

Mise en pratique de LSPI pour la commande linéaire quadratique adaptative d'une surface de manipulation à coussin d'air actif


Guillaume Laurent

Institut FEMTO-ST, UMR CNRS 6174 - UFC/ENSMM/UTBM
Département Automatique et Systèmes Micro-Mécatroniques
24, rue Alain Savary, 25000 Besançon, France
guillaume.laurent@ens2m.fr


JFPDA 2010
Besançon, 1er et 2 juin

- Steven J. Bradtke and B. Erik Ydstie and Andrew G. Barto, Adaptive linear quadratic control using policy iteration, In *Proc. of the American Control Conference*, 1994.

- Steven J. Bradtke and B. Erik Ydstie and Andrew G. Barto, Adaptive linear quadratic control using policy iteration, In *Proc. of the American Control Conference*, 1994.



- Steven J. Bradtke and B. Erik Ydstie and Andrew G. Barto, Adaptive linear quadratic control using policy iteration, In *Proc. of the American Control Conference*, 1994.



Mise en pratique sur un système réel dont la dynamique est variable

- 1 Commande linéaire quadratique
- 2 LSPI pour processus linéaires avec coût quadratique
- 3 Résultats de simulation
- 4 Surface de manipulation à coussin d'air actif
- 5 Résultats expérimentaux
- 6 Conclusions et perspectives

Plan de la présentation

- 1 Commande linéaire quadratique
- 2 LSPI pour processus linéaires avec coût quadratique
- 3 Résultats de simulation
- 4 Surface de manipulation à coussin d'air actif
- 5 Résultats expérimentaux
- 6 Conclusions et perspectives

Représentation d'état en temps discret d'un processus linéaire



Représentation d'état en temps discret d'un processus linéaire



$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

Représentation d'état en temps discret d'un processus linéaire



$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

- X_k est le vecteur d'état de dimension n

Représentation d'état en temps discret d'un processus linéaire



$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

- X_k est le vecteur d'état de dimension n
- U_k est le vecteur de commande de dimension m

Représentation d'état en temps discret d'un processus linéaire



$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

- X_k est le vecteur d'état de dimension n
- U_k est le vecteur de commande de dimension m
- Y_k est le vecteur de sortie de dimension p

Représentation d'état en temps discret d'un processus linéaire



$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

- X_k est le vecteur d'état de dimension n
- U_k est le vecteur de commande de dimension m
- Y_k est le vecteur de sortie de dimension p
- A est la matrice de dynamique de dimension $n \times n$

Représentation d'état en temps discret d'un processus linéaire



$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

- X_k est le vecteur d'état de dimension n
- U_k est le vecteur de commande de dimension m
- Y_k est le vecteur de sortie de dimension p
- A est la matrice de dynamique de dimension $n \times n$
- B est la matrice de commande de dimension $n \times m$

Représentation d'état en temps discret d'un processus linéaire



$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

- X_k est le vecteur d'état de dimension n
- U_k est le vecteur de commande de dimension m
- Y_k est le vecteur de sortie de dimension p
- A est la matrice de dynamique de dimension $n \times n$
- B est la matrice de commande de dimension $n \times m$
- C est la matrice d'observation de dimension $p \times n$

Représentation d'état en temps discret d'un processus linéaire



$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

- X_k est le vecteur d'état de dimension n
- U_k est le vecteur de commande de dimension m
- Y_k est le vecteur de sortie de dimension p
- A est la matrice de dynamique de dimension $n \times n$
- B est la matrice de commande de dimension $n \times m$
- C est la matrice d'observation de dimension $p \times n$
- D est la matrice d'action directe de dimension $p \times m$

Représentation d'état en temps discret d'un processus linéaire



$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

- X_k est le vecteur d'état de dimension n
- U_k est le vecteur de commande de dimension m
- Y_k est le vecteur de sortie de dimension p
- A est la matrice de dynamique de dimension $n \times n$
- B est la matrice de commande de dimension $n \times m$
- C est la matrice d'observation de dimension $p \times n$
- D est la matrice d'action directe de dimension $p \times m$

Commande linéaire quadratique

Processus linéaire :

$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

Commande linéaire quadratique

Processus linéaire :

$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

Loi de commande / politique :

$$U_k = \pi(X_k) = K \cdot X_k$$

K est une matrice dimension $m \times n$.

