РЕГУЛЯРИЗАЦИЯ КАК АПРИОРНОЕ РАСПРЕДЕЛЕНИЕ

Сергей Николенко

НИУ ВШЭ — Санкт-Петербург
27 января 2017 г.

Random facts:

- 27 января в Исландии --- День солнечного кофе: во многих регионах страны впервые из-за гор появляются лучи солнца, что воспринимается как прелюдия весны; исландцы традиционно пекут блины и пьют с ними кофе.

В ПРЕДЫДУЩИХ СЕРИЯХ...

- Теорема Байеса:

$$p(\theta|D) = \frac{p(\theta)p(D|\theta)}{p(D)}.$$

- Две основные задачи байесовского вывода:
  - найти апостериорное распределение

$$p(\theta \mid D) \propto p(D|\theta)p(\theta)$$

    (и/или найти максимальную апостериорную гипотезу $\arg\max_\theta p(\theta \mid D)$);
  - найти апостериорное распределение исходов дальнейших экспериментов:

$$p(x \mid D) \propto \int_{\theta \in \Theta} p(x \mid \theta)p(D|\theta)p(\theta)\mathrm{d}\theta.$$

- Мы выяснили, что метод наименьших квадратов – это метод максимального правдоподобия для нормально распределённого шума.

ПОЛИНОМИАЛЬНАЯ АППРОКСИМАЦИЯ

- Мы говорили о регрессии с базисными функциями:

$$f(\mathbf{x}, \mathbf{w}) = w_0 + \sum_{j=1}^{M} w_j \phi_j(\mathbf{x}) = \mathbf{w}^\top \phi(\mathbf{x}).$$

- Давайте для примера рассмотрим такую регрессию для $\phi_j(x) = x^j$, т.е.

$$f(x, \mathbf{w}) = w_0 + w_1 x + w_2 x^2 + \ldots + w_M x^M.$$

- И будем, как раньше, минимизировать квадратичную ошибку.
- Пример с кодом.

