

-
-
-
-
-

Análise de Componentes Principais

(Principal Component Analysis - PCA)

Aluizio Fausto Ribeiro Araújo
Universidade Federal de Pernambuco
Centro de Informática



-
-
-
-
-

Conteúdo

-
-
- Introdução
- Revisão Matemática
 - Revisão Estatística
 - Revisão de Álgebra Matricial
- Análise de Componentes Principais
 - Método da Covariância
 - Exemplo Ilustrativo
- PCA e Aprendizagem Auto-Organizada
 - Algoritmo Hebbiano Generalizado – AHG
 - Extração Adaptativa de Componentes Principais (*Adaptive Principal Components Extraction*) – APEX
- Referências

Introdução

- Análise de Componentes Principais é um método de identificar padrões nos dados, para expressá-los de modo a salientar as similaridades e diferenças existentes entre eles.
- Além de se encontrar os padrões nos dados, PCA pode ser usado para comprimir ou reduzir sua dimensionalidade.
- Portanto, PCA pode ser entendido como um método estatístico para seleção de características e redução de dimensionalidade:
 - Seleção de características envolve um processo no qual um espaço de dados é transformado em um espaço de características. Os dois espaços mencionados têm a mesma dimensão.
 - A transformação diminui o número de características tomadas, reduzindo dimensionalidade do conjunto de dados mas preservando a maior parte da informação intrínseca a ele.

Introdução

- Razões para reduzir dimensionalidade:
 - A maioria das técnicas de aprendizagem de máquinas não são efetivas para dados de alta dimensionalidade:
 - Maldição da dimensionalidade;
 - Métricas de distância perdem capacidade discriminante;
 - A dimensão relevante pode ser muito menor;
 - Permite visualização: Projeta dados em 2D ou 3D;
 - Possibilita compressão de dados;
 - Reduz tempo de processamento e número de parâmetros;
 - Viabiliza remoção de ruído.

Revisão de Estatística e Álgebra

- A seguir são expostos os conceitos básicos de estatística e álgebra necessários à compreensão do processo de Análise de Componentes Principais.
 - Conceitos de estatística:
 - Média, desvio padrão, variância, covariância, matriz de covariância.
 - Conceitos de álgebra matricial:
 - Autovalores e autovetores.

Conceitos de Estatística: Média

- Seja um conjunto X de dados retirados aleatoriamente de uma amostra de dados qualquer. Nela, X_1 denota o primeiro elemento da amostra, X_i o i -ésimo, e assim por diante até X_n que representa o último elemento da amostra contendo n elementos.
- A *média* do conjunto de dados X pode ser calculada por:

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} \quad (1)$$

- onde \bar{X} indica o valor médio do conjunto de dados X .

Conceitos de Estatística: Desvio Padrão

- O **desvio padrão** de uma amostra de dados define o quão espalhada em torno da média essa amostra está. Calcula-se o desvio padrão através da equação abaixo.

$$s = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{(n-1)}} \quad (2)$$

- onde s é o símbolo utilizado comumente para representar o desvio padrão de uma amostra.

Conceitos de Estatística: Variância

- **Variância** é outra medida do espalhamento do conjunto de dados. O cálculo da variância é apresentado a seguir:

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{(n-1)} \quad (3)$$

- s^2 denota a variância de uma amostra. A equação (3) pode ser reescrita de forma mais clara:

$$\text{var}(X) = \frac{\sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})}{(n-1)} \quad (4)$$

onde $\text{var}(X)$ caracteriza a variância do conjunto X .

Conceitos de Estatística: Variância

- O desvio padrão e a variância operam apenas sobre uma dimensão.
 - Em uma amostra com mais de uma dimensão seria necessário calculá-los para cada dimensão independentemente das outras.
- Contudo, em alguns casos é interessante ter uma medida de como os dados em cada dimensão variam em função da média e como estas variações, em dimensões distintas, se relacionam entre si.
 - A *covariância* é responsável por essa medida e é sempre calculada entre duas dimensões.

Conceitos de Estatística: Covariância

- A **covariância** entre duas variáveis aleatórias reais X e Y , com valores esperados $E(X) = \bar{X}$, $E(Y) = \bar{Y}$ é definida como uma medida de como as duas variáveis se modificam conjuntamente:

$$\text{cov}(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{(n-1)} \quad (5)$$

- A covariância entre uma dimensão e ela mesma é a variância.
- O sinal da covariância é importante pois
 - Se positivo, indica que ambas as dimensões crescem juntas.
 - Se negativo, indica que se uma dimensão cresce a outra decresce.
 - Quando a covariância é zero, indica que as dimensões são independentes entre si.

Conceitos de Estatística: Covariância

- A expressão geralmente usada para cálculo da covariância é:
$$\text{cov}(X, Y) = E(XY) - E(X) \cdot E(Y) = E(XY) - \bar{X} \cdot \bar{Y}$$
- Se X e Y são independentes, então a sua covariância é zero.
- É possível que X e Y não sejam independentes e tenham covariância zero, são as chamadas variáveis descorrelacionadas.
- Se X e Y são variáveis aleatórias de valor real e a, b, c e d constantes, então:

$$\text{cov}(X, Y) = \text{cov}(Y, X); \quad \text{cov}(aX + b, cY + d) = ac \text{cov}(Y, X)$$

$$\text{cov}\left(\sum_i X_i, \sum_j Y_j\right) = \sum_i \sum_j \text{cov}(X_i, Y_j)$$

Conceitos de Estatística: Matriz de Covariância

- **Matriz de covariância** é uma matriz simétrica que apresenta a covariância entre n variáveis.

