

# МАТЕМАТИЧЕСКИЕ ОСНОВЫ ТЕОРИИ ПРОГНОЗИРОВАНИЯ

Лектор

Сенько Олег Валентинович

Лекция 3

# Линейная регрессия

Распространённым средством решения задач

прогнозирования величины  $Y$  по переменным  $X_1, \dots, X_n$

является использование метода линейной регрессии

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_n X_n + \varepsilon$$

Где  $\beta_0, \beta_1, \dots, \beta_n$  регрессионные коэффициенты,

$\varepsilon$  - ошибка прогнозирования.

Регрессионные коэффициенты ищутся по обучающей

выборке  $\tilde{S}_t = \{(y_1, \mathbf{x}_1), \dots, (y_m, \mathbf{x}_m)\}$ , где  $\mathbf{x}_j = (x_{j1}, \dots, x_{jn})$

- вектор значений переменных  $X_1, \dots, X_n$  для  $j$ -го объекта.

# Линейная регрессия

Традиционным способом поиска регрессионных коэффициентов является метод наименьших квадратов (МНК).

МНК заключается в минимизации функционала

$$Q(\tilde{S}_t, \beta_0, \dots, \beta_n) = \frac{1}{m} \sum_{j=1}^m [y_j - \beta_0 - \sum_{i=1}^n x_{ji} \beta_i]^2$$
 То есть в качестве

оценок истинных значений регрессионных коэффициентов

берутся значения  $\beta_0, \beta_1, \dots, \beta_n$ , для которых  $Q(\tilde{S}_t, \beta_0, \dots, \beta_n)$

Принимает минимальное значение.

# Линейная регрессия

Предположим взаимосвязь между величиной  $Y$  и переменными  $X_1, \dots, X_n$

описывается выражением ,

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_n X_n + \varepsilon_N(0, \sigma) \quad (1)$$

Где ошибка  $\varepsilon_N$  распределена нормально, При 'этом дисперсия ошибки  $\sigma^2$  не зависит от  $X_1, \dots, X_n$ , а математическое ожидание ошибки равно  $0$  при произвольных значениях прогностических переменных:

$$E_{\Omega}(\varepsilon_N | \mathbf{x}) = 0, E_{\Omega}(\varepsilon_N^2 | \mathbf{x}) = \sigma^2 \quad \forall \mathbf{x} \in \tilde{X}$$

# Линейная регрессия

- В этом случае метод МНК тождественен более общему статистическому методу оценивания параметров статистических распределений – Методу максимального правдоподобия (ММП).
- **Метод максимального правдоподобия**

Предположим, что некоторое пространство событий, с заданным на нём вероятностной мерой  $\mathbf{P}$  характеризуется переменными  $Z_1, \dots, Z_d$

# Метод максимального правдоподобия

- Метод ММП позволяет восстанавливать плотность распределения вероятностей по случайным выборкам, если общий вид. плотности вероятностного распределения известен

Пусть плотность распределения  $\mathbf{P}$  принадлежит семейству функций, задаваемому вектором параметров  $(\theta_1, \dots, \theta_r)$ , принимающем значения из множества  $\tilde{\Theta}$

$$\{p(Z_1, \dots, Z_d, \theta_1, \dots, \theta_r) \mid \boldsymbol{\theta} \in \tilde{\Theta}\}$$

# Метод максимального правдоподобия

Предположим, что у нас имеется случайная выборка

объектов, описываемых векторами  $\{\mathbf{z}_1, \dots, \mathbf{z}_m\}$

переменных  $Z_1, \dots, Z_d$

Напомним, что метод МП заключается в выборе в

семействе

$\{p(Z_1, \dots, Z_d, \theta_1, \dots, \theta_r) \mid \boldsymbol{\theta} \in \tilde{\Theta}\}$  плотности, для которой

