

# Stochastické iterativní aproximace dynamického programování (SIDP)

Miroslav Zima

FJFI ČVUT

1. září 2010

# Obsah

- 1 Úloha řízení za neurčitosti
- 2 Suboptimální přístup k řešení pomocí SIDP
- 3 Srovnání SIDP s jinými metodami

# System

- System, jeho odezva na vstup  $u_t$  při realizaci šumu  $v_{t+1}$

$$y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta), \quad t = 0, \dots, N-1, \quad (1)$$

kde  $l_t = (y_{t:0}, u_{t-1:0})$  a  $\theta$  je neznámý parametr. Známe  $l_0$ , rozdělení šumu  $v_t$  a apriorní informaci  $f(\theta|T_0)$ .

# System

- System, jeho odezva na vstup  $u_t$  při realizaci šumu  $v_{t+1}$

$$y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta), \quad t = 0, \dots, N - 1, \quad (1)$$

kde  $l_t = (y_{t:0}, u_{t-1:0})$  a  $\theta$  je neznámý parametr. Známe  $l_0$ , rozdělení šumu  $v_t$  a apriorní informaci  $f(\theta | T_0)$ .

- Bayesovské učení k získání aposteriorní hustoty  $f(\theta | T_{t+1})$

$$f(\theta | T_{t+1}) = \frac{f(y_{t+1} | \theta, l_t, u_t) f(\theta | T_t)}{\int f(y_{t+1} | \theta, l_t, u_t) f(\theta | T_t) d\theta}. \quad (2)$$

# System

- System, jeho odezva na vstup  $u_t$  při realizaci šumu  $v_{t+1}$

$$y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta), \quad t = 0, \dots, N-1, \quad (1)$$

kde  $l_t = (y_{t:0}, u_{t-1:0})$  a  $\theta$  je neznámý parametr. Známe  $l_0$ , rozdělení šumu  $v_t$  a apriorní informaci  $f(\theta|T_0)$ .

- Bayesovské učení k získání aposteriori hustoty  $f(\theta|T_{t+1})$

$$f(\theta|T_{t+1}) = \frac{f(y_{t+1}|\theta, l_t, u_t)f(\theta|T_t)}{\int f(y_{t+1}|\theta, l_t, u_t)f(\theta|T_t)d\theta}. \quad (2)$$

- Hyperstav  $H_t = (l_t, T_t)$  platí

$$H_{t+1} = f_t(H_t, u_t, y_{t+1}), \quad t = 0, \dots, N-1. \quad (3)$$

# Formulace úlohy

- Ztrátová funkce (určuje kvalitu řízení)

$$g(y_{1:N}, u_{0:N-1}) = \sum_{t=0}^{N-1} g_t(y_{t+1}, u_t). \quad (4)$$

# Formulace úlohy

- Ztrátová funkce (určuje kvalitu řízení)

$$g(y_{1:N}, u_{0:N-1}) = \sum_{t=0}^{N-1} g_t(y_{t+1}, u_t). \quad (4)$$

- Řídící strategie

$$\mu_t(H_t) = u_t, \quad t = 0, 1, \dots, N-1. \quad (5)$$

# Formulace úlohy

- Ztrátová funkce (určuje kvalitu řízení)

$$g(y_{1:N}, u_{0:N-1}) = \sum_{t=0}^{N-1} g_t(y_{t+1}, u_t). \quad (4)$$

- Řídící strategie

$$\mu_t(H_t) = u_t, \quad t = 0, 1, \dots, N-1. \quad (5)$$

- Hledáme  $\pi = \mu_{0:N-1}$  minimalizující očekávanou ztrátu

$$J_\pi = \mathbb{E}_{\theta_0, v_{0:N-1}} \left\{ \sum_{t=0}^{N-1} g_t(y_{t+1}, \mu_t(H_t)) \right\}, \quad (6)$$



# Použití dynamického programování při řešení úlohy řízení s aditivní ztrátou

- Princip optimality  $\implies$  postupně od konce řídicího horizontu minimalizujeme dílčí očekávané ztráty

$$J_N(H_N) = 0, \quad (7)$$

$$J_t(H_t) = \min_{u_t \in U_t} \mathbb{E}_{y_{t+1}} \{g_t(y_{t+1}, u_t) + J_{t+1}(H_{t+1}) | H_t, u_t\}, \quad (8)$$

podmínky:  $y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta)$  a  $H_{t+1} = f_t(H_t, u_t, y_{t+1})$