$$M_{\text{cov}} = E[(\mathbf{X} - \bar{\mathbf{X}})(\mathbf{X} - \bar{\mathbf{X}})^T] :.$$

$$M_{\text{cov}} = \begin{bmatrix} E[(X_1 - \bar{X}_1)(X_1 - \bar{X}_1)] & E[(X_1 - \bar{X}_1)(X_2 - \bar{X}_2)] & \dots & E[(X_1 - \bar{X}_1)(X_n - \bar{X}_n)] \\ E[(X_2 - \bar{X}_2)(X_1 - \bar{X}_1)] & E[(X_2 - \bar{X}_2)(X_2 - \bar{X}_2)] & \dots & E[(X_2 - \bar{X}_2)(X_n - \bar{X}_n)] \\ \vdots & \vdots & \vdots & \vdots \\ E[(X_n - \bar{X}_n)(X_1 - \bar{X}_1)] & E[(X_n - \bar{X}_n)(X_2 - \bar{X}_2)] & \dots & E[(X_n - \bar{X}_n)(X_n - \bar{X}_n)] \end{bmatrix} \quad (6)$$

– onde, M_{cov} é a matriz com n linhas e n colunas.

- Assim, a célula da linha 2 e coluna 3, apresenta a covariância entre o 2º e 3º elementos.



Conceitos de Álgebra Matricial

- Seja $T : V \rightarrow V$ um operador linear. Um vetor $\mathbf{v} \in V$, $\mathbf{v} \neq \mathbf{0}_V$, é dito ser **autovetor**, vetor próprio ou vetor característico do operador T , se existir $\lambda \in R$ tal que $T(\mathbf{v}) = \lambda \cdot \mathbf{v}$.
- A escalar λ é chamada de **autovalor**, valor próprio ou valor característico do operador linear T associado ao autovetor \mathbf{v} .

- Por exemplo: $T : \mathbb{R}^3 \rightarrow \mathbb{R}^3$, $\begin{bmatrix} x \\ y \\ z \end{bmatrix} \rightarrow \begin{bmatrix} x + y + z \\ 2y + z \\ 2y + 3z \end{bmatrix}$, então

$$T(1,1,2) = \begin{bmatrix} 4 \\ 4 \\ 8 \end{bmatrix} = 4 \cdot \begin{bmatrix} 1 \\ 1 \\ 2 \end{bmatrix} = \lambda \mathbf{v}, \text{ autovetor } \mathbf{v} \text{ associado a um autovalor } \lambda.$$

Conceitos de Álgebra Matricial

- Autovetores de uma transformação são vetores cuja direção não é alterada por essa transformação.
- Seja \mathbf{A} uma matriz que representa uma transformação linear entre dois vetores.
- Se existir um vetor $\mathbf{v} \in R^n \neq \mathbf{0}_v$ tal que

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{I}\mathbf{v}, \quad \text{onde } \mathbf{v} = [v_1 \ v_2 \ \dots \ v_n]^T, \quad \mathbf{I}: \text{matriz diagonal unitária}$$

então λ_i é uma grandeza escalar chamada de autovalor (*eigenvalue*) de \mathbf{A} cujo autovetor (*eigenvector*) associado é \mathbf{v}_i .



Conceitos de Álgebra Matricial

- Propriedades dos autovetores:
 - Só há autovetores para matrizes quadradas;
 - Nem toda matriz quadrada os apresenta.
 - Uma matriz $n \times n$ tem no máximo n autovalores;
 - Se um autovetor for multiplicado por uma escalar, ele ainda será um autovetor relacionado ao mesmo autovalor;

$$2 \times \begin{pmatrix} 3 \\ 2 \end{pmatrix} = \begin{pmatrix} 6 \\ 4 \end{pmatrix}$$

$$\begin{pmatrix} 2 & 3 \\ 2 & 1 \end{pmatrix} \times \begin{pmatrix} 6 \\ 4 \end{pmatrix} = \begin{pmatrix} 24 \\ 16 \end{pmatrix} = 4 \times \begin{pmatrix} 6 \\ 4 \end{pmatrix}$$

- Autovetores são linearmente independentes entre si formando base de um espaço. Autovetores de matrizes simétricas são ortogonais.

Conceitos de Álgebra Matricial

- Essa última característica torna os autovetores de uma matriz interessante para representá-la em seu espaço, isto é, os autovetores são usados como os eixos do espaço de \mathbf{A} .
- Nesse caso para facilitar os cálculos usa-se autovetores unitários (magnitude igual a 1) correspondentes aos autovetores.
- Por fim, dá-se o nome de *autoespaço* (*eigenspace*) ao conjunto de autovetores que estão relacionados ao mesmo autovalor. O vetor nulo faz parte desse espaço, apesar de não ser um autovetor.

Conceitos de Álgebra Matricial

- Existem vários processos usados para encontrar os autovalores e autovetores de uma matriz quadrada:
 - Resolução direta do sistema linear;
 - Polinômio característico;
 - Diagonalização de matriz ou “*eigendecomposition*”;
 - Algoritmos iterativos.
- Se \mathbf{A} for a matriz canônica que representa o operador linear T :
 - Cálculo de autovalores de \mathbf{A} : $\det(\mathbf{A} - \lambda\mathbf{I}) = 0$;
 - Cálculo de autovetores de \mathbf{A} : para cada λ , são as soluções da equação $\mathbf{A}\mathbf{v} = \lambda\mathbf{v}$ ou $(\mathbf{A} - \lambda\mathbf{I})\mathbf{v} = 0$.

Análise de Componentes Principais - PCA

- PCA é uma transformação linear dos dados para um novo sistema de coordenadas, onde a maior variância de todas as projeções dos dados, será posicionada como primeira coordenada (chamada componente principal), a segunda maior variância será a segunda coordenada e assim por diante.
- PCA é também chamada de:
 - Transformada (discreta) de Karhunen-Loève - KLT (Kari Karhunen e Michel Loève);
 - Transformada de Hotelling (Harold Hotelling).
- PCA é a transformação linear ótima no intuito de preservar o subespaço que tem a maior variância.

