

Memórias Autossociativas de Projeção em Subespaço Baseadas em Máquinas de Vetores de Suporte

Emely Pujólli da Silva
Orientador: Prof. Dr. Marcos E. Valle

Universidade Estadual de Campinas
Instituto de Matemática, Matemática Aplicada e Computação Científica

Campinas, 23 de Abril de 2015

Memórias Associativas

Baseado na capacidade do cérebro humano em armazenar e recordar informações temos as **Memórias Associativas** - AM.

Memórias Associativas

Baseado na capacidade do cérebro humano em armazenar e recordar informações temos as **Memórias Associativas** - AM.

Assim uma memória associativa deve recuperar uma informação corrompida ou incompleta.

Memórias Associativas

Baseado na capacidade do cérebro humano em armazenar e recordar informações temos as **Memórias Associativas** - AM.

Assim uma memória associativa deve recuperar uma informação corrompida ou incompleta.

Exemplo

Escutamos: “É o amor”

Memórias Associativas

Baseado na capacidade do cérebro humano em armazenar e recordar informações temos as **Memórias Associativas** - AM.

Assim uma memória associativa deve recuperar uma informação corrompida ou incompleta.

Exemplo

Escutamos: “É o amor”

Associamos: “É o amooorrr que mexe com minha cabeça e me deixa assim...”

Formalmente temos

$$\mathcal{F} = \{(\mathbf{x}^\xi, \mathbf{y}^\xi) / \xi = 1, \dots, p\}$$

o conjunto de pares de vetores composto dos itens memorizados (padrão de entrada) e os itens lembrados (padrão de saída) é chamado o **conjunto das memórias fundamentais**

Formalmente temos

$$\mathcal{F} = \{(\mathbf{x}^\xi, \mathbf{y}^\xi) / \xi = 1, \dots, p\}$$

o conjunto de pares de vetores composto dos itens memorizados (padrão de entrada) e os itens lembrados (padrão de saída) é chamado o **conjunto das memórias fundamentais**

Uma memória associativa corresponde à uma aplicação \mathcal{M} de A em B espaços vetoriais, tal que

$$\mathcal{M}(\mathbf{x}^\xi) \approx \mathbf{y}^\xi$$

$$\mathcal{M}(\hat{\mathbf{x}}^\xi) \approx \mathbf{y}^\xi$$

para $\hat{\mathbf{x}}^\xi$ versão ruidosa de \mathbf{x}^ξ .

Podemos classificar uma memória associativa por:

Podemos classificar uma memória associativa por:

- heteroassociativa quando $\mathbf{y}^\xi \neq \mathbf{x}^\xi$ ou

Podemos classificar uma memória associativa por:

- heteroassociativa quando $\mathbf{y}^\xi \neq \mathbf{x}^\xi$ ou
- autoassociativa quando $\mathbf{y}^\xi = \mathbf{x}^\xi$.

Memória Autoassociativa

Seja o conjunto das memórias fundamentais da forma

$$\mathcal{F} = \{\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^p\}$$

onde os vetores $\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^p \in \mathbb{R}^n$ são chamados **memórias fundamentais**, e são linearmente independentes.

Memória Autoassociativa

Seja o conjunto das memórias fundamentais da forma

$$\mathcal{F} = \{\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^p\}$$

onde os vetores $\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^p \in \mathbb{R}^n$ são chamados **memórias fundamentais**, e são linearmente independentes.

Então buscamos uma aplicação $\mathcal{M} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ que satisfaça

$$\mathcal{M}(\mathbf{x}^\xi) = \mathbf{x}^\xi$$

$$\mathcal{M}(\hat{\mathbf{x}}^\xi) = \mathbf{x}^\xi$$

para $\hat{\mathbf{x}}^\xi$ versão ruidosa de \mathbf{x}^ξ .

