

# Aula 14/10/2020

Valor médio do MSE do conjunto de teste.

- **Training MSE versus Test MSE, em função da flexibilidade do modelo.**
- **Exercício:** estudar os três casos.
- **In practice**, one can usually compute the **training MSE** with relative ease;
- but estimating **test MSE** is considerably more **difficult** because usually **no test data** are available.
- As the previous three examples illustrate, **the flexibility level** corresponding to the model with **the minimal test MSE** can vary considerably among data sets.
- Throughout this book, we discuss **a variety of approaches** that can be used in practice to estimate this minimum point.
- One important method is **cross-validation (Chapter 5)**, which is a method for estimating test MSE using the training data.

$$E \left( y_0 - \hat{f}(x_0) \right)^2 = \text{Var}(\hat{f}(x_0)) + [\text{Bias}(\hat{f}(x_0))]^2 + \text{Var}(\epsilon).$$

**Expected test MSE, for a given value  $x_0$**  : valor esperado do “set MSE”, para um valor fixo de  $x_0$ , considerando as  $f$  estimadas, a partir de vários conjuntos de treinamento. É uma média (Esperança) sobre as  $f$  estimadas.

$\hat{f}$

- É chamada de método de aprendizado estatístico.
- É uma variável aleatória que depende do conjunto de treinamento usado para estimá-la ou “fitá-la”. E assim podemos calcular sua variância.

$\text{Var}(\hat{f}(x_0))$

- É como a  $f$  varia quando usamos diferentes conjuntos de treinamento.
- Característica ideal: não ser muito grande.
- In general, more flexible statistical methods have higher variance.

$\text{Var}(\epsilon)$ .

Variância do erro não redutível.

**Conjunto de treinamento:** Amostra Aleatória da disciplina de Estatística.




**Para cada conjunto de treinamento:** temos uma  $f$  estimada diferente.

**Para cada conjunto de treinamento  $i$ :**  $X_1, X_2, X_3, \dots, X_n$  temos uma  $f_i$  diferente.

Por exemplo, se quisermos usar uma função linear:

- $Y_i(x) = a(i,1)x + a(i,2) = f_i(x)$ , temos para  $x_0$  (fixo e pertencente ao conj. de teste)
  - $Y_i(x_0) = a(i,1)x_0 + a(i,2) = f_i(x_0)$ , onde
    - $a(i,1) = g_1(X_1, X_2, X_3, \dots, X_n)$  e  $a(i,2) = g_2(X_1, X_2, X_3, \dots, X_n)$  são variáveis aleatórias.
    - Como fixamos  $x_0$ ,  $f_i(x_0)$  é uma variável aleatória pois é função de  $a(i,1) = g_1(X_1, X_2, X_3, \dots, X_n)$  e  $a(i,2) = g_2(X_1, X_2, X_3, \dots, X_n)$ .
- Mas ainda fica a questão de qual distribuição de probabilidade que está sendo usada para calcular a Esperança.**

## Discutindo a Variância




- A curva verde é flexível e se adequa bem aos dados.
- Porém tem o método tem uma variância alta: mudar alguns pontos e a curva muda.
- Em contraste, a reta laranja é bem menos flexível, mas variaria pouco ao mudarmos alguns pontos do conjunto de treinamento.

$$\cdot [\text{Bias}(\hat{f}(x_0))]^2$$

O viés se refere ao erros provenientes pela escolha do modelo para uma situação da vida real, que pode ser bem complicada.


Por exemplo, a regressão linear assume que há uma relação linear entre  $Y$  e  $X_1, X_2, \dots, X_p$ .

É bem pouco provável que essa relação seja linear, e uma regressão linear trará um viés para a estimação de  $f$ .



- **A  $f$  verdadeira** da Figura ao lado é explicitamente não-linear. Não adianta ter mais dados de treinamento se continuarmos usando regressão linear.
- Não tem como produzir uma estimativa mais precisa. O uso do modelo de regressão linear causa um **grande viés** para esse exemplo.

## Discutindo o Viés



- Na figura ao lado a situação é bem diferente.
- A  $f$  verdadeira é aproximadamente linear.
- Então quanto mais dados de treinamento houver mais precisa será o modelo de regressão linear proposto.


**Quanto mais flexível o modelo menos viés haverá.**

$$E \left( y_0 - \hat{f}(x_0) \right)^2 = \text{Var}(\hat{f}(x_0)) + [\text{Bias}(\hat{f}(x_0))]^2 + \text{Var}(\epsilon).$$

**E finalmente, podemos interpretar essa expressão matemática:**

- Para diminuir o “test MSE”, é necessário que escolhamos um método de aprendizado estatístico que se tenha simultaneamente valores bem pequenos de variância e viés.
- Observar que a variância é sempre positiva, e que o viés está elevado ao quadrado, e portanto são ambos positivos.
- Portanto, o “test MSE” nunca vai ser menor que  $\text{Var}(\epsilon)$ .




- Quanto maior a flexibilidade do método selecionado, maior a variância e menor é o viés.
- Mudanças no Viés e na Variância determinam aumento ou diminuição do test MSE médio.



Análise dos casos já vistos, analisados segundo a expressão para o test MSE médio (em vermelho). Aparecem também a Variância (em laranja), o Viés (em azul).

- Nos 3 casos a variância aumenta quando a flexibilidade do modelo aumenta.
- A flexibilidade ótima (linha vertical tracejada) para o test MSE, para cada um dos modelos, muda consideravelmente.

Por que? Por que o viés e a variância se modificam de forma diferente.



**No primeiro gráfico**, vemos que o viés decai rapidamente, resultando e um decrescimento acentuado do test MSE médio.

**No segundo gráfico**, a  $f$  verdadeira é linear, então o viés decai bem pouco, e o mesmo ocorre para o test MSE.

**No terceiro gráfico**, há um declínio violento do viés, pois a verdadeira  $f$  é não-linear. Há um pequeno crescimento da variância, então o test MSE médio também tem um declínio acentuado.

- **The relationship between bias, variance, and test set MSE** given in Equation 2.7 and displayed in Figure 2.12 is referred to as the *bias-variance trade-off* (*perde-ganha ou troca ou balanço*) .

### **Good test set performance of a statistical learning method requires:**

- low variance and
- low squared bias.

This is referred to as a **trade-off** because it is easy to obtain a method with extremely low bias but high variance.

- **For instance**, by drawing a curve that passes through every single training observation

Or a method with very low variance but high bias

- **For instance** by fitting a horizontal line to the data.

**The challenge** lies in finding a method for which both the variance and the squared bias are low. This trade-off is one of the most important recurring themes in this book.