

Capítulo 1

Perceptron

1.1 Perceptron

O Perceptron foi introduzido por F. Rosenblatt na década de cinquenta. A rede neural artificial mais simples é o Perceptron de camada única esta tem vários nomes que refletem sua simplicidade e naturalidade. O Neurônio de Macculloch e Pitts ou o discriminador linear. É fundamental entender suas propriedades. Alguns autores, Minsky e Papert de forma mais contundente, escreveram sobre ele para depois deixá-lo de lado devido a limitações óbvias. Sem perceber que o futuro desenvolvimento da área deixaria seus argumentos sem força, o descartaram e nisso devolveram a ênfase em inteligência artificial à área de sistemas peritos. A importância do Perceptron se deve a vários motivos. Do ponto de vista pragmático, pode ser visto como um bloco na construção de máquinas mais poderosas. Isto inclui Máquinas de Vetor de Suporte (SVM) e Máquinas do Estado Líquido (LSM). Seu estudo em si pode ser revelador de várias propriedades que seriam impossíveis de ver ao atacar sistemas mais complicados sem o benefício da lição de casa prévia. Ainda assim são ricos o suficiente para despertar o interesse do ponto de vista teórico e experimental. Ainda mais, o uso de algoritmos de treinamento inteligentes permite competir com SVM em eficiência.

1.2 O problema de aprendizagem supervisionado

Considere um conjunto de vetores $\xi_\mu \in \mathbb{R}^N$, cada um associado a um rótulo σ_μ que formam o conjunto de aprendizagem $\mathcal{L} = \{\xi_\mu, \sigma_\mu\}$. Esta é a informação disponível. O caso mais simples possível é quando os rótulos σ_μ tomam valores ± 1 . O perceptron é definido por um vetor de pesos \mathbf{J} e uma função de transferência, que pode ser uma função contínua ou não, mas aqui olharemos primeiro para funções degrau: $sign(x)$ é o sinal de x . O perceptron classifica um vetor numa classe:

$$\sigma = sign(\mathbf{J} \cdot \xi). \quad (1.1)$$

Note que a classificação não depende dos módulos dos vetores. O problema de aprendizagem é determinar o conjunto de pesos \mathbf{J} que classifique os vetores de forma adequada, medida pelo erro de treinamento e_T ou o erro de generalização e_G ou ainda o erro de predição e_P . e_T mede a memorização dos rótulos. Os rótulos podem ter sido corrompidos por algum processo de ruído e o erro de predição mede a probabilidade de que um novo vetor seja classificado de forma igual ao rótulo enquanto o de generalização mede a probabilidade de que a classificação seja correta. Estas duas medidas coincidem quando não há ruído. O erro de generalização tem mais utilidade teórica, pois diz respeito à concordância com uma regra desconhecida e por inferir. O erro de predição pode ser estimado na prática.

O produto escalar determina a geometria do problema. O perceptron só pode classificar corretamente o conjunto de treinamento se houver um hiperplano que separe as duas classes, isto é só pode representar o problema de separação linear. O clássico problema do XOR, ou exclusivo, é o exemplo clássico:

Exercício Em duas dimensões, $\xi = (1, 1)$ e $(-1, -1)$ são classificados em uma categoria, e.g. $\sigma = 1$; e $\xi = (1, -1)$ e $(-1, 1)$ na outra $\sigma = -1$. Faça o desenho e convença-se que não há reta que separe os dois primeiros e vetores dos outros dois. Mas há duas soluções para este problema. Note que podemos usar duas retas para separá-los. Usamos 3 perceptrons. Um resolve o problema de separação com associado a uma reta, o segundo o problema associado à outra reta. O terceiro usa como entrada a saída dos perceptrons 1 e 2 e resolve o problema. Uma segunda solução passa por aumentar a dimensão do problema. Discuta.

1.2.1 Teorema de convergência do Perceptron

Provaremos a seguir o teorema de Rosenblatt para a convergência de um algoritmo de aprendizagem. Se existe uma solução, isto é se há um vetor \mathbf{B} que separe um conjunto de vetores nas categorias corretas com uma certa margem κ , então em um número finito de passos é possível encontrar algum vetor que também consiga essa separação. Chamamos acerto (ou erro) nesta seção, quando $\mathbf{J}(t) \cdot \xi_\mu \sigma_\mu < \sqrt{N}\kappa$ (caso contrário).

O algoritmo Perceptron de Rosenblatt é muito importante e simples. Os vetores do conjunto de treinamento serão considerados sequencialmente e apresentados ao perceptron, se a classificação é correta nada é feito. Se ocorre um erro, uma mudança no vetor de pesos $\mathbf{J}(t)$ é necessária. O processo se repete com o próximo exemplo da lista até conseguir convergência. Começamos da *tabula rasa*: $\mathbf{J} = 0$ e a correção é dar um passo paralelo ao vetor apresentado. Podemos considerar um índice temporal e pensar na dinâmica de aprendizado

$$\mathbf{J}(t+1) = \mathbf{J}(t) + \frac{f_\mu}{\sqrt{N}} \sigma_\mu \xi_\mu \quad (1.2)$$

onde f_μ , que chamaremos de função de modulação é 0 se $\mathbf{J}(t) \cdot \xi_\mu \sigma_\mu > \sqrt{N}\kappa$ (acerto) e 1 caso contrário (erro). Este é um algoritmo de correção de erros. A

função de modulação será central na discussão futura. Por agora simplesmente detecta erros.

