

Redes Neurais para Previsão de Séries Temporais


Bilzã Araújo

Conteúdo

- Introdução
- Arquiteturas
 - MLP
 - Elman
 - FIR
- Redes FIR
 - Plausibilidade Biológica
 - Temporal Backpropagation
- Considerações finais

Séries Temporais

- Ordem dos dados é fundamental
- Observações vizinhas são dependentes
- A evolução temporal encapsula informações importantes




Séries Temporais


- Análise da série temporal
- Previsão a partir da série temporal

$$x(1), x(2), \dots, x(n)$$

$$x(n+1), x(n+2) \dots$$




Arquitetura MLP




- MLP
- Representando tempo no espaço de atributos

Arquitetura MLP





- Bufferização
- Segmentação em tamanhos iguais
- Posição temporal relativa x absoluta

Arquitetura Elman



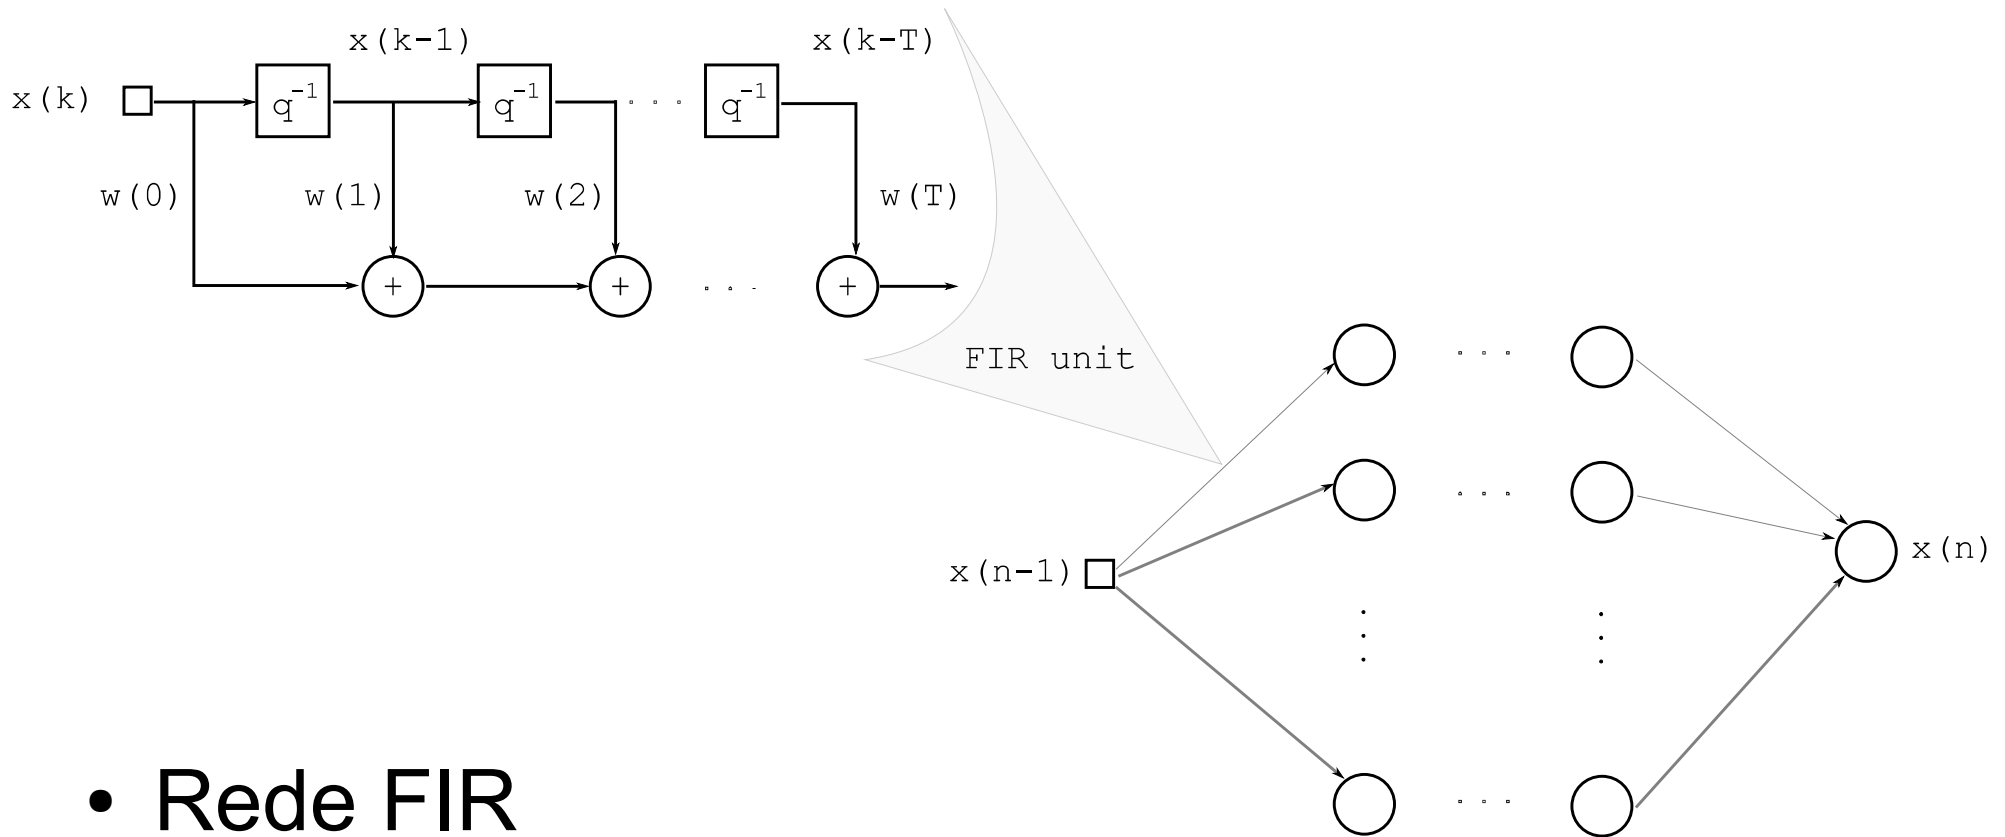
- Rede de Elman
- Recorrência e unidades de contexto