Análise de Componentes Principais - PCA

- Existem diferentes métodos para se realizar PCA:
 - Estatísticos e Algébricos
 - Método da Covariância
 - Método da Correlação
 - Redes Auto-Organizadas
 - Algoritmo Hebbiano Generalizado – AHG
 - Adaptive Principal Components Extraction – APEX
 - Kernel PCA

PCA- Método de Covariância

- Descrição:
 - O objetivo desse método é transformar um conjunto de dados \mathbf{x} de dimensão qualquer em um conjunto alternativo de dados \mathbf{y} de menor que o anterior.
 - Portanto, procura-se a matriz \mathbf{Y} , onde \mathbf{Y} é a transformada de Karhunen-Loève (KLT) da matriz \mathbf{X} :

$$\mathbf{Y} = \text{KLT}\{\mathbf{X}\}$$

PCA- Método de Covariância

Organização dos dados

- Suponha que se tem um conjunto de dados correspondendo a um conjunto de observações de M variáveis.
 - E que se queria reduzir os dados para L variáveis, $L < M$.
 - Suponha, também, que os dados estejam arrumados em um conjunto de N vetores de dados $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$.
 - Cada vetor representa uma única observação de M variáveis.
1. Escreva $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$ como vetores dispostos em colunas, cada um com M linhas.
 2. Arrume os vetores dispostos em colunas em uma única matriz \mathbf{X} de dimensão $M \times N$.

PCA- Método de Covariância

Cálculo da média empírica

3. Ache a média empírica para cada componente da matriz \mathbf{X} , para $m = 1, \dots, M$.
4. Coloque as médias calculadas em um vetor de médias \mathbf{u} de dimensão $M \times 1$.

$$u_m = \frac{\sum_{n=1}^N x_{mn}}{N}$$

PCA- Método de Covariância

Cálculo dos desvios a partir da média

5. Subtraia o vetor de médias \mathbf{u} de cada coluna da matriz \mathbf{X} .
6. Armazene os dados com a média subtraída na matriz \mathbf{B} , $M \times N$.

$$\mathbf{B} = \mathbf{X} - \mathbf{u} \cdot \mathbf{h}^T$$

onde \mathbf{h} é um vetor $N \times 1$, formado apenas de 1s:

$$\mathbf{h} = [1 \ 1 \ 1 \ \dots \ 1 \ 1]^T$$

PCA- Método de Covariância

Determinação da matriz de covariância

7. Ache a matriz de covariância empírica \mathbf{C} , $M \times M$, a partir do produto externo da matriz \mathbf{B} com ela mesma:

$$\mathbf{C} = E[\mathbf{B} \otimes \mathbf{B}] = E[\mathbf{B}\mathbf{B}^T] = \frac{1}{N-1} \mathbf{B}\mathbf{B}^T$$

onde

E é o valor esperado;

\otimes é o produto externo;

T denota uma matriz transposta.



PCA- Método de Covariância

Determinação dos autovetores e autovalores da matriz de covariância

8. Compute a matriz **D** de autovalores e a matriz **V** de autovetores a partir da matriz de covariância **C**:

$$\mathbf{C.V} = \mathbf{D.V}$$

9. A matriz **D** será uma matriz diagonal $M \times M$, onde

$$D_{pq} = \begin{cases} \lambda_m, & p = q = m; \\ 0, & p \neq q \end{cases}$$

onde λ_m é o m -ésimo autovalor da matriz de covariância **C**.

PCA- Método de Covariância

Determinação dos autovetores e autovalores da matriz de covariância

10. A matriz \mathbf{V} , de dimensão $M \times M$, contém M vetores dispostos em colunas, cada um com comprimento M , que representam os M autovetores da matriz de covariância \mathbf{C} .
11. Os autovalores e autovetores estão ordenados e pareados. O m -ésimo autovalor corresponde ao m -ésimo autovetor.

PCA- Método de Covariância

Reordenação dos autovetores e autovalores

12. Arrume as colunas da matriz de autovetores V e a matriz de autovalores D em ordem decrescente de autovalor.
13. Mantenha a mesma relação entre as colunas das duas matrizes.

PCA- Método de Covariância

Cálculo do índice de energia acumulada para cada autovetor

14. Os autovalores representam a distribuição de energia do conjunto de dados original em relação a cada autovetor, componentes da base dos dados.
15. O índice de energia acumulada g para cada m -ésimo autovetor é a soma do índice de energia de todos os autovetores de 1 até m :

$$g_m = \sum_{q=1}^m D_{pq}, \quad \text{para } p = q \text{ e } m = 1, \dots, M.$$

PCA- Método de Covariância

Seleção de subconjunto dos autovetores como vetores base

16. Salve as primeiras L colunas de \mathbf{V} como a matriz, $M \times L$, \mathbf{W} :

$$W_{pq} = V_{pq}, \quad \text{para } p = 1, \dots, M; \quad q = 1, \dots, L; \quad \text{e } 1 \leq L \leq M.$$

17. Use o vetor \mathbf{g} como um guia de escolha do valor apropriado para L . A idéia é escolher um valor para L tão pequeno quanto possível, desde que se tenha um valor percentual alto para \mathbf{g} .

Por exemplo, $g[m = L] \geq 90\%$

PCA- Método de Covariância

Conversão dos dados originais para z-scores

18. Crie um vetor do desvio padrão empírico, $M \times 1$, \mathbf{s} a partir da raiz quadrada de cada elemento ao longo da diagonal principal da matriz de covariância.

$$\mathbf{s} = \left[\sqrt{C_{pq}} \right] \quad p = q = m = 1, \dots, M$$

19. Calcule a matriz, $M \times N$, z -scores:

$$\mathbf{Z} = \frac{\mathbf{B}}{\mathbf{s} \cdot \mathbf{h}}$$

Divide-se elemento por elemento.