Definimos

$$b_\mu := \frac{1}{\sqrt{N}} \xi_\mu \cdot \mathbf{B}, \quad h_\mu(t) := \frac{1}{\sqrt{N}} \xi_\mu \cdot \mathbf{J}(t) \quad (1.3)$$

Podemos reescalar \mathbf{B} para que $\mathbf{B} \cdot \mathbf{B} = N$.

Supomos que exista \mathbf{B} e uma margem $\kappa > 0$ tal que para todo $\mu = 1 \dots P$

$$\xi_\mu \cdot \mathbf{B} \sigma_\mu \geq \sqrt{N} \kappa > 0 \quad (1.4)$$

ou $b_\mu \sigma_\mu \geq \kappa > 0$.

Num dado instante t , temos $F = \sum f_\mu$ e $\mathbf{J}(t) = \sum f_\mu \xi_\mu \sigma_\mu$, respectivamente o número de passos efetivos de aprendizagem e o estado dos pesos do perceptron. Para este teorema F é a quantidade central. Queremos mostrar que permanece finita, ou seja a partir de um certo ponto os valores de f_μ serão nulos e o todas as condições de estabilidade satisfeitas.

Multiplicamos as equações 1.5 por f_μ e as somamos obtendo

$$\sum f_\mu \xi_\mu \cdot \mathbf{B} \sigma_\mu = \sqrt{N} \mathbf{J} \cdot \mathbf{B} \geq F \kappa \quad (1.5)$$

Introduzimos $\rho = \frac{\mathbf{J} \cdot \mathbf{B}}{|\mathbf{J}| |\mathbf{B}|}$. É fácil mostrar que ρ esta entre -1 e 1 , pois é o cosseno do angulo entre os dois vetores. Assim temos

$$(F \kappa)^2 \leq \rho^2 N |\mathbf{J}|^2 \quad (1.6)$$

e da dinâmica, quando houve um erro ($f_\mu = 1$)

$$|\mathbf{J}(t+1)|^2 = |\mathbf{J}(t) + \frac{f_\mu}{\sqrt{N}} \sigma_\mu \xi_\mu|^2 \quad (1.7)$$

$$= |\mathbf{J}(t)|^2 + 2 \frac{f_\mu}{\sqrt{N}} \mathbf{J}(t) \cdot \xi_\mu \sigma_\mu + \frac{1}{N} |\xi_\mu|^2 \quad (1.8)$$

$$= |\mathbf{J}(t)|^2 + 2 f_\mu h_\mu(t) \sigma_\mu + 1 \quad (1.9)$$

Podemos usar a escala $|\xi_\mu|^2 = N$ porque a classificação não depende dos módulos. Com respeito ao exemplo μ , se tivesse sido corretamente classificado, então não haveria mudança. Portanto não o foi e $h_\mu \sigma_\mu < \kappa \sqrt{N}$.

$$|\mathbf{J}(t+1)|^2 \leq |\mathbf{J}(t)|^2 + 2\kappa + 1 \quad (1.10)$$

$$\leq F(2\kappa + 1) \quad (1.11)$$

pois a cada passo o aumento é menor que $2\kappa + 1$ e foram dados F passos efetivos de aprendizagem.

$$(F \kappa)^2 \leq N |\mathbf{J}(t+1)|^2 \leq NF(2\kappa + 1) \quad (1.12)$$

$$F \leq N(2\kappa^{-1} + \kappa^{-2}) \quad (1.13)$$

1.2.2 Comentários

Fica provado que se existir uma margem κ e um vetor \mathbf{B} , será encontrado algum vetor que reproduz os rótulos σ_μ para o conjunto de vetores no conjunto de treinamento. E se não for satisfeita alguma dessas condições? Primeiro, se os vetores forem sorteados de acordo a alguma distribuição de probabilidades, por exemplo uniformemente, pode ser que alguns estejam arbitrariamente perto da borda de decisão, o hiperplano perpendicular ao vetor professor \mathbf{B} . Neste caso o valor de κ será arbitrariamente pequeno. Isso levará à possibilidade de aprender a regra mas não em tempo finito. O vetor \mathbf{J} evoluirá, ficando cada vez mais perto de \mathbf{B} e o erro de generalização cairá com o número de exemplos apresentados.