Arquitetura Elman



- Memória sem limite rígido
- Decaimento exponencial
- *high depth, low resolution memory*

Arquitetura FIR




- Rede FIR
- Sinapses filtros Finite Impulse Response

A.D. Back and A.C. Tsoi, "FIR and IIR synapses, a new neural network architecture for time series modeling", Neural Computation, Vol. 3, pp. 375-385, 1991.

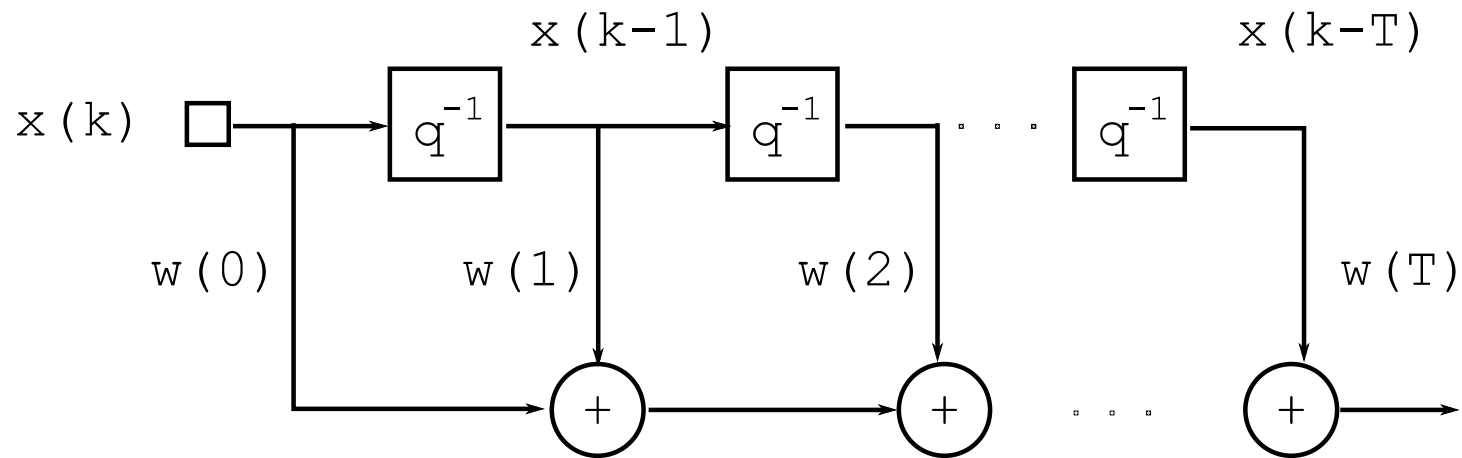
E. Wan, Finite impulse response neural networks with applications in time series prediction, Ph.D. Dissertation, Stanford University, November 1993.

