

• 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)»

МФТИ.ФПМИ.ИС.ИАД • 19 марта 2026

- 1 Методология решения прикладных задач ML**
 - Стандарт CRISP-DM и взгляд на эволюцию ИИ
 - Понимание задачи и данных
 - Предварительная обработка данных
- 2 Моделирование и оценивание моделей**
 - Типология постановок задач
 - Типология подходов к моделированию
 - Оценивание качества и выбор моделей
- 3 Задачи и методы с обратной связью**
 - Инкрементное и онлайн-обучение
 - 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

Эволюция ИИ как автоматизация 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


Эволюция ИИ как автоматизация 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



Эволюция ИИ как автоматизация 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 структуры

Эволюция ИИ как автоматизация 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 структуры
- *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)
- понижение размерности данных (dimensionality reduction)
- отбор информативных признаков (feature selection)
- восполнение пропусков в данных (missing values imputation)
- выявление аномалий/выбросов (outlier/anomaly detection)

Граница между предобработкой и моделированием нечёткая, глубокое обучение (Deep Learning) стирает её окончательно

Методы обработки пропущенных значений

- игнорировать объекты или признаки с пропусками
— ведёт к потере информации :(
- заполнить пропущенные значения признака f :
— средним или медианным значением \bar{f}
- прогнозировать значения признака f по остальным:
— регрессия для вещественного признака f
— классификация для дискретного признака f
— матричные разложения, автокодировщики
- использовать модели, способные игнорировать пропуски:
— решающие деревья
— голосование низкоразмерных базовых предикторов
- ввести бинарный признак $f'(x) = [f(x) \text{ не известно}]$

Y.Zhoua, S.Aryala, M.R.Bouadjeneka. A Comprehensive Review of Handling Missing Data: Exploring Special Missing Mechanisms. 2024

Методы выявления аномалий, выбросов, новизны

Аномальность объекта (anomaly/novelty/surprise score) — это значение функции потерь $\mathcal{L}(a(x_i, w), y_i)$ на данном объекте

Варианты оценивания аномальности:

- аномальность оценивается для объекта обучающей выборки (outlier) или для нового объекта (novelty)
- потеря зависит от y_i (supervised) или нет (unsupervised)
- при оценивании аномальности обучающего объекта он исключается из выборки ($a(x_i; X^\ell \setminus x_i)$) или нет ($a(x_i; X^\ell)$)
- функция потерь та же, что в критерии обучения или другая

Варианты использования оценок аномальности:

- жёсткое удаление аномальных объектов из выборки
- мягкое перевзвешивание объектов в критерии обучения

M. Salehi et al. A unified survey on anomaly, novelty, open-set, and out-of-distribution detection: solutions and future challenges. 2021.

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 $\mu: X^\ell \rightarrow W$
(empirical risk minimization, ERM), возможно, с регуляризацией:


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

$\mathcal{L}(w, x)$ — функция потерь (loss function),

тем больше, чем хуже модель $a(x, w)$ отработала на объекте x

$\mathcal{R}(w)$ — регуляризатор для формализации дополнительных требований к модели, τ — коэффициент регуляризации


Напоминание. Задачи обучения с учителем



Регрессия: $y_i \in Y = \mathbb{R}$

$$a(x, w) \in Y$$

$$\mathcal{L}(w, x_i) = L(a(x_i, w) - y_i), \text{ например: } L(\varepsilon) = \varepsilon^2$$



Бинарная классификация: $y_i \in Y = \{-1, +1\}$

$$a(x, w) = \text{sign } g(x, w)$$


$$\mathcal{L}(w, x_i) = L(g(x_i, w)y_i), \text{ например: } L(M) = (1-M)_+$$



Многоклассовая классификация: $y_i \in Y, |Y| < \infty$

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

$$\mathcal{L}(w, x_i) = \sum_{y \neq y_i} L(g_{y_i}(x_i, w_{y_i}) - g_y(x_i, w_y))$$



Обучение ранжированию: $y_i \in \{1, \dots, K\}$

$$a(x, w) \in Y = \mathbb{R}$$

$$\mathcal{L}(w, x_i) = \sum_{j: y_i < y_j} L(a(x_j, w) - a(x_i, w))$$


Обучение без учителя и с частичными данными от учителя

- матричные разложения (matrix factorization)
- автокодировщики (autoencoder)
- многомерное шкалирование (multidimensional scaling)
- восстановление плотности распределения (density estimation)
- восстановление смеси распределений (mixture estimation)
- кластеризация (clustering)
- поиск ассоциативных правил (association rule learning)

