

-
-
-
-
-

IF-705 – Automação Inteligente

Algoritmos Evolucionários para Modelagem

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



-
-
-
-
-

Sumário


- Introdução
- Representação de Plantas
- Metodologia para a identificação de sistemas
- Modelo Direto para identificação de sistemas
- Identificação com EAs
 - Representação
 - Função de Aptidão
 - Operadores de Variação e Seleção
 - Primeiros Trabalhos
 - Exemplo
- Identificação usando IIR e design do filtro
- Identificação usando modelo de Hammerstein
- Identificação de sistema caótico

Introdução

- Na modelagem da planta ou processo se utiliza o conhecimento de física, química ou biologia:
 - O modelo deve ser acurado para que o controlador possa assegurar estabilidade e outras características relevantes ao sistema.
- Alguns sistemas que podem não ter modelos acurados:
 - Processos químicos;
 - Robôs em ambiente não-estruturado;
 - Aeronave em movimento sujeita a forças incertas.
- Alternativa: Usar dados experimentais, entrada-saída da planta ou processo. A determinação de um modelo vindo de dados experimentais se chama identificação de sistemas.

Introdução

- **Identificação de Sistemas** é um termo utilizado para descrever as ferramentas matemáticas e os algoritmos que permitem construir **modelos matemáticos** a partir de **dados medidos**.



Introdução

- Modelagem ou identificação de sistemas empregam cada vez mais algoritmos de inteligência computacional
- As aplicações de CE em identificação propostas na literatura, têm abordado a identificação de processos lineares com estimativa do atraso de transporte, linearização de processos não-lineares, incluindo-se processos mono e multivariáveis.

Representação de Plantas

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

$$\begin{aligned}\mathbf{x}(t) &= \mathbf{f}(\mathbf{x}(t), u(t)) \\ y(t) &= g(\mathbf{x}(t))\end{aligned}$$

- Para um sistema SISO discreto no tempo:

$$\begin{aligned}\mathbf{x}[k + 1] &= \mathbf{f}(\mathbf{x}[k], u[k]) \\ y[k] &= h(\mathbf{x}[k])\end{aligned}$$

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.

Representação de Plantas

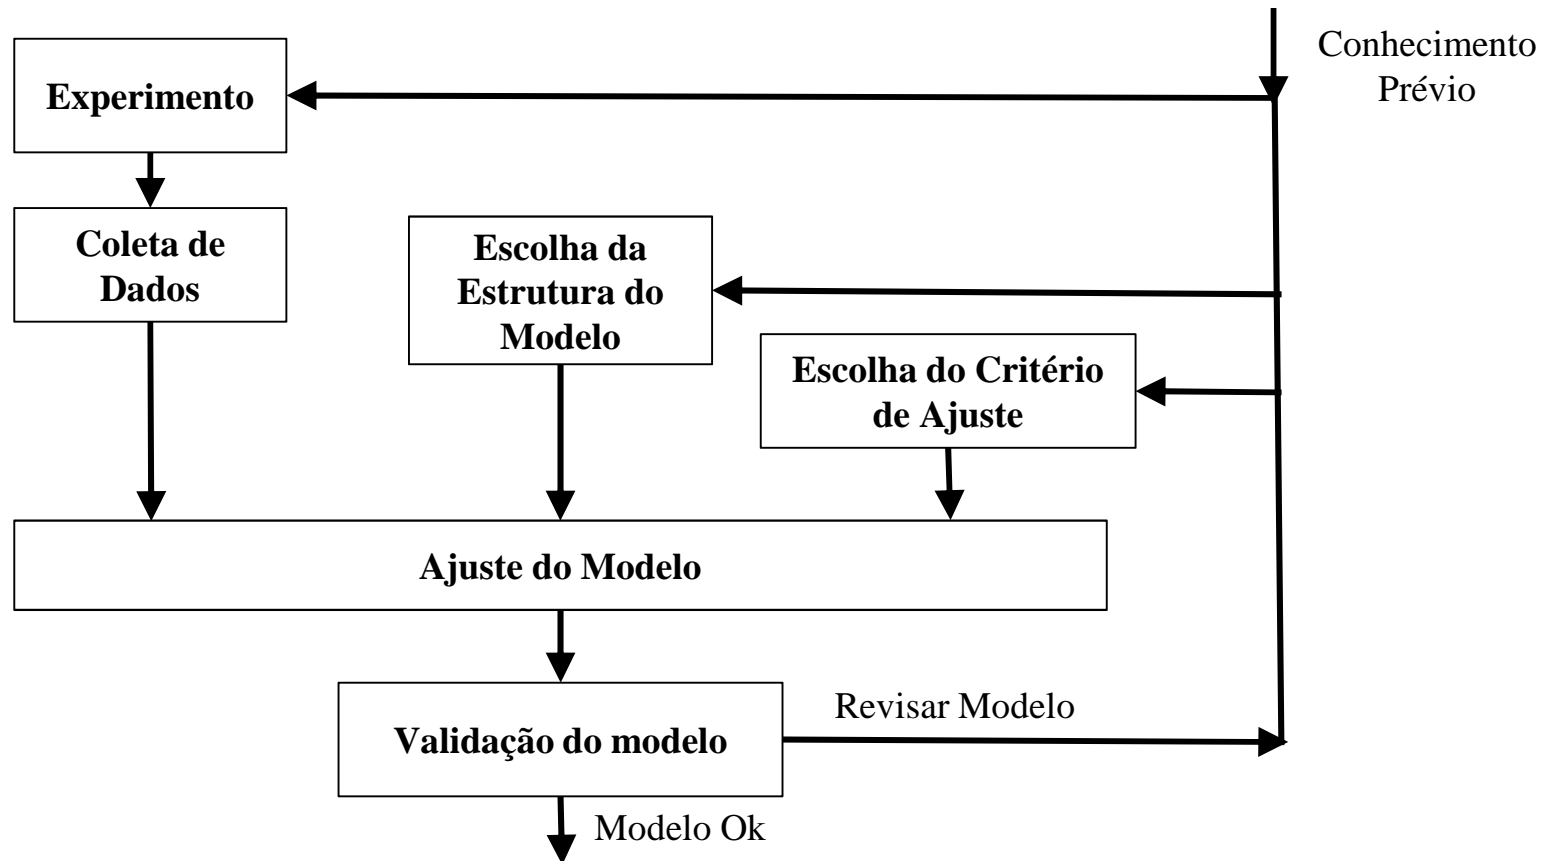
- A maioria dos modelos de plantas, admite que o sinal de saída possui informações sobre estados anteriores da planta, ou seja:

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

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 $u[k], \dots, u[k - n_u]$.

- Resta escolher os valores de n_y e n_u apropriados.

