

INTELIGÊNCIA COMPUTACIONAL E REDES NEURAIS EM ENGENHARIA ELÉTRICA

Prof. Emílio Del Moral Hernandez

Dep. de Eng. de Sistemas Eletrônicos

PSI-EPUSP

emilio_del_moral@ieee.org

www.lsi.usp/~emilio

PSI-2222 Práticas de Eletricidade e Eletrônica II
Seminário #2, ministrado em agosto de 2005

(© - Copyright) ¹

1. INTRODUÇÃO: A NATUREZA DA INTELIGÊNCIA COMPUTACIONAL

Este seminário aborda o campo interdisciplinar chamado inteligência computacional, que engloba como uma das ferramentas significativas as redes neurais, ou mais precisamente, as redes de neurônios artificiais. Nesta expressão, a palavra *artificiais* é usada para evidenciar a distinção com as redes neurais biológicas. A ênfase do seminário será em redes neurais artificiais, mas serão abordadas de forma breve algumas outras ferramentas que também se enquadram no âmbito geral de “inteligência computacional”, a saber: inteligência artificial simbólica, lógica difusa, e apoio à decisão com ferramentas estatísticas.

Falando de uma forma bastante abrangente, o objetivo do campo “inteligência computacional” é o desenvolvimento de técnicas que permitam incorporar no ambiente computacional, mesmo que de forma limitada, algumas das funcionalidades dos sistemas biológicos (humanos ou não) no que se refere a seus aspectos de inteligência. (tipicamente, a referência é a inteligência humana, mas de uma forma geral podemos considerar a inteligência biológica em suas diversas formas e níveis) É importante notar que quando se fala em inteligência computacional como imitação ou incorporação no

¹ *Este material, deve sempre ser citado quando usado em preparação de trabalhos ou artigos de sua autoria. O mesmo procedimento se aplica a qualquer outro material que não seja de sua autoria, inclusive às apostilas da EPUSP. Adicionalmente, reproduções sem modificação de partes de textos que não sejam originalmente seus, devem vir entre aspas. Tal respeito à autoria de trabalho intelectual deve ocorrer igualmente com textos disponíveis através da Internet.*

computador de aspectos da inteligência humana, estamos falando de formas limitadas e bastante específicas de tal faculdade, de maneira que, na realidade, o resultado de tal imitação está longe de corresponder a um substituto completo da inteligência humana, ou do sistema nervoso inspirador tomado da biologia. Em particular, no estado atual de pesquisa em que se encontra este campo, essa imitação das habilidades humanas se revela bastante limitada no que se refere a aspectos de flexibilidade, de capacidade de adaptação e de sensibilidade a contextos, habilidades que o ser humano possui em graus extraordinários. Em geral, as soluções de problemas em inteligência computacional funcionam com considerável sucesso, desde que o ambiente e as condições de contorno do problema a resolver sejam limitados a sub universos da realidade total e complexa com a qual o ser humano interage.

2. FERRAMENTAS USADAS EM INTELIGÊNCIA COMPUTACIONAL

Usa-se com frequência a expressão *ferramentas de inteligência computacional*; A razão para tal expressão e em particular para o emprego do termo *ferramentas*, é que tipicamente a imitação em computador de diferentes aspectos da inteligência humana é obtida por intermédio de diferentes estratégias e metodologias. Além disso, é também frequente que para uma dada aplicação em que se deseja tal imitação, mais de uma estratégia ou ferramenta tenha que ser utilizada. O uso de uma única classe de ferramenta ou metodologia específica não permite responder a todos os estilos e classes de problemas que surgem na imitação da inteligência biológica. Assim, tipicamente usamos diferentes ferramentas para obter diferentes funcionalidades; ademais, muito frequentemente também lançamos mão da conjugação de mais de uma ferramenta na implementação de uma função complexa por isso resultar em melhores resultados do que a aplicação de cada uma das ferramentas individualmente. Quando este é o caso, dizemos que estamos aplicando uma solução híbrida, que pode, por exemplo, empregar conjuntamente redes neurais e lógica fuzzy na solução de um mesmo problema.

