

Курс «Введение в машинное обучение»

Вероятностные модели машиинного обучения

Воронцов Константин Вячеславович

k.v.vorontsov@phystech.edu

<http://www.MachineLearning.ru/wiki?title=User:Vokov>

Этот курс доступен на странице вики-ресурса

<http://www.MachineLearning.ru/wiki>

«Введение в машинное обучение (курс лекций, К.В.Воронцов)»

- 1 Принцип максимума правдоподобия**
 - Оценивание плотности распределения
 - Разделение смеси плотностей
 - Восстановление регрессии
- 2 Дискриминативные модели классификации**
 - Обобщённая линейная модель
 - Логистическая регрессия
 - Аппроксимация и регуляризация эмпирического риска
- 3 Генеративные модели классификации**
 - Байесовская теория классификации
 - Наивный байесовский классификатор
 - Обзор байесовских классификаторов

Задача оценивания плотности — обучение без учителя

Дано: простая (i.i.d.) выборка $X^\ell = \{x_1, \dots, x_\ell\} \sim p(x)$

Найти параметрическую модель плотности распределения:

$$p(x) = \varphi(x; w),$$

где w — вектор параметров, φ — фиксированная функция

Критерий — максимум (логарифма) правдоподобия выборки,
MLE-оценивание параметра w (Maximum Likelihood Estimate):

$$L(w; X^\ell) = \ln \prod_{i=1}^{\ell} \varphi(x_i; w) = \sum_{i=1}^{\ell} \ln \varphi(x_i; w) \rightarrow \max_w$$

Аналитическое решение: необходимое условие экстремума

$$\frac{\partial}{\partial w} L(w; X^\ell) = \sum_{i=1}^{\ell} \frac{\partial}{\partial w} \ln \varphi(x_i; w) = 0,$$

при условии достаточной гладкости функции $\varphi(x; w)$ по w

Частный случай: многомерная гауссовская плотность

Пусть объекты x описываются n признаками $f_j(x) \in \mathbb{R}$ и выборка порождена n -мерной гауссовой плотностью:

$$x_i \sim p(x) = \mathcal{N}(x; \mu, \Sigma) = \frac{\exp(-\frac{1}{2}(x - \mu)^T \Sigma^{-1} (x - \mu))}{\sqrt{(2\pi)^n \det \Sigma}}, \quad x \in \mathbb{R}^n$$

$\mu \in \mathbb{R}^n$ — вектор математического ожидания, $\mu = E x$

$\Sigma \in \mathbb{R}^{n \times n}$ — ковариационная матрица, $\Sigma = E(x - \mu)(x - \mu)^T$

(симметричная, невырожденная, положительно определённая)

Выборочные оценки максимального правдоподобия:

$$\frac{\partial}{\partial \mu} \ln L(\mu, \Sigma; X^\ell) = 0 \quad \Rightarrow \quad \hat{\mu} = \frac{1}{\ell} \sum_{i=1}^{\ell} x_i$$

$$\frac{\partial}{\partial \Sigma} \ln L(\mu, \Sigma; X^\ell) = 0 \quad \Rightarrow \quad \hat{\Sigma} = \frac{1}{\ell} \sum_{i=1}^{\ell} (x_i - \hat{\mu})(x_i - \hat{\mu})^T$$

Оценка дискретного распределения

Дано: выборка $x_i \in X$, $|X| < \infty$, порождаемая i.i.d.

дискретным распределением ($p_x : x \in X$), $\sum_x p_x = 1$, $p_x \geq 0$

Найти: параметры распределения ($p_x : x \in X$)

Критерий: максимум (логарифма) правдоподобия выборки

$$\ln \prod_{i=1}^{\ell} p_{x_i} = \sum_{x \in X} \underbrace{\sum_{i=1}^{\ell} [x_i = x]}_{\ell_x} \ln p_x = \sum_{x \in X} \ell_x \ln p_x \rightarrow \max_{(p_x)}$$

Выборочная оценка максимального правдоподобия

$\hat{p}_x = \frac{\ell_x}{\ell}$ — частотные оценки вероятностей $p_x = P(x_i=x)$,
оценка минимума кросс-энтропии, эмпирическая гистограмма

Доказательство из условий ККТ: $\frac{\partial}{\partial p_x} \left(\sum_{x \in X} \ell_x \ln p_x + \mu \left(1 - \sum_{x \in X} p_x \right) \right) = 0$

