

Disciplina PSI2533 – Prof. Emilio - 2016

- Redes Neurais e Aprendizado de Máquina
- 4as feiras – às 9:20hs; 6as às 7:30hs
- Sala B2- 05
- Prof. Emilio Del Moral Hernandez
- emilio@lsi.usp.br



Prof. Emilio Del Moral Hernandez

ICONE – EPUSP: Grupo de Inteligência Computacional, Modelagem e Neurocomputação Eletrônica

Prof. Dr. Emilio Del Moral Hernandez

Graduação em Engenharia Elétrica na EPUSP

Doutorado em Engenharia Elétrica pela
University of Pennsylvania (Upenn – Philadelphia)

Livre Docente da EPUSP, na área de
Neurocomputação Eletrônica e Sistemas Adaptativos

Atuante no IEEE e nas atividades técnicas da IEEE - CIS

Contato: emilio.delmoral@usp.br / emilio@lsi.usp.br

Website do Grupo: www.lsi.usp.br/ICONE



Prof. Emilio Del Moral Hernandez

Programa aproximado em 2016

PSI-2533 Módulo de Redes Neurais e Aprendizado – 2016

Professor Emilio Del Moral Hernandez (3o módulo, 2o Semestre)
emilio@lsi.usp.br / www.lsi.usp.br/~emilio

Lista do que pretendemos neste terceiro módulo de PSI 2533:

(partes iniciais - aproximadamente 20% do tempo será usado para o entendimento de conceitos e estruturas das redes neurais)

- 1- Entender o que é uma rede neural do tipo SLP (Single Layer Perceptron) e o que é uma rede neural MLP (Multi Layer Perceptron). A ideia é entendermos como elas se relacionam com as redes neurais biológicas, que equações matemáticas elas envolvem, e qual o papel de suas entradas, de suas saídas e de seus pesos sinápticos ajustáveis.
- 2- Entender a diversidade de computações e processamentos que cada uma dessas redes pode realizar: processamentos lineares; não lineares; digitais; analógicos; mistos, conjugando todas essas classes. Conhecer a universalidade / generalidade das computações / processamentos realizados pelo MLP, tanto em processamento de informação para o reconhecimento de padrões quanto em processamento de informação envolvendo regressão multivariada, fusão de variáveis e estimação de grandezas a partir de outras. Discutir alguns casos interessantes de aplicação.
- 3- Entender o conceito de otimização dos pesos sinápticos para a representação, na rede MLP, de dados empíricos associados a um problema de modelagem, de regressão ou de reconhecimento de padrões, e de maximização de desempenho dessa modelagem por minimização de erro quadrático. Entender o conceito de generalização a partir dessa representação. Relacionar todos estes elementos com o cenário conceitual de aprendizado de máquina (machine learning). Discutir alguns casos concretos de dados empíricos usados no treinamento de redes neurais.

Prof. Emilio Del Moral Hernandez

Programa aproximado em 2016

(parte central - aproximadamente 70% do tempo, dedicado ao entendimento matemático e computacional da rede neural MLP)

- 4- Desenvolver conjuntamente (professor e classe) a matemática de otimização de pesos sinápticos de uma rede neural MLP exemplo, com base no gradiente descendente para a minimização do erro quadrático da RNA. Chegaremos a entender todos os detalhes do algoritmo de aprendizado por "Error Back Propagation" para uma MLP exemplo e um conjunto de treino genérico.
- 5- Ser capaz de refazer autonomamente essa matemática (autonomamente quer dizer, pelo/a aluno/a, como parte de exercício), adaptando-a adequadamente a qualquer outra rede neural MLP diferente da vista em sala, com diferentes números de nós, diferentes funções de não linearidade nos nós e diferentes números de entradas e saídas na rede. Discutir casos de aplicações de redes neurais com tais variações com relação à MLP exemplo. Entender o conceito de conjunto de teste.
- 6- Exercitar autonomamente, como parte de exercício, uma rede neural simples no ambiente de simulação computacional MBP ou Matlab.

(aprox. 10% do tempo, à análise de requisitos de implementação em software e em hardware)

- 7- Relacionar os resultados matemáticos dos estudos realizados com a estruturação geral de código para o aprendizado e a execução de uma rede neural, e – em havendo tempo – com alguns dos requisitos gerais de hardware para embarque ou integração (em CI) de uma rede neural MLP.

Prof. Emilio Del Moral Hernandez

... forma de trabalho e outras infos ...

