

МАШИННОЕ ОБУЧЕНИЕ

методы понижения размерности

Воронцов Константин Вячеславович
ФУПМ МФТИ • ВМК МГУ • Яндекс • FORECSYS

9 июля 2016
Сочи, Сириус • Проектная смена • 1–24 июля 2016

1 Способы измерения качества классификации

- Внутренние критерии
- Внешние критерии
- Понятие сложности модели

2 Отбор признаков

- Полный перебор
- Жадные алгоритмы
- Другие методы

3 Латентные модели

- Рекомендательные системы
- Латентные модели
- Неотрицательные матричные разложения

Анализ ошибок классификации

Задача классификации на два класса, $y_i \in \{-1, +1\}$.

Алгоритм классификации $a(x_i) \in \{-1, +1\}$

число объектов	ответ классификатора	правильный ответ
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	$a(x_i) = -1$	$y_i = +1$

Доля правильных классификаций (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 ни численность (дисбаланс) классов, ни цена ошибки на объектах разных классов.

Оценки качества двухклассовой классификации

В информационном поиске:

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

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

Precision — доля релевантных среди найденных

Recall — доля найденных среди релевантных

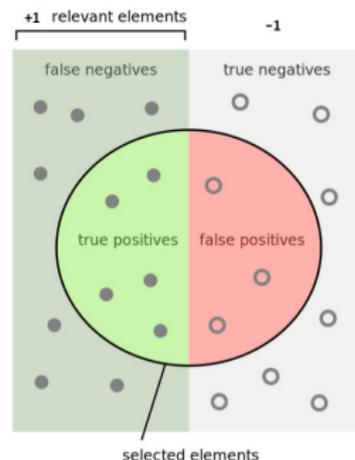
В медицинской диагностике:

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

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

Sensitivity — доля верных положительных диагнозов

Specificity — доля верных отрицательных диагнозов



$$\text{Precision} = \frac{\text{green circle}}{\text{green circle} + \text{red circle}} \quad \text{Recall} = \text{Sensitivity} = \frac{\text{green circle}}{\text{green circle} + \text{grey dots}}$$

$$\text{Accuracy} = \frac{\text{green circle} + \text{white circles}}{\text{green circle} + \text{red circle} + \text{grey dots} + \text{white circles}} \quad \text{Specificity} = \frac{\text{white circles}}{\text{white circles} + \text{red circle}}$$

Точность и полнота многоклассовой классификации

Для каждого класса $y \in Y$:

TP_y — верные положительные

FP_y — ложные положительные

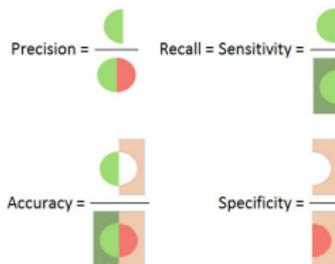
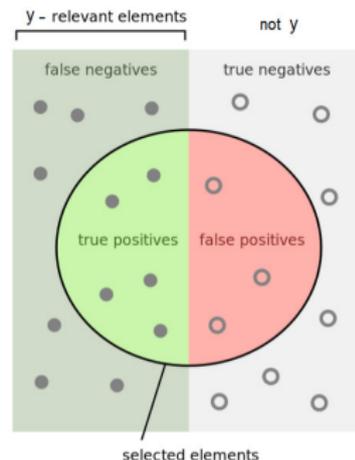
FN_y — ложные отрицательные

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

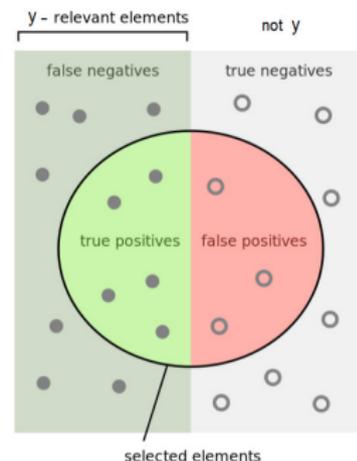
FN_y — ложные отрицательные

Точность и полнота с макроусреднением:

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

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

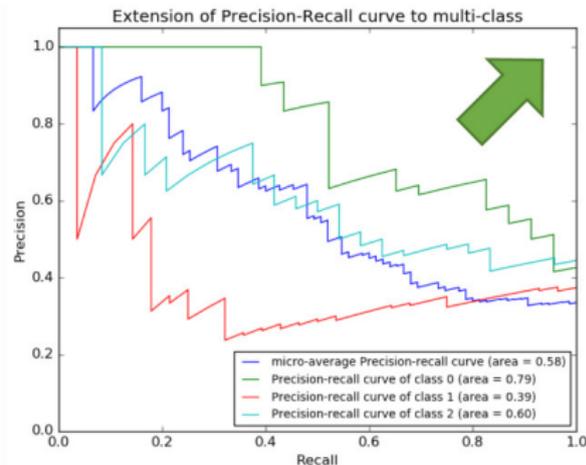
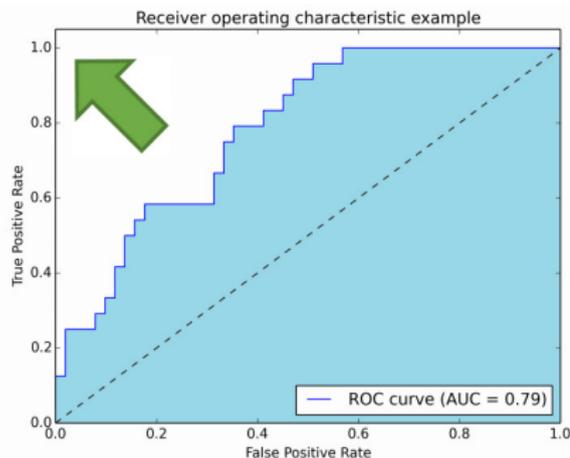
Макроусреднение чувствительно
 к ошибкам на малочисленных классах



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 (предсказательной) способности

Метод обучения μ строит алгоритм $a = \mu(X^\ell)$ по выборке X^ℓ .
 $Q(a, X^\ell)$ — критерий качества a на X^ℓ .

Внутренний критерий оценивает качество на обучении X^ℓ :

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

Недостаток: эта оценка оптимистично смещена.

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

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

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

Эмпирические оценки обобщающей способности

Метод обучения μ строит алгоритм $a = \mu(X^\ell)$ по выборке X^ℓ .

- Кросс-проверка (cross-validation) по N разбиениям,
 $X^L = X_n^\ell \sqcup X_n^k$, $L = \ell + k$:

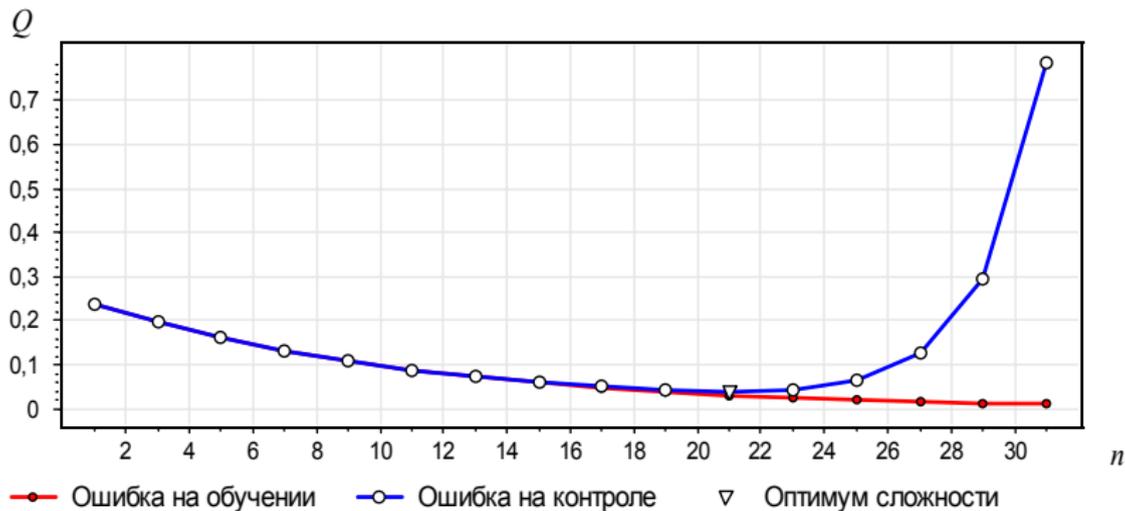
$$CV(\mu, X^L) = \frac{1}{N} \sum_{n=1}^N Q(\mu(X_n^\ell), X_n^k) \rightarrow \text{opt}$$

- Скользящий контроль (leave-one-out): $k = 1$, $N = L$
- **Стратификация классов:**
каждый класс X_y^L разбивается на блоки пропорциональных объёмов $X_y^L = X_{yn}^{\ell_y} \sqcup X_{yn}^{k_y}$, $\ell_y : k_y = \ell : k$

Основное отличие внешних критериев от внутренних

Внутренний критерий монотонно убывает с ростом сложности модели (например, числа признаков).

