

Курс «Введение в машинное обучение»

Методология машинного обучения

Воронцов Константин Вячеславович

k.v.vorontsov@phystech.edu

<http://www.MachineLearning.ru/wiki?title=User:Vokov>

Этот курс доступен на странице вики-ресурса

<http://www.MachineLearning.ru/wiki>

«Введение в машинное обучение (курс лекций, К.В.Воронцов)»

1 Методология решения прикладных задач ML

- Стандарт CRISP-DM и взгляд на эволюцию ИИ
- Понимание и предобработка данных
- Оценивание качества и выбор моделей

2 Типология задач машинного обучения

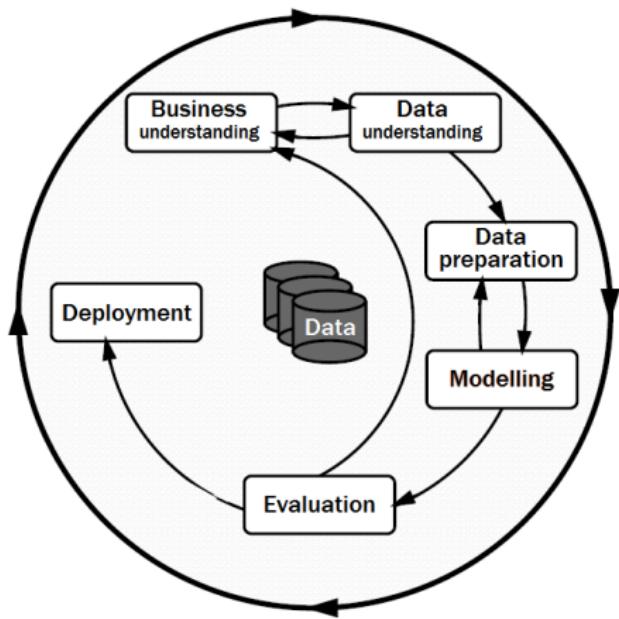
- Обучение с учителем, без учителя, частичное
- Обучение многих моделей
- Шесть школ машинного обучения по П.Домингосу

3 Задачи и методы с фактором времени

- Инкрементное и онлайновое обучение, прогнозирование
- Активное обучение и краудсорсинг
- Обучение с подкреплением

Межотраслевой стандарт интеллектуального анализа данных

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



Компании-инициаторы:

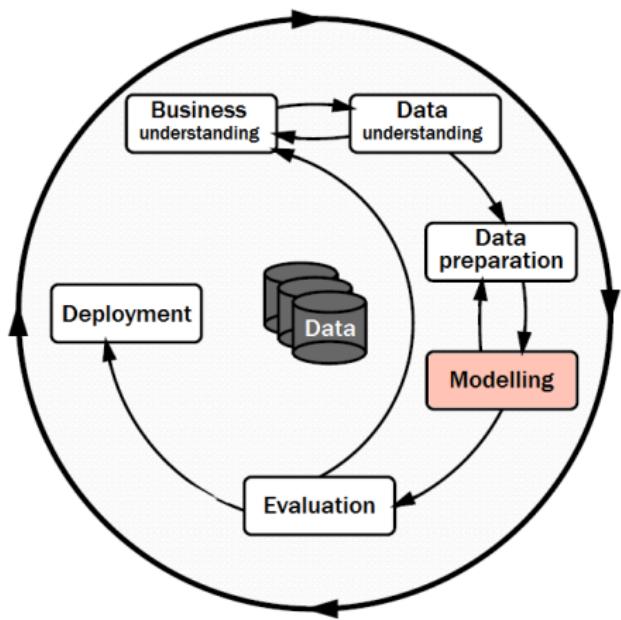
- SPSS
- Teradata
- Daimler AG
- NCR Corp.
- OHRA

Шаги процесса:

- понимание бизнеса
- понимание данных
- предобработка данных и инженерия признаков
- разработка моделей и настройка их параметров
- оценивание качества
- внедрение

Понимание эволюции ИИ как автоматизации шагов CRISP-DM

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

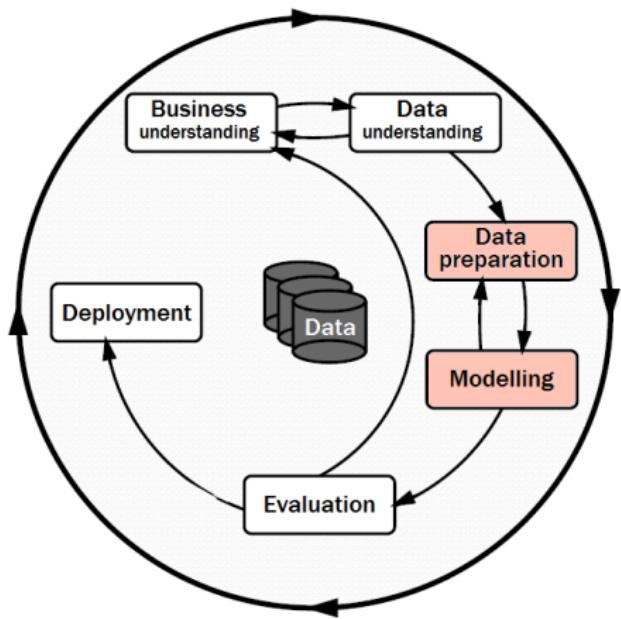


Эволюция ИИ:

- *Expert Systems*: жёсткие модели, основанные на правилах
- *Machine Learning*: параметрические модели, обучаемые по данным

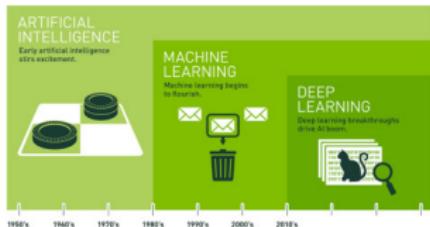
Понимание эволюции ИИ как автоматизации шагов CRISP-DM

