

- 
- 
- 
- 
- 

# IF-705 – Automação Inteligente

## Redes Neurais para Modelagem e Controle

Aluizio Fausto Ribeiro Araújo  
Universidade Federal de Pernambuco  
Centro de Informática - CIn  
Departamento de Sistemas da Computação  
aluizioa@cin.ufpe.br



- 
- 
- 
- 
-

# Sumário

- Introdução
- Neuro-Modelagem e Arquitetura de Controle
  - Estratégias de Modelagem
  - Arquitetura de Controle Supervisionado
  - Sistemas com Aprendizado por Reforço
  - Parametrização de Controladores Lineares

# Introdução

- Modelagem e controle adaptativo empregam cada vez mais modelos de computação inteligente;
- Aplicações em Controle Inteligente (CI) requerem algoritmos capazes de:
  - *Operar* em ambiente mal-definido e variante no tempo;
  - *Adaptar-se* a mudanças na dinâmica da planta ou do processo bem como ao efeitos do ambiente;
  - *Aprender* informações relevantes do meio-ambiente;
  - *Adicionar* poucas restrições à dinâmica da Planta.

# Introdução

- As características anteriores são essenciais para operação de sistema em ambientes incertos, com o mínimo de intervenções externas.
- O aprendizado humano possui as características desejadas. O desafio é dotar as máquinas com tais características.
- A capacidade de adaptação autônoma da computação inteligente oferece à área de Engenharia de Controle (EC):
  - Melhoria no desempenho de sistemas de controle devido à sua capacidade de adaptação;
  - Aumento da qualidade da solução;
  - Possibilidade de autonomia para os sistemas;
  - Diminuição dos custos de projeto e operacionais.

# Introdução

- Em geral, algoritmos de computação inteligente utilizam:
  - Linearização da planta e modelos de controladores;
  - Definição de diferentes valores de parâmetros para permitir flexibilidade e adaptação ao sistema.
- RNAs podem se aplicadas a sistemas *não-lineares*.
- Um sistema de controle inteligente pode ser implementado com diferentes tipos de RNAs e de algoritmos de aprendizagem:
  - A escolha do sistema de aprendizagem (abordagem e arquitetura) depende fundamentalmente do problema em questão.

# Neuro-Modelagem e Arquitetura de Controle

- Blocos de aprendizagem são empregados nos algoritmos de modelagem e controle neuro-inspirados.
- Modelagem e arquiteturas de controle são em geral independentes da abordagem de aprendizagem a ser empregada:
  - Algumas abordagens podem ser mais adequadas que outras;
  - A habilidade para modelagem e aprendizagem determina a aplicabilidade de uma escolha.
- O grau com que um algoritmo de aprendizagem satisfaz os pontos acima determinam sua adequação para modelagem e controle por aprendizagem online.

# Neuro-Modelagem e Arquitetura de Controle: Representação

- Sistema de equações de estado que representa um sistema de controle SISO contínuo no tempo:

$$\dot{\mathbf{x}}(t) = \mathbf{f}(\mathbf{x}(t), u(t))$$

$$y(t) = g(\mathbf{x}(t))$$

- Para um sistema SISO discreto no tempo:

$$\mathbf{x}[k+1] = \mathbf{f}(\mathbf{x}[k], u[k])$$

$$y[k] = g(\mathbf{x}[k])$$

onde  $\mathbf{x}[k]$  é o vetor do estado da planta,  $u[k]$  é o sinal de controle e  $y[k]$  é a saída observada da planta.

# Neuro-Modelagem e Arquitetura de Controle: Representação

- A maioria dos modelos de plantas, admite que o sinal de saída possui informações sobre estados anteriores da planta, ou seja:

$$y[k] = h(\mathbf{y}[k-1], \mathbf{u}[k])$$

onde  $\mathbf{y}[k-1]$  é um vetor de comprimento  $n_y$ , formado pelas saídas passadas  $y[k-1], \dots, y[k-n_y]$  e  $\mathbf{u}[k]$  é um vetor de comprimento  $n_u+1$ , formado pelas ações de controle presente e passadas  $u[k], \dots, u[k-n_u]$ .



# Neuro-Modelagem e Arquitetura de Controle: Representação

- Resta escolher os valores de  $n_y$  e  $n_u$  apropriados:
  - Se forem muito grandes, haverá perda de generalização e convergência pobre devido a sobre estimativa;
  - Se forem muito pequenos, o modelo será incapaz de captar a dinâmica existente, afetando a estabilidade de aprendizagem do sistema de controle.

# Neuro-Modelagem e Arquitetura de Controle: Representação

- Na década de 80, foi criada uma estrutura de modelagem não-linear genérica chamada de NARMAX (Nonlinear Auto-Regressive Moving Average Models with eXogenous inputs):

$$y[k] = h(y[k-1], \dots, y[k-n_y], u[k], \dots, y[k-n_u]) + e[k] \quad \text{Eq.4.4}$$

onde  $e[k]$  é uma perturbação aditiva.