Tendo em mente esta necessidade de empregar uma diversidade de estratégias de ataques, vamos elencar a seguir algumas das ferramentas de inteligência computacional que têm sido empregadas com sucesso:

- Redes de Neurônios Artificiais (ou simplesmente Redes Neurais)
- Técnicas de Inteligência Artificial Simbólica (IA)
- Linguagens declarativas para IA
- Lógica Difusa (Fuzzy Logic)
- Algoritmos Genéticos
- Técnicas de Filtragem Adaptativa
- Decisão com base em Métodos Estatísticos
- Classificação e Reconhecimento de Padrões com métodos diversos, inclusive métodos estatísticos
- Técnicas de Visão Computacional e Reconhecimento de Padrões Visuais

- Técnicas de Reconhecimento e Síntese de Voz
- Ferramentas de Otimização
- Ferramentas Estatísticas em geral
- Técnicas de Aprendizado de Máquina

3. OS PRINCÍPIOS BÁSICOS EM REDES NEURAIS

Vamos discutir agora com algum detalhe uma das ferramentas de inteligência computacional específica, as redes neurais, cuja estratégia na emulação de aspectos da inteligência humana se baseia no entendimento das estruturas de armazenamento e de processamento de informação realizados pelo sistema nervoso, nisto incluindo o cérebro e as demais partes do sistema nervoso central bem como os diversos sistemas sensoriais (audição, visão, tato, olfato e paladar).

As redes de neurônios artificiais são sistemas de computação adaptativos inspirados nas características de processamento de informação encontradas nos neurônios reais (biológicos) e nas características de suas interconexões. São sistemas de computação massivamente paralelos que podem ser implementados tanto em hardware quanto em software, sendo que os elementos de processamento individualmente têm capacidades relativamente limitadas. Tais elementos de processamento básicos são os chamados neurônios artificiais, imitam de alguma forma o processamento de informação realizado por um neurônio biológico, e quando utilizados em conjunto e interagindo uns com os outros, compõem o que se denomina uma rede neural. Outra denominação típica para os elementos de processamento das redes neurais é a expressão *nós de processamento*, ou nós da rede neural.

Vale a pena destacar, na forma de breve cronologia, alguns fatos importantes no desenvolvimento do campo de redes neurais e no surgimento dos seus elementos conceituais principais:

Década de 40: o neurônio de McCulloch e Pitts, uma proposta para a descrição matemática de cálculos lógicos com base nas estruturas neurais biológicas.

Década de 50: Em 1956 na 1ª Conferência Internacional de Inteligência Artificial, foi apresentado um modelo de rede neural artificial pelo pesquisador Nathaniel Rochester, da IBM.

Em 1959, foi demonstrada a rede adaptativa Adaline, que pode ser vista como um modelo linear dos principais mecanismos de processamento de informação e adaptação presentes no neurônio biológico.

Década de 1960: O Perceptron de Rosenblatt, em que um modelo neural não linear e adaptativo permite expressar os processamentos representados no modelo de

McCulloch e Pitts e incorporar um algoritmo de aprendizado supervisionado bastante eficaz.

Em 1969, Marvin Minsky e Seymour Papert publicaram um livro chamado “Perceptrons”, em que vários aspectos teóricos e limitações do Perceptron de Rosenblatt são formalizados e estudados.

Em 1982, John Hopfield apresentou um sistema neural artificial capaz de armazenar nas interconexões entre os neurônios informações complexas, como imagens por exemplo. Esta proposta teve um impacto importante no ressurgimento e crescimento nas décadas seguintes do interesse em redes neurais artificiais para a modelagem e emulação de aspectos da inteligência e percepção humanas. Ainda em 1982 a primeira conferência Estados Unidos-Japão sobre redes neurais realizou-se na cidade de Kioto.

Em 1994, ocorreu o primeiro congresso de Redes Neurais no Brasil. Atualmente, pelo menos dois congressos brasileiros específicos em redes neurais regularmente (Congresso Brasileiro de Redes Neurais e Simpósio Brasileiro de Redes Neurais), além de inúmeros eventos internacionais (entre eles o International Joint Conference on Neural Networks e o International Conference on Artificial Neural Networks), bem como eventos nacionais de abrangência mais geral que contam com seções específicas em redes neurais. Além disso, uma gama ampla de periódicos científicos trazem os principais avanços da área, como o IEEE Transactions on Neural Networks, publicado pelo Institute of Electrical and Electronics Engineers – IEEE, e o periódico Neural Networks, publicado pela editora Elsevier.