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



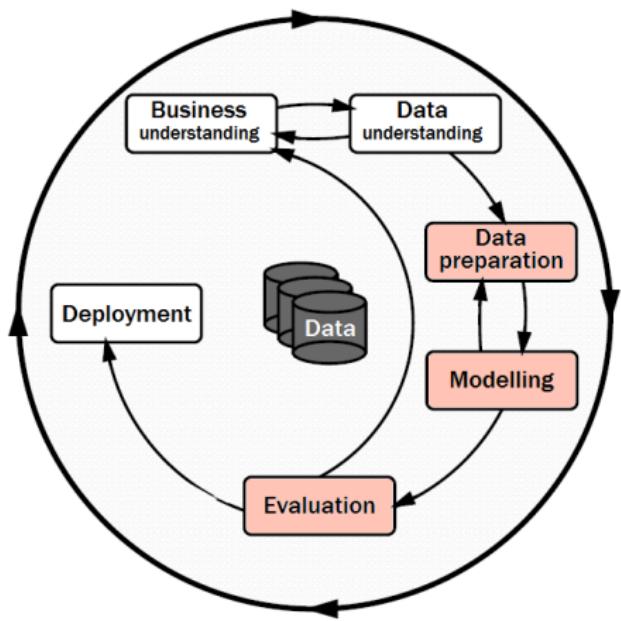
Эволюция ИИ:

- *Expert Systems*: жёсткие модели, основанные на правилах
- *Machine Learning*: параметрические модели, обучаемые по данным
- *Deep Learning*: модели с обучаемой векторизацией данных



Понимание эволюции ИИ как автоматизации шагов CRISP-DM

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

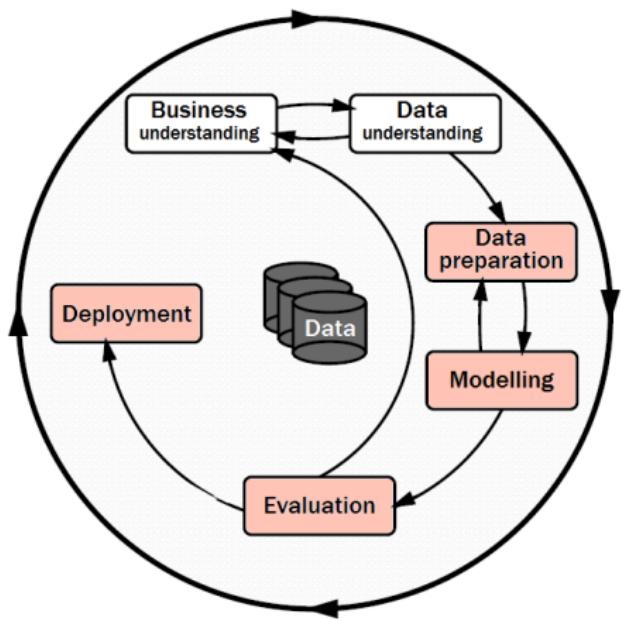


Эволюция ИИ:

- *Expert Systems*: жёсткие модели, основанные на правилах
- *Machine Learning*: параметрические модели, обучаемые по данным
- *Deep Learning*: модели с обучаемой векторизацией данных
- *AutoML*: автоматический выбор моделей и их строения

Понимание эволюции ИИ как автоматизации шагов CRISP-DM

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



Эволюция ИИ:

- *Expert Systems*: жёсткие модели, основанные на правилах
- *Machine Learning*: параметрические модели, обучаемые по данным
- *Deep Learning*: модели с обучаемой векторизацией данных
- *AutoML*: автоматический выбор моделей и их строения
- *Lifelong Learning*: бесшовная интеграция в бизнес-процесс

Особенности данных и постановок прикладных задач

- разнородные (признаки измерены в разных шкалах)
- неполные (измерены не все, имеются пропуски)
- неточные (измерены с погрешностями)
- противоречивые (объекты одинаковые, ответы разные)
- избыточные (сверхбольшие, не помещаются в память)
- недостаточные (объектов меньше, чем признаков)
- сложно структурированные (нет признаковых описаний)

Риски, связанные с постановкой задачи:

- «грязные» данные
(заказчик не обеспечивает качество данных)
- неясные критерии качества модели
(заказчик не определился с целями или критериями)

Методы предварительной обработки данных

- Преобразование признаков (feature transformation)
 - усиление или ослабление шкалы измерения признака
 - нормализация, стандартизация
 - трансформация функции распределения признака
- Выделение признаков из сырых данных (feature extraction), конструирование признаков (feature engineering)
- Обучаемая векторизация данных (representation learning)
- Восполнение пропусков в данных (missing values imputation)
- Обнаружение выбросов (outlier/anomaly detection)
- Понижение размерности данных (dimensionality reduction)
- Отбор информативных признаков (feature selection)

Задачи оценивания и выбора моделей

Дано:

$X^\ell = (x_1, \dots, x_\ell)$ — обучающая выборка

$A_t = \{a: X \times W_t \rightarrow Y\}$ — параметрические модели, $t \in T$

W_t — пространство параметров модели A_t

$\mu_t: (X \times Y)^\ell \rightarrow W_t$ — методы обучения, $t \in T$

Найти: метод μ_t с наилучшей обобщающей способностью.

Частные случаи:

- выбор лучшей модели A_t (model selection);
- выбор метода обучения μ_t для заданной модели A (в частности, оптимизация гиперпараметров);
- отбор признаков (feature selection):
 $F = \{f_j: X \rightarrow D_j: j = 1, \dots, n\}$ — множество признаков;
метод обучения μ_J использует только признаки $J \subseteq F$.

Обобщающая (предсказательная) способность метода

$\mathcal{L}(w, x)$ — функция потерь модели $a(w, x)$ на объекте x

$Q(w, X^\ell) = \frac{1}{\ell} \sum_{i=1}^{\ell} \mathcal{L}(w, x_i)$ — критерий качества $a(w, x)$ на X^ℓ

Внутренний критерий оценивает качество на обучении X^ℓ :

$$Q_\mu(X^\ell) = Q(\mu(X^\ell), X^\ell).$$

Недостаток: эта оценка смещена, т.к. μ минимизирует её же.

Внешний критерий оценивает качество «вне обучения»,
например, по отложенной (hold-out) контрольной выборке X^k :

