

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

Prof. Emilio Del Moral Hernandez
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. – ©

PSI3571 - Práticas em Reconhecimento de Padrões, Modelagem e Inteligência Computacional
Prof. Emilio Del Moral Hernandez - emilio@lsi.usp.br [e talvez + um segundo docente]

Programa Resumido

Conceitos em reconhecimento de padrões, em modelagem linear e não linear, e em redes neurais e inteligência computacional; Implementação de modelos de neurocomputação em software e em hardware; Redução de dimensionalidade; Aplicações alvo do reconhecimento de padrões e da modelagem não linear; Discussão de projetos práticos a serem desenvolvidos no curso; Execução acompanhada dos projetos práticos dos alunos; Apresentação e avaliação dos projetos finais.

Programa

A disciplina é implementada através de uma componente de discussões teóricas e outra componente equivalente de atividades práticas. Nas aulas são abordados conceitos e aspectos teóricos e operacionais relativos ao reconhecimento de padrões e à modelagem de sistemas reais não lineares, usando técnicas de neurocomputação e inteligência computacional, entre outras.

Concomitantemente, será também analisado como os conhecimentos e as técnicas já abordados em outras disciplinas da ênfase Eletrônica e Sistemas podem ser explorados para a implementação de sistemas de sistemas eletrônicos inteligentes em hardware e em software. Esta forma de definição dos projetos a serem desenvolvidos pelos estudantes pretende facilitar o surgimento de propostas com caráter integrativo, com a conjugação de conteúdos de várias disciplinas da sua formação. Após essa discussão e definição dos projetos práticos a serem desenvolvidos, uma parcela do tempo em classe servirá tanto para acompanhar a evolução dos projetos práticos quanto para o aporte de conceitos adicionais que facilitem a evolução dos projetos sendo conduzidos. O semestre se encerra com as apresentações finais por parte dos alunos, com a entrega de relatórios técnicos associados e com as demonstrações dos protótipos obtidos nos projetos práticos.

Os temas e etapas do curso são os seguintes:

- Breve discussão de conceitos em reconhecimento de padrões, modelagem linear e não linear e uso de redes neurais e inteligência computacional;
- Ambientes de implementação e prototipação de sistemas eletrônicos inteligentes em software e em hardware;
- Redução de dimensionalidade em reconhecimento de padrões e em modelagem;
- Discussão de aplicações alvo de reconhecimento de padrões e modelagem não linear, no universo da ênfase Eletrônica e Sistemas e em Engenharia em geral;
- Definição de possíveis projetos práticos da disciplina;
- Discussão e crítica das propostas individuais;
- Execução supervisionada dos projetos práticos desenvolvidos pelos alunos;
- Apresentação dos projetos finais.

Avaliação

Exercícios de aplicação, testes e provas.
Média ponderada de exercícios de aplicação, testes e provas.

Bibliografia

[1] Simon Haykin, "Redes Neurais: Princípios e Práticas", Bookman, 2001. [2] Simon Haykin, "Neural Networks and Learning Machines", Prentice Hall 2008. [3] R. O. Duda, P. E. Hart and D. G. Stork. "Pattern Classification", Wiley, 2001. [4] Cesare Alippi, "Intelligence for Embedded Systems, a Methodological Approach", Springer 2014. [5] André Fábio Kohn, "Reconhecimento de Padrões: uma Abordagem Estatística", Edição PEE/USP, 1998. [6] Apostilas da disciplina; Manuais de simuladores públicos de redes neurais e sistemas inteligentes;

Minha conexão com as temáticas do curso

- Mestrado (EPUSP), Doutorado (UPenn) relacionados
- Livre Docência em Neurocomputação Eletrônica e Sistemas Adaptativos – PSI-EPUSP
- Ensino de disciplinas de graduação e de pós graduação relacionadas
- Orientações de Mestrado e Doutorado em E.E.
- Orientações de IC e de TCC em E.E.
- Pesquisas realizadas no grupo ICONE-EPUSP
- IEEE Computational Intelligence Society (congressos e periódicos)

... ou seja, contextos de Eng Elétrica e assemelhados ...

6

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

***Um pouco sobre o histórico desta
disciplina, no contexto da
EC2 e EC3 ...***

***(disciplinas antecedentes e
disciplinas relacionadas)***

7

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

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

8

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

Para entendermos a heterogeneidade na turma, vamos conversar um pouco sobre:

- *A familiaridade / formação dos presentes em temáticas do curso*
- *Quais suas expectativas para este curso?*

(após a discussão com todos os demais, os presentes (26-fev-2018) entregaram estas informações 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)

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

Reconhecimento de Padrões, Modelagem, Intelig

O STOA PSI 3571 já está no ar e crescerá a cada semana!!!
Verifique uma vez por semana o que há de novo, sempre!

Prática x +
edisciplinas.usp.br/course/view.php?id=62312

Início > Meus Ambientes > 2018 > EP > PSI > PSI3571-101-2018

Ativar edição

Avisos

Informações gerais da disciplina

- Ementa do Jupiter USP - PSI3571
- Discussão com todos em sala de aula na 1a semana - Foco em alguns dos trechos da informação do Jupiter

Alguns materiais de apoio às atividades em sala de aula de início do semestre

Alguns materiais de apoio às atividades de início do semestre.

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

- Slides de apoio às atividades de sala de aula da primeira semana de aula de PSI3571 - 2018
- 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

O STOA PSI 3571 já está no ar e crescerá a cada semana!!!
Verifique uma vez por semana o que há de novo, sempre!

Curso: PSI3571 - Prática x +
edisciplinas.usp.br/course/view.php?id=62312

DISCIPLINAS USP

Disciplinas > Suporte > Idioma >

Início > Meus Ambientes > 2018 > EP > PSI > PSI3571-101-2018

Ativar edição

Avisos

Informações gerais da disciplina

- Ementa do Jupiter USP - PSI3571
- Discussão com todos em sala de aula na 1a semana - Foco em alguns dos trechos da informação do Jupiter

Alguns materiais de apoio às atividades em sala de aula de início do semestre

Alguns materiais de apoio às atividades de início do semestre.

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

- Slides de apoio às atividades de sala de aula da primeira semana de aula de PSI3571 - 2018
- 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
- Instale o ambiente MBP em seu computador Windows (instale / use máquina virtual se seu computador for Apple; ou use os computadores da sala C1-10 ou

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

Para entendermos a heterogeneidade na turma, vamos conversar um pouco sobre:

- ***A familiaridade / formação dos presentes em temáticas do curso***
- ***Quais suas expectativas para este curso?***

(após a discussão com todos os demais, os presentes entregaram estas informações 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)

13

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

Para entendermos a heterogeneidade na turma, vamos conversar um pouco sobre:

- ***A familiaridade / formação dos presentes em temáticas do curso***
- ***Quais suas expectativas para este curso?***

(após a discussão com todos os demais, os presentes entregaram estas informações 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)

14

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

... algumas outras disciplinas PSI em sistemas eletrônicos fortemente relacionadas

PSI3472
Conc. E Impl.
eletiva no 2º
Semestre
do 4º ano

PSI3571
Rec. Padrões e
Intel. Comput.
eletiva no
5º ano de E&S e
em 5º ano Biomédicas

PSI3471
(fundamentos)

PSI3422
Lab. de Sist.
Eletrônicos
2º sem 4º

Além disso, em acordo com a coordenação (CoC) estamos experimentando o formato de 3,5 horas (1 aula / semana)

15

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

Para atendermos à heterogeneidade:

- ***Entendimento do espectro e de dois extremos importantes – Módulos “E & S Avançado” e “Tópicos em Biomédicas”***
- ***Quero ter um interlocutor (pode ir mudando) de cada um desses grupos que regularmente discuta comigo ações de ajuste de andamento (porta vozes de cada grupo)***

16

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

***Para atendermos aos dois grupos,
“E & S Av.” e “Biomédicas”,
representativos do todo :***

- ***Cada grupo (e mesmo cada indivíduo) deve impor-se desafios de projeto com metas adequadas próprias que levem à evolução do aprendizado***
- ***A partir de um ponto das atividades, duas componentes de enunciados podem ser colocadas por mim, uma mais simples e outra mais desafiadora***

17

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

Tópicos, técnicas e tratamentos mais avançados podem ser trazidos / protagonizados nos projetos e nos seus estudos para eles, e isso é particularmente apropriado no caso de alunos do módulo de E & S avançado.

Os demais alunos também podem fazê-lo, mas desde que os fundamentos não sejam “bypassados” – Ou seja, alguns dos alunos trabalharão sem excessiva “ansiedade” (darão tempo ao tempo) em atingir muito rapidamente os mesmos resultados daqueles que já têm uma trajetória de cursos mais fundamentais que o professor mencionará / e cujos tópicos o professor trará para a disciplina em forma de resumos teóricos

18

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

Especialização / Aprofundamento

X

Interdisciplinaridade

X

**Complementação própria do aprendizado /
Aprendizados em velocidades e trajetórias
personalizadas**

19

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

Elencando alguns empréstimos da biologia na Inteligência Computacional

● Redes Neurais Artificiais

- O processamento não linear dos neurônios
- A plasticidade sináptica e o aprendizado



● Lógica “Fuzzy” (Lógica Nebulosa)

- A representação de informação imprecisa – funções de pertinência (conjuntos nebulosos)



● Computação Evolucionária

- A terminologia e os conceitos da evolução biológica: uma população composta por diversas soluções potenciais de um problema é refinada e evolui em novas gerações, que correspondem a novas populações de soluções potenciais, cada vez melhores



20

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

Computação Bioinspirada, Computação Neural e Eletrônica Neuromórfica

- Conjuga capacidades da inteligência biológica com os ambientes de computação, de processamento embarcado, de sensoriamento e de controle automático
- Emprega diferentes estratégias e metodologias, frequentemente integradas em sistemas híbridos
- Muitas vezes as duas seguintes vertentes caminham juntas (e particularmente em neurocomputação):
 - 1) Inspirar-se nos sistemas biológicos para delineamento de novos modelos de computação
 - 2) Emular ou substituir parcialmente as capacidades dos sistemas biológicos

21

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

Elencando alguns empréstimos da biologia na Inteligência Computacional

• Redes Neurais Artificiais – um foco no curso

- O processamento não linear dos neurônios
- A plasticidade sináptica e o aprendizado



• Lógica “Fuzzy” (Lógica Nebulosa)

- A representação de informação imprecisa – funções de pertinência (conjuntos nebulosos)



• Computação Evolucionária

- A terminologia e os conceitos da evolução biológica: uma população composta por diversas soluções potenciais de um problema é refinada e evolui em novas gerações, que correspondem a novas populações de soluções potenciais, cada vez melhores



22

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

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

23

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

Relembrando as duas classes de aplicação alvo a serem abordadas no curso

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

24

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

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



25

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

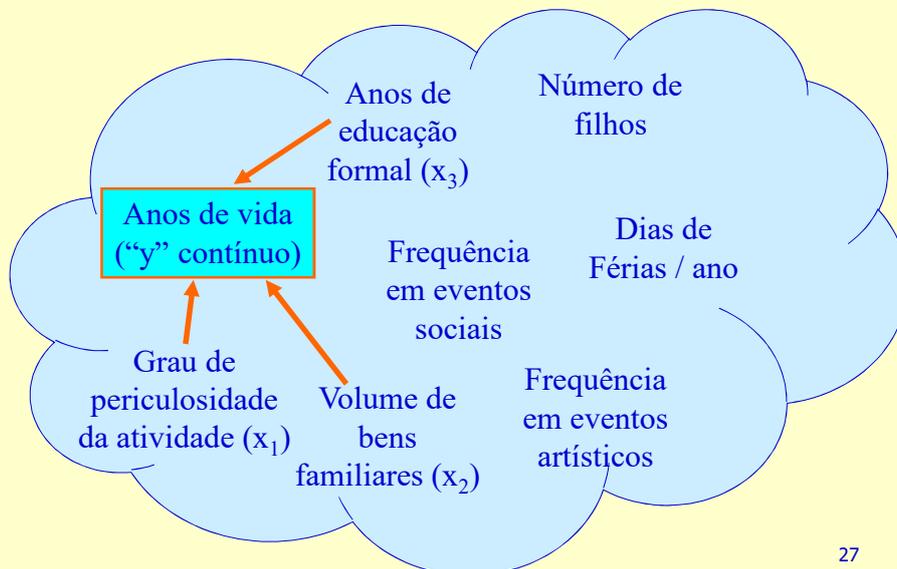
Um hipotético universo de variáveis interdependentes, passível de modelagem/ens



26

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

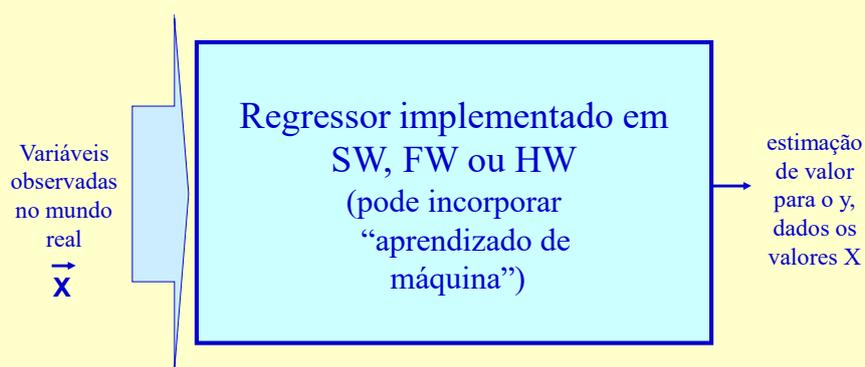
Um hipotético universo de variáveis interdependentes, passível de modelagem/ens



27

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

Regressor multivariado (em sw, fw ou hw)



28

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

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

29

Vamos pensar em nossos próprios desafios de regressão multivariada (com, digamos ao menos 3 variáveis de “entrada” no modelo) para a previsão / estimação de alguma grandeza relevante?
Façamos isto no contexto de Eletrônica e Sistemas / ou da sua ênfase / ou do seu Módulo Vermelho.

© Prof. Emilio Del Moral Hernandez

29

Após a discussão com todos os demais, os presentes entregaram 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

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

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

Conhecemos de outros cursos da Poli algumas possibilidades para regressão (linear) sobre dados empíricos desse universo, ou seja, exemplares de valores da trinca (x_1, x_2, x_3) e os correspondentes valores de y ...

- **Modelagem por reta média (considerando por exemplo unicamente a variável x_1 como impactante significativo em y)**
- **Modelagem por plano médio (considerando x_1 e x_2)**
- **Modelagem por hiperplano médio (x_1, x_2 e x_3)**

Discutamos em lousa alguma formulação matemática ...

31

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

Quais vocês acham seriam valores adequados aos pesos “w” de uma modelagem linear?

