

Активное обучение (Active Learning)

К. В. Воронцов
vokov@forecsys.ru

Этот курс доступен на странице вики-ресурса
<http://www.MachineLearning.ru/wiki>
«Машинное обучение (курс лекций, К.В.Воронцов)»

1 ноября 2017

1 Задачи активного обучения

- Постановка задачи активного обучения
- Приложения активного обучения
- Стратегии активного обучения

2 Стратегии активного обучения


- Отбор объектов из выборки
- Синтез объектов (планирование экспериментов)
- Оценивание качества активного обучения

3 Активное обучение с изучающими действиями

- Компромисс «изучение–применение» в активном обучении
- Экспоненциальный градиент
- Активное обучение с подкреплением

Постановка задачи активного обучения

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



Burr Settles. Active Learning Literature Survey. 2010.

Постановка задачи активного обучения

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

Вход: начальная размеченная выборка $X^\ell = (x_i, y_i)_{i=1}^\ell$;

Выход: модель a и размеченная выборка $(x_i, y_i)_{i=\ell+1}^{\ell+k}$;

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

пока остаются неразмеченные объекты

 | выбрать неразмеченный объект x_i ;

 | узнать для него y_i ;

 | дообучить модель a ещё на одном примере (x_i, y_i) ;

Цель активного обучения:

достичь как можно лучшего качества модели a ,

использовав как можно меньше дополнительных примеров k .

Примеры приложений активного обучения

- сбор ассессорских данных для информационного поиска, анализа текстов, сигналов, речи, изображений, видео
- планирование экспериментов в естественных науках (пример — комбинаторная химия)
- оптимизация трудно вычислимых функций (пример — поиск в пространстве гиперпараметров)
- управление ценами и ассортиментом в торговых сетях
- выбор товара для проведения маркетинговой акции

Стратегии активного обучения

- Отбор объектов из выборки (pool-based sampling):
какой следующий x_i выбрать из множества $X^k = \{x_i\}_{i=\ell+1}^{\ell+k}$
- Синтез объектов (query synthesis):
на каждом шаге построить оптимальный объект x_i ;
- Отбор объектов из потока (selective sampling):
для каждого приходящего x_i решать, стоит ли узнавать y_i .

Функционал качества модели $a(x, \theta)$ с параметром θ :

$$\sum_{i=1}^{\ell+k} C_i \mathcal{L}(\theta; x_i, y_i) \rightarrow \min_{\theta},$$

где \mathcal{L} — функция потерь, C_i — стоимость информации y_i для методов, чувствительных к стоимости (cost-sensitive)

Сэмплирование по неуверенности (uncertainty sampling)

Идея: выбирать x_i с наибольшей неопределенностью $a(x_i)$.

Задача многоклассовой классификации:

$$a(x) = \arg \max_{y \in Y} P(y|x)$$

$p_k(x)$, $k=1\dots|Y|$ — ранжированные по убыванию $P(y|x)$, $y \in Y$.

- Принцип наименьшей достоверности (least confidence):

$$x_i = \arg \min_{u \in X^k} p_1(u)$$

- Принцип наименьшей разности отступов (margin sampling):

$$x_i = \arg \min_{u \in X^k} (p_1(u) - p_2(u))$$

- Принцип максимума энтропии (maximum entropy):

$$x_i = \arg \min_{x \in X^k} \sum_k p_k(u) \ln p_k(u)$$


Сэмплирование по неуверенности (uncertainty sampling)

В случае двух классов эти три принципа эквивалентны.

В случае многих классов появляются различия.

Пример. Три класса, $p_1 + p_2 + p_3 = 1$.

Показаны линии уровня трёх критериев выбора объекта x_i :




Burr Settles. Active Learning Literature Survey. 2010.


Почему активное обучение быстрее пассивного

Пример 1. Синтетические данные: $\ell = 30$, $\ell + k = 400$;


- (a) два гауссовых класса;
- (b) логистическая регрессия по 30 случайным объектам;
- (c) логистическая регрессия по 30 объектам, отобранным с помощью активного обучения.



(a)



(b)



(c)

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


Почему активное обучение быстрее пассивного

Пример 2. Одномерная задача с пороговым классификатором:

$$x_i \sim \text{uniform}[-1, +1], \quad y_i = [x_i > 0], \quad a(x, \theta) = [x > \theta].$$

Оценим число шагов для определения θ с точностью $\frac{1}{k}$.

- Наивная стратегия: выбирать $x_i \sim \text{uniform}(X^k)$;
— число шагов $O(k)$.
- Бинарный поиск: выбирать x_i , ближайший к середине зазора между классами $\frac{1}{2}(\max_{y_j=0}(x_j) + \min_{y_j=1}(x_j))$;
— число шагов $O(\log k)$.