Задача разделения смеси распределений

Дано: выборка $\{x_1, \dots, x_\ell\}$, порождаемая i.i.d. из $p(x)$

Найти: модель вероятностной смеси k распределений:

$$p(x) = \sum_{j=1}^k w_j \varphi(x, \theta_j), \quad \sum_{j=1}^k w_j = 1, \quad w_j \geq 0,$$

описывающую двухуровневый процесс порождения данных:

- ① $j \sim P(j) \equiv w_j$ — дискретное априорное распределение
- ② $x \sim p(x|j) \equiv \varphi(x, \theta_j)$ — плотность j -й компоненты

Критерий максимума log-правдоподобия:

$$\left\{ \begin{array}{l} \ln \prod_{i=1}^{\ell} p(x_i) = \sum_{i=1}^{\ell} \ln \sum_{j=1}^k w_j \varphi(x_i, \theta_j) \rightarrow \max_{w, \theta} \\ \sum_{j=1}^k w_j = 1, \quad w_j \geq 0 \end{array} \right.$$

EM-алгоритм для разделения смеси распределений

Теорема (необходимые условия экстремума)

Точка $(w_j, \theta_j)_{j=1}^k$ локального экстремума $L(w, \theta)$ удовлетворяет системе уравнений относительно параметров модели w_j, θ_j и вспомогательных переменных g_{ij} :

$$\text{E-шаг: } g_{ij} = \frac{w_j \varphi(x_i, \theta_j)}{\sum_{s=1}^k w_s \varphi(x_i, \theta_s)}, \quad i = 1, \dots, \ell, \quad j = 1, \dots, k;$$

$$\text{M-шаг: } \theta_j = \arg \max_{\theta} \sum_{i=1}^{\ell} g_{ij} \ln \varphi(x_i, \theta), \quad j = 1, \dots, k;$$

$$w_j = \frac{1}{\ell} \sum_{i=1}^{\ell} g_{ij}, \quad j = 1, \dots, k.$$

EM-алгоритм — метод простых итераций для решения системы

Вероятностная интерпретация шагов EM-алгоритма

E-шаг — это формула Байеса:

$$g_{ij} = P(j|x_i) = \frac{P(j)p(x_i|j)}{p(x_i)} = \frac{w_j \varphi(x_i, \theta_j)}{p(x_i)} = \frac{w_j \varphi(x_i, \theta_j)}{\sum_{s=1}^k w_s \varphi(x_i, \theta_s)}$$

Нормировка условных вероятностей: $\sum_{j=1}^k g_{ij} = 1$

M-шаг — это максимизация взвешенного log-правдоподобия, с весами объектов g_{ij} для j -й компоненты смеси:

$$\theta_j = \arg \max_{\theta} \sum_{i=1}^{\ell} g_{ij} \ln \varphi(x_i, \theta),$$


вес компоненты определяется как средний вес её объектов:

$$w_j = \frac{1}{\ell} \sum_{i=1}^{\ell} g_{ij}$$

Пример: разделение гауссовой смеси

Две гауссовые компоненты $k = 2$ в пространстве $X = \mathbb{R}^2$.

Расположение компонент в зависимости от номера итерации L :



Вероятностная постановка задачи регрессии

Дано: выборка $(x_i, y_i)_{i=1}^{\ell}$, $x_i \in \mathbb{R}^n$, $y_i \in \mathbb{R}$

Найти: параметр w модели регрессии с гауссовским шумом:

$$y_i = a(x_i, w) + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma_i^2), \quad i = 1, \dots, \ell.$$

Эквивалентная запись: $y_i \sim \mathcal{N}(\mu_i, \sigma_i^2)$, $\mu_i = E y_i = a(x_i, w)$.

Критерий максимума правдоподобия эквивалентен МНК:

$$p(\varepsilon_1, \dots, \varepsilon_\ell | w) = \prod_{i=1}^{\ell} \frac{1}{\sigma_i \sqrt{2\pi}} \exp\left(-\frac{1}{2\sigma_i^2} \varepsilon_i^2\right) \rightarrow \max_w$$

$$-\ln p(\varepsilon_1, \dots, \varepsilon_\ell | w) = \text{const} + \frac{1}{2} \sum_{i=1}^{\ell} \frac{1}{\sigma_i^2} (a(x_i, w) - y_i)^2 \rightarrow \min_w$$

Что использовать вместо метода наименьших квадратов, если y_i не гауссовские, в частности, если y_i дискретнозначные?