Commande linéaire quadratique

Processus linéaire :

$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

Loi de commande / politique :

$$U_k = \pi(X_k) = K \cdot X_k$$

K est une matrice dimension $m \times n$.

Fonction de coût quadratique :

$$V^K(X) = \sum_{k=0}^{\infty} X_k' E X_k + U_k' F U_k, \quad X_0 = X$$

E et F sont des matrices symétriques définies positives.

Commande linéaire quadratique

Processus linéaire :

$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

Objectif : déterminer K minimisant $V^K(X)$.

Loi de commande / politique :

$$U_k = \pi(X_k) = K \cdot X_k$$

K est une matrice dimension $m \times n$.

Fonction de coût quadratique :

$$V^K(X) = \sum_{k=0}^{\infty} X_k' E X_k + U_k' F U_k, \quad X_0 = X$$

E et F sont des matrices symétriques définies positives.

Commande linéaire quadratique

Processus linéaire :

$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

Objectif : déterminer K minimisant $V^K(X)$.

Loi de commande / politique :

$$U_k = \pi(X_k) = K \cdot X_k$$

K est une matrice dimension $m \times n$.

Si (A, B) est commandable, on a :

$$K^* = -(B'PB + F)^{-1}B'PA$$

Fonction de coût quadratique :

$$V^K(X) = \sum_{k=0}^{\infty} X_k' E X_k + U_k' F U_k, \quad X_0 = X$$

E et F sont des matrices symétriques définies positives.

Commande linéaire quadratique

Processus linéaire :

$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

Loi de commande / politique :

$$U_k = \pi(X_k) = K \cdot X_k$$

K est une matrice dimension $m \times n$.

Fonction de coût quadratique :

$$V^K(X) = \sum_{k=0}^{\infty} X_k' E X_k + U_k' F U_k, \quad X_0 = X$$

E et F sont des matrices symétriques définies positives.

Objectif : déterminer K minimisant $V^K(X)$.

Si (A, B) est commandable, on a :

$$K^* = -(B'PB + F)^{-1} B'PA$$

P est la matrice de coût solution de l'équation :

$$E + A'PA - A'PB(B'PB + F)^{-1} B'PA = P$$

Commande linéaire quadratique

Processus linéaire :

$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

Loi de commande / politique :

$$U_k = \pi(X_k) = K \cdot X_k$$

K est une matrice dimension $m \times n$.

Fonction de coût quadratique :

$$V^K(X) = \sum_{k=0}^{\infty} X_k' E X_k + U_k' F U_k, \quad X_0 = X$$

E et F sont des matrices symétriques définies positives.

Objectif : déterminer K minimisant $V^K(X)$.

Si (A, B) est commandable, on a :

$$K^* = -(B'PB + F)^{-1} B'PA$$

P est la matrice de coût solution de l'équation :

$$E + A'PA - A'PB(B'PB + F)^{-1} B'PA = P$$

Fonction de valeur :

$$V^*(X) = X'PX$$

Plan de la présentation

- 1 Commande linéaire quadratique
- 2 **LSPI pour processus linéaires avec coût quadratique**
- 3 Résultats de simulation
- 4 Surface de manipulation à coussin d'air actif
- 5 Résultats expérimentaux
- 6 Conclusions et perspectives

Fonction de valeur d'action

Processus linéaire :

$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

Fonction de valeur d'action

Processus linéaire :