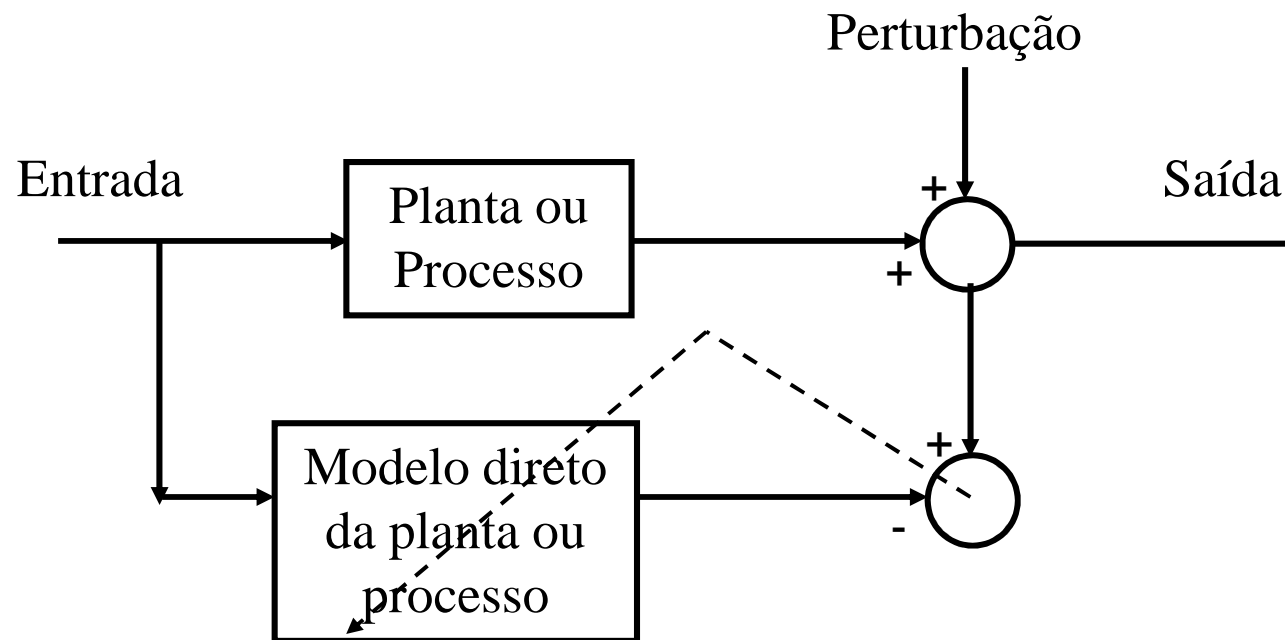
- Este é um modelo genérico, de forma que vários tipos de RNAs podem se adequar a ele.

# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

- Há quatro arquiteturas principais nos módulos de aprendizagem para modelar a planta:
  - Modelo Básico (ou Direto) da Planta (MDP);
  - Modelo Inverso da Planta (MIP);
  - Modelo de Operador (MO);
  - Modelo Inverso Especializado da Planta (MIEP).
- O sinal de entrada deve varrer todo o espaço de entrada da rede.
- Nos três primeiros casos, a saída obtida é comparada à desejada, produzida pela planta. Portanto, aprendizagem supervisionada pode ser utilizada para treinar os pesos da rede.
  - Apenas no Modelo Inverso Especializado da Planta, a saída da rede é a entrada da planta e o erro é considerado na saída desta.

# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

- Arquiteturas do Modelo Direto da planta ou processo:



# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

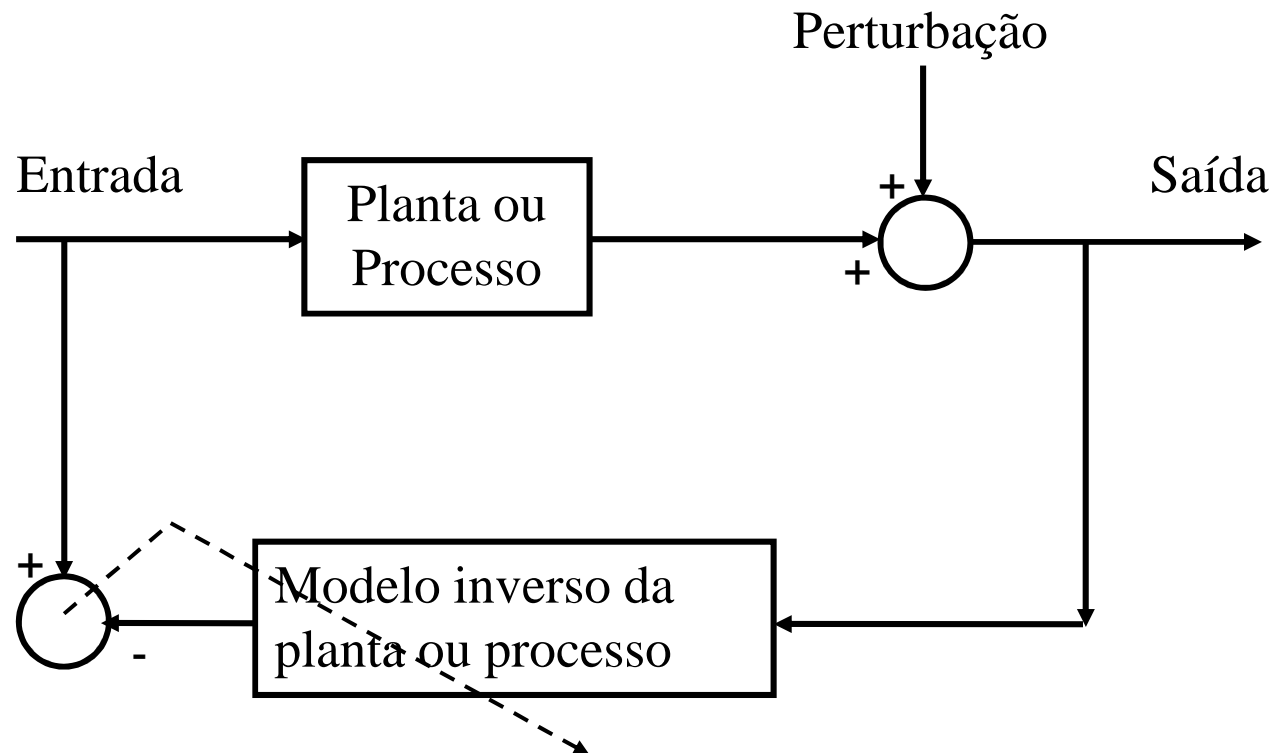
- Modelagem Básico da Planta (Modelo Direto da Planta)
  - O objetivo é modelar (identificar) o funcionamento da planta ou processo considerando suas entradas e saídas como pares para o treinamento.
  - A função de custo busca minimizar a esperança do erro quadrático:

$$J_y = E(\varepsilon_y^2(t)), \quad \varepsilon_y(t) = \hat{y}(t) - y(t)$$

onde  $y(t)$  é a saída da rede e  $\hat{y}(t)$  é a saída da planta.

# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

- Arquiteturas do Modelo Inverso da planta ou processo:



# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

- Modelagem Inversa da Planta

- O objetivo é formular um *controlador* de forma que a arquitetura como um todo (controlador/planta) tenha uma unidade de função de transferência;
- A planta precisa ser total ou localmente inversível;
- A função de custo do controle tenta minimizar a esperança do erro quadrático:

$$J_u = E(\varepsilon_u^2(t)), \quad \varepsilon_u(t) = \hat{u}(t) - u(t)$$

onde  $u(t)$  é a saída de controle da rede e  $\hat{u}(t)$  é o sinal de controle medido.

# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

- Modelagem Inversa da Planta:
  - O erro do sinal de controle é relacionado com o erro da planta de um sistema SISO por uma primeira aproximação:

$$\varepsilon_y(t) \approx \frac{dy(t)}{du(t)} \varepsilon_u(t)$$

onde  $dy/du$  é o Jacobiano da planta.

- Então a função de custo da resposta da Planta será:

$$J_y = E(\varepsilon_y^2(t)) \approx E \left[ \left( \frac{dy(y)}{du(t)} \right)^2 \varepsilon_u^2(t) \right]$$

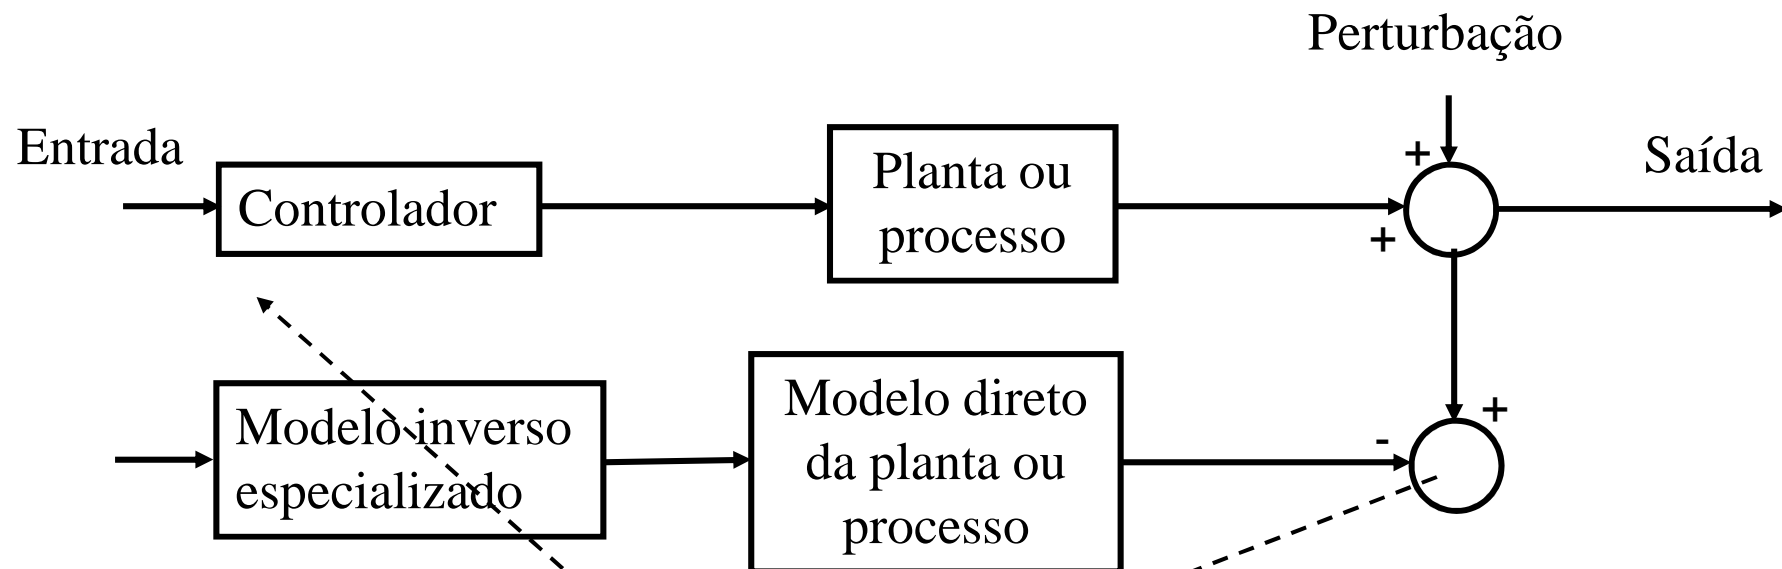


# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

- Modelagem Inversa da Planta :
  - Para planta não-linear, os valores do Jacobiano ( $dy/du$ ) devem variar, e haverá necessidade de ponderar o erro do controle.
  - Se o erro de saída não for correlacionado com o Jacobiano da planta, então:
$$J_y = E(\varepsilon_y^2(t)) \approx E\left[\left(\frac{dy(y)}{du(t)}\right)^2\right] E[\varepsilon_u^2(t)] \approx E\left[\left(\frac{dy(y)}{du(t)}\right)^2\right] J_u$$
  - E o Jacobiano poderá ser incorporado à taxa de treinamento.

# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

- Arquitetura do Modelo Inverso Especializado da Planta ou Processo
  - Após aprender o modelo da planta:



# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

- Modelagem Inversa Especializada da Planta:
  - De forma semelhante ao MIP, propõe um modelo inverso de planta com uma unidade de função de transferência.
  - O método é diferente daquele anteriormente descrito:
    - Constrói-se um Modelo Direto de Planta (MDP);
    - A diferença entre a resposta da MDP e da saída desejada forma um sinal de erro, que é retro-propagado para ajustar os parâmetros livres do Modelo Inverso.
  - A principal vantagem desta abordagem é o chamado *goal driven*. Isto é, tende a não aprender apenas ruídos.

# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

- Modelagem Inversa Especializada da Planta:
  - Para aplicações on-line, o erro de saída da planta força o MIP a se deslocar para regiões inexploradas no espaço das entradas, enquanto o MIEP só aprende quando o sinal de controle for suficientemente excitado.
  - Outra grande diferença o MIEP e o MIP é que o primeiro tenta minimizar o *erro quadrático da planta*, enquanto o segundo minimiza o *erro quadrático do controle*;
  - Novamente, se a planta for não linear, então como no MIEP, haverá uma incompatibilidade entre a verdadeira planta inversa e o modelo adaptativo.

# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

- Modelagem de Planta Inversa Especializada:
  - Arquiteturas de Modelagem Inversa podem ser utilizadas para *sintetizar* controladores, porém podem não ser tão robustos quanto controladores de aprendizagem alternativos, devido a falta de informação de realimentação.

# Neuro-Modelagem e Arquitetura de Controle: Estratégias de Modelagem

- Modelagem de Operadores:
  - O controlador é sintetizado pela aprendizagem de um especialista humano (operador do sistema);
  - O algoritmo de aprendizagem é rodado em paralelo a um operador habilidoso da planta:
    - As respostas do operador formam a saída desejada da RNA, que pode ser treinada com esses dados.
    - Em geral, o sinal que entra na rede precisa ser previamente filtrado pois existe muito ruído decorrente do fato que vários sinais de atuação diferentes resultam em sinais de entradas da rede similares.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Ao algoritmos de aprendizagem em baixo nível de abstração são definidos com respeito a modelos de modelagem e controle e arquitetura de sistemas de controle determinados.
- Uma dificuldade comum na elaboração de controladores com aprendizagem on-line é o *signal de desejado de controle* que frequentemente não está disponível.
- Em geral, a informação disponível é o *signal desejado da planta*:
  - Esta é a informação que pode ser empregada para treinamento do controlador.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Duas abordagens são definidas a partir de Controle Adaptativo:
  - Esquema direto: Constrói um modelo explícito do controlador desejado.
  - Esquema indireto: Produz um modelo da planta e sintetiza a lei de controle através de cálculo pré-definido de otimização/inversão.
- Exemplos de elaboração de controladores:
  - Controladores nebulosos auto-organizáveis são controladores diretos pois as regras nebulosas definem o controlador em si. Além disso, tais regras são modificadas a partir da avaliação conjunta dos erros de saída da planta e do controlador.
  - Sistemas de neuro-controle adaptativo são exemplos de esquema indireto pois constroem um modelo direto da planta para ser usado em um esquema de controle preditivo.



- 
- 

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Controladores diretos:
  - Controlador estabilizante fixo;
- Controladores indiretos:
  - Esquema aprendiz de controle preditivo;
  - Controle adaptativo por modelo de referência;
  - Controle de modelo interno.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Controlador Estabilizante Fixo:

