Armazenamento, Visualização & Representação

Victor Lobo

Mestrado em Estatística e Gestão de Informação

Uma imagem são mil palavras…

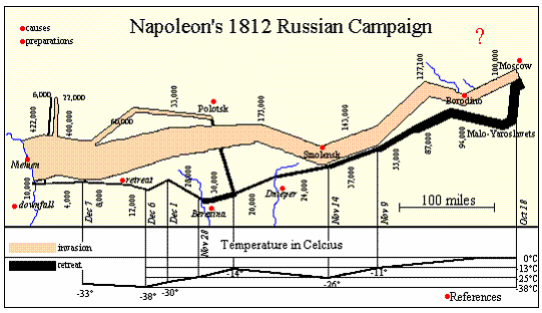

- Campanha da Rússia
  - 6 variáveis diferentes !

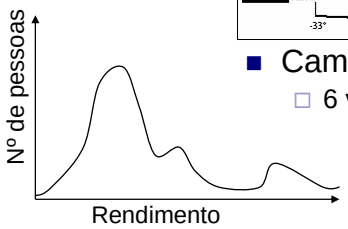

Casos notáveis…

- Surto de cólera em Londres, em 1854
  - Gráfico da distribuição de ocorrências de casos
  - Suspeita que algo no "centro" provocava a doença
  - Provou-se que a doença tinha origem num poço de água inquinado

In Visual and Statistical Thinking:
Displays of evidence for making decisions

Para quê visualizar ?

- Apoiar a exploração interactiva dos dados
- Analisar os resultados
- Apresentação e comunicação dos resultados
- Compreender os dados, ter uma perspectiva sobre eles
- O olho humano é melhor sistema de clustering…
- Desvantagens
  - Requerem *olhos humanos*
  - É uma análise *subjectiva*
  - Podem ser *enganadores*

Mentir com Gráficos

Gráfico com um eixo Y "enganador"

Year	Sales
1999	2110
2000	2105
2001	2120
2002	2121
2003	2124

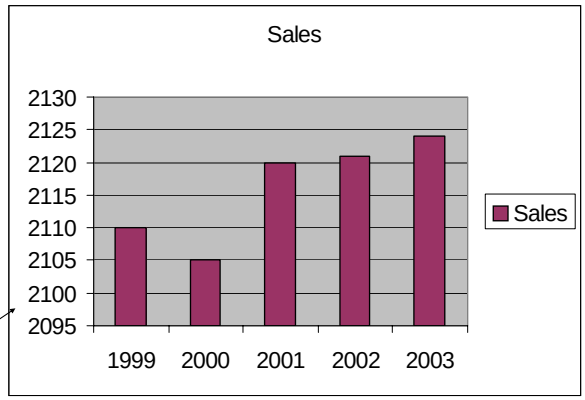

O eixo dos Y dá uma falsa sensação de grande mudança

Melhor…

Year	Sales
1999	2110
2000	2105
2001	2120
2002	2121
2003	2124

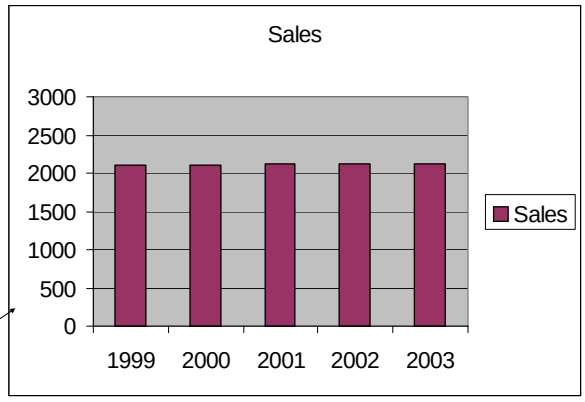

O eixo entre o 0 e os 2000 dá uma leitura correcta de pequenas alterações

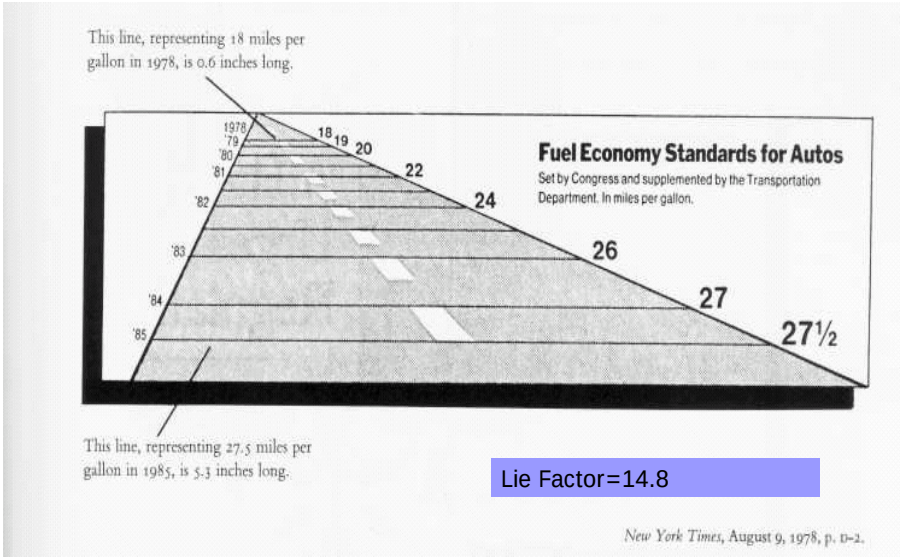

(E.R. Tufte, "The Visual Display of Quantitative Information", 2nd edition)

Lie Factor

$$Lie\ \ Factor\ = \frac{size\ \ of\ \ effect\ \ shown\ \ in\ \ graphic}{size\ \ of\ \ effect\ \ in\ \ data} =$$

$$= \frac{\frac{(5.3-0.6)}{0.6}}{\frac{(27.5-18.0)}{18}} = \frac{7.833}{0.528} = 14.8$$

Tufte requirement: 0.95<Lie Factor<1.05

(E.R. Tufte, "The Visual Display of Quantitative Information", 2nd edition)

Visualização de dados e dimensões

- 1 dimensão – Trivial
  - Listas, Histogramas
- 2 dimensões – Fácil
  - Tabelas de contingência, scatterplots,
- 3 dimensões – Complicado
  - Gráficos 3D, waterfall, contourplots
- Multidimensionais
  - Projecções para dimensões menores
  - Coordenadas paralelas, radarplots, caras de chernoff, stick figs.
  - Dados “com interesse” são quase sempre multidimensionais !!!