достигает максимума функция правдоподобия

$$L(\theta_1, \dots, \theta_r) = \prod_{j=1}^m p(\mathbf{z}_j, \boldsymbol{\theta})$$

# Метод максимального правдоподобия

Иными словами оценка  $\hat{\theta}$  вектора параметров

$\theta = (\theta_1, \dots, \theta_r)$  вычисляется как

$$\hat{\theta} = \arg \max_{\theta \in \tilde{\Theta}} \{L(\mathbf{z}_1, \dots, \mathbf{z}_m, \theta_1, \dots, \theta_r)\}$$

- Согласно модели (1) разность  $Y - \beta_0 - \beta_1 X_1 - \dots - \beta_n X_n$

Подчиняется нормальному распределению с нулевым

математическим ожиданием и дисперсией  $\sigma^2$



# Соответствие ММП и МНК

Плотность распределения в пространстве переменных  $(Y, X_1, \dots, X_n)$  может быть восстановлена по обучающей выборке  $\tilde{S}_t = \{(y_1, \mathbf{x}_1), \dots, (y_m, \mathbf{x}_m)\}$  путём максимизации функции правдоподобия

$$L(\tilde{S}_t, \beta_0, \dots, \beta_n) = \prod_{j=1}^m \frac{1}{(\sqrt{2\pi}\sigma)^m} \exp\left[-\frac{(y_j - \beta_0 - \sum_{i=1}^n x_{ji}\beta_i)^2}{2\sigma^2}\right]$$

# Соответствие ММП и МНК

Очевидно, точка экстремума функции правдоподобия

$L(\tilde{S}_t, \beta_0, \dots, \beta_n)$  совпадает с точкой экстремума функции

$$\ln[L(\tilde{S}_t, \beta_0, \dots, \beta_n)] = \sum_{j=1}^m \left[ -\frac{1}{2} \ln(2\pi) - \ln(\sigma) \right] +$$
$$-\frac{1}{2\sigma^2} \sum_{j=1}^m \left( y_j - \beta_0 - \sum_{i=1}^n x_{ji} \beta_i \right)^2$$

Очевидно, что точка максимума  $\ln[L(\tilde{S}_t, \beta_0, \dots, \beta_n)]$  совпадает с точкой минимума функции  $Q(\tilde{S}_t, \beta_0, \dots, \beta_n)$ , оптимизируемой в методе МНК, , что позволяет сделать вывод о эквивалентности ММП и МНК

# Одномерная линейная регрессия

Метод одномерной регрессии позволяет восстановить линейную зависимость переменной  $Y$  от единственной переменной  $X$  по обучающей выборке  $\tilde{S}_t = \{(y_1, x_1), \dots, (y_m, x_m)\}$

МНК заключается в минимизации функционала

$$Q(\tilde{S}_t, \beta_0, \beta_1) = \frac{1}{m} \sum_{j=1}^m [y_j - \beta_0 - \beta_1 x_j]^2$$

Иными словами оценки значений  $\beta$  - параметров

$(\hat{\beta}_0, \hat{\beta}_1)$  вычисляются как

$$(\hat{\beta}_0, \hat{\beta}_1) = \arg \min_{(\beta_0, \beta_1) \in \tilde{B}} \frac{1}{m} \sum_{j=1}^m [y_j - \beta_0 - \beta_1 x_j]^2$$

# Одномерная линейная регрессия

Необходимым условием минимума функционала  $Q(\tilde{S}_t, \beta_0, \beta_1)$

является выполнение системы из двух уравнений

$$\frac{\partial Q(\tilde{S}_t, \beta_0, \beta_1)}{\partial \beta_0} = -\frac{2\beta_0}{m} \sum_{j=1}^m y_j + \frac{2\beta_1}{m} \sum_{j=1}^m x_j = 0$$

$$\frac{\partial Q(\tilde{S}_t, \beta_0, \beta_1)}{\partial \beta_1} = -\frac{2\beta_0}{m} \sum_{j=1}^m x_j y_j + \frac{2\beta_1}{m} \sum_{j=1}^m x_j^2 = 0 \quad (2)$$