Após este pequeno parêntese histórico, vamos agora retomar o detalhamento e entendimento dos neurônios artificiais e das redes de neurônios. A “imitação da biologia e do sistema nervoso” citada no início deste tópico é feita pelas redes neurais artificiais tanto no nível do processamento microscópico realizado por uma célula do sistema nervoso individualmente, quanto no nível macroscópico, seja em termos de padrões de interconexão entre elementos de processamento, seja em termos dos comportamentos coletivos que emergem em uma rede biológica com vários neurônios.

Segundo o paradigma vigente em neurofisiologia, a informação é representada no sistema nervoso através de pulsos elétricos gerados pelos neurônios, denominados **potenciais de ação**. No que se refere ao campo de redes de neurônios artificiais, a forma específica na qual a atividade neural é representada no modelo matemático pode assumir diversas simplificações. Isso depende do grau de refinamento na representação de fenômenos biológicos que se tem em mente, o que por sua vez varia grandemente de grupo de pesquisa a grupo de pesquisa, de acordo com a orientação e a ênfase dos seus trabalhos. Nos modelos pulsados por exemplo (spiking neurons), assume-se que a forma dos potenciais de ação é irrelevante para a representação de informação e para a computação neural, não precisando-se portanto preservá-la na modelagem computacional. No entanto, em tais modelos se conserva integralmente a informação temporal referente aos instantes

de suas ocorrências, ou seja, o modelo representa o instante de ocorrência de cada potencial de ação, individualmente. Uma outra classe de modelos utiliza a representação da atividade neural unicamente através da frequência média dos potenciais de ação. Tal simplificação se baseia em resultados de experimentos demonstrando a não repetibilidade dos padrões temporais dos potenciais de ação que são gerados em resposta a estímulos idênticos, realizados de forma repetida em experimentos semelhantes sequenciados; observa-se no entanto a repetibilidade na frequência de tais pulsos ao longo dos experimentos sequenciados, o que justificaria considerar um mapeamento funcional entre entrada e saída baseado apenas em grandezas do tipo frequência de pulsos, não nos pulsos isoladamente. Tais modelos são conhecidos como modelos sigmoidais, ou de codificação for frequência de potenciais de ação. Uma terceira classe assume que modelos neurais com saída binária são suficientemente poderosos para representar uma classe bastante ampla de problemas computacionais. Em realidade, grande parte da pesquisa em redes neurais assume este tipo de modelo (binário), que tem a particular vantagem de, por sua simplicidade estrutural, permitir a formalização matemática em um grau não possível para os modelos mais complexos. Nos parágrafos que seguem, são apresentadas algumas das características de dois dos modelos neurais importantes citados aqui: o sigmoidal e o binário.

Basicamente, todos os tipos de redes neurais apresentam a mesma unidade de processamento: um neurônio artificial, que simula o comportamento do neurônio biológico. Esse neurônio artificial possui várias entradas, que correspondem às conexões sinápticas com outras unidades similares a ele, e uma saída, cujo valor depende diretamente da somatória ponderada de todas as saídas dos outros neurônios a esse conectado. Neste cálculo de integração dos estímulos das várias entradas, a ponderação é dada pelos pesos que cada conexão possui (fig. 1).

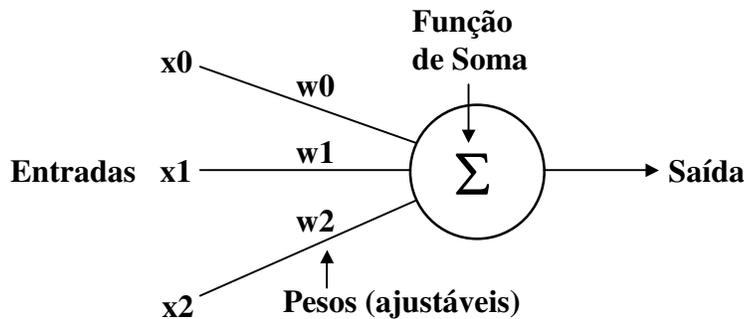


Figura 1 – Unidade processadora (neurônio artificial) do tipo linear (Adaline).

Assim, a somatória, que na figura (1) corresponde à saída do modelo neural, é dada por:

$$Soma = \sum_{i=1}^n x_i w_i \quad (1)$$

As constantes de ponderação w_i representam as conexões sinápticas biológicas que intermediam a interação entre neurônios vizinhos, x_i é o estímulo proveniente do neurônio vizinho i , e o resultado **Soma** representa o estímulo global (com as devidas ponderações relativas) recebido pelo neurônio de todos os seus vizinhos. O neurônio artificial acima representado corresponde ao modelo matemático conhecido como Adaline (Adaptive Linear Element). É importante notar que esse modelo somente incorpora transformações lineares; como consequência, temos que além de o modelo não permitir a implementação de computações complexas (há pois limitação do poder matemático), impede a representação de relações estímulo / resposta não lineares que de fato são observadas com frequência no neurônio biológico (há pois limitação do poder de modelagem de sistemas biológicos). Uma pequena alteração no modelo neural é necessária para a viabilizar as funcionalidades não lineares, através da introdução de uma função de transferência como representado na figure 2 a seguir.

