

Redes Neurais Artificiais

Uma Perspectiva de Filtragem

1. Filtragem e redes neurais artificiais	2
2. Aplicações.....	9
Referências.....	12

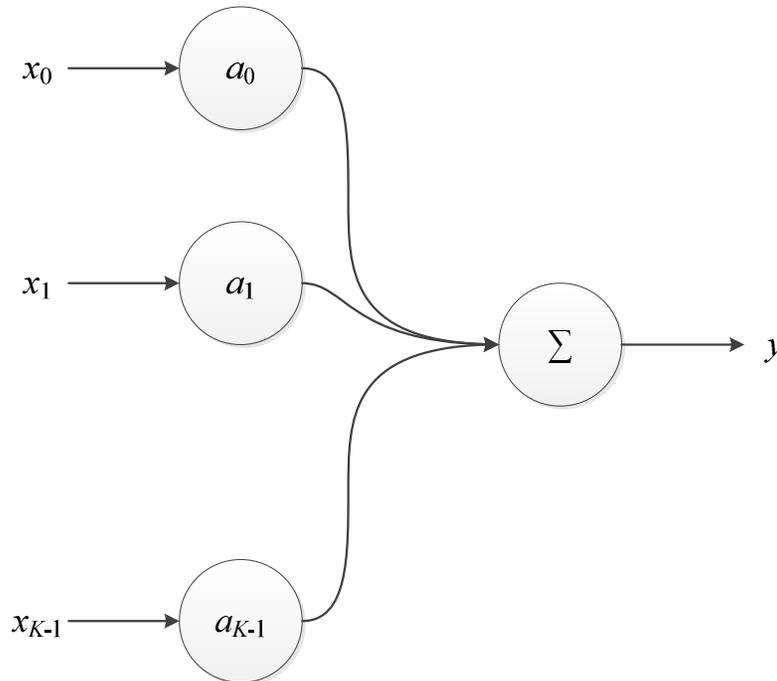
1. Filtragem e redes neurais artificiais

- Uma maneira particularmente interessante de visualizar como os diversos tópicos de redes neurais estão relacionados consiste em pensar nas diferentes vertentes sob o ponto de vista de um problema de filtragem.



- No âmbito de filtragem (adaptativa), o desafio é criar um sistema (filtro) que desempenhe uma determinada tarefa desejada no tocante à saída que ele produz para cada sinal de entrada.
- Para isto, três escolhas são absolutamente vitais: (1) estrutura; (2) critério; e (3) algoritmo de otimização.

- A primeira escolha está relacionada à estrutura do modelo, ou seja, a como pode ser caracterizado o mapeamento entrada-saída gerado pelo sistema.
- Neste contexto, é preciso considerar aspectos relacionados à linearidade, causalidade, presença ou não de realimentação (memória), etc.
- **Exemplo:**