Metodologia para Identificação

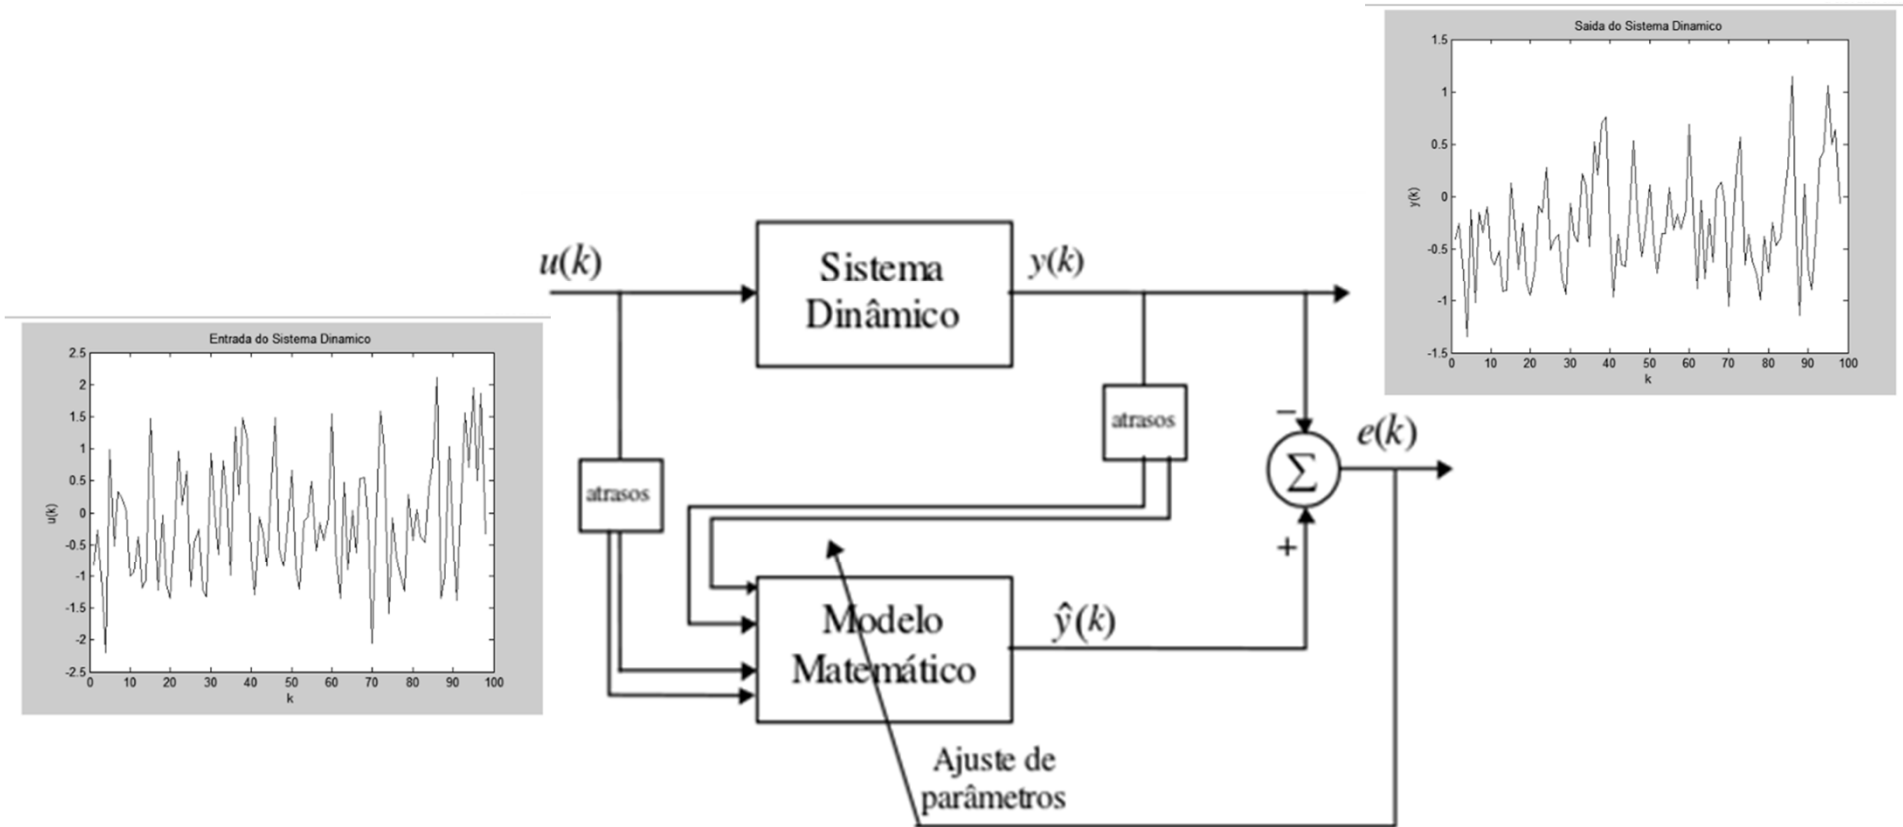


Metodologia para Identificação

A metodologia para a identificação dos parâmetros, pode ser a seguinte:

- **Off-line:** Entrada e saída do processo são gravadas e obtêm-se os parâmetros do modelo para o processo.
- **On-line:** Os parâmetros são calculados de forma recursiva à medida que um novo conjunto de dados está disponível, assim, a cada novo conjunto de dados os parâmetros são corrigidos. Este processo pode ser feito rapidamente à medida que o sistema muda. Esta metodologia é chamada de identificação em tempo real.

Modelo Direto para Identificação de Sistemas



Modelo Direto para Identificação de Sistemas

- 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:

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

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

Identificação com EAs


A identificação de sistemas pode ser decomposta em dois subproblemas inter-relacionados:

- Seleção de uma estrutura de modelo adequado (e.g. usando GP), e
- Estimativa dos parâmetros do modelo (e.g. usando GA).

Aplicações dos EAs para a identificação de sistemas têm tentado otimizar os parâmetros do modelo, ou a estrutura do modelo, ou por vezes ambos simultaneamente.

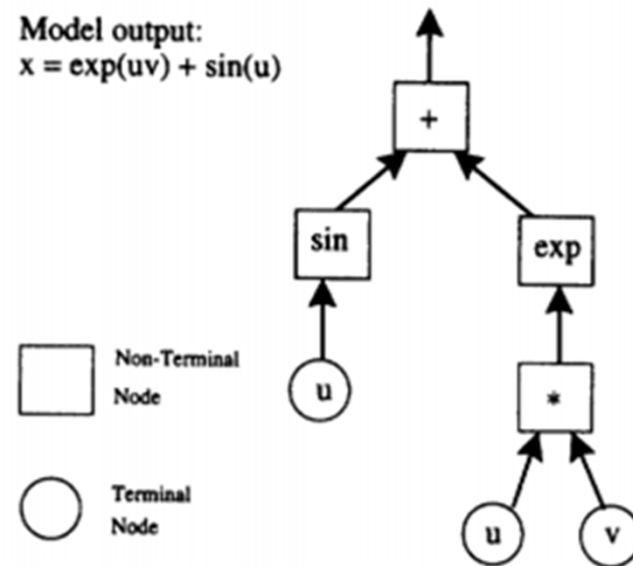
Identificação com EAs: Representação

- Real



Estrutura do cromossomo para a estimação de parâmetros

- Árvore



Estrutura do cromossomo para a seleção de uma estrutura de modelo adequado

Identificação com EAs: Função de Aptidão

Geralmente, é baseada no erro quadrático médio (MSE) entre os valores de saída calculados e os valores de saída medidos,

$$MSE = \frac{1}{N} \sum_{k=1}^N (y(k) - \hat{y}(k))^2$$

onde N é o número dos pontos de dados utilizados para a identificação do modelo.