Dados Univariados (1-D)

- Representações
  - Fáceis de interpretar
  - Completas
  - Problema da divisão em bins

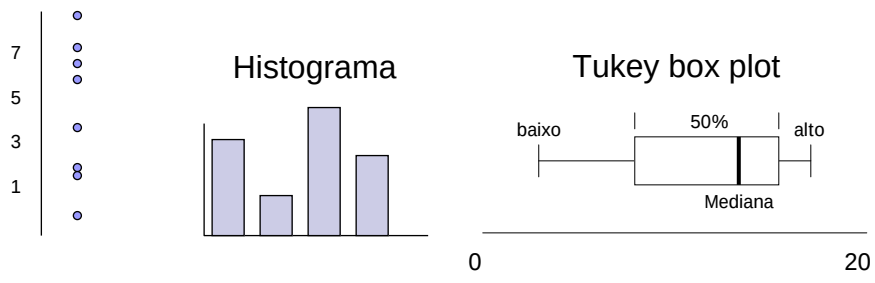

Dados Univariados (1-D)

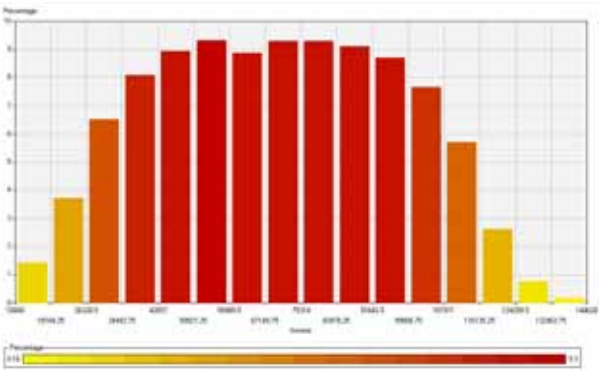

Dados Univariados (1-D)

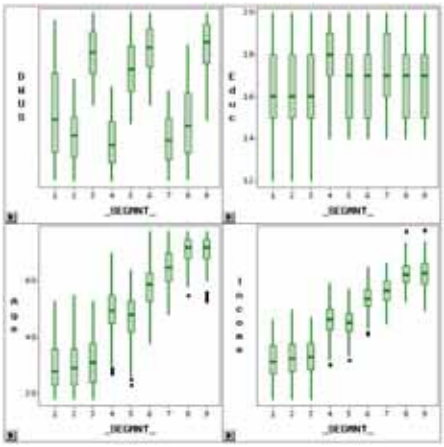

12

Dados Univariados (1-D)

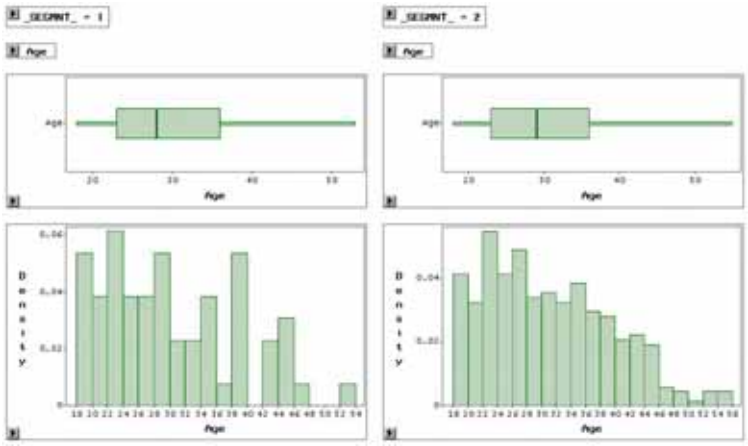

Dados Bivariados (2-D)

- Gráfico de dispersão, ou scatterplots

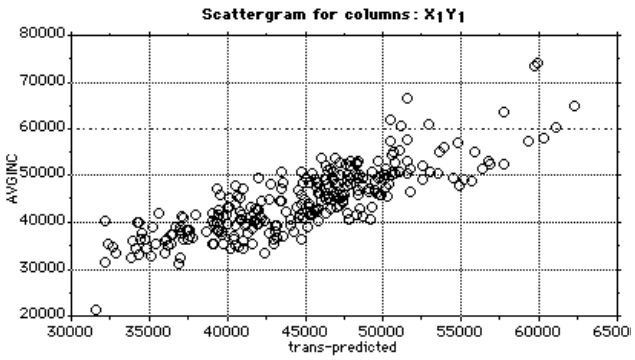

Dados Bivariados (2-D)

- Multiplos scatterplots

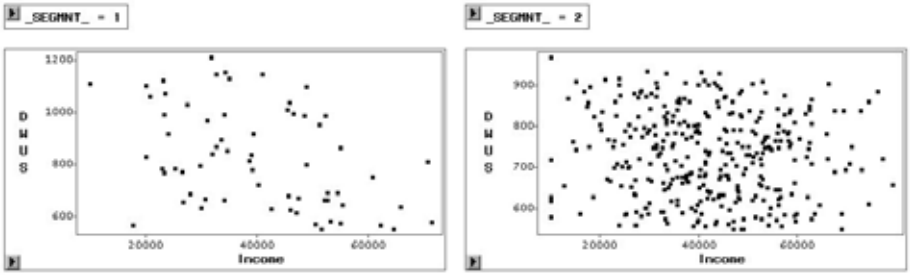

Dados Uni ou Bivariados (2-D)

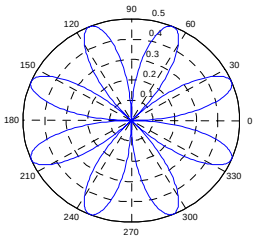

Polar

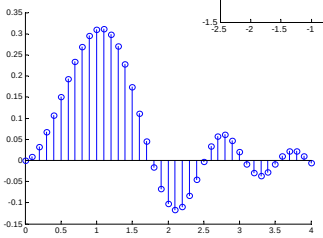

Stem plot

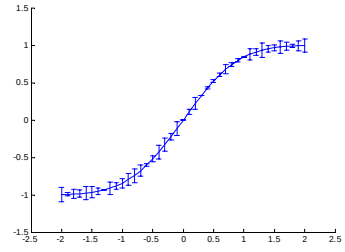

Box-plot

Histograma a 2 dimensões (Tabela de contingência a 3D)