Частичное обучение (semi-supervised learning)

- трансдуктивное обучение (transductive learning)
- одноклассовая классификация (one-class classification)
- обучение только на положительных примерах (PU-learning)

Задачи обучения без учителем



Автокодировщик:

$g(f(x_i, \alpha), \beta) = \hat{x}_i$ — реконструкция объекта


$$\mathcal{L}(\alpha, \beta; x_i) = \|\hat{x}_i - x_i\|$$



Восстановление плотности распределения:

$x_i \stackrel{\text{i.i.d.}}{\sim} p(x | \theta)$ — параметризация плотности


$$\mathcal{L}(\theta, x_i) = -\ln p(x_i | \theta)$$



Восстановление смеси плотностей:

$x_i \stackrel{\text{i.i.d.}}{\sim} p(x | \theta, w) = \sum_j w_j p(x | \theta_j)$, $w_j \geq 0$, $\sum_j w_j = 1$

$$\mathcal{L}(\theta, w; x_i) = -\ln p(x_i | \theta, w)$$



Кластеризация:

$a(x, w) = \arg \min_{y \in Y} \|x_i - w_y\|$, $|Y| < \infty$

$$\mathcal{L}(w, x_i) = \|x_i - \mu_{a(x_i, w)}\|$$

Задачи с совместным обучением нескольких моделей

Одновременное обучение:

- обучение автокодировщика (autoencoder)
- обучаемая векторизация данных (representation learning)
- многозадачное обучение (multi-task learning)
- состязательное обучение (adversarial learning, GAN)
- частичное обучение (semi-supervised learning)

Последовательное обучение:

- предобучение (pre-training)
- перенос обучения (transfer learning)
- самостоятельное обучение (self-supervised learning)
- дистилляция моделей или суррогатное моделирование
- обучение с привилегированной информацией (learning using privileged information, LUPI)

Задача частичного обучения (semi-supervised learning, SSL)

Дано:

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

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

Найти: $\{a_{k+1}, \dots, a_\ell\} \in Y$ — метки неразмеченных объектов

Критерий SSL без модели классификации (transductive learning):

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

Найти–Критерий SSL с параметрической моделью $a(x_i, w)$:

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

Суть **SSL** — это общая параметризация w в двух критериях, не обязательно классификации, не обязательно кластеризации

Дистилляция моделей и 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



трандуктивное



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 — данные баллистокордиографии
 x^* — данные ЭКГ (мониторирование по Холтеру)
 y — диагноз
- x — текстовый документ
 x^* — выделенные ключевые слова, фразы, фрагменты
 y — категория документа
- x — пара (запрос, документ)
 x^* — выделенные ассессором ключевые слова или фразы
 y — оценка релевантности

Задача обучения с привилегированной информацией

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

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

Модель-ученик a обучается быть не хуже модели-учителя a^* :

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

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


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

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

Пять (шесть) школ машинного обучения по П.Домингосу

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

Педро Домингос. Верховный алгоритм. 2016. 336 с.



Анализ ошибок бинарной классификации

Задача бинарной классификации: $y_i, a(x_i) \in \{-1, +1\}$.

	модель классификации	учитель
TP, True Positive	$a(x_i) = +1$	$y_i = +1$
TN, True Negative	$a(x_i) = -1$	$y_i = -1$
FP, False Positive	$a(x_i) = +1$	$y_i = -1$
FN, False Negative	$a(x_i) = -1$	$y_i = +1$

FP: ложноположительно, ошибка I рода, «ложная тревога»

FN: ложноотрицательно, ошибка II рода, «пропуск цели»

Правильность классификации (чем больше, тем лучше):

$$\text{Accuracy} = \frac{1}{\ell} \sum_{i=1}^{\ell} [a(x_i) = y_i] = \frac{\text{TP} + \text{TN}}{\text{FP} + \text{FN} + \text{TP} + \text{TN}}$$

Недостаток: не учитывается дисбаланс численности классов, а также различие цены ошибки I и II рода.

