

LABIC

## Redes Auto-organizáveis

---

SCE 5809 REDES NEURAIS

Profa. Roseli Romero  
2o. Semestre de 2010

PARTE I

Redes Neurais/2010

RAFR 1

LABIC

## PCA

---

- **Objetivo:** Dadas  $p$  variáveis,  
 $X_1, X_2, \dots, X_p$
- deseja-se achar combinações lineares dessas, para produzir índices que sejam não correlacionados, de tal forma que:
- Índices  $Z$ : componentes principais.

Redes Neurais/2010

RAFR 2

LABIC

## PCA

---

i-esima componente principal

$$Z_i = a_{i1}X_1 + a_{i2}X_2 + \dots + a_{ip}X_p$$

Com restrição:  $a_{i1}^2 + a_{i2}^2 + \dots + a_{ip}^2 = 1$

$Z_1, Z_2, \dots, Z_{i-1}, Z_i$  Não correlacionados

Redes Neurais/2010

RAFR 3

LABIC

## PCA

---

- ♦ PCA: resume-se em encontrar os autovalores e autovetores da matriz  $C$  de covariância dos dados
- ♦  $C = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1p} \\ c_{21} & c_{22} & \dots & c_{2p} \\ \vdots & \vdots & & \vdots \\ c_{p1} & c_{p2} & \dots & c_{pp} \end{bmatrix}$

Redes Neurais/2010

RAFR 4

LABIC

## PCA

---

- $\lambda$  é auto-valor de  $A$  se e somente se existe um vetor não nulo  $v$ , tal que  $A v = \lambda v$ .
- Todo vetor que satisfaça a essa condição é um auto-vetor.
- $P(\lambda) = |A - \lambda I|$  que é um polinômio de grau  $n$  em  $\lambda$  é chamado polinômio característico da matriz <sup>a</sup>

Redes Neurais/2010

RAFR 5

LABIC

## PCA

---

- Supondo que: os autovalores da matriz  $C$  estejam ordenados da seguinte forma:  
 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_j \geq \dots \geq \lambda_p$
- Os auto-vetores associados:  
 $a_1, a_2, \dots, a_j, \dots, a_p$

Redes Neurais/2010

RAFR 6

LABIC

## PCA

■ Propriedades

■ Para  $a_i^T a_j = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases}$

$$Z_i = a_{i1}X_1 + a_{i2}X_2 + \dots + a_{ip}X_p$$

■  $a_{j1}, a_{j2}, \dots, a_{jp}$  são os elementos do  $i$ -ésimo autovetor correspondente

Redes Neurais/2010

7

LABIC

## PCA

■ a soma dos auto-valores corresponde ao **traco da matriz covariância C**

$$\lambda_1 + \lambda_2 + \dots + \lambda_p = c_{11} + c_{22} + \dots + c_{pp}$$

■  $\text{var}(Z_1) \geq \text{var}(Z_2) \geq \dots \geq \text{var}(Z_p)$

$$\text{var}(Z_i) = \lambda_i$$

Redes Neurais/2010

8

LABIC

## Exemplo- conj. Iris.dat

Componente	Autovalor	Autovetores (coeficientes)			
		X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>
1	2.91082	0.522371	-0.263356	0.581254	0.565611
2	0.92122	0.372320	0.925556	0.021094	0.065417
3	0.14735	-0.721015	0.242033	0.140889	0.633804
4	0.02061	-0.261998	0.124137	0.801155	-0.523541

Redes Neurais/2010

9

LABIC

## PCA

■ Conclusões:

- Z1 é responsável por 72.77% do total da variância.
- Z2 é responsável por 23.03% do total da variância.
- Z3 é responsável por 3.68% do total da variância.
- Z4 é responsável por 0.52% do total da variância.

