MAE 5905: Introdução à Ciência de Dados

Pedro A. Morettin

Instituto de Matemática e Estatística
Universidade de São Paulo
pam@ime.usp.br
http://www.ime.usp.br/∼ pam

Aula 10

18 de abril de 2026

Sumário

1. Classificador de Margem Não Linear
2. Noções da Teoria
3. Regressão por SVM

CMNL

- Na seção anterior apresentamos um algoritmo de classificação (CMF), usado quando as fronteiras são lineares. Para fronteiras não lineares, precisamos aumentar a dimensão do espaço de dados por meio de outras funções, polinomiais ou não, para determinar as fronteiras de separação.
- Pode-se demonstrar que um classificador linear como aquele definido anteriormente (CMF) depende somente dos vetores suporte e pode ser escrito na forma

$$f(\mathbf{x}) = \sum_{i \in S} \gamma_i < \mathbf{x}, \mathbf{x}_i > + \delta, \tag{1}$$

  em que S indica o conjunto dos vetores suporte, os γ_i são funções de α e β e $< \mathbf{x}, \mathbf{y} >$ indica o produto interno dos vetores $\mathbf{x}$ e $\mathbf{y}$.
- Uma das vantagens de se utilizar kernels na construção de classificadores é que eles dependem somente dos vetores suporte e não de todas as observações o que implica uma redução considerável no custo computacional.

CMNL

- O classificador CMF usa um *kernel* linear, da forma

$$K(\mathbf{x}_i, \mathbf{x}_j) = \sum_{k=1}^{p} x_{ik} x_{jk} = \mathbf{x}_i^\top \mathbf{x}_j.$$

- Se quisermos usar um CMF em um espaço característico de dimensão maior, podemos incluir polinômios de grau maior ou mesmo outras funções na definição do classificador.
- Os *kernels* mais utilizados na prática são:

a) lineares: $K(\mathbf{x}_1, \mathbf{x}_2) = \mathbf{x}_1^\top \mathbf{x}_2$;
b) polinomiais: $K(\mathbf{x}_1, \mathbf{x}_2) = (a + \mathbf{x}_1^\top \mathbf{x}_2)^d$;
c) radiais: $K(\mathbf{x}_1, \mathbf{x}_2) = \exp\left(-\gamma ||\mathbf{x}_1 - \mathbf{x}_2||^2\right)$, com $\gamma > 0$ constante.
d) tangentes hiperbólicas: $K(\mathbf{x}_1, \mathbf{x}_2) = \tanh(\theta + k\mathbf{x}_1^\top \mathbf{x}_2)$.

CMNL

Os classificadores CMNL são obtidos combinando-se CMF com kernels não lineares, de modo a obter

$$f(\mathbf{x}) = \alpha + \sum_{i \in S} \gamma_i K(\mathbf{x}, \mathbf{x}_i) + \delta. \tag{2}$$

em que os γ_i são funções de α e $\boldsymbol{\beta}$.

Exemplo CMNL

- **Exemplo**. Consideremos uma análise alternativa para dados do exemplo anterior, utilizando um *kernel* polinomial, de grau 3.
- Os comandos e resultados da reanálise dos dados por meio do classificador de margem não linear são:

```
escolhaparam <- tune.svm(grupo ~ altfac + proffac, data = face,
                         kernel = "polynomial", degree=3,
                         gamma = 2^(-1:2), cost = 2^2:6)
> summary(escolhaparam)

Parameter tuning of svm:
- sampling method: 10-fold cross validation

- best parameters:
 degree gamma cost
      3   0.5    4
- best performance: 0.1681818
```

Exemplo CMNL

- Detailed performance results:

	degree	gamma	cost	error	dispersion
1	3	0.5	4	0.1681818	0.09440257
2	3	1.0	4	0.1772727	0.12024233
3	3	2.0	4	0.1872727	0.11722221
4	3	4.0	4	0.1872727	0.11722221
5	3	0.5	5	0.1972727	0.11314439
6	3	1.0	5	0.1772727	0.12024233
7	3	2.0	5	0.1872727	0.11722221
8	3	4.0	5	0.1872727	0.11722221
9	3	0.5	6	0.1872727	0.12634583
10	3	1.0	6	0.1772727	0.12024233
11	3	2.0	6	0.1872727	0.11722221
12	3	4.0	6	0.1872727	0.11722221

Exemplo CMNL

```
svm.model <- svm(grupo ~ altfac + proffac, data=face,
                 type='C-classification', kernel='polynomial',
                 degree=3, gamma=1, cost=4, coef0=1, scale=FALSE)
summary(svm.model)

Parameters:
   SVM-Type:  C-classification
 SVM-Kernel:  polynomial
       cost:  4
     degree:  3
     coef.0:  1
Number of Support Vectors:  40
 ( 11 10 19 )Number of Classes:  3
Levels:
 braq dolico meso
```

A tabela de classificação é

	true		
pred	braq	dolico	meso
braq	29	0	4
dolico	0	26	3
meso	4	5	30

acurácia=0,84

Exemplo CMNL

O gráfico correspondente está apresentado na Figura 1.

