

Redes neurais artificiais: conceitos e aplicações

Daniel Karrer (UFRJ) dkarrer@gpi.ufrj.br

Renato Florido Cameira (UFRJ) cameira@gpi.ufrj.br

André Strauss Vasques (UFRJ) astrauss@click21.com.br

Marcos de Almeida Benzecry (UFRJ) marcos_benzecry@yahoo.com.br

Resumo: O artigo se propõe a realizar uma introdução teórico-conceitual às redes neurais artificiais. Para isso, foi realizada uma breve revisão da bibliografia disponível, abrangendo em especial o neurônio booleano de McCulloch, além de uma breve descrição do funcionamento do neurônio biológico. Por fim, há uma seção onde são descritos exemplos e casos de aplicação das RNAs.

Palavras-chave: Redes neurais artificiais, Neurônio de McCulloch, Aplicações gerenciais e biológicas

1- Introdução

Segundo Braga, Carvalho e Ludemir (2000), em “Sistemas Inteligentes”, “as Redes Neurais Artificiais (RNAs) são modelos matemáticos que se assemelham às estruturas neurais biológicas e que tem capacidade computacional adquirida por meio de aprendizado e generalização”. O aprendizado em RNAs consiste na fase onde a rede neural absorve dados e, a partir destes, modifica seus parâmetros de entrada. Esta etapa pode ser considerada como uma adaptação da RNA às características intrínsecas de um problema, onde se procura cobrir um grande espectro de valores associados as variáveis pertinentes. Isto é feito para que a RNA adquira, através de uma melhora gradativa, uma boa capacidade de resposta para o maior número de situações possíveis. Por sua vez a generalização de uma RNA está associada à sua capacidade de dar respostas coerentes para dados não apresentados a ela durante o treinamento. Espera-se que uma RNA treinada tenha uma boa capacidade de generalização independentemente de ter sido controlada durante o treinamento. No entanto, atualmente, segundo Braga, Carvalho e Ludemir (2000), boa parte das pesquisas atual na área visa o desenvolvimento de modelos e técnicas de aprendizado que tenham algum controle de generalização. O

conceito atual é que aprendizado e generalização andam juntos em vez de a generalização surgir naturalmente como consequência do aprendizado.

Segundo Braga, Carvalho e Ludemir (2000), bem como Kovács (1996), o processamento da informação em RNAs é feito por meio de estruturas neurais artificiais em que o armazenamento e o processamento da informação são realizados de maneira paralela e distribuída, por elementos processadores relativamente simples. Cada elemento processador corresponde a um neurônio artificial, também conhecido como modelo de Mc Culloch e Pitts, ou simplesmente modelo MCP.

Ainda de acordo com Braga, Carvalho e Ludemir, “uma das características mais importantes das RNAs é que as mesmas são aproximadoras universais de funções multivariáveis contínuas. Em outras palavras, qualquer problema de aproximação de funções contínuas pode ser resolvido por meio de RNAs, independente do número de variáveis envolvidas.”

2 – O neurônio Biológico

De acordo com a descrição de Kovács (1996), como qualquer célula biológica, o neurônio é delimitado por uma fina membrana celular que além de sua função biológica normal, possui determinadas propriedades que são essenciais para o funcionamento elétrico da célula nervosa. A partir do corpo celular, ou soma – o centro dos processos metabólicos da célula nervosa – projetam-se extensões filamentosas, conhecidas como dendritos e axônio. A partir de estudos realizados na década de 50 e 60, passou-se a entender o neurônio biológico como sendo basicamente o dispositivo computacional elementar do sistema nervoso, que possuía múltiplas entradas e apenas uma saída. As entradas ocorrem através das conexões sinápticas, que conectam a árvore dendrital aos axônios de outras células nervosas. Os sinais que chegam por esses axônios são pulsos elétricos conhecidos como impulsos nervosos ou potenciais de ação, e constituem a informação que o neurônio processará, de alguma forma, para produzir como saída um impulso nervoso no seu axônio.