Se não existir um vetor \mathbf{B} , então temos algumas alternativas possíveis. Pode ser que não haja regra para a associação de rótulos aos vetores. Podemos encontrar, para número de exemplos P baixo em relação a N , direções \mathbf{J} que classificam corretamente os exemplos. Isso ocorre quando os vetores não são maliciosamente escolhidos (forma geral) e $\alpha = \frac{P}{N}$ é menor que 1. Para $\alpha < 2$ ainda há uma probabilidade razoável de poder separar os vetores nas duas classes. Acima de 2 fica cada vez mais difícil, para N 's maiores, de separá-los linearmente. Este resultado foi primeiro obtido por Cover usando idéias de geometria combinatória e posteriormente por Gardner usando o método de réplicas. No limite $N \rightarrow \infty$ com probabilidade 1 para $\alpha < 2$ e probabilidade 0 para $\alpha > 2$ ocorre separação linear por um hiperplano que pode ser encontrado com o algoritmo perceptron de Rosenblatt.

Em problemas de aplicações os vetores representam um conjunto de características de cada padrão a ser classificado. Se for possível aumentar o número de características N , mantendo P fixo e com isso levar o problema a casos linearmente separáveis, podemos usar o perceptron. Mas pode ser que essa estratégia seja impossível. Podemos então colocar vários perceptrons cuja saída é combinada para formar vetores de entrada num perceptron de saída. Assim temos as chamadas máquinas de camada escondida. Pode se provar (ref) que se o número de camadas escondidas for arbitrário, qualquer classificação pode ser implementada.

1.3 Aprendizagem supervisionada online

Vários cenários de aprendizagem podem ser considerados com respeito à forma como os exemplos são usados. Podemos usar todos os exemplos ao mesmo tempo e estudaremos isso mais adiante, sob o nome de aprendizagem offline. Podemos apresentar em subgrupos de tamanho menor que o que tem o conjunto de aprendizado. Podemos apresentar cada vetor de forma sequencial, visitando ciclicamente o conjunto de treinamento. Analisaremos a seguir cenários de apresentação única de exemplos. O interesse neste tipo de situação é que pode servir de modelo para várias situações de aprendizagem, pode ser estudado de forma relativamente fácil, apresenta um desempenho muito bom e serve como exemplo

para várias propriedades bastante gerais de situações de aprendizado.

Estudaremos o caso de N ser suficientemente grande para que $N \rightarrow \infty$ seja uma aproximação razoável. Isso nos permitirá escrever a dinâmica de aprendizado através de um conjunto pequeno de equações diferenciais ordinárias, obtidas por primeira vez por Kinzel e Rujan no contexto de seleção de exemplos.

Após a obtenção destas equações, estudaremos qual seria a melhor escolha da função de modulação, para poder extrair mais informação do conjunto de treinamento.

1.3.1 Formulação de aprendizagem online com apresentação única de exemplos

Voltemos às N equações 1.2. Transformamos as N equações em duas equações que descrevem o que podemos considerar como candidatos a parâmetros de ordem adequados para a descrição da aprendizagem. Para isso olhamos para o módulo de \mathbf{J} e para $\mathbf{B}\cdot\mathbf{J}$ que devem servir para medir a semelhança entre o aluno, representado por \mathbf{J} e a regra ou professor, dado por \mathbf{B} .

$$|\mathbf{J}(t+1)|^2 = |\mathbf{J}(t)|^2 + 2\frac{f_\mu}{\sqrt{N}}\sigma_\mu\mathbf{J}(t)\cdot\xi_\mu + \frac{f_\mu^2}{N}|\xi_\mu|^2 \quad (1.14)$$

$$\mathbf{B}\cdot\mathbf{J}(t+1) = \mathbf{B}\cdot\mathbf{J}(t) + \frac{f_\mu}{\sqrt{N}}\sigma_\mu\mathbf{B}\cdot\xi_\mu \quad (1.15)$$

e definimos $Q = \frac{|\mathbf{J}|}{\sqrt{N}}$ e $\rho = \frac{\mathbf{B}\cdot\mathbf{J}}{Q\sqrt{N}}$, e também para facilitar as equações abaixo $R = \rho Q = \frac{\mathbf{B}\cdot\mathbf{J}}{N}$

$$\Delta Q^2 = Q(t+1)^2 - Q(t)^2 = \frac{1}{N}(2f_\mu\sigma_\mu h_\mu + f_\mu^2) \quad (1.16)$$

$$\Delta R = R(t+1) - R(t) = \frac{1}{N}f_\mu\sigma_\mu b_\mu \quad (1.17)$$

$$\Delta\rho = \rho(t+1) - \rho(t) = \frac{1}{N}\left(\sigma_\mu(b_\mu - \frac{\rho}{Q}h_\mu)\frac{f_\mu}{Q} - \frac{\rho}{2}\left(\frac{f_\mu}{Q}\right)^2\right) \quad (1.18)$$