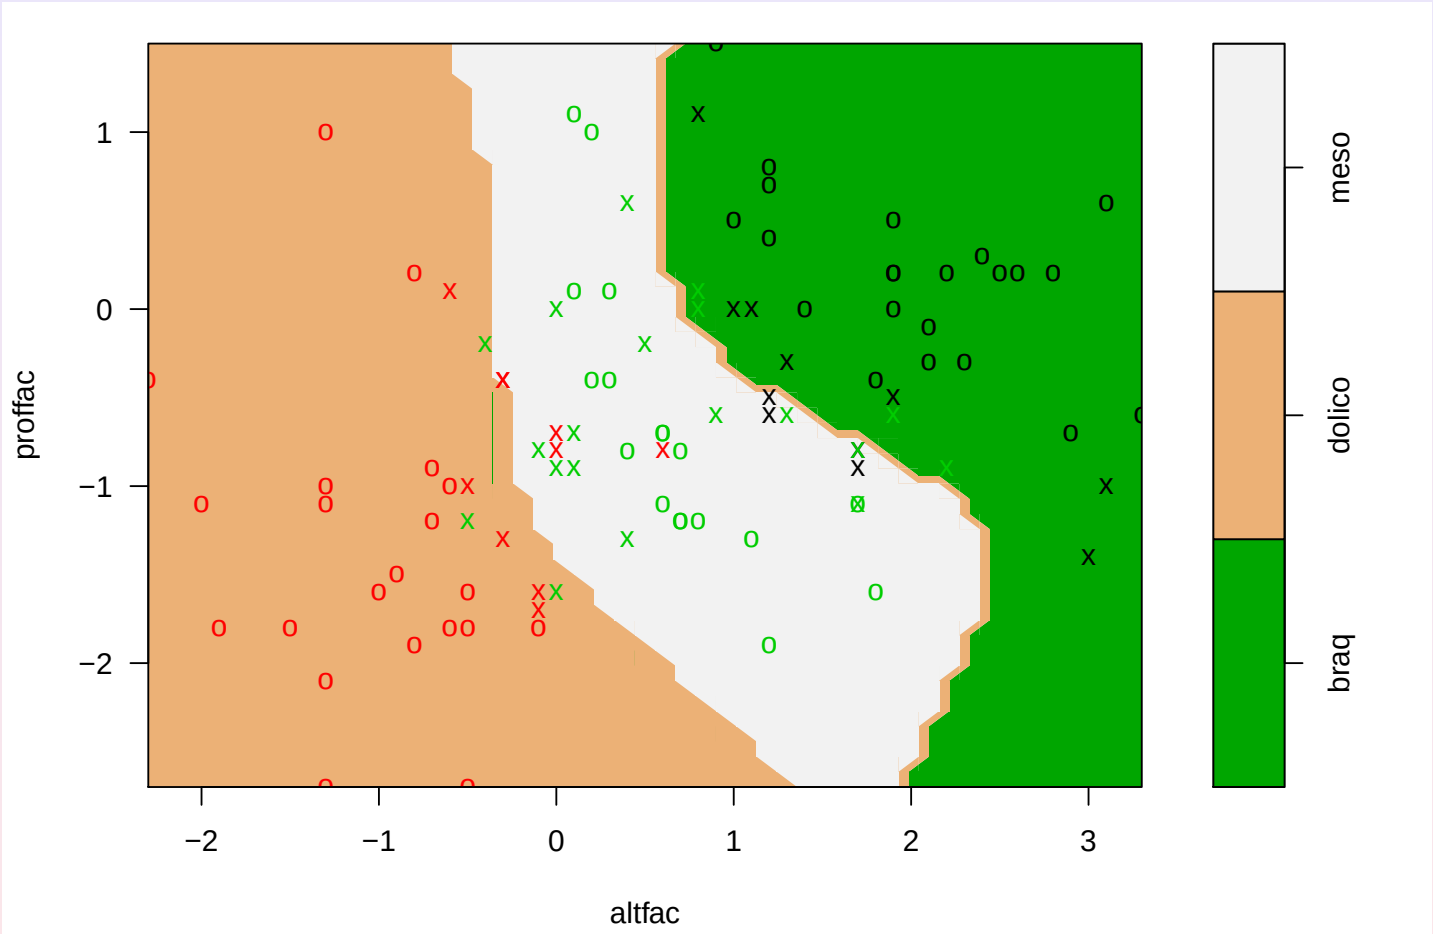


Figura: Classificação do tipo facial obtida pelo classificador de margem não linear.

