

Capítulo 2

Processos de Aprendizado

A propriedade mais significativa de uma Rede Neural Artificial é certamente a habilidade de aprender a partir do seu ambiente e melhorar seu desempenho através do aprendizado.

A melhora no desempenho de uma RNA ocorre ao longo do aprendizado, de acordo com critérios específicos adotados para atingir tal propósito.

O problema do aprendizado em RNAs é simplesmente o problema de encontrar, através de um processo interativo (relativo a uma aplicação na qual cada entrada provoca uma resposta) e iterativo (reiterado) um conjunto de parâmetros livres que possibilite à rede o desempenho desejado. Visto de uma forma ideal, o conhecimento de uma RNA sobre o ambiente em que está inserida deve aumentar a cada iteração do processo de aprendizagem.

Uma interessante definição de aprendizado no contexto de redes neurais é apresentada por Haykin em [3]:

Aprendizagem é um processo pelo qual os parâmetros livres de uma RNA são adaptados através de um processo de estimulação do ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela forma através da qual é efetuada a mudança nos parâmetros.

Esta definição implica nos seguintes eventos seqüenciais:

1. A rede é estimulada pelo ambiente;
2. A rede sofre mudanças nos seus parâmetros livres como resultado deste estímulo;
3. A rede responde de uma forma nova ao ambiente devido às mudanças que ocorreram em sua estrutura interna.

Um algoritmo de aprendizagem é um conjunto de regras definidas para a solução do problema de aprendizado. Vários algoritmos de aprendizagem são utilizados no projeto de RNAs, cada um deles possuindo características e vantagens específicas.

As duas formas básicas de aprendizagem (referidas na literatura específica de RNAs como paradigmas de aprendizagem) são: o aprendizado através de um tutor (aprendizado supervisionado) e o aprendizado sem um tutor (aprendizado não-supervisionado). Há ainda uma terceira forma de aprendizagem que utiliza um crítico (ou juiz) e é chamada aprendizagem por reforço.

2.1 Aprendizado Supervisionado

O aprendizado supervisionado é o aprendizado obtido por meio de um tutor. A Figura 2.1 apresenta o diagrama de blocos representativo deste tipo de aprendizado. O tutor detém o conhecimento do ambiente, o qual a rede neural desconhece. Um conjunto de exemplos entrada/saída representa este conhecimento.

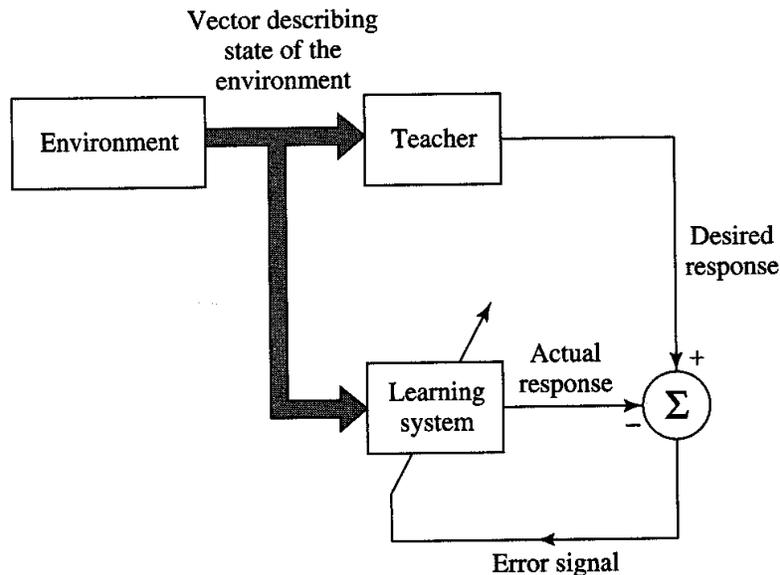


Figura 2.1: Diagrama de Blocos representativo do aprendizado por meio de um tutor.

No processo de construção do conhecimento, a RNA é exposta a um vetor de treino extraído do ambiente e o tutor provê à rede uma resposta desejada para este específico vetor de treino.

A resposta desejada é, portanto, o resultado ótimo que a rede deveria apresentar para aquele determinado vetor do conjunto de treino.

Os parâmetros da rede são ajustados de forma iterativa, passo a passo, através da influência combinada do vetor de treino e do sinal de erro. O sinal de erro é definido como a diferença entre a resposta desejada e a resposta efetivamente obtida da rede. Desta forma, o quanto possível do conhecimento do ambiente disponível ao tutor é transferido para a RNA, durante o treinamento. Quando esta condição é atingida, o tutor é dispensado e a rede passa a lidar com o ambiente por si só.

O processo acima descrito define o Aprendizado por Correção do Erro que iremos tratar na Seção 2.1.2 deste Capítulo. O sistema possui um elo fechado de realimentação (*closed-loop feedback*), mas o ambiente desconhecido não faz parte do elo.

Como forma de avaliar o desempenho de tal sistema pode-se considerar o erro médio quadrático (MSE: *Mean Square Error*) ou a soma dos erros quadráticos sobre o conjunto de treino, definida como uma função dos parâmetros livres do sistema.

2.1.1 Superfícies de Erro

A função dos parâmetros livres do sistema utilizada para avaliar sua performance pode ser vista como uma superfície de desempenho de erro multidimensional (denominada simplesmente Superfície de Erro), tendo os parâmetros livres como coordenadas. A superfície de erro, na verdade, é uma superfície média sobre todos os possíveis exemplos entrada/saída.

