



Искусственный интеллект, анализ данных и машинное обучение



ИУ-5

1. История развития машинного обучения. Машинное обучение как часть направления искусственного интеллекта.

Искусственный интеллект,
машинное обучение, наука о
данных, Data Mining, СППР.

Как они соотносятся между
собой?

Искусственный интеллект (Википедия)

- Участники Российской ассоциации искусственного интеллекта дают следующие определения искусственного интеллекта:
 - Научное направление, в рамках которого ставятся и решаются задачи аппаратного или программного моделирования тех видов человеческой деятельности, которые традиционно считаются интеллектуальными.
 - Свойство интеллектуальных систем выполнять функции (творческие), которые традиционно считаются прерогативой человека. При этом интеллектуальная система — это техническая или программная система, способная решать задачи, традиционно считающиеся творческими, принадлежащие конкретной предметной области, знания о которой хранятся в памяти такой системы. Структура интеллектуальной системы включает три основных блока — **базу знаний, решатель и интеллектуальный интерфейс**, позволяющий вести общение с ЭВМ без специальных программ для ввода данных.
 - Наука под названием «Искусственный интеллект» входит в комплекс компьютерных наук, а создаваемые на её основе технологии к информационным технологиям. Задачей этой науки является воссоздание с помощью вычислительных систем и иных искусственных устройств разумных рассуждений и действий.
- Как указывает председатель Петербургского отделения Российской ассоциации искусственного интеллекта Т. А. Гаврилова, в английском языке словосочетание *artificial intelligence* не имеет той слегка фантастической антропоморфной окраски, которую оно приобрело в довольно неудачном русском переводе. Слово *intelligence* означает «умение рассуждать разумно», а вовсе не «интеллект», для которого есть английский аналог *intellect*.
- **Сильный и слабый искусственные интеллекты** — гипотеза в философии искусственного интеллекта, согласно которой некоторые формы искусственного интеллекта могут действительно обосновывать и решать проблемы.
 - теория **сильного** искусственного интеллекта предполагает, что компьютеры могут приобрести способность мыслить и осознавать себя, хотя и не обязательно их мыслительный процесс будет подобен человеческому.
 - теория **слабого** искусственного интеллекта отвергает такую возможность.
- [Временная шкала развития искусственного интеллекта](#)

Дедуктивное и индуктивное обучение

Портал machinelearning.ru предлагает следующие определения:

- **Дедуктивное обучение** предполагает формализацию знаний экспертов и их перенос в компьютер в виде базы знаний. Дедуктивное обучение принято относить к области **экспертных систем**.
- **Обучение по прецедентам**, или **индуктивное обучение**, основано на выявлении общих закономерностей по частным эмпирическим данным. Поэтому термины **машинное обучение** и **обучение по прецедентам** можно считать синонимами.

Дополнительно может быть выделено **гибридное обучение**:

- Гибридная интеллектуальная система работает на основе правил. Правила могут как вноситься в систему экспертом, так и выводиться индуктивно на основе данных.

Экспертные системы (Википедия)

- Основной моделью данных ЭС является продукционное правило в формате антецедент-консеквент (условие-действие). Правила в ЭС закладываются экспертом.
- ЭС в цикле просматривает «операционную память» (текущий набор переменных), смотрит какие правила можно применить на основе текущего набора, применяет правила, получает новый набор переменных.
- ЭС позволяет осуществлять прямой логический вывод на основе правил (от исходных данных к новым данным на основе правил).
- Для ускорения работы используются различные алгоритмы, в частности RETE.
- Разработаны специальные топологии нейронных сетей, позволяющих записывать правила ЭС.
- Существует также обратный логический вывод, в котором на основе заданных целей система пытается подобрать факты из базы знаний, удовлетворяющие этим целям. Наиболее известен язык Prolog. Этот подход можно считать аналогом языков запросов в базах данных.

СППР (википедия)

- Методы слабого ИИ, предназначенные для решения задач конкретных пользователей.
- Может вообще не использовать методы ИИ (используют математические методы).
- Если СППР использует методы ИИ, то ее, как правило, называют интеллектуальной СППР.

Data Mining ([википедия](#))

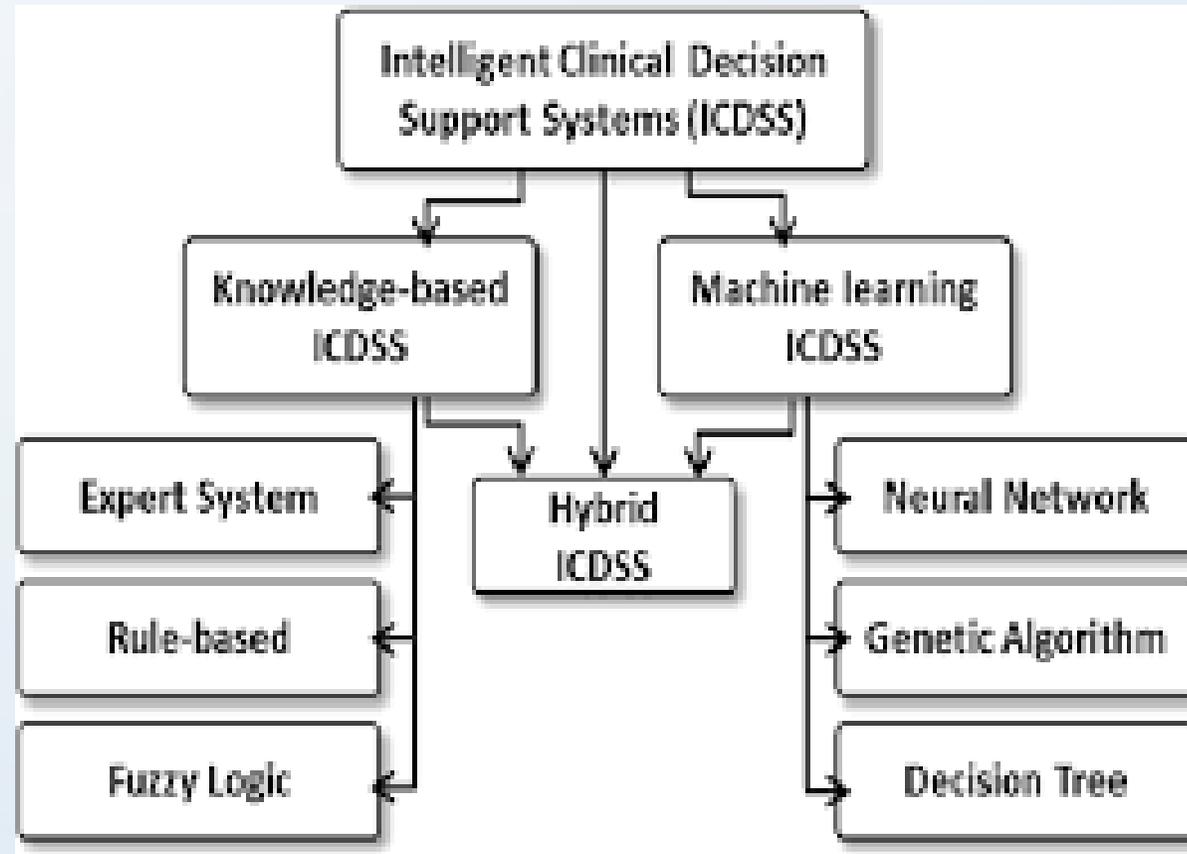
- Интеллектуальный анализ данных. Методы извлечения нетривиальных зависимостей из данных. Методы довольно разрозненные, аспект хранения данных не систематизирован (как правило используется термин «набор данных» - датасет).
- В целом данное направление близко к СППР ([википедия](#)) и ближе к слабому чем к сильному ИИ.
- Данное направление использует методы, наиболее близкие к машинному обучению. Фактически, данный термин предшествовал термину «машинное обучение».

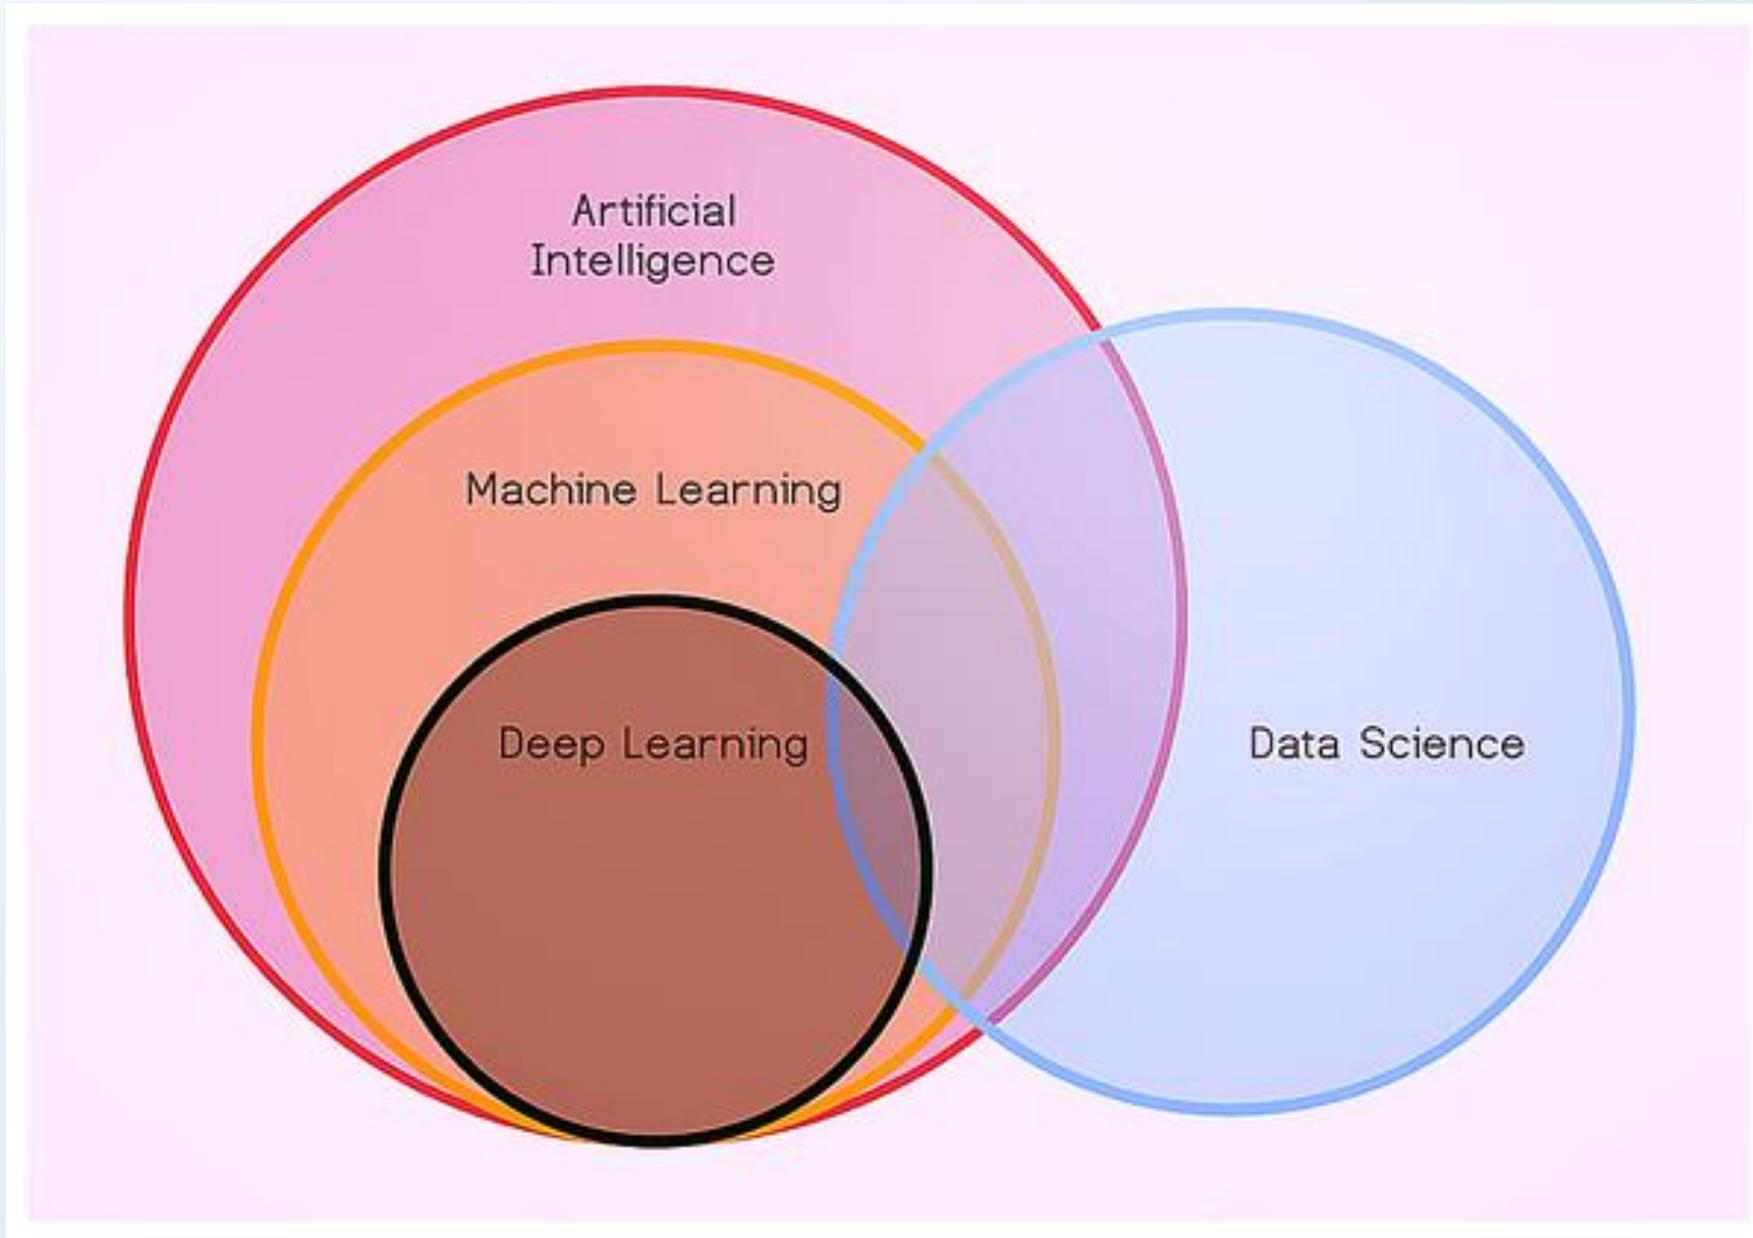
Машинное обучение (википедия)