Exemplo CMNL

- Neste caso, o número de classificações erradas (16) é igual ao caso do classificador de margem flexível. A TEC é 0,16.
- Com base nesses resultados, podemos classificar indivíduos para os quais dispomos apenas dos valores das variáveis preditoras. Com essa finalidade, consideremos o seguinte conjunto de previsão com 4 indivíduos:

	paciente	altfac	proffac
1	102	1.4	1.0
2	103	3.2	0.1
3	104	-2.9	-1.0
4	105	0.5	0.9

CMNL

Por meio dos seguintes comandos

```
svm.model <- svm(grupo ~ altfac + proffac, data=face, type='C-classification',
                 kernel='polynomial', degree=3, gamma=1, cost=4, coef0=1,
                 scale=FALSE, probability=TRUE)
prednovos  <- predict(svm.model, teste, probability=TRUE)
```

obtemos a tabela com as probabilidades de classificação de cada um dos 4 indivíduos

```
     1      2      3      4
  braq   braq  dolico   meso
attr(,"probabilities
```

```
      braq       dolico        meso
1 0.954231749 0.0193863931 0.0263818582
2 0.961362058 0.0006154201 0.0380225221
3 0.008257919 0.9910764215 0.0006656599
4 0.254247666 0.1197179567 0.6260343773
```

```
Levels: braq dolico meso
```

O processo classifica os indivíduos 102 e 103 como braquicéfalos, o indivíduo 104 como dolicocéfalo e o 105, como mesocéfalo.

Hiperplano separador

Um hiperplano definido num espaço de dimensão p é um **subespaço** de dimensão $p-1$ definido por

$$\alpha + \beta_1 X_1 + \ldots + \beta_p X_p = 0. \tag{3}$$

Um ponto com coordenadas $(x_1, \ldots, x_p)$ satisfazendo (3) situa-se no hiperplano. Se $\alpha + \beta_1 x_1 + \ldots + \beta_p x_p > 0$, esse ponto situa-se num lado do hiperplano e se $\alpha + \beta_1 x_1 + \ldots + \beta_p x_p < 0$, o ponto situa-se no outro lado desse hiperplano. Dessa forma, o hiperplano separa o espaço p dimensional em duas metades.

Teoria–CMM

- Consideremos o espaço característico $\mathcal{T} = \{\mathbf{x}_1, \ldots, \mathbf{x}_n\}$ e as respostas $y_1, \ldots, y_n$ com $y_i \in \{-1, 1\}$, definindo o conjunto de treinamento. Novos dados $\mathbf{x}_0$ são classificados de acordo com o sinal de $f(\mathbf{x}_0)$.
- Suponha que exista um hiperplano separador, de modo que α e $\boldsymbol{\beta}$ são tais que $f(\mathbf{x}) > 0$, para pontos com $y = +1$ e $f(\mathbf{x}) < 0$, para pontos com $y = -1$, de modo que $yf(\mathbf{x}) > 0$, para qualquer dado de treinamento.
- O CMM tem como objetivo maximizar a margem que é a menor distância entre o hiperplano e qualquer ponto do conjunto de treinamento.
- Para entender o procedimento de otimização, considere a distância de um ponto $\mathbf{x}$ ao hiperplano cuja equação é $f(\mathbf{x}) = 0$, nomeadamente

$$d = |f(\mathbf{x})|/||\boldsymbol{\beta}||,$$

em que denominador indica a norma do vetor $\boldsymbol{\beta}$.

Teoria–CMM

- Como o interesse está nos pontos que são corretamente classificados, devemos ter $y_i f(\mathbf{x}_i) > 0$, $i = 1, \ldots, n$. Logo, a distância entre qualquer ponto $\mathbf{x}_i$ e o hiperplano é

$$\frac{y_i f(\mathbf{x}_i)}{||\boldsymbol{\beta}||} = \frac{y_i(\alpha + \boldsymbol{\beta}^\top \mathbf{x}_i)}{||\boldsymbol{\beta}||}. \tag{4}$$

- A margem é a distância do hiperplano ao ponto $\mathbf{x}$ mais próximo e queremos escolher α e $\boldsymbol{\beta}$ de modo a maximizar essa distância. A margem máxima é obtida por meio da resolução de

$$\text{argmax}_{\alpha,\boldsymbol{\beta}} \left\{ \frac{1}{||\boldsymbol{\beta}||} \min \left[y_i(\alpha + \boldsymbol{\beta}^\top \mathbf{x}_i) \right] \right\}. \tag{5}$$

- A solução de (5) é complicada mas é possível obtê-la por meio da utilização de Multiplicadores de Lagrange. Note que se multiplicarmos α e $\boldsymbol{\beta}$ por uma constante, a distância de um ponto $\mathbf{x}$ ao hiperplano separador não se altera.

Teora–CMM

- Logo podemos considerar a transformação $\alpha^* = \alpha/f(\mathbf{x})$ e $\boldsymbol{\beta}^* = \boldsymbol{\beta}/f(\mathbf{x})$ e para o ponto mais próximo do hiperplano, digamos $\mathbf{x}^*$, obtendo

$$y^*(\alpha + \boldsymbol{\beta}^\top \mathbf{x}^*) = 1, \tag{6}$$

  e consequentemente, $d = ||\boldsymbol{\beta}||^{-1}$.
- Desse modo, todos os pontos do conjunto de treinamento satisfarão

$$y_i(\alpha + \boldsymbol{\beta}^\top \mathbf{x}_i) \geq 1, \quad i = 1, \ldots, n. \tag{7}$$

  Esta relação é chamada representação canônica do hiperplano separador.
- Dizemos que há uma restrição ativa para os pontos em que há igualdade; para os pontos em que vale a desigualdade, dizemos que há uma restrição inativa. Como sempre haverá um ponto que está mais próximo do hiperplano, sempre haverá uma restrição ativa.