O axônio ou fibra nervosa de um neurônio é um tubo filamentar delimitado pela membrana celular. Em repouso, isto é, sem a presença de um impulso nervoso, o interior da membrana está a um potencial eletronegativo de algumas dezenas de milivolts em relação ao exterior. Este é o potencial de repouso da membrana. A formação de um potencial de ação na membrana axonal ocorre quando esta sofre uma

despolarização suficientemente acentuada para cruzar um determinado valor conhecido como limiar de disparo. Neste momento, a membrana se despolariza rapidamente, em questão de alguns microsegundos, muito além do valor do limiar, e em seguida retorna mais lentamente, ao valor de repouso. Este fenômeno é o potencial de ação, que passa a se propagar ao longo da fibra nervosa na forma de uma onda não atenuada.

Como destacou, Kovács (1996), no neurônio biológico, há uma integração espaço-temporal dos estímulos: “A polarização ocorre imediatamente após a chegada do impulso nervoso na árvore dendrital e se propaga por difusão passiva por toda a membrana até o local em que poderá interferir no surgimento de potencial de ação (axônio) e, com o tempo, decai de maneira exponencial. Isto é, a membrana mantém, por algum tempo, a memória da atividade sináptica. Este fenômeno é conhecido como integração temporal dos estímulos pelo neurônio. Por outro lado, o potencial de ação é provocado no axônio de um neurônio pelo efeito combinado de todos os estímulos excitatórios e inibitórios que chegam a sua árvore dendrital. Esta característica reflete a integração espacial dos estímulos.”

3 – O neurônio Booleano de McCulloch

Em 1943, Warren McCulloch, juntamente com o estatístico Walter Pitts, publicaram no *Bulletin of Mathematical Biophysics* o artigo “A logical Calculus of the Ideas Immanent in Nervous Activity”. O neurônio de McCulloch é um dispositivo binário, que segue a lógica da figura 1. Sua saída poderia ser *pulso* ou *não pulso*, e as suas várias entradas tinham ganho arbitrário e poderiam ser excitatórias ou inibitórias.




Figura 1: Esquema de um Neurônio de McCulloch

As entradas do neurônio correspondem ao vetor de entrada $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$ de dimensão n . Para cada uma das entradas x_i , há um peso correspondente w_i na entrada dos neurônios. A soma das entradas x_i ponderadas pelo peso correspondente w_i é chamada de saída linear u , onde $u = \sum w_i x_i$. A saída y do neurônio, chamada de saída de ativação, é obtida pela aplicação de uma função f à saída linear u , indicada por $y = f(u)$. A função f é chamada de função de ativação e pode assumir várias formas, geralmente não-lineares. As quatro funções de ativação mais utilizadas são linear, rampa, degrau e sigmóide. Um exemplo típico de função de ativação é a função degrau unipolar:

$$f(u) = 0 \text{ se } u < \theta$$

$$f(u) = 1 \text{ se } u > \theta$$

onde θ é o limiar acima do qual a saída do neurônio é ativada. De acordo com os valores dos pesos e do limiar θ , o neurônio artificial pode computar funções diferentes.

Segundo Braga, Carvalho e Ludemir (2000), analisando o comportamento do neurônio representado pela equação acima e considerando uma entrada de dados com duas variáveis, podemos observar que a equação de decisão por meio da qual o neurônio ativa ou não a sua saída é equivalente a $w_1 x_1 + w_2 x_2 = \theta$, que corresponde à equação de uma reta no espaço das variáveis de entrada x_1 e x_2 (figura 2). Como pode ser observado, para cada conjunto de valores diferentes de w_1 , w_2 e θ teremos uma reta diferente no espaço de entrada definido pelas variáveis x_1 e x_2 . Com esta visualização geométrica do problema, pode-se entender melhor em que consiste o aprendizado em RNAs, que nada mais é do que o ajuste dos pesos w e de θ , de maneira que a superfície de decisão, neste caso uma reta, atenda aos requisitos de parada de um algoritmo.