$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

Fonction de valeur :

$$V(X) = X'PX$$

Fonction de valeur d'action

Processus linéaire :

$$\begin{cases} X_{k+1} &= AX_k + BU_k \\ Y_k &= CX_k + DU_k \end{cases}$$

Fonction de valeur :


$$V(X) = X'PX$$

Fonction de valeur d'action pour le critère γ -pondéré (Bradtke, 1994) :

$$\begin{aligned} Q(X, U) &= [X \quad U] \begin{bmatrix} E + \gamma A'PA & \gamma A'PB \\ \gamma B'PA & F + \gamma B'PB \end{bmatrix} \begin{bmatrix} X \\ U \end{bmatrix} \\ &= [X \quad U] \begin{bmatrix} H_{11} & H_{12} \\ H'_{12} & H_{22} \end{bmatrix} \begin{bmatrix} X \\ U \end{bmatrix} \\ &= [X \quad U] H \begin{bmatrix} X \\ U \end{bmatrix} \\ &= \phi'(X, U)\theta_t \end{aligned}$$

LSPI pour processus linéaires avec coût quadratique (Bradtke, 1994)

- 4 Recueil des échantillons :




$$U_k = \pi_t(X_k) + e_k = K_t X_k + e_k$$

où e_k est un signal d'exploration.

LSPI pour processus linéaires avec coût quadratique (Bradtke, 1994)

- ④ Recueil des échantillons :



$$U_k = \pi_t(X_k) + e_k = K_t X_k + e_k$$


où e_k est un signal d'exploration.

- ② Calcul de la fonction de valeur d'action Q^{π_t} (LSTDQ) :

$$\theta_{t+1} = \left[\sum_{k=0}^{M-1} \phi(X_k, U_k) [\phi(X_k, U_k) - \gamma \phi(X_{k+1}, \pi_t(X_{k+1}))]' \right]^{-1} \left[\sum_{k=0}^{M-1} \phi(X_k, U_k) r(X_k, U_k) \right]$$

LSPi pour processus linéaires avec coût quadratique (Bradtke, 1994)

- 1 Recueil des échantillons :



$$U_k = \pi_t(X_k) + e_k = K_t X_k + e_k$$

où e_k est un signal d'exploration.

- 2 Calcul de la fonction de valeur d'action Q^{π_t} (LSTDQ) :

$$\theta_{t+1} = \left[\sum_{k=0}^{M-1} \phi(X_k, U_k) [\phi(X_k, U_k) - \gamma \phi(X_{k+1}, \pi_t(X_{k+1}))]' \right]^{-1} \left[\sum_{k=0}^{M-1} \phi(X_k, U_k) r(X_k, U_k) \right]$$

- 3 Amélioration de la politique :

$$\forall X, \quad \pi_{t+1}(X) = \arg \min_V Q_{t+1}(X, V) = \arg \min_V \phi'(X, V) \theta_{t+1} = -H_{22}^{-1} H_{21} X$$

donc le nouveau correcteur est :

$$K_{t+1} = -H_{22}^{-1} H_{21}$$

LSPI pour processus linéaires avec coût quadratique (Bradtke, 1994)

1 **début**2 Initialiser le correcteur initial K_0 (doit être stabilisant)3 $t \leftarrow 0$ 4 **répéter**5 $\Phi \leftarrow 0$ 6 $\rho \leftarrow 0$ 7 Obtenir l'état initial X_0 du processus8 **pour** k de 0 à $M - 1$ **faire**9 $U_k \leftarrow K_t X_k + e_k$ (où e_k est un signal d'exploration); (partie en ligne)10 Appliquer U_k au processus et attendre X_{k+1} 11 $\Phi \leftarrow \Phi + \phi(X_k, U_k)[\phi(X_k, U_k) - \gamma\phi(X_{k+1}, K_t X_{k+1})]$ 12 $\rho \leftarrow \rho + \phi(X_k, U_k)r(X_k, U_k)$ 13 **fin**14 $\theta_{t+1} \leftarrow \Phi^{-1}\rho$; (partie hors ligne)15 Trouver les coefficients de H correspondants aux paramètres θ_{t+1} 16 $K_{t+1} \leftarrow -H_{22}^{-1}H_{21}$ 17 $t \leftarrow t + 1$ 18 **jusqu'à** $\theta_t \approx \theta_{t-1}$ 19 **fin**

LSPI pour processus linéaires avec coût quadratique (Bradtke, 1994)

Avantages de la méthode :

LSPI pour processus linéaires avec coût quadratique (Bradtke, 1994)

Avantages de la méthode :

- Ne nécessite pas de modèle

LSPI pour processus linéaires avec coût quadratique (Bradtke, 1994)

Avantages de la méthode :

- Ne nécessite pas de modèle
- Le nombre de paramètres de la fonction de valeur est faible $(n + m)(n + m + 1)/2$.

