

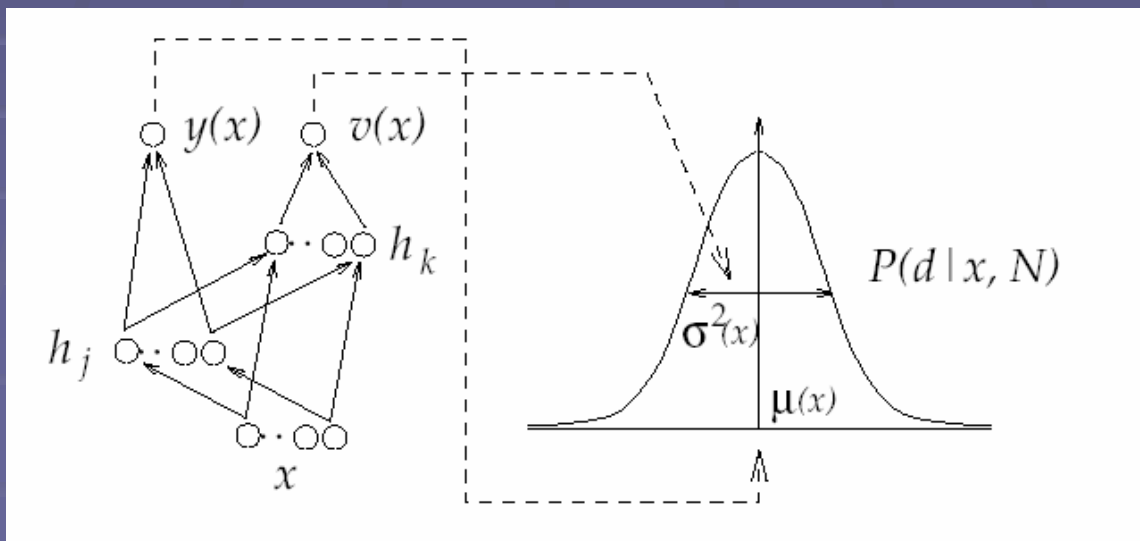
Aproximação de funções com intervalos de confiança

Adreas S. Weingend
David A. Nox

Resumo para a disciplina Redes Neurais.
Professor Antonio Carlos Thomé
Adriano Martins Moutinho

Obtendo barras de erro usando um esquema de máxima semelhança

- Usar redes neurais não só para estimar a média de uma função $f(x)$, mas também para estimar $v(x)$, a variância de $f(x)$.
- Utiliza-se, para isto, uma camada de neurônios auxiliar que estima a variância da função, escolhe-se uma função de ativação exponencial para este neurônio.



O problema do alvo

- O alvo para as unidades de saída é facilmente obtido, pois é a função $f(x)$ que se deseja estimar.
- No entanto, o alvo para os neurônios que estimam a variância não está disponível, sendo então criado um método de atualização dos pesos destas camadas maximizando o negativo do Log da semelhança ou custo, dado por:

$$C = -\sum_i \ln P(x_i / d_i, \eta)$$

Modelo Gaussiano de Erro

- Assumindo um modelo gaussiano para o erro, ou seja, que $f(x)$ será aproximada por $d(x) + n(x)$.

$$P(x_i/d_i, N) = \left[\frac{1}{\sqrt{2\pi\sigma^2(x_i)}} \right] \cdot e^{-\left\{ \frac{[d_i - \mu(x_i)]^2}{2\sigma^2(x_i)} \right\}}$$

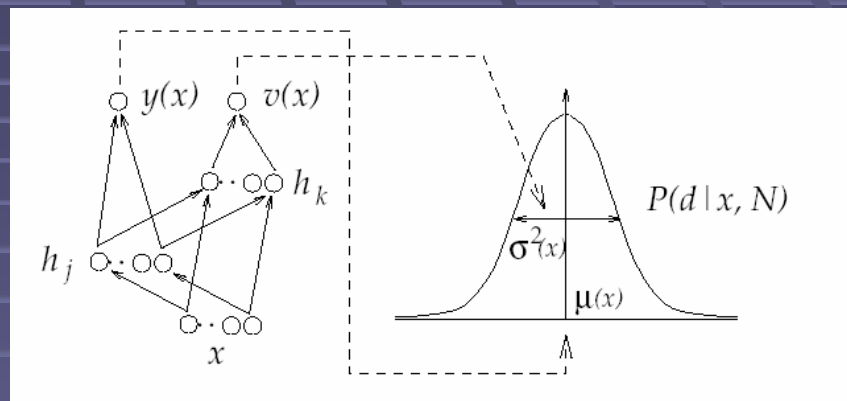
$$\therefore -\ln(P(x_i/d_i, N)) = \frac{2\pi v(x_i)}{2} + \left[\frac{[d_i - y(x_i)]^2}{2v(x_i)} \right]$$

$$C = -\sum \ln P(x_i/d_i, N) = \sum \frac{1}{2} \left(\frac{[d_i - y(x_i)]^2}{v(x_i)} + \ln[v(x_i)] \right)$$

