

Государственный экзамен по специальности

Петр Алексеевич Остроухов

Московский физико-технический институт
Факультет управления и прикладной математики
Кафедра интеллектуальных систем

18 января 2019 г.

Вопросы

- 1 Байесовская теория классификации. Линейный дискриминант Фишера. Метод окна Парзена.
- 2 Задачи геометрического поиска и критерии его эффективности. Алгоритмы локализации точки в простом и выпуклом многоугольниках.
- 3 Тематическое моделирование. Один из способов вывода EM-алгоритма, регуляризация и модальности, примеры регуляризаторов.

Байесовская теория
классификации. Линейный
дискриминант Фишера. Метод
окна Парзена.

Байесовская теория классификации

X — множество объектов, Y — конечное множество классов,
 $X \times Y$ — вероятностное пространство с плотностью
распределения $p(x, y)$.

- **Дано:** i.i.d. выборка $X^l = (x_i, y_i)_{i=1}^l \sim p(x, y)$;
- **Найти:** алгоритм $a : X \rightarrow Y$ с минимальной вероятностью ошибки.

Временное допущение: Пусть известна совместная плотность
распределения:

$$p(x, y) = p(x)P(y|x) = P(y)p(x|y).$$

Принцип максимума апостериорной вероятности:

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

Байесовская теория классификации

Теорема (Оптимальный байесовский классификатор)

Пусть $P(y)$ и $p(x|y)$ известны, $\lambda_y \geq 0$ — потеря от ошибки на объекте класса $y \in Y$. Тогда минимум среднего эмпирического риска:

$$R(a) = \sum_{y \in Y} \lambda_y \int [a(x) \neq y] p(x, y) dx$$

достигается байесовским классификатором

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

Байесовская теория классификации

Подзадачи

- 1 Восстановление плотности распределения по выборке

Дано: $X^l = (x_i, y_i)_{i=1}^l$ — обучающая выборка.

Найти: эмпирические оценки $\hat{P}(y)$ и $\hat{p}(x|y)$, $y \in Y$.

- 2 Построение классификатора

Дано: эмпирические оценки $\hat{P}(y)$ и $\hat{p}(x|y)$, $y \in Y$

(байесовский классификатор здесь уже не оптимален).

Найти: классификатор $a : X \times Y$, минимизирующий $R(a)$.

Байесовская теория классификации

Наивный байесовский классификатор

Допущение: признаки $f_j : X \rightarrow D_j$ — независимы друг от друга, $f_j \sim p_j(\xi|y)$, $y \in Y$, $j = 1, \dots, n$.

Тогда функции правдоподобия классов представимы в виде:

$$p(x|y) = p_1(\xi_1|y) \cdots p_n(\xi_n|y).$$

В итоге, наш классификатор:

$$a(x) = \arg \max_{y \in Y} \left(\log \lambda_y \hat{P}(y) + \sum_{i=1}^n \log \hat{p}(\xi_i|y) \right)$$

Непараметрическое восстановление плотности

По выборке $X^m = (x_i)_{i=1}^m$ оценить плотность $\hat{p}(x)$.

Дискретный случай: $X \gg m$. Гистограмма:

$$\hat{p}(x) = \frac{1}{m} \sum_{i=1}^m [x_i = x].$$

Одномерный непрерывный случай: $X = \mathbb{R}$. Эмпирическая оценка по окну ширины h :

$$\hat{p}_h(x) = \frac{1}{mh} \sum_{i=1}^m \frac{1}{2} \left[\frac{|x - x_i|}{h} < 1 \right].$$

Непараметрическое восстановление плотности

Обобщение: оценка Парзена-Розенблатта по окну h :

$$\hat{p}_h(x; X^m) = \frac{1}{mh} \sum_{i=1}^m K\left(\frac{x - x_i}{h}\right),$$

где $K(r)$ — ядро:

- четная;
- нормированная: $\int K(r)dr = 1$;
- невозрастающая при $r > 0$, неотрицательная функция.

Непараметрическое восстановление плотности

Многомерное обобщение: $\rho(x, x')$ — метрика на X . Тогда парzenовская оценка плотности для каждого класса $y \in Y$ в отдельности:

$$\hat{p}_h(x|y) = \frac{1}{l_y V(h)} \sum_{i:y_i=y} K\left(\frac{\rho(x, x_i)}{h}\right)$$

Классификация методом окна Парзена:

$$a(x; h) = \arg \max_y \frac{\lambda_y P(y)}{l_y V(h)} \sum_{i:y_i=y} K\left(\frac{\rho(x, x_i)}{h}\right),$$

- $V(h) = \int_X K\left(\frac{\rho(x, x_i)}{h}\right) dx$ не должен зависеть от x_i и y_i .
- проблема выбора $K(x)$, h , $\rho(x, x_i)$.