Plausibilidade Biológica



- Integração espacial e temporal
- Transporte axonal
- Modulação sináptica
- Dissipação carga da membrana

Filtro FIR



$$s(k) = \sum_i \sum_{n=0}^T w_i(n) x_i(k-n)$$

$$y(k) = f(s(k))$$

Temporal Backpropagation

- Aprendizado Supervisionado

$$e(k) = d(k) - y(k)$$

- Ajuste dos coeficientes dos filtros (pesos)

$$J = \sum_{k=1}^K e(k)^T e(k)$$

Temporal Backpropagation

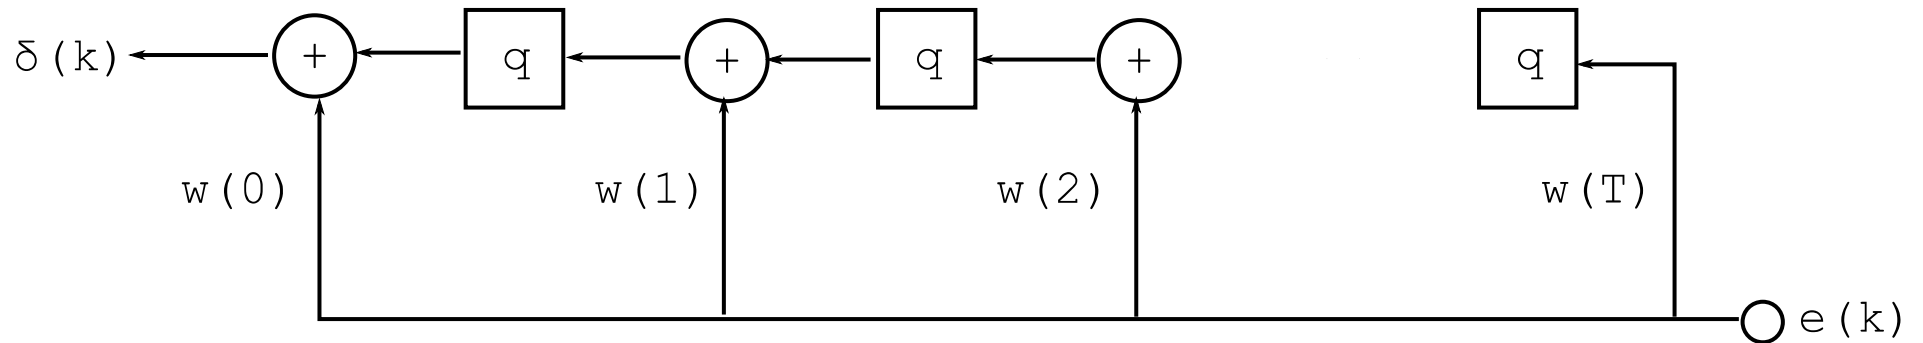
- Gradiente descendente instantâneo

$$W_{ij}^l(k+1) = W_{ij}^l(k) + \mu \frac{\partial e^T(k) e(k)}{\partial W_{ij}^l(k)}$$

- Temporal Backpropagation

$$\frac{\partial J}{\partial W_{ij}^l} = \sum_{k=1}^K \frac{e(k)^T e(k)}{W_{ij}^l}$$

Temporal Backpropagation



$$\Delta W_{ij}^l(k) = -\mu \delta_j^{l+1}(k) \cdot x_i^l(k)$$

$$\delta_j^{l+1}(k) = \begin{cases} -2e_j(k) f'(s_j^L(k)) & l = L \\ f'(s_j^l(k)) \cdot \sum_m \delta_m^{l+1}(k) \cdot W_{jm}^{l+1} & 1 \leq l \leq L-1 \end{cases}$$

Considerações Finais

- Extendendo as sinapse através de filtros FIR a rede torna-se capaz de processar características temporais
- Substituindo os parâmetros \mathbf{x} , \mathbf{w} e δ por escalares temos exatamente o algoritmo backpropagation
- Rede estável (garantia de convergência) com *high resolution* e *low depth memory*.
- Parâmetro de profundidade (T) determina sensibilidade dos filtros
- O ajuste dos coeficientes dos filtros permite dar maior/menor relevância as informações temporais

Obrigado pela Atenção!