# Použití dynamického programování při řešení úlohy řízení s aditivní ztrátou

- Princip optimality  $\implies$  postupně od konce řídicího horizontu minimalizujeme dílčí očekávané ztráty

$$J_N(H_N) = 0, \quad (7)$$

$$J_t(H_t) = \min_{u_t \in U_t} \mathbb{E}_{y_{t+1}} \{g_t(y_{t+1}, u_t) + J_{t+1}(H_{t+1}) | H_t, u_t\}, \quad (8)$$

podmínky:  $y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta)$  a  $H_{t+1} = f_t(H_t, u_t, y_{t+1})$

- Problémy v řešení

# Použití dynamického programování při řešení úlohy řízení s aditivní ztrátou

- Princip optimality  $\implies$  postupně od konce řídicího horizontu minimalizujeme dílčí očekávané ztráty

$$J_N(H_N) = 0, \quad (7)$$

$$J_t(H_t) = \min_{u_t \in U_t} \mathbb{E}_{y_{t+1}} \{g_t(y_{t+1}, u_t) + J_{t+1}(H_{t+1}) | H_t, u_t\}, \quad (8)$$

podmínky:  $y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta)$  a  $H_{t+1} = f_t(H_t, u_t, y_{t+1})$

- Problémy v řešení
  - výpočet střední hodnoty

# Použití dynamického programování při řešení úlohy řízení s aditivní ztrátou

- Princip optimality  $\implies$  postupně od konce řídicího horizontu minimalizujeme dílčí očekávané ztráty

$$J_N(H_N) = 0, \quad (7)$$

$$J_t(H_t) = \min_{u_t \in U_t} \mathbb{E}_{y_{t+1}} \{g_t(y_{t+1}, u_t) + J_{t+1}(H_{t+1}) | H_t, u_t\}, \quad (8)$$

podmínky:  $y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta)$  a  $H_{t+1} = f_t(H_t, u_t, y_{t+1})$

- Problémy v řešení
  - výpočet střední hodnoty
  - minimalizace vzhledem k  $u_t$

# Použití dynamického programování při řešení úlohy řízení s aditivní ztrátou

- Princip optimality  $\implies$  postupně od konce řídicího horizontu minimalizujeme dílčí očekávané ztráty

$$J_N(H_N) = 0, \quad (7)$$

$$J_t(H_t) = \min_{u_t \in U_t} \mathbb{E}_{y_{t+1}} \{g_t(y_{t+1}, u_t) + J_{t+1}(H_{t+1}) | H_t, u_t\}, \quad (8)$$

podmínky:  $y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta)$  a  $H_{t+1} = f_t(H_t, u_t, y_{t+1})$

- Problémy v řešení
  - výpočet střední hodnoty
  - minimalizace vzhledem k  $u_t$
  - Analytické řešení obvykle nejde nalézt  $\implies$  aproximační metody.

# SIDP

- Iterativní dynamické programování

# SIDP

- Iterativní dynamické programování
  - Namísto přímého nalezení  $\pi$  konstruujeme  $\pi_n \rightarrow \pi$

# SIDP

- Iterativní dynamické programování
  - Namísto přímého nalezení  $\pi$  konstruujeme  $\pi_n \rightarrow \pi$
- Stochastická aproximace = Metoda Monte Carlo



# SIDP

- Iterativní dynamické programování
  - Namísto přímého nalezení  $\pi$  konstruujeme  $\pi_n \rightarrow \pi$
- Stochastická aproximace = Metoda Monte Carlo
  - Očekávaná ztráta se aproximuje průměrem z  $n$  realizací ztráty

# SIDP

- Iterativní dynamické programování
  - Namísto přímého nalezení  $\pi$  konstruujeme  $\pi_n \rightarrow \pi$
- Stochastická aproximace = Metoda Monte Carlo
  - Očekávaná ztráta se aproximuje průměrem z  $n$  realizací ztráty
  - Generování realizace ztráty pro konkrétní bod  $H_t$

# SIDP

- Iterativní dynamické programování
  - Namísto přímého nalezení  $\pi$  konstruujeme  $\pi_n \rightarrow \pi$
- Stochastická aproximace = Metoda Monte Carlo
  - Očekávaná ztráta se aproximuje průměrem z  $n$  realizací ztráty
  - Generování realizace ztráty pro konkrétní bod  $H_t$ 
    - 1 generujeme  $v_t$  a  $\theta$  (použijeme  $f(\theta, T_t)$ )