Teoria–CMM

- Então, o problema de otimização implica maximizar $||\boldsymbol{\beta}||^{-1}$, que é equivalente a minimizar $||\boldsymbol{\beta}||^2$.
- Na linguagem de Vapnik (1995), isso equivale a escolher $f(\mathbf{x})$ de maneira que seja a mais achatada (*flat*) possível, que por sua vez implica que $\boldsymbol{\beta}$ deve ser pequeno.
- Isso corresponde à resolução do problema de programação quadrática

$$\text{argmin}_{\alpha,\boldsymbol{\beta}} \left\{ \frac{1}{2}||\boldsymbol{\beta}||^2 \right\}, \tag{8}$$

sujeito a (7). O fator $1/2$ é introduzido por conveniência.

- Com esse objetivo, para cada restrição em (7), introduzimos os Multiplicadores de Lagrange $\lambda_i \geq 0$, obtendo a função lagrangeana

$$L(\alpha, \boldsymbol{\beta}, \boldsymbol{\lambda}) = \frac{1}{2} - \sum_{i=1}^{n} \lambda_i [y_i(\alpha + \boldsymbol{\beta}^\top \mathbf{x}_i) - 1], \tag{9}$$

em que $\boldsymbol{\lambda} = (\lambda_1, \ldots, \lambda_n)^\top$. O sinal negativo no segundo termo de (9) justifica-se por que queremos minimizar em relação a α e $\boldsymbol{\beta}$ e maximizar em relação a $\boldsymbol{\lambda}$.

Teoria–CMM

- Derivando L em relação a $\boldsymbol{\beta}$ e a $\boldsymbol{\lambda}$, obtemos

$$\boldsymbol{\beta} = \sum_{i=1}^{n} \lambda_i y_i \mathbf{x}_i \quad \text{e} \quad \sum_{i=1}^{n} \lambda_i y_i = 0. \tag{10}$$

- Eliminando α e $\boldsymbol{\beta}$ em (9) e usando (10), obtemos a chamada representação dual do problema da margem máxima, no qual maximizamos

$$\tilde{L}(\boldsymbol{\lambda}) = \sum_{i=1}^{n} \lambda_i - \frac{1}{2} \sum_{i=1}^{n} \sum_{j=1}^{n} \lambda_i \lambda_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j), \tag{11}$$

com respeito a $\boldsymbol{\lambda}$, sujeito às restrições

$$\lambda_i \geq 0, \quad i = 1, \ldots, n, \tag{12}$$

$$\sum_{i=1}^{b} \lambda_i y_i = 0. \tag{13}$$

- Em (11), $K(\mathbf{x}, \mathbf{y}) = \mathbf{x}^\top \mathbf{y}$ é um *kernel* linear, que será estendido para algum *kernel* mais geral com a finalidade de ser aplicado a espaços característicos cuja dimensionalidade excede o número de dados. Esse *kernel* deve ser positivo definido.

Teoria–CMM

- Para classificar um novo dado $\mathbf{x}_0$ usando o modelo treinado, avaliamos o sinal de $f(\mathbf{x}_0)$, que por meio de (10), pode ser escrito como

$$f(\mathbf{x}_0) = \alpha + \sum_{i=1}^{n} \lambda_i y_i K(\mathbf{x}_0, \mathbf{x}_i). \tag{14}$$

- Pode-se demonstrar (veja Bishop, 2006), que esse tipo de otimização restrita satisfaz certas condições, chamadas de condições de Karush-Kuhn-Tucker (KKT) que implicam

$$\begin{aligned} \lambda_i &\geq 0, \\ y_i f(\mathbf{x}_i) - 1 &\geq 0, \\ \lambda_i (y_i f(\mathbf{x}_i) - 1) &= 0. \end{aligned} \tag{15}$$

Teoria–CMM

- Para cada ponto, ou $\lambda_i = 0$ ou $y_i f(\mathbf{x}_i) = 1$. Um ponto para o qual $\lambda_i = 0$ não aparece em (14) não tem influência na classificação de novos pontos.
- Os pontos restantes são chamados vetores suporte e satisfazem $y_i f(\mathbf{x}_i) = 1$; logo esses pontos estão sobre as fronteiras do espaço separador, como na Figura 3 da Aula 9.
- O valor de α pode ser encontrado a partir de

$$y_i \left(\sum_{j \in S} \lambda_j y_j K(\mathbf{x}_j \mathbf{x}_j) + \alpha \right) = 1, \tag{16}$$

em que S é o conjunto dos vetores suporte.

- Multiplicando essa expressão por y_i, observando que $y_i^2 = 1$ e tomando a média de todas as equações sobre S, obtemos

$$\alpha = \frac{1}{n_S} \sum_{i \in S} \left(y_i - \sum_{j \in S} \lambda_i y_i K(\mathbf{x}_i, \mathbf{x}_j) \right), \tag{17}$$

em que n_S é o número de vetores suporte.

