



Instituto Tecnológico de Aeronáutica

Divisão de Engenharia Eletrônica

Departamento de Sistemas e Controle

São José dos Campos, São Paulo, Brasil

Aula 14 - Controle adaptativo com modelo de referência ¹

Rubens J M Afonso

EE-209: Sistemas de controle não lineares

18 de outubro de 2017

¹Astrom e Wittenmark, *Adaptive Control*, 2nd Ed., Dover, 2008

Introdução

Por quê?

- Muitas vezes conhecemos a estrutura do modelo da planta, mas não sabemos o valor de (alguns de) seus parâmetros.
- Possíveis motivos:
 - Parâmetro desconhecido.
 - Parâmetro varia com o tempo, e.g, carga que um braço robótico deve transportar.
 - Parâmetros relacionados à faixa de operação da planta: parâmetros de aeronaves dependem de altitude, velocidade, etc.



Introdução

Por quê?

- Muitas vezes conhecemos a estrutura do modelo da planta, mas não sabemos o valor de (alguns de) seus parâmetros.
- Possíveis motivos:
 - Parâmetro desconhecido.
 - Parâmetro varia com o tempo, e.g, carga que um braço robótico deve transportar.
 - Parâmetros relacionados à faixa de operação da planta: parâmetros de aeronaves dependem de altitude, velocidade, etc.



Introdução

Por quê?

- Muitas vezes conhecemos a estrutura do modelo da planta, mas não sabemos o valor de (alguns de) seus parâmetros.
- Possíveis motivos:
 - Parâmetro desconhecido.
 - Parâmetro varia com o tempo, e.g, carga que um braço robótico deve transportar.
 - Parâmetros relacionados à faixa de operação da planta: parâmetros de aeronaves dependem de altitude, velocidade, etc.



Introdução

Por quê?

- Muitas vezes conhecemos a estrutura do modelo da planta, mas não sabemos o valor de (alguns de) seus parâmetros.
- Possíveis motivos:
 - Parâmetro desconhecido.
 - Parâmetro varia com o tempo, e.g, carga que um braço robótico deve transportar.
 - Parâmetros relacionados à faixa de operação da planta: parâmetros de aeronaves dependem de altitude, velocidade, etc.



Introdução

Por quê?

- Muitas vezes conhecemos a estrutura do modelo da planta, mas não sabemos o valor de (alguns de) seus parâmetros.
- Possíveis motivos:
 - Parâmetro desconhecido.
 - Parâmetro varia com o tempo, e.g, carga que um braço robótico deve transportar.
 - Parâmetros relacionados à faixa de operação da planta: parâmetros de aeronaves dependem de altitude, velocidade, etc.



Introdução

Como realizar o controle nessa situação?

- Controle robusto: manter estabilidade/desempenho para parâmetros variando dentro de intervalos conhecidos a priori.
- Controle adaptativo: estimar parâmetro e alterar o controlador de acordo.
 - Vantagens:
 - 1 Parâmetros podem assumir quaisquer valores (não requer conhecer faixa).
 - 2 Desempenho tende a melhorar conforme estimativa dos parâmetros melhora.



Introdução

Como realizar o controle nessa situação?

- Controle robusto: manter estabilidade/desempenho para parâmetros variando dentro de intervalos conhecidos a priori.
- Controle adaptativo: estimar parâmetro e alterar o controlador de acordo.
 - Vantagens:
 - 1 Parâmetros podem assumir quaisquer valores (não requer conhecer faixa).
 - 2 Desempenho tende a melhorar conforme estimativa dos parâmetros melhora.



Introdução

Como realizar o controle nessa situação?

- Controle robusto: manter estabilidade/desempenho para parâmetros variando dentro de intervalos conhecidos a priori.
- Controle adaptativo: estimar parâmetro e alterar o controlador de acordo.
 - Vantagens:
 - 1 Parâmetros podem assumir quaisquer valores (não requer conhecer faixa).
 - 2 Desempenho tende a melhorar conforme estimativa dos parâmetros melhora.



Introdução

Como realizar o controle nessa situação?

- Controle robusto: manter estabilidade/desempenho para parâmetros variando dentro de intervalos conhecidos a priori.
- Controle adaptativo: estimar parâmetro e alterar o controlador de acordo.
 - Vantagens:
 - 1 Parâmetros podem assumir quaisquer valores (não requer conhecer faixa).
 - 2 Desempenho tende a melhorar conforme estimativa dos parâmetros melhora.



Introdução

Como realizar o controle nessa situação?

- Controle robusto: manter estabilidade/desempenho para parâmetros variando dentro de intervalos conhecidos a priori.
- Controle adaptativo: estimar parâmetro e alterar o controlador de acordo.
 - Vantagens:
 - 1 Parâmetros podem assumir quaisquer valores (não requer conhecer faixa).
 - 2 Desempenho tende a melhorar conforme estimativa dos parâmetros melhora.



