

# Поиск оптимальной модели при решении задач нелинейной регрессии

Стрижов В.В.

Вычислительный центр им. А.А. Дородницына РАН

## Дано

Задана выборка  $D$ :

$\{\mathbf{x}_1, \dots, \mathbf{x}_N | \mathbf{x} \in \mathbb{R}^M\}$  — значения свободных переменных,  
 $\{y_1, \dots, y_N | y \in \mathbb{R}\}$  — значения зависимой переменной.

Задано множество параметрических гладких функций

$$G = \{g | g : \mathbb{R} \times \dots \times \mathbb{R} \longrightarrow \mathbb{R}\},$$
$$g = g(\mathbf{b}, \cdot, \cdot, \dots, \cdot).$$

$G$  задает множество суперпозиций  $\mathcal{F} = \{f(\mathbf{w}, \mathbf{x})\}$  путем обобщенного индуктивного определения. Вектор параметров  $\mathbf{w} = \mathbf{b}_1 : \mathbf{b}_2 : \dots : \mathbf{b}_r, \mathbf{w} \in \mathbb{R}^W$ .

## Найти

Регрессионную модель  $f_i \in \mathcal{F}$ , которая доставляет максимум

$$p(\mathbf{w}|D, \alpha, \beta, f_i).$$

$\alpha$  и  $\beta$  — дополнительные параметры.

## Модель порождения данных

$y = f_i(\mathbf{w}, \mathbf{x}) + \nu$  — модель с аддитивным Гауссовским шумом с дисперсией  $\sigma_\nu$ ,  $\beta = \frac{1}{\sigma_\nu^2}$ .

Плотность вероятности появления данных

$$p(D|\mathbf{w}, \beta, f_i) = \frac{\exp(-\beta E_D(D|\mathbf{w}, f_i))}{Z_D(\beta)},$$

где

$$E_D = \frac{\beta}{2} \sum_{n=1}^N (f_i(\mathbf{x}_n) - y_n)^2.$$

## Модель параметров

$\alpha$  — регуляризующий параметр,  $\alpha = \frac{1}{\sigma_{\mathbf{w}}^2}$ .

Плотность вероятности параметров

$$p(\mathbf{w}|\alpha, f_i) = \frac{\exp(-\alpha E_W(\mathbf{w}|f_i))}{Z_W(\alpha)},$$

где

$$E_W = \frac{\alpha}{2} \|\mathbf{w}\|^2.$$

## Критерий поиска

При заданных значениях гиперпараметров  $\alpha, \beta$  и фиксированной функции  $f_i$

$$\begin{aligned} p(\mathbf{w}|D, \alpha, \beta, f_i) &= \frac{p(D|\mathbf{w}, \beta, f_i)p(\mathbf{w}|\alpha, f_i)}{p(D|\alpha, \beta)} = \\ &= \frac{\exp(-S(\mathbf{w}|f_i))}{Z_S(\alpha, \beta)}. \end{aligned}$$

$S(\mathbf{w}|f_i) = \alpha E_W + \beta E_D$  — целевая функция.

## НВ: Связный Байесовский вывод

Первый уровень

$$p(\mathbf{w}|D, f_i) = \frac{p(D|\mathbf{w}, f_i)p(\mathbf{w}|f_i)}{\int p(D|\mathbf{w}', f_i)p(\mathbf{w}'|f_i)d\mathbf{w}'}$$

Второй уровень

$$P(f_i|D) = \frac{p(D|f_i)P(f_i)}{\sum_{i=1}^M p(D|f_i)P(f_i)}$$

## Аппроксимация ошибки

Приближим  $S(\mathbf{w})$  рядом Тейлора второго порядка

$$S(\mathbf{w}) \approx S(\mathbf{w}^{\text{MP}}) + \frac{1}{2}(\mathbf{w} - \mathbf{w}^{\text{MP}})^T A (\mathbf{w} - \mathbf{w}^{\text{MP}}),$$

матрица Гессе функции ошибок

$$A = \nabla^2 S(\mathbf{w}^{\text{MP}}) = \beta \nabla^2 E_D(\mathbf{w}^{\text{MP}}) + \alpha I.$$



## Настройка гиперпараметров

$$2\alpha E_W^{\text{MP}} = \gamma, \quad 2\beta E_D^{\text{MP}} = N - \gamma,$$

$$\gamma = W - \sum_{i=1}^W \frac{\lambda_i}{\lambda_i + \alpha},$$

$\lambda_1, \dots, \lambda_W$  — собственные значения  $\beta \nabla^2 E_D(\mathbf{w}^{\text{MP}})$ .