LSPI pour processus linéaires avec coût quadratique (Bradtke, 1994)

Avantages de la méthode :

- Ne nécessite pas de modèle
- Le nombre de paramètres de la fonction de valeur est faible $(n + m)(n + m + 1)/2$.
- Le calcul de la politique gloutonne est analytique et ne nécessite donc aucune méthode d'optimisation spécifique

LSPI pour processus linéaires avec coût quadratique (Bradtke, 1994)

Avantages de la méthode :

- Ne nécessite pas de modèle
- Le nombre de paramètres de la fonction de valeur est faible $(n + m)(n + m + 1)/2$.
- Le calcul de la politique gloutonne est analytique et ne nécessite donc aucune méthode d'optimisation spécifique
- Si le couple (A, B) est commandable, si K_0 est stabilisant et si la commande appliquée au processus comporte une part d'exploration suffisante, il existe un nombre fini d'échantillons M tel que la politique K_t converge vers la politique optimale (Bradtke, 1994)

LSPI pour processus linéaires avec coût quadratique (Bradtke, 1994)

Avantages de la méthode :

- Ne nécessite pas de modèle
- Le nombre de paramètres de la fonction de valeur est faible $(n + m)(n + m + 1)/2$.
- Le calcul de la politique gloutonne est analytique et ne nécessite donc aucune méthode d'optimisation spécifique
- Si le couple (A, B) est commandable, si K_0 est stabilisant et si la commande appliquée au processus comporte une part d'exploration suffisante, il existe un nombre fini d'échantillons M tel que la politique K_t converge vers la politique optimale (Bradtke, 1994)


Algorithme très adapté à la commande adaptative de systèmes linéaires stables

Plan de la présentation

- 1 Commande linéaire quadratique
- 2 LSPI pour processus linéaires avec coût quadratique
- 3 Résultats de simulation**
- 4 Surface de manipulation à coussin d'air actif
- 5 Résultats expérimentaux
- 6 Conclusions et perspectives


Processus simulé

Processus simulé :



Processus simulé

Processus simulé :




Modèle :

$$\begin{cases} X_{k+1} = \begin{bmatrix} 1.0000 & 0 & 0 \\ 0 & 0.9578 & 0 \\ 0 & 0 & 0.6756 \end{bmatrix} X_k + \begin{bmatrix} -0.0622 \\ 0.0621 \\ 0.0598 \end{bmatrix} u_k \\ x_k = \begin{bmatrix} -22.3632 & -24.6381 & 2.3784 \end{bmatrix} X_k \end{cases}$$

Processus simulé

Processus simulé :



Modèle :


$$\begin{cases} X_{k+1} = \begin{bmatrix} 1.0000 & 0 & 0 \\ 0 & 0.9578 & 0 \\ 0 & 0 & 0.6756 \end{bmatrix} X_k + \begin{bmatrix} -0.0622 \\ 0.0621 \\ 0.0598 \end{bmatrix} u_k \\ x_k = \begin{bmatrix} -22.3632 & -24.6381 & 2.3784 \end{bmatrix} X_k \end{cases}$$

Fonction de coût immédiat :

$$r(x, u) = x^2 + 10u^2$$

Processus simulé

Processus simulé :



Modèle :

$$\begin{cases} X_{k+1} = \begin{bmatrix} 1.0000 & 0 & 0 \\ 0 & 0.9578 & 0 \\ 0 & 0 & 0.6756 \end{bmatrix} X_k + \begin{bmatrix} -0.0622 \\ 0.0621 \\ 0.0598 \end{bmatrix} u_k \\ x_k = \begin{bmatrix} -22.3632 & -24.6381 & 2.3784 \end{bmatrix} X_k \end{cases}$$

Fonction de coût immédiat :

$$r(x, u) = x^2 + 10u^2$$

A l'instant $k = 0$, l'objet est placé à 20 mm de l'origine sans vitesse initiale.
Un essai dure 300 pas de calculs (30 pas par seconde).