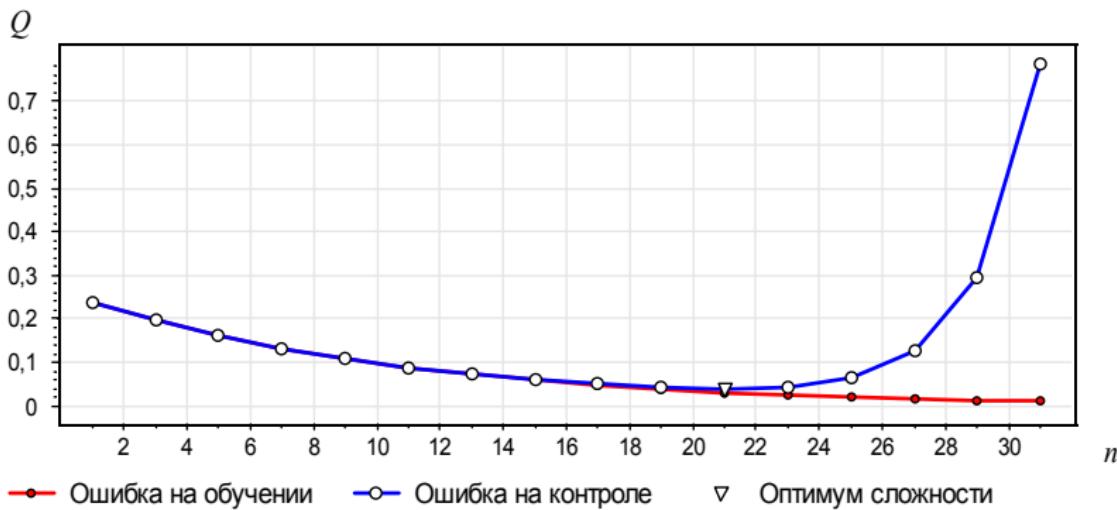
$$Q_\mu(X^\ell, X^k) = Q(\mu(X^\ell), X^k).$$

Недостаток: эта оценка зависит от разбиения $X^L = X^\ell \sqcup X^k$.

Основное отличие внешних критериев от внутренних

Внутренний критерий монотонно убывает с ростом сложности модели (числа признаков p или числа параметров $\dim w$).

Внешний критерий имеет характерный минимум, соответствующий оптимальной сложности модели.



Кросс-проверка (cross-validation, CV)

Усреднение оценок hold-out по заданному N — множеству разбиений $X^L = X_n^\ell \sqcup X_n^k$, $n = 1, \dots, N$:

$$CV(\mu, X^L) = \frac{1}{|N|} \sum_{n \in N} Q_\mu(X_n^\ell, X_n^k).$$

Частные случаи — разные способы задания множества N .

1. $|N| = 1$ — единственное разбиение: hold-out.
2. N — случайное множество разбиений: метод Монте-Карло.
3. N — множество всех $C_{\ell+k}^k$ разбиений:
полная кросс-проверка (complete cross-validation, CCV).

Недостаток: оценка CCV вычислительно слишком сложна.

Используются либо малые k , либо комбинаторные оценки CCV.

Скользящий контроль и поблочная кросс-проверка

4. Скользящий контроль (leave one out CV): $k = 1$,

$$\text{LOO}(\mu, X^L) = \frac{1}{L} \sum_{i=1}^L Q_\mu(X^L \setminus \{x_i\}, \{x_i\}).$$

Недостатки LOO: ресурсоёмкость, высокая дисперсия.

5. Кросс-проверка по q блокам (q -fold CV): случайное разбиение $X^L = X_1^{\ell_1} \sqcup \dots \sqcup X_q^{\ell_q}$ на q блоков (почти) равной длины,

$$\text{CV}_q(\mu, X^L) = \frac{1}{q} \sum_{n=1}^q Q_\mu(X^L \setminus X_n^{\ell_n}, X_n^{\ell_n}).$$

Недостатки q -fold CV:

- оценка существенно зависит от разбиения на блоки;
- каждый объект лишь один раз участвует в контроле.

Многократная поблочная кросс-проверка

6. Контроль t раз по q блокам ($t \times q$ -fold CV)

— стандарт «де факто» для тестирования методов обучения.

Выборка X^L разбивается t раз случайным образом на q блоков

$$X^L = X_{s1}^{\ell_1} \sqcup \cdots \sqcup X_{sq}^{\ell_q}, \quad s = 1, \dots, t, \quad \ell_1 + \cdots + \ell_q = L;$$

$$\text{CV}_{t \times q}(\mu, X^L) = \frac{1}{t} \sum_{s=1}^t \frac{1}{q} \sum_{n=1}^q Q_\mu(X^L \setminus X_{sn}^{\ell_n}, X_{sn}^{\ell_n}).$$

Преимущества $t \times q$ -fold CV:

- увеличением t можно улучшать точность оценки (компромисс между точностью и временем вычислений);
- каждый объект участвует в контроле ровно t раз;
- оценивание доверительных интервалов (95% при $t = 40$).

Методология анализа ошибок (потерь)

$\mathcal{L}(w, x_i)$ — функция потерь (чем меньше, тем лучше).

Критерий средней потери модели $a(x, w)$ на выборке U :

$$Q(w, U) = \frac{1}{|U|} \sum_{x_i \in U} \mathcal{L}(w, x_i)$$

Анализ потерь на обучающей выборке:

- Ранжировать объекты по убыванию потерь $\mathcal{L}_i = \mathcal{L}(w, x_i)$
- Объекты со сверхбольшими потерями — выбросы?
- Если нет, то как улучшить модель на этих объектах?

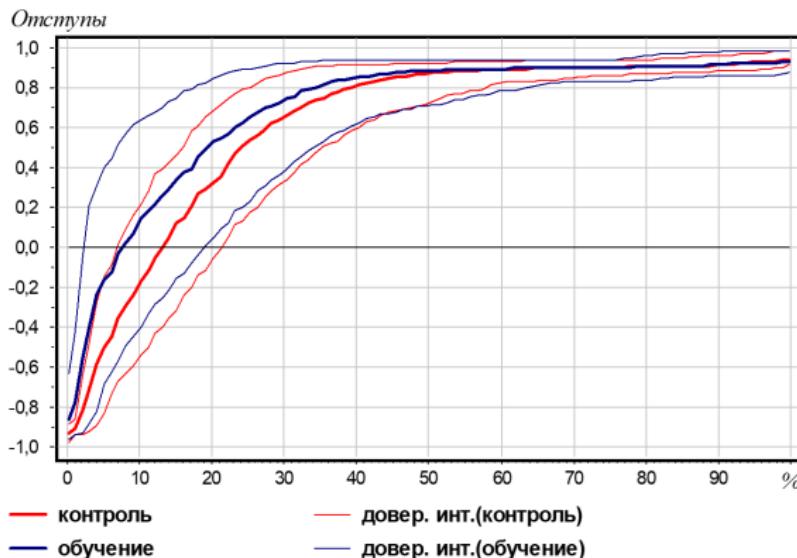
Сравнительный анализ потерь на обучении и teste:

- Сильно ли отличаются распределения потерь?
- Если сильно, то как устранить переобучение?
- Объекты со сверхбольшими различиями — выбросы?