Оценки  $(\hat{\beta}_0, \hat{\beta}_1)$  являются решением системы неравенств (2)

относительно параметров  $(\beta_0, \beta_1)$  соответственно

# Одномерная линейная регрессия

Таким образом оценки могут быть записаны в виде

$$\hat{\beta}_1 = \frac{\sum_{j=1}^m x_j y_j - \frac{1}{m} \sum_{j=1}^m x_j \sum_{j=1}^m y_j}{\sum_{j=1}^m x_j^2 - \frac{1}{m} \left( \sum_{j=1}^m x_j \right)^2}, \quad \hat{\beta}_0 = \bar{y} - \beta_1 \bar{x}, \quad \text{где}$$
$$\bar{y} = \frac{1}{m} \sum_{j=1}^m y_j, \quad \bar{x} = \frac{1}{m} \sum_{j=1}^m x_j$$

Выражение для  $\hat{\beta}_1$  может быть переписано в виде

$$\hat{\beta}_1 = \frac{\text{Cov}(Y, X | \tilde{S}_t)}{D(X)}, \quad \text{где} \quad \text{Cov}(Y, X | \tilde{S}_t) = \frac{1}{m} \sum_{j=1}^m (y_j - \bar{y})(x_j - \bar{x})$$

$$D(X | \tilde{S}_t) = \frac{1}{m} \sum_{j=1}^m (x_j - \bar{x})^2 \quad \text{соответственно}$$

выборочные ковариация и дисперсия

# Многомерная линейная регрессия

При вычислении оценки вектора  $\beta$  - параметров в случае многомерной линейной регрессии удобно использовать матрицу плана  $\mathbf{X}$  размера  $m \times (n+1)$  которая строится по обучающей выборке

$$\tilde{S}_t = \{(y_1, \mathbf{x}_1), \dots, (y_m, \mathbf{x}_m)\}$$

$$\mathbf{X} = \begin{pmatrix} 1 & x_{11} & \dots & x_{1n} \\ \dots & \dots & \dots & \dots \\ 1 & x_{j1} & \dots & x_{jn} \\ \dots & \dots & \dots & \dots \\ 1 & x_{m1} & \dots & x_{mn} \end{pmatrix}$$

# Многомерная линейная регрессия

Пусть  $\mathbf{y} = (y_1, \dots, y_m)$  - вектор значений переменной  $Y$ .

Связь значений  $Y$  с переменными  $(X_1, \dots, X_n)$  на объектах обучающей выборки может быть описана с

помощью матричного уравнения  $\mathbf{y} = \boldsymbol{\beta}\mathbf{X}^t + \boldsymbol{\varepsilon}$  где

$\boldsymbol{\varepsilon} = (\varepsilon_1, \dots, \varepsilon_m)$  - вектор ошибок для объектов  $\tilde{S}_t$ .

Функционал  $Q(\tilde{S}_t, \beta_0, \dots, \beta_n)$  Может быть записан в виде

$$Q(\tilde{S}_t, \beta_0, \dots, \beta_n) = \frac{1}{m} \sum_{j=1}^m \left[ y_j - \sum_{i=1}^{n+1} \beta_i \hat{x}_{ji} \right]^2, \text{ где } \hat{x}_{ji} - \text{элемент } \mathbf{X}$$

# Многомерная линейная регрессия

Необходимым условием минимума функционала

$Q(\tilde{S}_t, \beta_0, \dots, \beta_n)$  является выполнение системы из  $n + 1$  уравнений

$$\frac{\partial Q(\tilde{S}_t, \beta_0, \dots, \beta_n)}{\partial \beta_0} = 2 \left[ \sum_{j=1}^m y_j \hat{x}_{j1} - \sum_{j=1}^m \sum_{i=1}^{n+1} \beta_i \hat{x}_{ji} \hat{x}_{j1} \right] = 0 \quad (3)$$