Commande linéaire quadratique

Correcteur optimal :

$$K^* = [-6.5520 \quad -4.1332 \quad 0.0218]$$

Commande linéaire quadratique

Correcteur optimal :

$$K^* = [-6.5520 \quad -4.1332 \quad 0.0218]$$

Fonction de valeur :

$$V^*(X_0) = 5.3135e3, \quad X_0 = [-0.8943 \quad 0.0000 \quad 0.0000]'$$


Commande linéaire quadratique

Correcteur optimal :


$$K^* = [-6.5520 \quad -4.1332 \quad 0.0218]$$

Fonction de valeur :

$$V^*(X_0) = 5.3135e3, \quad X_0 = [-0.8943 \quad 0.0000 \quad 0.0000]'$$



(a) Position de l'objet en fonction du temps



(b) Commande en fonction du temps

FIGURE: Résultats de simulation avec le correcteur LQ.

Apprentissage *ex nihilo*

Le système étant simplement stable, nous pouvons choisir :

$$K_0 = [0 \quad 0 \quad 0]'$$

Apprentissage *ex nihilo*

Le système étant simplement stable, nous pouvons choisir :

$$K_0 = [0 \quad 0 \quad 0]'$$


- Signal d'exploration $e_k =$ bruit gaussien $\mathcal{N}(0, 5)$
- γ est fixé à 1 (l'horizon temporel est fini)
- Pour évaluer le critère $V(X_0)$, on utilise $e_k = 0$

Apprentissage *ex nihilo*


Le système étant simplement stable, nous pouvons choisir :

$$K_0 = [0 \quad 0 \quad 0]'$$

- Signal d'exploration $e_k = \text{bruit gaussien } \mathcal{N}(0, 5)$
- γ est fixé à 1 (l'horizon temporel est fini)
- Pour évaluer le critère $V(X_0)$, on utilise $e_k = 0$



(a) Critère $V(X_0)$ en fonction des itérations (en pointillés la valeur optimale du critère)





(b) Position de l'objet en fonction du temps

FIGURE: Résultats de simulation de LSPI initialisé avec une politique nulle.

Plan de la présentation


- 1 Commande linéaire quadratique
- 2 LSPI pour processus linéaires avec coût quadratique
- 3 Résultats de simulation
- 4 Surface de manipulation à coussin d'air actif
- 5 Résultats expérimentaux
- 6 Conclusions et perspectives

Surface de manipulation à coussin d'air actif



Surface de manipulation à coussin d'air actif

Dispositif expérimental :



Définition des commandes :

$u = -2$



$u = -1$



$u = 0$



$u = +1$



$u = +2$



Définition des commandes :






FIGURE: Position de l'objet en fonction du temps pour une commande constante $u = 2$.

Définition des commandes :



Identification paramétrique :

- Système d'ordre 2 + intégrateur
- Entrée U = commande u (ci-contre)
- Sortie Y = abscisse x de l'objet
- Echantillonnage = 30 Hz





FIGURE: Position de l'objet en fonction du temps pour une commande constante $u = 2$.

Définition des commandes :



Identification paramétrique :

- Système d'ordre 2 + intégrateur
- Entrée U = commande u (ci-contre)
- Sortie Y = abscisse x de l'objet
- Echantillonnage = 30 Hz

Modèle :

$$\begin{cases} X_{k+1} = \begin{bmatrix} 1.0000 & 0 & 0 \\ 0 & 0.9578 & 0 \\ 0 & 0 & 0.6756 \end{bmatrix} X_k + \begin{bmatrix} -0.0622 \\ 0.0621 \\ 0.0598 \end{bmatrix} u_k \\ x_k = \begin{bmatrix} -22.3632 & -24.6381 & 2.3784 \end{bmatrix} X_k \end{cases}$$





FIGURE: Position de l'objet en fonction du temps pour une commande constante $u = 2$.