- **No caso de**
 $\text{anos_vida} = f_{\text{Tlinear}}(\text{educação, bens, periculosidade})$
- **Qual o papel do viés nessa modelagem?**
- **Sabem a diferença de transformação linear e afim? ...**
.... Importante para conciliar nosso jargão em reconhecimento de padrões com o jargão de sistemas lineares

32

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

Relembrando as duas classes de aplicação alvo a serem abordadas no curso

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

33

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

Passemos a elaborar agora
uma situação hipotética de
reconhecimento de padrões
(y discreto), em lugar de
regressão multivariada (y
contínuo) ...

34

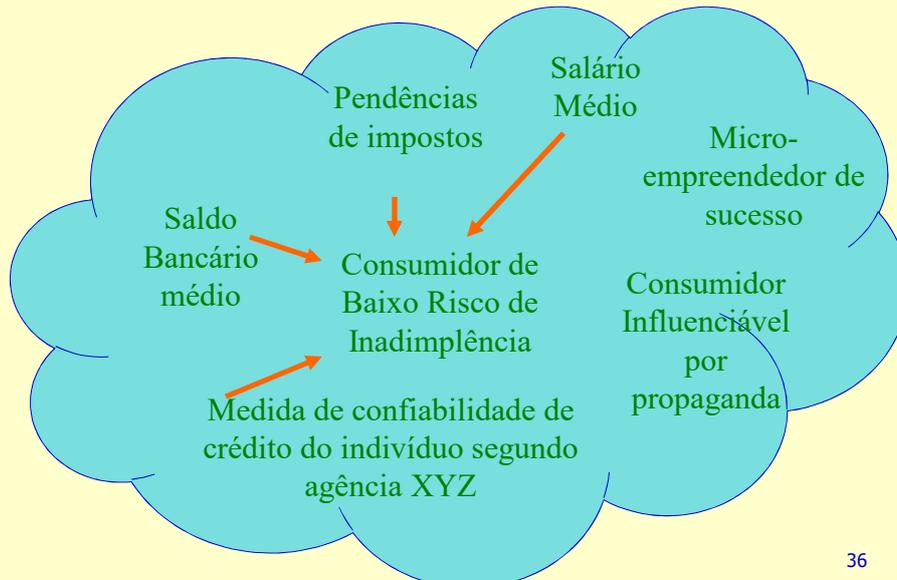
Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

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



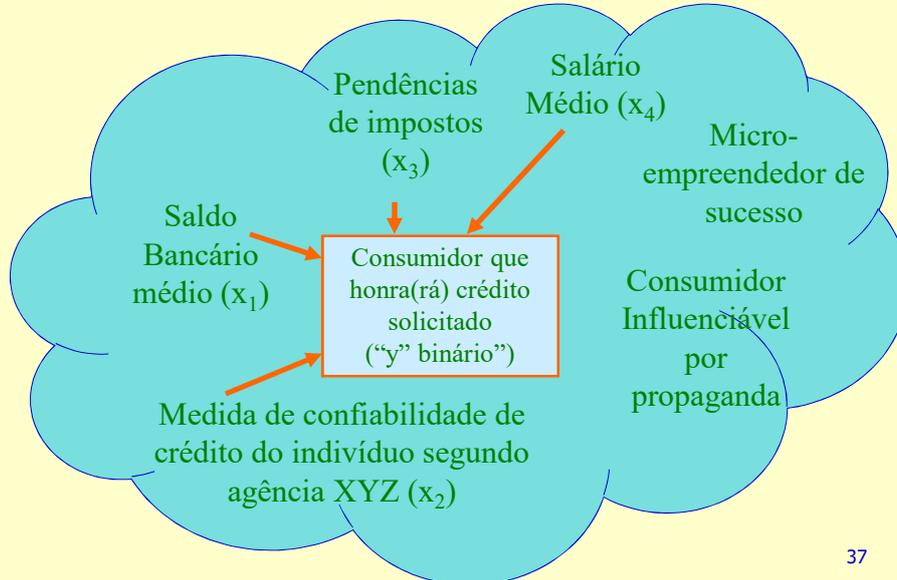
Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

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



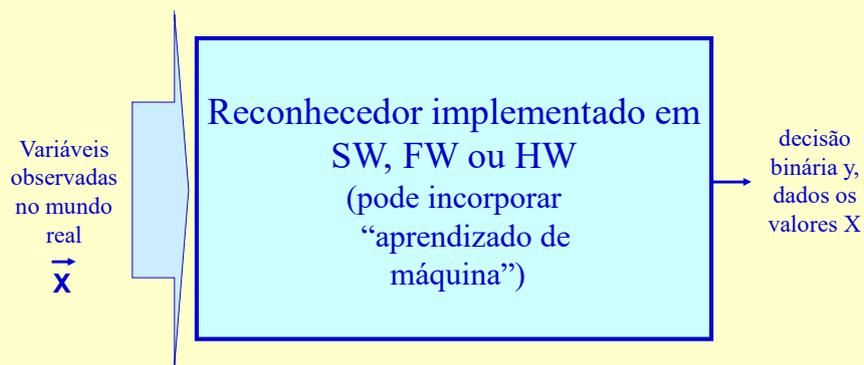
Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

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



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

Detector / reconhecedor multivariado (em sw, fw ou hw)



38

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

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

39

Vamos pensar em nossos próprios desafios de reconhecimento multivariado (com, digamos ao menos 3 variáveis de entrada no modelo) para uma classificação / reconhecimento / categorização automática relevante?
Façamos isto no contexto de Eletrônica e Sistemas.

© Prof. Emilio Del Moral Hernandez

39

Após a discussão com todos os demais, os presentes (05-março-2018) entregaram 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

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

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

edisciplinas.usp.br/course/view.php?id=62312

Avisos

Informações gerais da disciplina

- Ementa do Jupiter USP - PSI3571
- Discussão com todos em sala de aula na 1ª semana - Foco em alguns dos trechos da informação do Jupiter

Alguns materiais de apoio às atividades em sala de aula de início do semestre

Alguns materiais de apoio às atividades de início do semestre.

Atenção: A leitura dos materiais de apoio disponibilizado via STOA **NÃO Substituem 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.

- PSI3571 - para STOA - Slides de apoio às atividades de sala de aula - com entregas escritas - nas duas primeiras semanas de aula de 2018
- 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)

Materiais de PSI3571 apenas visíveis aos matriculados

Restrito Disponível se: Você faz parte de Turma 2018101

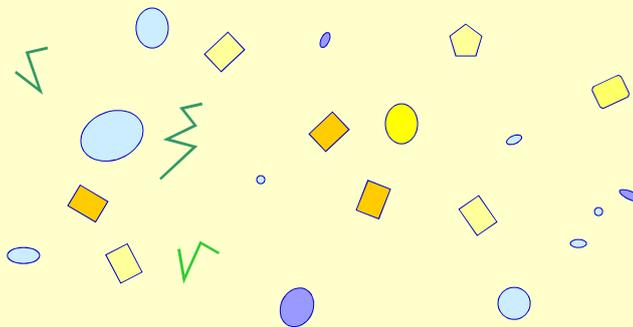
ATENÇÃO: Todos os materiais desta seção (todos os itens que seguem) devem ser usados apenas para as finalidades de estudo de PSI3571-2018, não devendo ser disponibilizados a pessoas externas sem prévio ok do Prof. Emilio. Em caso de dúvida sobre isso, fale comigo ao fim da aula.

- Arquivos de slides finais-gerados com os projetos de PSI2672 em 2017

Estes slides das apresentações dos 12 projetos de PSI2672 do ano passado (2017) ainda não estão incorporados ao repositório de projetos público de projetos PSI2672 (que hoje conta com apresentações finais de perto de 50 projetos e está disponível a todos neste STOA). Estas apresentações dos 12 projetos mais recentes da disciplina estão aqui disponibilizadas em caráter preliminar e devem ser usadas apenas para as finalidades de estudo de PSI3571-2018, não devendo ser repassadas a pessoas externas sem prévia autorização do Prof. Emilio. Em caso de dúvida sobre isso, fale pessoalmente comigo em sala de aula.

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

Universo de objetos observados ...

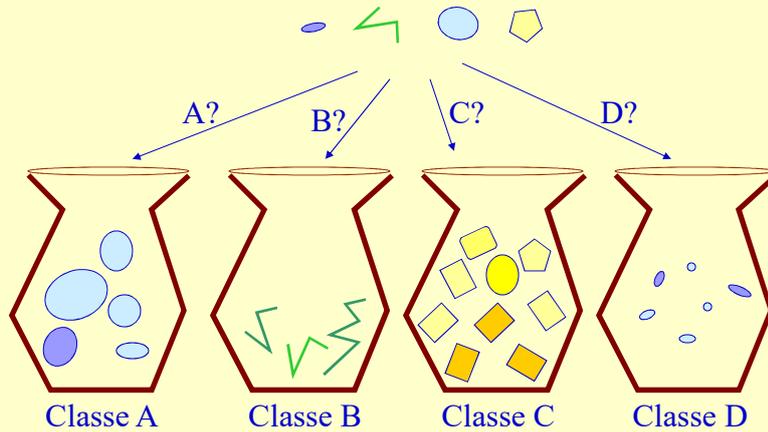


43

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

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

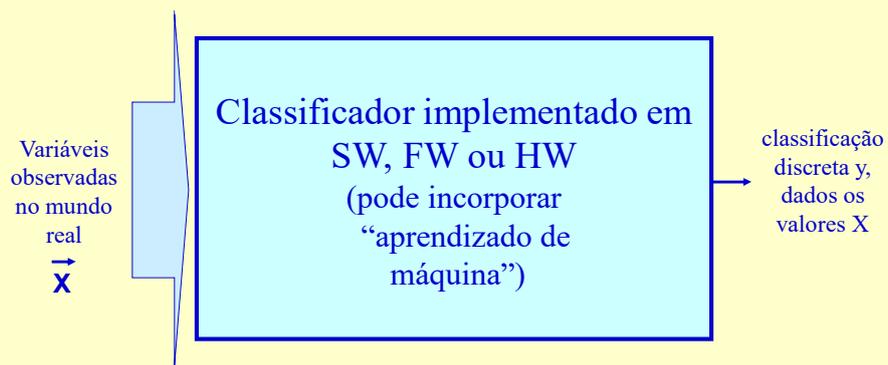
Um dado objeto específico observado é de que tipo ?



44

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

Classificador multivariado (em sw, fw ou hw)



45

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

Relembrando duas classes de aplicação alvo a abordadas no curso e iniciando a solução com técnicas LINEARES “(+-)”

46

- Regressores multivariados **lineares** e não lineares
- Reconhecimento automático de padrões ...
 - / discriminadores (ou identificadores)

lineares e não lineares

aparte formal ... Linear / Afim

© Prof. Emilio Del Moral Hernandez

46

Quais vocês acham seriam valores adequados aos pesos “w” de cada entrada nesses 2 exemplos?

48

- No caso de
 $\text{anos_vida} = f_{\text{Tlinear}}(\text{educação, bens, periculosidade})$
- E no caso de
 $\text{bom_pagador} = f_{\text{Dlinear}}(\text{saldo, salário, crédito})$
- Qual o papel do viés nessas duas análises?
- Sabem a diferença de transformação linear e afim? ...
.... Importante para conciliar nosso jargão em reconhecimento de padrões com o jargão de sistemas lineares

48

aparte formal ... Linear / Afim, a rigor são diferentes

49

Função afim

Origem: Wikipédia, a enciclopédia livre.

Nota: Não confundir com *Função linear*, ou *Transformação linear*.

Uma **função afim**, também conhecida como **função polinomial de grau 1** ou **função polinomial de primeiro grau** é uma função do tipo $f(x) = ax + b$, cujo gráfico é uma reta não perpendicular ao eixo ox . Tal função também pode ser entendida como uma transformação linear (Ax) seguida por uma translação $(+b)$.

$z \mapsto Ax + b$

no caso finito-dimensional cada função afim é dada por uma matriz A e por um vetor B , que possam ser escritos como a matriz A com uma "coluna extra do B ". Fisicamente, uma função afim é a que preserva:

1. Colinearidade entre pontos, isto é, três pontos que se encontram em uma linha continuam a ser colineares após a transformação;
2. relações das distâncias ao longo de uma linha, isto é, para os pontos colineares distintos p_1, p_2, p_3 , $\|p_2 - p_1\| / \|p_3 - p_2\|$.

Uma função afim é composta de um ou de diversos transformadores lineares. Diversas transformações lineares podem ser combinadas em uma única matriz, assim que a fórmula geral dada acima é ainda aplicável.

Em uma dimensão (ou seja, quando x e y são escalares), os termos A e b são chamados, respectivamente, de **coeficiente angular** e **coeficiente linear**.

Índice [esconder]

- 1 Definição formal
 - 1.1 Coeficientes^[R]
- 2 Função linear
 - 2.1 Função linear e proporcionalidade
- 3 Crescimento ou decréscimo
 - 3.1 Crescente
 - 3.2 Decrescente
 - 3.3 Constante
- 4 Zero
- 5 Aplicações
 - 5.1 Relação com a progressão aritmética
 - 5.2 Relação com o movimento retilíneo uniforme
- 6 Referências
- 7 Bibliografia

© Prof. Emilio Del Moral Hernandez

49

aparte formal ... Linear / Afim, a rigor são diferentes

50

Função linear

O coeficiente "b" determina o deslocamento da reta em relação à origem, por isso ele é conhecido como coeficiente linear da reta.

Função linear [editar | editar código-fonte]

Ver artigo principal: Função linear

Uma **função linear** é um caso particular da função afim onde $a \neq 0$ e $b = 0$, sendo, portanto, expressa como:

$$f(x) = ax.$$

Veja na figura ao lado um exemplo de gráfico de função linear.

Um caso específico da função linear é a função identidade, onde $a = 1$. Logo a função identidade é expressa como:

$$f(x) = x.$$

Observe na figura ao lado um exemplo de gráfico de função identidade.

Função linear e proporcionalidade [editar | editar código-fonte]

Ver artigo principal: Proporcionalidade

Uma das principais aplicações da função linear é a relação de proporção existente entre os elementos do domínio e da imagem, pois observamos que conforme variam os elementos do domínio, suas respectivas imagens variam na mesma proporção, sendo essa proporção o coeficiente angular da função, nesse caso chamado de taxa de variação.

Assim, seja a função linear $f(x) = ax$, vemos que o conjunto dos pontos que representa a reta dessa função são os pontos do tipo (x, ax) , onde a é a razão entre y e x .^[R]

Essa relação será diretamente proporcional se a função for crescente e inversamente proporcional se a função for decrescente.