PCA- Método de Covariância

Projeção dos z-scores na nova base

20. Os vetores projetados são as colunas da matriz

$$\mathbf{Y} = \mathbf{W}^T \cdot \mathbf{Z} = \text{KLT}\{\mathbf{X}\}$$

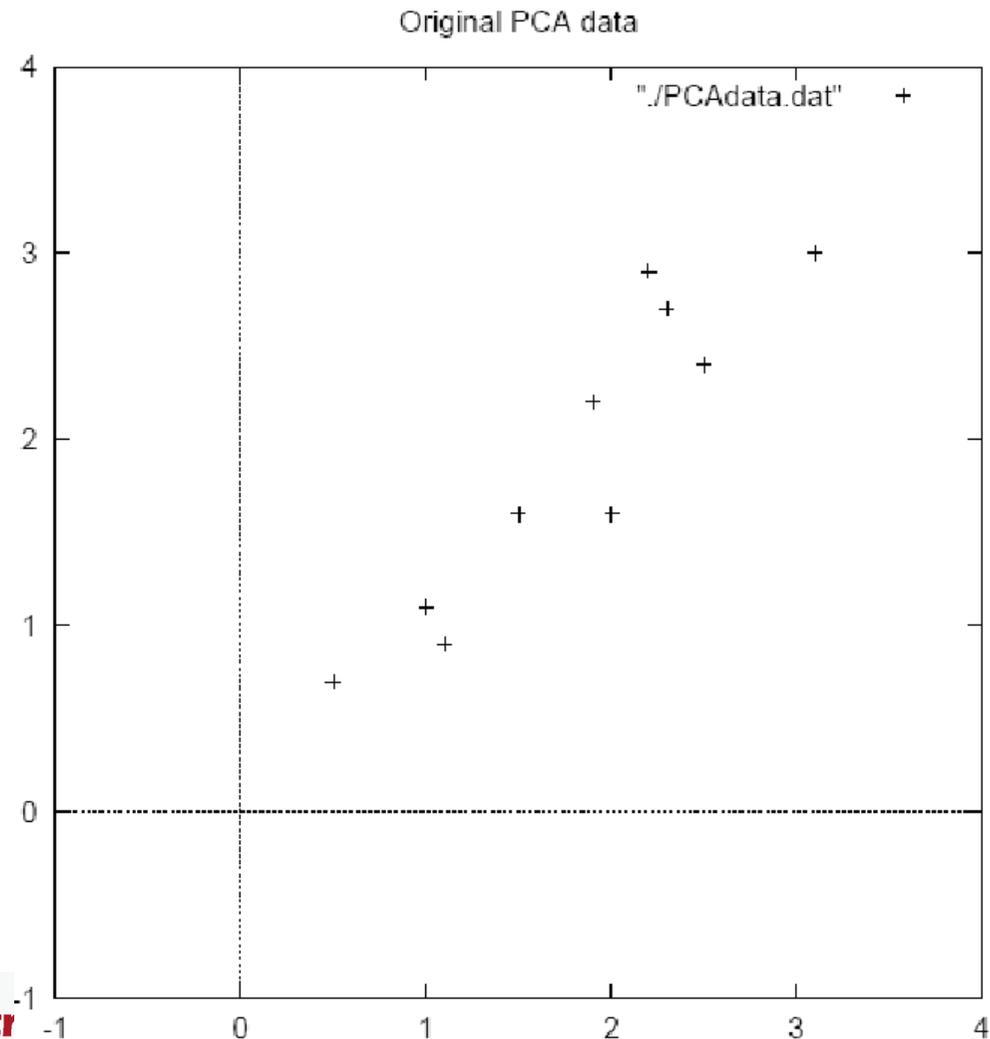
21. A coluna da matriz \mathbf{Y} representam a transformação de Karhunen-Loeve (KLT) dos vetores de dados das colunas da matriz \mathbf{X} .

