



Instituto Tecnológico de Aeronáutica

Divisão de Engenharia Eletrônica

Departamento de Sistemas e Controle

São José dos Campos, São Paulo, Brasil

Aula 10 - Análise de estabilidade de sistemas lineares usando desigualdades matriciais lineares ¹

Rubens J M Afonso

EE-209: Sistemas de controle não lineares

15 de setembro de 2017

¹S. P. Boyd et al, *Linear matrix inequalities in system and control theory*, Philadelphia : Society for Industrial and Applied Mathematics, 1994.

Análise de sistemas lineares pelos métodos de Lyapunov

As funções de Lyapunov são aditivas, i. e., se $V_1(\mathbf{x})$ e $V_2(\mathbf{x})$ forem funções de Lyapunov para

$$\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}), \quad (1)$$

então:

$$V(\mathbf{x}) = V_1(\mathbf{x}) + V_2(\mathbf{x})$$

também é uma função de Lyapunov para (1).

Como muitos sistemas envolvem a conexão de partes lineares, é interessante avaliar a estabilidade do conjunto usando os métodos de Lyapunov.



Outra razão é o desenvolvimento de técnicas para avaliar a **robustez** de sistemas lineares a variações nos parâmetros de maneira a sintetizar controladores robustos usando otimização computacional. Relembre que o critério de Routh-Hurwitz serve para avaliar a estabilidade face a variações nos parâmetros, mas sua aplicação para síntese é limitada. Por outro lado, usando os métodos de Lyapunov, pode-se escrever este problema de análise/síntese na forma de um problema de otimização numérica para o qual existem algoritmos de solução eficientes.



Definições preliminares

Definição

Uma matriz $M \in \mathbb{R}^{n \times n}$ é simétrica se $M = M^T$.

^a M é antissimétrica se $M = -M^T$.

Definição

Uma matriz $M \in \mathbb{R}^{n \times n}$ é positivo definida (PD) se

$$\mathbf{x}^T M \mathbf{x} > 0, \forall \mathbf{x} \neq 0.$$

Notação: $M > 0$.



Definição

Uma matriz $M \in \mathbb{R}^{n \times n}$ é positivo semidefinida (PSD) se

$$\mathbf{x}^T M \mathbf{x} \geq 0, \forall \mathbf{x}.$$

Notação: $M \geq 0$.

Definição

Uma matriz $M \in \mathbb{R}^{n \times n}$ é negativo definida (ND) se $-M$ é PD.

Notação: $M < 0$.

Definição

Uma matriz $M \in \mathbb{R}^{n \times n}$ é negativo semidefinida (NSD) se $-M$ é PSD.

Notação: $M \leq 0$.



Tomemos o sistema linear e invariante no tempo (autônomo) – LIT (*Linear Time Invariant*):

$$\dot{\mathbf{x}} = A\mathbf{x}. \quad (2)$$

Neste caso, que tipo de candidata a função de Lyapunov poderíamos usar? Parece natural escolher uma forma quadrática, como:

$$V(\mathbf{x}) = \mathbf{x}^T P \mathbf{x}, \quad (3)$$

em que $P > 0$. Derivando com respeito ao tempo:

$$\dot{V}(\mathbf{x}) = \dot{\mathbf{x}}^T P \mathbf{x} + \mathbf{x}^T P \dot{\mathbf{x}} = (A\mathbf{x})^T P \mathbf{x} + \mathbf{x}^T P (A\mathbf{x}) = \mathbf{x}^T (A^T P + PA) \mathbf{x}. \quad (4)$$

$\dot{V}(\mathbf{x})$ será ND se a matriz $A^T P + PA < 0$, i. e., se houver uma matriz $Q > 0$ tal que:

$$A^T P + PA = -Q. \quad (5)$$

A equação (5) é chamada de **Equação de Lyapunov**.