# SIDP

- Iterativní dynamické programování
  - Namísto přímého nalezení  $\pi$  konstruujeme  $\pi_n \rightarrow \pi$
- Stochastická aproximace = Metoda Monte Carlo
  - Očekávaná ztráta se aproximuje průměrem z  $n$  realizací ztráty
  - Generování realizace ztráty pro konkrétní bod  $H_t$ 
    - 1 generujeme  $v_t$  a  $\theta$  (použijeme  $f(\theta, T_t)$ )
    - 2 aplikací řídicího zásahu získáme  $y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta)$

# SIDP

- Iterativní dynamické programování
  - Namísto přímého nalezení  $\pi$  konstruujeme  $\pi_n \rightarrow \pi$
- Stochastická aproximace = Metoda Monte Carlo
  - Očekávaná ztráta se aproximuje průměrem z  $n$  realizací ztráty
  - Generování realizace ztráty pro konkrétní bod  $H_t$ 
    - 1 generujeme  $v_t$  a  $\theta$  (použijeme  $f(\theta, T_t)$ )
    - 2 aplikací řídicího zásahu získáme  $y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta)$
    - 3 k dosavadní ztrátě přičteme  $g_t(y_{t+1}, u_t)$

# SIDP

- Iterativní dynamické programování
  - Namísto přímého nalezení  $\pi$  konstruujeme  $\pi_n \rightarrow \pi$
- Stochastická aproximace = Metoda Monte Carlo
  - Očekávaná ztráta se aproximuje průměrem z  $n$  realizací ztráty
  - Generování realizace ztráty pro konkrétní bod  $H_t$ 
    - 1 generujeme  $v_t$  a  $\theta$  (použijeme  $f(\theta, T_t)$ )
    - 2 aplikací řídicího zásahu získáme  $y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta)$
    - 3 k dosavadní ztrátě přičteme  $g_t(y_{t+1}, u_t)$
    - 4 dopočítáme  $H_{t+1} = f_t(H_t, u_t, y_{t+1})$

# SIDP

- Iterativní dynamické programování
  - Namísto přímého nalezení  $\pi$  konstruujeme  $\pi_n \rightarrow \pi$
- Stochastická aproximace = Metoda Monte Carlo
  - Očekávaná ztráta se aproximuje průměrem z  $n$  realizací ztráty
  - Generování realizace ztráty pro konkrétní bod  $H_t$ 
    - 1 generujeme  $v_t$  a  $\theta$  (použijeme  $f(\theta, T_t)$ )
    - 2 aplikací řídicího zásahu získáme  $y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta)$
    - 3 k dosavadní ztrátě přičteme  $g_t(y_{t+1}, u_t)$
    - 4 dopočítáme  $H_{t+1} = f_t(H_t, u_t, y_{t+1})$
    - 5 interpolací/extrapolací  $\pi_n$  určíme optimální zásah pro  $H_{t+1}$

# SIDP

- Iterativní dynamické programování
  - Namísto přímého nalezení  $\pi$  konstruujeme  $\pi_n \rightarrow \pi$
- Stochastická aproximace = Metoda Monte Carlo
  - Očekávaná ztráta se aproximuje průměrem z  $n$  realizací ztráty
  - Generování realizace ztráty pro konkrétní bod  $H_t$ 
    - 1 generujeme  $v_t$  a  $\theta$  (použijeme  $f(\theta, T_t)$ )
    - 2 aplikací řídicího zásahu získáme  $y_{t+1} = h_t(l_t, u_t, v_{t+1}, \theta)$
    - 3 k dosavadní ztrátě přičteme  $g_t(y_{t+1}, u_t)$
    - 4 dopočítáme  $H_{t+1} = f_t(H_t, u_t, y_{t+1})$
    - 5 interpolací/extrapolací  $\pi_n$  určíme optimální zásah pro  $H_{t+1}$
    - 6 pokud  $t < N - 1 \implies 1$ .



# Integrátor s neznámým ziskem

- Výstup systému

$$y_{t+1} = y_t + \theta u_t + v_{t+1}, \quad t = 0, \dots, N-1, \quad (9)$$

kde  $\theta \neq 0$  neznáme, šum  $v_{t+1} \sim N(0, 0.1)$  a  $y_0 = 1$ .