Crescimento ou decréscimo [editar | editar código-fonte]

Uma função afim pode ser crescente, decrescente, dependendo do valor do coeficiente angular. Uma função pode ainda ser constante, se $a=0$ e aí ela terá grau 0.

Crescente [editar | editar código-fonte]

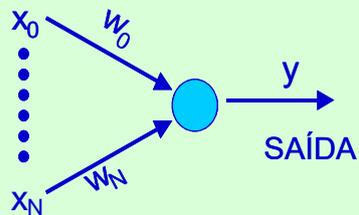
Uma função afim é crescente quando seu coeficiente angular for positivo, ou seja, $a > 0$.

Demonstração:^[R]

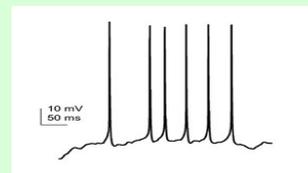
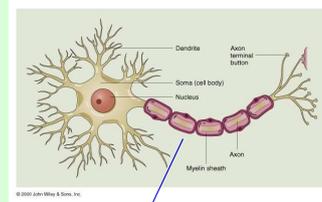
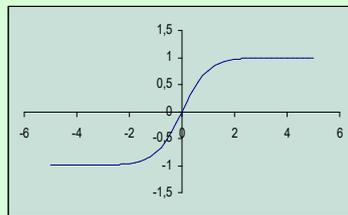
Por definição, dizemos que uma função $f: A \rightarrow B$ definida por $y = f(x)$ é crescente no conjunto $A_1 \subset A$ se, para dois valores quaisquer x_1 e x_2 pertencentes a A_1 , com $x_1 < x_2$, tivermos $f(x_1) < f(x_2)$.

Neurônio Artificial - inspirado no biológico (ou também chamado de “nó” da rede neural)

51



$$y = \text{tgh} (\sum w_i x_i)$$

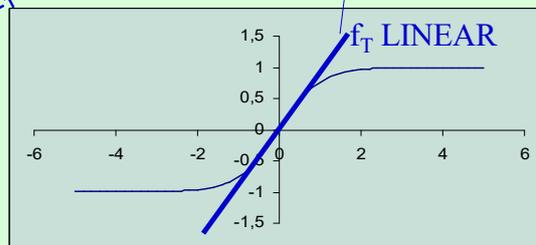
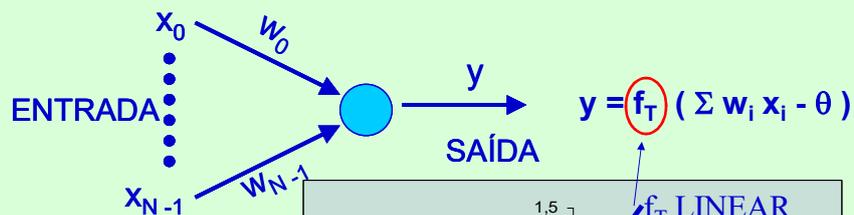


© Prof. Emilio Del Moral Hernandez

51

Caso particular do nó com comportamento linear ... $f_T(\text{arg}) = k \cdot \text{arg}$

52

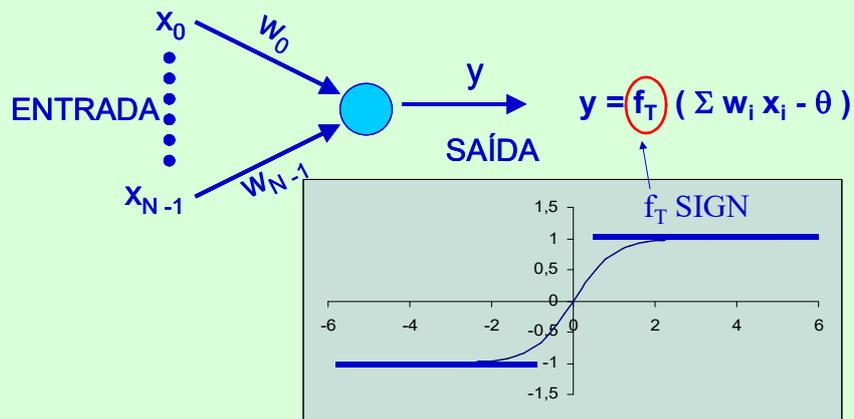


© Prof. Emilio Del Moral Hernandez

52

Caso particular do nó com comportamento binário ... $f_T(\text{arg}) = \text{sign}(\text{arg})$

53

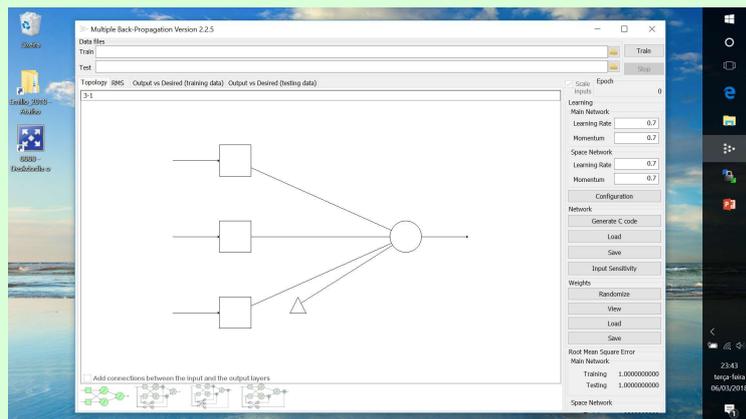


© Prof. Emilio Del Moral Hernandez

53

Instale o MBP e digite "3-1" no campo Topology

54

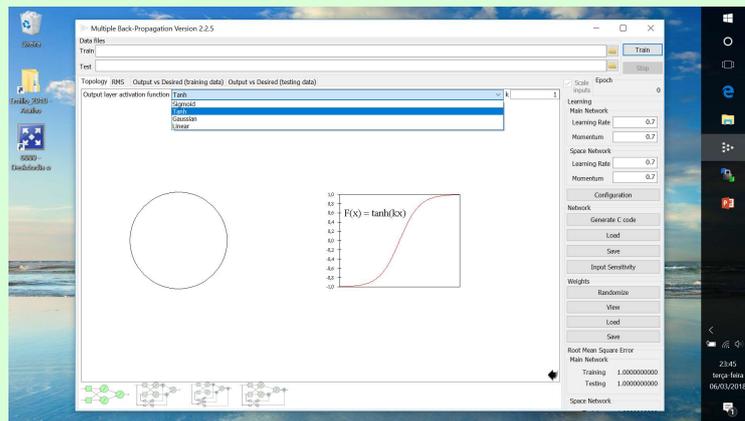


© Prof. Emilio Del Moral Hernandez

54

Depois escolha a função de ativação do nó neural

55



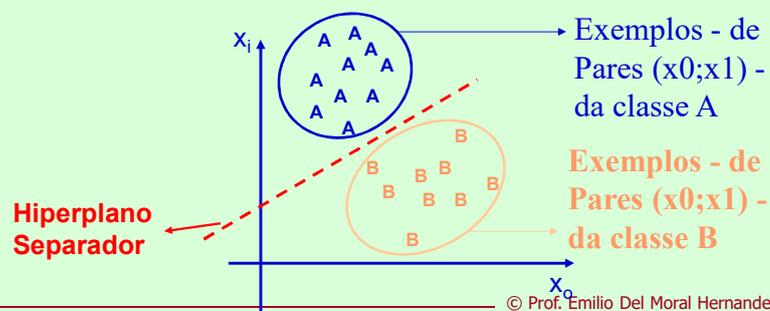
© Prof. Emilio Del Moral Hernandez

55

Um pioneiro ... o Perceptron: $y = \text{sinal}(\sum w_i x_i - \theta)$ (função de transferência tipo “degrau”)

56

- Viabiliza a classificação de padrões com separabilidade linear
- O algoritmo de aprendizado adapta os Ws de forma a encontrar o hiperplano de separação adequado
- Aprendizado por conjunto de treinamento



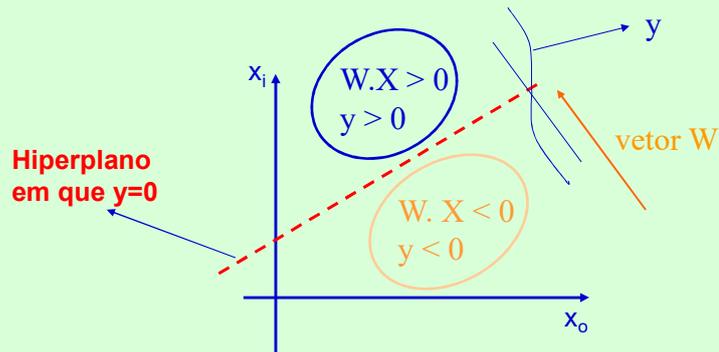
© Prof. Emilio Del Moral Hernandez

56

E se a saída do nosso problema não for digital? O "Perceptron Contínuo": $y = \text{tgh}(\sum w_i x_i - \theta)$

57

- Que problemas de entradas contínuas conseguimos atacar usando uma função de transferência tangente hiperbólica)



© Prof. Emilio Del Moral Hernandez

57

Indo além do neurônio "camaleão" simples Uma rede neural com 3 nós neurais ...

58

© Prof. Emilio Del Moral Hernandez

58

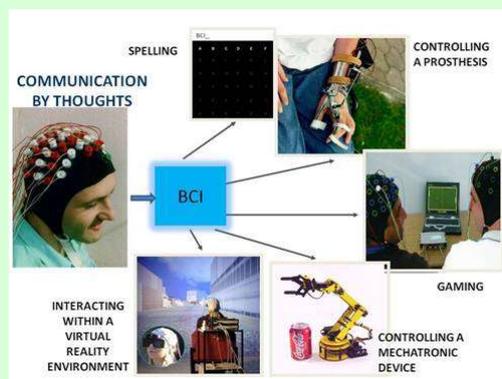
Alguns exemplos de sistemas de reconhecimento e de regressão multivariada, com os quais tive contato e que empregaram redes neurais e técnicas relacionadas

19

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

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

60

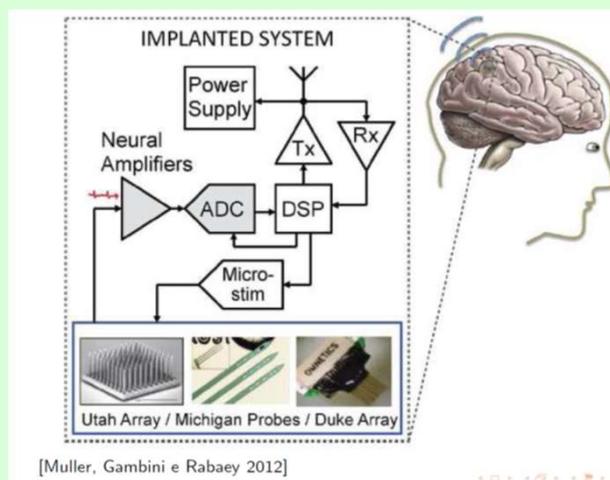


© Prof. Emilio Del Moral Hernandez

60

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

61



Slide - Contribuição de Julio Cesar Saldaña - EPUSP

© Prof. Emilio Del Moral Hernandez

61

Sistemas Implantáveis de Registro Neural e BCIs

62

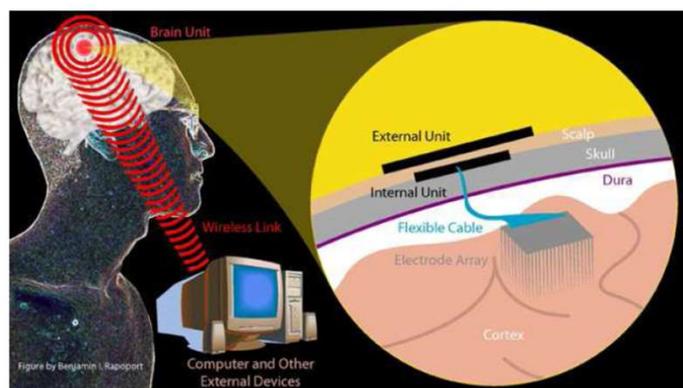


Figura 1: Imagem extraída do site do pesquisador Benjamin I. Rapoport

Slide - Contribuição de Julio Cesar Saldaña - EPUSP

© Prof. Emilio Del Moral Hernandez

62

Sistemas Implantáveis de Registro Neural e BCIs

63

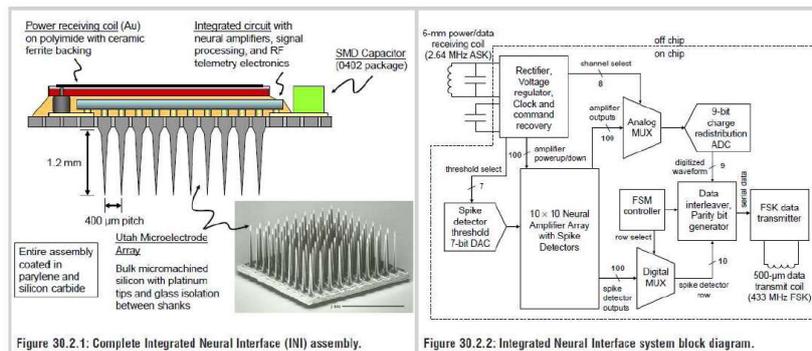


Figure 30.2.1: Complete Integrated Neural Interface (INI) assembly.