PCA- Método de Covariância

Exemplo

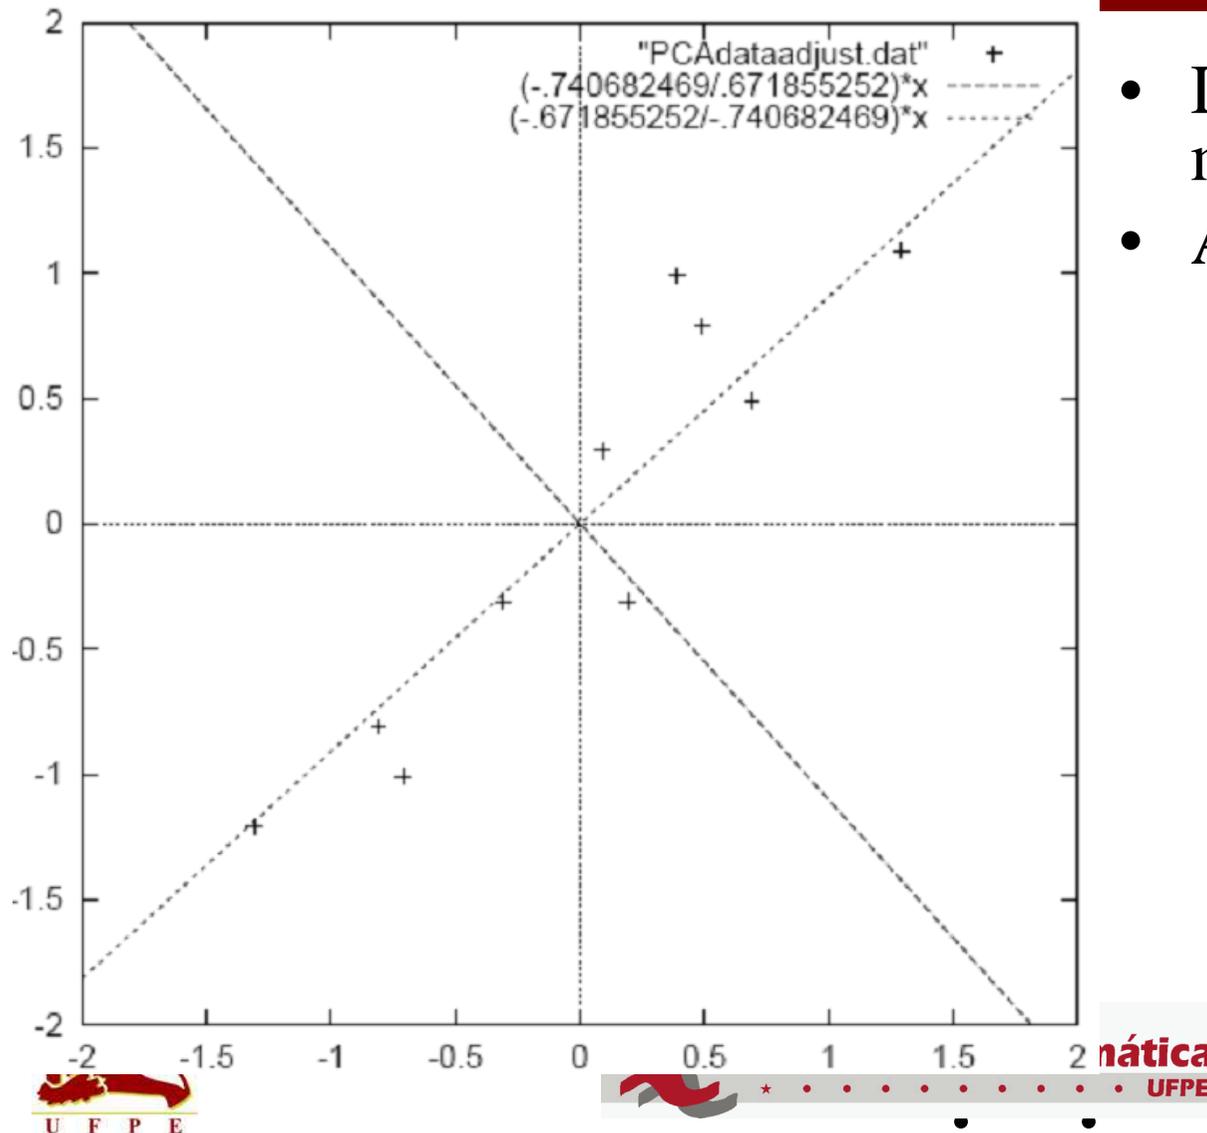
- Dados em 2 dimensões:

x	y
2.5	2.4
0.5	0.7
2.2	2.9
1.9	2.2
3.1	3.0
2.3	2.7
2	1.6
1	1.1
1.5	1.6
1.1	0.9



PCA- Método de Covariância

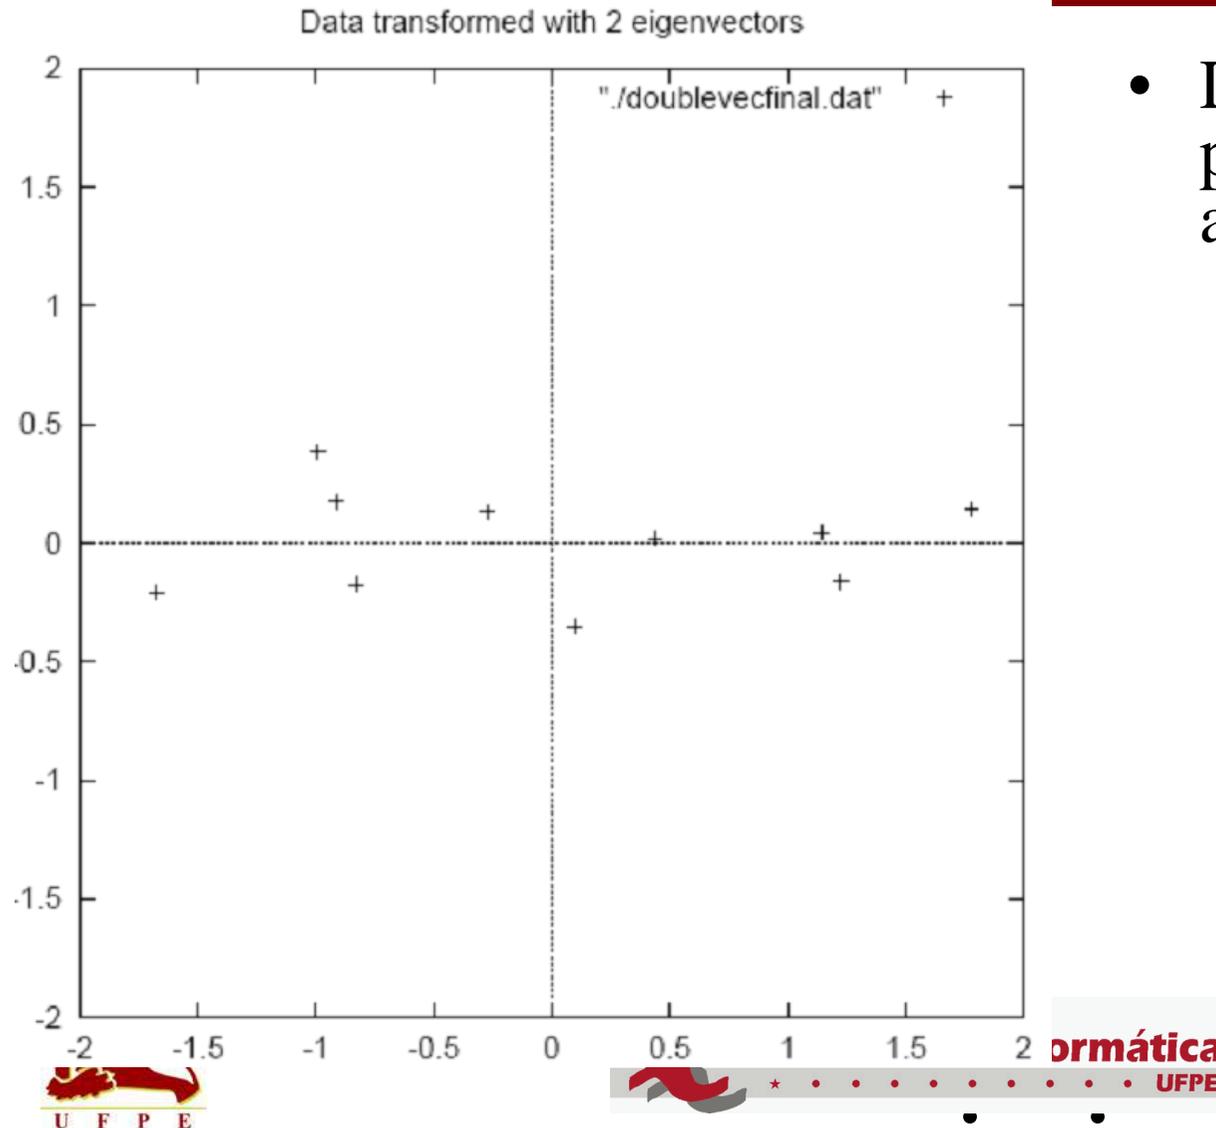
Exemplo



- Dados após remoção da média estão plotados.
- Autovetores computados:
 - Diagonais na imagem.

PCA- Método de Covariância

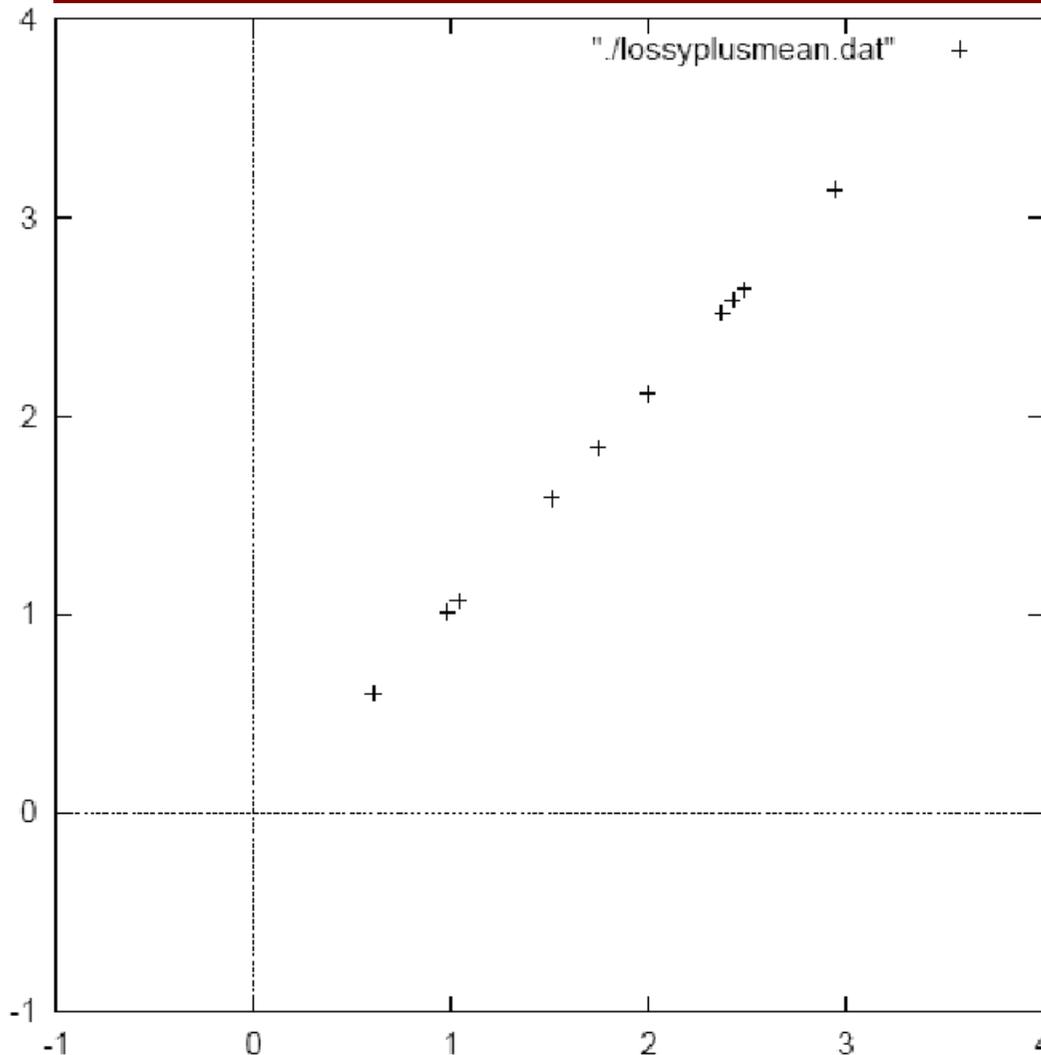
Exemplo



- Dados transformados para as bases dos autovetores calculados.