Um exemplo

Ganho da planta desconhecido

- Tem-se uma planta em malha aberta com função de transferência dada por $kG(s)$, em que $G(s)$ é conhecida, mas k é desconhecido.
- Deseja-se que a planta se comporte como $k_0G(s)$, com k_0 preestabelecido.
- Para isso, pode-se usar um ganho θ em cascata, como na Figura.



Um exemplo

Ganho da planta desconhecido


- Tem-se uma planta em malha aberta com função de transferência dada por $kG(s)$, em que $G(s)$ é conhecida, mas k é desconhecido.
- Deseja-se que a planta se comporte como $k_0G(s)$, com k_0 preestabelecido.
- Para isso, pode-se usar um ganho θ em cascata, como na Figura.



Um exemplo

Ganho da planta desconhecido


- Tem-se uma planta em malha aberta com função de transferência dada por $kG(s)$, em que $G(s)$ é conhecida, mas k é desconhecido.
- Deseja-se que a planta se comporte como $k_0G(s)$, com k_0 preestabelecido.
- Para isso, pode-se usar um ganho θ em cascata, como na Figura.



Um exemplo

Parâmetro do controlador depende do ganho desconhecido


- Caso conhecêssemos k , bastaria fazer $\theta = k_0/k$.
- Com k desconhecido, vamos estimar θ .
- Para isso, vamos usar a estrutura da Figura (válida para o caso geral, no caso deste exemplo, a malha de realimentação de y para o controlador não existe).



Um exemplo

Parâmetro do controlador depende do ganho desconhecido

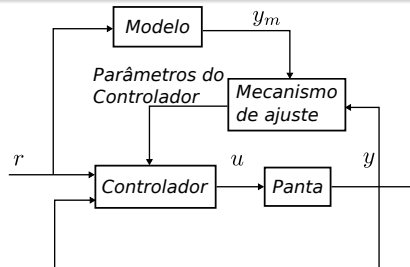
- Caso conhecêssemos k , bastaria fazer $\theta = k_0/k$.
- Com k desconhecido, vamos estimar θ .
- Para isso, vamos usar a estrutura da Figura (válida para o caso geral, no caso deste exemplo, a malha de realimentação de y para o controlador não existe).



Um exemplo

Parâmetro do controlador depende do ganho desconhecido


- Caso conhecêssemos k , bastaria fazer $\theta = k_0/k$.
- Com k desconhecido, vamos estimar θ .
- Para isso, vamos usar a estrutura da Figura (válida para o caso geral, no caso deste exemplo, a malha de realimentação de y para o controlador não existe).



Um exemplo

Modelo de comportamento desejado


- Nesse caso, o modelo desejado é $k_0G(s)$.
- E o controlador é simplesmente o ganho θ (o próprio parâmetro a ser adaptado).
- Resta determinar o mecanismo de ajuste. Como?



Um exemplo

Modelo de comportamento desejado


- Nesse caso, o modelo desejado é $k_0G(s)$.
- E o controlador é simplesmente o ganho θ (o próprio parâmetro a ser adaptado).
- Resta determinar o mecanismo de ajuste. Como?



Um exemplo

Modelo de comportamento desejado

- Nesse caso, o modelo desejado é $k_0G(s)$.
- E o controlador é simplesmente o ganho θ (o próprio parâmetro a ser adaptado).
- Resta determinar o mecanismo de ajuste. Como?



Um exemplo

Regra do MIT

- Seja o erro de rastreo $e = y - y_m$.
- Defina uma função $J(\theta) \propto |e|$ que é diretamente proporcional ao erro de rastreo.
- Minimizar $J(\theta) \Rightarrow$ minimizar $|e|$.
- Variação do parâmetro:

$$\frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta}, \quad \gamma > 0, \quad (1)$$

isto é, θ varia com sinal oposto ao de $\frac{\partial J}{\partial \theta}$.

- Com isso, θ varia na direção oposta à de maior crescimento de $J(\theta)$.
- Regra desenvolvida no *Instrumentation Laboratory* (atualmente *Draper Laboratory*) do MIT.



Um exemplo

Regra do MIT

- Seja o erro de rastreo $e = y - y_m$.
- Defina uma função $J(\theta) \propto |e|$ que é diretamente proporcional ao erro de rastreo.
- Minimizar $J(\theta) \Rightarrow$ minimizar $|e|$.
- Variação do parâmetro:

$$\frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta}, \quad \gamma > 0, \quad (1)$$

isto é, θ varia com sinal oposto ao de $\frac{\partial J}{\partial \theta}$.

- Com isso, θ varia na direção oposta à de maior crescimento de $J(\theta)$.
- Regra desenvolvida no *Instrumentation Laboratory* (atualmente *Draper Laboratory*) do MIT.