Teoria–CMF

- Vamos considerar agora, o caso em que as duas classes podem se sobrepor. Precisamos modificar o CMM para permitir que alguns pontos do conjunto de treinamento sejam classificados erroneamente. Para isso introduzimos uma penalidade, que cresce com a distância ao hiperplano separador.
- Isso é conseguido pela introdução de variáveis de folga (*slack*) $\xi_i \geq 0, i = 1, \ldots, n$, uma para cada dado.
- Então, $\xi_i = 0$ para pontos sobre ou dentro da fronteira correta [delimitada por $f(\mathbf{x}) = -1$ e $f(\mathbf{x}) = 1$] e ξ_i dado pela distância do ponto à fronteira, para os outros pontos.
- Assim, um ponto que estiver sobre o hiperplano $f(\mathbf{x}) = 0$ terá $\xi_i = 1$ e pontos com $\xi_i > 1$ são classificados erroneamente.
- Nesse caso, a restrição para o caso CMM será substituída por

$$y_i(\alpha + \boldsymbol{\beta}^\top \mathbf{x}_i) \geq 1 - \xi_i, \quad i = 1, \ldots, n, \tag{18}$$

com $\xi_i \geq 0$.

Teoria - CMF

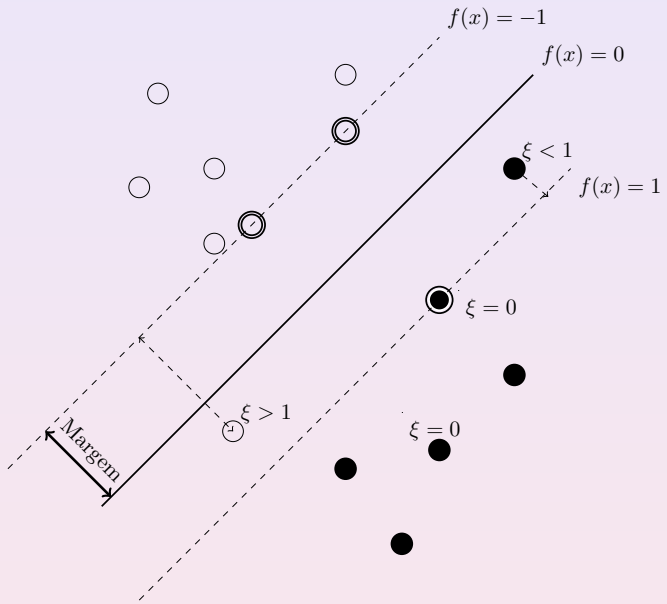


Figura: Detalhes sobre o classificador de margem flexível.

Teoria–CMF

- Pontos para os quais $0 < \xi_i \leq 1$ estão dentro da fronteira da margem, mas do lado correto do hiperplano, e pontos para os quais $\xi_i > 1$ estão do lado errado do hiperplano e são classificados erroneamente. Pontos para os quais $\xi_i = 0$ são corretamente classificados e estão sobre a fronteira da margem ou do lado correto da fronteira da margem.
- Nesse contexto, estamos diante de uma margem flexível ou suave. O objetivo é maximizar a margem e, para isso, minimizamos

$$C \sum_{i=1}^{n} \xi_i + \frac{1}{2} ||\beta||^2, \tag{19}$$

em que $C > 0$ controla o balanço entre a penalidade das variáveis de folga e a margem.

- Como qualquer ponto classificado erroneamente satisfaz $\xi_i > 1$, segue-se que $\sum_{i=1}^{n} \xi_i$ é um limite superior do número de classificações errôneas. No limite, quando $C \to \infty$, obtemos o CMM.

Teoria–CMF

- Para minimizar (19) sujeito a (18) e $\xi_i > 0$ consideramos o lagrangeano

$$L(\alpha, \boldsymbol{\beta}, \mathbf{x}_i, \boldsymbol{\lambda}, \boldsymbol{\mu}) = \frac{1}{2}||\boldsymbol{\beta}||^2 + C\sum_{i=1}^{n}\xi_i - \sum_{i=1}^{n}\lambda_i[y_i f(\mathbf{x}_i) + \xi_i - 1] - \sum_{i=1}^{n}\mu_i\xi_i, \tag{20}$$

  em quel $\lambda_i \geq 0, \mu_i \geq 0$ são multiplicadores de Lagrange.
- Derivando (21) com relação a $\boldsymbol{\beta}, \alpha, \xi_i$, obtemos

$$\boldsymbol{\beta} = \sum_{i=1}^{n}\lambda_i y_i \mathbf{x}_i, \quad \sum_{i=1}^{n}\lambda_i y_i = 0 \tag{21}$$

e

$$\lambda_i = C - \mu_i. \tag{22}$$

Teoria - CMF

- Substituindo (21) - (22) em (21), temos

$$\widetilde{L}(\boldsymbol{\lambda}) = \sum_{i=1}^{n} \lambda_i - \frac{1}{2} \sum_i \sum_j \lambda_i \lambda_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j), \tag{23}$$

que é uma expressão idêntica ao caso separável, com exceção das restrições, que são diferentes.

