

Nomenclatura

$\{x_1, x_2, \dots, x_N\} \equiv$ vectores/amostras

$\{y_1, y_2, \dots, y_N\} \equiv$ categorias correspondentes

$X_i = (x_i, y_i) \equiv$ padrão de treino

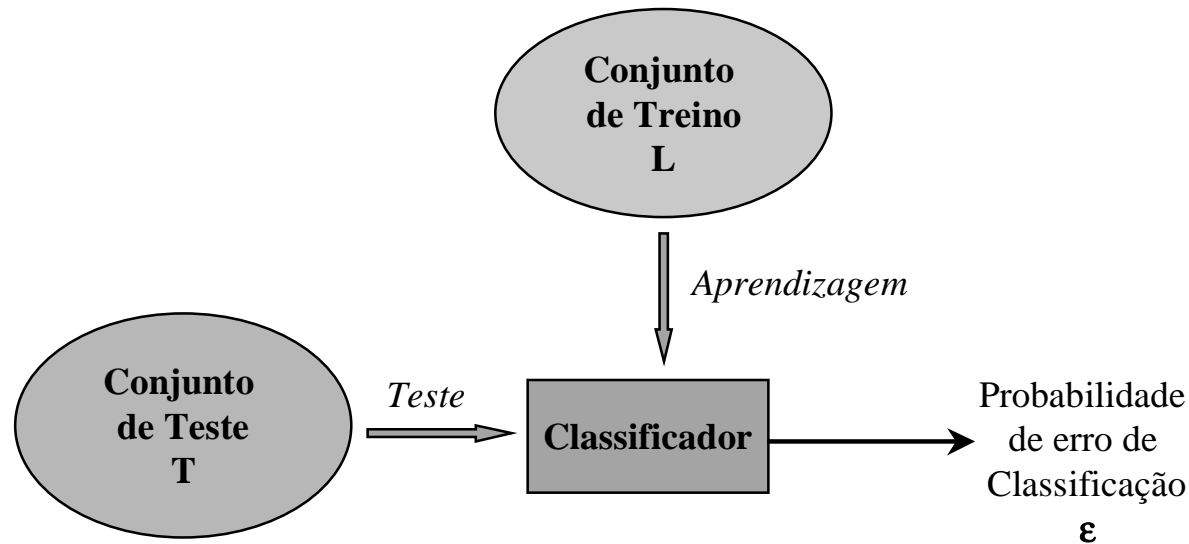
$X = \{X_i, i = 1, \dots, N\} \equiv$ conjunto de treino

$X_T = \{X_{iT}, i = 1, \dots, N_T\} \equiv$ conjunto de teste

$\eta(x, X) \equiv$ regra de decisão

$n_i = Q[y, \eta(x, X)] = \begin{cases} 0 & \text{se } \eta(x, X) = y \\ 1 & \text{caso contrário} \end{cases} \equiv$ indicador de erro

Estimação da Probabilidade de Erro com base em Conjunto Independente de Teste



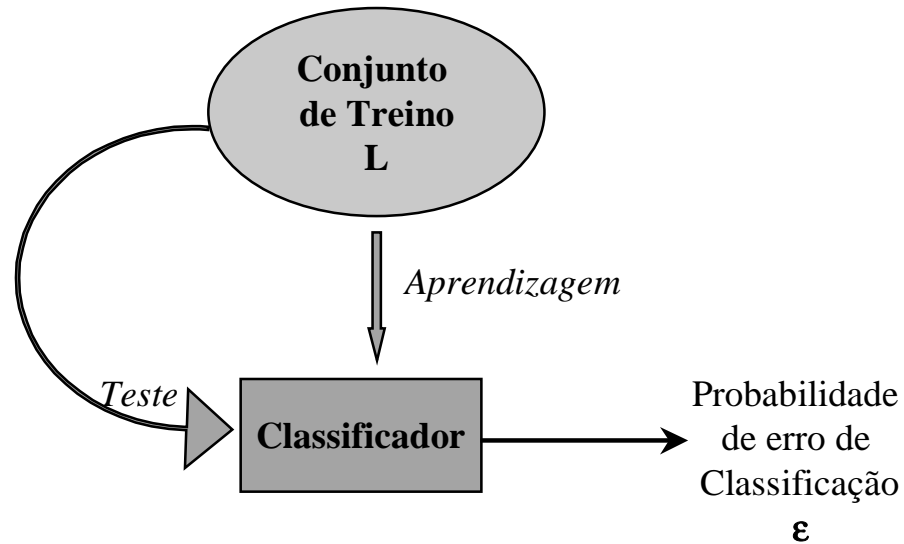
•Contar os erros:

$$n_i = \begin{cases} 0 & \text{se } x_i \text{ é classificado correctamente} \\ 1 & \text{se } x_i \text{ é classificado incorrectamente} \end{cases}$$

$$\hat{\varepsilon} = \hat{\varepsilon}(T, L) = \frac{\sum_{i=1}^{N_T} n_i}{N_T} = \frac{\sum_{i=1}^{N_T} Q[y_{iT}, \eta(x_{iT}, X)]}{N_T}$$

$$\hat{\varepsilon}(T, L) > \varepsilon$$

Erro Aparente ou de Re-substituição



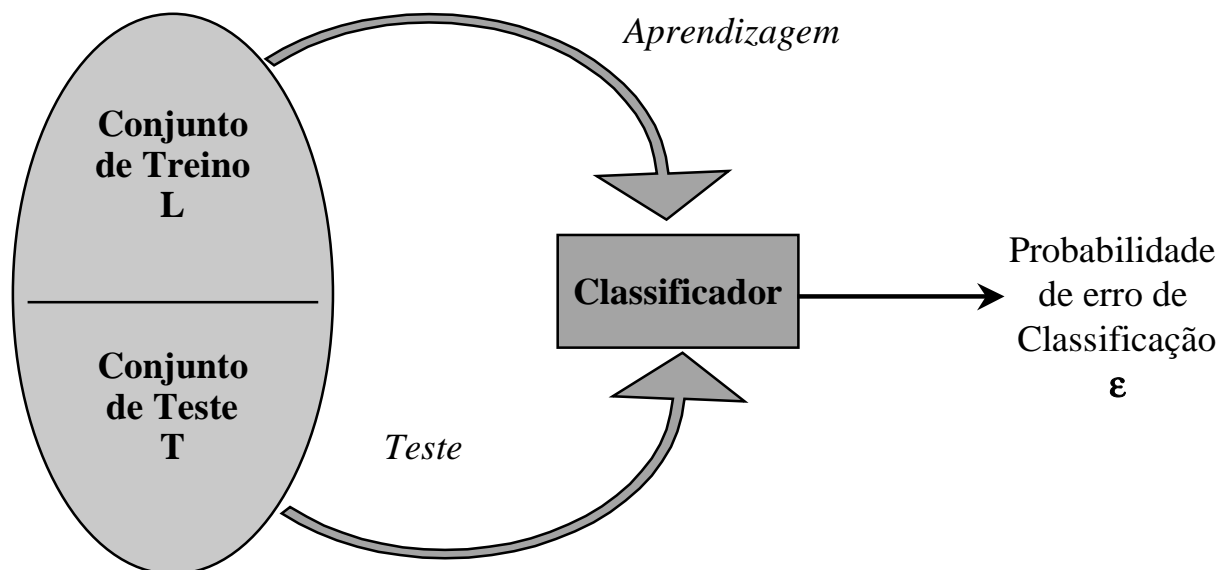
$$\hat{\epsilon}_{app} = \frac{\sum_{i=1}^N Q[y_i, \eta(x_i, X)]}{N}$$

- O mesmo conjunto de treino é usado para avaliação do classificador
- As estimativas da probabilidade de erro assim calculadas são otimistas:

$$\hat{\epsilon}_{app} = \hat{\epsilon}(L, L) < \epsilon$$

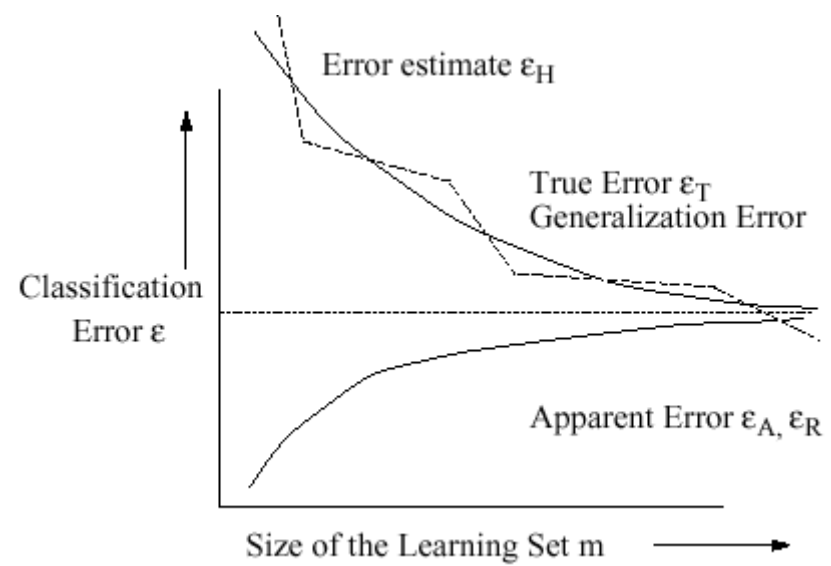
Este efeito é tanto mais notório quanto menor for o conjunto de treino (*over-fitting*)

