

Complemento II – Noções Introdutória em Redes Neurais

Esse documento é parte integrante do material fornecido pela WEB para a 2ª edição do livro *Data Mining: Conceitos, técnicas, algoritmos, orientações e aplicações*.

Visão geral

Em termos intuitivos, redes neurais artificiais (RNAs) são modelos matemáticos inspirados nos princípios de funcionamento dos neurônios biológicos e na estrutura do cérebro. Estes modelos têm capacidade de adquirir, armazenar e utilizar conhecimento experimental e buscam simular computacionalmente habilidades humanas tais como aprendizado, generalização, associação e abstração.

A tabela abaixo resume a relação entre características e comportamentos de RNAs com elementos da natureza.

Modelo Natural	Modelo Artificial
Cérebro	RNA
Neurônio Biológico	Neurônio artificial/ elementos processadores
Rede de Neurônios	Estrutura em camadas
10 bilhões de Neurônios	Centenas/ milhares de neurônios

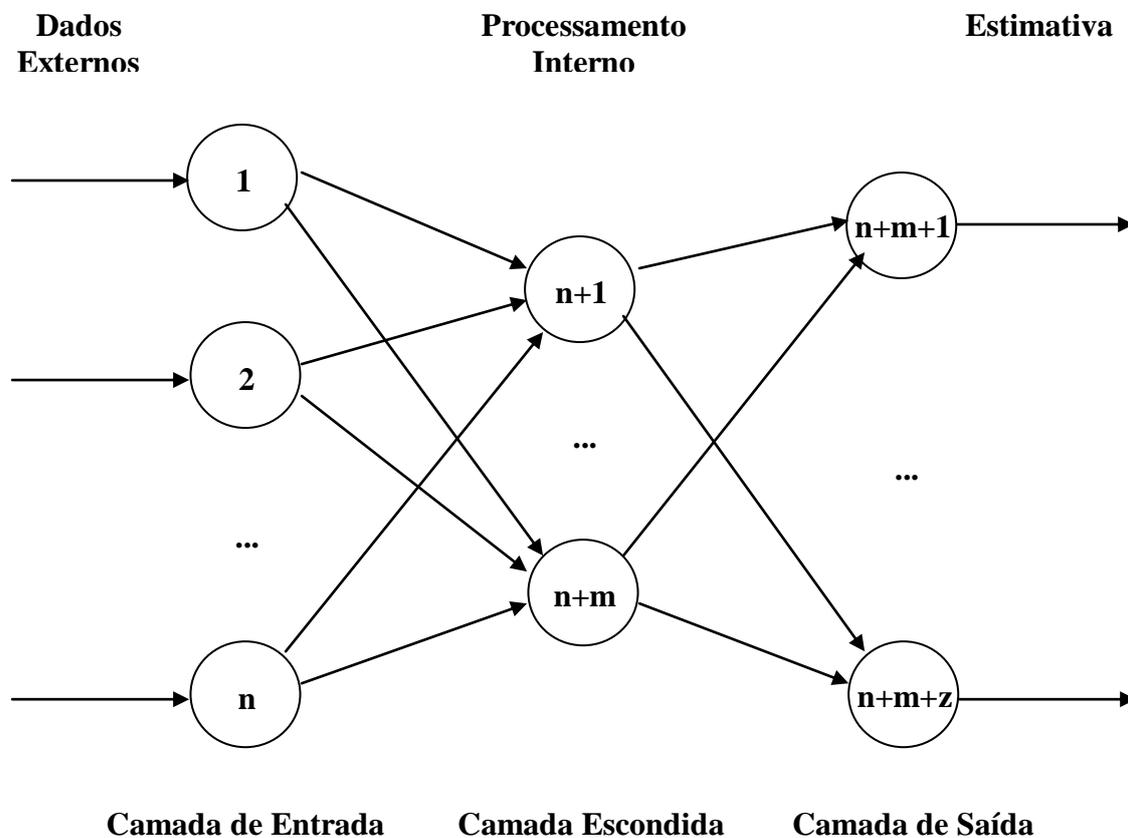
Devido à sua similaridade com a estrutura do cérebro, as RNAs apresentam algumas características similares às do comportamento humano, tais como:

- a) **Busca paralela e endereçamento pelo conteúdo.** O cérebro não possui endereço de memória. Analogamente, nas RNAs o conhecimento fica distribuído pela estrutura das redes, de forma que a procura pela informação ocorre de forma paralela e não sequencial.
- b) **Aprendizado por Experiência.** As RNAs tentam aprender padrões diretamente a partir dos dados. Para isso, utilizam um processo de repetidas apresentações dos dados à rede que busca abstrair modelos de conhecimento de forma automática. Este processo é denominado *aprendizado*, e é implementado por um *algoritmo de aprendizado*.
- c) **Generalização.** As RNAs são capazes de generalizar seu conhecimento a partir de exemplos anteriores. A capacidade de generalização permite que RNAs lidem com ruídos e distorções nos dados, respondendo corretamente a novos padrões.
- d) **Associação.** As RNAs são capazes de estabelecer relações entre padrões de natureza distinta. Por exemplo, identificar pessoas a partir de características da voz destas pessoas.
- e) **Abstração.** Abstração é a capacidade das RNAs em identificar a essência de um conjunto de dados de entrada. Isto significa que as RNAs são capazes de perceber quais as

características relevantes em um conjunto de entradas. Assim sendo, a partir de padrões ruidosos as RNAs podem extrair as informações dos padrões sem ruído.

f) **Robustez e Degradação Gradual.** Como a informação fica distribuída em uma RNA, a perda de um conjunto de neurônios artificiais não causa necessariamente o mau funcionamento desta rede. Na realidade, o desempenho de uma RNA tende a diminuir gradativamente na medida em que aumenta a quantidade de neurônios artificiais inoperantes.

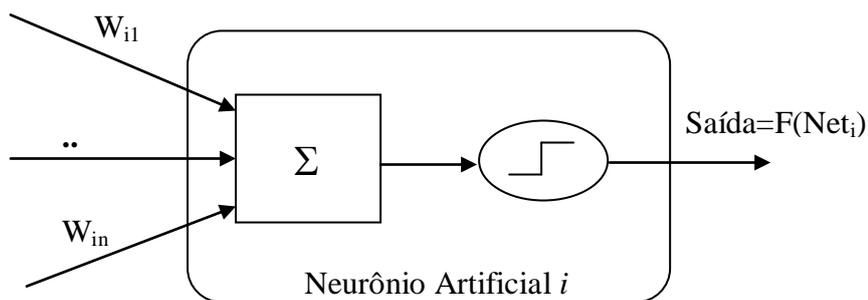
Semelhante ao sistema biológico, uma RNA possui, simplificada, um sistema de neurônios, e conexões ponderadas por valores reais denominados pesos. Numa RNA os neurônios são arrumados em camadas, com conexões entre elas. A figura abaixo ilustra graficamente a arquitetura de uma RNA simples. Os círculos representam os neurônios e as linhas representam os pesos das conexões. Por convenção, a camada que recebe os dados é chamada camada de entrada e a camada que mostra o resultado é chamada camada de saída. A camada interna, onde ocorre o processamento interno da rede é tradicionalmente chamada de camada escondida. Uma RNA pode conter uma ou várias camadas escondidas, de acordo com a complexidade do problema.



Em geral o processamento das RNAs ocorre da esquerda para a direita (*RNAs feed forward*). Para fins computacionais os neurônios são rotulados com uma numeração sequencial de cima para baixo, da esquerda para a direita, conforme ilustrado na figura acima.

A transmissão do sinal de uma célula para outra é um complexo processo químico, no qual substâncias específicas são liberadas pelo neurônio transmissor. O efeito é um aumento ou uma queda no potencial elétrico no corpo da célula receptora. Se este potencial alcançar o limite de ativação da célula, um pulso ou uma ação de potência e duração fixa é enviado para outros neurônios. Diz-se então que o neurônio está ativo.

O neurônio artificial foi projetado para imitar algumas das principais características de um neurônio biológico. Essencialmente, as entradas são aplicadas a um neurônio artificial, cada uma representando a saída de outros neurônios conectados a ele (vide figura acima). Cada entrada é multiplicada por um peso correspondente (W_{ij}), gerando entradas ponderadas, de forma análoga à força das *sinapses*. Em seguida todas estas entradas ponderadas são somadas, obtendo-se um valor *NET* (potencial de ativação do neurônio artificial) que será comparado com o valor limite para ativação do neurônio (F). Caso este valor alcance o valor limite de ativação do neurônio, ele será ativado. Caso contrário ele permanecerá inativo. A figura a seguir mostra o modelo que implementa esta idéia.



Modelagem

Conforme pode ser observado na figura acima, em essência, os elementos básicos de um neurônio artificial são os descritos a seguir.