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

63

Brain Computer Interfaces

64

Separação de impulsos elétricos ou Spike Sorting

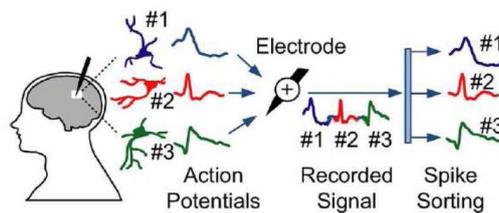


Figura 6: Extraída do artigo [Karkare, Gibson e Markovic 2013] (JSSC, Set. 2013)

Slide - Contribuição de Julio Cesar Saldaña - EPUSP

© Prof. Emilio Del Moral Hernandez

64

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 [jupyter](#)

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_apresentacao_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

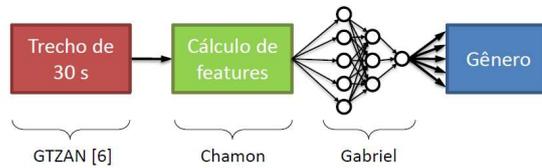
67

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

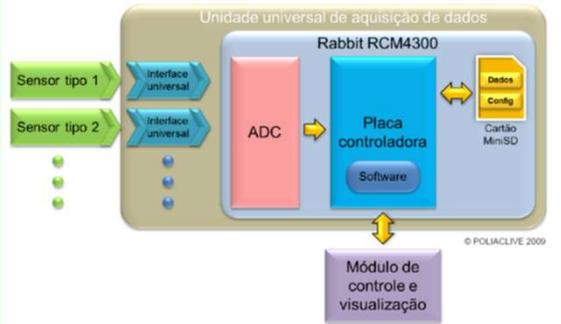
67

Sistema de fusão de sensores: por exemplo pressão e temperatura

68

Introdução

Eletrônica embarcada



projeto de alunos em PSI-2672

© Prof. Emilio Del Moral Hernandez

68

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

69



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

69

Seguidor do alvo dos olhos na tela do computador

70

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

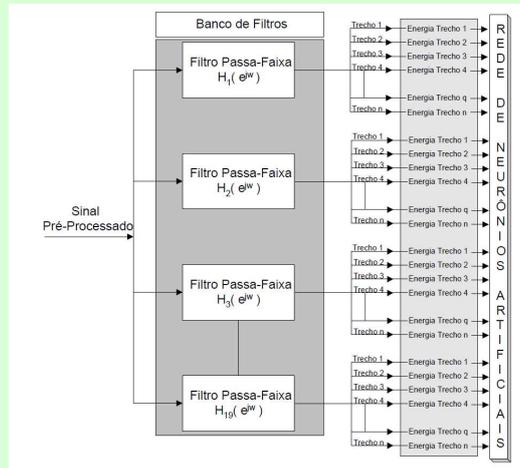


projeto de alunos em PSI-2672

70

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

71



© Prof. Emilio Del Moral Hernandez

71

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

73

O procedimento de detecção do Vazamento

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



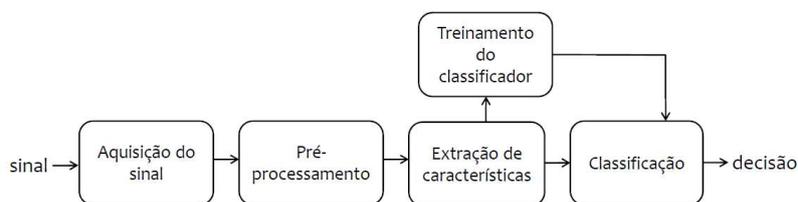
© Prof. Emilio Del Moral Hernandez

73

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

74

Sistema de Detecção de Vazamento



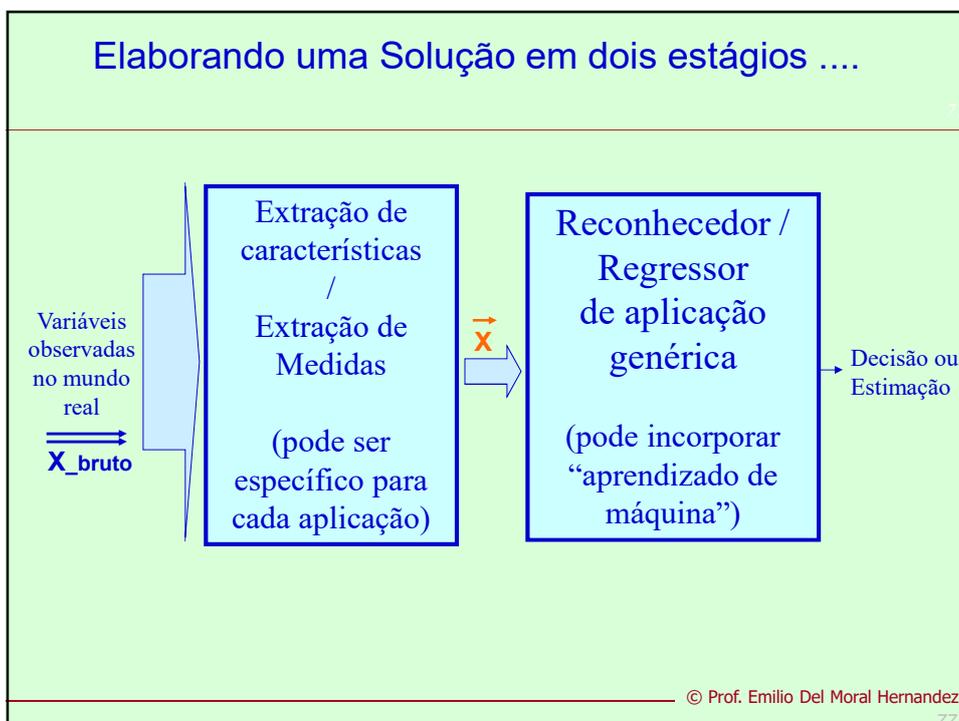
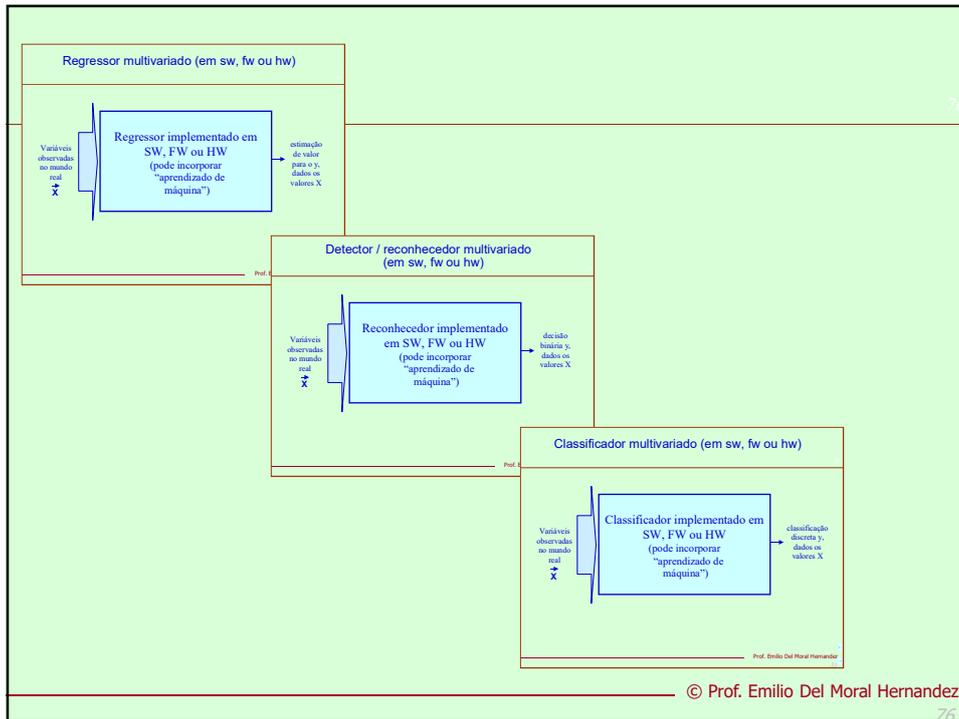
© Prof. Emilio Del Moral Hernandez

74

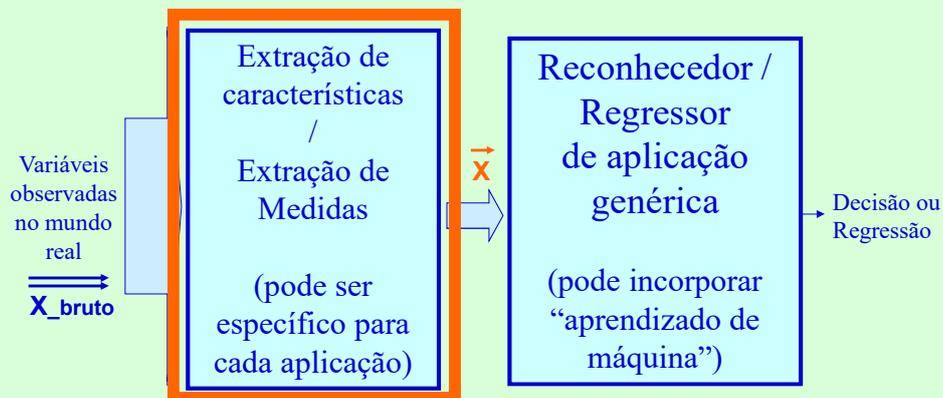
Em vários dos projetos de regressão e reconhecimento realizados (embora não em todos) houve a necessidade de uma solução envolvendo dois estágios ... Um primeiro responsável por extração de características / extração de medidas mais relevantes dos objetos "X" brutos, medidas essas normalmente específicas 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

© Prof. Emilio Del Moral Hernandez

75



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

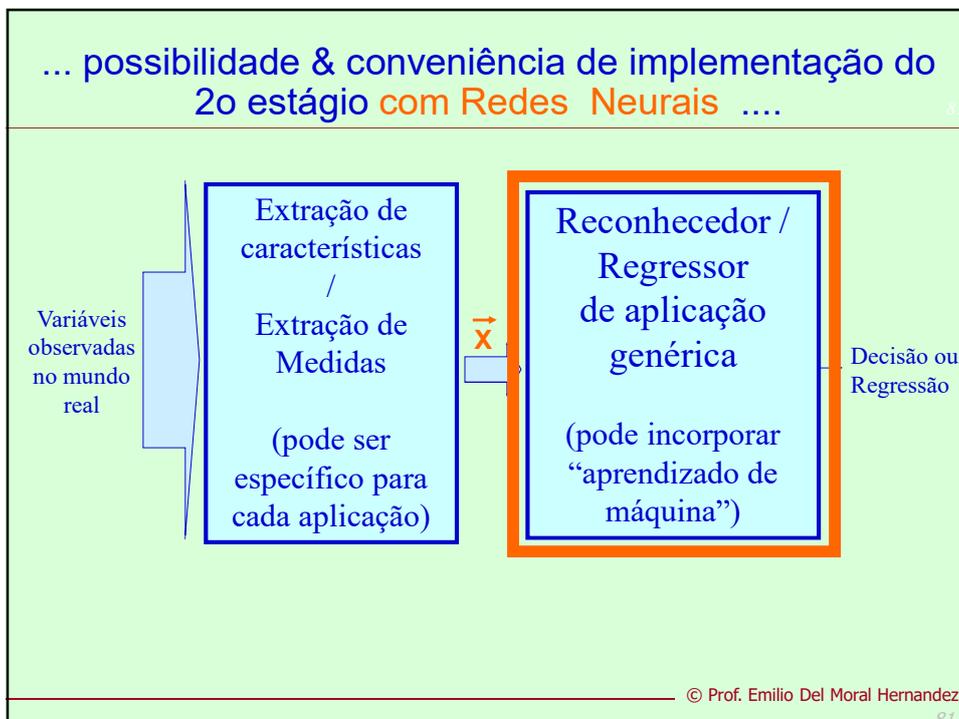
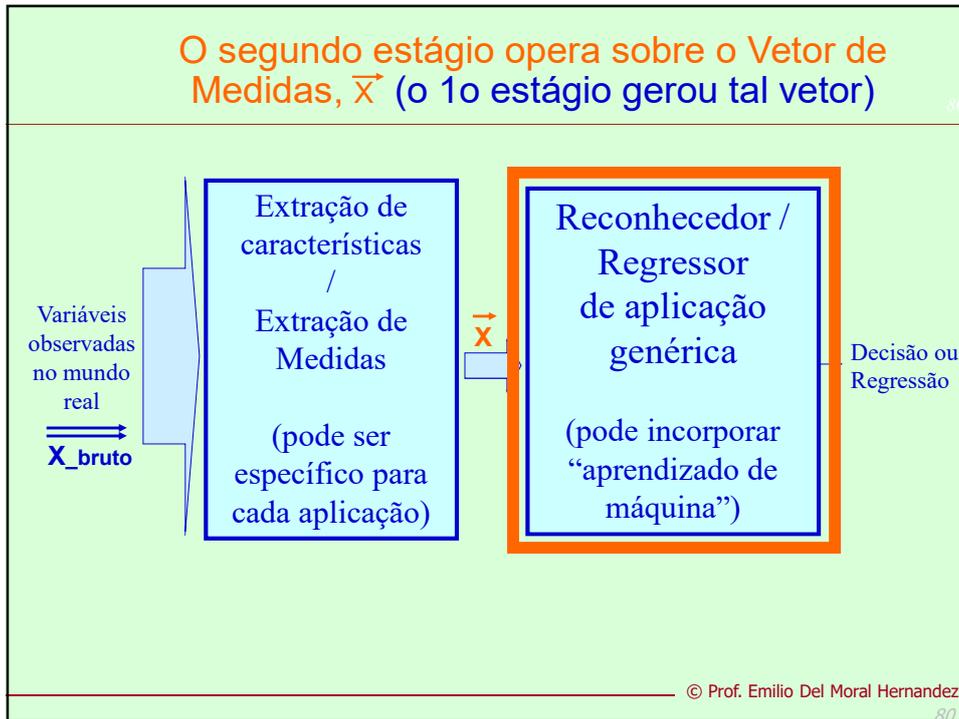


© Prof. Emilio Del Moral Hernandez

Alguns exemplos de grandezas componentes dos vetores de medidas X :

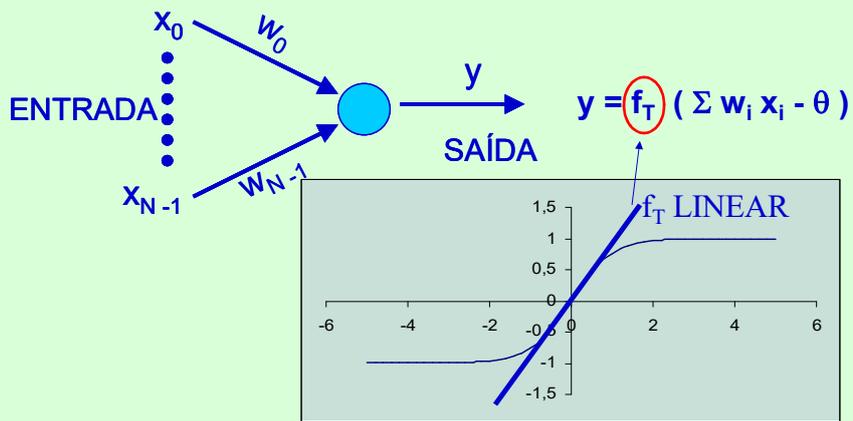
- Grandezas macroscópicas como energia do sinal, amplitude, frequência média ...
- Componentes de diversas harmônicas (análise em frequência)
- Componentes de análise tempo-frequência
- Intensidades luminosas ou intensidades em canais de cor (RGB por ex.)
- Histogramas de intensidades
- Principal Components (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



Caso particular do nó com comportamento linear
... $f_T(\text{arg}) = k \cdot \text{arg}$