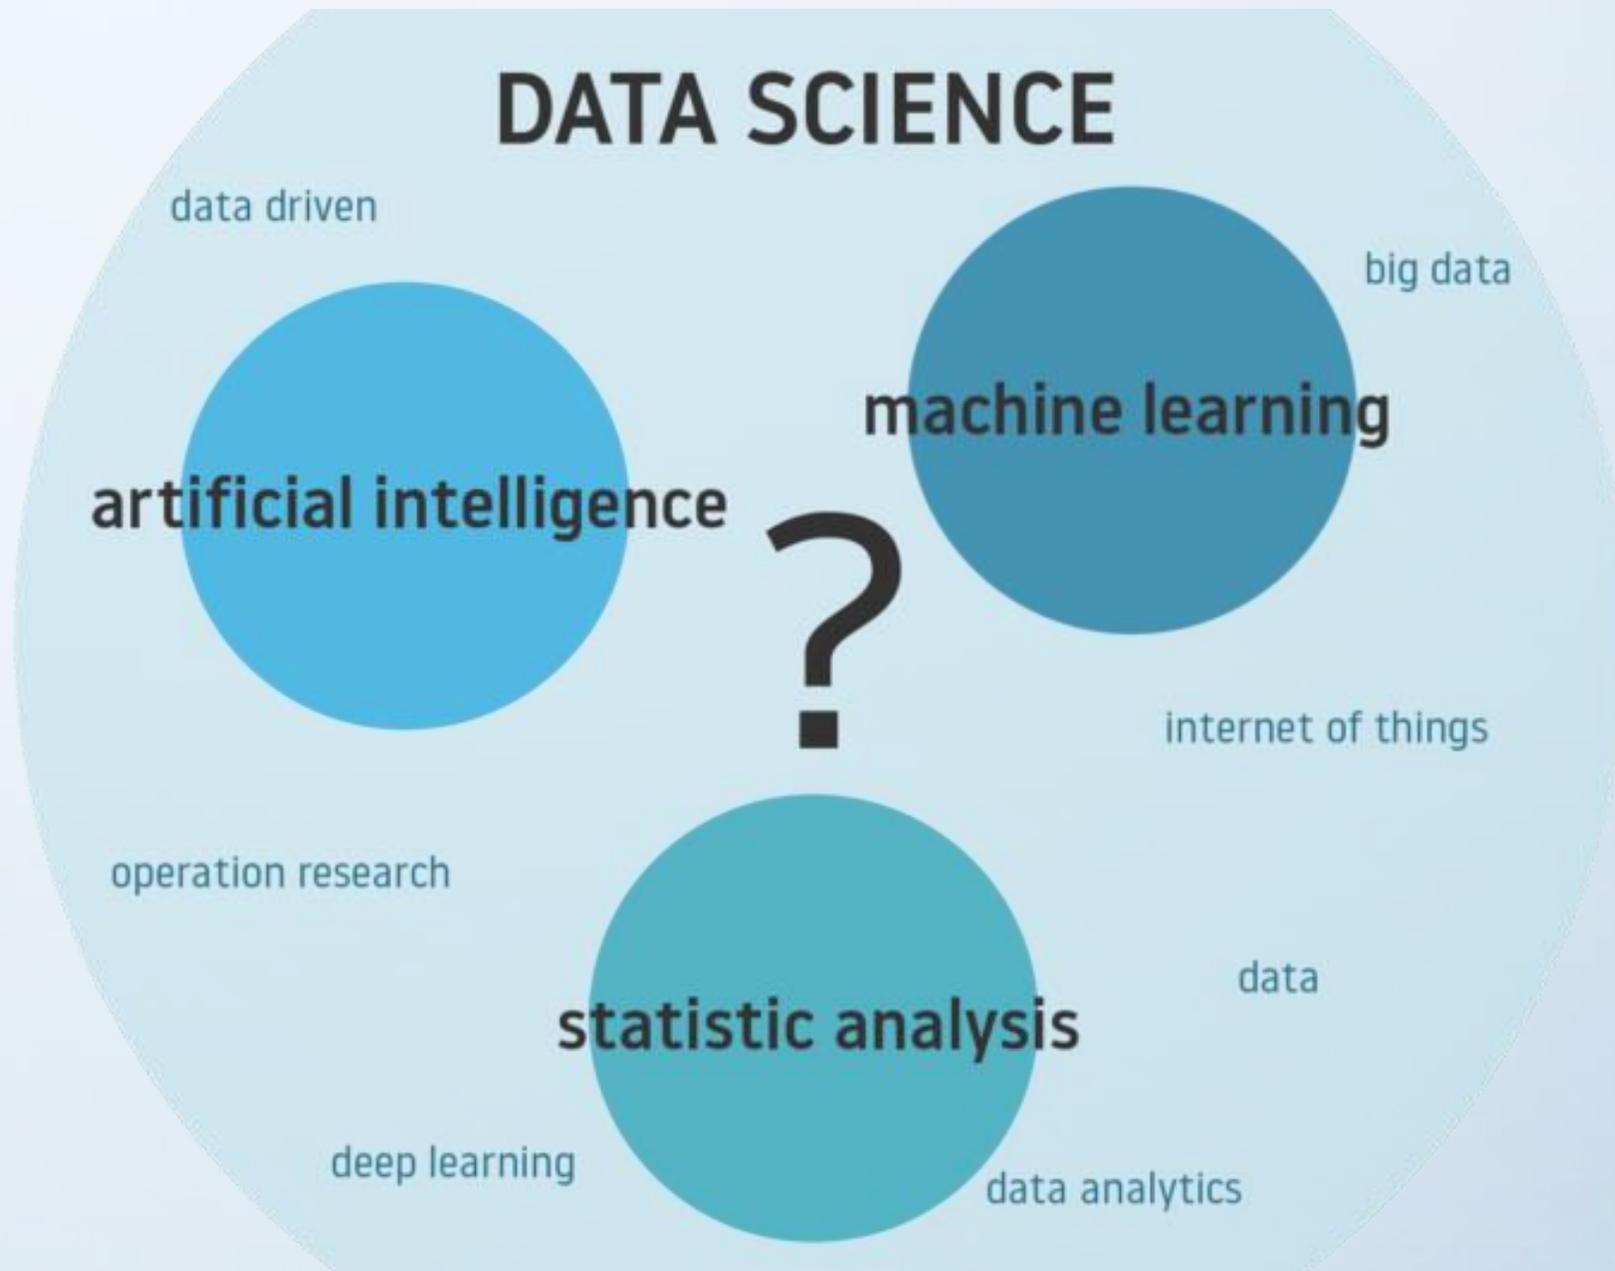
- Machine Learning, ML.
- Фактически является аналогом термина «обучение по прецедентам», который использовался в Data Mining.
- Основная задача – предсказание результата на основе предыдущих накопленных данных. Построение модели на основе накопленных данных называют обучением, поэтому используется термин «машинное обучение».
- Данные могут быть не упорядочены по времени (задачи классификации, регрессии) или упорядочены (прогнозирование временного ряда).
- Является набором наиболее низкоуровневых методов в ИИ. Применяемые алгоритмы очень сильно зависят от набора данных, на разных наборах данных разные алгоритмы могут показывать очень разное качество.
- Фактически основная задача – подобрать алгоритм, который покажет приемлемое качество предсказания на заданном наборе данных и не будет переобучаться.
- Появился лозунг «Data is the new science», то есть накопленные массивы данных определяют характер методов их обработки.

Наука о данных (data science)

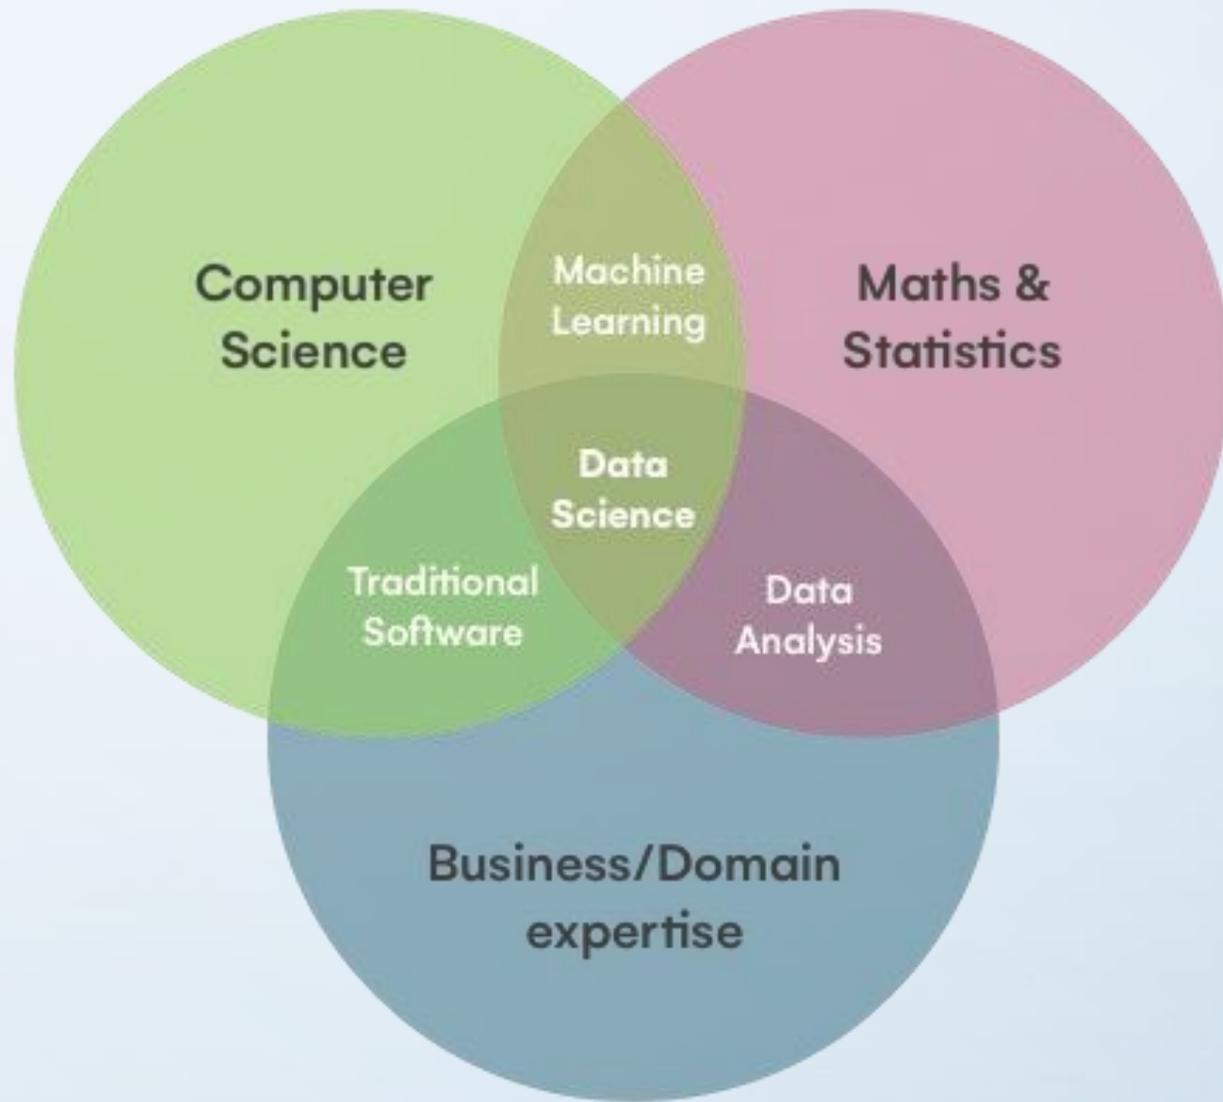
- В соответствии с ([википедия](#)):
 - Наука о данных (иногда даталогия – datalogy) – раздел информатики, изучающий проблемы анализа, обработки и представления данных в цифровой форме.
 - Объединяет методы по обработке данных в условиях больших объёмов и высокого уровня параллелизма, статистические методы, методы интеллектуального анализа данных и приложения искусственного интеллекта для работы с данными, а также методы проектирования и разработки баз данных.



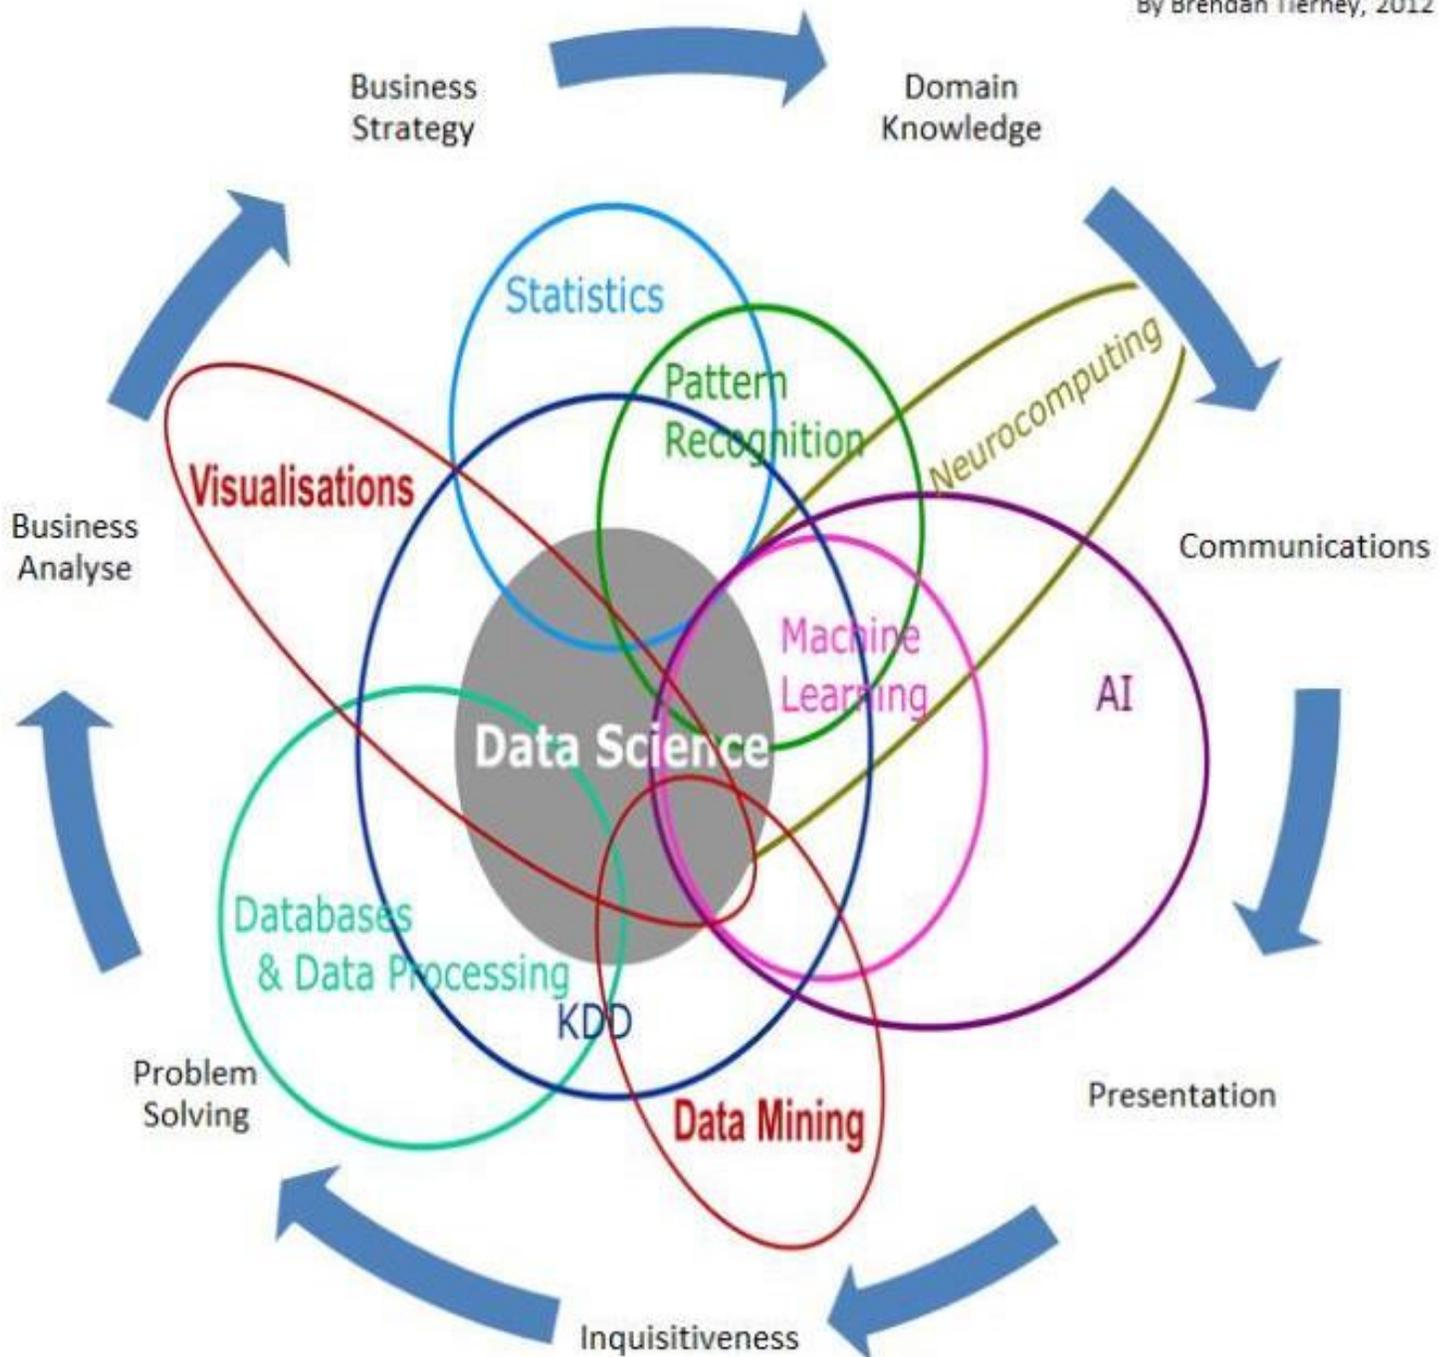




[Artificial intelligence vs data science – Datascience.aero](http://Datascience.aero)