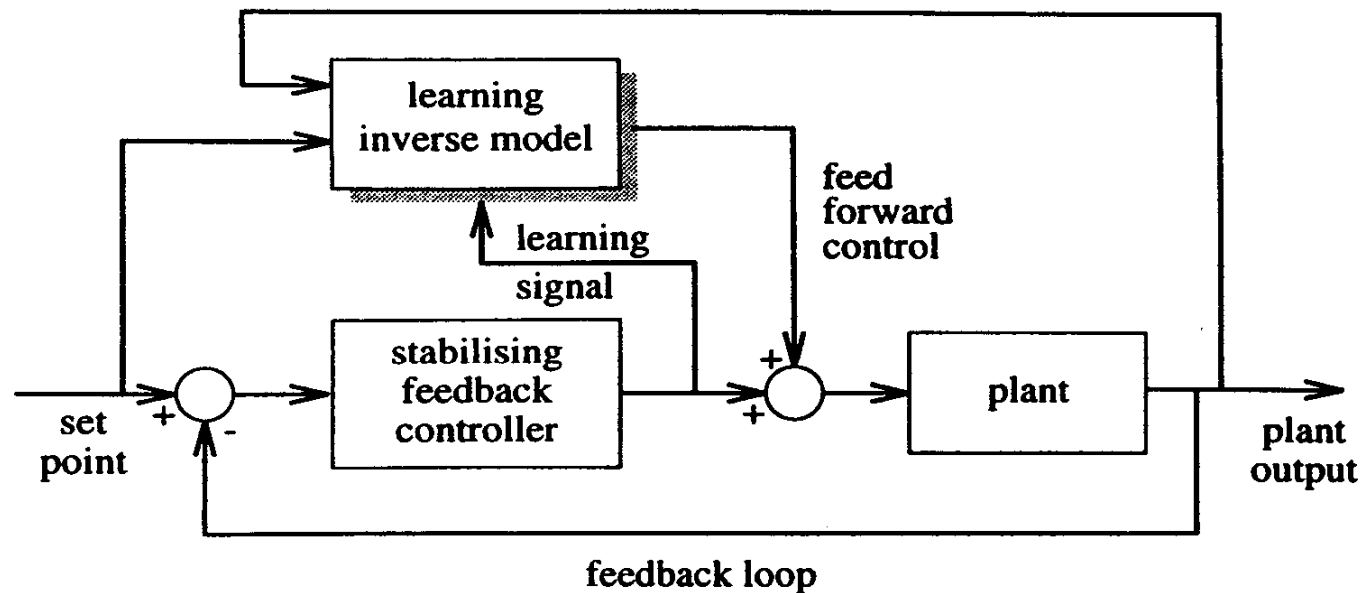


Figure 2.2 A direct learning controller; the fixed linear feedback controller is used to stabilise the system and to provide a training signal for the learning controller.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Controlador Estabilizante Fixo:
  - Controlador estabilizante leva o sistema a operação estável em seus pontos de operação. Ele se caracteriza por aprendizagem direta, estrutura fixa, linear e com controle com realimentação é utilizado para treinar uma rede de aprendizagem.
    - O desempenho do sistema de malha fechada depende do ponto atual de operação.
    - O sinal de controle atua como sinal de treinamento para o módulo de aprendizagem.
  - O treinamento on-line iterativo da RNA melhora gradualmente o desempenho tanto do sinal da planta quanto do sinal do controlador.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Controlador Estabilizante Fixo:
  - A apresentação de diferentes *set points* leva a aprendizagem do controlador a construir um modelo não-linear da superfície de controle desejada, de forma que a resposta da planta a um sinal antigo não seja “esquecido”. Isto deve ser visto com particular cuidado para aprendizagem supervisionada.
  - A aprendizagem sobre uma áreas do espaço de entradas afete minimamente o aprendido para outras regiões. Módulos neurais podem ser empregados para este tipo de aprendizagem.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Controlador Estabilizante Fixo:

- Desvantagens:

- Possuir um controlador linear fixo que determina o sinal de treinamento.
    - O módulo de aprendizagem se adapta vagarosamente se a performance do controlador linear for pobre.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Esquema Aprendiz de Controle Preditivo (EACP):
  - Controle com aprendizagem preditiva indireta configura uma estratégia de controle que avalia os efeitos das suas ações para muitos futuros passos de tempo. Escolhe-se a partir das avaliações futuras, a atual ação ótima de controle que será aplicada à planta.
  - A arquitetura requer:
    - Aprendizagem de um modelo de planta;
    - Uma função de desempenho que avalie o efeito a ação do controle;
    - Uma técnicas de otimização que determine a melhor ação de controle.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Esquema Aprendiz de Controle Preditivo (EACP):