- Patch graph

Dados 3-D

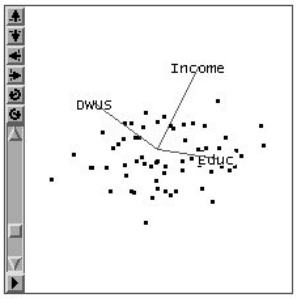

Scatter plot

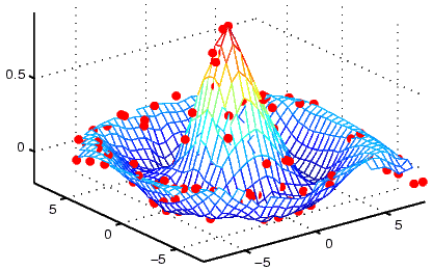

Surface Plot + Scatter plot

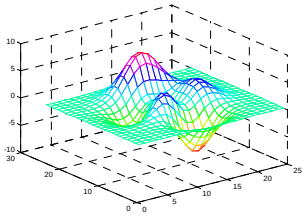

Surface Plot

Dados 3-D

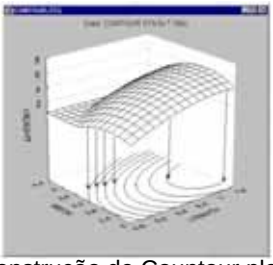

Construção de Countour plots

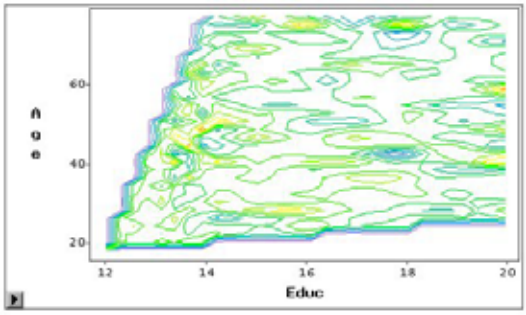

Countour plots, com curvas de nível

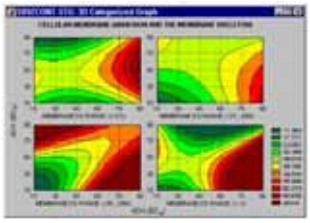

Countour plots, com cores

Dados multidimensionais

- Visualizações directas são impossíveis
- Alternativas:
  - Múltiplos gráficos
  - Coordenadas alternativas
    - Características não espaciais
    - Múltiplos eixos espaciais
  - Projecções sobre dimensões mais reduzidas

Múltiplos Gráficos

Dar a cada variável a seu gráfico

	A	B	C	D	E
1	4	1	8	3	5
2	6	3	4	2	1
3	5	7	2	4	3
4	2	6	3	1	5

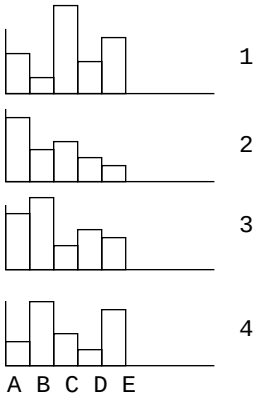

Problema: não mostra as correlações

Matriz de gráficos de dispersão

Representar cada um dos possíveis pares de variáveis com o diagrama de dispersão correspondente

Q: Utilidade?
A: Correlações lineares

Q: Ponto fraco?
A: efeitos multivariados

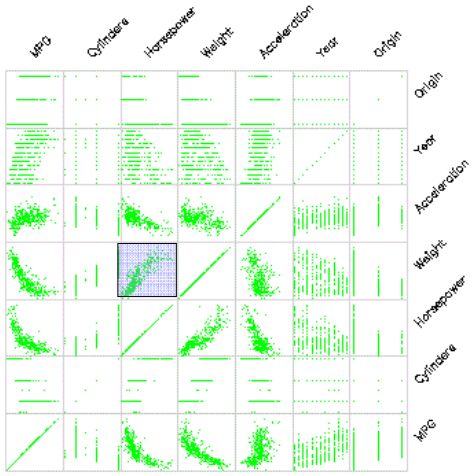

Coordenadas Paralelas

- Codificar as variáveis ao longo de um eixo horizontal
- As linhas verticais especificam os valores

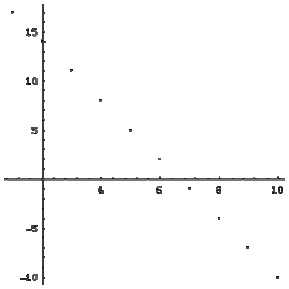

Dados em coordenada Cartesianas

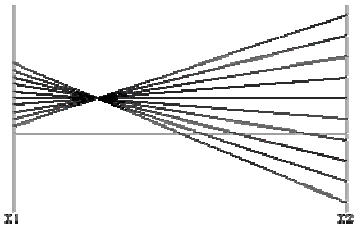

Os mesmos dados em coordenadas paralelas

Invented by Alfred Inselberg while at IBM, 1985

Exemplo: visualizar o “iris dataset”

- A flor Iris tem várias variantes, 3 das quais são:
  1 -Iris Setosa
  2 -Iris Versicolour
  3 -Iris Virginica
- Para 50 flores de cada uma das variantes foram medidas 4 características (medidas em cm)
  - Largura da pétala
  - Comprimento da pétala
  - Largura da Sépala
  - Comprimento da Sépala
- (Questão típica)
  - É possível determinar a variante a partir desses 4 parâmetros ?

