ОБУЧЕНИЕ РАНЖИРОВАНИЮ

Сергей Николенко

СПбГУ — Санкт-Петербург

22 февраля 2024 г.

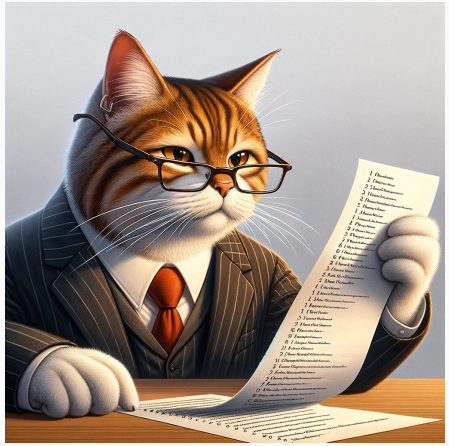

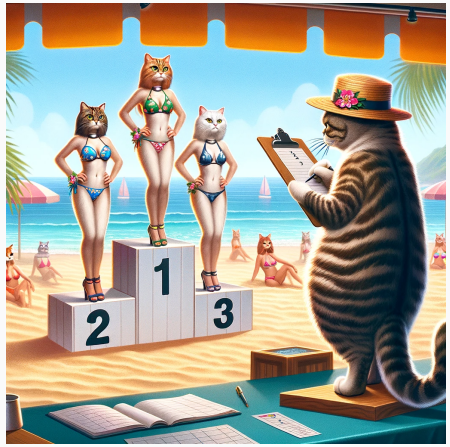

Random facts:

- 22 февраля в Японии — день кошек; 2 по-японски «ни», а из 22.2 может получиться «ня-ня-ня», что и с котиками связано напрямую
- 22 февраля 1632 г. Галилео Галилей опубликовал «Диалог о двух главнейших системах мира — птолемеевой и коперниковой»
- 22 февраля 1946 г. Зельман Ваксман открыл второй (после пенициллина) антибиотик — стрептомицин, первое работающее средство от туберкулёза и чумы
- 22 февраля 1966 г. был запущен спутник «Космос-110» с собаками Ветерком и Угольком на борту; через 22 дня, 17 марта он приземлился; собаки потеряли шерсть и были очень слабыми, но вскоре полностью поправились; Ветерок прожил после полёта 12 лет
- 22 февраля 1980 г. — «Чудо на льду»: в решающем матче Олимпиады в Лейк-Плэсиде сборная СССР уступила США (3:4); сестра одного из игроков сборной США вспоминала, что не видела столько флагов на улицах с 1960-х — «но тогда мы их жгли»...
- 22 февраля 1983 г. в Eugene O'Neill Theatre прошла премьера постановки пьесы Артура Бикнелла «Moose Murders»; постановка закрылась после одного представления и стала легендарным образцом провала, ставшим на Бродвее нарицательным

Learning to rank

Метрики ранжирования

- Ещё одна важная постановка задачи – *learning to rank* (ранжирование).
- Задача поиска: выдать ранжированный список наиболее релевантных документов по запросу.
- Классические метрики:
  (1) точность (precision) – количество «хороших» (релевантных запросу) документов в выдаче, делённое на общее количество документов в выдаче;
  (2) полнота (recall) – количество «хороших» документов в выдаче, делённое на общее число релевантных документов в базе поисковой системы.
- Однако здесь те же проблемы; эти параметры не зависят от ранжирования выдачи, надо знать заранее, сколько потребуется рекомендаций.

Метрики ранжирования

- Метрики качества ранжирования:
  - NDCG, Normalized Discounted Commulative Gain; выберем топ-k рекомендаций (k может быть заведомо больше нужного числа) и посчитаем:

$$\mathrm{DCG}_k = \sum_{i=1}^{k} \frac{2^{\hat{r}_i} - 1}{\log_2(1+i)},$$

$$\mathrm{NDCG}_k = \frac{\mathrm{DCG}_k}{\mathrm{IDCG}_k},$$

    где $\hat{r}_i$ – наша оценка рейтинга продукта на позиции i, а IDCG_k – значение DCG_k при ранжировании по истинным значениям (рейтингам из валидационного набора);
  - NDCG от 0 до 1, но ей трудно придумать естественную интерпретацию (как вероятность чего-нибудь, например).