Обобщённая линейная модель (Generalized Linear Model, GLM)

Нормальная линейная модель для математического ожидания:

$$y_i \sim \mathcal{N}(\mu_i, \sigma_i^2), \quad \mu_i = \langle x_i, w \rangle = E y_i$$

Обобщённая линейная модель для математического ожидания:

$$y_i \sim \text{Exp}(\theta_i, \varphi_i), \quad \theta_i = \langle x_i, w \rangle = g(E y_i)$$

Exp — экспоненциальное семейство распределений

с параметрами θ_i, φ_i и параметрами-функциями $c(\theta), h(y, \varphi)$:

$$p(y_i | \theta_i, \varphi_i) = \exp\left(\frac{y_i \theta_i - c(\theta_i)}{\varphi_i} + h(y_i, \varphi_i)\right)$$

Математическое ожидание и дисперсия с.в. $y_i \sim \text{Exp}(\theta_i, \varphi_i)$:

$$\mu_i = E y_i = c'(\theta_i) \Rightarrow \theta_i = [c']^{-1}(\mu_i) = g(E y_i)$$

$$D y_i = \varphi_i c''(\theta_i)$$

$g(\mu) = [c']^{-1}(\mu)$ — монотонная функция связи (link function)

Примеры распределений из экспоненциального семейства

Нормальное (гауссовское) распределение, $y_i \in \mathbb{R}$:

$$\begin{aligned} p(y_i | \mu_i, \sigma_i^2) &= \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{1}{2\sigma_i^2}(y_i - \mu_i)^2\right) = \\ &= \exp\left(\frac{y_i\mu_i - \frac{1}{2}\mu_i^2}{\sigma_i^2} - \frac{y_i^2}{2\sigma_i^2} - \frac{1}{2} \ln(2\pi\sigma_i^2)\right); \end{aligned}$$

$$\theta_i = g(\mu_i) = \mu_i, \quad c(\theta_i) = \frac{1}{2}\mu_i^2 = \frac{1}{2}\theta_i^2, \quad \varphi_i = \sigma_i^2.$$

Распределение Бернулли, $y_i \in \{0, 1\}$:

$$p(y_i | \mu_i) = \mu_i^{y_i} (1 - \mu_i)^{1-y_i} = \exp\left(y_i \ln \frac{\mu_i}{1-\mu_i} + \ln(1 - \mu_i)\right);$$

$$\theta_i = g(\mu_i) = \ln \frac{\mu_i}{1-\mu_i}, \quad c(\theta_i) = -\ln(1 - \mu_i) = \ln(1 + e^{\theta_i}).$$

Примеры распределений из экспоненциального семейства

Биномиальное распределение, $y_i \in \{0, 1, \dots, n_i\}$:

$$\begin{aligned} p(y_i | \mu_i, n_i) &= C_{n_i}^{y_i} \left(\frac{\mu_i}{n_i}\right)^{y_i} \left(1 - \frac{\mu_i}{n_i}\right)^{n_i - y_i} = \\ &= \exp\left(y_i \ln \frac{\mu_i}{n_i - \mu_i} + n_i \ln(n_i - \mu_i) + \ln C_{n_i}^{y_i} - n_i \ln n_i\right); \end{aligned}$$

$$\theta_i = g(\mu_i) = \ln \frac{\mu_i}{n_i - \mu_i}, \quad c(\theta_i) = -n_i \ln(n_i - \mu_i) = n_i \ln \frac{1+e^{\theta_i}}{n_i}.$$

Пуассоновское распределение, $y_i \in \{0, 1, 2, \dots\}$:

$$p(y_i | \mu_i) = \frac{e^{-\mu_i} \mu_i^{y_i}}{y_i!} = \exp\left(\frac{y_i \ln(\mu_i) - \mu_i}{1} - \ln y_i!\right);$$

$$\theta_i = g(\mu_i) = \ln(\mu_i), \quad c(\theta_i) = \mu_i = e^{\theta_i}, \quad \varphi_i = 1.$$