Combinador linear

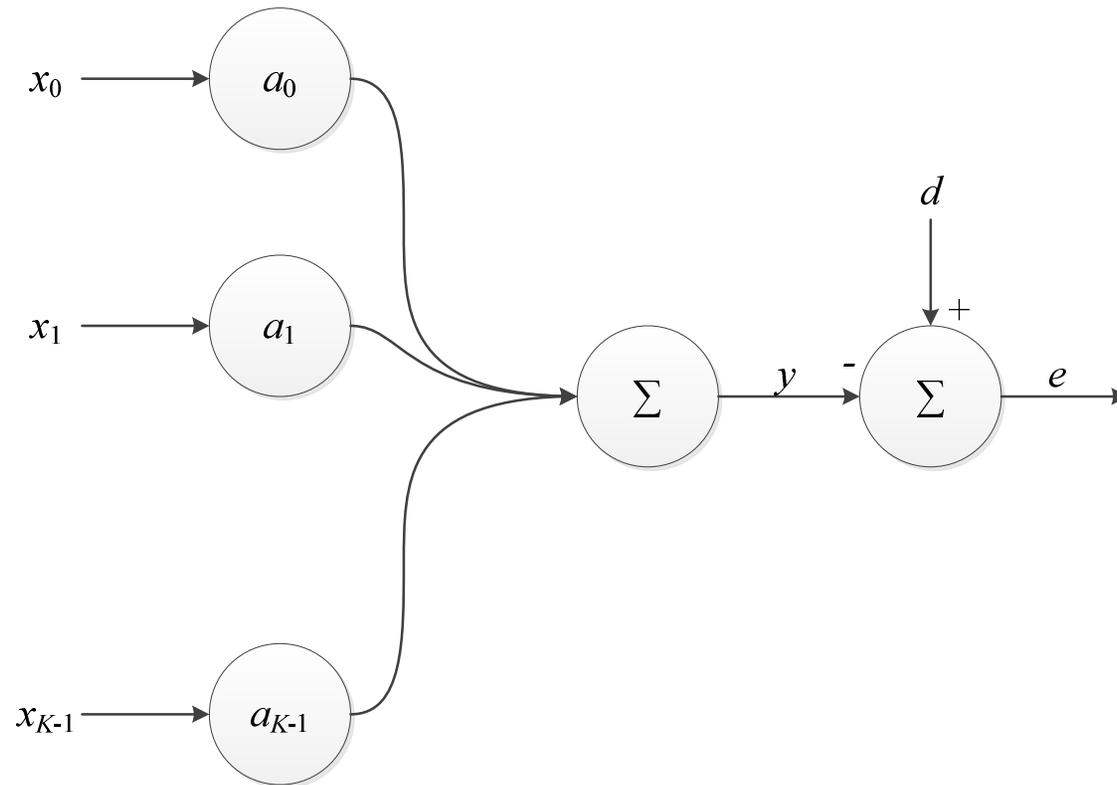
$$y = \sum_{i=0}^{K-1} a_i x_i$$

- **Temas relacionados:**

- ✓ Redes *feedforward*: MLP, RBF, ELM.
 - ✓ Redes recorrentes: Hopfield, ESN.
 - ✓ Mapas auto-organizáveis.
 - ✓ Aprendizado construtivo.
 - ✓ *Deep learning*.
- Implicitamente, diversas questões estão envolvidas na definição da estrutura do sistema neural:
 - ✓ Qual o modelo de neurônio artificial?
 - ✓ Quantas camadas existem na rede?
 - ✓ Qual o padrão de conectividade entre as unidades da rede?
 - A estrutura escolhida para o sistema, a qual é caracterizada pela existência de diversos parâmetros (e.g., os coeficientes a_i da combinação linear), precisa ser ajustada ou adaptada tendo em vista um objetivo específico.

- A segunda escolha tem a ver com o critério de adaptação (otimização), o qual exprime matematicamente o que se deseja atingir durante o processo de adaptação ou aprendizado, revelando o grau de sucesso alcançado pela rede na realização da tarefa.
- Tal escolha gravita em torno de um aspecto importante: a quantidade de informação a priori que se encontra disponível com respeito ao comportamento desejado.
- **Conceitos relacionados:**
 - ✓ Aprendizado supervisionado.
 - ✓ Aprendizado não-supervisionado.
 - ✓ Função de erro (custo).
 - ✓ Regularização.
 - ✓ Capacidade de generalização.

Exemplo:



- Deseja-se encontrar os valores dos coeficientes a_i que façam com que a saída y seja a mais parecida possível com a referência d .

- Dada a disponibilidade de uma resposta desejada para o padrão de entrada fornecido ao sistema, é possível observar o sinal de erro (e) e, portanto, estabelecer como critério a minimização de uma função diretamente ligada ao erro, como, por exemplo, o erro quadrático médio:

$$\min_{a_i} \frac{1}{N} \sum_{k=1}^N |e_k|^2$$

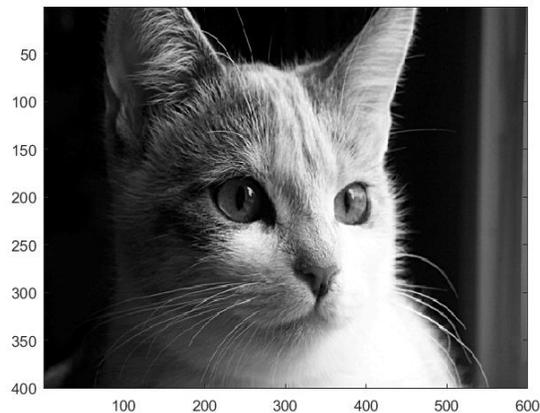
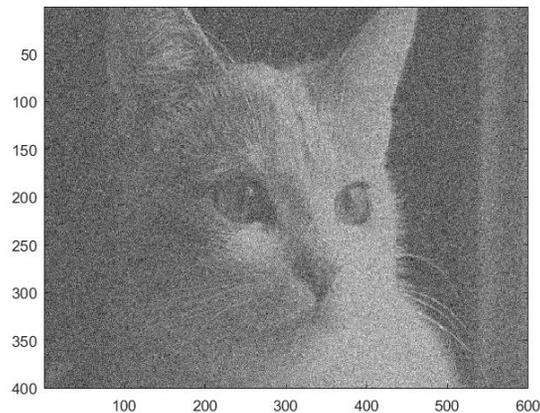
- Via de regra, o objetivo deve ser atingido no maior nível possível. Em outras palavras, busca-se o conjunto de parâmetros do sistema que otimize uma determinada função matemática que representa o objetivo a ser alcançado. Logo, a definição do critério dá origem a um problema de otimização.
- Por fim, uma vez estabelecido o objetivo e conhecida a estrutura do modelo, é preciso escolher o algoritmo responsável por encontrar os parâmetros ótimos do sistema.