Para informes administrativos, usarei: o Moodle STOA + avisos escritos em lousa na aula + e-mails enviados a sua conta USP (endereço de e-mail listado no sistema Jupiter)

Informes administrativos dados no início de semestre:

Este módulo compreende as aulas entre as provas P2 e a P3, correspondendo pois ao material que será avaliado na P3. A P3 será com consulta apenas a uma A4 frente e verso com anotações de estudo manuscritas por você, identificada e assinada, e que deve obrigatoriamente ser entregue junto com a sua prova. Temos na disciplina PSI2533 uma componente de exercícios para nota que corresponde a 20% da nota final no curso, resultante da média com todos exercícios pedidos nos três módulos. Além dos exercícios com nota, exercícios para treino e estudo complementares poderão ajudar no seu aprendizado e no bom desempenho nas avaliações (P3 e Exs).

As anotações de discussões em aula e desenvolvimentos feitos em lousa têm se mostrado muito úteis ao aprendizado nos diversos anos anteriores, complementando os slides e outros materiais de apoio utilizados (PDFs e impressos eventualmente distribuídos em sala). **Um item de estudo**

OBRIGATÓRIO AUTÔNOMO refere-se à revisão detalhada dos seguintes três tópicos previamente aprendidos por todos: *1) O Método do Gradiente Descendente; 2) Derivadas Parciais; e 3) Regra da Derivada da Cadeia de Múltiplos Estágios.*

A referência mais ampla em redes neurais que recomendo é o excelente “Neural Networks: a Comprehensive Foundation” – de Simon Haykin. Ele é disponível na nossa biblioteca, em português. O material que se planeja cobrir está contido nos 4 capítulos iniciais desta referência. Outras referências: o livro em português do professor Zsolt Kovacs, também disponível na biblioteca; além destes livros aqui destacados, há diversos materiais introdutórios disponíveis na web, os interessantes tutoriais para uso do ambiente MBP (Multiple Back Propagation) disponíveis na internet, e livros diversos na nossa biblioteca.

Bons estudos!

Prof. Emilio Del Moral Hernandez


Computação Bioinspirada, Computação Neural e Eletrônica Neuromórfica

- Conjugue 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 delimitação de novos modelos de computação
 - 2) Emular ou substituir parcialmente as capacidades dos sistemas biológicos

Prof. Emilio Del Moral Hernandez

Elencando alguns empréstimos da biologia

- **Redes Neurais Artificiais – *nosso foco***
 - 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



Prof. Emilio Del Moral Hernandez

Redes Neurais Artificiais

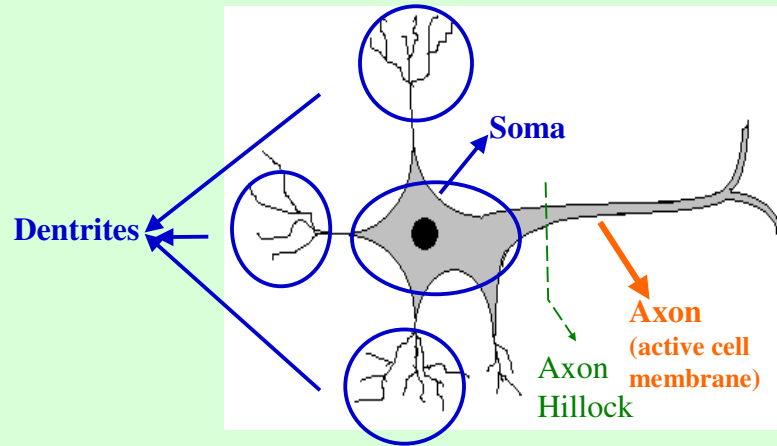
São: sistemas computacionais, de implementação em hardware ou software, que imitam as habilidades computacionais do sistema nervoso biológico, usando um grande número de processadores simples (neurônios artificiais) e interconectados entre si.

Emprestam da biologia:

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



Prof. Emilio Del Moral Hernandez

Fundamentos ... O neurônio biológico



Prof. Emilio Del Moral Hernandez

Action Potential generation and Propagation (Potenciais de Ação = nome técnico dos pulsos neurais)





... ions principais ...

Sódio, Potássio, Cloro...