Внешний критерий имеет характерный минимум, соответствующий оптимальной сложности модели.



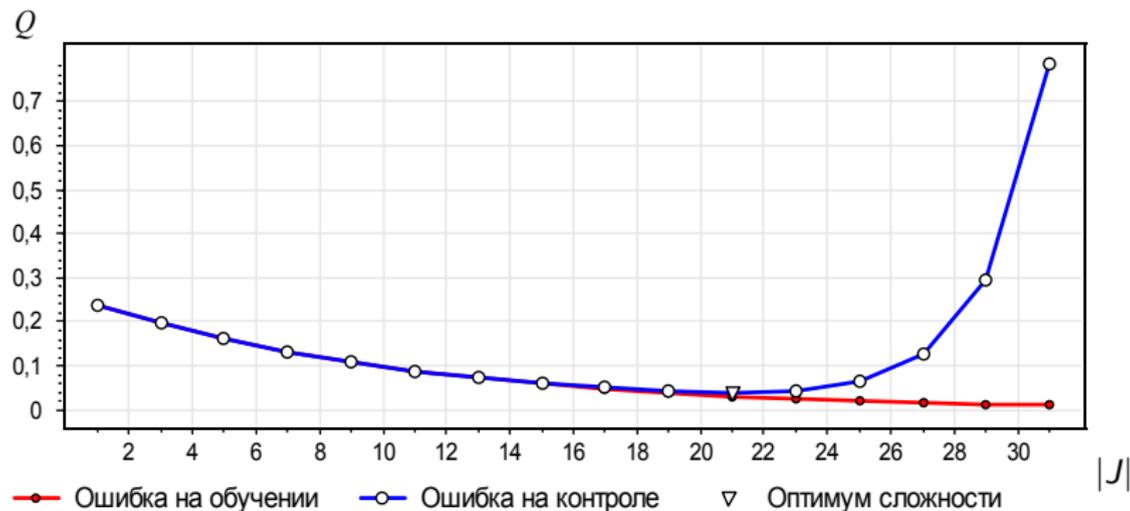
Задача отбора признаков по внешнему критерию

$F = \{f_j(x) : j = 1, \dots, n\}$ — множество признаков;

μ_J — метод обучения, использующий только признаки $J \subseteq F$;

$Q(J) = Q(\mu_J, X^\ell)$ — выбранный внешний критерий.

$Q(J) \rightarrow \min$ — задача дискретной оптимизации.



Сортировка с отсечением

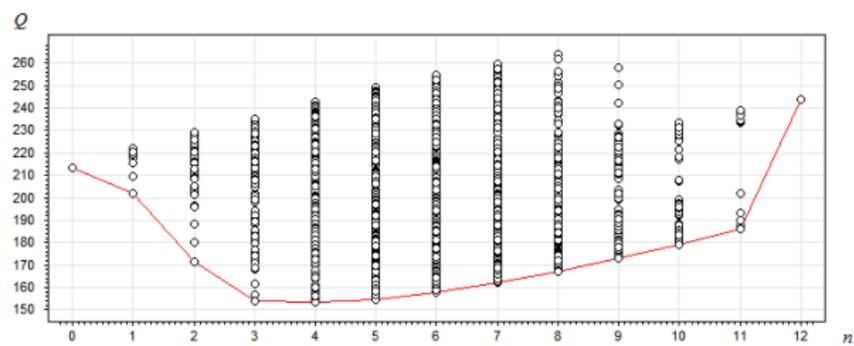
Фольклорный метод отбора признаков:

- Ввести меру индивидуальной информативности признака:
 - $|w_j|$ — модуль веса в линейном классификаторе,
 - $\langle f_j, y \rangle$ — скалярное произведение вектора значений признака и вектора ответов на всей выборке,
 - отношение среднего значения признака на объектах классов $+1$ и -1 ,
 - доля лучших наборов J низкой размерности (например, 3), содержащих признак f_j .
- Отсортировать признаки по убыванию информативности
- Взять лучшие K признаков
- Параметр K оптимизировать по внешнему критерию

Преимущества — простота реализации и скорость.

Недостаток — не во всех задачах это приводит к успеху.

