

# Obsah

<b>Úvod</b>	<b>4</b>
<b>1 Úloha stochastického řízení</b>	<b>6</b>
1.1 Formulace základní úlohy stochastického řízení . . . . .	6
1.1.1 Systém a jeho popis . . . . .	6
1.1.2 Ztrátová funkce a optimální řízení . . . . .	6
1.2 Úloha stochastického řízení s aditivní ztrátou . . . . .	7
1.2.1 Aditivní ztrátová funkce . . . . .	7
1.2.2 Dynamické programování . . . . .	7
1.2.3 Použití dynamického programování při řešení úlohy stochastického řízení s aditivní ztrátou . . . . .	8
<b>2 Úloha stochastického řízení s neúplným pozorováním</b>	<b>9</b>
2.1 Formulace úlohy stochastického řízení s nepřesnými daty . . . . .	9
2.1.1 Výstup systému a infomační vektor . . . . .	9
2.1.2 Optimální řízení pro úlohu s nepřesnými daty . . . . .	9
2.1.3 Převod na úlohu s úplnými daty . . . . .	10
2.2 Řízení systému s neznámými parametry . . . . .	10
2.2.1 Systém s neznámými parametry, hyperstav . . . . .	11
2.2.2 Převod na úlohu s nepřesnými daty . . . . .	11
2.2.3 Kalmanův filtr . . . . .	12
<b>3 Suboptimální přístupy k úloze duálního řízení</b>	<b>14</b>
3.1 Duální řízení . . . . .	14
3.2 Certainty equivalent control . . . . .	15
3.3 Opatrné řízení . . . . .	16

3.4	Iterativní dynamické programování . . . . .	16
3.4.1	Diskretizace prostoru . . . . .	16
3.5	Metoda Monte Carlo . . . . .	17
3.5.1	Použití metody Monte Carlo k výpočtu očekávané ztráty . . .	17
3.6	SIDP . . . . .	18
3.6.1	Algoritmus SIDP . . . . .	18
3.6.2	Detaily algoritmu . . . . .	19
<b>4</b>	<b>Srovnání suboptimální přístupů při řízení jednoduchého systému</b>	<b>22</b>
4.1	Integrátor s neznámým ziskem . . . . .	22
4.1.1	Popis systému . . . . .	22
4.1.2	Transformace rovnic systému . . . . .	23
4.2	Srovnávané řídící algoritmy . . . . .	24
4.2.1	Klasický přístup k dynamickému programování . . . . .	24
4.2.2	Certainty equivalent control . . . . .	25
4.2.3	Metoda opatrného řízení . . . . .	25
4.2.4	SIDP . . . . .	26
4.2.5	Popis experimentu . . . . .	26
4.3	Srovnání jednotlivých přístupů . . . . .	26
4.3.1	Výsledky simulace . . . . .	27
4.3.2	Shrnutí výsledků simulace . . . . .	28
<b>Závěr</b>		<b>34</b>
<b>Seznam použitých zdrojů</b>		<b>35</b>

# Značení

V této bakalářské práci je použito následující značení:

$t$	diskrétní časový okamžik
$a_t$	hodnota veličiny v čase $t$
$\mathbb{E}_a$	operátor střední hodnoty s rozdělením pravděpodobnosti $P^a$
$t:s$	posloupnost časů $(t, t+1, \dots, s)$
$a_{t:s}$	posloupnost veličin $(a_t, a_{t+1}, \dots, a_s)$
$g_{t:s}(a_{t:s})$	posloupnost funkčních hodnot $(g_t(a_t), g_{t+1}(a_{t+1}), \dots, g_s(a_s))$
$ H $	počet prvků v množině $H$

# Úvod

V technické praxi, stejně jako běžném životě, jsme nuceni dělat rozhodnutí. Ať už se jedná o řízení výrobní linky či hledání optimálního spojení mezi dvěma místy, naše rozhodnutí vychází ze znalostí, které o světě máme. Chceme-li činit úspěšná rozhodnutí, je třeba vyřešit dvě úlohy: 1) řízený objekt co nejlépe poznat a 2) dosáhnout cíle, který jsme si vytyčili. Tyto dva úkoly jsou však většinou v rozporu: systém se nejlépe pozná, když se nechová podle našich požadavků. V reálném světě navíc existují náhodné jevy, poruchy a nepředvídané situace, které jednotně nazýváme neurčitostí. Tato skutečnost způsobuje, že naše znalost systému není nikdy dokonalá.

Za účelem řízení systémů, které jsou buď natolik složité, že jejich deterministický popis je nemožný, nebo obsahují náhodné prvky již ze své podstaty, vzniklo stochastické řízení, nebo-li optimální řízení za neurčitosti. Cílem stochastického řízení je minimalizovat velikost odchylek systému od požadovaného stavu optimalizací řídících zásahů.

Jeden z přístupů k řešení tohoto probému je dynamické programování, které navrhl americký matematik Richard Bellman [3]. Jedná se o metodu, která s využitím zpětného chodu minimalizuje hodnotu očekávané ztátové funkce.

Přímá aplikace tohoto postupu je však bohužel i u poměrně jednoduchých značně komplikována složitostí výpočtu. K řešení úlohy je proto vhodné požít approximačních metod.

V sedesátých letech 20. století navrhl Alexander Aronovich Feldbaum řešení použitím takzvaného duálního řízení [5]. Hlavní myšlenkou tohoto přístupu bylo, že řízení musí nejen minimalizovat aktuální ztrátu, ale rovněž musí získat o systému co nejvíce informací pro minimalizaci budoucích ztrát.

Další z možných approximačních metod je použití stochastické iterativní approximace řešení. To spočívá v použití iterativního dynamického programování a simulační metody Monte Carlo. Tento přístup byl popsán v článku [11]. Podstatou algoritmu je hledání řešení úlohy dynamického programování iterativně, za použití metody Monte Carlo pro simulaci neurčitosti v systému.

Tato bakalářská práce si klade následující cíle

- Formulace úlohy stochastického řízení
- Řešení úlohy stochastického řízení s aditivní ztrátou funkcí pomocí dynam-

## ického programování

- Formulace úlohy stochastického řízení s neúplným pozorováním a její převedení na úlohu s úplnými znalostmi systému
- Představení některých suboptimálních přístupů k úloze stochastického řízení
- Aplikace a porovnání zmíněných metod k nalezení optimální strategie na jednoduchém systému
- Na základě získaných výsledků diskutovat výhody a nevýhody algoritmu a jeho použitelnost při aplikaci na další úlohy.

Cílem práce je seznámení se s problémy, které approximativní řešení úlohy stochastického řízení přináší. Přínosem je pak vytvoření konkrétní implementace algoritmu stochastického iterativního dynamického programování a jeho srovnání s jinými algoritmy. To umožňuje získat přehled o kladných a záporných stránkách jednotlivých přístupů a posoudit jejich aplikovatelnost na reálné úlohy. Očekávaným výsledkem srovnání algoritmu iterativního dynamického programování s jinými, v literatuře běžnějšími, je větší časová náročnost výpočtu a lepší robustnost a přesnost výsledného řízení.

# Kapitola 1

## Úloha stochastického řízení

### 1.1 Formulace základní úlohy stochastického řízení

#### 1.1.1 Systém a jeho popis

Ústředním pojmem v teorii řízení je systém. Systém je část světa, kterou chceme poznat či řídit. Ovlivňování systému, ať už za účelem jeho lepšího poznání, či za účelem řízení, provádíme pomocí vstupů (řídících zásahů). Ve většině případů je řešení úlohy stochastického řízení prováděno numericky, je proto účelné pracovat s diskrétním časem. Budeme-li proto uvažovat diskrétní povahu času, stav systému v časovém okamžiku  $t$  podél konečného horizontu délky  $N$  popisuje soustava rovnic

$$x_{t+1} = f_k(x_t, u_t, w_t), \quad t = 0, 1, \dots, N-1, \quad (1.1)$$

kde  $x_t$  je stav systému v čase  $t$ ,  $u_t$  je řídící zásah v čase  $t$  a  $w_t$  náhodná veličina reprezentující přítomnost šumu. Zde předpokládáme, že tvar rovnic  $f_t$  je nám znám, například z fyzikálního rozboru úlohy, či ze znalosti konstrukce stroje, který popisujieme. Dále předpokládáme, že stav systému můžeme přímo pozorovat. Případem neúplného pozorování se zabývá následující kapitola.

#### 1.1.2 Ztrátová funkce a optimální řízení

Cílem je pro zadaný systém (1.1) navrhnout řízení, které bude systém udržovat co nejblíže požadovaného stavu. Pro tyto účely máme v úloze řízení k dispozici předepsanou ztrátovou (resp. účelovou) funkci

$$g(x_{1:N}, u_{0:N-1}), \quad (1.2)$$

která určuje nakolik jsme vytyčených cílů dosáhli.

Označme  $U(x_t)$  neprázdnou množinu přípustných řídících zásahů pro systém nacházející se ve stavu  $x_t$ . Přípustnou řídící strategii  $\pi = \mu_{0:N-1}$  budeme rozumět posloupnost zobrazení

$$\mu_t(x_t) = u_t \quad t = 0, 1, \dots, N-1, \quad (1.3)$$

kde  $\mu_t(x_t) = u_t \in U(x_t)$  je přípustný řídící zásah. Neprázdná množina  $\Pi$  pak bude značit množinu všech přípustných řídících strategií.

Pro danou řídící strategii označme očekávanou ztrátu jako

$$J_\pi(x_0) = \underset{w_{0:N-1}}{\mathbb{E}} \{g(x_{1:N}, \mu_{0:N-1}(x_{0:N-1}))\}. \quad (1.4)$$

Úlohou je potom najít takovou  $\pi^*$ , pro kterou platí

$$J_{\pi^*}(x_0) = \min_{\pi \in \Pi} J_\pi(x_0). \quad (1.5)$$

Celkově se tedy jedná o optimalizační úlohu nalézt takovou posloupnost funkcí (1.3), která minimalizuje očekávanou ztrátovou (1.4) za podmínek (1.1).

## 1.2 Úloha stochastického řízení s aditivní ztrátou

Úlohu stochastického řízení tak, jak byla definována v předchozí části, nelze obecně řešit. Je tedy potřeba úlohu nějak blíže specifikovat.

### 1.2.1 Aditivní ztrátová funkce

Jako vhodné se ukazuje omezit se na nějaký speciální tvar ztrátové funkce (1.4). Budeme proto dále uvažovat tzv. aditivní tvar ztrátové funkce, tedy že existují funkce  $g_t$  takové, že můžeme psát

$$g(x_{1:N}, u_{0:N-1}) = \sum_{t=1}^{N-1} g_t(x_{t+1}, u_t). \quad (1.6)$$

Očekávanou ztrátu (1.4) potom můžeme přepsat do tvaru

$$J_\pi(x_0) = \underset{w_{0:N-1}}{\mathbb{E}} \left\{ \sum_{t=0}^{N-1} g_t(x_{t+1}, \mu_t(x_t)) \right\}. \quad (1.7)$$

### 1.2.2 Dynamické programování

Takto specifikovaná úloha stochastického řízení se dá řešit použitím dynamického programování [3]. Dynamické programování je přístup k řešení optimalizačních úloh, na které se můžeme dívat jako na posloupnost rozhodnutí, pro které platí tzv. princip optimality. Ten říká, že optimální posloupnost rozhodnutí má tu vlastnost, že pro libovolný počáteční stav a rozhodnutí musí být všechna následující rozhodnutí optimální vzhledem k výsledkům rozhodnutí prvního.

