовать и предсказывать слова по контексту
- Обучаются по терабайтам текстов, «они видели в языке всё»
- Мультиязычны: обучаются на десятках языков
- Мультизадачны: для каждой новой задачи NLP/NLU достаточно предобученной модели или дообучения на небольшой выборке



Трансформеры: размер имеет значение

Рост числа параметров больших языковых моделей



Проблемки общего искусственного интеллекта


Sparks of Artificial General Intelligence:
Early experiments with GPT-4

Sébastien Bubeck, Varun Chandrasekaran, Ronen Eldan, Johannes Gehrke,
Eric Horvitz, Ece Kamar, Peter Lee, Yin Tat Lee, Yuanzhi Li, Scott Lundberg,
Harsha Nori, Hamid Palangi, Marco Tulio Ribeiro, Yi Zhang
Microsoft Research (27 March 2023)

Новые способности модели, не закладывавшиеся при обучении:

- объяснять свои ответы, перефразировать, переводить на другие языки
- реферировать, генерировать планы, сценарии, шаблоны
- строить аналогии, менять тональность, стиль, глубину изложения
- генерировать программный код на различных языках
- решать некоторые логические и математические задачи
- искать и исправлять собственные ошибки по подсказке

Новые (эмерджентные) способности модели

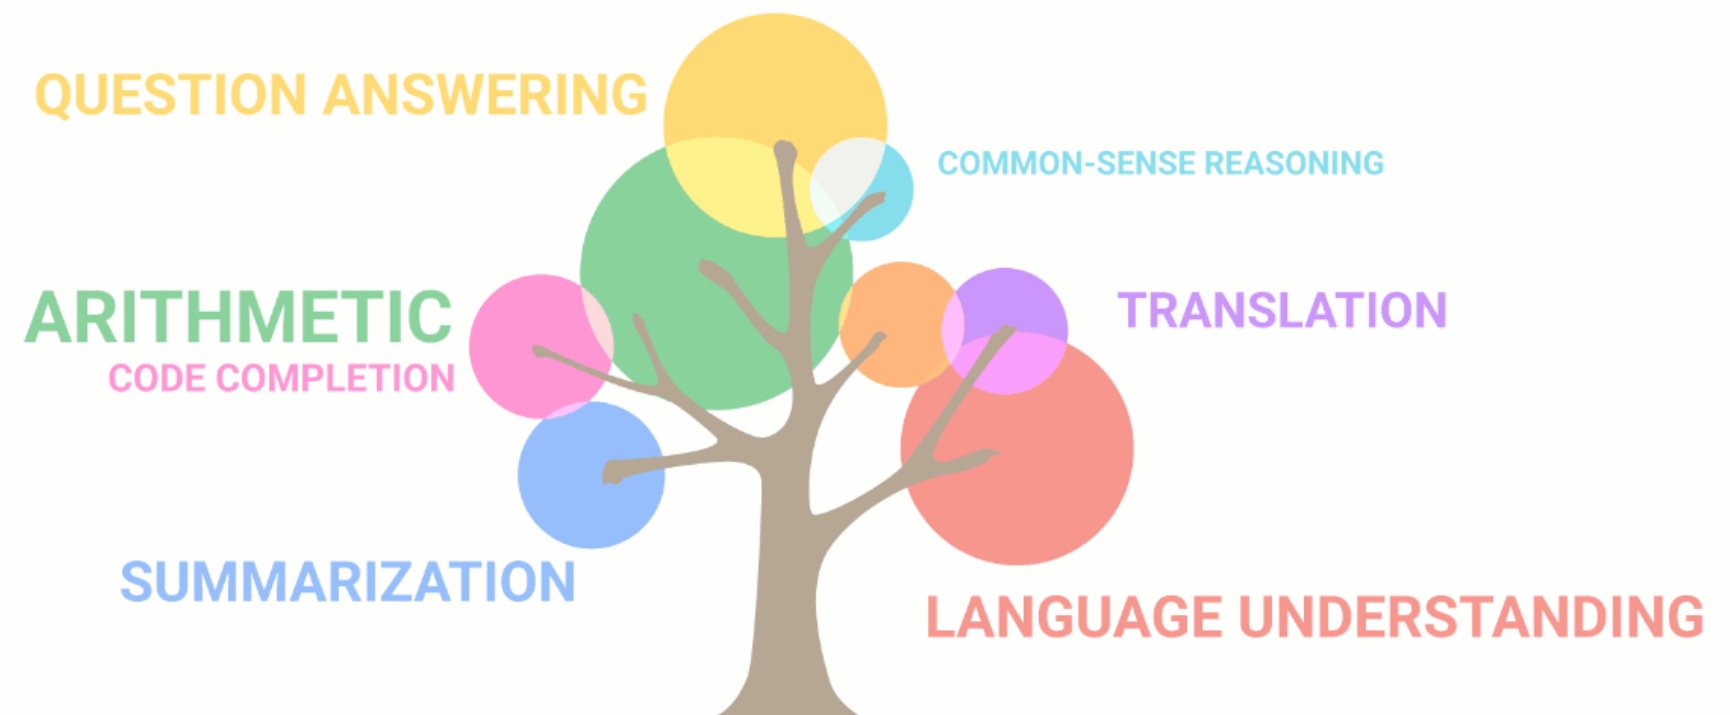


GPT-2: 14-Feb-2019

1,5 млрд. параметров, корпус 10 млрд. токенов (40Gb), контекст 768 слов (1,5 стр.)

- способность написать эссе, которое конкурсное жюри не смогло отличить от написанного человеком