Prof. Emilio Del Moral Hernandez

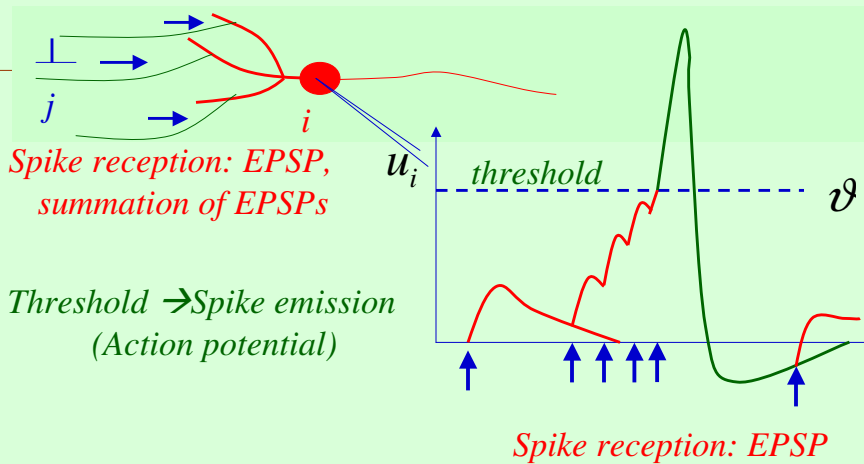
Sinapses



Conexões Sinápticas ... podem ser excitatórias ou inibitórias, mais fortes ou mais fracas, mais lentas ou mais rápidas, ... de acordo com o tipo (dopamina, serotonina, etc ...) e com a quantidade de neurotransmissores envolvidos.

Conceitos de Peso Sináptico e de Plasticidade Sináptica

Prof. Emilio Del Moral Hernandez

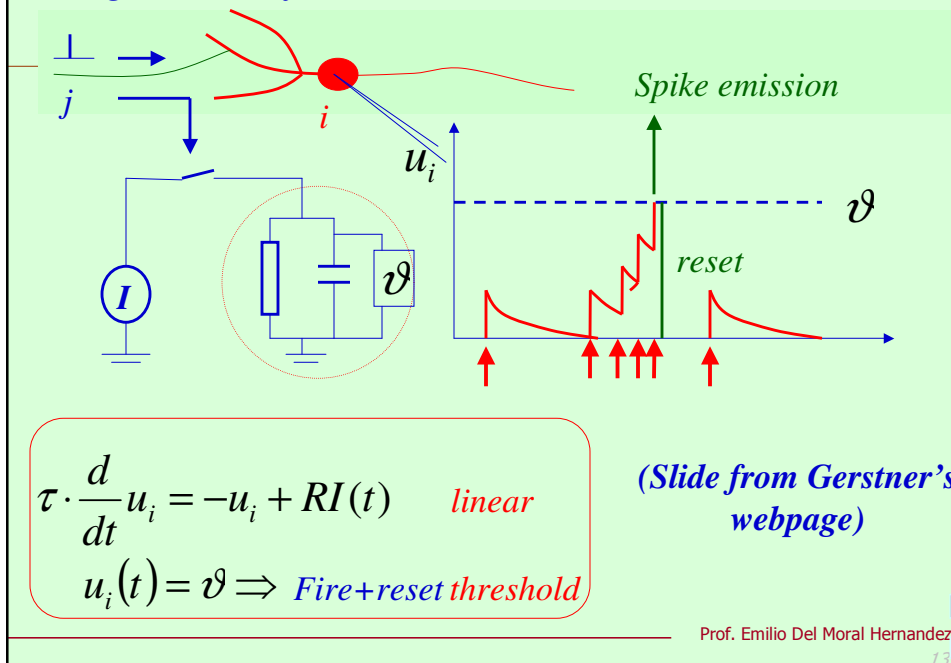


Phenomenology of spike generation

(Slide from Gerstner's webpage)


Prof. Emilio Del Moral Hernandez

Integrate-and-fire Model and the Electronic Version



Sinal gerado por circuito com transistores CMOS, para codificação por pulsos neurais individuais

Potencial de ação gerado por neurônio CMOS

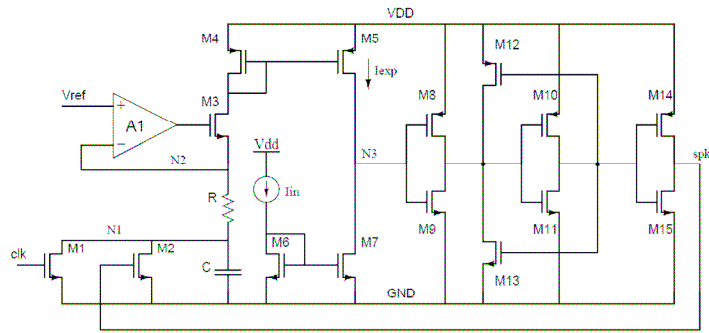


Prof. Emilio Del Moral Hernandez
 Grupo ICONE-EPUSP-PSI
 Trabalho de pós graduação de Julio Cesar Saldaña