Непараметрическое восстановление плотности

Замечания

- выбор ядра не сильно влияет на качество восстановления плотности при $m \rightarrow \infty$;
- выбор h существенно влияет на качество.

Проблема: при наличии локальных сгущений любая h не оптимальна.

Идея: задавать не ширину окна h , а число соседей k , и тогда:

$$h_k(x) = \rho(x, x^{(k+1)}),$$

$x^{(i)}$ — i -й сосед, среди ранжированных по расстоянию от x .
При этом $V(h)$ не должна зависеть от y , поэтому выборка ранжируется целиком, а не по классам.

Параметрическое восстановление плотности

Задана параметрическая модель плотности

$$p(x) = \phi(x; \theta),$$

где θ — параметр, ϕ — фиксированная функция.
Нужно найти оптимальное значение θ по по i.i.d. выборке.

Принцип максимума правдоподобия:

$$L(\theta; X^m) = \sum_{i=1}^m \log \phi(x_i; \theta) \rightarrow \max_{\theta}.$$

Необходимое условие оптимума:

$$\frac{\partial L(\theta; X^m)}{\partial \theta} = \sum_{i=1}^m \frac{\partial \log \phi(x_i; \theta)}{\partial \theta} = 0,$$

где функция $\phi(x; \theta)$ — достаточно гладкая по θ .

Параметрическое восстановление плотности

Пусть $X \subset \mathbb{R}^n$.

Гипотеза: классы имеют n -мерные гауссовские плотности:

$$p(x|y) = \mathcal{N}(x; \mu_y, \Sigma_y) = \frac{\exp(-\frac{1}{2}(x - \mu_y)^T \Sigma_y^{-1}(x - \mu_y))}{\sqrt{(2\pi)^n \det \Sigma_y}}, \quad y \in Y,$$

где μ_y — вектор математического ожидания (центр) класса $y \in Y$, Σ_y — симметричная, положительно определенная, невырожденная ковариационная матрица класса $y \in Y$.

Теорема

- 1 Разделяющая поверхность $\{x \in X | \lambda_y P(y)p(x|y) = \lambda_s P(s)p(x|s)\}$ квадратична $\forall y, s \in Y, y \neq s$.
- 2 Если $\Sigma_y = \Sigma_s$, то она вырождается в линейную.

Параметрическое восстановление плотности:

Теорема

Оценки максимального правдоподобия для n -мерных гауссовских плотностей классов $y \in Y$:

$$\hat{\mu}_y = \frac{1}{l_y} \sum_{i:y_i=y} x_i;$$

$$\hat{\Sigma}_y = \frac{1}{l_y} \sum_{i:y_i=y} (x_i - \hat{\mu}_y)(x_i - \hat{\mu}_y)^T.$$

Квадратичный дискриминант:

$$a(x) = \arg \max_y \log \lambda_y P(y) - \frac{1}{2}(x - \hat{\mu}_y)^T \hat{\Sigma}_y^{-1} (x - \hat{\mu}_y) - \frac{1}{2} \log \det \hat{\Sigma}_y.$$

Проблема: для малочисленных классов возможно $\det \hat{\Sigma}_y = 0$.

Параметрическое восстановление

плотности:

Допущение: ковариационные матрицы классов равны:

$$\Sigma_y = \Sigma, \quad \forall y \in Y.$$

Оценка максимума правдоподобия для Σ :

$$\hat{\Sigma} = \frac{1}{l} \sum_{i=1}^l (x_i - \hat{\mu}_{y_i})(x_i - \hat{\mu}_{y_i})^T.$$

Линейный дискриминант Фишера:

$$\begin{aligned} a(x) &= \arg \max_y \lambda_y \hat{P}(y) \hat{p}(x|y) = \\ &= \arg \max_y (\log(\lambda_y \hat{P}(y)) - \frac{1}{2} \hat{\mu}_y^T \hat{\Sigma}_y^{-1} \hat{\mu}_y + x^T \hat{\Sigma}_y^{-1} \hat{\mu}_y); \\ a(x) &= \arg \max_y (x^T \alpha_y + \beta_y). \end{aligned}$$

Задачи геометрического
поиска и критерии его
эффективности. Алгоритмы
локализации точки в простом
и выпуклом многоугольниках.

Задачи геометрического поиска и критерии его эффективности.

Задача поиска

Дано: набор данных, именуемый *файлом* и некоторый новый элемент данных, именуемые *образцом*.