[Data science vs. data analytics \(ironhack.com\)](http://ironhack.com)



[Ссылка на источник](#)

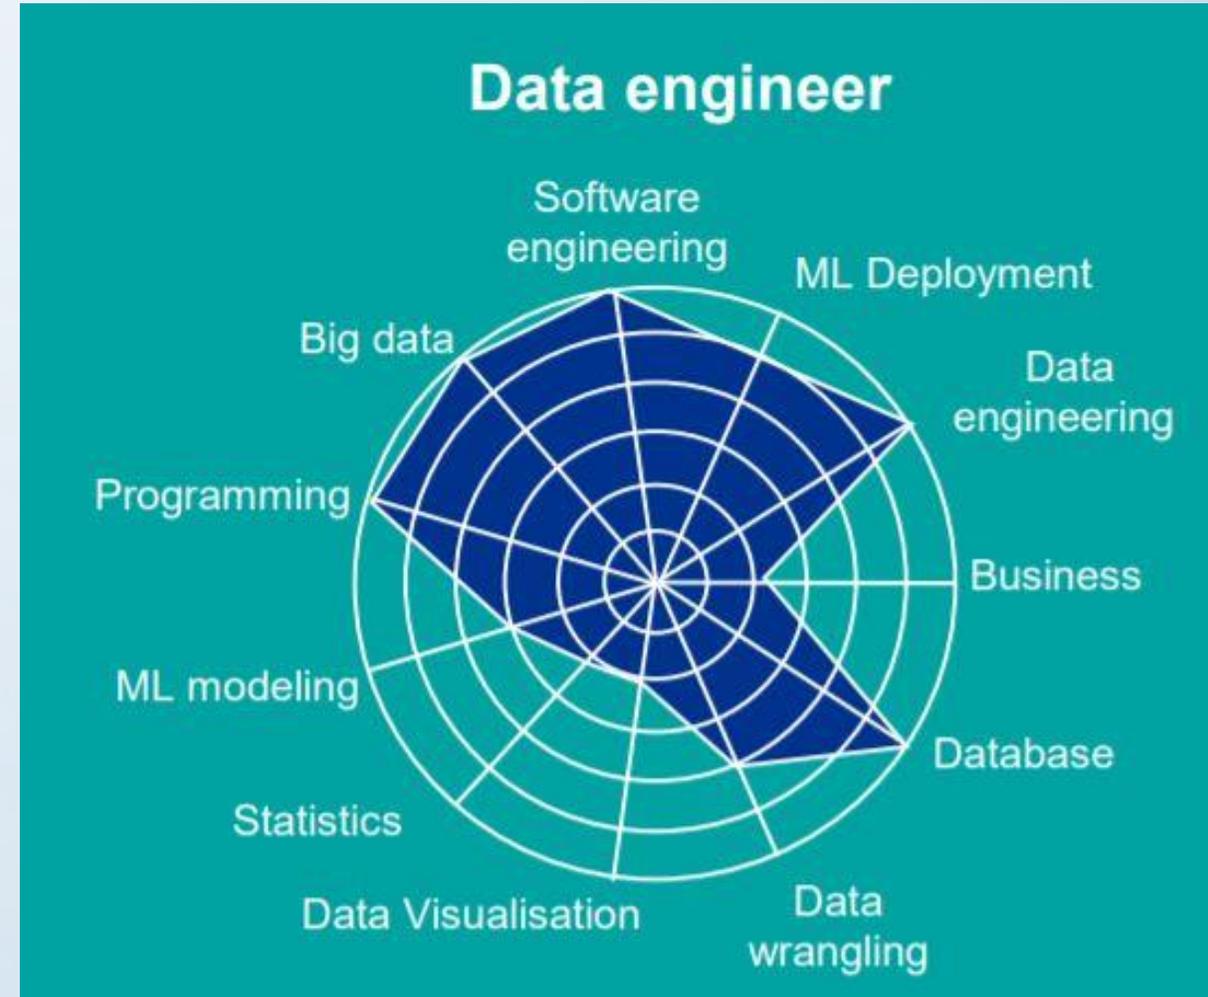
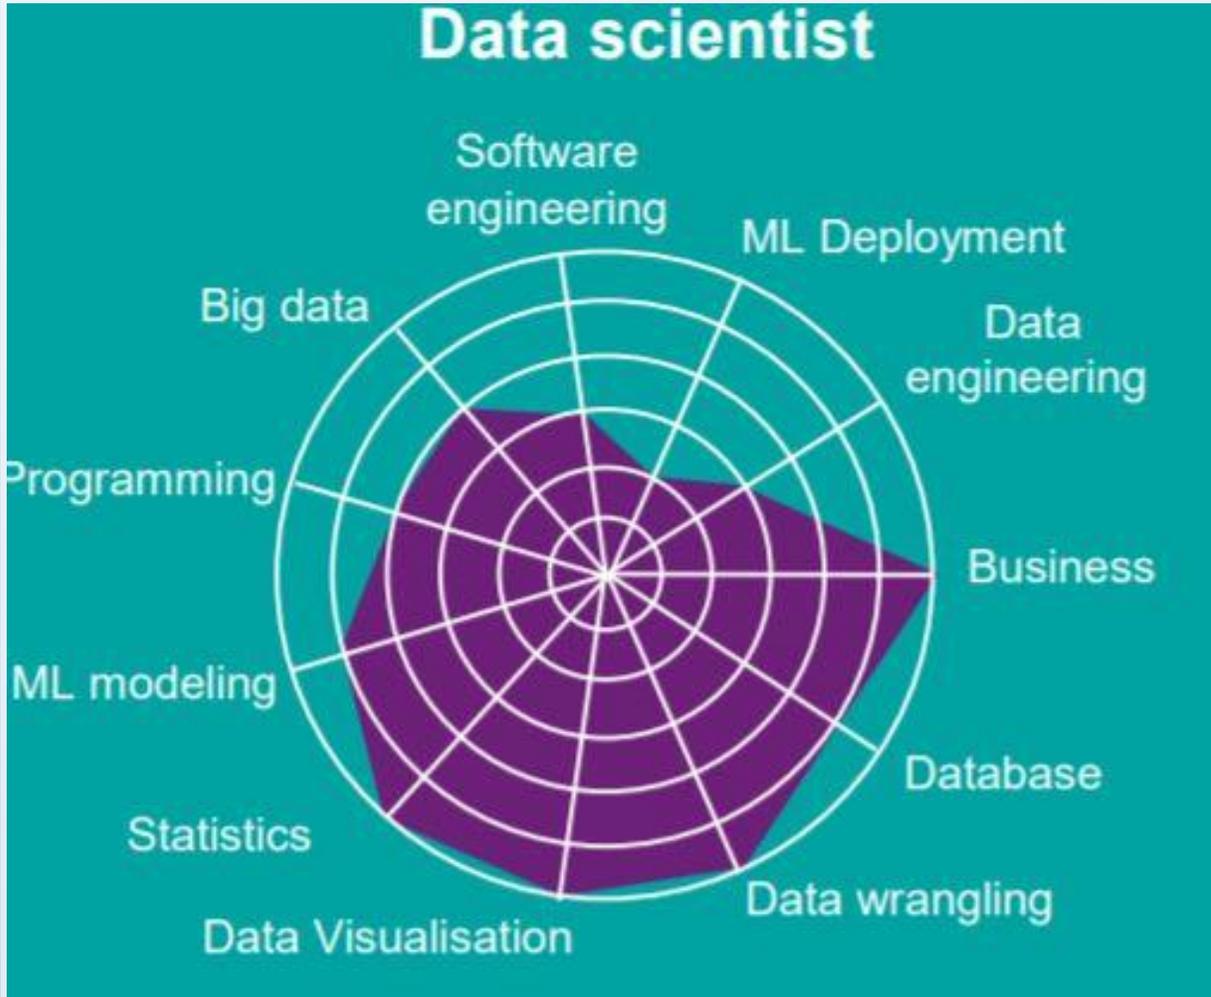
2. Профили специалистов в области анализа данных

Data Scientist и Data Engineer

- Традиционно роль IT-специалиста, выполняющего анализ данных, называют «Data Scientist», то есть специалист по изучению данных и построению моделей, аналитик данных.
- Но данные для анализа нужно где-то хранить, передавать, обрабатывать и т.д. Роль IT-специалиста, которые это обеспечивает называют «Data Engineer».
- В основном роль IT-специалиста «Data Engineer» сейчас связана именно с обработкой больших данных.
- Data Engineer это специалист по базам данных, системный администратор (с хорошим знанием виртуализации и Big Data фреймворков), разработчик ETL-процессов (<https://ru.wikipedia.org/wiki/ETL>).

Data Scientist и Data Engineer - 2

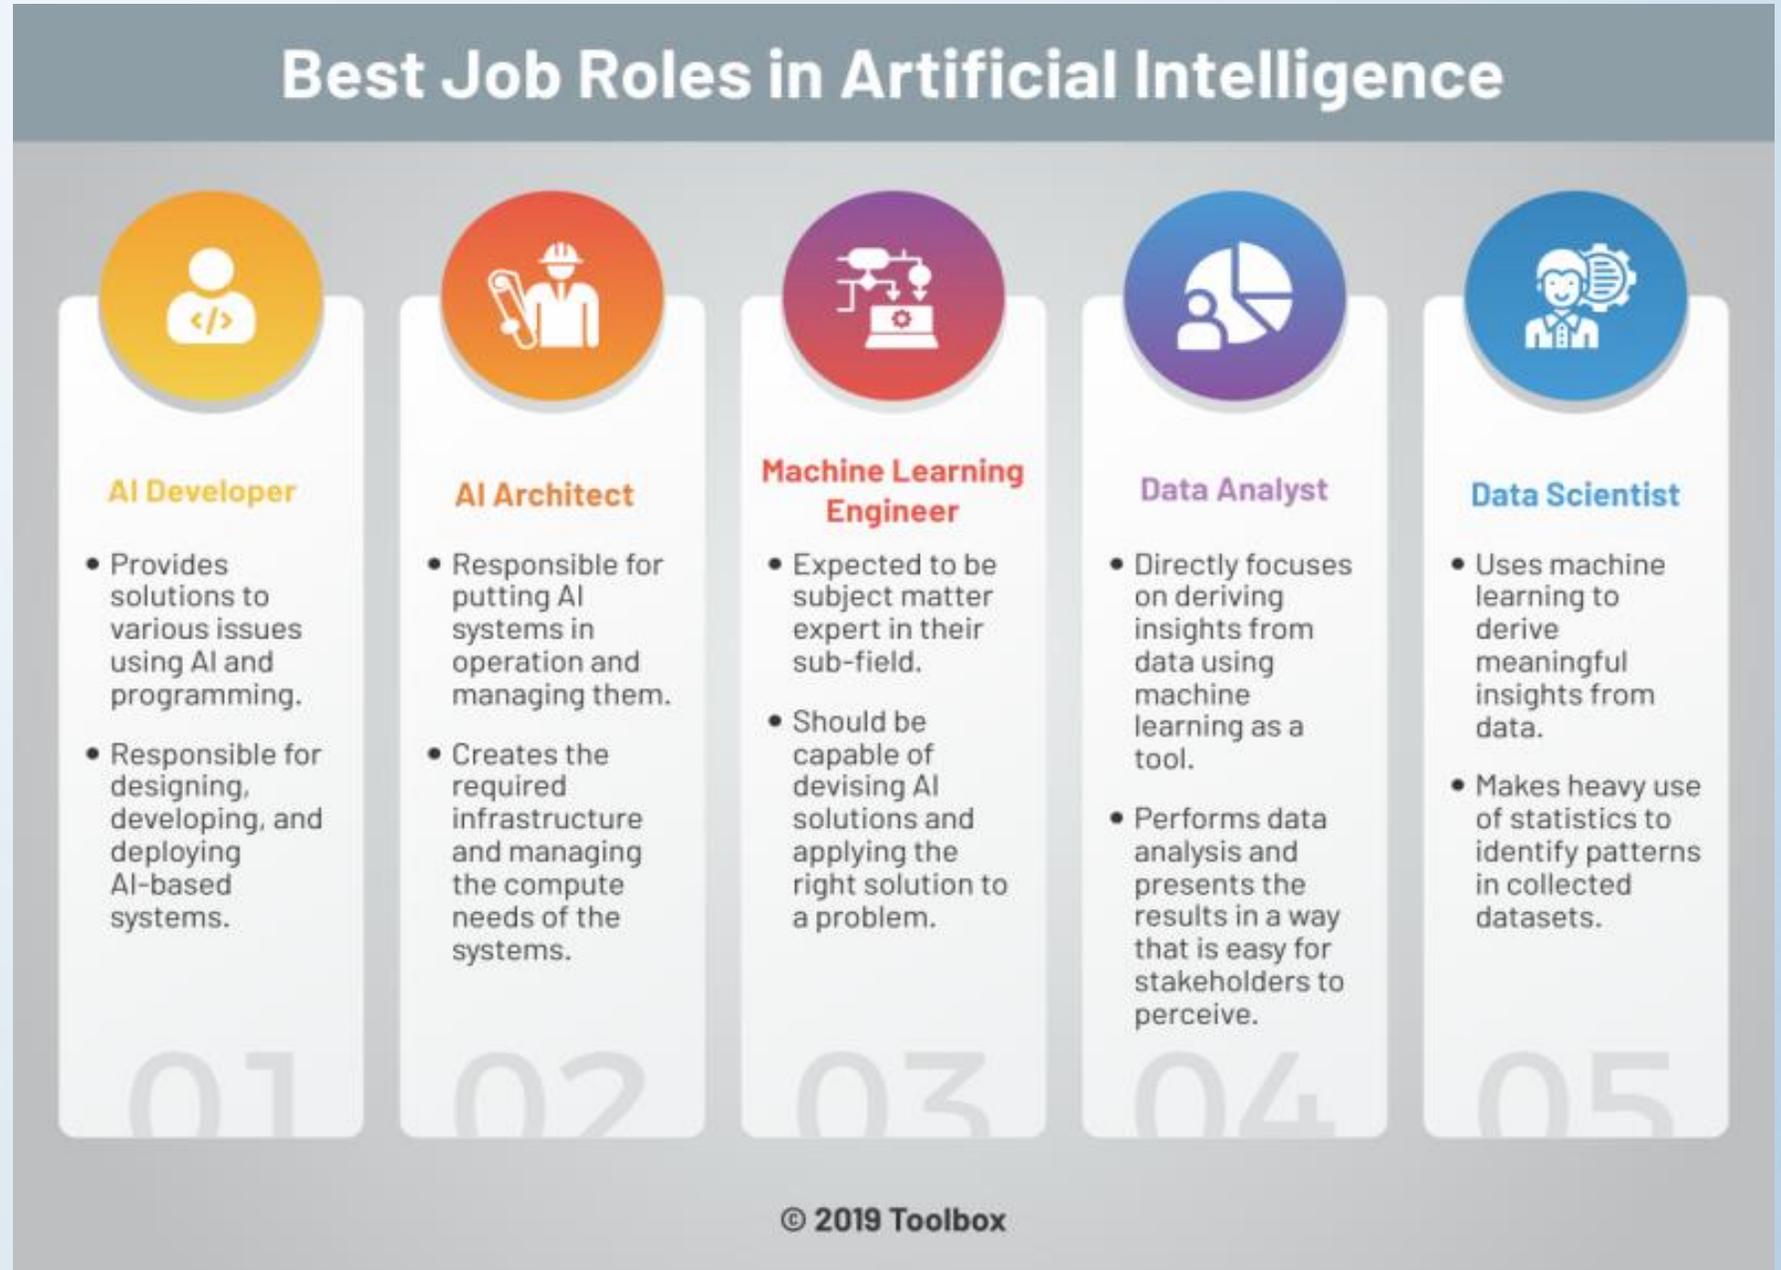
- [Ссылка на статью](#)

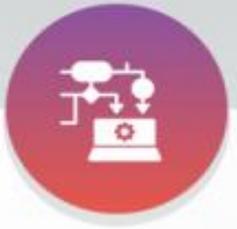


Профили специалистов в области анализа данных

- [Описание 1](#)
- [Описание 2](#)
- [Описание 3:](#)

Best Job Roles in Artificial Intelligence



01	02	03	04	05
 <h3>AI Developer</h3> <ul style="list-style-type: none">• Provides solutions to various issues using AI and programming.• Responsible for designing, developing, and deploying AI-based systems.	 <h3>AI Architect</h3> <ul style="list-style-type: none">• Responsible for putting AI systems in operation and managing them.• Creates the required infrastructure and managing the compute needs of the systems.	 <h3>Machine Learning Engineer</h3> <ul style="list-style-type: none">• Expected to be subject matter expert in their sub-field.• Should be capable of devising AI solutions and applying the right solution to a problem.	 <h3>Data Analyst</h3> <ul style="list-style-type: none">• Directly focuses on deriving insights from data using machine learning as a tool.• Performs data analysis and presents the results in a way that is easy for stakeholders to perceive.	 <h3>Data Scientist</h3> <ul style="list-style-type: none">• Uses machine learning to derive meaningful insights from data.• Makes heavy use of statistics to identify patterns in collected datasets.