PCA- Método de Covariância

Exemplo



- Dados após cálculo do PCA usando um dos dois autovetores transformados de volta para a base original.
- Houve redução de dimensionalidade dos dados para apenas 1 dimensão.

PCA

Aprendizagem Auto-Organizada

- Auto-organização de um sistema aparece sem pressão explícita ou imposição do mundo exterior ao sistema. Portanto, as restrições estruturais importantes são internas ao sistema decorrentes de interações entre seus componentes independentemente de sua natureza física. A organização pode se modificar no tempo ou no espaço, tendo comportamento estável ou um transitório.
 - A auto-organização busca regras gerais de crescimento e evolução de estruturas de sistemas, sua forma e predição de organização futura devido a mudanças em seus componentes. Resultados em um sistema devem ser aplicáveis a outros com características similares de rede.

PCA

Aprendizagem Auto-Organizada

- Quatro princípios são fundamentais para a auto-organização, segundo von der Malsburg (Haykin, 2001):
 1. Modificações nos pesos sinápticos tendem a se auto-amplificar.
 2. A limitação de recursos leva as sinapses a competirem entre si, causando fortalecimento de umas em detrimento de outras.
 3. As modificações em pesos sinápticos tendem a cooperar entre si.
 4. Os padrões de entrada apresentam informações redundantes que é assimilada pela rede neural na forma de conhecimento.

PCA

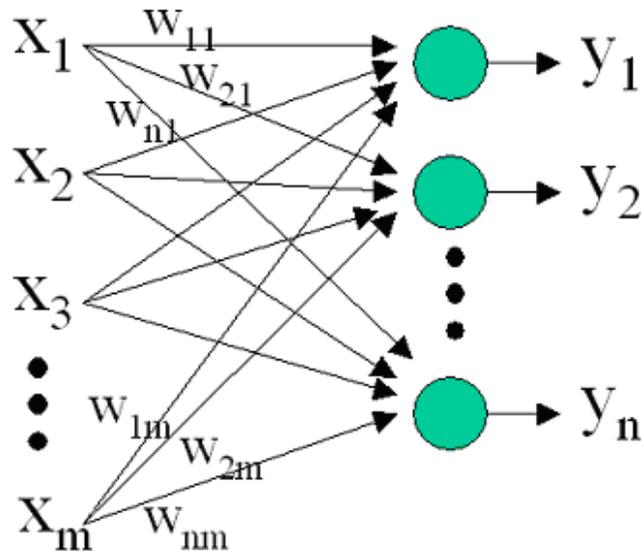
Aprendizagem Auto-Organizada

- A auto-organização de uma rede neural acontece em dois níveis que interagem como um laço de *realimentação*:
 - *Atividade*: Padrões de atividade são gerados pela rede em resposta a sinais de entrada.
 - *Conectividade*: Pesos sinápticos da rede são alterados em resposta aos padrões de atividades.
- Redes neurais auto-organizadas se comportam analogamente ao método estatístico de análise de componentes principais.
- A seguir é apresentado uma técnica de PCA baseada em uma rede com aprendizado Hebbiano.

PCA

Algoritmo Hebbiano Generalizado - AHG

- Solução para o PCA, empregando redes neurais, que pertence à classe dos algoritmos de re-estimação dos métodos de PCA.
- Seja uma rede alimentada para frente e com aprendizado Hebbiano, possuindo os seguintes parâmetros estruturais:



1. Cada neurônio na camada de saída de rede é linear.
2. A rede tem m entradas e n saídas, sendo ambas pré-especificadas. A rede apresenta menos saídas que entradas, $n < m$.

PCA

Algoritmo Hebbiano Generalizado - AHG

- Os nodos de saída devem determinar as componentes principais se consideradas as duas hipóteses mencionadas um tipo particular de aprendizagem hebbiana.
- O aprendizado consiste na adaptação do conjunto de pesos sinápticos, $\{w_{ji}\}$, propagando os valores de entrada até os nodos da camada de saída, onde $i=1, 2, \dots, m$ e $j=1, 2, \dots, n$.
- A função de saída, $y_j(k)$, de cada neurônio de saída, j , no tempo, k , produz uma resposta a partir dos valores de entrada $\{x_i(k)/i=1, 2, \dots, m\}$, e caracteriza-se por:

$$y_j(k) = \sum_{i=1}^m w_{ji}(k)x_i(k) \quad , \quad j = 1, 2, \dots, n$$

PCA

Algoritmo Hebbiano Generalizado - AHG

- O peso sináptico w_{ji} é adaptado via regra generalizada de aprendizagem hebbiana, conforme equação abaixo:

$$\Delta w_{ji}(k) = \eta \left[y_j(k)x_i(k) - y_j(k) \sum_{l=1}^j w_{li}(k)y_l(k) \right], \quad \begin{array}{l} i = 1, 2, \dots, m \\ j = 1, 2, \dots, n \end{array}$$

- Esta modificação aplicada ao peso sináptico $w_{ji}(k)$ no tempo k , tem η como sua taxa de aprendizagem.

- Para melhor entendimento do GHA:

$$\therefore \Delta w_{ji}(k) = \eta y_j(k) \left[x_i(k) - \sum_{l=1}^{j-1} (w_{li}(k)y_l(k)) - w_{ji}(k)y_j(k) \right]$$

$$\therefore \Delta w_{ji}(k) = \eta y_j(k) [x'_i(k) - w_{ji}(k)y_j(k)]$$



PCA

Algoritmo Hebbiano Generalizado - AHG

O termo $y_j(k)x'_i(k)$ corresponde à auto-amplificação decorrente do princípio 1 da auto-organização.