Iris Setosa

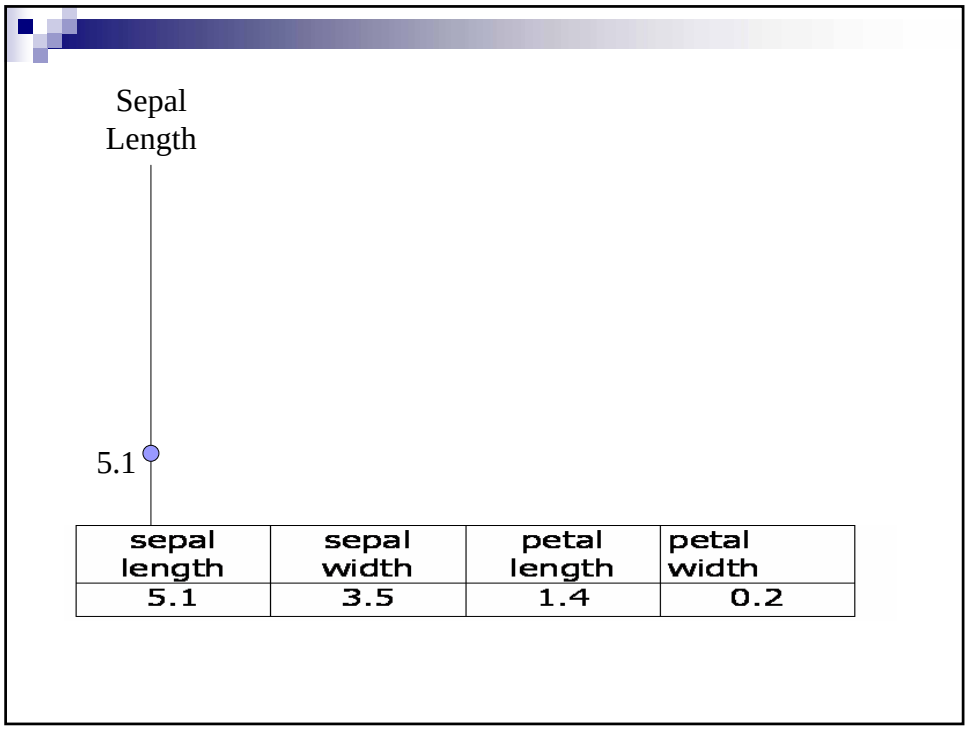

sepal length	sepal width	petal length	petal width
5.1	3.5	1.4	0.2

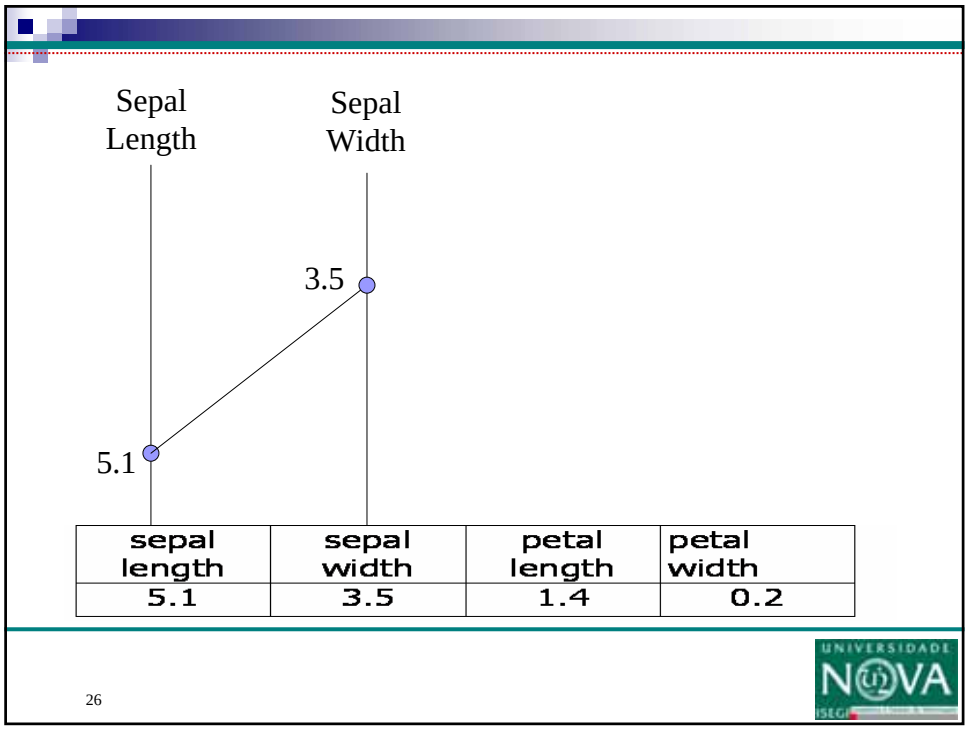

sepal length	sepal width	petal length	petal width
5.1	3.5	1.4	0.2

26

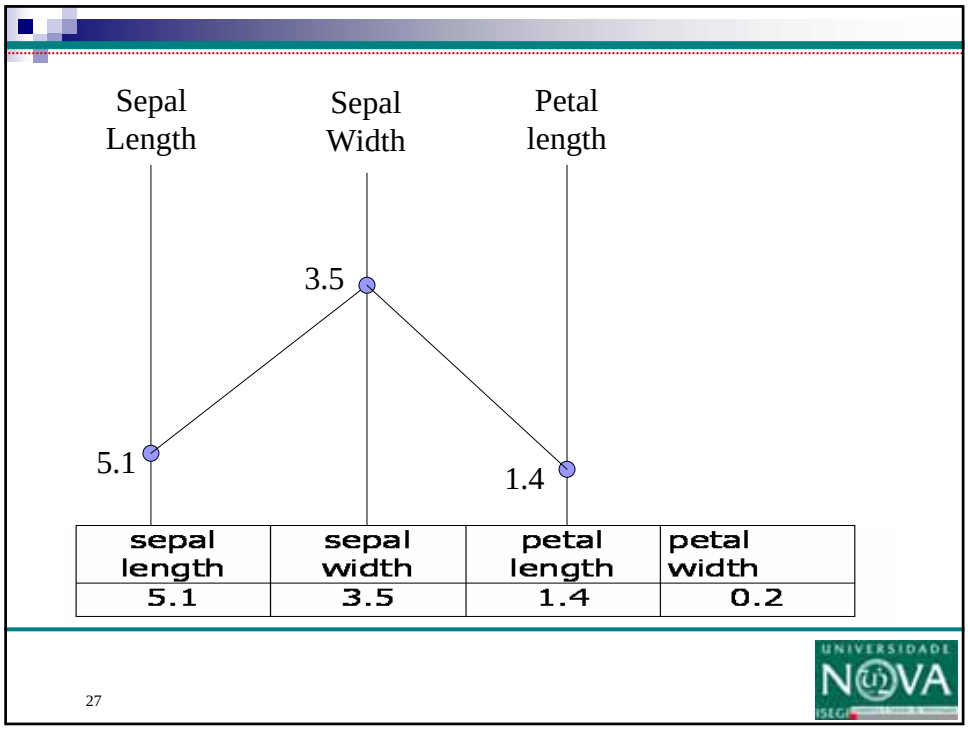
Sepal Length
Sepal Width
Petal length
3.5
5.1
1.4
sepal length
sepal width
petal length
petal width
5.1
3.5
1.4
0.2
27