Prof. Emilio Del Moral Hernandez

Circuito neuromórfico para codificação temporal de informação, em redes neurais pulsadas

Circuito codificador



Prof. Emilio Del Moral Hernandez
Grupo ICONE-EPUSP-PSI
Trabalho de pós graduação de Julio Cesar Saldaña

Prof. Emilio Del Moral Hernandez

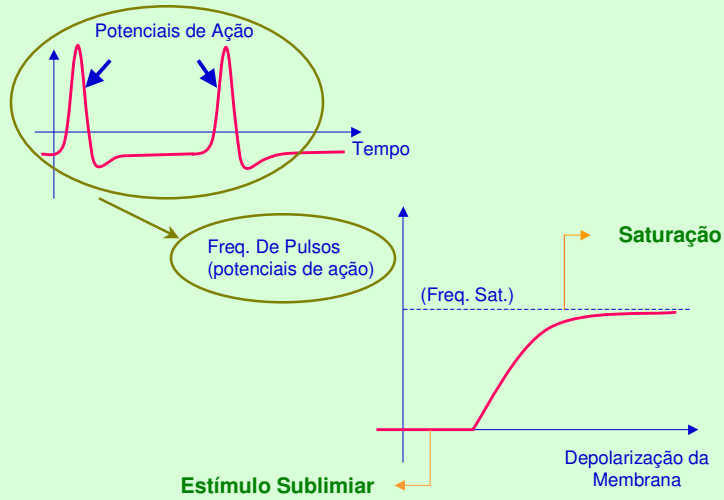
Codificação de informação em neurônios biológicos

- Freqüencial
- Phase
- Sincronização
- ??? Outros ???

- Os modelos neurais mais clássicos >>>
Predominantemente codificação FREQUENCIAL!!!!

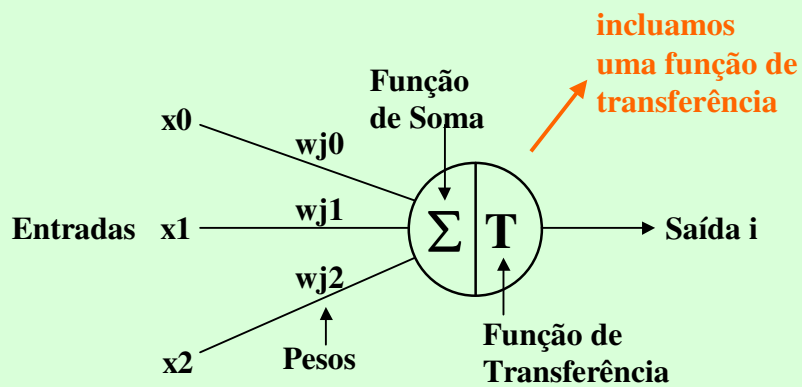
Prof. Emilio Del Moral Hernandez

Estudando a relação não linear entre volume de estímulo e volume de atividade de saída



Prof. Emilio Del Moral Hernandez

Modelando a Relação Entrada / Saída do neurônio



Prof. Emilio Del Moral Hernandez



Temos pois duas componentes de cálculo complementares no neurônio:

1) Uma linear (soma ponderada das entradas)



2) Outra não linear (Função de transferência da classe sigmoidal)