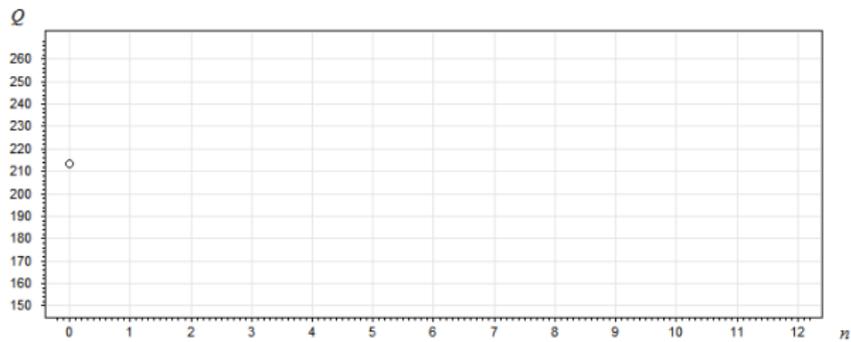
Алгоритм полного перебора (Full Search)



Вход: множество F , критерий Q , параметр d

- 1 $Q^* := Q(\emptyset)$ — инициализация;
- 2 **для всех** $j = 1, \dots, n$, где j — сложность наборов:
- 3 $J_j := \arg \min_{J: |J|=j} Q(J)$ — лучший набор сложности j ;
- 4 **если** $Q(J_j) < Q^*$ **то** $j^* := j$; $Q^* := Q(J_j)$;
- 5 **если** $j - j^* \geq d$ **то выход** J_{j^*} ;

Алгоритм полного перебора (Full Search)

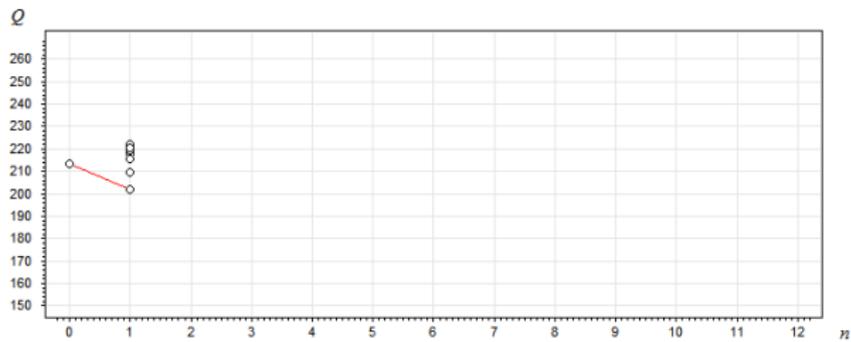


$$d = 3$$
$$j = 0$$

Вход: множество F , критерий Q , параметр d

- 1 $Q^* := Q(\emptyset)$ — инициализация;
- 2 **для всех** $j = 1, \dots, n$, где j — сложность наборов:
- 3 $J_j := \arg \min_{J: |J|=j} Q(J)$ — лучший набор сложности j ;
- 4 **если** $Q(J_j) < Q^*$ **то** $j^* := j$; $Q^* := Q(J_j)$;
- 5 **если** $j - j^* \geq d$ **то выход** J_{j^*} ;

Алгоритм полного перебора (Full Search)

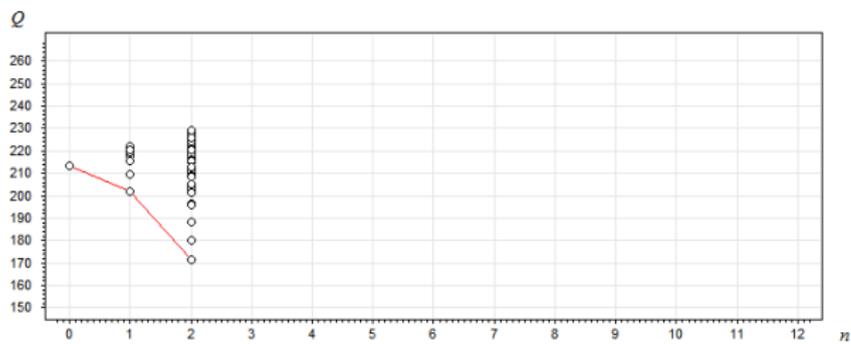


$$d = 3$$
$$j = 1$$
$$j^* = 1$$

Вход: множество F , критерий Q , параметр d

- 1 $Q^* := Q(\emptyset)$ — инициализация;
- 2 **для всех** $j = 1, \dots, n$, где j — сложность наборов:
- 3 $J_j := \arg \min_{J: |J|=j} Q(J)$ — лучший набор сложности j ;
- 4 **если** $Q(J_j) < Q^*$ **то** $j^* := j$; $Q^* := Q(J_j)$;
- 5 **если** $j - j^* \geq d$ **то выход** J_{j^*} ;

