


**ČESKÉ VYSOKÉ
UČENÍ TECHNICKÉ
V PRAZE**

**FAKULTA
STROJNÍ**



**TEZE
DISERTAČNÍ
PRÁCE**

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

FAKULTA STROJNÍ

ÚSTAV přístrojové a řídicí techniky

TEZE DISERTAČNÍ PRÁCE

Adaptivní metody pro řízení hydraulických systémů

Ing. Martin Veselý

Doktorský studijní program: Strojní inženýrství

Studijní obor: Technická kybernetika

Školitel: Doc. Ing. Ivo Bukovský Ph.D.

Teze disertace k získání akademického titulu "doktor", ve zkratce "Ph.D."

Praha

Březen 2021

Název anglicky: Adaptive Control Method of Hydraulics Systems

Disertační práce byla vypracována v kombinované formě doktorského studia na Ústavu přístrojové a řídicí techniky Fakulty strojní ČVUT v Praze.

Disertant: Ing. Martin Veselý

Ústav přístrojové a řídicí techniky, Fakulta strojní ČVUT v Praze
Praha, Technická 4, Praha 6

Školitel: Doc. Ing. Ivo Bukovský Ph.D.

Ústav mechaniky, biomechaniky a mechatroniky, Fakulta strojní
ČVUT v Praze
Praha, Technická 4, Praha 6

Oponenti:

Teze byly rozeslány dne:

Obhajoba disertace se koná dne v hod.

v zasedací místnosti č. 17 (v přízemí) Fakulty strojní ČVUT v Praze,
Technická 4, Praha 6

před komisí pro obhajobu disertační práce ve studijním oboru Technická
kybernetika.

S disertací je možno se seznámit na oddělení vědy a výzkumu Fakulty strojní
ČVUT v Praze, Technická 4, Praha 6.

prof. Ing. Tomáš Vyhlídal, Ph.D.

předseda oborové rady oboru Technická kybernetika
Fakulta strojní ČVUT v Praze

Anotace

Adaptivní metody pro řízení hydraulických systémů

Tato práce se zabývá adaptivním řízením hydraulických systémů s elektromagneticky řízenými proporcionálními ventily. Jsou uvažovány vlastnosti ventilů, které jsou proměnné v čase, jako je zesílení ventilu, hysterese a mrtvá pásma šoupátka. Tato práce prezentuje výzkum návrhu regulátorů, které jsou schopny měnit své parametry v závislosti na změně chování proporcionálního ventilu v reálném čase. Pro řízení byla zvolena strategie řízení s referenčním modelem a s využitím polynomiálních neuronových jednotek. Práce předkládá návrh řešení problému učení vah polynomiálních neuronových jednotek v reálném čase použité jako regulátor. Za tímto účelem je v práci využit sériově-paralelní referenční model a nové sestavení kritériální funkce. Práce ukazuje možnost rozšíření kritériální funkce o statické zesílení a offset. Řízení s referenčním modelem je porovnáváno s prediktivním řízením. Schopnost adaptace regulátoru v reálném čase je testována v simulacích. Schopnost řídit reálný systém byla testována na hydraulickém standu simulující hydraulický lis.

Annotation

Adaptive Control Method of Hydraulics Systems

This thesis presents adaptive control method of hydraulic systems with electromagnetic proportional valves. Some valve properties are considered time variable such as valve gain, hysteresis and valve's dead zones. This thesis also presents research of the design of controllers that are able to change their parameters in response to change in proportional valve behavior in real time. Model Reference Adaptive Control using polynomial neural units was chosen as the control strategy. This work proposes solution of the problem of weight learning of polynomial neural units as a controller in real time. A static reference model and new built criterion function are used for this purpose. The criterion function can also be extended with static gain and offset. Reference model adaptive control is compared with predictive model control strategy. The ability of the controller to learn in real time was tested in simulation. The ability to control real system was tested on hydraulic stand simulating a hydraulic press.

