

PSI3571 – Práticas em Reconhecimento de Padrões, Modelagem e Inteligência Computacional

Prof. Emilio Del Moral Hernandez
Profa. Roseli de Deus Lopes
Escola Politécnica da Universidade de São Paulo
Departamento de Eng. De Sistemas Eletrônicos



emilio_del_moral@ieee.org
www.lsi.usp.br/~emilio

1

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

1

Parte A: recordando alguns pontos já, aquecendo os motores em reconhecimento de padrões e revisitando exemplos de sistemas desenvolvidos por colegas em anos anteriores

2

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

2

... retomando um slide anteriormente apresentado ...

Alguns alvos das práticas / projetos deste curso

- Modelagem envolvendo sistemas com múltiplas variáveis
- Uso de ferramentas que possibilitem representação de fenômenos não lineares (além dos lineares)
- Reconhecimento / Identificação / Classificação de “objetos” a partir de medidas múltiplas (vindas de múltiplos sensores, por exemplo)
- Regressão / previsão / estimação de grandezas analógicas a partir de medidas correlacionadas com tal grandeza
- Exploração de elementos para “automação parcial” da modelagem, via aprendizado de máquina

3

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

3

Destacando ao menos duas classes de aplicação alvo importantes para o curso

- Regressão multivariada (linear e não linear)
- Reconhecimento automático de padrões ...

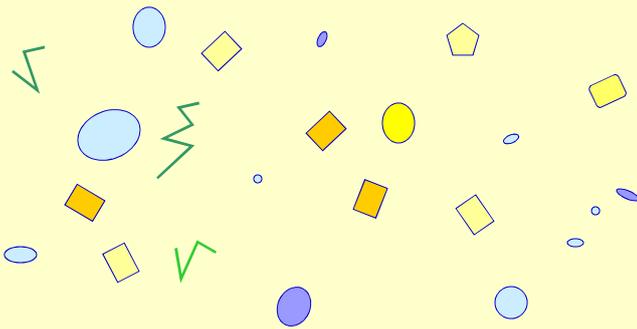
4

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

4

Uma metáfora para a tarefa de classificação de padrões genérica ou multiclases (classificação não binária)...

Universo de objetos observados ...



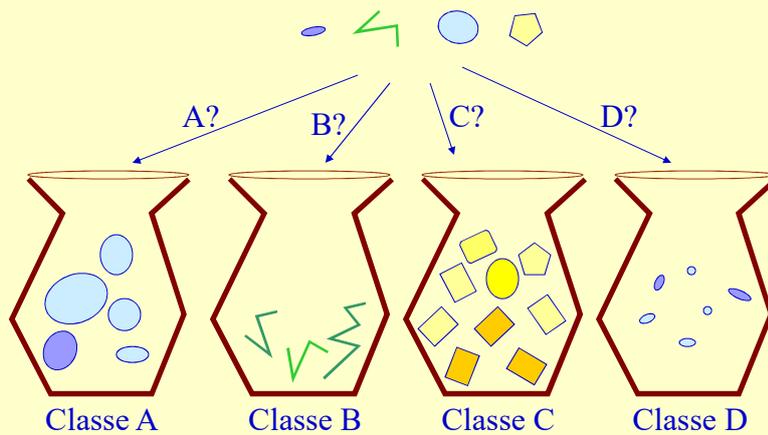
5

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

5

Uma metáfora para a tarefa de classificação de padrões genérica ou multiclases (classificação não binária)...

Um dado objeto específico observado é de que tipo ?

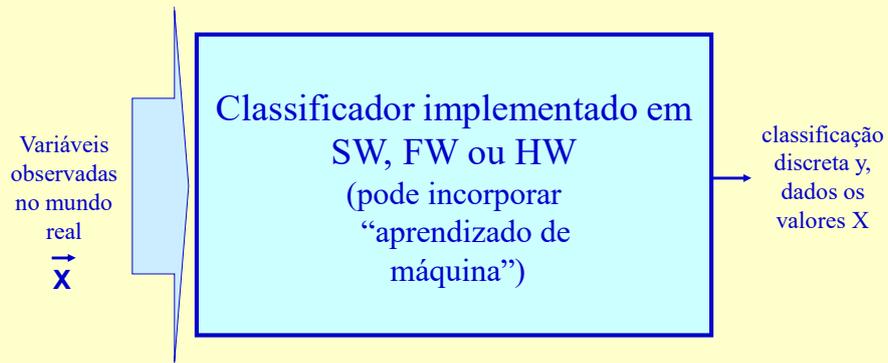


6

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

6

Classificador multivariado (em sw, fw ou hw)



7

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

7

Um hipotético universo de variáveis interdependentes, passível de modelagem/ens

Vamos pensar em nossos próprios desafios de reconhecimento multivariado (com, digamos ao menos 4 variáveis de entrada no modelo) para uma classificação / reconhecimento / categorização automática relevante?

Faça isto no contexto de Eletrônica e Sistemas / ou da sua ênfase / ou do seu Módulo Vermelho..

8

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

8

Após a apresentação rápida das propostas a todos os demais, os presentes entregam as suas propostas (são apenas propostas para discussão, não propostas de projetos finais) em escrito ao Prof.; se você não esteve nesta discussão e entrega, contate o professor pessoalmente ao fim da aula e também faça a sua entrega atrasada dessas informações em escrito nessa ocasião da conversa com o professor – inclua no texto a data em que ocorre a sua entrega

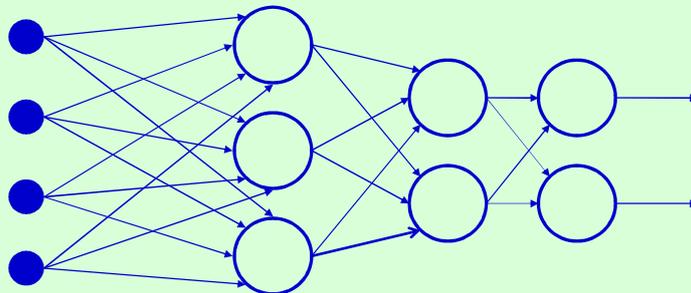
**ATIVIDADE EM SALA,
COM DEBATE COM COLEGAS
E ENTREGA ESCRITA**

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

9

A RNA mais clássica: o Multi Layer Perceptron (MLP)

- Múltiplas entradas / Múltiplas saídas / Múltiplas camadas
- Variáveis (internas e externas) analógicas ou digitais
- Relações lineares ou não lineares entre elas



© Prof. Emilio Del Moral Hernandez

10

Alguns exemplos de sistemas de reconhecimento e de regressão multivariada, com os quais tive contato e que empregaram redes neurais e técnicas relacionadas

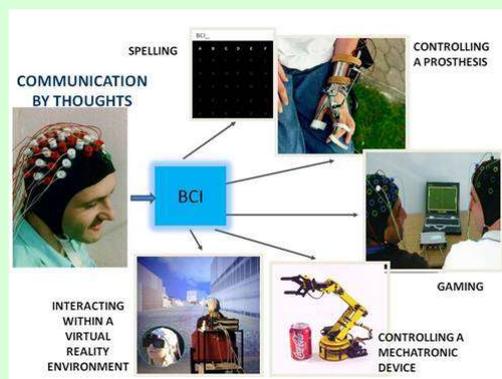
19

PSI2672 – Rec Padrões, Modelagem, Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2016

11

Brain Computer Interfaces ... “um amplo parênteses” ...

12



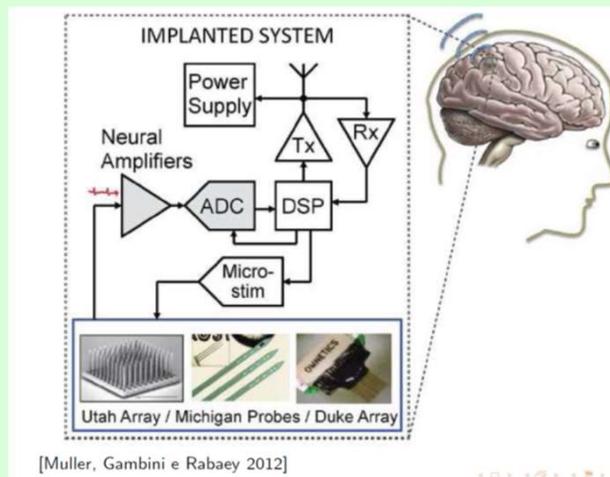
© Prof. Emilio Del Moral Hernandez

12

12

Brain Computer Interfaces – área do trabalho do doutorando Julio Cesar Saldaña

13



[Muller, Gambini e Rabaey 2012]

Slide - Contribuição de Julio Cesar Saldaña - EPUSP

© Prof. Emilio Del Moral Hernandez

13

13

Sistemas Implantáveis de Registro Neural e BCIs

14

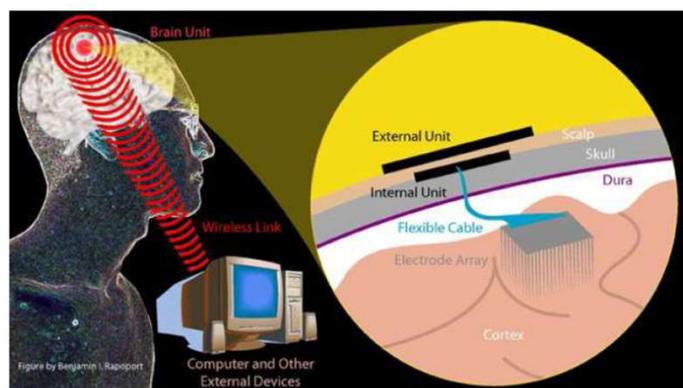


Figura 1: Imagem extraída do site do pesquisador Benjamin I. Rapoport

Slide - Contribuição de Julio Cesar Saldaña - EPUSP

© Prof. Emilio Del Moral Hernandez

14

14

Sistemas Implantáveis de Registro Neural e BCIs

15

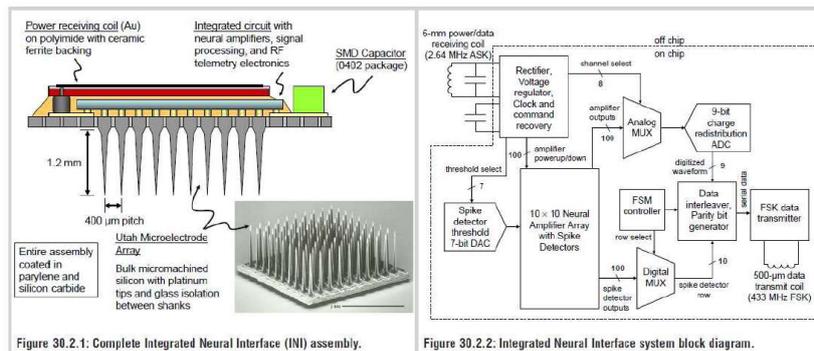


Figure 30.2.1: Complete Integrated Neural Interface (INI) assembly.

Figure 30.2.2: Integrated Neural Interface system block diagram.

[Harrison et al. 2006], [Harrison et al. 2007]

Slide - Contribuição de Julio Cesar Saldaña - EPUSP

© Prof. Emilio Del Moral Hernandez

15

15

Brain Computer Interfaces

16

Separação de impulsos elétricos ou Spike Sorting

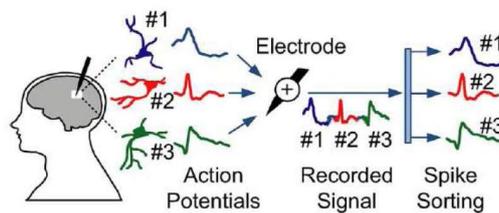


Figura 6: Extraída do artigo [Karkare, Gibson e Markovic 2013] (JSSC, Set. 2013)

Slide - Contribuição de Julio Cesar Saldaña - EPUSP

© Prof. Emilio Del Moral Hernandez

16

16

Alguns exemplos de projetos de 5º ano em PSI2672 da EC2 de anos anteriores (2011 a 2017); No 5o ano da EC3, atividades de projeto similares ocorrem na eletiva PSI3571.

Exemplos de projetos concebidos e realizados por alunos da disciplina EC2 PSI-2672 (na EC3, ~ PSI-3571)

PSI 2672 - Práticas em Reconhecimento de Padrões, Modelagem e Neurocomputação

material
bibliografia
exemplos
2011

Projetos finais:

1. Classificação em gêneros musicais ([gr_I_apresentacao_Musicas.pdf](#))
2. Implementação de um sistema para correção da medida de um sensor de pressão diferencial ([gr_II_Apresentacao_rna_sensor_pressao_03_01.pdf](#))
3. Análise da qualidade dos vinhos a partir de testes físicos-químicos ([gr_III_apresentacao_PSI2672 - Análise de vinhos.pdf](#))
4. Reconhecimento de placas de trânsito ([gr_IV_apresentacao_Reconhecimento_de_placas.pdf](#))
5. Reconhecedor de alcoolismo ([gr_V_apresentacao_Reconhecedor Alcoolismo.pdf](#))
6. Língua eletrônica ([gr_VI_apresentação_lingua_eletronica.pdf](#))
7. Reconhecimento de dígitos ([gr_VII_apresentacao_Reconhecedor de digitos.pdf](#))

Informações sobre o programa do curso: [Programa PSI2672_2011.pdf](#)

Classificação automática de generos musicais

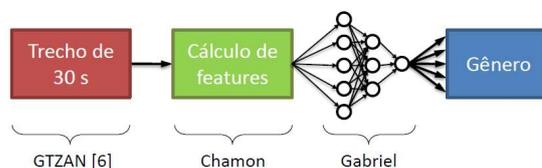
19

DESCRIÇÃO DO PROBLEMA

Categorizar músicas em gêneros automaticamente baseado em trechos de suas gravações e exemplos rotulados *a priori*

- 1) Blues
- 2) Classical
- 3) Country
- 4) Disco
- 5) Hip-Hop
- 6) Jazz
- 7) Metal
- 8) Pop
- 9) Reggae
- 10) Rock

A SOLUÇÃO



projeto de alunos em PSI-2672

© Prof. Emilio Del Moral Hernandez

19

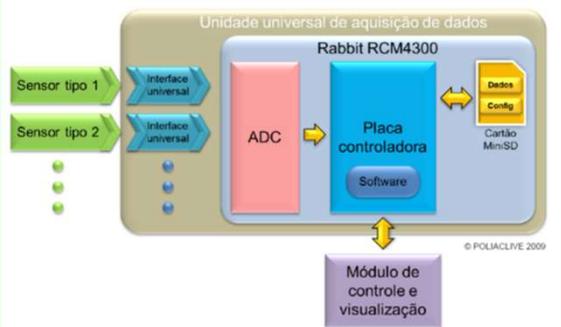
19

Sistema de fusão de sensores: por exemplo pressão e temperatura

20

Introdução

Eletrônica embarcada



projeto de alunos em PSI-2672

© Prof. Emilio Del Moral Hernandez

20

20

Língua Eletrônica para controle de qualidade alimentar e detecção de substâncias nocivas