Prof. Emilio Del Moral Hernandez

Computação linear e não linear, com codificação frequencial



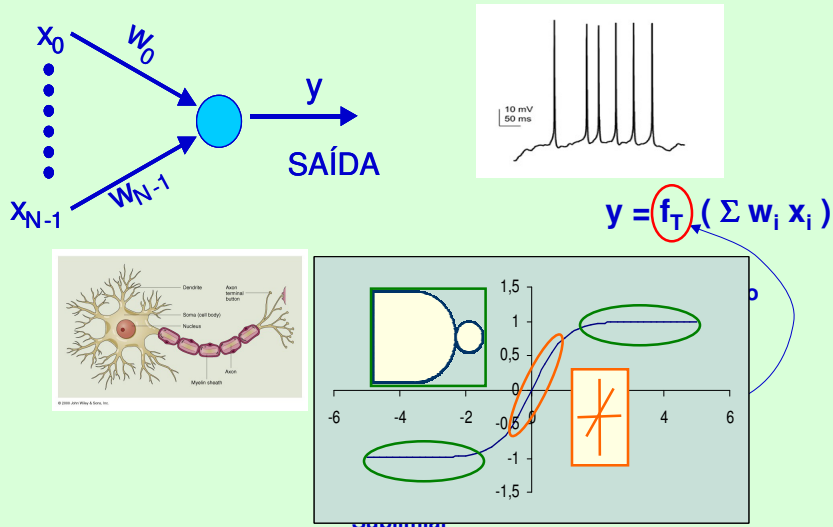
$$y = f_T(\sum w_i x_i)$$



Prof. Emilio Del Moral Hernandez

Computação linear e não linear, com codificação freqüencial

21




Prof. Emilio Del Moral Hernandez

21

O Perceptron Digital: $y = \text{signal}(\sum w_i x_i - \theta)$ (função de transferência tipo "degrau")

22

- 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

22

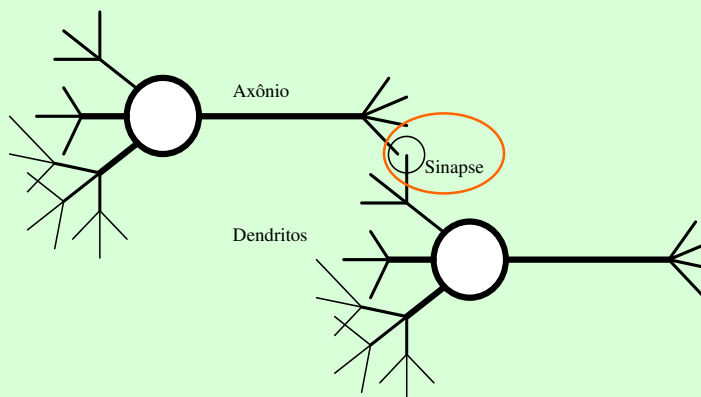
E se a saída do nosso problema não for digital?
O "Perceptron Contínuo": $y = \text{tgh}(\sum w_i x_i - \theta)$

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



Prof. Emilio Del Moral Hernandez

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




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

Prof. Emilio Del Moral Hernandez


Três arquiteturas neurais importantes

(abordadas em pósgrad – PSI 5886)



1) MLP
- Multi Layer
Perceptron



2) Memória
Associativa
de Hopfield



3) Mapas Auto-
Organizáveis
de Kohonen




Outras funções de transferência não linear

<p>Hard Limiter (limite rápido)</p> <p>$s < 0, y = -1$ $s > 0, y = 1$</p>	<p>Ramping Function (função de rampa)</p> <p>$s < 0, y = 0$ $0 \leq s \leq 1, y = s$ $s > 1, y = 1$</p>
<p>Sigmoide Function (função sigmóide)</p> <p>$y = 1/(1 + e^{-s})$</p>	<p>Sigmoide Function (função sigmóide)</p> <p>$x > 0, y = 1 - 1/(1 + s)$ $x < 0, y = -1 + 1/(1 - s)$</p>

- Com escalamento do argumento, pode-se abarcar os universos digital e analógico / linear e não linear simultaneamente

Foco deste Curso: 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

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

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

A captura de ecrã mostra o site "Multiple Back-Propagation" no navegador. O cabeçalho do site inclui o nome "Multiple Back-Propagation" e um menu de navegação com links para "About", "Screenshots", "Download", "Tutorial", "Datasets", "FAQ", "News", "Bugs", "Request a feature", "Papers" e "Develop/Contact". Abaixo do menu, há uma seção intitulada "TUTORIAL" com uma lista de 12 itens:

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


À direita da lista, há uma imagem de uma interface gráfica de software que mostra um diagrama de uma rede neural e painéis de configuração.