Platnost principu optimality pro očekávanou ztrátu tvaru (1.7) je intuitivně snadno pochopitelná. Pokud by totiž nějaký úsek řídící strategie nebyl optimální, pak očekávanou ztrátu snížíme přechodem ke strategii, ve které onu neoptimální část nahradíme

optimálním řešením podproblému na daném úseku. Přesný důkaz platnosti principu optimality pro očekávanou ztrátu tvaru (1.7) lze nalézt například v [4].

### 1.2.3 Použití dynamického programování při řešení úlohy stochastického řízení s aditivní ztrátou

Při řešení úlohy stochastického řízení s aditivní ztrátou je možné postupovat, jak je u úloh řešených pomocí dynamického programování zvykem. Ze tímto účelem označme  $J_t(x_t)$  minimální hodnotu střední ztráty od okamžiku  $t$  do  $N$  v závislosti na  $x_t$ . Dle (1.7) pro ni můžeme psát

$$J_N(x_N) = 0 \quad (1.8)$$

$$J_t(x_t) = \min_{u_t \in U(x_t)} \mathbb{E}_{w_t} \{g_k(x_{t+1}, u_t) + J_{t+1}(x_{t+1})\} \quad t = 0, \dots, N-1. \quad (1.9)$$

Při konstrukci optimální řídící strategie budeme postupovat od konce řídícího horizontu a postupně hledat  $J_t(x_t)$ . Pro výpočet  $x_{t+1}$  se použije rovnice (1.1). Libovolná řídící strategie  $\pi = \{\mu_0, \dots, \mu_{N-1}\}$ , která splňuje systém rovnic

$$J_t(x_t) = \mathbb{E}_{w_t} \{g_k(x_t, \mu_t(x_t), w_t) + J_{t+1}(f_t(x_t, \mu_t(x_t), w_t))\} \quad t = 0, \dots, N-1 \quad (1.10)$$

pak bude optimální posloupností rozhodnutí.

# Kapitola 2

## Úloha stochastického řízení s neúplným pozorováním

Při aplikaci matematického modelování na řešení nějaké konkrétní úlohy se obvykle potýkáme s problémem, jak určit konstanty, které daný model určují. Zkoumáme-li například nějaký fyzikální systém, z rozboru fyzikálních zákonitostí obvykle známe tvar rovnic, které určují jeho vývoj v čase, nicméně počáteční podmínky či parametry, které v rovnicích vystupují a jsou pro daný systém charakteristické, můžeme získat pouze nepřímo, obvykle měřením vhodných veličin. Tato kapitola se zabývá modifikací úlohy stochastického řízení pro případ přítomnosti neznámých parametrů.

### 2.1 Formulace úlohy stochastického řízení s nepřesnými daty

#### 2.1.1 Výstup systému a infomační vektor

Informace o stavu systému  $x_t$  v čase  $t$  získáváme pomocí výstupu  $y_t$ , který je dán jako

$$y_0 = h_0(x_0, v_0), \quad y_{t+1} = h_{t+1}(x_{t+1}, u_t, v_{t+1}), \quad t = 1, \dots, N-1, \quad (2.1)$$

kde  $v_t$  je náhodná veličina charakterizující chybu měření. Počáteční stav  $x_0$  je dán rozdělením pravděpodobnosti  $P^{x_0}$  a další vývoj systému určuje soustava (1.1).

Informace, které jsou v průběhu řízení k dispozici je zvykem psát ve formě tzv. informačního vektoru, který má tvar

$$I_0 = y_0, \quad I_{t+1} = (y_{0:t+1}, u_{0:t}), \quad t = 1, \dots, N-1. \quad (2.2)$$

#### 2.1.2 Optimální řízení pro úlohu s nepřesnými daty

Řídící zásah nyní nemůže explicitně záviset na stavu systému, protože máme k dispozici pouze informační vektor. Podobně jako v předešlé kapitole proto zavádíme

neprázdnou množinu  $U(I_t)$  všech přípustných řídících zásahů za informace  $I_t$ . Přípustnou řídící strategii  $\pi = \mu_{0:N-1}$  bude posloupnost

$$\mu_t(I_t) = u_t \quad t = 0, 1, \dots, N-1, \quad (2.3)$$

kde  $\mu_t(I_t) = u_t \in U(I_t)$  je přípustný řídící zásah.

Úkolem je najít přípustnou strategii, která by minimalizovala očekávanou ztrátu

$$J_\pi = \underset{x_0, w_{0:N-1}, v_{0:N}}{\mathbf{E}} \left\{ \sum_{t=0}^{N-1} g_t(x_{t+1}, \mu_t(x_t)) \right\}, \quad (2.4)$$

za podmínek (1.1) a (2.1).

### 2.1.3 Převod na úlohu s úplnými daty

Protože v čase  $t$  nemáme k dispozici přímo stav systému  $x_t$ , ale pouze informační vektor  $I_t$ , nemůžeme použít postup z předchozí kapitoly. Před tím je potřeba úlohu vhodně transformovat. Za tímto účelem zapíšeme informační vektor ve tvaru

$$I_0 = y_0, \quad I_{t+1} = (I_t, u_t, y_{t+1}), \quad t = 1, \dots, N-1. \quad (2.5)$$

Na tuto rovnost můžeme pohlížet jako na rovnice systému (1.1). Stav v čase  $t$  je nyní  $I_t$ , vstup  $u_t$  a  $y_{t+1}$  náhodná veličina podmíněná  $I_t$  a  $u_t$  přes (2.1).

Dále přejdeme k nové ztrátové funkci, kterou definujeme jako

$$\tilde{g}_t(I_{t+1}, u_t) = \underset{x_{t+1}}{\mathbf{E}} \{g_t(x_{t+1}, u_t) | I_t, u_t\}, \quad t = 1, \dots, N-1, \quad (2.6)$$

kde  $x_{t+1}$  se počítá dle (1.1) a  $x_t$  se považuje za náhodnou veličinu podmíněnou informačním vektorem  $I_t$ .

Očekávanou ztrátu podproblému od času  $t$  do  $N$  nyní můžeme psát ve tvaru

$$J_N(I_N) = 0 \quad (2.7)$$

$$J_t(I_t) = \min_{u_t \in U_t} \underset{w_t, y_{t+1}}{\mathbf{E}} \{\tilde{g}_t(I_{t+1}, u_t) + J_{t+1}(I_{t+1}) | I_t, u_t\} \quad t = 0, \dots, N-1 \quad (2.8)$$

Tato úloha již může být řešena pomocí dynamického programování. Pří řešení budeme postupovat od konce řídícího horizontu a postupně hledat  $J_t(I_t)$ . Potom libovolná  $\pi = \{\mu_0, \dots, \mu_{N-1}\}$ , která nabývá minimální očekávané ztráty  $J_0(y_0)$  je optimální řídící strategie.

## 2.2 Řízení systému s neznámými parametry

Pokud chceme řídit systém, jehož výstup závisí na nějakém neznámém konstantním parametru  $\theta$ , můžeme využít znalosti řešení problému s neúplným pozorováním. Parametr  $\theta$  bude reprezentovat stav systému  $x_t$ , který se nyní v čase nemění.

### 2.2.1 Systém s neznámými parametry, hyperstav

V této úloze máme výstupy systému  $y_t$  popsány jako

$$y_0 = h_0(\theta, v_0), \quad y_{t+1} = h_t(I_t^{(d)}, \theta, u_t, v_{t+1}), \quad t = 0, \dots, N-1, \quad (2.9)$$

kde  $I_t^{(d)} = (y_{t:t-d}, u_{t-1:t-d})$  a číslo  $d$  se nazývá řád modelu.

Označme  $T_t$  dostatečnou statistiku pro parametr  $\theta$  založenou na informacích dostupných v čase  $t$ . Pokud dostatečná statistika neexistuje, pak bude  $T_t$  označovat nějakou její vhodnou approximaci. Označme dále  $H_t = (I_t^{(d)}, T_t)$  tzv. hyperstav systému.

Předpokládejme dále, že o parametru  $\theta$  máme nějakou apriorní informaci v podobě hustoty pravděpodobnosti  $f(\theta|T_0)$ . Aposteriorní hustotu  $f(\theta|T_{t+1})$  získáme pomocí Bayesova vzorce

$$f(\theta|T_{t+1}) = \frac{f(y_{t+1}|\theta, I_t^{(d)}, u_t)f(\theta|T_t)}{\int f(y_{t+1}|\theta, I_t^{(d)}, u_t)f(\theta|T_t)d\theta} \quad (2.10)$$

Rekurzivní použití vzorce (2.10) pro odhad parametru  $\theta$  se nazývá postup Bayesovského učení [10].

Pro vývoj hyperstavu  $H_t$  v čase můžeme na základě (2.10) psát

$$H_{t+1} = f_t(H_t, u_t, y_{t+1}), \quad t = 1, \dots, N-1. \quad (2.11)$$

Rovnici (2.11) můžeme podobně jako (2.5) považovat za rovnici systému (1.1) pro stav  $H_t$  a vstup  $u_t$  s šumem  $y_{t+1}$ .

### 2.2.2 Převod na úlohu s nepřesnými daty

Ztrátová funkce je nyní

$$g(y_{1:N}, u_{0:N-1}) = \sum_{t=0}^{N-1} g_t(y_{t+1}, u_t). \quad (2.12)$$

Úlohou je nalezení řídící strategie  $\pi = \mu_{0:N-1}$ , která by minimalizovala očekávanou ztrátu

$$J_\pi = \underset{\theta_0, v_{0:N-1}}{\text{E}} \left\{ \sum_{t=0}^{N-1} g_t(y_{t+1}, \mu_t(H_t)) \right\}, \quad (2.13)$$

za apriorní informace  $f(\theta|T_0)$ , známého rozdělení šumu  $v_t$  a podmínek (2.11) a (2.9).

Rovnice (2.11), (2.9) a (2.12) potom představují úlohu stochastického řízení s nepřesnými daty.

Úlohu opět řešíme pomocí dynamického programování, tedy postupnou minimalizací očekávané ztráty od konce řídícího horizontu

$$J_N(H_N) = 0 \quad (2.14)$$

$$J_t(H_t) = \min_{u_t \in U_t} \underset{y_{t+1}}{\text{E}} \{ g_t(y_{t+1}, u_t) + J_{t+1}(H_{t+1}) | H_t, u_t \}, \quad t = 0, \dots, N-1, \quad (2.15)$$

kde  $H_{t+1}$  se počítá dle (2.11). Střední hodnota vzhledem k  $y_{t+1}$  se počítá pomocí (2.9) a  $f(\theta|T_t)$  jakožto aktuálního odhadu na parametr  $\theta$ .

### 2.2.3 Kalmanův filtr

Pokud v rovnících (2.9) popisujících výstup systému vystupuje aditivní gaussovský šum a neznámý parametr je separován jako lineární člen, můžeme vypočítat konkrétní tvar rovnice (2.11), tzv. Kalmanův filtr [7].