Сэмплирование по несогласию в комитете (query by committee)

Идея: выбирать x_i с наибольшей несогласованностью решений комитета моделей $a_t(x_i) = \arg \max_{y \in Y} P_t(y|x), t = 1, \dots, T$.

- Принцип максимума энтропии:

выбираем x_i , на котором $a_t(x_i)$ максимально различны:

$$x_i = \arg \min_{u \in X^k} \sum_{y \in Y} \hat{p}(y|u) \ln \hat{p}(y|u),$$

где $\hat{p}(y|u) = \frac{1}{T} \sum_{t=1}^T [a_t(u) = y]$.

- Принцип максимума средней KL -дивергенции:

выбираем x_i , на котором $P_t(y|x_i)$ максимально различны:


$$x_i = \arg \max_{u \in X^k} \sum_{t=1}^T \text{KL}(P_t(y|u) \parallel \bar{P}(y|u)),$$

где $\bar{P}(y|u) = \frac{1}{T} \sum_{t=1}^T P_t(y|u)$ — консенсус комитета.

Сокращение пространства решений (version space reduction)

Идея: выбирать x_i , максимально сужая множество решений.

Пример. Пространства допустимых решений для линейных и пороговых классификаторов (двумерный случай):



Бустинг и бэггинг находят конечные подмножества решений. Поэтому сэмплирование по несогласию в комитете — это аппроксимация принципа сокращения пространства решений.

Ожидаемое изменение модели (expected model change)

Идея: выбрать x_i , который в методе стохастического градиента привёл бы к наибольшему изменению модели.

Параметрическая модель многоклассовой классификации:

$$a(x, \theta) = \arg \max_{y \in Y} P(y|x, \theta);$$

Для каждого $u \in X^k$ и $y \in Y$ оценим длину градиентного шага в пространстве параметров θ при дообучении модели на (u, y) ; пусть $\nabla_{\theta}\mathcal{L}(\theta; u, y)$ — вектор градиента функции потерь.

Принцип максимума ожидаемой длины градиента:

$$x_i = \arg \max_{u \in X^k} \sum_{y \in Y} P(y|u, \theta) \|\nabla_{\theta}\mathcal{L}(\theta; u, y)\|.$$

Ожидаемое сокращение ошибки (expected error reduction)

Идея: выбрать x_i , который после обучения даст наиболее уверенную классификацию неразмеченной выборки X^k .

Для каждого $u \in X^k$ и $y \in Y$ обучим модель классификации, добавив к размеченной обучающей выборке X^ℓ пример (u, y) :

$$a_{uy}(x) = \arg \max_{z \in Y} P_{uy}(z|x).$$

- Принцип максимума уверенности на неразмеченных данных:

$$x_i = \arg \max_{u \in X^k} \sum_{y \in Y} P(y|u) \sum_{j=\ell+1}^{\ell+k} P_{uy}(a_{uy}(x_j)|x_j).$$

- Принцип минимума энтропии неразмеченных данных:

$$x_i = \arg \max_{u \in X^k} \sum_{y \in Y} P(y|u) \sum_{j=\ell+1}^{\ell+k} \sum_{z \in Y} P_{uy}(z|x_j) \log P_{uy}(z|x_j).$$

Сокращение дисперсии (variance reduction)

Идея: выбрать x , который после дообучения модели $a(x, \theta)$ даст наименьшую оценку дисперсии $\sigma_a^2(x)$.

Задача регрессии, метод наименьших квадратов:

$$S^2(\theta) = \frac{1}{\ell} \sum_{i=1}^{\ell} (a(x_i, \theta) - y_i)^2 \rightarrow \min_{\theta}.$$

Из теории оптимального планирования экспериментов (OED, optimal experiment design):

$$x = \arg \min_{x \in X} \sigma_a^2(x), \quad \sigma_a^2(x) \approx S^2 \left(\frac{\partial a(x)}{\partial \theta} \right)^T \left(\frac{\partial S^2}{\partial \theta^2} \right)^{-1} \left(\frac{\partial a(x)}{\partial \theta} \right).$$

В частности, для линейной регрессии

$$\sigma_a^2(x) \approx S^2 x^T (F^T F)^{-1} x,$$

где F — матрица объекты–признаки.

Взвешивание по плотности (density-weighted methods)

Идея: понижать вес нерепрезентативных объектов.

Пример. Объект A более
пограничный, но менее
репрезентативный, чем B.



