

Reconhecimento de Padrões

Análise de Discriminantes

Prof. Dr. rer.nat. Aldo von Wangenheim

The Cyclops Project
German-Brazilian Cooperation Programme on IT
CNPq GMD DLR

Prof. Dr. rer.nat. Aldo von Wangenheim

The Cyclops Project
German-Brazilian Cooperation Programme on IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC

Análise de Discriminantes

A **análise de funções discriminantes** é utilizada para determinar quais variáveis discriminam entre dois ou mais grupos que ocorrem naturalmente.

- **Clientes de uma empresa:**
 - **Análise de Discriminantes:** Como selecionar variáveis que melhor discriminam clientes que permanecem e clientes que abandonam os serviços da empresa?
 - **Construção de regras de classificação:** Conhecidos os valores das variáveis de um novo cliente, classifica-lo no grupo dos que abandonam ou no grupo dos que permanecem na empresa.
- **Clientes de um banco:**
 - **Análise de Discriminantes:** Como selecionar variáveis que melhor discriminam clientes que pagam e clientes que não pagam seus débitos?
 - **Construção de regras de classificação:** Conhecidos os valores das variáveis de um novo cliente, classifica-lo no grupo dos que pagam ou no grupo dos que não pagam.

The Cyclops Project
German-Brazilian Cooperation Programme on IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC

Objetivos da Análise de Discriminantes

- Suponha que nos medimos um conjunto de 100 pessoas, sendo 50 homens e 50 mulheres. Em média, os homens são mais altos que as mulheres, então podemos dizer com uma probabilidade razoável que se uma pessoa é alta, então ela é provavelmente homem.
- Podemos generalizar as idéias acima em casos não tão triviais.

 **The Cyclops Project**
Geração de Software Corporativo e Programação em IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC



Objetivos da Análise de Discriminantes

Estruturando o que foi dito acima, queremos:

- Medir o poder de discriminação de cada variável ou grupo de variáveis;
- Descrever graficamente ou algebricamente diferentes grupos em termos de variáveis discriminadoras;
- Desenvolver regras para classificar novos elementos.

 **The Cyclops Project**
Geração de Software Corporativo e Programação em IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC



Objetivos da Análise de Discriminantes

- A idéia por trás da análise de discriminantes é a determinação do quando os grupos diferem em relação as médias das variáveis e então usar estas variáveis para prever novos casos.
- Nosso objetivo será determinar quais variáveis são categóricas, *i.e.*, nos permitem discriminar entre categorias.

 **The Cyclops Project**
Geração de Software Corporativo e Programação em IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC



Principais Perguntas

- Considerando amostras de p variáveis, relativas a elementos de g grupos, como pode-se :
 - verificar as variáveis que discriminam (separam) melhor os grupos;
 - medir analiticamente a separação dos grupos;
 - visualizar graficamente a separação dos grupos.
- Como organizo um esquema de classificação ?
 - A partir de amostras de p variáveis de elementos de vários grupos, como pode-se criar regras de classificação que permitam classificar novos elementos em um dos grupos?
 - Como avaliar a qualidade do processo de classificação?

The Cyclops Project
Geração de Software Corporativo e Programação em IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC

Exemplo

Tomemos para isso o seguinte exemplo:

- **Grupo 1:** mulheres não portadoras de hemofilia A (normais) ($n_1 = 30$)
- **Grupo 2:** mulheres portadoras de hemofilia A (portadoras) ($n_2 = 22$)
- Suponha que as variáveis discriminadoras são: X_1 e X_2 (duas variáveis contínuas medindo duas substâncias diferentes observadas em exames de sangue).

The Cyclops Project
Geração de Software Corporativo e Programação em IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC

Exemplo: Os dados

ind.	GRUPO	X1	X2
1	1	-0,0056	-0,1657
2	1	-0,1698	-0,1585
3	1	-0,3469	-0,1879
...
31	2	-0,3478	0,1151
32	2	-0,3618	-0,2008
33	2	-0,4986	-0,0860
...

The Cyclops Project
Geração de Software Corporativo e Programação em IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC

Exemplo: Um *scatter plot* da distribuição dos dados fica assim:

● grupo=1
■ grupo=2

The Cyclops Project
Geração de Software Computacional e Programação em IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC

Função de Análise de Discriminantes

Função discriminante linear de Fisher para 2 grupos

The Cyclops Project
Geração de Software Computacional e Programação em IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC

Formas de Análise de Discriminantes

Análise de Discriminantes sobre uma única Variável

- Para teste se uma variável discrimina entre grupos usamos o teste **F**.
- O Teste **F** é calculado como a razão entre a variância inter grupos e a média da variância intra grupo. Se a variância inter-grupo é significativamente maior, então existe diferença entre as médias.