Qualquer operação do sistema sob a supervisão do tutor é representada como um ponto sobre a superfície de erro.

Para que o sistema melhore seu desempenho ao longo do tempo e, portanto, aprenda a partir do tutor, o ponto de operação tem que se mover sucessivamente em direção ao ponto de mínimo da superfície de erro.

Uma característica extremamente importante a observar é que este ponto de mínimo pode ser um ponto de mínimo local ou um ponto de mínimo global, conforme ilustrado na Figura 2.2.

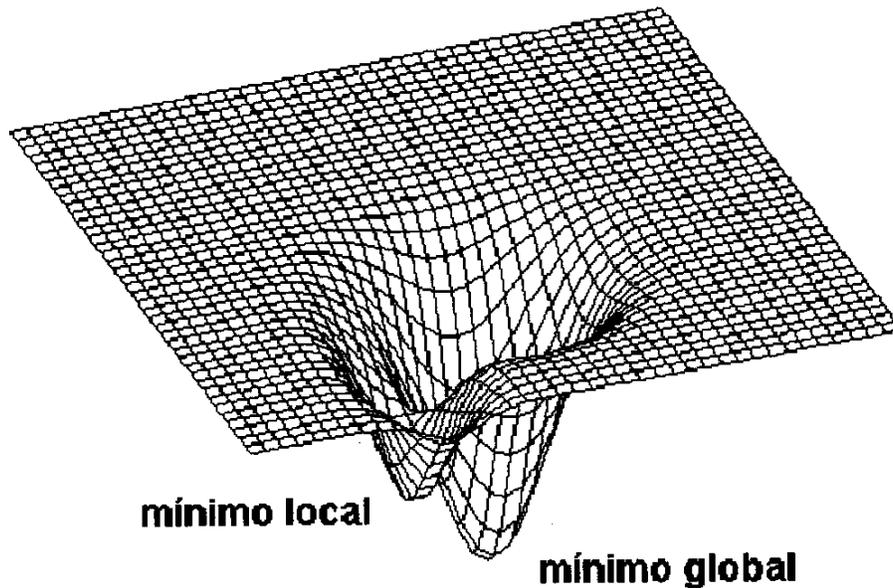


Figura 2.2: Superfície de Erro apresentando um ponto de mínimo local e um ponto de mínimo global.

Na elaboração de algoritmos para treinamento de RNAs é necessário que sejam tomados alguns cuidados para que o ponto de operação não fique preso em um mínimo local. Tal fato irá comprometer o desempenho do algoritmo, pois mascara o resultado, fazendo parecer que foi encontrado o desejado mínimo global. Artifícios para escapar desta armadilha serão comentados ao longo dos próximos capítulos.

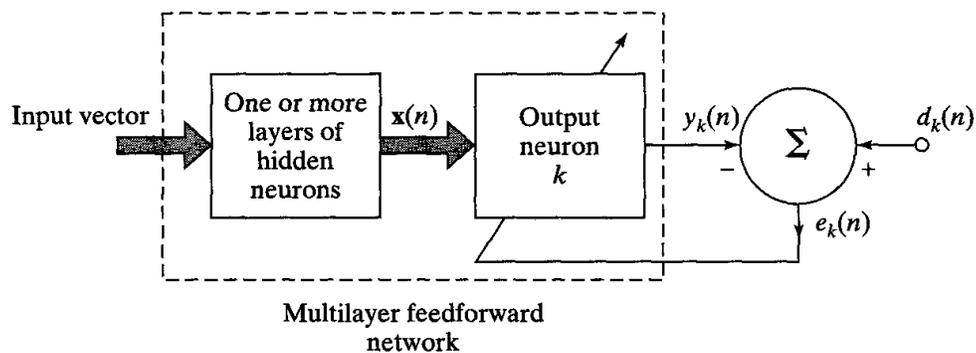
Um sistema de aprendizado supervisionado executa esta operação (descer em direção ao ponto de mínimo) a partir da informação do gradiente da superfície de erro associada ao comportamento do sistema. O gradiente de uma superfície de erro em qualquer ponto é o vetor que, partindo deste ponto, aponta na direção de descida mais íngreme (*steepest descent*).

Existindo um algoritmo adequadamente projetado para minimizar a função de custo, um apropriado conjunto de exemplos entrada/saída e tempo suficiente para o

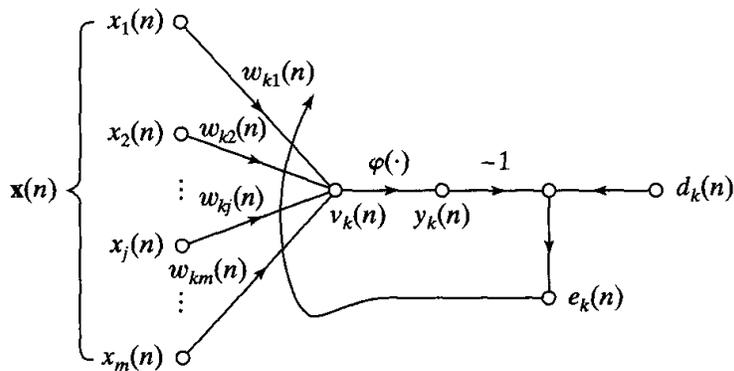
treinamento, um sistema supervisionado de aprendizado é usualmente capaz de desempenhar tarefas como classificação de padrões e aproximação de funções.

2.1.2 Aprendizado por Correção do Erro

Consideremos o caso simples de um neurônio k constituindo o único nó computacional na camada de saída de uma RNA progressiva, conforme mostrado na Figura 2.3 (a).