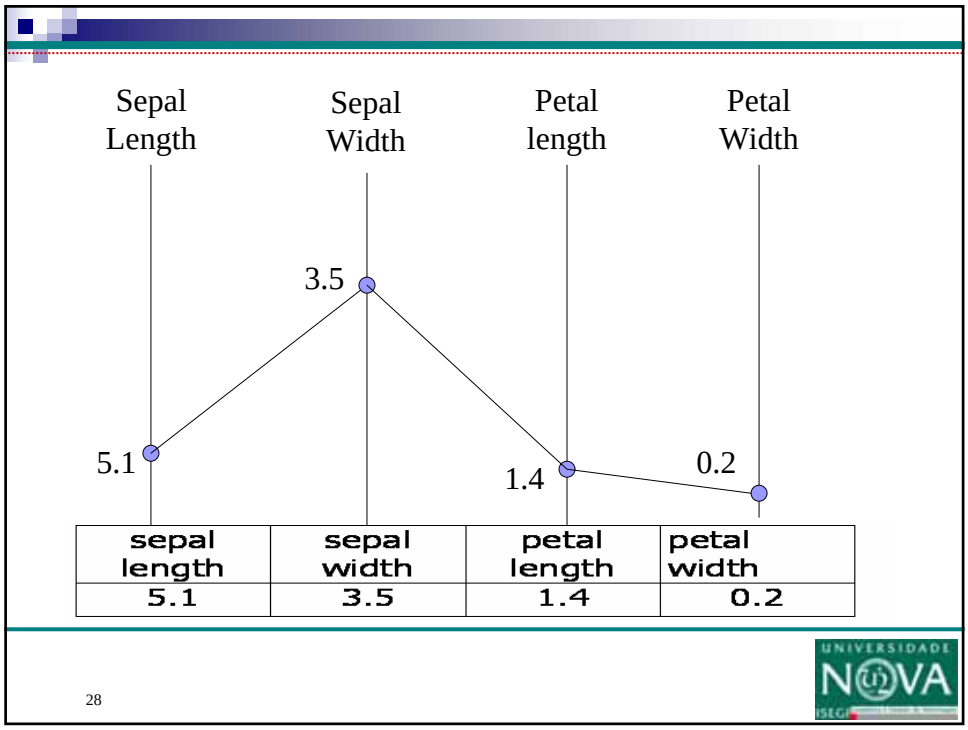
Sepal Length
Sepal Width
Petal length
Petal Width
3.5
5.1
1.4
0.2
sepal length
sepal width
petal length
petal width
5.1
3.5
1.4
0.2
28

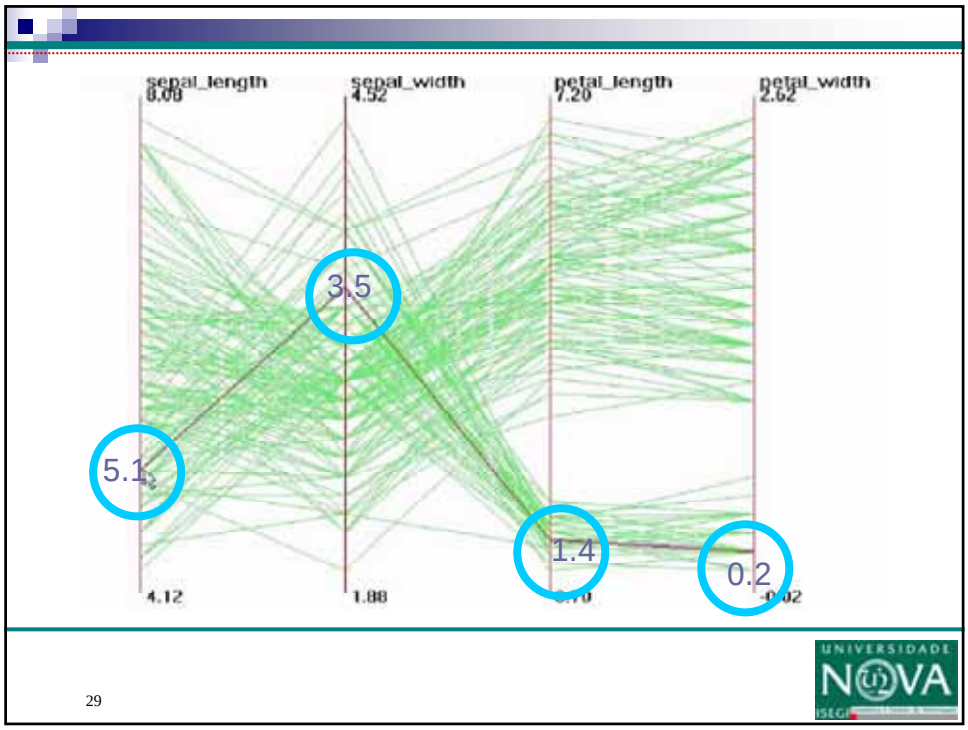

Star plots (ou *radar*, ou *spider*)

- Por os diversos eixos numa “roda”

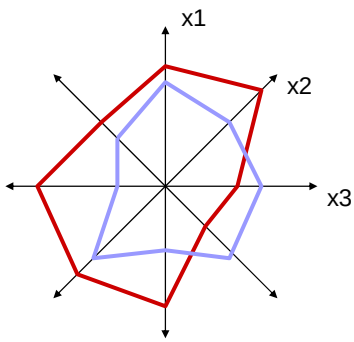

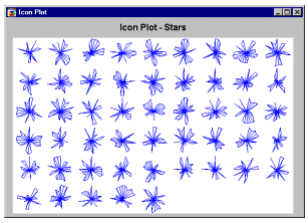

Trilinear Graphs

- Quando a soma de 3 variáveis é constante

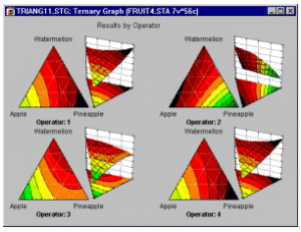

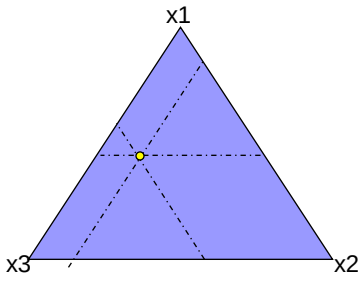

Caras de Chernoff

- As dimensões correspondem a características da face
  - Até 11 dimensões facilmente reconhecíveis.
  - A posição da cara num gráfico 2 ou 3D acrescenta ainda mais dimensões.
  - A escolha das características pode ser polémica…