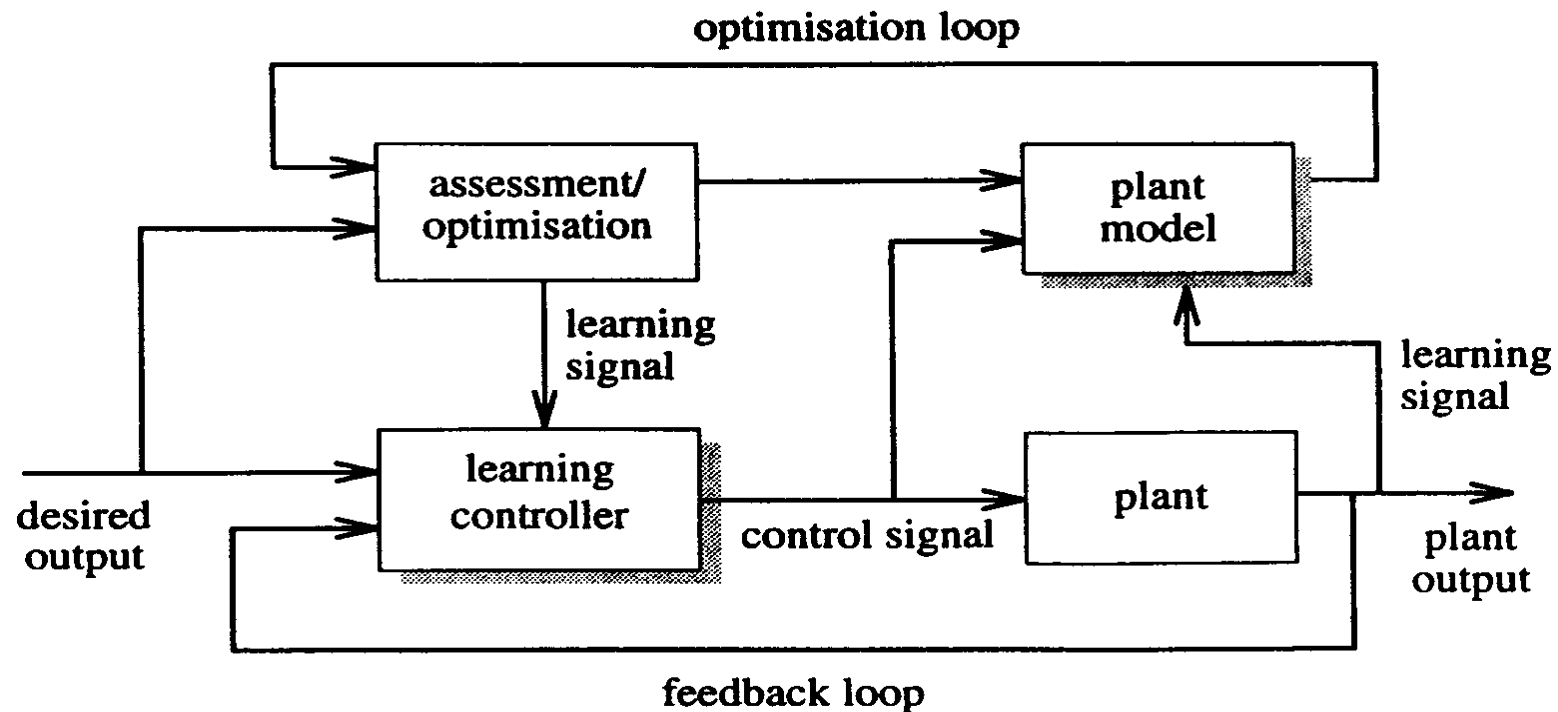


Figure 2.3 A learning predictive control architecture.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Esquema Aprendiz de Controle Preditivo (EACP):
  - Na figura, um elemento de aprendizagem de controle foi incluído. Portanto, após algum tempo de treinamento, espera-se que os cálculos com a otimização não precisem mais ser realizados.
  - Se a planta for variável temporalmente, o modelo geralmente é adaptativo, embora os cálculos iniciais da otimização podem resultar em um controle pobre, se o modelo do processo for pobre.
  - Se o modelo de planta for boa, e a função de performance e a estratégia de procura forem apropriadamente escolhidas, o regime de controle apresentará um excelente controle de laço fechado.



# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Esquema Aprendiz de Controle Preditivo (EACP):
  - Desvantagens:
    - Cálculo de otimização com múltiplos passos requer grande custo computacional, o que restringe a problemas em que o tempo de resposta não seja crítico.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Controle Adaptativo por Modelo de Referência:

- É largamente utilizado no campo de controle adaptativo linear.
- O objetivo é ajustar o sinal de controle, de maneira estável, tal que a saída da Planta  $y[k]$  convirja assintoticamente para a saída do modelo de referência desejado  $y^d[k]$ :

$$\lim_{k \rightarrow \infty} \|y[k] - y^d[k]\| < \varepsilon$$

- A performance do algoritmo depende da escolha de um modelo de referência adequado bem como de um mecanismo de aprendizagem apropriado.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Controle Adaptativo por Modelo de Referência:

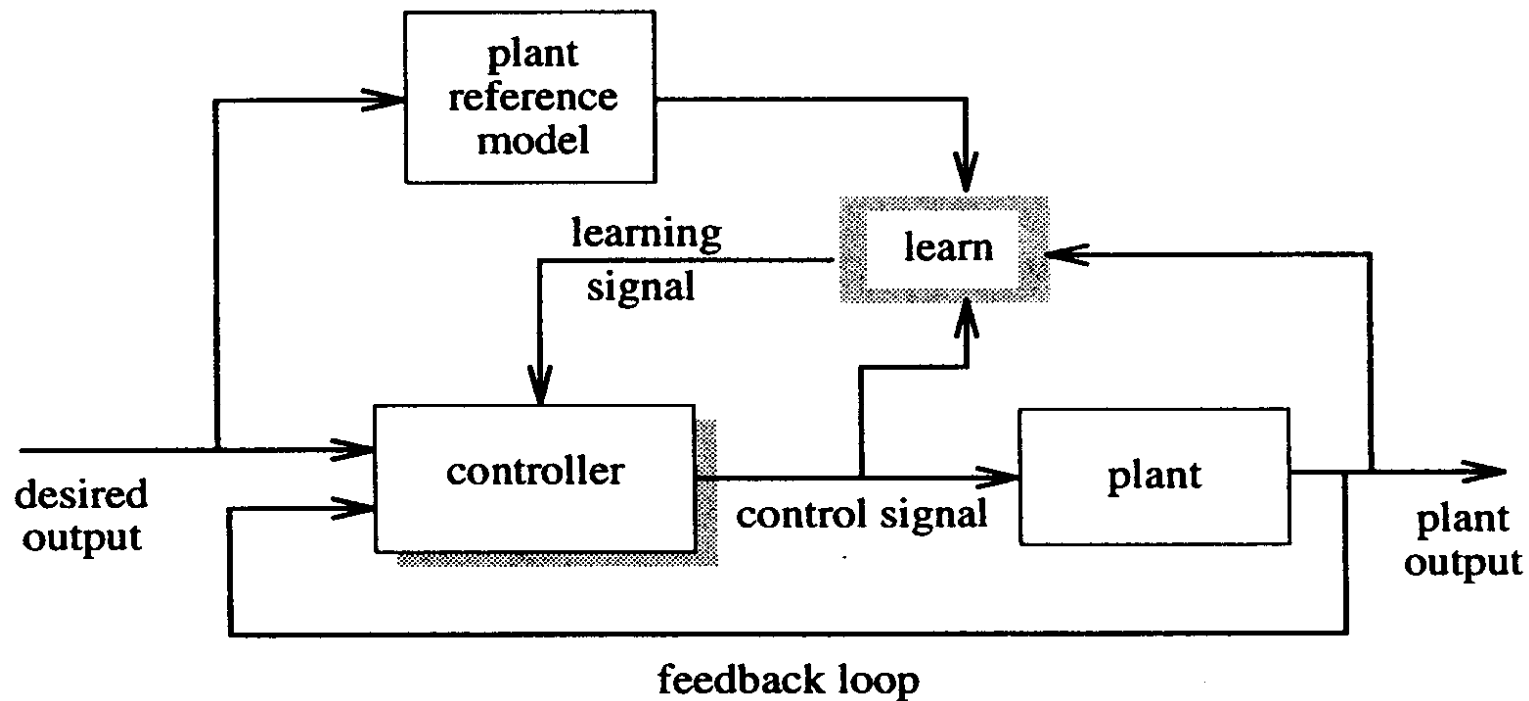


Figure 2.4 A model reference control architecture.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Controle de Modelo Interno:
  - Utiliza uma estrutura semelhante aquela do EACP.
  - Neste caso, o módulo de aprendizagem é usado para modelar o processo diretamente, recebendo o sinal de controle aplicado.
  - O erro entre o modelo e a saída da planta é usado como sinal de retorno e passado para o controlador;