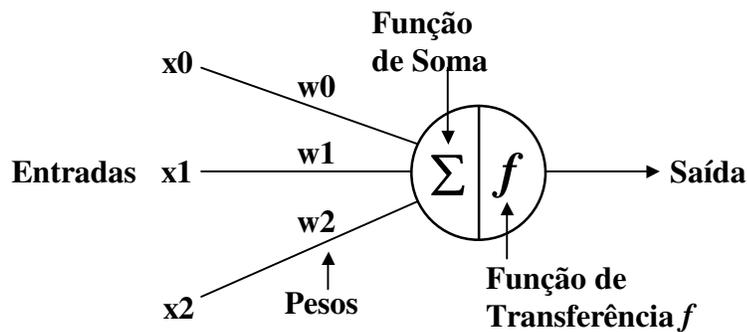


Figura 2 – Neurônio artificial com função de transferência não linear.

De acordo com o valor da variável Soma, e de acordo com a função de transferência à qual essa variável Soma é aplicada (ou também conhecida como função de ativação), o novo modelo de neurônio, não linear, fornecerá uma saída em resposta aos estímulos x_i , conforme representado na seguinte equação:

$$Saída = f(Soma) \quad (2)$$

Na sua forma mais simples, a função de transferência não linear f pode ser binária (discreta), como no caso do modelo conhecido como Perceptron de Rosenblatt. Neste caso, o modelo tendo uma saída binária permite representar funcionalidades de natureza lógica realizadas pelos neurônios biológicos. É o caso da tomada de decisões (uma funcionalidade digital por natureza). Por outro lado, para o caso de modelagem de funcionalidades do sistema nervoso em que não apenas grandezas digitais estão em jogo, mas uma gama de valores analógicos são necessários para a representação da atividade neural, devemos empregar uma função de transferência f com saída contínua, como por exemplo a função tangente hiperbólica (neste caso o modelo pode ser chamado de

sigmoidal). Em ambos os casos, a idéia é que essa função de transferência possa imitar, em algum grau, a relação entrada / saída observada nos neurônios biológicos.

4. ALGUMAS ARQUITETURAS TÍPICAS EM REDES NEURAIS

Chegamos agora ao momento de passarmos de modelos de neurônios isolados para as redes neurais propriamente ditas, em que vários “neurônios artificiais” são interconectados, interagindo uns com os outros. Conjuntos de neurônios artificiais como os discutidos acima, organizados e conectados de várias formas, podem resultar em diferentes arquiteturas neurais, com características e aplicações bastante distintas, algumas das quais serão discutidas aqui. No entanto, todas essas arquiteturas com diferenças bastante grandes entre si são chamadas indistintamente de *redes neurais*, pelo simples fato de que o bloco microscópico usado na construção de cada uma dessas arquitetura é o neurônio artificial representado na figura 2. Em outro contexto, tal denominação genérica é o que também se observa na expressão *circuitos digitais*: embora a memória do seu computador pessoal, o processador central do mesmo, e o seu relógio de pulso digital tenham funções muito distintas entre si e metodologias de projeto e princípios de funcionamento muito diferentes, todos eles podem ser chamados indiscriminadamente de circuitos digitais, por empregarem portas lógicas como o elemento mais microscópico de construção do sistema completo. Da mesma forma, o termo *redes neurais* é empregado para designar um grande leque de arquiteturas, com aplicações muitas vezes disjuntas, princípios de funcionamento e técnicas de projeto totalmente diversas, mantendo entre si em comum apenas o bloco básico (neurônio artificial) e alguns princípios gerais tais como o paralelismo de processamento e a adaptabilidade a mais de uma função alvo dentro de uma aplicação. Outra característica importante nas redes neurais é a programabilidade da função específica desejada através de conjuntos de exemplos (conjunto de treinamento). Isto contrasta com a estratégia mais tradicional de se ter a programação de funcionalidade de um sistema de computação definida através de uma prescrição explícita, na forma de um algoritmo, de uma equação ou sistema de equações modelando o problema alvo, ou através da definição precisa e formal de regras de causa e efeito entre as variáveis envolvidas na aplicação. Em lugar de tal especificação formal do sistema computacional, temos apenas a apresentação de “exemplos de treinamento” à rede neural. Este aspecto é retomado mais a frente, no tópico 5 (Aprendizado e adaptabilidade em inteligência computacional – os algoritmos de treinamento / aprendizado).

