

Fundamentos de Inteligência Artificial [5COP099]



Dr. Sylvio Barbon Junior

Departamento de Computação - UEL

Disciplina Anual

Aula 15

Redes Neurais Artificiais (Adaline)

Aula 15 - Redes Neurais Artificiais (Adaline)


Sumário

- Introdução
- Bias (limiar)
- Rede Neural Adaline

Introdução

- A Rede Neural Perceptron, em seus ajustes de peso não é considerada a distância entre a saída e a resposta desejada;
- A Rede Neural Adaline (ADaptive LINEar) foi desenvolvida em 1960 (Widrow e Hoff) e sua principal função era na área de processamento digital de sinais;
- Utiliza o ajuste de erro pela Regra Delta;
- Uma Adaline de várias camadas é chamada Madaline;
- É de arquitetura feedforward;
- Soluciona problemas de **regressão**;

Introdução





Bias (limiar) θ

- O bias (θ), também chamado de viés ou limiar tem a mesma função do intercepto para os modelos de regressão. [representa o ponto em que a reta regressora corta um dos eixos]
- Se uma RNA não faz o uso do bias em uma dada camada não será possível produzir uma saída diferente de 0 quando os atributos forem 0;
- O bias promove flexibilidade ao ajuste da RNA;
- Os valores atribuídos ao bias são normalmente -1 ou 1;
- O peso (w_0) deve ser associado ao bias e ajustado como os outros.

Aula 14 - Redes Neurais Artificiais

Bias (limiar) θ

Funções sigmoides sem (esquerda) e com bias = 1 (direita)



Rede Neural Adaline

- Uma das diferenças com relação à Perceptron é o bloco de verificação de erro, para Perceptron: $erro = d - y$, já para a Adaline $erro = d - u$.
- Assim, para ajustes dos pesos serão utilizados os valores obtidos antes da função de ativação $g(\cdot)$.
- O treinamento é baseado na Regra Delta que tem como núcleo o Gradiente Descendente ou Mínimos Quadrados. Assim espera-se encontrar os pesos e limiar que minimizam a diferença entre d e u em função do Erro Quadrático Médio (EQM).

$$E_{qm}(w) = \frac{1}{p} \sum_{k=1}^p (d^{(k)} - u)^2$$

Rede Neural Adaline


Início {Algoritmo EQM}

- <1> Obter a quantidade de padrões de treinamento $\{p\}$;
- <2> Iniciar a variável E_{qm} com valor zero $\{E_{qm} \leftarrow 0\}$;
- <3> Para todas as amostras de treinamento $\{\mathbf{x}^{(k)}, d^{(k)}\}$, fazer:
 - <3.1> $u \leftarrow \mathbf{w}^T \cdot \mathbf{x}^{(k)}$;
 - <3.2> $E_{qm} \leftarrow E_{qm} + (d^{(k)} - u)^2$;
- <4> $E_{qm} \leftarrow \frac{E_{qm}}{p}$;

Fim {Algoritmo EQM}



Aula 14 - Redes Neurais Artificiais

Rede Neural Adaline





Rede Neural Adaline

Épocas de treinamento para encontrar o melhor Hiperplano.



Rede Neural Adaline

Comparação entre Perceptron e Adaline



Rede Neural Adaline

Início {Algoritmo *Adaline* – Fase de Treinamento}

- <1> Obter o conjunto de amostras de treinamento $\{ \mathbf{x}^{(k)} \}$;
 - <2> Associar a saída desejada $\{ d^{(k)} \}$ para cada amostra obtida;
 - <3> Iniciar o vetor \mathbf{w} com valores aleatórios pequenos;
 - <4> Especificar taxa de aprendizagem $\{ \eta \}$ e precisão requerida $\{ \varepsilon \}$;
 - <5> Iniciar o contador de número de épocas $\{ \text{época} \leftarrow 0 \}$;
 - <6> Repetir as instruções:
 - <6.1> $E_{qm}^{anterior} \leftarrow E_{qm}(\mathbf{w})$;
 - <6.2> Para todas as amostras de treinamento $\{ \mathbf{x}^{(k)}, d^{(k)} \}$, fazer:
 - <6.2.1> $u \leftarrow \mathbf{w}^T \cdot \mathbf{x}^{(k)}$;
 - <6.2.2> $\mathbf{w} \leftarrow \mathbf{w} + \eta \cdot (d^{(k)} - u) \cdot \mathbf{x}^{(k)}$;
 - <6.3> $\text{época} \leftarrow \text{época} + 1$;
 - <6.4> $E_{qm}^{atual} \leftarrow E_{qm}(\mathbf{w})$;
- Até que: $| E_{qm}^{atual} - E_{qm}^{anterior} | \leq \varepsilon$

Fim {Algoritmo *Adaline* – Fase de Treinamento}

Rede Neural Adaline

Início {Algoritmo *Adaline* – Fase de Operação}

- <1> Obter uma amostra a ser classificada $\{ \mathbf{x} \}$;
- <2> Utilizar o vetor \mathbf{w} ajustado durante o treinamento;
- <3> Executar as seguintes instruções:
 - <3.1> $u \leftarrow \mathbf{w}^T \cdot \mathbf{x}$;
 - <3.2> $y \leftarrow \text{sinal}(u)$;
 - <3.3> Se $y = -1$
 - <3.3.1> Então: amostra $\mathbf{x} \in \{Classe A\}$
 - <3.4> Se $y = 1$
 - <3.4.1> Então: amostra $\mathbf{x} \in \{Classe B\}$

Fim {Algoritmo *Adaline* – Fase de Operação}

Referências

1. Coppin, B. Inteligência Artificial. LTC. 2010.
2. Russell, S.; Norvig, P. Artificial Intelligence: a modern approach. Prentice Hall. 2010. Localização: BC – Número de Chamada: 519.683 R967a 3.ed.
3. Luger, G. F. Inteligência Artificial: estruturas e estratégias para a resolução de problemas complexos. Bookman. 2004. Localização: BC – Número de Chamada: 519.683 L951a 4.ed.
4. Carvalho, André, et al. "Inteligência Artificial—uma abordagem de aprendizado de máquina." Rio de Janeiro: LTC (2011).
5. Silva, IN da, Danilo Hernane Spatti, and Rogério Andrade Flauzino. "Redes neurais artificiais para engenharia e ciências aplicadas." São Paulo: Artliber (2010).