Obsah

1. Úvod.....	1
2. Současný stav poznání.....	2
2.1. Hydraulické systémy s proporcionálními ventily.....	2
2.2. Adaptivní algoritmy řízení s referenčním modelem.....	3
2.2.1. Polynomiální modely použité při řízení.....	3
2.2.2. Přístupy adaptivních algoritmů řízení s referenčním modelem....	4
2.2.3. Učení vah neuronů metodou gradient descent.....	5
2.3. Závěr rešeršní části studie.....	6
3. Cíle disertační práce.....	6
4. Teorie.....	7
4.1. HONU jako model řízené soustavy.....	7
4.2. Takagiho-Sugenův HONU modely.....	7
4.3. Normalizovaný Gradient Descent.....	8
4.4. Normalizovaný stochastic mini-batch gradient descent.....	9
4.5. Řízení se sériově-paralelním referenčním modelem.....	9
4.6. Matematický popis HONU jako MRAC regulátor.....	10
4.7. Matematický popis T-S HONU jako MRAC regulátor.....	11
4.8. Učící algoritmus GD pro adaptaci vah HONU jako regulátoru.....	11
4.9. Gradient v GD pro HONU jako regulátor a LNU jako model systému. 13	
4.10. Gradient v GD pro HONU jako regulátor a HONU jako model systému	14
4.11. Gradient v GD pro HONU jako regulátor a T-S HONU jako model	14
systému.....	14
4.12. Rozšíření kriteriální funkce o statické zesílení a posunutí.....	15
4.13. Řízení adaptivním regulátorem MPC se sériově-paralelním	16
referenčním modelem.....	16
5. Experimentální část.....	17
5.1. Identifikace.....	18
5.2. Řízení modelu hydraulického systému.....	18
5.3. Řízení hydraulického standu.....	22
6. Závěr.....	24
Vlastní publikace.....	27
Publikace.....	28
Curriculum Vitae.....	32

1. Úvod

Hydraulické systémy skládající se z 4-cestného proporcionálního ventilu a lineárního hydraulického motoru jsou v praxi převážně řízeny klasickými regulátory (algoritmy řízení), jakými jsou například stavové řízení nebo PID řízení, v základních nebo přizpůsobených verzích. Tyto regulátory jsou založeny na předpokladu, že chování těchto systémů je blízko chování soustav lineárních diferenciálních rovnic a že se toto chování nemění během procesu nebo během životnosti stroje. Obvyklými kritérii řízení u těchto systémů je rychlost ustálení na žádané hodnotě, velikost překmitu, energetická náročnost a robustnost.

Hlavní motivací pro vývoj řídicích systémů je cena:

- Cena za dosažení toho, aby chování systému bylo blízko lineárnímu. Je snaha nahradit konstrukčně složité prvky za prvky jednodušší a tím i levnější. Je požadováno, aby takový systém byl stejně kvalitně uřízen.
- Cena za pracovní čas kvalifikovaného inženýra, který sestaví vhodný regulátor pro daný systém. Cílem je, aby odborníci na dané systémy nemuseli být zároveň odborníky v řízení a nemuseli řízení příliš rozumět.
- Cena za doladění regulátoru pro každý kus stroje zvlášť. Je snaha, aby bylo třeba pouze jedno jediné nastavení a regulátor se sám doladil pro daný stroj.
- Cena za servis stroje během jeho životnosti. Je požadováno použití jednodušších prvků, které jsou méně náročné na údržbu. Regulátor by se měl adaptovat během procesu a životnosti stroje.


I malá úspora na jednom stroji může znamenat velkou úsporu při větších sériích. To je motivací pro návrh adaptivních nelineárních regulátorů pro řízení hydraulických systémů tak, aby nebylo třeba regulátor každého stroje seřizovat zvlášť, nebyl třeba jeho následný servis během životnosti stroje, výsledné chování systému s regulátorem bylo stále stejné během pracovního procesu i během životnosti stroje a nebyly kladeny vyšší nároky na lineární chování hydraulických komponentů.

2. *Současný stav poznání*

2.1. *Hydraulické systémy s proporcionálními ventily*

Článek [7] se zabývá možnostmi modelování třecích sil. Je v něm ukázáno více příčin vzniku třecích sil a jsou zde sestaveny i výsledné modely tření. Článek se dále zabývá problematikou modelování a simulování tohoto systému, zejména kvůli jeho nespojitosti při nulové rychlosti, při níž třecí síla roste až do limitní hodnoty tak, aby zabránila možnému pohybu. Je zde navrženo zjednodušení a nespojitost v nulové rychlosti je nahrazena velkým nárůstem třecí síly s rychlostí. V [11] je ukázáno, že právě tření šoupátka a kotvy elektromagnetu v rozváděči způsobuje hysterezi ventilu.