ROC-кривая (Receiver Operating Characteristic)

Модель классификации: $a(x; w, w_0) = \text{sign}(g(x, w) - w_0)$

Кривая ROC: как меняется качество a при варьировании w_0
(чем больше w_0 , тем больше x_i , на которых $a(x_i) = -1$)

- по оси X : доля ошибочных положительных классификаций (FPR — false positive rate):

$$\text{FPR}(a) = \frac{\text{FP}}{\text{FP} + \text{TN}} = \frac{\sum_{i=1}^{\ell} [y_i = -1][a(x_i; w, w_0) = +1]}{\sum_{i=1}^{\ell} [y_i = -1]}$$

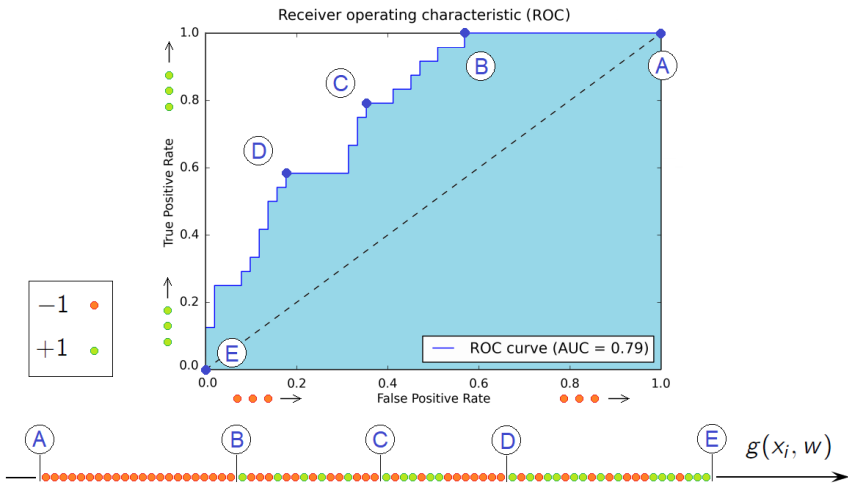
$1 - \text{FPR}(a)$ называется специфичностью алгоритма a

- по оси Y : доля правильных положительных классификаций (TPR — true positive rate):

$$\text{TPR}(a) = \frac{\text{TP}}{\text{TP} + \text{FN}} = \frac{\sum_{i=1}^{\ell} [y_i = +1][a(x_i; w, w_0) = +1]}{\sum_{i=1}^{\ell} [y_i = +1]}$$

$\text{TPR}(a)$ называется также чувствительностью алгоритма a

ROC-кривая и площадь под кривой AUC (Area Under Curve)



ABCDE — положения порога w_0 на оси значений функции g

Задача максимизации AUROC — площади под ROC-кривой

Модель классификации: $a(x; w, w_0) = \text{sign}(g(x, w) - w_0)$

AUROC равна доле правильно упорядоченных пар (x_i, x_j) , это критерий бинарного ранжирования с парной функцией потерь:

$$\begin{aligned} \text{AUROC}(w) &= \frac{1}{\ell_-} \sum_{i=1}^{\ell} [y_i = -1] \text{TPR}_i = \\ &= \frac{1}{\ell_- \ell_+} \sum_{i=1}^{\ell} \sum_{j=1}^{\ell} [y_i < y_j] [g(x_i, w) < g(x_j, w)] \rightarrow \max_w \end{aligned}$$

Критерий максимума аппроксимированного AUROC:

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

$$1 - \text{AUROC}(w) \leq Q(w) = \sum_{i,j: y_i < y_j} \underbrace{L(g(x_j, w) - g(x_i, w))}_{M_{ij}(w)} \rightarrow \min_w$$

SG: градиентные шаги по парам объектов (x_i, x_j) : $y_i < y_j$

Точность и полнота бинарной классификации

В информационном поиске не важен TN:

$$\text{Точность, Precision} = \frac{TP}{TP+FP}$$

$$\text{Полнота, Recall} = \frac{TP}{TP+FN}$$

$$\text{F-мера} = \frac{2PR}{P+R}$$

Precision — доля релевантных среди найденных

Recall — доля найденных среди релевантных


В медицинской диагностике важно всё:

$$\text{Чувствительность, Sensitivity} = \frac{TP}{TP+FN}$$

$$\text{Специфичность, Specificity} = \frac{TN}{TN+FP}$$

Sensitivity — доля верных положительных диагнозов

Specificity — доля верных отрицательных диагнозов



Точность и полнота многоклассовой классификации

Для каждого класса $y \in Y$:

TP_y — верные положительные

FP_y — ложные положительные


FN_y — ложные отрицательные

Точность и полнота с микроусреднением:

$$\text{Precision: } P = \frac{\sum_y TP_y}{\sum_y (TP_y + FP_y)};$$

$$\text{Recall: } R = \frac{\sum_y TP_y}{\sum_y (TP_y + FN_y)};$$

Микроусреднение не чувствительно
 к ошибкам на малочисленных классах



Точность и полнота многоклассовой классификации

Для каждого класса $y \in Y$:

TP_y — верные положительные

FP_y — ложные положительные


FN_y — ложные отрицательные

Точность и полнота с макроусреднением:

$$\text{Precision: } P = \frac{1}{|Y|} \sum_y \frac{TP_y}{TP_y + FP_y};$$

$$\text{Recall: } R = \frac{1}{|Y|} \sum_y \frac{TP_y}{TP_y + FN_y};$$



Макроусреднение чувствительно
 к ошибкам на малочисленных классах



Кривые ROC и Precision-Recall

Модель классификации: $a(x) = \text{sign}(\langle x, w \rangle - w_0)$

Каждая точка кривой соответствует значению порога w_0



AUROC — площадь под ROC-кривой

AUPRC — площадь под кривой Precision-Recall

Примеры из Python scikit learn: <http://scikit-learn.org/dev>

Оценивание обобщающей способности и выбор 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

$\mu_t: X^\ell \rightarrow W_t$ — 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 $a(x, w)$ на X^ℓ

$\mu: X^\ell \rightarrow W$ — метод обучения модели $a(x, w)$, $w \in W$

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 :

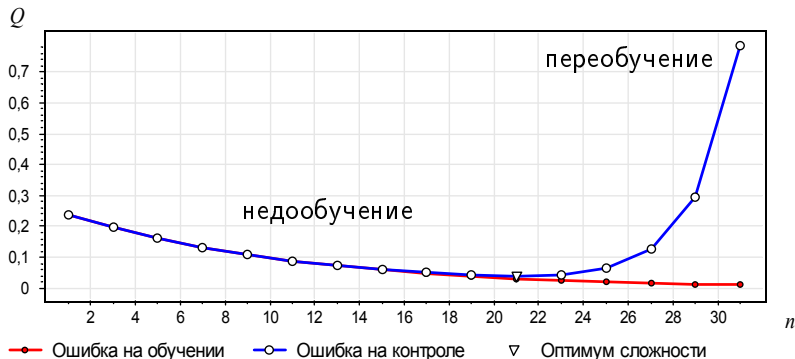
$$Q_\mu(X^\ell, X^k) = Q(\mu(X^\ell), X^k)$$

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 параметров $\dim w$ или числа признаков n).

Внешний критерий не подвержен переобучению, имеет минимум, соответствующий оптимальной сложности модели:



Кросс-проверка (cross-validation, CV)

Усреднение по множеству разбиений $X^L = X_n^\ell \sqcup X_n^k$, $n \in N$:

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

- $|N| = 1$ — единственное (случайное) разбиение: *hold-out*
- N — множество случайных разбиений: *метод Монте-Карло*
- $N = \{(X^L \setminus \{x_i\}) \sqcup \{x_i\}\}_{i=1..L}$, каждый объект становится контролем один раз, *скользящий контроль (leave one out)*
- $N = \{(X^L \setminus B_n) \sqcup B_n\}_{n=1..q}$, где $B_1 \sqcup \dots \sqcup B_q = X^L$
— разбиение *на q блоков* равной ± 1 длины (*q -fold CV*),
каждый объект участвует в контроле один раз
- $N = \{(X^L \setminus B_n^s) \sqcup B_n^s\}_{n=1..q, s=1..t}$, где $B_1^s \sqcup \dots \sqcup B_q^s = X^L$
— t разбиений *на q блоков* равной ± 1 длины (*$t \times q$ -fold CV*),
каждый объект участвует в контроле ровно t раз
- N — все $C_{\ell+k}^k$ разбиений: *complete cross-validation, CCV*

Методология анализа ошибок (потерь)

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

Среднее потерь на выборке U и эмпирическое распределение:

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

$$F(\lambda; w, U) = \frac{1}{|U|} \sum_{x_i \in U} [\mathcal{L}(w, x_i) \leq \lambda]$$

Анализ потерь на обучающей выборке $U = X^\ell$:

- 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?

Сравнение потерь на обучении $U = X^\ell$ и тесте $U = X^k$:

- Сильно ли отличаются распределения потерь?
- Если сильно, то это переобучение — как его устранить?