.....

$$\frac{\partial Q(\tilde{S}_t, \beta_0, \dots, \beta_n)}{\partial \beta_n} = 2 \left[ \sum_{j=1}^m y_j \hat{x}_{jn} - \sum_{j=1}^m \sum_{i=1}^{n+1} \beta_i \hat{x}_{ji} \hat{x}_{jn} \right] = 0$$



# Многомерная линейная регрессия

Вектор оценок значений регрессионных коэффициентов

$\hat{\boldsymbol{\beta}} = (\hat{\beta}_0, \dots, \hat{\beta}_n)$  является решением системы уравнений (3)

В матричной форме система (3) может быть записана в виде

$$-2\mathbf{X}^t \mathbf{y}^t + 2\mathbf{X}^t \mathbf{X} \boldsymbol{\beta}^t = 0 \quad (4)$$

Решение системы (4) существует, если  $\det(\mathbf{X}^t \mathbf{X}) \neq 0$

# Многомерная линейная регрессия

- В этом случае для  $\mathbf{X}^t \mathbf{X}$  существует обратная матрица и решение (4) относительно вектора может быть записано в виде:  $\hat{\boldsymbol{\beta}}^t = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t y^t$

# МУЛЬТИКОЛЛИНЕАРНОСТЬ

Явление мультиколлинеарности,

Из теории матриц следует, что  $\det(\mathbf{X}^t \mathbf{X}) = 0$  если ранг матрицы  $\mathbf{X}$  по строкам менее  $n$ . Однако при сильной коррелированности одной из переменных с какой-либо линейной комбинацией других переменных

значение  $\det(\mathbf{X}^t \mathbf{X})$  оказывается близким 0

При этом вычисленный вектор оценок  $\hat{\boldsymbol{\beta}}^t$  может сильно изменяться при небольших изменениях в обучающей выборке..

# Свойства оптимальных регрессий

- Рассмотрим свойства линейных регрессий, минимизирующих квадрат ошибки на пространстве событий  $\Omega$ . Пусть  $R(X_1, \dots, X_n)$  - регрессионная функция, которая не может быть улучшена с помощью дополнительного линейного преобразования. Иными словами
- $$\forall \alpha_0, \alpha_1 \quad E_{\Omega} (Y - \alpha_0 - \alpha_1 R)^2 \geq E_{\Omega} (Y - R)^2$$

# Свойства оптимальных регрессий

- То есть минимум  $E_{\Omega}(Y - \alpha_0 - \alpha_1 R)^2$  достигается при

$$\alpha_0 = 0, \quad \alpha_1 = 1$$

$$E_{\Omega}(Y - \alpha_0 - \alpha_1 R)^2 = E_{\Omega}Y^2 - 2\alpha_0 E_{\Omega}Y - \\ - 2\alpha_1 E_{\Omega}(YR) + \alpha_1^2 E_{\Omega}R^2 + 2\alpha_1 \alpha_0 E_{\Omega}R + \alpha_0^2$$

Необходимым условием экстремума  $E_{\Omega}(Y - \alpha_0 - \alpha_1 R)^2$

является равенство 0 частных производных

$$\frac{\partial E_{\Omega}(Y - \alpha_0 - \alpha_1 R)^2}{\partial \alpha_0}, \quad \frac{\partial E_{\Omega}(Y - \alpha_0 - \alpha_1 R)^2}{\partial \alpha_1}$$