Datasheet proporcionálního ventilu SP08-47C [8] společnosti Hydraforce udává hysterezi ventilu do 7%. Je zde uvedeno změna odporu cívky 24% při změně její teploty z 20 °C na 40 °C. S rostoucím odporem pak dle Ohmova zákona klesá i proud protékající cívku. Cívka je zahřívána právě elektrickým proudem, který cívku protéká. Není-li proud cívku regulován, cívka se postupně zahřívá a klesá elektromagnetické pole a cívka tzv. vadne.



Obr. 1: *Závislost průtoku na řídicím proudu ventilu SP08-47C společnosti Hydraforce při vstupním tlaku 240 bar a frekvenci PWM signálu 100 Hz. Šedou barvou jsou vyznačena rozsah průtoku pro daný řídicí proud.*

Na obr.1 je závislost průtoku ventilem na vstupním řídicím proudu s vyznačenými rozsahy průtoku pro zvolený řídicí proud. Velikost pole je dána jak hysterezí ventilu, tak i nejistotou velikostí offsetu (minimálním

proudem při kterém začne růst průtok ventilem). U ventilu SP08-47C je tento průtokový rozsah 50% jmenovitého průtoku.

Předřadných řídicími elektronik EVDR-0201 od společnosti Hydraforce [9] Elektroniky jednak eliminují hysterezi ventilů pomocí frekvence PWM řídicího signálu v řádu 40-450 Hz. Vhodná frekvence způsobí malé vibrace šoupátka ventilu, které mají zanedbatelný vliv na průtok ventilem, ale zapříčiní dynamické mazání šoupátka a kotvy elektromagnetu. Dynamické mazání eliminuje tzv. suché tření a tím i hysterezi. Druhým účelem těchto elektronik je odstranění závislosti statických charakteristik ventilu na teplotě cívky elektromagnetu. Síla elektromagnetu, která určuje polohu šoupátka, je při konstantním napětí v cívkách elektromagnetů závislá na elektrickém proudu. Proto je zde použito zpětnovazebné řízení proudu procházejícím cívkou elektromagnetu.

2.2. Adaptivní algoritmy řízení s referenčním modelem

Při adaptivním řízení regulátor uzpůsobuje (adaptuje) své chování v závislosti na změnách chování řízeného systému tak, aby se chování uzavřeného regulačního obvodu blížilo chování požadovanému. U regulátorů využívající vnitřní matematický model řízeného systému se i tento model musí adaptovat (přizpůsobit své parametry, změnit svou strukturu) nebo vyměnit za jiný model. Proto je následující podkapitola nejprve věnuje modelům, které jsou vhodné jako modely řízeného systému, tak použitelné jako samotný regulátor.

2.2.1. Polynomiální modely použité při řízení

Článek [11] porovnává použití QNU, QNN a MLP při identifikaci parní turbíny a kotle. Je zde analyzován problém růstu počtu vah s počtem vstupů a jako možné řešení je zde navrženo vytvoření QNN bez skryté vrstvy. Dále je zde ukázáno postupné učení QNN metodou Levenberg-Marquardt. Je zde rovněž diskutována rychlost učení a zmíněn problém více lokálních minim optimalizační funkce při učení MLP, což se netýká QNU. Rovněž ukazuje i možné použití dvouvrstvé QNN nebo kombinace QNU a LNU i jako regulátoru, za účelem snížení výpočetní náročnosti.

Takagiho-Sugenův model [13] reprezentuje fuzzy modely s numerickým výstupem. Na rozdíl od Mandaniho fuzzy modelu [14] má aproximační schopnost omezenou, avšak lze lépe analyzovat jeho vlastnosti včetně stability. Vytvoření fuzzy relací lze buď sestavit ručně pomocí expertních znalostí, nebo identifikací fuzzy relací z dat.