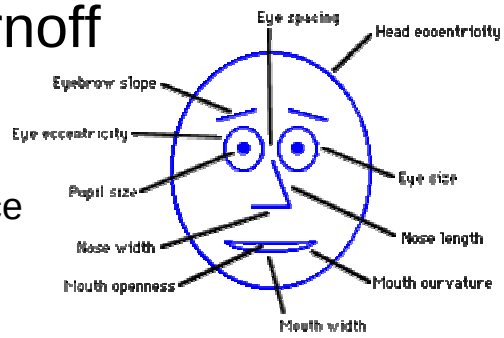

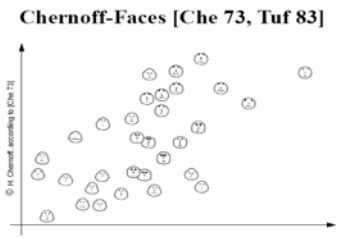

Exemplos de visualizações com caras de Chernoff

- Dados demográficos sobre portugal
  - Largura da face: **taxa de fecundidade** de nados-vivos por 1 000 mulheres em idade fecunda: 15-49anos)
  - Largura do nariz: **índice de envelhecimento** (n.° de residentes com 65 e mais anos por 100 residentes com menos de 15 anos)
  - Comprimento do nariz: **taxa de mortalidade** (numero de óbitos por 1 000 habitantes)
  - Curvatura da boca: **taxa de natalidade** (numera de nados-vtvos por 1 000 habitantes)
  - Comprimento da boca: **nados-vivos fora do casamento** (nados-vivos fora do casamento por 100 nados-vivos)
  - Tamanho das orelhas: **taxa de nupcialidade**
  - (numero de casamentos por 1 000 habitantes
  - Ângulo das sobrancelhas: **taxa de divorcio** (numero de div6rcios por 1 000 habitantes)

[Silva 06]

Cartogramas

- Quando se quer realçar uma característica sobre um mapa geográfico

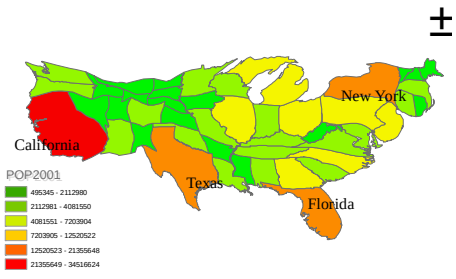

Outros…

- Andrew's curves
  - Cada variável corresponde a uma frequência [Andrew 72]
- Wireframe, contour, circular, bubble graph, high-low-close graph, Vector, surface, pictograms….

Software para visualização

- Genéricos – Excel, Matlab, Mathcad, SPSS,etc
- Dedicados
  - Tableau Software
    - www.tableausoftware.com tem demos, trials, e videos
- Applets disponíveis na net
  - http://www.hesketh.com/schampeo/projects/Faces/interactive.html

Bibliografia

- Edward R.Tufte, Visual Explanations, Graphics Press, 1997
- Edward R.Tufte, The Visual Display of Quantitative Information, Graphics Press, 1983
- Robert L. Harris, Information Graphics – A comprehensive ilustrated reference, Oxford University Press, 1999
- Gene Zelazny, Say it with charts- The executive's guide to Visual Communication, McGraw-Hill, 2000
- Fayyad, Usama; Grinstein, Georges; Wierse, Andreas; Information Visualization in Data Mining and Knowledge Discovery, Morgan Kaufmann, 2002
- Ana Alexandrino da Silva, Gráficos e Mapas, Lidel, 2006
- Statsoft Textbooks
  - http://www.statsoft.com/textbook/stathome.html

Projecções para 2 dimensões

Projecções sobre espaços visualizáveis

- Ideia geral:
  - Mapear os dados para um espaço de 1 ou 2 dimensões
- Mapear para espaços de 1 dimensão
  - Permite definir uma ordenação
- Mapear para espaços de 2 dimensões
  - Permite visualizar a “distribuição” dos dados (semelhanças, diferenças, clusters)

Exemplos

Problemas com as projecções

- Perdem informação
  - Podem perder MUITA informação e dar uma imagem errada
- Medidas para saber "o que não estamos a ver"
  - Variância explicada
  - Stress
  - Outros erros (erro de quantização, topológico,etc)

Dimensão *intrínseca*

- Dimensão do sub-espaço dos dados
  - Pode ou não haver um mapeamento linear
- Estimativas da dimensão intrínseca
  - Com PCA – Verificar a diminuição dos V.P.
    - Basicamente, medir a variância explicada
  - Com medidas de stress (em MDS)
  - Com medidas de erro

Seleccionar componentes mais "relevantes" para visualização

- Será sempre uma "boa" escolha ?

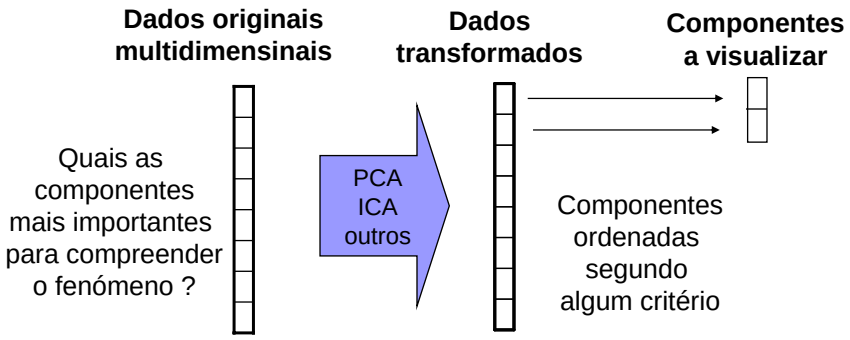

PCA – Principal Component Analysis

- Principal Component Analysis
  - Análise de componente principais
  - Transformada (discreta) de Karhunen-Loève
  - Transformada linear para o espaço definido pelos vectores próprios da martriz de covariância dos dados.
    - Não é mais que uma mudança de coordenadas (eixos)
    - Eixos ordenados pelos valores próprios
    - Utiliza-se normalmente SVD

Componentes principais

- Mudança de eixos
  - Os novos eixos estão “alinhados” com as direcções de maior de variação
  - Continuam a ser eixos perpendiculares
  - Podem “esconder aspectos importantes”

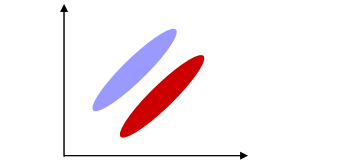

A 2ª componente é que separa !

A dimensão intínseca é 1 !

Problemas com ACP

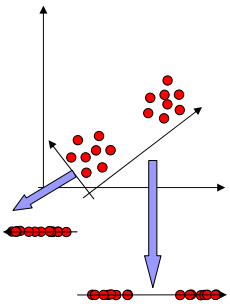

Corre bem !

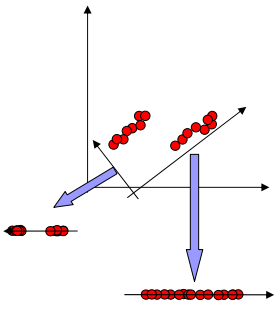

Menos bem !

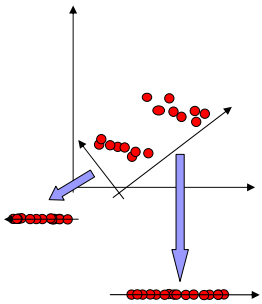

Mal !