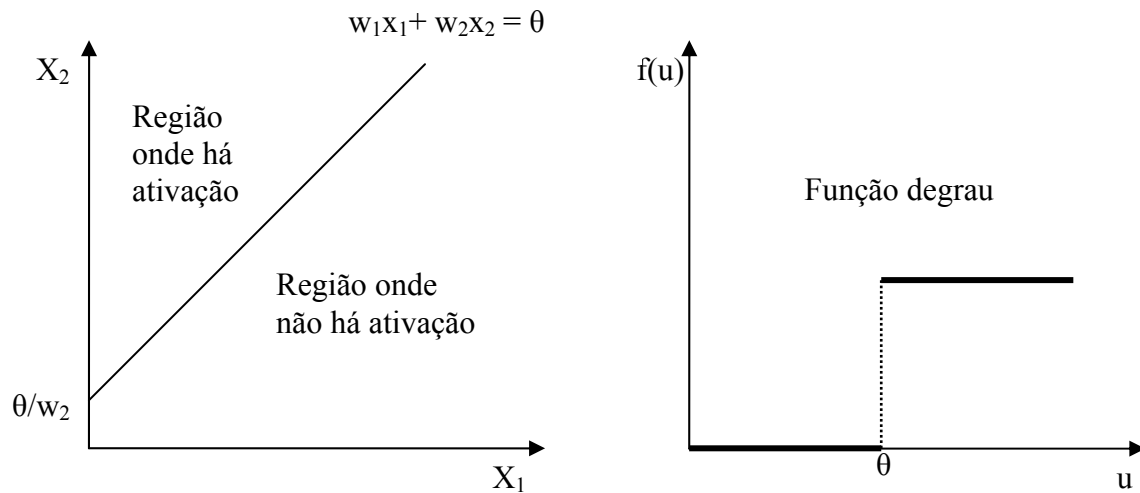


Figura 2: Representação gráfica

Como apontado por Braga, Carvalho e Ludemir (2000), uma Rede Neural é, portanto, formada por elementos processadores simples. Cada elemento processador executa uma função simples, mas a RNA como um todo tem capacidade computacional para resolução de problemas complexos. A estrutura apresentada na figura 3 possui quatro entradas (x_1, x_2, x_3, x_4), duas saídas (y_1, y_2) e quatro neurônios na camada intermediária, e é capaz de resolver problemas de regressão, classificação ou predição no espaço R^4 . É também um exemplo de rede neural do tipo *feed-forward*.




Figura 3: esquema de uma rede neural de 2 camadas

4 – Aprendizado

Conforme descrito anteriormente na introdução, as RNAs caracterizam-se pelo aprendizado por meio de exemplos. Para um determinado conjunto de dados, o algoritmo de aprendizado deve ser responsável pela adaptação dos parâmetros da rede, de maneira que, em um número finito de iterações do algoritmo, haja convergência para uma solução. O critério de convergência varia de acordo com o algoritmo e com o paradigma de aprendizado, mas pode envolver, por exemplo, a minimização de uma função-objetivo, a variação do erro de saída ou mesmo a variação das magnitudes dos vetores de peso da rede.

Basicamente, considera-se que o processo de aprendizado tem como característica a ocorrência de estímulo da rede pelo meio externo através da apresentação do conjunto de dados. Como consequência deste estímulo, o algoritmo de aprendizado provoca mudança nos parâmetros da rede e, finalmente, a mudança nos parâmetros acarreta em mudança no comportamento da RNA. Espera-se que a mudança gradual no comportamento da rede resulte em melhoria gradativa do seu desempenho.