Алгоритм полного перебора (Full Search)



$$d = 3$$

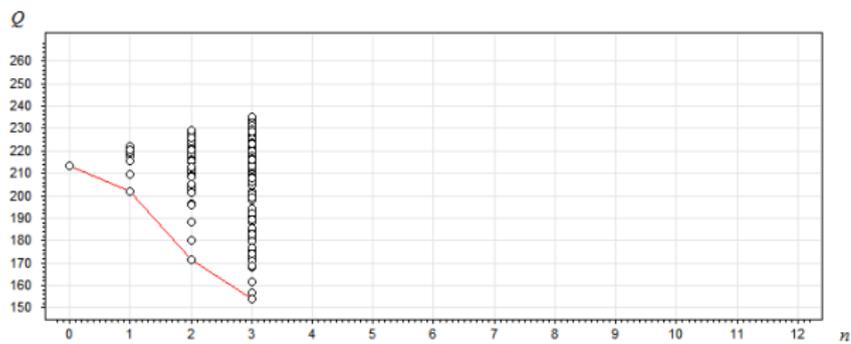
$$j = 2$$

$$j^* = 2$$

Вход: множество F , критерий Q , параметр d

- 1 $Q^* := Q(\emptyset)$ — инициализация;
- 2 **для всех** $j = 1, \dots, n$, где j — сложность наборов:
- 3 $J_j := \arg \min_{J: |J|=j} Q(J)$ — лучший набор сложности j ;
- 4 **если** $Q(J_j) < Q^*$ **то** $j^* := j$; $Q^* := Q(J_j)$;
- 5 **если** $j - j^* \geq d$ **то выход** J_{j^*} ;

Алгоритм полного перебора (Full Search)



$$d = 3$$

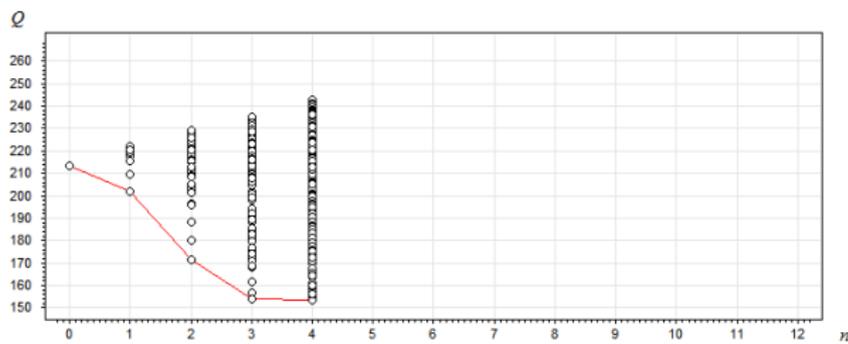
$$j = 3$$

$$j^* = 3$$

Вход: множество F , критерий Q , параметр d

- 1 $Q^* := Q(\emptyset)$ — инициализация;
- 2 **для всех** $j = 1, \dots, n$, где j — сложность наборов:
- 3 $J_j := \arg \min_{J: |J|=j} Q(J)$ — лучший набор сложности j ;
- 4 **если** $Q(J_j) < Q^*$ **то** $j^* := j$; $Q^* := Q(J_j)$;
- 5 **если** $j - j^* \geq d$ **то выход** J_{j^*} ;

Алгоритм полного перебора (Full Search)