The Cyclops Project
Geração de Software Computacional e Programação em IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC

Análise de variância:

$$F = \frac{\text{variância entre grupos}}{\text{variância dentro dos grupos}}$$

Análise de variância com 2 agrupamentos

	SS entre	gl	SS dentro	gl	F
comp. sép.	76,7	1	72,31	148	157,0
larg. sép.	54,2	1	94,76	148	84,7
comp. pét.	126,9	1	22,13	148	848,6
larg. pét.	117,3	1	31,68	148	548,1

 **The Cyclops Project**
Germes e Saberes Computacionais em Programa em IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC



Análise de Discriminantes com Múltiplas Variáveis

- Neste caso, teremos uma matriz com variâncias e covariâncias totais, e outra com a média das variâncias e covariâncias intra grupo.
- Comparamos as matrizes via teste F multivariado

 **The Cyclops Project**
Germes e Saberes Computacionais em Programa em IT
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC



Presupostos Fundamentais

- Dados distribuídos seguindo uma distribuição normal.
 - O que nem sempre ocorre, o mundo não é tão simples
 - Precisamos de um número significativo de dados
- A variância e a covariância entre as variáveis de cada grupo é homogênea, ou seja, não há diferenças absurdas entre elas.

 **The Cyclops Project**
Germes e Saberes Computacionais em Programa em IT
CNPq GMD DLR


Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC



Modos de usar

Análise de Discriminantes do Tipo Passo a Passo

- A cada passo, revisamos todas as variáveis e avaliamos qual contribui mais na discriminação entre os grupos. Esta variável então será incluída em um "modelo".
- Guiada pelo teste F para a inclusão ou remoção da variável.



The Cyclops Project
Geração de Software Corporativo e Pesquisa em IA
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC

Análise de Discriminantes para Determinação de Funções Discriminantes entre Vários Grupos


- Calculamos mais que uma função discriminante.
- Temos uma função que discrimina um grupo de cada outro grupo do modelo.

The Cyclops Project
Geração de Software Corporativo e Pesquisa em IA
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC

Exemplo

- Para exemplificar a utilização de análise de discriminantes vamos nos basear em um conjunto de dados bastante utilizado para demonstrar Análise de Discriminantes: o conjunto de dados sobre três espécies de flores do gênero *Iris*, *Iris setosa* (comum nos jardins da nossa ilha), *Iris versicolor* e *Iris virginica*. Estes dados foram colhidos por Fisher em 1936 e até hoje servem de exemplo de como se pode escolher funções discriminantes para um conjunto de dados composto por três classes. Os dados descrevem 150 espécimes de *Iris* de acordo com 4 características: comprimento das sépalas, comprimento das pétalas, largura das sépalas e largura das pétalas. A quinta variável é a **variável de grupo** ou **variável categórica**, que associa a classificação a cada espécime ou caso observado. Apresentamos uma parte desse conjunto de dados abaixo:




The Cyclops Project
Germán Saubidó, Carlos Peña, y Priscilla Almeida
CNPq, GMQ, DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC

Classificando novos casos

- Após calcularmos a função discriminantes, obteremos as constantes da função.
- Podemos usar estas constantes como constantes de uma outra função, uma função de classificação.
- Temos portanto uma função para cada grupo. Estas funções fornecem uma pontuação, ou seja, uma probabilidade de um caso novo pertencer aquele grupo.
 - O caso então pertence para a grupo em que a função obteve a maior pontuação.




The Cyclops Project
Geração de Software Computacional em Física e Matemática
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC



Outro exemplo: Câncer Cerebral

- No câncer cerebral mais comum, o que ocorre nas células **gliais** ou de suporte do cérebro, o fator mais importante a ser determinado é a taxa de crescimento do tumor, o que vai determinar a forma de tratamento.
- Determinar esta taxa depende de uma série de fatores que um patologista experiente é capaz de identificar em uma lâmina de uma biópsia cerebral.



The Cyclops Project
Geração de Software Computacional em Física e Matemática
CNPq GMD DLR

Disciplina Reconhecimento de Padrões
Curso de Ciência da Computação
INE/CTC/UFSC



Exercício

- Procure nos "Links Úteis" da página por fontes de software livre para Análise de Discriminantes.
 - <http://www.inf.ufsc.br/~awangenh/RP/estatisticas.html#4.5>. Links
- Tome um conjunto de quatro sets de dados, dentre estes:
 - Os dados da flor do Gênero Iris disponíveis na página
 - Os dados de câncer cerebral (gliomas) que serão fornecidos
 - Outros dois conjuntos quaisquer que você deverá procurar também nos "Links Úteis".
- Realize dois conjuntos de Análises de Discriminantes sobre estes sets de dados:
 - Um deles buscando uma variável discriminatória para divisão em apenas dois grupos
 - Outra multigrupos, buscando o conjunto de funções discriminatórias.
 - No último caso utilize apenas metade dos dados para a A.D., utilizando então as funções geradas para classificar os dados restantes. Verifique a acurácia de sua classificação.