# Свойства оптимальных регрессий

Что эквивалентно уравнениям

$$2\alpha_1 E_{\Omega}R + 2\alpha_0 - 2\alpha_1 E_{\Omega}Y = 0$$

$$-2E_{\Omega}(YR) + 2\alpha_1 E_{\Omega}R^2 + 2\alpha_0 E_{\Omega}R = 0$$

Принимая во внимание, что в точке экстремума  $\alpha_0 = 0$ ,  $\alpha_1 = 1$

получаем следующие свойства оптимального линейного

прогнозирующего алгоритма

$$1) E_{\Omega}R = E_{\Omega}Y \quad 2) E_{\Omega}R^2 = E_{\Omega}(YR)$$

# Свойства оптимальных регрессий

- Из свойств 1) 2) следует, что дисперсия  $R$  равна ковариации  $Y$  и  $R$

$$D(R) = E_{\Omega}(R - E_{\Omega}R)^2 = E_{\Omega}R^2 - (E_{\Omega}R)^2$$

$$\text{cov}(YR) = E_{\Omega}\{(R - E_{\Omega}R)(Y - E_{\Omega}Y)\} = E_{\Omega}(RY) - (E_{\Omega}R)^2$$

То есть 3)  $\text{cov}(YR) = D(R)$

# Свойства оптимальных регрессий

Рассмотрим коэффициент корреляции между  $Y$  и  $R$

$$3) \quad K(YR) = \frac{\text{cov}(YR)}{\sqrt{D(Y)D(R)}} = \sqrt{\frac{D(R)}{D(Y)}}$$

Величина ошибки прогнозирования  $Y$  с помощью  $R$

$$\begin{aligned} 4) \Delta(Y, R) &= E_{\Omega} (Y - R)^2 = E_{\Omega} Y^2 - 2E_{\Omega} (YR) + E_{\Omega} R^2 = \\ &= E_{\Omega} Y^2 - E_{\Omega} R^2 = E_{\Omega} Y^2 - (E_{\Omega} Y)^2 + (E_{\Omega} Y)^2 - E_{\Omega} R^2 = \\ &= E_{\Omega} Y^2 - (E_{\Omega} Y)^2 + (E_{\Omega} R)^2 - E_{\Omega} R^2 = D(Y) - D(R) \end{aligned}$$



# Свойства оптимальных регрессий

Из свойств (3) и (4) легко следует свойство для

относительной ошибки  $\Delta_r(Y, R) = \Delta_r(Y, R) / D(Y)$

$$5) \Delta_r(Y, R) = 1 - K^2(Y, R)$$

# Разложение обобщённой ошибки

Напомним, что обобщающая способность алгоритма прогнозирования  $A(\mathbf{x}, \tilde{S}_t)$ , обученного по выборке  $\tilde{S}_t$  с помощью метода  $\mathbf{A}$  измеряется величиной потерь на генеральной совокупности  $\Omega$

$$E_{\Omega}\{\lambda[Y, A(\mathbf{x}, \tilde{S}_t)]\} = \int_{\Omega} \lambda[Y, A(\mathbf{x})] P(d\omega)$$

# Разложение обобщённой ошибки

- Для оценки эффективности использования метода прогнозирования  $A$  для прогнозирования случайного процесса, связанного с генеральной совокупностью  $\Omega$  при размере обучающей выборки естественно  $m$  использовать математическое ожидание потерь по пространству всевозможных обучающих выборок  $\tilde{S}_m$

длины  $m$  -

$$\Omega_m = \Omega \times \dots \times \Omega$$

$$E_{\Omega_m} E_{\Omega} \{ \lambda[Y, A(\mathbf{x}, \tilde{S}_m)] \}$$

# Разложение обобщённой ошибки

При использовании в качестве функции потерь квадрата ошибки  $\lambda[y_j, A(\mathbf{x}_j)] = [y_j - A(\mathbf{x}_j)]^2$  обобщённые потери (обобщённая квадратичная ошибка  $\Delta_G$ ) принимает вид

$$\Delta_G = E_{\Omega_m} E_{\Omega} \{ [Y - A(\mathbf{x}, \tilde{S}_m)]^2 \}$$

Проведём преобразования

$$\begin{aligned} \Delta_G &= E_{\Omega_m} E_{\Omega} \{ [Y - E(Y | \mathbf{x}) + E(Y | \mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)]^2 \} = \\ &= E_{\Omega_m} E_{\Omega} \{ [Y - E(Y | \mathbf{x})]^2 \} + E_{\Omega_m} E_{\Omega} \{ [E(Y | \mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)]^2 \} + \\ &\quad + E_{\Omega_m} E_{\Omega} \{ [E(Y | \mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)][Y - E(Y | \mathbf{x})] \} \end{aligned}$$