# Integrátor s neznámým ziskem

- Výstup systému

$$y_{t+1} = y_t + \theta u_t + v_{t+1}, \quad t = 0, \dots, N-1, \quad (9)$$

kde  $\theta \neq 0$  neznáme, šum  $v_{t+1} \sim N(0, 0.1)$  a  $y_0 = 1$ .

- Ztrátová funkce je kvadratická

$$g(y_{1:N}, u_{0:N-1}) = \sum_{t=0}^{N-1} y_{t+1}^2. \quad (10)$$

# Integrátor s neznámým ziskem

- Výstup systému

$$y_{t+1} = y_t + \theta u_t + v_{t+1}, \quad t = 0, \dots, N-1, \quad (9)$$

kde  $\theta \neq 0$  neznáme, šum  $v_{t+1} \sim N(0, 0.1)$  a  $y_0 = 1$ .

- Ztrátová funkce je kvadratická

$$g(y_{1:N}, u_{0:N-1}) = \sum_{t=0}^{N-1} y_{t+1}^2. \quad (10)$$

- Předpoklad  $\text{Cov}(v_{t+1}, \theta_t) = 0$  a  $T_0 = (\hat{\theta}_0, P_0) \implies$  lze získat konkrétní tvar rce  $H_{t+1} = f_t(H_t, u_t, y_{t+1})$ .

# Integrátor s neznámým ziskem

- Výstup systému

$$y_{t+1} = y_t + \theta u_t + v_{t+1}, \quad t = 0, \dots, N-1, \quad (9)$$

kde  $\theta \neq 0$  neznáme, šum  $v_{t+1} \sim N(0, 0.1)$  a  $y_0 = 1$ .

- Ztrátová funkce je kvadratická

$$g(y_{1:N}, u_{0:N-1}) = \sum_{t=0}^{N-1} y_{t+1}^2. \quad (10)$$

- Předpoklad  $\text{Cov}(v_{t+1}, \theta_t) = 0$  a  $T_0 = (\hat{\theta}_0, P_0) \implies$  lze získat konkrétní tvar rce  $H_{t+1} = f_t(H_t, u_t, y_{t+1})$ .
- Hyperstav systému  $H_t$  tvoří vektor  $(y_t, \hat{\theta}_t, P_t)$  (lze ho vhodnou transformací redukovat na  $\text{dim}=2$ ).

# Konkurenční metody

- Certainty equivalence (CEC)

# Konkurenční metody

- Certainty equivalence (CEC)
  - pro návrh řídicího zásahu je brán bodový odhad  $\hat{\theta}$

# Konkurenční metody

- Certainty equivalence (CEC)
  - pro návrh řídicího zásahu je brán bodový odhad  $\hat{\theta}$
  - je možné získat analytické vyjádření pro optimální řídicí zásah

# Konkurenční metody

- Certainty equivalence (CEC)
  - pro návrh řídicího zásahu je brán bodový odhad  $\hat{\theta}$
  - je možné získat analytické vyjádření pro optimální řídicí zásah
- Cautious control (CC)



# Konkurenční metody

- Certainty equivalence (CEC)
  - pro návrh řídicího zásahu je brán bodový odhad  $\hat{\theta}$
  - je možné získat analytické vyjádření pro optimální řídicí zásah
- Cautious control (CC)
  - hledá se optimální řízení na horizontu délky  $N = 1$

# Konkurenční metody

- Certainty equivalence (CEC)
  - pro návrh řídicího zásahu je brán bodový odhad  $\hat{\theta}$
  - je možné získat analytické vyjádření pro optimální řídicí zásah
- Cautious control (CC)
  - hledá se optimální řízení na horizontu délky  $N = 1$
  - je možné získat analytické vyjádření pro optimální řídicí zásah

# Konkurenční metody

- Certainty equivalence (CEC)
  - pro návrh řídicího zásahu je brán bodový odhad  $\hat{\theta}$
  - je možné získat analytické vyjádření pro optimální řídicí zásah
- Cautious control (CC)
  - hledá se optimální řízení na horizontu délky  $N = 1$
  - je možné získat analytické vyjádření pro optimální řídicí zásah
- Klasický numerický přístup k dynamickému programování (DP)