1. Gordura
2. Proteína
3. Lactose
4. pH

- Sistema com 4 sensores;
- Sistema com 5 frequências diferentes em cada sensor;
 - $4 \times 5 = 20$ entradas para a RNA

projeto de alunos em PSI-2672

© Prof. Emilio Del Moral Hernandez

21

Seguidor do alvo dos olhos na tela do computador

Eye-tracker – Definição do problema

"Utilizar técnicas neurais para determinar a posição (x,y) para a qual os olhos do usuário estão apontados na tela"



Coleta de dados

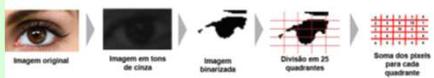


Método semi-automático de coleta de dados:

- Divisão da tela do computador em 25 quadrantes
- Para cada quadrante, tirar 20 fotos do olho (somente do olho, não do rosto todo) apontando para a posição (com ajuda de software para tirar fotos e salvá-las)

Total de elementos da amostra: 500 fotos

Pré-processamento

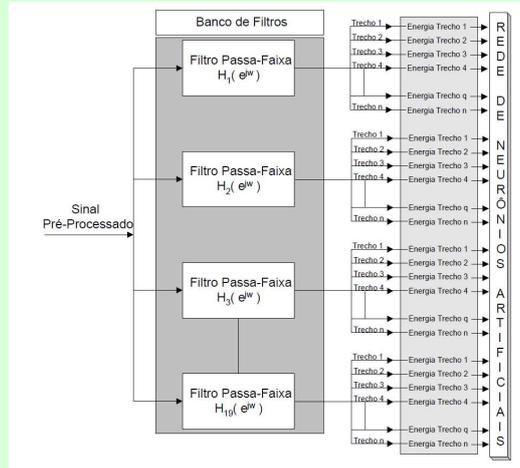


projeto de alunos em PSI-2672

22

TCC em Reconhecimento de comandos de voz (Daniel e Gabriel) – sobe, desce, esquerda, direita

23



© Prof. Emilio Del Moral Hernandez

23

23

Exemplo de modelagem / reconhecimento automático de padrões ... (tese de Liselene / Prof Miguel)

25

O procedimento de detecção do Vazamento

- * Haste de escuta
- * Correlacionador de ruído
- * Geofone



© Prof. Emilio Del Moral Hernandez

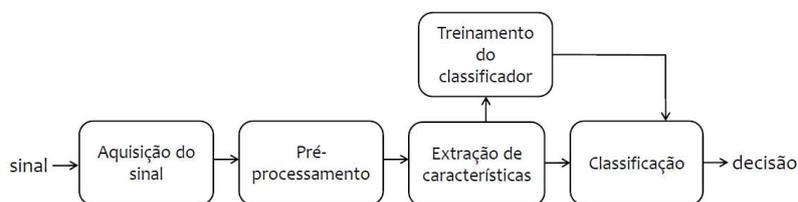
25

25

Exemplo de modelagem / reconhecimento automático de padrões ... (tese de Liselene / Prof Miguel)

26

Sistema de Detecção de Vazamento



© Prof. Emilio Del Moral Hernandez

26

26

Inventário de Projetos Desenvolvidos em PSI 2672 - Práticas em Reconhecimento de Padrões, Modelagem e Neurocomputação, nas 6 turmas de 2011 a 2016
prof. Emilio Del Moral Hernandez

27

Ano 2016

- Cancelador ativo de ruído
- Classificação de fibrilação atrial a partir de eletrocardiograma
- Classificador de movimentos a partir de acelerômetro vestível
- Estimador de Valor de Ações (Flutuações Financeiras e Predição)
- Estimador de desempenho em redação (desempenho escolar)
- Medidor da qualidade da água
- Reconhecedor de dígitos de placas de veículos
- Reconhecedor de imagens de frutas
- Rec. da intenção de mover a mão direita e a esquerda a partir de sinais cerebrais

Ano 2015

- Estimador do valor de fechamento das ações da Petrobras
- Classificador de instrumentos musicais
- Regressor embarcado para ventilação inteligente
- Solar Power Production Estimation (Software for a Smart Metering device)
- Reconhecedor de Objetos em Imagens Digitais
- Reconhecimento de Folhas a Partir de Fotos com Fundo Branco
- Benchmark de CPUs: um regressor multivariado de desempenho
- Reconhecedor de caracteres: um classificador de padrões
- Reconhecedor de acordes musicais: um classificador de padrões
- Deteção de Fraudes em Compras no Cartão
- Padrões nos Sobreviventes e Vítimas do Titanic
- Estimador de pigmentos para tintas a partir de uma amostra

© Prof. Emilio Del Moral Hernandez

27

27

Ano 2014	<ul style="list-style-type: none"> Identificador de sistema dinâmico Previsor Futebolístico Eye tracker Reconhecimento de placas de automóveis Reconhecimento de padrões de consumo em aparelhos aplicado a Smart Grids Estimativa de preços de carros Classificador de cogumelos venenosos
Ano 2013	<ul style="list-style-type: none"> Classificação de sinais de EEG e relação com epilepsia Estimador de consumo de eletricidade residencial Análise Sentimental de notícias Identificação de um Pixel Isolado em uma Imagem Simples Preditor de sobrevivência em pacientes Cardíacos Estimador do grau do mal de Parkinson Classificador de idiomas
Ano 2012	<ul style="list-style-type: none"> Classificação da Qualidade do Leite Estimador de PH para amostras de vinho Previsão de Ações na Bolsa de Valores (reconhecedor de padrões) Previsão de Ações na Bolsa de Valores (estimador) Reconhecedor de Combustível Adulterado
Ano 2011	<ul style="list-style-type: none"> Classificação em Gêneros Musicais Estimador de Correção do Erro de um Sensor de Pressão Diferencial Análise da qualidade de vinhos baseado em características físico-químicas Sistema de reconhecimento de Placas de Trânsito Reconhecedor de Alcoolismo e Sinais Cerebrais Língua eletrônica para a determinação de propriedades do leite

28

Amostra de materiais STOA de anos anteriores

29

Sistemas USP | Curso: PSI3571 - Prática

https://disciplinas.usp.br/course/view.php?id=62312

Materiais de apoio às atividades em sala de aula

Materiais de apoio às atividades em sala de aula.

Atenção: A leitura dos materiais de apoio disponibilizado via STOA **NÃO Substitui as discussões e o aprendizado que ocorrem com a sua presença nas aulas desta disciplina**. Se tiver alguma dúvida sobre a necessidade da sua presença em sala de aula, estou disponível para ajudá-lo a entender; me procure após encerrarmos a nossa próxima aula e conversamos sobre isso.

- Repositório (36Mb) de apresentações finais de PSI2672 nos anos 2011 a 2016 - perto de 50 ; projetos de alunos de 5o ano / Prof Emilio Del Moral Hernandez
- Breve descrição dos projetos PSI2672 que foram apresentados em 2017
- Instale o ambiente MBP no seu computador Windows (instale / use máquina virtual se seu computador for Apple; ou use os computadores da sala C1-10 ou similar)
- PSI3571 - para STOA - Slides de apoio às atividades de sala de aula - com entregas escritas - nas 4 primeiras semanas de aula de 2018
- Enunciado da atividade PSI3571 Individual - slides para apresentar na aula de 2 de abril
- Transforme seus slides para a atividade de apresentação de 02 de abril em (um) arquivo PDF e deposite aqui neste escaninho!
- PSI3571 - para STOA - Slides de apoio às atividades de sala na 5a semana de aula - com apresentações e atividade de avaliação dos colegas
- Slides para a parte extra da 5a semana de aula em PSI3571 - Aprendizado do MLP por EBP - Opcional para quem já fez PSI3471 no 4o ano
- Slides para a parte extra da 6a semana de aula em PSI3571 - Deduzindo expressões analíticas do EBP - Opcional para quem já fez PSI3471 no 4o ano
- PSI3571 -para STOA em07-05-2018 - Slides de apoio as exposicoes da 6a semana de aula ate a aula do dia 07 de maio

Restrito Disponível se: Você faz parte de Turma 2018101

- Slides de apoio à parte extra da aula em 07 de maio - tema Sobreaprendizado
- Slides de apoio às temáticas e atividades na aula em 14 de maio - temas diversos
- Slides de apoio às temáticas e atividades na aula em 21 de maio - temas diversos
- Slides de apoio às temáticas e atividades na aula em 04 de junho - temas de finalização de projetos

© Prof. Emilio Del Moral Hernandez

29

30

PSI3571-101-2018: RES x + v

https://edisciplinas.usp.br/mod/page/view.php?id=2335830

Início > Ambientes > 2018 > EP > PSI > PSI3571-101-2018 > Informações gerais da disciplina > RESUMO DAS APRESENTAÇÕES FINAIS DOS PROJETOS DE PS...

RESUMO DAS APRESENTAÇÕES FINAIS DOS PROJETOS DE PSI3571 EM 2018

EQUIPES de PSI3571 e SEUS TEMAS de projetos em 2018 (em mais detalhes adiante):

Equipe I
(Douglas Navarro, Gabriel Gouveia, Tiago Nagy)
- Regressor multivariado: Estado do metrô - Sistema de predição de estado de operação do metrô de São Paulo
- Reconhecedor de padrões: Detector presencial de veículos - Reconhecedor de carros em vídeos
- Regressor multivariado: Detector angular de veículos - Preditor de ângulo de carros em vídeos

Equipe II
(Fernando, João Lucas, Thomas Mujal)
- Regressor: Controle de drones
- Reconhecedor: Reconhecedor de eventos em ambiente residencial
- Reconhecedor: Identificador de faces humanas

Equipe III
(Lucas Perreira Kok, Fábio Alves, Pedro Kozilek)
- Regressor: Banho quente - Sistema preditor de quanto tempo falta para o próximo banho
- Reconhecedor: Reconhecedor de Risco de Desmatamento
- Regressor: Cálculo da taxa de gordura corporal

Equipe IV
(André Ferrari, Ibraim Rebouças, Rodrigo Zobarán)
- Regressor: Estimador de corrente
- Reconhecedor: Detecção de defeitos em máquinas por amostragem sonora.
- Reconhecedor: Validação de áudios

Equipe V
(Alexandre Oide, Gabriel Kim, Lincoln Kawakami)
- Regressor: Previsor de alcance no lançamento de um projétil
- Reconhecedor: Reconhecedor de tipo de interação tátil de uma pessoa e um modelo (e.g brinquedo)

© Prof. Emilio Del Moral Hernandez

30

30

31

PSI3571-101-2018: RES x + v

https://edisciplinas.usp.br/mod/page/view.php?id=2335830

Equipe V
(Alexandre Oide, Gabriel Kim, Lincoln Kawakami)
- Regressor: Previsor de alcance no lançamento de um projétil
- Regressor: ColorRec - Dispositivo capaz de reconhecer a cor (RGB) de superfícies.
- Reconhecedor: Reconhecedor de tipo de interação tátil de uma pessoa e um modelo (e.g brinquedo)

----- Mais detalhes sobre alguns dos projetos listados acima ...

Estimador de estado do metrô - Este sistema busca abstrair a noção intuitiva de pessoas que usam o metrô diariamente e sabem os piores horários para embarcar.

Detector presencial de veículos - Esse projeto busca identificar veículos presentes em vídeos. A rede neural é usada como uma das etapas do processamento, que inclui outras etapas responsáveis por diminuir falsos positivos e assegurar uma boa identificação. O contexto do projeto é o de câmeras automotivas, que poderiam ser usadas, por exemplo, em veículos autônomos.

Estimador de orientação angular de veículos - Esse regressor entraria ao final do projeto de veículos autônomos. Após a identificação dos veículos em cada frame, esta rede neural identificaria o ângulo do veículo. No contexto do projeto, isto poderia ajudar o sistema inteligente do veículo a evitar colisões.

Controle de drones - desenvolvimento de um sistema de controle alternativo aos existentes para voo de drones. Através de leituras como posicionamento espacial e movimentação, visa-se gerar um estímulo preciso de alimentação dos motores do drone a fim de que a trajetória realizada seja igual a desejada.

Reconhecedor de eventos em ambiente residencial - através da interpretação de sinais de microfone, objetiva-se identificar padrões sonoros correspondentes a eventos em uma residência, como o abrir de uma porta, ou o ligar de um microondas. Com esse aprendizado supervisionado, é possível identificar eventos e monitorar atividade em um cômodo da residência, bem como estimar dados de consumo de energia elétrica, por exemplo.

Identificador de faces humanas - identificar padrões presentes em faces humanas e utilizá-los para identificar pessoas em fotos.

Previsor de banho quente - Sistema preditor de quanto tempo falta para o próximo banho - O crescimento do uso de boilers para manutenção da água quente sanitária é algo que traz bastante conforto para o banho. No entanto pode trazer custos adicionais em comparação com sistemas tradicionais de chuveiro elétrico. Pensando nisso estudamos um sistema que estime em quanto tempo se dará o próximo banho de forma a servir de informação de quando o complemento elétrico do boiler deverá ser acionado para preparar a água quente somente quando ela efetivamente for usada.

Cálculo da taxa de gordura corporal - A taxa de gordura corporal é um indicador de saúde relevante. Apesar de apresentar uma importância igual, se não maior, do que a massa do indivíduo, a taxa de gordura corporal é pouco calculada devido a sua complexidade de cálculo sem equipamentos médicos. Os dois métodos mais populares para a estimativa da massa de gordura corporal são o adipômetro e a balança de bioimpedância. Ambos os métodos apresentam imprecisões e dificuldades técnicas para a estimativa do indicador. Pensando nisso foi desenvolvido o um regressor que estima o percentual de gordura do corpo com base em diferentes medidas de circunferência do corpo humano.

© Prof. Emilio Del Moral Hernandez

31

31

32

PSI3571-101-2018: RES x + v

https://edisciplinas.usp.br/mod/page/view.php?id=2335830

com o mesmo reconhecimento gestos como: caminhos, apertados, parciais, etc.

CONVITE: Nos dias 11 e 18 de junho na sala B2-09 das 15 hs até as 18:30 teremos apresentações de 15 projetos práticos desenvolvidos pelos alunos de PSI3571 - Práticas em Reconhecimento de Padrões, Modelagem e Inteligência Computacional - da turma de 2018. Todos os projetos envolvem sistemas multivariados com aplicações concretas de ferramentas de reconhecimento de padrões e de fusão de informação (regressores multivariados). Eles foram desenvolvidos por alunos de 5o ano de Eletrônica e Sistemas / Sistemas Eletrônicos, Automação e Controle, Engenharia Ambiental, Mecânica e Biomédicas. Aqui vai uma prévia de temáticas de alguns dos trabalhos que serão apresentados: controle de drones, identificação de faces, reconhecimento de eventos residenciais, detecção de presença de veículos, avaliação de estado do metrô, estimação angular de veículos, modelagem de transistores, análise automática de falhas em máquinas, detecção de adulteração de áudios, previsão de uso de aquecedor de água, detecção de áreas desmatadas, estimação de gordura corporal, modelagem de processo balístico, medida de cores em superfícies, reconhecimento de ações táteis.