Redes Neurais/2010

10

LABIC

## PCA

Redes Neurais/2010

11

LABIC

## Reconstrucao dos dados originais

$$Z = [Z_1, Z_2, \dots, Z_p]^T$$

$$= [X^T a_1, X^T a_2, \dots, X^T a_{p-1}]^T$$

$$= A^T X$$

$$X = A Z = \sum_{i=1}^p Z_i a_i \quad A^T = A^{-1}$$

Redes Neurais/2010

12

LABIC

## Reducao da Dimensionalidade

- Sejam  $\lambda_1, \lambda_2, \dots, \lambda_m$
- os m auto-valores da matriz C
- Entao  $X' \sim X$  onde:
 
$$X' = \sum_{i=1}^m Z_i a_i \quad m < p$$
- o erro:  $e = X - X'$  onde:
 
$$e = \sum_{i=m+1}^p Z_i a_i$$

RAFR Redes Neurais/2010 13

LABIC

- O vetor de erro  $e$  é ortogonal ao vetor  $X'$ , que aproxima X.  
Verifique isto!!!  
A equação:  $e^T X' = 0$  : princípio da ortogonalidade
- Existe uma rede neural que implementa PCA, proposta por RUBNER-89.

RAFR Redes Neurais/2010 14

LABIC

## PCA – Conceitos Básicos

- Polinômio Característico  
 $P(\lambda) = \det(A - \lambda I) = 0$

porque  $Av = \lambda v \Rightarrow (A - \lambda I)v = 0 \Rightarrow$   
 se  $v$  não nulo  $\Rightarrow \det(A - \lambda I) = 0$

RAFR Redes Neurais/2010 15

LABIC

## Exemplo:

- Determinar os auto-valores e auto-vetores de:
 
$$A = \begin{pmatrix} 2 & 1 \\ 1 & 2 \end{pmatrix}$$

$$\det(A - \lambda I) = \begin{vmatrix} 2-\lambda & 1 \\ 1 & 2-\lambda \end{vmatrix} = (2-\lambda)^2 - 3 = 0$$
- Sol:  $\lambda_1=3$  e  $\lambda_2=1$

RAFR Redes Neurais/2010 16

LABIC

## Exemplo

- Determinar o auto-vetor assoc. a  $\lambda_1=3$ 

$$-v_1 + v_2 = 0$$

$$v_1 - v_2 = 0$$
 Sol:  $v_1 = v_2$

Portanto  $v = [1 \ 1]^T$   
 Analogamente,  $v = [1 \ -1]^T$  para  $\lambda_2=1$

RAFR Redes Neurais/2010 17

LABIC

## Aplicacao

- Taxas de Compressão para Blocos 8x8

Número de Componentes Principais	Dimensão do Bloco Compactado	Taxa de Compressão
1	8x1	$1 - (1/8) = 87.5\%$
2	8x2	$1 - (2/8) = 75\%$
3	8x3	$1 - (3/8) = 62.5\%$
4	8x4	$1 - (4/8) = 50\%$

RAFR Redes Neurais/2010 18

LABIC

## Aplicação

- **Taxas de Compressão para Blocos 16x16**

Número de Componentes Principais	Dimensão do Bloco Compactado	Taxa de Compressão
1	16x1	$1 - (1/16) = 93,75\%$
2	16x2	$1 - (2/16) = 87,5\%$

RAFR Redes Neurais/2010 19

LABIC

## Operações em PCA

- Det. dos auto-valores e auto-vetores: cálculo do determinante e sol. de um sistema de eq. lineares.

RAFR Redes Neurais/2010 20

LABIC

## Exercicio

- Implementar a técnica PCA (use o Matlab ou algum pacote estatístico, ou 1 ling. de progr.) e verifique as 2 comp. Principais obtidas para o conj. iris

RAFR Redes Neurais/2010 21

LABIC

## Reconstrução dos dados originais

$$Z = [Z_1, Z_2, \dots, Z_p]^T$$

$$= [X^T a_1, X^T a_2, \dots, X^T a_{p-1}]^T$$

$$= A^T X$$

$$X = A Z = \sum_{i=1}^p Z_i a_i \quad A^T = A^{-1}$$

RAFR Redes Neurais/2010 22

LABIC

## Redução da Dimensionalidade

- Sejam  $\lambda_1, \lambda_2, \dots, \lambda_m$
- os m auto-valores da matriz C
- Entao  $X' \sim X$  onde:
 
$$X' = \sum_{i=1}^m Z_i a_i \quad m < p$$
- o erro:  $e = X - X'$  onde:
 
$$e = \sum_{i=m+1}^p Z_i a_i$$

RAFR Redes Neurais/2010 23

LABIC

- O vetor de erro  $e$  é ortogonal ao vetor  $X'$ , que aproxima X. Verifique isto!!!  
A equação:  $e^T X' = 0$ : princípio da ortogonalidade
- Existe uma rede neural que implementa PCA, proposta por RUBN-89 (vamos ver!!!)