Identificação com EAs: Função de Aptidão

No caso dos algoritmos que trabalhem com representação árvore, em vez de MSE, é usado o coeficiente de correlação r , dos valores de saída medidos e calculados. Alguns trabalhos sugerem a incorporação de um termo de penalização na função de aptidão:

$$f_i = \frac{r_i}{1 + \exp(a_1(L_i - a_2))}$$

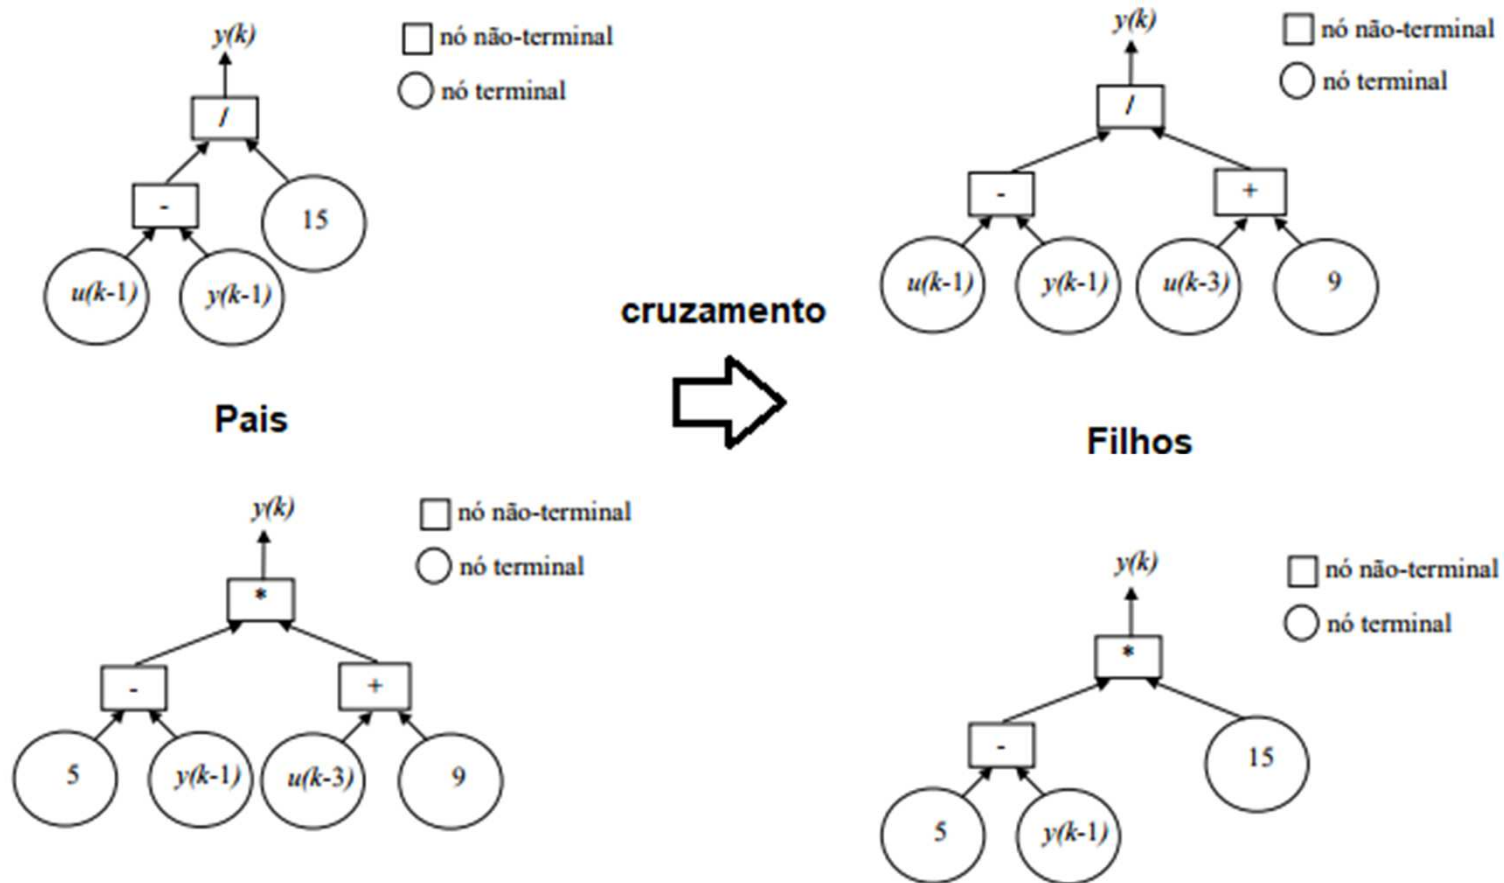
onde f_i é o valor de aptidão calculado, r_i é o coeficiente de correlação, L_i é o tamanho da árvore (número de nós), a_1 e a_2 são parâmetros da função de penalidade.

Identificação com EAs: Operadores de Variação e Seleção

- Os operadores de variação são escolhidos dependendo da representação escolhida.
- Os operadores de seleção são independentes da representação.

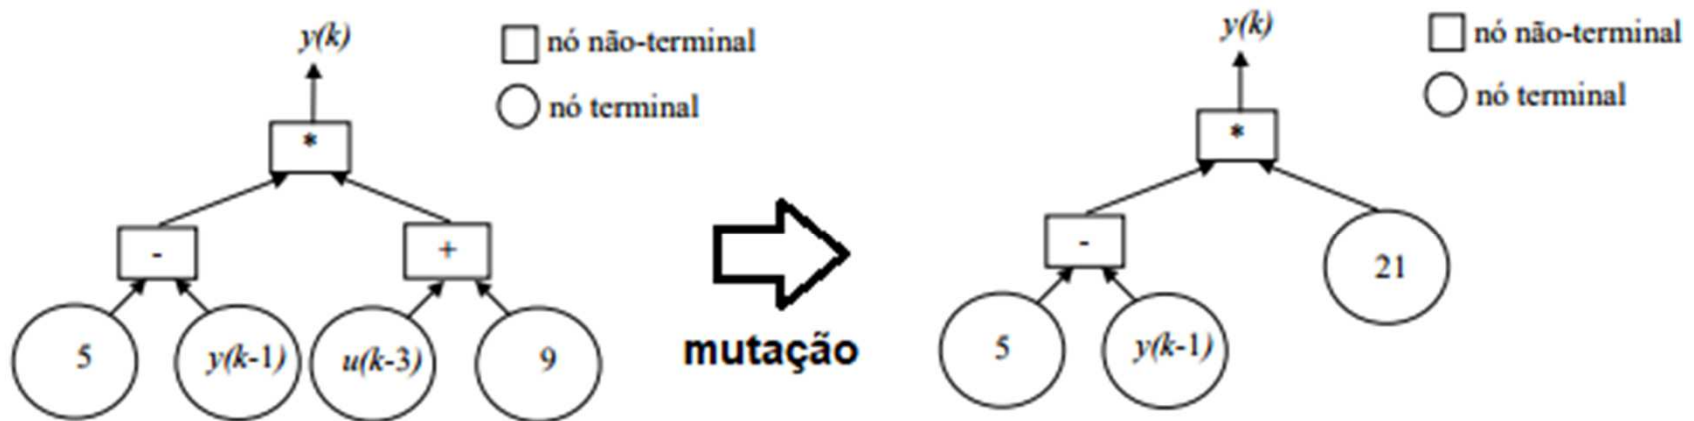
Identificação com EAs: Exemplo de Operadores de Variação

Exemplo de operação de cruzamento.