(a) Block diagram of a neural network, highlighting the only neuron in the output layer



(b) Signal-flow graph of output neuron

Figura 2.3: Aprendizado por correção de erro.

O neurônio k é estimulado por um vetor de sinais $\underline{x}(n)$ produzido por uma ou mais camadas de neurônios escondidos, que são, por sua vez, estimuladas por um vetor de entrada aplicado aos nós fonte da camada de entrada da RNA. O argumento n denota tempo

discreto, ou seja, o passo temporal de um processo iterativo envolvido em ajustar os pesos sinápticos do neurônio k . O sinal de saída do neurônio k é denotado por $y_k(n)$. Este sinal de saída (representando a única saída da RNA) é comparado a uma "resposta desejada" ou "saída alvo", denotada por $d_k(n)$. Conseqüentemente, um sinal de erro, denotado por $e_k(n)$, é produzido. Assim, teremos,

$$e_k(n) = d_k(n) - y_k(n) \quad (2.1)$$

O sinal de erro $e_k(n)$ aciona um "mecanismo de controle" cujo propósito é aplicar uma seqüência de ajustes corretivos aos pesos sinápticos do neurônio k . Os ajustes corretivos são projetados para aproximar, passo a passo, o sinal de saída $y_k(n)$ da resposta desejada $d_k(n)$. Este objetivo é atingido através da minimização de uma "função de custo" também chamada "índice de desempenho", $J(n)$, definida em termos do sinal de erro $e_k(n)$ como:

$$J(n) = \frac{1}{2} e_k^2(n) \quad (2.2)$$

Observando-se a Equação (2.2) pode-se dizer que $J(n)$ é o valor instantâneo da energia do erro.

Os ajustes passo a passo dos pesos sinápticos do neurônio k continuam até que o sistema tenha atingido um estado estável, ou seja, os pesos sinápticos tenham estabilizado. Neste momento o processo de aprendizagem está concluído.

A minimização da função de custo $J(n)$ conduz a uma regra de aprendizagem comumente referida como Regra Delta ou Regra de Widrow-Hoff. Seja $w_{kj}(n)$ o valor do peso sináptico w_{kj} do neurônio k excitado pelo elemento $x_j(n)$ do vetor de sinais $\underline{x}(n)$ no instante de tempo n . De acordo com a Regra Delta, o ajuste $\Delta w_{kj}(n)$ a ser aplicado ao peso sináptico w_{kj} no instante de tempo n é definido por

$$\Delta w_{kj}(n) = \eta e_k(n) x_j(n) \quad (2.3)$$

onde o parâmetro η é uma constante positiva que determina a razão de aprendizado à medida que evoluímos de um passo a outro no processo de aprendizagem.

A Regra Delta pode ser assim expressa:

O ajuste feito a um peso sináptico de um neurônio é proporcional ao produto do sinal de erro pelo sinal de entrada da sinapse em questão.

A Regra Delta presume que o sinal de erro seja diretamente mensurável, ou seja, é necessário que tenhamos uma forma de suprir a resposta desejada, a partir de alguma fonte externa, que tenha acesso direto ao neurônio k (conforme pode ser observado na Figura 2.3(a)). A partir da mesma figura também se pode observar que o aprendizado por correção de erro é, por natureza, local. Ou seja, os ajustes sinápticos feitos pela Regra Delta são localizados ao redor do neurônio k .

Tendo computado o ajuste sináptico $\Delta w_{kj}(n)$, o valor atualizado do peso sináptico w_{kj} é determinado por

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}(n) \quad (2.4)$$

onde $w_{kj}(n)$ e $w_{kj}(n+1)$ podem ser vistos, respectivamente, como o valor antigo e o valor novo (atualizado) do peso sináptico w_{kj} .

A Figura 2.3(b) mostra o grafo de fluxo de sinal representativo do processo de aprendizado por correção de erro, focando a atividade ao redor do neurônio k . O sinal de entrada x_j e o potencial de ativação v_k do neurônio k são chamados, respectivamente, de sinais pré-sináptico e pós-sináptico da j -ésima sinapse do neurônio k .

Ainda observando a Figura 2.3(b) pode-se verificar que o processo de aprendizado por correção de erro é um exemplo de um sistema realimentado de elo fechado (*closed-loop feedback*) e, portanto, a estabilidade de tal sistema é determinada pelos parâmetros que constituem os elos de realimentação do sistema. No único elo fechado de realimentação existente no processo, um parâmetro de particular interesse é o parâmetro razão de

aprendizagem η . Portanto, para que seja atingida a estabilidade ou convergência do processo de aprendizagem iterativo é preciso garantir que η seja cuidadosamente selecionado. Na prática, o parâmetro η representa um papel importante na determinação do desempenho do processo de aprendizagem por correção de erro. Em capítulos posteriores teremos a oportunidade de abordar critérios para a escolha adequada do parâmetro razão de aprendizado.

2.2 Aprendizado por Reforço.

Consideremos agora um tipo de aprendizado em que não é utilizado um tutor, como no aprendizado supervisionado, mas sim um crítico (ou juiz). Neste tipo de aprendizado (denominado aprendizado por reforço), o aprendizado de um mapeamento entrada/saída é desempenhado através da interação continuada com o ambiente buscando minimizar um índice escalar de desempenho.

A Figura 2.4 mostra o diagrama de blocos de uma forma de sistema de aprendizagem por reforço, construído em torno de um crítico que converte um sinal de reforço primário recebido do ambiente em um sinal de reforço de maior qualidade chamado "sinal de reforço heurístico", ambos escalares.