Backpropagation para camada de estimativa de variância

- Para a camada y temos:
(derivando o custo C em respeito aos pesos)

$$\Delta w_{yj} = \eta \cdot \frac{1}{v(x_i)} [d_i - y(x_i)] h_j(x_i)$$



- Para a camada v temos:

$$\Delta w_{vj} = \eta \cdot \frac{1}{2 \cdot v(x_i)} \left[[d_i - y(x_i)]^2 - v(x_i) \right] h_j(x_i)$$

Modificação feita na taxa de aprendizado, baixando em faixas onde a variância é alta!

Mecânica de treinamento

- Como a camada de estimativa da variância faz a atualização dos pesos de acordo com uma estimativa da variância dos padrões de entrada. O treinamento é dividido em três partes para evitar valores imprecisos de variância, até que $y(x)$ (saída da rede) esteja pelo menos um pouco aproximado à $f(x)$. O treinamento é dividido em três partes.

Mecânica de treinamento (cont.)

- Fase 1 (Aprendendo a média):

Os dados são divididos aleatoriamente em duas partes iguais A e B. Faz-se o treinamento usando gradiente descendente simples, ignorando os termos de variâncias na equações de atualização de pesos, e usando A como treinamento e B como validação cruzada.

Mecânica de treinamento (cont.)

- Fase 2 (Aprendendo a variância):

Usando agora B como treinamento e A como validação cruzada, se conecta a camada v e treina-se usando como função de performance os erros quadráticos. Usa-se, para tal, ainda um gradiente descendente simples ignorando os termos de variância nas atualizações de pesos. Os pesos obtidos na fase 1 ficam congelados.

Mecânica de treinamento (cont.)

- Fase 3 (Regressão ponderada):

Divide-se novamente o conjunto de dados em A' e B' , descongela-se todos os pesos e usa-se o treinamento conforme descrito anteriormente, ou seja, usando-se os termos de variância que impedem que o ajuste dos pesos seja grande em regiões onde a variância é grande.

Experimento #1

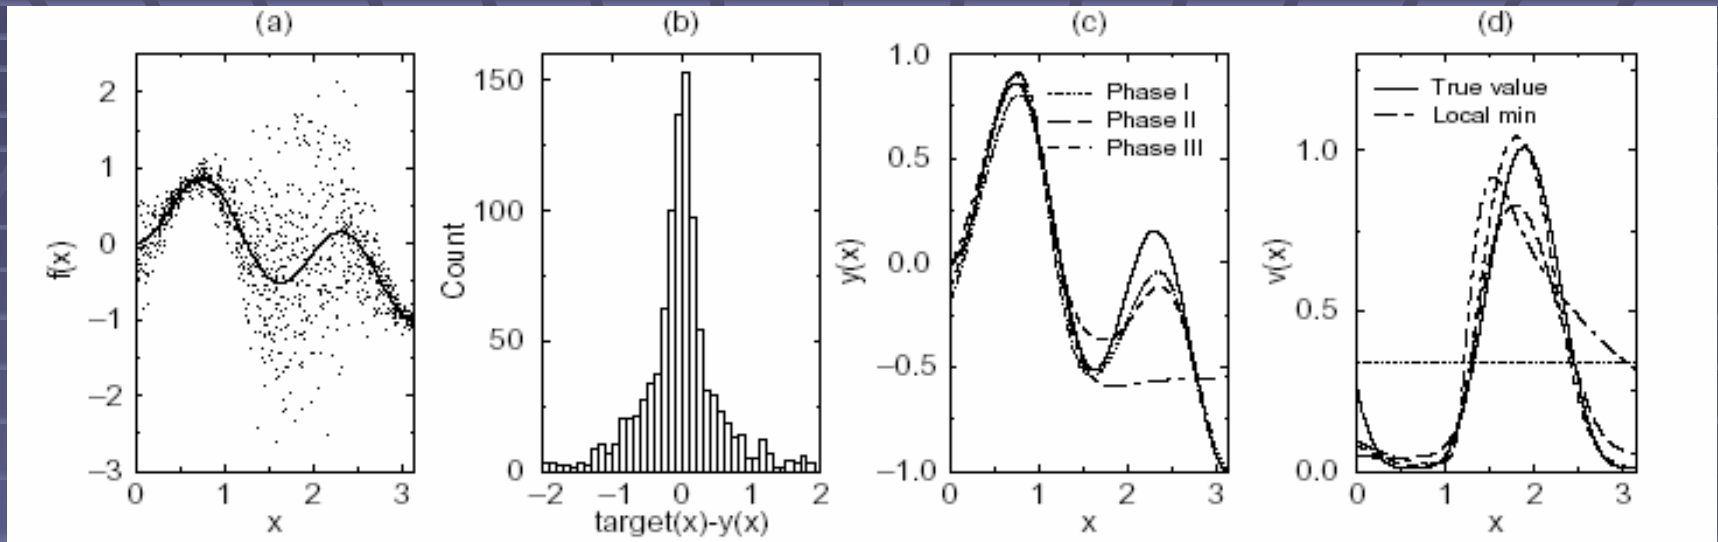
- Gera-se dados a partir de uma $f(x)$ conhecida, tendo uma variância $\sigma^2(x)$ também conhecida.

