3. Aprendizado de RNAs

Prof. Renato Tinós

Depto. de Computação e Matemática (FFCLRP/USP)

3. Aprendizado

3.1. Aprendizado em RNAs

3.2. Tipos de Aprendizado

- Aprendizado Supervisionado
- Aprendizado Não-Supervisionado
- Aprendizado com Avaliação da Qualidade da Solução do Problema

3.3. Estratégias de Aprendizado

- Aprendizado por Correção de Erro
- Aprendizado Competitivo
- Aprendizado Hebbiano
- Aprendizado por Reforço
- Aprendizado Evolutivo

3.1. Aprendizado em RNAs

- **Processo de Aprendizado**

- **Várias definições. Exemplos:**

- » *“Capacidade de aprender a partir de seu ambiente”*

- » *“Melhorar o desempenho em solucionar determinados problemas com o tempo”*

- De acordo com algum critério pré-estabelecido

- Exemplo: redução da soma do erro médio quadrático

3.1. Aprendizado em RNAs

- **Em RNAs**

- *“Aprendizado é um processo pelo qual os parâmetros livres de uma RNA são adaptados através de um processo de estimulação pelo ambiente no qual a RNA está inserida”*

- » Parâmetros livres de uma RNA são geralmente adaptados iterativamente

- Idealmente, uma RNA sabe mais sobre seu ambiente após cada iteração

- Exemplo

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \Delta\mathbf{w}(n)$$

- *“O tipo de aprendizado é determinado pela maneira pela qual a modificação dos parâmetros ocorre”*

3.1. Aprendizado em RNAs

- **Em RNAs**
 - O processo de aprendizado geralmente implica na seguinte sequência de eventos
 1. A RNA é estimulada pelo ambiente
 2. A RNA sofre modificações em seus parâmetros livres como resultado desta estimulação
 3. A RNA reponde de uma nova maneira ao ambiente, devido às modificações ocorridas na sua estrutura interna

3.1. Aprendizado em RNAs

3.2. Tipos de Aprendizado

- **Aprendizado supervisionado**

- Professor externo

- » Possui conhecimento sobre ambiente

- ❑ Representado por conjunto de pares ($\mathbf{x}(n)$, $\mathbf{d}(n)$) utilizados no treinamento, ou seja, as saídas desejadas são conhecidas

- Em outras palavras, os exemplos de treinamento são **rotulados**

- » Geralmente, a RNA não possui informações prévias sobre ambiente

- ❑ Conhecimento *a priori* pode ser inserido

- » Parâmetros da rede são ajustados geralmente através de apresentações sucessivas de pares ($\mathbf{x}(n)$, $\mathbf{d}(n)$)

- ❑ Rede procura reproduzir comportamento do professor

3.2. Tipos de Aprendizizado

- **Aprendizado supervisionado**

3.2. Tipos de Aprendizado

- **Aprendizado não-supervisionado**
 - Não tem professor externo ou crítico
 - » Não se conhece nem as saídas desejadas nem a qualidade da solução do problema
 - Extração de características estatisticamente relevantes dos conjuntos de exemplos
 - Clusterização
 - » Criação de agrupamentos de exemplos
 - Sem classificá-los

3.2. Tipos de Aprendizado

- **Aprendizado não-supervisionado**

3.2. Tipos de Aprendizado

- **Pode se ainda definir uma tipo intermediário entre os aprendizados supervisionado e não supervisionado:**
 - **Aprendizado semi-supervisionado**
 - » Conjunto de treinamento formado por
 - parte dos exemplos **com** saída desejada conhecida (rotulados)
 - parte dos exemplos **sem** saída desejada conhecida (não-rotulados)
 - » Interessante em diversos contextos
 - Rotular é geralmente uma tarefa difícil
 - Muitas aplicações envolvem quantidades massivas de dados (**Big Data**)
 - » Geralmente, utilizam-se técnicas supervisionadas em conjunto com técnicas não-supervisionadas no aprendizado semi-supervisionado