Método *Hold-Out*

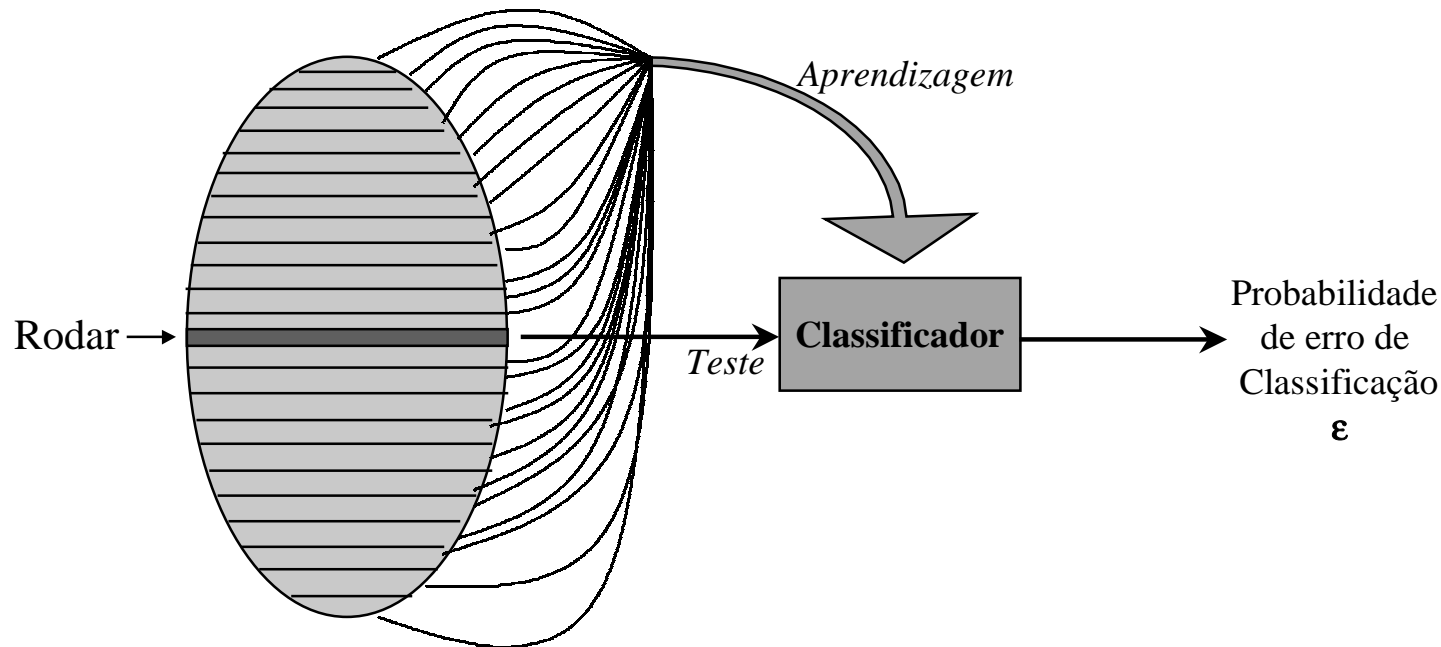


$$\hat{\epsilon}_H = \hat{\epsilon}(T, L) = \frac{\sum_{i=1}^{N_T} \mathcal{Q}[y_{iT}, \eta(x_{iT}, X_L)]}{N_T}$$

$\hat{\epsilon}_H(T, L) > \epsilon$: pessimista.