Примеры распределений из экспоненциального семейства

- нормальное (гауссовское)
- распределение Пуассона
- биномиальное и мультиномиальное
- геометрическое
- χ^2 -распределение
- бета-распределение
- гамма-распределение
- распределение Дирихле
- распределение Лапласа с фиксированным матожиданием

Контр-примеры не экспоненциальных распределений:

- t -распределение Стьюдента, Коши, гипергеометрическое

Двухклассовая логистическая регрессия

Распределение Бернулли, $y_i \in \{0, 1\}$: $p(y_i|\mu_i) = \mu_i^{y_i}(1 - \mu_i)^{1-y_i}$

$$\theta_i = g(\mu_i) = \ln \frac{\mu_i}{1-\mu_i} \quad \text{E}y_i = \mu_i = g^{-1}(\theta_i) = \frac{1}{1+\exp(-\theta_i)} \equiv \sigma(\theta_i)$$

Дано: выборка $(x_i, y_i)_{i=1}^{\ell}$, $x_i \in \mathbb{R}^n$, $y_i \in \{0, 1\} \sim p(y_i|\mu_i)$

Найти: линейную модель $g(\text{E}y_i) = \langle x_i, w \rangle$

Критерий: максимум log-правдоподобия (log-loss)

$$\sum_{i=1}^{\ell} \ln p(y_i|\mu_i, x_i) = \sum_{i=1}^{\ell} y_i \ln \mu_i + (1 - y_i) \ln(1 - \mu_i) \rightarrow \max_w$$

Удобная перекодировка: $y_i \in \{0, 1\} \rightarrow \tilde{y}_i = 2y_i - 1 \in \{-1, 1\}$

$$\sum_{i=1}^{\ell} \ln(1 + \exp(-\langle w, x_i \rangle \tilde{y}_i)) \rightarrow \min_w$$

Логистическая регрессия как частный случай GLM


Всего лишь из двух предположений:

- y_i — бернульиевские случайные величины с $Ey_i = \mu_i$
- μ_i связано с линейной моделью $g(\mu_i) = \langle x_i, w \rangle$

следуют все основные свойства логистической регрессии:

- логарифмическая функция потерь $\ln(1 + \exp(-\langle x_i, w \rangle \tilde{y}_i))$;
- сигмоидная функция связи $P(y_i|x_i) = \sigma(\langle x_i, w \rangle \tilde{y}_i)$;
- связь линейной модели с отношением шансов (odds ratio):

$$\langle x_i, w \rangle = \ln \frac{\mu_i}{1-\mu_i} = \ln \frac{P(y_i=1|x_i)}{P(y_i=0|x_i)}$$



Многоклассовая логистическая регрессия

Линейный классификатор при произвольном числе классов $|Y|$:

$$a(x) = \arg \max_{y \in Y} \langle w_y, x \rangle, \quad x, w_y \in \mathbb{R}^n$$

Вероятность того, что объект x относится к классу y :

$$P(y|x, w) = \frac{\exp \langle w_y, x \rangle}{\sum_{z \in Y} \exp \langle w_z, x \rangle} = \text{SoftMax}_{y \in Y} \langle w_y, x \rangle,$$

функция SoftMax: $\mathbb{R}^Y \rightarrow \mathbb{R}^Y$ переводит произвольный вектор в нормированный вектор дискретного распределения.

Максимизация правдоподобия (log-loss):

$$Q(w) = - \sum_{i=1}^{\ell} \log P(y_i|x_i, w) \rightarrow \min_w$$

Калибровка Платта (classifier with probabilistic output)


Пусть для простоты классов два, $Y = \{-1, +1\}$.

Задача. Для классификатора вида $a(x) = \text{sign}(x, w)$ построить функцию оценки условной вероятности $P(y|x)$.