$$d = 3$$

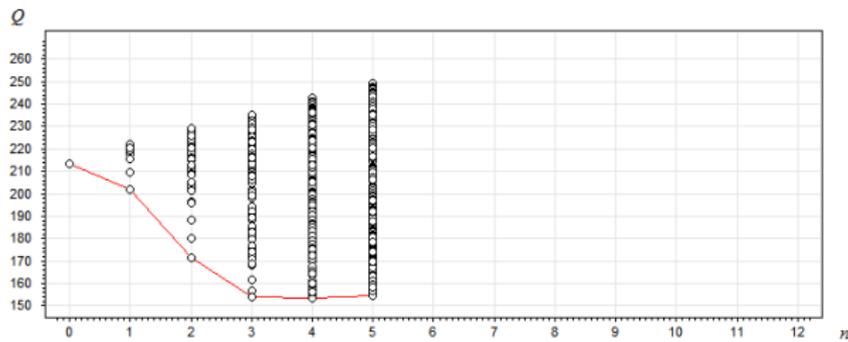
$$j = 4$$

$$j^* = 4$$

Вход: множество F , критерий Q , параметр d

- 1 $Q^* := Q(\emptyset)$ — инициализация;
- 2 **для всех** $j = 1, \dots, n$, где j — сложность наборов:
- 3 $J_j := \arg \min_{J: |J|=j} Q(J)$ — лучший набор сложности j ;
- 4 **если** $Q(J_j) < Q^*$ **то** $j^* := j$; $Q^* := Q(J_j)$;
- 5 **если** $j - j^* \geq d$ **то выход** J_{j^*} ;

Алгоритм полного перебора (Full Search)



$$d = 3$$

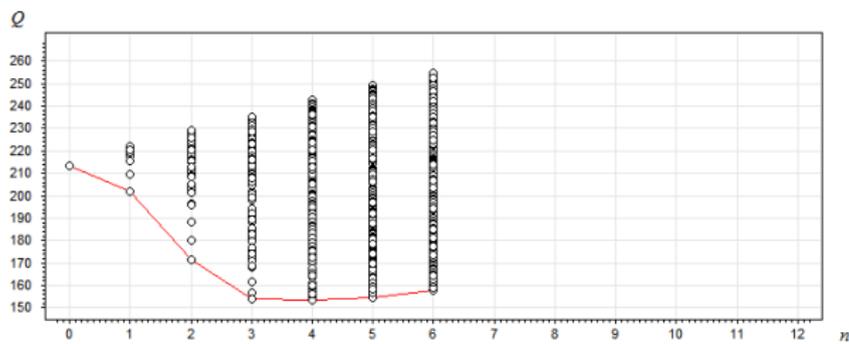
$$j = 5$$

$$j^* = 4$$

Вход: множество F , критерий Q , параметр d

- 1 $Q^* := Q(\emptyset)$ — инициализация;
- 2 **для всех** $j = 1, \dots, n$, где j — сложность наборов:
- 3 $J_j := \arg \min_{J: |J|=j} Q(J)$ — лучший набор сложности j ;
- 4 **если** $Q(J_j) < Q^*$ **то** $j^* := j$; $Q^* := Q(J_j)$;
- 5 **если** $j - j^* \geq d$ **то выход** J_{j^*} ;

Алгоритм полного перебора (Full Search)



$$d = 3$$

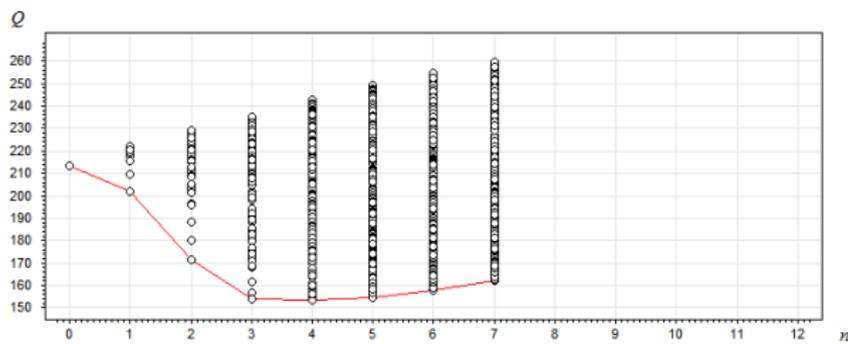
$$j = 6$$

$$j^* = 4$$

Вход: множество F , критерий Q , параметр d

- 1 $Q^* := Q(\emptyset)$ — инициализация;
- 2 **для всех** $j = 1, \dots, n$, где j — сложность наборов:
- 3 $J_j := \arg \min_{J: |J|=j} Q(J)$ — лучший набор сложности j ;
- 4 **если** $Q(J_j) < Q^*$ **то** $j^* := j$; $Q^* := Q(J_j)$;
- 5 **если** $j - j^* \geq d$ **то выход** J_{j^*} ;

Алгоритм полного перебора (Full Search)



$$d = 3$$

$$j = 7$$

$$j^* = 4$$

Вход: множество F , критерий Q , параметр d

- 1 $Q^* := Q(\emptyset)$ — инициализация;
- 2 **для всех** $j = 1, \dots, n$, где j — сложность наборов:
- 3 $J_j := \arg \min_{J: |J|=j} Q(J)$ — лучший набор сложности j ;
- 4 **если** $Q(J_j) < Q^*$ **то** $j^* := j$; $Q^* := Q(J_j)$;
- 5 **если** $j - j^* \geq d$ **то выход** J_{j^*} ;

Алгоритм полного перебора (Full Search)

Преимущества:

- простота реализации;
- гарантированный результат;
- полный перебор эффективен, когда
 - информативных признаков не много, $j^* \lesssim 5$;
 - всего признаков не много, $n \lesssim 20..100$.