Método *Leave-one-Out* ou *Jack-knifing* ou *Cross-Validation*



- Guarda uma amostra para teste, usando os restantes N-1 padrões para treino

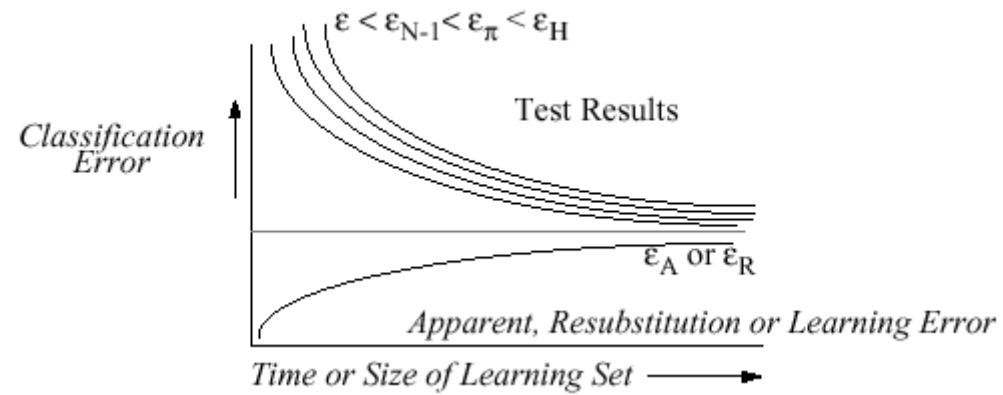
$$\hat{\epsilon}_{JK} = \frac{\sum_{i=1}^N Q[y_i, \eta(x_i, X_{(i)})]}{N}$$

c/ $X_{(i)} = X - \{X_i\}$ (retirar o j ésimo padrão de X)

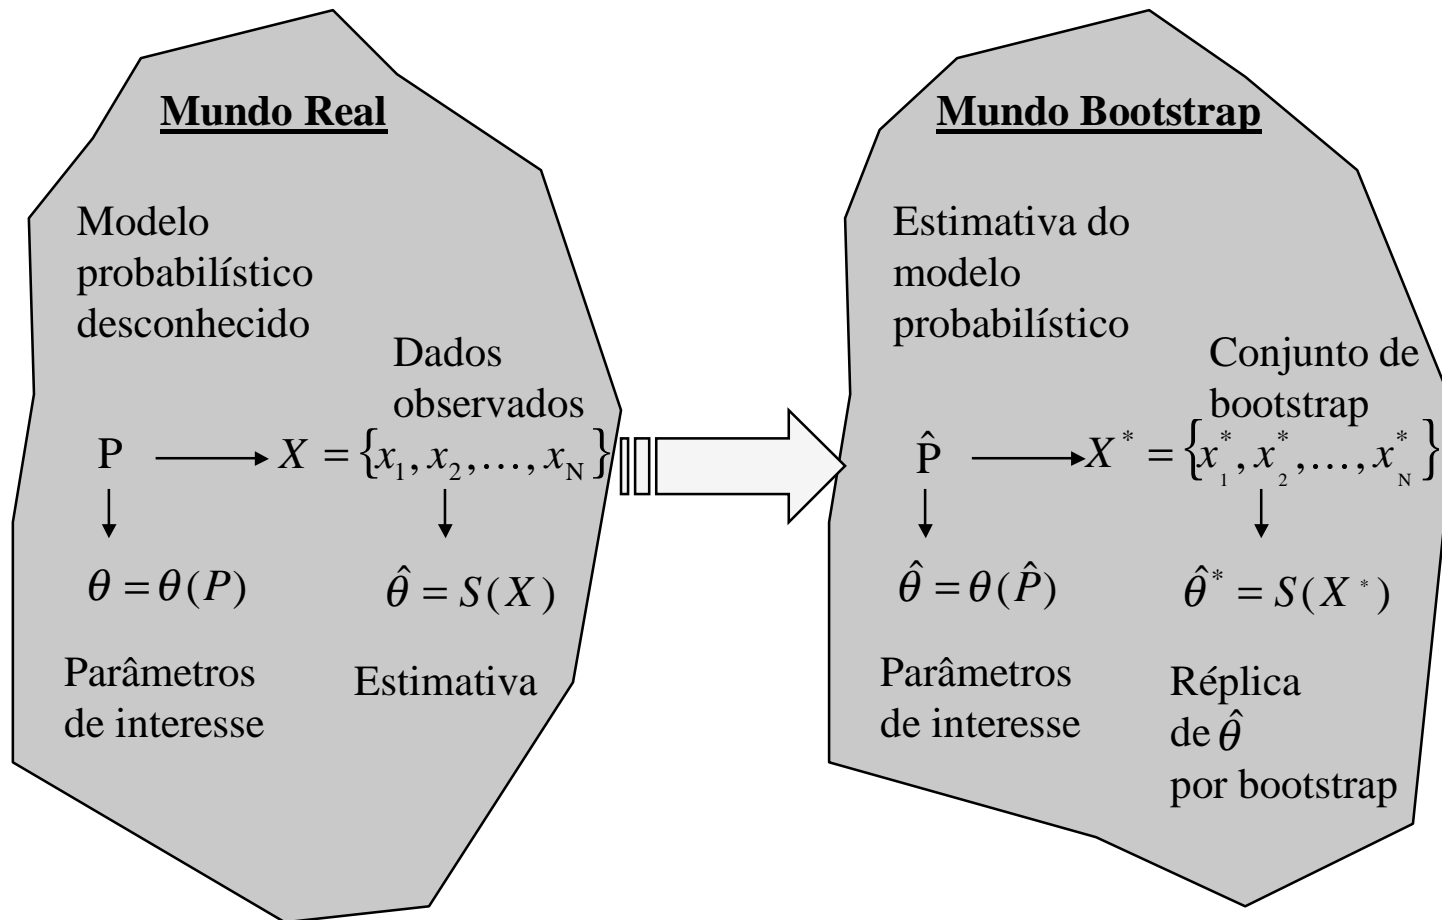
- Estimativa menos polarizada que a anterior mas de grande variância

