

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)»

ШАД Яндекс • 24 ноября 2020

1 Стратегии активного обучения

- Постановка задачи активного обучения
- Отбор объектов из выборки
- Синтез объектов (планирование экспериментов)

2 Активное обучение с изучающими действиями

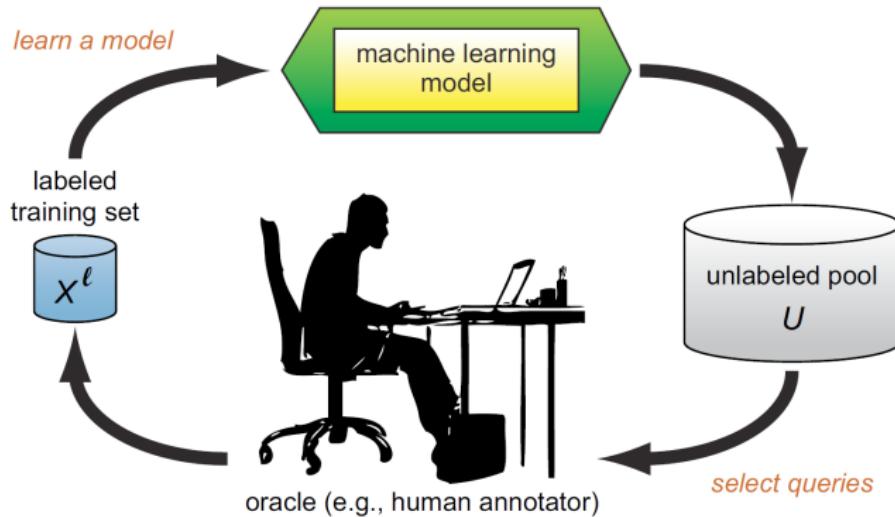
- Компромисс «изучение–применение»
- Алгоритм ε -active
- Экспоненциальный градиент

3 Активное обучение в краудсорсинге

- Задача краудсорсинга
- Согласование оценок аннотаторов
- Активное распределение заданий по аннотаторам

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

$u_i = \arg \max_{u \in U} \phi(u)$ — выбрать неразмеченный объект;

узнать для него $y_i^* = y(u_i)$;

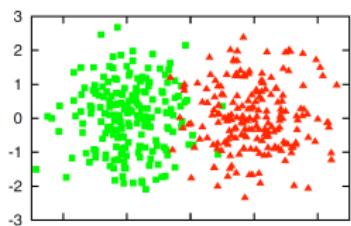
дообучить модель $a(x)$ ещё на одном примере (u_i, y_i^*) ;

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

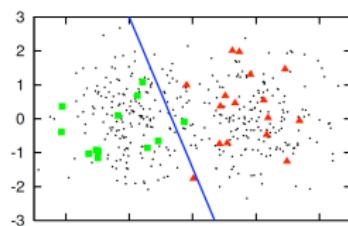
Почему активное обучение быстрее пассивного

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

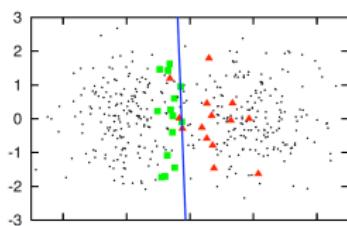
- (a) два гауссовских класса;
- (b) логистическая регрессия по 30 случайным объектам;
- (c) логистическая регрессия по 30 объектам, отобранным с помощью активного обучения.