82

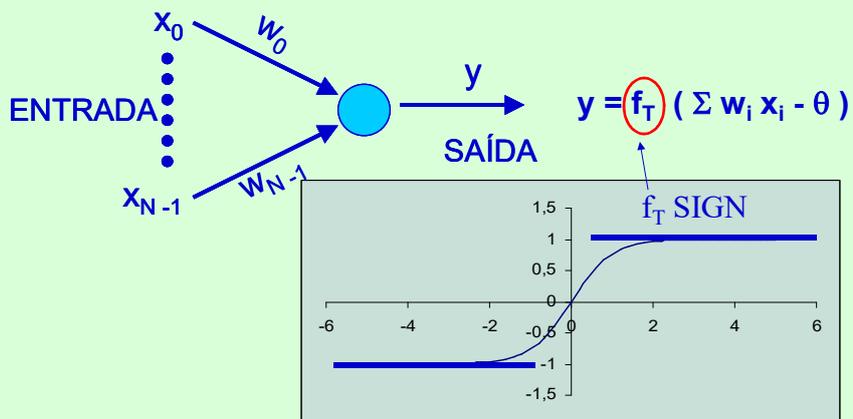


© Prof. Emilio Del Moral Hernandez

82

Caso particular do nó com comportamento binário
... $f_T(\text{arg}) = \text{sign}(\text{arg})$

83

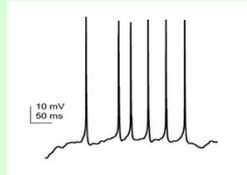
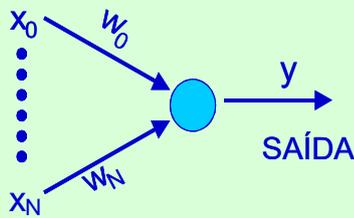


© Prof. Emilio Del Moral Hernandez

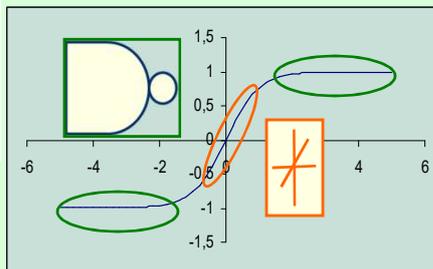
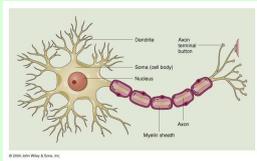
83

Computação linear e não linear, com codificação freqüencial

84



$$y = f_T(\sum w_i x_i)$$



© Prof. Emilio Del Moral Hernandez

84

Redes Neurais Artificiais

85

São: sistemas computacionais, de implementação em hardware ou software, que imitam as habilidades computacionais do sistema nervoso biológico, usando um grande número de processadores simples (neurônios artificiais) e interconectados entre si.

Emprestam da biologia:

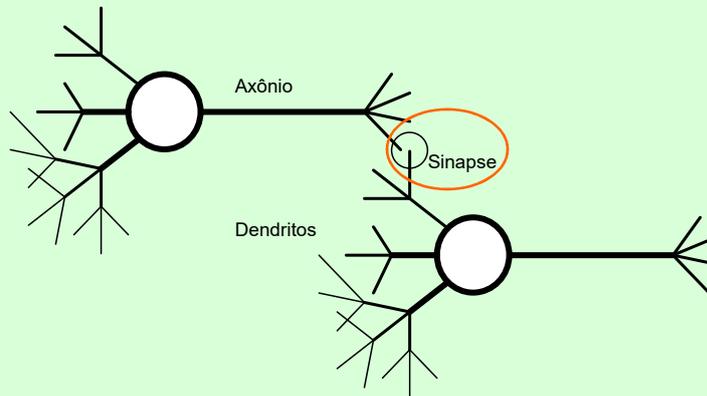
- A estrutura de processamento microscópico (processamento de informação de neurônios individuais)
- Em algum grau, aspectos da organização de redes neurais biológicas – como os neurônios se interligam
- O aprendizado através de exemplos (através de casos)

© Prof. Emilio Del Moral Hernandez

85

Cômputos mais complexos ... são realizados pelo encadeamento de vários neurônios

86



A conexão entre um axônio de um neurônio e um dendrito de outro é denominada **Sinapse**

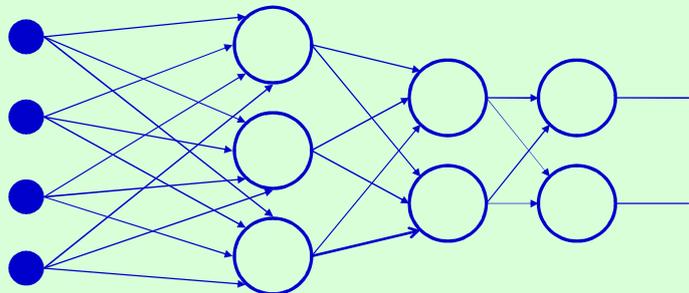
© Prof. Emilio Del Moral Hernandez

86

Foco deste Curso:
o Multi Layer Perceptron (MLP)

87

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

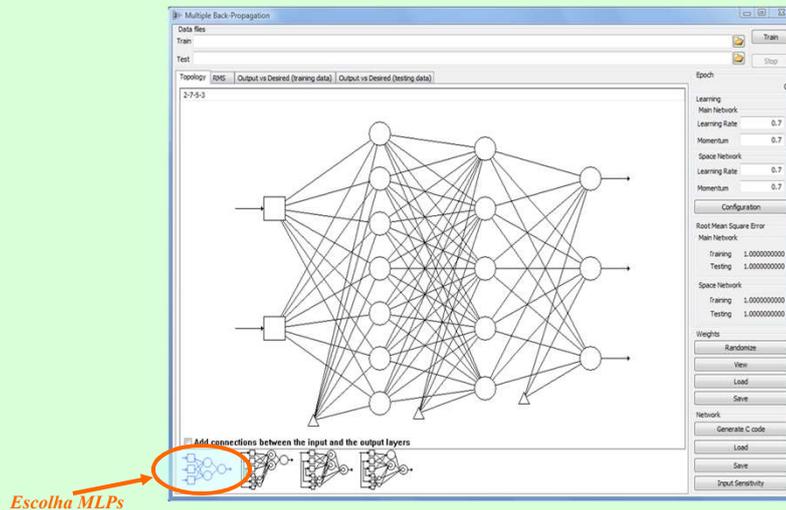


© Prof. Emilio Del Moral Hernandez

87

Exemplo de tela do ambiente MBP definindo uma Rede Neural do tipo MLP – Topology “2-7-5-3”

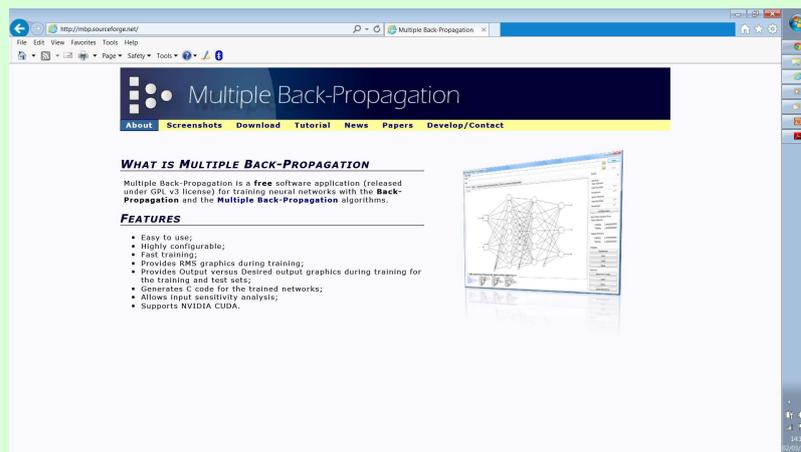
88



© Prof. Emilio Del Moral Hernandez

“Sugestão” ... visite os tutoriais do MBP - <http://mbp.sourceforge.net/> -
e instale-o no seu computador Windows.
(Na sala C1-10: o MBP deve estar instalado já no início do semestre)

89

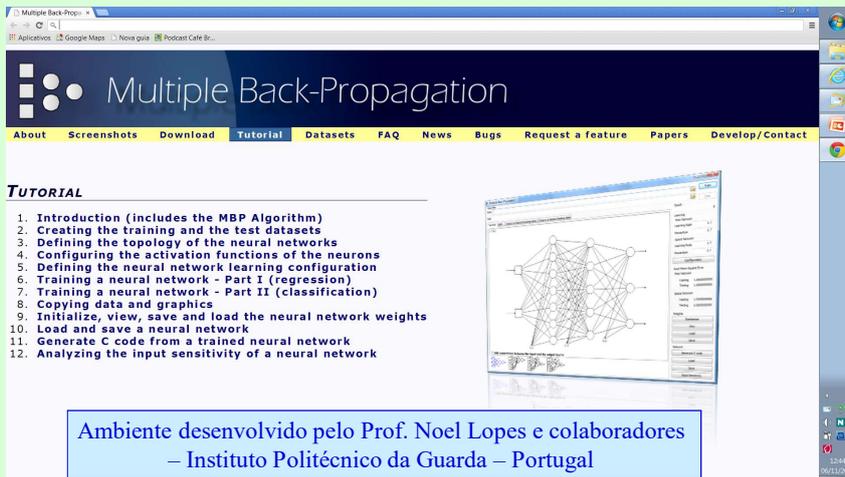


© Prof. Emilio Del Moral Hernandez

MBP – uma plataforma didática para redes neurais gratuita, de fácil uso e com 12 excelentes tutoriais

90

site <http://mbp.sourceforge.net/>



The screenshot shows the website for Multiple Back-Propagation (MBP). The page has a dark blue header with the title "Multiple Back-Propagation" and a navigation menu with links: About, Screenshots, Download, Tutorial, Datasets, FAQ, News, Bugs, Request a feature, Papers, Develop/Contact. Below the header is a "TUTORIAL" section with a numbered list of 12 items:

1. Introduction (includes the MBP Algorithm)
2. Creating the training and the test datasets
3. Defining the topology of the neural networks
4. Configuring the activation functions of the neurons
5. Defining the neural network learning configuration
6. Training a neural network - Part I (regression)
7. Training a neural network - Part II (classification)
8. Copying data and graphics
9. Initialize, view, save and load the neural network weights
10. Load and save a neural network
11. Generate C code from a trained neural network
12. Analyzing the input sensitivity of a neural network

To the right of the list is a screenshot of the MBP software interface, showing a neural network diagram with nodes and connections, and various configuration panels.

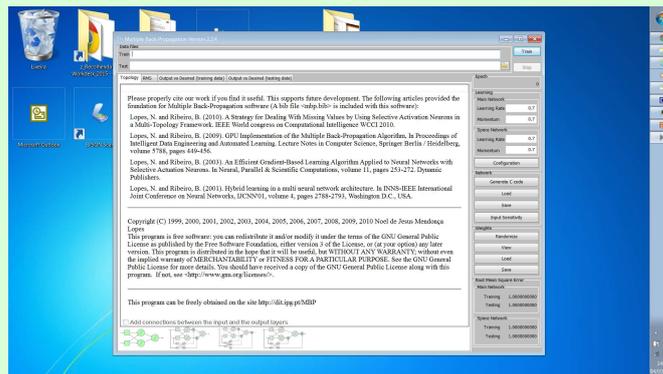
Ambiente desenvolvido pelo Prof. Noel Lopes e colaboradores
– Instituto Politécnico da Guarda – Portugal

© Prof. Emilio Del Moral Hernandez

91

Comece a usar o MBP em situações simples

91



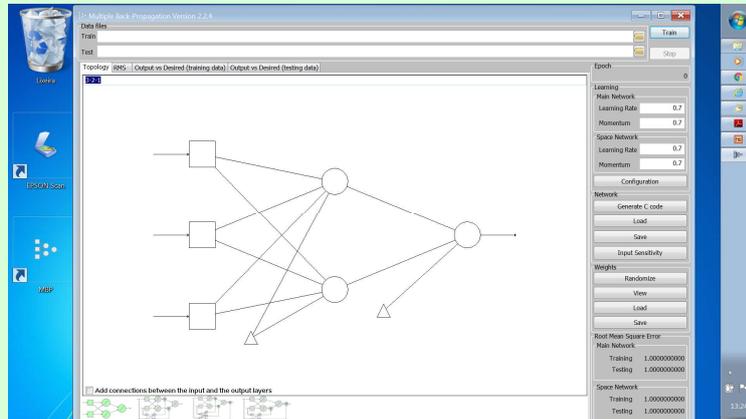
The screenshot shows the MBP software interface. It features a central window with a neural network diagram and various configuration panels on the right. The interface includes a menu bar, a toolbar, and a main workspace. The neural network diagram shows a multi-layered structure with nodes and connections. The configuration panels on the right allow users to adjust parameters such as learning rate, momentum, and network topology. The interface is designed to be user-friendly and educational.

© Prof. Emilio Del Moral Hernandez

92

Instale-o e digite "3-2-1" no campo Topology, ;-)

92

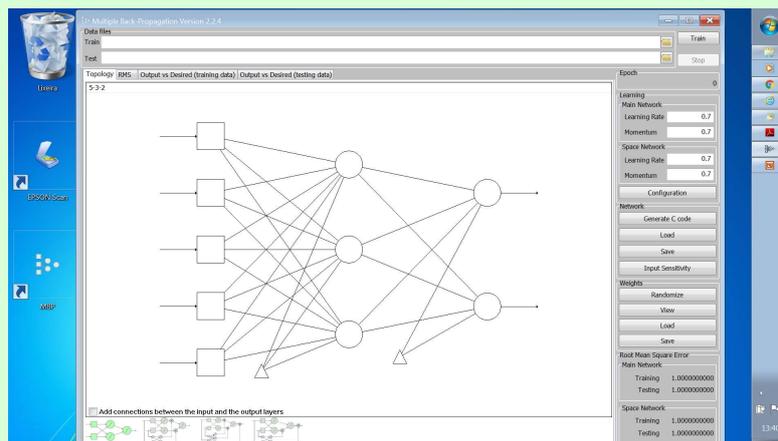


© Prof. Emilio Del Moral Hernandez

92

Instale-o e digite "5-3-2" no campo Topology, ;-)

93



© Prof. Emilio Del Moral Hernandez

93

12 tutoriais curtos narrados (~5 mins cada). Abra um browser e acesse ... <http://mbp.sourceforge.net/tutorial.html>

The screenshot shows the website for Multiple Back-Propagation. The navigation menu includes: About, Screenshots, Download, Tutorial, News, Papers, Develop/Contact. The 'TUTORIAL' section lists 12 items:

1. Introduction (includes the MBP Algorithm)
2. Creating the training and the test datasets
3. Defining the topology of the neural networks
4. Configuring the activation functions of the neurons
5. Defining the neural network learning configuration
6. Training a neural network - Part I (regression)
7. Training a neural network - Part II (classification)
8. Copying data and graphics
9. Initialize, view, save and load the neural network weights
10. Load and save a neural network
11. Generate C code from a trained neural network
12. Analyzing the input sensitivity of a neural network

On the right side of the page, there is a screenshot of the software interface showing a neural network diagram with multiple layers of nodes.