Модель условной вероятности:

$$\pi(x; a, b) = P(y=1|x) = \sigma(ag(x, w) + b)$$

где $\sigma(z) = \frac{1}{1+e^{-z}}$ — сигмоидная функция



Калибровка коэффициентов a, b по контрольной выборке методом максимума правдоподобия (снова log-loss):

$$\sum_{y_i=-1} \log(1 - \pi(x_i; a, b)) + \sum_{y_i=+1} \log \pi(x_i; a, b) \rightarrow \max_{a, b}$$

Вероятностные дискриминативные модели классификации

Дано: простая (i.i.d.) выборка $(x_i, y_i)_{i=1}^{\ell} \sim p(x, y)$,
порожденная в.п. $X \times Y$ с неизвестной плотностью $p(x, y)$

Найти: модель плотности $p(x, y; w) = P(y|x, w)p(x)$, где
 $P(y|x, w)$ — модель условной вероятности класса с параметром w
 $p(x)$ — неизвестное и непараметризуемое распределение на X

Критерий: максимум правдоподобия, т.е. \max плотности совместного распределения всей выборки данных:

$$\prod_{i=1}^{\ell} p(x_i, y_i; w) = \prod_{i=1}^{\ell} P(y_i|x_i, w) p(x_i) \rightarrow \max_w$$

Логарифм правдоподобия (log-likelihood, log-loss):

$$\sum_{i=1}^{\ell} \ln P(y_i|x_i, w) \rightarrow \max_w$$

Связь правдоподобия и аппроксимации эмпирического риска

Максимизация логарифма правдоподобия,

$P(y|x, w)$ — модель условной вероятности класса:

$$-\sum_{i=1}^{\ell} \ln P(y_i|x_i, w) \rightarrow \min_w$$

Минимизация аппроксимированного эмпирического риска,
 $g(x, w)$ — модель разделяющей поверхности, $Y = \{\pm 1\}$:

$$\sum_{i=1}^{\ell} \mathcal{L}(y_i g(x_i, w)) \rightarrow \min_w;$$

Эти два принципа эквивалентны, если положить

$$-\ln P(y_i|x_i, w) = \mathcal{L}(y_i g(x_i, w)).$$

модель $P(y x, w)$	↔	модель $g(x, w)$ и $\mathcal{L}(M)$.
--------------------	---	---------------------------------------

Вероятностный смысл регуляризации

$P(y|x, w)$ — вероятностная модель данных;

$p(w; \gamma)$ — априорное распределение параметров модели;

γ — вектор гиперпараметров;

Теперь не только появление выборки X^ℓ ,

но и появление модели w также полагается стохастическим.

Совместное правдоподобие данных и модели:

$$p(X^\ell, w) = p(X^\ell|w) \color{red}{p(w; \gamma)}.$$

Принцип максимума апостериорной вероятности

(Maximum a Posteriori Probability, MAP):

$$Q_{\text{MAP}}(w) = \ln p(X^\ell, w) = \underbrace{\sum_{i=1}^{\ell} \ln P(y_i|x_i, w)}_{Q_{\text{MLE}}(w)} + \underbrace{\color{red}{\ln p(w; \gamma)}}_{\text{регуляризатор}} \rightarrow \max_w$$

Примеры: априорные распределения Гаусса и Лапласа

Пусть веса w_j независимы, $Ew_j = 0$, $Dw_j = C$.

Распределение Гаусса и квадратичный (L_2) регуляризатор:

$$p(w; C) = \frac{1}{(2\pi C)^{n/2}} \exp\left(-\frac{\|w\|^2}{2C}\right), \quad \|w\|^2 = \sum_{j=1}^n w_j^2,$$

$$-\ln p(w; C) = \frac{1}{2C} \|w\|^2 + \text{const}$$

Распределение Лапласа и абсолютный (L_1) регуляризатор:

$$p(w; C) = \frac{1}{(2C)^n} \exp\left(-\frac{\|w\|}{C}\right), \quad \|w\| = \sum_{j=1}^n |w_j|,$$

$$-\ln p(w; C) = \frac{1}{C} \|w\| + \text{const}$$

C — гиперпараметр, $\tau = \frac{1}{C}$ — коэффициент регуляризации.

Вероятностные генеративные модели классификации

X — объекты, Y — классы, $X \times Y$ — в.п. с плотностью $p(x, y)$

Дано: $X^\ell = (x_i, y_i)_{i=1}^\ell \sim p(x, y)$ — простая выборка (i.i.d.)