Alunos EPUSP, docentes e demais convidados dos autores dos trabalhos apresentados serão muito bem vindos para acompanhar as exposições e os debates entre os alunos de PSI3571 após cada apresentação. Prestigiemos e aprendamos com estas interessantes apresentações finais dos 15 projetos práticos.

(para mais detalhes, visite o link <https://edisciplinas.usp.br/mod/page/view.php?id=2335830>)

--- Calendário detalhado das Apresentações:

- Em **11 de junho** (15:00h pontualmente): equipes **I, II e IV**, em ordem sorteada no dia.
- Em **18 de junho** (15:00hs pontualmente): equipes **III e V**, em ordem sorteada no dia.

Equipes:

- Equipe I:** Douglas, Gabriel Gouveia e Tiago (apresentam **dia 11**)
- Equipe II:** Fernando, João Lucas e Thomas (apresentam **dia 11**)
- Equipe III:** Fábio, Lucas e Pedro (apresentam **dia 18**)
- Equipe IV:** André, Ibraim e Rodrigo (apresentam **dia 11**)
- Equipe V:** Alexandre, Gabriel Kim e Lincoln (apresentam **dia 18**)

Última atualização: terça, 12 jun 2018, 18:51

© Prof. Emilio Del Moral Hernandez

32

32

33

Parte B: Soluções em 2 estágios ... Quase uma necessidade em reconhecedores de alto desempenho

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

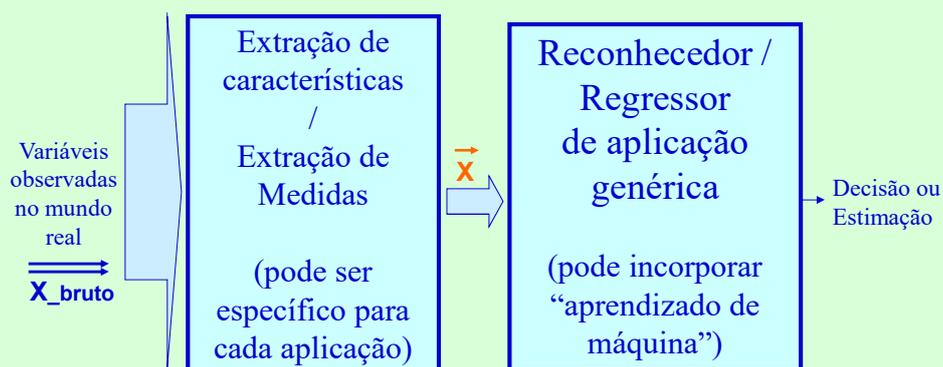
33

33

Em vários dos projetos de regressão e reconhecimento realizados (embora não em todos) houve a necessidade de uma solução envolvendo dois estágios ... Um primeiro responsável por extração de características / extração de medidas mais relevantes dos objetos "X" brutos, medidas essas normalmente específicas para cada aplicação, e um segundo estágio atuando sobre o vetor com essas diversas medidas, e que emprega alguma técnica para a regressão / identificação de padrões, independente da aplicação, como é o caso de redes neurais artificiais

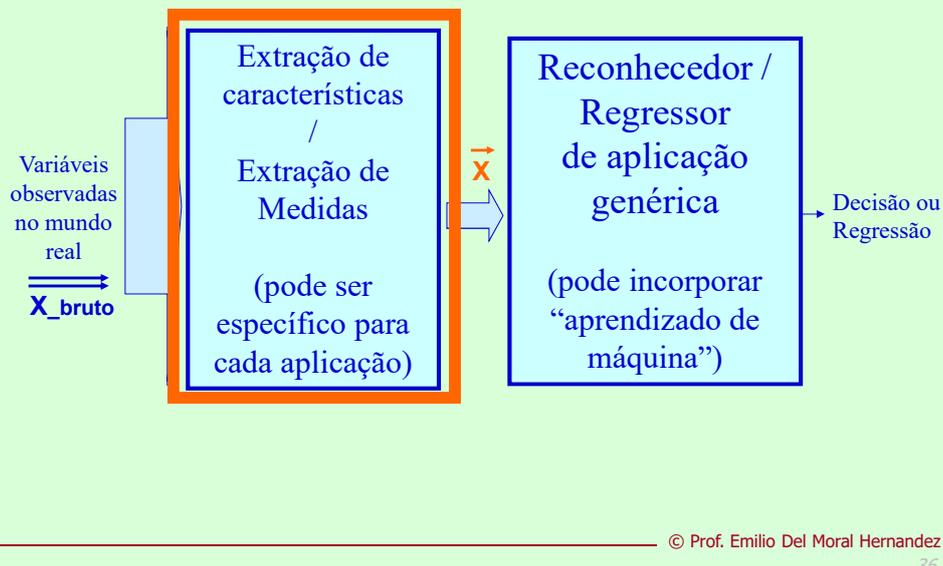
34

Elaborando uma Solução em dois estágios



35

... O 1o estágio gera um Vetor de Medidas, \vec{X}
(o segundo estágio operará sobre tal vetor)



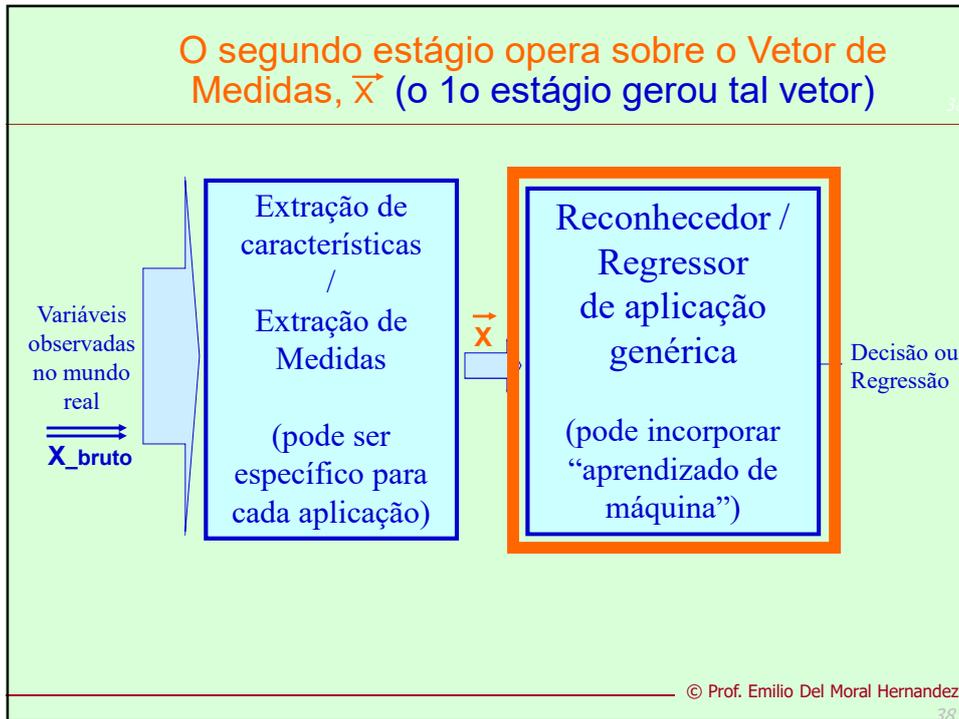
36

Alguns exemplos de grandezas componentes dos vetores de medidas X :

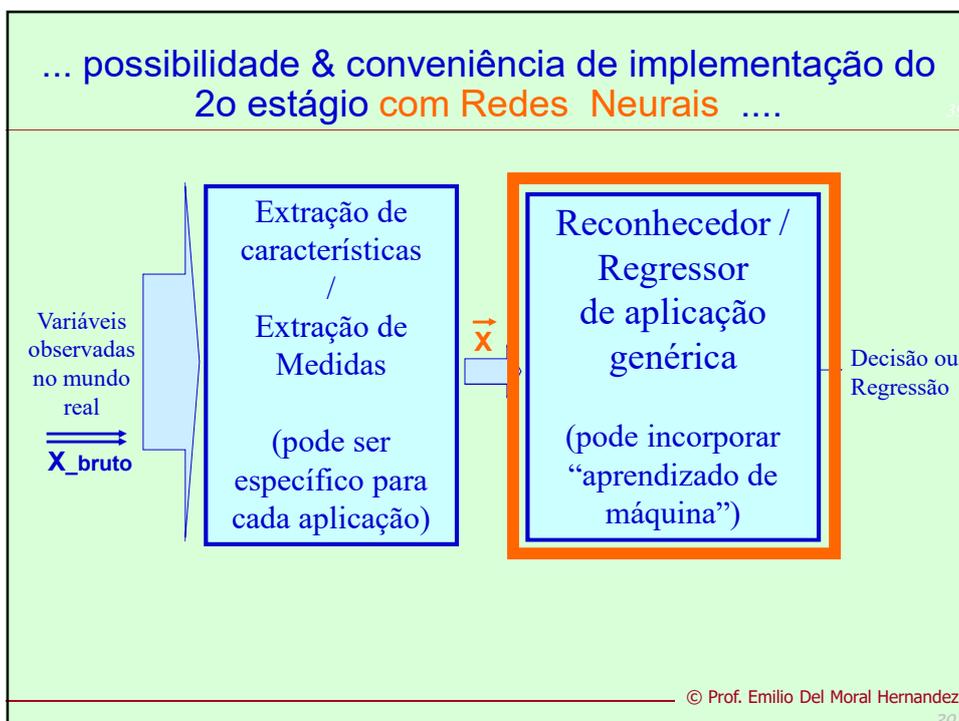
- Grandezas macroscópicas como energia do sinal, amplitude, frequência média ...
- Componentes de diversas harmônicas (análise em frequência)
- Componentes de análise tempo-frequência
- Intensidades luminosas ou intensidades em canais de cor (RGB por ex.)
- Histogramas de intensidades
- Principal Components (componentes principais – PCA)
- Medidas sobre séries temporais (médias móveis, por exemplo; medidas de dispersão / instabilidade localizadas)
- Medidas específicas à aplicação, experimentadas em problemas similares ao seu, relatadas na literatura técnica como sendo de sucesso

© Prof. Emilio Del Moral Hernandez

37



38



39

**Parte C: Separadores com Fronteiras lineares
e Separadores com Fronteiras genéricas
(fronteiras não lineares) – Entendendo porquê
Redes Neurais MLPs implementam
superfícies de separação quaisquer**

40

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

40

***1) Discriminadores com
fronteiras lineares***

***2) Banco de vários
discriminadores com fronteiras
lineares + circuitos
combinatórios: reconhecimento
de padrões com fronteiras de
separação arbitrárias***

© - Prof. Emilio Del Moral Hernandez

41

1) Entendamos em lousa como automatizar o cálculo para saber “de que lado” do hiperplano um vetor X genérico está ... Usemos nossos conhecimentos anteriores de algebra linear e vetores

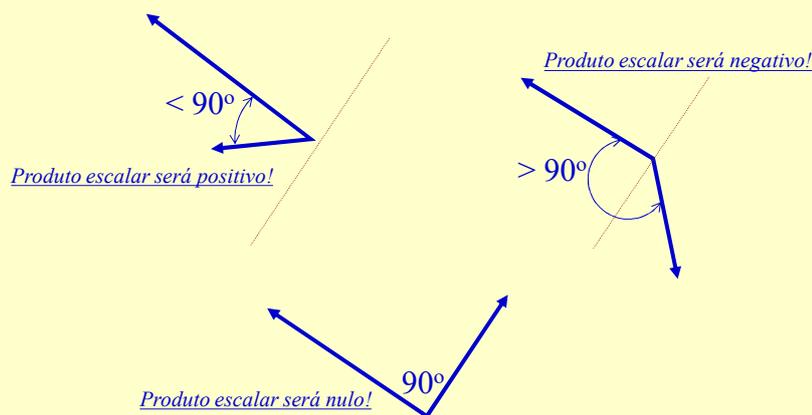
2) Entendamos em lousa também a relação direta entre a equação de um hiperplano separador genérico e a equação do Perceptron de Roseblatt

42

© - Prof. Emilio Del Moral Hernandez

42

Aquecendo os motores em lousa com a interpretação geométrica do produto escalar em 2D e 3D ... o resultado desse produto é positivo, nulo ou negativo, de acordo com o ângulo entre os vetores / ou seja, de acordo com o alinhamento ou desalinhamento entre eles ...

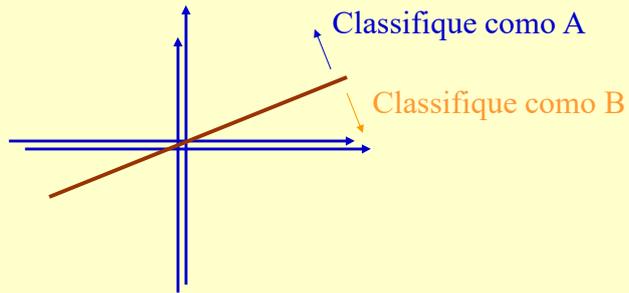


43

© - Prof. Emilio Del Moral Hernandez

43

Primeiro estudemos o poder de separação de um hiperplano sem viés (ele “passa na origem”)

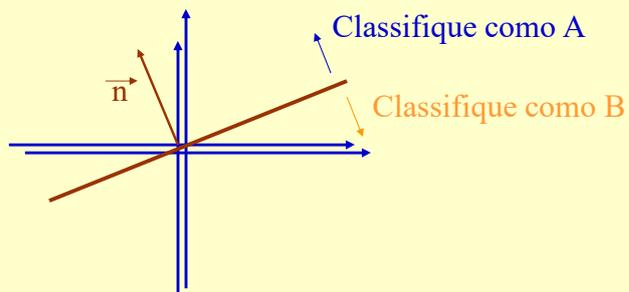


44

© - Prof. Emilio Del Moral Hernandez

44

Primeiro estudemos o poder de separação de um hiperplano sem viés (ele “passa na origem”)

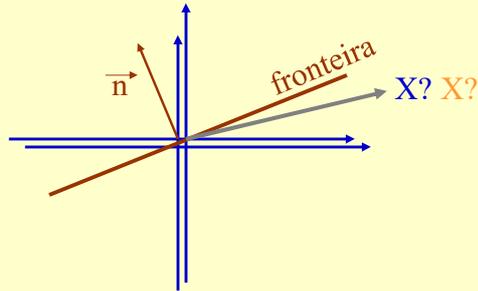


45

© - Prof. Emilio Del Moral Hernandez

45

Primeiro estudemos o poder de separação de um hiperplano sem viés (ele “passa na origem”)

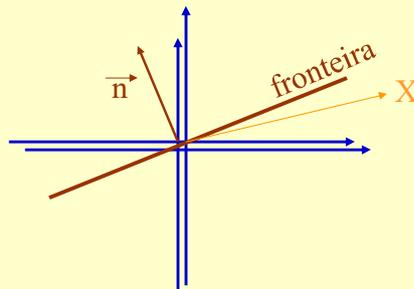


46

© - Prof. Emilio Del Moral Hernandez

46

Primeiro estudemos o poder de separação de um hiperplano sem viés (ele “passa na origem”)



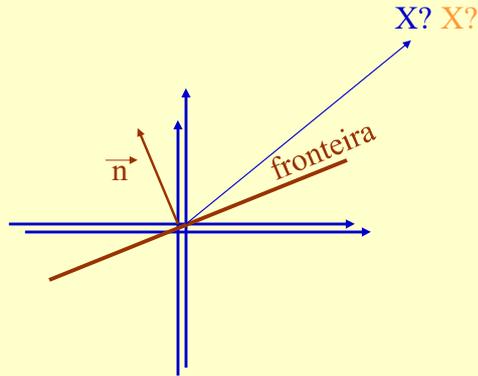
... neste caso, $X \cdot N < 0$: esse sinal negativo no valor do produto escalar $X \cdot N$ indica que X está no “semi-espaco oposto” à direção do vetor normal ao plano.