© Prof. Emilio Del Moral Hernandez

Tutorial 2 – criando 2 conjuntos empíricos, de treino e de teste

The screenshot shows the software interface for Multiple Back-Propagation. A window titled 'Tutorial 2' is open, displaying the text: 'Creating the training and the test datasets.' The interface includes a 'Data Sets' section with 'Train' and 'Test' fields, a 'Epoch' counter, and a 'Configuration' panel with various parameters like Learning Rate, Momentum, and Weights. The software interface also shows a neural network diagram and a 'Weights' section.

© Prof. Emilio Del Moral Hernandez

Multiple Back-Propagation

Train Test

Weights: Randomize Load Save

X	Y
0.218959	0.196178
0.047045	0.162958
0.678865	0.833997
0.679296	0.602405
0.934693	0.623243
0.383502	0.838679
0.519416	0.671648

© Prof. Emilio Del Moral Hernandez

Multiple Back-Propagation

Train Test

Weights: Randomize Load Save

Tetrahydrocortisone	Pregnenetriol	Type
3.0	1.3	A
1.9	1.4	A
9.1	0.6	B
9.2	7.9	C
2.6	0.1	A
3.9	0.6	B
3.8	0.2	A

Still you can code characteristics that have non-numeric values transforming them into numeric characteristics.

© Prof. Emilio Del Moral Hernandez

Dados empíricos para treino do modelo e dados empíricos para o teste do modelo ...

100

Dois conceitos centrais em aprendizado de máquina

Atividade com relato escrito a ser entregue em folha A4 identificada:

a) a1- Qual meu plano para a coleta de dados empíricos para o meu desafio de regressão? a2- Quantos cenários empíricos eu consigo coletar em 4 hs de trabalho? a3- e qual o formato da tabela de dados empíricos e a natureza de cada linha ou coluna? B4 - Qual o custo dessa coleta em 4hs?

b) Idem para meu plano de coleta de dados empíricos para meu reconhecedor de padrões. (b1 a b4)

Apresente a) e b) a um colega da sala que você NÃO conheça previamente, refine com isso seu relato e anote o nome dele no seu relato escrito.

© Prof. Emilio Del Moral Hernandez

100

Começemos com “A” (proposta de regressor) ...

101

Atividade com relato escrito a ser entregue em folha A4 identificada:

A-regressor) a1- Qual meu plano para a coleta de dados empíricos para o meu desafio de regressão? a2- Quantos cenários empíricos eu consigo coletar em 4 hs de trabalho? a3- e qual o formato da tabela de dados empíricos e a natureza de cada linha ou coluna? a4 - Qual o custo dessa coleta de 4hs?

Apresente A) (a1 até a4) a um colega da sala que você NÃO conheça previamente, refine com isso seu relato e anote o nome dele no seu relato escrito.

z

Após a discussão da a1 a a4 com o colega de sala não conhecido previamente, os presentes (12-março-2018) entregaram seus relatos escritos ao Prof.; se você não esteve nesta discussão e entrega, contate o professor pessoalmente ao fim da próxima aula e também faça a sua entrega atrasada nessa ocasião da conversa com o professor

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

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

Aula

3

de PSI3571 em
12-mar-2018

**terminou aqui
para parte dos alunos (aqueles que
fizeram anteriormente PSI3471)**

103

103

Intervalo de 10 mins ...

104

*Após o intervalo – Entendimento
detalhado da relação entre o neurônio
artificial e o neurônio biológico!*

*(para quem já fez PSI3471 comigo –
disciplina de 4º ano –, é recordação e
opcional, mas pode ser divertido!)*

104

105

Extra Slides seguem,
referentes a discussão em 50 mins
finais da aula apenas com os alunos
que não cursaram previamente a
disciplina de 4º ano PSI3471 ...

>>>>>

© Prof. Emilio Del Moral Hernandez

105

Redes Neurais Artificiais

São sistemas computacionais, de implementação em hardware ou software, que imitam as habilidades computacionais do sistema nervoso biológico, usando um grande número de processadores simples (neurônios artificiais) e interconectados entre si.

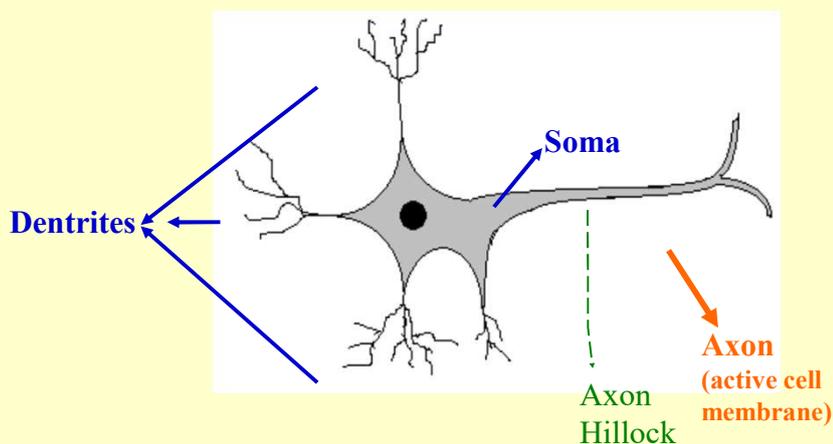
Emprestam da biologia:

- A estrutura de processamento microscópico (processamento de informação de neurônios individuais)
- Em algum grau, aspectos da organização de redes neurais biológicas
- Aspectos de plasticidade sináptica e do aprendizado através de exemplos (através de casos)

106

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

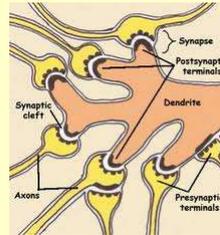
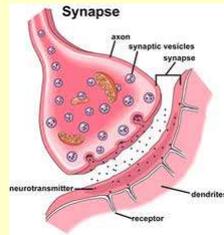
The biological neuron



107

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

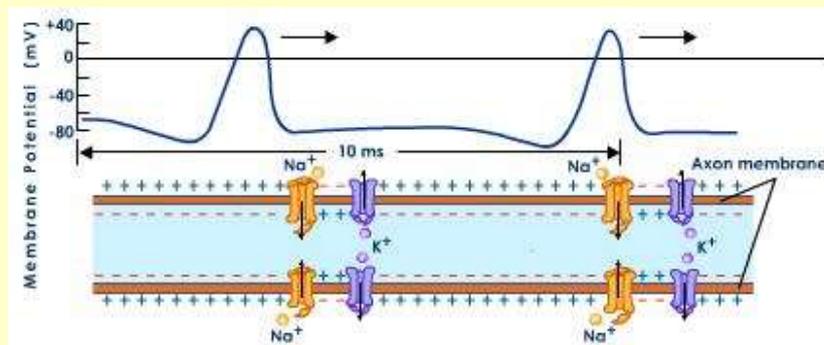
Sinapses



108

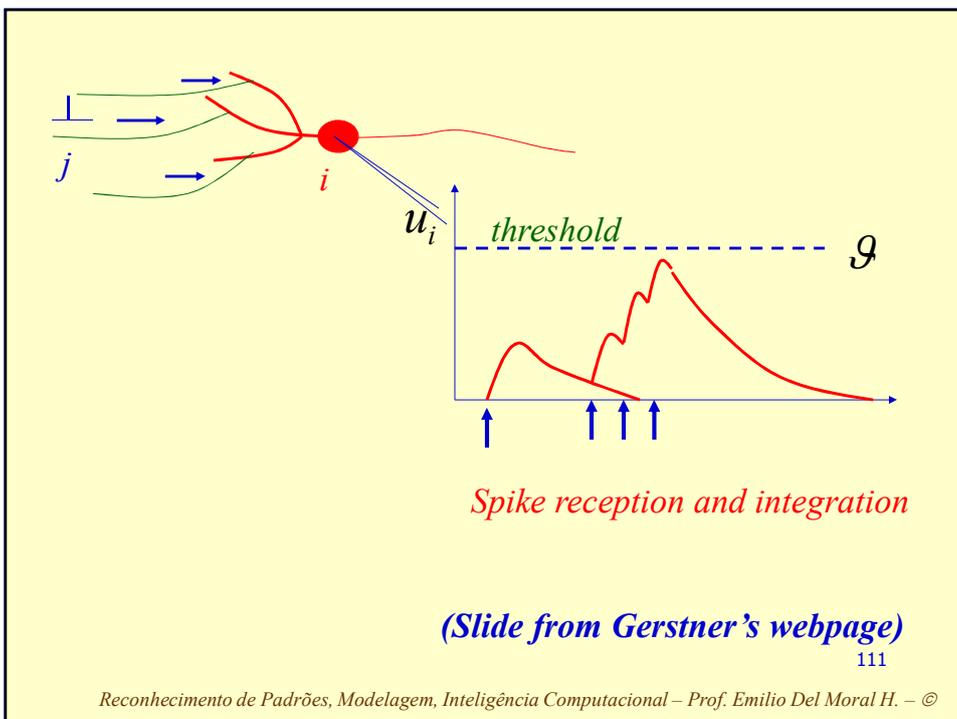
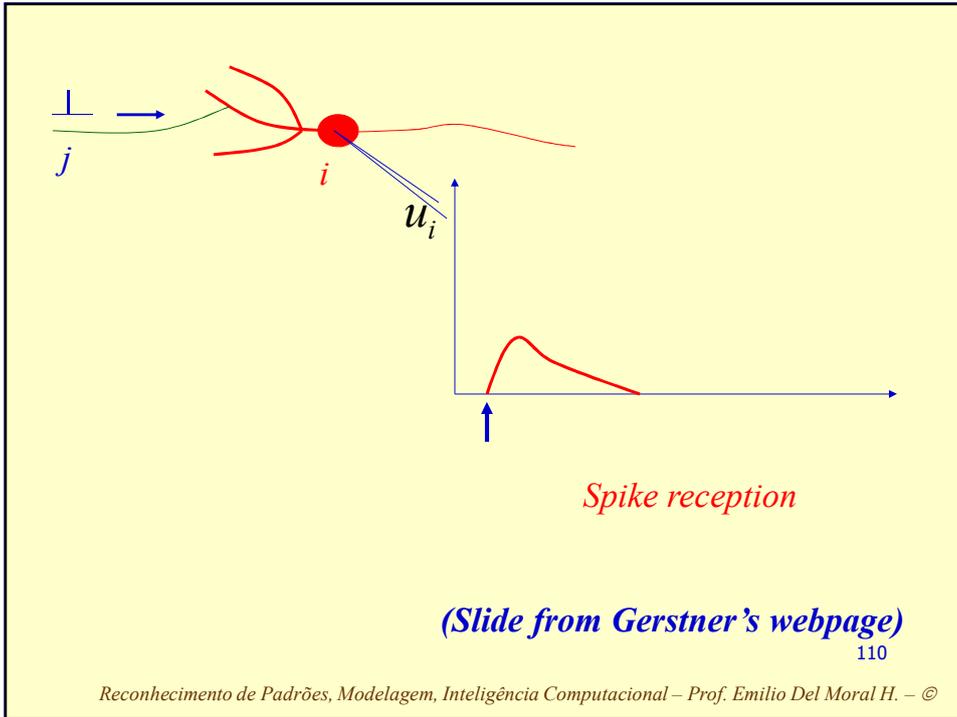
Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

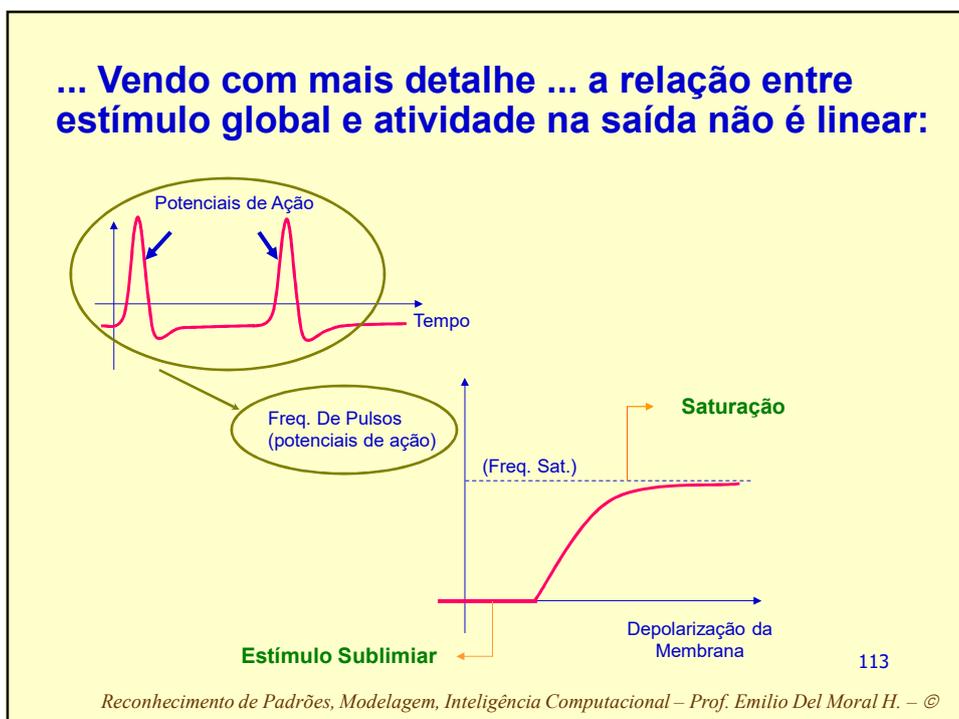
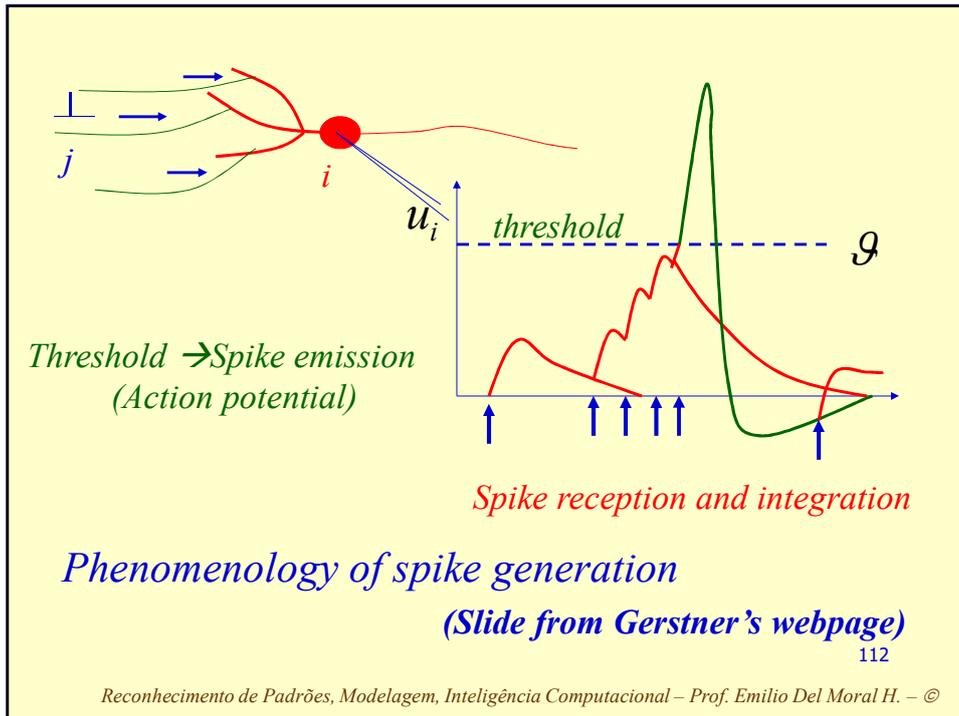
Action Potential Generation and Propagation (no Axônio e ramificações axonais)