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

Prof. Emilio Del Moral Hernandez

Exemplo de tela do ambiente MBP definindo uma Rede Neural

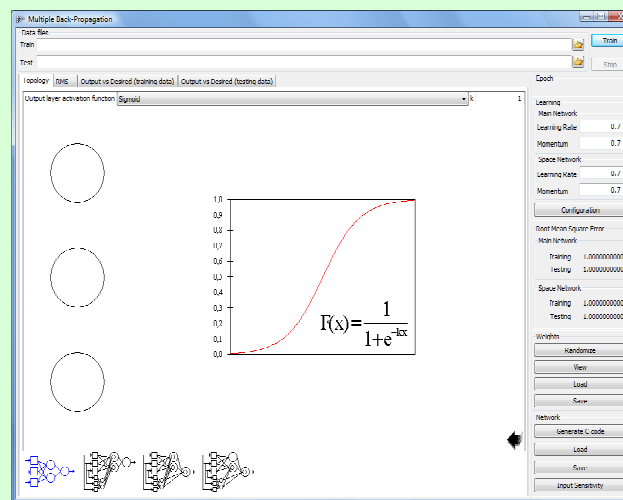
29



Prof. Emilio Del Moral Hernandez

Algumas Telas do MBP Mudando a função do nó neural

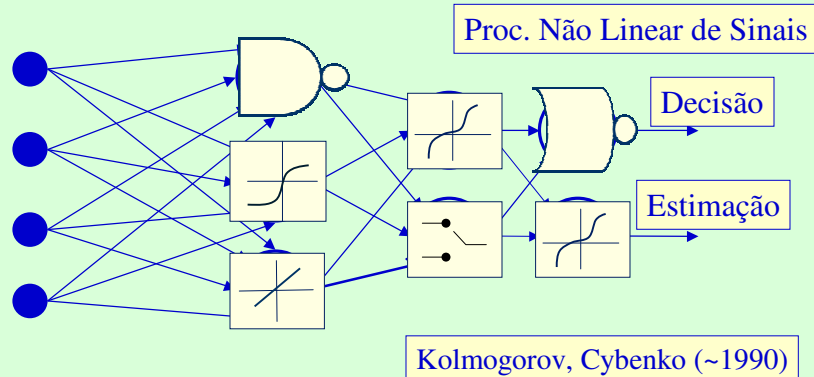
30



Prof. Emilio Del Moral Hernandez

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

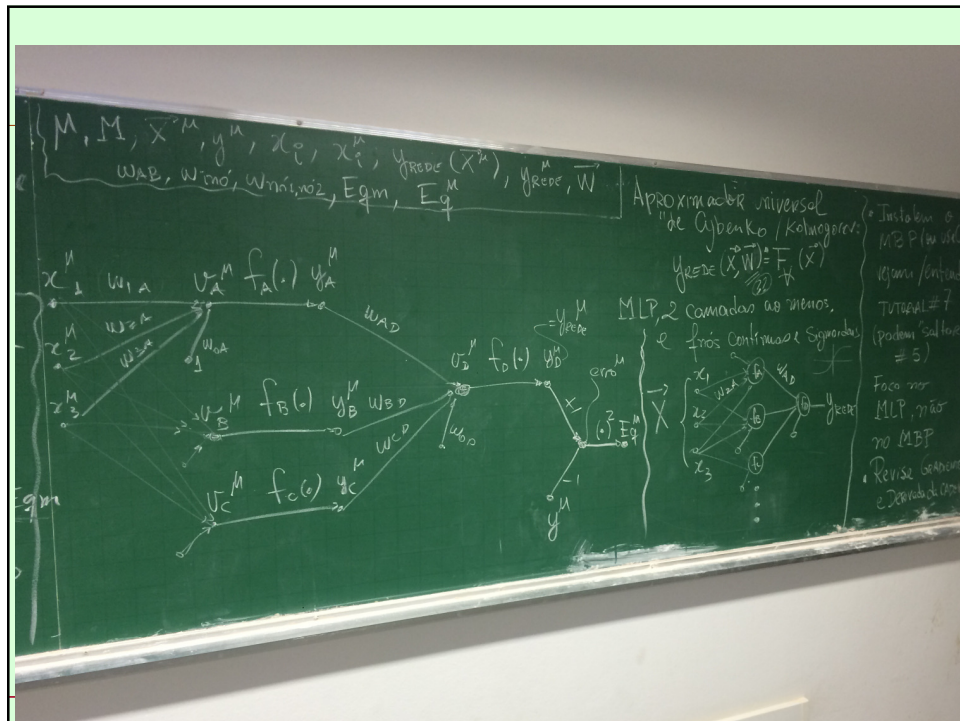
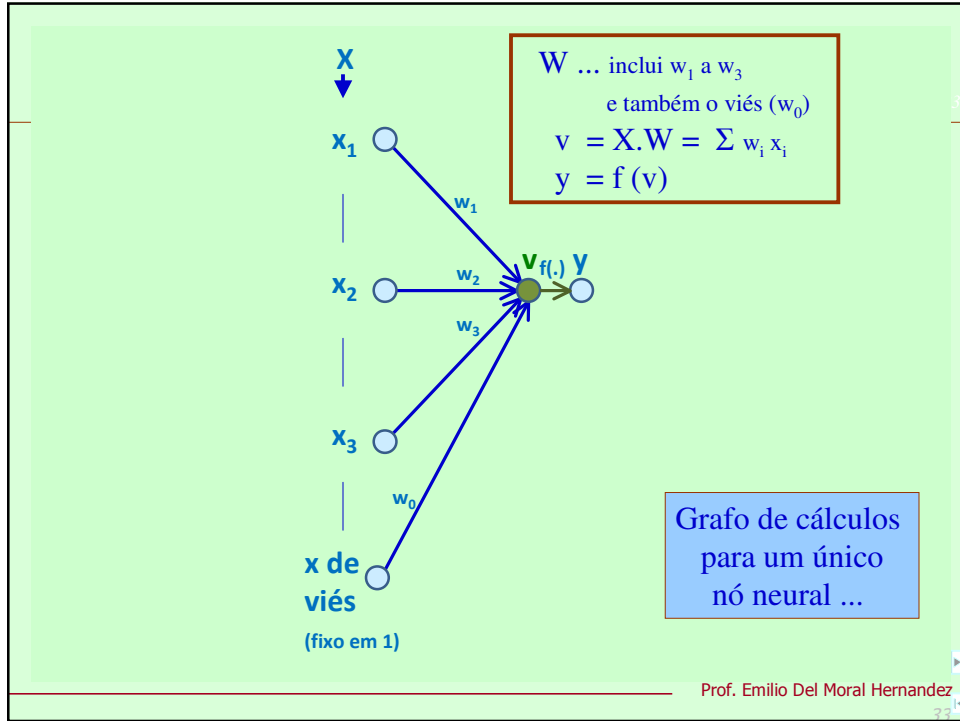



