

Možnosti využití dynamického programování v bezsenzorovém řízení

Václav Šmíd

21. února 2011

Obsah

Dynamické programování

Řízení elektrických pohonů

Vektorové řízení pohonu

Neznámé parametry

Opatrné LQ řízení

Experimenty

Motivace

- ▶ GACR projekt "Regulace a identifikace parametrů střídavých elektrických pohonů v kritických provozních stavech"
 - FEL ZČU** nejlepší existující používané metody pro řízení pohonů (PID+expertní znalost)
 - ÚTIA** pokročilé techniky řízení (Bayesovské odhadování, dynamické programování)
- ▶ Cílem je zlepšit stávající techniky ve dvou směrech:
 1. shora dolů - aplikovat pokročilé věci na pohony a získat zpětnou vazbu pro vylepšování,
 2. zdola nahoru - navrhnout pomocí pokročilých technik jednoduché vylepšení stávajících.
- ▶ Cíl přednášky je
 1. představit současný stav,
 2. vytipovat směr vývoje.

Dynamické programování

Máme systém popsaný diferenciální (diferenční) rovnicí

$$x_{t+1} = f(x_t, u_t),$$

a chceme dosáhnout požadovaného chování.

Řízení je optimální pokud minimalizuje ztrátu:

$$L = \sum_{t=1}^T l_t(x_t, u_t).$$

Dynamické programování

Máme systém popsaný diferenciální (diferenční) rovnicí

$$x_{t+1} = f(x_t, u_t),$$

a chceme dosáhnout požadovaného chování.

Řízení je optimální pokud minimalizuje ztrátu:

$$L = \sum_{t=1}^T l_t(x_t, u_t).$$

Nutná a postačující podmínka optima, (Bellman, 1957)¹:

$$V(x_\tau) = \min_{u(x_t)} \{l_t(x_\tau, u_\tau) + V(f(x_\tau, u_\tau))\},$$

$$u(x_\tau) = \arg \min_{u(x_\tau)} \{l_t(x_\tau, u_\tau) + V(f(x_\tau, u_\tau))\}.$$

Rekurze $\tau = t+h, \dots, t$, $V(x_{t+h}) = 0$.

¹Dynamic Programming

Vlastnosti dynamického programování

- ▶ Analytické řešení pro
 - ▶ **LQ** lineární systém s kvadratickou ztrátou, (Peterka and Bláha, 1966)²
 - ▶ konečný počet stavů systému a řídících zásahů,
- ▶ Četná numerická řešení pro nízké dimenze (curse of dimensionality)
- ▶ Snadné rozšíření na **stochastické** problémy
 - ▶ **LQG** - LQ s Gausovskou distribucí neurčitosti,
 - ▶ **MDP** - Markov Decision Process
 - ▶ numerická řešení jsou **snáze** řešitelná (Belbas, personal communication).
- ▶ Alternativní formulace,
 - ▶ neurodynamic control (Bertsekas, 2001)³,
 - ▶ reinforcement learning (Sutton and Barto, 1998)⁴
 - ▶ fully probabilistic approach (Kárný, 1995)⁵

²Synthesis of regulation loops according to quadratic criterion

³Dynamic Programming and Optimal Control

⁴Reinforcement Learning: An Introduction

⁵Towards fully probabilistic control design

Dynamické programování v řízení pohonů

- ▶ DP se prakticky nepoužívá (začíná se s LQ řízením)
- ▶ Hlavní směry
 1. **vektorové řízení:** Řízení PID regulátory v d-q souřednicích.
 2. **přímé řízení momentu:** výběr ze 4 možných akcí.
- ▶ Souvislosti:
 - ▶ vektorové řízení a PID \iff LQG a varianty
 - ▶ přímé řízení momentu \iff diskrétní (Markovské) modely

Vektorové řízení pohonu

Model

$$\begin{aligned}\frac{di_{s\alpha}}{dt} &= -\frac{R_s}{L_s} i_{s\alpha} + \frac{\Psi_{PM}}{L_s} \omega_{me} \sin \vartheta + \frac{u_{s\alpha}}{L_s}, \\ \frac{di_{s\beta}}{dt} &= -\frac{R_s}{L_s} i_{s\beta} - \frac{\Psi_{PM}}{L_s} \omega_{me} \cos \vartheta + \frac{u_{s\beta}}{L_s}, \\ \frac{d\omega}{dt} &= \frac{k_p p_p^2 \Psi_{pm}}{J} (i_{s\beta} \cos \vartheta - i_{s\alpha} \sin \vartheta) - \frac{B}{J} \omega - \frac{p_p}{J} T_L, \\ \frac{d\vartheta}{dt} &= \omega.\end{aligned}\tag{1}$$

Ztráta

$$L = \sum_{t=1}^T (\omega - \bar{\omega})^2$$

Složité řízení, s rostoucím ω hrají $\sin()$ a $\cos()$ významnější úlohu.