Метрики ранжирования

- Метрики качества ранжирования:
  - AUC, Area Under (ROC) Curve; можно считать по всей выдаче сразу;
  - AUC – вероятность того, что случайно выбранная пара продуктов с разными оценками будет отранжирована правильно (релевантный будет выше в выдаче, чем нерелевантный);
  - в бинарном случае можно посчитать в замкнутом виде:

$$\hat{A} = \frac{S_0 - n_0(n_0+1)/2}{n_0 n_1},$$

где n_0, n_1 – число релевантных и нерелевантных запросу документов, $S_0 = \sum p_i$ – сумма номеров позиций релевантных объектов в выдаче.

Метрики ранжирования

- Метрики, основанные на каскадных моделях пользователей.
- ERR (Expected Reciprocal Rank) – ожидаемый обратный ранг документа, на котором остановится пользователь:

$$\mathrm{ERR} = \sum_{i=1}^{n} \frac{1}{i} p(\text{пользователь остановится на } i) =$$

$$= \sum_{i=1}^{n} \frac{1}{i} R(y_i) \prod_{j=1}^{i-1} (1 - R(y_i)),$$

  где остановка происходит, если случайное число от 0 до 1 меньше $R(y)$; часто используют $R(r) = \frac{2^r - 1}{2^{r_{\max}}}$.
- К сожалению, все метрики качества кусочно-постоянные. Надо что-то придумывать.

BM25

- Классическая функция BM25, ещё из 1970-80-х годов:

$$\text{score}(D, Q) = \sum_{i=1}^{n} \text{idf}(q_i) \frac{\text{tf}(q_i, D)(k_1 + 1)}{\text{tf}(q_i, D) + k_1 \left(1 - b + b \frac{|D|}{\text{Avgdoclen}}\right)},$$

  где q_i – ключевые слова из запроса Q, D – документ, k_i – параметры, которые можно обучить или выставить $k_1 \in [1.2, 2.0]$, $b = 0.75$.

- Сейчас обычно пытаются переформулировать как задачу supervised learning.
- Данные вида (Q, D, r), где r – оценка релевантности (обычно дискретная и размеченная людьми).

Три подхода

- Выделяя признаки в паре (Q, D), получим $(\mathbf{x}_j^q, r_j^q)_{q,j}$.
- Три подхода к тому, чтобы сделать непрерывную целевую функцию:
  - *pointwise* (поточечный): для функции ошибки ℓ (например, ошибка регрессии или классификации)

$$\sum_{q,j} \ell(f(\mathbf{x}_j^q), r_j^q) \to \min;$$

  - *pairwise* (попарный): правильно упорядочиваем пары с разными оценками

$$\sum_q \sum_{i,j: r_i^q > r_j^q} \ell(f(\mathbf{x}_i^q) - f(\mathbf{x}_j^q)) \to \min;$$

  - *listwise* (списочный): определим функцию потери на всём списке документов, ассоциированных с запросом,

$$\ell\left(\{f(\mathbf{x}_j^q)\}_{j=1}^{m_q}, \{r_j^q\}_{j=1}^{m_q}\right) \to \min.$$

Развитие learning to rank

- Обычно подходы работают на pairwise-ошибке:
  - RankSVM: берём SVM с ошибкой $\ell(t) = \max(0, 1 - t)$ и обучаем на попарных сравнениях;
  - RankBoost, RankNet, LambdaRank (поговорим о них).
- Публичные датасеты и большие продвижения около 2010:
  - «Интернет-математика» от Яндекса (2009),
  - Microsoft Learning to Rank Datasets (2010),
  - Yahoo! Learning to Rank Challenge (2010).

RankNet

RankNet

- RankNet – первая идея pairwise-подхода.
- Пусть у нас есть кое-какие прямые данные для обучения (т.е. про некоторые подмножества документов эксперт сказал, какие более релевантны, какие менее).
- Подход к решению: давайте обучать функцию, которая по данному вектору атрибутов $\mathbf{x} \in \mathbb{R}^n$ выдаёт $f(\mathbf{x})$ и ранжирует документы по значению $f(\mathbf{x})$.