# Разложение обобщённой ошибки

Справедливо равенство

$$E_{\Omega_m} E\{[E(Y | \mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)][Y - E(Y | \mathbf{x})]\} = 0 \quad ,$$

которое следует из того, что для при любом  $\mathbf{x}$

$$E\{[Y - E(Y | \mathbf{x})]\} = \int_M E\{[Y - E(Y | \mathbf{x})] | \mathbf{x}\} p(\mathbf{x}) dx_1 \dots dx_n \quad ,$$

а  $E\{[Y - E(Y | \mathbf{x})]\} = 0$

Принимая во внимание, что  $[Y - E(Y | \mathbf{x})]^2$  не зависит от  $\tilde{S}_m$

получаем

$$E_{\Omega_m} E\{[Y - E(Y | \mathbf{x})]^2\} = E\{[Y - E(Y | \mathbf{x})]^2\}$$

# Разложение обобщённой ошибки

В итоге

$$\Delta_G = E_{\Omega} \{ [Y - E(Y | \mathbf{x})]^2 \} + E_{\Omega_m} E_{\Omega} [E(Y | \mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)]^2 \}$$

Введём обозначение

$$\hat{A}(\mathbf{x}) = E_{\Omega_m} \{ A(\mathbf{x}, \tilde{S}_m) \}$$

Компонента разложения

$$E_{\Omega_m} E_{\Omega} [E(Y | \mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)]^2 \}$$

Может быть представлена в виде

$$E_{\Omega_m} E_{\Omega} [E(Y | \mathbf{x}) - \hat{A}(\mathbf{x}) + \hat{A}(\mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)]^2 \} =$$

# Разложение обобщённой ошибки

$$= E_{\Omega_m} E_{\Omega} \{ [E(Y | \mathbf{x}) - \hat{A}(\mathbf{x})]^2 \} + E_{\Omega_m} E_{\Omega} \{ [\hat{A}(\mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)]^2 \} + \\ + E_{\Omega_m} E_{\Omega} \{ [\hat{A}(\mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)][E(Y | \mathbf{x}) - \hat{A}(\mathbf{x})] \}$$

Справедливо равенство

$$E_{\Omega_m} E_{\Omega} \{ [\hat{A}(\mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)][E(Y | \mathbf{x}) - \hat{A}(\mathbf{x})] \} = 0$$

Действительно

$$E_{\Omega_m} E_{\Omega} \{ [\hat{A}(\mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)][E(Y | \mathbf{x}) - \hat{A}(\mathbf{x})] \} = \\ = E_{\Omega} \{ [E(Y | \mathbf{x}) - \hat{A}(\mathbf{x})] E_{\Omega_m} \{ [\hat{A}(\mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)] \} \}$$

# Разложение обобщённой ошибки

Из определения  $\hat{A}(\mathbf{x})$  следует

$$E_{\Omega_m} \{[\hat{A}(\mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)]\} = 0$$

В итоге справедливо трёхкомпонентное разложение обобщённой квадратичной ошибки  $\Delta_G$

$$\begin{aligned} \Delta_G &= E_{\Omega} \{[Y - E(Y | \mathbf{x})]^2\} + E_{\Omega} \{[E(Y | \mathbf{x}) - \hat{A}(\mathbf{x})]^2\} + \\ &\quad + E_{\Omega_m} E_{\Omega} \{[\hat{A}(\mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)]^2\} = \\ &= \Delta_N + \Delta_B + \Delta_V \end{aligned}$$



# Разложение обобщённой ошибки

Шумовая компонента

$$\Delta_N = E_{\Omega} \{ [Y - E(Y | \mathbf{x})]^2 \}$$

является минимально достижимой квадратичной ошибкой прогноза, которая не может быть устранена с использованием только математических средств.