47

© - Prof. Emilio Del Moral Hernandez

47

Primeiro estudemos o poder de separação de um hiperplano sem viés (ele “passa na origem”)

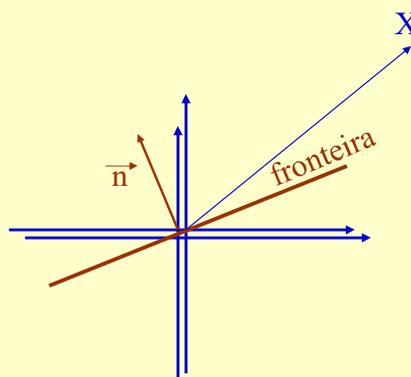


48

© - Prof. Emilio Del Moral Hernandez

48

Primeiro estudemos o poder de separação de um hiperplano sem viés (ele “passa na origem”)



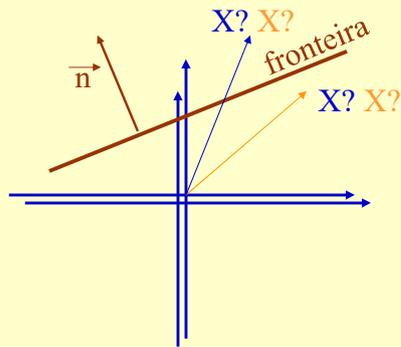
... neste caso, $X \cdot N > 0$: esse sinal positivo no valor do produto escalar $X \cdot N$ indica que X está no “semi-espaço alinhado” à direção do vetor normal ao plano.

49

© - Prof. Emilio Del Moral Hernandez

49

Agora, o poder de separação de um hiperplano COM viés (ele não necessariamente “passa na origem”)

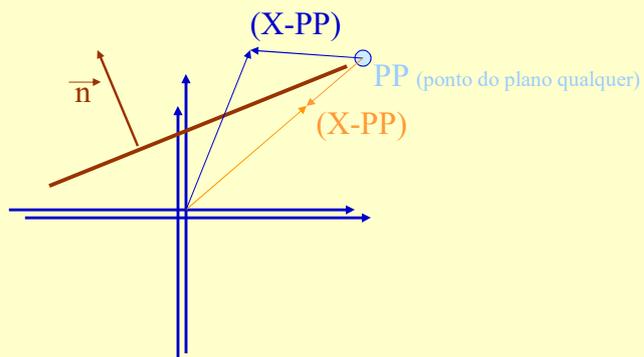


Agora, infelizmente temos $X.N > 0$ nos dois casos de X!!!
A regra de separação anterior não nos serve mais! 50

© - Prof. Emilio Del Moral Hernandez

50

Agora, foquemos no maior poder do hiperplano COM viés (ele não necessariamente “passa na origem”)

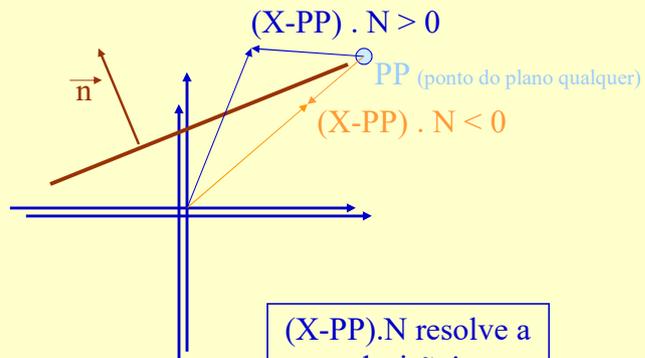


51

© - Prof. Emilio Del Moral Hernandez

51

Agora, foquemos no maior poder do hiperplano COM viés (ele não necessariamente “passa na origem”)



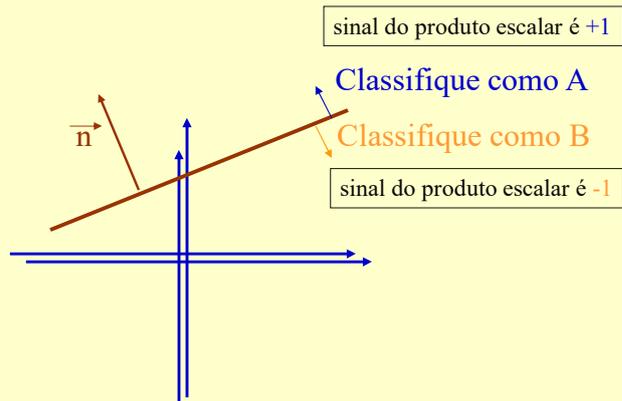
$(X-PP).N$ resolve a decisão!
 Nota: PP pode ser qualquer ponto do plano

52

© - Prof. Emilio Del Moral Hernandez

52

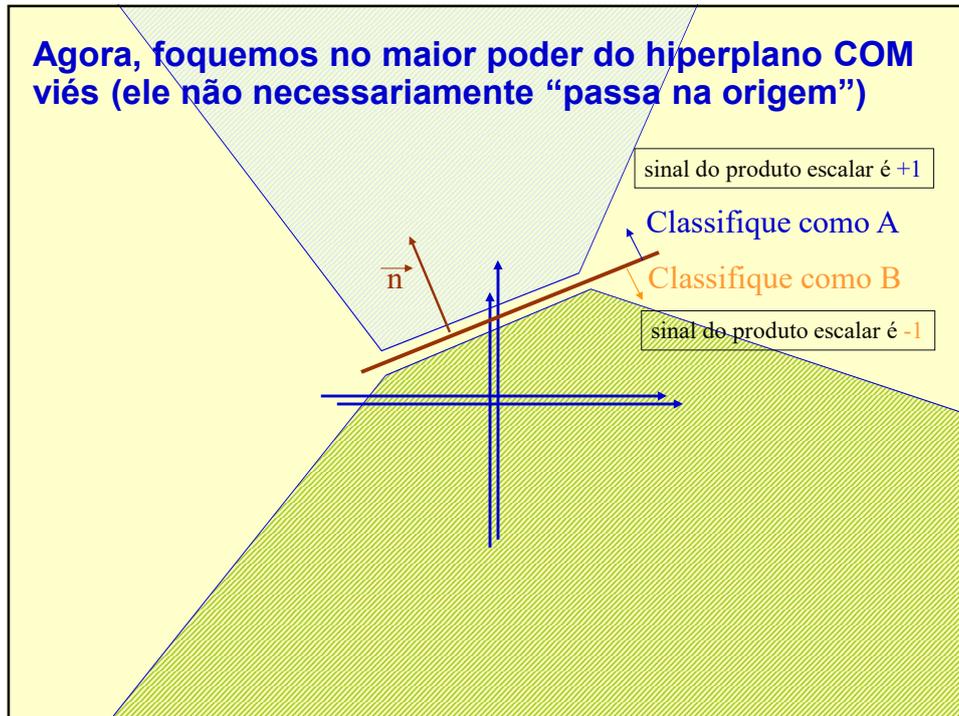
Agora, foquemos no maior poder do hiperplano COM viés (ele não necessariamente “passa na origem”)



53

© - Prof. Emilio Del Moral Hernandez

53



54

Em lousa...

Conciliando “ $(X-PP).N > 0$?”

com

o Perceptron de Rosenblatt:

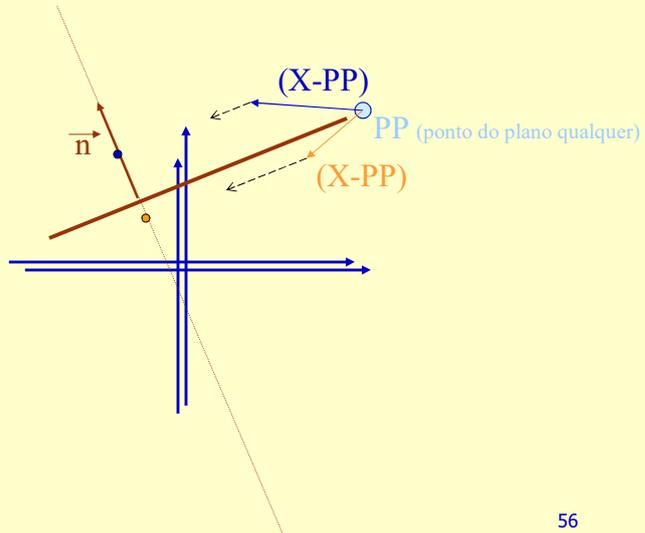
$$y = \text{sign}(W.X - \text{viés})$$

55

© - Prof. Emilio Del Moral Hernandez

55

O produto escalar $(X-PP).n$ entendido como projeção de X num eixo “principal” (unidimensional) de discriminação

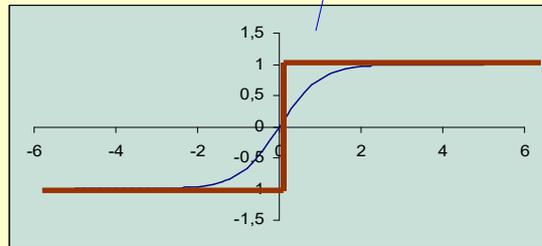
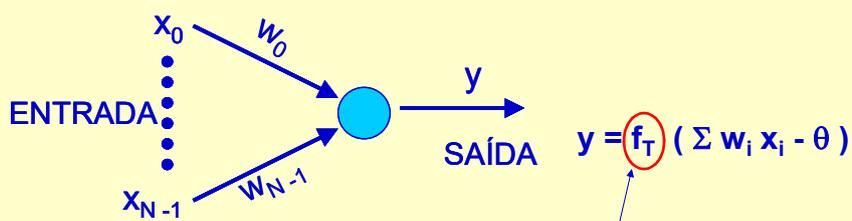


56

© - Prof. Emilio Del Moral Hernandez

56

$f_T \text{ Sign}(\cdot) \dots$ versus $\dots f_T \text{ Sigmoide}(\cdot)$

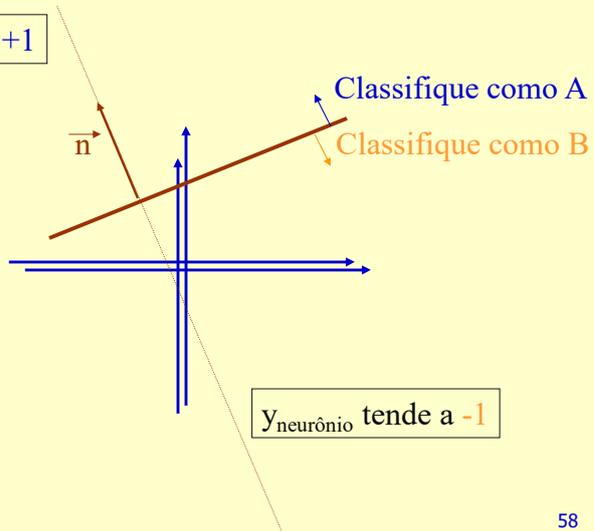


© - Prof. Emilio Del Moral Hernandez

57

O Perceptron de Rosenblat, mesmo que seja “algo contínuo” (não digital) em y , é efetivo como um discriminador linear!

$y_{\text{neurônio}}$ tende a +1



58

© - Prof. Emilio Del Moral Hernandez

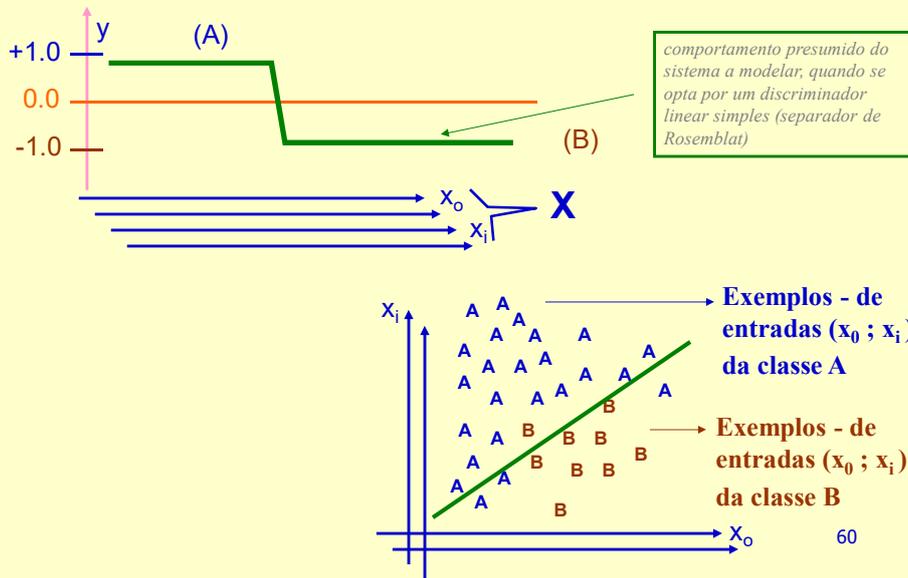
58

... E se o separador linear apresentar baixo desempenho?

© - Prof. Emilio Del Moral Hernandez

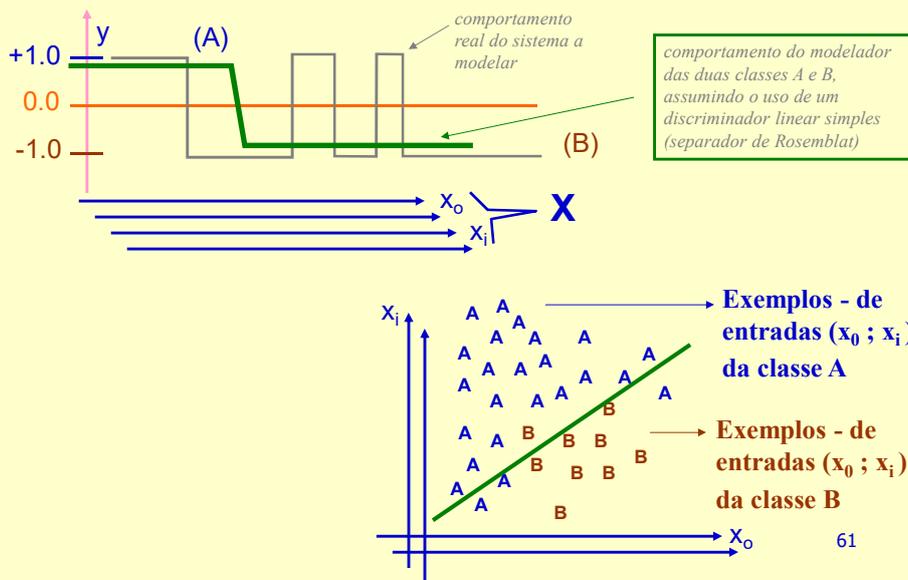
59

No caso de classificação binária / reconhecimento de padrões ...