Componentes Independentes

- ICA – Indepenant Component Analysys
  - Maximizam a independência estatística (minimizam a informação mútua)
- Diferenças em relação a PCA

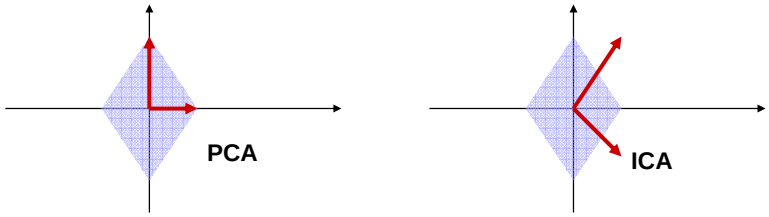

Componentes Independentes

- Bom comportamento para clustering
  - Muitas vezes melhor que PCA por "espalhar" melhor os dados
- Bom para "blind source separation"
  - Separar causas independentes que se manifestam no mesmo fenómeno
- Disponibilidade
  - Técnica recente… ainda pouco divulgadada
  - Boas implementações em Matlab e C
  - Livro de referencia (embora não a ref.original):
    - Hyvärinen, A., J. Karhunen, et al. (2001). Independent Component Analysis, Wiley-Interscience.

Referências sobre ICA

- Primeiras referências
  - B.Ans, J.Herault, C.Jutten, “Adaptative Neural architectures: Detection of primitives”, COGNITIVA’85, Paris, France, 1985
  - P.Comon, “Independant Component Analysis, a new concept ?”, Signal Processing, vol36,n3,pp278-283, July 1994
- Algoritmo mais usado. FastICA
  - Hyvärinen, A., J. Karhunen, et al. (2001). Independent Component Analysis, Wiley-Interscience.
  - V.Zarzoso, P.Comon, “How Fast is FastICA?”, Proc.European Signal Processing Conf., Florence, Italy, Setember 2006
- Recensão recente
  - A.Kachenoura et al.,”ICA: A Potential Tool for BCI Systems”, IEEE Signal processing Magazine, vol25, n.1, pp 57-68, January 2008
- Código freeware e material de apoio
  - FastICA para Matlab, R, C++, Python, e muitos apontadores para informação
  - http://www.cis.hut.fi/projects/ica/fastica/

MDS – MultiDimensional Scaling

- Objectivo
  - Representação gráfica a 2D que preserva as distâncias originais entre objectos
- Vários algoritmos (e por vezes nomes diferentes)
  - Sammon Mapping (1968)
  - Também conhecido como Perceptual Mapping
  - É um processo iterativo
  - Não é, rigorosamente, um mapeamento…
- Stress
  - Mede a distorção que não foi possível eliminar

$$Stress = \sqrt{\frac{(d_{ij} - \hat{d}_{ij})^2}{(d_{ij} - \bar{d})^2}}$$

d_{ij} = distância verdadeira

$\hat{d}$ = distância no grafico 2 d

$\bar{d}$ = média das distâncias

Exemplos de MDS

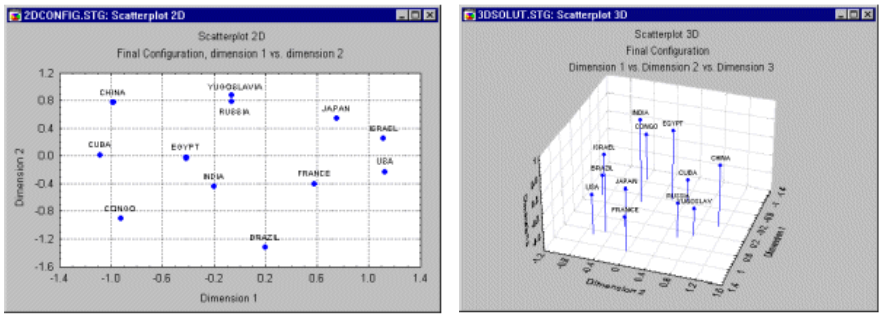

Exemplo com países do mundo caracterizados por indicadores socio-económicos

- Nota:
  - Ao acrescentar mais um dado é necessário recalcular tudo !

Transformações tempo/frequência

- Transformada de Fourier
  - É uma mudança de referencial !
  - Projecta um espaço sobre outro
- Transformadas tempo/frequência
  - Wavelets
  - Wigner-Ville
  - Identificam a ocorrência (localizada no tempo) de fenómenos que se vêm melhor na frequência…

Transformada de Fourier

- Aplicações
  - Análise de séries temporais
  - Análise de imagens
  - Análise de dados com dependências "periódicas" entre eles
- Permite:
  - Invariância a "tempo"
  - Invariância a "posição"
- O que é:
  - Um decomposição em senos e cosenos
  - Uma projecção do espaço original sobre um espaço de funções

Transformada de Fourier

- O que é a "decomposição" ?

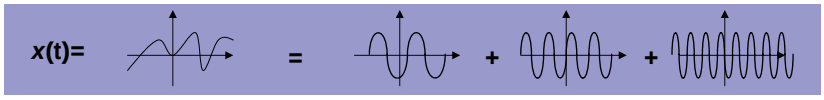

- Com o que é que fico ? Com o que quiser…
  - Com as amplitudes de cada frequência…
  - Com os valores das 2 frequências mais "fortes"…
- Notas:
  - Para não perder informação *N*-pontos geram *N*-pontos
  - Posso calcular a transformada mesmo que faltem valores

Curvas principais, SOM, etc

- Curvas principais
  - Hastie 1989
  - Define-se parametricamente a família de curvas sobre o qual os dados são projectados
- SOM
  - Kohonen 1982
  - Serão discutidas mais tarde

Bibliografia

- Sammon, J. W., Jr (1969). "A Nonlinear Mapping for Data Structure Analysis." IEEE Transactions on Computers **C-18**(5)
- Hastie, T. and W. Stuetzle (1989). "Principal curves." Journal of the American Statistical Association **84**(406): 502-516.
- Hyvarinen, A. and E. Oja (2000). "Independant component analysis: algorithms and applications." Neural Networks **13**: 411-430
- Hyvärinen, A., J. Karhunen, et al. (2001). Independent Component Analysis, Wiley-Interscience.