Новые (эмерджентные) способности модели

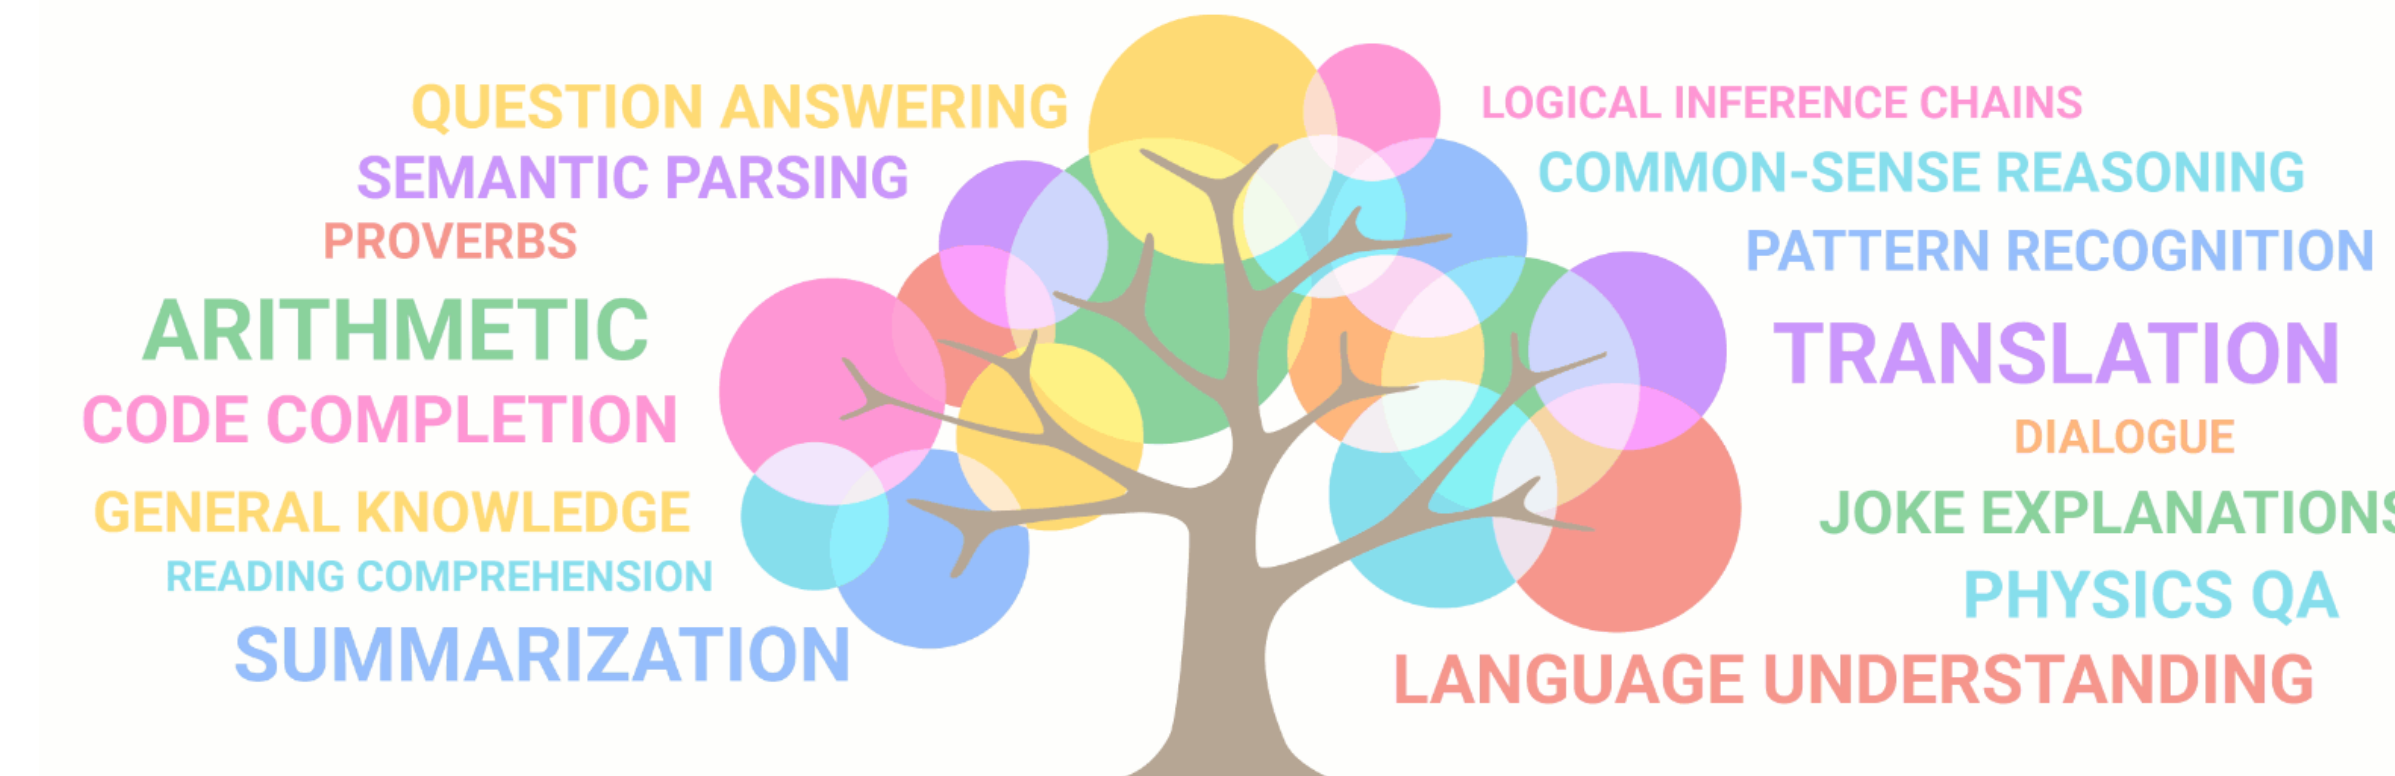


GPT-3: 11-Jun-2020

175 млрд. параметров, корпус 500 млрд. токенов, контекст 1536 слов (3 стр.)

- способность делать перевод на другие языки
- способность решать логические и простейшие математические задачи
- способность генерировать программный код по текстовому описанию

Новые (эмерджентные) способности модели



GPT-4: 14-Mar-2023


>1 трл. параметров, корпус >1Tb, контекст 24 000 слов (48 страниц)

- способность описывать и анализировать изображения
- способность реагировать на подсказки вроде «Let's think step by step»
- способность решать качественные физические задачи по картинке

Модели внимания: аннотирование изображений



A woman is throwing a frisbee in a park.
 A dog is standing on a hardwood floor.
 A stop sign is on a road with a mountain in the background.