Segundo Kovács (1996), a modificação do processamento ou da estrutura de conhecimento de uma rede neural envolve a alteração do seu padrão de interconexão. Em princípio, isto pode ser feito de três maneiras: desenvolvimento de novas conexões; perda de conexões existentes na rede ou modificação dos pesos das conexões já existentes

5 - Aprendizado e Generalização

Segundo Braga, carvalho e Ludemir (2000), “o objetivo principal do aprendizado em Redes Neurais é a obtenção de modelos com boa capacidade de generalização tendo como base o conjunto de dados”. Em problemas de aproximação, classificação e predição, o conjunto de treinamento é composto por pares de entrada e saída (x, y_d) , sendo caracterizada previamente a saída desejada y_d para um determinado valor de entrada x . O ajuste de pesos deve modificar a saída y de forma que a diferença entre y e y_d , ou seja, o erro, diminua a cada iteração. No entanto a minimização pura e simples do erro pode não levar a resultados satisfatórios. Portanto é preciso fazer mais do que simplesmente minimizar o erro do conjunto de treinamento para se obter boa

resposta de generalização. O objetivo dos algoritmos de treinamento deve ser o de aproximar funções geradoras f_g dos dados e não simplesmente o de minimizar o erro do conjunto de treinamento.

6 – Classificação das Redes Neurais

Existem diversos tipos de RNA e diferentes maneiras de classificá-las. Talvez a mais importante seja quanto à forma de aprendizado que pode ser: supervisionada e não supervisionada.

Como apontam Portugal e Fernandes (1995), no aprendizado supervisionado são sucessivamente apresentadas à rede conjuntos de padrões de entrada e seus correspondentes padrões de saída. Durante este processo, a rede realiza um ajustamento dos pesos das conexões entre os elementos de processamento, segundo uma determinada lei de aprendizagem, até que o erro entre os padrões de saída gerados pela rede alcance um valor mínimo desejado. Por exemplo, *perceptron*, *adaline* e *madaline*, *backpropagation*, são algumas dentre as dezenas de leis de aprendizagem supervisionada.

No aprendizado não-supervisionado a rede “analisa” os conjuntos de dados apresentados a ela, determina algumas propriedades dos conjuntos de dados e “aprende” a refletir estas propriedades na sua saída. A rede utiliza padrões, regularidades e correlações para agrupar os conjuntos de dados em classes. As propriedades que a rede vai “aprender” sobre os dados podem variar em função do tipo de arquitetura utilizada e da lei de aprendizagem. Por exemplo, Mapa Auto-Organizável de Kohonen, Redes de Hopfield e Memória Associativa Bidirecional, são alguns métodos de aprendizado não-supervisionado.

As redes também podem ser classificadas quanto às suas características: contínua, discreta, determinística e estocástica, ou quanto à sua estrutura: redes de múltiplas camadas - *multilayer feedforward network*, cujo fluxo de dados segue uma única direção e redes recursivas - *recurrent network*.

7 – Modelagem em Redes Neurais artificiais

Para o desenvolvimento de um modelo ou projeto baseado em redes neurais artificiais são necessárias diversas etapas: definição do problema; coleta dos dados de treinamento e de teste; pré e pós-processamento dos dados; projeto da estrutura da rede; treinamento; teste e validação.

Na elaboração do projeto da RNA ideal para solucionar um determinado problema, uma das tarefas mais difíceis é determinar o número de elementos de processamento da camada oculta, bem como o número de camadas ocultas (camadas intermediárias ou ocultas são as camadas onde é feita a maior parte do processamento, através de conexões ponderadas. Podem ser consideradas extratoras de características). Não existem regras para isto, entretanto, estudos como o Teorema de Kolmogorov demonstraram que uma única camada oculta é suficiente para representar qualquer função ou para resolver a maioria dos problemas de generalização. Todavia, estes não indicam o número de elementos de processamento que esta camada deve conter.