ПОЛИНОМИАЛЬНАЯ АППРОКСИМАЦИЯ

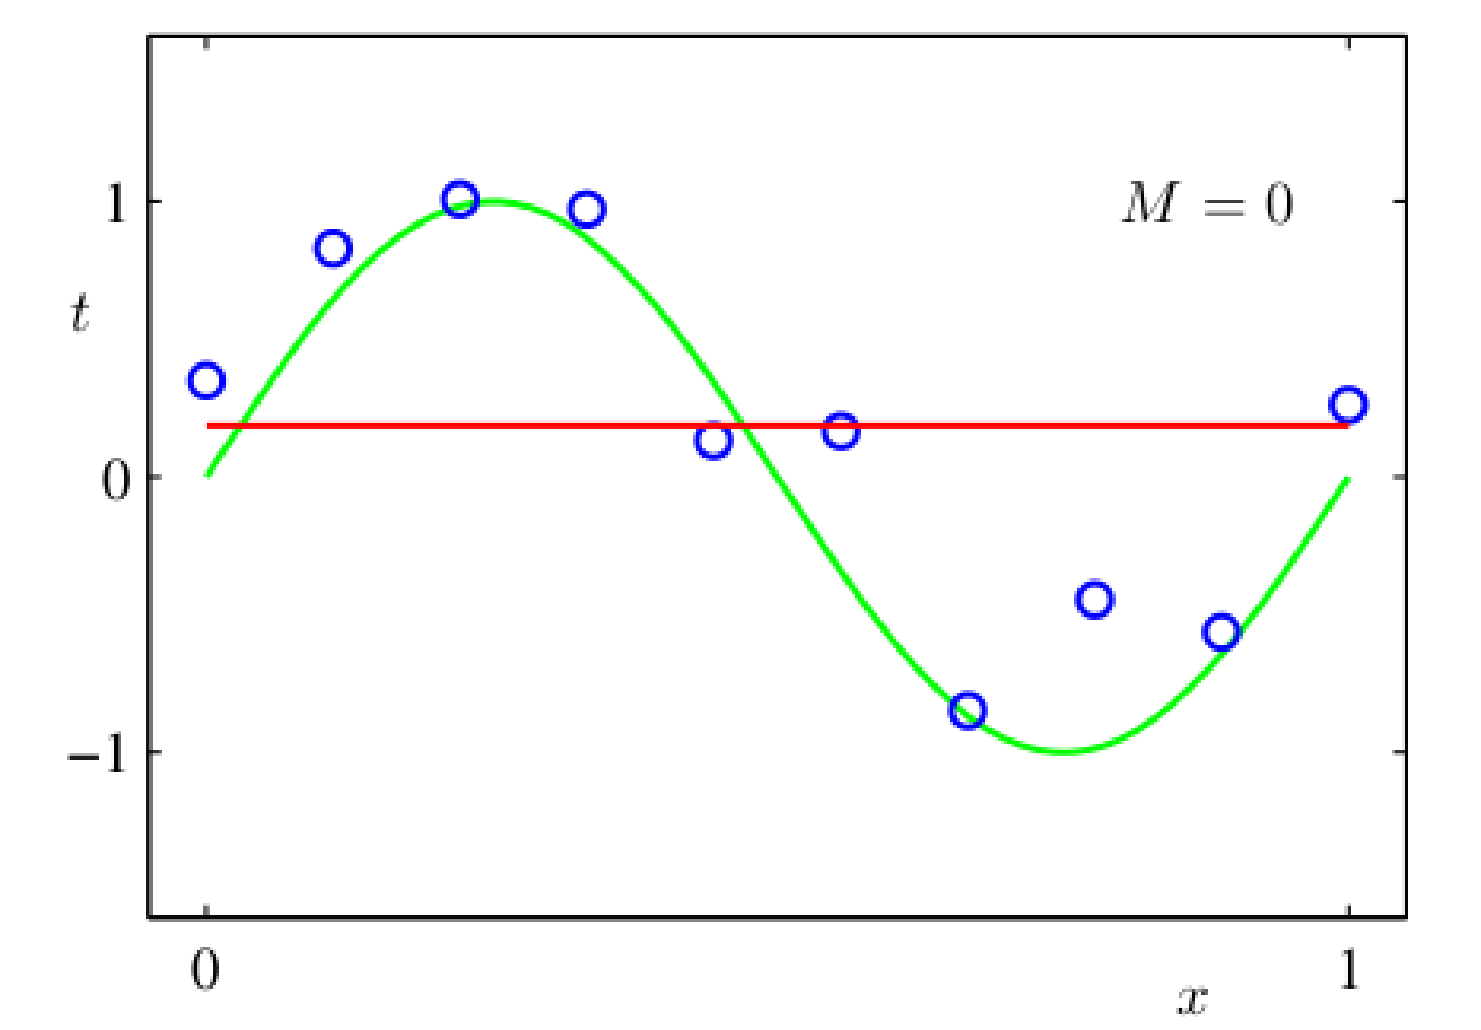

ПОЛИНОМИАЛЬНАЯ АППРОКСИМАЦИЯ

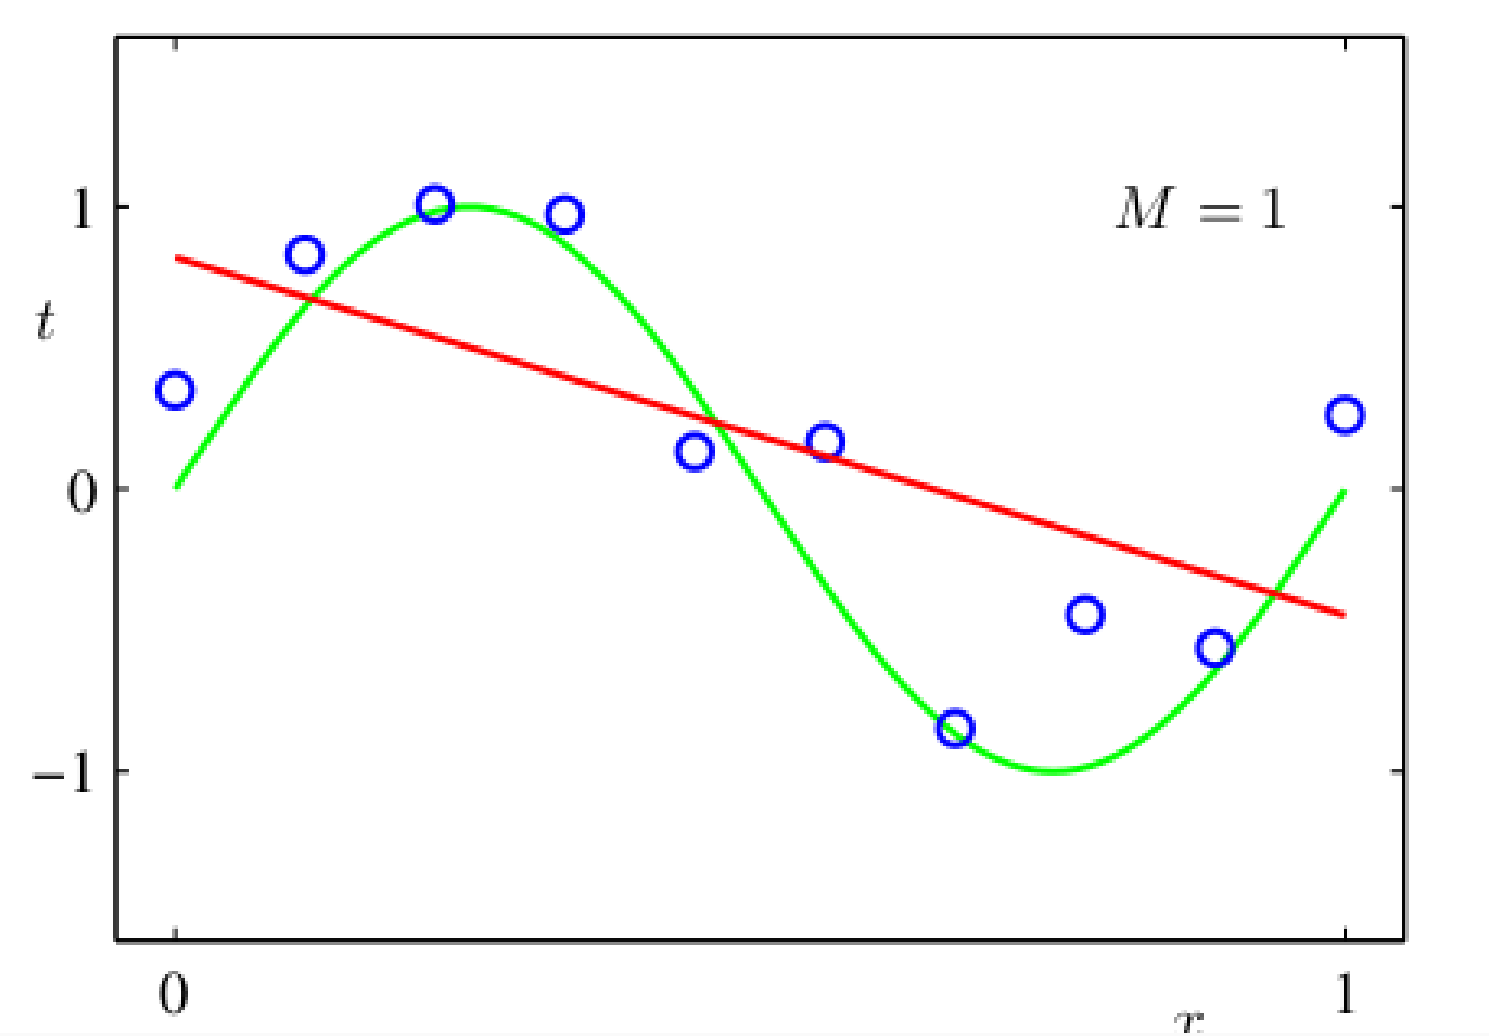

ПОЛИНОМИАЛЬНАЯ АППРОКСИМАЦИЯ