# Разложение обобщённой ошибки

Составляющая сдвига (Bias)

$$\Delta_B = E_{\Omega} \{ [E(Y | \mathbf{x}) - \hat{A}(\mathbf{x})]^2 \}$$

Высокое значение компоненты сдвига в модели  $\tilde{M} = \{A: \tilde{X} \rightarrow \tilde{Y}\}$

Алгоритмов, достаточно хорошо аппроксимирующих объективно существующую зависимость  $Y$  от переменных  $X_1, \dots, X_n$

Составляющая сдвига может быть снижена путём включения в модель

Дополнительных алгоритмов прогнозирования, позволяющих повысить точность аппроксимации

# Разложение обобщённой ошибки

Дисперсионная составляющая (Variance)

$$\Delta_V = E_{\Omega_m} E_{\Omega} \{ [\hat{A}(\mathbf{x}) - A(\mathbf{x}, \tilde{S}_m)]^2 \}$$

характеризует неустойчивость обученных прогнозирующих алгоритмов при статистически возможных изменениях в обучающих выборках. Дисперсионная составляющая возрастает при небольших размерах обучающей выборки. Дисперсионная составляющая может быть снижена путём выбора сложности модели, соответствующей размеру обучающих данных.

# Разложение обобщённой ошибки

Таким образом существует

**Bias-Variance дилемма**

Составляющая сдвига может быть снижена путём увеличения разнообразия модели. Однако увеличение разнообразия модели при недостаточном объёме обучающих данных ведёт к росту компоненты сдвига.

Наиболее высокая точность прогноза достигается, при поддержании правильного баланса между разнообразием используемой модели и объёмом обучающих данных

# Методы регрессии, основанные на регуляризации по Тихонову

Использование стандартного варианта метода наименьших квадратов ведёт к увеличению неустойчивости обучения при увеличении числа  $X$  переменных при ограниченном размере обучающей выборки  $\tilde{S}_t$ . Небольшое изменение векторных описаний объектов  $\tilde{S}_t$  приводит к значительному изменению оценок регрессионных параметров  $\beta_0, \dots, \beta_n$ . Подобные изменения оценок  $\beta_0, \dots, \beta_n$  ведёт к возрастанию вариационной компоненты  $\Delta_V$  и следовательно к увеличению всей обобщённой ошибки.

# Методы регрессии, основанные на регуляризации по Тихонову

Неустойчивость обучения ещё более возрастает при наличии явления мультиколлинеарности.

Одним из возможных способов борьбы с неустойчивостью является использование методов регуляризации. На первом этапе переходим от исходных переменных  $X_1, \dots, X_n$  к стандартизированным  $X_1^s, \dots, X_n^s$ , где

$$X_i^s = \frac{X_i - \hat{X}_i}{\hat{\sigma}_i}, \quad \hat{X}_i = \frac{1}{m} \sum_{j=1}^m x_{ji}, \quad \hat{\sigma}_i = \sqrt{\frac{1}{m} \sum_{j=1}^m (x_{ji} - \hat{X}_i)^2}$$

а также от  $Y$  к  $Y^s = Y - \frac{1}{m} \sum_{j=1}^m y_j$

# Методы регрессии, основанные на регуляризации по Тихонову

От стандартного функционала метода наименьших квадратов

$$Q(\tilde{S}_t, \beta_0, \dots, \beta_n) = \frac{1}{m} \sum_{j=1}^m \left[ y_j - \sum_{i=1}^{n+1} \beta_i \hat{x}_{ji} \right]^2$$