Uma matriz $P \in \mathbb{R}^{n \times n}$ pode ser decomposta na soma de uma parte simétrica P_s e uma antissimétrica P_{as} :

$$P = P_s + P_{as}, \quad P_s = \frac{P + P^T}{2}, \quad P_{as} = \frac{P - P^T}{2}$$

Dessa forma:

$$\begin{aligned} (\mathbf{x}^T P \mathbf{x})^T &= \mathbf{x}^T P^T \mathbf{x} = \cancel{\mathbf{x}^T P_s \mathbf{x}} - \mathbf{x}^T P_{as} \mathbf{x} \underbrace{=}_{\mathbf{x}^T P \mathbf{x} \in \mathbb{R}} \mathbf{x}^T P \mathbf{x} = \cancel{\mathbf{x}^T P_s \mathbf{x}} + \mathbf{x}^T P_{as} \mathbf{x} \\ &- \mathbf{x}^T P_{as} \mathbf{x} = \mathbf{x}^T P_{as} \mathbf{x} \Rightarrow 2\mathbf{x}^T P_{as} \mathbf{x} = 0. \end{aligned}$$

Assim

$$\mathbf{x}^T P \mathbf{x} = \mathbf{x}^T P_s \mathbf{x} + \mathbf{x}^T P_{as} \mathbf{x} \xrightarrow{0} \mathbf{x}^T P_s \mathbf{x}.$$



Vamos restringir a busca às matrizes P simétricas, visto que isto não altera o valor de $V(\mathbf{x})$. Caso $P = P^T$, então, da equação de Lyapunov (5):

$$-Q = A^T P + PA = A^T P^T + P^T A = (A^T P + PA)^T = -Q^T,$$

isto é, a matriz Q também deve ser simétrica.

Desta forma, restringe-se a busca a matrizes P e Q simétricas e PD que satisfaçam (5) para demonstrar que a origem é PE estável do sistema (2). Contudo, arbitrando P pode-se encontrar Q que não seja PD. Como a condição é apenas suficiente, nada se pode afirmar.



Exemplo: considere um sistema da forma (2), em que

$$A = \begin{bmatrix} 0 & 4 \\ -8 & -12 \end{bmatrix},$$

e arbitra-se:

$$P = I.$$

Então, usando (5):

$$Q = - \begin{bmatrix} 0 & 4 \\ -8 & -12 \end{bmatrix} - \begin{bmatrix} 0 & -8 \\ 4 & -12 \end{bmatrix} = \begin{bmatrix} 0 & 4 \\ 4 & 24 \end{bmatrix},$$

donde

$$\mathbf{x}^T Q \mathbf{x} = 8x_1x_2 + 24x_2^2 = 0, \forall \mathbf{x} = \begin{bmatrix} x_1 \\ 0 \end{bmatrix} \rightarrow Q \text{ não é PD.}$$

Com isso, não conseguimos concluir nada a respeito da estabilidade da origem do sistema (2).



Proposta de procedimento

Podemos resolver (5) para P dada uma matriz Q simétrica e PD, de forma a maximizar as chances de satisfazer as condições para estabilidade. Retomando o exemplo anterior com $Q = I$, a equação de Lyapunov (5) fica:

$$\begin{bmatrix} 0 & 4 \\ -8 & -12 \end{bmatrix} \begin{bmatrix} p_{11} & p_{12} \\ p_{12} & p_{22} \end{bmatrix} + \begin{bmatrix} p_{11} & p_{12} \\ p_{12} & p_{22} \end{bmatrix} \begin{bmatrix} 0 & -8 \\ 4 & -12 \end{bmatrix} = \begin{bmatrix} -1 & 0 \\ 0 & -1 \end{bmatrix},$$

$$\begin{bmatrix} 4p_{12} & 4p_{22} \\ -8p_{11} - 12p_{12} & -8p_{12} - 12p_{22} \end{bmatrix} + \begin{bmatrix} 4p_{12} & -8p_{11} - 12p_{12} \\ 4p_{22} & -8p_{12} - 12p_{22} \end{bmatrix} = \begin{bmatrix} -1 & 0 \\ 0 & -1 \end{bmatrix},$$

$$\begin{bmatrix} 8p_{12} & -8p_{11} - 12p_{12} + 4p_{22} \\ -8p_{11} - 12p_{12} + 4p_{22} & -16p_{12} - 24p_{22} \end{bmatrix} = \begin{bmatrix} -1 & 0 \\ 0 & -1 \end{bmatrix},$$

donde

$$p_{12} = -\frac{1}{8}, \quad p_{22} = \frac{1}{8}, \quad p_{11} = \frac{1}{4}.$$



$$\begin{aligned}\mathbf{x}^T P \mathbf{x} &= p_{11}x_1^2 + 2p_{12}x_1x_2 + p_{22}x_2^2 = \frac{1}{4}x_1^2 - \frac{1}{4}x_1x_2 + \frac{1}{8}x_2^2 = \\ &= \frac{1}{8}[2x_1^2 - 2x_1x_2 + x_2^2] = \frac{1}{8}[x_1^2 + (x_1 - x_2)^2] > 0, \forall \mathbf{x} \neq 0 \rightarrow P \text{ é PD.}\end{aligned}$$

Assim, $V(\mathbf{x}) = \mathbf{x}^T P \mathbf{x}$ é uma função de Lyapunov para o sistema (2) \rightarrow a origem é PE estável. Adicionalmente, como $Q > 0$, pode-se concluir que a estabilidade é assintótica.