Um exemplo

Regra do MIT

- Seja o erro de rastreo $e = y - y_m$.
- Defina uma função $J(\theta) \propto |e|$ que é diretamente proporcional ao erro de rastreo.
- Minimizar $J(\theta) \Rightarrow$ minimizar $|e|$.
- Variação do parâmetro:

$$\frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta}, \quad \gamma > 0, \quad (1)$$

isto é, θ varia com sinal oposto ao de $\frac{\partial J}{\partial \theta}$.

- Com isso, θ varia na direção oposta à de maior crescimento de $J(\theta)$.
- Regra desenvolvida no *Instrumentation Laboratory* (atualmente *Draper Laboratory*) do MIT.



Um exemplo

Regra do MIT

- Seja o erro de rastreo $e = y - y_m$.
- Defina uma função $J(\theta) \propto |e|$ que é diretamente proporcional ao erro de rastreo.
- Minimizar $J(\theta) \Rightarrow$ minimizar $|e|$.
- Variação do parâmetro:

$$\frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta}, \quad \gamma > 0, \quad (1)$$

isto é, θ varia com sinal oposto ao de $\frac{\partial J}{\partial \theta}$.

- Com isso, θ varia na direção oposta à de maior crescimento de $J(\theta)$.
- Regra desenvolvida no *Instrumentation Laboratory* (atualmente *Draper Laboratory*) do MIT.



Um exemplo

Regra do MIT

- Seja o erro de rastreo $e = y - y_m$.
- Defina uma função $J(\theta) \propto |e|$ que é diretamente proporcional ao erro de rastreo.
- Minimizar $J(\theta) \Rightarrow$ minimizar $|e|$.
- Variação do parâmetro:

$$\frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta}, \quad \gamma > 0, \quad (1)$$

isto é, θ varia com sinal oposto ao de $\frac{\partial J}{\partial \theta}$.

- Com isso, θ varia na direção oposta à de maior crescimento de $J(\theta)$.
- Regra desenvolvida no *Instrumentation Laboratory* (atualmente *Draper Laboratory*) do MIT.



Um exemplo

Regra do MIT

- Seja o erro de rastreo $e = y - y_m$.
- Defina uma função $J(\theta) \propto |e|$ que é diretamente proporcional ao erro de rastreo.
- Minimizar $J(\theta) \Rightarrow$ minimizar $|e|$.
- Variação do parâmetro:

$$\frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta}, \quad \gamma > 0, \quad (1)$$

isto é, θ varia com sinal oposto ao de $\frac{\partial J}{\partial \theta}$.

- Com isso, θ varia na direção oposta à de maior crescimento de $J(\theta)$.
- Regra desenvolvida no *Instrumentation Laboratory* (atualmente *Draper Laboratory*) do MIT.



Um exemplo

Regra do MIT

- Possíveis valores de $J(\theta)$:

- $J(\theta) = \frac{1}{2}e^2 \Rightarrow \frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta} = -\gamma e \frac{\partial e}{\partial \theta}$

- $J(\theta) = |e| \Rightarrow \frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta} = -\gamma \text{sgn}(e) \frac{\partial e}{\partial \theta}$

- entre outros...



Um exemplo

Regra do MIT

- Possíveis valores de $J(\theta)$:

- $J(\theta) = \frac{1}{2}e^2 \Rightarrow \frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta} = -\gamma e \frac{\partial e}{\partial \theta}$

- $J(\theta) = |e| \Rightarrow \frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta} = -\gamma \text{sgn}(e) \frac{\partial e}{\partial \theta}$

- entre outros...



Um exemplo

Regra do MIT

- Possíveis valores de $J(\theta)$:

- $J(\theta) = \frac{1}{2}e^2 \Rightarrow \frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta} = -\gamma e \frac{\partial e}{\partial \theta}$

- $J(\theta) = |e| \Rightarrow \frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta} = -\gamma \text{sgn}(e) \frac{\partial e}{\partial \theta}$

- entre outros...



Um exemplo

Regra do MIT para o nosso exemplo

- Erro de rastreo $e = y - y_m = kG(s)\theta r - k_0G(s)r$.^a
- Escolhendo $J(\theta) = \frac{1}{2}e^2$:

$$\frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta} = -\gamma e \frac{\partial e}{\partial \theta} = -\gamma e k G(s) r = -\gamma e \frac{k}{k_0} y_m = -\gamma' e y_m. \quad (2)$$

- Desde que se conheça o sinal de k , o termo γ' terá sinal conhecido (γ é arbitrado). Então, podemos arbitrar diretamente γ' , eliminando a dependência no parâmetro desconhecido k e mantendo a direção de crescimento de θ oposta à de $\frac{\partial J}{\partial \theta}$.