RankNet

- Итак, для тестовых примеров $\mathbf{x}_i$ и $\mathbf{x}_j$ модель считает $s_i = f(\mathbf{x}_i)$ и $s_j = f(\mathbf{x}_j)$, а затем оценивает

$$p_{ij} = p(\mathbf{x}_i \succ \mathbf{x}_j) = \frac{1}{1 + e^{-\alpha(s_i - s_j)}}.$$

- А данные – это на самом деле $q(\mathbf{x}_i \succ \mathbf{x}_j)$, либо точные из $\{0, 1\}$, либо усреднённые по нескольким экспертам.
- Поэтому разумная функция ошибки – кросс-энтропия

$$C = -q_{ij} \log p_{ij} - (1 - q_{ij}) \log(1 - p_{ij}).$$

RankNet

- Ошибка: $C = -q_{ij} \log p_{ij} - (1 - q_{ij}) \log(1 - p_{ij})$.
- Для самого частого случая, когда оценки релевантности точные, и $q_{ij} = (1 + S_{ij})/2$ для $S_{ij} \in \{-1, 0, +1\}$, мы получаем

$$C = \frac{1}{2}(1 - S_{ij})\alpha(s_i - s_j) + \log\left(1 + e^{-\alpha(s_i - s_j)}\right), \text{ т.е.}$$

$$C = \begin{cases} \log\left(1 + e^{-\alpha(s_i - s_j)}\right), & \text{если } S_{ij} = 1, \\ \log\left(1 + e^{-\alpha(s_j - s_i)}\right), & \text{если } S_{ij} = -1. \end{cases}$$

- Т.е. ошибка симметрична, что уже добрый знак.

RankNet

- Ошибка: $C = -q_{ij} \log p_{ij} - (1 - q_{ij}) \log(1 - p_{ij})$.
- Давайте подсчитаем градиент по s_i:

$$\frac{\partial C}{\partial s_i} = \alpha \left(\frac{1 - S_{ij}}{2} - \frac{1}{1 + e^{\alpha(s_i - s_j)}} \right) = -\frac{\partial C}{\partial s_j}.$$

- И теперь осталось использовать этот подсчёт для градиента по весам:

$$\frac{\partial C}{\partial w_k} = \sum_i \frac{\partial C}{\partial s_i} \frac{\partial s_i}{\partial w_k} + \sum_j \frac{\partial C}{\partial s_j} \frac{\partial s_j}{\partial w_k}.$$

RankNet

- Основной пафос RankNet – в том, что это можно факторизовать:

$$\frac{\partial C}{\partial w_k} = \sum_i \frac{\partial C}{\partial s_i}\frac{\partial s_i}{\partial w_k} + \sum_j \frac{\partial C}{\partial s_j}\frac{\partial s_j}{\partial w_k} = \lambda_{ij}\left(\frac{\partial s_i}{\partial w_k} - \frac{\partial s_j}{\partial w_k}\right),$$

  где

$$\lambda_{ij} = \frac{\partial C(s_i - s_j)}{\partial s_i} = \alpha\left(\frac{1 - S_{ij}}{2} - \frac{1}{1 + e^{\alpha(s_i - s_j)}}\right).$$

- Переупорядочив пары так, чтобы всегда было $\mathbf{x}_i \succ \mathbf{x}_j$ и $S_{ij} = 1$, получим

$$\lambda_{ij} = \frac{\partial C(s_i - s_j)}{\partial s_i} = -\alpha\frac{1}{1 + e^{\alpha(s_i - s_j)}}.$$

RankNet

- $\lambda_{ij} = \frac{\partial C(s_i - s_j)}{\partial s_i} = -\alpha \frac{1}{1+e^{\alpha(s_i - s_j)}}$.
- Значит, если для данной выдачи есть множество пар I, в которых известно, что $\mathbf{x}_i \succ \mathbf{x}_j$, $(i,j) \in I$, то суммарный апдейт для веса w_k будет

$$\Delta w_k = -\eta \left[\sum_{(i,j)\in I} \lambda_{ij} \frac{\partial s_i}{\partial w_k} - \lambda_{ij} \frac{\partial s_j}{\partial w_k} \right] = -\eta \sum_i \lambda_i \frac{\partial s_i}{\partial w_k},$$

$$\text{где } \lambda_i = \sum_{j:(i,j)\in I} \lambda_{ij} - \sum_{j:(j,i)\in I} \lambda_{ij}.$$

- И можно просто считать λ_i по таким mini-batches от каждого запроса, а потом уже апдейтить.
- Иначе говоря, λ_i «тянет» ссылку в выдаче вверх или вниз, и мы апдейтим веса на основе этого.

