



FUNDAÇÃO UNIVERSIDADE FEDERAL
DO VALE DO SÃO FRANCISCO



Redes Neurais Artificial

Inteligência Artificial

Professor: Rosalvo Ferreira de Oliveira Neto

1. Definições
2. Histórico
3. Conceitos Básicos
4. Aprendizado em RNA
5. Exemplo de Aprendizado com Perceptron


Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência.

- Redes Neurais Artificiais (RNA) são modelos de computação com propriedades particulares
 - ◆ Capacidade de se adaptar ou aprender
 - ◆ Generalizar
 - ◆ Agrupar ou organizar dados

- Modelos inspirados no cérebro humano
 - ◆ Compostas por várias unidades de processamento (“neurônios”)
 - ◆ Interligadas por um grande número de conexões (“sinapses”)
- Eficientes onde métodos tradicionais têm se mostrado inadequados


Inspiração biológica

Em média, cada neurônio forma entre mil e dez mil sinapses. O cérebro humano possui cerca de 10^{11} neurônios, e o número de sinapses é maior que 10^{14} , possibilitando a formação de redes muito complexa.



- 1940-1950: início das Redes neurais com McCulloch e Pitts
- 1950-1960: Perceptron de aprendizado supervisionado.
- 1960-1970: Pouco avanço
- 1980-2000: Redes simétricas e o Backpropagation

Redes Neurais Artificiais



- Aprendem através de exemplos
- Adaptabilidade
- Capacidade de generalização
- Tolerância a falhas
- Implementação rápida


- Estrutura geral das RNA
 - 1. Unidades de processamento (neurônios)
 - 2. Conexões
 - 3. Topologia

Unidades de processamento n_i (nós)

1. Estado de ativação a_i
2. Função de ativação F_i
3. Função de saída f_i

Unidades de processamento

Objetivo: receber entradas de conjunto de unidades A, computar função sobre entradas e enviar resultado para conjunto de unidades B



Unidades de processamento - Estado de ativação

- ♦ Representa o estado dos neurônios da rede
- ♦ Pode assumir valores
 - Binários (0 e 1)
 - Bipolares (-1 e +1)
 - Reais
- ♦ Definido através de funções de ativação

Unidades de processamento - Funções de ativação

- Processa conjunto de entradas recebidas e o transforma em estado de ativação – Atualiza o estado de ativação do neurônio
- Funções de ativação típicas envolvem:
 - Adições
 - Comparações
 - Transformações matemáticas

■ Funções de ativação mais comuns

- ♦ $a(t + 1) = u(t)$ (linear)
- ♦ $a(t + 1) = \begin{cases} 1, & \text{se } u(t) \geq \theta \\ 0, & \text{se } u(t) < \theta \end{cases}$ (threshold ou limiar)
- ♦ $a(t + 1) = 1/(1 + e^{-\lambda u(t)})$ (sigmoid logística)
- ♦ $a(t + 1) = \frac{(1 - e^{-\lambda u(t)})}{(1 + e^{-\lambda u(t)})}$ (tangente hiperbólica)

■ Função de saída

- ◆ Transforma estado de ativação de uma unidade em seu sinal de saída

$$y_i(t) = f_i(a_i(t))$$

- ◆ Geralmente é uma função identidade

■ Conexões

- Definem como neurônios estão interligados
 - ◆ Nós são conectados entre si através de conexões específicas
- Codificam conhecimento da rede
 - ◆ Uma conexão geralmente tem um valor de ponderamento ou **peso** associada a ela

- Tipos de conexões ($w_{ik}(t)$)
 - ◆ Excitatória: ($w_{ik}(t) > 0$)
 - ◆ Inibitória: ($w_{ik}(t) < 0$)
 - ◆ Conexão inexistente: ($w_{ik}(t) = 0$)

- Número de conexões de um nó
 - ◆ Fan-in: número de conexões de entrada
 - ◆ Fan-out: número de conexões de saída


■ Topologia

■ Número de camadas

- ◆ Uma camada (Ex Perceptron, Adaline)
- ◆ Multi-camadas (Ex MLP)
 - Completamente conectada
 - Parcialmente conectada
 - Localmente conectada