^aMistura de notação entre domínio da frequência e do tempo



Um exemplo

Regra do MIT para o nosso exemplo

- Erro de rastreo $e = y - y_m = kG(s)\theta r - k_0G(s)r$.^a
- Escolhendo $J(\theta) = \frac{1}{2}e^2$:

$$\frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta} = -\gamma e \frac{\partial e}{\partial \theta} = -\gamma e k G(s) r = -\gamma e \frac{k}{k_0} y_m = -\gamma' e y_m. \quad (2)$$

- Desde que se conheça o sinal de k , o termo γ' terá sinal conhecido (γ é arbitrado). Então, podemos arbitrar diretamente γ' , eliminando a dependência no parâmetro desconhecido k e mantendo a direção de crescimento de θ oposta à de $\frac{\partial J}{\partial \theta}$.

^aMistura de notação entre domínio da frequência e do tempo



Um exemplo

Regra do MIT para o nosso exemplo

- Erro de rastreo $e = y - y_m = kG(s)\theta r - k_0G(s)r$.^a
- Escolhendo $J(\theta) = \frac{1}{2}e^2$:

$$\frac{d\theta}{dt} = -\gamma \frac{\partial J}{\partial \theta} = -\gamma e \frac{\partial e}{\partial \theta} = -\gamma e k G(s) r = -\gamma e \frac{k}{k_0} y_m = -\gamma' e y_m. \quad (2)$$

- Desde que se conheça o sinal de k , o termo γ' terá sinal conhecido (γ é arbitrado). Então, podemos arbitrar diretamente γ' , eliminando a dependência no parâmetro desconhecido k e mantendo a direção de crescimento de θ oposta à de $\frac{\partial J}{\partial \theta}$.

^aMistura de notação entre domínio da frequência e do tempo



Um exemplo

Exemplo numérico



- Vamos assumir
 - $G(s) = 1/(s + 1)$ dinâmica conhecida;
 - $k = 1$ desconhecido (usado apenas na simulação);
 - $k_0 = 2$ desejado;
 - $\gamma' = 1$ (ganho de adaptação);
 - $r = \text{sen}(t)$ referência;
 - $\theta(0) = 0$ valor inicial de θ ;



Um exemplo

Exemplo numérico

- Vamos assumir
 - $G(s) = 1/(s + 1)$ dinâmica conhecida;
 - $k = 1$ desconhecido (usado apenas na simulação);
 - $k_0 = 2$ desejado;
 - $\gamma = 1$ (ganho de adaptação);
 - $r = \text{sen}(t)$ referência;
 - $\theta(0) = 0$ valor inicial de θ ;



Convergência da estimativa do parâmetro

Mesmo exemplo, outra dinâmica

- Assumindo $G(s) = 1$ para o mesmo exemplo;
- Erro de rastreo $e = y - y_m = k\theta r - k_0 r = k(\theta - \theta^0)r$, em que $\theta^0 = k_0/k$.

$$\frac{d\theta}{dt} = -\gamma e \frac{\partial e}{\partial \theta} = -\gamma e k r = -\gamma k^2 r^2 (\theta - \theta^0). \quad (3)$$

- Solução:

$$\theta(t) = \theta^0 + [\theta(0) - \theta^0] e^{-\gamma k^2 I_t} \quad (4)$$

com

$$I_t = \int_0^t r^2(\tau) d\tau. \quad (5)$$



Convergência da estimativa do parâmetro

Mesmo exemplo, outra dinâmica

- Assumindo $G(s) = 1$ para o mesmo exemplo;
- Erro de rastreo $e = y - y_m = k\theta r - k_0 r = k(\theta - \theta^0)r$, em que $\theta^0 = k_0/k$.

$$\frac{d\theta}{dt} = -\gamma e \frac{\partial e}{\partial \theta} = -\gamma e k r = -\gamma k^2 r^2 (\theta - \theta^0). \quad (3)$$

- Solução:

$$\theta(t) = \theta^0 + [\theta(0) - \theta^0] e^{-\gamma k^2 I_t} \quad (4)$$

com

$$I_t = \int_0^t r^2(\tau) d\tau. \quad (5)$$



Convergência da estimativa do parâmetro

Mesmo exemplo, outra dinâmica

- Assumindo $G(s) = 1$ para o mesmo exemplo;
- Erro de rastreo $e = y - y_m = k\theta r - k_0 r = k(\theta - \theta^0)r$, em que $\theta^0 = k_0/k$.