Автоматический выбор моделей и гиперпараметров (AutoML)

Проблема: подбор структуры модели, архитектуры нейросети, значений гиперпараметров требуют слишком много ресурсов

Дано: выборка «задача, структура» → внешние критерии

Найти: условия следующего эксперимента с моделью

Критерий: минимум затрат ресурсов на поиск оптимальной модели, сопоставимой по качеству с моделями, построенными профессиональными исследователями

Близкая классическая задача — *планирование экспериментов*

Ф.Хуттер, Л.Коттхофф, Х.Ваншорен. Введение в автоматизированное машинное обучение (AutoML). 2023.

П.Браздил, Я.В.Рейн, К.Соарес, Х.Ваншорен. Метаобучение. Применение в AutoML и науке о данных. 2023.

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

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

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

Проблема: слишком много методов, слишком долго запускать

Дано: выборка «задача, метод» → внешние критерии

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

Критерий: отличие предсказанного метода от оптимального
по выбранному для задачи внешнему критерию качества

Признаки объекта «задача»:

- 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.

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

Две модели, «базовая A» и «улучшенная B»,
построенные по историческим данным X^ℓ ,
тестируются по выбранным метрикам 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, но злоупотреблять выбором из многих моделей не стоит
- накопление данных X^k может потребовать много времени — отсечку времени между A и B можно двигать в прошлое
- работа модели может формировать смещённый поток данных (например, в рекомендательных системах)

Задача онлайнного обучения с учителем

Дано: $(x_i, y_i)_{i=1}^{\ell}$ — поток объектов с ответами

Найти: $a(x, w)$ — адаптивную модель $y(x)$ с параметром w и правило обновления параметров модели $w_{i-1} \mapsto w_i$

Критерий: убывание кривой обучения (LOO learning curve)

$$Q(t) = \frac{1}{t} \sum_{i=1}^t \mathcal{L}(a(x_i, w_{i-1}), y_i) \rightarrow \min,$$

где $\mathcal{L}(a, y)$ — потеря модели a в сравнении с y

инициализировать параметры модели w_0 ;

для всех $i = 1, \dots, \ell$

получить объект x_i и предсказать $a_i := a(x_i, w_{i-1})$;

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

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

Проблематика инкрементного и онлайнного 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 не забывать ранее выученный материал?
- Либо, наоборот, как забывать самые старые объекты?

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 отличия?

- **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: $Y_t = (y_0, y_1, \dots, y_t)$ — временной ряд, $y_i \in \mathbb{R}$

Найти: $\hat{y}_{t+d}(Y_t, w)$ — модель прогноза на момент $t + d$
где w — вектор параметров модели,
 $d = 1, \dots, D$, D — горизонт прогнозирования

Критерий: минимум среднеквадратичной ошибки прогнозов:

$$\sum_{d=1}^D \sum_{t=T_0}^T (\hat{y}_{t+d}(Y_t, w) - y_{t+d})^2 \rightarrow \min_w$$


Пример: линейная модель *авторегрессии*. В роли признаков выступают непосредственно n предыдущих наблюдений ряда:

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

Обучающая выборка: $\ell = t - n + 1$ моментов истории ряда

Постановка задачи активного обучения

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



Burr Settles. Active Learning Literature Survey. 2010.

Постановка задачи активного обучения

- Дано:** $X^\ell = (x_i, y_i)_{i=1}^\ell$ — выборка размеченных объектов
 $U = (u_i)_{i=1}^K$ — пул неразмеченных объектов
- Найти:** $\varphi(u)$ — модель перспективности разметки $u \in U$
 $a(x, w)$ — модель с инкрементным обучением
 $(u_i, y_i^*)_{i=1}^k, k \leq K$ — размеченная выборка
- Критерий:** достичь как можно лучшего качества модели a ,
разметив как можно меньше объектов из U

обучить модель a по начальной выборке $(x_i, y_i)_{i=1}^\ell$;

пока есть неразмеченные объекты и модель не обучилась

$u_i = \arg \max_{u \in U} \varphi(u)$ — наиболее перспективный объект;

$y_i^* = y(u_i)$ — запросить ответ учителя (оракула);

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

Почему активное обучение быстрее пассивного


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

(a) два гауссовских класса;


логистическая регрессия, обученная 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 вычисляемых функций (пример — оптимизация гиперпараметров, AutoML)