LambdaRank

LambdaRank

- Проблема с RankNet в том, что оптимизируется число попарных ошибок, а это не всегда то, что нужно.
- Градиенты RankNet – это не то же самое, что градиенты NDCG:

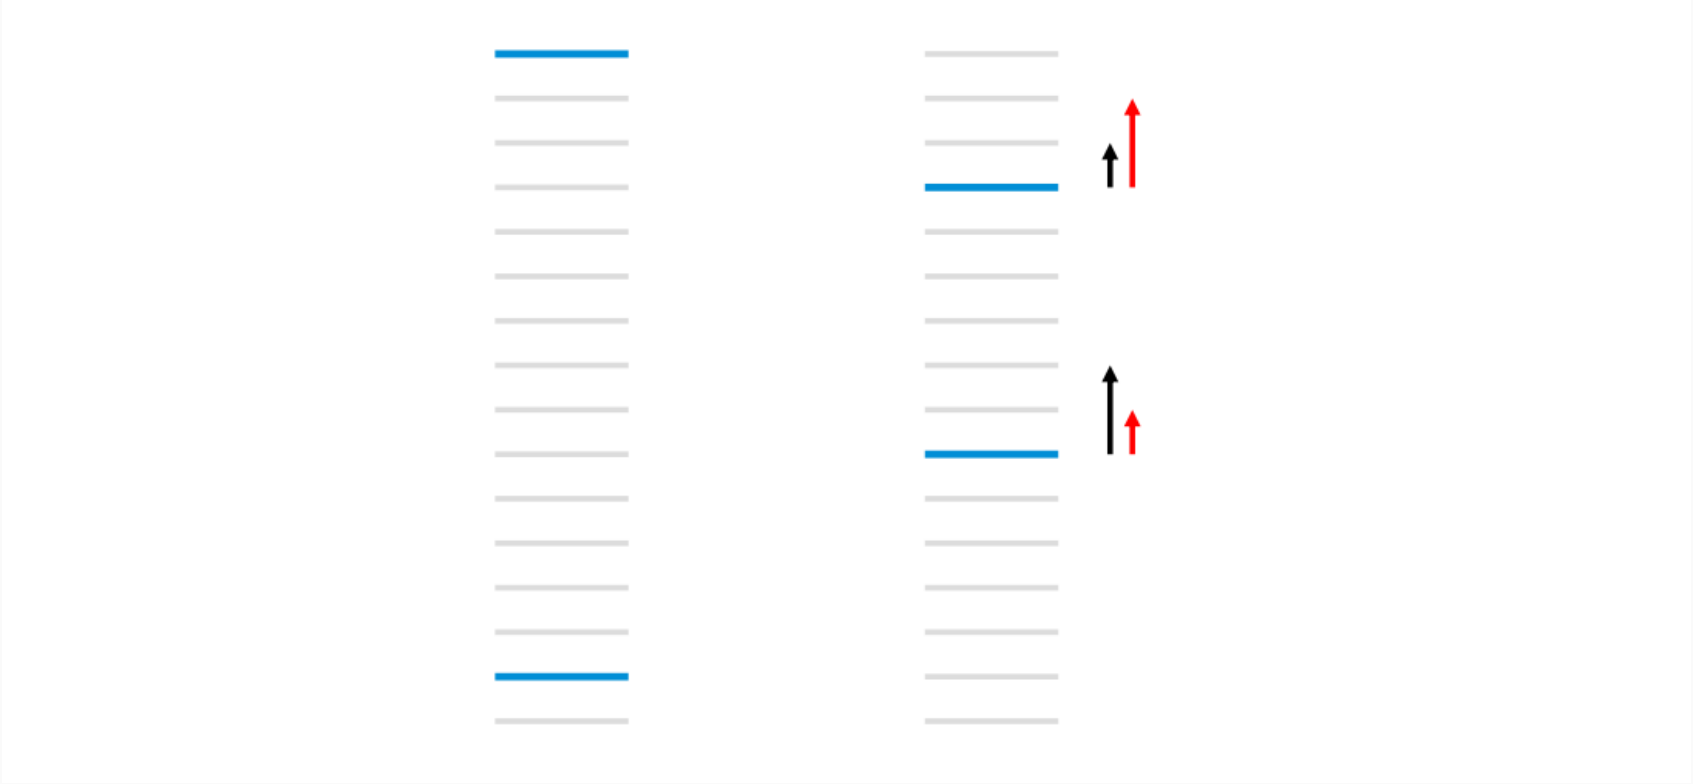

- Как оптимизировать, скажем, NDCG?