-

$$\frac{d\theta}{dt} = -\gamma e \frac{\partial e}{\partial \theta} = -\gamma e k r = -\gamma k^2 r^2 (\theta - \theta^0). \quad (3)$$

- Solução:

$$\theta(t) = \theta^0 + [\theta(0) - \theta^0] e^{-\gamma k^2 I_t} \quad (4)$$

com

$$I_t = \int_0^t r^2(\tau) d\tau. \quad (5)$$



Convergência da estimativa do parâmetro

Mesmo exemplo, outra dinâmica

- Assumindo $G(s) = 1$ para o mesmo exemplo;
- Erro de rastreo $e = y - y_m = k\theta r - k_0 r = k(\theta - \theta^0)r$, em que $\theta^0 = k_0/k$.

-

$$\frac{d\theta}{dt} = -\gamma e \frac{\partial e}{\partial \theta} = -\gamma e k r = -\gamma k^2 r^2 (\theta - \theta^0). \quad (3)$$

- Solução:

$$\theta(t) = \theta^0 + [\theta(0) - \theta^0] e^{-\gamma k^2 I_t} \quad (4)$$

com

$$I_t = \int_0^t r^2(\tau) d\tau. \quad (5)$$



Convergência da estimativa do parâmetro

Necessidade de “persistência” da excitação

- Solução:

$$\theta(t) = \theta^0 + [\theta(0) - \theta^0]e^{-\gamma k^2 I_t} \quad (6)$$

com

$$I_t = \int_0^t r^2(\tau) d\tau. \quad (7)$$

- $\theta(t) \rightarrow \theta^0 \Leftrightarrow I_t \rightarrow \infty$, i.e., excitação r persistente.
- Mas o erro de rastreamento $e = k(\theta - \theta^0)r \rightarrow 0$ de qualquer forma:
 - r é persistente, $\theta - \theta^0 \rightarrow 0$;
 - $r \rightarrow 0$, $e = k(\theta - \theta^0)r \rightarrow 0$.



Convergência da estimativa do parâmetro

Necessidade de “persistência” da excitação

- Solução:

$$\theta(t) = \theta^0 + [\theta(0) - \theta^0]e^{-\gamma k^2 I_t} \quad (6)$$

com

$$I_t = \int_0^t r^2(\tau) d\tau. \quad (7)$$

- $\theta(t) \rightarrow \theta^0 \Leftrightarrow I_t \rightarrow \infty$, i.e., excitação r persistente.
- Mas o erro de rastreo $e = k(\theta - \theta^0)r \rightarrow 0$ de qualquer forma:
 - r é persistente, $\theta - \theta^0 \rightarrow 0$;
 - $r \rightarrow 0$, $e = k(\theta - \theta^0)r \rightarrow 0$.



Convergência da estimativa do parâmetro

Necessidade de “persistência” da excitação

- Solução:

$$\theta(t) = \theta^0 + [\theta(0) - \theta^0]e^{-\gamma k^2 I_t} \quad (6)$$

com

$$I_t = \int_0^t r^2(\tau) d\tau. \quad (7)$$

- $\theta(t) \rightarrow \theta^0 \Leftrightarrow I_t \rightarrow \infty$, i.e., excitação r persistente.
- Mas o erro de rastreo $e = k(\theta - \theta^0)r \rightarrow 0$ de qualquer forma:
 - r é persistente, $\theta - \theta^0 \rightarrow 0$;
 - $r \rightarrow 0$, $e = k(\theta - \theta^0)r \rightarrow 0$.



Convergência da estimativa do parâmetro

Necessidade de “persistência” da excitação

- Solução:

$$\theta(t) = \theta^0 + [\theta(0) - \theta^0]e^{-\gamma k^2 I_t} \quad (6)$$

com



$$I_t = \int_0^t r^2(\tau) d\tau. \quad (7)$$

- $\theta(t) \rightarrow \theta^0 \Leftrightarrow I_t \rightarrow \infty$, i.e., excitação r persistente.
- Mas o erro de rastreo $e = k(\theta - \theta^0)r \rightarrow 0$ de qualquer forma:
 - r é persistente, $\theta - \theta^0 \rightarrow 0$;
 - $r \rightarrow 0$, $e = k(\theta - \theta^0)r \rightarrow 0$.





Convergência da estimativa do parâmetro

Excitação persistente



Convergência da estimativa do parâmetro

Excitação não persistente



Outras formas de obter mecanismo de adaptação

Baseado na teoria de Lyapunov

- Determinar erro de rastreo $e = y - y_m$ e \dot{e} .
- \dot{e} contém os parâmetros a serem estimados.
- Propor função candidata de Lyapunov V para este sistema dinâmico.
- Caso $\dot{V} \leq 0$ (PSD), usar Lema de Barbalat (*Lyapunov-like analysis*).



Outras formas de obter mecanismo de adaptação

Baseado na teoria de Lyapunov

- Determinar erro de rastreo $e = y - y_m$ e \dot{e} .
- \dot{e} contém os parâmetros a serem estimados.
- Propor função candidata de Lyapunov V para este sistema dinâmico.
- Caso $\dot{V} \leq 0$ (PSD), usar Lema de Barbalat (*Lyapunov-like analysis*).