- Como $\lambda_i \geq 0$ são multiplicadores de Lagrange e como $\mu_i \geq 0$, de (22) segue que $\lambda_i \leq C$. Logo, precisamos maximizar (23) com respeito às variáveis duais λ_i, sujeito a

$$0 \leq \lambda_i \leq C, \tag{24}$$

$$\sum_{i=1}^{n} \lambda_i y_i = 0, \quad i = 1, \ldots, n. \tag{25}$$

- Novamente, estamos diante de um problema de programação quadrática.

Teoria - CMF

- A previsão para um novo ponto $\mathbf{x}$ é obtida avaliando o sinal de $f(\mathbf{x})$ na equação do hiperplano(eq. 3, Aula 9). Substituindo (21) nessa mesma equação, obtemos

$$f(\mathbf{x}) = \alpha + \sum_{i=1}^{n} \lambda_i y_i K(\mathbf{x}, \mathbf{x}_i). \tag{26}$$

- Dados para os quais $\lambda_i = 0$ não contribuem para (26). Os dados restantes formam os vetores de suporte. Para esses, $\lambda_i > 0$ e, por (28) abaixo, devem satisfazer

$$y_i f(\mathbf{x}_i) = 1 - \xi_i. \tag{27}$$

- No caso de CMF, as condições de KKT são dadas por

$$\lambda_i \geq 0, \quad y_i f(\mathbf{x}_i) - 1 + \xi_i \geq 0,$$

$$\lambda_i (y_i f(\mathbf{x}_i) - 1 + \xi_i) = 0, \tag{28}$$

$$\mu_i \geq 0, \quad \xi_i \geq 0,$$

$$\mu_i \xi_i = 0, \quad i = 1, \ldots, n. \tag{29}$$

Teoria - CMF

- Procedendo como no caso de CMM, obtemos

$$\alpha = \frac{1}{N_{\mathcal{M}}} \sum_{i \in \mathcal{M}} \left(y_i - \sum_{j \in S} \lambda_j y_j K(\mathbf{x}_i, \mathbf{x}_j) \right), \tag{30}$$

  em que $\mathcal{M}$ é o conjunto do pontos tais que $0 < \lambda_i < C$.
- Se $\lambda_i < C$, então, por (22), $\mu_i > 0$ e por (29), temos $\xi = 0$ e tais pontos estão na fronteira de separação. Pontos com $\lambda_i = C$ estão dentro da fronteira de separação e podem ser classificados corretamente se $\xi_i \leq 1$ e erroneamente se $\xi_i > 1$.

Teoria-CMNL

- Seja $\mathcal{X}$ o conjunto de dados (ou de padrões). A função $K : \mathcal{X} \times \mathcal{X} \to \mathbb{R}$ é um kernel se existir um espaço vetorial com produto interno, $\mathcal{H}$ (usualmente um espaço de Hilbert) e uma aplicação $\Phi : \mathcal{X} \to \mathcal{H}$, tal que, para todos $x, y \in \mathcal{X}$, tivermos

$$K(x, y) =< \Phi(x), \Phi(y) > . \tag{31}$$

  Φ é a aplicação característica e $\mathcal{H}$, o espaço característico.

- Por exemplo, tomemos $\mathcal{X} = \mathbb{R}^2$ e $\mathcal{H} = \mathbb{R}^3$ e definamos

$$\begin{aligned} \Phi : \mathbb{R}^2 &\to \mathbb{R}^3, \\ (x_1, x_2) &\to (x_1^2, x_2^2, \sqrt{2}x_1x_2). \end{aligned}$$

  Então, se $x = (x_1, x_2)$ e $y = (y_1, y_2)$, é fácil verificar que $< \Phi(x), \Phi(y) >=< x, y >$; logo $K(x, y) =< \Phi(x), \Phi(y) >=< x, y >$ é um *kernel*.

Teoria-CMNL

- Para tornar o algoritmo de suporte vetorial não linear, notamos que ele depende somente de produtos internos entre os vetores de $\mathcal{X}$; logo, é suficiente conhecer $K(\mathbf{x}, \mathbf{x}^\top) =< \Phi(\mathbf{x}), \Phi(\mathbf{x}^\top) >$, e não Φ explicitamente. Isso permite formular o problema de otimização, substituindo a derivada do Lagrangeano no caso de CMF por

$$\boldsymbol{\beta} = \sum_{i=1}^{n} \alpha_i \Phi(\mathbf{x}_i). \tag{32}$$

- Agora, $\boldsymbol{\beta}$ não é mais dado explicitamente como antes. Também, o problema de otimização é agora realizado no espaço característico e não em $\mathcal{X}$.
- Os *kernels* a serem usados têm que satisfazer certas condições de admissibilidade. Veja Smola e Schölkopf (2004) para detalhes. Os *kernels* mencionados anteriormente são admissíveis.