Анализ распределения отступов в задаче классификации

Вместо потерь $\mathcal{L}_i = L(M_i)$ можно ранжировать отступы M_i

Видно: переобучение, зону неуверенной классификации



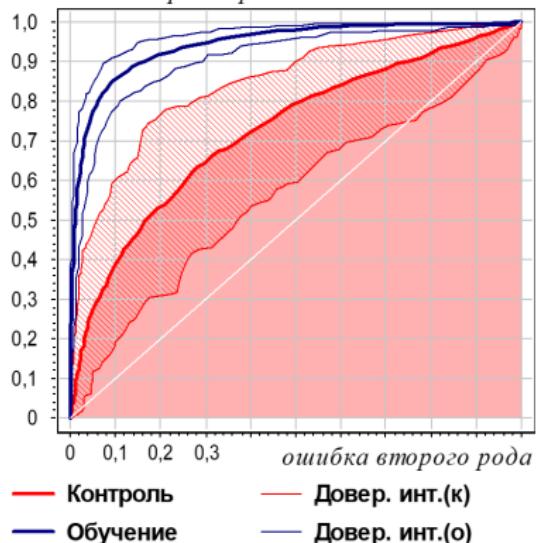
Задача UCI:australian, метод JRip

Анализ ROC-кривых

ROC-кривые можно строить отдельно для каждого класса

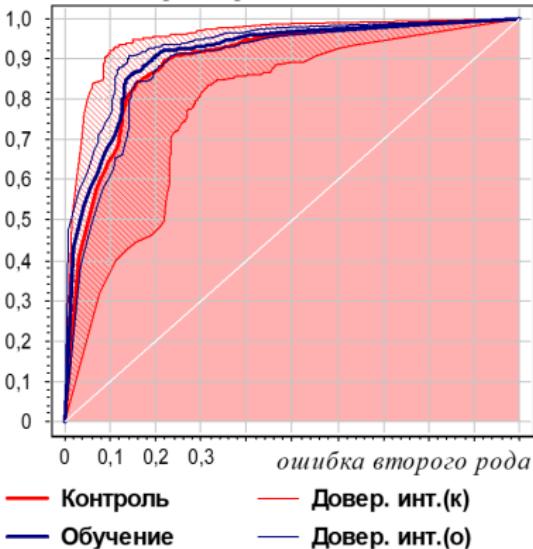
Видно: переобучение, устойчивость, различия классов

1 - ошибка первого рода



Задача UCI:liver, метод Bagging

1 - ошибка первого рода



Задача UCI:heart, метод Naïve Bayes

A/B тестирование (A/B testing, Split Testing)

Две модели, «базовая A» и «улучшенная B»,
построенные по историческим данным X^ℓ ,
тестируются по метрике качества Q на новых данных X^k

В чём отличия A/B тестирования от обычного hold-out?

- X^k — это именно будущие данные (out-of-time), а не часть прошлых данных, исключённых из обучения (out-of-sample)
- больше реализма: за это время могут измениться свойства потока данных, реальные данные не обязаны быть i.i.d.
- однократный выбор модели почти не переобучается
- накопление данных X^k может потребовать много времени
- работа модели может влиять на формирование потока данных (например, в рекомендательных системах)

Мета-обучение (meta-learning, learning to learn)

Проблема: слишком много методов, слишком долго запускать

Дано: выборка «задача, метод» → критерии качества

Найти: модель многоклассовой классификации, предсказывающую, каким методом решать задачу

Критерий: точность предсказания оптимального метода

Признаки:

- размерные характеристики задачи
- характеристики пространства признаков: типы, выбросы, пропуски, корреляции
- результаты быстрых низкоразмерных методов

Joaquin Vanschoren. Meta-learning Architectures: Collecting, Organizing and Exploiting Meta-knowledge. 2009.

Joaquin Vanschoren. Meta-Learning: A Survey. 2018.

Автоматический выбор моделей и гиперпараметров (AutoML)

Проблема:

подбор структуры модели (архитектуры нейросети)
и гиперпараметров требует слишком много ресурсов

Дано: выборка «задача, структура» → критерии качества

Найти: какой следующий эксперимент провести с моделью

Критерий:

минимизация затрат ресурсов на автоматический поиск
оптимальной модели, сопоставимой по качеству с моделями,
построенными профессиональными исследователями

Близкая классическая задача — планирование экспериментов

Xin He et al. AutoML: A Survey of the State-of-the-Art. 2019

<https://github.com/sberbank-ai-lab/LightAutoML> — AutoML от Сбербанка

Эксперименты на реальных данных

Эксперименты на конкретной прикладной задаче:

- цель — решить задачу как можно лучше
- важно понимание задачи и данных
- важно придумывать информативные признаки
- конкурсы по анализу данных: <http://www.kaggle.com>

Эксперименты на наборах прикладных задач:

- цель — протестировать метод в разнообразных условиях
- нет необходимости (и времени) разбираться в сути задач : (
- признаки, как правило, уже кем-то придуманы
- репозиторий UC Irvine Machine Learning Repository
<http://archive.ics.uci.edu/ml> (668 задачи, 2024-09-01)

Эксперименты на синтетических данных

Используются для тестирования новых методов обучения.
Преимущество — мы знаем истинную $y(x)$ (ground truth)

Эксперименты на синтетических данных:

- цель — отладить метод, выявить границы применимости
- объекты x_i из придуманного распределения (часто 2D)
- ответы $y_i = y(x_i)$ для придуманной функции $y(x)$
- двумерные данные + визуализация выборки

Эксперименты на полу-синтетических данных:

- цель — протестировать помехоустойчивость модели
- объекты x_i из реальной задачи (признаки + шум)
- ответы $y_i = y(x_i)$ для придуманной функции $y(x)$ (+ шум)

Напоминание. Общая постановка задач машинного обучения

Дано: X — пространство объектов

$X^\ell = \{x_1, \dots, x_\ell\} \subset X$ — обучающая выборка (training sample)
 $a(x, w)$, $a: X \times W \rightarrow Y$ — параметрическая модель, гипотеза

Найти $w \in W$ — вектор параметров модели $a(x, w)$

Критерий минимизации эмпирического риска
(empirical risk minimization, ERM):

$$\sum_{i=1}^{\ell} \mathcal{L}(w, x_i) + \tau \mathcal{R}(w) \rightarrow \min_w$$

$\mathcal{L}(w, x)$ — функция потерь (loss function),
тем больше, чем хуже модель $a(x, w)$ обработала объект x
 $\mathcal{R}(w)$ — регуляризатор для формализации дополнительных
требований к модели, τ — коэффициент регуляризации