$$f(x) = \sin(w_\alpha x) \cdot \sin(w_\beta x) \rightarrow w_\alpha = 2,5 \text{ e } w_\beta = 1.5$$

- O alvo é gerado adicionando-se um ruído gaussiano com variância em função de x .

$$\sigma^2(x) = 0,01 + 0,25 \cdot [1 - \sin(w_\alpha x)]^2$$

Experimento #1 (cont.)



Conclusões:

- O uso das três fases permitiu uma melhor aproximação da função $f(x)$ na faixa onde o ruído é menor, ignorando a faixa onde há maior incerteza. Obteve-se também, uma melhor aproximação da variância de $f(x)$.

Experimento #2

- Banco de dados da competição “Santa Fé” de intensidade de lasers.
- O objetivo da competição era estimar, com barras de erro, uma continuação de 100 pontos para a série de intensidade de lasers.
- Foram usados métodos para reamostrar a série e obter mais do que os 1000 pontos disponíveis.

Experimento #2 (cont.)

- Usando-se o método descrito no paper, foram executadas as etapas 1, 2 e 3 sem nenhuma alteração significativa.
- No entanto, para melhorar a performance da rede, foi utilizada uma técnica de validação que previa 100 pontos de continuação da série a partir de 500 pontos contínuos retirados de um local aleatório dos dados.

Experimento #2 (cont.)

- Assim, foram geradas duas continuações para a série. Uma chamada “single step” e outra iterativa.
- Na série “single step” a continuação é gerada automaticamente pela rede.
- Na continuação iterativa, faz-se previsões para a série usando \pm uma variância do vetor de entrada. Se a distância entre estas duas previsões for maior que a estimativa de variância dada pela rede, esta distância é usada como estimativa de erro.
- Também foi colocada um limite em 4 na variância prevista pois na competição era muito crítico definir uma barra de erros muito pequena.


Experimento #2 (cont.)

Resultados:

	Train		Test		
	900-pt single st. NMSE	900-1000 iterated NMSE	1-100 single st. NMSE	1-100 iterated NMSE	NALL
Naive Baseline	—	—	—	1.001	8.50
Sauer (1994)	—	—	—	0.080	4.84
Wan (1994)					
Network	0.0004	0.0026	0.0230	0.055	—
Competition Entry	—	—	—	0.028	3.48
This Paper					
Network	0.0010	0.0142	0.0198	0.096	—
Competition Conditions	—	—	—	0.016	3.28

- Os resultados foram melhores que os dois primeiros colocados na competição


Resultados



- O histograma decai rapidamente, o que indica um bom desempenho do sistema.
A não simetria do histograma indica variância não uniforme

Conclusões:

- A série foi bastante aproximada pela técnica até próximo a $t = 66s$, onde ocorre um colapso e os valores passam a não ser mais previsíveis. Neste ponto a previsão passa a ser feita com base na média e variância do ponto de treinamento onde isso também ocorre.



Conclusões finais

- Este método pode ser usado como método matemático de previsão da variância de uma série temporal, tendo-se uma previsão dos pontos onde a série não será previsível.
- Com alguns ajustes, pode-se utilizar os métodos descritos neste paper em problemas de classificação de padrões, onde se terá a classe a qual pertence o padrão, bem como uma quantificação da incerteza deste fato.