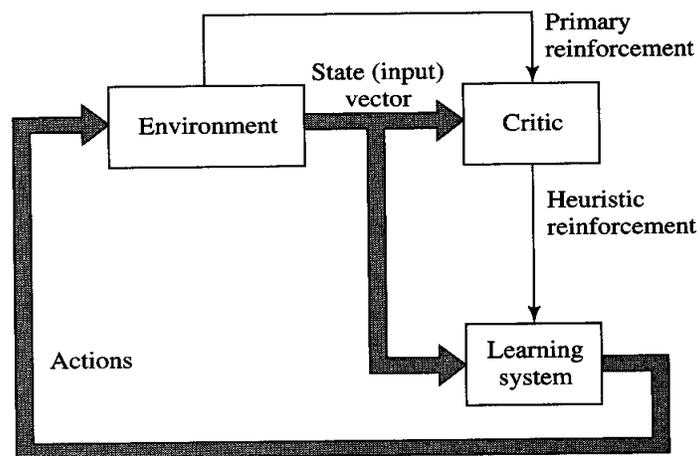


Figura 2.4: Diagrama de blocos do aprendizado por reforço.

Basicamente, o sistema é projetado para aprender a partir de um reforço atrasado, o que significa que o sistema observa uma seqüência temporal de estímulos (também recebida do ambiente), a qual pode resultar na generalização do sinal de reforço heurístico. Em conseqüência, busca-se minimizar uma função de custo que é dada pelo valor esperado do custo cumulativo das ações tomadas sobre uma seqüência de passos, ao invés de simplesmente minimizar o custo imediato.

A importância do aprendizado por reforço é que ele provê as bases para o sistema interagir com o ambiente e, por meio disso, desenvolver a habilidade de aprender a desempenhar uma tarefa prescrita, somente com base nas saídas da sua própria experiência, resultante da interação.

2.3 Aprendizado Não-Supervisionado.

Em algoritmos de aprendizado não-supervisionado ou auto-organizado (como são freqüentemente referidos na literatura de RNAs) não há um tutor externo ou crítico para supervisionar o processo de aprendizado, como indica o diagrama de blocos mostrado na Figura 2.5. Dito de outra forma, algoritmos de aprendizado não-supervisionado não requerem o conhecimento de saídas desejadas, ou seja, não são utilizados exemplos entrada/saída a serem aprendidos pela rede.

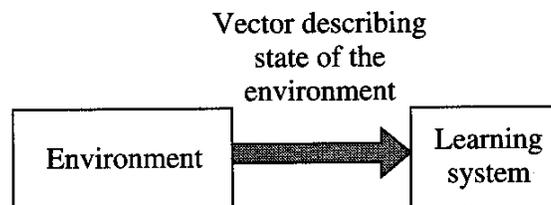


Figura 2.5: Diagrama de blocos do aprendizado não-supervisionado.

Durante o treinamento, somente padrões de entrada são apresentados à RNA até que a rede se torne "sintonizada" às regularidades estatísticas dos dados de entrada. A partir

desta condição, a rede desenvolve a habilidade de formar representações internas para codificar características da entrada (por exemplo, adaptar os pesos de suas conexões para representar os padrões de entrada) e, por meio disto, agrupar os padrões de entrada em grupos com características similares ou criar novos grupos automaticamente.

2.3.1 Aprendizado Baseado em Memória

No aprendizado baseado em memória, todas (ou a maior parte) das experiências passadas são explicitamente armazenadas em uma grande memória de exemplos entrada/saída corretamente classificados: $\{(\underline{x}_i, d_i)\}_{i=1}^N$, onde \underline{x}_i denota um vetor de entrada e d_i denota a correspondente resposta desejada (a resposta desejada foi considerada escalar, podendo, no entanto, ser vetorial).

Por exemplo, em um problema de classificação de padrões binário há duas classes ou hipóteses, denotadas por C_1 e C_2 , a serem consideradas. Neste exemplo, a resposta desejada d_i assume o valor zero (ou -1) para a classe C_1 e o valor 1 para a classe C_2 . Quando desejarmos classificar um vetor teste $\underline{x}_{\text{teste}}$ nunca antes conhecido, o algoritmo irá responder recuperando e analisando os dados de treino em uma vizinhança local de $\underline{x}_{\text{teste}}$.

Todos os algoritmos de aprendizagem baseados em memória envolvem dois ingredientes essenciais:

- Um critério usado para definir a vizinhança local do vetor de teste $\underline{x}_{\text{teste}}$.
- Uma regra de aprendizagem aplicada aos exemplos de treino na vizinhança local de $\underline{x}_{\text{teste}}$.

Os algoritmos de aprendizado diferem na maneira pela qual estes dois ingredientes são definidos. A seguir são descritas duas heurísticas de aprendizagem baseadas em memória: a regra do vizinho mais próximo (*nearest neighbor rule*) e uma variante desta regra chamada classificador dos k -vizinhos mais próximos (*k-nearest neighbor classifier*).

i) Classificador pela regra do vizinho mais próximo
(*nearest neighbor rule*):

A vizinhança local é definida como o exemplo de treino que está localizado na vizinhança imediata do vetor de teste $\underline{x}_{\text{teste}}$. Em sua definição matemática, a regra pode ser escrita como: o vetor

$$\underline{x}'_N \in \{\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N\} \quad (2.5)$$