LambdaRank

- Заметим, что нам сама ошибка не нужна, а нужны только градиенты λ (стрелочки).
- Давайте просто представим себе мифическую функцию ошибки C, у которой градиент

$$\lambda_{ij} = \frac{\partial C(s_i - s_j)}{\partial s_i} = \frac{-\alpha}{1 + e^{\alpha(s_i - s_j)}} \left|\Delta_{\text{NDCG}}\right|,$$

  где Δ_{NDCG} – это то, на сколько NDCG изменится, если поменять i и j местами.
- То есть мы считаем градиенты уже после сортировки документов по оценкам, и градиенты как будто от NDCG.

LambdaRank

- NDCG нужно максимизировать, так что берём

$$\Delta w_k = \eta \frac{\partial C}{\partial w_k}, \text{ и тогда}$$

$$\delta C = \frac{\partial C}{\partial w_k} \delta w_k = \eta \left(\frac{\partial C}{\partial w_k} \right)^2 > 0.$$

- Оказывается, что такой подход фактически напрямую оптимизирует NDCG (сглаженную версию).
- Мощная идея: можно не знать функцию, а просто придумать разумные градиенты; чтобы под них существовала функция, в разумных случаях достаточно (лемма Пуанкаре), чтобы сходились вторые частные производные.

RankBoost

RankBoost

- RankBoost: задачу ранжирования по массе разных фич, характеризующих документы и запросы, можно решить и бустингом.
- Формально говоря, нам надо обучить функцию $F(\mathbf{x}) : \mathbb{R}^n \to \mathbb{R}$ по входу $\{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ и функции частичных предпочтений $\Phi : \mathbf{X} \times \mathbf{X} \to \mathbb{R}$ ($\Phi(\mathbf{x}_i, \mathbf{x}_j) > 0$, если $\mathbf{x}_i$ лучше $\mathbf{x}_j$, и т.д.).
- Обычно в качестве функции Φ подаётся просто разбиение на «хорошие» (например, релевантные) и «плохие»: $\Phi(\mathbf{x}, \mathbf{y}) = 1$ для хорошего $\mathbf{x}$ и плохого $\mathbf{y}$ и 0, если они из одного множества.

RankBoost

- RankBoost по сути работает примерно как AdaBoost, но раньше веса давали распределение на примерах, а теперь – на парах примеров: инициализируем распределение $D^{(1)} = D(\mathbf{x}, \mathbf{y})$ на $\mathbf{X} \times \mathbf{X}$, а потом для $m = 1..M$:
  1. обучаем слабую ранжирующую функцию $h_m(\mathbf{x}) : \mathbf{X} \to \mathbb{R}$ по распределению $D^{(m)}$;
  2. выбираем $\alpha_m \in \mathbb{R}$ (потом скажу как);
  3. пересчитываем новое распределение

$$D^{(m+1)}(\mathbf{x}, \mathbf{y}) = \frac{1}{Z_m} D^{(m)}(\mathbf{x}, \mathbf{y}) e^{\alpha_m (h_m(\mathbf{x}) - h_m(\mathbf{y}))}.$$

  4. После обучения ранжируем как $H_M(\mathbf{x}) = \sum_{m=1}^{M} \alpha_m h_m(\mathbf{x})$.