Definição

Seja

$$\mathcal{S} = \{\mathbf{s} \in \mathbb{R}^n; \mathcal{M}(\mathbf{s}) = \mathbf{s}\}$$

o conjunto dos pontos fixos da aplicação \mathcal{M} . Uma memória associativa $\mathcal{M} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ é uma memória autoassociativa de projeção (PAM) se

$$\mathcal{M}(\mathbf{x}) \in \mathcal{S} \text{ e } d(\mathbf{x}, \mathcal{M}(\mathbf{x})) \leq d(\mathbf{x}, \mathbf{s}), \quad \forall \mathbf{s} \in \mathcal{S} \quad (1)$$

com d uma certa medida de distância em \mathbb{R}^n .

Definição

Seja

$$\mathcal{S} = \{\mathbf{s} \in \mathbb{R}^n; \mathcal{M}(\mathbf{s}) = \mathbf{s}\}$$

o conjunto dos pontos fixos da aplicação \mathcal{M} . Uma memória associativa $\mathcal{M} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ é uma memória autoassociativa de projeção (PAM) se

$$\mathcal{M}(\mathbf{x}) \in \mathcal{S} \text{ e } d(\mathbf{x}, \mathcal{M}(\mathbf{x})) \leq d(\mathbf{x}, \mathbf{s}), \quad \forall \mathbf{s} \in \mathcal{S} \quad (1)$$

com d uma certa medida de distância em \mathbb{R}^n .

Definição

Se $\mathcal{M} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ é uma memória autoassociativa de projeção e \mathcal{S} subespaço de \mathbb{R}^n , então dizemos que \mathcal{M} é uma memória autoassociativa de projeção em subespaço (SPAM).

Definição

Seja

$$\mathcal{S} = \{\mathbf{s} \in \mathbb{R}^n; \mathcal{M}(\mathbf{s}) = \mathbf{s}\}$$

o conjunto dos pontos fixos da aplicação \mathcal{M} . Uma memória associativa $\mathcal{M} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ é uma memória autoassociativa de projeção (PAM) se

$$\mathcal{M}(\mathbf{x}) \in \mathcal{S} \text{ e } d(\mathbf{x}, \mathcal{M}(\mathbf{x})) \leq d(\mathbf{x}, \mathbf{s}), \quad \forall \mathbf{s} \in \mathcal{S} \quad (1)$$

com d uma certa medida de distância em \mathbb{R}^n .

Definição

Se $\mathcal{M} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ é uma memória autoassociativa de projeção e \mathcal{S} subespaço de \mathbb{R}^n , então dizemos que \mathcal{M} é uma memória autoassociativa de projeção em subespaço (SPAM).

Note que $\mathfrak{F} \subseteq \mathcal{S}$ para uma memória autoassociativa.

Vamos estudar algumas memórias, para isso faremos a seguinte hipótese:

Vamos estudar algumas memórias, para isso faremos a seguinte hipótese:

Suponhamos \mathcal{S} o subespaço gerado pelas memórias fundamentais, isto é $\mathcal{S} = [\mathfrak{F}]$.

Vamos estudar algumas memórias, para isso faremos a seguinte hipótese:

Suponhamos \mathcal{S} o subespaço gerado pelas memórias fundamentais, isto é $\mathcal{S} = [\mathfrak{F}]$.

Dado o padrão de entrada $\mathbf{x} \in \mathbb{R}^n$ sua saída $\mathcal{M}(\mathbf{x}) \in \mathcal{S}$ é combinação linear dos elementos de \mathfrak{F} isto é, existem $\alpha_1, \alpha_2, \dots, \alpha_p \in \mathbb{R}$ escalares tais que

$$\mathcal{M}(\mathbf{x}) = \alpha_1 \mathbf{x}^1 + \alpha_2 \mathbf{x}^2 + \dots + \alpha_p \mathbf{x}^p$$