Observação: usando o teorema “Segundo método de Lyapunov – versão global”, chega-se a uma condição suficiente para a estabilidade. No entanto, para o sistema (2) LIT, é possível obter uma condição necessária.



Determinando se uma matriz é PD

Problema

Como determinar se a matriz obtida $P > 0$?

Uma alternativa para isso consiste em usar o critério de Sylvester:

Critério (de Sylvester)

Uma matriz $M \in \mathbb{R}^{n \times n}$ é PD se e somente se

- $\det([m_{ij}]) > 0$, $i = 1, 2, \dots, n$, $j = 1, 2, \dots, i$, isto é, se todos os blocos quadrados construídos a partir do elemento m_{11} tiverem determinantes positivos.



Teorema (Estabilidade de sistema LIT – condição necessária e suficiente)

A origem é PE estável do sistema (2) se e somente se, para qualquer matriz $Q > 0$ simétrica, a solução única P da equação de Lyapunov (5) for simétrica e PD.

Demonstração.

Já mostramos que a condição é suficiente aplicando o segundo método de Lyapunov. Seja $Q > 0$ uma matriz simétrica e seja:

$$P = \int_0^{\infty} e^{A^T \tau} Q e^{A \tau} d\tau,$$

esta integral converge se e somente se A for estável.



Continuação.

$$P^T = \int_0^{\infty} (e^{A\tau})^T Q^T (e^{A^T\tau})^T d\tau = \int_0^{\infty} e^{A^T\tau} Q e^{A\tau} d\tau = P,$$

$$\mathbf{x}^T P \mathbf{x} = \int_0^{\infty} \underbrace{\mathbf{x}^T e^{A^T\tau}}_{\mathbf{y}^T} Q \underbrace{e^{A\tau} \mathbf{x}}_{\mathbf{y}} d\tau = \int_0^{\infty} \underbrace{\mathbf{y}^T Q \mathbf{y}}_{\geq 0} d\tau \geq 0,$$

Lembrando que A é estável, então $e^{A\tau}$ é não singular, resultando que $\mathbf{x} = 0 \Leftrightarrow \mathbf{y} = 0$, então $\mathbf{x}^T P \mathbf{x} > 0, \forall \mathbf{x} \neq 0$. Isto é, esta definição resulta em $P > 0$ e $P = P^T$.

Como A é estável, tem-se que $e^{A\tau} \xrightarrow{\tau \rightarrow \infty} 0$, donde se pode escrever:

$$-Q = -IQI = \underbrace{e^{A^T\infty}}_0 Q \underbrace{e^{A\infty}}_0 - \underbrace{e^{A^T0}}_I Q \underbrace{e^{A0}}_I = \int_{\tau=0}^{\infty} d[e^{A^T\tau} Q e^{A\tau}]$$



Continuação.

Realizando a mudança de variáveis de integração:

$$\begin{aligned} -Q &= \int_{\tau=0}^{\infty} d[e^{A^T\tau} Q e^{A\tau}] = \int_0^{\infty} \frac{d}{d\tau} [e^{A^T\tau} Q e^{A\tau}] d\tau \\ &\int_0^{\infty} [A^T e^{A^T\tau} Q e^{A\tau} + e^{A^T\tau} Q e^{A\tau} A] d\tau \\ &A^T \int_0^{\infty} e^{A^T\tau} Q e^{A\tau} d\tau + \int_0^{\infty} e^{A^T\tau} Q e^{A\tau} d\tau A = A^T P + PA. \end{aligned}$$

Demonstrando que se A é estável, então P é solução PD e simétrica da equação de Lyapunov (5) – **condição necessária**.



Continuação.