$d-q$ souřadnice

Po transformaci

$$\begin{bmatrix} i_{sd} \\ i_{sq} \end{bmatrix} = \begin{bmatrix} \cos \vartheta & \sin \vartheta \\ -\sin \vartheta & \cos \vartheta \end{bmatrix} \begin{bmatrix} i_{s\alpha} \\ i_{s\beta} \end{bmatrix}$$

získáme stavový prostor,

$$x_t = [i_{sd}, i_{sq}, \omega, \vartheta]$$

ve kterém lze konstantní žádanou hodnotu ω převést na **konstantní žádané hodnoty** $\bar{i}_{sd}, \bar{i}_{sq}$.

Problém se redukuje na

$$x_t = A(\omega)x_{t-1} + Bu_t.$$

se zanedbáním časového vývoje ω dostáváme lineární systém (LQG).


LQ řízení: příklad

Jednorozměrný systém

$$x_{t+1} = bx_t + cu_t$$

stabilní ($b < 1$).

- ▶ počáteční podmínka: $x_t = 0$
- ▶ požadovaná hodnota: $\bar{x}_t = 1$ dosažená vstupem s malou energií,




LQ řízení: příklad

Jednorozměrný systém

$$x_{t+1} = bx_t + cu_t$$

stabilní ($b < 1$).

- ▶ počáteční podmínka: $x_t = 0$
- ▶ požadovaná hodnota: $\bar{x}_t = 1$ dosažená vstupem s malou energií,



Kritérium:

$$L = \sum_{t=1}^T (x_t - \bar{x}_t)^2 + \beta u_t^2$$

kde β je zvolená konstanta.

LQ řízení: odvození

Čas $t = t + h$

$$u_{t+h} = \arg \min_{u(x_{t+h})} ((x_{t+h} - \bar{x}_{t+h})^2 + \beta u_{t+h}^2)$$

LQ řízení: odvození

Čas $t = t + h$

$$u_{t+h} = \arg \min_{u(x_{t+h})} ((x_{t+h} - \bar{x}_{t+h})^2 + \beta u_{t+h}^2) = 0$$

LQ řízení: odvození

Čas $t = t + h$

$$u_{t+h} = \arg \min_{u(x_{t+h})} ((x_{t+h} - \bar{x}_{t+h})^2 + \beta u_{t+h}^2) = 0$$

$$V(x_{t+h}) = (x_{t+h} - \bar{x}_{t+h})^2$$

LQ řízení: odvození

Čas $t = t + h$

$$u_{t+h} = \arg \min_{u(x_{t+h})} ((x_{t+h} - \bar{x}_{t+h})^2 + \beta u_{t+h}^2) = 0$$

$$V(x_{t+h}) = (x_{t+h} - \bar{x}_{t+h})^2 = [x_{t+h}, 1] \begin{bmatrix} 1 & -\bar{x}_{t+h} \\ -\bar{x}_{t+h} & \bar{x}_{t+h}^2 \end{bmatrix} \begin{bmatrix} x_{t+h} \\ 1 \end{bmatrix}$$

LQ řízení: odvození

Čas $t = t + h$

$$u_{t+h} = \arg \min_{u(x_{t+h})} ((x_{t+h} - \bar{x}_{t+h})^2 + \beta u_{t+h}^2) = 0$$

$$V(x_{t+h}) = (x_{t+h} - \bar{x}_{t+h})^2 = [x_{t+h}, 1] \begin{bmatrix} 1 & -\bar{x}_{t+h} \\ -\bar{x}_{t+h} & \bar{x}_{t+h}^2 \end{bmatrix} \begin{bmatrix} x_{t+h} \\ 1 \end{bmatrix}$$

Čas $t = t + h - 1$

$$u_{t+h-1} = \arg \min_{u(x_{t+h-1})} ((x_{t+h-1} - \bar{x}_{t+h-1})^2 + \beta u_{t+h-1}^2 + V(bx_{t+h-1} + cu_t))$$

LQ řízení: odvození

Čas $t = t + h$

$$u_{t+h} = \arg \min_{u(x_{t+h})} ((x_{t+h} - \bar{x}_{t+h})^2 + \beta u_{t+h}^2) = 0$$

$$V(x_{t+h}) = (x_{t+h} - \bar{x}_{t+h})^2 = [x_{t+h}, 1] \begin{bmatrix} 1 & -\bar{x}_{t+h} \\ -\bar{x}_{t+h} & \bar{x}_{t+h}^2 \end{bmatrix} \begin{bmatrix} x_{t+h} \\ 1 \end{bmatrix}$$