# Konkurenční metody


- Certainty equivalence (CEC)
  - pro návrh řídicího zásahu je brán bodový odhad  $\hat{\theta}$
  - je možné získat analytické vyjádření pro optimální řídicí zásah
- Cautious control (CC)
  - hledá se optimální řízení na horizontu délky  $N = 1$
  - je možné získat analytické vyjádření pro optimální řídicí zásah
- Klasický numerický přístup k dynamickému programování (DP)
  - Pro výpočet střední hodnoty je použita Simpsonova metoda

# Konkurenční metody

- Certainty equivalence (CEC)
  - pro návrh řídicího zásahu je brán bodový odhad  $\hat{\theta}$
  - je možné získat analytické vyjádření pro optimální řídicí zásah
- Cautious control (CC)
  - hledá se optimální řízení na horizontu délky  $N = 1$
  - je možné získat analytické vyjádření pro optimální řídicí zásah
- Klasický numerický přístup k dynamickému programování (DP)
  - Pro výpočet střední hodnoty je použita Simpsonova metoda
  - K minimalizaci ztráty slouží jednoduchá interpolační metoda.

# Kvantitativní srovnání



- Dosažená ztráta - průměr přes 1000 simulací
- $\theta$  = první nenulová realizace veličiny s rozdělením  $N(\hat{\theta}_0, P_0)$



- Metoda CEC neposkytuje použitelné řízení
- Metoda CC funguje pouze při  $\hat{\theta}_0 \neq 0$ . Tehdy dosahuje nejnižší ztráty.
- SIDP a DP dobře řídí vždy. Při lepší počáteční identifikaci má SIDP horší výsledky (diskretizace).

# Kvalitativní srovnání SIDP a DP


- Četnost konkrétních realizací ztráty - 1000 simulací.



- SIDP se vyhýbá výrazně špatnému řízení ( $> 10$ )
- DP častěji nabývá nižší celkové ztráty ( $< 1$ )
- SIDP navrhuje opatrnější zásahy  $\implies$  pomalejší identifikace  $\theta$

# Test robustnosti

- Dosažená ztráta vzhledem k apriorní informaci - 1000 simulací.
- $\theta =$  první nenulová realizace náhodné veličiny s rozdělením  $N(1, 10)$ , různá apriorní informace na  $\hat{\theta}_0$ , rozptyl  $P_0 = 10$ .



- Vyšší odolnost metody SIDP vůči špatné apriorní informaci
- SIDP poskytuje dobré řízení i pro  $\hat{\theta}_0 = -10$ , přitom skutečné  $\theta = 1$



# Závěr

- Předměty BP

# Závěr

- Předměty BP
  - Úloha řízení za neurčitosti - teoretické řešení pomocí dynamického programování

# Závěr

- Předměty BP
  - Úloha řízení za neurčitosti - teoretické řešení pomocí dynamického programování
  - Algoritmus SIDP jako možná aproximační metoda

# Závěr

- Předměty BP
  - Úloha řízení za neurčitosti - teoretické řešení pomocí dynamického programování
  - Algoritmus SIDP jako možná aproximační metoda
  - Implementace SIDP pro řízení jednoduchého systému, porovnání s dalšími metodami

# Závěr

- Předměty BP
  - Úloha řízení za neurčitosti - teoretické řešení pomocí dynamického programování
  - Algoritmus SIDP jako možná aproximační metoda
  - Implementace SIDP pro řízení jednoduchého systému, porovnání s dalšími metodami
- Možná další práce

# Závěr

- Předměty BP
  - Úloha řízení za neurčitosti - teoretické řešení pomocí dynamického programování
  - Algoritmus SIDP jako možná aproximační metoda
  - Implementace SIDP pro řízení jednoduchého systému, porovnání s dalšími metodami
- Možná další práce
  - Navrhnout algoritmus, který by byl méně výpočetně náročný a stále poskytoval dobré řízení

# Závěr

- Předměty BP
  - Úloha řízení za neurčitosti - teoretické řešení pomocí dynamického programování
  - Algoritmus SIDP jako možná aproximační metoda
  - Implementace SIDP pro řízení jednoduchého systému, porovnání s dalšími metodami
- Možná další práce
  - Navrhnout algoritmus, který by byl méně výpočetně náročný a stále poskytoval dobré řízení
  - např.  $u_t = u_t^{(1)} + u_t^{(2)}$ , kde  $u_t^{(1)}$  minimalizuje ztrátu (například CC) a  $u_t^{(2)}$  budí systém za účelem jeho lepší identifikace (použití SIDP).

Děkuji za pozornost