é dito estar na vizinhança mais próxima de $\underline{x}_{\text{teste}}$ se

$$\min_i d(\underline{x}_i, \underline{x}_{\text{teste}}) = d(\underline{x}'_N, \underline{x}_{\text{teste}}) \quad (2.6)$$

onde $d(\underline{x}_i, \underline{x}_{\text{teste}})$ é a distância Euclidiana entre os vetores \underline{x}_i e $\underline{x}_{\text{teste}}$. A classe associada com a distância mínima, ou seja, o vetor \underline{x}'_N , é reportado como a classificação de $\underline{x}_{\text{teste}}$. Esta regra é independente da distribuição subjacente responsável pela geração dos exemplos de treino.

ii) Classificador pela regra dos k-vizinhos mais próximos
(*k-nearest neighbor classifier*):

Uma variante do classificador pela regra do vizinho mais próximo (*nearest neighbor rule*) é o classificador dos k -vizinhos mais próximos (*k-nearest neighbor classifier*), cujo procedimento é assim definido:

- Identificar os k padrões classificados que estejam mais proximamente localizados ao vetor teste $\underline{x}_{\text{teste}}$ para algum inteiro k .
- Atribuir $\underline{x}_{\text{teste}}$ à classe (hipótese) que é mais frequentemente representada nos k vizinhos mais próximos a $\underline{x}_{\text{teste}}$ (isto é, a classificação é feita pelo "voto da maioria").

Assim, o classificador dos k -vizinhos mais próximos atua como um "dispositivo que calcula a média". Em particular, o classificador discrimina contra um elemento "estranho" presente na vizinhança, conforme ilustrado na Figura 2.6 para $k = 3$. Um elemento

"estranho" é uma observação que é improvavelmente grande para um modelo nominal de interesse.

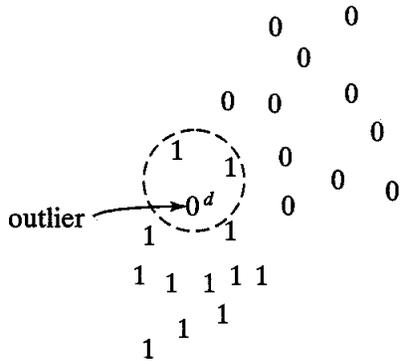


Figura 2.6: A área dentro do círculo tracejado inclui dois pontos pertencentes à classe 1 e um ponto "estranho" pertencente à classe 0. O ponto d corresponde ao vetor de teste $\underline{x}_{\text{teste}}$. Com $k = 3$, o classificador dos 3-vizinhos mais próximos atribui classe 1 ao ponto d embora ele esteja mais próximo do elemento "estranho" (a maioria vence).

Um interessante e muito importante exemplo de classificador baseado em memória é a rede neural do tipo *Radial-Basis Function*, que será estudada em capítulo posterior.

2.3.2 Aprendizado Hebbiano

O postulado de aprendizado de Hebb é a mais velha e mais famosa de todas as regras de aprendizagem:

Quando um axônio de uma célula A está próximo o suficiente para excitar uma célula B e repetidamente ou persistentemente participa de sua ativação, algum processo de crescimento ou alteração metabólica acontece em uma ou ambas as células, tal que a eficiência de A como uma das células que ativa B é aumentada.

Esta afirmação é feita por Hebb no contexto da neurobiologia, como uma base do aprendizado associativo a nível celular. O aprendizado associativo pode resultar em uma modificação duradoura no padrão de atividade de um conjunto de células nervosas espacialmente distribuído.

Expandindo o postulado de Hebb em duas regras:

1. Se dois neurônios em cada um dos lados da sinapse (conexão) são ativados simultaneamente (isto é, sincronamente), então a força daquela sinapse é seletivamente aumentada.
2. Se dois neurônios em cada um dos lados da sinapse são ativados de forma assíncrona, então aquela sinapse é seletivamente enfraquecida ou eliminada.

Uma sinapse com tais características é chamada de sinapse Hebbiana. Mais precisamente, uma sinapse Hebbiana é definida como uma sinapse que usa um mecanismo dependente do tempo, altamente localizado, e fortemente interativo para aumentar a eficiência sináptica como uma função da correlação entre as atividades pré-sinápticas e pós-sinápticas. A partir desta definição pode-se deduzir as quatro propriedades principais que caracterizam uma sinapse Hebbiana:

1. Mecanismo dependente do tempo:

As modificações em uma sinapse Hebbiana dependem do tempo exato da ocorrência dos sinais pré-sinápticos e pós-sinápticos.

2. Mecanismo localizado:

Pela sua natureza, uma sinapse é o local de transmissão onde os sinais de informação que chegam (representando atividade nas unidades pré-sinápticas e pós-sinápticas) estão em contiguidade espaço-temporal. Esta informação localmente disponível é usada por uma sinapse Hebbiana para produzir uma modificação sináptica local.

3. Mecanismo Interativo:

A ocorrência de uma mudança em uma sinapse Hebbiana depende dos sinais em ambos os lados da sinapse, ou seja, entre sinais pré-sinápticos e pós-sinápticos. Sinais pré-sinápticos e pós-sinápticos não coincidentes produzem depressão sináptica.

4. Mecanismo Conjuncional ou Correlacional:

A co-ocorrência de sinais pré-sinápticos e pós-sinápticos dentro de um curto intervalo de tempo é suficiente para produzir a modificação sináptica. Por esta razão a sinapse Hebbiana é algumas vezes referida como uma sinapse conjuncional.

A sinapse Hebbiana também pode ser caracterizada em termos estatísticos. Em particular, a correlação temporal entre sinais pré-sinápticos e pós-sinápticos é vista como sendo responsável pela mudança sináptica. Por isso, a sinapse Hebbiana é também referida como uma sinapse correlacional.