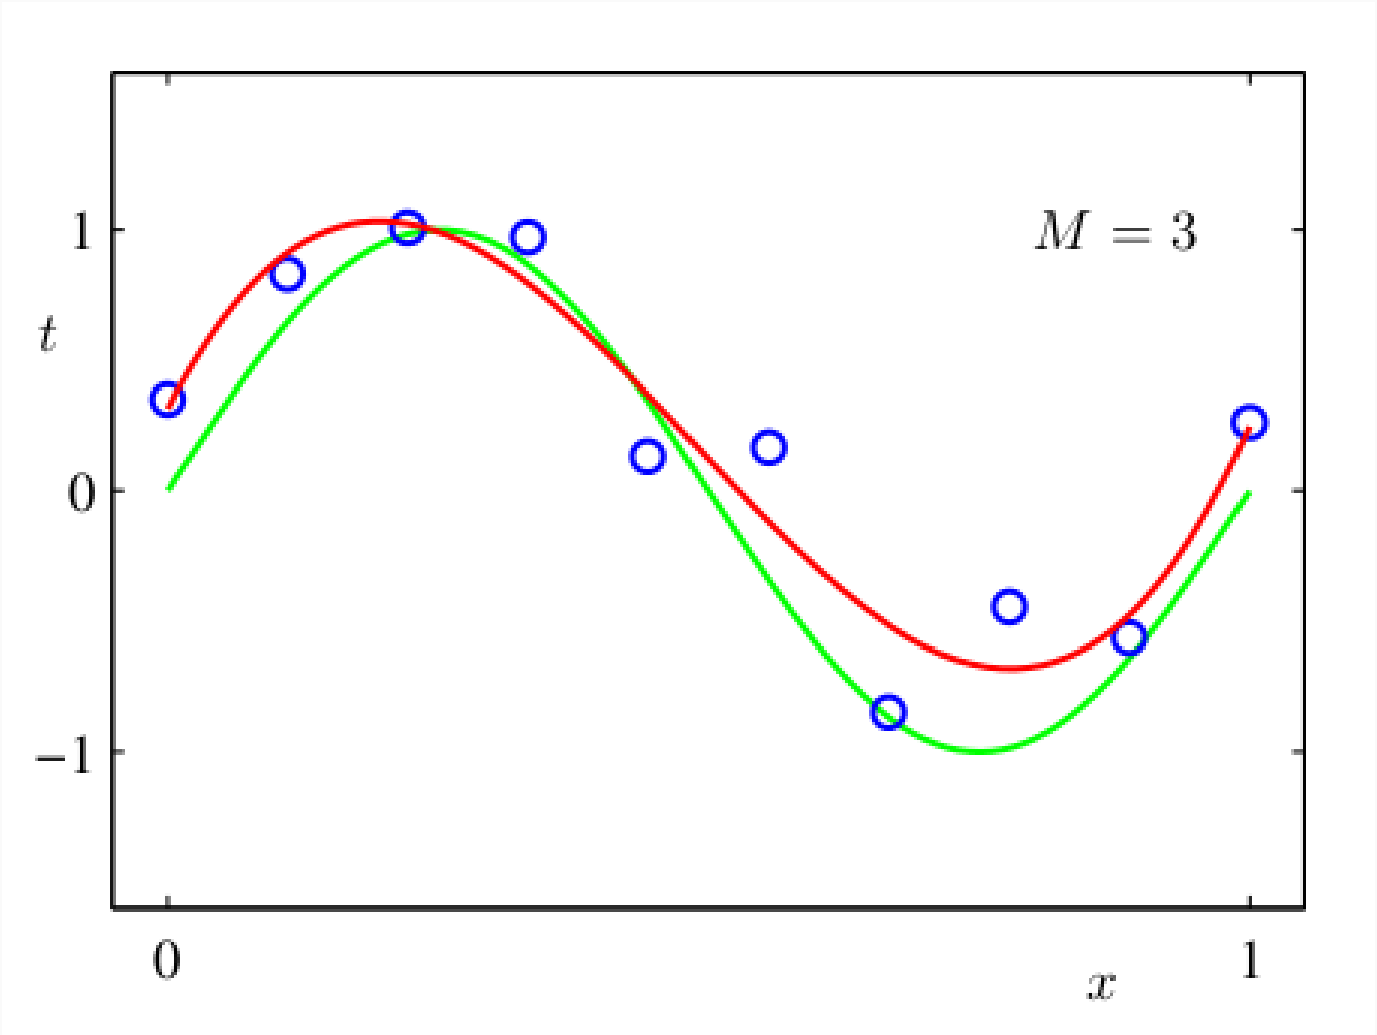

ПОЛИНОМИАЛЬНАЯ АППРОКСИМАЦИЯ

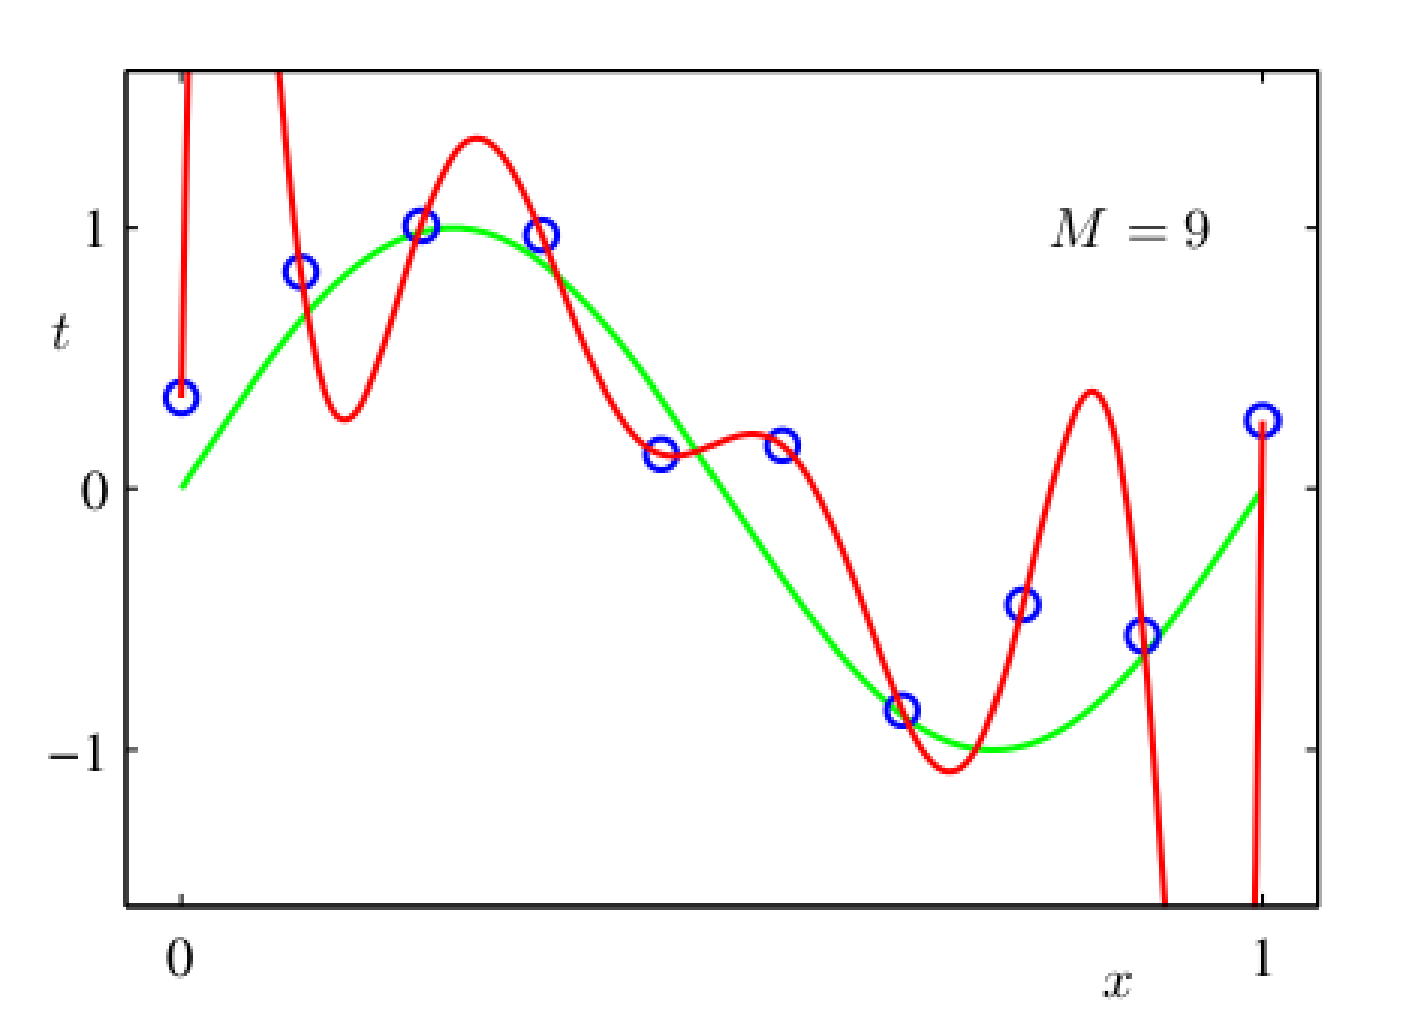

Значения RMS

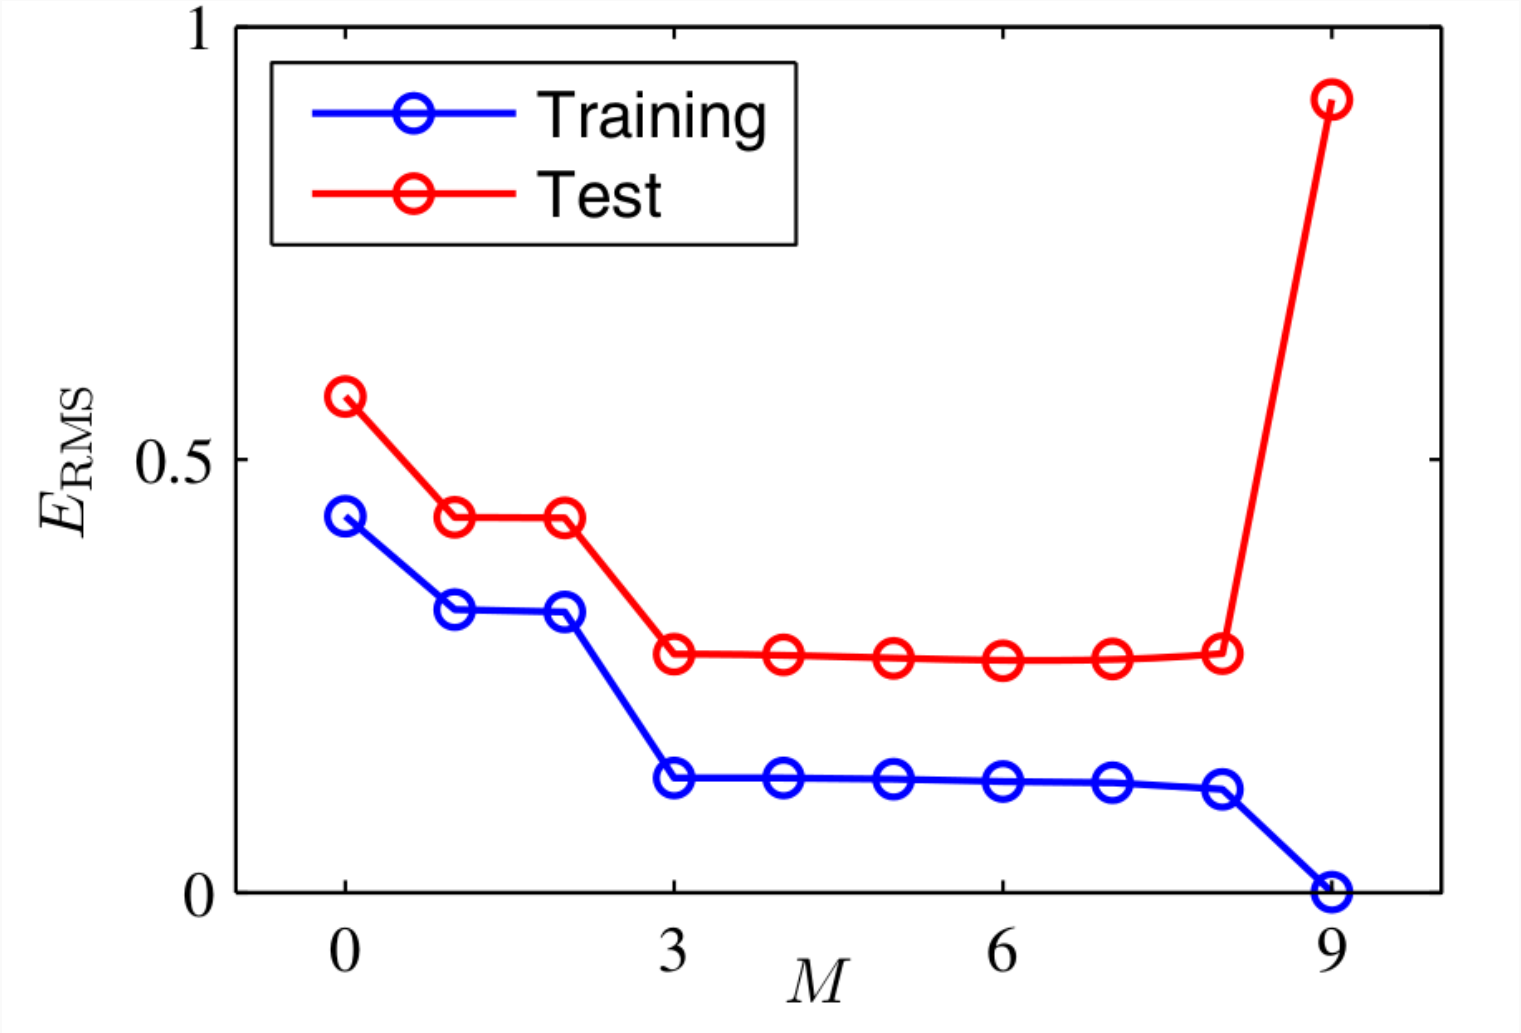

МОЖНО СОБРАТЬ БОЛЬШЕ ДАННЫХ...