- No exemplo do combinador linear, existe uma solução em forma fechada baseada na pseudoinversa de Moore-Penrose que minimiza o erro quadrático médio.
- **Temas relacionados:**
 - ✓ Otimização não-linear.
 - ✓ Retropropagação do erro (*error backpropagation*).
 - ✓ *Online* x *offline*.
 - ✓ Iterativo x solução fechada.
 - ✓ Batelada x padrão-a-padrão.
- Evidentemente, o sucesso no emprego de uma rede neural em uma determinada tarefa de aprendizado de máquina depende do quão adequadas são as escolhas feitas diante das características do problema.

2. Aplicações

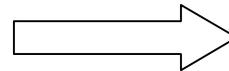
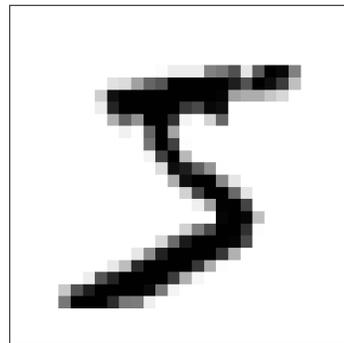
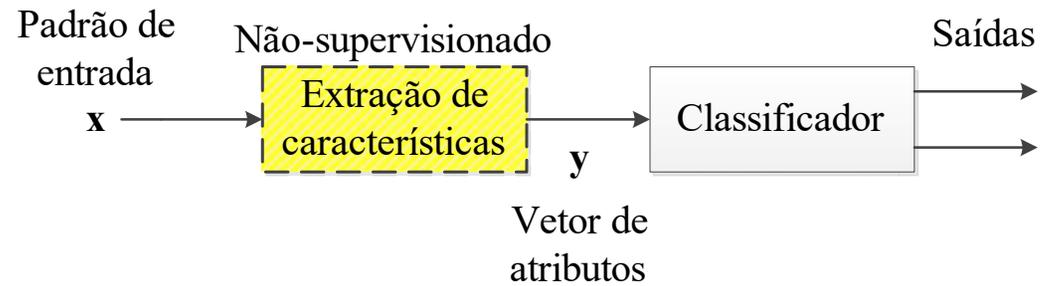
- **Associação de padrões (memória associativa):**

- ✓ O modelo é construído a fim de armazenar padrões puros que devem ser recuperados; dada uma entrada com distorções ou ruído, o modelo deve fornecer na saída o padrão correspondente.



Reconhecimento de padrões (classificação):

- ✓ Para cada padrão de entrada, o objetivo é identificar a classe à qual ele pertence.



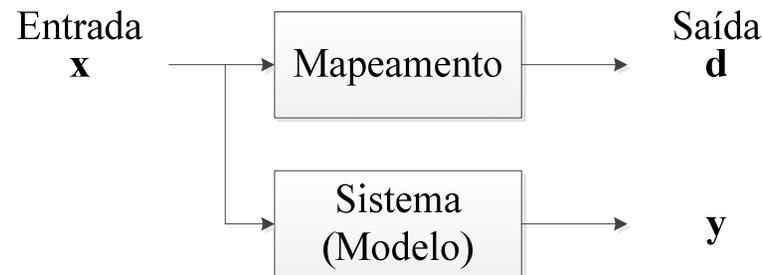
Dígito '0' – 0
Dígito '1' – 0
⋮
Dígito '5' – 1
⋮
Dígito '9' – 0

- **Aproximação de funções:**

- ✓ A partir de um conjunto de amostras entrada-saída $\{\mathbf{x}_i, \mathbf{d}_i\}$, $i = 1, \dots, N$, queremos construir um modelo que forneça uma boa aproximação do mapeamento desconhecido, inclusive quando tivermos na entrada novos padrões \mathbf{x} (que não foram utilizados durante o ajuste do modelo).

- ✓ **Casos práticos:**

- Identificação de sistemas.
- Identificação inversa (e.g., equalização de canais).
- Predição de séries temporais.



- **Controle:**

✓ O objetivo é forçar a planta a seguir um comportamento desejado em sua saída.



Referências

HAYKIN, S. “Adaptive Filter Theory”, Pearson, 5th edition, 2013.

ROMANO, J. M. T., ATTUX, R. R. F., CAVALCANTE, C. C. & SUYAMA, R. “Unsupervised Signal Processing: Channel Equalization and Source Separation”, CRC Press, 2011.