60

No caso de classificação binária / reconhecimento de padrões ...



61

Matriz de confusão para caracterização de desempenho de reconhecedor de padrões

	“Classe A” (sugestão do MLP)	“Classe B” (sugestão do MLP)
Classe A	AC_A	ER_A
Classe B	ER_B	AC_B



- AC_A : padrão da classe A reconhecido como classe A
- ER_A : padrão da classe A reconhecido como classe B
- AC_B : padrão da classe B reconhecido como classe B
- ER_B : padrão da classe B reconhecido como classe A

Taxa de Acertos Tente calculá-la com base nos elementos acima presentes na matriz de confusão

62

© - Prof. Emilio Del Moral Hernandez

62

... E se o separador linear apresentar baixo desempenho?

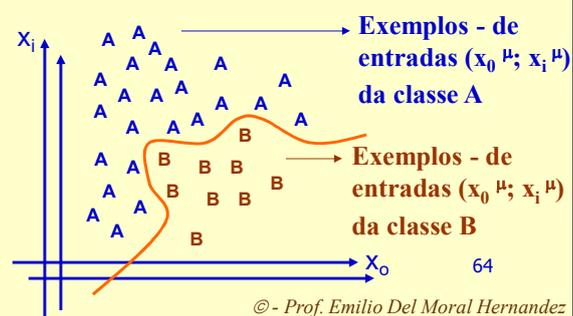
2) Banco de discriminadores lineares + circuitos combinatórios: reconhecimento de padrões com fronteiras de separação arbitrárias

© - Prof. Emilio Del Moral Hernandez

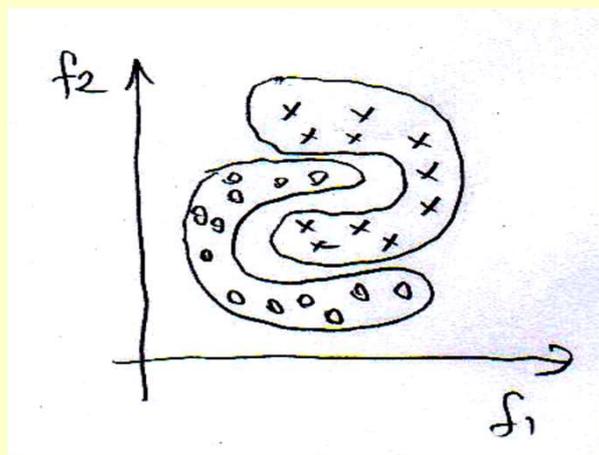
63

Em cenários mais complicados (e com “exigência” do máximo desempenho) ...

- Não há separabilidade linear (através de hiperplano)
- A linha / ou a hipersuperfície de separação tem que ser algo mais elaborado que um hiperplano



64



65

Seguindo com casos mais complicados de configurações, para espaço X 3D e superior

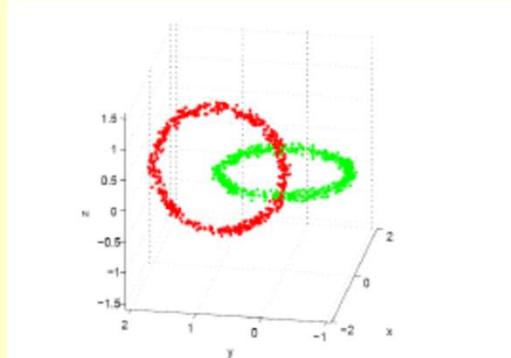


Figura 1 – Chainlink Dataset

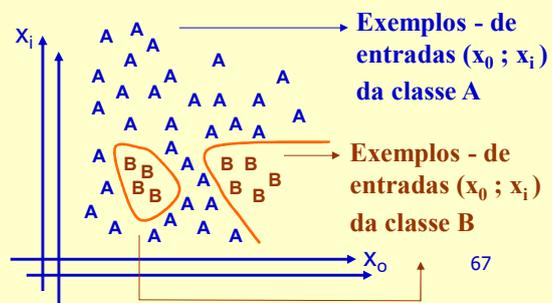
66

© - Prof. Emilio Del Moral Hernandez

66

Seguindo com casos complicados de configurações de classes A e B

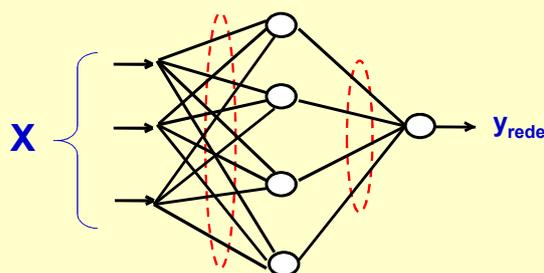
- Não há sequer contiguidade / há fragmentação das regiões do espaço associados a cada classe



67

Caso particular de uma rede de uma camada de neurônios escondidos e um neurônio na saída

- lembrete ... Segundo Kolmogorov e Cybenko, esta estrutura simples é suficiente (é um aproximador universal de funções de x_1, x_2, x_3, \dots)
- Temos nesse caso duas camadas de neurônios e duas camadas de pesos a otimizar durante o treinamento



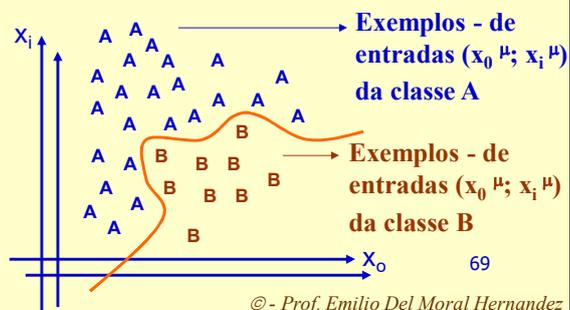
68

© - Prof. Emilio Del Moral Hernandez

68

Em cenários mais complicados (e com “exigência” do máximo desempenho) ...

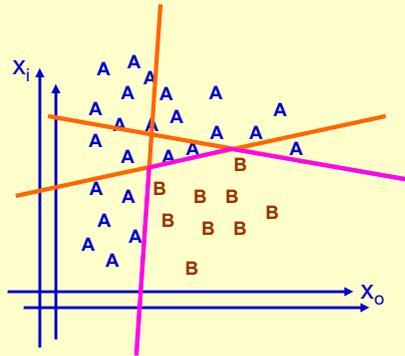
- Não há separabilidade linear (através de hiperplano)
- A linha / ou a hipersuperfície de separação tem que ser algo mais elaborado que um hiperplano



© - Prof. Emilio Del Moral Hernandez

69

Cybenko “pelas bordas” ... Conjugando vários separadores lineares para uma fronteira genérica



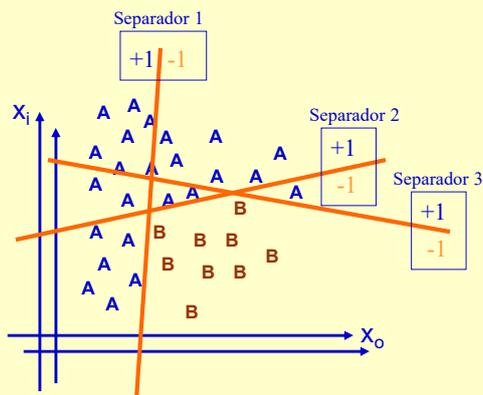
70

© - Prof. Emilio Del Moral Hernandez

70

Cybenko “pelas bordas” ... Conjugando vários separadores lineares para uma fronteira genérica

Cada um dos 3 separadores tem alguma falha, Quando considerado isoladamente.



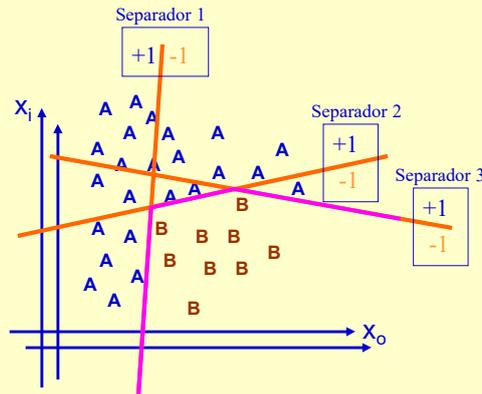
71

© - Prof. Emilio Del Moral Hernandez

71

Cybenko “pelas bordas” ... Conjugando vários separadores lineares para uma fronteira genérica

Cada um dos 3 separadores tem alguma falha,
Quando considerado isoladamente.



Solução coletiva:

Decisão por A =

A segundo Sep. 1

OR

A segundo Sep. 2

OR

A segundo Sep. 3

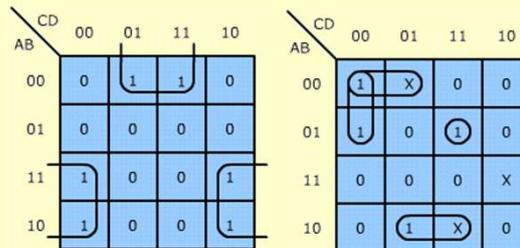
Em outros casos, o cálculo lógico pode ser mais complexo, mas ORs, NORs, NOTs, ANDs e NANDs, sempre darão conta do recado! (Karnaugh)

72

© - Prof. Emilio Del Moral Hernandez

72

Recordemos que com vários ANDs e um OR (ambos factíveis com nós neurais simples) podemos implementar qualquer circuito combinatório ... (... recordem isto de sistemas digitais) ...



Exemplo de cálculo digital envolvendo as saídas de 4 separadores lineares ($S_1, S_2, S_3,$ e S_4) ...

$$F = S_1' \cdot S_2' \cdot S_4' + S_1' \cdot S_2 \cdot S_3 \cdot S_4 + S_1 \cdot S_2' \cdot S_4$$

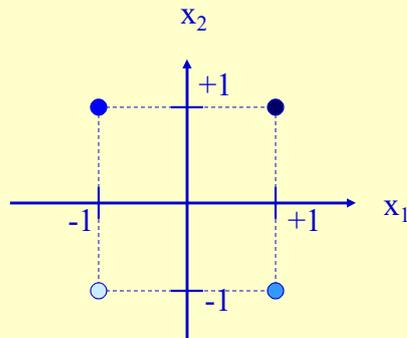
73

© - Prof. Emilio Del Moral Hernandez

73

Implementemos algumas portas digitais de 2 entradas, x_1 e x_2 , com o neurônio camaleão ...

$$y_{\text{neurônio}} = \text{tgh}(w_1 \cdot x_1 + w_2 \cdot x_2 + w_0)$$



**Domínio dos X possíveis ... 4 valores:
 (-1,-1), (-1,+1), (+1,-1) e (+1,+1)**

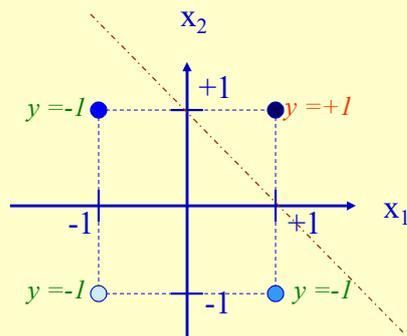
74

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

74

Implementemos algumas portas digitais de 2 entradas, x_1 e x_2 , com o neurônio camaleão ...

façamos uma porta AND: $y_{\text{neurônio}} = \text{tgh}(w_1 \cdot x_1 + w_2 \cdot x_2 + w_0)$



$$y_{\text{neurônio}} = \text{tgh}(1000 \cdot [1 \cdot x_1 + 1 \cdot x_2 - 1])$$

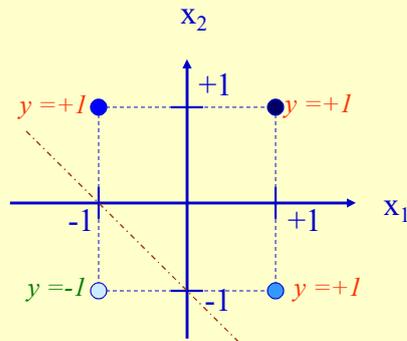
75

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

75

Implementemos algumas portas digitais de 2 entradas, x_1 e x_2 , com o neurônio camaleão ...

façamos uma porta OR: $y_{\text{neurônio}} = \text{tgh}(w_1 \cdot x_1 + w_2 \cdot x_2 + w_0)$



$$y_{\text{neurônio}} = \text{tgh}(1000 \cdot [1 \cdot x_1 + 1 \cdot x_2 + 1])$$

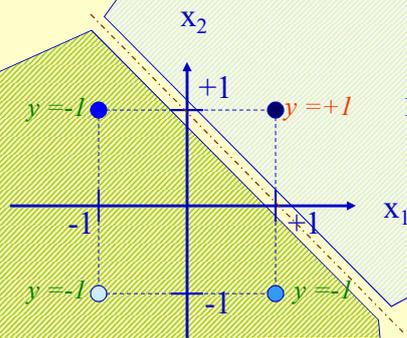
76

PSI2672 – Rec. de Padrões, Modelagem e Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2015-16

76

Digressão O que acontece se em vez de entradas digitais tivermos entradas analógicas nas portas lógicas?? !!! ...

... uma porta AND "semianalógica": $y_{\text{neurônio}} = \text{tgh}(w_1 \cdot x_1 + w_2 \cdot x_2 + w_0)$



ENTRADAS COM VALORES ANALÓGICOS!

$$y_{\text{neurônio}} = \text{tgh}(1000 \cdot [1 \cdot x_1 + 1 \cdot x_2 - 1])$$

77

Moral Hernandez – © 2015-16

77

*Resumo ... Então
precisamos de 3 camadas
para uma fronteira de
separação genérica ?*

- * 1 camada para o “banco
de separadores”*
- * 1 camada para os ANDs
das saídas do banco*
- * 1 camada para o OR*

78

© - Prof. Emilio Del Moral Hernandez

78

ATENÇÃO: em ambos os casos dos separadores analisados (com fronteira linear e com fronteira não linear), as redes neurais são sempre **NÃO LINEARES**, já que qualquer separador, por ter saída binária, é matematicamente falando um cálculo **NÃO linear**

79

Métodos Numéricos e Reconhecimento de Padrões – © Prof. Emilio Del Moral – EPUSP

79

Resumo ... Então precisamos de 3 camadas para uma fronteira de separação genérica ?

Não Necessariamente!

Cybenko mostrou que 2 camadas e nós NÃO puramente digitais podem fazer o serviço!

© - Prof. Emilio Del Moral Hernandez

80

Cybenko - Demonstração

Math. Control Signals Systems (1989) 2: 303-314

Mathematics of Control, Signals, and Systems
© 1989 Springer-Verlag New York, Inc.