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Controle de Modelo Interno:

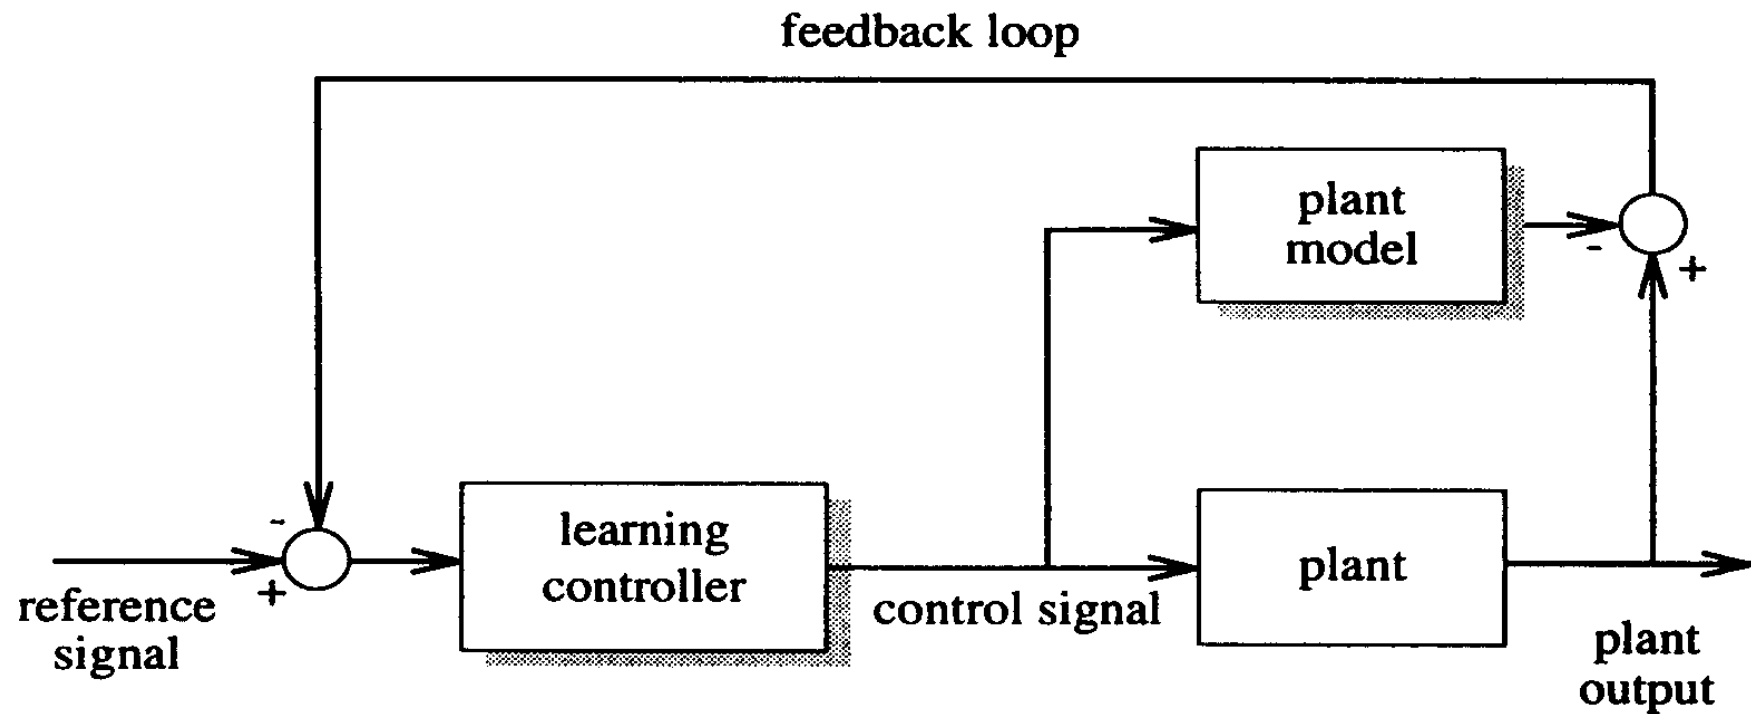


Figure 2.5 An internal model control architecture.

# Neuro-Modelagem e Arquitetura de Controle: Arquitetura de Controle Supervisionado

- Controle de Modelo Interno:
  - O modelo do Controlador Interno é geralmente ajustado para ser o inverso do modelo da Planta e qualquer dos regimes de modelagem inversa descritos anteriormente pode ser usado para sintetizar um Controlador apropriado.
  - Pode ser estendida para sistemas não-lineares a partir de avaliações de robustez e de estabilidade.