- **Conexões entre os Processadores:** A cada conexão de entrada de um neurônio artificial, existe um valor real, denominado peso sináptico, que determina o efeito desta entrada sobre o neurônio em questão. Quanto maior / menor este valor, maior a influência positiva / negativa do neurônio de onde sai a referida conexão. De forma análoga, a cada conexão de saída há um

peso sináptico que determina a influência deste neurônio sobre o neurônio de chegada desta conexão.

- **Regra de Propagação:** É a forma com que as entradas provenientes de outros neurônios artificiais são combinadas aos pesos sinápticos correspondentes de um determinado neurônio (j). A regra de propagação estabelece o potencial de ativação do neurônio (net_j). Uma regra de propagação muito utilizada é o produto escalar entre o vetor de entrada e o vetor de pesos $\sum_{i=1}^n$

$$O_i W_{ij}$$

- **Função de Ativação:** Determina o novo valor do estado de ativação de um neurônio artificial, a partir de seu potencial de ativação Net_j . Determina saída efetiva do neurônio artificial. Esta função pode ter várias formas: uma função linear; uma função limiar (função degrau); ou ainda uma função que simule mais precisamente as características não lineares do neurônio biológico. No caso de F ser uma função linear, a saída do neurônio é expressa por:

$$F(Net_j) = O_j = K * Net_j$$

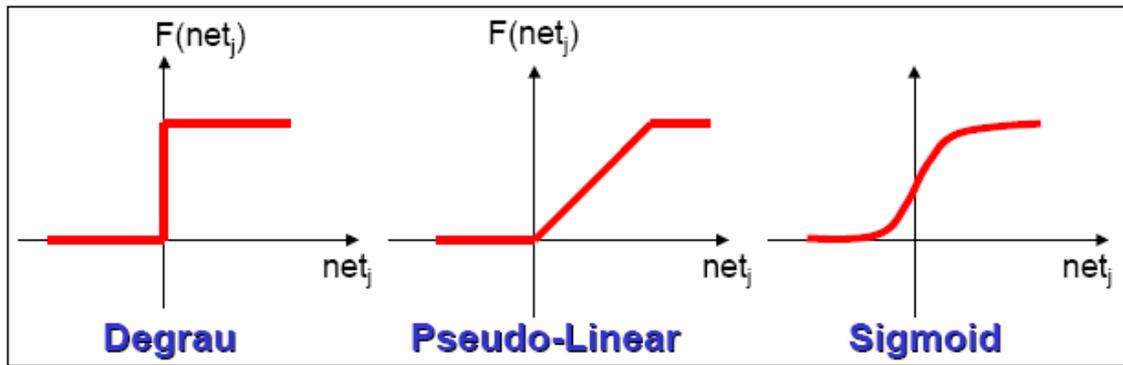
onde K é uma constante.

Caso F seja uma função degrau, a saída seria:

$$O_j = \begin{cases} 1, se .net_j \geq T \\ 0, se .net_j < T \end{cases}$$

onde T é o valor de limiar do neurônio artificial (constante).

No caso de se querer simular com maior precisão os neurônios biológicos, podem ser utilizadas funções não lineares. Elas se caracterizam por não deixarem a saída do neurônio exceder certos valores limites, os quais, em geral, são menores que os valores de Net_j . A função não linear mais utilizada é a função sigmóide, a qual é representada matematicamente por $F(x) = 1/(1+e^{-x})$. Adequando-a ao neurônio artificial tem-se: $O_j = 1/(1+e^{-net_j})$. A figura abaixo apresenta graficamente algumas das principais funções de ativação utilizadas em RNAs.



É interessante ressaltar que o modelo simples de neurônio artificial apresentado ignora diversas características do neurônio natural, tais como a não consideração dos atrasos de tempo que afetam a dinâmica do sistema – as entradas produzem saídas imediatas - e a não inclusão dos efeitos de sincronismo ou de modulação de frequência - característica que alguns pesquisadores acham de fundamental importância. Apesar destas limitações, as *RNAs* formadas por simples neurônios artificiais possuem atributos semelhantes aos do sistema biológico, como a capacidade de aprendizado e generalização, podendo-se dizer que a essência do funcionamento do neurônio natural tenha sido absorvida.