Fortalecimento Sináptico:

Atividade positivamente correlacionada produz reforço na sinapse.

Depressão Sináptica:

Atividade não correlacionada ou negativamente correlacionada produz enfraquecimento na sinapse.

Para formular o aprendizado Hebbiano em termos matemáticos, consideremos um peso sináptico w_{kj} do neurônio k com sinais pré-sinápticos e pós-sinápticos denotados por x_j e y_k , respectivamente. O ajuste aplicado ao peso sináptico w_{kj} no intervalo de tempo n é expresso na forma geral

$$\Delta w_{kj}(n) = F(y_k(n), x_j(n)) \quad (2.7)$$

onde $F(\cdot, \cdot)$ é uma função de ambos sinais pré-sinápticos e pós-sinápticos. (Os sinais $x_j(n)$ e $y_k(n)$ são freqüentemente tratados como adimensionais.)

A seguir apresentaremos duas formas (ambas Hebbianas) para a Expressão (2.7). A primeira delas é baseada na hipótese de Hebb e a segunda, na hipótese da covariância.

a) Hipótese de Hebb

A forma mais simples de aprendizado Hebbiano é descrita por

$$\Delta w_{kj}(n) = \eta y_k(n) x_j(n) \quad (2.8)$$

onde o parâmetro η é uma constante positiva que determina a razão de aprendizado. A Equação (2.8) enfatiza a natureza correlacional da sinapse Hebbiana.

A curva superior da Figura 2.7 mostra uma representação gráfica da Equação (2.8) com a mudança no peso $\Delta w_{kj}(n)$ plotada versus o sinal de saída (atividade pós-sináptica) y_k . Pode ser observado que a aplicação repetida do sinal de entrada (atividade pré-sináptica) x_j leva a um aumento em y_k e, portanto, a um crescimento exponencial que leva a conexão sináptica à saturação, ponto em que nenhuma informação será armazenada na sinapse e a seletividade é perdida.

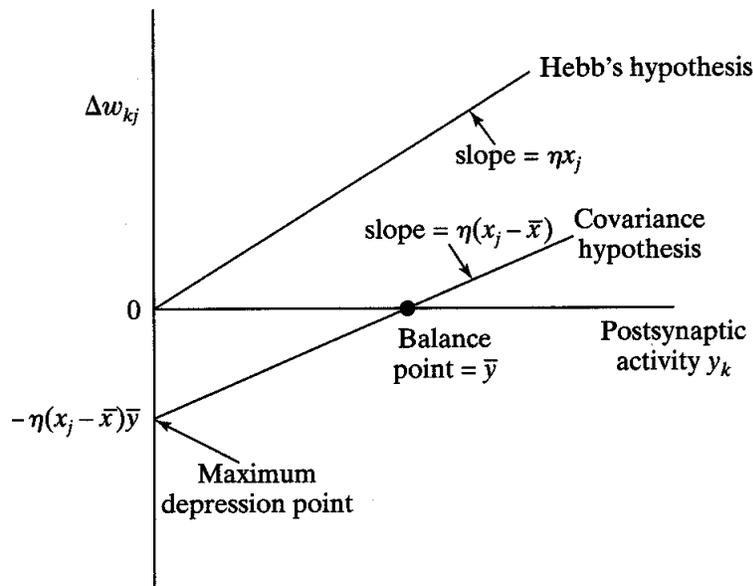


Figura 2.7: Ilustração da hipótese de Hebb e da hipótese da covariância.

b) Hipótese da Covariância

Uma forma de superar a limitação da hipótese de Hebb é utilizar a hipótese da Covariância, em que os sinais pré-sinápticos e pós-sinápticos na Equação (2.8) são substituídos pelos sinais pré-sinápticos e pós-sinápticos dos quais foram retirados seus respectivos valores médios sobre um determinado intervalo de tempo. Sejam \bar{x} e \bar{y} os valores médios referidos dos sinais pré-sinápticos e pós-sinápticos x_j e y_k , respectivamente. De acordo com a hipótese da covariância, o ajuste aplicado ao peso sináptico w_{kj} é definido por

$$\Delta w_{kj} = \eta(x_j - \bar{x})(y_k - \bar{y}) \quad (2.9)$$

onde η é o parâmetro razão de aprendizado. Os valores médios \bar{x} e \bar{y} constituem limiares pré-sinápticos e pós-sinápticos, os quais determinam o sinal da modificação sináptica.

A Figura 2.7 ilustra a diferença entre a hipótese de Hebb e a hipótese da covariância. Em ambos os casos, a dependência de Δw_{kj} sobre y_k é linear; entretanto, a intercepção com o eixo y_k na hipótese de Hebb é na origem, enquanto que na hipótese da covariância é em $y_k = \bar{y}$.

A partir da Equação (2.9) podem ser feitas observações importantes:

1. Pesos sinápticos w_{kj} são fortalecidos se há níveis suficientes de atividade pré-sináptica e pós-sináptica; ou seja, as condições $x_j > \bar{x}$ e $y_k > \bar{y}$ são ambas satisfeitas.
2. Pesos sinápticos w_{kj} são deprimidos se há:
 - uma ativação pré-sináptica (isto é, $x_j > \bar{x}$) na ausência de suficiente ativação pós-sináptica (isto é, $y_k < \bar{y}$), ou
 - uma ativação pós-sináptica (isto é, $y_k > \bar{y}$) na ausência de suficiente ativação pré-sináptica (isto é, $x_j < \bar{x}$).