Dle předpokladu má výstup v čase  $t$  tvar

$$y_{t+1} = \tilde{h}_t(I_t, u_t) + A_t(I_t, u_t)\theta + v_{t+1},, \quad t = 0, \dots, N-1. \quad (2.16)$$

kde  $\tilde{h}_t(I_t, u_t)$ , resp.  $A_t(I_t, u_t)$  je známá funkce, resp. matice závisící na informačním vektoru a aktuální vstupu. Dále předpokládáme gaussovské rozložení šumu  $v_{t+1}$  se známým rozptylem

$$v_{t+1} \sim N(0, Q_{t+1}), \quad (2.17)$$

gaussovské rozložení odhadu neznámého parametru  $\theta_t$  a jejich nekorelovanost, tedy

$$\theta_t \sim N(\hat{\theta}_t, P_t), \quad (2.18)$$

$$\text{Cov}(v_{t+1}, \theta_t) = 0. \quad (2.19)$$

Dosazením do (2.10) se odvodí, že aposteriorní hustota pravděpodobnosti  $f(\theta|T_{t+1})$  je rovněž gaussovská a její parametry  $(\hat{\theta}_{t+1}, P_{t+1})$  splňují rovnice

$$K_t = P_t A_t (A_t^T P_t A_t + Q_t)^{-1} \quad (2.20)$$

$$\hat{\theta}_{t+1} = \hat{\theta}_t + K_t(y_{t+1} - \tilde{h}_t(I_t, u_t) - A_t \hat{\theta}_t), \quad (2.21)$$

$$P_{t+1} = (I - K_t A_t) P_t. \quad (2.22)$$

Odvození lze nalézt v [10].

Alternativní odvození bez požadavku gaussovského šumu je možné provést za předpokladu, že odhadovací procedura střední hodnoty  $\hat{\theta}_{t+1}$  neznámého parametru  $\theta$  budeme hledat ve tvaru lineární opravy střední hodnoty  $\hat{\theta}_t$  úměrné neurčitosti v systému. Tedy že

$$\hat{\theta}_{t+1} = \hat{\theta}_t + K_t(y_{t+1} - \mathbb{E}_{\theta, v_t} y_{t+1}), \quad (2.23)$$

kde  $K_t$  je neznámá matice, kterou určíme z požadavku minimalizace výsledné matice rozptylu  $P_{t+1}$ . Pro šum  $v_t$  budeme požadovat nulovou střední hodnotu a existenci druhého momentu. Matice rozptylu označíme opět  $Q_t$ .

Pro matici  $P_{t+1}$  jako funkci  $K_t$  můžeme psát

$$P_{t+1}(K_t) = \mathbb{E}[(\theta - \hat{\theta}_{t+1})(\theta - \hat{\theta}_{t+1})^T]. \quad (2.24)$$

Dosazením za  $\hat{\theta}_{t+1}$  z (2.23) a za  $y_t$  ze (2.16) a úpravou dostaneme (pro libovolnou matici  $B$  budeme pro lepší čitelnost namísto  $BB^T$  psát zkráceně  $B^2$ )

$$\begin{aligned} P_{t+1}(K_t) &= \mathbb{E}_{\theta, v_t} \left\{ (\theta - \hat{\theta}_t - K_t(y_{t+1} - \tilde{h}_t(I_t, u_t) - A_t \hat{\theta}_t))^2 \right\} \\ &= \mathbb{E}_{\theta, v_t} \left\{ ((I - K_t A_t)(\theta - \hat{\theta}_t) - K_t v_t)^2 \right\} \\ &= (I - K_t A_t) \mathbb{E} \left\{ (\theta - \hat{\theta}_t)^2 \right\} (I - K_t A_t)^T - (I - K_t A_t) \text{Cov}(\theta, v_t) K_t^T - \\ &\quad - K_t \text{Cov}(\theta, v_t) (I - K_t A_t)^T + K_t \mathbb{E} \left\{ v_t^2 \right\} K_t^T. \end{aligned}$$

Použitím definice  $P_t$ ,  $Q_t$  a předpokladu  $\text{Cov}(\theta, v_t) = 0$  máme

$$P_{t+1}(K_t) = (I - K_t A_t) P_t (I - K_t A_t)^T + K_t Q_t K_t^T. \quad (2.25)$$

Protože požadujeme minimální rozptyl odhadu  $\hat{\theta}_{t+1}$ , určíme  $K_t$  z rovnice

$$\frac{\partial \text{tr}(P_t)}{\partial K_t} = 0. \quad (2.26)$$

K provedením derivace použijeme vzorce\*ODVOZENI BUDE ASI AZ V DODATKU\*

$$\frac{\partial \text{tr}(MXN)}{\partial X} = M^T N^T, \quad (2.27)$$

$$\frac{\partial \text{tr}(MXNX^TO)}{\partial X} = M^T O^T X N + O M X N, \quad (2.28)$$

kde  $M$ ,  $N$  a  $O$  jsou konstantní matice.

Tím získáme lineární rovnici pro  $K_t$  tvaru

$$-P_t^T A_t - P_t A_t + K_t A_t P_t K_t + K_t A_t^T P_t K_t + 2Q_t K_t = 0, \quad (2.29)$$

která má řešení

$$K_t = P_t A_t (A_t^T P_t A_t + Q_t)^{-1} \quad (2.30)$$

Dosazením (2.30) do (2.25) po úpravě dostaneme

$$P_{t+1} = (I - K_t A_t) P_t \quad (2.31)$$

Rovnice (2.23), (2.30) a (2.31) představují rovnice Kalmanova filtru.

# Kapitola 3

## Suboptimální přístupy k úloze duálního řízení

Ačkoliv použití dynamického programování přináší významný pokrok v řešení úlohy stochastického řízení, analytické řešení obvykle není možné získat. V každém časovém kroku se totiž potýkáme se dvěma obecně obtížnými problémemy: 1) výpočet střední hodnoty a 2) minimalizace vzhledem k  $u_t$ . Oba problémy obecně nemají analytické řešení a bez další specifikace úlohy je proto třeba přejít k approximačním metodám.

V této kapitole se předkládá popis několika možných přístupů k approximativnímu řešení úlohy duálního řízení. Přípomeňme, že úlohou duálního řízení je nalezení řídící strategie  $\pi = \mu_{0:N-1}$ , která by minimalizovala očekávanou ztrátu

$$J_\pi = \underset{\theta_0, v_{0:N-1}}{\text{E}} \left\{ \sum_{t=0}^{N-1} g_t(y_{t+1}, \mu_t(H_t)) \right\}, \quad (3.1)$$

za apriorní informace  $\theta_0$  a podmínek

$$H_{t+1} = f_t(H_t, u_t, y_{t+1}), \quad (3.2)$$

$$y_0 = h_0(\theta, v_0), \quad y_{t+1} = h_t(I_t^{(d)}, \theta, u_t, v_{t+1}), \quad t = 0, \dots, N-1, \quad (3.3)$$

kde  $H_t = (I_t^{(d)}, T_t)$  je hyperstav systému a  $T_t$  dostatečná statistika pro neznámý parametr  $\theta$  v čase  $t$ .

Úlohu řešíme pomocí dynamického programování, tedy postupnou minimalizací očekávané ztráty od konce řídícího horizontu

$$J_t(H_t) = \min_{u_t \in U_t} \underset{y_{t+1}}{\text{E}} \{g_t(y_{t+1}, u_t) + J_{t+1}(H_{t+1})|H_t, u_t\}, \quad t = 0, \dots, N-1, \quad (3.4)$$

kde  $T_{t+1}$  a  $y_{t+1}$  se počítá dle (3.2) a (3.3).

### 3.1 Duální řízení

K navržení kvalitního řízení systému s neznámými parametry je potřeba eliminovat neurčitost, která způsobuje nepředvídané chování systému. Hledané řízení by tedy mělo zároveň

- minimalizovat aktuální ztrátu,
- získat o systému co nejvíce informací pro minimalizaci budoucích ztrát.

Tento postup, nazývaný duální řízení, navrhl Alexander Feldbaum v práci [5]. Název metody pochází z faktu, že požadavky, které na dobré duální řízení klademe, jsou v obecně rozporu. Abychom se o systému něco nového dozvěděli, je vhodné ho vybudit do stavu, kde může vykazovat nepředvídané chování. Naopak pro minimalizaci aktuální ztráty potřebujeme systém uvést do stavu předem známého.

Jak konkrétně volit tvar optimálního řídícího  $\mu_t(H_t)$ , aby odpovídalo principu duálního řízení, je obvykle obtížná úloha. Často (například [12]) se tak volí approximace tvaru

$$\mu_t(H_t) = \mu_t^{(1)}(H_t) + \mu_t^{(2)}(H_t), \quad (3.5)$$

kde  $\mu_t^{(1)}$  je řídící zásah snažící se o minimalizaci aktuální ztráty a  $\mu_t^{(2)}$  je budící zásah, který slouží k excitaci systému za účelem identifikace neznámých parametrů.

Problém je nyní ve výrazu (3.5) vhodně určit funkce  $\mu_t^{(1)}$  a  $\mu_t^{(2)}$ . Vhodným výběrem na řídící složku  $\mu_t^{(1)}$  duálního řízení je například řízení metodou opatrného řízení (v anglické literatuře "cautious control", zkráceně pak CC), nebo metodou certainty equivalence. Obě metody budou probrány dále. Pro budící složku je obvykle obtížné určit nějaký funkcionální tvar. Jako vhodná approximace se ukazuje použití bílého šumu, který se zapne jen pokud neurčitost v systému překročí nějakou mezní hodnotu. Nevhodnou této přímočaré approximace je nutnost určení amplitudy budícího signálu. K tomu obvykle nějakou systematickou metodu k dispozici nemáme.

## 3.2 Certainty equivalent control

Při použití metody Certainty equivalent control (CEC) (například [4]) se v rovnici pro očekávanou ztrátu (3.4) nahradí náhodná veličina  $y_{t+1}$  střední hodnotou  $\hat{y}_{t+1}$ . Ta se vypočítá z (3.3) pomocí známých rozdělení na  $v_t$  a postačující statistiky  $T_t$  pro parametr  $\theta$ . Očekávaná ztráta (3.4) tak přejde v

$$J_t(H_t) = \min_{u_t \in U_t} \left\{ g_t(\hat{y}_t, u_t) + J_{t+1}(\hat{H}_{t+1}) | H_t, u_t \right\}, \quad t = 0, \dots, N-1, \quad (3.6)$$

Tím odpadne počítání střední hodnoty a zbývá pouze problém minimalizace vzhledem k  $u_t$ . Jedná se tedy o jednodušší úlohu, kterou se již může povést vyřešit. Nutno podotknout, že optimální řízení získané metodou separace nemusí být optimální řízení pro původní úlohu. Některé vlastnosti CEC jsou probírány v další při aplikaci na řízení jednoduchého systému. Podrobnější pojednání lze nalézt v [4].

### 3.3 Opatrné řízení

Metoda opatrného řízení (anglicky "cautious control", například [12]) spočívá v optimalizaci očekávané ztráty (3.4) na horizontu délky  $N = 1$ . Minimalizujeme tedy

$$J_0(H_0) = \min_{u_0 \in U_0} \mathbb{E} \{ g_0(y_1, u_0) | H_0, u_0 \}. \quad (3.7)$$

Stačí tedy spočítat střední hodnotu  $g_0(y_1, u_0)$  vzhledem k  $y_1$  a výsledek minimalizovat vzhledem k  $u_0$ . Poznamenejme, že výsledné řízení nebude zcela jistě duální. To plyne z toho, že minimalizujeme očekávanou ztrátu pouze jeden krok dopředu a tedy se nemůže projevit výhoda identifikace parametrů pomocí vybuzení systému mimo požadovaný stav.