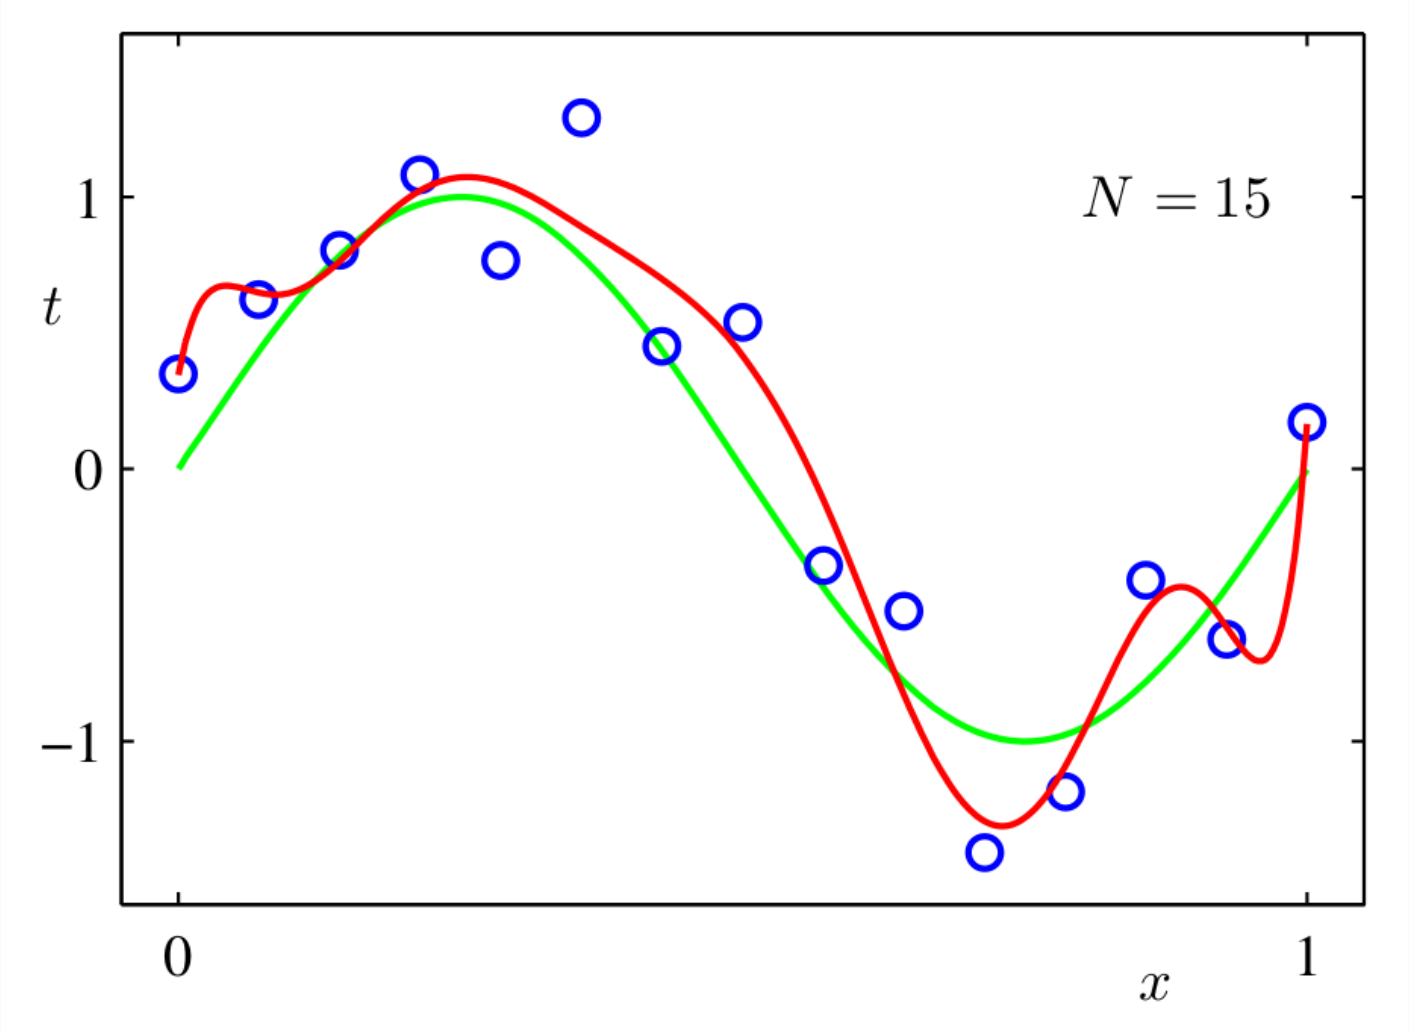

МОЖНО СОБРАТЬ БОЛЬШЕ ДАННЫХ...

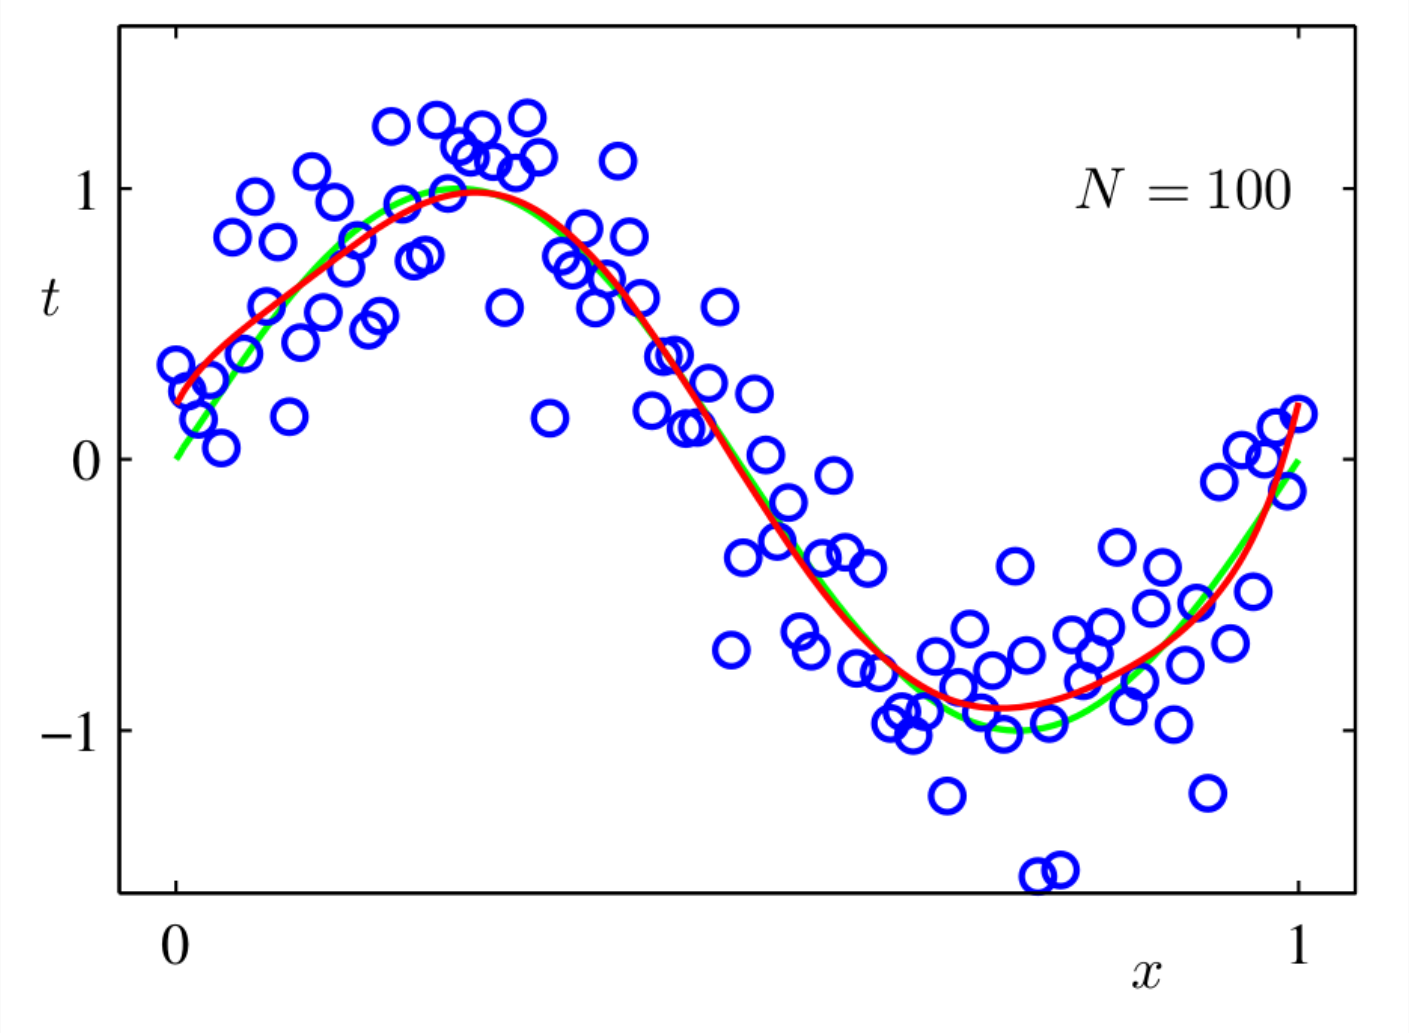

Значения коэффициентов

	$M=0$	$M=1$	$M=6$	$M=9$
$w_0^\star$	0.19	0.82	0.31	0.35
$w_1^\star$		-1.27	7.99	232.37
$w_2^\star$			-25.43	-5321.83
$w_3^\star$			17.37	48568.31
$w_4^\star$				-231639.30
$w_5^\star$				640042.26
$w_6^\star$				-1061800.52
$w_7^\star$				1042400.18
$w_8^\star$				-557682.99
$w_9^\star$				125201.43

РЕГУЛЯРИЗАЦИЯ

- Итак, получается, что у нас сильно растут коэффициенты.
- Давайте попробуем с этим бороться. Бороться будем прямолинейно и простодушно: возьмём и добавим размер коэффициентов в функцию ошибки.

РЕГУЛЯРИЗАЦИЯ

- Было (для тестовых примеров $\{(x_i, y_i)\}_{i=1}^N$):

$$\mathrm{RSS}(\mathbf{w}) = \frac{1}{2}\sum_{i=1}^{N}(f(x_i, \mathbf{w}) - y_i)^2.$$

- Стало:

$$\mathrm{RSS}(\mathbf{w}) = \frac{1}{2}\sum_{i=1}^{N}(f(x_i, \mathbf{w}) - y_i)^2 + \frac{\alpha}{2}\left\|\mathbf{w}\right\|^2,$$

  где α – коэффициент регуляризации (его надо будет как-нибудь выбрать).

- Как оптимизировать эту функцию ошибки?