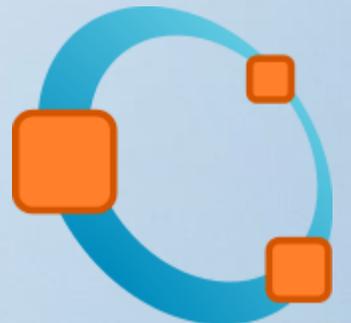
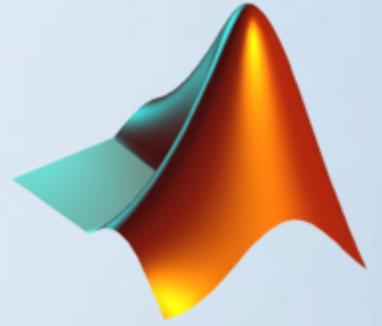
© 2019 Toolbox

3. Языки анализа данных

- Общая особенность всех языков, применяемых для машинного обучения – использование **векторизации вычислений**. Компиляторы (интерпретаторы) реализуют высокую производительность для векторизованных вычислений.
- Алгоритмы работают не с отдельными ячейками данных, а с многомерными массивами, что увеличивает их производительность.
- В некоторых языках векторизация встроена непосредственно в язык, в некоторых реализована с помощью библиотек. В частности в Python векторизация реализована с помощью библиотеки NumPy.
- В Python также для повышения производительности используют элементы функционального программирования.

MATLAB

- Matrix Laboratory - пакет прикладных программ для решения задач технических вычислений и одноименный язык программирования, используемый в этом пакете. Пакет используют более миллиона инженерных и научных работников, он работает на большинстве современных операционных систем, включая Windows, Linux, Mac OS.
- De facto является пакетом №1 для анализа данных и машинного обучения.
- DSL-язык пакета MATLAB ориентирован на математиков. Не предназначен для разработки полнофункциональных программных систем.
- Пакет является проприетарным и платным.
- Существует свободно-распространяемый аналог - GNU Octave, язык которого в целом совместим с MATLAB, но который содержит меньше библиотек и отличается менее высокой производительностью.



R

- R — язык программирования для статистической обработки данных и работы с графикой, а также свободная программная среда вычислений с открытым исходным кодом.
- Изначально был ориентирован на задачи математической статистики, но в настоящее время содержит большое количество пакетов для анализа данных и машинного обучения.
- DSL-язык, ориентированный на математиков. Не предназначен для разработки полнофункциональных программных систем.



Julia



- Высокоуровневый высокопроизводительный свободный язык программирования с динамической типизацией, созданный для математических вычислений. Эффективен также и для написания программ общего назначения.
- Синтаксис языка схож с синтаксисом других математических языков (например, MATLAB и Octave), однако имеет некоторые существенные отличия. Julia написана на Си, C++ и Scheme.
- В стандартный комплект входит JIT-компилятор на основе LLVM, благодаря чему, по утверждению авторов языка, приложения, полностью написанные на языке, практически не уступают в производительности приложениям, написанным на статически компилируемых языках вроде Си или C++. Большая часть стандартной библиотеки языка написана на нём же.
- Также язык имеет встроенную поддержку большого числа команд для распределенных вычислений.
- Преимущества:
 - Производительность;
 - Ориентирован на параллельные вычисления.
- Недостатки:
 - Активно развивается, но пока находится в экспериментальной фазе.

Python



- Высокоуровневый язык программирования общего назначения, ориентированный на повышение производительности разработчика и читаемости кода. Синтаксис ядра Python минималистичен. В то же время стандартная библиотека включает большой объём полезных функций.
- Python поддерживает несколько парадигм программирования, в том числе структурное, объектно-ориентированное, функциональное, императивное и аспектно-ориентированное.
- Как и C++ поддерживает множественное наследование.
- Большинство библиотек является обертками над библиотеками, написанными на C/C++, что обеспечивает хорошую производительность работы библиотек.
- **Как правило, вызов библиотечной функции (написанной на C/C++) намного производительнее аналогичного кода написанного прикладным программистом на Python (особенно если это ML-алгоритм написанный без использования векторизации).**
- Основное преимущество Python состоит в том, что может использоваться и как язык для обработки данных и как язык для разработки приложений (веб-приложений). Это очень облегчает встраивание ML-решений в веб-приложения.

Другие языки

- C, C++ 
- C# 
- F# 
- Golang 
- Rust 

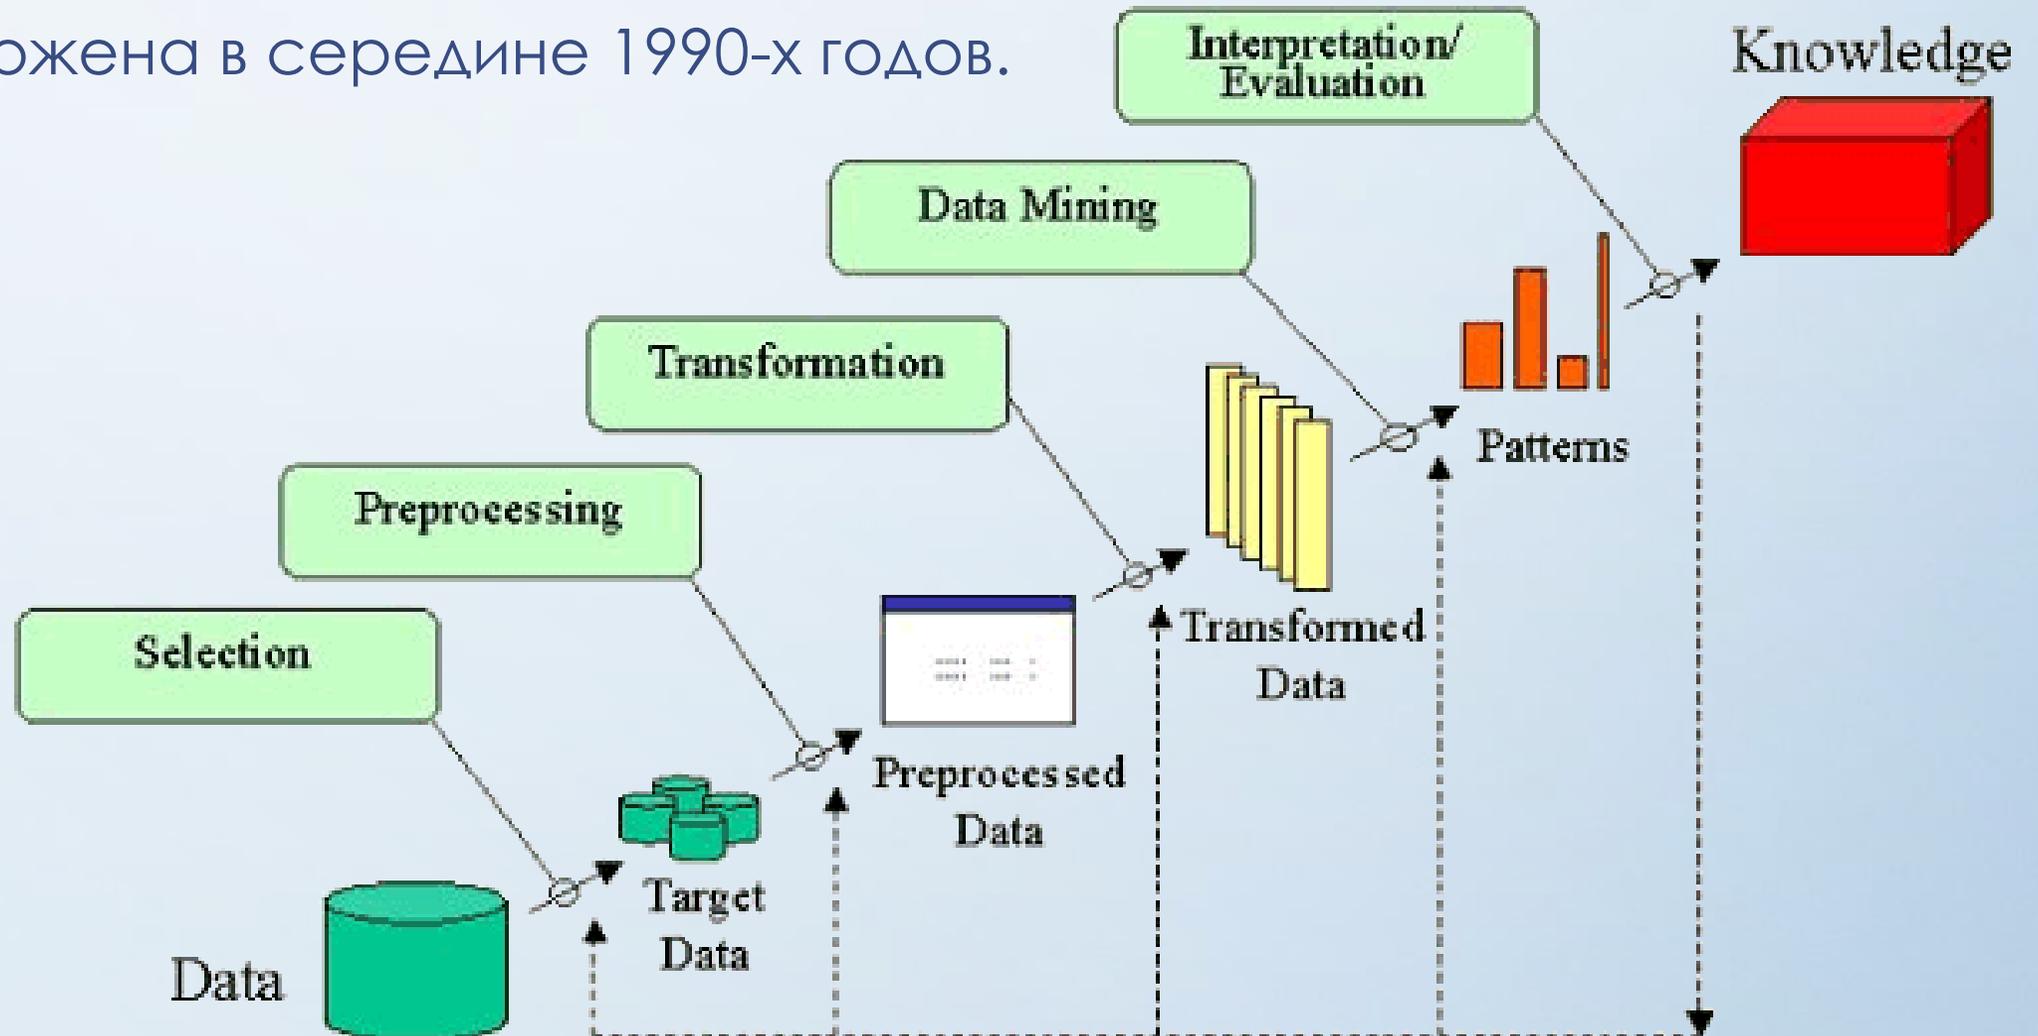
4. Методологии анализа данных

Методология

- В рамках **практического аспекта** (ориентированного на решение практических задач) **методология понимается как совокупность систематизированных определённым образом приёмов и способов организации деятельности**, применяемых в какой-либо области научного или практического знания. **Организовать деятельность означает упорядочить её в целостную систему с чётко определёнными характеристиками, логической структурой и процессом её осуществления (временной структурой)**. В границах обслуживания типовых программ деятельности практически ориентированная методология сводится к обеспечению их нормативно-рационального построения — алгоритмизируется.
 - Источник: <https://gtmarket.ru/concepts/6870>

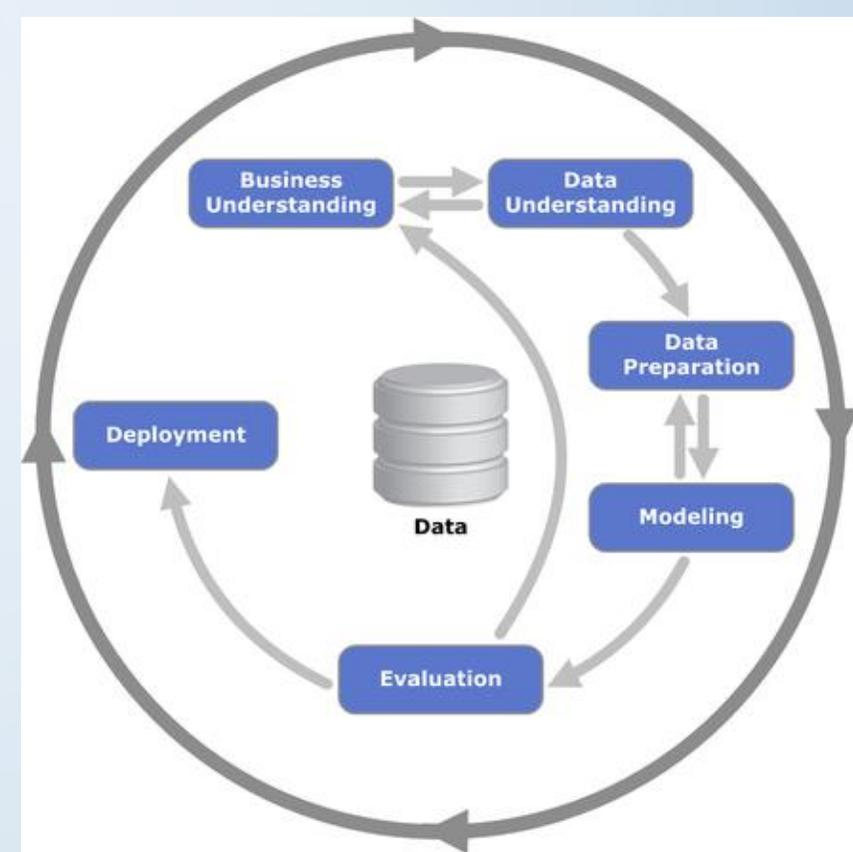
KDD Process

- Методология KDD (Knowledge Discovery in Databases) Process - http://www2.cs.uregina.ca/~dbd/cs831/notes/kdd/1_kdd.html
- Предложена в середине 1990-х годов.