Tomamos agora o limite termodinâmico e usamos que os parâmetros de ordem Q^2 e R ou ρ adquirem seus valores macroscópicos devido à automediancia, pois são compostos de somas. Já as diferenças ΔQ^2 e ΔR se transformam em derivadas. Definimos $\alpha = \mu/N$ e $d\alpha = 1/N$

$$\frac{\Delta Q^2}{1/N} = 2f_\mu\sigma_\mu h_\mu + f_\mu^2 \quad (1.19)$$

$$\frac{\Delta R}{1/N} = f_\mu\sigma_\mu b_\mu \quad (1.20)$$

$$\frac{\Delta\rho}{1/N} = \left(\sigma_\mu(b_\mu - \frac{\rho}{Q}h_\mu)\frac{f_\mu}{Q} - \frac{\rho}{2}\left(\frac{f_\mu}{Q}\right)^2\right) \quad (1.21)$$

$$\frac{dQ^2}{d\alpha} = \left\langle \lim_{N \rightarrow \infty} \frac{\Delta Q^2}{1/N} \right\rangle \quad (1.22)$$

$$\frac{dR}{d\alpha} = \left\langle \lim_{N \rightarrow \infty} \frac{\Delta R}{1/N} \right\rangle \quad (1.23)$$

$$\frac{d\rho}{d\alpha} = \left\langle \lim_{N \rightarrow \infty} \frac{\Delta \rho}{1/N} \right\rangle \quad (1.24)$$

$$\frac{dQ^2}{d\alpha} = \langle 2f\sigma h + f^2 \rangle \quad (1.25)$$

$$\frac{dR}{d\alpha} = \langle f\sigma b \rangle \quad (1.26)$$

$$\frac{d\rho}{d\alpha} = \left\langle \left(\sigma \left(b - \frac{\rho}{Q} h \right) \frac{f}{Q} - \frac{\rho}{2} \left(\frac{f}{Q} \right)^2 \right) \right\rangle \quad (1.27)$$

onde a média é feita sobre o exemplo que foi usado no passo de aprendizagem.

exercício Mostre das equações acima que $Qd\rho/d\alpha + \rho dQ/d\alpha = dR/d\alpha$

Equações diferenciais ordinárias para descrever a dinâmica de aprendizagem foram introduzidas em um caso específico $f = 1$ por Kinzel e Rujan e posteriormente generalizadas por OK e NC. Reents e Urbanczick mostram em (PRL 1998) que a dedução acima pode ser demonstrada de forma rigorosa.

1.3.2 Distribuição dos campos no caso de exemplos uniformemente distribuídos

Precisamos calcular $P(b, h | \mathbf{B}, \mathbf{J})$ que escrevemos $P(b, h)$ por simplicidade:

$$\begin{aligned} P(b, h) &= \int d\mu(\xi) \delta\left(b - \frac{\xi \cdot \mathbf{B}}{\sqrt{N}}\right) \delta\left(h - \frac{\xi \cdot \mathbf{J}}{\sqrt{N}}\right) \\ &= \int d\mu(\xi) \frac{d\hat{b}d\hat{h}}{(2\pi)^2} \exp -i\hat{b}\left(b - \frac{\xi \cdot \mathbf{B}}{\sqrt{N}}\right) \exp -i\hat{h}\left(h - \frac{\xi \cdot \mathbf{J}}{\sqrt{N}}\right) \\ &= \int \frac{d\hat{b}d\hat{h}}{(2\pi)^2} \exp -i(\hat{b}b + \hat{h}h) \int d\mu(\xi) \exp i\left(\frac{\xi \cdot (\hat{b}\mathbf{B} + \hat{h}\mathbf{J})}{\sqrt{N}}\right) \end{aligned} \quad (1.28)$$

e pelo teorema do limite central segue que $P(b, h)$ é uma gaussiana correlacionada. Para o caso em que a distribuição de exemplos é uniforme ($P(\xi_i = 1) =$

$P(\xi_i = -1) = 1/2$) temos:

$$\begin{aligned}
\int d\mu(\xi) \exp i\left(\frac{\xi \cdot (\hat{b}\mathbf{B} + \hat{h}\mathbf{J})}{\sqrt{N}}\right) &= \prod_i^N \int d\xi P(\xi) \exp i\left(\frac{\xi_i (\hat{b}B_i + \hat{h}J_i)}{\sqrt{N}}\right) \\
&= \prod_i^N \cos\left(\frac{(\hat{b}B_i + \hat{h}J_i)}{\sqrt{N}}\right) \\
&= \prod_i^N \exp -\frac{1}{2} \left(\frac{(\hat{b}B_i + \hat{h}J_i)}{\sqrt{N}}\right)^2 \\
&= \exp -\frac{1}{2} \frac{(\hat{b}^2 \mathbf{B}^2 + 2\hat{b}\hat{h}\mathbf{B} \cdot \mathbf{J} + \hat{h}^2 \mathbf{J}^2)}{N} \\
&= \exp -\frac{1}{2} (\hat{b}^2 + 2\hat{b}\hat{h}\rho Q + \hat{h}^2 Q^2) \quad (1.29)
\end{aligned}$$

e só falta fazer a transformada de Fourier

$$\begin{aligned}
P(b, h) &= \int \frac{dbd\hat{h}}{(2\pi)^2} \exp -i(\hat{b}b + \hat{h}h) \exp -\frac{1}{2} (\hat{b}^2 + 2\hat{b}\hat{h}\rho Q + \hat{h}^2 Q^2) \\
&= \frac{1}{2\pi\sqrt{1-\rho^2}} \exp -\frac{b^2 + 2\rho bhQ^{-1} + Q^{-2}h^2}{2(1-\rho^2)} \quad (1.30)
\end{aligned}$$