РЕГУЛЯРИЗАЦИЯ

- Да точно так же – запишем как

$$\mathrm{RSS}(\mathbf{w}) = \frac{1}{2}(\mathbf{y} - \mathbf{X}\mathbf{w})^\top (\mathbf{y} - \mathbf{X}\mathbf{w}) + \frac{\alpha}{2}\mathbf{w}^\top \mathbf{w}$$

  и возьмём производную; получится

$$\mathbf{w}^* = (\mathbf{X}^\top \mathbf{X} + \alpha \mathbf{I})^{-1} \mathbf{X}^\top \mathbf{y}.$$

- Это *гребневая регрессия* (ridge regression); кстати, добавление $\alpha\mathbf{I}$ к матрице неполного ранга делает её обратимой; это и есть *регуляризация*, и это и было исходной мотивацией для гребневой регрессии.

ГРЕБНЕВАЯ РЕГРЕССИЯ: $\ln \alpha = -\infty$

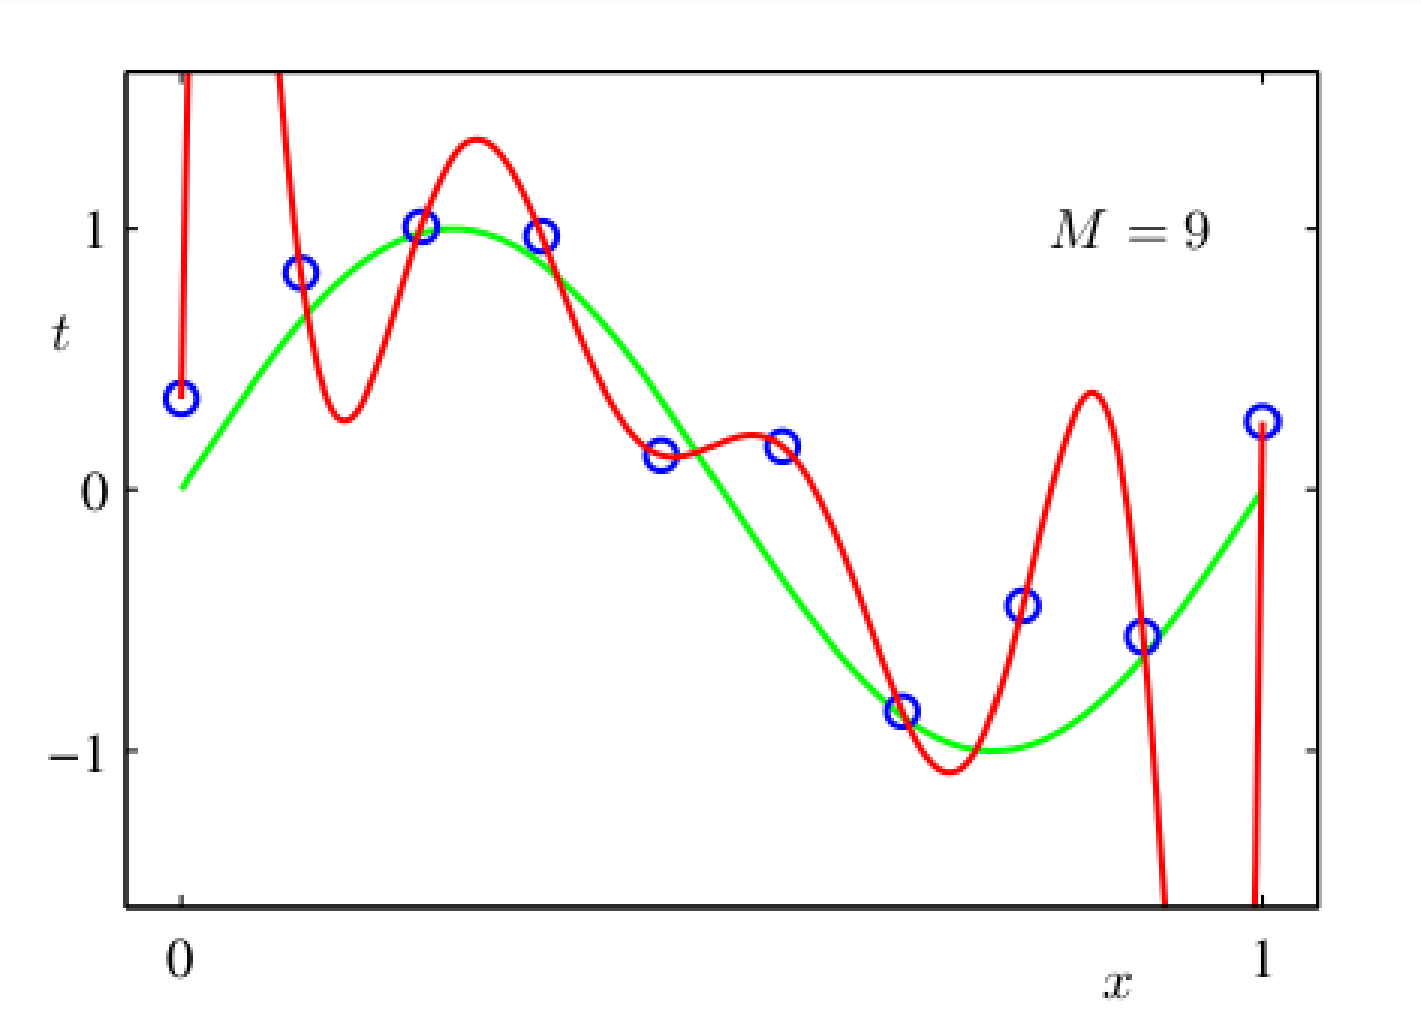

ГРЕБНЕВАЯ РЕГРЕССИЯ: $\ln \alpha = -18$

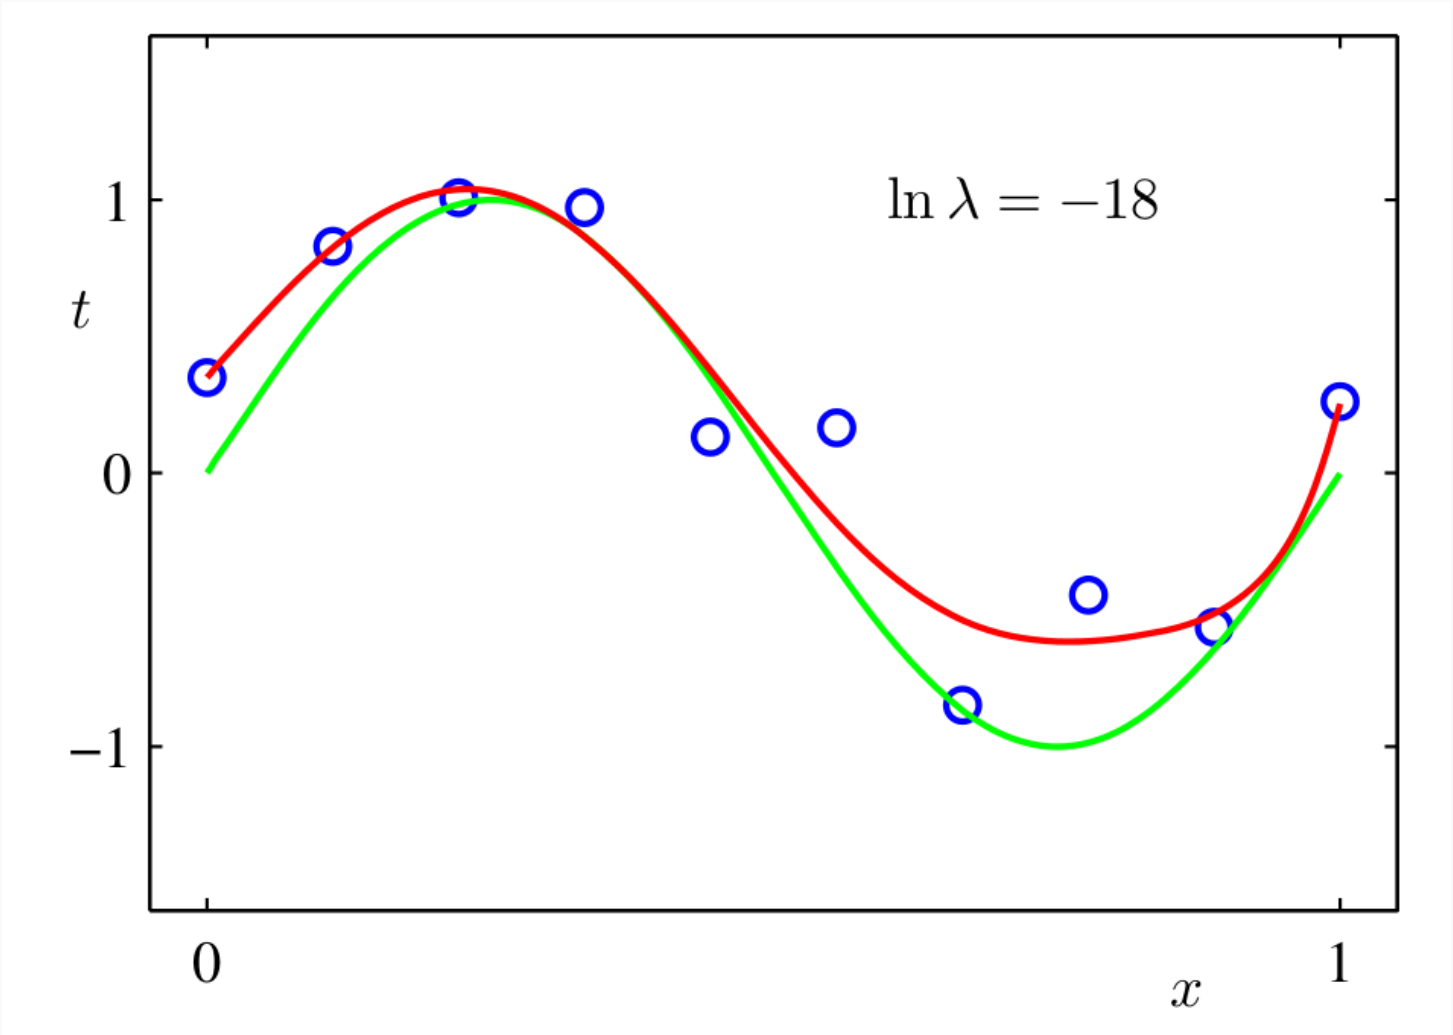

ГРЕБНЕВАЯ РЕГРЕССИЯ: $\ln \alpha = 0$

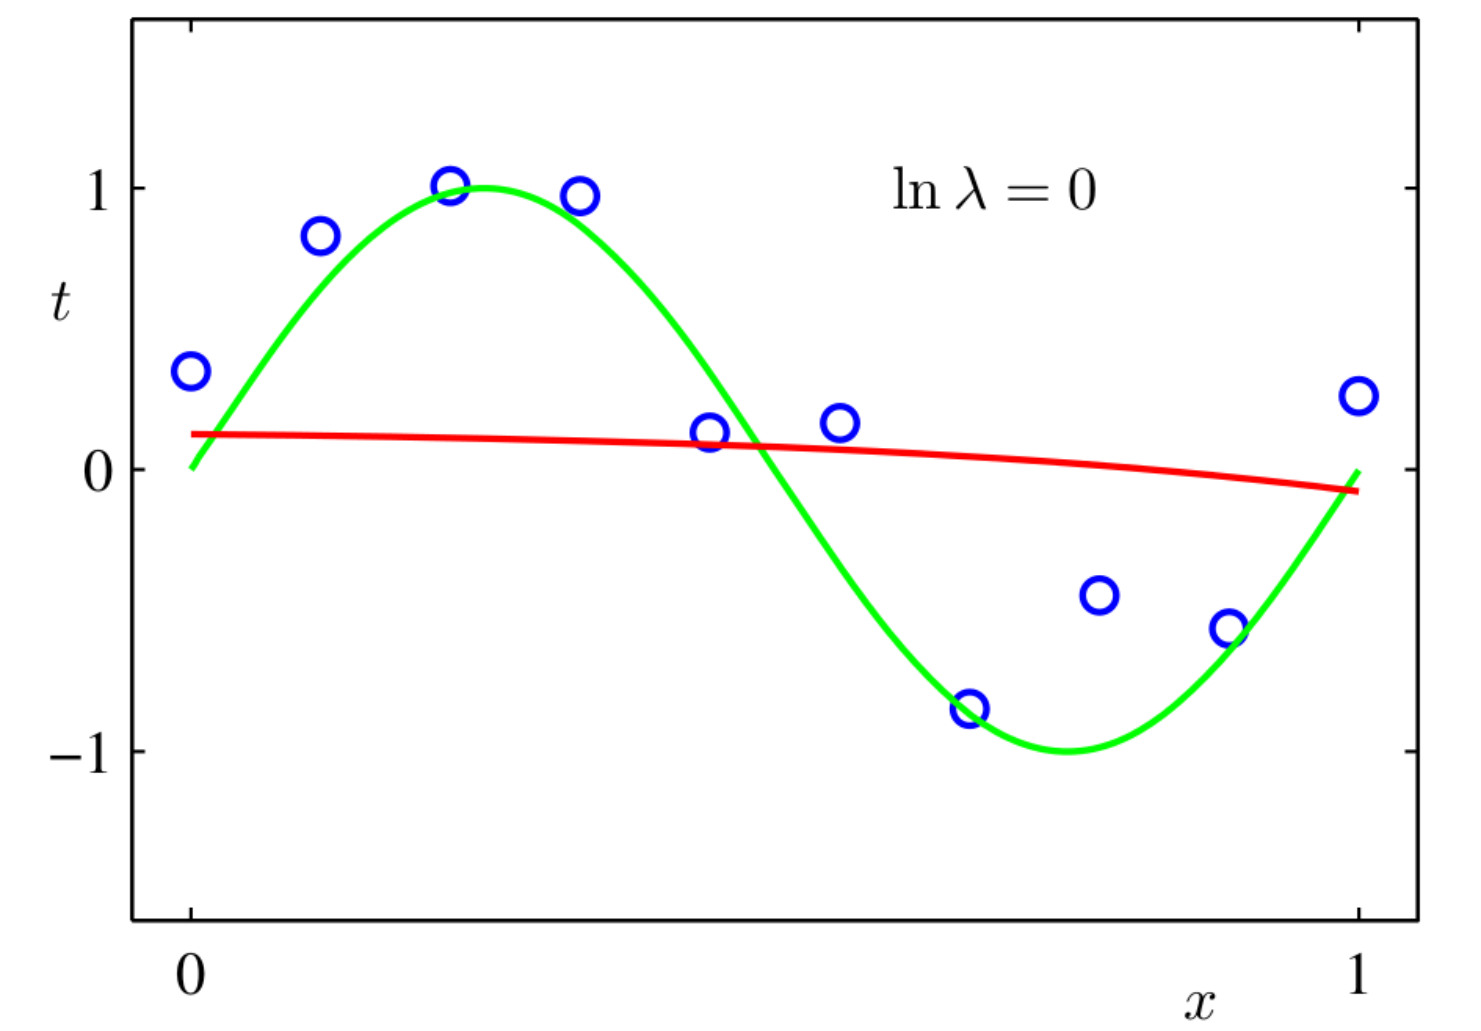

ГРЕБНЕВАЯ РЕГРЕССИЯ: КОЭФФИЦИЕНТЫ

	$\ln \lambda = -\infty$	$\ln \lambda = -18$	$\ln \lambda = 0$
$w_0^\star$	0.35	0.35	0.13
$w_1^\star$	232.37	4.74	-0.05
$w_2^\star$	-5321.83	-0.77	-0.06
$w_3^\star$	48568.31	-31.97	-0.05
$w_4^\star$	-231639.30	-3.89	-0.03
$w_5^\star$	640042.26	55.28	-0.02
$w_6^\star$	-1061800.52	41.32	-0.01
$w_7^\star$	1042400.18	-45.95	-0.00
$w_8^\star$	-557682.99	-91.53	0.00
$w_9^\star$	125201.43	72.68	0.01