Uma maneira de descrever esse problema é como um problema de minimização

$$\min_{\alpha \in \mathbb{R}^p} d(\mathbf{x}, X\alpha).$$

Uma maneira de descrever esse problema é como um problema de minimização

$$\min_{\alpha \in \mathbb{R}^p} d(\mathbf{x}, X\alpha).$$

Em forma matricial

$$\mathbf{x} \approx X\alpha$$

com $X = [\mathbf{x}^1, \dots, \mathbf{x}^p] \in \mathbb{R}^{n \times p}$ a matriz de posto completo denominada *matriz das memórias fundamentais* e $\alpha = [\alpha_1, \dots, \alpha_p]$ o vetor dos coeficientes.

Em um problema de Regressão Multilinear procuramos estimar $f : \mathcal{X} \rightarrow \mathcal{Y}$ no ponto x dado a observação y , ou seja $y \approx f(x)$.

Estimadores de Regressão

Em um problema de Regressão Multilinear procuramos estimar $f : \mathcal{X} \rightarrow \mathcal{Y}$ no ponto x dado a observação y , ou seja $y \approx f(x)$.

Em outras palavras, buscamos $f(x)$ de modo que o erro ε na expressão

$$y = f(x) + \varepsilon \quad (2)$$

se torne o menor possível.

Estimadores de Regressão

Em um problema de Regressão Multilinear procuramos estimar $f : \mathcal{X} \rightarrow \mathcal{Y}$ no ponto x dado a observação y , ou seja $y \approx f(x)$.

Em outras palavras, buscamos $f(x)$ de modo que o erro ε na expressão

$$y = f(x) + \varepsilon \quad (2)$$

se torne o menor possível.

Uma maneira de resolver (2) é utilizar uma função perda para descrever quanto o erro irá influenciar na estimativa de $f(x)$.

Definição

Denote por $(x, y, f(x)) \in \mathcal{X} \times \mathcal{Y} \times \mathcal{Y}$ a tripla consistindo do padrão x , uma observação y e uma previsão $f(x)$. Então a aplicação $\rho : \mathcal{X} \times \mathcal{Y} \times \mathcal{Y} \rightarrow [0, \infty)$ com a propriedade $\rho(x, y, y) = 0$ para todo $x \in \mathcal{X}$ e $y \in \mathcal{Y}$ é chamada de função perda.

Definição

Denote por $(x, y, f(x)) \in \mathcal{X} \times \mathcal{Y} \times \mathcal{Y}$ a tripla consistindo do padrão x , uma observação y e uma previsão $f(x)$. Então a aplicação $\rho : \mathcal{X} \times \mathcal{Y} \times \mathcal{Y} \rightarrow [0, \infty)$ com a propriedade $\rho(x, y, y) = 0$ para todo $x \in \mathcal{X}$ e $y \in \mathcal{Y}$ é chamada de função perda.

Os algoritmos de regressão são estruturados de acordo com o risco. Ou seja, a solução do problema é encontrada minimizando alguma forma do funcional risco.

Definição

Denote por $(x, y, f(x)) \in \mathcal{X} \times \mathcal{Y} \times \mathcal{Y}$ a tripla consistindo do padrão x , uma observação y e uma previsão $f(x)$. Então a aplicação $\rho : \mathcal{X} \times \mathcal{Y} \times \mathcal{Y} \rightarrow [0, \infty)$ com a propriedade $\rho(x, y, y) = 0$ para todo $x \in \mathcal{X}$ e $y \in \mathcal{Y}$ é chamada de função perda.

Os algoritmos de regressão são estruturados de acordo com o risco. Ou seja, a solução do problema é encontrada minimizando alguma forma do funcional risco. Estimadores minimizam o risco empírico.