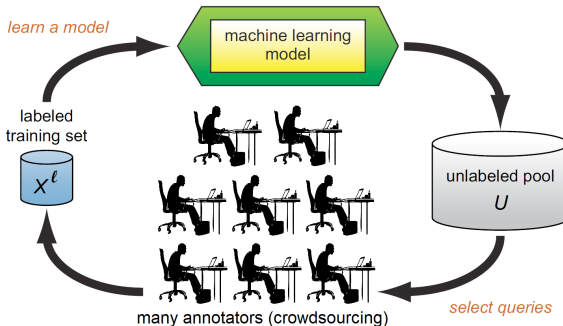
Применения в бизнесе:

- 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)

- Дано:** агент, действующий в среде $\langle A, p(r|a) \rangle$
 A — конечное множество *действий* (action, arm)
 $p(r|a)$ — неизвестное распределение *премии* за $a \in A$
- Найти:** $\pi_t(a)$ — *стратегию* (policy) агента в раундах t ,
распределение на множестве действий A
- Критерий:** $\sum_{t=1}^T r_t \rightarrow \max$ — суммарная премия в конце игры

Игра агента со средой: инициализация стратегии $\pi_1(a)$;
для всех раундов $t = 1, \dots, T$

- агент выбирает действие $a_t \sim \pi_t(a)$;
- среда генерирует премию $r_t \sim p(r|a_t)$;
- агент корректирует стратегию $\pi_{t+1}(a)$;

$$Q(a) = \lim_{T \rightarrow \infty} \frac{\sum_{t=1}^T r_t [a_t = a]}{\sum_{t=1}^T [a_t = a]} \rightarrow \max_{a \in A} \text{ — ценность действия } a$$

Постановка задачи в случае, когда агент влияет на среду

- Дано:** агент, действующий в среде $\langle A, S, p(r | a, s), p(s | a, s) \rangle$
 A — конечное множество *действий* (action, arm)
 S — **конечное множество состояний среды** (state)
 $p(r | a, s)$ — неизвестное распределение премий
 $p(s' | a, s)$ — **неизвестное распределение переходов**
- Найти:** $\pi_t(a | s)$ — *стратегия* (policy) агента в раундах t
- Критерий:** $\sum_{t=1}^T r_t \rightarrow \max$ — суммарная премия в конце игры

Игра агента со средой: инициализация $s_1, \pi_1(a | s_1)$;

для всех раундов $t = 1, \dots, T$

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

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

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

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

Отличия от обычных задач машинного обучения


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

Параметрические модели, которые можно обучать:

- функция ценности действия в состоянии $Q(s, a; \mathbf{w})$
$$Q^\pi(s, a) = \mathbb{E}_\pi \left(\sum_{k=0}^{\infty} \gamma^k r_{t+k} \mid s_t = s, a_t = a \right)$$
- функция ценности состояния $V(s; \mathbf{w})$
$$V^\pi(s) = \mathbb{E}_\pi \left(\sum_{k=0}^{\infty} \gamma^k r_{t+k} \mid s_t = s \right)$$
- стратегия $\pi_{t+1}(a \mid s; \mathbf{w})$
- предсказательная модель среды $(r_t, s_{t+1}) = \mu(s_t, a_t; \mathbf{w})$

Примеры прикладных задач

- Управление роботами, технологическими процессами
- Рекомендация товаров, новостей, рекламы
- Управление портфелем ценных бумаг, игра на бирже
- Управление ценами и ассортиментом в сетях продаж
- Маршрутизация в телекоммуникационных сетях
- Генерация движений персонажей в мультипликации
- Обучение LLM с обратной связью от пользователей (RLHF)
- Мультиагентные системы
- Стратегические игры: шахматы, го, Atari, Dota2, StarCraft2



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

V.Mnih et al. (DeepMind). Playing Atari with deep reinforcement learning. 2013

По исходным данным:

- данные табличные / сложно структурированные
- данные статичные / динамичные, потоковые, во времени
- данные малые / большие, в том числе распределённые

По постановкам задачи обучения:

- обучение с учителем / без учителя / частично с учителем
- обучение одной модели / совместно нескольких моделей
- обучение статичное / динамичное, с обратной связью

По подходам к построению моделей:

- эвристическая основа — 5(6) научных школ по Домингосу
- модель предиктивная / генеративная
- структура модели глубокая (deep) / неглубокая (shallow)

Николенко С. Машинное обучение: основы, 2025.

Николенко С., Кадурин А., Архангельская Е. Глубокое обучение: основы, 2024.

Марков С. Охота на электроовец. Большая книга искусственного интеллекта. В 2-х томах. 2024. (<https://markoff.science>)