Čas $t = t + h - 1$



$$u_{t+h-1} = \arg \min_{u(x_{t+h-1})} ((x_{t+h-1} - \bar{x}_{t+h-1})^2 + \beta u_{t+h-1}^2 + V(bx_{t+h-1} + cu_t))$$
$$\dots = -l_1 x_{t+h-1} - l_2,$$

$$V(x_{t+h-1}) = [x_{t+h-1}, 1] \Psi \begin{bmatrix} x_{t+h-1} \\ 1 \end{bmatrix}.$$

Výsledkem je PK regulátor s proměnnými koeficienty.

LQ řízení: simulace

PK regulace jsou ustálené hodnoty LQ.



LQ s neznámými parametry

Jednorozměrný systém

$$x_{t+1} = x_t + \textcolor{red}{c} u_t + \sigma_e e_t.$$

Neznámé c. Kritérium:

$$L = \sum_{t=1}^T (x_t - \bar{x}_t)^2 + \beta u_t^2$$

Bellmanova rovnice je nyní:

$$V(x_\tau) = \min_{u(x_\tau)} \mathbf{E}_c \{ I(x_\tau, u_\tau) + V(f(x_\tau, u_\tau)) \},$$

$$u(x_\tau) = \arg \min_{u(x_\tau)} \mathbf{E}_c \{ I(x_\tau, u_\tau) + V(f(x_\tau, u_\tau)) \}.$$

kde $\mathbf{E}_c[]$ je očekávaná hodnota pro neurčitou hodnotu c daná $p(c|x_t, u(x_t))$.

Odhad parametru c

Předpokládejme, že počáteční odhad c je $p(c) = \mathcal{N}(c_0, \sigma_0)$. Pak vývoj odhadu parametru je:

$$\begin{aligned} p(c|x_{1:t+1}) &= \mathcal{N}(\hat{c}_{t+1}, \sigma_{t+1}), \\ \hat{c}_{t+1} &= \hat{c}_t + \frac{u_t \sigma_t}{u_t^2 \sigma_t + \sigma_e} (x_{t+1} - x_t - \hat{c}_t u_t), \\ \sigma_{t+1} &= \left(1 - \frac{u_t^2 \sigma_t}{u_t^2 \sigma_t + \sigma_e}\right) \sigma_t. \end{aligned}$$

Je možné interpretovat jako 3rozměrný systém se stavem $H_t = [x_t, \hat{c}_t, \sigma_t]$ a očekávanou ztrátou

$$E((x_t - \bar{x}_t)^2 + \beta u_t^2) = (x_{t-1} + \hat{c}_t u_t - \bar{x}_t)^2 + (\beta + \sigma_t^2) u_t^2.$$

Analytické řešení neexistuje. Dobrý cvičný příklad, integrátor s neznámým ziskem (Åström and Helmersson, 1986)⁶

⁶Dual control of an integrator with unknown gain

Integrátor s neznámým ziskem

Simuluje bezsensorové řízení v nulových otáčkách:

- ▶ c_t může být jak kladné tak záporné se stejnou pravděpodobností,
- ▶ c_t může být 0 - brzda,
- ▶ počáteční neurčitost je veliká (v ořezaných gausovkách dokonce roste),
- ▶ lze rozšířit na časově proměnné c_t - simuluje průchody nulou.

⁷Dual control of an integrator with unknown gain

⁸Stochastic Iterative dynamic programming: a Monte Carlo approach to dual control

⁹Iterative local dynamic programming

Integrátor s neznámým ziskem

Simuluje bezsensorové řízení v nulových otáčkách:

- ▶ c_t může být jak kladné tak záporné se stejnou pravděpodobností,
- ▶ c_t může být 0 - brzda,
- ▶ počáteční neurčitost je veliká (v ořezaných gausovkách dokonce roste),
- ▶ lze rozšířit na časově proměnné c_t - simuluje průchody nulou.

Existující řešení:

- ▶ Numerické na gridu (Åström and Helmersson, 1986)⁷,
- ▶ Monte Carlo (Thompson and Cluet, 2005)⁸, ověřoval M. Zima,
- ▶ Pomocí lokální LQ aproximace (Todorov and Tassa, 2009)⁹, ověřoval M. Vahala,



⁷Dual control of an integrator with unknown gain

⁸Stochastic Iterative dynamic programming: a Monte Carlo approach to dual control

⁹Iterative local dynamic programming

Opatrné LQ řízení


Výsledky pro Monte Carlo řešení metodou SIDP, (M. Zima, 2010)



Opatrné řízení:

- ▶ stejné jako standardní LQ pro penalizaci energie $(\beta + \sigma_t)u_t^2$ s konstatním σ_t
- ▶ není duální. Dualita je významná pouze pro $\hat{c}_0 = 0$.