Definição

Denote por $(x, y, f(x)) \in \mathcal{X} \times \mathcal{Y} \times \mathcal{Y}$ a tripla consistindo do padrão x , uma observação y e uma previsão $f(x)$. Então a aplicação $\rho : \mathcal{X} \times \mathcal{Y} \times \mathcal{Y} \rightarrow [0, \infty)$ com a propriedade $\rho(x, y, y) = 0$ para todo $x \in \mathcal{X}$ e $y \in \mathcal{Y}$ é chamada de função perda.

Os algoritmos de regressão são estruturados de acordo com o risco. Ou seja, a solução do problema é encontrada minimizando alguma forma do funcional risco. Estimadores minimizam o risco empírico.

Definição

O risco empírico é definido como

$$R_{emp}[f] = \frac{1}{n} \sum_{i=1}^n \rho(x_i, y_i, f(x_i))$$

No caso da regressão, a função perda toma a forma particular

$$\rho(x, y, f(x)) = \tilde{\rho}(f(x) - y)$$

com $\tilde{\rho} : \mathbb{R} \rightarrow [0, \infty)$.

No caso da regressão, a função perda toma a forma particular

$$\rho(x, y, f(x)) = \tilde{\rho}(f(x) - y)$$

com $\tilde{\rho} : \mathbb{R} \rightarrow [0, \infty)$.

Então um Estimador de regressão resolve o seguinte problema

$$\min \sum_{i=1}^n \rho(f(x_i) - y_i).$$

No caso da regressão, a função perda toma a forma particular

$$\rho(x, y, f(x)) = \tilde{\rho}(f(x) - y)$$

com $\tilde{\rho} : \mathbb{R} \rightarrow [0, \infty)$.

Então um Estimador de regressão resolve o seguinte problema


$$\min \sum_{i=1}^n \rho(f(x_i) - y_i).$$

Cada estimador resolve o problema de regressão colocando hipóteses sobre a função perda ρ .

Exemplos de funções perda


Perda Quadrada

$$\rho_Q(u) = (u)^2$$




Função perda de Tukey

$$\rho_T(u) = \begin{cases} \frac{u^2}{2} - \frac{u^4}{2k^2} + \frac{u^6}{6k^4} & \text{se } |u| \leq k \\ \frac{u^2}{6} & \text{se } |u| > k \end{cases}$$



Função perda ε -insensível

$$\rho_\varepsilon(u) = \begin{cases} |u| - \varepsilon & \text{se } |u| \geq \varepsilon \\ 0 & \text{c. c.} \end{cases}$$



Colocando em termos das memórias autoassociativas

$$\arg \min_{\alpha \in \mathbb{R}^p} \sum_{i=1}^n \rho \left(\sum_{j=1}^p X_{ij} \alpha_j - x_i \right)$$

Resolver o problema de regressão com estimadores, resulta na solução do problema de memórias autoassociativas com a hipótese de que \mathcal{S} é subespaço gerado pelas memórias fundamentais.

Seja o caso em que $\rho(u) = u^2$ ou seja, a função perda toma a forma da métrica euclideana

$$\alpha^* = \arg \min_{\alpha \in \mathbb{R}^p} \|\mathbf{x} - X\alpha\|_2$$

que é o problema de quadrados mínimos, cuja a solução de norma mínima pode ser obtido por

$$\alpha^* = X^\dagger \mathbf{x}$$

onde X^\dagger representa a pseudo-inversa de X .

O padrão pode ser recuperado utilizando a expressão

$$\mathcal{M}(\mathbf{x}) = X\alpha^*$$

Este é o modelo introduzido por Kohonen e Ruohonen, chamado **Memória Associativa Linear Ótima** - OLAM.

O padrão pode ser recuperado utilizando a expressão

$$\mathcal{M}(\mathbf{x}) = X\alpha^*$$

Este é o modelo introduzido por Kohonen e Ruohonen, chamado **Memória Associativa Linear Ótima** - OLAM.

Ainda, $\mathcal{M}(\mathbf{x}) = M_0\mathbf{x}$ com $M_0 = XX^\dagger$ chamada matriz peso sináptico, o que faz da aplicação \mathcal{M} linear.