Любой критерий сэмплирования объектов, имеющий вид

$$x_i = \arg \max_x \phi(x),$$


может быть уточнён локальной оценкой плотности:

$$x_i = \arg \max_x \phi(x) \left(\sum_{j=\ell+1}^{\ell+k} \text{sim}(x, x_j) \right)^\beta,$$

$\text{sim}(x, x_j)$ — оценка близости x и x_j (чем ближе, тем больше).

Оценивание качества активного обучения

Кривая обучения (learning curve) — зависимость точности классификации на тесте от числа обучающих объектов.



Burr Settles. Active Learning Literature Survey. 2010.

Необходимость изучающих действий в активном обучении

Недостатки стратегий активного обучения:

- остаются не обследованные области пространства X ,
- в результате снижается качество обучения,
- увеличивается время обучения.

Идеи применения изучающих действий:

- брать случайный объект с вероятностью ε
- адаптировать параметр ε в зависимости от успешности изучающих действий
- использовать обучение с подкреплением (contextual MAB)

Djallel Bouneffouf et al. Contextual bandit for active learning: active Thompson sampling. 2014.

Djallel Bouneffouf. Exponentiated Gradient Exploration for Active Learning. 2016.

Алгоритм ε -active

Алгоритм — обёртка над любой стратегией активного обучения

Вход: начальная размеченная выборка $X^\ell = (x_i, y_i)_{i=1}^\ell$;

Выход: модель a и размеченная выборка $(x_i, y_i)_{i=\ell+1}^{\ell+k}$;

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

пока остаются неразмеченные объекты

выбрать неразмеченный x ; случайно с вероятностью ε ,

либо $x_i = \arg \max_x \phi(x)$ с вероятностью $1 - \varepsilon$;

узнать y_i для объекта x_i ;

дообучить модель a ещё на одном примере (x_i, y_i) ;

Проблема:

как подбирать вероятность ε исследовательских действий?

как её адаптировать (уменьшать) со временем?

Экспоненциальный градиент (Exponential Gradient)

$\varepsilon_1, \dots, \varepsilon_K$ — сетка значений параметра ε ;

p_1, \dots, p_K — вероятности использовать значения $\varepsilon_1, \dots, \varepsilon_K$;

β, τ, κ — параметры метода.

Идея алгоритма EG-active: аналогично алгоритму AdaBoost, экспоненциально увеличивать p_k в случае успеха ε_k :

- экспоненциальное обновление весов w_k по значению критерия $\phi(x_i)$ на выбранном объекте x_i :

$$w_k := w_k \exp\left(\frac{\tau}{p_k}(\phi(x_i) + \beta)\right);$$

- перенормировка вероятностей:

$$p_k := (1 - \kappa) \frac{w_k}{\sum_j w_j} + \kappa \frac{1}{K}.$$

Алгоритм EG-active

Вход: $X^\ell = (x_i, y_i)_{i=1}^\ell$, параметры $\varepsilon_1, \dots, \varepsilon_K$, β , τ , κ ;

Выход: модель a и размеченная выборка $(x_i, y_i)_{i=\ell+1}^{\ell+k}$;

инициализация: $p_k := \frac{1}{K}$, $w_k := 1$;

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

пока остаются неразмеченные объекты

выбрать k из дискретного распределения (p_1, \dots, p_K) ;

выбрать неразмеченный x_i случайно с вероятностью ε_k ,

либо $x_i = \arg \max_x \phi(x)$ с вероятностью $1 - \varepsilon_k$;

узнать y_i для объекта x_i ;

дообучить модель a ещё на одном примере (x_i, y_i) ;

$w_k := w_k \exp\left(\frac{\tau}{p_k}(\phi(x_i) + \beta)\right)$;

$p_k := (1 - \kappa) \frac{w_k}{\sum_j w_j} + \kappa \frac{1}{K}$;

Применение обучения с подкреплением для активного обучения

Недостатки стратегий активного обучения:

- остаются не обследованные области пространства X ,
- в результате снижается качество обучения,
- увеличивается время обучения.

Идеи применения контекстного бандита (contextual MAB):

- **действия (ручки)** — это кластеры объектов,
- **контекст кластера** — его векторное признаковое описание,
- **премия** поощряет изменение модели $a(x, \theta)$,
- **линейная модель** используется для выбора действий.

Djallel Bouneffouf et al. Contextual bandit for active learning: active Thompson sampling. 2014.

William R. Thompson. On the likelihood that one unknown probability exceeds another in view of the evidence of two samples. 1933.

Томпсоновское сэмплирование (Thompson sampling)

C — множество действий (ручек, кластеров объектов),
 $b_{tc} \in \mathbb{R}^n$ — вектор признаков кластера $c \in C$ на шаге t ,
 $w \in \mathbb{R}^n$ — вектор коэффициентов линейной модели.