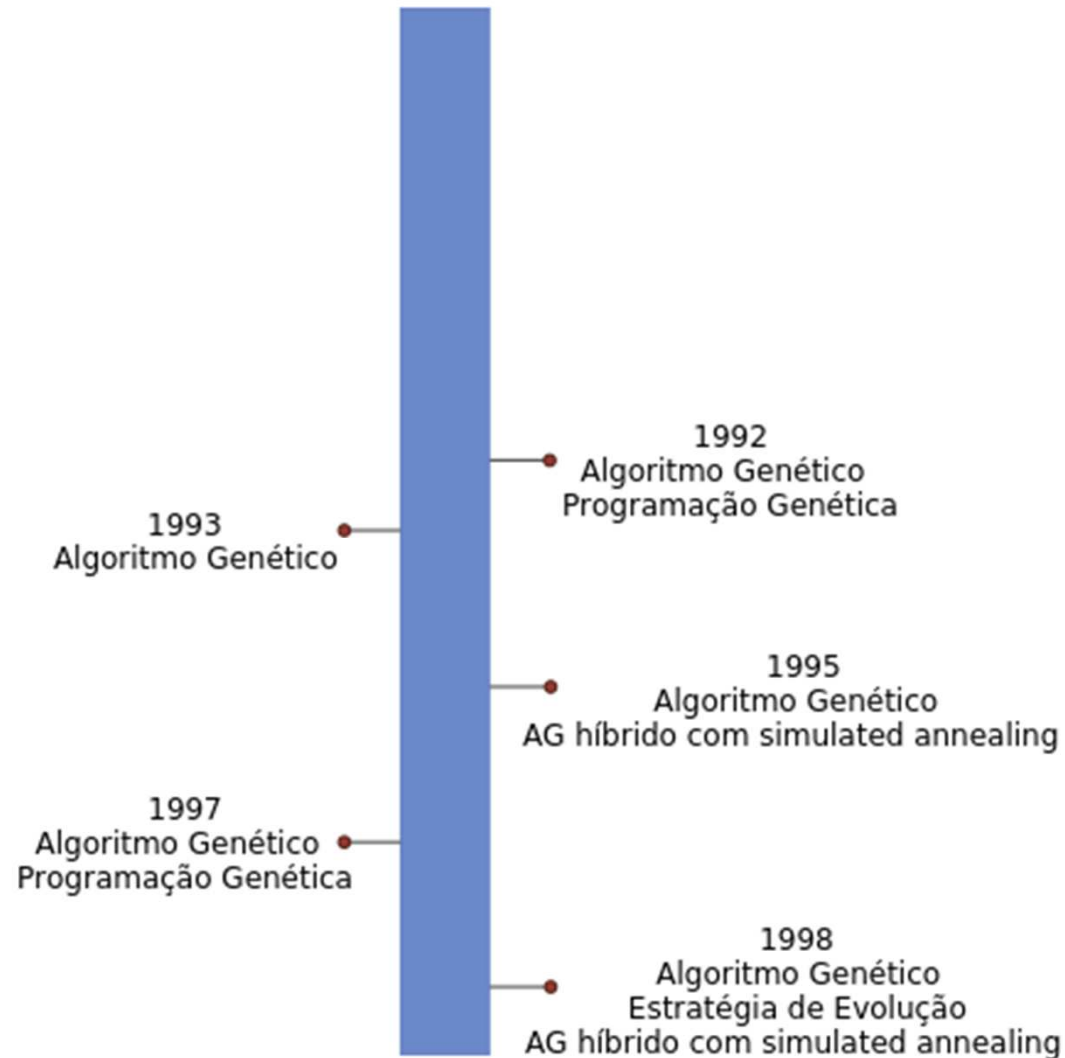


Identificação com EAs: Exemplo de Operadores de Variação

Exemplo de operação de mutação.



Identificação com EAs: Primeiros Trabalhos



Identificação com EAs: Primeiros Trabalhos

- Kristinsson & Dumont (1992) tratam a identificação de processos por AGs e realizam comparações com a técnica da variável instrumental recursiva.
- Koza (1992) apresenta um procedimento de identificação pela utilização de PG visando encontrar uma função da resposta ao impulso de um sistema linear invariante no tempo.
- Flockton & White (1993) descrevem a identificação de pólos e zeros para codificação da estrutura e coeficientes de um filtro digital por AGs.

Identificação com EAs: Primeiros Trabalhos

- Li & Jeon (1993) tratam a utilização de AGs para identificação dos regressores de sistemas NARX (*Non-linear AutoRegressive model structure eXogenous inputs*) e efetuam uma abrangente comparação com o algoritmo dos MQR ortogonal.
- Tan & Li (1995) apresentam o desenvolvimento de AGs para sistemas de identificação do tipo norma L_∞ , no domínio da frequência, em aplicações de controle robusto.
- Li *et al.* (1995) tratam a utilização de AG híbrido com *simulated annealing* em problemas de identificação e linearização de processos.

Identificação com EAs: Primeiros Trabalhos

- Fardin *et al.* (1997) aplicam os AGs em identificação de sistemas discretos, este procedimento deu início à aplicação de técnicas de controle preditivo baseado em modelo.
- Lee *et al.* (1997) tratam o problema de modelagem em sistemas de potência por PG .
- Coelho & Coelho (1998) apresentam um estudo comparativo de AGs, EEs e AG híbrido com *simulated annealing* aplicado a problemas de identificação e controle de processos experimentais.

Identificação com EAs: Exemplo

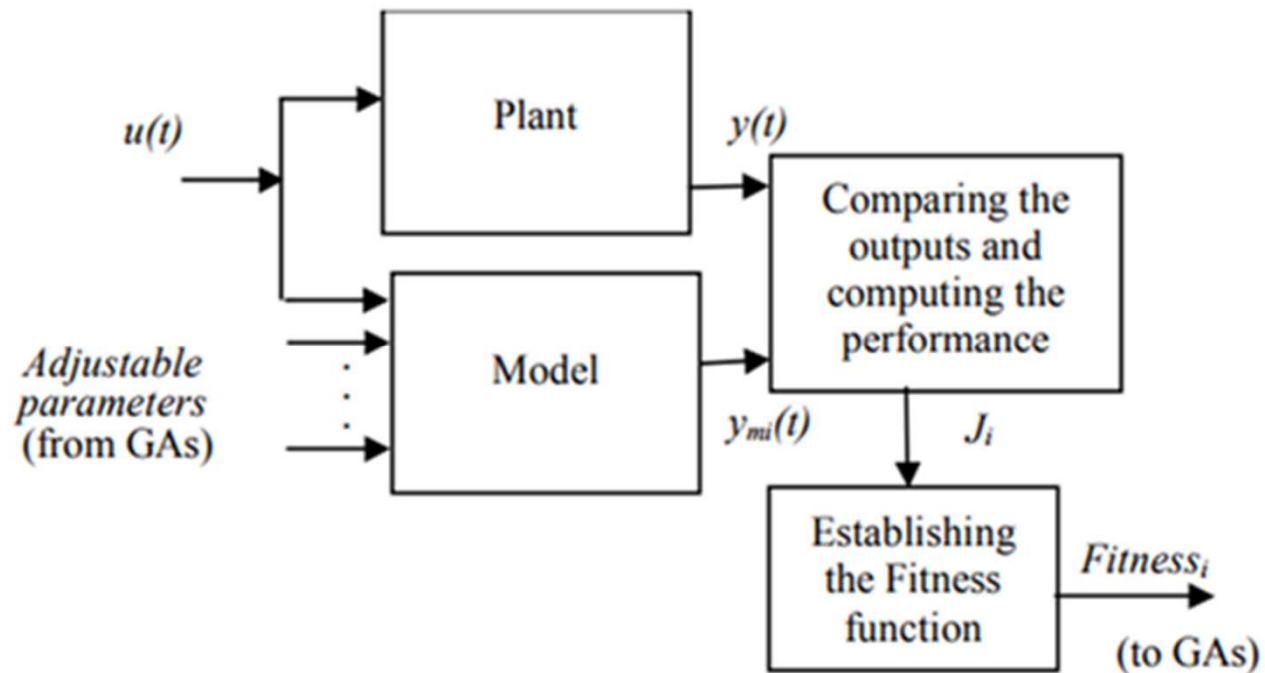
- Identificação de Sistema Usando Algoritmos Genéticos
 - Pode ser aplicada à identificação de sistemas de tempo contínuo e discreto.
 - Pode ser usada em aplicações on-line e off-line.
 - Pode ser usado para:
 - identificar diretamente pólos e zeros, ou

$$H_p = K_p \frac{a_k s^k + a_{k-1} s^{k-1} + \dots + a_1 s + 1}{b_m s^m + b_{m-1} s^{m-1} + \dots + b_1 s + 1} e^{-\tau s} \quad \text{ou} \quad H_p = \frac{K_p}{T_p + 1} e^{-\tau s}$$

- obter os valores de parâmetros físicos.