$$P(h) = \frac{1}{\sqrt{2\pi Q^2}} \exp -\left(\frac{h^2}{2Q^2}\right) \quad (1.31)$$

$$P(b) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{b^2}{2}\right) \quad (1.32)$$

$$P(h|b) = \frac{1}{2\pi Q\sqrt{1-\rho^2}} \exp -\frac{(b - \rho hQ^{-1})^2}{2(1-\rho^2)} \quad (1.33)$$

onde usamos $\mathbf{B}^2/N = 1$, $\mathbf{J}^2/N = Q^2$ e $\rho = \frac{\mathbf{B} \cdot \mathbf{J}}{|\mathbf{B}||\mathbf{J}|}$

Assim temos $\langle b^2 \rangle = 1$, $\langle h^2 \rangle = Q^2$, $\langle bh \rangle = \rho$.

1.3.3 Erro de generalização

O erro de generalização é uma ferramenta útil para medir o desempenho de um algoritmo de aprendizado e podemos calculá-lo, novamente para distribuições uniformes de exemplos, a partir de

$$e_g = \int d\mu(\xi) \Theta(-\mathbf{J} \cdot \xi \mathbf{B} \cdot \xi) \quad (1.34)$$

$$\begin{aligned}
&= \int d\mu(\xi) dbdh \delta\left(b - \frac{\xi \cdot \mathbf{B}}{\sqrt{N}}\right) \delta\left(h - \frac{\xi \cdot \mathbf{J}}{\sqrt{N}}\right) \Theta(-hb) \\
&= \int dbdh P(b, h) \Theta(-hb) \\
&= \frac{1}{\pi} \cos^{-1} \rho \quad (1.35)
\end{aligned}$$

1.4 Algoritmos de aprendizado

Podemos estudar as equações diferenciais 1.27 para alguns casos especiais de algoritmos de aprendizagem. Os mais conhecidos são

- Algoritmo de Hebb, $f_H = 1$
- Algoritmo Perceptron de Rosenblatt, $f_P = \Theta(-bh)$
- Adaline
- AdaTron

Mais do que dar ênfase aos resultados em particular que cada algoritmo fornece, estudos deste tipo levam a questões sobre vantagens de um algoritmo sobre outro. Qual atinge o menor erro de generalização? Qual é mais eficiente? Qual é mais robusto ante mudanças das hipóteses usadas para construir este cenário de aprendizagem modelo? Qual pode ser generalizado para problemas não linearmente separáveis? A seguir estudamos o problema de generalização ótima, feito em situação bastante artificial e simplificada mas que dá alguns resultados interessantes.

1.5 Algoritmo de generalização ótima

Para a dinâmica dada pela equação 1.2 queremos encontrar f de forma a ter maior ganho de informação por exemplo. A primeira pergunta que pode ser feita é sobre o espaço que f vive. Podemos de forma geral olhar para todas as variáveis do problema e definir dois grupos

- Conjunto das variáveis acessíveis ou visíveis \mathcal{V}
- Conjunto das variáveis não acessíveis ou escondidas \mathcal{H}

É óbvio que para definir uma situação minimamente realista precisamos nos restringir a funções de modulação que dependam somente das variáveis \mathcal{V} . As médias que aparecem na equação 1.27 podem ser consideradas sobre a distribuição $P(\mathcal{V}, \mathcal{H}) = P(\mathcal{V})P(\mathcal{H}|\mathcal{V})$ e portanto podemos escrever a equação para a dinâmica

$$\begin{aligned} \frac{d\rho}{d\alpha} &= \left\langle \left(\sigma\left(b - \frac{\rho}{Q}h\right) \frac{f}{Q} - \frac{\rho}{2} \left(\frac{f}{Q}\right)^2 \right) \right\rangle_{\mathcal{V}, \mathcal{H}} \\ \frac{d\rho}{d\alpha} &= \left\langle \left\langle \sigma\left(b - \frac{\rho}{Q}h\right) \right\rangle_{\mathcal{H}|\mathcal{V}} \frac{f}{Q} - \frac{\rho}{2} \left(\frac{f}{Q}\right)^2 \right\rangle_{\mathcal{V}} \end{aligned} \quad (1.36)$$

A derivada $\frac{d\rho}{d\alpha}$ é um funcional da função de modulação f e portanto podemos tomar uma derivada funcional para calcular o máximo de aumento médio de ρ a cada passo da dinâmica. Dado que o erro de generalização depende unicamente

de ρ , estaremos maximizando a queda média de e_G . Obtemos que a máxima generalização on-line é obtido com a função de modulação

$$f_o = \langle Q \sigma \left(\frac{b}{\rho} - \frac{h}{Q} \right) \rangle_{\mathcal{H}|\mathcal{V}} \quad (1.37)$$