LOLIMOT (Local Linear Model Tree) [15] je strategie identifikací fuzzy relací z data. Je založena na ortogonálním dělení vstupního prostoru, a to vždy podle oblasti fuzzy relace, která se nejvíce podílí na celkové chybě modelu. Testuje se rozdělení této oblasti na 2 stejně velké části podle všech fuzzy parametrů. Jako výsledné rozdělení je vzato to, které nejvíce zmenšilo chybu celého modelu. Iteračním způsobem se pak prostor dělí, dokud není dosaženo požadované přesnosti modelu, nebo maximálního povoleného množství lokálních modelů. Výhodou dané metody je, že jsou vylimitovány pouze ty fuzzy parametry, které mají vliv na schopnost aproximovat systém. Oproti výše zmíněným metodám vede na menší počet lokálních modelů.

2.2.2. Přístupy adaptivních algoritmů řízení s referenčním modelem

Článek [16] shrnuje poznatky ze své doby o možných strukturách řízení s referenčním modelem. Jsou zde ukázány dva směry adaptivního řízení. Jednak nepřímé adaptivní systémy, kde adaptace parametrů regulátoru jsou založeny na on-line identifikaci řízeného systému, následovanou optimalizačními parametry regulátoru. A též přímé adaptivní systémy, kde adaptace parametrů regulátoru je založena na on-line minimalizaci kritériální funkce. Řízení s referenčním modelem může být založeno na obou principech. V článku jsou prezentovány dva přímé adaptivní systémy s referenčním modelem, a to se sériovým RM a paralelním RM. Z obou předcházejících struktur MRAS je pak ukázána možnost sestavení tzv. sériově-paralelního referenčního modelu. Je uvedeno, že tato struktura zvýší rychlost učení, na druhou stranu rychlost učení bude omezena velikostí šumu.

V knize [17] jsou ukázány základní směry adaptivního řízení, tj. dopředné, přímé a nepřímé zpětnovazebné adaptivní řízení. Je zde vyslovena základní hypotéza adaptivního řízení: Přizpůsobovat parametry regulátoru tak, aby regulační obvod měl stále námi požadované chování, a to i přes probíhající změny v řízeném systému a poruch působící na řízený systém. Pro přímé adaptivní řízení s referenčním modelem (MRAC) jsou zde uvedeny základní předpoklady pro určování parametrů regulátoru. Je zde ukázána i modifikace referenčního sériově-paralelního modelu, kde výstup z referenčního modelu je počítán z žádané hodnoty a předchozích hodnot řízeného modelu (*Obr. 1*).

V kapitole knihy [18] je ukázána aplikace referenčního modelu pro řízení strategií MPC. Je zde ukázán princip referenčního modelu, který se v každém čase reinitializuje. Je předpokládáno, že predikovaný průběh žádané hodnoty nebude optimální z důvodu nepřesného výpočtu akčních signálů a predikovaného průběhu řízeného systému. Tím že je provedena reinitializace, referenční model akceptuje aktuální průběh regulované

veličiny a uvede dál novou trajektorii, kterou by se měla regulovaná veličina vydat. Pokud je řízen systém se vstupním dopravním zpožděním, reinicializace proběhne až po predikci regulované veličiny o toto zpoždění. V kapitole je uvedeno, že takto použitý referenční model lze interpretovat jako požadované chování referenčního modelu. Porovnáním této kapitoly se sériově-paralelním modelem použitým v [16] a [17] se jedná o stejný princip použití referenčního modelu. U strategie řízení MRAC je provedena predikce pouze o jeden časový krok.

2.2.3. Učení vah neuronů metodou gradient descent

Gradientní metody (bez rozšíření) hledají lokální extrémy funkcí. Vycházejí z vhodně zvolené kriteriální funkce, která nabývá svého minima právě pro optimální stav. Při učení neuronových sítí je kriteriální funkce obvykle sestavena tak, aby nabývala svého minima právě při nulové referenční odchylce e (odchylka mezi žádoucí odezvou a odezvou neuronové sítě). Hledá takové hodnoty optimalizačních parametrů, které sníží hodnotu kriteriální funkce. Kriteriální funkce bývá sestavena, jako kvadratická funkce a to buď globální chyby (2.2) [20], chyby v daném časovém kroku (2.3) [21], nebo jako dávkové chyby (2.4) [22].