Напоминание. Обучение модели регрессии

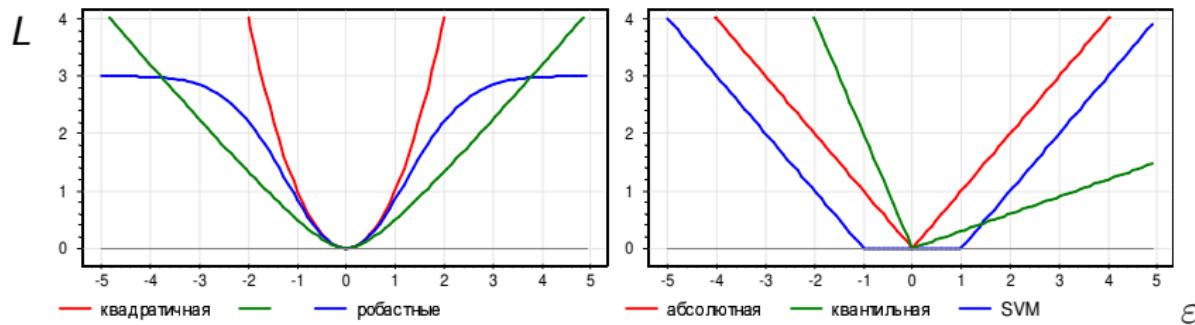
Дано: обучающая выборка $(x_i, y_i)_{i=1}^{\ell}$ с ответами $y_i \in \mathbb{R}$

Найти: вектор параметров w модели регрессии $a(x, w)$

Критерий: минимум эмпирического риска

$$\sum_{i=1}^{\ell} L(a(x_i, w) - y_i) \rightarrow \min_w$$

Унимодальные функции потерь $L(\varepsilon)$ от невязки $\varepsilon = a(x, w) - y$:



Напоминание. Обучение бинарного классификатора

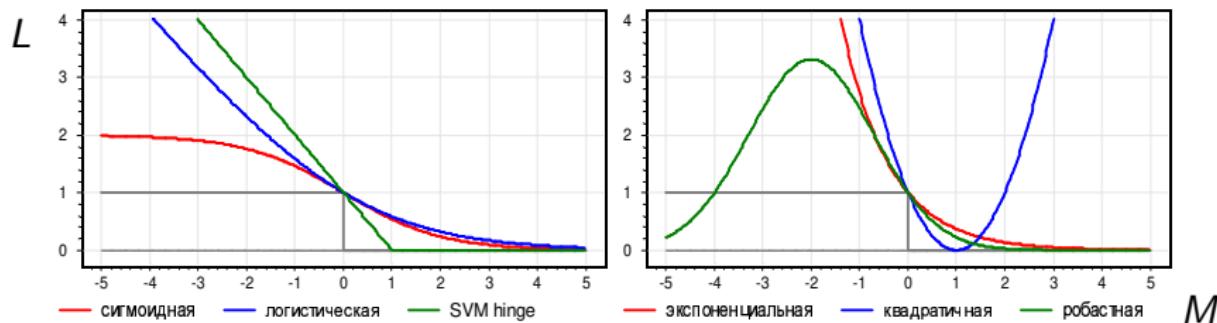
Дано: обучающая выборка $(x_i, y_i)_{i=1}^{\ell}$, $y_i \in \{-1, +1\}$

Найти: вектор w модели классификации $a(x, w) = \text{sign } g(x, w)$

Критерий: \min аппроксимированного эмпирического риска

$$\sum_{i=1}^{\ell} [g(x_i, w)y_i < 0] \leq \sum_{i=1}^{\ell} L(g(x_i, w)y_i) \rightarrow \min_w$$

Убывающие функции потерь $L(M)$ от отступа $M = g(x, w)y$:



Напоминание. Обучение многоклассового классификатора

Дано: обучающая выборка $(x_i, y_i)_{i=1}^{\ell}$, $y_i \in Y$, $|Y| < \infty$

Найти: вектор $w = (w_y : y \in Y)$ модели классификации

$$a(x, w) = \arg \max_{y \in Y} g_y(x, w_y)$$

Критерий «каждый против каждого»:

$$\sum_{i=1}^{\ell} \sum_{y \neq y_i} \underbrace{[g_{y_i}(x_i, w_{y_i}) - g_y(x_i, w_y)]}_{M_{iy}(w)} < 0 \leq \sum_{i=1}^{\ell} \sum_{y \neq y_i} L(M_{iy}(w)) \rightarrow \min_w$$

Критерий «каждый против всех»:

$$\sum_{i=1}^{\ell} L(\min_{y \neq y_i} M_{iy}(w)) \rightarrow \min_w$$

где $M_{iy}(w)$ — отступ объекта x_i относительно класса y

Напоминание. Обучение ранжированию, максимизация AUC

Дано: обучающая выборка (x_1, \dots, x_ℓ) ,

$i \prec j$ — отношение « x_j лучше, чем x_i » между объектами из X^ℓ

Найти: параметры w модели ранжирования $a(x, w)$,

восстанавливающей правильное отношение порядка:

$$i \prec j \Rightarrow a(x_i, w) < a(x_j, w)$$

Критерий: число неверно ранжированных пар объектов

$$\begin{aligned} Q(w) &= \sum_{i \prec j} \left[\underbrace{a(x_j, w) - a(x_i, w)}_{M_{ij}(w)} < 0 \right] \\ &\leq \sum_{i \prec j} L(a(x_j, w) - a(x_i, w)) \rightarrow \min_w \end{aligned}$$

где $L(M)$ — убывающая функция парного отступа $M_{ij}(w)$

Обучение без учителя и с частичной разметкой

- восстановление плотности распределения (density estimation)
- восстановление смеси распределений (mixture estimation)
- кластеризация (clustering)
- обучение автокодировщика (autoencoder)
- одноклассовая классификация (one-class classification)
- обнаружение выбросов (outlier/anomaly/novelty detection)
- поиск ассоциативных правил (association rule learning)

Частичное обучение (semi-supervised learning)

- трансдуктивное обучение (transductive learning)
- обучение только на положительных примерах (PU-learning)

Задача кластеризации (clustering)

Дано: $X^\ell = \{x_1, \dots, x_\ell\}$ — обучающая выборка, $x_i \in \mathbb{R}^n$

Найти:

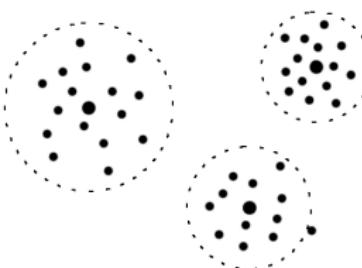
- центры кластеров — параметры $\mu_j \in \mathbb{R}^n, j = 1, \dots, K$
- какому кластеру принадлежит каждый объект $a_i \in \{1, \dots, K\}$

Критерий: минимум суммы
внутрикластерных расстояний

$$\sum_{i=1}^{\ell} \|x_i - \mu_{a_i}\|^2 \rightarrow \min_{\{a_i\}, \{\mu_j\}}$$

Метрика, как правило, евклидова
(но может быть и другая):

$$\|x - \mu_j\|^2 = \sum_{d=1}^n (f_d(x) - \mu_{jd})^2$$



Задача частичного обучения (semi-supervised learning, SSL)

Дано:

$X^k = \{x_1, \dots, x_k\}$ — размеченные объекты (labeled data);
 $\{y_1, \dots, y_k\}, y_i \in Y$

$U = \{x_{k+1}, \dots, x_\ell\}$ — неразмеченные объекты (unlabeled data).