3.2. Tipos de Aprendizado

- Aprendizado semi-supervisionado

3.2. Tipos de Aprendizado

- **Programação neuro-dinâmica**
 - Muitas vezes, é chamada de aprendizado por reforço
 - » Entretanto, o aprendizado por reforço pode ser entendido como uma estratégia e não como um tipo de aprendizado
 - Sem professor
 - » As saídas desejadas não são conhecidas
 - Com um **crítico externo**
 - » Avalia a qualidade da solução do problema
 - Utilizado geralmente em problemas que envolvem agentes inteligentes
 - » Exemplo: robôs e assistentes inteligentes

3.2. Tipos de Aprendizado

- Programação neuro-dinâmica
 - Soluções (ou parte das soluções)
 - » Com qualidade baixa são punidas
 - » Com qualidade alta são recompensadas
 - O algoritmo de aprendizado procura maximizar a qualidade da solução
 - Exemplos de estratégias
 - » Aprendizado por reforço
 - » Aprendizado evolutivo
 - Geralmente é muito mais lento que o aprendizado supervisionado

3.2. Tipos de Aprendizado

- Programação neuro-dinâmica

3.2. Tipos de Aprendizado

Tarefa	Exemplo	Tipos mais comuns
Aproximação	Dado pares ($\mathbf{x}$, $\mathbf{d}$) obtidos em um experimento, aproximar função	Supervisionado
Associação		
Autoassociação	Associar $\mathbf{x}$ com $\mathbf{x}$	Não supervisionado
Heteroassociação	Associar $\mathbf{x}$ com $\mathbf{y}$	Supervisionado
Classificação de padrões	Diagnóstico por computador	Supervisionado
Previsão	Série temporal	Supervisionado
Controle	Jogos com agentes	Programação Neuro-Dinâmica
Clusterização	Associar genes com funções similares	Não supervisionado

3.3. Estratégias de Aprendizado

- **Estratégias de aprendizado**
 - Conjunto de passos e regras utilizadas para a solução de um problema de aprendizado
 - Grande variedade
 - » As vantagens e desvantagens dependem dos problemas a serem solucionados
 - » Geralmente diferem na maneira como os parâmetros livres da RNA são ajustados
 - Exemplo: diferentes regras para o cálculo de $\Delta \mathbf{w}(n)$
 - » Algumas estratégias são apresentadas a seguir

3.3. Estratégias de Aprendizado

- **Aprendizado por correção de erro**
 - Estratégia mais utilizada
 - Baseia-se na correção dos parâmetros livres da RNA de acordo com a minimização do erro computado como a diferença da saída da RNA e a saída desejada apresentada pelo professor
 - » Erro instantâneo da saída k

$$e_k(n) = d_k(n) - y_k(n) \quad (3.1)$$

3.3. Estratégias de Aprendizado

- **Aprendizado por correção de erro**
 - Grafo de fluxo de sinal do neurônio de saída k

3.3. Estratégias de Aprendizado

- **Aprendizado por correção de erro**
 - Os ajustes nos parâmetros livres são projetados para aproximar passo a passo a saída da RNA da saída desejada
 - Este objetivo é alcançado minimizando-se uma função de custo baseada em $e_k(n)$
 - » Valor instantâneo da energia do erro

$$E(n) = \frac{1}{2} \sum_k e_k^2(n) \quad (3.2)$$

3.3. Estratégias de Aprendizado

- **Aprendizado por correção de erro**
 - Após seleção da função de custo, o aprendizado torna-se um problema de otimização
 - Considerando que a superfície de erro é um parabolóide (com um único mínimo), podemos utilizar uma **técnica de otimização baseada no cálculo do gradiente**
 - » Em cada instante

$$\Delta w_{kj}(n) = -\eta \nabla E(n) \quad (3.3)$$

na qual w_{kj} é o peso sináptico do neurônio k excitado pelo elemento j do vetor $\mathbf{x}$

3.3. Estratégias de Aprendizado

Superfície de Erro

3.3. Estratégias de Aprendizado

- **Aprendizado por correção de erro**
 - A minimização da função de custo dada pela Eq. (3.2) em relação aos parâmetros livres da rede resulta na **regra Delta** ou regra de Widrow e Hoff.