$$Q_{GE} = \frac{1}{2} \sum_{i=k_0}^k (e_{(i)})^2 \quad (2.1)$$

$$Q_{LE(k)} = \frac{1}{2} (e_{(k)})^2 \quad (2.2)$$

$$Q_{BE(k)} = \frac{1}{2} \cdot \sum_{i=1}^m e_{i(k|i)}^2 \quad (2.3)$$

Změnu hodnot optimalizačních parametrů se provádí proti směru gradientu kriteriální funkce [19]:

$$\mathbf{w}_{(k)} = \mathbf{w}_{(k-1)} - \mu_{(k)} \cdot \frac{\partial Q_{(k)}}{\partial \mathbf{w}_{(k-1)}} \quad (2.4)$$

Kde μ je parametr učení (learning rate), na jehož velikost závisí rychlost učení ale i stabilita učení či schopnost dosažení optima. Optimalizační metoda gradient descent je proto dále vylepšena optimalizací parametru učení μ v každém časovém kroku k .

2.3. Závěr rešeršní části studie

V kap.2.1 jsou uvedeny vlastnosti hydraulických systémů významné pro řízení. Zejména je pak ukázán problém hystereze rozváděče, offsetu a závislost statických charakteristik ventilů na teplotě cívky elektromagnetu.

Nebylo nalezeno čistě softwarové řešení, které by odstranilo nutnost použití předřadných elektronik a jejich nutnost jejich nastavení pro každý ventil zvlášť.

Byl zkoumán tzv. sériově-paralelní (statický) referenční model, vedoucí ke vnučování chování referenčního modelu uzavřenému regulačnímu obvodu a učení regulátoru v reálném čase. U regulátorů využívající jednotky HONU byla dosud vždy použita pouze varianta s paralelní referenční model.

3. Cíle disertační práce

Práce si klade za cíl vyřešit problém nutnosti využití předřadných řídicích elektronik sloužících k potlačení hystereze proporcionálních ventilů a jejich závislosti zesílení ventilů na teplotách cívek elektromagnetu.

Hypotéza: Pokud by bylo vyřešeno učení regulátoru s jednotkami HONU v reálném čase pomocí sériově-paralelního referenčního modelu, regulátor by tím byl schopen dostatečně rychle měnit své chování v reálném čase, tak aby reagoval na změny chování hydraulického systému.

Z hypotézy byli stanoveny následující cíle disertační práce:

Cíl 1: *Vytvoření nového zrychleného algoritmu učení, pro regulátory s referenčním modelem, využívající polynomiální neuronové jednotky HONU, použitím adaptivního regulátoru s modifikovaným sériově-paralelním referenčním modelem.*

Cíl 2: *Vytvoření postupu adaptace řízení, sestavení korektního učícího algoritmu pro HONU jako regulátor se sériově-paralelním referenčním modelem a vyřešení problému gradientní metody pro výpočet vah HONU jako regulátor.*

Cíl 3: *Sestavení regulátoru se zvýšenou rychlostí učení pro řízení hydraulického lisu.*

4. Teorie

4.1. HONU jako model řízené soustavy

Neuronové jednotky vyšších řádů HONU byly definovány v [24], a dále bez agregační funkce [10] jsou ukázány v Tab.1.

Tabulka 1: Neuronové jednotky HONU

Název	Rovnice	r
LNU	$y_{(k)} = \sum_{i=1}^n w_i \cdot x_{i(k)}$	1
QNU	$y_{(k)} = \sum_{i=1}^n \sum_{j=i}^n w_{ij} \cdot x_{i(k)} \cdot x_{j(k)}$	2
CNU	$y_{(k)} = \sum_{i=1}^n \sum_{j=i}^n \sum_{g=j}^n w_{ijg} \cdot x_{i(k)} \cdot x_{j(k)} \cdot x_{g(k)}$	3

Kde y je výstup z neuronu, \mathbf{W} je r -rozměrný tenzor neuronových vah w , \mathbf{x} je vstupním vektorem do neuronu, který lze pro dynamický systém s jedním stupněm volnosti zapsat např. jako vektor zpožděných vstupů a výstupů ze systému následovně:

$$\mathbf{x}_{(k)} = [1, y_{(k-n)}, \dots, y_{(k-1)}, u_{(k-m-\tau+1)}, \dots, u_{(k-\tau)}]^T \quad (4.1)$$

Kde n je počet zpožděných výstupů, m je počet zpožděných vstupů a τ je diskrétní zpoždění vstupů. Neuronové váhy \mathbf{W} použité v *tab.1* jsou tenzorem řádu r . Z praktických důvodů lze HONU řádu r přepsat jako násobení vektorů:

$$y_{(k)} = \mathbf{w} \cdot \mathbf{colx}_{(k)} \quad (4.2)$$

Kde sloupcový vektor \mathbf{colx} je kombinací členů vstupního vektoru (4.1).