переходим к регуляризованному функционалу ,  
соответствующему методу гребневая регрессия

$$Q_r(\tilde{S}_t, \beta_0, \dots, \beta_n) = \frac{1}{m} \sum_{j=1}^m \left[ y_j^s - \sum_{i=1}^{n+1} \beta_i \hat{x}_{ji}^s \right]^2 + \gamma \sum_{i=0}^n \beta_i^2$$

# Методы регрессии, основанные на регуляризации по Тихонову

Слагаемое  $\gamma \sum_{i=0}^n \beta_i^2$ , где  $\gamma$  - положительный вещественный параметр, носит название штрафной функции или просто штрафа. Необходимым условием минимума

функционала  $Q_r(\tilde{S}_t, \beta_0, \dots, \beta_n)$  является выполнение

системы из уравнений

$$\frac{\partial Q(\tilde{S}_t, \beta_0, \dots, \beta_n)}{\partial \beta_0} = 2 \left[ \sum_{j=1}^m y_j \hat{x}_{j1}^s - \sum_{j=1}^m \sum_{i=1}^{n+1} \beta_i \hat{x}_{ji}^s \hat{x}_{j1}^s + \gamma \beta_0 \right] = 0 \quad (5)$$

.....

$$\frac{\partial Q(\tilde{S}_t, \beta_0, \dots, \beta_n)}{\partial \beta_n} = 2 \left[ \sum_{j=1}^m y_j \hat{x}_{jn}^s - \sum_{j=1}^m \sum_{i=1}^{n+1} \beta_i \hat{x}_{ji}^s \hat{x}_{jn}^s + \gamma \beta_n \right] = 0$$



# Методы регрессии, основанные на регуляризации по Тихонову

Таким образом вектор оценок регрессионных коэффициентов в методе гребневая регрессия  $\hat{\boldsymbol{\beta}} = (\hat{\beta}_0, \dots, \hat{\beta}_n)$  является решением системы (5).

В матричной форме система (5) может быть записана в виде

$$-(\mathbf{X}^s)^t \mathbf{y}^t + [(\mathbf{X}^s)^t \mathbf{X} + \gamma I] \hat{\boldsymbol{\beta}}^t = 0$$

или в виде

$$\hat{\boldsymbol{\beta}}^t = (\mathbf{X}^s)^t (\mathbf{y}^s)^t [(\mathbf{X}^s)^t \mathbf{X} + \gamma I]^{-1}$$

# Методы регрессии, основанные на регуляризации по Тихонову

Отметим, что произведение  $(\mathbf{X}^s)^t \mathbf{X}$  представляет собой симметрическую неотрицательно определённую матрицу.

Матрица  $[(\mathbf{X}^s)^t \mathbf{X} + \gamma I]$  также является симметрической матрицей.

Каждому собственному значению  $\lambda_i$  матрицы  $(\mathbf{X}^s)^t \mathbf{X}$  соответствует собственное значение матрицы  $[(\mathbf{X}^s)^t \mathbf{X} + \gamma I]$  -  
 $= \lambda_i + \gamma$

Таким образом минимальное собственное значение матрицы

$[(\mathbf{X}^s)^t \mathbf{X} + \gamma I]$  удовлетворяет неравенству  $\lambda_{\min} \geq \gamma$

# Методы регрессии, основанные на регуляризации по Тихонову

Откуда следует, что всегда  $\det[(\mathbf{X}^s)^t \mathbf{X} + \gamma I] > 0$ , а обратная матрица  $[(\mathbf{X}^s)^t \mathbf{X} + \gamma I]^{-1}$  всегда существует.

Большая величина  $\det[(\mathbf{X}^s)^t \mathbf{X} + \gamma I]$  приводит к относительно небольшим изменениям оценок регрессионных коэффициентов при небольших изменениях в обучающих выборках.