A natureza da função de transferência não linear f , o número de nós de processamento empregados na rede e a topologia de interconexão entre eles, têm todos impacto importante no tipo de computações que podem ser realizadas pelas redes compostas por vários nós como os descritos na figura 2. Em primeiro lugar, é importante reafirmar que a não linearidade em f viabiliza a implementação de mapeamentos complexos entre as variáveis de entrada da rede e as variáveis de saída. Entre outras coisas, isto permite que se abarquem os universos de aplicação com saídas digitais para a rede neural, mediante escolha adequada da função f . O Perceptron simples corresponde à forma mais básica de

modelo neural, para a qual a função de transferência se reduz a uma função com apenas dois valores em seu repertório de saídas, seja do tipo degrau ou do tipo sinal.

Tradicionalmente o perceptron simples é definido em forma bipolar (saída +1 ou -1), através da função sinal:

$$\text{Saída} = \text{sinal}(\sum w_i x_i - \theta) \quad (3)$$

Pela natureza de elemento de decisão da função f e pela operação de combinação linear das entradas, que corresponde a um produto escalar entre o vetor de pesos w_i e o vetor de entradas x_i , o Perceptron simples viabiliza a separação / classificação de padrões de entrada através de um hiperplano definido pelos pesos w_i (para entender isto, basta recordar os fundamentos que você aprendeu em algebra linear e geometria analítica). Um algoritmo de aprendizado adequado adapta os w_i de forma a encontrar o hiperplano de separação adequado a um certo repertório de exemplos que se deseja separar em duas classes. É o clássico algoritmo de aprendizado do Perceptron.

Naturalmente, uma estrutura de cálculo tão simples como a do Perceptron, expressa na Equação (3), não atende a todas as necessidades de classificação de padrões no caso geral. À medida que cálculos mais complexos que a classificação com separabilidade linear é necessária, empregamos uma estrutura com diversos neurônios encadeados. Com isso, temos o conceito do Multi Layer Perceptron (MLP), cujas características principais são as seguintes:

- 1) possui múltiplas entradas / múltiplas saídas / múltiplas camadas;
- 2) entradas e saídas podem ser tanto analógicas quanto digitais;
- 3) não há mais a restrição de separabilidade linear entre classes.

A figura 3 representa uma arquitetura do tipo MLP com 20 neurônios organizados em 5 camadas. Cada nó (círculo) representa um neurônio e cada linha uma conexão entre saída de um neurônio e uma entrada de neurônio da camada seguinte.

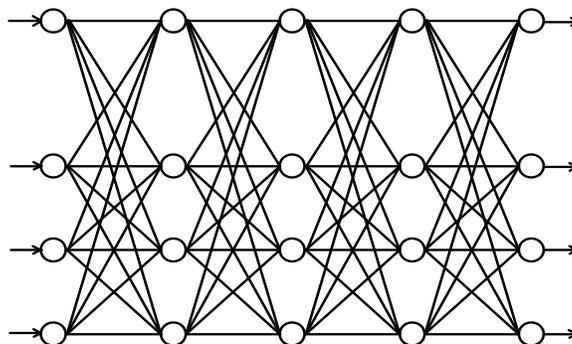


Figura 3 – Rede do tipo MLP (Multi Layer Perceptron) de 5 camadas. Cada um dos 20 círculos representa um neurônio artificial, e cada linha representa uma conexão sináptica, com seu peso programável.

Como pode ser verificado, o fluxo de informação ocorre em camadas de neurônios, sem que haja realimentação (retorno da informação da saída para a entrada de algum dos neurônios da rede). Esta organização em camadas e a ausência de realimentação é própria da arquitetura MLP, não se observando tais características no entanto em muitas outras arquiteturas neurais importantes, não abordadas aqui por limitação de tempo. Apenas a título de comentário, a arquitetura de Hopfield por exemplo, é densa em realimentações e não possui qualquer organização em camadas.