Para demonstrar que esta solução é única, basta escrever a candidata a solução P_1 como:

$$P_1 = - \int_{\tau=0}^{\infty} d[e^{A^T \tau} P_1 e^{A \tau}] = - \int_0^{\infty} e^{A^T \tau} (A^T P_1 + P_1 A) e^{A \tau} d\tau$$
$$\int_0^{\infty} e^{A^T \tau} Q e^{A \tau} d\tau = P,$$

isto é, qualquer candidata deve ser a própria solução que já foi determinada. □



A busca de uma solução simétrica $P > 0$ para a equação de Lyapunov (5) dada uma matriz simétrica $Q > 0$ pode ser feita numericamente sem necessidade de resolver o sistema linear de equações resultante sobre as componentes de P . Para isso, reescreve-se o problema como:

Problema

Encontrar P tal que:

$$P > 0$$

$$A^T P + PA < 0.$$

Este problema pode ser encarado como um problema de programação semidefinida (*Semidefinite Programming* – SDP), em que se deseja encontrar uma solução viável. Em particular, a categoria de problema SDP em que se encaixa é chamado de problema com Desigualdades Matriciais Lineares (*Linear Matrix Inequalities* – LMI). Existem diversos pacotes computacionais eficientes disponíveis para resolver este tipo de problema, como LMILAB, SeDuMi, MOSEK, entre outros.



Exemplo computacional

Usando o pacote YALMIP, pode-se escrever o problema SDP com LMI e realizar a solução numérica através de diversos pacotes de solução diferentes².

Definindo a matriz A do sistema e definindo a matriz P como variável SDP:

$$A = [-1 \ 2 \ 0; -3 \ -4 \ 1; 0 \ 0 \ -2];$$

$$P = \text{sdpvar}(3, 3);$$

Escrevendo as restrições ($P > 0$ e $A^T P + P A < 0$):

$$F = [P \geq 0, A' * P + P * A \leq 0];$$

²<https://yalmip.github.io/tutorial/semidefiniteprogramming/>



$$F = [P \succeq 0, A' * P + P * A \preceq 0];$$

Ressalta-se que as restrições adicionadas não são estritas, como devem ser para aplicação do teorema, pois não se pode fazer dessa forma no problema SDP. Para isso, pode-se definir uma margem pequena o suficiente e impor $P \succeq \epsilon I$, $\epsilon > 0$, que significa que $P - \epsilon I \succeq 0$ (a matriz $P - \epsilon I$ é PSD).

$$\begin{aligned} \mathbf{x}^T (P - \epsilon I) \mathbf{x} \geq 0 &\rightarrow \mathbf{x}^T P \mathbf{x} \geq \mathbf{x}^T \epsilon I \mathbf{x} = \epsilon \mathbf{x}^T \mathbf{x} > 0, \forall \mathbf{x} \neq 0, \\ \mathbf{x}^T P \mathbf{x} > 0, \forall \mathbf{x} \neq 0 &\rightarrow P \succ 0. \end{aligned}$$

Assim:

$$\text{epsilon} = 1e-6;$$

$$F = [P \succeq \text{epsilon} * \text{eye}(3), A' * P + P * A \preceq -\text{epsilon} * \text{eye}(3)];$$



Resolvendo o problema e atribuindo a solução à variável $P_{feasible}$:

```
optimize (F);
```

```
 $P_{feasible}$  = value(P);
```

obtém-se:

```
 $P_{feasible}$  =
```

```

0.5603    0.0452   -0.0070
0.0452    0.2490    0.0348
-0.0070   0.0348    0.4116

```

que é um resultado dependente de máquina, algoritmo de solução, implementação computacional e tolerâncias numéricas. Usando o critério de Sylvester:

$$\left. \begin{array}{l} p_{11} = 0,5603 > 0 \\ \begin{vmatrix} 0,5603 & 0,0452 \\ 0,0452 & 0,2490 \end{vmatrix} = 0,1374 > 0 \\ \det P = 0,0559 > 0 \end{array} \right\} \Rightarrow P > 0.$$



Calculando $Q = -(A^T P + PA)$:

$$Q = -(A' * P_{feasible} + P_{feasible} * A)$$

$$Q =$$

$$\begin{bmatrix} 1.3918 & -0.1475 & 0.0384 \\ -0.1475 & 1.8108 & -0.0260 \\ 0.0384 & -0.0260 & 1.5766 \end{bmatrix}$$