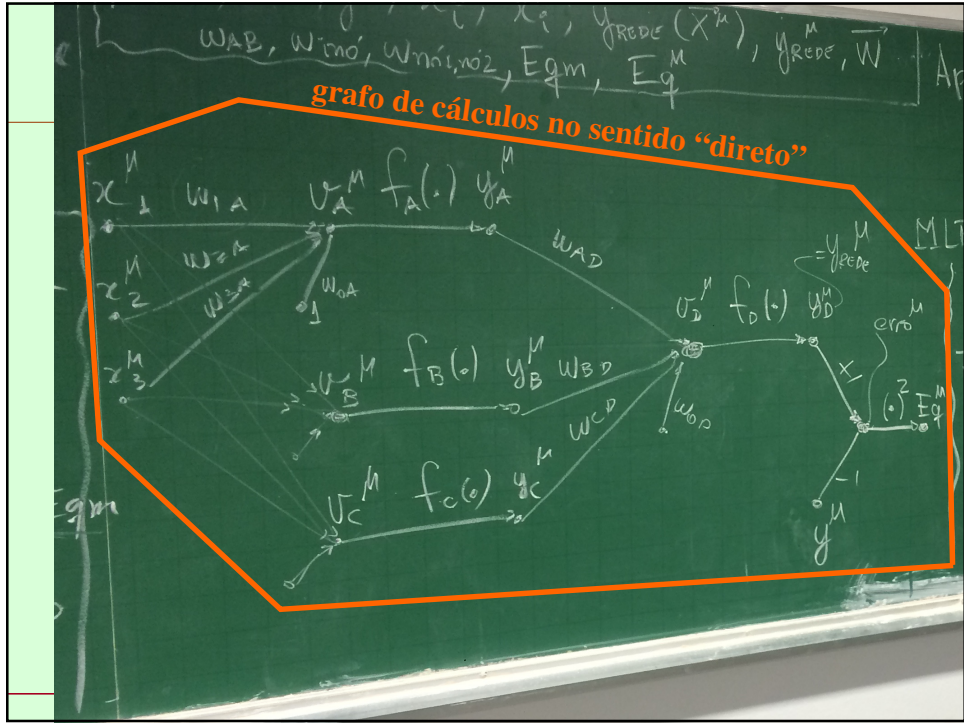
Prof. Emilio Del Moral Hernandez

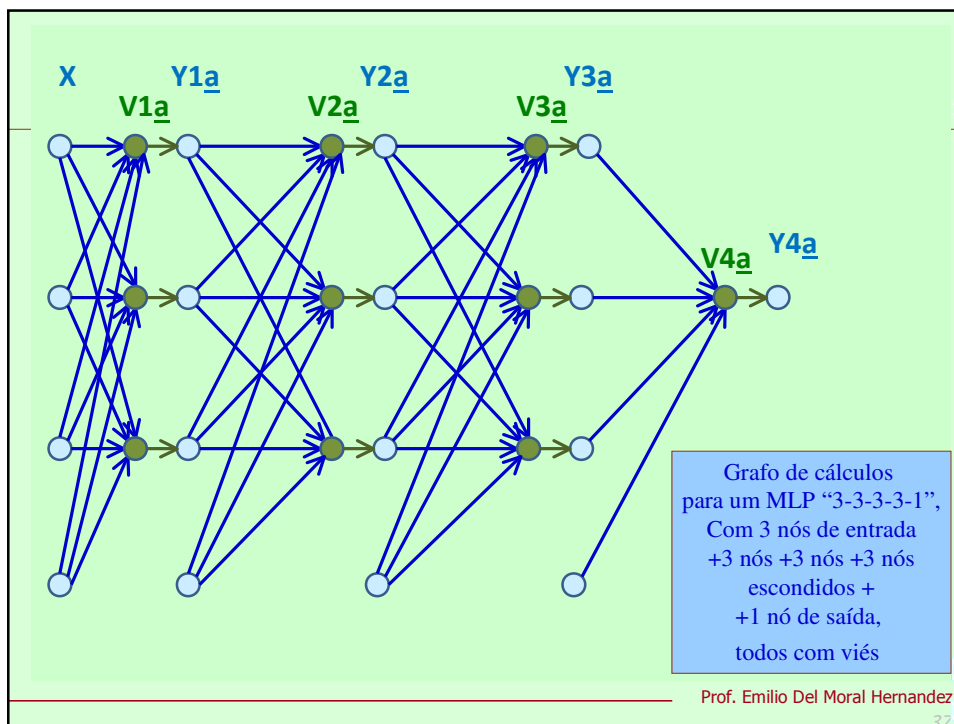
Resumindo os aspectos conceituais principais

- 1) Não linearidade com a função neural sigmoidal
 - 2) Possibilidade de conjugar na mesma estrutura ...
 - Cálculos digitais
 - Cálculos lineares multivariáveis
 - Funções genéricas não lineares multivariáveis
 - 3) Comportamento adaptativo com aprendizado através de exemplos
-
- Problemas complexos, multidimensionais, não lineares e mesmo aqueles sem teoria conhecida
 - Decisão automática, estimação, reconhecimento de padrões, classificação, processamento não linear de sinais, *clustering* multidimensional ...

Prof. Emilio Del Moral Hernandez







... erro da rede com relação ao conjunto de treinamento como um todo; simbologia (\bar{X}^μ ; y^μ); Erro quadrático de exemplar (Eq^μ); Erro quadrático médio (Eqm)

Resumo de principais resultados em lousa ...


μ identifica um de M exemplos de treinamento

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


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

Prof. Emilio Del Moral Hernandez

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



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




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

$$\Delta \vec{W} = -\eta \cdot \vec{\nabla} Eqm \quad \dots \text{em loop} \dots$$

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

Prof. Emilio Del Moral Hernandez

Algumas Telas do MBP: acompanhando a queda do erro (RMS) da rede neural enquanto está aprendendo / adaptando seus pesos



Prof. Emilio Del Moral Hernandez

Obs: Aplicação do Eqm(W) com o método do ∇^2

Otimização dos w 's (\vec{W}), para que a RNA (\vec{W}) aproxime com qualidade os seus dados empíricos.

M casos (\vec{x}^m, y^m)

M		x_1	x_2	x_3	x_4	x_5	y
1	Caso #1	32	15	73	.	.	0.85
2	Caso #2	42	63	.	.	.	0.7
3	#3	-0.5
.

Em Loop:

$$\vec{W}_{REFINADO} = \vec{W}_{ANTERIOR} + \Delta \vec{W}$$

$\frac{\partial Eqm}{\partial W} = ?$

$-\eta \nabla Eqm$

Ex.1 do prof Emilio (completo: STOA) ...
 Treino no MBP +
 Dedução de fórmulas de Del y_{rede} / Del w
 ... ou de fórmulas de Del Eq / Del w