Regressão via SVM

- Dado um conjunto de treinamento, $\mathcal{T} = \{(\mathbf{x}_1, y_1), \ldots, (\mathbf{x}_n, y_n)\}$, o objetivo é obter uma função $f(\mathbf{x}_i)$, a mais achatada (*flat*) possível tal que $|y_i - f(\mathbf{x}_i)| < \epsilon$, $i = 1, \ldots, n$ em que $\epsilon > 0$ é o maior erro que estamos dispostos a cometer. Por exemplo, ϵ pode ser a máxima perda que admitimos ao negociar com ações dadas certas características obtidas do balanço de um conjunto de empresas.
- No caso de funções lineares, o objetivo é determinar α e $\boldsymbol{\beta}$ tais que $|f(\mathbf{x}_i)| = |\alpha + \boldsymbol{\beta}^\top \mathbf{x}_i| \leq \epsilon$. A condição de que $f(\mathbf{x})$ seja a mais achatada possível corresponde a que $\boldsymbol{\beta}$ seja pequeno, ou seja o problema a resolver pode ser expresso como

$$\text{minimizar } \frac{1}{2}||\boldsymbol{\beta}||^2 \text{ sujeito a } \begin{cases} y_i - \boldsymbol{\beta}^\top \mathbf{x}_i - \alpha \leq \epsilon, \\ \alpha + \boldsymbol{\beta}^\top \mathbf{x}_i - y_i \leq \epsilon \end{cases} . \tag{33}$$

Regressão via SVM

- Nem sempre as condições (33) podem ser satisfeitas e nesse caso, assim como nos modelos de classificação, podemos introduzir variáveis de folga ξ_i e ξ_i^*, $i = 1, \ldots, n$, que permitem flexibilizar a restrição de que o máximo erro permitido seja ϵ. O problema a resolver nesse contexto é

$$\text{minimizar } \frac{1}{2}||\boldsymbol{\beta}||^2 + \sum_{i=1}^{n} C(\xi + \xi^*) \text{ sujeito a } \begin{cases} y_i - \boldsymbol{\beta}^\top \mathbf{x}_i - \alpha \leq \epsilon + \xi_i, \\ \alpha + \boldsymbol{\beta}^\top \mathbf{x}_i - y_i \leq \epsilon + \xi_i^*, \\ \xi_i, \xi_i* > 0. \end{cases} \tag{34}$$

- A constante $C > 0$ determina um compromisso entre o achatamento da função f e o quanto estamos dispostos a tolerar erros com magnitude maior do que ϵ.

Regressão via SVM

- As soluções de (33) ou (34) podem ser encontradas mais facilmente usando a formulação dual (ver Nota de Capítulo 3). No caso de modelos lineares, a previsão para um elemento com valor das variáveis preditoras igual a $\mathbf{x}_0$ é obtida de

$$f(\mathbf{x}_0) = \sum_{i=1}^{n} \widehat{\boldsymbol{\lambda}}_i K(\mathbf{x}_0, \mathbf{x}_i) + \widehat{\alpha},$$

  em que $\widehat{\boldsymbol{\lambda}}_i$ são multiplicadores de Lagrange, $K(\mathbf{x}_0, \mathbf{x}_i)$ é um *kernel*, $\widehat{\alpha} = y_i - \varepsilon - \widehat{\boldsymbol{\beta}}^\top \mathbf{x}_i$ e $\widehat{\boldsymbol{\beta}} = \sum_{i=1}^{n} \widehat{\boldsymbol{\lambda}}_i \mathbf{x}_i$.
- Os vetores suporte são aqueles para os quais os multiplicadores de Lagrange $\widehat{\boldsymbol{\lambda}}_i$ são positivos.
- Se optarmos por um *kernel* linear, $K(\mathbf{x}, \mathbf{x}_i) =< \mathbf{x}_0, \mathbf{x}_i >$.

Regressão via SVM - Exemplo

Consideremos os dados de distancia com o objetivo de estudar a relação entre a distância com que motoristas conseguem distinguir um certo objeto e sua idade. O diagrama de dispersão e a reta de mínimos quadrados ajustada $(y = 174,2 - 1,0x)$ correspondentes estão apresentados na Figura 3.