Définition des commandes :



Identification paramétrique :

- Système d'ordre 2 + intégrateur
- Entrée U = commande u (ci-contre)
- Sortie Y = abscisse x de l'objet
- Echantillonnage = 30 Hz

Modèle :

$$\begin{cases} X_{k+1} = \begin{bmatrix} 1.0000 & 0 & 0 \\ 0 & 0.9578 & 0 \\ 0 & 0 & 0.6756 \end{bmatrix} X_k + \begin{bmatrix} -0.0622 \\ 0.0621 \\ 0.0598 \end{bmatrix} u_k \\ x_k = \begin{bmatrix} -22.3632 & -24.6381 & 2.3784 \end{bmatrix} X_k \end{cases}$$

Fonction de coût immédiat

$$r(x, u) = x^2 + 10u^2$$






FIGURE: Position de l'objet en fonction du temps pour une commande constante $u = 2$.

Reconstruction de l'état

Reconstruction de l'état




Reconstruction de l'état



Observateur de Luenberger :

$$\begin{cases} \hat{X}_{k+1} &= A\hat{X}_k + BU_k + L(Y_k - \hat{Y}_k) \\ \hat{Y}_k &= C\hat{X}_k \end{cases}$$

Reconstruction de l'état



Observateur de Luenberger :

$$\begin{cases} \hat{X}_{k+1} &= A\hat{X}_k + BU_k + L(Y_k - \hat{Y}_k) \\ \hat{Y}_k &= C\hat{X}_k \end{cases}$$

Coefficients de l'observateur choisis en simulation de façon à minimiser l'impact de l'observateur sur le critère $V(X_0)$.

Plan de la présentation

- 1 Commande linéaire quadratique
- 2 LSPI pour processus linéaires avec coût quadratique
- 3 Résultats de simulation
- 4 Surface de manipulation à coussin d'air actif
- 5 Résultats expérimentaux**
- 6 Conclusions et perspectives

Commande linéaire quadratique

Correcteur optimal (calculé à l'aide du modèle) :

$$K^* = [-6.5520 \quad -4.1332 \quad 0.0218]$$


Commande linéaire quadratique

Correcteur optimal (calculé à l'aide du modèle) :


$$K^* = [-6.5520 \quad -4.1332 \quad 0.0218]$$

Fonction de valeur théorique : $V^*(X_0) = 5.3135e3$

Fonction de valeur mesurée : $V(X_0) = 2.3917e4$



(a) Position de l'objet en fonction du temps



(b) Commande en fonction du temps

FIGURE: Résultats expérimentaux avec le correcteur LQ.

Apprentissage *ex nihilo*


Le système étant simplement stable, nous pouvons choisir :

$$K_0 = [0 \quad 0 \quad 0]'$$


Apprentissage *ex nihilo*

Le système étant simplement stable, nous pouvons choisir :

$$K_0 = [0 \quad 0 \quad 0]'$$



(a) Critère $V(X_0)$ en fonction des itérations (moyenne sur 6 essais, en pointillés la valeur du critère pour la commande LQ)



(b) Position de l'objet en fonction du temps

FIGURE: Résultats expérimentaux de LSPI initialisé avec une politique nulle.

Fonction de formatage

L'algorithme peut générer des commandes irréalisables :

$$U_k \leftarrow K_t X_k + e_k$$

Fonction de formatage

L'algorithme peut générer des commandes irréalisables :

$$U_k \leftarrow K_t X_k + e_k$$

Nous avons donc remplacé cette ligne par :

$$U_k \leftarrow f(K_t X_k + e_k)$$

f étant une fonction de formatage de la commande. f est spécifique au système.

Fonction de formatage

L'algorithme peut générer des commandes irréalisables :

$$U_k \leftarrow K_t X_k + e_k$$

Nous avons donc remplacé cette ligne par :

$$U_k \leftarrow f(K_t X_k + e_k)$$

f étant une fonction de formatage de la commande. f est spécifique au système.