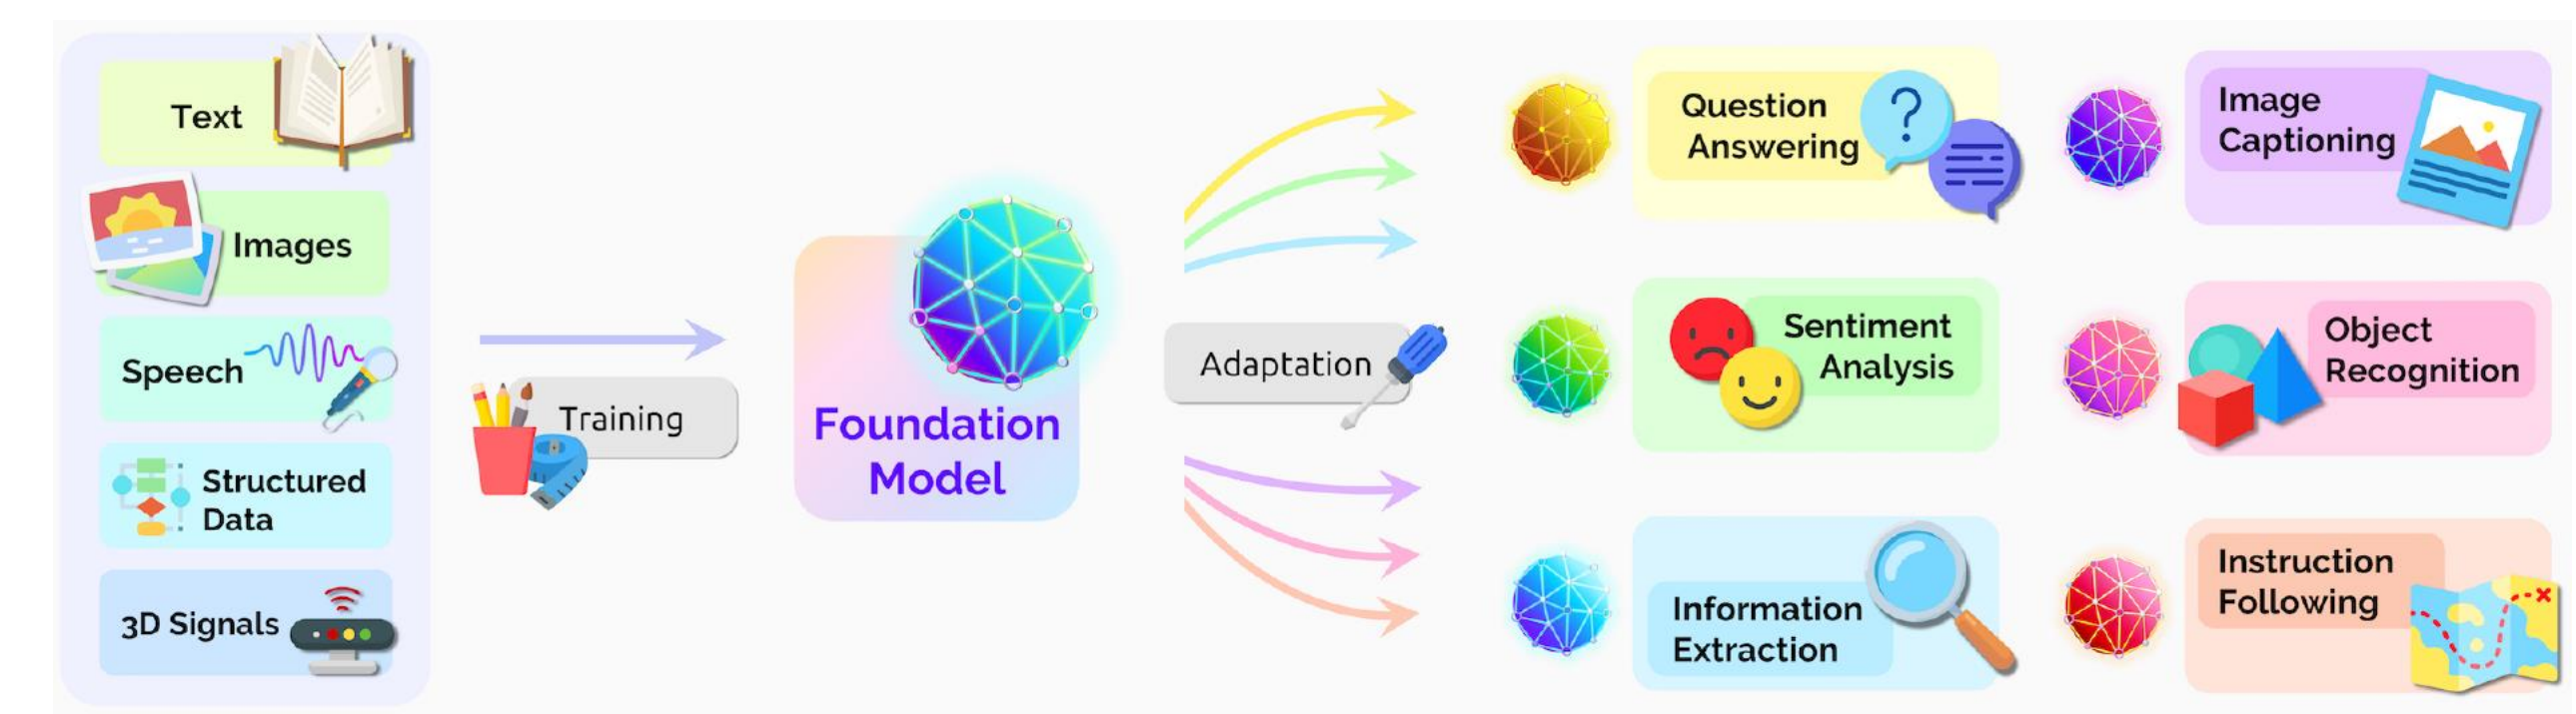