A equação para ρ pode ser escrita

$$\frac{d\rho}{d\alpha} = \frac{\rho}{Q^2} \langle f_o f - \frac{1}{2} f^2 \rangle_{\mathcal{V}} \quad (1.38)$$

e para a escolha de $f = f_0$

$$\frac{dQ^2}{d\alpha} = \langle 2f_o \langle \sigma h \rangle_{\mathcal{H}|\mathcal{V}} + f_o^2 \rangle_{\mathcal{V}} \quad (1.39)$$

$$\frac{dR}{d\alpha} = \langle f_o \langle \sigma b \rangle_{\mathcal{H}|\mathcal{V}} \rangle_{\mathcal{V}} \quad (1.40)$$

$$\frac{d\rho}{d\alpha} = \frac{\rho}{2Q^2} \langle f_o^2 \rangle_{\mathcal{V}} \quad (1.41)$$

$$\frac{1}{Q} \frac{dQ}{d\alpha} = \frac{1}{2} \langle \left(\frac{\langle b \rangle_{\mathcal{H}|\mathcal{V}}}{\rho} \right)^2 - \left(\frac{\langle h \rangle_{\mathcal{H}|\mathcal{V}}}{Q} \right)^2 \rangle_{\mathcal{V}} \quad (1.42)$$

$$\frac{1}{\rho} \frac{d\rho}{d\alpha} = \frac{1}{2} \langle \left(\frac{\langle b \rangle_{\mathcal{H}|\mathcal{V}}}{\rho} \right)^2 + \left(\frac{\langle h \rangle_{\mathcal{H}|\mathcal{V}}}{Q} \right)^2 - 2 \left(\frac{\langle b \rangle_{\mathcal{H}|\mathcal{V}}}{\rho} \right) \left(\frac{\langle h \rangle_{\mathcal{H}|\mathcal{V}}}{Q} \right) \rangle_{\mathcal{V}}$$

Mostraremos que sob certas circunstâncias

$$\frac{1}{Q} \frac{dQ}{d\alpha} - \frac{1}{\rho} \frac{d\rho}{d\alpha} = - \langle \left(\frac{\langle h \rangle_{\mathcal{H}|\mathcal{V}}}{Q} \right)^2 \rangle_{\mathcal{V}} + \langle \left(\frac{\langle b \rangle_{\mathcal{H}|\mathcal{V}}}{\rho} \right) \left(\frac{\langle h \rangle_{\mathcal{H}|\mathcal{V}}}{Q} \right) \rangle_{\mathcal{V}}$$

é zero, portanto $\frac{1}{Q} \frac{dQ}{d\alpha} = \frac{1}{\rho} \frac{d\rho}{d\alpha}$, o que pode permitir avaliar ρ , medindo Q , que não precisa de informação sobre a regra para ser medido.

Defina

$$\Gamma = \frac{\sqrt{1 - \rho^2}}{\rho} = \tan(\pi e_G) \quad (1.43)$$

$$Dx = \frac{dx}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \quad (1.44)$$

$$H(y) = \int_y^\infty Dx = \frac{1}{2} \operatorname{erfc}\left(\frac{x}{\sqrt{2}}\right) \quad (1.45)$$

A equação para ρ pode ser escrita

$$\frac{d\rho}{d\alpha} = \frac{1 - \rho^2}{2\pi\rho} \int_{-\infty}^{\infty} Dx \frac{\exp(-x^2/\Gamma^2)}{H(x/\Gamma)} \quad (1.46)$$

onde usamos o resultado:

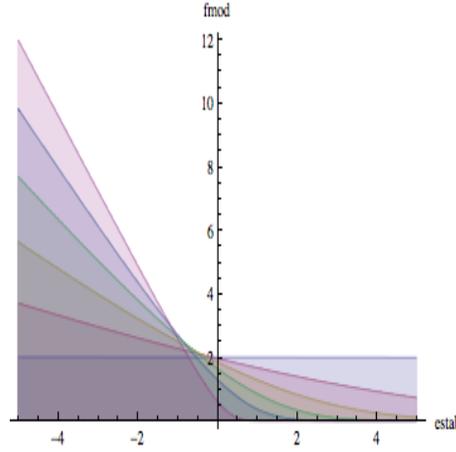


Figura 1.1: Função modulação de perceptron como função de $\sigma h/Q$ para diferentes valores de ρ (0.. Regra linearmente separável e estática, distribuição uniforme de exemplos;

Exercício Mostre que a função de modulação no caso do perceptron, é dada por

$$f_o(h, \rho, \sigma, Q) = \frac{Q\Gamma}{\sqrt{2\pi}} \frac{e^{-\frac{1}{2}(\frac{h}{Q\Gamma})^2}}{H(-\frac{\sigma h}{Q\Gamma})} \quad (1.47)$$

Exercício Mostre que assintoticamente $e_G \approx C\alpha^{-1}$. Mostre ainda que a constante $C \approx 0.88$

1.5.1 Análise da função de modulação

A forma da função modulação é interessante. Ela determina a intensidade com que o termo puramente hebbiano muda o vetor de pesos. Se σ e h são visíveis, então

$$f_o = \frac{Q}{\rho} \sigma \left(\langle b \rangle_{\mathcal{H}|V} - \frac{\rho}{Q} h \right) \quad (1.48)$$

e f_o funciona quase como se estivesse tentando corrigir erros. Calcula $\langle b \rangle_{\mathcal{H}|V}$, se este valor fosse comparado com h/Q , então seria um puro corretor de erros. Mas não é exatamente isso que é feito. A comparação é com $\rho h/Q$. Ou seja, leva em conta que h/Q e b não são perfeitamente correlacionados. Isso faz com que para os estágios iniciais de aprendizagem, quando ρ é pequeno, o valor de h não seja muito importante.