(a)



(b)



(c)

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

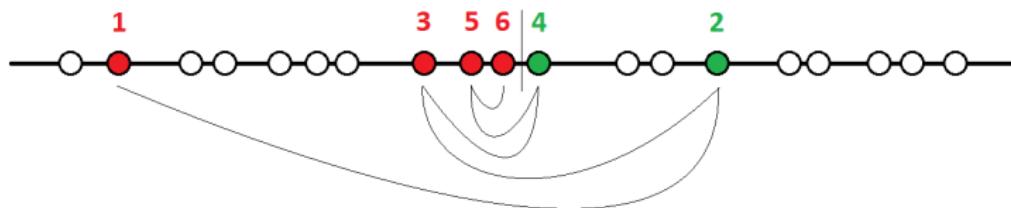
Почему активное обучение быстрее пассивного

Пример 2. Одномерная задача с пороговым классификатором:

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

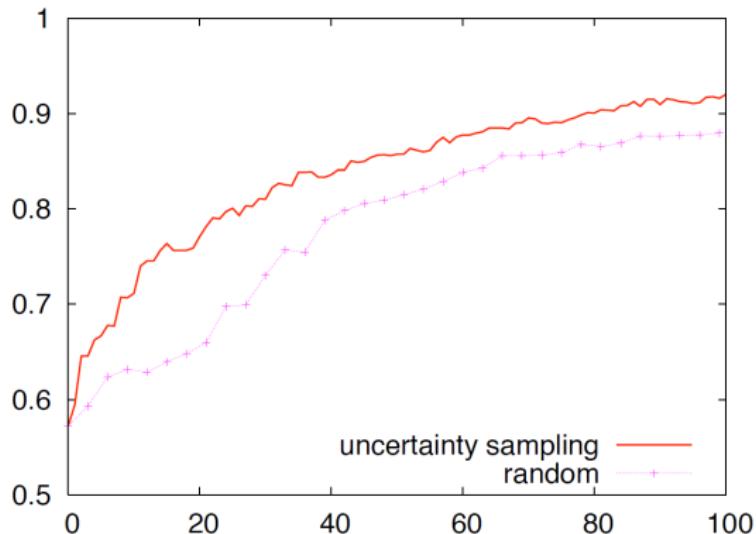
Оценим число шагов для определения θ с точностью $\frac{1}{k}$.

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



Оценивание качества активного обучения

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



Burr Settles. Active Learning Literature Survey. 2010.

Стратегии активного обучения

- Отбор объектов из выборки (pool-based sampling):
какой следующий u_i выбрать из множества $U = \{u_i\}_{i=1}^K$
- Синтез объектов (query synthesis):
на каждом шаге синтезировать оптимальный объект u_i ;
- Отбор объектов из потока (selective sampling):
для каждого приходящего u_i решать, стоит ли узнавать y_i^*

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

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

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

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 (пример — комбинаторная химия)
- оптимизация трудно вычислимых функций (пример — поиск в пространстве гиперпараметров)

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

Сэмплирование по неуверенности (uncertainty sampling)

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

Задача многоклассовой классификации:

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

$p_m(u)$, $m=1\dots|Y|$ — ранжированные по убыванию $P(y|u)$, $y \in Y$.

- Принцип *наименьшей достоверности* (least confidence):

$$u_i = \arg \min_{u \in U} p_1(u)$$

- Принцип *наименьшей разности отступов* (margin sampling):

$$u_i = \arg \min_{u \in U} (p_1(u) - p_2(u))$$

- Принцип *максимума энтропии* (maximum entropy):

$$u_i = \arg \min_{x \in U} \sum_m p_m(u) \ln p_m(u)$$

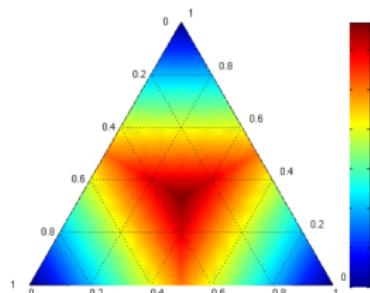
Сэмплирование по неуверенности (uncertainty sampling)

В случае двух классов эти три принципа эквивалентны.