Identificação com EAs: Exemplo

- Identificação de Sistema Usando Algoritmos Genéticos



Identificação com EAs: Exemplo

- GAs usa indivíduos codificados como vetor de números reais, que eram os n parâmetros no processo de estimativa.



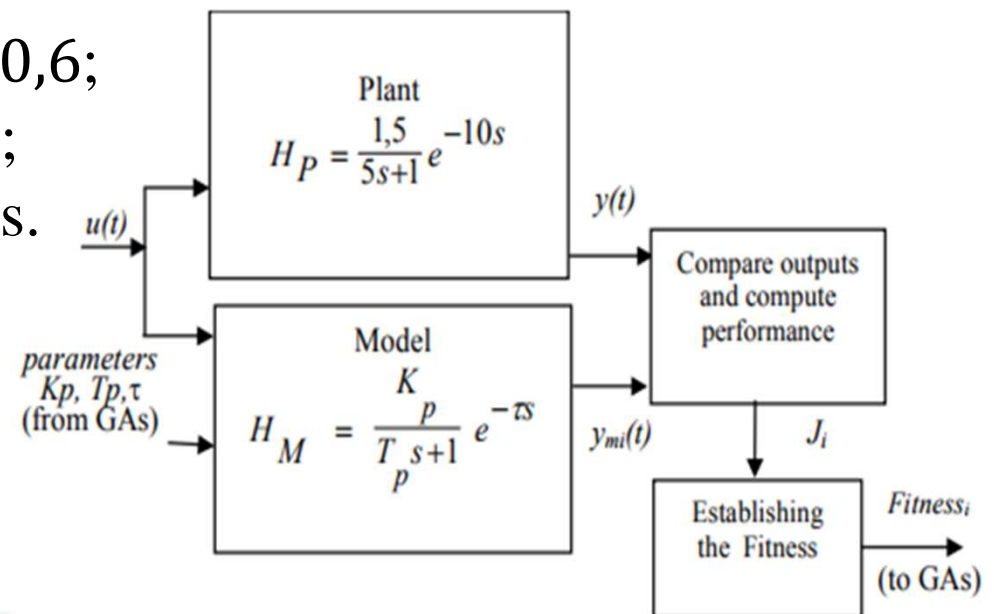
- A função de custo utilizada pode ser o erro entre a saída estimada e real sobre uma janela de dados, formada pelo par de entrada-saída atual e as N_e amostras anteriores.

$$J_i(\text{param}_i) = \sum_{j=1}^{N_e} \int_0^{t_{max}} k_j \{ \text{abs}[y_j(t) - \hat{y}_{ij}(t)] \} dt$$

$u(t) = u_j(t)$

Identificação com EAs: Exemplo

- Parâmetros do GA:
 - Tamanho da população $N = 50$;
 - Seleção por torneio com o tamanho $T = 5$;
 - Cruzamento aritmético;
 - Mutação uniforme;
 - Probabilidade de cruzamento 0,6;
 - Probabilidade de mutação 0,1;
 - Critério de parada 50 gerações.



Identificação com EAs: Exemplo

Resultados obtidos:

$$Kp = 1,4999 \quad Tp = 4,9916$$
$$\tau = 10,0049 \quad Aptidão = 0,9995$$


Planta

$$H_p = \frac{1,5}{5s + 1} e^{-10s}$$

Acuracidade: 99,9%

M é a média do aptidão.

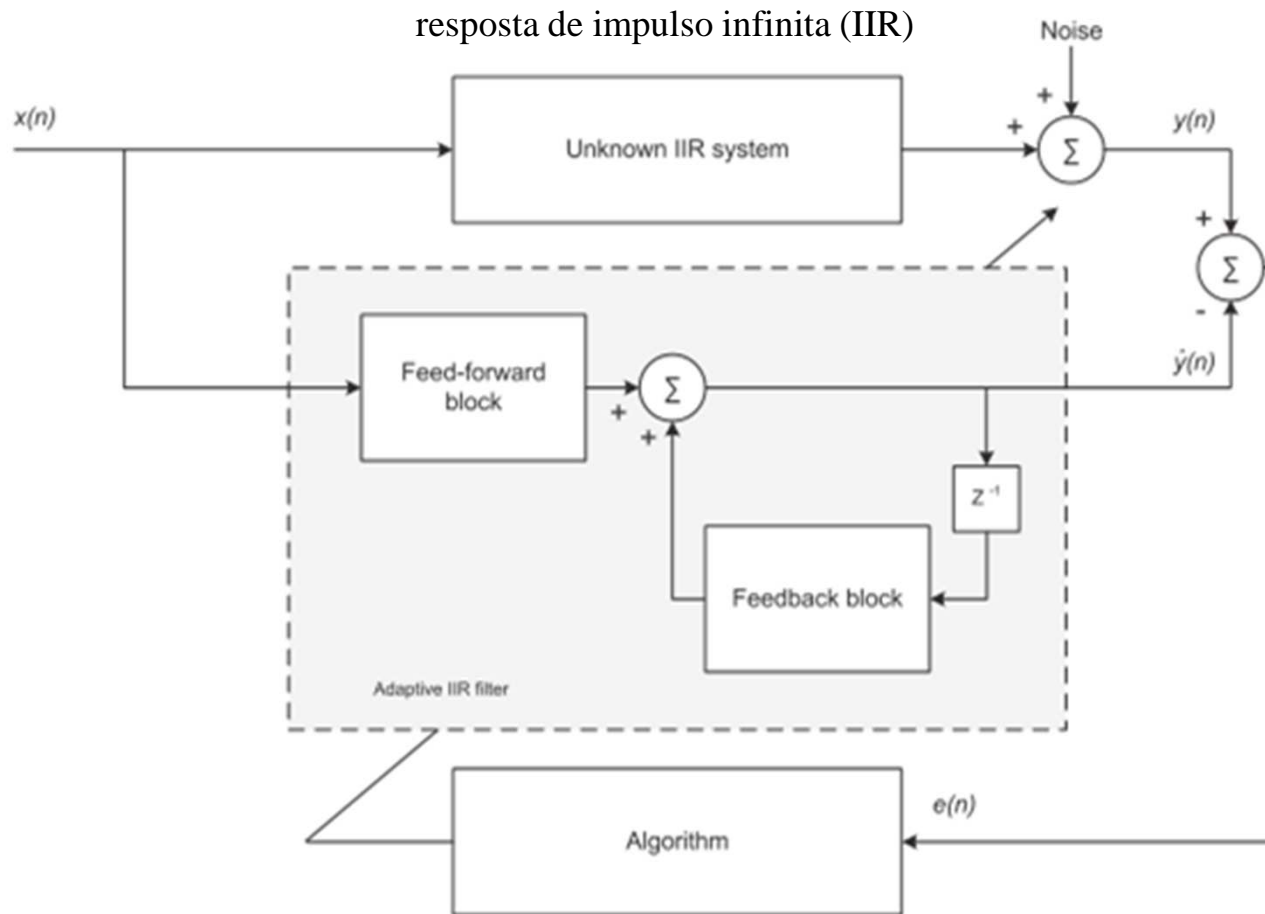
S é o desvio padrão.