ГРЕБНЕВАЯ РЕГРЕССИЯ: RMS

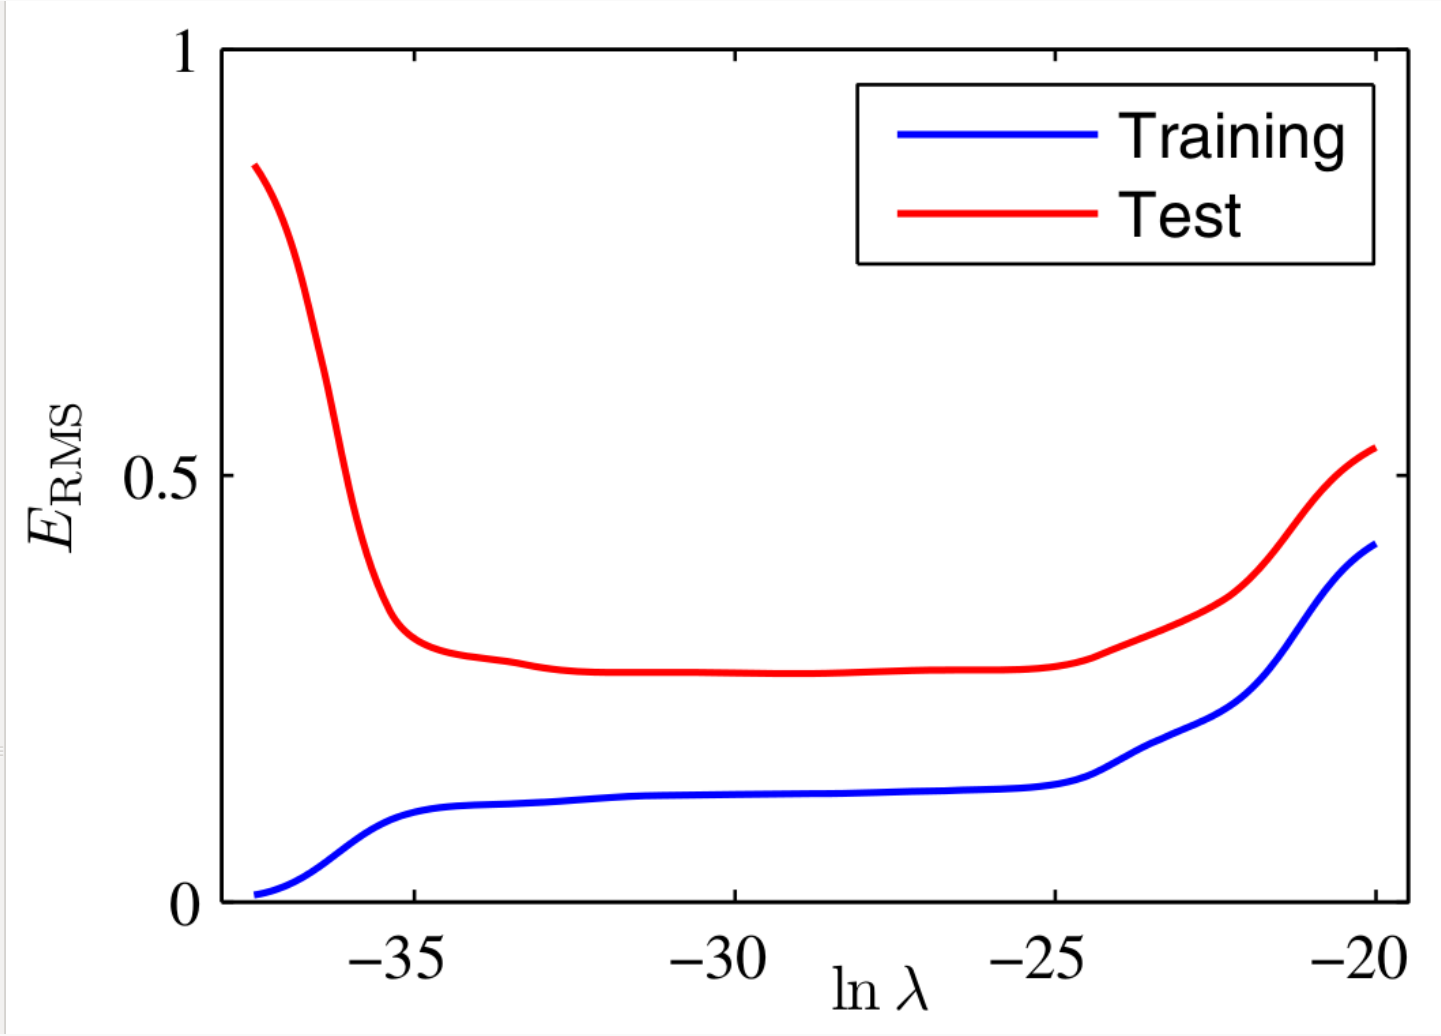

ДРУГАЯ РЕГУЛЯРИЗАЦИЯ

- Почему именно так? Почему именно $\frac{\alpha}{2}\|\mathbf{w}\|^2$?
- Мы сейчас ответим на этот вопрос, но, вообще говоря, это не обязательно.
- Лассо-регрессия (lasso regression) регуляризует L_1-нормой, а не L_2:

$$\text{RSS}(\mathbf{w}) = \frac{1}{2}\sum_{i=1}^{N}(f(x_i, \mathbf{w}) - y_i)^2 + \alpha\sum_{j=0}^{M}|w_j|.$$

- Есть и другие типы; об этом будем говорить позже.

Байесовская регуляризация

- А теперь давайте посмотрим на регрессию с совсем байесовской стороны.
- Напомним основу байесовского подхода:
  1. найти апостериорное распределение на гипотезах/параметрах:

$$p(\theta \mid D) \propto p(D|\theta)p(\theta)$$

     (и/или найти максимальную апостериорную гипотезу $\arg\max_\theta p(\theta \mid D)$);
  2. найти апостериорное распределение исходов дальнейших экспериментов:

$$p(x \mid D) \propto \int_{\theta \in \Theta} p(x \mid \theta)p(D|\theta)p(\theta)\mathrm{d}\theta.$$

Байесовская регуляризация

- В нашем рассмотрении пока не было никаких априорных распределений.
- Давайте какое-нибудь введём; например, нормальное (почему так – позже):

$$p(\mathbf{w}) = \mathcal{N}(\mathbf{w} \mid \mu_0, \Sigma_0).$$

- Рассмотрим набор данных $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ со значениями $\mathbf{t} = \{t_1, \dots, t_N\}$. В этой модели мы предполагаем, что данные независимы и одинаково распределены:

$$p(\mathbf{t} \mid \mathbf{X}, \mathbf{w}, \sigma^2) = \prod_{n=1}^{N} \mathcal{N}\left(t_n \mid \mathbf{w}^\top \phi(\mathbf{x}_n), \sigma^2\right).$$

Байесовская регуляризация

- Тогда наша задача – посчитать

$$p(\mathbf{w} \mid \mathbf{t}) \propto p(\mathbf{t} \mid \mathbf{X}, \mathbf{w}, \sigma^2) p(\mathbf{w})$$
$$= \mathcal{N}(\mathbf{w} \mid \mu_0, \Sigma_0) \prod_{n=1}^{N} \mathcal{N}\left(t_n \mid \mathbf{w}^\top \phi(\mathbf{x}_n), \sigma^2\right).$$

- Давайте подсчитаем.

Байесовская регуляризация

- Получится

$$p(\mathbf{w} \mid \mathbf{t}) = \mathcal{N}(\mathbf{w} \mid \mu_N, \Sigma_N),$$
$$\mu_N = \Sigma_N \left(\Sigma_0^{-1} \mu_0 + \frac{1}{\sigma^2} \Phi^\top \mathbf{t} \right),$$
$$\Sigma_N = \left(\Sigma_0^{-1} + \frac{1}{\sigma^2} \Phi^\top \Phi \right)^{-1}.$$

- Теперь давайте подсчитаем логарифм правдоподобия.

Байесовская регуляризация

- Если мы возьмём априорное распределение около нуля:

$$p(\mathbf{w}) = \mathcal{N}(\mathbf{w} \mid 0, \frac{1}{\alpha}\mathbf{I}),$$

то логарифм правдоподобия получится

$$\ln p(\mathbf{w} \mid \mathbf{t}) = -\frac{1}{2\sigma^2}\sum_{n=1}^{N}\left(t_n - \mathbf{w}^\top \phi(\mathbf{x}_n)\right)^2 - \frac{\alpha}{2}\mathbf{w}^\top\mathbf{w} + \text{const},$$

то есть в точности гребневая регрессия.

ПРИМЕР

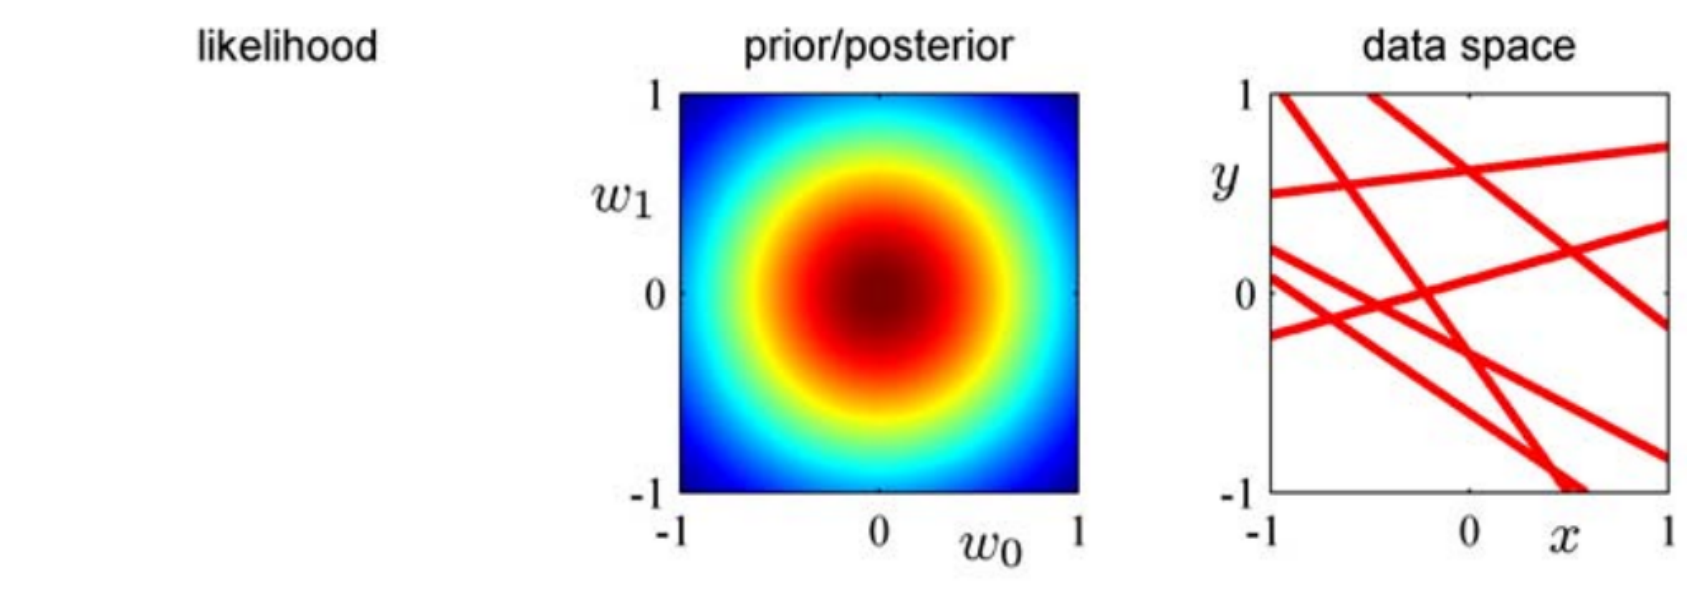
likelihood
prior/posterior
data space
1
w_1
0
-1
-1
0
w_0
1
1
y
0
-1
-1
0
x
1