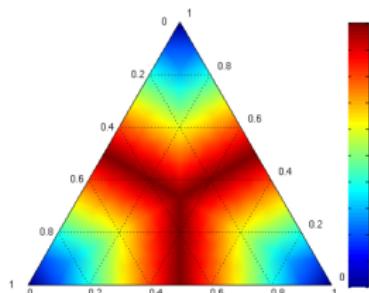
В случае многих классов появляются различия.

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

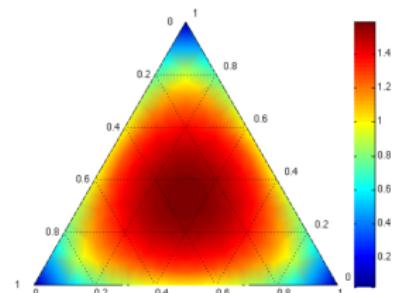
Показаны линии уровня трёх критериев выбора объекта:



$\min p_1$



$\min(p_1 - p_2)$



$\min \sum_m p_m \ln p_m$

Burr Settles. Active Learning Literature Survey. 2010.

Сэмплирование по несогласию в комитете (query by committee)

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

- Принцип максимума энтропии:

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

$$u_i = \arg \min_{u \in U} \sum_{y \in Y} \hat{p}(y|u) \ln \hat{p}(y|u),$$

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

- Принцип максимума средней KL -дивергенции:

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

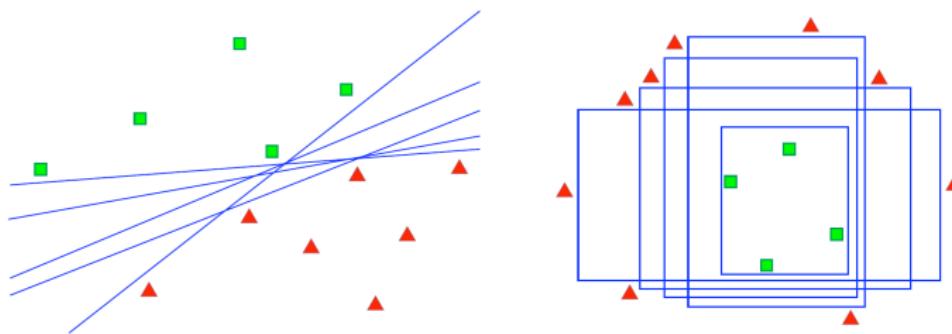
$$u_i = \arg \max_{u \in U} \sum_{t=1}^T \text{KL}(P_t(y|u) \parallel \bar{P}(y|u)),$$

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 u_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 u_i , который в методе стохастического градиента привёл бы к наибольшему изменению модели.

Параметрическая модель многоклассовой классификации:

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

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

Принцип максимума ожидаемой длины градиента:

$$u_i = \arg \max_{u \in U} \sum_{y \in Y} P(y|u, \theta) \|\nabla_{\theta}\mathcal{L}(u, y; \theta)\|.$$

Ожидаемое сокращение ошибки (expected error reduction)

Идея: выбирать u_i , который после дообучения даст наиболее уверенную классификацию неразмеченной выборки $U \setminus u_i$.

Для каждого $u \in U$ 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:

$$u_i = \arg \max_{u \in U} \sum_{y \in Y} P(y|u) \sum_{u_j \in U \setminus u} P_{uy}(a_{uy}(u_j)|u_j).$$