Os tipos de redes neurais mais adequadas são as redes multicamadas do tipo *feedforward* com método de aprendizagem supervisionado (utilizando o algoritmo de *backpropagation*). A parte principal do algoritmo de *backpropagation* é a maneira interativa pela qual os erros utilizados para adaptar os pesos são propagados para trás, isto é, a partir da camada de saída para as camadas anteriores.

8– Aplicações

De acordo com Turbam, McLean e Wetherbe (2004), além de seu papel de mecanismo computacional alternativo, a computação neural também pode ser combinada com outros sistemas de informação baseados em computador para produzir sistemas híbridos poderosos.

Em geral, as RNAs não apresentam um bom desempenho em tarefas que não são bem executadas por pessoas. Por exemplo, cálculos matemáticos e processamento de transações que exijam rapidez não são adequados para as RNAs e são mais bem executadas pelos computadores convencionais. Entre as áreas de aplicação das RNAs podemos citar:

- **Data Mining:** Localizar dados em bancos de dados complexos e em sites da Web;

- ***Fraudes tributárias:*** identificar, localizar e assinalar irregularidades;
- ***Serviços financeiros:*** identificar padrões de dados sobre o mercado de ações e auxiliar em estratégias de negociação de ações e títulos; escolha e comercialização de commodities, subscrição de hipoteca, precificação de ofertas iniciais ao público e previsão de taxas de câmbio;
- ***Avaliação de pedidos de financiamento:*** avaliar a seriedade dos pedidos de financiamento, com base em padrões de informações anteriores (nível de critério do cliente);
- ***Previsão de solvência:*** avaliando os pontos fortes e fracos de empresas e prevendo possíveis fracassos;
- ***Análise de novos produtos:*** previsão de vendas e marketing dirigido;
- ***Gestão de tarifas aéreas:*** procura de assentos e escalas de tripulação;
- ***Avaliação de funcionários e candidatos a vagas:*** dados dos candidatos comparados às exigências da função de critérios de desempenho;
- ***Alocação de recursos baseada em dados históricos e experimentais:*** descobrir alocações que maximizem os resultados;
- ***Identificação de alvos de aquisição:*** prever quais empresas estão mais sujeitas a serem compradas por outras;
- ***Validação de assinatura:*** comparação e confirmação de assinaturas com amostras no cadastro;
- ***Previsões:*** antecipar as exigências de comportamento e de pessoal;
- ***Deteção de fraudes contra seguradoras:*** descobrir padrões de fraude;
- ***Deteção de fraudes contra administradoras de cartões de crédito:*** análise de padrões de compra para deteção de fraude;
- ***Entre outros.***

9 – Estudo de caso: Aplicações de Redes Neurais Artificiais em Bioinformática

As Redes Neurais Artificiais podem ser aplicadas a diversos problemas da Bioinformática, que costumam envolver reconhecimento de padrões. Adequam-se aos casos onde há necessidade de manipulação de conhecimento impreciso; além de possibilitarem a construção de modelos a partir de exemplos depositados em bancos de dados.

Análise de Sequências de Genomas: Uma importante área de aplicação da Bioinformática é a Análise de Sequências (nucleotídeos ou aminoácidos), obtidas a partir do seqüenciamento de genomas dos mais diversos organismos. Várias abordagens podem ser utilizadas:

a) Reconhecimento de Sinais - Segundo o "Dogma Central da Biologia Molecular", toda informação genética de um organismo está codificada em seu genoma. Portanto, a análise de seqüências envolveria a identificação de padrões associados a funcionalidades biológicas. Como o Reconhecimento de Padrões é uma das principais aplicações das Redes Neurais Artificiais, é interessante que estas sejam aplicadas em Bioinformática, quando o problema envolver identificação de sinais biológicos. São exemplos de sinais a serem reconhecidos em seqüências de nucleotídeos: Promotores (início da transcrição); Sinais de término de transcrição; *Start codon* (início de tradução); *Stop codons* (término de tradução); RBS (*ribosome binding site*).

b) Identificação de Assinaturas - Um outro tipo importante de análise é a caracterização da proteína, com base nos motivos encontrados em sua seqüência de aminoácidos. Uma maneira de realizar esta classificação seria através da construção de Mapas Auto-Organizáveis contendo os motivos de interesse.

c) Identificação de Repetições e de Regiões de Baixa Complexidade - De maneira similar aos motivos em seqüências de aminoácidos, tanto as repetições como as regiões de baixa complexidade poderiam ser detectadas através dos Mapas Auto-Organizáveis.