Найти: классификации $\{a_{k+1}, \dots, a_\ell\}$ неразмеченных, $a_i \in Y$

Критерий: без модели классификации (transductive learning):

$$\sum_{i=1}^{\ell} \|x_i - \mu_{a_i}\|^2 + \lambda \sum_{i=1}^k [a_i \neq y_i] \rightarrow \min_{\{a_i\}, \{\mu_j\}}$$

Критерий с моделью классификации $a(x_i, w) = a_i \in Y$:

$$\sum_{i=1}^{\ell} \|x_i - \mu_{a(x_i, w)}\|^2 + \lambda \sum_{i=1}^k \mathcal{L}(w, x_i, y_i) + \tau R(w) \rightarrow \min_{w, \{\mu_j\}}$$

где $\mathcal{L}(w, x_i, y_i)$ — функция потерь для модели $a(x_i, w)$

Совместное обучение нескольких моделей

- частичное обучение (semi-supervised learning)
- обучение автокодировщика (autoencoder)
- обучаемая векторизация данных (representation learning)
- самостоятельное обучение (self-supervised learning)
- многомерное шкалирование (multidimensional scaling)
- предобучение (pre-training)
- перенос обучения (transfer learning)
- многозадачное обучение (multi-task learning)
- состязательное обучение (adversarial learning)
- дистилляция моделей или суррогатное моделирование
- обучение с привилегированной информацией

Дистилляция моделей или суррогатное моделирование

Обучение **сложной модели** $a(x, w)$ «долго, дорого»:

$$\sum_{i=1}^{\ell} \mathcal{L}(a(x_i, w), y_i) \rightarrow \min_w$$

Обучение простой модели $b(x, w')$, возможно, на других данных:

$$\sum_{i=1}^k \mathcal{L}(b(x'_i, w'), a(x'_i, w)) \rightarrow \min_{w'}$$

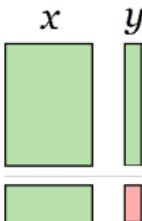
Примеры задач:

- замена сложной модели (климат, аэродинамика и др.), которая вычисляется на суперкомпьютере месяцами, «лёгкой» аппроксимирующей суррогатной моделью
- замена сложной нейросети, которая обучается неделями на больших данных, «лёгкой» аппроксимирующей нейросетью с минимизацией числа нейронов и связей

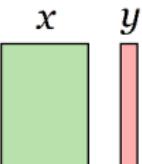
Обучение с использованием привилегированной информации

LUPI — Learning Using Privileged Information

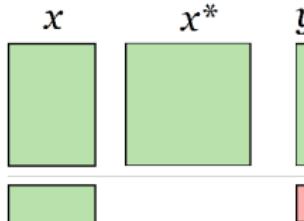
с учителем



без учителя



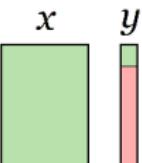
привилегированное (LUPI)



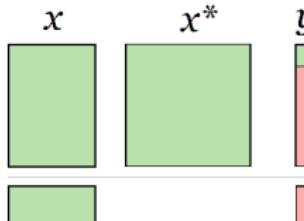
частичное



трансдуктивное



частичное LUPI



V. Vapnik, A. Vashist. A new learning paradigm: Learning Using Privileged Information // Neural Networks. 2009.

Примеры задач с привилегированной информацией x^*

- x — первичная (1D) структура белка
 x^* — третичная (3D) структура белка
 y — иерархическая классификация функции белка
- x — предыстория временного ряда
 x^* — информация о будущем поведении ряда
 y — прогноз следующей точки ряда
- x — текстовый документ
 x^* — выделенные ключевые слова или фразы
 y — категория документа
- x — пара (запрос, документ)
 x^* — выделенные ассессором ключевые слова или фразы
 y — оценка релевантности

Обучение с привилегированной информацией

Раздельное обучение модели-ученика и **модели-учителя**:

$$\sum_{i=1}^{\ell} \mathcal{L}(a(x_i, w), y_i) \rightarrow \min_w \quad \sum_{i=1}^{\ell} \mathcal{L}(a(x_i^*, w^*), y_i) \rightarrow \min_w$$

Модель-ученик обучается повторять ошибки **модели-учителя**:

$$\sum_{i=1}^{\ell} \mathcal{L}(a(x_i, w), y_i) + \mu \mathcal{L}(a(x_i, w), a(x_i^*, w^*)) \rightarrow \min_w$$

Совместное обучение модели-ученика и **модели-учителя**:

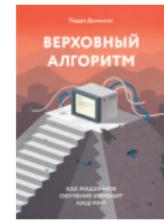
$$\begin{aligned} \sum_{i=1}^{\ell} \mathcal{L}(a(x_i, w), y_i) + \lambda \mathcal{L}(a(x_i^*, w^*), y_i) + \\ + \mu \mathcal{L}(a(x_i, w), a(x_i^*, w^*)) \rightarrow \min_{w, w^*} \end{aligned}$$

D.Lopez-Paz, L.Bottou, B.Scholkopf, V.Vapnik. Unifying distillation and privileged information. 2016.

Основные школы машинного обучения

- ❶ **СИМВОЛИЗМ** – поиск логических закономерностей
 - Decision Tree, Rule Induction
- ❷ **коннекционизм** – обучаемые нейронные сети
 - BackPropagation, Deep Belief Nets, Deep Learning
- ❸ **эволюционизм** – саморазвитие сложных моделей
 - Genetic Algorithms, Genetic Programming, Symbolic Regression
- ❹ **байесионизм** – оценивание распределений параметров
 - Naive Bayes, Bayesian Networks, Graphical Models
- ❺ **аналогизм** – «близким объектам близкие ответы»
 - kNN, RBF, SVM, Kernel Smoothing
- ⊕ **композиционизм** – кооперация моделей
 - Weighted Voting, Boosting, Bagging, Stacking, Random Forest, Яндекс.CatBoost

Домингос П. Верховный алгоритм. 2016. 336 с.