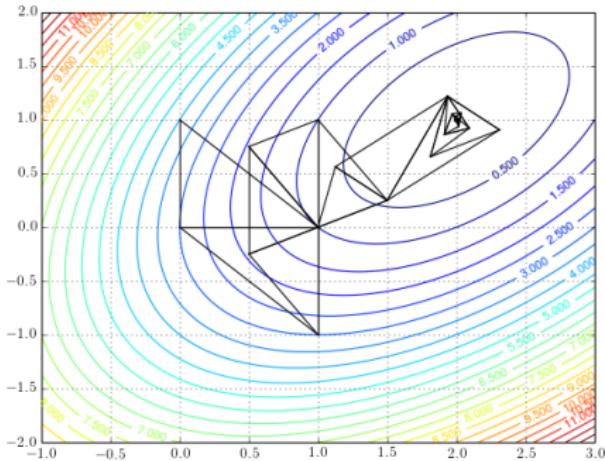
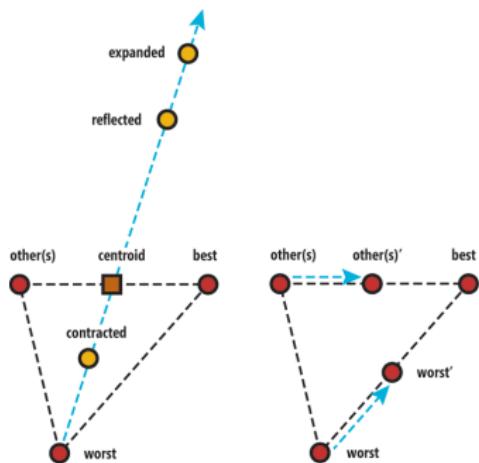
- Принцип минимума энтропии неразмеченных данных:

$$u_i = \arg \max_{u \in U} \sum_{y \in Y} P(y|u) \sum_{u_j \in U \setminus u} \sum_{z \in Y} P_{uy}(z|u_j) \log P_{uy}(z|u_j).$$

Безградиентная оптимизация. Метод Нелдера–Мида

Идея: выбирать объекты u_i не из конечного пула, а из всего X , максимизируя $\max_{u \in X} \phi(u)$ любым безградиентным методом.

Метод Нелдера–Мида: перемещение и деформирование симплекса из $n + 1$ точек в пространстве X размерности n



J.A.Nelder, R.Mead. A simplex method for function minimization. 1965.

Метод Нелдера–Мида: «отражение–растяжение–сжатие»

повторять

сортировка $n + 1$ точек: $\phi(x_w) < \phi(x_o) < \dots < \phi(x_b)$;

центроид x_c : по всем точкам кроме x_w ;

отражение: $x_r := x_c + \alpha(x_c - x_w)$;

если $\phi(x_b) < \phi(x_r)$ **то**

растяжение: $x_{exp} := x_c + \gamma(x_r - x_c)$;

$x_w := (\phi(x_r) < \phi(x_{exp})) ? x_{exp} : x_r$;

иначе если $\phi(x_o) < \phi(x_r) < \phi(x_b)$ **то** $x_w := x_r$;

иначе

сжатие: $x_{con} := x_c + \beta(x_w - x_c)$;

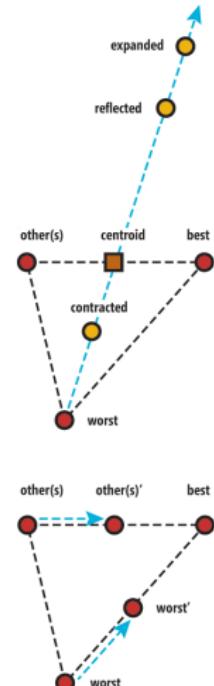
если $\phi(x_w) < \phi(x_{con})$ **то** $x_w := x_{con}$;

иначе

сжатие симплекса: $x_i := x_b + \sigma(x_i - x_b)$;

пока $\phi(x_w) \ll \phi(x_b)$;

Рекомендуемые параметры: $\alpha = 1$, $\beta = \frac{1}{2}$, $\gamma = 2$, $\sigma = \frac{1}{2}$



Сокращение дисперсии (variance reduction)

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

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):

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

В частности, для линейной регрессии

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

где F — матрица объекты–признаки.

Взвешивание по плотности (density-weighted methods)

Идея: понижать вес нерепрезентативных объектов.

Пример. Объект А более
пограничный, но менее
репрезентативный, чем В.