CRISP-DM

- CRISP-DM (Cross-Industry Standard Process for Data Mining – межотраслевой стандартный процесс для исследования данных) – проверенная в промышленности и наиболее распространённая методология по исследованию данных.
- Первые версии предложены в конце 1990-х годов.
- Модель жизненного цикла исследования данных состоит из шести фаз, а стрелки обозначают наиболее важные и частые зависимости между фазами. Последовательность этих фаз строго не определена. Как правило в большинстве проектов приходится возвращаться к предыдущим этапам, а затем снова двигаться вперед. Описание фаз:
 1. Понимание бизнес-целей (Business Understanding)
 2. Начальное изучение данных (Data Understanding)
 3. Подготовка данных (Data Preparation)
 4. Моделирование (Modeling)
 5. Оценка качества модели (Evaluation)
 6. Внедрение (Deployment)

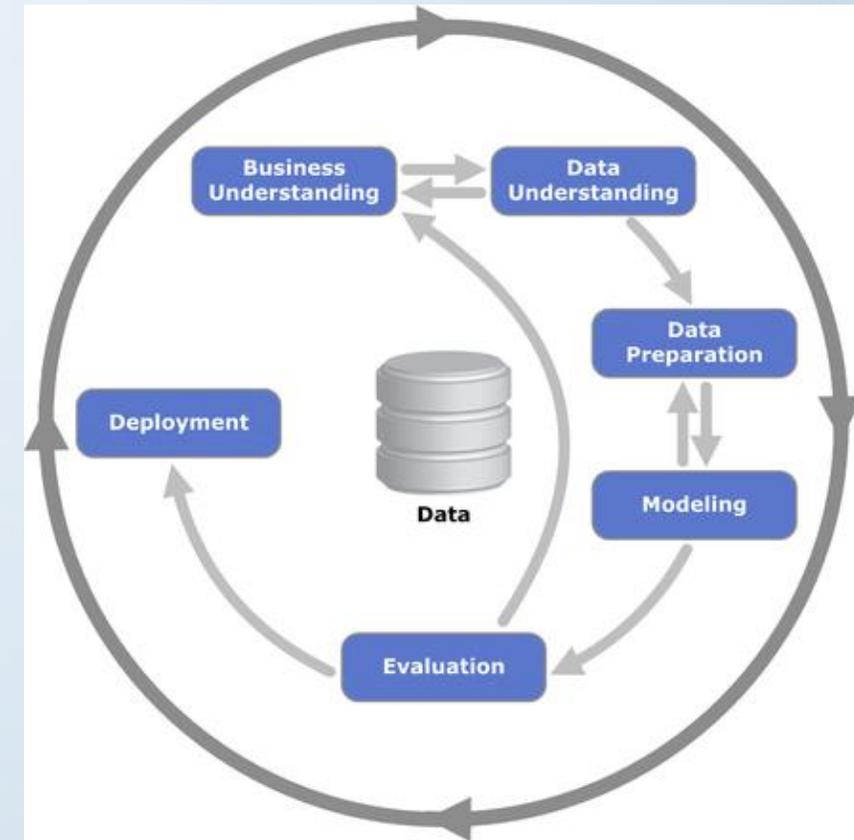


Анализ данных и АСОИУ

- На первый взгляд может показаться что анализ данных и «традиционные» информационные системы являются различными подходами. Так ли это?
- Проектирование АСОИУ (существуют различные модели проектирования: каскадная, спиральная):
 1. Определение целей автоматизации, постановка задач.
 2. Изучение предметной области.
 3. Построение модели (схемы) базы данных (с учетом целей автоматизации) – выделение сущностей, связей, атрибутов.
 4. Разработка информационной системы (автоматизация бизнес-процессов, создание форм, отчетов и т.д.)
 5. Оценка качества разработанной системы (тестирование, проверка работоспособности, моделирование нагрузки).
- Постановка и решение задачи анализа данных:
 1. Понимание бизнес-целей. Определение целей анализа данных.
 2. Начальное изучение данных (первичное изучение набора данных, первичная визуализация данных).
 3. Подготовка данных. Очистка данных, удаление аномалий. Выделение из исходных данных признаков (features) для решения задачи:
 - feature extraction – «технический» процесс выделения признаков, например из текстов или изображений.
 - feature engineering – «смысловое» выделение и синтез признаков, которые позволят получить наилучшее качество решения задачи.
 - Кодирование признаков (прежде всего категориальных).
 4. Моделирование. Разработка модели в терминах алгоритмов машинного обучения (применение одного или нескольких алгоритмов).
 5. Оценка качества разработанной модели (с помощью методов оценки качества, используемых в машинном обучении).
- При проектировании АСОИУ акцент делается на «накопленные» пользователем бизнес процессы (в каком порядке и какие данные вводятся в формы ввода и сохраняются в БД, какие формируются отчеты и т.д.)
- При решении задачи анализа данных акцент делается на «накопленные» пользователем данные. Как помочь пользователю извлечь пользу из накопленных им данных. Какие нетривиальные зависимости можно найти. Какие решения можно помочь принять. Задачу анализа данных можно рассматривать как элемент СППР.
- Решение задачи машинного обучения можно рассматривать как частный случай АСОИУ, где мы помогаем пользователю в решении задач, на основе накопленных им данных. Здесь работают как Data Scientist, так и Data Engineer.

CRISP-DM и машинное обучение (анализ датасетов)

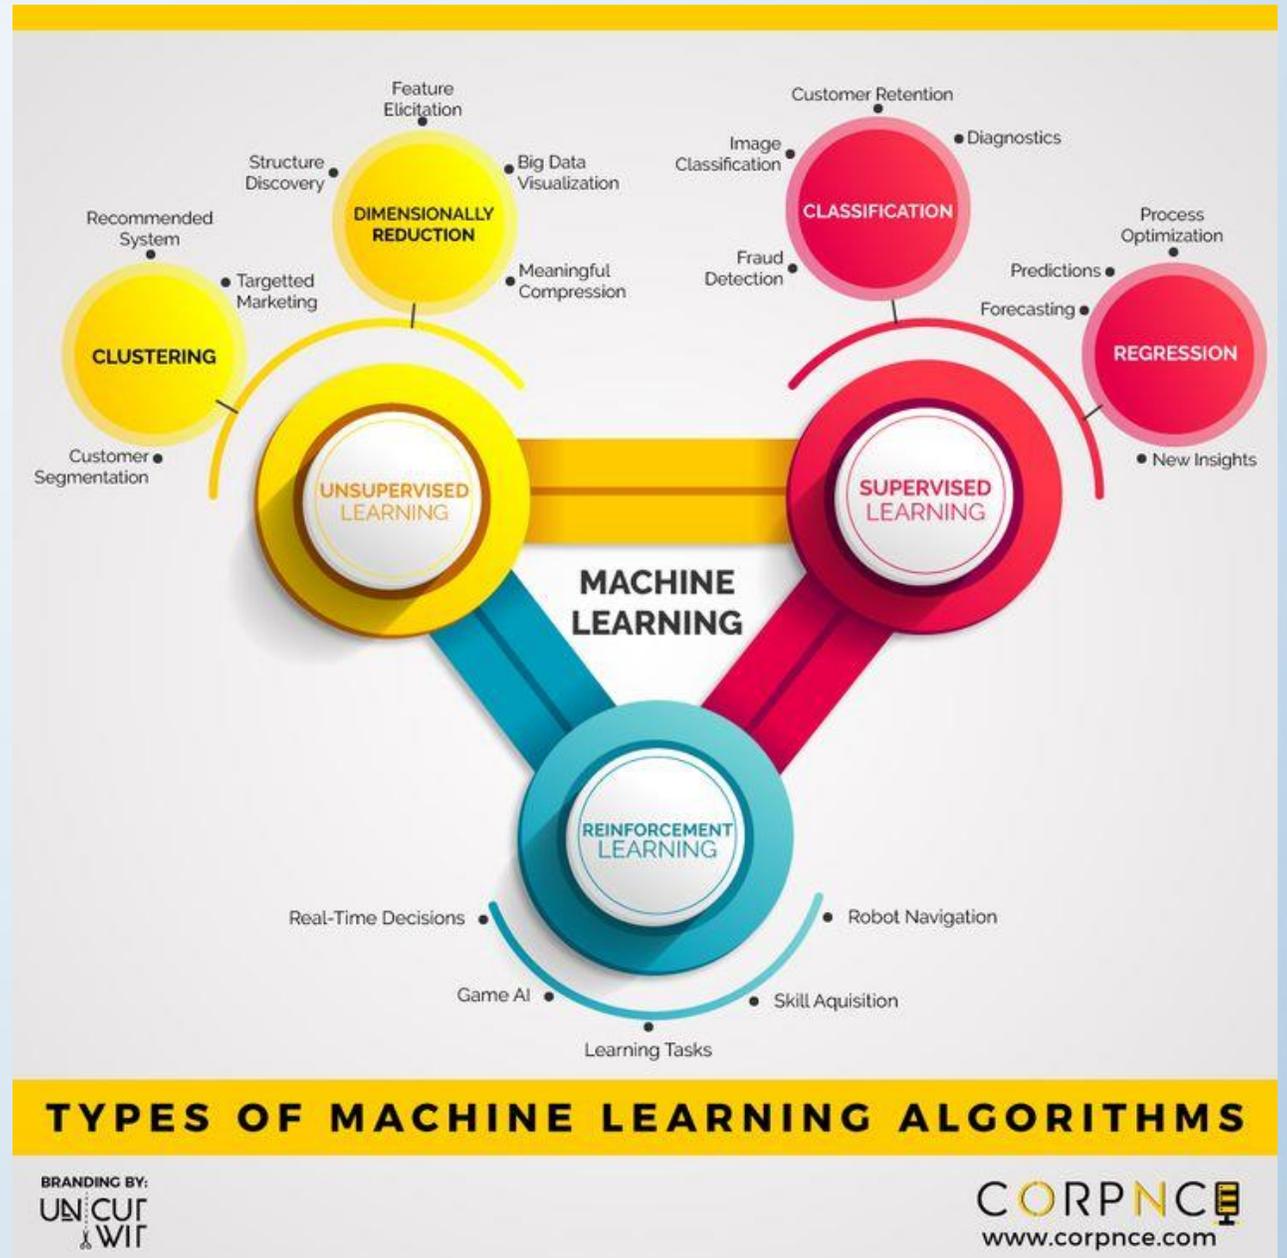
1. **Понимание бизнес-целей (Business Understanding)** – НЕТ. Как правило, на этапе решения задачи машинного обучения цель уже задана.
2. Начальное изучение данных (Data Understanding) – ДА. Первичное изучение набора данных, первичная визуализация данных.
3. Подготовка данных (Data Preparation) – ДА. Очистка данных, удаление аномалий. Выделение из исходных данных признаков (features) для решения задачи.
4. Моделирование (Modeling) – ДА. Разработка модели в терминах алгоритмов машинного обучения.
5. Оценка (Evaluation) – ДА. Оценка качества разработанной модели с помощью методов оценки качества, используемых в машинном обучении.
6. **Внедрение (Deployment) MLOps** – НЕТ.



5. Базовые задачи машинного обучения

Типы («Классификация») задач ML

- Обучение с учителем (supervised learning)
 - Классификация
 - Регрессия
 - Прогнозирование временных рядов
- Обучение без учителя (unsupervised learning)
 - Кластеризация
 - Методы понижения размерности
- Обучение с подкреплением (reinforcement learning)
- [Карта методов scikit-learn](#)



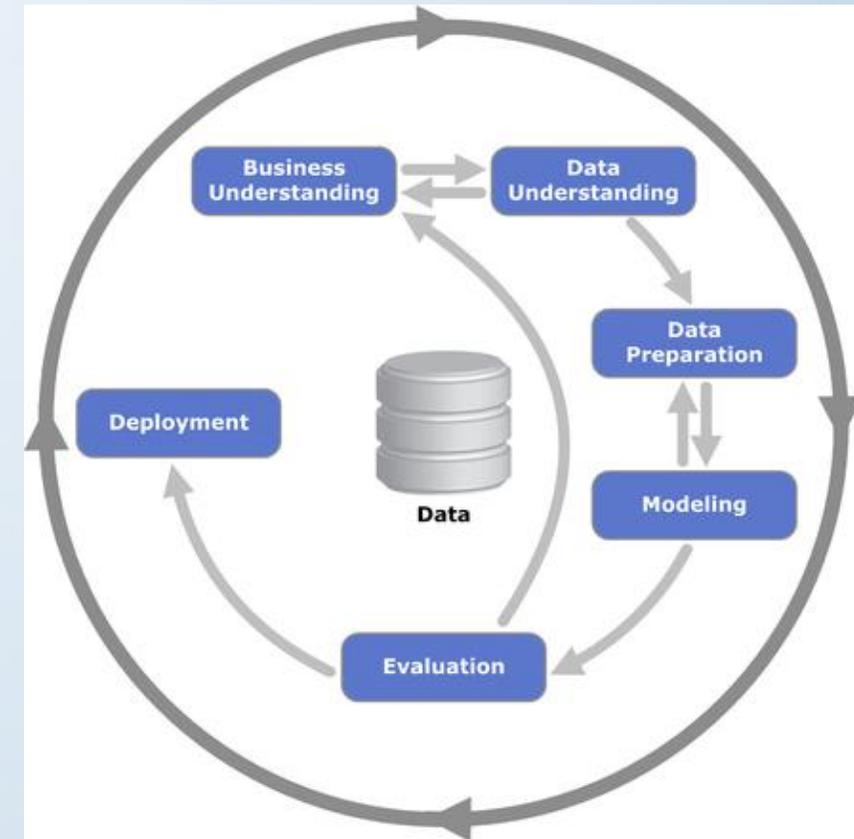
Некоторые типы шкал измерений

- **Количественный (действительный) признак, который является действительным числом. Основной вид шкалы, к которому пытаются свести все остальные.**
- **Качественный (категориальный) признак.**
 - Номинальная шкала (шкала наименований, классификационная шкала), по которой объектам дается некоторый признак (производится классификация объектов по этому признаку). Название «номинальный» объясняется тем, что такой признак дает лишь ничем не связанные имена объектам. Примерами измерений в номинальном типе шкал могут служить номера автомашин, телефонов, коды городов, объектов и т.д. **(Nominal variable). Способ кодирования - One-Hot Encoding.**
 - Частный случай – бинарная шкала $\{0, 1\}$, $\{\text{False}, \text{True}\}$. **(Dichotomous variable)**
 - Шкала называется ранговой (шкала порядка), если множество ее значений состоит из монотонно возрастающих чисел. При этом нет метрики, по которой можно сказать насколько одно значение больше или меньше другого. Примером шкалы порядка может служить шкала твердости минералов (предложенная в 1811 г. немецким ученым Ф. Моосом), шкала силы ветра, сортности товаров в торговле, различные социологические шкалы и т.д. **(Ordinal variable). Способ кодирования - Label Encoding.**



CRISP-DM и машинное обучение (анализ датасетов)

1. **Понимание бизнес-целей (Business Understanding)** – НЕТ. Как правило, на этапе решения задачи машинного обучения цель уже задана.
2. Начальное изучение данных (Data Understanding) – ДА. Первичное изучение набора данных, первичная визуализация данных.
3. **Подготовка данных (Data Preparation)** – ДА. **Очистка данных, удаление аномалий. Выделение из исходных данных признаков (features) для решения задачи.**
4. Моделирование (Modeling) – ДА. Разработка модели в терминах алгоритмов машинного обучения.
5. Оценка (Evaluation) – ДА. Оценка качества разработанной модели с помощью методов оценки качества, используемых в машинном обучении.
6. **Внедрение (Deployment)** – НЕТ. Оставим эту задачу дата-инженерам.