Нужно установить связь между образцом и файлом. Поисковое сообщение, в соответствии с которым ведется просмотр файлы, называется *запросом*.

Особенности геометрического поиска

:

- данные отображают сложные структуры (полигоны, полиэдры и т.п.);
- результатом поиска может оказаться не элемент файла, а положение образца относительно файла.

Задачи геометрического поиска и критерии его эффективности.


Анализ требуемых ресурсов оценивается по четырем категориям:

- 1 *Время запроса.* (Сколько времени необходимо на один запрос?)
- 2 *Память.* (Сколько памяти необходимо для структуры данных?)
- 3 *Время предобработки.* (Сколько времени потребуется на включение элемента данных в структуру или на удаление из нее?)

Главные модели геометрического поиска:

- *Задача локализации.* Файл — разбиение геометрического пространства, запрос — точка.
- *Задача регионального поиска.* Файл содержит набор точек пространства. Запрос — некоторая стандартная геометрическая фигура, произвольно перемещаемая в этом пространстве.

Локализация точки в простом многоугольнике



Даны простой многоугольник P и точка z . Определить, находится ли q внутри P .


- $L = 0$
- *for* i *in* $(1, N)$ *do* (цикл по всем ребрам)
- *if* (ребро[i] не горизонтально) *and* (ребро[i]) пересекает l нижним концом справа от q
 - *then* $L = L + 1$
- *if* L нечетно *then* q внутри, иначе — снаружи.

Локализация точки в простом многоугольнике

Теорема

Принадлежность точки внутренней области простого n -угольника можно установить за время $O(n)$ без предобработки.

Локализация точки в выпуклом многоугольнике



Предобработка: расположить точки в векторе в направлении по часовой стрелки.

Провести из первой точки лучи через все остальные вершины. Далее необходимо понять, в каком из полученных углов лежит точка. В конце концов, необходимо понять, по какую сторону от ребра сектора лежит данная точка.

Локализация точки в выпуклом многоугольнике

- Предобработка требует времени $O(n)$
- Выполнение запроса требует $O(\log n)$ для поиска сектора, содержащего z , и постоянного времени для локализации точки внутри треугольника сектора.

Теорема

Время ответа на запрос о принадлежности точки выпуклому n -угольнику равно $O(\log n)$ при затратах $O(n)$ памяти и $O(n)$ времени на предобработку.

Тематическое моделирование.
Один из способов вывода
EM-алгоритма, регуляризация
и модальности, примеры
регуляризаторов.

Тематическое моделирование (ТМ)

- W — конечное множество слов
- D — конечное множество документов
- T — конечное множество тем (скрыто)
- $D \times W \times T$ — дискретная генеральная совокупность
- гипотеза условной независимости: $p(w|t, d) = p(w|t)$

Вероятностная тематическая модель порождения текста:

$$p(w|d) = \sum_{t \in T} p(w|t, d)p(t|d) = \sum_{t \in T} p(w|t)p(t|d) = \sum_{t \in T} \phi_{wt}\theta_{td}$$

ТМ [ДНК]

- Дано: n_{dw} — частоты слов в документах $\Rightarrow \hat{p}(w|d) = \frac{n_{dw}}{n_d}$
- Найти:
 - $\phi_{wt} = p(w|t)$ — вероятности слов в темах
 - $\theta_{td} = p(t|d)$ — вероятности тем в документах
- Критерий максимизации правдоподобия:

$$\begin{aligned}\mathcal{L}(\Phi; \Theta) &= \ln p((d, w)_{d \in D, w \in W}; \Phi, \Theta) = \\ &= \ln \prod_{w \in W} \prod_{d \in D} (p(w|d) p(d))^{n_{dw}} = \\ &= \sum_{w \in W} \sum_{d \in D} n_{dw} \ln \sum_{t \in T} \phi_{wt} \theta_{td} \rightarrow \max_{\Phi; \Theta}\end{aligned}$$

$$\sum_{w \in W} \phi_{wt} = 1, \phi_{wt} \geq 0, \sum_{t \in T} \theta_{td} = 1, \theta_{td} \geq 0.$$

TM [ARTM]

MMΠ + ARTM:

$$\sum_{d,w} n_{dw} \log \sum_{t \in T} \phi_{wt} \theta_{td} + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}; \quad R(\Phi, \Theta) = \sum_{i=1}^k \tau_i R_i(\Phi, \Theta)$$
$$\sum_{w \in W} \phi_{wt} = \{0, 1\}, \phi_{wt} \geq 0, \sum_{t \in T} \theta_{td} = \{0, 1\}, \theta_{td} \geq 0.$$