## Алгоритм поиска

Заданы  $D$ ,  $G$  и порожден набор  $F_0 = \{f_1, \dots, f_M\}$

*Начало итераций*

Для каждой  $f_i$  минимизируем функцию ошибок  $S_i(\mathbf{w})$ .

Определяем новые значения гиперпараметров  $\alpha'_{ij}$  и  $\beta'_i$

$$\beta'_i = \frac{N - \gamma}{E_D(f_i)}, \quad \alpha'_{ij} = \frac{\gamma}{E_W(\mathbf{b}_{ij})}.$$

Изменение гиперпараметров может быть повторено после нахождения нового локального минимума  $S_i(\mathbf{w})$ .

## Порождение моделей $f'_1, \dots, f'_M$

Для каждой модели  $f_i$  строится производная модель  $f'_i$ .

В  $f_i$  выбирается элемент  $g_{ij} : \min_j(\alpha_{ij})$ .

Выбирается модель  $f_\xi$  из  $F_0 \setminus \{f_i\}$  и ее элемент  $g_{\xi\zeta}$ . Законы распределения величин  $\xi, \zeta$  являются параметрами алгоритма оптимизации.

Модель  $f'_i$  порождается из модели  $f_i$  путем замещения элемента  $g_{ij}$  с его аргументами на элемент  $g_{\xi\zeta}$  с его аргументами.

## Мутация и селекция моделей


С заданной вероятностью  $f'_i$  подвергается мутации.

Из множества  $G$  выбирается элемент  $g_\chi$  и замещает элемент  $g'_{i\psi}$ . Законы распределения величин  $\chi, \psi$  — параметры алгоритма.


При селекции из объединенного множества родительских и порожденных функций в соответствии с критерием  $S$  выбираются  $M$  наилучших.

*Конец итераций*

# Пример



## Исходная и восстановленная выборка



## Порождающие функции

Функция	Описание	Параметры
$g(\mathbf{b}, x_1, x_2)$		
plus	$y = x_1 + x_2$	—
times	$y = x_1 x_2$	—
$g(\mathbf{b}, x_1)$		
divide	$y = 1/x$	—
multiply	$y = ax$	$a$
add	$y = x + a$	$a$
gaussian	$y = \frac{\lambda}{\sqrt{2\pi\sigma}} \exp\left(-\frac{(x-\xi)^2}{2\sigma^2}\right) + a$	$\lambda, \sigma, \xi, a$
linear	$y = ax + b$	$a, b$
parabolic	$y = ax^2 + bx + c$	$a, b, c$
cubic	$y = ax^3 + bx^2 + cx + d$	$a, b, c, d$
logsig	$y = \frac{\lambda}{1 + \exp(-\sigma(x-\xi))} + a$	$\lambda, \sigma, \xi, a$

# Модели

$f$

mse( $y - \hat{y}$ )  
 max( $y - \hat{y}$ )  
 #w

	$+(h, h, h, h)$	$\times(\div l, +(h, h, h, e))$	$+(\times(+(\times(h, \div h), h), e), h)$
mse( $y - \hat{y}$ )	0.0034	0.0037	0.0035
max( $y - \hat{y}$ )	0.0421	0.0325	0.00338
#w	16	16	16

Легенда: h — gaussian, c — cubic, l — logsig



**ОТВЕТ**

$$y = (ax + b)^{-1} \left( x + \sum_{i=1}^3 \frac{\lambda_i}{\sqrt{2\pi\sigma_i}} \exp\left(-\frac{(x - \xi_i)^2}{2\sigma_i^2}\right) + a_i \right),$$

$X \ni \mathbf{x}, W \ni \mathbf{w}.$

## Выводы

Предложен способ получать несложные адекватные модели, которые возможно интерпретировать.

Поиск моделей в неявно заданном множестве  $\mathcal{F}$  выполняется путем анализа гиперпараметров элементов моделей.