RAFR Redes Neurais/2010 24

LABIC

## • Algoritmo da PCA

1. Padronize os dados correspondentes às variáveis para que estes tenham média igual a 0 e variância igual a 1.
2. Calcule a matriz de covariância  $C$ .
3. Encontre os autovalores da matriz  $C$  e seus correspondentes auto-vetores. Os coeficientes da  $i$ -ésima componente principal são dados pelo auto-vetor associado ao  $i$ -ésimo auto-valor

RAFR Redes Neurais/2010 25

LABIC

4. Descarte as componentes que acumulem uma pequena proporção da variação dos dados. Por exemplo, se os dados originais tiverem 20 variáveis e as três primeiras componentes principais forem responsáveis por 90% do total da variância, as outras 17 componentes principais podem ser ignoradas.

RAFR Redes Neurais/2010 26

LABIC

## Aplicação

### ■ Taxas de Compressão para Blocos 8x8

Número de Componentes Principais	Dimensão do Bloco Compactado	Taxa de Compressão
1	8x1	$1 - \left(\frac{1}{8}\right) = 87,5\%$
2	8x2	$1 - \left(\frac{2}{8}\right) = 75\%$
3	8x3	$1 - \left(\frac{3}{8}\right) = 62,5\%$
4	8x4	$1 - \left(\frac{4}{8}\right) = 50\%$

RAFR Redes Neurais/2010 27

LABIC

## Aplicação

### ■ Taxas de Compressão para Blocos 16x16

Número de Componentes Principais	Dimensão do Bloco Compactado	Taxa de Compressão
1	16x1	$1 - \left(\frac{1}{16}\right) = 93,75\%$
2	16x2	$1 - \left(\frac{2}{16}\right) = 87,5\%$

RAFR Redes Neurais/2010 28

LABIC

## Algoritmo PCA - Matlab

```

%%%
% Componentes Principais
% PCA - Roseli Romero
% carregamento do arquivo iris.dat
load iris;
% verificando a dimensão do conjunto
[n,p] = size(iris);
% tirando a primeira coluna da matriz de dados
iris(:,1)=[];
p=p-1;
X = iris; % matriz X contem os dados
% centrando os dados na media 0
S = std(X); % S armazena os desvios-padrao de cada coluna de X
M = mean(X); % M armazena as medias de cada coluna de X
X = X - ones(n,1) * M;
% transformando os dados para ter variancia 1
X = X ./ (ones(n,1) * S);
% calculando a matriz de covariancia C
C = (X'*X)/n;
% auto-valoros (A) e auto-vetores (V) da matriz de covariancia
[V,A] = eig(C);
A = diag(A);

```

RAFR Redes Neurais/2010 29

LABIC

```

% ordenando auto-valoros e auto-vetores por ordem crescente de auto-valoros
V = V'; % coloca auto-vetores nas linhas de V
A=[A,V]; % concatena A e V (cada linha de A contem um auto-valor e auto-vetor)
A=sortrows(A,1); % ordena os auto-valoros em ordem crescente
A=A(:,1) % separa auto-valoros em A e imprime na tela
V = sortrows(V,1);
% calculando as componentes principais
Z=[];
for i=1:p
    Vt = V(p+1:.); % pega os auto-vetores em ordem decrescente dos auto-valoros
    Z(:,i) = X * Vt; % otém-se a i-ésima componente principal
end
% salvando as componentes principais em um arquivo
save('componentes_iris.mat')
Z1=Z(:, 1:2)
L= Z1(1:50,:);
L1=Z1(51:100,:);
L2=Z1(101:150,:);
% fazendo o grafico das duas primeiras componentes
plot(Z1,Z2,'-')
% fazendo o grafico das tres classes separadas
plot(L(:,1),L(:,2),'L1',L(:,1),L(:,2),'L2',L(:,1),L(:,2),'L3','*')

```

RAFR Redes Neurais/2010 30

LABIC

## RNA para Compressão de Imagens

- Padrão JPEG: mais utilizado
- PCA Clássica: método estatístico multivariado
- Rede PCA Adaptativa: arquitetura de Redes Neurais Artificiais