» Ex.: para um único neurônio com ativação linear:

$$\Delta w_{kj}(n) = \eta e_k(n) x_j(n) \quad (3.4)$$

A regra Delta pode ser formulada como

» “o ajuste feito em um peso sináptico é proporcional ao produto do sinal de erro pelo sinal de entrada da sinapse”

3.3. Estratégias de Aprendizado

- **Aprendizado Hebbiano**

- Regra mais antiga e conhecida, proposta pelo neuropsicólogo D. O. Hebb em 1949
- Se dois neurônios estão simultaneamente ativos, a conexão entre eles deve ser fortalecida
- Regra modificada (sinapse Hebbiana)
 - » Dois neurônios são ativados sincronamente, força da sinapse deve ser aumentada
 - » Dois neurônios são ativados assincronamente, força da sinapse deve ser reduzida

3.3. Estratégias de Aprendizado

• Aprendizado Hebbiano

- Regra mais antiga e conhecida, proposta pelo neuropsicólogo D. O. Hebb em 1949:
 - » *“Quando um axônio da célula A está perto o suficiente para excitar uma célula B e participa do seu disparo repetida e persistentemente, então algum processo de crescimento ou modificação metabólica acontece em uma das células ou em ambas, de tal forma que a eficiência de A como uma das células que dispara B é aumentada”*
- Pode-se reformulá-la como
 1. Se dois neurônios estão simultaneamente ativos, então a conexão entre eles é fortalecida
 2. Se dois neurônios são ativados assincronamente, então a conexão entre eles é reduzida

3.3. Estratégias de Aprendizado

- **Aprendizado Hebbiano**

- A forma geral do aprendizado Hebbiano é

$$\Delta w_{kj}(n) = F(y_k(n), x_j(n)) \quad (3.5)$$

- Sendo que na forma mais simples (conhecida como hipótese de Hebb), a função $F(.)$ é linear, ou seja

$$\Delta w_{kj}(n) = \eta y_k(n) x_j(n) \quad (3.6)$$

3.3. Estratégias de Aprendizado

- **Aprendizado Hebbiano**

- A Eq. (3.6) resulta em um crescimento exponencial de Δw_{kj} que pode levar a saturação se o sinal de entrada é aplicado repetidas vezes. Este problema pode ser superado se utilizarmos a hipótese da covariância dada por

$$\Delta w_{kj}(n) = \eta (y_k(n) - \bar{y})(x_j(n) - \bar{x}) \quad (3.7)$$

sendo $\bar{x}$ e $\bar{y}$ os valores médios que determinam os limiares pré e pós-sináptico

3.3. Estratégias de Aprendizado

- **Aprendizado Competitivo**
 - Neste aprendizado, neurônios competem entre si para se tornarem ativos
 - » Apenas um neurônio se torna ativo
 - Adequado para descobrir características estatisticamente salientes
 - » Podem ser usadas para classificar conjuntos de entradas

3.3. Estratégias de Aprendizado

- **Aprendizado Competitivo**
 - Elementos básicos
 - » Conjunto de neurônios iguais (exceto por alguns pesos aleatoriamente distribuídos)
 - » Limite no poder de cada neurônio
 - » Mecanismo que permita neurônios competirem pelo direito de responder a um dado subconjunto de entradas
 - Apenas um neurônio se torna ativo em um determinado instante
 - Vencedor leva tudo (*winner-takes-all*)
 - Neurônios individuais se especializam em conjuntos de padrões semelhantes

3.3. Estratégias de Aprendizado

- **Aprendizado Competitivo**

- **Arquitetura mais simples**

- » Uma camada de neurônios completamente conectados à entrada (excitatória)

- » Conexões laterais entre neurônios (inibitórias)

- » Pesos normalizados

$$\sum w_{kj}^2(n) = 1 \quad (\text{para todo neurônio } k)$$

- » Regra de aprendizagem competitiva

$$\Delta w_{kj} \begin{cases} \eta (x_j - w_{kj}) & \text{se o neurônio } k \text{ vencer a competição} \\ 0 & \text{caso contrário} \end{cases} \quad (3.8)$$

3.3. Estratégias de Aprendizado

- **Aprendizado Competitivo**

- **Exemplo**

$$y_k = \begin{cases} 1 & \text{se } u_k > u_l \text{ para todo } l, l \neq k \\ 0 & \text{caso contrário} \end{cases} \quad (3.9)$$