### 3.4 Iterativní dynamické programování

Iterativní dynamické programování [8] je jednou z variant klasického přístupu k nalezení optimální strategie, která minimalizuje očekávanou ztrátu (3.4). Standardní numerický přístup k dynamickému programování lze shrnout následovně

1. prostor proměnných  $H_t$  se diskretizuje do mřížky,
2. postupně se od konce horizontu napočítává minimální očekávaná ztráta  $J_t(H_t)$  pro každý bod diskretizace  $H_t$ . K výpočtu se používají již napočtené minimální očekávané ztráty v následujících časech,
3. optimální strategie bude ta, na které bude nabito minimální očekávané ztráty z počátečního stavu na konec řídícího horizontu.

Tento postup je přímočarou aplikací principu dynamického programování. Bohužel je velmi citlivý na dimenzi stavového prostoru  $H_t$ , který je potřeba diskretizovat, neboť počet bodů potřebných k discretizaci roste exponenciálně s dimenzí prostoru. Tato skutečnost se v anglické literatuře označuje jako "curse of dimensionality".

Oproti klasickému dynamickému programování iterativní dynamické programování problém řeší v sérii iterací. V každé iteraci se vychází ze strategie spočtené v předchozím běhu a prostřednictvím perturbací tohoto (suboptimálního) řešení se hledá strategie, pro kterou bude očekávaná ztráta nižší. Tato se použije v následující iteraci. Výhodnost iterativního přístupu spočívá ve snížení citlivosti na dimenzi úlohy.

#### 3.4.1 Diskretizace prostoru

Při hledání optimální strategie  $\mu_t(H_t)$  je pro přesné vycílení očekávané ztráty (3.8) na úseku řídícího horizontu  $t : N$  nutné znát její analytické vyjádření. To ale není obvykle možné. Je proto nutné přejít k nějaké approximaci, například

1. předpokládat nějaký tvar optimální strategie a při výpočtu určit pouze konstanty, které výslednou strategii určí jednoznačně,
2. diskretizovat prostor ( $H_t$ ) a počítat  $\mu_t(H_t)$  jen v bodech diskretizace a jinde se uchýlit k interpolaci (popřípadě extrapolaci).

Jakým způsobem efektivně diskretizovat prostor nezávislých proměnných pro approximativní výpočet očekávané ztráty (3.8) je při použití dynamického programování obtížná otázka. Bude-li bodů v diskretizaci příliš málo, bude výpočet nespolehlivý, naopak pro příliš jemnou diskretizaci bude počet bodů v diskretizaci hyperstavu rychle stoupat a časová náročnost výpočtu pak prakticky znemožní jeho řešení.

Zde se ukazuje výhodnost použití iterativního dynamického programování. Při něm totiž stačí diskretizovat jen tu část prostoru, která bude potřebná v následující iteraci. Pomocí perturbací strategie spočtené v předchozím kroku se určí ta část prostoru, která je pro bezprostřední výpočet podstatná. Díky tomu stačí k dostatečně jemné diskretizaci podstatně méně bodů. Iterativní dynamické programování tak problém nárůstu časové náročnosti se zvyšující se dimenzí hyperstavu neřeší, nicméně díky tomu, že stačí používat výrazně méně bodů k diskretizaci prostoru, ho alespoň částečně redukuje.

KONVERGENCE = CCA 2 STRANY

## 3.5 Metoda Monte Carlo

Metoda Monte Carlo [6] je statistická simulační metoda. Její princip spočívá ve vzorkování nějaké náhodné veličiny za účelem odhadu její hledané charakteristiky, např. střední hodnoty. V této práci je metoda Monte Carlo použita k výpočtu očekávané ztráty (3.4).

### 3.5.1 Použití metody Monte Carlo k výpočtu očekávané ztráty

Pří běžném použití dynamického programování máme při výpočtu  $J_t(H_t)$  k dispozici předpis pro následující očekávanou ztrátu  $J_{t+1}(H_{t+1})$ . Metoda monte Carlo by nám však dala k dispozici pouze odhad očekávané ztráty. Použití těchto approximací v dalším výpočtu by chybu výpočtu navyšovalo.

Namísto  $J_t(H_t)$  je proto vhodné pro další výpočet uchovávat  $\mu_t(H_t)$ . Očekávanou ztrátu v čase  $t$  pak lze počítat jako průměr  $n$  realizací náhodných veličin přes které je prováděna střední hodnota  $(\theta_{t:N-1}, v_{t:N})$ , tedy

$$\frac{1}{n} \sum_{i=1}^n \left( g_j(y_{j+1}^i, \mu_j(H_j)) + \sum_{j=t+1}^{N-1} g_j(y_{j+1}^i, \mu_j(H_j^i)) \right), \quad (3.8)$$

kde  $y_{j+1}^i$  se počítá podle (3.3) jako

$$y_{j+1}^i = h_j(I_j^i, \theta_j^i, \mu(H_j^i), v_{j+1}^i), \quad j = t, \dots, N-1, \quad i = 1, \dots, n, \quad (3.9)$$

počet opakování algoritmu	$n_{pass}$
počet iterací algoritmu	$n_{iter}$
počet bodů v diskretizaci každé dimenze $H_t$	$n_g$
apriorní řídící strategie	$\mu_{0:N-1}$
počet kadnidátů na změnu řídícího zásahu	$m$
počáteční rozsah pro hledání optimálního řídícího zásahu	$\beta^{in}$
parametr pro redukci $\beta^{in}$ při opakování algoritmu	$\gamma$
parametr pro redukci $\beta^{in}$ při iterování algoritmu	$\lambda$
počet realizací pro odhad metodou Monte Carlo	$n$

Tabulka 3.1: Parametry algoritmu SIDP

a index  $i$  označuje  $i$ -tou realizaci dané veličiny. Realizace  $\theta_{t:N-1}$  se generují podél trajektorie (3.3). To znamená, že  $\theta_{j+1}^i$  se generuje až ve chvíli, kdy je známé  $I_j^i$ ,  $u_j^i$ , postačující statistika  $T_j^i$  a  $y_{j+1}^i$  a tedy přes (3.2) i postačující statistika  $T_{j+1}^i$ .

Výpočet je při uchovávání  $\mu_t(H_t)$  namísto  $J_t(H_t)$  časově náročnější. Namísto přečtení  $J_t(H_t)$  je totiž nutné přečíst hodnotu  $\mu_t(H_t)$  a následně vygenerovat trajektorii od času  $t$  do konce horizontu. To obnáší vygenerovat generovat náhodnou realizace šumu  $v_t$  a neznámého parametru  $\theta$  (pomocí  $T_t$ ), aplikovat řídící zásah, tedy dle (3.3) vypočítat  $y_{t+1}$  a následně (3.2) dle vypočítat  $T_{t+1}$ . Tím bude určen bod v  $H_{t+1}$ . Zde pak pomocí interpolace (a extrapolace) určíme optimální zásah, který aplikujeme. Podobně jako prve tak určíme následující bod v  $H_{t+2}$ , až nakonec se dostaneme na konec řídícího horizontu. Při výpočtu postupně napočítáváme hodnotu ztrátové funkce.

## 3.6 SIDP

Metoda stochastického iterativního dynamického programování (SIDP) [11] spočívá v současném použití metody Monte Carlo k získání aproximace pro očekávanou ztrátu a iterativního dynamického programování k nalezení optimální strategie. Při použití iterativního dynamického programování se uchýlíme k diskretizaci prostoru hyperstavů a budeme používat interpolaci (popřípadě extrapolaci) napočtených hodnot. Poznamenejme, že díky předpokladu gaussovského rozdělení odhadu neznámého parametru  $\theta$ , diskretizace vzhledem k  $T_t$  znamená diskretizaci vzhledem k  $(\hat{\theta}_t, P_t)$ .

### 3.6.1 Algoritmus SIDP

V tomto odílu je popsán algoritmus SIDP, tak jak byl navržen v [11]. Parametry algoritmu jsou uvedeny v tabulce 3.1. Jak plyne z popisu 1, časová složitost algoritmu SIDP vzhledem k jeho parametry je  $O(n_{pass}n_{iter}N^2mnn_g^{\dim H_N})$  (časová náročnost metody Monte Carlo je úměrná vzdálenosti od konce horizontu, proto je časová složitost úměrná druhé mocnině  $N$ ).

---

**Algorithm 1** Schéma algoritmu SIDP

---

```
for  $i = 1$  to  $n_{pass}$  do
    for  $j = 1$  to  $n_{iter}$  do
         $\beta_{i,j} := \gamma^{j-1} \lambda^{i-1} \beta^{in}$ 
        for  $k = 1$  to  $|H_t|$  do
            spočti trajektorii  $H_{0,k}$ , použij aktuální  $\pi^*$ , její interpolace a extrapolace a
            realizace neznámého parametru  $\theta_0, \dots, \theta_{N-1}$  podél této trajektorie
        end for
        for  $t = N - 1$  to  $0$  do
            vytvoř  $\tilde{H}_t$  jakožto rovnoměrnou síť v oblasti bodů  $H_t$ 
            interpoluj (extrapoluj)  $\mu_t^*(H_t)$  na  $\mu_t^*(\tilde{H}_t)$ 
            for  $k = 1$  to  $|H_t|$  do
                for  $m = -\lceil \frac{m-1}{2} \rceil$  to  $\lceil \frac{m}{2} \rceil$  do
                    pro  $\tilde{H}_{t,k}$  vygeneruj kandidáta na řízení  $\mu_t(\tilde{H}_{t,k}) = \mu_t^*(\tilde{H}_{t,k}) + m\beta_{i,j}$ 
                    pomocí metody Monte Carlo spočti očekávanou ztrátu
                end for
                rozhodnutí s nejnižší očekávanou ztrátou uchovej jako nové optimální
                rozhodnutí pro  $\tilde{H}_{t,k}$ .
            end for
        end for
    end for
end for
end for
```

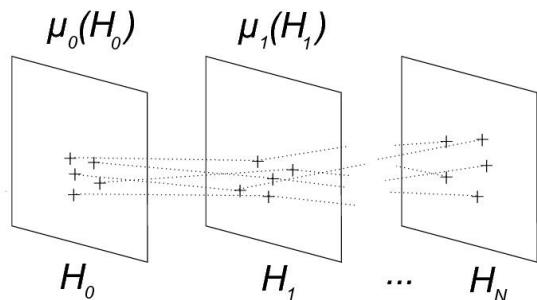
---

### 3.6.2 Detaily algoritmu

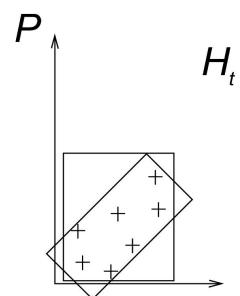
Část prostoru, která se bude v následující iteraci algoritmu diskretizovat se určí pomocí aktuálního suboptimálního řešení a náhodných realizací šumu  $v_{0:N}$  a neznámého parametru  $\theta_{0:N}$ . Pomocí těchto realizací vygenerujeme trajektorie v  $H_{0:N}$ . V každé časové úrovni pak diskretizujeme jen tu část prostoru, kterou takto vygenerované trajektorie prochází. Schématicky je situace znázorněna na obrázku 3.1

V této práci se pro diskretizaci zasažené části prostoru volí jednoduchá metoda, ve které se ve směru souřadných os spočte nejmenší hyperkvádr obahující vygenerované body. Prostor se poté diskretizuje pouze v této oblasti. V práci [11], kde je metoda SIDP navržena, je pro diskretizaci prostoru použit hyperkvádr s obecnou orientací. Metodu k jeho určení převzali autoři z [2]. Tento postup by měl vést k ještě efektivnější diskretizaci prostoru. Nicméně metoda, která je v naší práci použita se ukázala jako postačující. Navíc je implementačně podstatně jednodušší a vyhledávání v tabulce s orientací ve směru souřadných je rychlejší. Výhodou je i to, že můžeme snadno zaručit požadavek na kladný rozptyl  $P_t$  neznámého parametru  $\theta$ , viz obrázek 3.2 .