Aplicando o critério de Sylvester a Q :

$$\left. \begin{array}{l} q_{11} = 1,3918 > 0 \\ \begin{vmatrix} 1,3918 & -0,1475 \\ -0,1475 & 1,8108 \end{vmatrix} = 2,4986 > 0 \\ \det Q = 3,9360 > 0 \end{array} \right\} \Rightarrow Q > 0.$$

Conclusão: pelo teorema de estabilidade de sistema LIT, a origem é PE assintoticamente estável do sistema (2) com:

$$A = \begin{bmatrix} -1 & 2 & 0 \\ -3 & -4 & 1 \\ 0 & 0 & -2 \end{bmatrix}$$



Forma mais simples

$$A = \begin{bmatrix} -1 & 2 & 0 \\ -3 & -4 & 1 \\ 0 & 0 & -2 \end{bmatrix}$$

$$\det(\lambda I - A) = \begin{vmatrix} \lambda + 1 & -2 & 0 \\ 3 & \lambda + 4 & -1 \\ 0 & 0 & \lambda + 2 \end{vmatrix} = \lambda^3 + 7\lambda^2 + 20\lambda + 20$$

Autovalores

$$\lambda_1 = -2,5 + 1,9365j, \quad \lambda_2 = -2,5 - 1,9365j, \quad \lambda_3 = -2.$$

Isto é, pelo primeiro método de Lyapunov, já se poderia concluir que a origem é PE assintoticamente estável.

Pergunta

Então, por que usar LMI para análise de estabilidade de sistemas lineares?



Esboço da resposta: robustez da estabilidade a variação de parâmetros

Suponhamos que a matriz A tenha um parâmetro α incerto, porém limitado a um intervalo conhecido $\alpha \in [\underline{\alpha}, \bar{\alpha}]$

$$A = \begin{bmatrix} \alpha & 2 & 0 \\ -3 & -4 & 1 \\ 0 & 0 & -2 \end{bmatrix}$$

Esta matriz pode ser escrita como uma combinação convexa $A = \rho_1 A_1 + \rho_2 A_2$, em que:

$$A_1 = \begin{bmatrix} \underline{\alpha} & 2 & 0 \\ -3 & -4 & 1 \\ 0 & 0 & -2 \end{bmatrix}, A_2 = \begin{bmatrix} \bar{\alpha} & 2 & 0 \\ -3 & -4 & 1 \\ 0 & 0 & -2 \end{bmatrix}$$

$$\rho_1, \rho_2 \geq 0, \rho_1 + \rho_2 = 1.$$



Para estabilidade, devem-se satisfazer:

$$P > 0$$

$$A^T P + PA < 0$$

$$\forall A = \rho_1 A_1 + \rho_2 A_2, \rho_1, \rho_2 \geq 0, \rho_1 + \rho_2 = 1$$

Problema

Se ρ_1 e ρ_2 foram variáveis, as desigualdades $A^T P + PA < 0$ envolverão produto de variáveis, deixando de serem LMI. Como reescrever este problema de maneira a eliminar as variáveis ρ_1 e ρ_2 ?



Uma saída: convexidade

Reescrevendo:

$$A^T P + PA = (\rho_1 A_1 + \rho_2 A_2)^T P + P(\rho_1 A_1 + \rho_2 A_2) \\ \rho_1 (A_1^T P + PA_1) + \rho_2 (A_2^T P + PA_2).$$

Se impusermos:

$$A_1^T P + PA_1 < 0, \\ A_2^T P + PA_2 < 0,$$

então, como $\rho_1, \rho_2 \geq 0$:

$$A^T P + PA = \rho_1 \underbrace{(A_1^T P + PA_1)}_{<0} + \rho_2 \underbrace{(A_2^T P + PA_2)}_{<0} < 0.$$



Para estabilidade, devem-se satisfazer:

$$P > 0$$

$$A_1^T P + P A_1 < 0$$

$$A_2^T P + P A_2 < 0$$

Resolvendo computacionalmente para $\underline{\alpha} = -5$ e $\bar{\alpha} = 0$:

```
alpha_inf = -5;
```

```
alpha_sup = 0;
```

```
A1 = [alpha_inf    2    0
      -3    -4    1
       0    0   -2 ];
```

```
A2 = [alpha_sup    2    0
      -3    -4    1
       0    0   -2 ];
```