Certainty equivalence: proměnné c



Dual control

Optimální řízení může být aproximativně rozděleno na dvě složky:

$$u_t = u_{\text{opatrné}}(x_t) + u_{\text{budící}}(x_t).$$

kde:

opatrné řízení je optimální 1-krokové řízení.

budící řízení udržuje systém (pokud možno) pozorovatelný.

Obecně je těžké najít kompromis (Filatov and Unbehauen, 2000)¹⁰, (Simpkins, Callafon, and Todorov, 2008)¹¹. Známé "triky" (Peterka, Böhm, Halousková, Kárný, and Maršík, 1982)¹².

Můžeme zkusit náhodný šum:


$$u_{\text{budící}}(x_t) = \mathcal{N}(0, \sigma_{\text{budící}}).$$

¹⁰Survey of adaptive dual control methods

¹¹Optimal trade-off between exploration and exploitation

¹²Algorithms for microprocessor-based control of technologic processes

Duální řízení s konstantním buzením



Plně pravděpodobnostní varianta LQ

LQ je speciálním případem FPD


$$\begin{aligned} {}^1f(u_t) &= \mathcal{N}(0, \beta^{-1}) \\ {}^1f(x_t) &= \mathcal{N}(0, \sigma_e) \end{aligned}$$

$${}^0f(u_t|x_t) = \mathcal{N}(u_{LQ}(x_t), \sigma_{FPD,t}).$$


kde LQ vznikne zanedbáním $\sigma_{FPD,t}$.

Co když $\sigma_{FPD,t}$ použijeme?

Plně pravděpodobnostní varianta LQ




Plně pravděpodobnostní varianta LQ II



Druhý pohled

Test s šumem v pozorování, σ_e :



Ztráty:

CE	CC	FPD
12.64	12.61	12.67

Limita pro neproměnné $c_t = c$, σ_{FPD} nekonverguje k 0.

Závěr

Současný stav:

- ▶ PI s naladěným konstantním ziskem + rozladěný Kalman filtr
- ▶ LQ varianty se zkoušejí jako nová (výpočetně náročná) technika

Vybrané směry:

- ▶ Opatrné řízení + správně naladěný Klaman filtr
- ▶ prozkoumání variant FPD (λ , jiná forma entropie?)
- ▶ diskrétní modelování

Literatura I

- Åström, KJ and A. Helmersson (1986). "Dual control of an integrator with unknown gain". In: *Computers & Mathematics with Applications* 12.6, pp. 653–662.
- Bellman, R. (1957). *Dynamic Programming*. New York: Princeton University Press.
- Bertsekas, D.P. (2001). *Dynamic Programming and Optimal Control*. 2nd edition. Nashua, US: Athena Scientific.
- Filatov, NM and H. Unbehauen (2000). "Survey of adaptive dual control methods". In: *IEE Proceedings-Control Theory and Applications* 147.1, pp. 118–128.
- Kárný, M. (1995). "Towards fully probabilistic control design". In: *IFAC Symposium ACASP'95*. Ed. by Cs. Bányász. Budapest, pp. 261–264.
- Peterka, V. and S. Bláha (1966). "Synthesis of regulation loops according to quadratic criterion". In: *Kybernetika* 1. In Czech, pp. 127–143.
- Peterka, V., J. Böhm, A. Halousková, M. Kárný, and J. Maršík (1982). *Algorithms for microprocessor-based control of technologic processes*. Tech. rep. in Czech. Prague, Plzen: UTIA CSAV, Skoda.

Literatura II

- Simpkins, A., R. de Callafon, and E. Todorov (2008). "Optimal trade-off between exploration and exploitation". In: *American Control Conference, 2008*, pp. 33–38.
- Sutton, R.S. and A.G. Barto (1998). *Reinforcement Learning: An Introduction*. Cambridge, MA: MIT Press.
- Thompson, A.M. and W.R. Cluet (2005). "Stochastic Iterative dynamic programming: a Monte Carlo approach to dual control". In: *Automatica* 41, pp. 767–778.
- Todorov, E. and Y. Tassa (2009). "Iterative local dynamic programming". In: *Proceedings of the 2nd IEEE Symposium on Adaptive Dynamic Programming and Reinforcement Learning*, pp. 90 –95.