310

G. Cybenko

313

Approximation by Superpositions of a Sigmoidal Function*

G. Cybenko†

Abstract. In this paper we demonstrate that finite linear combinations of compositions of a fixed, univariate function and a set of affine functionals can uniformly approximate any continuous function of a real variable with support in the unit hypercube, only mild conditions are imposed on the univariate function. Our results settle an open question about representability in the class of single hidden layer neural networks. In particular, we show that arbitrary decision regions can be arbitrarily well approximated by continuous feedforward neural networks with only a single internal, hidden layer and any continuous sigmoidal nonlinearity. The paper discusses approximation properties of other possible types of nonlinearities that might be implemented by artificial neural networks.

Key words. Neural networks, Approximation, Completeness.

1. Introduction

A number of diverse application areas are concerned with the representation of general functions of an n -dimensional real variable, $x \in \mathbb{R}^n$, by finite linear combinations of the form

$$\sum_{j=1}^m \alpha_j \sigma(\gamma_j^T x + \theta_j), \quad (1)$$

where $y_j \in \mathbb{R}^n$ and $\alpha_j, \theta_j \in \mathbb{R}$ are fixed, γ_j^T is the transpose of y_j so that $\gamma_j^T x$ is the inner product of y_j and x . Here the univariate function σ depends heavily on the context of the application. Our major concern is with so-called sigmoidal σ 's:

$$\sigma(t) = \begin{cases} 1 & \text{as } t \rightarrow +\infty, \\ 0 & \text{as } t \rightarrow -\infty. \end{cases}$$

Such functions arise naturally in neural network theory as the activation function of a neural node (or unit as is becoming the preferred term) [L1], [RHM]. The main result of this paper is a demonstration of the fact that sums of the form (1) are dense in the space of continuous functions on the unit cube if σ is any continuous sigmoidal

* Date received: October 21, 1988. Date revised: February 17, 1989. This research was supported in part by NSF Grant DCR-8619103, ONR Contract N000-86-G-0202 and DOE Grant DE-FG02-85ER20005.

† Center for Supercomputing Research and Development and Department of Electrical and Computer Engineering, University of Illinois, Urbana 61801, U.S.A.

303

4. Results for Other Activation Functions

In this section we discuss other classes of activation functions that have approximation properties similar to the ones enjoyed by continuous sigmoidals. Since these other examples are of somewhat less practical interest, we only sketch the corresponding proofs.

There is considerable interest in discontinuous sigmoidal functions such as hard limiters ($\sigma(x) = 1$ for $x \geq 0$ and $\sigma(x) = 0$ for $x < 0$). Discontinuous sigmoidal functions are not used as often as continuous ones (because of the lack of good training algorithms) but they are of theoretical interest because of their close relationship to classical perceptrons and Gamba networks [MP].

Assume that σ is a bounded, measurable sigmoidal function. We have an analog of Theorem 2 that goes as follows:

Theorem 4. Let σ be a bounded measurable sigmoidal function. Then finite sums of the form

$$G(x) = \sum_{j=1}^m \alpha_j \sigma(\gamma_j^T x + \theta_j)$$

are dense in $L^1(I_n)$. In other words, given any $f \in L^1(I_n)$ and $\epsilon > 0$, there is a sum, $G(x)$, of the above form for which

$$\|G - f\|_{L^1} = \int_{I_n} |G(x) - f(x)| dx < \epsilon.$$

The proof follows the proof of Theorems 1 and 2 with obvious changes such as replacing continuous functions by integrable functions and using the fact that $L^1(I_n)$ is the dual of $L^\infty(I_n)$. The notion of being discriminatory accordingly changes to the following: for $h \in L^\infty(I_n)$ the condition that

$$\int_{I_n} \sigma(\gamma^T x + \theta) h(x) dx = 0$$

for all γ and θ implies that $h(x) = 0$ almost everywhere. General sigmoidal functions are discriminatory in this sense as already seen in Lemma 1 because measures of the form $h(x) dx$ belong to $M(I_n)$.

Since convergence in L^1 implies convergence in measure [A], we have an analog of Theorem 3 that goes as follows:

Theorem 5. Let σ be a general sigmoidal function. Let f be the decision function for any finite measurable partition of I_n . For any $\epsilon > 0$, there is a finite sum of the form

$$G(x) = \sum_{j=1}^m \alpha_j \sigma(\gamma_j^T x + \theta_j)$$

and a set $D \subset I_n$, so that $m(D) \geq 1 - \epsilon$ and

$$|G(x) - f(x)| < \epsilon \quad \text{for } x \in D.$$

313

ed are quite powerful, we that remain to be answered imation (or equivalently, simation of a given quality? y) a role in determining the suspect quite strongly that i will require astronomical dimensionalities that plagues Some recent progress con- srominated and the number ound in [MSJ] and [BH], ineness of the results of this : more attention.

n, Christopher Chase, Lee atarov, Richard Lippmann, tences, and improvements

New York, 1972.

realizations?, *Neural Comput.* (to

tems and control, *IEEE Control*

3. Classifying learnable geometric

ndings of the 18th Annual ACM

p. 273-282.

and the Pompeiu problem, *Am.*

sets using the Radon transform,

wo Hidden Layers are Sufficient,

University, 1988.

of linear combinations, *SIAM J.*

us mappings by neural networks,

EE Trans. Acoust. Speech Signal

stoward networks are universal

a Neural Net and Conventional

87.

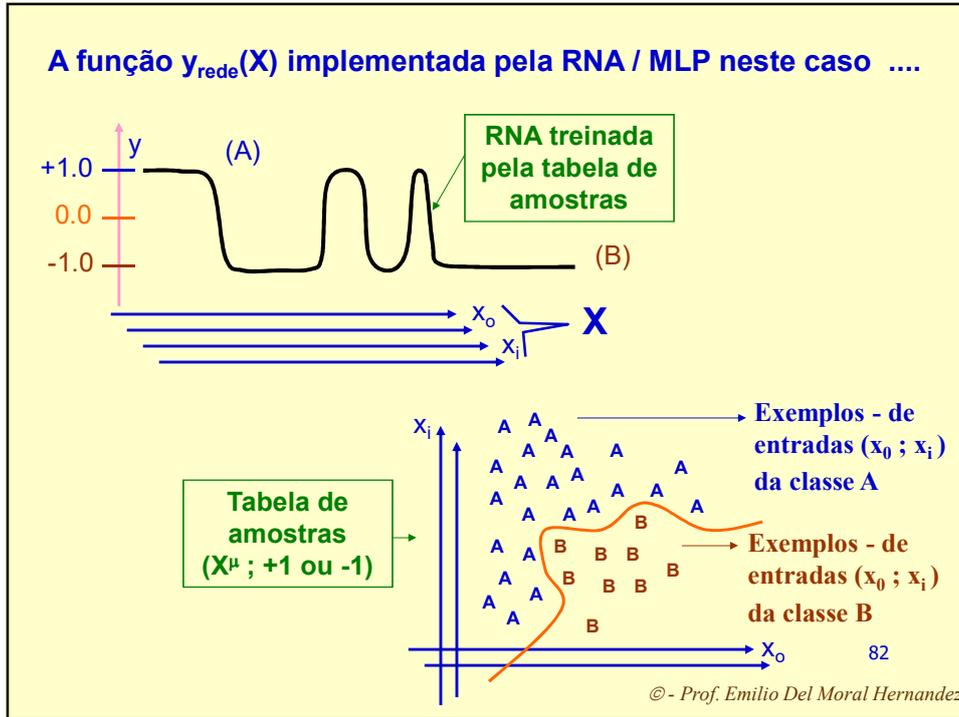
mal Classifiers, Technical Report,

-475.

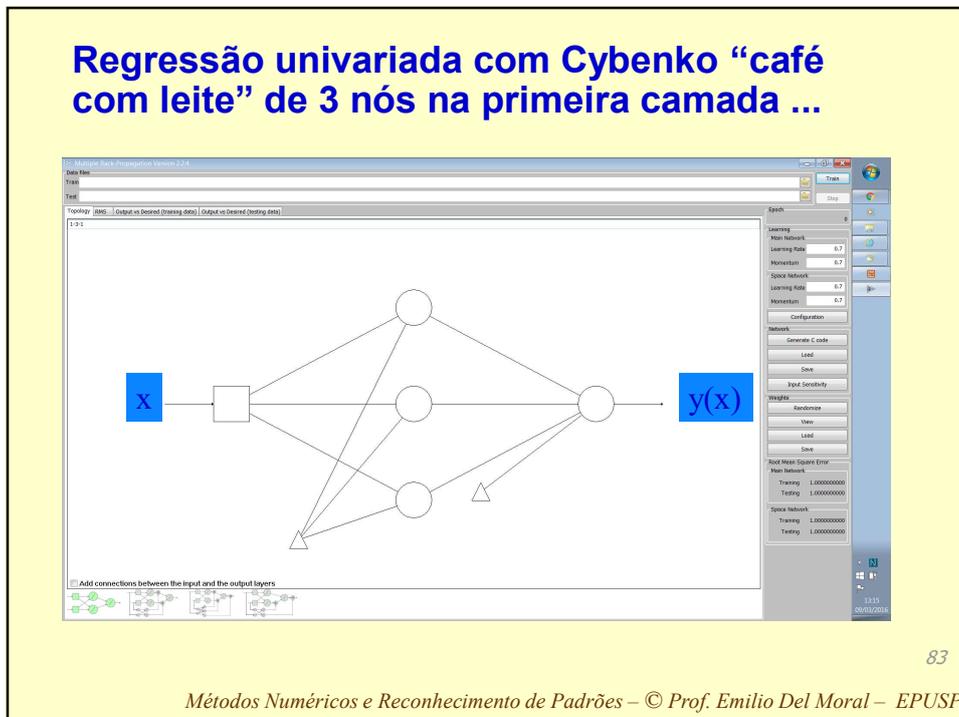
works by sigmoidal functions,

A. University of Lowell, 1988.

81



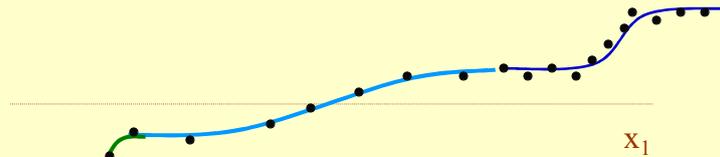
82



83

Cybenko “café com leite” (regressão genérica univariada), para aproximação universal de funções de 1 variável x_1 apenas?

... superposição de várias sigmóides deslocadas e escaladas



Vocês enxergam acima 3 nós “tgh” na primeira camada, com com 3 viéses distintos e 3 escaladores de x_1 distintos, e mais um 4o nó combinador (somatória simples de 3 entradas) na camada de saída?

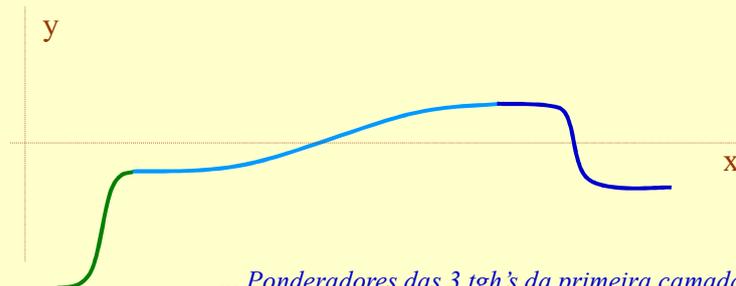
84

Métodos Numéricos e Reconhecimento de Padrões – © Prof. Emilio Del Moral – EPUSP

84

Cybenko “café com leite”, para aproximação universal de funções de 1 variável x apenas?

... superposição de várias sigmóides deslocadas horizontalmente e verticalmente e escaladas tanto em x quanto em y ...



... Ponderadores das 3 tgh's da primeira camada, que são implementados nos pesos sinápticos do 4o nó, não são mais unitários nem necessariamente positivos

85

Métodos Numéricos e Reconhecimento de Padrões – © Prof. Emilio Del Moral – EPUSP

85

E sempre que não tivermos separabilidade linear temos que usar um banco de separadores?

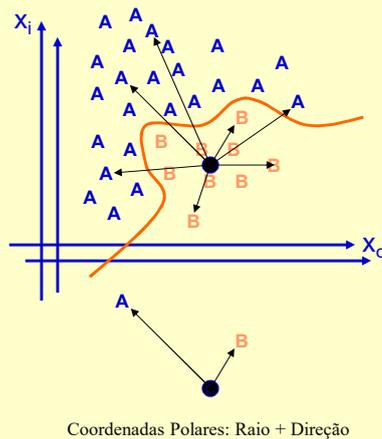
Às vezes não ... Às vezes podemos por transformações adequadas de variáveis (transformações não lineares) promover a separabilidade linear ...

86

© - Prof. Emilio Del Moral Hernandez

86

... embora não tenhamos que nos limitar a discriminadores lineares, há situações em que a simples reescrita de X em novas coordenadas pode em alguns casos promover (ou melhorar) a discriminação linear



Para estes dados empíricos em particular, vemos que se o vetor de medidas X for reescrito em coordenadas polares, com reposicionamento adequado da origem, podemos ter melhor separabilidade com um discriminador linear

87

© - Prof. Emilio Del Moral Hernandez

87

*E somente podemos
classificar usando
redes neurais?*

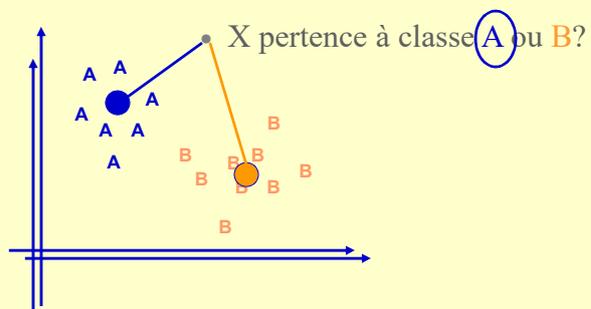
88

© - Prof. Emilio Del Moral Hernandez

88

Um classificador NÃO Neural simples ...

**... Decisão entre A e B por distância menor aos dois
centróides dos conjuntos de exemplares de treino
das classes A e B**



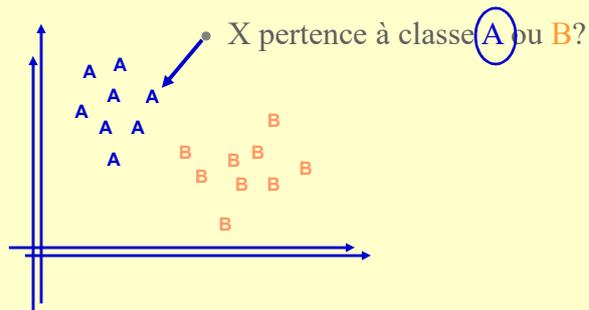
89

© - Prof. Emilio Del Moral Hernandez

89

Um classificador popular, NÃO Neural, simples ...

... Decisão entre A e B pela distância (a menor) aos exemplares de treino considerados individualmente: classificador por **Vizinho mais próximo** (distância Euclidiana ou NÃO Euclidiana!)