Недостатки:

- в остальных случаях оооооочень долго — $O(2^n)$;
- чем больше перебирается вариантов, тем больше переобучение (особенно, если лучшие из вариантов существенно различны и одинаково плохи).

Способы устранения:

- эвристические методы сокращённого перебора.

Алгоритм жадного добавления (Add)

Вход: множество F , критерий Q , параметр d ;

- 1 $J_0 := \emptyset$; $Q^* := Q(\emptyset)$ — инициализация;
- 2 **для всех** $j = 1, \dots, n$, где j — сложность наборов
- 3 найди признак, наиболее выгодный для добавления:
 $f^* := \arg \min_{f \in F \setminus J_{j-1}} Q(J_{j-1} \cup \{f\})$;
- 4 добавить этот признак в набор:
 $J_j := J_{j-1} \cup \{f^*\}$;
- 5 **если** $Q(J_j) < Q^*$ **то** $j^* := j$; $Q^* := Q(J_j)$;
- 6 **если** $j - j^* \geq d$ **то выход** J_{j^*} ;

Переборные методы отбора признаков

Преимущества жадного Add:

- относительно быстрый — $O(n^2)$, точнее $O(n(j^* + d))$;

Недостатки жадного Add:

- склонен включать в набор лишние признаки

Другие методы отбора признаков:

- Add-Del — чередование добавлений и удалений
- поиск в ширину (метод группового учёта аргументов)
- поиск в глубину (метод ветвей и границ)
- эволюционные (генетические) алгоритмы
- случайный поиск с адаптацией

Определения и обозначения

U — множество субъектов (users/пользователей/клиентов);

I — множество объектов (items/предметов/товаров/ресурсов);

r_{ui} — матрица рейтингов или бинарных значений,
например, $r_{ui} = [\text{клиент } u \text{ использовал товар } i]$;

$D = \{(u, i) \mid \text{значение } r_{ui} \text{ известно}\}$

Задачи:

- прогнозирование незаполненных ячеек r_{ui} ;
- формирование списка рекомендаций для u или для i .
- оценивание сходства: $\rho(u, u')$, $\rho(i, i')$, $\rho(u, i)$;

Рекомендательная система на основе рейтингов

U — клиенты интернет-магазина;

I — товары (книги, фильмы, музыка, и т.п.);

r_{ui} = рейтинг, который клиент u выставил товару i ;

Пример: конкурс Netflix [www.netflixprize.com]

- 2 октября 2006 — 21 сентября 2009; главный приз — \$10⁶;
- $|U| = 0.48 \cdot 10^6$; $|I| = 17 \cdot 10^3$;
- 10⁸ рейтингов $\{1, 2, 3, 4, 5\}$;
- точность прогнозов оценивается по тестовой выборке D' :

$$\text{RMSE}^2 = \frac{1}{|D'|} \sum_{(u,i) \in D'} (r_{ui} - \hat{r}_{ui})^2;$$

- задача: уменьшить RMSE с 0.9514 до 0.8563 (на 10%).

Матричные разложения

T — множество тем (интересов): $|T| \ll |U|$, $|T| \ll |I|$;

p_{tu} — неизвестный профиль клиента u ; $P = (p_{tu})_{|T| \times |U|}$;

q_{ti} — неизвестный профиль объекта i ; $Q = (q_{ti})_{|T| \times |I|}$;

Задача: найти разложение $r_{ui} = \sum_{t \in T} p_{tu} q_{ti}$

Матричная запись: $R = P^T Q$

Вероятностный смысл: $r_{ui} = \sum_{t \in T} p_{tu} q_{ti}$

Методы решения:

SVD — сингулярное разложение (плохо интерпретируется);

NNMF — неотрицательное матричное разложение: $p_{tu} \geq 0$, $q_{ti} \geq 0$;

PLSA — вероятностный латентный семантический анализ.

Разреженный SVD (Singular Value Decomposition)

Обычный не разреженный SVD: $\|R - P^T Q\|^2 \rightarrow \min_{P, Q}$.