Rotação e Estimação pelo Método *Leave-one-out*

- **Particionar o conjunto de dados num número elevado de sub-conjuntos (no limite, N)**
- **Usar todos os sub-conjuntos à excepção de um para treino**
- **Usar o conjunto deixado de fora para teste**
- **Repetir sobre todos os sub-conjuntos calculando a média das estimativas**


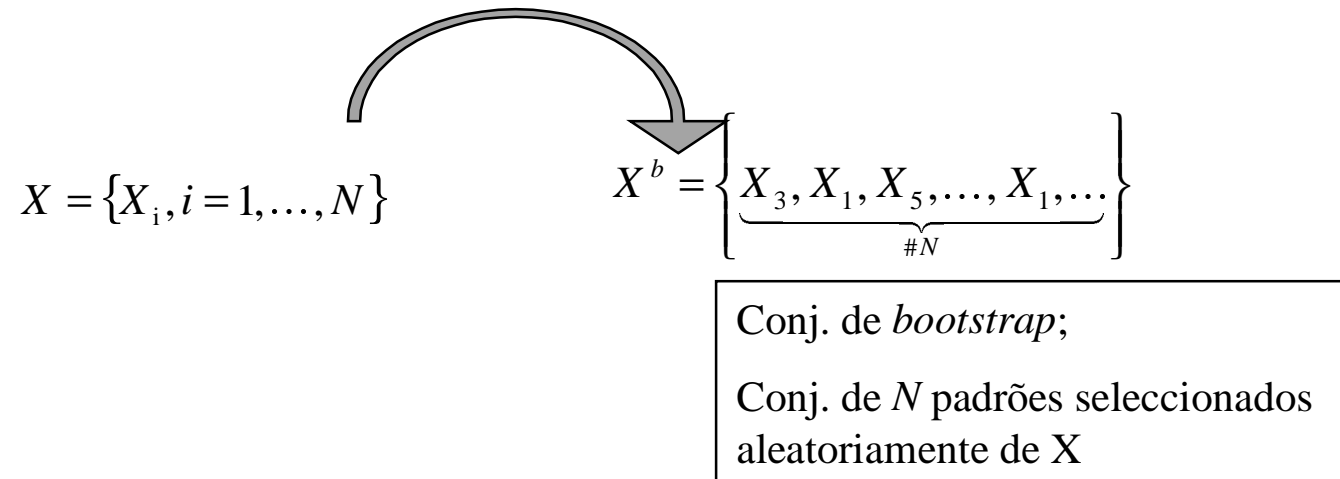


Bootstraping

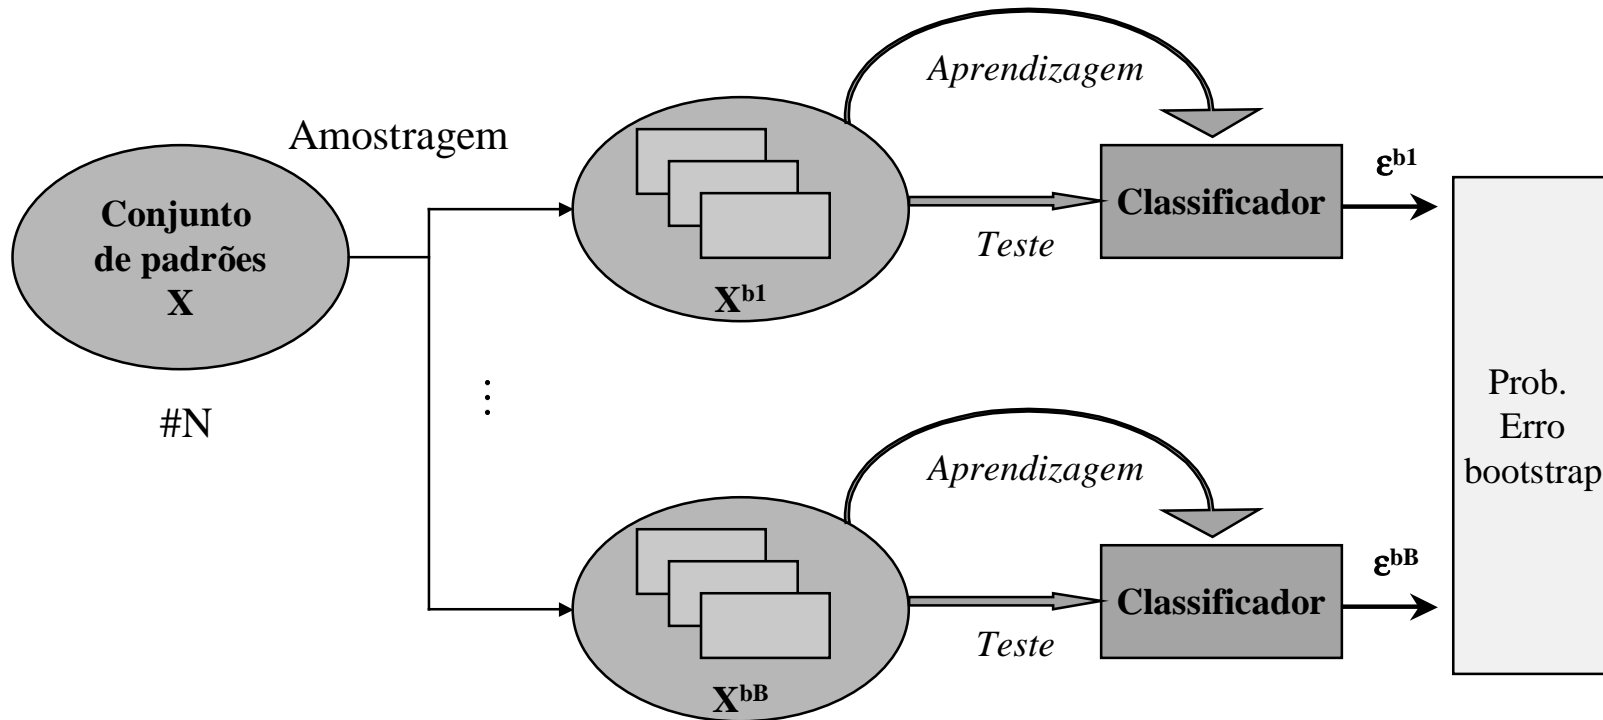


Técnicas de *Bootstrapping* na Estimação da Probabilidade de Erro do Classificador

- Uso de conjuntos de treino obtidos por amostragem, com reposição, dos dados/padrões existentes