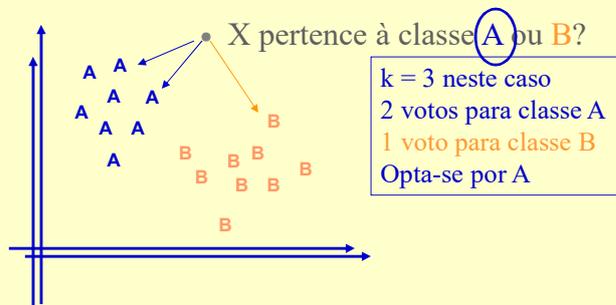
90

© - Prof. Emilio Del Moral Hernandez

90

Outro classificador NÃO Neural simples ...

... Decisão entre A e B pela k distâncias (as menores) aos exemplares de treino + votação: classificador por **k Vizinhos** mais próximos (distância Euclidiana ou NÃO Euclidiana!)



91

© - Prof. Emilio Del Moral Hernandez

91

Parte D: Medidas de qualidade de Separadores / Reconhecedores: Taxas de acertos e erros / Matriz de Confusão / Sensibilidade / Especificidade / Curva ROC quando o limiar de decisão é ajustado

92

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

92

Medidas de desempenho em reconhecedores de padrões / detectores e classificadores

© - Prof. Emilio Del Moral Hernandez

93

Algumas medidas de qualidade para reconhedores de padrões ...

- Taxa de acertos (%)
- Taxa de erros (% complementar)
- Taxa de acertos em separado para as duas classes (A x B) ... Taxas de acerto / erro para A .. e para B ...

Sensibilidade, Especificidade, etc etc

... Sensibilidade = VP / Todos casos realmente Positivos

... Especificidade = VN / Todos casos realmente Negativos

94

© - Prof. Emilio Del Moral Hernandez

94

(I) Podemos ter imperfeição na separabilidade de classes gerada por limitações da fronteira separadora da classe de modelagem empregada:

fronteira linear

x

não linear ("curva") específica

x

fronteira universal

95

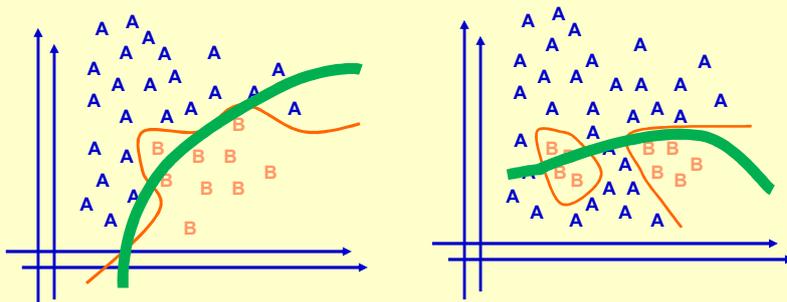
© - Prof. Emilio Del Moral Hernandez

95

Capacidade de reconhecimento de padrões em casos complexos NÃO LINEARES

Com as RNAs, a hipersuperfície de separação entre classes vai muito além dos hiperplanos

Em verde: fronteiras limitadas (implementadas com poucos nós neurais), que levam a alguns erros na classificação automática.

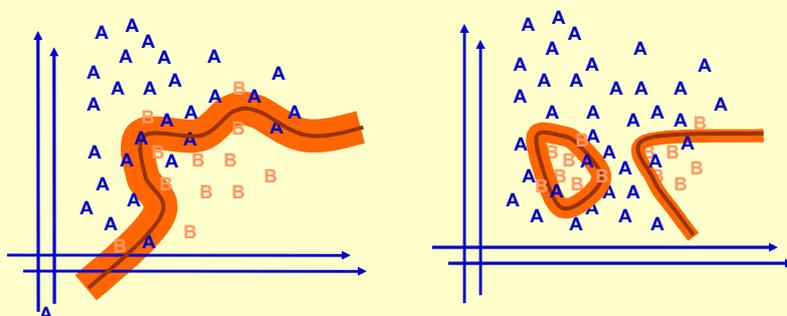


96

© Prof. Emilio Del Moral – EPUSP

96

Situações de classes com sobreposição parcial no espaço de atributos X ; situações de fronteiras de separação difusas ...

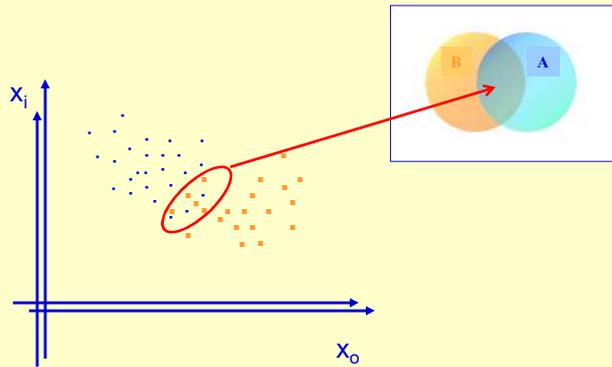


97

© Prof. Emilio Del Moral – EPUSP

97

Sobreposição parcial de classes



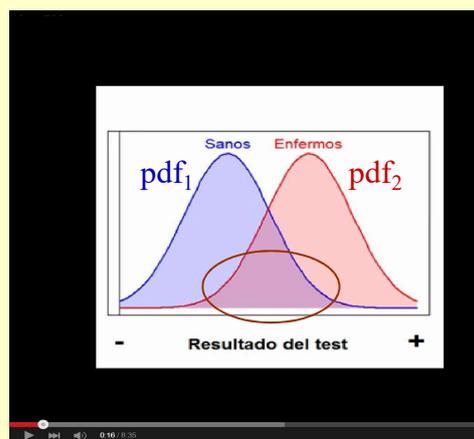
98

© - Prof. Emilio Del Moral Hernandez

98

Sobreposição parcial de classes

<https://www.youtube.com/watch?v=pA4E2uVHiYo> (início do vídeo)



Exemplo em diagnóstico médico:

Para certas faixas de valores, observamos que mesmo tendo-se exatamente o mesmo resultado clínico (tendo-se o mesmo valor de “nosso X ”) pode ocorrer tanto de um indivíduo que obteve tal valor de resultado no exame estar SÃO (“nosso $y = -1$ ”) quanto de um outro com o mesmo valor de resultado estar ENFERMO (“nosso $y = +1$ ”). ... Podemos dizer que há sobreposição significativa das duas funções de densidade de probabilidade $f_{dp_1}(X|sadio)$ e $f_{dp_2}(X|enfermo)$.

99

© - Prof. Emilio Del Moral Hernandez

99

Matriz de confusão para caracterização de desempenho de reconhecedor de padrões

	“Classe A” (sugestão do MLP)	“Classe B” (sugestão do MLP)	
(Sabidamente) Classe A	AC_A	ER_A	✗
(Sabidamente) Classe B	ER_B	AC_B	

- AC_A : padrão da classe A reconhecido como classe A
- ER_A : padrão da classe A reconhecido como classe B
- AC_B : padrão da classe B reconhecido como classe B
- ER_B : padrão da classe B reconhecido como classe A

Taxa de Acertos Tente calculá-la com base nos elementos acima presentes na matriz de confusão

100

© - Prof. Emílio Del Moral Hernandez
exemplo desenvolvido por Leandro Augusto da Silva

100

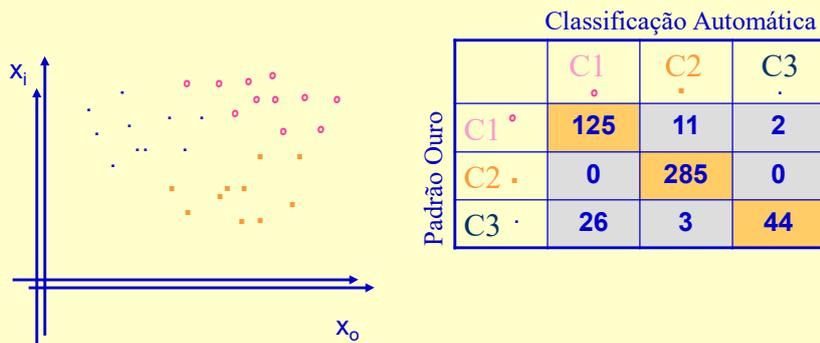
Um parênteses ... Como você generalizaria o conceito de matriz de confusão para o caso de 3 classes em vez de duas? E para 10 classes?

101

© - Prof. Emílio Del Moral Hernandez

101

A matriz de confusão quando temos 3 (ou mais) classes



$$\text{Taxa de acertos global} = (125+285+44) / 495 = 92\%$$

(... aqui usamos a média simples – não ponderada – supondo o mesmo volume de exemplares empíricos nas três classes, C1, C2 e C3!)

102

© - Prof. Emilio Del Moral Hernandez

102

Análise Diferencial de Audio (DAA)

Experimento PPC910

Classificado (Real)	1	2	3	4	5	6	7	8	9	0	TPR(%)
1	47										100.0
2		46						2			95.8
3	2		51								96.2
4		2	35	5			9				68.6
5		11	1	26			8	11	2		44.1
6		1	3		46				2		88.5
7					1	57	5				90.5
8		11	2		21		23	4			37.7
9	1	3	7	1	5	2		22	9		44.0
0							1	3	42		91.3
TPR Médio											76±25

Atributos **logLIT** mostraram-se razoáveis para este experimento, mas com grande variância. No melhor caso, acerto médio de **76±25%**.

103

© - Prof. Emilio Del Moral Hernandez

103

Medidas de desempenho específicas para detectores

© - Prof. Emilio Del Moral Hernandez

104

Casos em que o classificador binário é encarado como um detector / identificador

- Uma das duas classes representa a detecção / o reconhecimento / a ocorrência de um dado cenário relevante e que está sendo alvo de detecção.
 - Por ex: detecção de provável doença num diagnóstico, detecção de uma potencial turbulência no mercado, detecção de uma provável fraude em curso, detecção de um potencial consumidor de um produto, etc etc etc.
- A outra classe, complementar à anterior, indica a **NÃO** ocorrência de tal cenário relevante e que está sendo alvo de detecção.
 - complementarmente: não há doença provável, não há potencial turbulência, não há provável fraude em curso, não é consumidor provável, etc etc etc.
- Nesse caso, uma classe é denominada positiva (= sim, temos detecção do cenário alvo) e a outra negativa (= não, o cenário alvo não foi detectado)

105

© - Prof. Emilio Del Moral Hernandez

105

Casos em que o classificador binário é encarado como um detector / identificador

- Assim, em lugar da saída binária do classificador automático ser encarada não mais como sendo a indicação de uma de duas classes abstratas A e B, mas sim como sendo a **indicação Positiva (P)** do detector ou a **indicação Negativa (N)** do detector, para a ocorrência de um alvo específico de interesse na detecção
- E temos expressões específicas associadas aos casos de **acertos** ou **erros** na classificação automática realizada, respectivamente **Classificações Verdadeiras (V)** e **Classificações Falsas (F)**

106

© - Prof. Emilio Del Moral Hernandez

106

Estendendo termos técnicos relacionados à matriz de confusão e suas componentes ...

- Dando destaque a uma das duas classes binárias: “Diagnóstico Positivo” / “Diagnóstico Negativo”
- Interpretações em outros contextos que não o médico:
 - Alarme de reconhecimento disparado x Alarme em silêncio
 - Risco provável previsto x Sem risco previsto
 - Necessidade de providência x Normalidade (sem necessidade)
 - Oportunidade de ação x Sem destaques que mereçam ação
- Contrastando o diagnóstico perfeito com o diagnóstico imperfeito de um exame ou de um autômato:
Diagnóstico Verdadeiro / Diagnóstico Falso
- Combinações dos diversos cenários VP / FP / VN / FN
 - Verdadeiro Positivo; Falso Positivo;
 - Verdadeiro Negativo; Falso Negativo.

107

© - Prof. Emilio Del Moral Hernandez

107

VP/FN/FP/VN ... Sensibilidade e Especificidade

<https://www.youtube.com/watch?v=y7Puf75vK0w>

Sensibilidade? Especificidade?

- sensibilidade: $\frac{VP}{D}$ → muito sensível: detecta bem os doentes ↑FP
90%

- especificidade: $\frac{VN}{ND}$ → muito específico: detecta bem os não doentes ↑FN
90%

Entenda o que é Sensibilidade e Especificidade #Dose Diária

5.554

108

© - Prof. Emilio Del Moral Hernandez

108

VP/FN/FP/VN ... Sensibilidade e Especificidade

<https://www.youtube.com/watch?v=y7Puf75vK0w>

Sensibilidade? Especificidade?

- sensibilidade: $\frac{VP}{D}$ → muito sensível: detecta bem os doentes ↑FP
90%

- especificidade: $\frac{VN}{ND}$ → muito específico: detecta bem os não doentes ↑FN
90%

doente	doente
90 VP	10 FP
10 FN	90 VN
100 D	100 ND

teste de detecção => GRIPE

Entenda o que é Sensibilidade e Especificidade #Dose Diária

5.554

109

© - Prof. Emilio Del Moral Hernandez

109

VP/FN/FP/VN ... Sensibilidade e Especificidade (& ROC)

<https://www.youtube.com/watch?v=y7Puf75vK0w>

110

© - Prof. Emilio Del Moral Hernandez

110

Resumo ... Medidas de qualidade em reconhecedores de padrões / detectores

- Taxa de acertos (%)
- Taxa de erros (% complementar)
- Taxa de acertos em separado para as duas classes:
 - (A x B) ... Taxas de acerto e de erro para A e p / B
- Em situações em que uma das classes tem o significado de diagnóstico positivo e a outra de diagnóstico negativo, temos outras taxas consideradas relevantes ...
- Sensibilidade, Especificidade, etc etc
 - ... Sensibilidade = $VP / \text{Todos casos realmente Positivos}$
 - ... Especificidade = $VN / \text{Todos casos realmente Negativos}$

111

© - Prof. Emilio Del Moral Hernandez

111

***Mais medidas de
desempenho específicas
para detectores***

© - Prof. Emilio Del Moral Hernandez

112

***O conceito de limiar
ajustável em detectores***

113

© - Prof. Emilio Del Moral Hernandez

113

Estendendo conceitos relacionados à matriz de confusão e suas componentes VP, VN, FP, FN ...