Note que no caso do MLP, a função de transferência adotada tipicamente é do tipo sigmoideal (tangente hiperbólica por exemplo), de forma que com escalamentos adequados do argumento da função de transferência (ou dos pesos que indiretamente escalam as entradas) é possível passar de mapeamentos entrada-saída aproximadamente lineares a mapeamentos de natureza essencialmente digital, sem mudar a função f propriamente dita, mas apenas com o recurso de escalamento do argumento. Esta transição entre comportamento analógico e digital é possível porque a função $\text{tanh}(x)$ pode ser vista como o caso limite da função tangente hiperbólica com constante escalamento tendendo a infinito.

Entre as aplicações do MLP, podemos citar a classificação de padrões sem separabilidade linear já mencionada, a aproximação de funções genéricas (inclusive analógicas) e a fusão não linear de grandezas analógicas multidimensionais, além da previsão de séries temporais não lineares. Note que o aprendizado através de exemplos do MLP (discutido em mais detalhes no próximo tópico) permite que ele realize as funções acima sem a necessidade de um modelo matemático conhecido / confiável

Aqui tivemos a oportunidade de abordar apenas duas arquiteturas neurais clássicas, o Perceptron e o MLP, mas vale a pena mencionar o que já ressaltamos no início: existe um leque muito grande de arquiteturas e aplicações correspondentes. Entre elas, podemos citar as arquiteturas de Hopfield, as arquiteturas com modelos pulsados, as arquiteturas com funções de base radial (radial basis functions – RBFs), as arquiteturas do tipo ART (Adaptive Resonance Theory), e os mapas auto organizáveis de Kohonen, entre outras. Algumas dessas arquiteturas não discutidas neste texto serão abordadas muito brevemente no seminário de PSI 2222. De qualquer forma, maiores detalhes destas e de outras arquiteturas não citadas aqui podem ser obtidos nas diversas referências comentadas no tópico 7 à frente, denominado “Onde Conseguir mais Informação sobre Redes Neurais e suas Aplicações”.

5. APRENDIZADO E ADAPTABILIDADE EM INTELIGÊNCIA COMPUTACIONAL – OS ALGORITMOS DE TREINAMENTO / APRENDIZADO

Um aspecto importante em redes neurais é a definição das conexões entre os elementos de processamento e a definição dos pesos associados a essas conexões. Pode-se dizer que a informação armazenada e a computação realizada por uma determinada rede neural são definidas mais pela topologia de conexões entre elementos e pelos pesos atribuídos a essas conexões que propriamente pelos elementos de processamento individualmente. Em função disso, essas conexões entre os neurônios artificiais de uma rede são normalmente programáveis, e muitas vezes existe algum mecanismo do tipo "aprendizado", através do qual a rede "incorpora experiência a partir de exemplos que lhe são apresentados". Isto é particularmente interessante para a solução de problemas cuja especificação não é suficientemente estruturada, o que dificulta a sua representação em uma forma algorítmica (própria aos ambientes computacionais baseados em linguagens procedurais) ou mesmo na forma de uma lista de regras (própria às linguagens declarativas). Tal situação ocorre por exemplo nas tarefas de reconhecimento de padrões visuais, de reconhecimento de padrões de voz, e em leitura automática de textos manuscritos, e este é um dos motivos pelos quais as redes neurais são usadas nessas áreas.

Este conceito de adaptação da rede face a uma descrição do problema que se pretende resolver através de exemplos dá origem a uma expressão que aparece com frequência no contexto de redes neurais: *“redes neurais possuem a capacidade de aprender por exemplos”*. Outra expressão comum que descreve essa característica é a que segue: *“as informações são apresentadas à rede, que extrai informações a partir dos padrões apresentados”*. Embora estas frases pareçam dar às redes neurais o poder especial e quase mágico de “entender” o problema a ser incorporado por elas, o que ocorre concretamente é algo bem simples de entender do ponto de vista matemático: os graus de liberdade das redes neurais (os pesos w) são adaptados de forma a que uma dada mapeamento entrada / saída desejado (e descrito por um repertório de pares entrada / saída chamados de exemplo de treinamento) seja obtido. Isto é realizado através de algum algoritmo de adaptação ou aprendizado, que tenha “características boas” em termos de viabilizar o aprendizado de um leque amplo de diferentes mapeamentos entrada / saída. Em resumo, a expressão “aprendizado da rede neural”, embora normalmente traga um toque de charme às redes neurais, nada mais significa do que o processo de adaptação educada dos pesos w_i da rede, de forma a viabilizar o mapeamento entre entradas e saídas descritos por uma lista de exemplos representativos de uma dada aplicação.