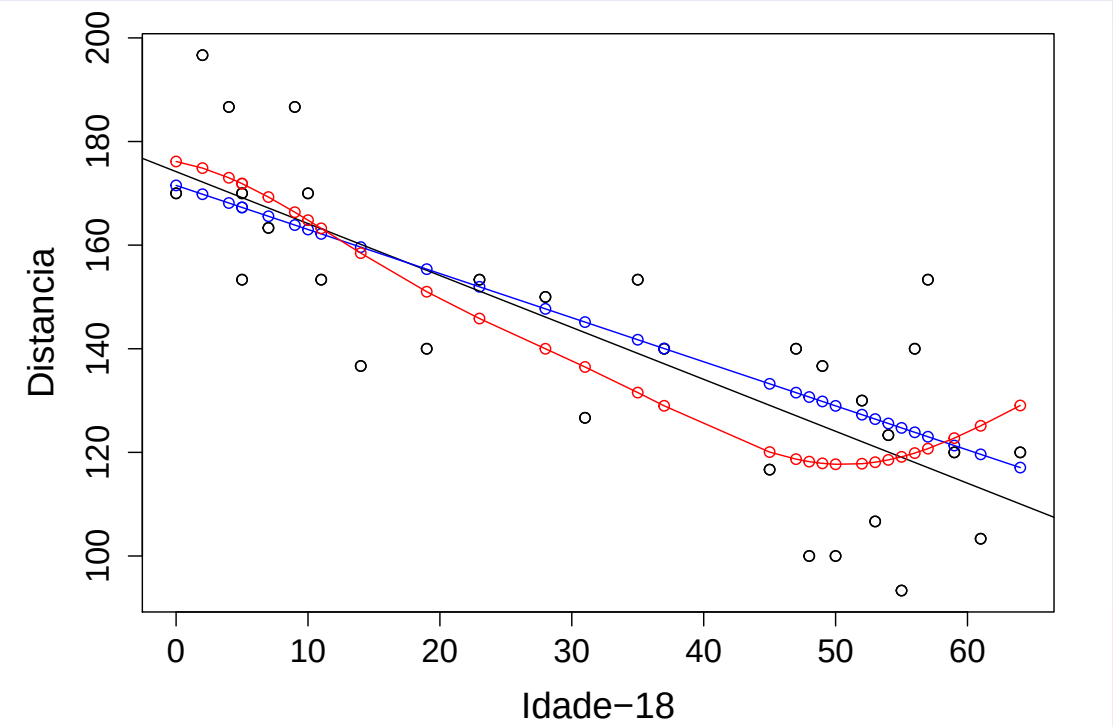


Figura 3: Regressão SVM para os dados de distância.

Regressão via SVM - Exemplo

O ajuste de uma regressão com suporte vetorial baseada num *kernel* linear com os parâmetros *default* pode ser obtido por meio dos comandos

```
model1<- svm(x, y, kernel="linear")
summary(model1)
Parameters:
   SVM-Type:  eps-regression
 SVM-Kernel:  linear
       cost:  1
      gamma:  1
    epsilon:  0.1
Number of Support Vectors:  23

betahat <- model1$rho
[1] -0.08572489
coef1 <- sum(model1$coefs*x[model1$index])
alfahat <- coef1/model1$rho
[1] 172.8264
```

de forma que a função previsora corresponde à $f(x) = 172,9 - 0,09x$.

Regressão via SVM - Exemplo

- A previsão para as distâncias segundo esse modelo pode ser obtida por meio do comando `yhat1 <- predict(model1, x)`. O *RMSE* correspondente pode ser obtido por meio do comando `rmse(yhat1, y)` é $16,51464$ (maior do que o *RMSE* associado ao ajuste por meio de mínimos quadrados, que é $16,02487$).
- Um modelo mais flexível pode ser ajustado com um *kernel* radial do tipo $K(\mathbf{x}_1, \mathbf{x}_2) = \exp\left(-\gamma||\mathbf{x}_1 - \mathbf{x}_2||^2\right)$ com $\gamma > 0$ constante. Nesse caso, convém realizar uma análise de sensibilidade com validação cruzada para a seleção da melhor combinação dos valores do máximo erro ϵ que estamos dispostos a cometer e do custo de penalização, C. Isso pode ser concretizado por meio dos comandos

```
sensib <- tune(svm, y ~ x,  ranges = list(epsilon = seq(0,1,0.1),
              cost = 2^(2:9)))
Parameter tuning of svm:
- sampling method: 10-fold cross validation
- best parameters:
 epsilon cost
     0.8    8
- best performance: 275.8086
```

Regressão via SVM - Exemplo

Com esses resultados, realizamos um ajuste por meio de um *kernel* radial com parâmetros $C = 8$ e $\epsilon = 0.8$, obtendo

```
model2 <- svm(x, y, kernel="radial", cost=8, epsilon=0.8)
summary(model2)
Parameters:
   SVM-Type:  eps-regression
 SVM-Kernel:  radial
       cost:  8
      gamma:  1
    epsilon:  0.8
Number of Support Vectors:  6
```

O *RMSE* para esse modelo é $15,84272$, menor do que aqueles obtidos por meio dos demais ajustes. Um gráfico com os ajustes por mínimos quadrados (em preto) e por regressões com suporte vetorial baseadas em *kernels* linear (em azul) e radial (em vermelho) está apresentado na Figura 3.

Regressão via SVM - Observações

- Algoritmos de suporte vetorial no contexto de regressão também podem ser utilizados com o mesmo propósito de suavização daquele concretizado pelo método **Lowess** (veja a Nota de Capítulo 2 do Capítulo 5).
- Nesse contexto, a suavidade do ajuste deve ser modulada pela escolha do parâmetro ϵ. Valores de ϵ pequenos (próximos de zero) geram curvas mais suaves e requerem muitos vetores suporte, podendo produzir sobreajuste. Valores de ϵ grandes (próximos de 1,0, por exemplo) geram curvas menos suaves e requerem menos vetores suporte.
- O parâmetro C tem influência no equilíbrio entre as magnitudes da margem e das variáveis de folga. Em geral, o valor desse parâmetro deve ser selecionado por meio de uma análise de sensibilidade concretizada por validação cruzada.

Referências

Morettin, P. A. e Singer, J. M. (2024). *Estatística e Ciência de Dados*. 2a. edição. LTC: Rio de Janeiro.

Smola, A. J. and Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, **14**, 199–222.

Vapnik, V. (1995). *The Nature of Statistical Learning Theory.* New York: Springer.

Vapnik, V. (1998). *Statistical Learning Theory*. New York: Wiley.