Identificação usando IIR e Design do Filtro

- Um sistema LTI prático pode ser modelado com menor número de coeficientes usando um filtro IIR (resposta de impulso infinita) em comparação com um filtro FIR (resposta ao impulso finita).
- Embora existam preocupações com a estabilidade, esta propriedade dos filtros IIR os tornou um candidato popular para identificação prática de sistemas e design de filtros.
- A superfície de erro envolvida no processo de modelagem pode ser uni-modal ou multimodal dependendo da ordem do modelo a estimar. A superfície do erro é tipicamente multimodal quando a ordem é sob ou sobre estimada.

Identificação usando IIR e Design do Filtro



Identificação usando IIR e Design do Filtro

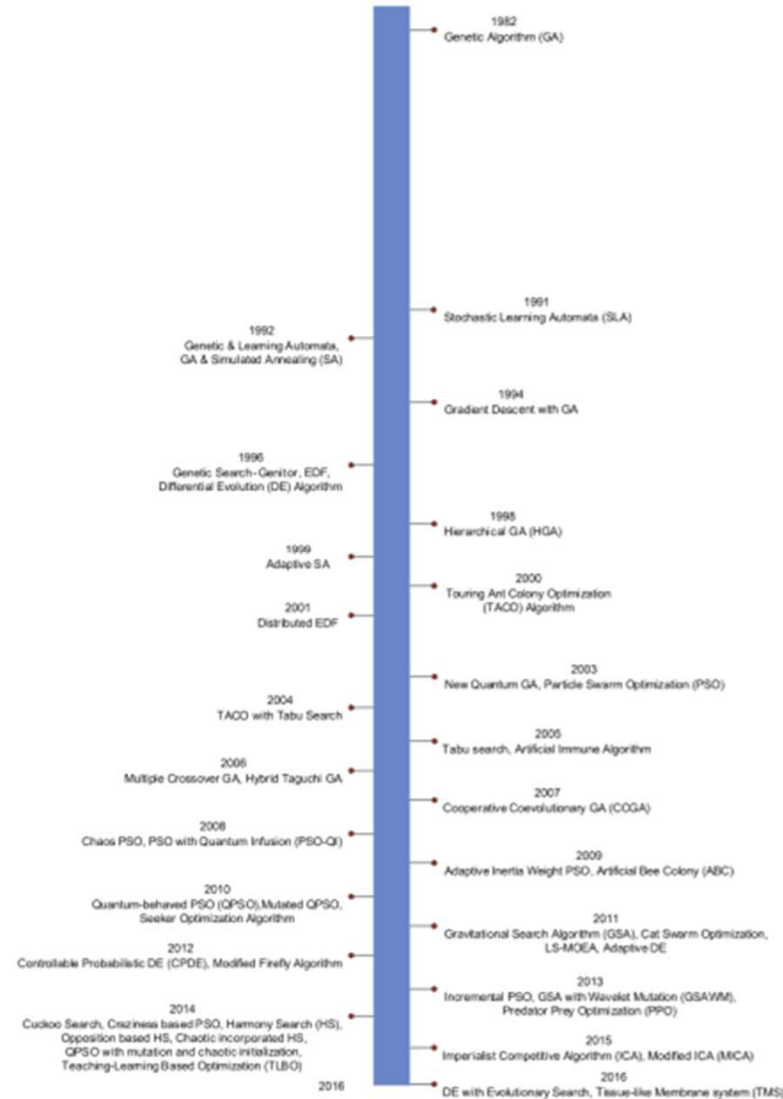
- O filtro IIR discreto é geralmente descrito em termos de equações de diferenças:

$$y[n] = \frac{1}{a_0} \left(\sum_{i=0}^P b_i x[n-i] - \sum_{j=1}^Q a_j y[n-j] \right)$$

onde:

- P é a ordem do filtro de realimentação,
- b_i são os coeficientes do filtro de realimentação,
- Q é a ordem do filtro de feedback,
- a_j são os coeficientes do filtro de feedback,
- $x[n]$ é o sinal de entrada,
- $y[n]$ é o sinal de saída.

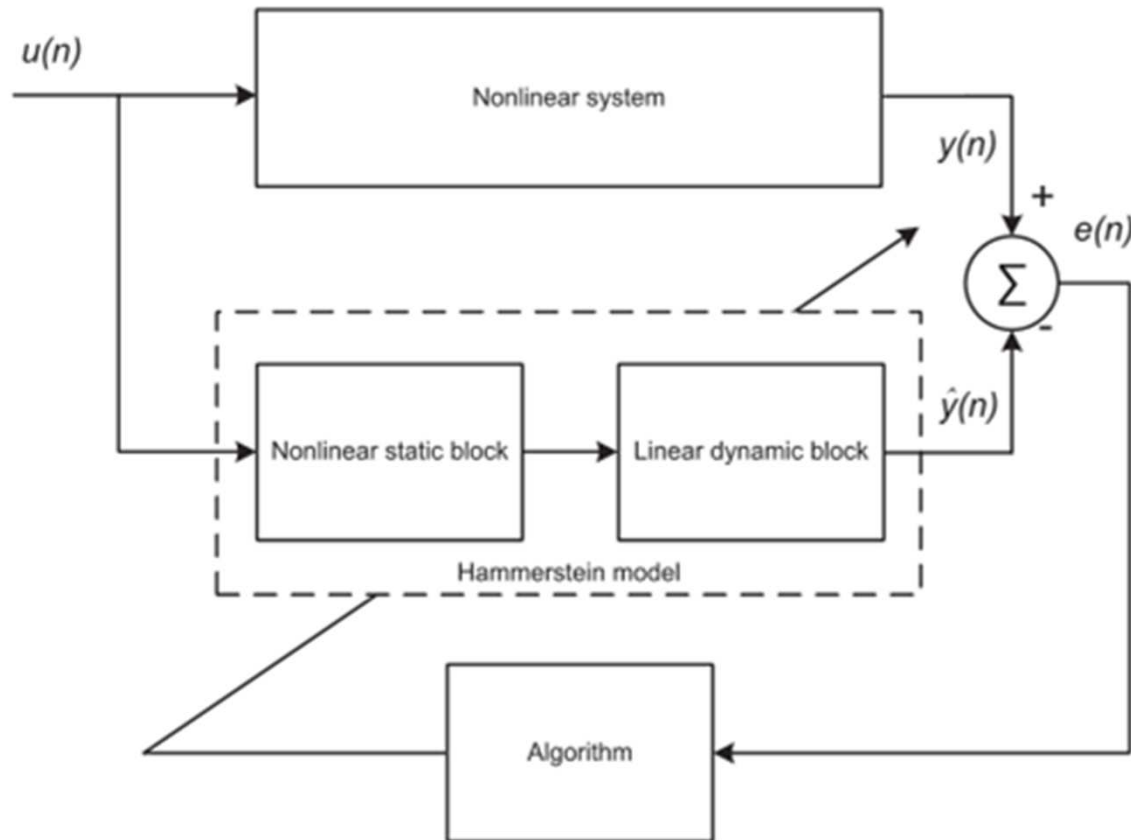
Identificação usando IIR e Design do Filtro



Identificação usando modelo de Hammerstein

- Usado para a identificação de sistemas não-lineares dinâmicos tais como colunas de destilação, permutadores de calor, previsão de velocidade do vento.
- Consiste essencialmente em um bloco não-linear estático, seguido de uma seção linear dinâmica.
- É popular devido à sua capacidade de efetivamente modelar atuadores com uma não-linearidade dominante. Outras não-linearidades não são significativas.
- Em um esquema de identificação de sistema de Hammerstein usando algoritmos evolucionários, os parâmetros adaptativos do bloco não-linear e/ou o bloco linear são atualizados minimizando a esperança do erro quadrático.