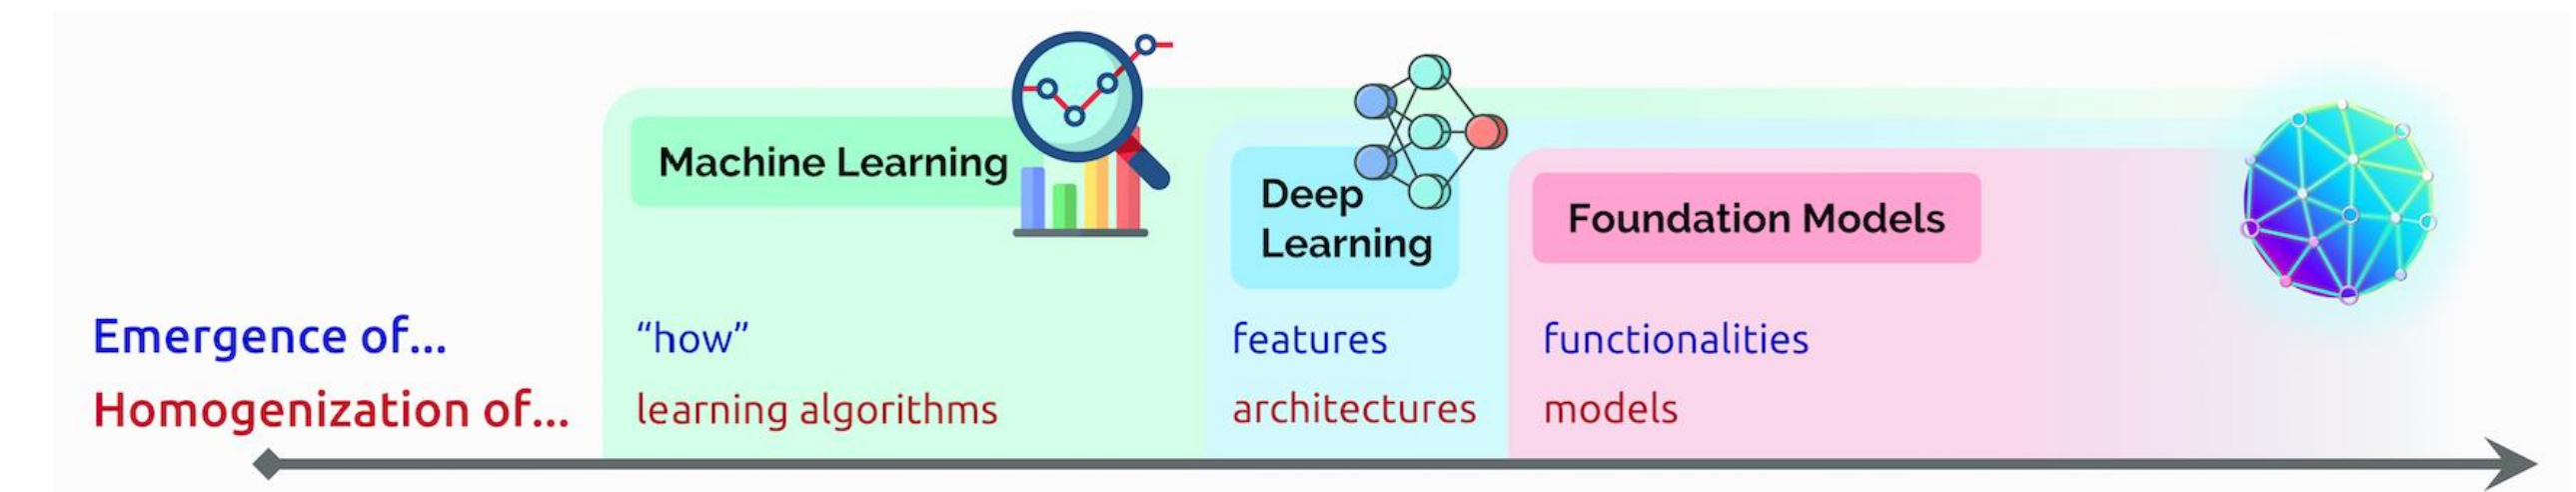