Outras formas de obter mecanismo de adaptação

Baseado na teoria de Lyapunov

- Determinar erro de rastreo $e = y - y_m$ e \dot{e} .
- \dot{e} contém os parâmetros a serem estimados.
- Propor função candidata de Lyapunov V para este sistema dinâmico.
- Caso $\dot{V} \leq 0$ (PSD), usar Lema de Barbalat (*Lyapunov-like analysis*).



Outras formas de obter mecanismo de adaptação

Baseado na teoria de Lyapunov

- Determinar erro de rastreo $e = y - y_m$ e \dot{e} .
- \dot{e} contém os parâmetros a serem estimados.
- Propor função candidata de Lyapunov V para este sistema dinâmico.
- Caso $\dot{V} \leq 0$ (PSD), usar Lema de Barbalat (*Lyapunov-like analysis*).



Exemplo com teoria de Lyapunov

Sistema para exemplo

- Sistema $\dot{y} = -ay + bu$, a e b desconhecidos.
- Modelo desejado $\dot{y}_m = -a_m y_m + b_m r$.
- Controle $u = \theta_1 r - \theta_2 y$, θ_1 e θ_2 parâmetros do controlador.
- $\dot{e} = \dot{y} - \dot{y}_m = -ay + bu + a_m y_m - b_m r = -ay + b\theta_1 r - b\theta_2 y + a_m y_m - b_m r = a_m y_m + (-a - b\theta_2)y + (b\theta_1 - b_m)r = -a_m e + (a_m - a - b\theta_2)y + (b\theta_1 - b_m)r$.



Exemplo com teoria de Lyapunov

Sistema para exemplo

- Sistema $\dot{y} = -ay + bu$, a e b desconhecidos.
- Modelo desejado $\dot{y}_m = -a_my_m + b_mr$.
- Controle $u = \theta_1 r - \theta_2 y$, θ_1 e θ_2 parâmetros do controlador.
- $\dot{e} = \dot{y} - \dot{y}_m = -ay + bu + a_my_m - b_mr = -ay + b\theta_1 r - b\theta_2 y + a_my_m - b_mr = a_my_m + (-a - b\theta_2)y + (b\theta_1 - b_m)r = -a_me + (a_m - a - b\theta_2)y + (b\theta_1 - b_m)r$.



Exemplo com teoria de Lyapunov

Sistema para exemplo

- Sistema $\dot{y} = -ay + bu$, a e b desconhecidos.
- Modelo desejado $\dot{y}_m = -a_m y_m + b_m r$.
- Controle $u = \theta_1 r - \theta_2 y$, θ_1 e θ_2 parâmetros do controlador.
- $\dot{e} = \dot{y} - \dot{y}_m = -ay + bu + a_m y_m - b_m r = -ay + b\theta_1 r - b\theta_2 y + a_m y_m - b_m r = a_m y_m + (-a - b\theta_2)y + (b\theta_1 - b_m)r = -a_m e + (a_m - a - b\theta_2)y + (b\theta_1 - b_m)r$.



Exemplo com teoria de Lyapunov

Sistema para exemplo

- Sistema $\dot{y} = -ay + bu$, a e b desconhecidos.
- Modelo desejado $\dot{y}_m = -a_m y_m + b_m r$.
- Controle $u = \theta_1 r - \theta_2 y$, θ_1 e θ_2 parâmetros do controlador.
- $\dot{e} = \dot{y} - \dot{y}_m = -ay + bu + a_m y_m - b_m r = -ay + b\theta_1 r - b\theta_2 y + a_m y_m - b_m r = a_m y_m + (-a - b\theta_2)y + (b\theta_1 - b_m)r = -a_m e + (a_m - a - b\theta_2)y + (b\theta_1 - b_m)r$.



Exemplo com teoria de Lyapunov

Lyapunov-like analysis



$$V(e, \theta_1, \theta_2) = \frac{1}{2} \left[e^2 + \frac{1}{b\gamma} (b\theta_2 + a - a_m)^2 + \frac{1}{b\gamma} (b\theta_1 - b_m)^2 \right]. \quad (8)$$

- Assumindo que $b\gamma > 0$, V é limitada inferiormente por 0.
- A derivada de V é

$$\dot{V} = e\dot{e} + \frac{1}{\gamma} (b\theta_2 + a - a_m)\dot{\theta}_2 + \frac{1}{\gamma} (b\theta_1 - b_m)\dot{\theta}_1, \quad (9)$$

$$\dot{V} = -a_m e^2 + \frac{1}{\gamma} (b\theta_2 + a - a_m)(\dot{\theta}_2 - \gamma e y) + \frac{1}{\gamma} (b\theta_1 - b_m)(\dot{\theta}_1 + \gamma e r). \quad (10)$$