Sendo u_k a ativação interna do neurônio k

3.3. Estratégias de Aprendizado

- **Aprendizado por reforço**
 - Utilizado em problemas que envolvam aprendizado direcionada à meta e à tomada de decisão
 - Tem raízes na teorias do aprendizado dos animais
 - Enfatiza a interação de um **agente** com o ambiente
 - » Geralmente, o agente não conhece *a priori* o seu meio ambiente

3.3. Estratégias de Aprendizado

- **Aprendizado por reforço**

- **Agente**

- » Entidade que percebe o seu meio ambiente (através de sensores) e age sobre este meio ambiente (através de atuadores)

- Exemplo:

- Animais

- Robôs

- Agente de Software

- » Possui programas que definem como ele interage com o meio ambiente

3.3. Estratégias de Aprendizado

- **Aprendizado por reforço**
 - Não utiliza o conceito do professor
 - » Ou seja, não se sabe *a priori* quais são as ações que devem ser tomadas (saídas desejadas)
 - Utiliza uma informação sobre a qualidade da ações (**sinal de reforço**) obtida através de um **Crítico**
 - » Esta informação pode ser do tipo punição ou recompensa para determinados estados
 - Exemplo
 - Estado meta
 - Obstáculo

3.3. Estratégias de Aprendizado

- **Aprendizado por reforço**

3.3. Estratégias de Aprendizado

- **Aprendizado por reforço**
 - **Sinal de Reforço**
 - » É utilizado para definir as ações do agente
 - Exemplo: modifica os pesos de uma RNA
 - » É atualizado pelo crítico de acordo com avaliação da solução obtida
 - **Objetivo**
 - » Maximizar os sinais de reforço obtidos
 - Otimizando assim a solução para um determinado problema

3.3. Estratégias de Aprendizado

- **Aprendizado por reforço**

- **Exemplo**

» Busca de um caminho ótimo por um robô

-0.04	0.08	0.21	+1
-0.16	Obstáculo	-0.44	-1
-0.29	-0.42	-0.54	-0.77

3.3. Estratégias de Aprendizado

- **Aprendizado evolutivo**

- Utiliza algoritmos evolutivos, e.g., **algoritmos genéticos**, para o aprendizado (otimização) dos parâmetros da rede neural
- Algoritmos genéticos utilizam conceitos de evolução por seleção natural em problemas de otimização
 - » Parâmetros são codificados em um vetor (**cromossomo**) de uma solução (**indivíduo**)
 - Solução: rede neural
 - » Considera um conjunto de indivíduos (**população**)
 - » Indivíduos (redes neurais) são avaliados
 - Qualidade da solução é avaliada
 - » Indivíduos mais aptos tem maior chance de sobreviver (i.e., ir para próxima população)
 - » Indivíduos são transformados, geralmente por **recombinação e mutação**

3.3. Estratégias de Aprendizado

- Algoritmo Genético

3.3. Estratégias de Aprendizado

Algoritmo Genético

Início

$t \leftarrow 1$

inicializePopulacao($\mathbf{P}_t$)

avaliePopulacao($\mathbf{P}_t$)

enquanto (criterioConvergencia == 0)

$\mathbf{P}_{t+1} \leftarrow \text{selecao}(\mathbf{P}_t)$

$\mathbf{P}_{t+1} \leftarrow \text{transformePopulacao}(\mathbf{P}_{t+1})$

avaliePopulacao($\mathbf{P}_{t+1}$)

$t \leftarrow t + 1$

fim enquanto

Fim

3.3. Estratégias de Aprendizado

Exemplos.

1) Robôs Evolutivos

3.3. Estratégias de Aprendizado

Exemplos: 2) Jogos

<https://www.youtube.com/watch?v=qv6UVOQ0F44&feature=youtu.be>

- **Referências**

- **Haykin, S. S.. *Redes neurais: princípios e prática*. 2ª ed., Bookman, 2001.**
 - » Capítulo 2
- **Braga, A.P.; Carvalho, C.P.L.F. & Ludermir, T.B.. *Redes neurais artificiais: Teoria e Aplicações*. LTC, 2000.**
 - Capítulo 2