109

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





Integrate-and-fire Model

$$\tau \cdot \frac{d}{dt} u_i = -u_i + RI(t) \quad \text{Linear}$$

$$u_i(t) = \mathcal{G} \Rightarrow \text{Fire+reset Não linear}$$

(Slide from Gerstner's webpage)

114

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

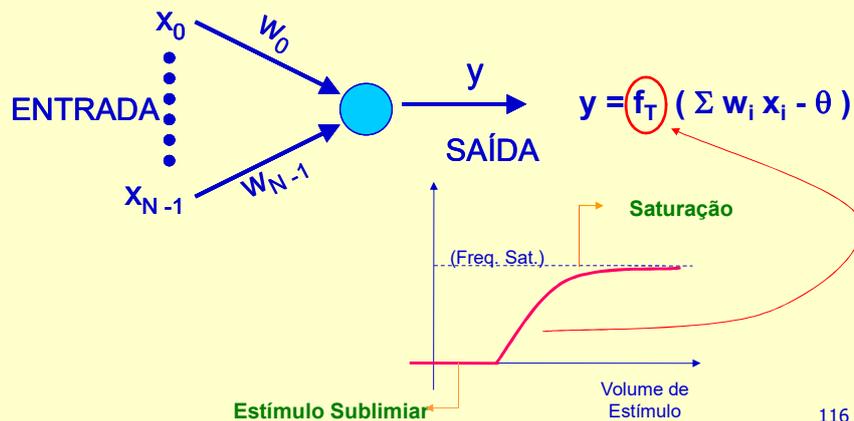
Computação e adaptabilidade em um nó neural

$$y = f_T(\sum w_i x_i - \theta)$$

115

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

**Resumo ... um nó (neural) realiza a seguinte
computação analógica com PLASTICIDADE
proporcionada pelos w ajustáveis ...**



116

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

Fim do extra ... A aula

3

de PSI3571 em
12-mar-2018

**terminou aqui
para todos alunos**

117

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

Redes Neurais Artificiais

118

São: sistemas computacionais, de implementação em hardware ou software, que imitam as habilidades computacionais do sistema nervoso biológico, usando um grande número de processadores simples (neurônios artificiais) e interconectados entre si.

Emprestam da biologia:

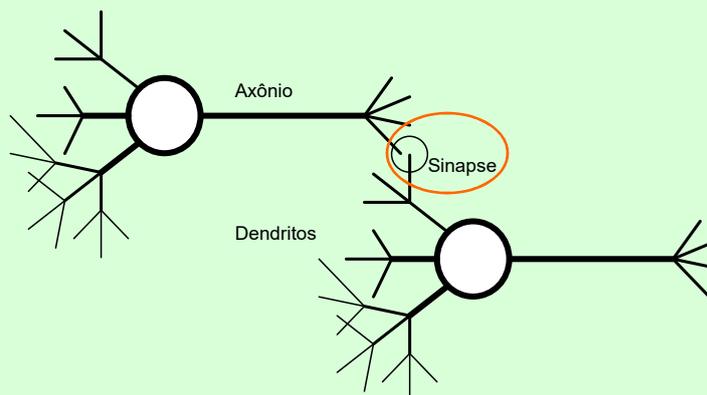
- A estrutura de processamento microscópico (processamento de informação de neurônios individuais)
- Em algum grau, aspectos da organização de redes neurais biológicas – como os neurônios se interligam
- O aprendizado através de exemplos (através de casos)

© Prof. Emilio Del Moral Hernandez

118

Cômputos mais complexos ... são realizados pelo encadeamento de vários neurônios

119



A conexão entre um axônio de um neurônio e um dendrito de outro é denominada **Sinapse**

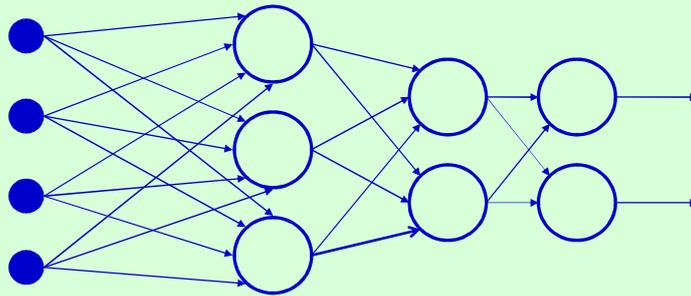
© Prof. Emilio Del Moral Hernandez

119

Foco deste Curso: o Multi Layer Perceptron (MLP)

120

- 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

120

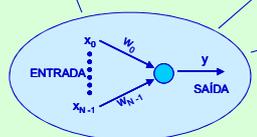
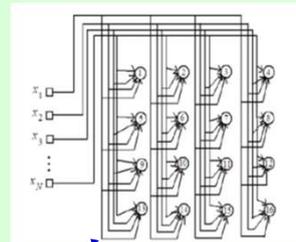
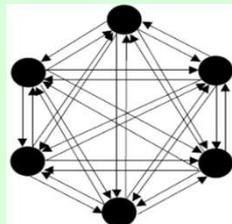
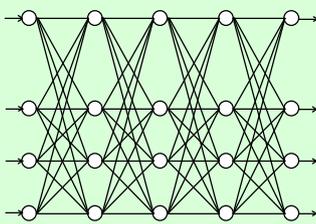
Três arquiteturas neurais importantes (abordadas em pósgrad – PSI 5886)

121

1) MLP
- Multi Layer
Perceptron

2) Memória
Associativa
de Hopfield

3) Mapas Auto-
Organizáveis
de Kohonen



© Prof. Emilio Del Moral Hernandez

121

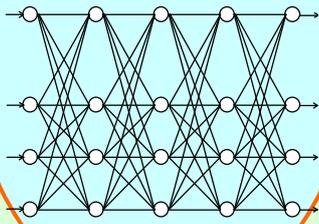
Três arquiteturas neurais importantes

(abordadas em pósgrad – PSI 5886)

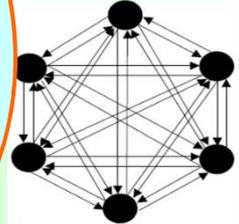
122

Nosso Foco aqui

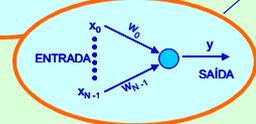
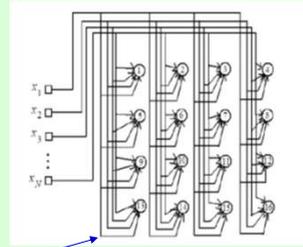
1) MLP
- Multi Layer
Perceptron



2) Memória
Associativa
de Hopfield



3) Mapas Auto-
Organizáveis
de Kohonen



© Prof. Emilio Del Moral Hernandez

122

Redes Neurais Artificiais

123

São: sistemas computacionais, de implementação em software, que imitam as habilidades computacionais do sistema nervoso biológico, usando um grande número de elementos simples (neurônios artificiais) e interligados.

Empre...

A modelagem fiel da biologia está nas redes neurais?
Quanto? Onde? Quando?

- A modelagem de processamento microscópico (processamento de informação de neurônios individuais)
- Em algum grau, aspectos da organização de redes neurais biológicas – como os neurônios se interligam
- O aprendizado através de exemplos (através de casos)

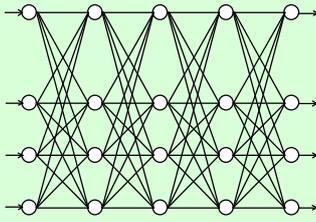
© Prof. Emilio Del Moral Hernandez

123

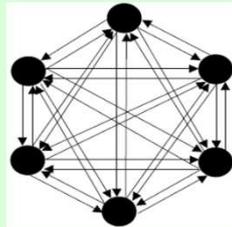
Três arquiteturas neurais importantes (abordadas em pósgrad – PSI 5886)

124

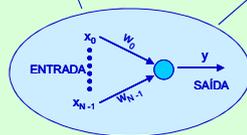
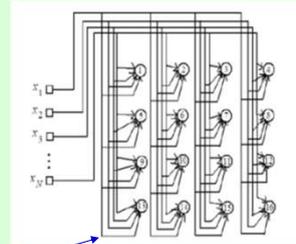
1) MLP
- Multi Layer
Perceptron



2) Memória
Associativa
de Hopfield



3) Mapas Auto-
Organizáveis
de Kohonen



© Prof. Emilio Del Moral Hernandez

124

*Como escolhemos
os valores dos
diversos w 's de um
MLP?*

125

© Prof. Emilio Del Moral Hernandez

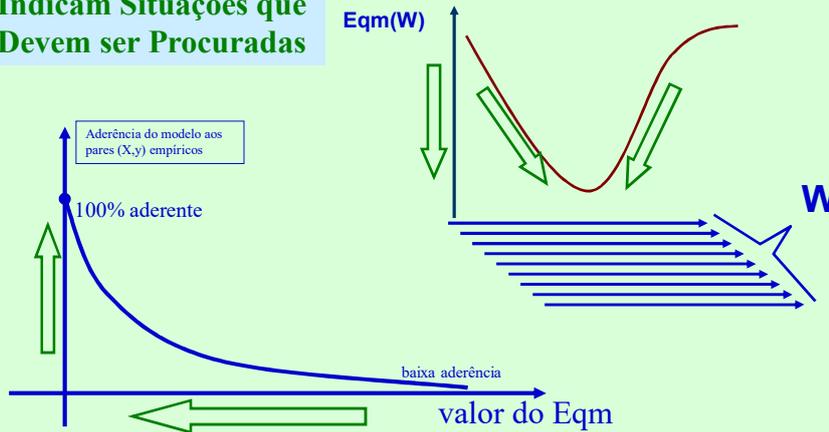
125

O que devemos buscar quando exploramos o espaço de pesos W buscando que a RNA seja um bom modelo?

126

Devemos buscar Maximização da aderência = Mínimo Eqm possível

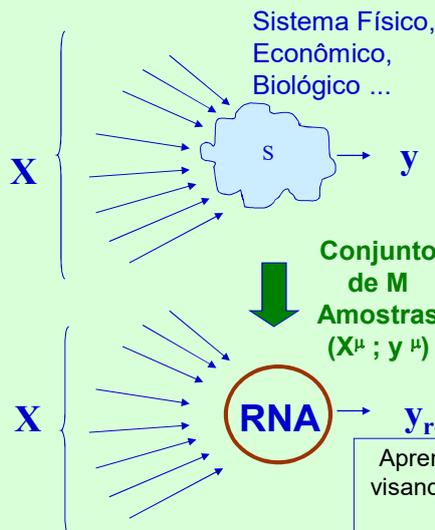
As Setas Verdes Indicam Situações que Devem ser Procuradas



126

Conjunto de treino em arquiteturas supervisionadas (ex. clássico: MLP com Error Back Propagation)

127



A computação desejada da rede pode ser definida simplesmente através de amostras / exemplos do comportamento requerido

$$Eqm = \frac{1}{M} \sum_{\mu=1}^M (y_{rede}(\vec{X}^{\mu}, \vec{W}) - y^{\mu})^2$$

$$\vec{\Delta W} = -\eta \cdot \vec{\nabla} Eqm$$

... em loop ...

Aprendizado: Espaço de pesos W é explorado visando aproximar ao máximo a computação da rede da computação desejada

© Prof. Emilio Del Moral Hernandez

127

Aprendizado do MLP por Error Back Propagation ...

$$\Delta \vec{W} = -\eta \cdot \vec{\nabla} E_{qm}$$

Gradiente de Eqm no espaço de pesos = $(\partial E_{qm}(W)/\partial w_1, \partial E_{qm}(W)/\partial w_2, \partial E_{qm}(W)/\partial w_3, \dots)$

Chegando às fórmulas das derivadas parciais, necessárias à Bússola do Gradiente

128

© Prof. Emilio Del Moral – EPUSP

A modelagem fiel da biologia está nas redes neurais?
Quanto? Onde? Quando?

Como escolhemos os valores dos diversos w 's de um MLP?

129

© Prof. Emilio Del Moral Hernandez

129

A modelagem fiel da biologia está nas redes neurais?
Quanto? Onde? Quando?

130

Como escolhemos os valores dos diversos w 's nas arquiteturas de Hopfield e Kohonen?

© Prof. Emilio Del Moral Hernandez

130

Para quem quiser avançar mais aceleradamente ... Pesquise os nichos de aplicação, as equações de operação entrada / saída e os algoritmos de aprendizado das Redes neurais Não MLP: Memórias associativas de Hopfield, Mapas autoorganizados de Kohonen, Redes de RBFs, SVMs, ConvNNs,... etc etc.

131

© Prof. Emilio Del Moral Hernandez

131

Complementemos com “B” (proposta de reconhecimento de padrões) ...

132

Atividade com relato escrito a ser entregue em folha A4 identificada: B-reconhecedor) b1- Qual meu plano para a coleta de dados empíricos para o meu desafio de reconhecimento? b2- Quantos cenários empíricos eu consigo coletar em 4 hs / 4 dias de trabalho? b3- e qual o formato da tabela de dados empíricos e a natureza de cada linha ou coluna? b4 - Qual o custo dessa coleta de 4hs?