Найти: $a: X \rightarrow Y$ с минимальной вероятностью ошибки

Пусть известна совместная плотность

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

$P(y)$ — априорная вероятность класса y

$p(x|y)$ — функция правдоподобия класса y

$P(y|x)$ — апостериорная вероятность класса y


По формуле Байеса: $P(y|x) = \frac{P(y)p(x|y)}{p(x)}$

Байесовский классификатор:

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

Классификация по максимуму функции правдоподобия

Частный случай: $a(x) = \arg \max_{y \in Y} p(x|y)$ при равных $P(y)$



Два подхода к обучению классификации

1 Дискриминативный (discriminative):

x — неслучайные векторы

$P(y|x, w)$ — модель классификации

Примеры: LR, GLM, SVM, RBF



2 Генеративный (generative):

$x \sim p(x|y)$ — случайные векторы

$p(x|y, \theta)$ — модель генерации данных

Примеры: NB, PW, FLD, RBF



Байесовские модели классификации — генеративные:

- моделируют форму классов не только вдоль границы, но и на всём пространстве, что избыточно для классификации
- требуют больше данных для обучения
- более устойчивы к шумовым выбросам

Оптимальность байесовского классификатора

Теорема

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

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

достигается оптимальным байесовским классификатором

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

Замечание 1: после подстановки эмпирических оценок $\hat{P}(y)$ и $\hat{p}(x|y)$ байесовский классификатор уже не оптимален

Замечание 2: задача оценивания плотности распределения — более сложная, чем задача классификации

Наивный байесовский классификатор (Naïve Bayes)

Наивное предположение:

признаки $f_j: X \rightarrow D_j$ — независимые случайные величины с плотностями распределения, $p_j(\xi|y)$, $y \in Y$, $j = 1, \dots, n$

Тогда функции правдоподобия классов представимы в виде произведения одномерных плотностей по признакам, $x^j \equiv f_j(x)$:

$$p(x|y) = p_1(x^1|y) \cdots p_n(x^n|y), \quad x = (x^1, \dots, x^n), \quad y \in Y$$

Прологарифмировав под argmax , получим классификатор

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

Восстановление n одномерных плотностей

— намного более простая задача, чем одной n -мерной

Квадратичный дискриминант (Quadratic Discriminant Analysis)

Гипотеза: каждый класс $y \in Y$ имеет n -мерную гауссовскую плотность с центром μ_y и ковариационной матрицей Σ_y :

$$p(x|y) = \mathcal{N}(x; \mu_y, \Sigma_y) = \frac{\exp\left(-\frac{1}{2}(x - \mu_y)^\top \Sigma_y^{-1} (x - \mu_y)\right)}{\sqrt{(2\pi)^n \det \Sigma_y}}$$


Теорема

- Разделяющая поверхность, определяемая уравнением $\lambda_y P(y)p(x|y) = \lambda_s P(s)p(x|s)$, квадратична для всех $y, s \in Y$.
- Если $\Sigma_y = \Sigma_s$, то поверхность вырождается в линейную.

Квадратичный дискриминант — подстановочный алгоритм:

$$a(x) = \arg \max_{y \in Y} \left(\ln \lambda_y P(y) - \frac{1}{2}(x - \hat{\mu}_y)^\top \hat{\Sigma}_y^{-1} (x - \hat{\mu}_y) - \frac{1}{2} \ln \det \hat{\Sigma}_y \right)$$

Геометрический смысл квадратичного дискриминанта



Линейный дискриминант Фишера (Fisher Linear Discriminant)

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

Пусть ковариационные матрицы классов равны: $\Sigma_y = \Sigma$, $y \in Y$.

Оценка максимума правдоподобия для Σ :

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

Линейный дискриминант — подстановочный алгоритм:


$$\begin{aligned} a(x) &= \arg \max_{y \in Y} \lambda_y \hat{P}(y) \hat{p}(x|y) = \\ &= \arg \max_{y \in Y} \underbrace{\left(\ln(\lambda_y \hat{P}(y)) - \frac{1}{2} \hat{\mu}_y^T \hat{\Sigma}^{-1} \hat{\mu}_y \right)}_{\beta_y} + \underbrace{x^T \hat{\Sigma}^{-1} \hat{\mu}_y}_{w_y}; \end{aligned}$$

$$a(x) = \arg \max_{y \in Y} (x^T w_y + \beta_y).$$

В случае мультиколлинеарности — обращать матрицу $\hat{\Sigma} + \tau I_n$.

Геометрическая интерпретация линейного дискриминанта

В одномерной проекции на направляющий вектор разделяющей гиперплоскости классы разделяются наилучшим образом, то есть с минимальной вероятностью ошибки:



Ось проекции перпендикулярна общей касательной эллипсоидов рассеяния

Fisher R. A. The use of multiple measurements in taxonomic problems. 1936.