A little girl sitting on a bed with a teddy bear.
 A group of people sitting on a boat in the water.
 A giraffe standing in a forest with trees in the background.

Интерпретация: на какие области модель обращает внимание, генерируя подчёркнутое слово в описании изображения

Kelvin Xu et al. Show, attend and tell: neural image caption generation with visual attention. 2016

Фундаментальные модели (Foundation Models)



R.Bommasani et al. (CRFM, Stanford University). On the opportunities and risks of foundation models. 2021

Возможности и угрозы: чаты GPT способны...

- | | |
|--|--|
| <ul style="list-style-type: none"> • помогать с рутинно-творческой работой • генерировать документы или сайты по техническому заданию • в том числе медицинские, юридические документы по шаблонам • искать и структурировать профессиональную информацию • делать обзоры, рефераты, сводки на разных языках • генерировать программный код по описанию • обсуждать новости, поддерживать разговор по теме • разговаривать с детьми с учётом возрастных особенностей • выполнять функции воспитателя, учителя, наставника • оказывать психологическую помощь | <ul style="list-style-type: none"> • «галлюцинировать», давать неверные сведения, касающиеся здоровья человека, законов, событий, технологий, других людей • вызывать необоснованное доверие и манипулировать человеком • переубеждать, побуждать человека к действиям, не выгодным ему • поддерживать предрассудки и лженаучные представления • поддерживать пропагандистские медиа-кампании • неконтролируемо влиять на формирование мировоззрения у подростков • оказывать депрессивное воздействие на психику |
|--|--|

Шаги практического решения задач AI/DS/ML

Формализация постановки, «ДНК» задачи


- **Дано:** выборка «объекты-признаки → ответы»
- **Найти:** предсказательная модель
- **Критерии:** качество предсказаний, KPI

Моделирование

- предобработка и векторизация данных
- формализация модели
- оптимизация (обучение) модели
- оценивание и выбор моделей

Внедрение

- оценивание качества оффлайн и онлайн
- интеграция с бизнес-процессами



CRISP-DM:
CRoss Industry Standard Process
for Data Mining (1999)

Особенности реальных данных

В реальных приложениях данные бывают ...