TM [EM-алгоритм]

EM-алгоритм — метод простых итераций для системы уравнений

$$\sum_{d,w} n_{dw} \log \sum_{t \in T} \phi_{wt} \theta_{td} + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}; \quad R(\Phi, \Theta) = \sum_{i=1}^k \tau_i R_i(\Phi, \Theta)$$

$$\sum_{w \in W} \phi_{wt} = \{0, 1\}, \quad \phi_{wt} \geq 0, \quad \sum_{t \in T} \theta_{td} = \{0, 1\}, \quad \theta_{td} \geq 0.$$

E-шаг:

$$p_{tdw} = \text{norm}_{t \in T}(\phi_{wt} \theta_{td})$$

M-шаг:

$$\phi_{wt} = \text{norm}_{t \in T} \left(n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right), \quad n_{wt} = \sum_{d \in D} n_{dw} p_{tdw};$$

$$\theta_{td} = \text{norm}_{t \in T} \left(n_{td} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right), \quad n_{td} = \sum_{w \in d} n_{dw} p_{tdw}.$$

ТМ [EM-алгоритм]

Решение может быть вырожденным для некоторых тем (столбцов матриц Φ) и документов (столбцов матрицы Θ).

Тема t вырождена, если для всех термов $w \in W$

$$n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \leq 0$$

Если тема вырождена, то $\phi_{wt} \equiv 0$; т.е. происходит отбор тем.

Документ d вырожден, если для всех тем $t \in T$

$$n_{td} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \leq 0$$

Если документ вырожден, то $\theta_{td} \equiv 0$; что означает, что модель не может описать данный документ.

Условия ККН

$$\begin{cases} f(x) \rightarrow \min_x; \\ g_i(x) \leq 0, \quad i = 1, \dots, m; \\ h_j(x) = 0, \quad j = 1, \dots, k. \end{cases}$$

Необходимые условия. Если x — точка локального минимума, то существуют множители $\mu_i, i = 1, \dots, m, \lambda_j, j = 1, \dots, k$:

$$\frac{\partial \mathcal{L}}{\partial x} = 0, \quad \mathcal{L}(x; \mu, \lambda) = f(x) + \sum_{i=1}^m \mu_i g_i(x) + \sum_{j=1}^k \lambda_j h_j(x);$$

$g_i(x) \leq 0; h_j(x) = 0$; (исходные ограничения)

$\mu_i \geq 0$; (двойственные ограничения)

$\mu_i g_i(x) = 0$; условия дополняющей нежесткости

ТМ [EM-алгоритм]

- 1 Условия ККТ для ϕ_{wt} (аналогично для θ_{td}):

$$\sum_d n_{dw} \frac{\theta_{td}}{p(w|d)} + \frac{\partial R}{\partial \phi_{wt}} = \lambda_t - \mu_{wt}; \quad \mu_{wt} \geq 0; \quad \mu_{wt} \phi_{wt} = 0.$$

- 2 Умножим обе части равенства на ϕ_{wt} и выделим p_{tdw} :

$$\phi_{wt} \lambda_t = \sum_d n_{dw} \frac{\phi_{wt} \theta_{td}}{p(w|d)} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} = n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}}.$$

- 3 Если $\lambda_t \leq 0$, то тема t вырождена, $\phi_{wt} \equiv 0$ для всех w .

- 4 Если $\lambda_t > 0$, то либо $\phi_{wt} = 0$, либо $n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} > 0$:

$$\phi_{wt} \lambda_t = \left(n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right)_+.$$

- 5 Суммируем обе части равенства по $w \in W$:

$$\lambda_t = \sum_{w \in W} \left(n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right)_+.$$

- 6 Подставив λ_t из (5) в (4), получим результат.

TM [модальности]

Пусть M — множество модальностей. Тогда

$$\forall m \in M \exists W_m : \forall i \neq j W_i \cap W_j = \emptyset, \bigcup_{m \in M} W_m = W.$$

Тематическая модель для каждой модальности остается без изменений.

ММП для мультимодальной модели:

$$\sum_{m \in M} \tau_m \sum_{d \in D} \sum_{w \in W_m} n_{dw} \ln \sum_{t \in T} \phi_{wt} \theta_{td} \rightarrow \max_{\Phi, \Theta}$$

$$\sum_{w \in W} \phi_{wt} = \{0, 1\}, \phi_{wt} \geq 0, \sum_{t \in T} \theta_{td} = \{0, 1\}, \theta_{td} \geq 0,$$

где τ_m — веса модальностей.