Máme-li diskretizovanou požadovanou část prostoru, je nutné na ni namapovat dosavadní napočtené optimální řízení. K tomu se použije interpolace, popřípadě extrapolace napočteného řešení. V této práci je interpolace/extrapolace realizována jednoduše pomocí nejbližšího již napočteného bodu. Možným vylepšením by byla například lineární projekce či vážený průměr nejbližších napočtených bodů.



Obrázek 3.1: Trajektorie v hyperstavu – jednotlivá realizace trajektorie je napočítávána pomocí realizací šumu a neznámého parametru



Obrázek 3.2: Oblast určená k diskretizaci  $H_t$  – ačkoliv je objem obecně orientovaného hyperkvádru menší, body v něm nesplňují požadavek na kladný rozptyl  $P$

Pro každý z bodů (nejprve pro ty na konci řídícího horizontu) se optimální řídící zásah hledá pomocí perturbace stávajícího suboptimálního řešení. Pro daný bod se proto vygeneruje  $m$  kandidátů na optimální zásah, rovnoměrně kolem optimálního zásahu z předcházející iterace. Jako jeden z kandidátů na optimální řízení se vždy ponechá stávající suboptimální řešení z minulé iterace.

Kandidáti na řízení se nyní porovnají pomocí metody Monte Carlo. Jak již bylo popsáno výše, pro každého kandidáta se vygeneruje  $n$  realizací ztráty, přes které se dle (3.8) spočte průměr.

Namísto jednoduchého porovnání pomocí průměru lze kandidáty na optimální řídící zásah porovnat nějakým sofistikovanějším víceúrovňovým algoritmem. Jedno z možných vylepšení je použito i v [11]. Konkrétně se jedná o dvouúrovňový algoritmus popsaný v [9]. V první úrovni tohoto algoritmu se nejprve pro každého kandidáta  $u_t$  vygeneruje  $n_0$  realizací. Na jejich základě se vyberou ti, na který je nabyceno minima s pravděpodobností větší než je daná mezi  $\alpha_0$ . Pro tyto se v druhé fázi vygeneruje dostatečný počet realizací tak, aby bylo možné nejlepší rozhodnutí zvolit s pravděpodobností alespoň rovné zadané mezi  $\alpha_1$ . Takto upravený algoritmus metody Monte Carlo je robustnější. Navíc umožňuje efektivní porovnání většího množství kandidátů, neboť počet realizací v první fázi může být poměrně nízký, slouží pouze k odfiltraci zjevně horších kandidátů na řízení. Pro účely této práce postačuje základní verze metody Monte Carlo a proto je v následující implementaci SIDP použita.

Výstupem algoritmu je poté tabulka optimálních řídících zásahů bodech diskretizace. Samotné řízení systému je pak prováděno aplikací pedpočtených optimálních zásahů.

# Kapitola 4

## Srovnání suboptimální přístupů při řízení jednoduchého systému

V této kapitole je popsán jednoduchý systém, na kterém jsou porovnány některé řídící algoritmy založené na principech uvedených v předešlé kapitole.

### 4.1 Integrátor s neznámým ziskem

Integrátor s neznámým ziskem, jakožto systém vhodný k ilustraci výhod duálního řízení, byl podrobně zkoumán v [1]. Pro srovnání uvádíme rovněž tamější výsledky.

#### 4.1.1 Popis systému

Výstup systému je popsán jako

$$y_{t+1} = y_t + \theta u_t + v_{t+1} \quad t = 0, \dots, N-1, \quad (4.1)$$

$$v_{t+1} \sim N(0, \sigma^2), \quad (4.2)$$

kde  $\theta \neq 0$  je neznámý parametr a rozptyl šumu  $\sigma^2 = 0, 1$ . Počáteční hodnota výstupu je nastavena na  $y_0 = 1$ .

O neznámém parametru  $\theta$  máme v čase  $t$  informaci v podobě dostatečné statistiky  $T_t = (\hat{\theta}_t, P_t)$ , tvořené střední hodnotou a rozptylem. Předpokládáme nekorelovanost  $\theta$  s šumem, tedy že

$$\text{Cov}(v_{t+1}, \theta) = 0. \quad (4.3)$$

Optimální řízení je takové, které udrží výstupy systému na nulové hodnotě. Ztrátová funkce je kvadratická v  $y_{t+1}$ , čili

$$g(y_{1:N}, u_{0:N-1}) = \sum_{t=0}^{N-1} y_{t+1}^2. \quad (4.4)$$

Odhadovací procedurou pro parametr  $\theta$  je Kalmanův filtr. Pro systém (4.1) má tvar

$$K_t = \frac{u_t P_t}{u_t^2 P_t + \sigma^2} \quad (4.5)$$

$$\hat{\theta}_{t+1} = \hat{\theta}_t + K_t(y_{t+1} - u_t \hat{\theta}_t), \quad (4.6)$$

$$P_{t+1} = (1 - K_t u_t) P_t. \quad (4.7)$$

Hyperstav systému  $H_t$  tvoří vektor  $(y_t, \hat{\theta}_t, P_t)$ . Očekávaná ztráta je

$$J_t(H_t) = \min_{u_t \in U_t} \mathbb{E}_{y_{t+1}} \{ y_{t+1}^2 + J_{t+1}(H_{t+1}) | H_t, u_t \}, \quad t = 0, \dots, N-1. \quad (4.8)$$

Ta po dosazení z (4.1) a částečném provedení střední hodnoty přejde na tvar

$$J_t(H_t) = \min_{u_t \in U_t} \left\{ (y_t + \hat{\theta}_t u_t)^2 + u_t^2 P_t + \sigma^2 + \mathbb{E}_{y_{t+1}} (J_{t+1}(H_{t+1})) | y_t, \hat{\theta}_t, P_t, u_t \right\}. \quad (4.9)$$

#### 4.1.2 Transformace rovnic systému

Před samotnou aplikací nějakého řídícího algoritmu lze úlohu vhodnou transformací proměnných zjednodušit. Dle [1] je takovou transformací přechod od stavového popisu  $(y_t, \hat{\theta}_t, P_t, u_t)$  k popisu pomocí nových proměnných  $(\eta_t, \beta_t, \zeta_t, \nu_t)$  dle vztahů

$$\eta_t = \frac{y_t}{\sigma}, \quad (4.10)$$

$$\beta_t = \frac{\hat{\theta}_t}{\sqrt{P_t}}, \quad (4.11)$$

$$\zeta_t = \frac{1}{\sqrt{P_t}}, \quad (4.12)$$

$$\nu_t = \frac{u_t \sqrt{P_t}}{\sigma}. \quad (4.13)$$

Současně můžeme neurčitost ve výstupu (4.1) reprezentovat jedinou normalizovanou náhodnou veličinou podle

$$s_t = \frac{y_{t+1} - y_t + \hat{\theta}_t u_t}{\sqrt{u_t^2 P_t + \sigma^2}} \sim N(0, 1). \quad (4.14)$$

Rovnice pro výstup (4.1) a následující odhad neznámého parametru (4.6) tak přejde v

$$\eta_{t+1} = \eta_t + \beta_t \nu_t + \sqrt{1 + \nu_t^2} s_t \quad (4.15)$$

$$\beta_{t+1} = \sqrt{1 + \nu_t^2} \beta_t + \nu_t s_t \quad (4.16)$$

Přejdeme-li k vhodně upravené očekávané ztrátě, dostaneme

$$V_t(\eta_t, \beta_t, \zeta_t) = \frac{J_t(y_t, \hat{\theta}_t, P_t)}{\sigma^2} \quad (4.17)$$

$$= \min_{\nu_t} \left\{ (\eta_t + \beta_t \nu_t)^2 + \nu_t^2 + 1 + \mathbb{E}_{s_t} (V_{t+1}(\eta_{t+1}, \beta_{t+1}, \zeta_{t+1})) \right\}. \quad (4.18)$$

Nyní spočteme očekávanou ztrátu pro  $N - 1$  jako

$$V_{N-1}(\eta_{N-1}, \beta_{N-1}, \zeta_{N-1}) = \min_{\nu_{N-1}} \{(\eta_{N-1} + \beta_{N-1}\nu_{N-1})^2 + \nu_{N-1}^2 + 1\}. \quad (4.19)$$

Pomocí diferenciálního počtu pak získáme optimální zásah ve tvaru

$$\nu_{N-1} = -\frac{\eta_{N-1}\beta_{N-1}}{1 + \beta_{N-1}^2} \quad (4.20)$$

a očekávanou ztrátu rovnu

$$V_{N-1}(\eta_{N-1}, \beta_{N-1}, \zeta_{N-1}) = \frac{\eta_{N-1}^2 + 1}{\beta_{N-1}^2 + 1}. \quad (4.21)$$

Protože optimální zásah  $\nu_{N-1}$  ani očekávaná ztráta  $V_{N-1}$  nezávisí na  $\zeta_{N-1}$ , díky tvaru  $V_t$  nebude rovněž optimální zásah  $\nu_t$  a očekávaná ztráta  $V_t$  záviset na  $\zeta_t$ . K nalezení optimálního řízení tedy stačí v každém čase  $t$  uvažovat pouze dvourozměrný hyperstav  $H_t = (\eta_t, \beta_t)$ . Navíc můžeme bez újmy na obecnosti počítat optimální zásah pouze pro kladné hodnoty  $\eta_t$  a  $\beta_t$ . Optimální řízení tedy napočteme pouze pro kladné hodnoty  $y_t$  a  $\theta_t$ , pro ostatní možnosti pak díky tvaru (4.1) dostaneme požadovaný řídící zásah vhodnou volbou znaménka napočteného optimálního zásahu.

## 4.2 Srovnávané řídící algoritmy

V tomto oddílu jsou popsány řídící algoritmy, které budou posléze porovnány při řízení systému (4.1). Algoritmy jsou založené na principech uvedených v předešlé kapitole.

### 4.2.1 Klasický přístup k dynamickému programování

V článku [1] je problém řízení systému (4.1) řešen pomocí přímé aplikace numerických metod na řešení úlohy dynamického programovaní. Jde o schéma popsané v sekci 3.4. Prostor hyperstavů byl diskretizován do mřížky 64x64. Pro každý bod hyperstavu se napočítala očekávaná ztráta, mimo body mřížky se použila kubická interpolace. K numerické integraci byla použita klasická Simpsonova metoda. K nalezení minima se pak použila jednoduchá metoda při níž se každými třemi body na mřížce proložila parabola, nalezlo její minimum a to se pak testovalo, zda-li je globálním minimem očekávané ztráty.

Výslednou approximaci optimálního řízení pak autoři uvádějí jako

$$\nu_t = -\frac{0,56 + \beta_t}{2,2 + 0,08\beta_t + \beta_t^2}\eta_t - \frac{1,9}{1,7 + \beta_t^4} \quad (4.22)$$

První člen v (4.22) můžeme interpretovat jako modifikované opatrné řízení, druhý člen pak jako budící složku řízení.