ПРИМЕР

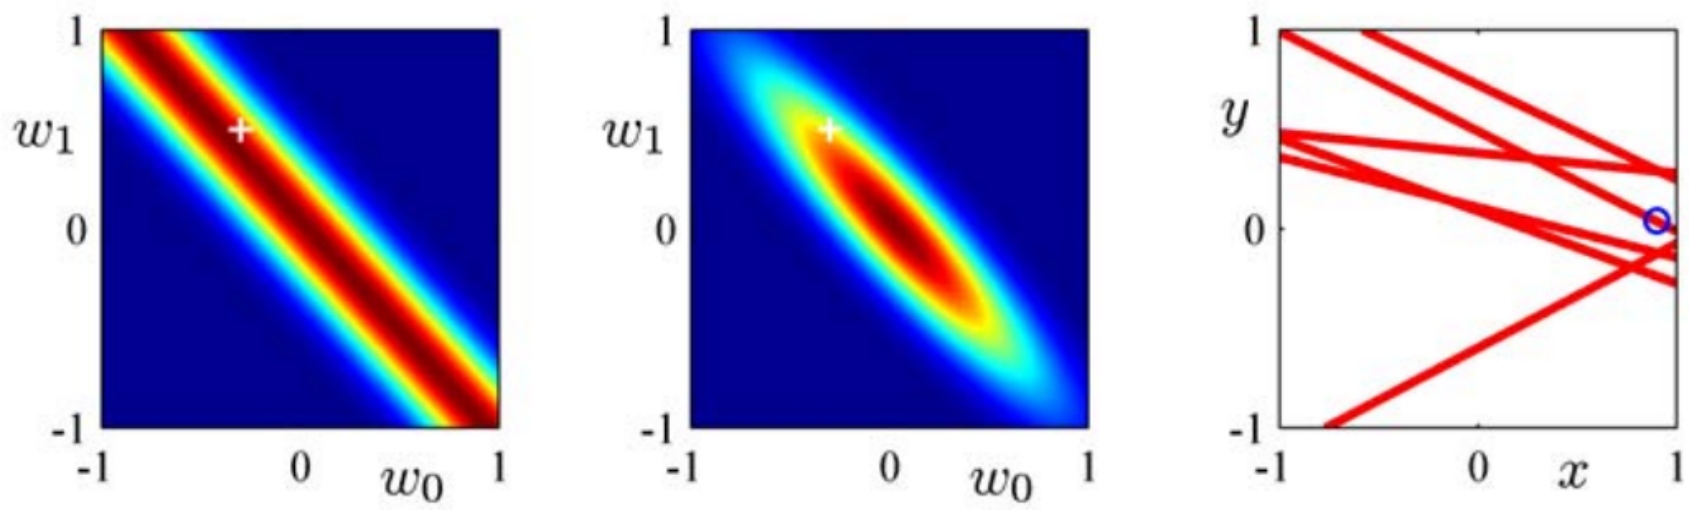

ПРИМЕР

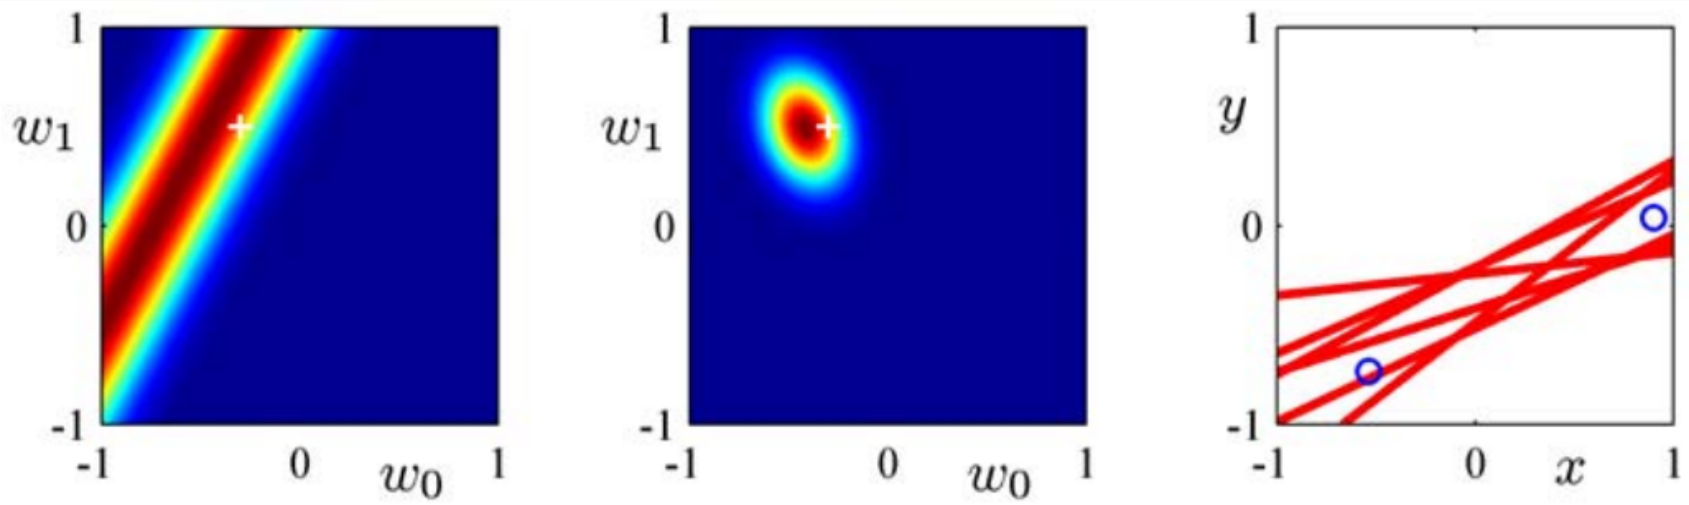

ПРИМЕР

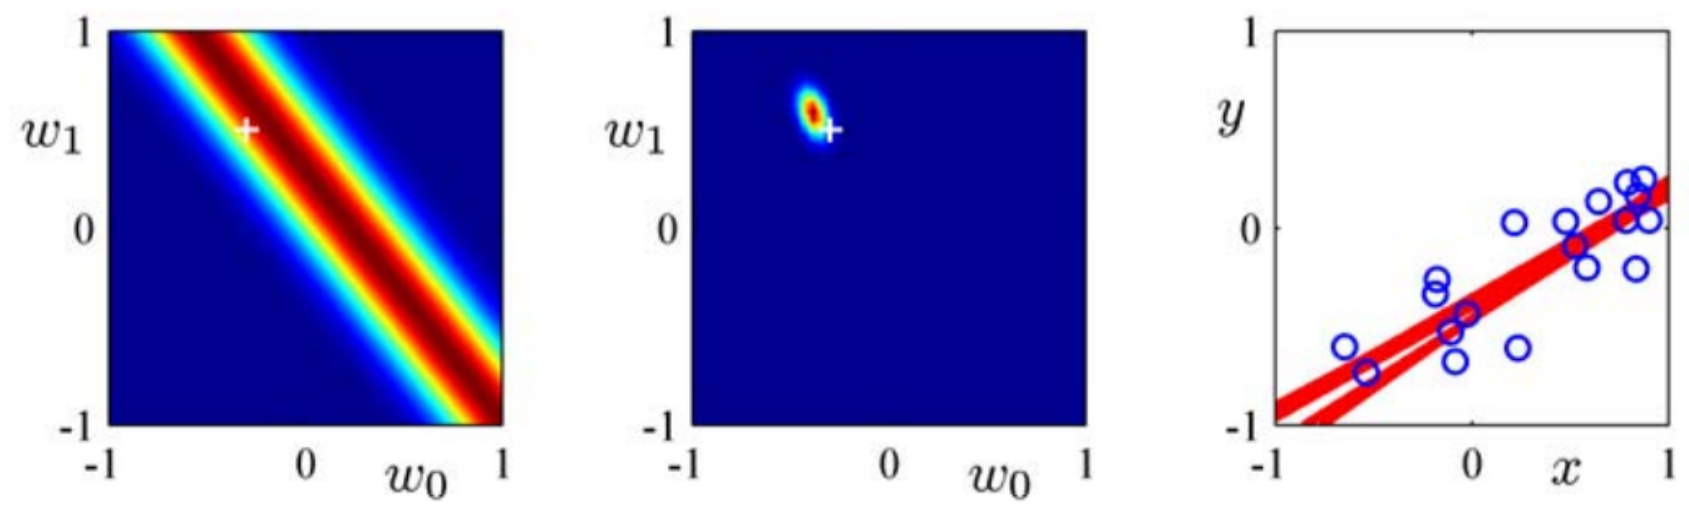

ОБОБЩЕНИЕ

- Можно слегка обобщить – рассмотреть априорное распределение более общего вида

$$p(\mathbf{w} \mid \alpha) = \left[\frac{q}{2}\left(\frac{\alpha}{2}\right)^{1/q}\frac{1}{\Gamma(1/q)}\right]^M e^{-\frac{\alpha}{2}\sum_{j=1}^{M}|w_j|^q}.$$

Упражнение. Подсчитайте логарифм правдоподобия.

СПАСИБО!

Спасибо за внимание!