Exemplo com teoria de Lyapunov

Lyapunov-like analysis



$$V(e, \theta_1, \theta_2) = \frac{1}{2} \left[e^2 + \frac{1}{b\gamma} (b\theta_2 + a - a_m)^2 + \frac{1}{b\gamma} (b\theta_1 - b_m)^2 \right]. \quad (8)$$

- Assumindo que $b\gamma > 0$, V é limitada inferiormente por 0.
- A derivada de V é

$$\dot{V} = e\dot{e} + \frac{1}{\gamma} (b\theta_2 + a - a_m)\dot{\theta}_2 + \frac{1}{\gamma} (b\theta_1 - b_m)\dot{\theta}_1, \quad (9)$$

$$\dot{V} = -a_m e^2 + \frac{1}{\gamma} (b\theta_2 + a - a_m)(\dot{\theta}_2 - \gamma e y) + \frac{1}{\gamma} (b\theta_1 - b_m)(\dot{\theta}_1 + \gamma e r). \quad (10)$$



Exemplo com teoria de Lyapunov

Lyapunov-like analysis



$$V(e, \theta_1, \theta_2) = \frac{1}{2} \left[e^2 + \frac{1}{b\gamma} (b\theta_2 + a - a_m)^2 + \frac{1}{b\gamma} (b\theta_1 - b_m)^2 \right]. \quad (8)$$

- Assumindo que $b\gamma > 0$, V é limitada inferiormente por 0.
- A derivada de V é

$$\dot{V} = e\dot{e} + \frac{1}{\gamma} (b\theta_2 + a - a_m)\dot{\theta}_2 + \frac{1}{\gamma} (b\theta_1 - b_m)\dot{\theta}_1, \quad (9)$$

$$\dot{V} = -a_m e^2 + \frac{1}{\gamma} (b\theta_2 + a - a_m)(\dot{\theta}_2 - \gamma e y) + \frac{1}{\gamma} (b\theta_1 - b_m)(\dot{\theta}_1 + \gamma e r). \quad (10)$$



Exemplo com teoria de Lyapunov

Lyapunov-like analysis



$$V(e, \theta_1, \theta_2) = \frac{1}{2} \left[e^2 + \frac{1}{b\gamma} (b\theta_2 + a - a_m)^2 + \frac{1}{b\gamma} (b\theta_1 - b_m)^2 \right]. \quad (8)$$

- Assumindo que $b\gamma > 0$, V é limitada inferiormente por 0.
- A derivada de V é

$$\dot{V} = e\dot{e} + \frac{1}{\gamma} (b\theta_2 + a - a_m)\dot{\theta}_2 + \frac{1}{\gamma} (b\theta_1 - b_m)\dot{\theta}_1, \quad (9)$$

$$\dot{V} = -a_m e^2 + \frac{1}{\gamma} (b\theta_2 + a - a_m)(\dot{\theta}_2 - \gamma e y) + \frac{1}{\gamma} (b\theta_1 - b_m)(\dot{\theta}_1 + \gamma e r). \quad (10)$$



Exemplo com teoria de Lyapunov

Lyapunov-like analysis

- A derivada de V é

$$\dot{V} = -a_m e^2 + \frac{1}{\gamma} (b\theta_2 + a - a_m)(\dot{\theta}_2 - \gamma e y) + \frac{1}{\gamma} (b\theta_1 - b_m)(\dot{\theta}_1 + \gamma e r). \quad (11)$$

- Escolhendo

$$\dot{\theta}_1 = -\gamma r e \quad (12)$$

$$\dot{\theta}_2 = \gamma y e \quad (13)$$

tem-se

$$\dot{V} = -a_m e^2. \quad (14)$$



Exemplo com teoria de Lyapunov

Lyapunov-like analysis

- A derivada de V é

$$\dot{V} = -a_m e^2 + \frac{1}{\gamma} (b\theta_2 + a - a_m)(\dot{\theta}_2 - \gamma e y) + \frac{1}{\gamma} (b\theta_1 - b_m)(\dot{\theta}_1 + \gamma e r). \quad (11)$$

- Escolhendo

$$\dot{\theta}_1 = -\gamma r e \quad (12)$$

$$\dot{\theta}_2 = \gamma y e \quad (13)$$

tem-se

$$\dot{V} = -a_m e^2. \quad (14)$$



Exemplo com teoria de Lyapunov

Lyapunov-like analysis

- A derivada

$$\dot{V} = -a_m e^2 \leq 0. \quad (15)$$

é NSD apenas.