Redes feedforward

- Sinais seguem em uma única direção



Redes recorrentes

- Possuem conexões ligando saída da rede a sua entrada



Aprendizado em RNAs

- Capacidade de aprender a partir de seu ambiente e melhorar sua performance com o tempo
- Parâmetros livres de uma RNA são adaptados através de estímulos fornecidos pelo ambiente
 - ◆ Processo iterativo de ajustes aplicado a sinapses e thresholds
 - ◆ Idealmente, a RNA sabe mais sobre seu ambiente após cada iteração

Aprendizado em RNAs

- RNA deve produzir para cada conjunto de entradas apresentado o conjunto de saídas desejado
 - ♦ $w_{ik}(t+1) = w_{ik}(t) + \Delta w_{ik}(t)$

- Mecanismos de aprendizado
 - ◆ Modificação de pesos ($\Delta w_{ij}(t)$) associados às conexões
 - ◆ Armazenamento de novos valores em conteúdos de memória
 - ◆ Acréscimo e/ou eliminação de conexões/neurônios


Tipos de Aprendizado em RNAs

- Supervisionado
- Não Supervisionado

■ Professor externo

- ◆ Possui conhecimento sobre ambiente
 - Representado por conjunto de pares (x, d)
 - Geralmente, a rede não possui informações prévias sobre ambiente
- ◆ Parâmetros da rede são ajustados por (x, d)
- ◆ Rede procura emular professor

Aprendizado supervisionado




Aprendizado Supervisionado

Aprendizado não supervisionado

- Não tem crítico ou professor externo
- Extração de características estatisticamente relevantes
 - ◆ Cria classes automaticamente

Aprendizado não supervisionado



Aprendizado Não-supervisionado

- Regra Delta (Widrow e Hoff 1960)
- Erro: $e_k(t) = d_k(t) - y_k(t)$
- Minimizar função de custo baseada em $e_k(t)$
- Função de custo
 - ◆ $c(t) = -1/2 \sum e_k^2(t)$
 - ◆ Aprendizado atinge solução estável quando os pesos não precisam mudar muito


- Após seleção da função de custo, aprendizado se torna um problema de otimização
 - ◆ RNA é otimizada pela minimização de $c(t)$ com respeito aos pesos da rede

- Modelo matemático:
 - ◆ $\Delta w_{ik}(t) = \eta e_k(t) x_i(t)$

■ Taxa de aprendizado (η)

- ♦ $0 < \eta < 1$


- ♦ Taxas pequenas



- Média das entradas anteriores
- Estimativas estáveis de peso
- Aprendizado lento

- ♦ Taxas grandes

- ♦ Taxas variáveis



- Captação de mudanças no processo
- Instabilidade

Perceptrons

- Desenvolvido por Rosembat, 1958
- Rede mais simples para classificação de padrões linearmente separáveis
- Utiliza modelo de McCulloch-Pitts como neurônio

■ Estado de ativação

- ◆ 1 = ativo
- ◆ -1 = inativo

■ Função de ativação

- ◆
$$a_i(t + 1) = \begin{cases} -1, & \text{se } u_i(t) < 0 \\ +1, & \text{se } u_i(t) \geq 0 \end{cases}$$

$$u = \sum_{j=1}^N x_j w_j - \theta$$

Perceptrons

- Função de saída = função identidade
- Duas camadas
 - ◆ Camada de pré-processamento
 - M máscaras fixas para extração de características
 - ◆ Camada de discriminação
 - Uma unidade de saída para discriminar padrões de entrada
 - Pesos determinados através de aprendizado

■ Treinamento

- ◆ Supervisionado
- ◆ Correção de erro

- $\Delta w_{ij} = \eta x_i (d_j - y_j)$ $(d \neq y)$
- $\Delta w_{ij} = 0$ $(d = y)$

- ## ■ Teorema de convergência: se é possível classificar um conjunto de entradas, uma rede Perceptron fará a classificação

Algoritmo de treinamento

1) Iniciar todas as conexões com $w_{ij} = 0$;

2) Repita

Para cada par de treinamento (X, d)

Calcular a saída y

Se $(d \neq y)$

Então

Atualizar pesos dos neurônios

Até o erro ser aceitável

Algoritmo de teste

1) Apresentar padrão X a ser reconhecido

2) Calcular a saída y

3) Se $(y = -1)$

Então

$X \in \text{classe } 0$

Senão

$X \in \text{classe } 1$

Exemplo

Dada uma rede do tipo Perceptron formada por um neurônio com três terminais de entrada, utilizando pesos iniciais $w_0 = 0.4$, $w_1 = -0.6$ e $w_2 = 0.6$, limiar $\theta = 0.5$ e uma taxa de aprendizado $= 0.4$, responda os itens abaixo:

- a) Ensinar a rede a gerar a saída -1 para o padrão 001 e a saída +1 para os padrão 110
- b) A que classe pertencem os padrões 111, 000, 100 e 011?