Diversos métodos de aprendizado / treinamento foram desenvolvidos, sendo que os denominados algoritmos de Aprendizado Supervisionado são os de mais fácil entendimento face às discussões que fizemos até o momento. Neste tipo de aprendizado, as informações são apresentadas à rede sob a forma de padrões de entrada e dos resultados correspondentes desejados, conhecidos previamente. O algoritmo “supervisor” verifica as saídas geradas pela rede, para os padrões de entrada dos exemplos de treinamento, e as compara com as saídas desejadas, guiando assim o ajuste nas conexões sinápticas de forma a minimizar a diferença entre saída desejada e saída oferecida pela

rede. Os algoritmos de aprendizado supervisionado mais conhecidos são o “Regra Delta”, para o Perceptron simples, e o “Error Backpropagation”, para o MLP. Em ambos os casos, sempre que ocorre erro no reconhecimento de uma entrada, um ajuste sináptico é conduzido. O ajuste sináptico procura portanto corrigir os pesos de modo que se produza a saída desejada diante da respectiva entrada, representando assim o aprendizado, em cada neurônio, do fato apresentado. Dessa forma, pode-se dizer que ao final do processo de aprendizado, o conhecimento dos neurônios / da rede neural reside nos pesos sinápticos.

6. ÁREAS DE APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS EM ENGENHARIA ELÉTRICA

Entre as áreas de aplicação de redes neurais podemos destacar a implementação de classificadores e reconhecedores de padrões, de sistemas de armazenamento e recuperação de informações do tipo memória associativa e sistemas de hetero-associação (extensão do conceito de memórias endereçadas por conteúdo), a implementação de sistemas de controle adaptativo e a solução de problemas de otimização. Ainda como área de aplicação, mais ligada á biologia, podemos citar o uso de tais redes para a modelagem de percepção e de cognição. A seguir temos uma lista de aplicações típicas em forma telegráfica:

- Reconhecimento de padrões
- Reconhecimento de caracteres
- Reconhecimento e síntese de voz
- Conversão de texto para voz
- Visão artificial e visão robótica
- Avaliação de riscos de inadimplência / detecção de padrões de risco
- Previsão de vendas / previsão de séries temporais
- Modelagem e identificação de sistemas não lineares multivariáveis
- Sistemas para o apoio à decisão
- Processamento de informações não estruturadas
- Processamento / reconhecimento / classificação de sinais e imagens
- Interfaces homem-máquina naturais
- Mineração de dados (datamining)
- Problemas de otimização
- Modelagem cognitiva

Como uma forma prática de dar uma idéia de como as redes neurais e a inteligência computacional têm se relacionado com as atividades de pesquisa e desenvolvimento nos departamentos de engenharia elétrica da EPUSP, listo a seguir alguns dos trabalhos em curso, e em seguida alguns dos docentes envolvidos em temas de redes neurais além de mim. Certamente a lista não é completa, mas permite ter uma idéia bastante boa das áreas

de utilização de redes neurais dentro das várias áreas em que os nossos quatro departamentos atuam:

- Emprego de redes neurais em reconhecimento e classificação de padrões e em fusão de informações em sistemas multissensores
- Aproximação de funções e modelagem de histerese
- Aplicação das redes neurais artificiais na confiabilidade metrológica
- Estudo de novos modelos de computação neural envolvendo fenômenos de bifurcação e dinâmica caótica, bem como sua implementação eletrônica
- Desenvolvimento de novas arquiteturas neurais a partir da fusão de mais de uma arquitetura clássica
- Clustering de dados multidimensionais em diversas áreas
- Neurocomputação e técnicas de fusão de dados aplicadas no reconhecimento e caracterização de objetos em imagens médicas
- Arquiteturas neurais de Kohonen para o Data Mining em aplicações de comércio eletrônico
- Modelagem e simulação de estágios iniciais do sistema visual com aplicação de redes neurais
- Arquiteturas neurais híbridas para o reconhecimento de padrões
- Sistemas de neurocomputação para análise de sistemas multissensores para aplicações ambientais e biomédicas
- Reconhedores de voz via redes neurais
- Eletrônica não linear e dinâmica caótica: desenvolvimento de modelos eletrônicos de neurônios pulsados
- Mapas auto organizáveis (redes neurais de Kohonen) como ferramenta para o clustering de empresas no setor elétrico brasileiro
- Aplicação de redes neurais em detecção de padrões em séries temporais do mercado financeiro e em previsão de carga em sistemas de distribuição de energia elétrica
- Sistema neurofuzzy para controle de semáforos inteligentes
- Sistemas de controle adaptativos
- Sensores neuromórficos: línguas eletrônicas / retinas eletrônicas / narizes eletrônicos / ouvidos eletrônicos
- Neurônios de bifurcação e aplicações em otimização e em memórias associativas