10- Estudo de caso: Administradoras de cartão de crédito

Somente 0,25% do faturamento da *Visa International*, em 1995, foi perdido para as fraudes, mas o 655 milhões de dólares que esse percentual representa são uma perda significativa que merece ser prevenida. A *Visa* está concentrando seus esforços agora sobre a reversão do número de transações fraudulentas, utilizando para isso a ajuda da tecnologia de redes neurais.

A maioria das pessoas costuma manter um padrão bem-definido de uso de cartão de crédito e raramente faz compras supérfluas. As redes neurais foram desenhadas para perceber quando um cartão, normalmente usado uma vez por semana para abastecer o automóvel, por exemplo, de repente é usado para comprar vários ingressos para a mais famosa estréia de teatro na Broadway.

Os bancos associados à rede Visa acreditam que a tecnologia de redes neurais é um sucesso. O *Bank of America* usa um sistema de identificação de risco de portador de cartão de crédito (CRIS) e cortou o uso fraudulento de cartões de crédito em dois terços. O *Toronto Dominion Bank* descobriu que as perdas haviam diminuído, e seu atendimento ao cliente melhorado muito desde a introdução da computação neural. Outro banco registrou uma economia de 5,5 milhões de dólares em seis meses. Em 1994, os bancos associados à *Visa* perderam mais de 148 milhões de dólares com falsificação de cartões – o que representa uma queda maior que 16%. Com esses números, os 2 milhões de dólares que a *Visa* investiu na instalação do CRIS parecem ter valido a pena. De fato, a *Visa* diz que obteve retorno sobre o investimento no CRIS em apenas 1 ano.

Em 1995, o CRIS realizou mais de 16 bilhões de transações. Em 2000, o *VisaNet* (o *data warehouse* e operações de e-mail da *Visa*) e o CRIS efetuavam mais de 5250 transações por segundo. No outono de 2000, o CRIS conseguia avisar em poucos minutos seus bancos associados sobre qualquer fraude que estivesse ocorrendo com alguma transação.

A administradora japonesa de cartões de crédito *Sumitomo Credit Service Co.* utiliza o *Falcon*, um sistema baseado em redes neurais da *HNC Corp.* O produto consegue ler bem os caracteres japoneses, protegendo 18 milhões de portadores de cartões de crédito no Japão.

11 – Conclusão

A partir de nosso estudo dos conceitos básicos, conclui-se que as RNAs representam uma parte importante do conhecimento que está se formando no campo de sistemas inteligentes e inteligência artificial. Através dos estudos de caso, percebe-se o poder desta ferramenta, que pode, dentre outras coisas, ser de grande valia no âmbito da engenharia de produção como suporte a gestão de informação e suporte à tomada de decisão.

12 – Bibliografia

Rezende, Solange O. (2003). *Sistemas Inteligentes – Fundamentos e aplicações*. Barueri, SP. Editora Manole.

Turbam, E., McLean, E., Wetherbe, J. (2004) . Tecnologia da Informação para Gestão. Porto Alegre, RS. Editora Bookman.

Kovács, Zsolt L. (1996). Redes Neurais Artificiais : Fundamentos e aplicações. São Paulo , SP – Livraria da Física Editora.

Artigo "Redes Neurais Artificiais e Previsão de Séries Econômicas: uma introdução". Marcelo S. Portugal e Luiz Gustavo L. Fernandes, 1995