### 4.2.2 Certainty equivalent control

Očekávaná ztráta (4.17) přejde v

$$V_t(\eta_t, \beta_t) = \min_{\nu_t} \{ \hat{\eta}_{t+1}^2 + V_{t+1}(\eta_{t+1}, \beta_{t+1}) \} \quad (4.23)$$

Střední hodnota výstupu je dle (4.15) rovna

$$\hat{\eta}_{t+1} = \eta_t + \beta_t \nu_t, \quad (4.24)$$

Optimální řídící zásah bude tedy pro každé  $\beta_t \neq 0$  roven

$$\nu_t = -\frac{\eta_t}{\beta_t}. \quad (4.25)$$

Pokud  $\beta_t = 0$ , pak to dle (4.11) znamená, že i  $\hat{\theta}_t = 0$  (to se může stát ačkoliv  $\theta \neq 0$ ). Aktuální očekávaná ztráta nezávisí na  $\nu_t$  a můžeme tedy volit libovolný řídící zásah bez vlivu na hodnotu očekávané ztráty. V takovém případě volíme za řídící zásah realizaci bílého šumu (velikost rozptylu bude upřesněna u konkrétního experimentu). Jedná se vlastně o jednoduchou aplikaci principu duálního řízení popsaného rovnicí (3.5).

Z tvaru optimálního řídícího zásahu (4.25) snadno zjistíme, že CEC je metodou neduálního. Pokud je totiž výstup systému na požadované hodnotě, řídící zásah nebude systém vychylovat za účelem lepší identifikace parametru  $\theta$ . Nicméně díky tomu, že máme k dispozici analytické vyjádření  $\nu_t$ , může být řízení pomocí metody CEC prováděno s minimálními výpočetními nároky. To může být v některých aplikacích rozhodující výhodou.

Aplikace metody CEC v podobě řídícího zásahu (4.25) je zjevně nevhodná pro malé hodnoty  $\beta_t$ . Metoda bude totiž generovat, příliš velké řídící zásahy bez ohledu na možnou přítomnost neurčitosti. Konkrétní výsledky budou prezentovány dále v práci.

### 4.2.3 Metoda opatrného řízení

Optimální řídící zásah je pro metodu opatrného řízení (caution control, CC) dán dle (4.20) jako

$$\nu_t = -\frac{\eta_t \beta_t}{1 + \beta_t^2}. \quad (4.26)$$

Všimněme se, že pro velké hodnoty  $\beta_t$  přejde optimální zásah pro metodu opatrného řízení (4.26) v optimální zásah metody CEC (4.25). Naproti tomu pro malé hodnoty  $\beta_t$  (tedy pro velké hodnoty neurčitosti v identifikaci parametru  $\theta_t$ , viz (4.11)) bude řízení podstatně konzervativnější. Opět se podařilo získat analytické vyjádření  $\nu_t$  a výpočet optimálního řízení pomocí metody CC může být prováděn velmi efektivně.

počet opakování algoritmu	$n_{pass}$	4
počet iterací algoritmu	$n_{iter}$	8
počet bodů v diskretizaci každé dimenze $H_t$	$n_g$	20
apriorní řídící strategie	$\mu_{0:N-1}$	0
počet kadnidátů na změnu řídícího zásahu	$m$	7
počáteční rozsah pro hledání optimálního řídícího zásahu	$\beta^{in}$	1
parametr pro redukci $\beta^{in}$ při opakování algoritmu	$\gamma$	0,9
parametr pro redukci $\beta^{in}$ při iterování algoritmu	$\lambda$	0,8
počet realizací pro odhad metodou Monte Carlo	$n$	20

Tabulka 4.1: Konkrétní volba parametrů algoritmu SIDP

#### 4.2.4 SIDP

Dle popisu (a následné transformace) systému (4.1) je pro výpočet optimální strategie pomocí algoritmu SIDP nutné diskretizovat dvoudimenzionální prostor nezávisle proměnných  $H_t = (\eta_t, \beta_t)$ . Implementace algoritmu byla provedena v souladu s oddílem 3.6.2. Konkrétní nastavení parametrů algoritmu zachycuje tabulka 4.1. Výpočet za daných parametrů trval v řadech desítek minut.

#### 4.2.5 Popis experimentu

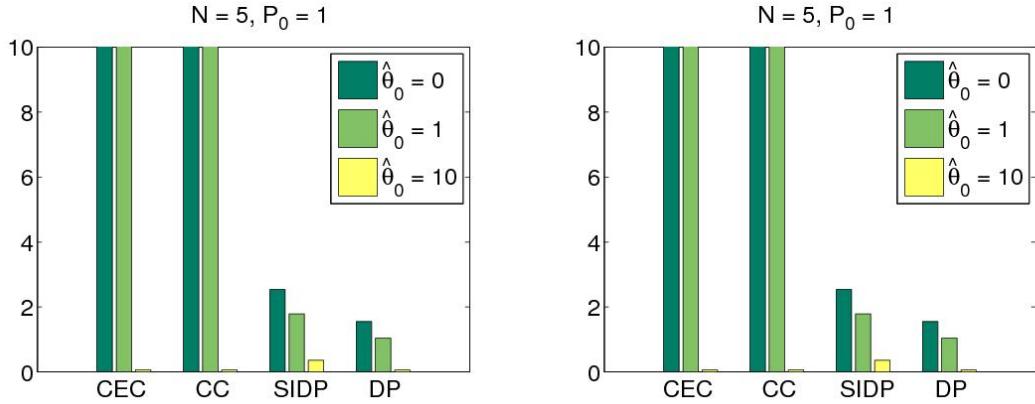
Systém (4.1) je možné v případě potřeby vhodně posunou či přeškálovat, není tedy potřeba uvažovat jiné hodnoty referenčního signálu a počátečního výstupu. Kvalitu výsledného řízení posuzujeme z hlediska celkové ztráty vygenerované podél horizontu délky  $N$  aplikací dané řídící strategie.

Řídící horizont byl v první sérii experimentů zvolen jako  $N_1 = 5$  v druhé pak  $N_2 = 10$ . Kvalita řízení byla testována vzhledem k různým hodnotám počátečního odhadu  $\theta$ , tedy k různým hodnotám  $(\hat{\theta}_0, P_0)$ . Ty byly postupně voleny z množiny  $\{10; 1; 0\} \times \{10; 1; 0, 1\}$ . Každá simulace byla opakována 1000x, uvedené hodnoty celkové ztráty jsou pak průměrem přes jednotlivé realizace.

Pro každé jednotlivé opakování simulace byla skutečná hodnota parametru  $\theta$  pro počáteční hodnoty  $(\hat{\theta}_0, P_0)$  zvolena jako první nenulová realizace náhodné veličiny s rozdělením  $N(\hat{\theta}_0, P_0)$ . Pro takto vygenerovanou hodnotu  $\theta$  byly postupně aplikovány výše popsané řídící algoritmy. Pro snížení vlivu náhodnosti při porovnání kvality řízení byly všechny realizace šumu (v rámci jednoho opakování simulace) v průběhu řízení jednotlivými algoritmy voleny stejně.

### 4.3 Srovnání jednotlivých přístupů

V této sekci jsou porovnány popsané algoritmy při řízení systému (4.1). Očekávaným výsledkem bylo, že v případě velké počáteční neznalosti systému bude duální řízení získané pomocí SIDP výrazně výhodnější oproti neduálním metodám. Ty zde zastupuje metoda opatrného řízení (CC) a metoda caution control (CEC). Pro srovnání



Obrázek 4.1: Výsledky simulace pro délku horizontu  $N = 5$ , rozptyl  $P_0 = 1$  a  $P_0 = 10$  a různé střední hodnoty  $\hat{\theta}_0$

je uveden výsledek získaný klasickým numerickým přístupem k dynamickému programování (DP) převzatý z [1]. Jak vyplývá z tvaru (4.22), jedná se rovněž o duální metodu. Očekává se, že výsledky získané pomocí klasického DP budou srovnatelné s výsledky získanými metodou SIDP. Nicméně jak bylo prověřeno v článku [11], srovnatelné výsledky dává SIDP již při desetinovém výpočetním čase. To je způsobeno tím, že se při použití metody SIDP diskretizuje jen ta část hyperstavu, která je v další iteraci algoritmu. Pro efektivní diskretizaci tedy stačí výrazně méně (ve výsledcích zde použitých 64x64 pro metodu DP, zatímco pro SIDP jen 20x20).

### 4.3.1 Výsledky simulace

Kvantitativní výsledky simulací zachycují obrázky 4.1 a 4.2. Kvalitativní pak série obrázků 4.3–4.6.

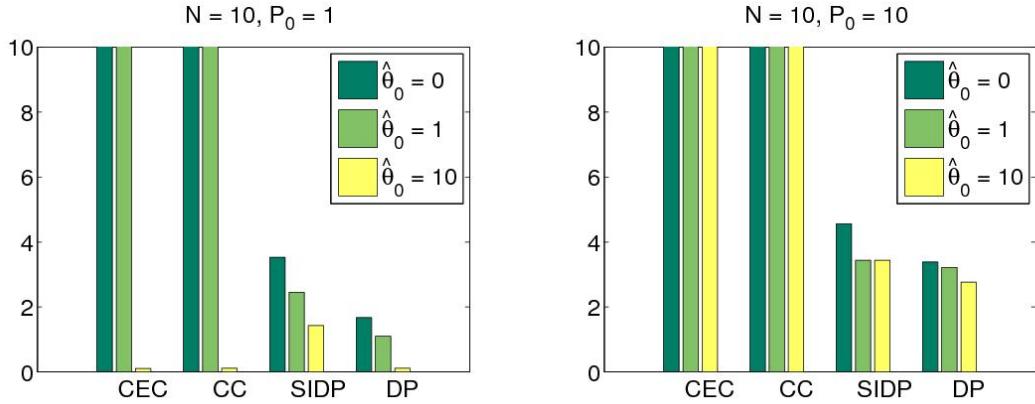
Na obrázku 4.1 jsou zachyceny výsledek pro délku řídícího horizontu  $N = 5$ , počáteční hodnoty rovptylu  $P_0 = 1$  a  $P_0 = 10$  a různé hodnoty  $\hat{\theta}_0$ , konkrétně pro hodnoty  $\{0, 1, 10\}$ .

První pozorovatelný výsledek pro případ  $P_0 = 1$  je, že neduální metody (CEC a CC) poskytují v průměru použitelné výsledky pouze pokud je hodnota parametru  $\theta$  dostatečně vzdálena od nuly, tedy pro počáteční odhad  $\hat{\theta}_0 = 10$ . V ostatních případech je řízení silně závislé na náhodných realizacích šumu a v průměru je takové řešení nepoužitelné. Oproti tomu duální metody (SIDP a DP) poskytují dobré řízení pro všechny testované kombinace  $(\hat{\theta}_0, P_0)$ .

Poznamenejme však, že pro hodnoty  $(\hat{\theta}_0, P_0) = (10, 1)$  je použití neduálních metod velmi vhodné. Dávají totiž srovnatelné výsledky s duálními metodami (v případě SIDP dokonce lepší) a to za mnohem nižších výpočetních nároků.

Pro počáteční hodnotu rovptylu  $P_0 = 10$  nebyly neduální metody úspěšné pro žadnou testovanou hodnotu  $\hat{\theta}_0$ . Obě duální metody pak v průměru opět dělají srovnatelné výsledky.

Srovnávací studie pro délku horizontu  $N = 10$  (obrázek 4.2) dopadla velice podobně



Obrázek 4.2: Výsledky simulace pro délku horizontu  $N = 5$ , rozptyl  $P_0 = 1$  a  $P_0 = 10$  a různé střední hodnoty  $\hat{\theta}_0$

jako v předchozím případě. Neduální metody v průměru opět fungovaly pouze pro nastavení  $(\hat{\theta}_0, P_0) = (10, 1)$ , tedy když byl skutečný parametr  $\theta$  dostatečně vzdálen od nuly. V tomto případě však dosahovaly velmi nízké ztráty.