Задача онлайнового обучения

Задача обучения с учителем на потоке данных:

$(x_i, y_i)_{i=1}^{\ell}$ — последовательность прецедентов «объект, ответ»

$a(x, w)$ — параметрическая модель зависимости $y(x)$

$\mathcal{L}(a, y)$ — функция потерь

инициализировать параметры модели w_0 ;

для всех $i = 1, \dots, \ell$

получить очередной объект x_i ;

сделать предсказание $a_i := a(x_i, w_{i-1})$;

получить ответ y_i и оценить потерю $\mathcal{L}_i := \mathcal{L}(a_i, y_i)$;

обновить модель $w_i := \text{Update}(w_{i-1}, x_i, y_i)$;

$$Q(t) = \frac{1}{t} \sum_{i=1}^t \mathcal{L}_i \quad \text{кривая обучения (LOO learning curve)}$$

Steven C. H. Hoi et al. Online learning: a comprehensive survey. 2018

Проблематика инкрементного и онлайнового обучения

- Как эффективно обновить модель по одному прецеденту?
- Как усложнять модель по мере роста объёма данных?
- Как обеспечить то же качество, что в оффлайне?
- Как избежать хранения всей выборки данных?
- Как при этом избежать «катастрофического забывания»?
- Как, добавляя новые объекты, ещё и удалять старые?

Что может добавляться в задачах машинного обучения:

- объекты — основной, но не единственный случай
- признаки
- размерность модели
- классы / кластеры
- подвыборки / подзадачи
- области пространства данных, разладки (concept drift)

Online Learning \neq Incremental Learning. В чём различия?

- **Online** обрабатывает объекты в потоке, по одному
Incremental может накапливать пакеты обновлений
- **Online** может забывать старые данные (catastrophic forgetting)
Incremental часто подразумевает эквивалентность результата оффлайновому обучению по полной выборке
- **Online** исследования озабочены теоретическими гарантиями
Incremental сосредоточен на реализации быстрых алгоритмов
- **Online** обязательно является **Incremental**
Incremental НЕ обязательно является **Online**

Continual (lifelong) learning — обучение одной модели разным задачам так, чтобы новые задачи не вытесняли старые

Anytime algorithm — алгоритм, который обучается по потоку, но в любой момент может быть использован для предсказаний

Задачи прогнозирования временных рядов

Дано: $y_0, y_1, \dots, y_t, \dots$ — временной ряд, $y_i \in \mathbb{R}$

Найти: $\hat{y}_{t+d}(w) = f_{t,d}(y_1, \dots, y_t; w)$ — модель временного ряда,
где $d = 1, \dots, D$, D — горизонт прогнозирования,
 w — вектор параметров модели.

Критерий: минимум среднеквадратичной ошибки прогнозов:

$$\sum_{t=T_0}^T (\hat{y}_{t+d}(w) - y_{t+d})^2 \rightarrow \min_w$$

Пример: линейная модель авторегрессии.

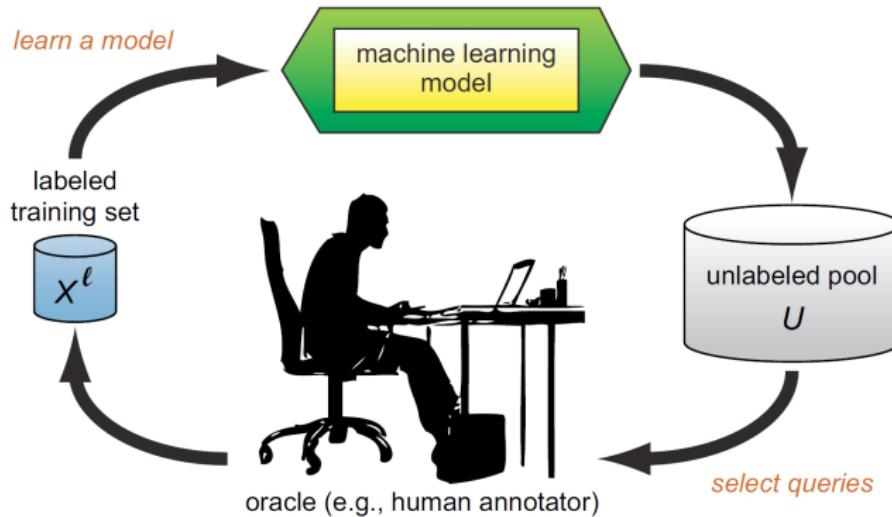
В роли признаков выступают n предыдущих наблюдений ряда:

$$\hat{y}_{t+1}(w) = \sum_{j=1}^n w_j y_{t-j+1}, \quad w \in \mathbb{R}^n$$

В роли объектов $\ell = t - n + 1$ моментов истории ряда.

Постановка задачи активного обучения

Задача: обучение модели $a: X \rightarrow Y$ по выборке (x_i, y_i) ,
когда получение ответов $y_i = y(x_i)$ стоит дорого.



Burr Settles. Active Learning Literature Survey. 2010.

Постановка задачи активного обучения

Задача: обучение модели $a: X \rightarrow Y$ по выборке (x_i, y_i) ,
когда получение ответов $y_i = y(x_i)$ стоит дорого.

Вход: $X^\ell = (x_i, y_i)_{i=1}^\ell$ — выборка размеченных объектов;
 $U = (u_i)_{i=1}^K$ — выборка (пул) неразмеченных объектов;

Выход: модель a и размеченная выборка $(u_i, y_i^*)_{i=1}^k$, $k \leq K$;
обучить модель a по начальной выборке $(x_i, y_i)_{i=1}^\ell$;

пока есть неразмеченные объекты и модель не обучилась

$u_i = \arg \max_{u \in U} \phi(u)$ максимум оценки перспективности;

узнать для него $y_i^* = y(u_i)$;

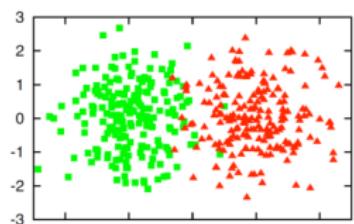
дообучить модель $a(x)$ ещё на одном примере (u_i, y_i^*) ;

Цель: достичь как можно лучшего качества модели a ,
использовав как можно меньше дополнительных примеров k .