Данные

и

признаки

Табличные данные (объекты-атрибуты)

Атрибуты (свойства, поля данных)

Город	Год рождения	Доход	Пол
Москва	1990	100,00	Ж
Курск	1975	85,3	М
Москва	1983	40,5	Ж
Брянск	1960	90,5	М

Объекты

номинальная шкала шкала порядка действительный признак бинарная шкала



Признаки

Город	Год рождения	Доход	Пол
1	1990	100,00	0
2	1975	85,3	1
1	1983	40,5	0
3	1960	90,5	1

Объекты

Текстовые данные (тексты-слова)



Изображения (изображения-пиксели)

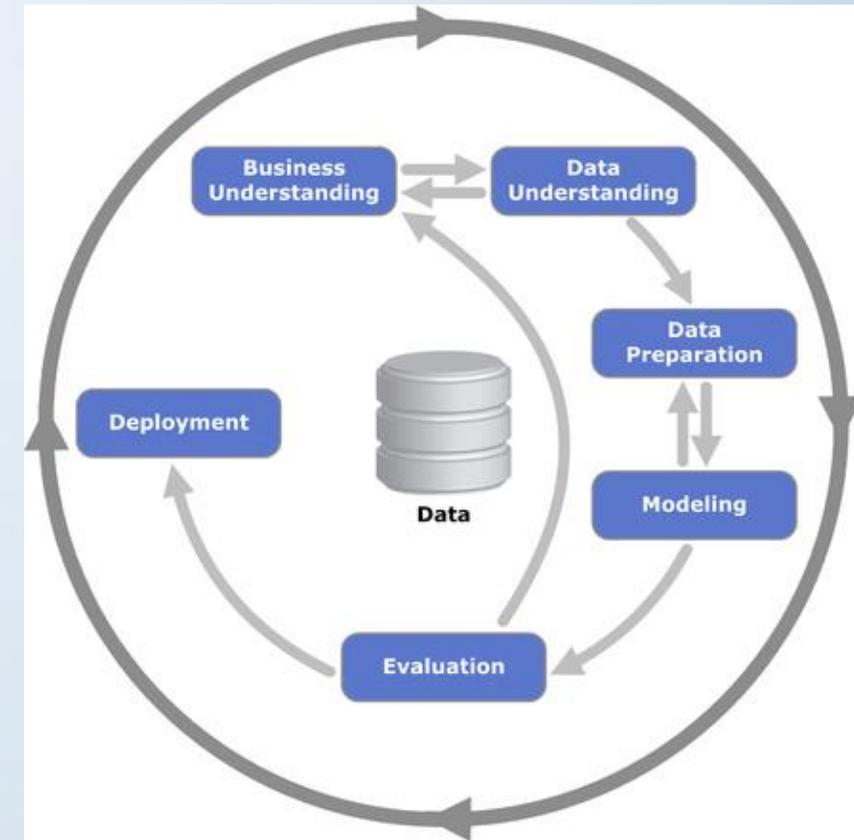


Формирование признаков
(feature engineering)

- Матрица объекты-признаки (feature data)
- Эту матрицу традиционно обозначают буквой X.

CRISP-DM и машинное обучение (анализ датасетов)

1. **Понимание бизнес-целей (Business Understanding)** – НЕТ. Как правило, на этапе решения задачи машинного обучения цель уже задана.
2. Начальное изучение данных (Data Understanding) – ДА. Первичное изучение набора данных, первичная визуализация данных.
3. Подготовка данных (Data Preparation) – ДА. Очистка данных, удаление аномалий. Выделение из исходных данных признаков (features) для решения задачи.
4. **Моделирование (Modeling)** – ДА. **Разработка модели в терминах алгоритмов машинного обучения.**
5. **Оценка (Evaluation)** – ДА. **Оценка качества разработанной модели с помощью методов оценки качества, используемых в машинном обучении.**
6. **Внедрение (Deployment)** – НЕТ. Оставим эту задачу дата-инженерам.



Обучение с учителем (на примере регрессии)

- Каждой строке матрицы X ставится в соответствие значение столбца ответов Y .
 Y -действительный (непрерывный) признак.

Признаки (X)				Объекты	Ответы (Y)
Город	Год рождения	Доход	Пол		Доход в будущем периоде
1	1990	100,00	0	120,05	
2	1975	85,3	1	87,30	
1	1983	40,5	0	55,20	
3	1960	90,5	1	87,40	
обучающая выборка					
2	1965	97,5	1	НУЖНО ПРЕДСКАЗАТЬ	
тестовая выборка					

- Ответы на тестовой выборке могут быть известны, но аналитику данных их не дают, заказчик может использовать их для итогового тестирования.
- Признаки на обучающей и тестовой выборке должны быть одинаково закодированы.**
- Обучение с учителем происходит в две фазы:
 - Собственно обучение. $M = \text{Alg.fit}(X_{\text{обуч}}, Y_{\text{обуч}}, H)$. Используемый нами алгоритм Alg строит модель соответствия M между $X_{\text{обуч}}$ и $Y_{\text{обуч}}$ с учетом гиперпараметров алгоритма H .
 - Предсказание. $Y_{\text{тест}} = \text{Alg.predict}(M, X_{\text{тест}})$.
- Гиперпараметры алгоритма – параметры, значение которых задается до начала обучения (значение остальных параметров настраивается в процессе обучения). У каждого алгоритма гиперпараметры свои, для их правильной настройки используются специальные методы, в частности перебор по сетке (grid search).
- Модель соответствия M можно рассматривать как функцию $f: Y=f(X)$. Но в более общем виде стоит рассматривать M как морфизм из теории категорий (введение в теорию категорий).

Оценка качества (на примере регрессии)

- Идея всех методов оценки качества состоит в том, чтобы понять насколько велика ошибка предсказания алгоритма, насколько хорошо или плохо он предсказывает. Разница только в используемых метриках.
- $M = \text{Alg.fit}(X_{\text{обуч}}, Y_{\text{обуч}}, H)$. $\hat{Y}_{\text{обуч}} = \text{Alg.predict}(M, X_{\text{обуч}})$. $\hat{Y}_{\text{обуч}}$ – результат работы алгоритма на обучающей выборке.
- При оценке качества стараются учесть возможное переобучение модели.
- Наиболее простая метрика – среднеквадратичная ошибка:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

Классификация

- Бинарная классификация (Y-значение по бинарной шкале)

Признаки (X)				Объекты	Ответы (Y)
Город	Год рождения	Доход	Пол		Переедет в другой город?
1	1990	100,00	0		1 (Да)
2	1975	85,3	1		0 (Нет)
1	1983	40,5	0		0 (Нет)
3	1960	90,5	1		1 (Да)
обучающая выборка					
2	1965	97,5	1		НУЖНО ПРЕДСКАЗАТЬ
тестовая выборка					

- Многоклассовая классификация ([Multiclass classification](#)). Y-значение по номинальной или ранговой шкале, Label Encoding.

Признаки (X)				Объекты	Ответы (Y)
Город	Год рождения	Доход	Пол		В какой город переедет?
1	1990	100,00	0		2
2	1975	85,3	1		2
1	1983	40,5	0		1
3	1960	90,5	1		1
обучающая выборка					
2	1965	97,5	1		НУЖНО ПРЕДСКАЗАТЬ
тестовая выборка					

- Многометочная классификация ([Multi-label classification](#)) Y-множество значений по номинальной шкале, Label Encoding. Предсказывается несколько значений классов.

Признаки (X)				Объекты	Ответы (Y)
Город	Год рождения	Доход	Пол		В какой город переедет?
1	1990	100,00	0		2, 3
2	1975	85,3	1		2
1	1983	40,5	0		1
3	1960	90,5	1		1, 3
обучающая выборка					
2	1965	97,5	1		НУЖНО ПРЕДСКАЗАТЬ
тестовая выборка					

- Метрика качества – точность ([accuracy](#)) – доля правильно предсказанных меток классов.

Обучение без учителя (на примере кластеризации)

- Обучающей выборки нет.
- Для каждой строки матрицы X алгоритм пытается предсказать значение метки (номера) кластера Y .
- $Y = \text{Alg.fit_predict}(X, H)$. Используется алгоритм Alg с набором гиперпараметров H .
- Метрики оценки качества базируются на оценке расстояний между получившимися кластерами.
- Одним из наиболее сложных и интересных методов обучения без учителя являются самоорганизующиеся карты Кохонена.
- Другой важной задачей обучения без учителя является задача снижения (понижения) размерности данных.



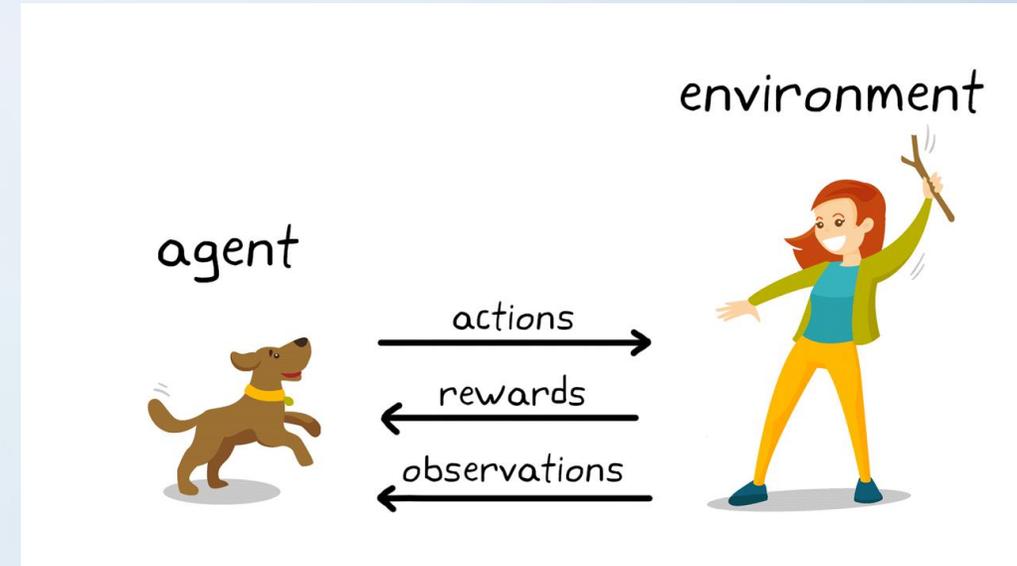
Обучение с подкреплением

- Reinforcement Learning – RL.
- Обучение с обратной связью, с опосредованным учителем.
- Алгоритм обучается, взаимодействуя с некоторой средой. Откликом среды являются сигналы подкрепления, поэтому такое обучение является частным случаем обучения с учителем, но учителем является среда или её модель.
- Частным случаем обучения с подкреплением является Q-обучение.

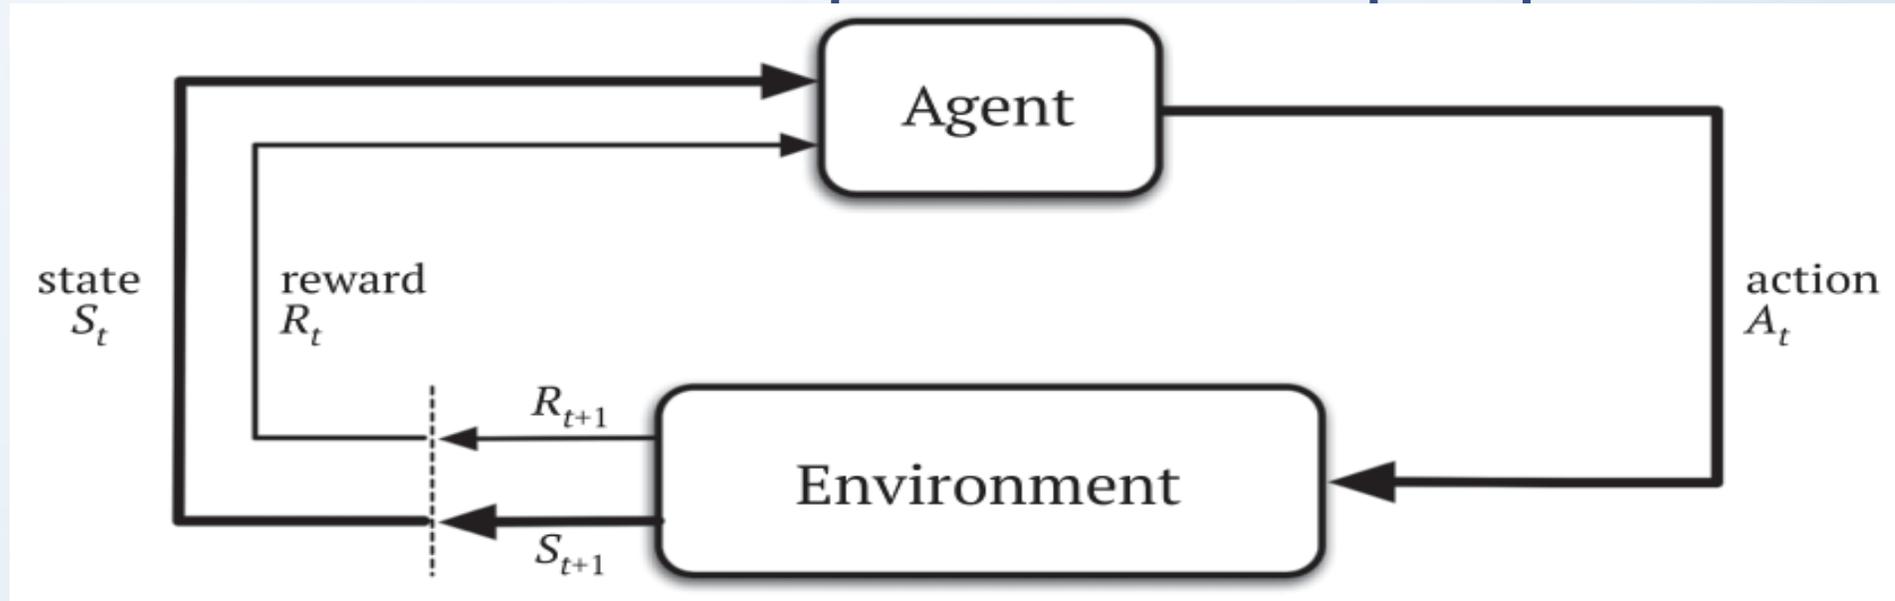


Типичный алгоритм RL неформально

1. Агент взаимодействует со средой, выполняя действие.
2. Агент выполняет действие и переходит из одного состояния в другое.
3. Агент получает награду на основании выполненного действия.
4. В зависимости от награды агент понимает, было действие хорошим или плохим.
5. Если действие было хорошим, то есть если агент получил положительную награду, то агент предпочитает выполнить это действие еще раз.
6. В противном случае агент пытается выполнить другое действие, приводящее к положительной награде. Таким образом, по сути, происходит процесс обучения методом проб и ошибок.



Типичный алгоритм RL формально

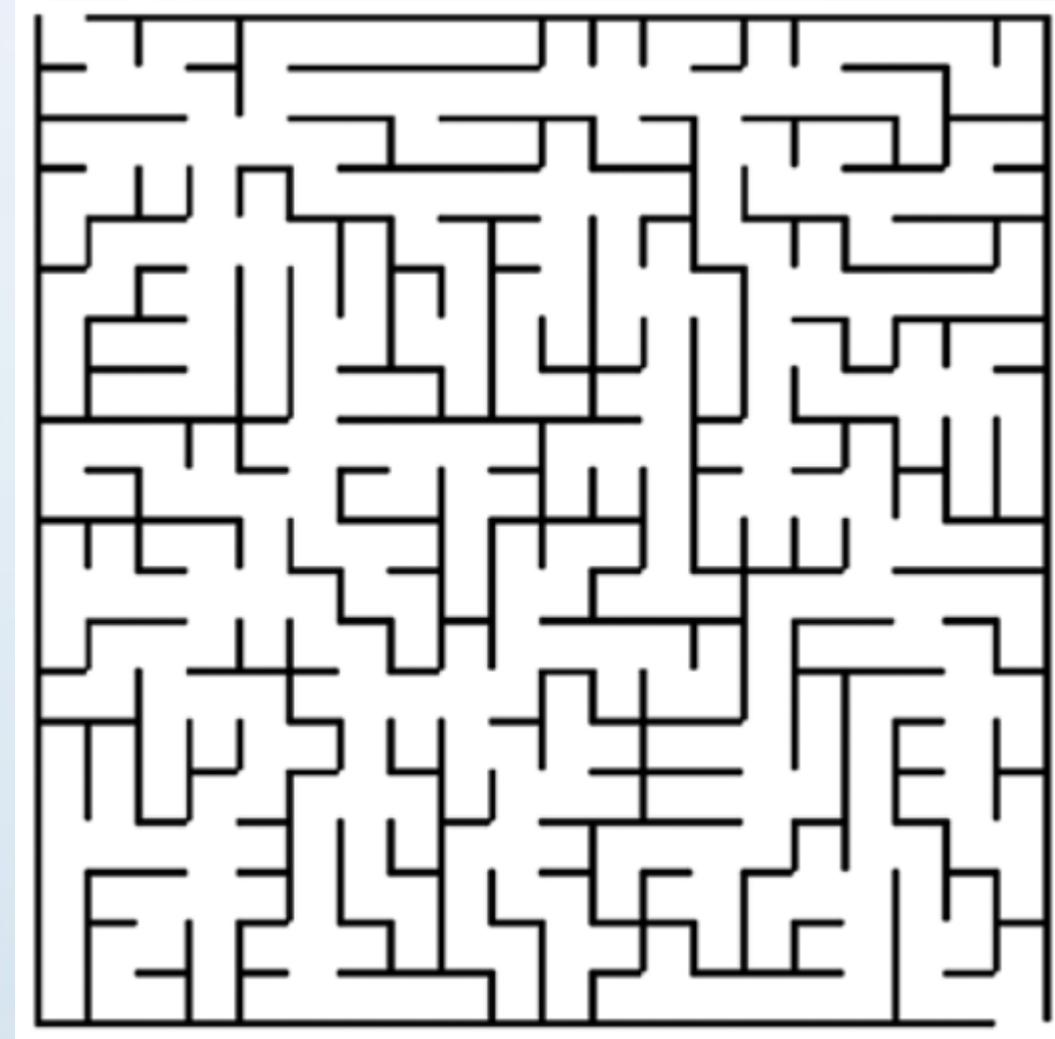


Взаимодействие между агентом и окружающей средой в марковском процессе принятия решений.