Exemplo prático (TPC opcional 1)

- Numa escola universitária são realizados inquéritos aos alunos sobre as características dos professores.
- É necessário promover um dos professores auxiliares a associado.
- Os profs catedráticos gostariam de conhecer o mais possível as características dos professores auxiliares para escolher o “melhor”. Gostariam de contar com o “input” dos alunos sobre o desempenho pedagógico.
- Usando os dados disponibilizados pelos inquéritos, prepare uma apresentação 1 minuto (60segundos) para esses professores, deixando-lhes depois uma folha A4 com o que fôr mais importante.

Pré-Processamento dos dados

Porquê pré-processar os dados

- Valores omissos (missing values)
- Factores de escala
- Invariância a factores irrelevantes
- Eliminar dados contraditórios
- Eliminar dados redundantes
- Discretizar ou tornar contínuo
- Introduzir conhecimento “à priori”
- Reduzir a “praga da dimensionalidade”
- Facilitar o processamento posterior

Valores omissos

- Usar técnicas que lidem bem com eles
- Substitui-los
  - Por valores “neutros”
  - Por valores “médios” (média, mediana, moda, etc)
  - Por valores “do vizinho mais próximo”
    - K-vizinhos, parzen, etc
  - Interpolações
    - Lineares, com “splines”, com Fourier, etc.
  - Com um estimador “inteligente”
    - Usar os restantes dados para fazer a previsão

Alternativa: Eliminar valores omissos

- Eliminar registos
  - Podemos ficar com poucos dados
  - (neste caso 3 em 10)
- Eliminar variáveis
  - Podemos ficar com poucas características
  - (neste caso 4 em 9)

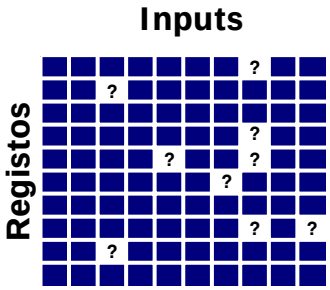

Abordagem iterativa

- Usar primeiro uma aproximação “grosseira”
  - Eliminar registos / variáveis
  - Usar simplesmente valores médios
- Observar os resultados
  - Conseguem-se boas previsões ?
  - Resultados são realistas ?
- Abordagem mais fina
  - Estimar valores para os omissos
  - Usar “clusters” para definir médias

Normalização dos dados

Nomalização

- Efeitos de mudanças de escala

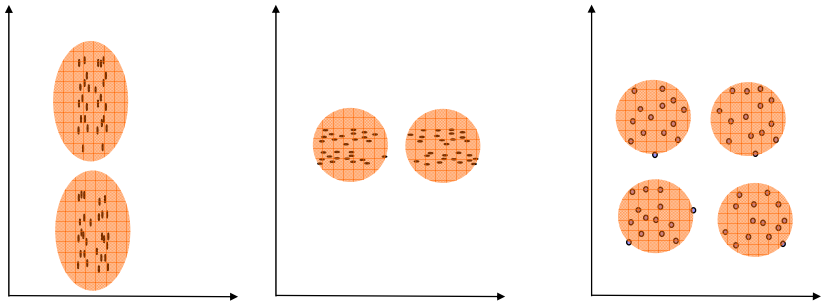

O que é perto do quê ?

Porquê normalizar

- Para cada variável individual
  - Para não comparar “alhos com bugalhos” !
- Entre variáveis
  - Para que métodos que dependem de distâncias (logo de escala) não fiquem “trancados” numa única característica
  - Para que as diferentes características tenham importâncias proporcionais.

Porquê normalizar

- Entre indivíduos
  - Para insensibilizar a factores de escala
  - Para identificar “prefis” em vez de valores absolutos

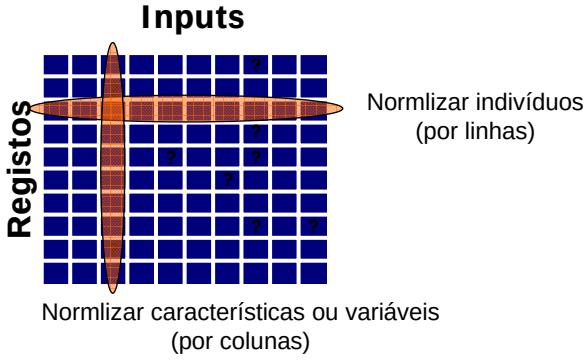

Objectivos possíveis

- Aproximar a distribuição de uniforme
  - "Espalha" maximamente os dados
- Aproximar a distribuição normal
  - Identifica bem os extremos e deixa que estes sejam muito diferentes
- Ter maior resolução na "zona de interesse"

Pré-processamento

- Algumas normalizações mais comuns
  - Min-Max
    - y'∈[0,1]

$$y' = \left(\frac{y - \min}{\max - \min} \right)$$

  - Z-score
    - y' centrado em 0 com σ=1

$$y' = \frac{y - média}{DesvioPadrão}$$

  - Percentis
    - Distribuição final sigmoidal

$$y' = nº\ de\ ordem$$

  - Sigmoidal (logística)
    - y' com maior resoução "no centro"

$$y' = \frac{1 - e^{-\alpha}}{1 + e^{-\alpha}}$$

Normalização sigmoidal

- Diferencia a “zona de transição”

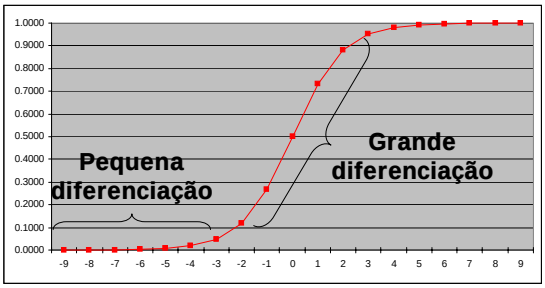

Outros problemas de pré-processamento

Eliminar outliers

- Efeito de alavanca dos outliers
- Efeito de "esmagamento" dos outliers
- Eliminar outliers
  - Estatística (baseado em σ)
  - Problema dos "inliers"
  - Métodos "detectores" de outliers
    - Com k-médias
    - Com SOM

Conversões entre tipos de dados

- Nominal / Binário
  - 1 bit para cada valor possível
- Ordinal / Numérico
  - Respeitar ou não a escala ?
- Numérico / Ordinal
  - Como discretizar ?

Outras transformações

- Médias para reduzir ruído
- Ratios para insensibilizar a escala
- Combinar dados
  - É introdução de conhecimento “à priori”

Quanto pré-processamento ?

- Mais pré-processamento
  - Maior incorporação de conhecimento à priori
  - Mais trabalho inicial, tarefas mais fáceis e fiáveis mais tarde
- Menos pré-processamento
  - Maior esforço mais tarde
  - Maior “pressão” sobre sistema de classificação/ previsão / clustering
  - Princípio: “garbage in – garbage out”