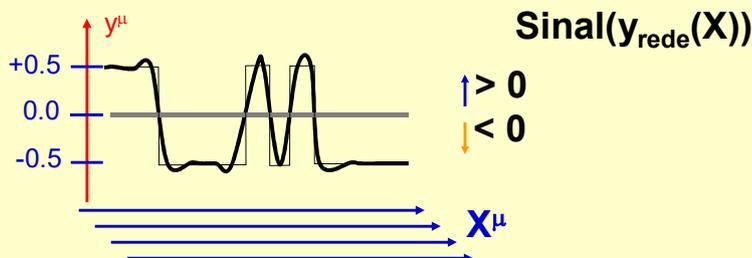
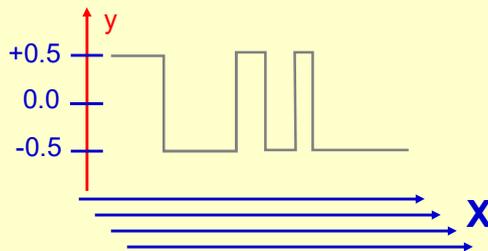
- **Conceito de limiar ajustável como parte do reconhecedor** (sensibilidade ajustável pelo usuário / variável de acordo com a circunstância)
- Indo do **Reconhecedor / Detector super estressado** – detector super sensível – ao **Reconhecedor / Detector super dorminhoco** – detector super específico – ...
(vamos de de 100% diagnósticos P a 100% diagnósticos N)
- Sensibilidade e Especificidade combinadas com o conceito de limiar ajustável leva ao conceito da curva ROC ...
Curva ROC de um reconhecedor com limiar ajustável:
Mapeamos a evolução dos valores de Sensibilidade e de Especificidade para todos os limiares, desde o extremo de detecção super sensível (baixo limiar) até o extremo oposto de detecção super específica (alto limiar), passando por todos os cenários intermediários de limiar.

114

© - Prof. Emilio Del Moral Hernandez

114

A função $f(X)$ a perseguir é desconhecida e assume valores binários

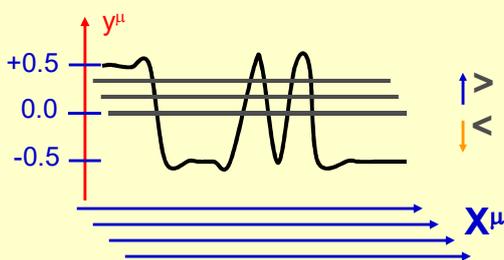
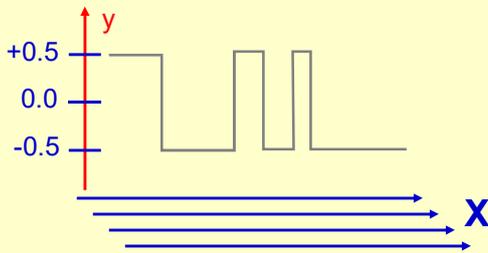


115

© - Prof. Emilio Del Moral Hernandez

115

A função $f(X)$ a perseguir é desconhecida e assume valores binários



Sinal($y_{rede}(X)$ -limiar)

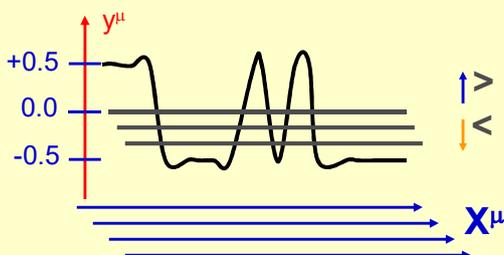
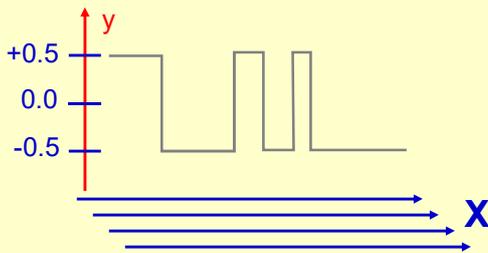
↑ > limiar
↓ < limiar

116

© - Prof. Emilio Del Moral Hernandez

116

A função $f(X)$ a perseguir é desconhecida e assume valores binários



Sinal($y_{rede}(X)$ -limiar)

↑ > limiar
↓ < limiar

117

© - Prof. Emilio Del Moral Hernandez

117

Podemos ter limiar variável em ...

- Redes neurais
- SVMs
- Comitês com composição (Adaboost e outros)
- Decisores estatísticos
- ...
- ...
- Sempre que houver uma grandeza de “saída” comparada com um limiar no estágio final, para a geração a classificação da decisão

Positivo versus Negativo

118

© - Prof. Emilio Del Moral Hernandez

118

***Aplicando o conceito de
limiar ajustável a projetos
concretos***

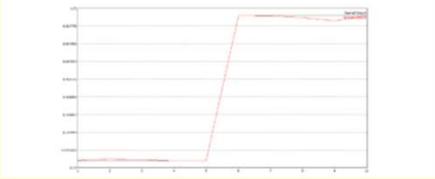
119

© - Prof. Emilio Del Moral Hernandez

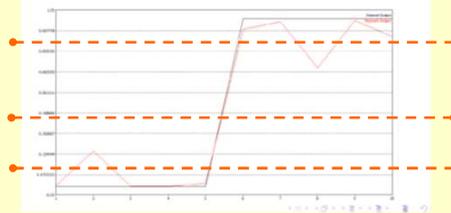
119

**Carlos – Henrique – Pedro / detector de caracter
(exemplo de limiar ajustável num projeto PSI2672 de 2015)**

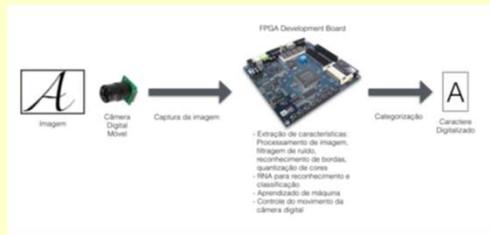
- Dimensão do vetor de entrada = 484 (uma entrada correspondente a cada elemento da matriz 22 x 22)
- Treinamento na RNA com 1 nó de função de transferência linear:



- Teste na RNA com 1 camada escondida formada por 10 nós de função de transferência tanh:



Conceito de limiar de detecção ajustável



120

© - Prof. Emilio Del Moral Hernandez

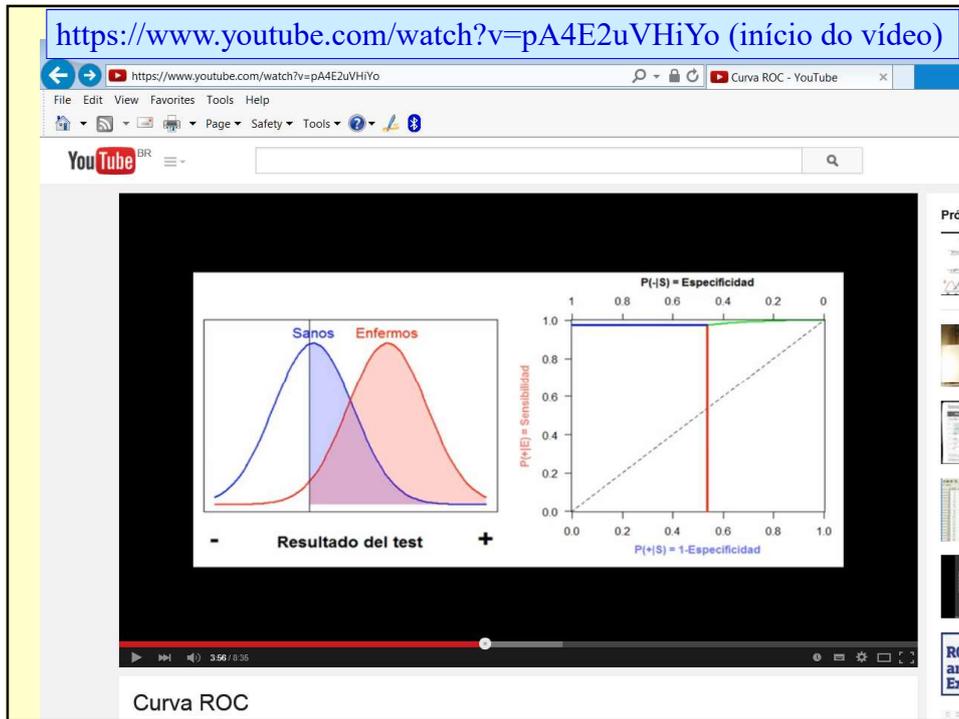
120

***O conceito de curva ROC
associada ao exercício
completo do leque de
valores do limiar ajustável
em um detector***

121

© - Prof. Emilio Del Moral Hernandez

121



122

Conceito da curva ROC: construção ...

<https://www.youtube.com/watch?v=pA4E2uVHiYo> (início do vídeo)

De limiares bem baixos –
detetor bem sensível, a
 limiares bem altos –
detetor bem específico

Curva ROC

123

A comparação geral de qualidades de detecção associadas as duas ROCs distintas é muitas vezes feita pelo contraste dos valores da área sob a curva ROC: AUC (área under the curve)

124

© - Prof. Emilio Del Moral Hernandez

124

Importante lembrete:

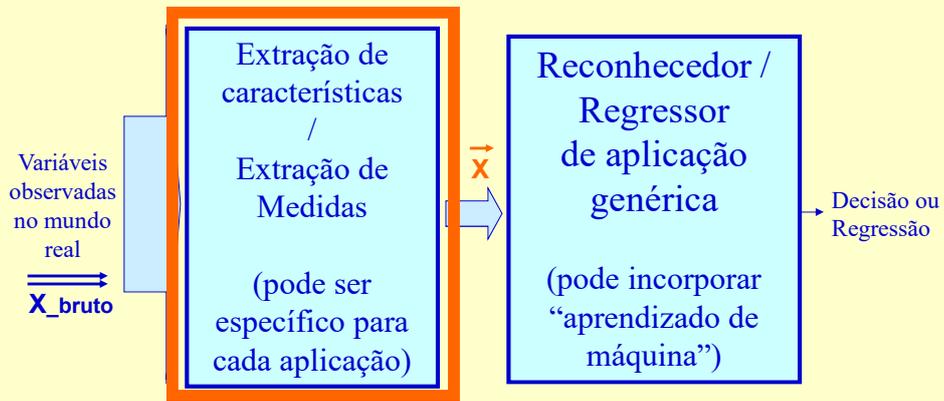
***diferentes estratégias de pré –
processamento e mesmo de
reconhecimento podem levar a
diferentes desempenhos de detecção
e portanto a diferentes ROCs***

125

© - Prof. Emilio Del Moral Hernandez

125

... O 1o estágio gera um Vetor de Medidas, \vec{X}
 (o segundo estágio operará sobre tal vetor)



126

© - Prof. Emilio Del Moral Hernandez

126

Comparando diversas ROCs, de detectores distintos ...

<https://www.youtube.com/watch?v=pA4E2uVHiYo> (início do vídeo)

© - Prof. Emilio Del Moral Hernandez

127

Comparando diversas ROCs, de detectores distintos ...

<https://www.youtube.com/watch?v=pA4E2uVHiYo> (início do vídeo)

AUC alta (0.99) – bom discriminador

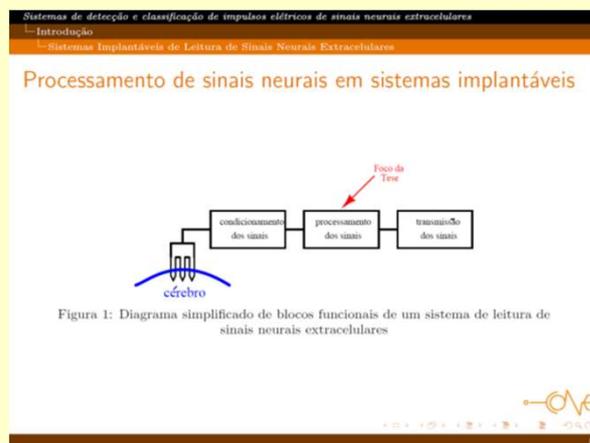
AUC só 0.5 – o pior discriminador

128

© - Prof. Emilio Del Moral Hernandez

128

Exemplo concreto de efeito benéfico do pré-processamento no contexto de Brain Computer Interface, estudado pelo doutorando Júlio Cesar Saldaña

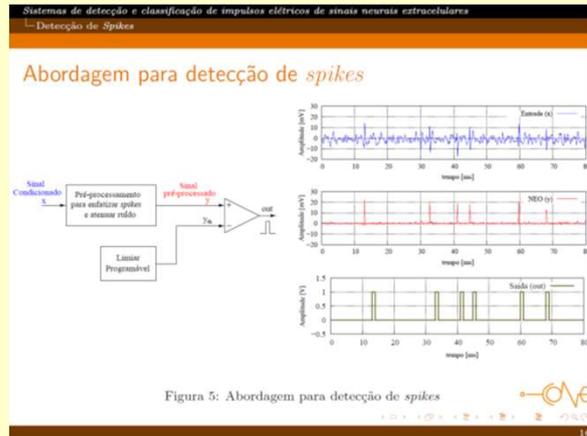


129

© - Prof. Emilio Del Moral Hernandez

129

Exemplo de pré-processamento no contexto de Brain Computer Interface, estudado pelo doutorando Júlio Cesar Saldaña

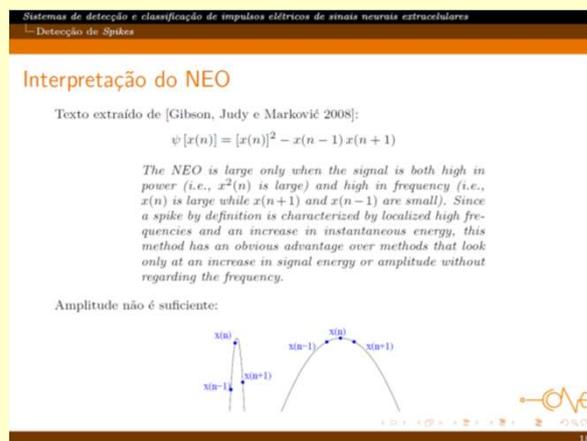


130

© - Prof. Emilio Del Moral Hernandez

130

Exemplo de pré-processamento no contexto de Brain Computer Interface, estudado pelo doutorando Júlio Cesar Saldaña



131

© - Prof. Emilio Del Moral Hernandez

131

Contexto: BCI. Duas ROCs contrastando pre-processamento distintos em um detetor de pulsos corticais (BCI) com limiar variável

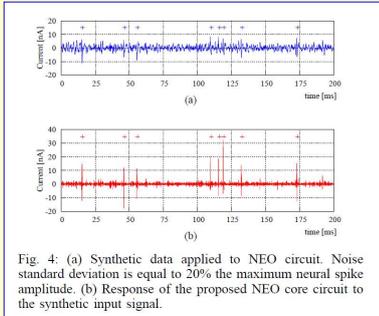


Fig. 4: (a) Synthetic data applied to NEO circuit. Noise standard deviation is equal to 20% the maximum neural spike amplitude. (b) Response of the proposed NEO core circuit to the synthetic input signal.

*Trabalho do doutorando
Júlio Cesar Saldaña*

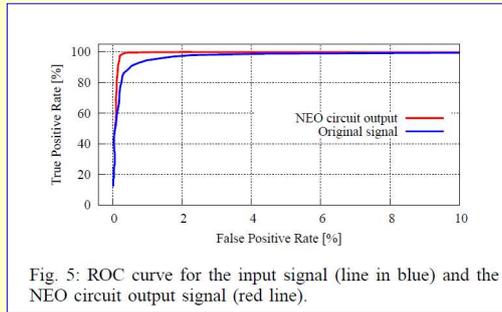


Fig. 5: ROC curve for the input signal (line in blue) and the NEO circuit output signal (red line).

132

© - Prof. Emilio Del Moral Hernandez