Разреженный SVD: $\sum_{(u, i) \in D} \underbrace{\left(r_{ui} - \bar{r}_u - \bar{r}_i - \sum_{t \in T} p_{tu} q_{ti} \right)^2}_{\varepsilon_{ui}} \rightarrow \min_{P, Q}$.

Метод стохастического градиента:

перебираем все $(u, i) \in D$ многократно в случайном порядке и делаем каждый раз градиентный шаг для задачи $\varepsilon_{ui}^2 \rightarrow \min_{p_u, q_i}$:

$$p_{tu} := p_{tu} + \eta \varepsilon_{ui} q_{ti}, \quad t \in T;$$

$$q_{ti} := q_{ti} + \eta \varepsilon_{ui} p_{ti}, \quad t \in T;$$

Tacáks G., Pilászy I., Németh B., Tikk D. Scalable collaborative filtering approaches for large recommendation systems // JMLR, 2009, No. 10, Pp. 623–656.

Разреженный SVD (Singular Value Decomposition)

Преимущества метода стохастического градиента:

- легко вводится регуляризация:

$$\epsilon_{ui}^2 + \lambda \|p_u\|^2 + \mu \|q_i\|^2 \rightarrow \min_{p_u, q_i};$$

- легко вводятся ограничения неотрицательности:

$$p_{tu} \geq 0, \quad q_{ti} \geq 0 \quad (\text{метод проекции градиента});$$

- легко вводится обобщение для ранговых данных:

$$\sum_{(u,i) \in D} \left(r_{ui} - \bar{r}_u - \bar{r}_i - \beta \left(\sum_{t \in T} p_{tu} q_{ti} \right) \right)^2 \rightarrow \min_{P, Q, \beta}.$$

- легко реализуются все виды инкрементности: добавление
 - ещё одного клиента u ,
 - ещё одного объекта i ,
 - ещё одного значения r_{ui} .
- высокая численная эффективность на больших данных;

NNMF (Non-Negative Matrix Factorization)

Метод чередующихся наименьших квадратов
 (Alternating Least Squares, ALS):

$$D = \left\| R - \sum_{t \in T} p_t q_t^T \right\|^2 = \left\| R_t - p_t q_t^T \right\|^2 \rightarrow \min_{\{p_t \geq 0, q_t \geq 0\}}$$

Идея: искать поочерёдно то строки p_t , то строки q_t при фиксированных остальных $s \neq t$, $R_{tui} = r_{ui} - \sum_{s \in T \setminus t} p_{su} q_{si}$.

$$\frac{\partial D}{\partial p_t} = 0 \Rightarrow (p_t^T q_t - R_t) q_t^T = 0 \Rightarrow p_{tu} = \left(\frac{\sum_i q_{ti} R_{tui}}{\sum_i q_{ti}^2} \right)_+$$

$$\frac{\partial D}{\partial q_t} = 0 \Rightarrow p_t (p_t^T q_t - R_t) = 0 \Rightarrow q_{ti} = \left(\frac{\sum_u p_{tu} R_{tui}}{\sum_u p_{tu}^2} \right)_+$$

Cichocki A., Zdunek R., Amari S., Hierarchical ALS algorithms for nonnegative matrix and 3D tensor factorization // Springer LNCS, 2007, v.4666, pp.169–176.

Использование латентных профилей

Оценивание сходства клиентов/объектов:

$$\rho^2(u, u') = \sum_{t \in T} (p_{tu} - p_{tu'})^2,$$

аналогично для $\rho(i, i')$, $\rho(u, i)$,

p_{tu} — сжатое признаковое описание клиента u ,

q_{ti} — сжатое признаковое описание объекта i .

Предсказание незаполненных ячеек:

$$\hat{r}_{ui} = \sum_{t \in T} p_{tu} q_{ti}$$

Рекомендация клиенту u — формирование списка товаров, ранжированного по убыванию \hat{r}_{ui} .

Резюме

- Недостаточная сложность модели ведёт к недообучению
- Избыточная сложность модели ведёт к переобучению
- Для оптимизации сложности нужен внешний критерий
- Чем больше данных, тем более сложную модель можно построить
- Самая простая характеристика сложности — число признаков
- Способы оптимизации сложности модели:
 - отбор признаков;
 - преобразование признаков;
 - латентные модели типа матричных разложений

Воронцов Константин Вячеславович

voron@forecsys.ru

www.MachineLearning.ru • Участник:Vokov

Если что-то было не понятно,
не стесняйтесь подходить и спрашивать :)