Identificação usando modelo de Hammerstein



Identificação usando modelo de Hammerstein

- O bloco não linear é caracterizado por :

$$y_{n_l}(n) = f(u(n)) = c_1 u(n) + c_2 u^2(n) + \dots + c_{n_l} u^{n_l}(n)$$

onde:

- $u(n)$ é o sinal de entrada,
- $y_{n_l}(n)$ é a saída do bloco não-linear,
- $c_{n_l}(n)$ são os coeficientes da função não linear.
- c_1 é geralmente 1 para ter uma parametrização única da estrutura do modelo de Hammerstein.

Identificação usando modelo de Hammerstein

- O bloco linear é caracterizado por:

$$\hat{y}(n) = H(z^{-1})y_{n_l}(n) = \frac{B(z^{-1})}{A(z^{-1})}y_{n_l}(n)$$

onde:

- $y_{n_l}(n)$ é a saída do bloco não-linear (entrada do bloco linear)
- $\hat{y}(n)$ é a saída do modelo de Hammerstein,
- $A(z^{-1})$ e $B(z^{-1})$ são polinômios da forma:

$$A(z^{-1}) = 1 + a_1z^{-1} + a_2z^{-2} + \dots + a_{n_a}z^{-n_a}$$

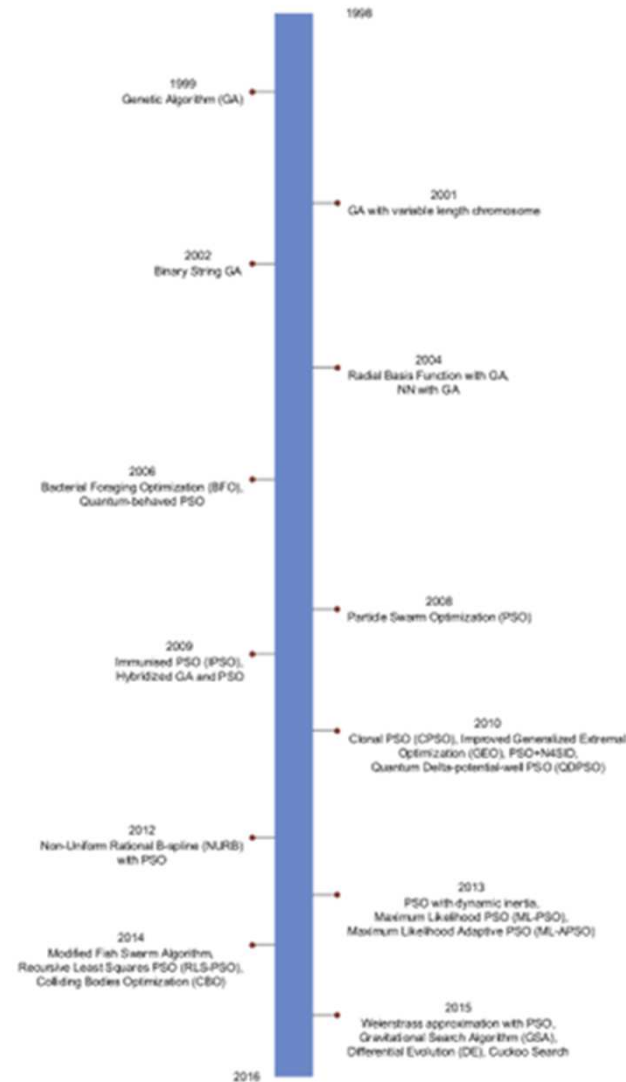
$$B(z^{-1}) = b_1z^{-1} + b_2z^{-2} + \dots + b_{n_b}z^{-n_b}$$

O objetivo da identificação é estimar o conjunto de parâmetros θ (parâmetros dos blocos não-linear e linear) minimizando o erro $e(n)$ entre a saída medida e a saída do modelo de Hammerstein.

$$\theta = (a_1 \ a_2 \ \dots \ a_{n_a} \ b_1 \ b_2 \ \dots \ b_{n_b} \ c_2 \ \dots \ c_{n_c})^T$$



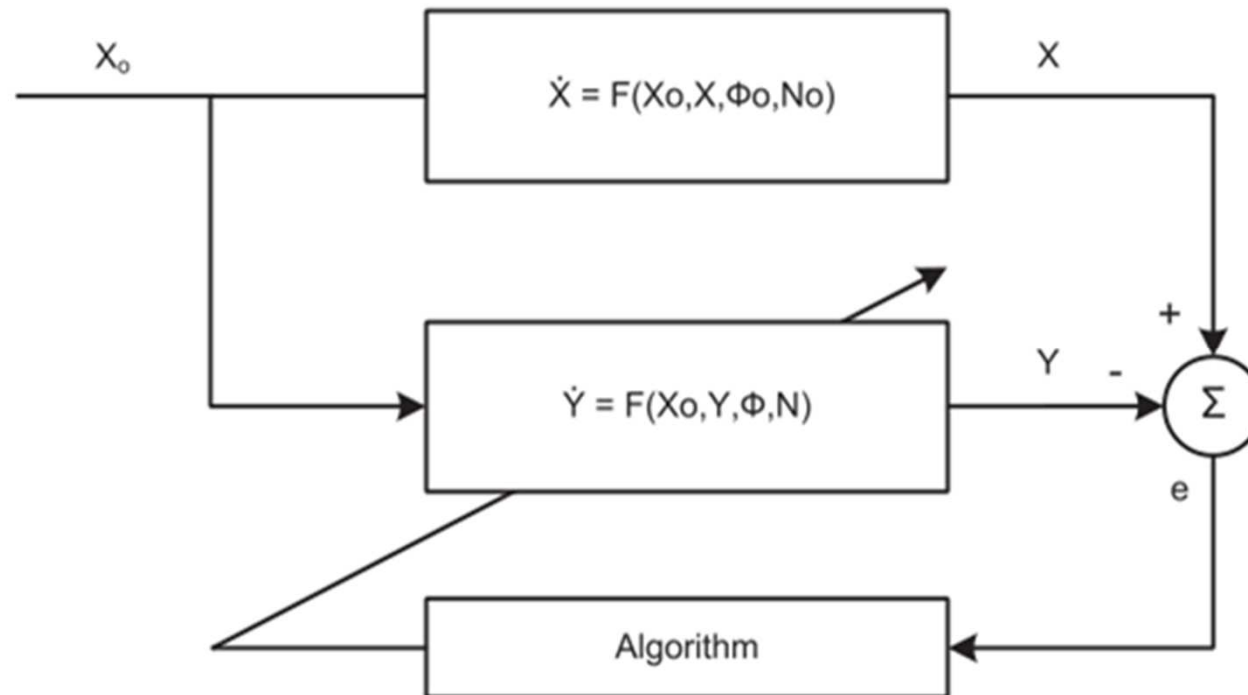
Identificação usando modelo de Hammerstein



Identificação de Sistema Caótico

- Os sistemas caóticos são sistemas cujo comportamento é altamente sensível às condições iniciais.
- Muitos sistemas do mundo real podem ser considerados como sistemas caóticos.
- A teoria do caos encontrou aplicações em diversas áreas como a identificação de parâmetros de sistemas caóticos.
- Como o espaço de busca neste problema de identificação é multimodal, os esforços foram feitos para formular o problema como uma tarefa de otimização resolvida com algoritmos evolucionários.