A lista acima foi preparada com base em trabalhos que eu e diversos outros docentes dos quatro departamentos da elétrica da EPUSP temos realizado, em conjunto com nossos orientados e colaboradores, nas áreas de redes neurais e inteligência computacional. Gostaria de mencionar aqui alguns desses demais docentes trabalhando com redes neurais, de citar brevemente alguns de seus interesses, e de agradecer-lhes por terem facilitado

materiais e informações que de alguma forma ajudaram na preparação deste texto ou na preparação do seminário de PSI 2222:

- Prof. Ademar Ferreira (PTC), que tem atuado na aplicação de sistemas neurais e sistemas fuzzy em problemas de controle.
- Prof. Aquiles Grimoni (PEA), atuando em aplicação de redes neurais a problemas em energia elétrica.
- Prof. Javier Ramirez (PSI), que tem atuado em sistemas sensores com processamento neural e em particular com narizes eletrônicos
- Prof. Marco Túlio de Andrade (PCS), atuando em sistemas fuzzy e neurofuzzy

7. ONDE CONSEGUIR MAIS INFORMAÇÃO SOBRE REDES NEURAIS E SUAS APLICAÇÕES

No site que segue, você poderá encontrar diversos textos que permitem um aprofundamento maior no tema: <http://www.kcl.ac.uk/neuronet/intro/index.html>.

Através do site www.lsi.usp.br/~emilio, você pode chegar a esse link e a outros sites com materiais sobre redes neurais em diversos níveis de profundidade, desde artigos introdutórios até artigos sobre temas bastante específicos que são hoje objeto de pesquisa. Outra fonte de consulta para alguns tópicos em arquiteturas neurais pode ser encontrada no trabalho de iniciação científica [Experimentos com arquiteturas neurais clássicas para o desenvolvimento de arquiteturas neurais híbridas](#), de Clayton Silva Oliveira e Emílio Del Moral Hernandez, disponível no próprio site da EPUSP:

<http://www.poli.usp.br/PesquisaPoli/Publicacoescpq/ProducaoIC2002/>.
(uma vez no site, localize o artigo com título e autores acima)

Nesse trabalho, duas arquiteturas neurais importantes são abordadas: a arquitetura MLP – multi layer perceptron - e a arquitetura de Hopfield.

Duas referências bastante importantes são os livros de David Rumelhart (Parallel Distributed Processing) e de Simon Haykin (Neural Networks: a Comprehensive Foundation), ambos disponíveis na nossa biblioteca. Naturalmente, você deve escolher destas duas extensas referências aqueles capítulos que são acessíveis a você no seu estágio de formação. Em particular, o livro de Haykin nos seus capítulos 1 e 2 é bastante acessível na maior parte de seus conteúdos.

Dois artigos introdutórios: Artificial Neural Networks: A Tutorial, de autoria de Anil K Jain e Jianchang Mao, publicado na IEEE Computer de março de 1996, pp. 31-44, identificado e recomendado pelo nosso colega o Professor Aquiles Grimoni (PEA). Pode ser copiado para uso pessoal com finalidade de estudo; Um outro artigo, também identificado pelo Professor Aquiles, que pode ser de interesse: Artificial Neural Networks

and Computational Intelligence, de autoria de Roger L. King e publicado em outubro de 1998, no IEEE Computer Applications in Power pp.15-25.

Outro site relacionado, no qual informações em inteligência computacional e redes neurais podem ser obtidas: as notas de aula da PUC do Rio de Janeiro: http://www.ica.ele.puc-rio.br/cursos/crs_lst_notas.asp;

Enfim, os interessados em conhecer mais sobre redes neurais estão convidados a me contatar por e-mail, pois posso indicar materiais adicionais de leitura.

Obrigado,
Prof. Dr. Emilio Del Moral Hernandez
emilio_del_moral@ieee.org
www.lsi.usp.br/~emilio