Exemplo 1: resposta a

a) Treinar a rede

a.1) Para o padrão 001 $(d = -1)$

Passo 1: definir a saída da rede

$$u = 0(0.4) + 0(-0.6) + 1(0.6) - 1(0.5) = 0.1$$
$$y = u = +1 \text{ (uma vez } 0.1 \text{ } ^3 0)$$

Passo 2: atualizar os pesos

$$w_0 = 0.4 + 0.4(0)(-1 - (+1)) = 0.4$$

$$w_1 = -0.6 + 0.4(0)(-1 - (+1)) = -0.6$$

$$w_2 = 0.6 + 0.4(1)(-1 - (+1)) = -0.2$$

$$w_3 = 0.5 + 0.4(-1)(-1 - (+1)) = 1.3$$

Exemplo 1: resposta a

a) Treinar a rede

a.2) Para o padrão 110 (d = 1)

Passo 1: definir a saída da rede

$$u = 1(0.4) + 1(-0.6) + 0(-0.2) - 1(1.3) = -1.5$$

$$y = u = -1 \text{ (uma vez } -1.5 < 0 \text{)}$$

Passo 2: atualizar pesos

$$w_0 = 0.4 + 0.4(1)(1 - (-1)) = 1.2$$

$$w_1 = -0.6 + 0.4(1)(1 - (-1)) = 0.2$$

$$w_2 = -0.2 + 0.4(0)(1 - (-1)) = -0.2$$

$$w_3 = 1.3 + 0.4(-1)(1 - (-1)) = 0.5$$

Exemplo 1: resposta a

a) Treinar a rede

a.3) Para o padrão 001 $(d = -1)$

Passo 1: definir a saída da rede

$$u = 0(1.2) + 0(0.2) + 1(-0.2) - 1(0.5) = -0.7$$

$$y = u = -1 \text{ (uma vez } -0.7 < 0)$$

Passo 2: atualizar pesos

Como $d = y$, os pesos não precisam ser modificados

Exemplo 1: resposta a

a) Treinar a rede

a.4) Para o padrão 110 ($d = 1$)

Passo 1: definir a saída da rede

$$u = 1(1.2) + 1(0.2) + 0(-0.2) - 1(0.5) = 0.9$$

$$y = u = 1 \text{ (uma vez } 0.9 \geq 0 \text{)}$$

Passo 2: atualizar pesos

Como $d = y$, os pesos não precisam ser

Exemplo 1: resposta b

b) Testar a rede

b.1) Para o padrão 111

$$u = 1(1.2) + 1(0.2) + 1(-0.2) - 1(0.5) = 0.7$$

$$y = u = 1 \text{ (porque } 0.7 \geq 0 \text{) } \rightarrow \text{classe 1}$$

b.2) Para o padrão 000

$$u = 0(1.2) + 0(0.2) + 0(-0.2) - 1(0.5) = -0.5$$

$$y = u = -1 \text{ (porque } -0.5 < 0 \text{) } \rightarrow \text{classe 0}$$

Exemplo 1: resposta b

b) Testar a rede

b.3) Para o padrão 100

$$u = 1(1.2) + 0(0.2) + 0(-0.2) + 1(-0.5) = 0.7$$

$$y = u = 1 \text{ (porque } 0.7 \geq 0 \text{)} \rightarrow \text{classe 1}$$

b.4) Para o padrão 011

$$u = 0(1.2) + 1(0.2) + 1(-0.2) - 1(0.5) = -0.5$$

$$y = u = -1 \text{ (porque } -0.5 < 0 \text{)} \rightarrow \text{classe 0}$$

- Classificação de padrões
- Clustering/categorização
- Aproximação de funções
- Previsão
- Otimização
- etc...



FUNDAÇÃO UNIVERSIDADE FEDERAL
DO VALE DO SÃO FRANCISCO