Любой критерий выбора объектов, имеющий вид

$$u = \arg \max_{u \in U} \phi(u),$$

может быть уточнён локальной оценкой плотности:

$$u = \arg \max_{u \in U} \phi(u) \left(\sum_{u' \in U} \text{sim}(u, u') \right)^\beta,$$

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

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

*Djallel Bouneffouf. Exponentiated gradient exploration for active learning. 2016.
Djallel Bouneffouf et al. Contextual bandit for active learning: active Thompson sampling. 2014.*

Алгоритм ε -active

Алгоритм — обёртка над любой стратегией активного обучения

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

Выход: модель a и размеченная выборка $(u_i, y_i^*)_{i=1}^k$;

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

пока есть неразмеченные объекты и модель не обучилась

выбрать неразмеченный u_i ; случайно с вероятностью ε ,

либо $u_i = \arg \max_{u \in U} \phi(u)$ с вероятностью $1 - \varepsilon$;

узнать $y_i^* = y(u_i)$ для объекта u_i ;

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

Проблема:

как подбирать вероятность ε исследовательских действий?

как её адаптировать (уменьшать) со временем?

Экспоненциальный градиент (Exponential Gradient)

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

p_1, \dots, p_H — вероятности использовать значения $\varepsilon_1, \dots, \varepsilon_H$;
 β, τ, κ — параметры метода.

Идея алгоритма EG-active: аналогично алгоритму AdaBoost, экспоненциально увеличивать p_h в случае успеха ε_h :

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

$$w_h := w_h \exp\left(\frac{\tau}{p_h}(\phi(u_i) + \beta)\right);$$

- перенормировка вероятностей:

$$p_h := (1 - \kappa) \frac{w_h}{\sum_j w_j} + \kappa \frac{1}{H}.$$

Алгоритм EG-active

Вход: $X^\ell = (x_i, y_i)_{i=1}^\ell$, $U = (u_i)_{i=1}^K$, параметры $\varepsilon_1, \dots, \varepsilon_H, \beta, \tau, \kappa$;

Выход: модель a и размеченная выборка $(u_i, y_i^*)_{i=1}^k$;

инициализация: $p_h := \frac{1}{H}$, $w_h := 1$;

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

пока есть неразмеченные объекты и модель не обучилась

выбрать h из дискретного распределения (p_1, \dots, p_H) ;

выбрать неразмеченный u_i случайно с вероятностью ε_h ,

либо $u_i = \arg \max_{u \in U} \phi(u)$ с вероятностью $1 - \varepsilon_h$;

узнать y_i^* для объекта u_i ;

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

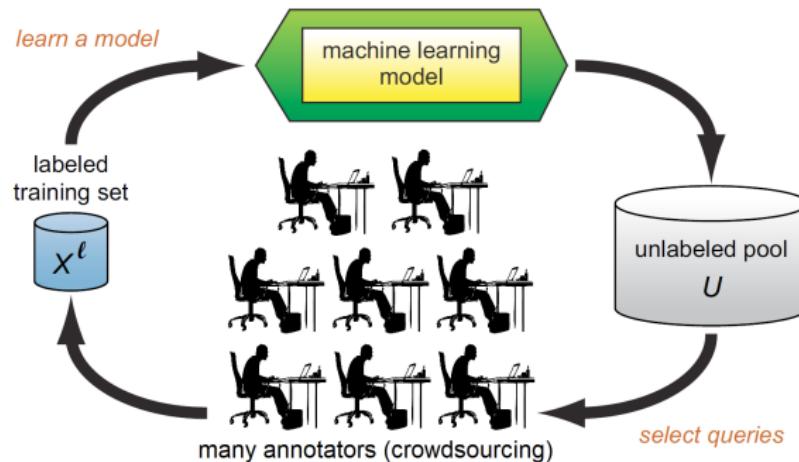
$w_h := w_h \exp\left(\frac{\tau}{p_h}(\phi(u_i) + \beta)\right)$;

$p_h := (1 - \kappa) \frac{w_h}{\sum_j w_j} + \kappa \frac{1}{H}$;

Активное обучение, когда аннотаторов много

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

Задача: сформировать согласованный «правильный» ответ \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.