Definindo P como matriz simétrica e PD e adicionando restrições:

```
P = sdpvar(3,3);
epsilon = 1e-6;
F = [P >= epsilon*eye(3), ...
A1'*P + P*A1 <= -epsilon*eye(3), ...
A2'*P + P*A2 <= -epsilon*eye(3)];
```

Achando solução viável:

```
optimize(F)
Pfeasible = value(P)
Pfeasible =
```

0.2592	0.0543	-0.0031
0.0543	0.1732	0.0259
-0.0031	0.0259	0.3435



Verificando se é PD:

```
Pfeasible(1,1)
ans = 0.2592
det(Pfeasible(1:2,1:2))
ans = 0.0419
det(Pfeasible)
ans = 0.0142
```

Saída na tela:

```
yalmiptime: 0.2844
solvertime: 0.0226
      info: 'Successfully solved (SeDuMi-1.3)'
```

problem: 0



Outra maneira mais fácil

$$\det(\lambda I - A) = \begin{vmatrix} \lambda - \alpha & -2 & 0 \\ 3 & \lambda + 4 & -1 \\ 0 & 0 & \lambda + 2 \end{vmatrix}$$

$$\lambda^3 + (6 - \alpha)\lambda^2 + (14 - 6\alpha)\lambda + (12 - 8\alpha)$$

Construindo a tabela de Routh associada a este polinômio:

s^3	1	$14 - 6\alpha$
s^2	$6 - \alpha$	$12 - 8\alpha$
s^1	$\frac{6\alpha^2 - 42\alpha + 78}{6 - \alpha}$	
s^0	$12 - 8\alpha$	

Aplicando o critério de Routh-Hurwitz:

$$\alpha < 6, \quad \alpha < 1,5, \quad (\alpha^2 - 7\alpha + 13 > 0, \forall \alpha).$$



Verificando faixa computacionalmente

Com $\bar{\alpha} = 1,45$, saída na tela:

```
yalmiptime: 0.2691
solvertime: 0.0309
      info: 'Successfully solved (SeDuMi-1.3)'
      problem: 0
```

Com $\bar{\alpha} = 1,55$, saída na tela:

```
yalmiptime: 0.2730
solvertime: 0.0750
      info: 'Infeasible problem (SeDuMi-1.3)'
      problem: 1
```

Infeasible problem \Rightarrow não foi possível encontrar solução que atenda às desigualdades.



Mais uma vez...

Pergunta

Então, por que usar LMI para análise de estabilidade de sistemas lineares?

Resposta 1

Claramente, usar o critério de Routh-Hurwitz com diversos parâmetros variáveis pode resultar em múltiplas equações não lineares nos parâmetros para determinar as faixas de estabilidade. Nesse caso, usando LMI seria simplesmente o caso de se adicionarem mais desigualdades para novos vértices de matrizes A_3, A_4, \dots

Resposta 2

Síntese de controladores lineares robustos otimizando critérios de desempenho.



Exemplo de aplicação para síntese

Considere um sistema LIT incerto descrito pela equação no espaço de estados

$$\dot{x}(t) = A(\rho)x(t) + Bu(t), \quad (6)$$

em que $x \in \mathbb{R}^n$ é o vetor de estados, $u \in \mathbb{R}^m$ é o vetor de controle e $A(\rho)$ é uma matriz desconhecida, a qual pertence a um domínio convexo e limitado incerto (politópico) Θ dado por

$$\Theta = \left\{ A(\rho) : A(\rho) = \sum_{i=1}^N \rho_i A_i, \rho \in \Phi \right\} \quad (7)$$

com

$$\Phi = \left\{ \rho \in \mathbb{R}^N, \sum_{i=1}^N \rho_i = 1; \rho_i \geq 0 \right\}. \quad (8)$$



Qualquer matriz $A(\rho)$ em Θ pode ser descrita como combinação convexa dos vértices $A_i, i = 1, \dots, N$ do politopo. Usando a candidata a função de Lyapunov:

$$V(\mathbf{x}) = \mathbf{x}^T P \mathbf{x}, \quad (9)$$

tem-se

$$\dot{V}(\mathbf{x}) = \dot{\mathbf{x}}^T P \mathbf{x} + \mathbf{x}^T P \dot{\mathbf{x}} = \{[A(\rho) + BK] \mathbf{x}\}^T P \mathbf{x} + \mathbf{x}^T P \{[A(\rho) + BK] \mathbf{x}\}, \quad (10)$$

que será ND para qualquer ρ se

$$(A_i + BK)^T P + P(A_i + BK) < 0, \forall i \in \{1, 2, \dots, N\}. \quad (11)$$



$$(A_i + BK)^T P + P(A_i + BK) < 0, \forall i \in \{1, 2, \dots, N\}. \quad (12)$$