Identificação de Sistema Caótico



Identificação de Sistema Caótico

- Um sistema caótico N-dimensional está caracterizado por:

$$\dot{X} = F(X_0, X, \phi_0)$$

onde:

- $X_0 = [x_{10}, x_{20}, \dots, x_{N0}]^T$ é o vetor de estado inicial
- $X = [x_1, x_2, \dots, x_N]^T$ é o vetor de estado
- $\phi_0 = [\phi_{10}, \phi_{20}, \dots, \phi_{N0}]^T$ é o vetor de parâmetros do sistema d-dimensional.

Identificação de Sistema Caótico

Em um esforço para estimar o vetor de parâmetro desconhecido ϕ_0 com a suposição de que a estrutura do sistema é conhecida, o sistema estimado pode ser descrito como:

$$\dot{Y} = F(X_0, Y, \phi)$$

onde:

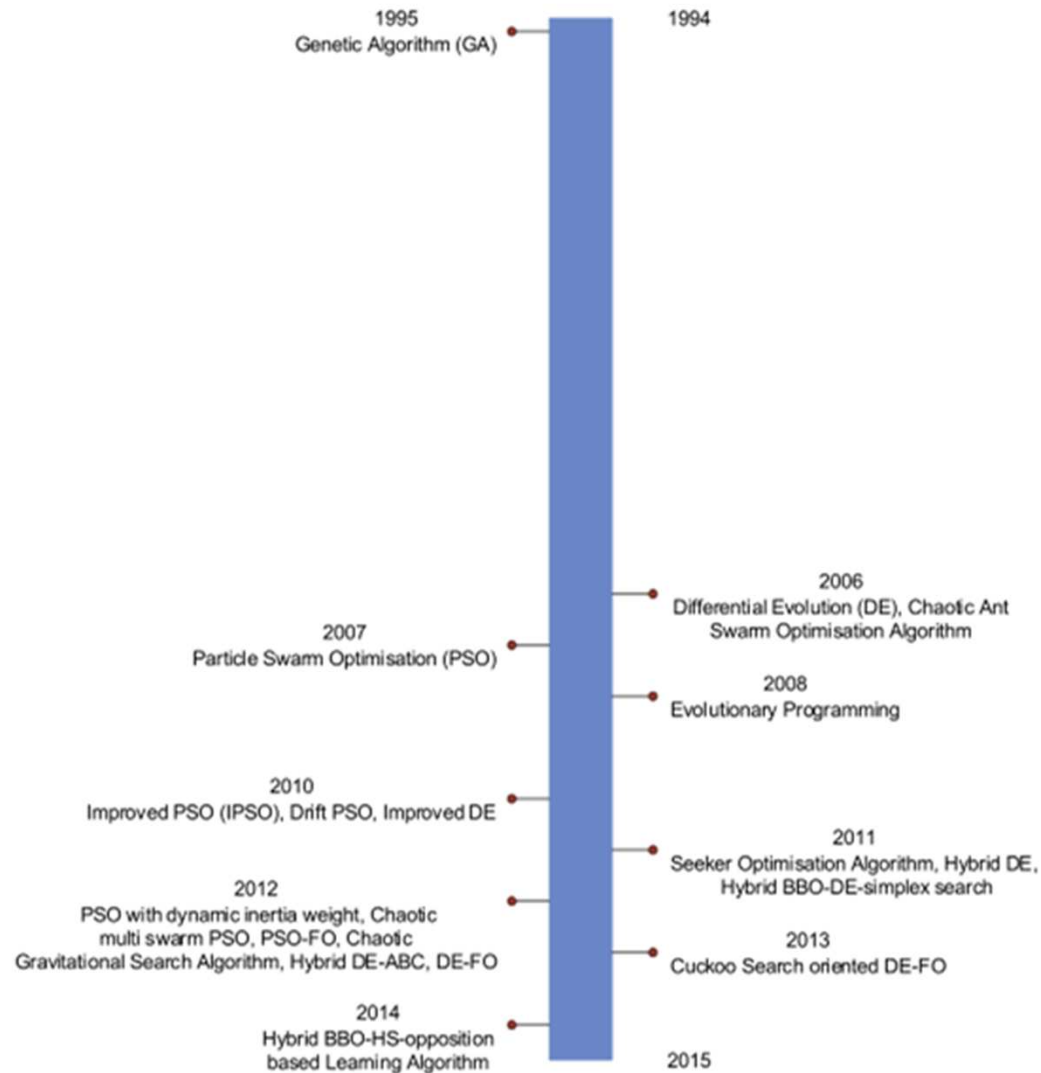
- $Y = [y_1, y_2, \dots, y_N]^T$ é o vetor de estado
- $\phi = [\phi_1, \phi_2, \dots, \phi_N]^T$ é o vetor d -dimensional de parâmetros do sistema estimado.

A função de aptidão é $\xi = \frac{1}{M} \sum_{k=1}^M \|X_k - Y_k\|^2$

onde X_k e Y_k representam o vetor de estado do sistema caótico e sua estimativa para o instante k , e M indica o comprimento dos dados usados para a estimação dos parâmetros.



Identificação de Sistema Caótico



Referências

1. Kristinsson, K., & Dumont, G. A. (1992). System identification and control using genetic algorithms. *IEEE Transactions on Systems, Man, and Cybernetics*, 22(5), 1033-1046.
2. Fleming, P. J., & Purshouse, R. C. (2002). Evolutionary algorithms in control systems engineering: a survey. *Control engineering practice*, 10(11), 1223-1241.
3. Vladu, E., & Dragomir, T. L. (2005). Using genetic algorithms in system identification. In *6th International Symposium of Hungarian Researchers on computational Intelligence*.
4. Altamiranda, Edmary, Rodrigo Calderón, and E. Colina. "An evolutionary algorithm for linear system identification." *Proceeding of the 6th WSEAS international conference on signal proceeding, Robotics and Automation, WSEAS*. 2007.
5. Dotoli, M., Fay, A., Miśkowicz, M., & Seatzu, C. (2015). A Survey on Advanced Control Approaches in Factory Automation. *IFAC-PapersOnLine*, 48(3), 394-399.
6. Worden, K., Antoniadou, I., Tiboaca, O. D., Manson, G., & Barthorpe, R. J. (2016). Linear and Nonlinear System Identification Using Evolutionary Optimisation. In *Simulation-Driven Modeling and Optimization* (pp. 325-345). Springer International Publishing.
7. Gotmare, A., Bhattacharjee, S. S., Patidar, R., & George, N. V. (2017). Swarm and evolutionary computing algorithms for system identification and filter design: A comprehensive review. *Swarm and Evolutionary Computation*, 32, 68-84.