- Тогда получится такая теорема: если вернуться от $D^{(m+1)}(\mathbf{x}, \mathbf{y})$ к $D(\mathbf{x}, \mathbf{y})$, будет

$$D^{(m+1)}(\mathbf{x}, \mathbf{y}) = \frac{1}{\prod_m Z_m} D(\mathbf{x}, \mathbf{y}) e^{H_M(\mathbf{x}) - H_M(\mathbf{y})}.$$

- Значит, ошибку можно оценить как

$$J_M = \sum_{\mathbf{x},\mathbf{y}} D(\mathbf{x}, \mathbf{y}) \left[H_M(\mathbf{x}) \geq H_M(\mathbf{y})\right] \leq$$

$$\leq \sum_{\mathbf{x},\mathbf{y}} D(\mathbf{x}, \mathbf{y}) e^{H_M(\mathbf{x}) - H_M(\mathbf{y})} = \sum_{\mathbf{x},\mathbf{y}} D^{(m+1)}(\mathbf{x}, \mathbf{y}) \prod_m Z_m = \prod_m Z_m.$$

- И выбирать α_m можно (и нужно) так, чтобы минимизировать $\prod_m Z_m$, т.е. на шаге m минимизировать

$$Z_m = \sum_{\mathbf{x},\mathbf{y}} D^{(m)}(\mathbf{x},\mathbf{y}) e^{\alpha_m (h_m(\mathbf{x}) - h_m(\mathbf{y}))}.$$

- Формально для нас h_m – чёрный ящик, но на практике мы часто выбираем алгоритм обучения и для h_m, так что его тоже можно выбирать так, чтобы минимизировать Z_m.

RankBoost

- Теорема: для любого слабого ранжирования h $Z(\alpha)$ имеет единственный минимум, так что можно просто бинарным поиском.
- Если $h \in \{0, 1\}$, можно и аналитически: обозначим $W_b = \sum_{\mathbf{x},\mathbf{y}} D(\mathbf{x}, \mathbf{y}) \, [h(\mathbf{x}) - h(\mathbf{y}) = b]$. Тогда

$$\alpha_{\text{opt}} = \frac{1}{2} \ln \left(\frac{W_{-1}}{W_{+1}} \right), \quad Z = W_0 + 2\sqrt{W_{-1} W_{+1}}.$$

- А для $h \in [0, 1]$ можно приблизить: $e^{\alpha x} \leq \left(\frac{1+x}{2}\right) e^{\alpha} + \left(\frac{1-x}{2}\right) e^{-\alpha}$, $x \in [-1, 1]$, так что

$$Z \leq \left(\frac{1-r}{2}\right) e^{\alpha} + \left(\frac{1+r}{2}\right) e^{-\alpha}, \quad r = \sum_{\mathbf{x},\mathbf{y}} D(\mathbf{x}, \mathbf{y}) \left(h(\mathbf{x}) - h(\mathbf{y})\right),$$

  и можно выбирать

$$\alpha_{\text{opt}} = \frac{1}{2} \ln \left(\frac{1+r}{1-r}\right),$$

  а h можно обучать так, чтобы максимизировать $|r|$.

- Но можно и ещё лучше...

MART

Деревья регрессии

- Теперь давайте градиентный бустинг применять к задаче ранжирования более напрямую.
- Начнём с чуть изменённых обозначений для деревьев принятия решений в случае регрессии.
- Рассмотрим датасет $\mathbf{X} = \{\mathbf{x}_i, y_i\}$.
- Можно определить *regression stump* (регрессионный пень) так: выбираем одну координату (атрибут) j (т.е. берём x_{ij}) и ищем там оптимальное разбиение – такое значение порога t, что

$$S_j = \sum_{i \in \text{Left}} \left(y_i - \mu_{\text{Left}}\right)^2 + \sum_{i \in \text{Right}} \left(y_i - \mu_{\text{Right}}\right)^2$$

минимизируется, где Left и Right – множества точек слева и справа от t по j-й координате.

Деревья регрессии

- Если повторить эту процедуру L раз (как-то выбирая для расщепления листья – например, по максимальной дисперсии), получится регрессионное дерево с L листьями.
- В каждом листе определим γ_l – среднее по y_i из этого листа.
- Тогда, чтобы применить регрессионное дерево, надо по нему спуститься до листа и взять γ_l из этого листа.

MART

- MART – это бустинг, сделанный на регрессионных деревьях.
- Иначе говоря, окончательная модель будет, опять же, по $\mathbf{x} \in \mathbb{R}^d$ искать $y \in \mathbb{R}$, и искать в виде

$$F_M(\mathbf{x}) = \sum_{m=1}^{M} \alpha_m f_m(\mathbf{x}),$$

где $f_m(\mathbf{x})$ задаётся регрессионным деревом, а $\alpha_m \in \mathbb{R}$ – веса бустинга, и в процессе обучения обучаются одновременно f_m и α_m.