Admitindo uma mudança de variáveis por meio de uma transformação não singular $\mathbf{y} = P\mathbf{x}$:

$$\mathbf{x}^T \left[(A_i + BK)^T P + P(A_i + BK) \right] \mathbf{x} < 0$$

$$\mathbf{y}^T (P^{-1})^T \left[(A_i + BK)^T P + P(A_i + BK) \right] P^{-1} \mathbf{y} < 0$$

$$\mathbf{y}^T \left[(A_i P^{-1} + B K P^{-1})^T + (A_i P^{-1} + B K P^{-1}) \right] \mathbf{y} < 0$$

$$(A_i P^{-1} + B K P^{-1})^T + (A_i P^{-1} + B K P^{-1}) < 0$$



$$\begin{aligned}(A_i P^{-1} + B K P^{-1})^T + (A_i P^{-1} + B K P^{-1}) &< 0 \\ (A_i Y + B K Y)^T + (A_i Y + B K Y) &< 0\end{aligned}$$

Esta última não é LMI, pois envolve o produto das variáveis K e $Y = P^{-1}$. Reescrevendo em termos de uma nova variável $X = KY$, tem-se.

$$Y A_i^T + A_i Y + X^T B^T + B X < 0, \forall i \in \{1, 2, \dots, N\}. \quad (13)$$



Assim, chegamos às LMIs para estabilidade. O problema tem duas variáveis X e Y , que devem satisfazer às seguintes LMIs:

$$\begin{aligned}YA_i^T + A_iY + X^T B^T + BX &< 0 \\ Y &> 0\end{aligned}\tag{14}$$

O ganho do controlador pode ser recuperado fazendo $K = XY^{-1} = XP$.



Exemplo: massa mola com incerteza na constante de mola

Um sistema massa mola com massa $m = 1$ kg, incerteza na constante de mola $k \in [1, 4]$ N/m e variável de controle sendo a força sobre a massa pode ser modelado como:

$$\dot{\mathbf{x}} = A(\rho)\mathbf{x} + Bu$$

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ -k & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u = \begin{bmatrix} 0 & 1 \\ -(1-\rho) - 5\rho & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u$$

em que os vértices do politopo Θ são

$$A_1 = A(\rho = 0) \text{ e } A_2 = A(\rho = 1).$$



$$A_1 = A(\rho = 0) \text{ e } A_2 = A(\rho = 1).$$

Resolvendo para encontrar X e Y que satisfaçam às LMIs (14), têm-se:

$$Y = \begin{bmatrix} 0,2786 & -0,2947 \\ -0,2947 & 1,305 \end{bmatrix}, X = [-0,4041 \quad -1,559],$$
$$K = XY^{-1} = [-3,566 \quad -2,000].$$

Com este ganho, os autovalores de $A_1 + BK$ e $A_2 + BK$, são $-1,000 \pm 1,888j$ e $-1,000 + 2,562j$, respectivamente.



Impondo taxa de decaimento mínima

Se pudermos impor que:

$$\dot{V} < -2\alpha V,$$

Então o sistema será exponencialmente estável:

$$\dot{V} + 2\alpha V = e^{-2\alpha t} \frac{d}{dt} (e^{2\alpha t} V) < 0 \Rightarrow \frac{d}{dt} (e^{2\alpha t} V) < 0,$$

$$\int \frac{d}{dt} (e^{\alpha t} V) dt < 0,$$

$$e^{2\alpha t} V(\mathbf{x}(t)) - e^{2\alpha 0} V(\mathbf{x}(0)) < 0 \Rightarrow V(\mathbf{x}(t)) < e^{-2\alpha t} V(\mathbf{x}(0)).$$

Com

$$V(\mathbf{x}(t)) = \mathbf{x}^T(t) P \mathbf{x}(t),$$

$$\mathbf{x}^T(t) P \mathbf{x}(t) < e^{-2\alpha t} \mathbf{x}^T(0) P \mathbf{x}(0),$$

$$\|\mathbf{x}(t)\| < e^{-\alpha t} \|\mathbf{x}(0)\|.$$