Apesar da simplicidade da solução de quadrados mínimos esta tem sido criticada por sua falta de robustez, ou seja, insensibilidade à pequenas variações nas hipóteses.

ε —Regressão de Vetor de Suporte

Apesar da simplicidade da solução de quadrados mínimos esta tem sido criticada por sua falta de robustez, ou seja, insensibilidade à pequenas variações nas hipóteses.

Uma melhora pode ser obtida ao substituir a aproximação de quadrados mínimos por um estimador robusto e elegante para o problema de regressão multilinear $X\alpha \approx \mathbf{x}$.

ε –Regressão de Vetor de Suporte

Apesar da simplicidade da solução de quadrados mínimos esta tem sido criticada por sua falta de robusteza, ou seja, insensibilidade à pequenas variações nas hipóteses.

Uma melhora pode ser obtida ao substituir a aproximação de quadrados mínimos por um estimador robusto e elegante para o problema de regressão multilinear $X\alpha \approx \mathbf{x}$.

A ε –regressão de vetor de suporte tem como objetivo encontrar o α tal que $X\alpha$ tenha no máximo ε de diferença do padrão desejado \mathbf{x} e ao mesmo tempo, ser o mais plana possível.

ε –Regressão de Vetor de Suporte

Apesar da simplicidade da solução de quadrados mínimos esta tem sido criticada por sua falta de robustez, ou seja, insensibilidade à pequenas variações nas hipóteses.

Uma melhora pode ser obtida ao substituir a aproximação de quadrados mínimos por um estimador robusto e elegante para o problema de regressão multilinear $X\alpha \approx \mathbf{x}$.

A ε –regressão de vetor de suporte tem como objetivo encontrar o α tal que $X\alpha$ tenha no máximo ε de diferença do padrão desejado \mathbf{x} e ao mesmo tempo, ser o mais plana possível.

A planitude neste caso, significa que procuramos um α com magnitude pequena.

O funcional risco tem a forma

$$R[\boldsymbol{\alpha}; X, \mathbf{x}] = \frac{1}{2} \|\boldsymbol{\alpha}\|^2 + C \sum_{i=1}^n \rho_{\varepsilon} \left(\sum_{j=1}^p X_{ij} \alpha_j - x_i \right) \quad (3)$$

onde $C > 0$ é a constante que determina a troca entra a planitude e a quantidade de desvios maiores que ε são permitidos.

O funcional risco tem a forma

$$R[\boldsymbol{\alpha}; X, \mathbf{x}] = \frac{1}{2} \|\boldsymbol{\alpha}\|^2 + C \sum_{i=1}^n \rho_{\epsilon} \left(\sum_{j=1}^p X_{ij} \alpha_j - x_i \right) \quad (3)$$

onde $C > 0$ é a constante que determina a troca entre a planitude e a quantidade de desvios maiores que ϵ são permitidos.

Para minimizar o risco (3) colocamos na forma de um problema de otimização convexa, e para permitir alguns erros incluímos variáveis de folga.

O funcional risco tem a forma

$$R[\alpha; X, \mathbf{x}] = \frac{1}{2} \|\alpha\|^2 + C \sum_{i=1}^n \rho_{\epsilon} \left(\sum_{j=1}^p X_{ij} \alpha_j - x_i \right) \quad (3)$$

onde $C > 0$ é a constante que determina a troca entre a planitude e a quantidade de desvios maiores que ϵ são permitidos.