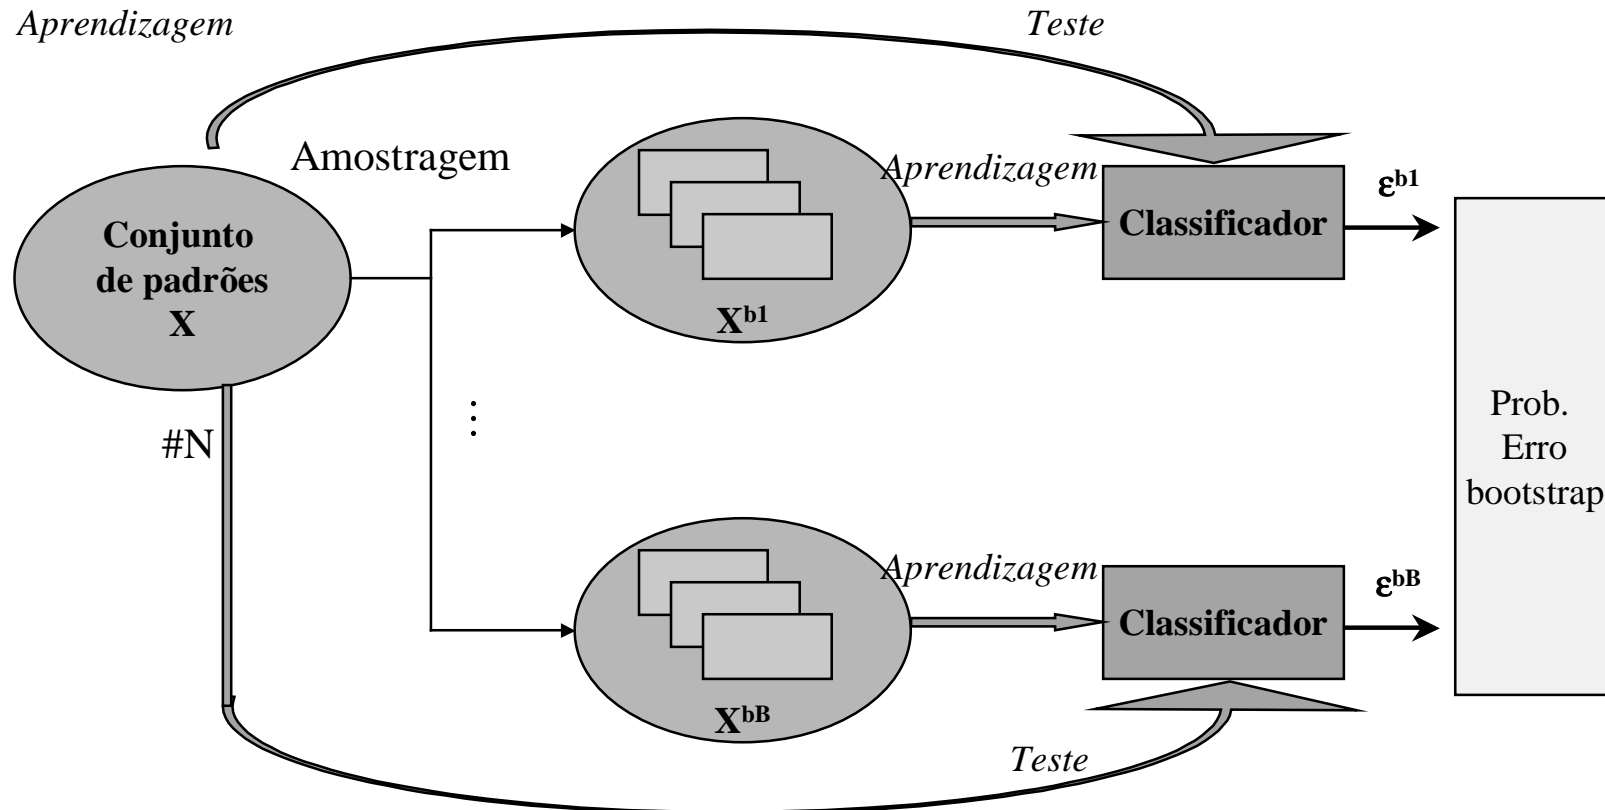


Erro Aparente por Bootstrap



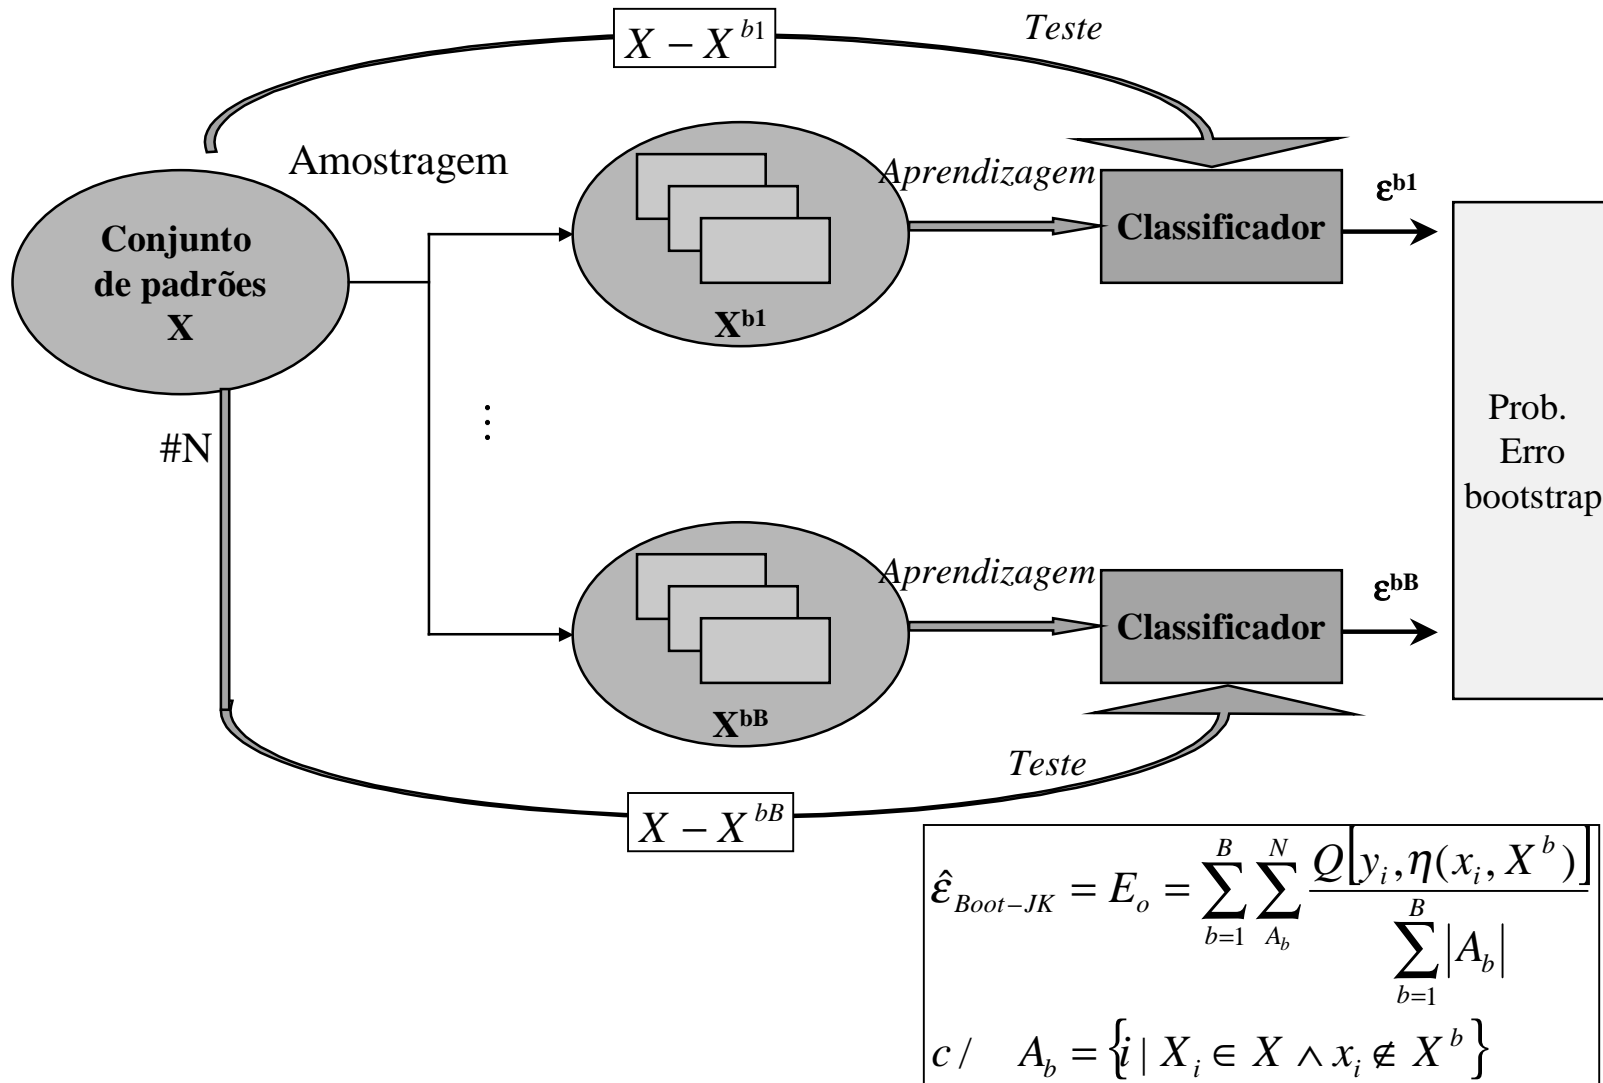
$$\hat{\epsilon}_{\text{Boot-app}} = \text{App} = \frac{1}{B} \sum_{b=1}^B \frac{1}{N} \sum_{\substack{i=1 \\ x_i \in X^b}}^N Q[y_i, \eta(x_i, X^b)]$$

Erro Simples Estimado por *Bootstrap*



$$\hat{\epsilon}_{\text{Boot-simple}} = \text{Simple} = \frac{1}{B} \sum_{b=1}^B \frac{1}{N} \sum_{\substack{i=1 \\ x_i \in X}}^N Q[y_i, \eta(x_i, X^b)]$$

Estimativa *Jack-Knifing* por *Bootstrap*



Estimativa E_{632}

$$E_{632} = 0.386 \times A_{pp} + 0.362 \times E_o$$

- **Ideia: ajuste no optimismo do erro aparente**
- **Factor 0.362 provêm de um argumento teórico que as amostras de bootstrap usadas no cálculo de E_o estão distânciadas da média de um conjunto de teste típico por um factor aproximadamente de 1/.362**
- **Desta forma a estimativa torna-se praticamente não enviesada**