- разнородные (признаки измерены в разных шкалах)
- неполные (признаки измерены не все, имеются пропуски)
- неточные (признаки измерены с погрешностями)
- противоречивые (объекты одинаковые, ответы разные)
- избыточные (сверхбольшие, не помещаются в память)
- недостаточные (объектов меньше, чем признаков)
- неструктурированные (нет признаков описаний)
- **«грязные» (ошибочные, грубо не соответствующие истине)**

со всем этим
можно
работать 😊

но только не
с грязными
данными! 😞

Необходимые условия применения ИИ

• Полнота, чистота, достоверность данных

- Автоматизация и цифровизация бизнес-процессов
- Улучшение качества данных (от «цифрового чучела» к цифровому двойнику)
- Трудовая и технологическая дисциплина при работе с данными

• Культура постановки задач

- Понимание бизнес-целей и их формализация через измеримые критерии
- Предметная экспертиза вместо «абстрактной веры во всемогущий ИИ»
- Готовность пилотировать новые технологии («data-driven» на всех уровнях)

• Культура анализа данных

- Владение средствами визуализации и понимания данных
- Тщательный анализ ошибок при выборе моделей
- Умение находить «простые но гениальные» решения

Выводы (технологические): о составных частях успеха ИИ

- принцип эмпирической индукции Фрэнсиса Бэкона
- минимизация (и аппроксимация) эмпирического риска
- регуляризация некорректно поставленных задач
- коннекционизм и глубокие нейросетевые архитектуры
- векторизация сложно структурированных данных
- самостоятельное обучение вместо обучения по разметке
- увеличение скорости и параллелизма вычислителей

Выводы (гуманитарные): как относиться к ИИ и его развитию

- ИИ = Имитация Интеллекта, набор технологий, не объект, не субъект
- ИИ начинается с постановки задачи *Дано-Найти-Критерий*
- *Люди* ставят задачу и несут ответственность за её решение, *за чистоту и достоверность данных* — тоже
- *Глубокие нейронные сети* — не аналог мозга человека, а обучаемая векторизация сложно структурированных данных
- *Генеративные модели текста* — не интеллект, а новый языковой интерфейс к знанию человечества содержимому Интернета, с его избыточностью, неточностью, противоречивостью

Рекомендуемые материалы

- *Визильтер Ю. В.* От слабого ИИ к общему универсальному интеллекту (обзор тенденций 2020-2023). Семинар РАИИ и ФИЦ ИУ РАН «Проблемы искусственного интеллекта» 31.01.2024 <https://rutube.ru/video/2aad53ec833f19918c1593398a2a1b88/>
- Не пропустите открытие тысячелетия! // Vital Math, 13 января 2024, <https://www.youtube.com/watch?v=JZjH0it9Jyg>
- Report: AI Decrypted: A Guide for Navigating AI Developments in 2024, January 24, 2024 (Навигатор по ИИ-ландшафту от DENTONS GLOBAL ADVISORS) <https://www.albrightstonebridge.com/news/report-ai-decrypted-guide-navigating-ai-developments-2024>
- 5 идей применения ИИ в вашем бизнесе прямо сейчас, 5 октября 2023. <https://dzen.ru/a/ZR6ZeK5B3lL6OxXv>
- *Воронцов К. В.* Лекции по машинному обучению. www.MachineLearning.ru, 2004-2023.
- *Гарбук С.В., Губинский А.М.* Искусственный интеллект в ведущих странах мира: стратегии развития и военное применение. Знание, 2020.
- *Шумский С. А.* Машинный интеллект. РИОР ИНФРА-М, 2020.



XV Академические чтения, посвященные памяти
академика РААСН Осипова Г.Л.

Научно-практическая конференция «Перспективы использования
искусственного интеллекта в градостроительной деятельности»,
Москва, 2 – 3 июля 2024 г.

Модераторы:

Валерия Мозганова, Радиостанция Business FM, руководитель отдела
«Недвижимость»

Евгений Карант, НИИСФ РААСН, ведущий инженер

Полный список докладов доступен на сайте ЦифраСтрой по ссылке

<https://cifrastroy.ru/news/buduschee-iskusstvennogo-intellekta-v-gradostroitelstve>