Согласование оценок аннотаторов

$y_{it} \in Y$ — ответ аннотатора $t \in T$ на объекте u_i

$T_i \subseteq T$ — множество аннотаторов, разметивших объект u_i

Взвешенное голосование аннотаторов:

$$\hat{y}_i = \arg \max_{y \in Y} \sum_{t \in T_i} w_t [y_{it} = y]$$

w_t — вес аннотатора при голосовании

$w_t = 1$ при голосовании по большинству (majority voting, MV)

$w_t = \log \frac{q_t}{1-q_t}$ при предположении, что аннотаторы независимы

EM-подобный алгоритм согласования аннотаций объекта u_i :

пока оценки не сойдутся

оценить правильный ответ \hat{y}_i ;

оценить надёжности q_t и веса w_t аннотаторов;

если $q_t < \delta$ **то** исключить аннотатора из оценки;

Варианты моделирования надёжности аннотаторов

- По результатам выполнения тестовых заданий.
- Моделирование матрицы ошибок $|Y| \times |Y|$:

$$\pi_{yz}^t = P[\text{аннотатор } t \text{ ставит } z \text{ вместо } y], \quad y, z \in Y$$

- Моделирование трудности объектов:

$$q_t(u_i) = \sigma\left(\frac{\alpha_t}{\beta_i}\right) = \frac{1}{1 + \exp(-\frac{\alpha_t}{\beta_i})},$$

α_t — частотная оценка надёжности аннотатора t ;

β_i — оценка трудности объекта u_i (по большому $|T_i|$).

- Моделирование тематической компетентности аннотаторов:
 $p(\text{topic}|u_i)$ — тематическое векторное представление объекта u_i , например, если объект является текстом

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

Задача назначения заданий аннотаторам

Общая схема распределения заданий:

$$\begin{cases} u_i = \arg \max_{u \in U} \phi(u) & \text{— выбор неразмеченного объекта в AL} \\ t = \arg \max_{t \in T} q_t(u_i) & \text{— выбор наиболее уверенного аннотатора} \end{cases}$$

Обучение вероятностной модели уверенности аннотатора $q_t(u_i, \theta_t) = \sigma(\theta_t^\top u_i)$ на размеченных им объектах U_t :

$$\sum_{u_i \in U_t} (y_{it} = \hat{y}_i) q_t(u_i, \theta_t) + (y_{it} \neq \hat{y}_i) (1 - q_t(u_i, \theta_t)) \rightarrow \max_{\theta_t}$$

Недостаток: одни аннотаторы будут выбираться слишком часто, другие не будут выбираться совсем

Сэмплирование аннотаторов: $t \sim q_t(u_i)p(t)$ с учётом априорной информации $p(t)$ о средней надёжности q_t , опыте, текущей доступности, объёме проделанной работы.

Резюме

- Активное обучение используется для уменьшения обучающей выборки, когда размеченные данные дороги
- При малом объёме размеченных данных оно достигает того же качества, что пассивное при полной разметке
- Два основных типа активного обучения:
выбор объектов из пула и синтез новых объектов
- Введение изучающих действий в активном обучении позволяет ещё быстрее обследовать пространство X
- В краудсорсинге активное обучение совмещается с оцениванием надёжности аннотаторов и трудности заданий при распределении заданий по аннотаторам

P.Kumar, A.Gupta. Active learning query strategies for classification, regression, and clustering: a survey. 2020

Pengzhen Ren et al. A survey of deep active learning. 2020

Burr Settles. Active learning literature survey. 2010

C.C.Aggarwal et al. Active learning: a survey // Data classification: algorithms and applications. 2014

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