Redes Neurais/2010

RAFR 31

LABIC

## Motivação

- Redução da quantidade de dados armazenadas em sistemas computacionais
- Redução da dimensionalidade de imagens que ocupem grande quantidade de memória
- Obtenção de métodos que
  - atinjam altas taxas de compressão
  - não prejudiquem a qualidade visual

Redes Neurais/2010

RAFR 32

LABIC

## RNA PCA Adaptativa

- Postulado de Hebb[Hebb-1949]: “Quando um axônio da célula A está suficientemente próximo para excitar uma célula B e repetidamente tenta excitá-la, algum processo crescente ou mudanças metabólicas ocorrem em ambas as células”.
- Transformando em regras [Sten-73]:
  - Se dois neurônios ligados por uma sinapse são simultaneamente ativados, a intensidade dessa sinapse(conexão) é aumentada
  - Se dois neurônios ligados por uma sinapse são ativados assincronamente, a intensidade dessa sinapse é diminuída ou até mesmo eliminada.

Redes Neurais/2010

RAFR 33

LABIC

- Regra de Hebb:
 
$$\Delta w_{kj}(n) = \eta y_k(n) x_j(n)$$

Onde  $\eta$  é uma constante positiva – veloc.de aprendizado  
 $y_k(n)$  é a saída do neurônio k no tempo n  
 $x_j$  é j-ésimo elemento do vetor de entrada no tempo n
- Regra Anti-Hebbiana [Foldiak, 1989]
 
$$\Delta w_{kj}(n) = -\eta y_k(n) x_j(n)$$

Redes Neurais/2010

RAFR 34

LABIC

## Rede PCA Adaptativa

Saída : 
$$y_j(n) = \sum_{i=0}^{p-1} w_{ij}(n) x_i(n) + \sum_{l < j} u_{lj}(n) y_l(n)$$

Ajuste dos pesos: 
$$\Delta w_{ij}(n) = \eta x_i(n) y_j(n)$$

Ajuste dos pesos laterais: 
$$\Delta u_{lj}(n) = -\mu y_l(n) y_j(n)$$

Redes Neurais/2010

RAFR 35

LABIC

## Teorema de Convergência[Sang-89]

“Se a matriz de pesos sinápticos  $W(n)$  for associada a valores aleatórios no tempo  $n = 0$ , então, com probabilidade 1, a regra generalizada de Hebb irá convergir na média, e, no limite, irá se aproximar de uma matriz cujas colunas serão os primeiros  $m$  autovetores da matriz  $C$  de covariancia dos vetores de entrada  $x(n)$ , ordenados por ordem decrescente de autovalor.”

Redes Neurais/2010

RAFR 36

LABIC

## Teorema

Portanto, no limite, pode-se escrever:

$$\Delta w_j(n) \rightarrow 0 \quad w_j \rightarrow a_j \quad j = 0, 1, \dots, m-1$$

tal que  $\|w_j(n)\| = 1$  para todo  $j$ . Os valores representam os autovetores normalizados associados aos  $m$  maiores autovalores da matriz  $C$  de covariância dos vetores de entrada  $x(n)$ , estando esses autovalores ordenados em ordem decrescente.

RAFR Redes Neurais/2010 37

LABIC

- Pode-se acelerar a convergência da rede introduzindo um termo *momentum*  $\beta$  e deixando que os parâmetros de aprendizagem e o *momentum* diminuam com o tempo. Em [MAO-95], utilizou-se:

$$\Delta w_{ij}(n+1) = \eta(n) x_i y_j + \beta(n) \Delta w_{ij}(n) \quad (1)$$

RAFR Redes Neurais/2010 38

LABIC

$$\Delta u_{ij}(n+1) = -\mu(n) y_i y_j + \beta(n) \Delta u_{ij}(n) \quad (2)$$

onde  $\eta(n+1) = \max(\alpha\eta(n), 0.0001)$ ,  $\mu(n+1) = \max(\alpha\mu(n), 0.0002)$ ,  $\beta(n+1) = \max(\alpha\beta(n), 0.0001)$  e  $\alpha$  é o fator de diminuição.