Игра агента и среды (contextual bandit with linear payoff):

инициализация априорного распределения $p_1(w)$;
для всех $t = 1, \dots, T$

среда сообщает агенту контексты b_{tc} для всех $c \in C$;
агент сэмплирует вектор линейной модели $w_t \sim p_t(w)$;
агент выбирает действие $c_t = \arg \max_{c \in C} \langle b_{tc}, w_t \rangle$;

среда генерирует премию r_t ;
агент корректирует распределение по формуле Байеса:
 $p_{t+1}(w) \propto p(r_t|w)p_t(w)$;

Томпсоновское сэмплирование (гауссовский случай)

Априорные и апостериорные распределения — гауссовские.

Игра агента и среды (contextual bandit with linear payoff):

инициализация: $B = I_{n \times n}$; $w = 0_n$; $f = 0_n$;

для всех $t = 1, \dots, T$

среда сообщает агенту контексты b_{tc} для всех $c \in C$;

агент сэмплирует вектор линейной модели

$w_t \sim \mathcal{N}(w, \sigma^2 B^{-1})$;

агент выбирает действие $c_t = \arg \max_{c \in C} \langle b_{tc}, w_t \rangle$;

среда генерирует премию r_t ;

агент корректирует распределение по формуле Байеса:

$B := B + b_{tc} b_{tc}^\top$; $f := f + b_{tc} r_t$; $w := B^{-1} f$;

Рекомендуемое значение константы $\sigma^2 = 0.25$.

Активное томпсоновское сэмплирование

Игра агента и среды (встраиваем активное обучение)

$C :=$ кластеризация неразмеченной выборки X^k ;

инициализация: $B = I_{n \times n}$; $w = 0_n$; $f = 0_n$;

для всех $t = 1, \dots, T$, пока остаются неразмеченные объекты

вычислить контексты b_{tc} для всех кластеров $c \in C$;

сэмплировать вектор линейной модели $w_t \sim \mathcal{N}(w, \sigma^2 B^{-1})$;

выбрать кластер $c_t = \arg \max_{c \in C} \langle b_{tc}, w_t \rangle$;

выбрать случайный неразмеченный x_i из кластера c_t ;

узнать для него y_i ;

дообучить модель a ещё на одном примере (x_i, y_i) ;

вычислить премию r_t (формула на следующем слайде);

скорректировать распределение по формуле Байеса:

$B := B + b_{tc} b_{tc}^\top$; $f := f + b_{tc} r_t$; $w := B^{-1} f$;

Как вычисляются премии


Идея: премия поощряет изменение модели $a(x, \theta)$.

$H_t = (a(x_i, \theta_t))_{i=1}^{\ell+k}$ — вектор ответов на выборке $X^\ell \cup X^k$

Премия — угол между векторами H_t и H_{t-1} :

$$r_t := e^{\beta t} \arccos \frac{\langle H_t, H_{t-1} \rangle}{\|H_t\| \|H_{t-1}\|},$$

где экспоненциальный множитель компенсирует убывание расстояний;
 $\beta = 0.121$ — эмпирически подобранный параметр.



Djallel Bouneffouf et al. Contextual bandit for active learning: active Thompson sampling. 2014.

Как вычисляются признаки контекстов (кластеров)

$$b_{tc} = (\text{Mdis}_c, \text{Vdis}_c, |c|, \text{plb}_{tc}, \text{MixRate}_{tcy})$$

- Mdis_c — среднее внутрикластерное расстояние;
- Vdis_c — дисперсия внутрикластерных расстояний;
- $|c|$ — число объектов в кластере;
- plb_{tc} — доля размеченных объектов в кластере;
- MixRate_{tcy} — доля объектов класса $y \in Y$ в кластере.

Всего признаков: $4 + |Y|$.

Djallel Bouneffouf et al. Contextual bandit for active learning: active Thompson sampling. 2014.


Как оценивается качество

Накопленные потери (cumulative regret):

$$R(T) = \sum_{t=1}^T (\langle b_{tc_t^*}, w_t \rangle - \langle b_{tc}, w_t \rangle),$$

c_t^* — оптимальное действие ($R = 0$, если все действия оптимальны)

Сравнение накопленных потерь для различных алгоритмов:



- Активное обучение используется для уменьшения обучающей выборки, когда размеченные данные дороги
- Активное обучение быстрее пассивного
- При малом объёме размеченных данных оно достигает того же качества, что пассивное при полной разметке
- Введение изучающих действий в активном обучении позволяет ещё быстрее обследовать пространство X
- Для этого в последние годы стали применяться адаптивные стратегии или обучение с подкреплением