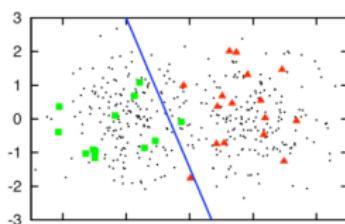
Почему активное обучение быстрее пассивного

Пример. Синтетические данные: $\ell = 30$, $\ell + k = 400$;

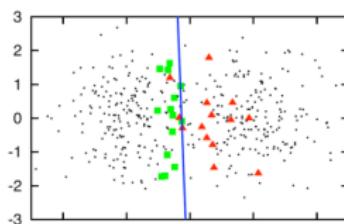
- (a) два гауссовских класса;
логистическая регрессия по 30 объектам:
- (b) случайным;
- (c) отобранным по максимуму неуверенности классификации.



(a)



(b)



(c)

Обучение по смещённой неслучайной выборке требует меньше данных для построения алгоритма сопоставимого качества.

Примеры приложений активного обучения

- сбор ассессорских данных для информационного поиска, анализа текстов, сигналов, речи, изображений, видео
- в том числе на платформах краудсорсинга
- планирование экспериментов в естественных науках или на производстве (пример — комбинаторная химия)
- оптимизация трудно вычислимых функций (пример — оптимизация гиперпараметров, AutoML)

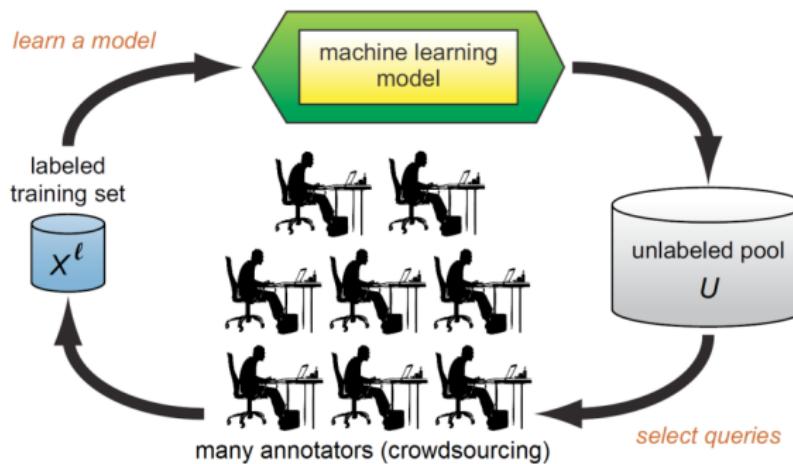
Применения в бизнесе:

- управление ценами и ассортиментом в торговых сетях
- выбор товара для проведения маркетинговой акции
- проактивное взаимодействие с клиентами
- выборочный контроль качества
- выявление аномалий в данных, случаев мошенничества

Краудсорсинг: активное обучение, когда аннотаторов много

y_{it} — ответы аннотаторов $t \in T$ на объекте u_i

Задача: сформировать согласованный ответ (консенсус) \hat{y}_i и оценить надёжность каждого аннотатора $q_t = P[y_{it} = \hat{y}_i]$



Р.А. Гилязев, Д.Ю. Турдаков. Активное обучение и краудсорсинг: обзор методов оптимизации разметки данных. 2018.

Задача о многоруком бандите (multi-armed bandit)

A — конечное множество возможных действий

$p(r|a)$ — неизвестное распределение премии $r \in \mathbb{R}$ для $a \in A$

$\pi_t(a)$ — стратегия (policy) агента в раунде t , распределение на A

Игра агента со средой: инициализация стратегии $\pi_1(a)$;

для всех раундов $t = 1, \dots, T, \dots$

агент выбирает действие $a_t \sim \pi_t(a)$;

среда генерирует премию $r_t \sim p(r|a_t)$;

агент корректирует стратегию $\pi_{t+1}(a)$;

$$Q_t(a) = \frac{\sum_{i=1}^t r_i[a_i = a]}{\sum_{i=1}^t [a_i = a]} \quad \text{— средняя премия в } t \text{ раундах}$$

$$Q^*(a) = \lim_{t \rightarrow \infty} Q_t(a) \rightarrow \max_{a \in A} \quad \text{— ценность действия } a$$

Постановка задачи в случае, когда агент влияет на среду

A — конечное множество возможных действий (action)

S — конечное множество состояний среды (state)

Игра агента со средой: инициализация стратегии $\pi_1(a | s)$ и состояния среды s_1 ;

для всех раундов $t = 1, \dots, T, \dots$

агент выбирает действие $a_t \sim \pi_t(a | s_t)$;

среда генерирует премию $r_t \sim p(r | a_t, s_t)$

и новое состояние $s_{t+1} \sim p(s | a_t, s_t)$;

агент корректирует стратегию $\pi_{t+1}(a | s)$;

Функции ценности:

$$V^\pi(s) = E_\pi \left(\sum_{k=0}^{\infty} \gamma^k r_{t+k} \mid s_t = s \right) — \text{состояния } s$$

$$Q^\pi(s, a) = E_\pi \left(\sum_{k=0}^{\infty} \gamma^k r_{t+k} \mid s_t = s, a_t = a \right) — \text{действия в состоянии } s$$

Примеры прикладных задач

- Управление роботами, технологическими процессами
- Генерация движений персонажей в мультипликации
- Рекомендация новостных статей пользователям
- Показ рекламы в Интернете
- Управление портфелем ценных бумаг, игра на бирже
- Управление ценами и ассортиментом в сетях продаж
- Маршрутизация в телекоммуникационных сетях
- Стратегические игры: шахматы, го, Dota2, StarCraft2, ...

Обобщения постановки задачи:

- Есть информация о состоянии среды или о контексте
- Есть параметрическая модель стратегии/ценности/среды

H. Robbins. Some aspects of the sequential design of experiments. 1952.

Отличия от обычных задач машинного обучения

- выборка (s_t, a_t, r_t) не является независимой
- распределение $p(s_t, a_t, r_t)$ может меняться во времени и зависеть от стратегии агента π
- премии могут быть
 - отложенными (оценивать действия с задержкой)
 - разреженными (почти всё время $r_t = 0$)
 - зашумлёнными (не ясно, за что именно премия)

Какие параметрические модели можно обучать:

- функцию ценности действия в состоянии $Q(s, a; \textcolor{red}{w})$
- функцию ценности состояния $V(s; \textcolor{red}{w})$
- стратегию $\pi_{t+1}(a|s; \textcolor{red}{w})$
- модель среды $(r_t, s_{t+1}) = \mu(s_t, a_t; \textcolor{red}{w})$