Série obrázků 4.3 zachycuje výsledky řízení metodou certainty equivalence při jednotlivých simulacích pro různé kombinace  $(\hat{\theta}_0, P_0)$ . Uvedené histogramy ukazují, že ač se v mnoha případech podařilo pomocí metody CE navrhnout řídící strategii s celkově nízkou ztrátou, ve většině případů bylo řízení neúspěšné a vedlo k vysoké ztrátě. Jak již bylo zmíněno výše, vyjímkou tvoří pouze případ  $(\hat{\theta}_0, P_0) = (10, 1)$ , kdy je použití metody CE velmi vhodné.

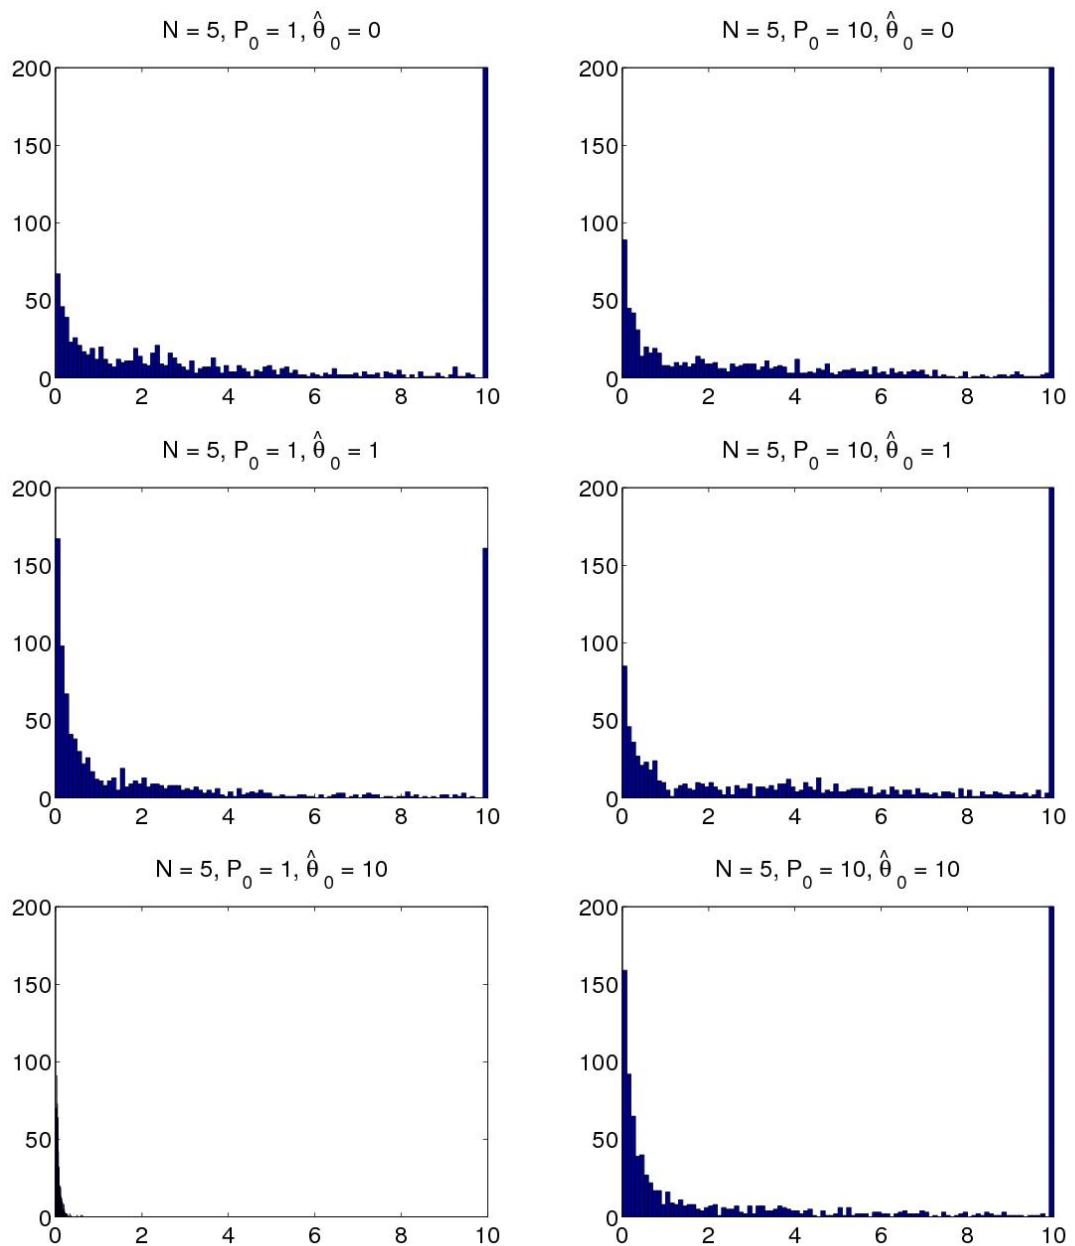
Na 4.4 jsou zobrazeny obdobné výsledky pro metodou cautious control. Oproti metodě CE můžeme pozorovat pokles výrazně špatného řízení pro hodnoty  $(\hat{\theta}_0, P_0) = (1, 1)$  a  $(\hat{\theta}_0, P_0) = (10, 10)$ . Nicméně metoda opatrného řízení se opět ukazuje reálně použitelná pouze pro případ  $(\hat{\theta}_0, P_0) = (10, 1)$ .

Výsledky pro jednotlivé simulace při řízení metodou SIDP jsou na obrázku 4.5. Hlavní rozdíl oproti předchozím dvěma metodám je znatelný pokles v počtu totálního selhání řízení. To se objevuje puze při hodnotách rozptylu  $P_0 = 10$  a i tehdy je podstatně nižší než v předchozích případech. Naproti tomu je v mnoha případech dosaženo ztráty, která je vyšší než při použití řízení pomocí CE a CC. Algoritmus SIDP tedy vychází v průměru lépe díky robustnosti vůči výrazné špatnému řízení.

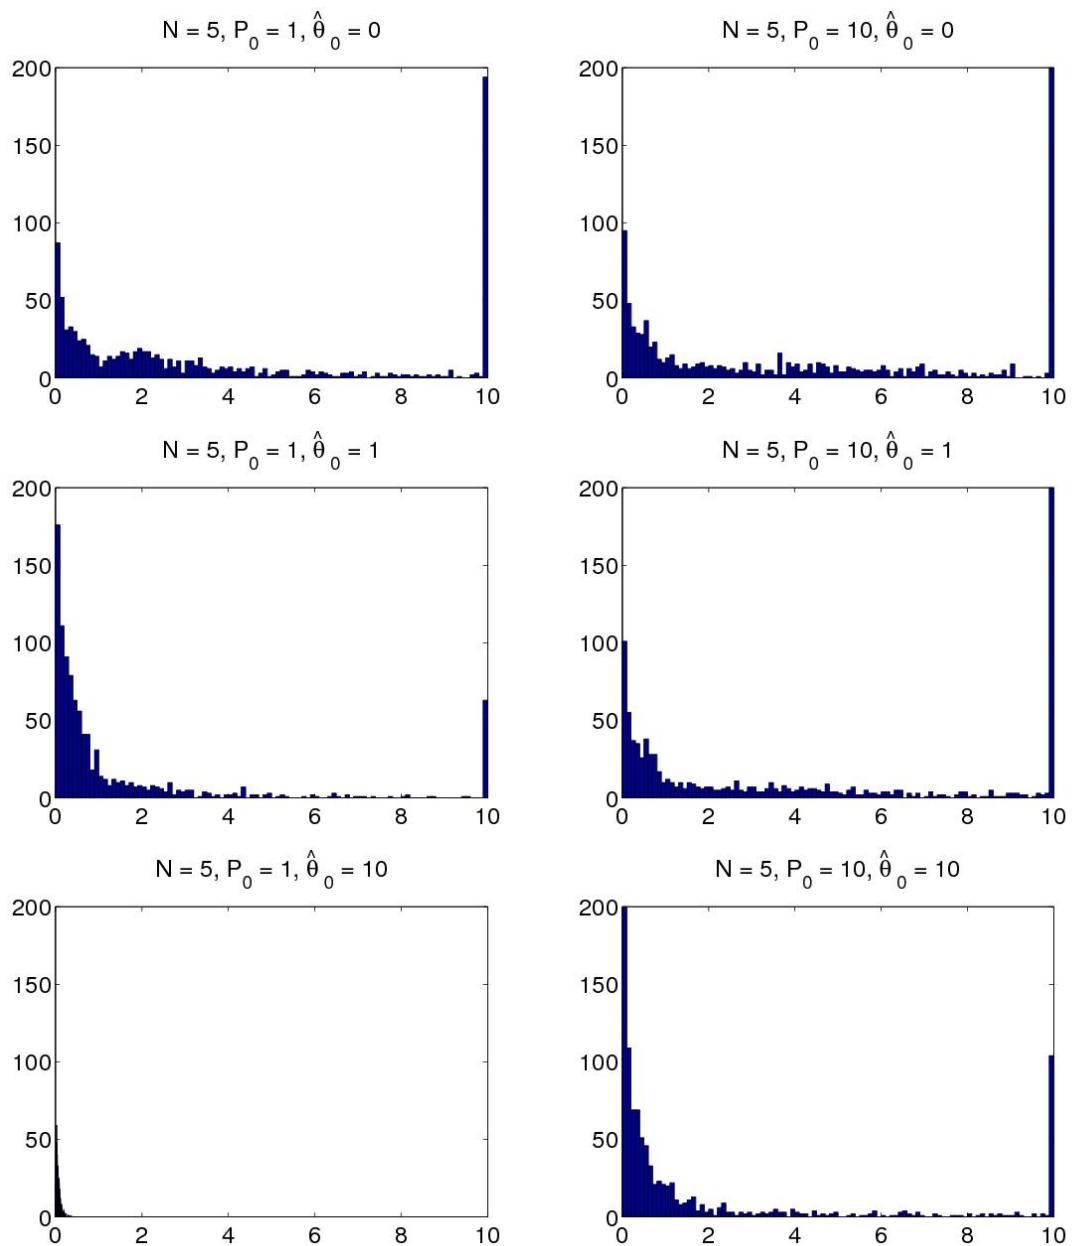
Histogramy pro metodu klasického numerického přístupu k řešení DP zobrazuje 4.6. Ačkoliv kvantitativně vychází řízení pomocí SIDP a DP velmi podobně, při kvalitativním porovnání pomocí histogramů si můžeme všimnout, že řízení metodou DP častěji nabývá nižší celkové ztráty než SIDP, ale rovněž i častěji selhává a dosahuje tak vysoké ztráty.