Гауссовская смесь с диагональными матрицами ковариации

Гауссовская смесь GMM — Gaussian Mixture Model

Допущения:

- ① Функции правдоподобия классов $p(x|y)$ представимы в виде смесей k_y компонент, **для каждого класса $y \in Y$**
- ② Компоненты $j = 1, \dots, k_y$ имеют n -мерные гауссовские плотности с некоррелированными признаками:
 $\mu_{yj} = (\mu_{yj1}, \dots, \mu_{yjn})$, $\Sigma_{yj} = \text{diag}(\sigma_{yj1}^2, \dots, \sigma_{yjn}^2)$:

$$p(x|y) = \sum_{j=1}^{k_y} w_{yj} p_{yj}(x), \quad p_{yj}(x) = \mathcal{N}(x; \mu_{yj}, \Sigma_{yj})$$

$$\sum_{j=1}^{k_y} w_{yj} = 1, \quad w_{yj} \geq 0$$

EM-алгоритм. Эмпирические оценки средних и дисперсий

Числовые признаки: $f_d: X \rightarrow \mathbb{R}$, $d = 1, \dots, n$.

E-шаг: для всех $y \in Y$, $j = 1, \dots, k_y$, $d = 1, \dots, n$:

$$g_{yij} = \frac{w_{yj} \mathcal{N}(x_i; \mu_{yj}, \Sigma_{yj})}{p(x_i|y)} \equiv P(j|x_i, y_i = y)$$

M-шаг: для всех $y \in Y$, $j = 1, \dots, k_y$, $d = 1, \dots, n$

$$w_{yj} = \frac{1}{\ell_y} \sum_{i: y_i = y} g_{yij}$$

$$\hat{\mu}_{yjd} = \frac{1}{\ell_y w_{yj}} \sum_{i: y_i = y} g_{yij} f_d(x_i)$$

$$\hat{\sigma}_{yjd}^2 = \frac{1}{\ell_y w_{yj}} \sum_{i: y_i = y} g_{yij} (f_d(x_i) - \hat{\mu}_{yjd})^2$$

Замечание: компоненты «наивны», но смесь не «наивна»

Байесовский классификатор

Подставим гауссовскую смесь в байесовский классификатор:

$$a(x) = \arg \max_{y \in Y} \lambda_y P_y \underbrace{\sum_{j=1}^{k_y} w_{yj} \mathcal{N}_{yj} \exp \left(-\frac{1}{2} \rho_{yj}^2(x, \mu_{yj}) \right)}_{p_{yj}(x)}$$
$$\Gamma_y(x)$$

$\mathcal{N}_{yj} = (2\pi)^{-\frac{n}{2}} (\sigma_{yj1} \cdots \sigma_{yjn})^{-1}$ — нормировочные множители;
 $\rho_{yj}(x, \mu_{yj})$ — взвешенная евклидова метрика в $X = \mathbb{R}^n$:


$$\rho_{yj}^2(x, \mu_{yj}) = \sum_{d=1}^n \frac{1}{\sigma_{yjd}^2} (f_d(x) - \mu_{yjd})^2.$$

Интерпретация: это метрический классификатор, в котором
 $p_{yj}(x)$ — близость объекта x к j -й компоненте класса y ;
 $\Gamma_y(x)$ — близость объекта x к классу y .

Сеть радиальных базисных функций (RBF)

Трёхслойная сеть RBF (Radial Basis Functions):

$$a(x) = \arg \max_{y \in Y} \lambda_y P_y \sum_{j=1}^{k_y} w_{yj} p_{yj}(x)$$



Резюме в конце лекции

- Обучение вероятностных порождающих (генеративных) моделей — методом максимума правдоподобия
 - восстановление плотности по данным (без учителя)
 - обучение регрессии (с учителем)
 - обучение классификации (с учителем)
- Вероятностный смысл регуляризации — априорное распределение в пространстве параметров модели
- Логистическая регрессия — метод классификации, оценивающий условные вероятности классов $P(y|x)$
- Два подхода к обучению классификации:
 - дискриминативный: модель вероятности классов $P(y|x, w)$
 - генеративный: модель плотности классов $p(x|y, w)$
- Байесовские методы классификации — генеративные, основаны на оценивании плотностей классов