- Агент и среда взаимодействуют на каждом шаге дискретной последовательности временных шагов, $t = 0, 1, 2, 3, \dots$
- На каждом временном шаге t агент получает некоторое представление состояния окружающей среды S_t и, исходя из него, выбирает действие A_t .
- На следующем шаге агент в качестве последствия своего действия получает числовое вознаграждение R_{t+1} и оказывается в новом состоянии S_{t+1} .
- В результате порождается траектория $S_0 \rightarrow A_0 \mid R_1, S_1 \rightarrow A_1 \mid R_2, S_2 \rightarrow A_2 \dots$

Пример задачи RL - лабиринт

- Цель игры — добраться до выхода и не заблудиться в лабиринте.
- Агент — тот, кто перемещается по лабиринту.
- Среда — лабиринт.
- Состояние — позиция в лабиринте, на которой в данный момент находится агент.
- Агент выполняет действие, перемещаясь из одного состояния в другое.
- Агент получает положительный результат, если при выполнении действия он не наталкивается на препятствие, и отрицательный результат, если при своем действии он наталкивается на препятствие и не может добраться до конечной точки.



6. Прикладные задачи машинного обучения и тенденции развития

- <https://paperswithcode.com/sota> - публикации, сгруппированные по основным направлениям ИИ.
- В настоящее время почти любая прикладная задача решается сложным **ансамблем методов** машинного обучения (чаще всего ансамблем нейронных сетей).
- Также активно используются **Foundation Models**, **Большие Языковые Модели** (LLM).
- Перспективой является переход к **КОГНИТИВНЫМ архитектурам**.

Базовые архитектуры нейронных сетей

- Глубокое обучение
- Сверточная нейронная сеть
- Рекуррентная нейронная сеть
- (Вариационный) автокодировщик
- Генеративно-состязательная сеть
- Механизм внимания в нейронных сетях

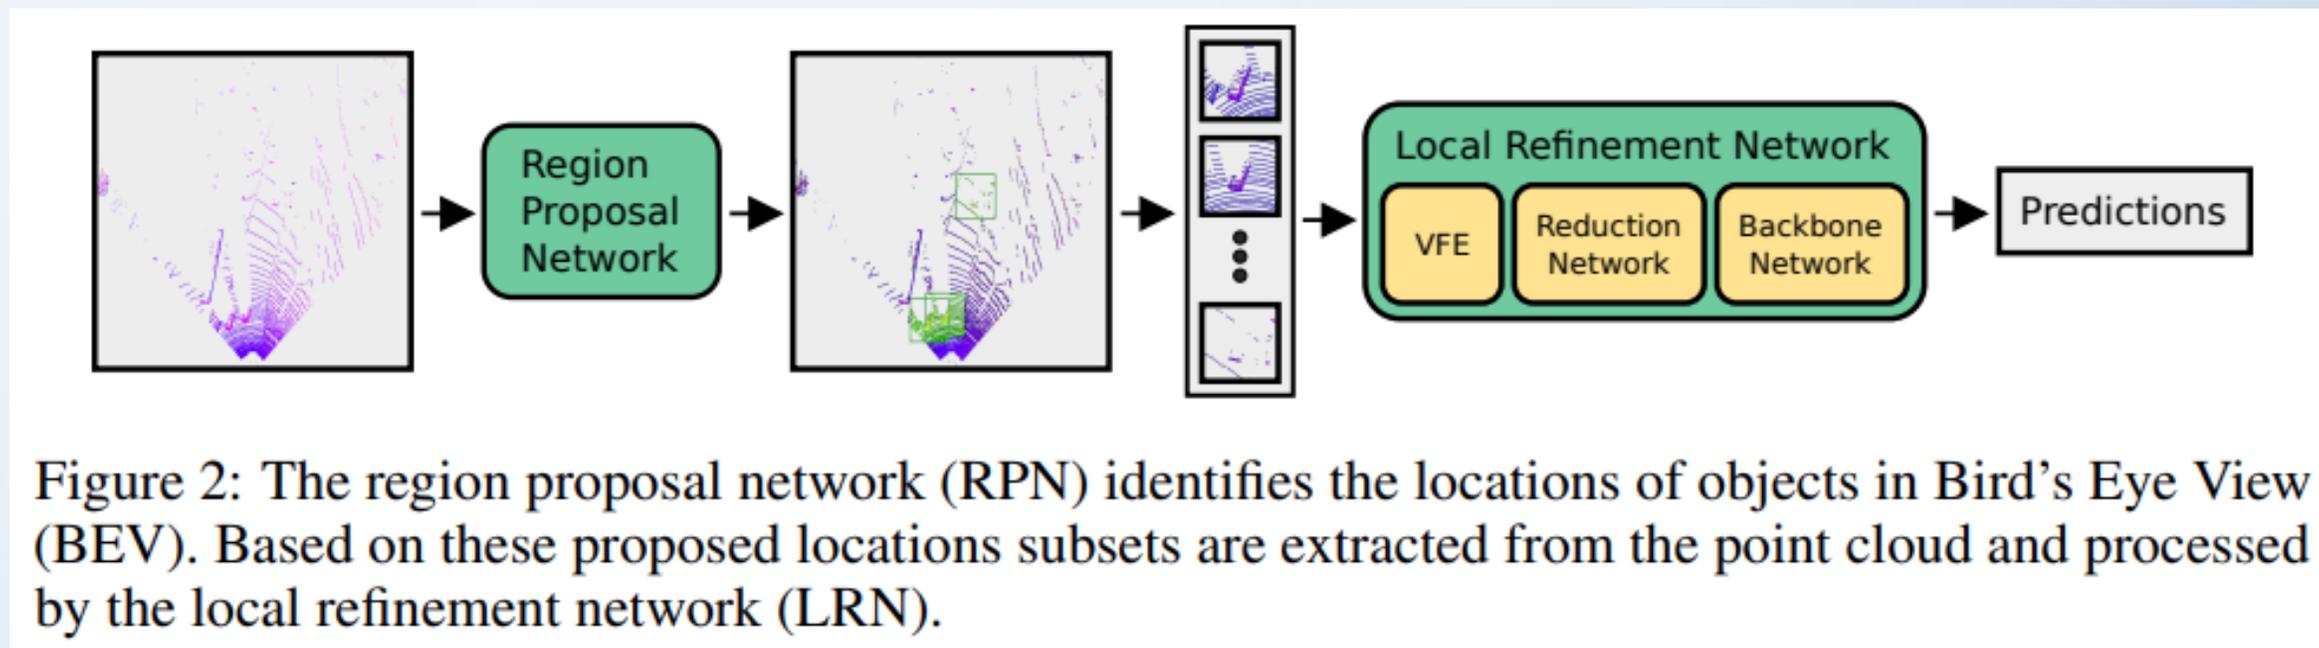


Figure 2: The region proposal network (RPN) identifies the locations of objects in Bird's Eye View (BEV). Based on these proposed locations subsets are extracted from the point cloud and processed by the local refinement network (LRN).

Johannes Lehner et al. Patch Refinement - Localized 3D Object Detection, arXiv:1910.04093v1 (2)

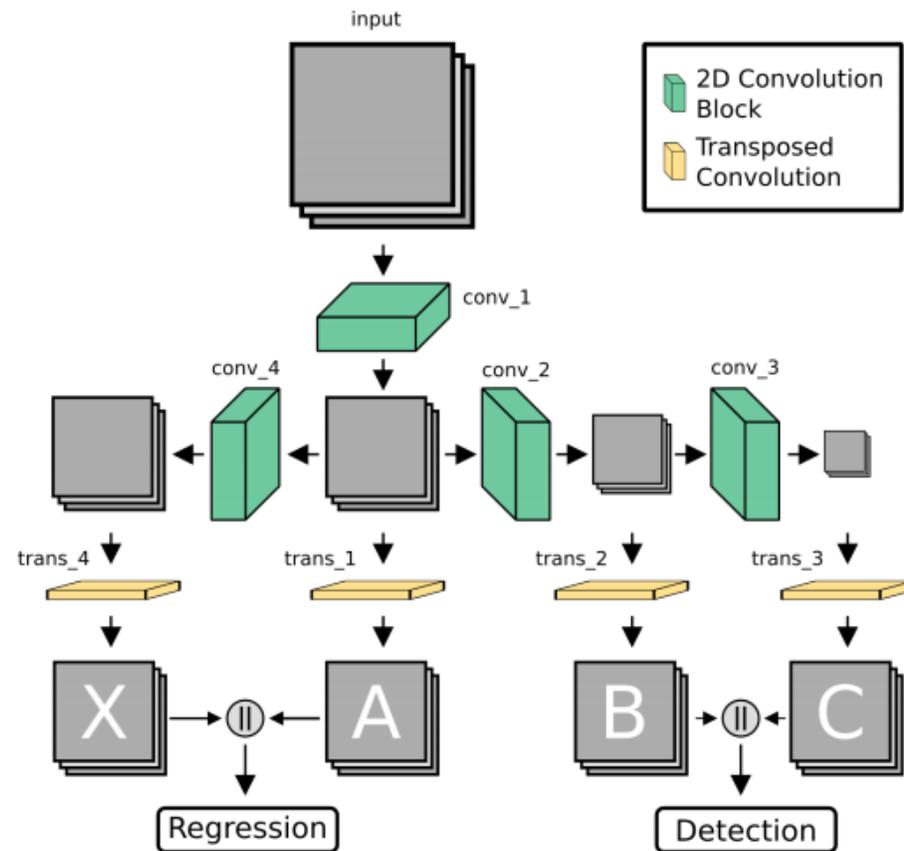


Figure 3: Architecture of the backbone network. The network is designed in a way that regression is performed on feature maps of higher resolution and limited receptive fields, while detection is performed on higher level feature maps with a larger receptive field. Before regression, we concatenate feature maps A and X and before detection we concatenate B and C .

Michihiro Yasunaga, Percy Liang. Graph-based, Self-Supervised Program Repair from Diagnostic Feedback, arXiv:2005.10636v2

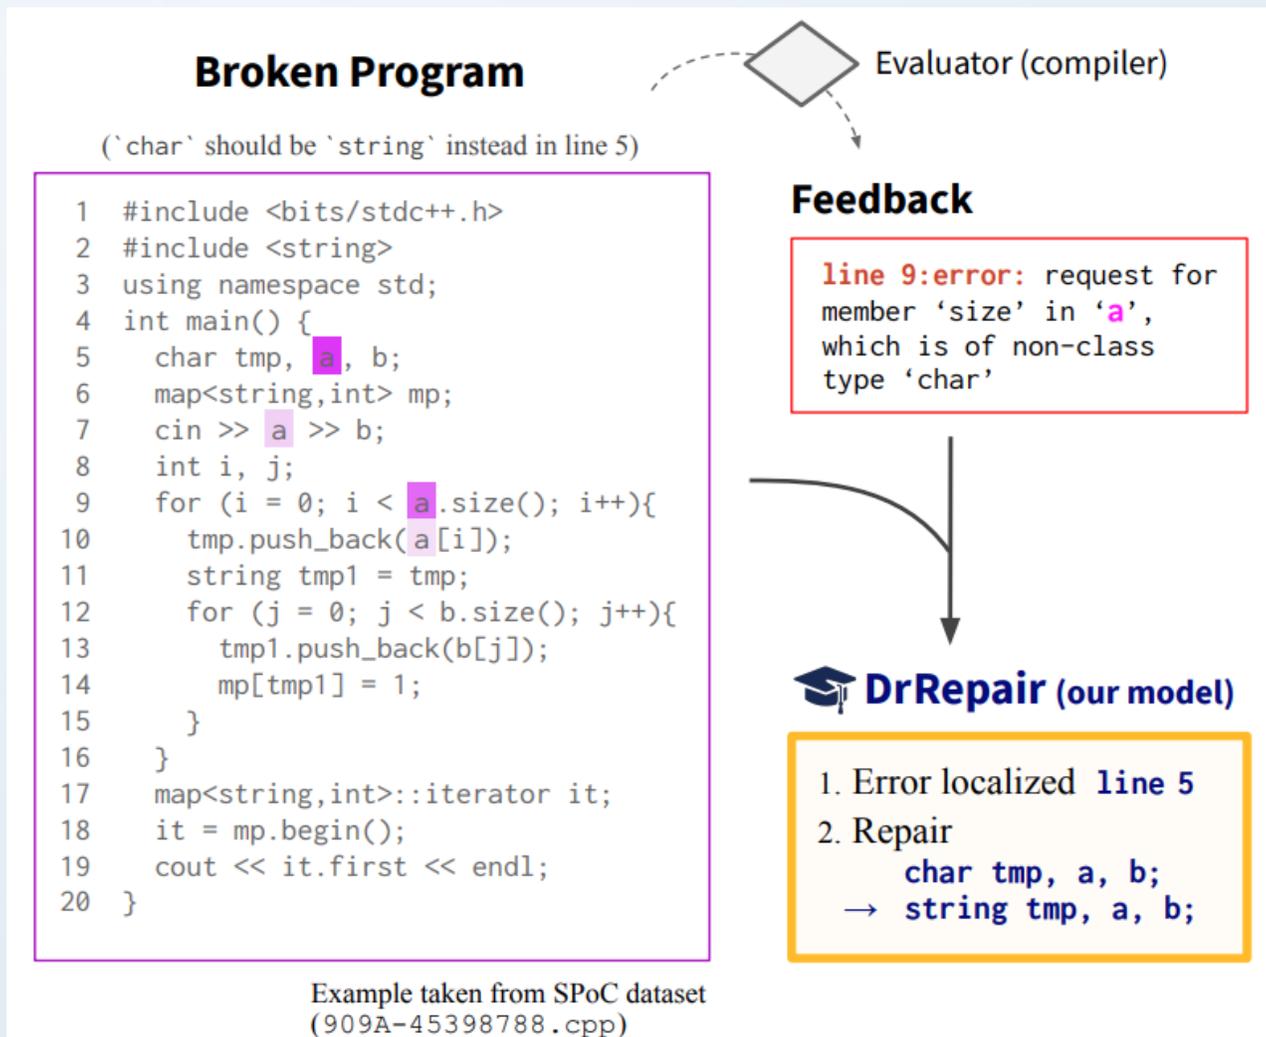


Figure 1. Given a broken program and diagnostic feedback (compiler error message), our goal is to localize an erroneous line and generate a repaired line.