Pour le système étudié ici, la fonction de formatage est définie par :

$$f(u) = \begin{cases} -5 & \text{si } u < -5 \\ 5 & \text{si } u > 5 \\ \text{Arrondi}(u) & \text{si } -5 \leq u \leq 5 \end{cases}$$

Apprentissage *ex nihilo* avec fonction de formatage


Le système étant simplement stable, nous pouvons choisir :

$$K_0 = [0 \quad 0 \quad 0]'$$


Apprentissage *ex nihilo* avec fonction de formatage

Le système étant simplement stable, nous pouvons choisir :

$$K_0 = [0 \quad 0 \quad 0]'$$



(a) Critère $V(X_0)$ en fonction des itérations (moyenne sur 7 essais, en pointillés la valeur du critère pour la commande LQ)



(b) Position de l'objet en fonction du temps

FIGURE: Résultats expérimentaux de LSPI initialisé avec une politique nulle.

Apprentissage *ex nihilo* avec fonction de formatage

Itération 0 avec exploration

Itération 8 sans exploration

Plan de la présentation

- 1 Commande linéaire quadratique
- 2 LSPI pour processus linéaires avec coût quadratique
- 3 Résultats de simulation
- 4 Surface de manipulation à coussin d'air actif
- 5 Résultats expérimentaux
- 6 Conclusions et perspectives

Conclusions et perspectives

Conclusions :

Conclusions :

- Méthode d'apprentissage de commande optimale sans modèle


Conclusions :

- Méthode d'apprentissage de commande optimale sans modèle
- Convergence garantie et rapide \Rightarrow commande adaptative

Conclusions et perspectives

Conclusions :


- Méthode d'apprentissage de commande optimale sans modèle
- Convergence garantie et rapide \Rightarrow commande adaptative
- Robuste aux non-linéarités du système réel et aux perturbations extérieures



Conclusions et perspectives

Conclusions :

- Méthode d'apprentissage de commande optimale sans modèle
- Convergence garantie et rapide \Rightarrow commande adaptative
- Robuste aux non-linéarités du système réel et aux perturbations extérieures




Problèmes et perspectives associées :

Conclusions et perspectives

Conclusions :

- Méthode d'apprentissage de commande optimale sans modèle
- Convergence garantie et rapide \Rightarrow commande adaptative
- Robuste aux non-linéarités du système réel et aux perturbations extérieures




Problèmes et perspectives associées :

- Nécessite un observateur si l'état n'est pas directement observé

Conclusions et perspectives

Conclusions :

- Méthode d'apprentissage de commande optimale sans modèle
- Convergence garantie et rapide \Rightarrow commande adaptative
- Robuste aux non-linéarités du système réel et aux perturbations extérieures




Problèmes et perspectives associées :

- Nécessite un observateur si l'état n'est pas directement observé
- Exploration plus intelligente \Rightarrow apprentissage actif

Conclusions et perspectives

Conclusions :

- Méthode d'apprentissage de commande optimale sans modèle
- Convergence garantie et rapide \Rightarrow commande adaptative
- Robuste aux non-linéarités du système réel et aux perturbations extérieures




Problèmes et perspectives associées :

- Nécessite un observateur si l'état n'est pas directement observé
- Exploration plus intelligente \Rightarrow apprentissage actif
- Améliorations techniques de la surface

Conclusions et perspectives

Conclusions :

- Méthode d'apprentissage de commande optimale sans modèle
- Convergence garantie et rapide \Rightarrow commande adaptative
- Robuste aux non-linéarités du système réel et aux perturbations extérieures



Problèmes et perspectives associées :

- Nécessite un observateur si l'état n'est pas directement observé
- Exploration plus intelligente \Rightarrow apprentissage actif
- Améliorations techniques de la surface
- Commande individuelle des jets d'air : *système à 115 entrées et 3 sorties (x, y, θ) !!!*

Merci !

Des questions ?