Assim a função de modulação (fig ??) é para valores pequenos de ρ é uma constante. Aprendizagem leva a aumento de ρ e a modulação da mudança dos pesos diminui para exemplos corretamente classificados mas aumenta para padrões em que a previsão se mostra errada.

1.5.2 Seleção de Exemplos

Se os exemplos não forem escolhidos de forma uniforme, a função de modulação ainda será a mesma, pois a distribuição relevante é $P(b|h)$, mas a escolha de exemplos nos permite aumentar em muito o desempenho do algoritmo de aprendizagem. A equação da dinâmica, para uma distribuição qualquer de exemplos $P(h)$ pode ser escrita como

$$\frac{d\rho}{d\alpha} = \frac{1 - \rho^2}{2\pi\rho} \int_{-\infty}^{\infty} dh P(h) \exp(-h^2/\Gamma^2) \left[\frac{1}{H(x/\Gamma)} + \frac{1}{H(x/\Gamma)} \right] \quad (1.49)$$

Note que o fator que multiplica $P(h)$ é positivo, simétrico ante a troca $h \rightarrow -h$ e ainda tem um máximo para $h = 0$. Podemos escolher a distribuição de exemplos que maximiza $\frac{d\rho}{d\alpha}$:

$$P(h) = \delta(h) \quad (1.50)$$

Isto significa que se os exemplos com a menor margem possível forem escolhidos pela rede aluno a taxa de decaimento do erro de generalização será máxima. Kinzel e Ruján sugeriram de forma heurística que esta seria a melhor forma de selecionar os exemplos. A prova acima, olhando para a equação da dinâmica, foi dada por KiCa. A equação diferencial fica simples, pois a delta faz a integral e obtemos

$$\frac{d\rho}{d\alpha} = 2 \frac{1 - \rho^2}{\pi\rho} \quad (1.51)$$

com a condição inicial $\rho = 0$, temos

$$\rho = \sqrt{1 - e^{-2\alpha/\pi}} \quad (1.52)$$

Aqui vemos a vantagem de usar o algoritmo variacional. A seleção de exemplos leva a um algoritmo que converge exponencialmente rápido, mas isso não ocorre para o algoritmo hebbiano estudado por Kinzel e Ruján, que continua decaindo com $\alpha^{-1/2}$ mesmo selecionando os exemplos. A única melhora ocorre no prefator constante, que cai à metade.

1.6 Aprendizagem na presença de ruído

Há várias formas de generalizar o modelo simples de aprendizado descrito acima. Podemos ter uma regra que muda no tempo, de forma determinística ou aleatória, ou a comunicação entre a rede que aprende e a fonte dos rótulos σ_B pode ser imperfeita. Nesta seção consideraremos dois tipos de modelos para o ruído, aditivo e multiplicativo. Denotamos o rótulo que chega ao aluno τ e abaixo descreveremos como depende de σ . Além do erro de generalização

$$e_G = \langle \Theta(-h\sigma) \rangle_\xi \quad (1.53)$$

devemos considerar o erro de predição

$$e_P = \langle \Theta(-h\tau) \rangle_{\xi, \tau} \quad (1.54)$$

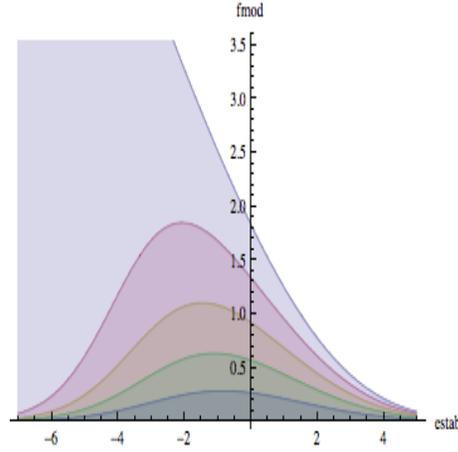


Figura 1.2: Função modulação de perceptron como função de $\sigma h/Q$ e ruído multiplicativo ϵ ($\rho = 0, 4$). Regra linearmente separável e estática, distribuição uniforme de exemplos;

mostraremos, dentro do contexto de alguns modelos, que embora o erro de predição não possa ser reduzido a zero pelo processo de aprendizado, o erro de generalização ainda pode convergir a zero na presença de ruído.