As várias topologias de redes neurais estão divididas, basicamente, em duas classes: *não-recorrentes* e *recorrentes*. As *RNAs não-recorrentes* são aquelas que não possuem realimentação de suas saídas para suas entradas e por isso são também ditas "sem memória". A estrutura das *RNAs* ditas não-recorrentes é em camadas, podendo estas *RNAs* serem formadas por uma (*RNA* de camada única) ou mais camadas (*RNA* multi-camada). Redes neurais multi-camadas contêm um conjunto de neurônios de entrada, uma camada de saída e uma ou mais camadas escondidas. A camada de entrada da rede apenas distribui os padrões. A camada de saída apresenta o resultado final do processamento da rede. As *RNAs* de uma camada são também chamadas de "*perceptrons*", e possuem um espectro de representações limitado. As *RNAs* multi-camadas, por suprirem as deficiências das redes de uma única camada, possuem uma gama maior de aplicações bem sucedidas.

Processamento

É importante destacar que existem dois tipos de processamento em *RNAs*. O primeiro tipo é chamado de aprendizado ou etapa de treinamento. Em linha gerais, o treinamento de uma *RNA* é o processo de atualização dos pesos sinápticos para a aquisição de conhecimento a partir dos dados. O segundo tipo de processamento é chamado de teste ou recuperação da informação. O

teste de uma RNA é o processo de cálculo da saída da rede a partir da apresentação de padrões de entrada.

De todas as propriedades interessantes das redes neurais artificiais, nenhuma captura tão bem a característica humana como a habilidade de aprender. Ao invés de especificar todos os detalhes de uma computação tem-se a possibilidade de treinar uma rede para fazer esta computação. Isto significa que as redes neurais podem tratar problemas onde regras apropriadas são muito difíceis de se conhecer previamente, sendo estas regras abstraídas a partir dos dados.

O objetivo do treinamento de uma RNA é fazer com que a aplicação de um conjunto de entradas produza um conjunto de saídas desejado ou, no mínimo, um conjunto de saídas consistentes. Cada conjunto de entrada ou saída é chamado de vetor. O treinamento é realizado pela aplicação seqüencial dos vetores de entradas (e em alguns casos também os de saída), enquanto os pesos da rede são ajustados de acordo com um procedimento de treinamento pré-determinado (algoritmo de treinamento). Durante o treinamento de uma rede, espera-se que os pesos gradualmente convirjam para determinados valores, tal que a aplicação dos vetores de entrada produza as saídas desejadas.

Os procedimentos de treinamento que levam as RNAs a aprender determinadas tarefas podem ser classificados em duas classes de treinamento: supervisionado e não-supervisionado.

O treinamento *supervisionado* necessita de um par de vetores composto do vetor de entrada e do vetor alvo que se deseja como saída. Juntos, estes vetores são chamados de par de treinamento ou vetor de treinamento, sendo interessante ressaltar que geralmente a rede é treinada com vários vetores de treinamento.

O procedimento de treinamento funciona da seguinte forma: o vetor de entrada é aplicado. A saída da rede é calculada e comparada com o correspondente vetor alvo. O erro encontrado é então realimentado através da rede e os pesos são atualizados de acordo com um algoritmo determinado a fim de minimizar este erro. Este processo de treinamento é repetido até que o erro para os vetores de treinamento tenha alcançado níveis bem baixos.

O treinamento *não supervisionado*, por sua vez, não requer vetor alvo para as saídas e, obviamente, não faz comparações para determinar a resposta ideal. O treinamento não supervisionado modifica os pesos da rede de forma a produzir saídas que sejam consistentes, isto é, tanto a apresentação de um dos vetores de treinamento, como a apresentação de um vetor que é suficientemente similar a um dos vetores de treinamento, irá produzir o mesmo padrão nas

saídas. O processo de treinamento não supervisionado extrai as propriedades estatísticas do conjunto de treinamento e agrupa os vetores similares em classes.

Aplicações

São diversos os exemplos de aplicações práticas reais das RNAs. A seguir encontram-se relacionados alguns deles:

- Reconhecimento de padrões
- Classificação de padrões
- Correção de padrões
- Previsão de séries temporais
- Suporte à decisão
- Mineração de Dados

Para Saber Mais

Caso o leitor deseje, maiores detalhes sobre Redes Neurais podem ser obtidos na literatura especializada.

Braga, A. P., Carvalho, A. P., Ludermir, T. B. *Redes Neurais Artificiais – Teoria e Aplicações*, 2ª. ed., Rio de Janeiro: LTC, 2007.

Haykin, Simon. **Redes Neurais: Princípios e Prática**. 2ª ed., Porto Alegre: Bookman, 2001.