Para minimizar o risco (3) colocamos na forma de um problema de otimização convexa, e para permitir alguns erros incluímos variáveis de folga.

$$\begin{aligned} \text{minimizar} \quad & \frac{1}{2} \|\alpha\|^2 + C \sum_{i=1}^n (\xi_i^+ + \xi_i^-) \\ \text{sujeito à} \quad & \mathbf{x} - X\alpha \leq \epsilon + \boldsymbol{\xi}^+ \\ & X\alpha - \mathbf{x} \leq \epsilon + \boldsymbol{\xi}^- \\ & \boldsymbol{\xi}^+, \boldsymbol{\xi}^- \geq 0 \end{aligned} \quad (4)$$

Muitas vezes, o problema (4) é mais fácil ser resolvido na sua forma dual. A idéia é contruir a Função de Lagrange utilizando a função objetivo e colocando pesos nas restrições. Assim

Muitas vezes, o problema (4) é mais fácil ser resolvido na sua forma dual. A idéia é contruir a Função de Lagrange utilizando a função objetivo e colocando pesos nas restrições. Assim

$$\begin{aligned}
 L(\boldsymbol{\alpha}, \lambda^+, \lambda^-, \eta^+, \eta^-) &= \frac{1}{2} \sum_{j=1}^p \alpha_j^2 + C \sum_{i=1}^n (\xi_i^+ + \xi_i^-) \\
 &\quad - \sum_{i=1}^n \lambda_i^+ (\varepsilon - y_i + \xi_i^+ + \sum_{j=1}^p X_{ij} \alpha_j) \\
 &\quad - \sum_{i=1}^n \lambda_i^- (\varepsilon + y_i + \xi_i^- - \sum_{j=1}^p X_{ij} \alpha_j) \\
 &\quad - \sum_{i=1}^n (\eta_i^+ \xi_i^+ + \eta_i^- \xi_i^-)
 \end{aligned} \tag{5}$$

Aqui $\lambda^-, \lambda^+, \eta^-, \eta^+ \geq 0$ são os multiplicadores de Lagrange.

É possível verificar que essa função tem ponto de sela com respeito às variáveis primais e duais na solução (SMOLA, SCHOLKOPF).

É possível verificar que essa função tem ponto de sela com respeito às variáveis primais e duais na solução (SMOLA, SCHOLKOPF).

Derivamos a função de Lagrange com respeito à α_k , ξ^+ e ξ^- , obtendo as expressões

$$\alpha_k = \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) X_{ik}$$
$$\eta_k^+ = C - \lambda_k^+$$
$$\eta_k^- = C - \lambda_k^-$$

E das duas últimas expressões, obtemos ainda

$$C - \lambda_k^+ = \eta_k^+ \geq 0 \Leftrightarrow \lambda_k^+ \leq C$$
$$C - \lambda_k^- = \eta_k^- \geq 0 \Leftrightarrow \lambda_k^- \leq C, \quad \forall k = 1, \dots, n.$$

Encontramos o seguinte problema dual

$$\begin{aligned} \text{Maximizar} \quad & -\frac{1}{2} \sum_{j=1}^p \left[\sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) X_{ij} \right]^2 \\ & - \sum_{i=1}^n (\lambda_i^+ + \lambda_i^-) \varepsilon + \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) y_i \\ \text{sujeito à} \quad & 0 \leq \boldsymbol{\lambda}^+ \leq \mathbf{C} \\ & 0 \leq \boldsymbol{\lambda}^- \leq \mathbf{C} \end{aligned} \tag{6}$$

É a solução do problema

$$\alpha^* = X^T(\lambda^+ - \lambda^-)$$

conhecida como expansão do vetor de suporte e determina a estimativa α^* em função dos multiplicadores de Lagrange.

É a solução do problema

$$\boldsymbol{\alpha}^* = \mathbf{X}^T (\boldsymbol{\lambda}^+ - \boldsymbol{\lambda}^-)$$

conhecida como expansão do vetor de suporte e determina a estimativa $\boldsymbol{\alpha}^*$ em função dos multiplicadores de Lagrange.

Dessa maneira o padrão recordado toma a forma

$$\mathcal{M}(\mathbf{x}) = \mathbf{X}\boldsymbol{\alpha}^*$$

Próxima apresentação...

Obrigada!