- Então $V(t) \leq V(0) \Rightarrow V$ é limitada $\Rightarrow e, \theta_1$ e θ_2 limitados. Se o modelo desejado for estável, $y = e + y_m$ será limitado também, em vista de e e y_m o serem.
- Calculando a segunda derivada

$$\ddot{V} = -a_m e \dot{e} = 2[a_m^2 e^2 + a_m(a_m - a - b\theta_2)ey + a_m(b\theta_1 - b_m)er]. \quad (16)$$

é limitada, pois e, θ_1, θ_2, y e r (escolhido) são limitados

- Pelo Lema de Barbalat, se \ddot{V} for limitada, $\dot{V} \rightarrow 0 \Rightarrow e \rightarrow 0$.



Exemplo com teoria de Lyapunov

Lyapunov-like analysis

- A derivada

$$\dot{V} = -a_m e^2 \leq 0. \quad (15)$$

é NSD apenas.

- Então $V(t) \leq V(0) \Rightarrow V$ é limitada $\Rightarrow e, \theta_1$ e θ_2 limitados. Se o modelo desejado for estável, $y = e + y_m$ será limitado também, em vista de e e y_m o serem.
- Calculando a segunda derivada

$$\ddot{V} = -a_m e \dot{e} = 2[a_m^2 e^2 + a_m(a_m - a - b\theta_2)ey + a_m(b\theta_1 - b_m)er]. \quad (16)$$

é limitada, pois e, θ_1, θ_2, y e r (escolhido) são limitados

- Pelo Lema de Barbalat, se \ddot{V} for limitada, $\dot{V} \rightarrow 0 \Rightarrow e \rightarrow 0$.



Exemplo com teoria de Lyapunov

Lyapunov-like analysis

- A derivada

$$\dot{V} = -a_m e^2 \leq 0. \quad (15)$$

é NSD apenas.

- Então $V(t) \leq V(0) \Rightarrow V$ é limitada $\Rightarrow e, \theta_1$ e θ_2 limitados. Se o modelo desejado for estável, $y = e + y_m$ será limitado também, em vista de e e y_m o serem.
- Calculando a segunda derivada

$$\ddot{V} = -a_m e \dot{e} = 2[a_m^2 e^2 + a_m(a_m - a - b\theta_2)ey + a_m(b\theta_1 - b_m)er]. \quad (16)$$

é limitada, pois e, θ_1, θ_2, y e r (escolhido) são limitados

- Pelo Lema de Barbalat, se \ddot{V} for limitada, $\dot{V} \rightarrow 0 \Rightarrow e \rightarrow 0$.



Exemplo com teoria de Lyapunov

Cálculo dos parâmetros para rastreo perfeito

- Sistema teria rastreo perfeito se:

$$\dot{y} = -ay + bu = -ay + b\theta_1 r - b\theta_2 y = (-a - b\theta_2)y + b\theta_1 r \quad (17)$$

$$\dot{y}_m = -a_m y + b_m r = (-a - b\theta_2)y + b\theta_1 r \quad (18)$$

$$\theta_1^0 = \frac{b_m}{b} \quad (19)$$

$$\theta_2^0 = \frac{a_m - a}{b} \quad (20)$$



Exemplo com teoria de Lyapunov

Exemplo numérico

- $G(s) = \frac{0,5}{s+1}$, i. e, $a = 1$ e $b = 0,5$.
- $G_m(s) = \frac{2}{s+2}$, i. e, $a_m = 2$ e $b_m = 2$.
- $\theta_1^0 = \frac{b_m}{b} = 4$ e $\theta_2^0 = \frac{a_m - a}{b} = 2$.
- $\gamma = 1$.



Exemplo com teoria de Lyapunov

Exemplo numérico

- $G(s) = \frac{0,5}{s+1}$, i. e, $a = 1$ e $b = 0,5$.
- $G_m(s) = \frac{2}{s+2}$, i. e, $a_m = 2$ e $b_m = 2$.
- $\theta_1^0 = \frac{b_m}{b} = 4$ e $\theta_2^0 = \frac{a_m - a}{b} = 2$.
- $\gamma = 1$.



Exemplo com teoria de Lyapunov

Exemplo numérico

- $G(s) = \frac{0,5}{s+1}$, i. e, $a = 1$ e $b = 0,5$.
- $G_m(s) = \frac{2}{s+2}$, i. e, $a_m = 2$ e $b_m = 2$.
- $\theta_1^0 = \frac{b_m}{b} = 4$ e $\theta_2^0 = \frac{a_m - a}{b} = 2$.
- $\gamma = 1$.



Exemplo com teoria de Lyapunov

Exemplo numérico

- $G(s) = \frac{0,5}{s+1}$, i. e, $a = 1$ e $b = 0,5$.
- $G_m(s) = \frac{2}{s+2}$, i. e, $a_m = 2$ e $b_m = 2$.
- $\theta_1^0 = \frac{b_m}{b} = 4$ e $\theta_2^0 = \frac{a_m - a}{b} = 2$.
- $\gamma = 1$.



Resultado de simulação