### 4.3.2 Shrnutí výsledků simulace

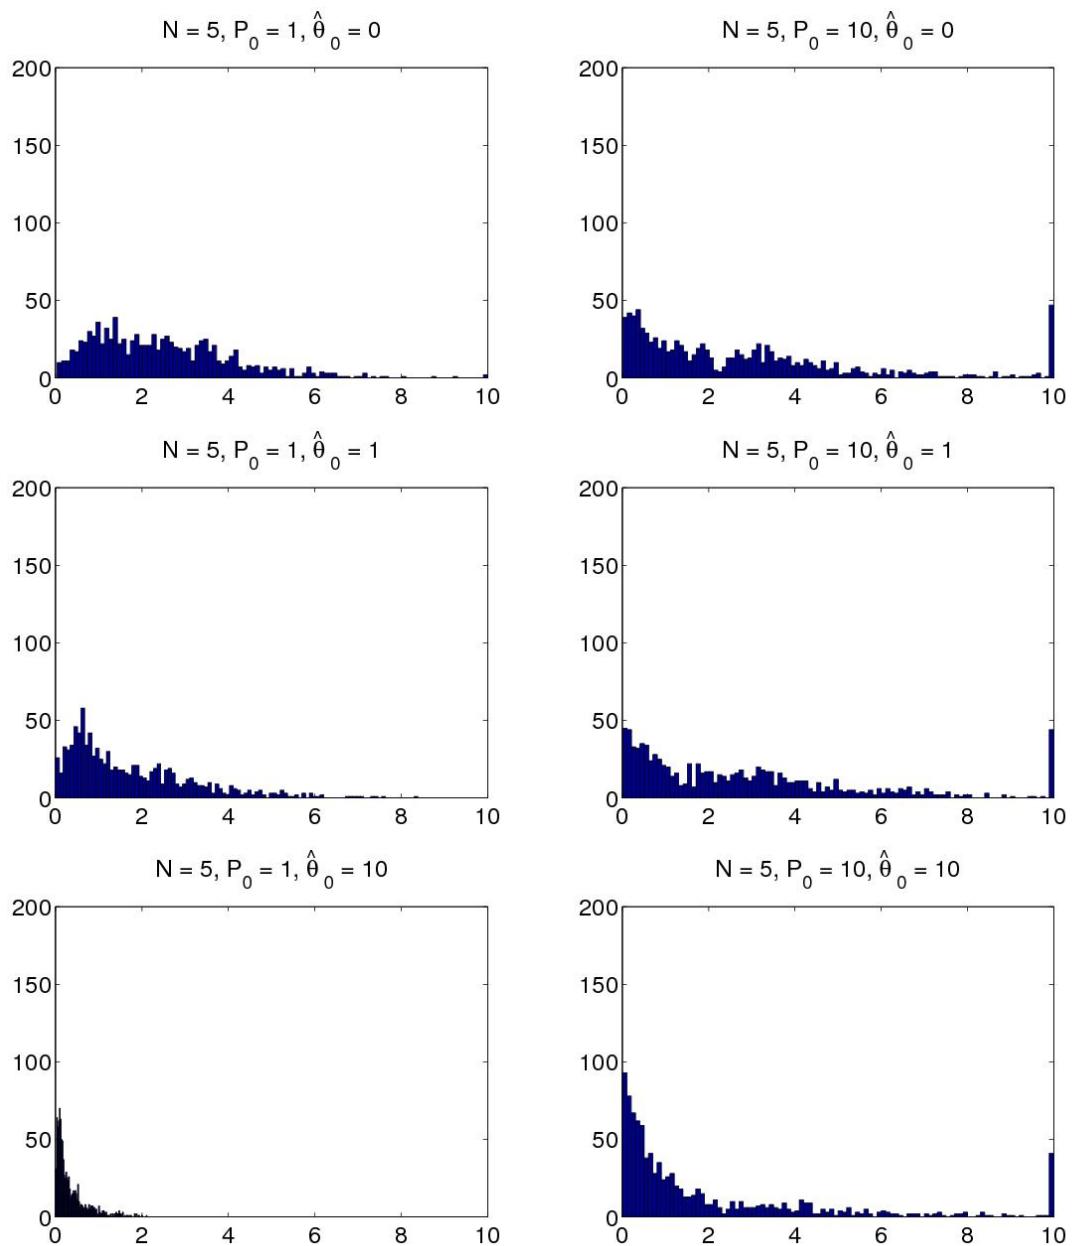
Dle provedených simulací vychází neduální metody (certainty equivalence a cautious control) použitelné pouze pro hodnoty parametrů  $(\hat{\theta}_0, P_0) = (10, 1)$ . V ostatních



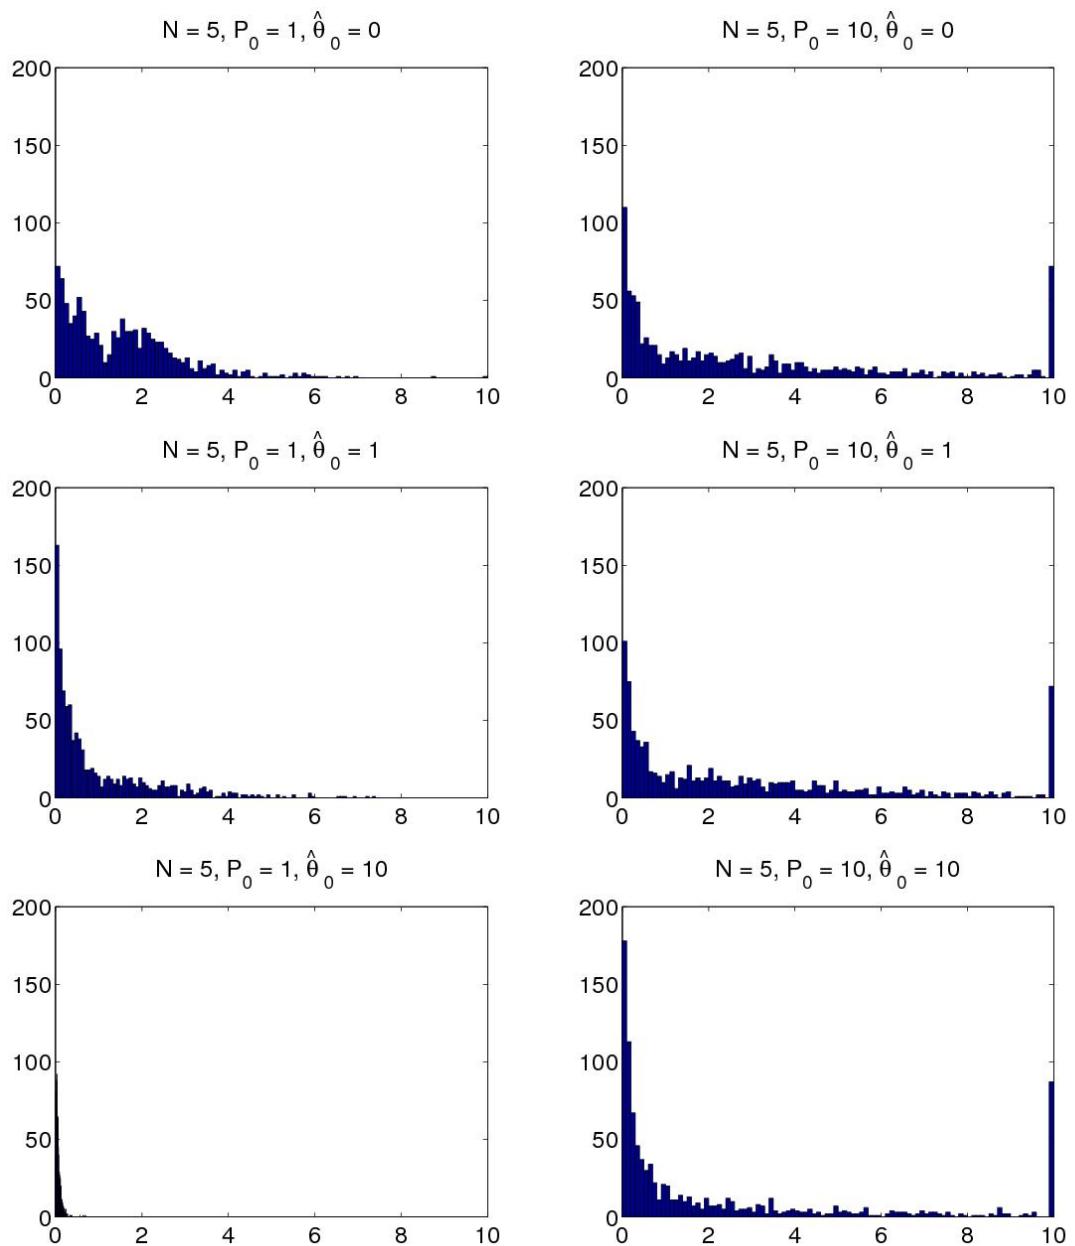
Obrázek 4.3: Výsledky jednotlivých simulací při řízení metodou certainty equivalence



Obrázek 4.4: Výsledky jednotlivých simulací při řízení metodou cautious control



Obrázek 4.5: Výsledky jednotlivých simulací při řízení metodou SIDP



Obrázek 4.6: Výsledky jednotlivých simulací při řízení metodou metodou DP

případech, se metody ukázaly jako nepoužitelné. Podle kvalitativního zkoumání to bylo způsobeno tím, že v mnoha případech, ztráta výrazně překročila rozumnou mez. Přesto se občas podařilo navrhnout úspěšné řízení.

Duální metody (numerické řešení DP převzaté z [1] a SIDP) dokázaly navrhnout úspěšné řízení pro libovolné hodnoty parametrů  $(\hat{\theta}_0, P_0)$ . Obě zmiňované metody pak dosahovaly obvykle kvantitativně stejných výsledků. Jediný výraznější rozdíl byl při řízení na horizontu délky  $N = 10$  pro rozptyl  $P_0 = 1$ . Tehdy si vedla lépe metoda DP. Metoda SIDP se ukázala jako robustnější, naproti tomu však čatěji dosahovala mírně vyšší ztráty než DP. Chování obou duálních metod tak vychází průměrně velmi podobné. Nutno však připomenout výsledek z [11], že SIDP dosahuje srovnatelného výsledku s DP již při zhruba desetinovém výpočetním čase.

# Závěr

Sem přijde zaver

# Seznam použitých zdrojů

- [1] K. J. Åström and A. Helmersson. Dual control of an integrator with unknown gain. *Computers & Mathematics with Applications*, 12(6):653–662, 1986.
- [2] G. Barequet and S. Har-Peled. Efficiently approximating the minimum-volume bounding box of a point set in three dimensions. *Journal of Algorithms*, 38:91–109, 2001.
- [3] R. Bellman. *Dynamic Programming*. Princeton University Press, 1957.
- [4] D.P. Bertsekas. *Dynamic Programming and Optimal Control, vol. 1*. Athena Scientific, 1995.
- [5] AA Feldbaum. *Optimal control systems*. Academic Press, New York, 1965.
- [6] J.M. Hammersley and D.C. Handscomb. *Monte carlo methods*. Taylor & Francis, 1964.
- [7] R.E. Kalman. A new approach to linear filtering and prediction problems. *Journal of basic Engineering*, 82(1):35–45, 1960.
- [8] R. Luus. *Iterative dynamic programming*. CRC Press, 2000.
- [9] B.L. Nelson, J. Swann, D. Goldsman, and W. Song. Simple procedures for selecting the best simulated system when the number of alternatives is large. *Operations Research*, 49(6):950–963, 2001.
- [10] V. Peterka. Bayesian system identification. *Automatica*, 17(1):41–53, 1981.
- [11] A.M. Thompson and W.R. Cluett. Stochastic iterative dynamic programming: a Monte Carlo approach to dual control. *Automatica*, 41(5):767–778, 2005.
- [12] B. Wittenmark. Adaptive dual control. *Control Systems, Robotics and Automation, Encyclopedia of Life Support Systems (EOLSS), Developed under the auspices of the UNESCO*, 2002.