Nestas condições o resultado da seção anterior muda. A média nas equações da dinâmica deveria ser feita sobre o rótulo ruidoso, mas a idéia de otimizar ainda fornece resultados interessantes. A equação $f_o = \langle Q\sigma(\frac{b}{\rho} - \frac{h}{Q}) \rangle_{\mathcal{H}|\mathcal{V}}$ ainda vale, mas mudam o conjunto de variáveis escondidas \mathcal{H} , que passa a incluir σ e o de variáveis acessíveis \mathcal{V} , que passa a ter τ

1.6.1 Ruído Multiplicativo

Com probabilidade $\eta \leq 1/2$ o rótulo σ é invertido: $P(\tau = \sigma) = 1 - \eta$, e $P(\tau = -\sigma) = \eta$.

Os erros de predição e generalização estão relacionados, pois para qualquer função

$$\langle V(h, b, \tau) \rangle_{P(h, b, \tau)} = \eta \langle V(h, b, -\text{sign}(b)) \rangle_{P(h, b)} + (1 - \eta) \langle V(h, b, \text{sign}(b)) \rangle_{P(h, b)}$$

e portanto $e_P = \eta(1 - e_g) + (1 - \eta)e_G = \eta + (1 - 2\eta)e_G$, que sempre fica acima do nível η de ruído η

Hebb com ruído

Primeiro olhamos para aprendizagem hebbiano. As equações da dinâmica são

$$\frac{dQ^2}{d\alpha} = \sqrt{\frac{2}{\pi}}(1 - 2\eta) \quad (1.55)$$

$$\frac{d\rho}{d\alpha} = 2\sqrt{\frac{2}{\pi}}(1 - 2\eta)\rho + 1 \quad (1.56)$$

A dinâmica de Hebb é tão simples que podemos encontrar uma solução analítica.

Exercício Obtenha as equações acima (1.56) e mostre que

$$e_G(\alpha) = \frac{1}{\pi} \arccos \left[\left(1 + \frac{\pi}{2(1 - 2\eta)^2 \alpha} \right)^{-\frac{1}{2}} \right] \quad (1.57)$$

Usando que para $\rho \rightarrow 1$ o erro vai a zero e podemos olhar o comportamento assintótico, $\cos \pi e_G = 1 - (\pi e_G)^2 / 2\rho$

$$e_G(\alpha) = \frac{C(\eta)}{\sqrt{\alpha}}, \quad (1.58)$$

com $C(\eta) = 1/\sqrt{2\pi(1 - 2\eta)}$. Para $\eta < 1/2$ a regra é aprendida lentamente mas totalmente. A medida que o nível de ruído aumenta o prefator $C(\eta)$, que não depende de α aumenta e diverge em $\eta = 1/2$, refletindo o fato que não há informação nenhuma nos exemplos que permita inferir a regra.

Algoritmo ótimo com ruído multiplicativo

Primeiro precisamos

$$P(b|h, \tau) = \frac{P(b, \tau|h)}{P(\tau|h)} = \frac{P(\tau|b, h)P(b|h)}{P(\tau|h)} \quad (1.59)$$

pois b não é acessível e τ e h o são. Assim, como τ , dado b , não depende de h , se reduz a

$$P(b|h, \tau) = \frac{P(\tau|b)P(b|h)}{P(\tau|h)} P(\tau|h) \quad (1.60)$$

Usando que $P(\tau|b)$ e $P(\tau|h)$ são as marginais de $P(\sigma, \tau|b)$ e $P(\sigma, \tau|h)$, podemos escrever

$$P(\tau|b) = \sum_{\sigma} P(\sigma, \tau|b) = \sum_{\sigma} P(\tau|\sigma, b)P(\sigma|b) \quad (1.61)$$

$$= \sum_{\sigma} P(\tau|\sigma)P(\sigma|b) \quad (1.62)$$

$$P(\tau|h) = \sum_{\sigma} P(\sigma, \tau|h) = \sum_{\sigma} P(\tau|\sigma, h)P(\sigma|h) \quad (1.63)$$

$$= \sum_{\sigma} P(\tau|\sigma)P(\sigma|h) \quad (1.64)$$

É fácil ver que $P(\sigma|b) = \Theta(-\sigma b)$ e $P(\sigma|h) = H(-\sigma h/\Gamma)$, o que leva a

$$P(\tau|b) = \eta + (1 - \frac{\eta}{2})\Theta(-\sigma b) \quad (1.65)$$

$$P(\tau|h) = \eta + (1 - \frac{\eta}{2})H(-\sigma h/Q\Gamma) \quad (1.66)$$

$$P(b|h, \tau) = P(b|h) \frac{(1 - 2\eta)\Theta(-\sigma b)}{\eta + (1 - 2\eta)H(-\sigma h/Q\Gamma)} \quad (1.67)$$

que vale para a distribuição uniforme de exemplos. Assim é possível chegar à forma da função de modulação que aparece na figura 1.2:

$$f(h, \tau, Q, \rho, \eta) = \frac{Q\Gamma}{\sqrt{2\pi}} (1 - 2\eta) \frac{e^{-(\frac{h}{Q\Gamma})^2}}{\eta + (1 - 2\eta)H(-\sigma h/(Q\Gamma))} \quad (1.68)$$

1.6.2 Estimativa do ruído

1.7 Complexidade dos algoritmos e Ordenamento temporal