Apresente B) (b1 até b4) a um colega da sala que você NÃO conheça previamente – ele fará o papel do seu engenheiro auxiliar na coleta de dados e questionará pesadamente seus planos de coleta b1 até b4;

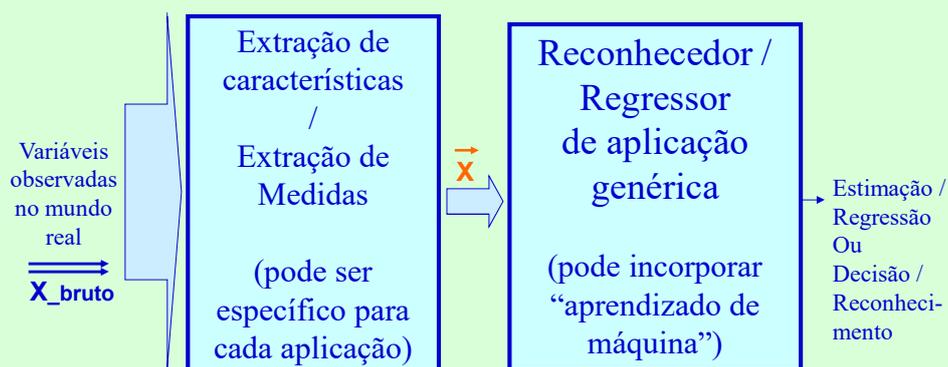
Refine com esta conversa o seu relato escrito e anote o nome dele no fim desse relato, com o título “Nome do engenheiro auxiliar de coleta de dados”.

© Prof. Emilio Del Moral Hernandez

132

Elaborando uma Solução em dois estágios

133



Atividade com relato escrito a ser entregue em A4 identificada ...

O meu desafio de regressão / reconhecimento precisa do primeiro estágio ?

A dimensão de entrada é (digamos) > 50 ? Que extratores de características poderiam ser úteis no minha aplicação?

Apresente seu relato escrito a um colega da sala que você NÃO conheça

Falemos agora um pouco sobre ambientes computacionais que poderemos usar nos projetos ...

MBP para prototipação rápida, Matlab, etc ...

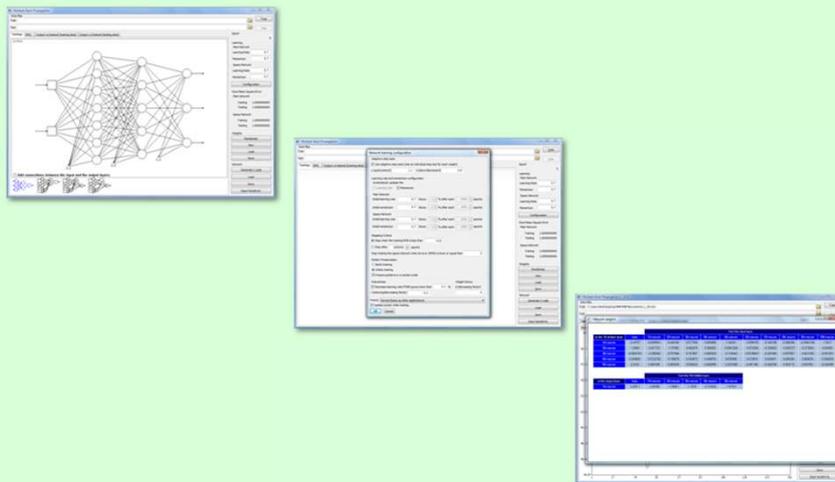
Me digam vocês de outros e iniciemos uma seção no STOA para registro de bons achados!

134

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

Algumas Telas do MBP

135



© Prof. Emilio Del Moral Hernandez

135

Conhecemos outros ambientes de modelagem úteis a PSI3571 além do MBP?

136

Vamos resgatar nas nossas trajetórias elementos que nos permitiriam modelagem multivariada / reconhecimento de padrões / regressão ?

Acrescentemos essas possibilidades ao seu diário de bordo PSI3571 – um dossiê cumulativo de seus progressos e atividades, acessível ao professor.

© Prof. Emilio Del Moral Hernandez

136

Enunciado preliminar! Pode ser ligeiramente modificado até 21/3

Tarefa para desenvolvimento próprio e entrega até a aula de 2ª f. da Semana Santa +1(dia 2/abril)

137

- a) Slides com a descrição de uma proposta de regressor e outra proposta para apresentação a todos da classe:
 - Variáveis envolvidas
 - Utilidade e consumidor alvo
 - Plano de coleta e viabilidade / velocidade de coleta
 - Engenheiros (colegas da sala) que ajudaram no refinamento do produto e da coleta
 - Descrição breve da necessidade do primeiro estágio de redução de dimensionalidade / extração de características (de >> 50 para menos de 20 digamos), seja para uma das propostas ou para uma variante de uma delas
 - Slides com os resultados e explicações da pesquisa bibliográfica adiante referente a extração de características adhoc
 - Slides com os resultados e explicações da pesquisa bibliográfica adiante referente a ambientes de computação e extração de características que pretende usar nos seus projetos
- b) Pesquisa bibliográfica de métodos de redução de características / extração de medidas adhoc para sua aplicação (não vale o método genérico PCA, que será praticado em separado de qualquer forma). Não vale tampouco Fourier nua e crua (isto já é feijão com arroz para muitos)
- c) Pesquisa bibliográfica de ambientes de computação e extração de características que poderia usar nos seus projetos (não vale MBP, que será praticado em prototipação de ordem zero de qualquer forma).

© Prof. Emilio Del Moral Hernandez

137

Aula

4

de PSI3571 em
19-mar-2018

**terminou aqui
para parte dos alunos (aqueles que
fizeram anteriormente PSI3471)**

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

Intervalo de 10 mins ...

***Após o intervalo – 40 mins sobre o
entendimento das premissas da
aproximação universal de Kolmogorov-
Cybenko!***

***(para quem já fez PSI3471 comigo – disciplina de
4º ano –, é recordação e opcional, mas pode ser
útil / necessário rever se não entendeu direito em
PSI3471!)***

De onde vem o grande poder do MLP?

Theorem of [Kolmogorov &] Cybenko:

- Kolmogorov:

Given any F of many variables $x_1, x_2, x_3, x_4 \dots$ for example, the complicated $F = [x_1 \cdot \sin(x_2) + \log(x_3)] / x_4 + \text{etc} \dots$ or any other F , the following approximation can always be obtained ...

$F(x_1, x_2, x_3, x_4 \dots) \sim$ linear combination and composition of a finite (limited) number of functions $g_k(v)$ of just one variable v , and we can have arbitrary precision in the approximation of F

- Cybenko: adapted Kolmogorov for the particular case in which the single argument functions g_k are approximated by a sum of sigmoidal functions ... he noticed that several sigmoids shifted and scaled properly can approximate any $g_k(\text{scalar argument})$

Cybenko concluded that any arbitrary F CAN be "implemented" by an ANN with sigmoidal nodes and just 1 hidden layer!!

Cybenko – Enunciado da Prova ... (premissas + resultado)

The screenshot shows the Wikipedia article for the 'Universal approximation theorem'. The title is 'Universal approximation theorem'. The article text states: 'In the mathematical theory of artificial neural networks, the **universal approximation theorem** states^[1] that a feed-forward network with a single hidden layer containing a finite number of neurons (i.e., a multilayer perceptron), can approximate continuous functions on compact subsets of \mathbb{R}^n , under mild assumptions on the activation function. The theorem thus states that simple neural networks can represent a wide variety of interesting functions when given appropriate parameters; it does not touch upon the algorithmic learnability of those parameters. One of the first versions of the theorem was proved by George Cybenko in 1989 for sigmoid activation functions^[2]. Kurt Hornik showed in 1991^[3] that it is not the specific choice of the activation function, but rather the multilayer feedforward architecture itself which gives neural networks the potential of being universal approximators. The output units are always assumed to be linear. For notational convenience, only the single output case will be shown. The general case can easily be deduced from the single output case.'

Formal statement [edit]

The theorem^{[3][4][5]} in mathematical terms:

Let $\varphi(\cdot)$ be a nonconstant, bounded, and monotonically-increasing continuous function. Let I_m denote the m -dimensional unit hypercube $[0, 1]^m$. The space of continuous functions on I_m is denoted by $C(I_m)$. Then, given any function $f \in C(I_m)$ and $\epsilon > 0$, there exist an integer N and real constants $a_i, b_i \in \mathbb{R}, w_i \in \mathbb{R}^m$, where $i = 1, \dots, N$ such that we may define:

$$F(x) = \sum_{i=1}^N \alpha_i \varphi(w_i^T x + b_i)$$

as an approximate realization of the function f where f is independent of φ , that is,

$$\|F(x) - f(x)\| < \epsilon$$

for all $x \in I_m$. In other words, functions of the form $F(x)$ are dense in $C(I_m)$.

References [edit]

- ↑ Balazs Csordás Csáji: Approximation with Artificial Neural Networks; Faculty of Sciences, Eötvös Loránd University, Hungary
- ↑ ↑ Cybenko, G. (1989) "Approximations by superpositions of sigmoidal functions". *Mathematics of Control, Signals, and Systems*, 2 (4), 303-314
- ↑ ↑ Kurt Hornik (1991) "Approximation Capabilities of Multilayer Feedforward Networks". *Neural Networks*, 4(2), 251-257
- ↑ Haykin, Simon (1998): *Neural Networks: A Comprehensive Foundation*, Volume 2, Prentice Hall, ISBN 0-13-27350-1.
- ↑ Hassoun, M. (1995) *Fundamentals of Artificial Neural Networks* MIT Press, p. 48

↑ This applied mathematics-related article is a stub. You can help Wikipedia by expanding it.

Categories: Theorems in discrete mathematics | Artificial neural networks | Neural networks | Network architecture | Networks | Information, knowledge, and uncertainty | Applied mathematics stubs

The page was last modified on 1 June 2014, at 20:06.

Fwd: Proposta ...eml | Alterações vag...doc | [Mostrar todos os downloads...](#)

© Prof. Emilio Del Moral Hernandez

142

Entendamos ...

- as premissas da demonstração de Cybenko
- a notação não muito familiar a nós que ele usou
- o quão poderoso é o resultado que ele obteve
- como com passos simples podemos estender a sua aplicação (ou ... *relaxando algumas das (apenas aparentes) limitações impostas nas premissas*)

Kurt Hornik showed in 1991^[2] that it is not the specific choice of the φ assumed to be linear. For notational convenience, only the single out

Formal statement [\[edit\]](#)

The theorem^{[2][3][4][5]} in mathematical terms:

Let $\varphi(\cdot)$ be a nonconstant, bounded, and monotonically-increasing function in $C(I_m)$ and $\epsilon > 0$, there exist an integer N and real constants α_i, b_i

$$F(x) = \sum_{i=1}^N \alpha_i \varphi(w_i^T x + b_i)$$

as an approximate realization of the function f where f is independent of N

$$|F(x) - f(x)| < \epsilon$$

for all $x \in I_m$. In other words, functions of the form $F(x)$ are dense in $C(I_m)$.

Kurt Hornik showed in 1991^[2] that it is not the specific choice of the φ assumed to be linear. For notational convenience, only the single out

Formal statement [\[edit\]](#)

The theorem^{[2][3][4][5]} in mathematical terms:

Let $\varphi(\cdot)$ be a nonconstant, bounded, and monotonically-increasing function in $C(I_m)$ and $\epsilon > 0$, there exist an integer N and real constants α_i, b_i

$$F(x) = \sum_{i=1}^N \alpha_i \varphi(w_i^T x + b_i)$$

as an approximate realization of the function f where f is independent of N

$$|F(x) - f(x)| < \epsilon$$

for all $x \in I_m$. In other words, functions of the form $F(x)$ are dense in $C(I_m)$.

Kurt Hornik showed in 1991^[2] that it is not the specific choice of the φ assumed to be linear. For notational convenience, only the single out

Formal statement [edit]

The theorem^{[2][3][4][5]} in mathematical terms:

$y_{rede}(X)$

X

Let $\varphi(\cdot)$ be a nonconstant, bounded, and monotonically-increasing function in $C(I_m)$ and $\epsilon > 0$, there exist an integer N and real constants α_i and b_i

$$F(x) = \sum_{i=1}^N \alpha_i \varphi(w_i^T x + b_i)$$

número de nós escondidos

sigmoidal

viés; : viés do nó escondido i

W_i : vetor de pesos do nó escondido i

elementos do vetor de pesos do nó linear de saída W_s

$$|F(x) - f(x)| < \epsilon$$

for all $x \in I_m$. In other words, functions of the form $F(x)$ are dense in $C(I_m)$.

Kurt Hornik showed in 1991^[2] that it is not the specific choice of the φ assumed to be linear. For notational convenience, only the single out

Formal statement [edit]

The theorem^{[2][3][4][5]} in mathematical terms:

Let $\varphi(\cdot)$ be a nonconstant, bounded, and monotonically-increasing function in $C(I_m)$ and $\epsilon > 0$, there exist an integer N and real constants α_i and b_i

$y_{rede}(X)$

Fescondida_sistema(X)

$$F(x) = \sum_{i=1}^N \alpha_i \varphi(w_i^T x + b_i)$$

as an approximate realization of the function f where f is independent of x

Limite de erro

$$|F(x) - f(x)| < \epsilon$$

for all $x \in I_m$. In other words, functions of the form $F(x)$ are dense in $C(I_m)$.

Cybenko – a prova matemática, disponível para download na internet, é bastante complexa

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

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

Approximation by Superpositions of a Sigmoidal Function*

G. Cybenko†

Abstract. In this paper we demonstrate that finite linear combinations of superpositions of a fixed, univariate function and a set of affine functions can uniformly approximate any continuous function of n real variables 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 interval, 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

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

where $y_j \in \mathbb{R}^n$ and $\alpha_j, \theta_j \in \mathbb{R}$ are fixed. (y^T is the transpose of y so that $y^T x$ is the inner product of y 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.

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

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 N00010-86-G-0202 and DOE Grant DE-FG02-83ER22001.
† Center for Supercomputing Research and Development and Department of Electrical and Computer Engineering, University of Illinois, Urbana, Illinois 61801, U.S.A.

310

G. Cybenko

313

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 bounded measurable sigmoidal function. Then finite sums of the form

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

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

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

for all y 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

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

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

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

ed are quite powerful, we that remain to be answered imation (or equivalently, imation 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- proximated and the number ound in [MS] and [BH], iments of the results of this : more attention.

n, Christopher Chase, Lee marov, Richard Lippmann, rence, and improvements

New York, 1972; nstitutions, Neural Comput. (to stems and control, IEEE Control b, Classifying learnable geometric ridings of the 18th Annual ACM p. 273-282. and the Pappas problem, Ann. lets using the Radon transform, wo Hidden Layers are Sufficient, University, 1988. of linear combinations, SIAM J. us mappings by neural networks, IEEE Trans. Acoust. Speech Signal sllward networks are universal a Neural Net and Conventional at, nal Classifiers, Technical Report, -475. tworks by sigmoidal functions, n, University of Lowell, 1988.

Fim do extra – A aula

4

de PSI3571 em
19-mar-2018

terminou aqui para todos alunos

149

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