RAFR Redes Neurais/2010 39

LABIC

## Algoritmo PCA Adaptativa-[Rubn-89]

**Início**

1. Inicialize todos os pesos de conexões com pequenos valores aleatórios e escolha os valores para os parâmetros de aprendizagem. Normalize-os em [0,1]. Se normalizar em [-1,1] pode mudar os sinais dos auto-vetores.
2. Repita
  - 2.1 Seleccione aleatoriamente um padrão  $p$ -dimensional e apresente-o à rede.
  - 2.2 Ajuste os pesos das conexões entre a camada de entrada e a camada de saída de acordo com a Eq. (1)
  - 2.3 Normalize os vetores-peso (em colunas).
  - 2.4 Atualize os pesos laterais de acordo com a equação (2) (não precisa normalizar)
  - 2.5 Modifique os parâmetros  $\beta$ ,  $\eta$ , e  $\mu$ .

Até que {todos os pesos laterais sejam suficientemente pequenos (a soma de seus valores absolutos seja menor que algum *threshold*  $\epsilon$ ) ou {um número de iterações máximo seja atingido}.

**Fim.**

RAFR Redes Neurais/2010 40

LABIC

## Experimentos Realizados

- Dados sobre as imagens:
  - ♦ conjunto composto por 208 imagens médicas
  - ♦ dimensão 480x640 pixels (valor em nível de cinza)
  - ♦ representação de cortes de um fígado humano
  - ♦ aquisição a partir de um microscópio laser, pelo Departamento de Patologia da Fiocruz

RAFR Redes Neurais/2010 41

LABIC

## Taxas de Compressão

$$\text{Taxa de Compressão} = 1 - \frac{\text{comprimento da cadeia de dados comprimidos}}{\text{comprimento da cadeia de dados originais}}$$

**Taxas de Compressão para Blocos 32x32**

Número de Componentes Principais	Taxa de Compressão
1	$1 - \left(\frac{1}{32}\right) = 96,875\%$
2	$1 - \left(\frac{2}{32}\right) = 93,75\%$
3	$1 - \left(\frac{3}{32}\right) = 90,625\%$

RAFR Redes Neurais/2010 42

LABIC

## Compressão de Imagens através do Padrão JPEG

- Utilização do aplicativo xv (xview) para linux:
  - possui módulo para compressão JPEG
  - possibilita que o usuário selecione taxa de compressão

RAFR Redes Neurais/2010 43

LABIC

## Discussão de Resultados (1)

MSE	Rede PCA Adaptativa			PCA Clássica			JPEG		
	96,875%	93,75%	90,625%	96,875%	93,75%	90,625%	96%	93%	90%
Imagem 1	5.82	4.91	4.27	5.43	4.69	4.21	9.72	7.01	6.10
Imagem 2	6.75	5.49	4.78	6.17	5.17	4.62	9.97	7.58	6.65
Imagem 3	5.20	4.08	3.40	4.64	3.77	3.26	8.91	6.44	5.39
Imagem 4	5.80	4.36	3.58	5.18	4.07	3.44	9.30	6.72	5.64
Imagem 5	6.08	4.50	3.67	5.30	4.16	3.50	9.47	6.76	5.65
Imagem 6	5.19	4.00	3.34	4.64	3.75	3.22	8.90	6.44	5.36
Imagem 7	5.41	3.96	3.33	4.81	3.74	3.21	9.04	6.51	5.39
Imagem 8	5.39	4.06	3.39	4.79	3.81	3.26	8.99	6.48	5.37
Imagem 9	5.32	3.92	3.27	4.66	3.68	3.16	8.93	6.40	5.32
Imagem 10	5.61	4.22	3.53	4.81	3.41	3.41	9.47	6.63	5.57

RAFR Redes Neurais/2010 44

LABIC

## Discussão de Resultados (2)

Imagem Original      Compressão PCA Clássica

Compressão Rede PCA      Compressão JPEG

RAFR Redes Neurais/2010 45

LABIC

## Conclusões

- 3 técnicas de compressão foram apresentadas e aplicadas em uma sequência de imagens médicas
- Analisando os MSE cometidos pelas técnicas,
  - ♦ Os resultados da Rede PCA foram bem similares aos obtidos pela PCA Clássica
  - ♦ O desempenho do padrão JPEG foi inferior aos desempenhos obtidos pelas duas outras técnicas

RAFR Redes Neurais/2010 46

LABIC

## Conclusões (cont.)

- Analisando a qualidade das imagens recuperadas,
  - ♦ A compressão JPEG forma padrões que dificultam a análise das imagens
  - ♦ As técnicas PCA preservam pequenas estruturas que possibilitam a detecção de doenças

RAFR Redes Neurais/2010 47