2.3.3 Aprendizado Competitivo

Nesta forma de aprendizado os neurônios da camada de saída de uma RNA competem entre si para serem ativados. Enquanto em uma RNA baseada em aprendizado Hebbiano vários neurônios de saída podem estar ativados simultaneamente, em uma RNA baseada em aprendizado competitivo somente um único neurônio é ativo a qualquer tempo. Esta característica torna o aprendizado competitivo altamente apropriado para descobrir características estatisticamente salientes que podem ser usadas para classificar um conjunto de padrões de entrada.

Há três elementos básicos para uma regra de aprendizado competitivo:

1. Um conjunto de neurônios que são todos iguais exceto por alguns pesos sinápticos aleatoriamente distribuídos, e que, portanto, respondem de forma diferente a um dado conjunto de padrões de entrada.
2. Um limite imposto na "força" de cada neurônio.
3. Um mecanismo que permite aos neurônios competirem pelo direito de responder a um dado subconjunto de entradas, tal que apenas um neurônio de saída, ou somente um neurônio por grupo está ativo, de cada vez. O neurônio que vence a competição é chamado neurônio *winner-takes-all*.

Os neurônios individuais da RNA se tornam detectores de características para diferentes classes de padrões de entrada, pois aprendem a se especializar em conjuntos de padrões similares.

Na forma mais simples de aprendizado competitivo, a rede tem uma única camada de neurônios de saída, cada um deles completamente conectado aos nós de entrada. A RNA pode incluir conexões de realimentação entre os neurônios, como mostra a Figura 2.8. No exemplo mostrado na figura, as conexões de realimentação desempenham inibição lateral, em que cada neurônio tende a inibir o neurônio ao qual está lateralmente conectado. Em contraste, as conexões sinápticas progressivas na rede da mesma figura são todas excitatórias.

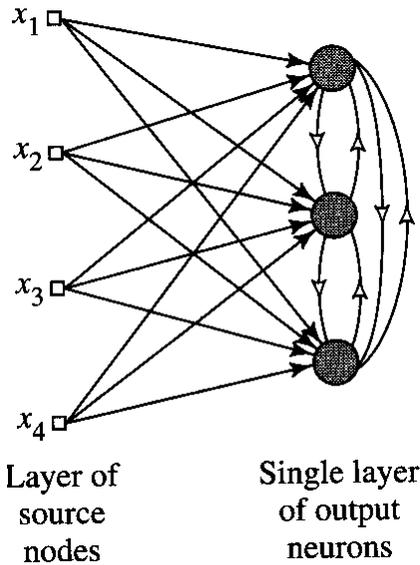


Figura 2.8: Arquitetura de uma rede sob aprendizado competitivo simples com conexões progressivas excitatórias partindo dos nós fonte para os neurônios, e conexões laterais inibitórias entre os neurônios.

Para um neurônio k ser o neurônio vencedor, seu potencial de ativação v_k para um específico padrão de entrada \underline{x} deve ser o maior dentre todos os neurônios na rede. O sinal de saída y_k do neurônio vencedor k é feito igual a um; os sinais de saída de todos os outros neurônios que perdem a competição são feitos iguais a zero. Pode-se então escrever que

$$y_k = \begin{cases} 1 & \text{se } v_k > v_j \text{ para todo } j, j \neq k \\ 0 & \text{em caso contrário} \end{cases} \quad (2.10)$$

onde o potencial de ativação v_k representa a ação combinada de todas as entradas progressivas e realimentadas para o neurônio k .

Seja w_{kj} o peso sináptico que conecta o nó de entrada j ao neurônio k . Como os neurônios irão competir uns com os outros é justo inicializar os pesos sinápticos excitatórios com valores positivos e tais que a soma dos pesos para o neurônio k seja igual a 1, isto é,

$$\sum_j w_{kj} = 1 \quad \text{para todo } k \quad (2.11)$$

De acordo com a regra padrão de aprendizagem competitiva, a mudança Δw_{kj} aplicada ao peso sináptico w_{kj} é definida por

$$\Delta w_{kj} = \begin{cases} \eta(x_j - w_{kj}) & \text{se o neurônio } k \text{ vence a competição} \\ 0 & \text{se o neurônio } k \text{ perde a competição} \end{cases} \quad (2.12)$$

onde η é o parâmetro razão de aprendizado. Esta regra tem o efeito global de mover o vetor de pesos sinápticos \underline{w}_k do neurônio vencedor k na direção do padrão de entrada \underline{x} .

Os pesos sinápticos inibitórios (quando existem), em geral, apresentam valores constantes.

2.4 Tarefas de Aprendizagem

Nas Seções anteriores discutimos diversos algoritmos supervisionados e não-supervisionados. A escolha de um particular algoritmo de aprendizado é motivada pela tarefa que se deseja que a RNA desempenhe. Esta Seção tem o propósito de apresentar alguns exemplos de tarefas de aprendizagem:

2.4.1. Associação de Padrões (Memória Associativa).

Descrição:

- Autoassociação de Padrões: Nesta tarefa de aprendizagem a RNA deve "armazenar" um conjunto de padrões (vetores), através da apresentação repetida destes padrões à rede. Posteriormente é apresentado à RNA uma descrição parcial ou distorcida (ruidosa) de um padrão original nela armazenado e a tarefa requerida da rede é recuperar este particular padrão.
- Heteroassociação de Padrões: Heteroassociação difere da Autoassociação no sentido de que um conjunto arbitrário de padrões de entrada é associado a outro conjunto arbitrário de padrões de entrada. Posteriormente é apresentada à RNA um particular padrão para que a rede recupere o padrão associado.