# Neuro-Modelagem e Arquitetura de Controle: Sistemas com Aprendizado por Reforço

- Na aprendizagem por reforço, a informação disponível é um retorno avaliativa para um conjunto particular de ações.
- Esta aprendizagem foi pioneiramente aplicada ao problema do pêndulo invertido com a restrição de que a plataforma do pêndulo não poderia se mover mais que uma certa distância da posição inicial, de forma a manter o pêndulo aproximadamente na vertical:
  - Se a restrição for violada então um sinal de falha é enviada para o algoritmo de aprendizagem;
  - O controlador determina o balanço do pêndulo invertido, cujos sinais de falha serão cada vez menos freqüentes com a aprendizagem.

# Neuro-Modelagem e Arquitetura de Controle: Sistemas com Aprendizado por Reforço

- A solução proposta foi construir um regime de controle composto por duas estruturas adaptativas:
  - Elemento de Procura Associativa (EPA): Reproduz um sinal de controle ótimo que satisfaça um determinado objetivo de performance.
  - Elemento Crítico Adaptativo: Monitora a performance do controlador internamente, e provê um sinal de reforço interno que é usado para treinar o EPA.
    - O ECA é treinado utilizando um sinal externo de sucesso/fracasso.



# Neuro-Modelagem e Arquitetura de Controle: Sistemas com Aprendizado por Reforço

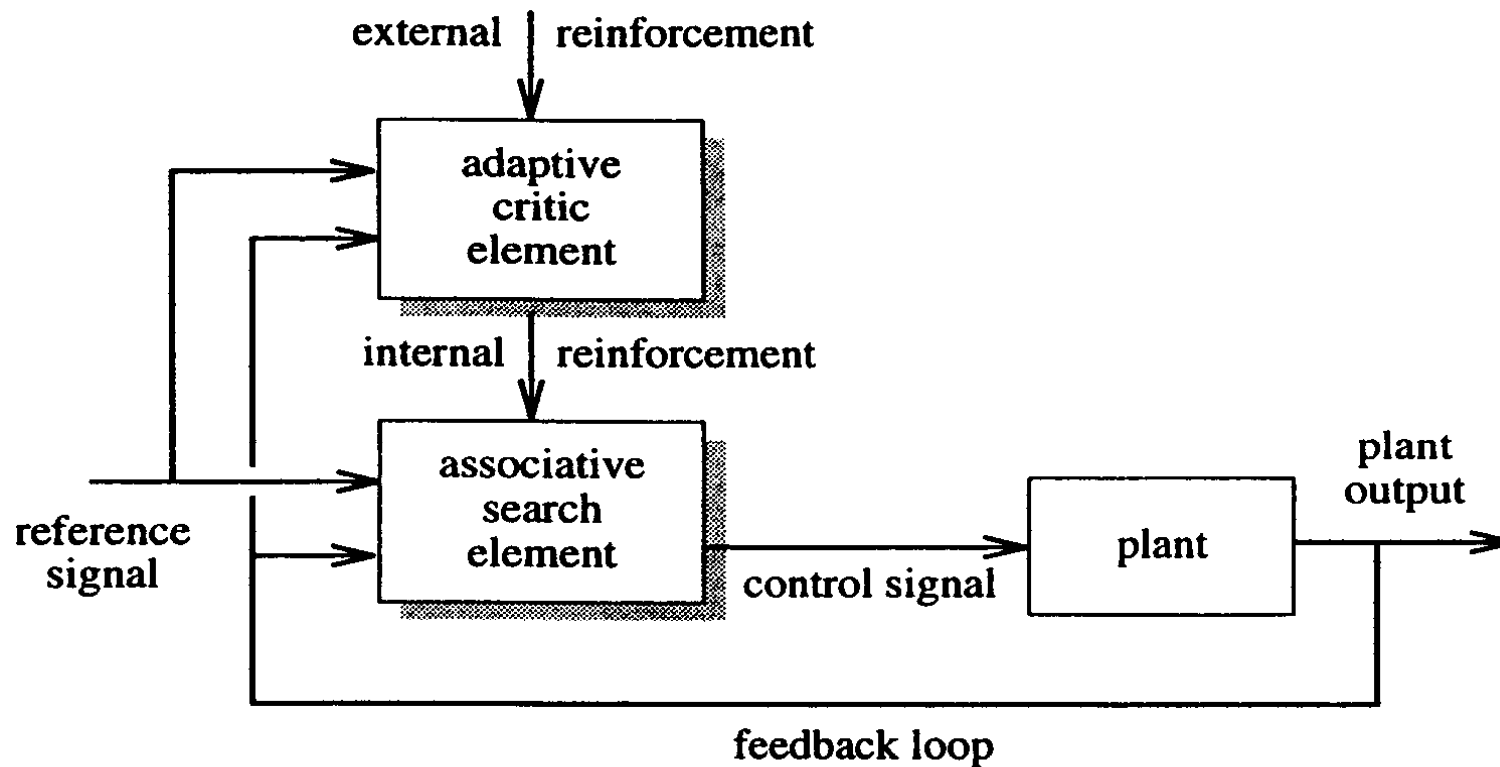


Figure 2.6 An ASE/ACE reinforcement system's architecture.

# Bibliografia Básica

- Brown, M. & Harris, C. (1994). *Neurofuzzy Adaptive Modelling and Control*. Prentice-Hall (International Series in Systems and Control Engineering). ISBN-10: 0-13-134453-6.
- Hunt, K. J., Sbarbaro, D., Zbikowski, R., & Gawthrop, P. J. (1992). Neural networks for control systems - A survey. *Automatica*, 28 (6): 1083-1112.
- IEEE Task force on Intelligent Control: <http://www3.nd.edu/~pantsakl/Publications/162-RTFIC.pdf>
- Passino, K. M. (2010) Intelligent Control. In *The Control Systems Handbook*, Second Edition: Control System Advanced Methods. Edited by William S. Levine, 54-1 - 54-12, CRC Press