MART

- Нам нужно понять, как обучать новое дерево F_{m+1}, если мы уже обучили m деревьев.
- Зафиксируем функцию ошибки C (она дана свыше).
- Идея: следующее дерево моделирует производные ошибки по текущей модели в точках из датасета:

$$\Delta C \approx \frac{\partial C(F_m)}{\partial F_m} \Delta F,$$

и ΔC будет отрицательным, если взять для $\eta > 0$

$$\Delta F = -\eta \frac{\partial C(F_m)}{\partial F_m}.$$

- Непараметрический метод: мы рассматриваем F_m *в каждой точке из датасета* как «параметр» и по ним оптимизируем.

MART

- Пример: бинарная классификация, $y_i \in \{\pm 1\}$, $\mathbf{x} \in \mathbb{R}^n$, $F(\mathbf{x})$.
- Обозначим $p_+ = p(y = 1 \mid \mathbf{x})$, $p_- = p(y = -1 \mid \mathbf{x})$, $I_+(\mathbf{x}_i) = [y_i = 1]$, $I_-(\mathbf{x}_i) = [y_i = -1]$.
- Будем использовать (как и в RankNet, кстати) перекрёстную энтропию

$$L(y, F) = -I_+ \log p_+ - I_i \log p_i.$$

- Логистическая регрессия моделирует log odds:

$$F_N(\mathbf{x}) = \frac{1}{2}\log\left(\frac{p_+}{p_-}\right),$$

$$p_+ = \frac{1}{1+e^{-2\alpha F_m(\mathbf{x})}}, \quad p_- = \frac{1}{1+e^{2\alpha F_m(\mathbf{x})}},$$

и мы получаем

$$L(y,F) = \log\left(1+e^{-2y\alpha F_m(\mathbf{x})}\right).$$

MART

- $L(y, F) = \log\left(1 + e^{-2y\alpha F_m(\mathbf{x})}\right).$
- От этой функции легко взять производную по $F(\mathbf{x})$:

$$\bar{y}_i = \left[\frac{\partial L(y_i, F(\mathbf{x}_i))}{\partial F(\mathbf{x}_i)}\right]_{F(\mathbf{x})=F_m(\mathbf{x})} = \frac{2y_i\alpha}{1 + e^{2y_i\alpha F_m(\mathbf{x})}}.$$

- И мы строим новое регрессионное дерево, которое пытается смоделировать $\bar{y}_i$.

MART

- Осталось только выбрать вес, с которым это новое дерево войдёт в сумму.
- Мы хотим выбрать (примерно) оптимальный шаг для каждого листа, т.е. минимизировать потери:

$$\gamma_{lm} = \arg\min_{\gamma} \log\left(1 + e^{2y_i \alpha(F_m(\mathbf{x})+\gamma)}\right) = \arg\min_{\gamma} g(\gamma).$$

- Минимизировать можно итеративно по методу Ньютона-Рапсона: $\gamma_{n+1} = \gamma_n - \frac{g'(\gamma_n)}{g''(\gamma_n)}$.

MART

- И мы аппроксимируем одним шагом этого метода, начиная с нуля:

$$\gamma_{lm} = -\frac{g'}{g''} = \frac{\sum_{x_i \in R_{lm}} \bar{y}_i}{\sum_{x_i \in R_{lm}} |\bar{y}_i| \left(2\alpha - |\bar{y}_i|\right)}.$$

Упражнение. Проверьте эту формулу.

LambdaMART

LambdaMART

- Теперь уже понятно, как из MART сделать LambdaMART.
- Мы просто добавим в градиенты целевую метрику, например

$$\lambda_{ij} = S_{ij} \left| \Delta \mathrm{NDCG} \frac{\partial C_{ij}}{\partial o_{ij}} \right|, \quad o_{ij} = F(x_i) - F(x_j).$$

- Функция ошибки нам тоже уже известна:

$$\begin{aligned} C_{ij} =& C(o_{ij}) = s_j - s_i + \log\left(1 + e^{s_i - s_j}\right), \\ \frac{\partial C_{ij}}{\partial o_{ij}} =& \frac{\partial C_{ij}}{\partial s_i} = -\frac{1}{1 + e^{o_{ij}}}. \end{aligned}$$

LambdaMART

- Получается, что знак λ_{ij} зависит только от меток i и j, и в каждой точке мы можем собрать все «действующие силы» как

$$\lambda_i = \sum_j \lambda_{ij}.$$

- Это и называется LambdaMART.
- Вариант: LambdaSMART (submodel): мы инициализируем первое дерево какой-нибудь обученной хорошей базовой моделью, а всё дальнейшее – это её уточнение.