Paradigma de aprendizagem envolvido: Aprendizado não-supervisionado.

2.4.2. Reconhecimento de Padrões.

Descrição:

- É o processo através do qual um padrão (ou sinal) recebido é associado a alguma classe, dentro de um pré-determinado número de classes.

A RNA é submetida primeiramente a uma seção de treino, durante a qual lhe são repetidamente apresentados um conjunto de padrões de entrada, cada um deles associado à categoria particular a que pertence.

Posteriormente, um padrão desconhecido é apresentado à rede, mas que pertença à mesma população de padrões usados para treinar a rede.

A rede poderá identificar a que classe de padrões este novo padrão pertence, devido à informação extraída do conjunto de treino.

Paradigma de aprendizagem envolvido: Dependendo da aplicação de interesse, podem ser considerados dois casos:

Caso 1: A RNA é dividida em duas partes, uma delas submetida a aprendizado não-supervisionado para extração de características e a outra submetida a aprendizado supervisionado para classificação.

Caso 2: A RNA é do tipo progressiva multicamadas, utilizando algoritmo de aprendizagem supervisionado. A extração de características é realizada pelas unidades da(s) camada(s) escondida(s).

2.4.3. Aproximação de Funções.

Descrição:

- Processo através do qual a RNA apresenta uma solução para o mapeamento entrada /saída de interesse $\underline{d} = f(\underline{x})$, cuja função $f(\cdot)$ que o descreve tem sua expressão analítica desconhecida.

A rede projetada deve aproximar a função desconhecida, de tal forma que o mapeamento entrada/saída efetivamente realizado pela rede aproxime $f(\cdot)$ para todas as entradas.

Para construir o conhecimento sobre o mapeamento entrada/saída, a rede é provida de um conjunto de exemplos representativos deste mapeamento.

Desde que o tamanho do conjunto de treino seja suficientemente grande e a rede disponha de um número adequado de parâmetros livres, o erro de aproximação obtido será suficientemente pequeno para a tarefa proposta.

Paradigma de aprendizagem envolvido: Aprendizado Supervisionado.

2.4.4. Controle de Processos.

Descrição:

- O controle de um processo (ou parte crítica de um sistema) através de uma RNA pode ser descrito conforme segue:

O sistema envolve o uso de um elo de realimentação (*feedback loop*) no processo a ser controlado; ou seja, a saída do processo é alimentada de volta para a entrada.

A saída do processo é, então, subtraída de um sinal de referência provido por uma fonte externa.

O sinal de erro assim produzido é aplicado a um controlador neural com o propósito de ajustar seus parâmetros livres.

O principal objetivo do controlador é prover entradas apropriadas ao processo para que a saída acompanhe o sinal de referência.

O controlador, na verdade, deve inverter o comportamento entrada/saída do processo.

Paradigma de aprendizagem envolvido: Aprendizado Supervisionado.

2.4.5. Filtragem Espacial (Antenas Adaptativas).

Descrição:

A Filtragem Espacial é uma forma de filtragem usada para distinguir entre as propriedades espaciais de um sinal alvo e do ruído de fundo. É um processo usado em sistemas de radar e sonar, onde a tarefa principal é detectar e rastrear um alvo de interesse na presença combinada de ruído de recepção e sinais de interferência.

O sinal alvo se origina de uma direção desconhecida e não há informação disponível *a priori* sobre os sinais causadores da interferência. Uma forma de enfrentar situações deste tipo é usar um cancelador de lobo lateral generalizado. O sistema consiste de: (1) Um conjunto de antenas, o qual provê uma forma de amostrar o sinal observado em pontos discretos no espaço; (2) Um combinador linear definido por um conjunto de pesos fixos, cuja saída é a resposta desejada e que atua como um filtro espacial, caracterizado por um padrão de radiação (um gráfico polar da amplitude da saída da antena \times o ângulo incidente do sinal que é recebido). O lobo principal deste padrão de radiação é apontado ao longo de uma direção prescrita, para a qual o cancelador de lobo lateral generalizado é constricto a produzir uma resposta sem distorção. A saída do combinador linear provê uma resposta desejada para o dispositivo usado na filtragem espacial. (3) Uma matriz bloqueadora de sinal, cuja função é cancelar interferência que se disperse pelos lobos laterais do padrão de radiação do filtro espacial representando o combinador linear. (4) Uma RNA com parâmetros ajustáveis, a qual tem a tarefa de acomodar variações estatísticas nos sinais de interferência. Os ajustes nos parâmetros livres da rede são obtidos através de um algoritmo de aprendizagem por correção de erro que opera sobre o sinal de erro definido como a diferença entre a saída do combinador linear e a saída efetiva da RNA. O cancelador de lobo lateral generalizado opera sob a supervisão do combinador linear que assume o papel de um tutor.

Paradigma de aprendizagem envolvido: Aprendizado Supervisionado.

2.5 Referências Bibliográficas do Capítulo 2:

- [1] M. H. Hassoun, *Fundamentals of Artificial Neural Networks*, MIT Press, Massachusetts, 1995.
- [2] S. Haykin, *Adaptive Filter Theory*, 3rd ed., Prentice Hall, Upper Saddle River, New Jersey, 1996.
- [3] S. Haykin, *Neural Networks*, 2nd ed., Prentice Hall, Upper Saddle River, New Jersey, 1999.
- [4] Z.L.Kovács, *Redes Neurais Artificiais*, Editora Acadêmica São Paulo, São Paulo, 1996.