O termo negativo, $-w_{ji}(k)y_j(k)$, é responsável pela estabilização decorrente do princípio 2, competição entre sinapses dos neurônios.

- Existem duas formas de realimentação que atuam no neurônio:
 - Realimentação positiva para auto-amplificação, i.e., causa crescimento de peso sináptico devido à entrada externa;
 - Realimentação negativa devido ao termo $-y_j(k)$ que controla o crescimento, i.e., causa estabilização do peso sináptico.

PCA

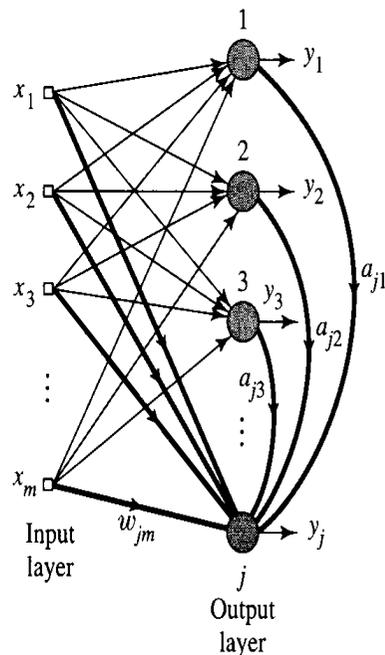
AHG - Algoritmo

- Os cálculos do AHG estão em 3 passos dados a seguir:
 - Passo 1: Inicialize os pesos sinápticos da rede, w_{ji} , com valores pequenos, e atribua valor positivo pequeno à taxa de aprendizado η .
 - Passo 2: Para $k=1, i=1, 2, \dots, m$ e $j=1, 2, \dots, n$, calcule os valores de saída de cada nodo, $y_j(k)$, e os valores de ajuste dos pesos, $\Delta w_{ji}(k)$, usando as equações anteriores.
 - Passo 3: Incremente k em 1, vá para o passo 2 e continue até os pesos sinápticos, w_{ji} , alcançarem seus valores de equilíbrio. Para k grande, o peso sináptico w_{ji} do neurônio j converge para a i -ésima componente do autovetor associado com o j -ésimo autovalor da matriz de correlação do vetor de entrada $\mathbf{x}(t)$.
- Os pesos dos nodos são as componentes de cada autovetor associado a seu autovalor relacionado com a saída y_j do nodo.

PCA

Algoritmo Extração de Componentes Principais Adaptativa - APEX

- O Algoritmo Extração de Componentes Principais Adaptativa (Adaptive Principal Components Extraction - APEX) emprega rede neural com realimentação e pertence à classe dos algoritmos de descorrelação dos métodos de PCA.
- Sua estrutura é definida como:



1. Neurônio lineares na camada de saída.
2. A rede tem conexões excitatórias entre cada nodo de entrada para todos os nodos de saída.
3. A rede tem conexões, de realimentação, inibitórias dos nodos 1 a $j-1$ para o nodo j . Essas conexões empregam aprendizagem anti-Hebbiana.

PCA

Algoritmo Extração de Componentes Principais Adaptativa - APEX

- Algoritmo APEX:
 - Passo 1: Inicialize os pesos w_{ji} , e a_{jl} com valores pequenos, e atribua valor positivo pequeno à taxa de aprendizado η .
 - Passo 2: Para $j=1$, $k=1, 2, \dots$ e $i=1, 2, \dots, m$, calcule as saídas de cada nodo, $y_1(k)$, e os ajustes dos pesos, $\Delta w_{1i}(k)$:

$$y_1(k) = \mathbf{w}_1^T(k) \mathbf{x}(k)$$

$$\Delta \mathbf{w}_1(k+1) = \eta [y_1(k) \mathbf{x}(k) - y_1^2(k) \mathbf{w}_1(k)]$$

onde para valores altos de k , o vetor de pesos \mathbf{w}_1 tende para o autovetor \mathbf{v}_1 associado ao maior autovalor λ_1 .

PCA

Algoritmo Extração de Componentes Principais Adaptativa - APEX

- Algoritmo APEX (continuação):

- Passo 3: Para $j=2, k=1, 2, \dots$ e $i=1, 2, \dots, m$, calcule:

$$\mathbf{y}_{j-1}(k) = [y_1(k) \ y_2(k) \ \dots \ y_{j-1}(k)]$$

$$y_j(k) = \mathbf{w}_j^T(k)\mathbf{x}(k) + \mathbf{a}_j^T(k)\mathbf{y}_{j-1}(k)$$

$$\Delta\mathbf{w}_j(k+1) = \eta[y_j(k)\mathbf{x}(k) - y_j^2(k)\mathbf{w}_j(k)]$$

$$\Delta\mathbf{a}_j(k+1) = \eta[y_j(k)\mathbf{y}_{j-1}(k) - y_j^2(k)\mathbf{a}_j(k)]$$

- Passo 4: Incremente j de 1 e vá para o passo 3. Repita o processo até atingir o número pré-determinado de componentes principais. Para k grande, os vetores de pesos excitatórios tendem ao autovetores e os inibitórias tendem a zero.

Referências

- Haykin, S. O. (2009). *Neural Networks and Learning Machines*. McMaster University, Ontario Canada, 3rd ed.
- Gonzalez, R.C., e Woods, R.E., *Processamento de Imagens Digitais*, Editora Edgard Blücher, 2000.
- Smith, L., *A Tutorial on Principal Component Analysis*, http://csnet.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf, 2002.
- Weisstein, Eric W. *Eigenvalue*. *MathWorld - The Web's Most Extensive Mathematics Resource*, <http://mathworld.wolfram.com> (julho 2006).