Michihiro Yasunaga, Percy Liang. Graph-based, Self-Supervised Program Repair from Diagnostic Feedback, arXiv:2005.10636v2

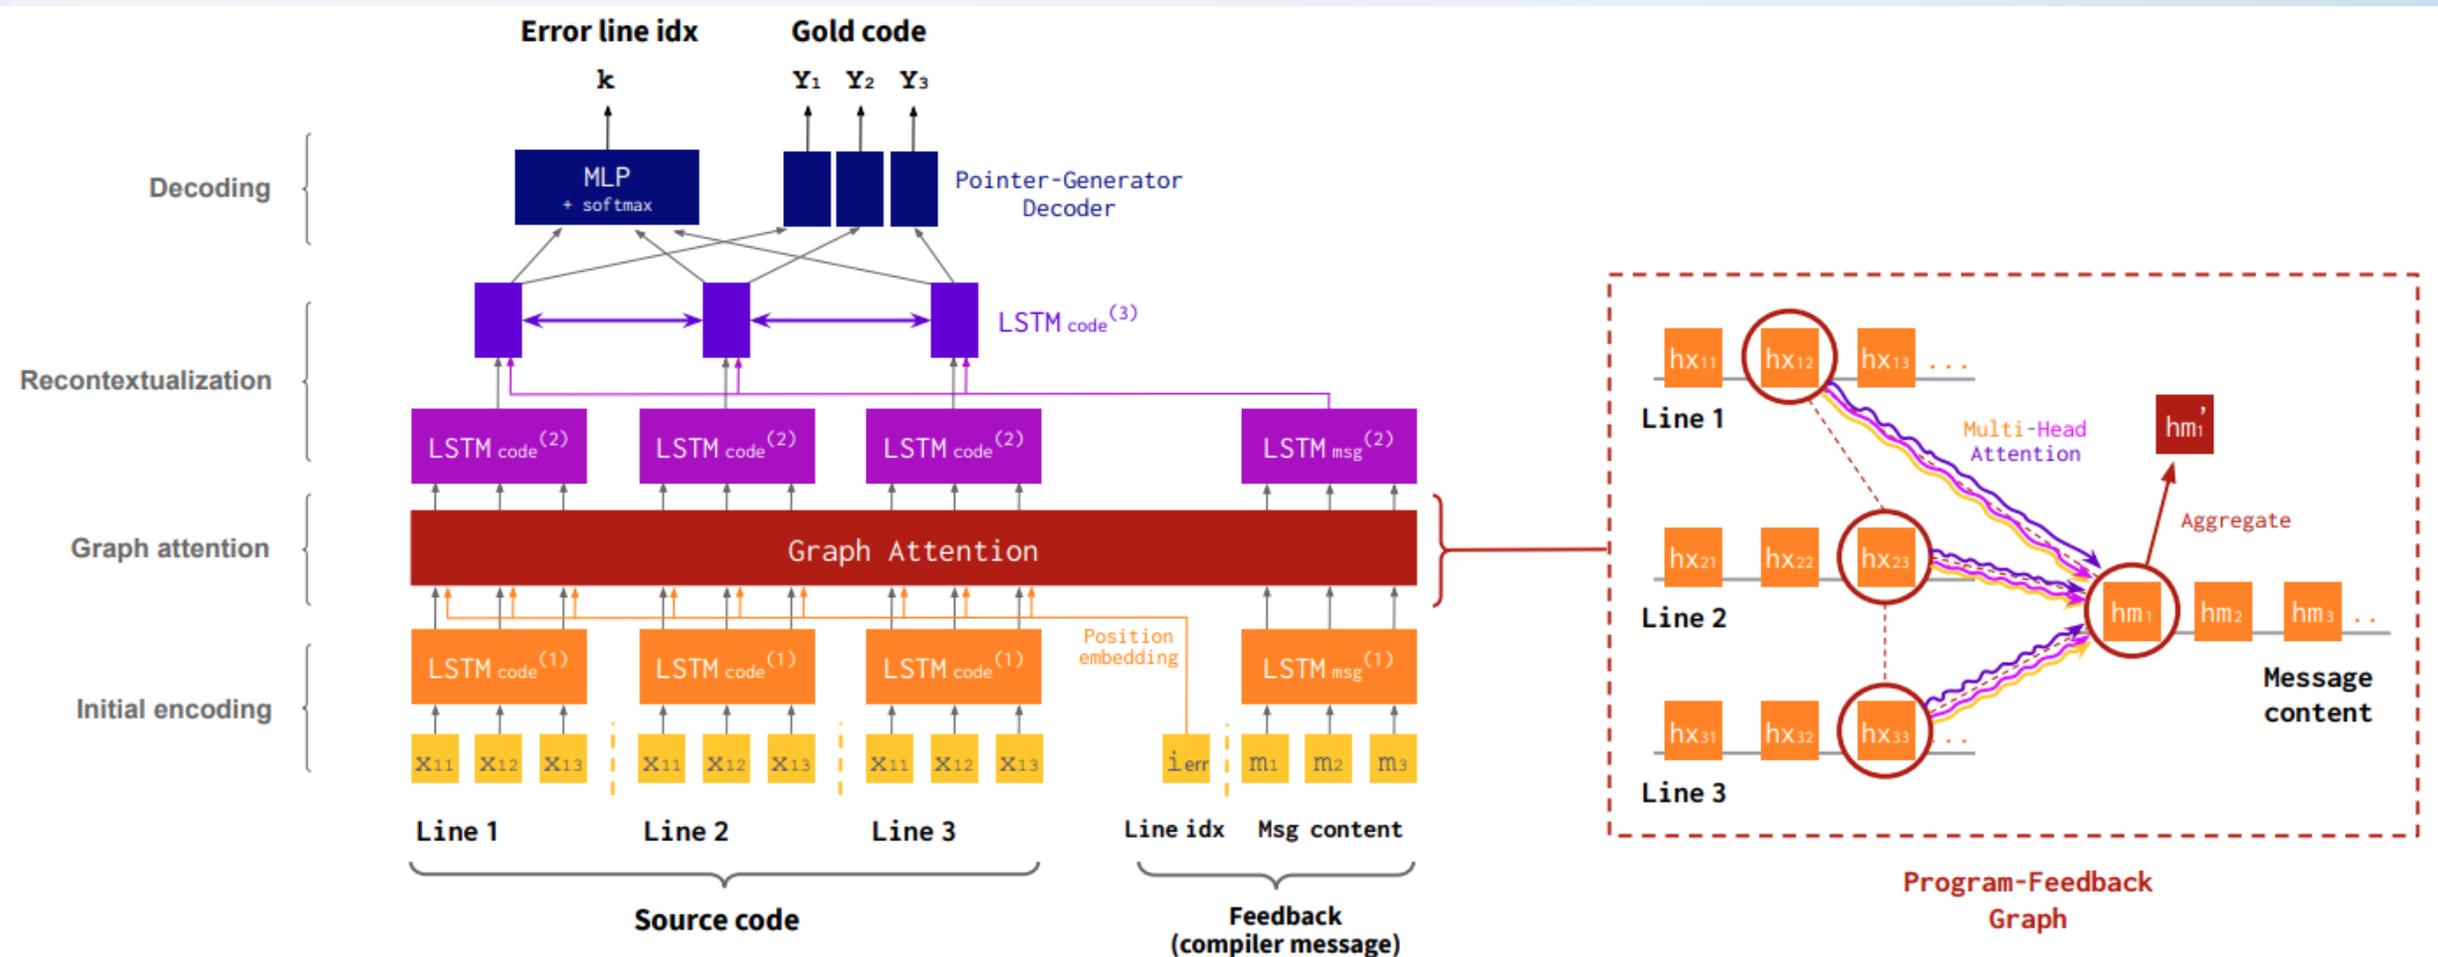
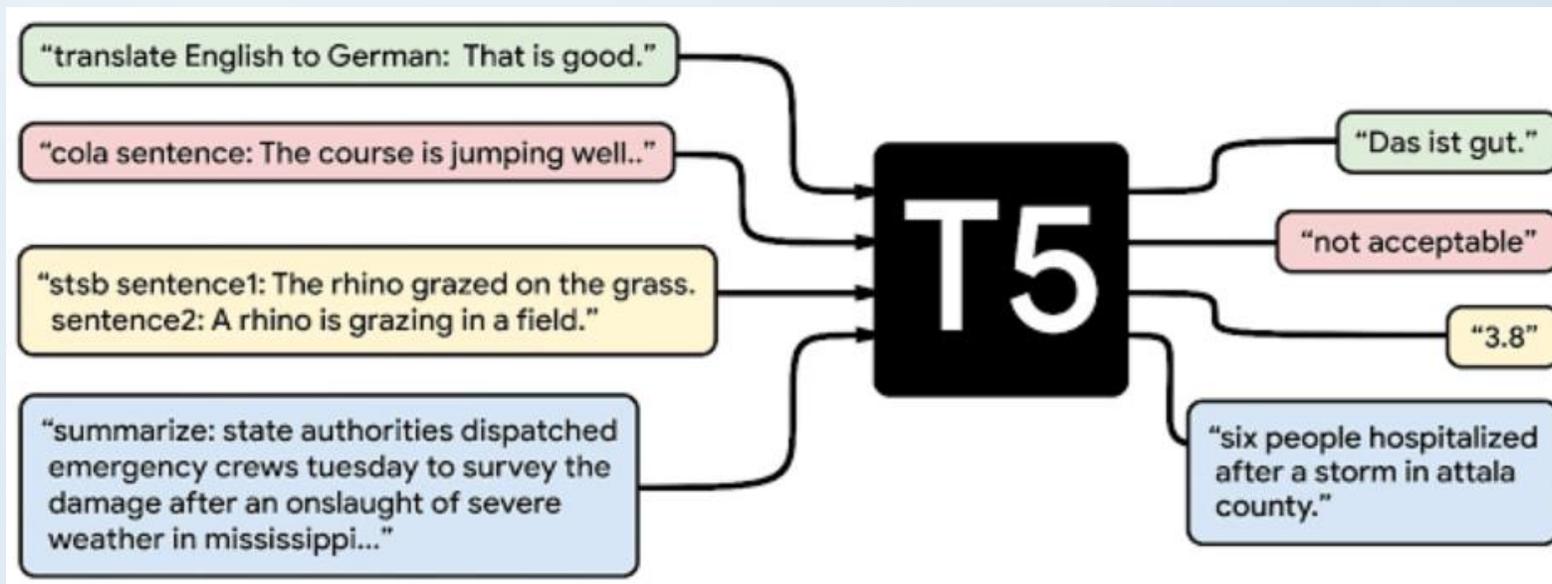


Figure 3. DrRepair model. It takes in a program $x = (x_1, \dots, x_L)$ and diagnostic feedback from a compiler $f = (i_{err}, m_{err})$ as inputs (**bottom**), encodes them via LSTM and graph attention layers, and decodes the error line index k and repaired code y_k (**top**). The right-hand side illustrates the graph attention mechanism. Best viewed in color.

Модель Google T5

- Использует трансформерную нейросетевую архитектуру с небольшими улучшениями.
- Обучается на очень большом датасете.
- Позволяет решать различные задачи обработки ЕЯ.
- Является одной из наиболее практичных моделей. Доступна в Google Collab, опубликована в репозитории - <https://github.com/google-research/text-to-text-transfer-transformer>
- Источники:
 - Базовая статья «Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer» – <https://arxiv.org/abs/1910.10683>
 - Блог компании Google - <https://ai.googleblog.com/2020/02/exploring-transfer-learning-with-t5.html>
 - Статья - <https://towardsdatascience.com/t5-text-to-text-transfer-transformer-643f89e8905e>
 - Статья «Многозадачная модель T5 для русского языка» – <https://habr.com/ru/post/581932/>



Сверхбольшие модели – PaLM

- Используется стандартная трансформерная архитектура нейронной сети с рядом улучшений.
- Модель содержит 540 миллиардов параметров.
- Обучена с использованием 6144 тензорных процессоров Google TPU на платформе параллельных вычислений Pathways. Данные для обучения включали комбинации английских и многоязычных датасетов с текстами сайтов, книг, статей Википедии, чатов и кодов с GitHub.
- PaLM была проверена в нескольких сотнях задач по пониманию и генерации языка и показала превосходство в большинстве из них, причем во многих случаях – со значительным отрывом. Среди таких задач определение причин и следствий, понимание содержания, угадывание фильмов по эмодзи, поиск синонимов и контраргументов, перевод текста. В задачах ответы на вопросы и составления выводов точность PaLM превосходит аналогичные модели в несколько раз.
- Источники:
 - Базовая статья «PaLM: Scaling Language Modeling with Pathways» – <https://arxiv.org/abs/2204.02311>
 - Блог компании Google - <https://ai.googleblog.com/2022/04/pathways-language-model-palm-scaling-to.html>
 - Статья на русском языке - <https://neurohive.io/ru/papers/palm-yazykovaya-model-google-s-540-milliardami-parametrov/>

Explaining a Joke

Input: Did you see that Google just hired an eloquent whale for their TPU team? It showed them how to communicate between two different pods!

Model Output: TPUs are a type of computer chip that Google uses for deep learning. A "pod" is a group of TPUs. A "pod" is also a group of whales. The joke is that the whale is able to communicate between two groups of whales, but the speaker is pretending that the whale is able to communicate between two groups of TPUs.

Logical Inference

Input: Shelley is from Virginia, but is visiting that city with that famous market where they throw the fish. Going home next Tuesday!

Question: Is it likely that Shelley will be near the Pacific Ocean this weekend?

Model Output: The city with the famous market where they throw the fish is Seattle, Washington. Seattle is on the Pacific Ocean. Shelley is visiting Seattle, so she will be near the Pacific Ocean this weekend. The answer is "yes", it is likely that Shelley will be near the Pacific Ocean this weekend.

Уровни развития интеллектуальных систем (интерактивный ИИ) - 1

Соучредитель DeepMind Мустафа Сулейман:

- Генеративный ИИ — это всего лишь этап. Дальше — интерактивный ИИ.
- Первая волна ИИ касалась классификации. Глубокое обучение показало, что мы можем научить компьютер классифицировать различные типы входных данных: изображения, видео, аудио, язык.
- Сейчас мы находимся в генеративной волне, когда вы берете входные данные и создаете новые данные. Пример - ChatGPT.
- Дальше будет волна интерактивного ИИ: боты, выполняющие задачи, которые вы перед ними ставите, призывая другое программное обеспечение и других людей для выполнения задач. И эти ИИ смогут действовать. Вы просто дадите ему общую цель высокого уровня, и он будет использовать все имеющиеся у него инструменты для достижения этой цели. ИИ будет разговаривать с другими людьми, разговаривать с другими ИИ.
- **Это огромный сдвиг в том, на что способны технологии. Это очень, очень глубокий момент в истории технологий, который, я думаю, многие люди недооценивают. Сегодняшние технологии статичны. Грубо говоря, он делает то, что вы ему говорите. Но скоро технологии будут анимированы. У ИИ будет потенциальная свобода действий, если вы ее дадите. То, что мы создаем инструменты, обладающие такой, знаете ли, свободой воли, является настоящим шагом в истории нашего вида.**
- *Источник: <https://vc.ru/future/843088-souchreditel-deepmind-generativnyy-ii-eto-vsego-lish-etap-dalshe-interaktivnyy-ii>*

Уровни развития интеллектуальных систем (интерактивный ИИ) - 2

- Уже существует бот AutoGPT, которому можно поставить цель, а он самостоятельно разбивает ее на подзадачи и выполняет их, в процессе взаимодействуя с веб-сайтами, ботами и людьми.
- Пример: AutoGPT сам заказал пиццу, заменил целый отдел продаж (нашел ЛПР и их контакты, составил для них письмо, разослал и назначил встречи в календаре с теми, кто ответил), написал сайт (попутно устанавливая на компьютер ПО, которое не было установлено).
- *Источник: <https://vc.ru/future/843088-souchreditel-deepmind-generativnyy-ii-eto-vsego-lish-etap-dalshe-interaktivnyy-ii>*
- Сайт конференции BICA-2023: (<https://bica2023.org/>)
- “The future of AI is in interacting fluidly with humans.” — Paul Robertson

Когнитивная архитектура (википедия)

- Набор высокоуровневых когнитивных механизмов: память (кратковременная и долговременная), внимание, способность прогнозирования, планирования, восприятие окружающей среды, которые в идеале обеспечивают сильный ИИ.
- Обладает способностью к самообучению, не требует подбора гиперпараметров, в отличие от «примитивных» алгоритмов ML.