LambdaMART

- Остался только один вопрос: откуда взять веса α_i (при $f_i(\mathbf{x})$)?
- Базовый LambdaMART выбирает эти веса индивидуально для каждого листа дерева.
- Мы хотим сдвинуться в сторону минимума ошибки; значит, надо идти в сторону нуля производной. Один шаг метода Ньютона-Рапсона:

$$F_m(x_i) = F_{m-1}(x_i) + v \sum_l \gamma_{lm} \left[x_i \in R_{lm}\right],$$

где $\gamma_{lm} = \dfrac{F'_m(x_i)}{F''_m(x_i)}$, а v – регуляризатор.

- Первая производная – это просто λ_i; вторая производная – λ_i':

$$\gamma_{lm} = \frac{\sum_{x_i \in R_{lm}} \lambda_i}{\sum_{x_i \in R_{lm}} \frac{\partial \lambda_i}{\partial F_m(x_i)}}$$

- И теперь можно собрать весь алгоритм целиком.

LambdaSMART: алгоритм

1. $F_0(x_i) = \text{BaseModel}(x_i)$, $i = 0..N$.
2. Для m от 1 до M (числа деревьев в сумме):
   - 2.1 $y_i = \lambda_i = \sum_j \lambda_{ij}$, $i = 0..N$ (считаем градиенты);
   - 2.2 $w_i = \frac{\partial y_i}{\partial F(x_i)}$, $i = 0..N$ (вторые производные);
   - 2.3 строим новое дерево $\{R_{lm}\}_{l=1}^{L}$ на вершинах $\{y_i, x_i\}_{n=1}^{N}$;
   - 2.4 $\gamma_{lm} = \frac{\sum_{x_i \in R_{lm}} y_i}{\sum_{x_i \in R_{lm}} w_i}$, $l = 1..L$ (веса узлов);
   - 2.5 $F_m(x_i) = F_{m-1}(x_i) + v \sum_l \gamma_{lm} \left[x_i \in R_{lm}\right]$, $i = 0..N$.

Как оптимизировать α_m

- В Lambda[S]MART веса бустинга подбираются как шаг метода Ньютона для каждого листа дерева.
- Но благодаря тому, что наши IR-метрики дискретные, можно просто подобрать оптимальный α_m.
- Давайте рассмотрим общую задачу: предположим, что у нас есть две ранжирующих функции, R и R', и мы хотим их оптимально линейно скомбинировать, т.е. подобрать оптимальный коэффициент α в

$$s_i = (1 - \alpha)s_i^R + \alpha s_i^{R'}.$$

Как оптимизировать α_m

- Идея простая: представьте себе, как α меняется от 0 (в чистом виде R) до 1 (в чистом виде R').
- Тогда метрики вроде NDCG реально меняются только в точках пересечения (да и то не всегда, а только если пересеклись документы с разными метками).
- Ну вот и давайте просто переберём все такие пары, найдём их точки пересечения и составим список интересных значений α.
- А затем отсортируем список, подсчитаем метрику в каждом интервале и найдём оптимальный α; для ситуации бустинга просто надо это делать на каждом шаге.
- Кажется, что это очень тупо, но на самом деле это квадратичный алгоритм, что не так уж страшно.

Как оптимизировать α_m

- LambdaMART – победитель в Yahoo! Learning to Rank Challenge (2011).
- Что было нового с тех пор?
- Plackett-Luce model выражает ранжирование в виде вероятностей:
  - выбираем первый документ с вероятностью, пропорциональной релевантности;
  - выбираем второй документ из остальных тоже пропорционально релевантности...
- Это даёт непрерывную listwise-ошибку, которую можно оптимизировать.
- BayesRank оптимизирует её, MatrixNet, видимо, тоже.

Спасибо!

Спасибо за внимание!