4.2. Takagiho-Sugenův HONU modely

Použitím HONU ve tvaru (4.3) jako modelů konsekventu, lze zapsat Takagi-Sugenov (T-S) HONU-fuzzy model v následujících tvarech [5]:

$$\begin{aligned} y_{n(k)} &= \sum_{i=1}^d \phi_i \cdot y_{i(k)} = \sum_{i=1}^d \phi_i \cdot \mathbf{w}_i \cdot \mathbf{colx}_{(k)} \\ &= \phi \cdot \mathbf{W} \cdot \mathbf{colx} \\ &= \mathbf{w} \cdot \mathbf{colx}_{TS(k)} \end{aligned} \quad (4.3)$$

$$\mathbf{colx}_{TS(k)} = \left[\phi_1 \cdot \mathbf{colx}_{(k)}^T, \phi_2 \cdot \mathbf{colx}_{(k)}^T, \dots, \phi_d \cdot \mathbf{colx}_{(k)}^T \right]^T \quad (4.4)$$

Kde d je počet lokálních modelů HONU. ϕ je normalizovaný vektor měr příslušností a lze jej spočítat podle měr příslušností β , a to následovně:

$$\phi_j = \frac{\beta_j}{\sum_{i=1}^d \beta_i} \quad (4.5)$$

Pro výpočet měr příslušností byli použity Gaussovy funkce:

$$\beta_i = e^{\sum_{p=1}^P (z_{(p)} - S_{(i,p)}) \cdot \sigma^{-2}} \quad (4.6)$$

Kde S je střed Gaussovy funkce a σ udává šířku funkce. z je hodnota fuzzy parametru p . Fuzzy relace (volba S, P a σ) byly sestaveny strategií LOLIMOT [15].

4.3. Normalizovaný Gradient Descent

Normalizovaný gradient descent (NGD) je gradientní optimalizační metoda hledající lokální extrém. Cílem identifikace je, aby se výstup z modelu $y_{(k)}$ blížil měřené hodnotě řízeného systému $y_{ref(k)}$, a to v libovolném stavu. Obvykle je používána následující kriteriální funkce [20]:

$$Q_{(k)} = \frac{1}{2} e_{(k)}^2 = \frac{1}{2} (y_{ref(k)} - y_{(k)})^2 \quad (4.7)$$

Samotný algoritmus NGD má následující má pro učení vah následující podobu [12]:

$$\mathbf{w}_{(k)} = \mathbf{w}_{(k-1)} - \mu_{(k)} \cdot \frac{\partial Q_{(k)}}{\partial \mathbf{w}_{(k-1)}} \quad (4.8)$$

O velikosti změny velikosti vah rozhoduje součinitel rychlosti učení μ . Hodnota $\mu_{(k)}$ může být stanovena tak, aby kriteriální funkce (4.7) po úpravě vah $\tilde{Q}_{(k)}$ byla minimální. $\mu_{(k)}$ lze pak spočítat metodou nejmenších následující podmínkou [53]:

$$\frac{\partial \tilde{Q}_{(k)}}{\mu_{(k)}} = 0 \quad (4.9)$$

Pro učení HONU jako modelu řízeného systému lze pak odvodit následující vztah pro normalizovaný koeficient učení:

$$\mu_{(k)} = \frac{\mu_{norm}}{\mathbf{colx}_{(k)}^T \cdot \mathbf{colx}_{(k)} + \epsilon} \quad (4.10)$$

Kde $\mu_{norm} \in (0, 2)$ a maximální rychlosti učení je dosaženo při $\mu_{norm} = 1$.

4.4. Normalizovaný stochastic mini-batch gradient descent

Tato podkapitola vychází ze studie [4]. Normalizovaný mini-batch gradient descent je gradientní metoda s normalizovaným koeficientem učení a kriteriální funkcí ve tvaru (4.11) [23], kde je zvolena m náhodných vzorů (dávka) v intervalu $\langle k - h + 1, k \rangle$. Kde h je šířka okna.

$$\begin{aligned}
 Q_{(k)} &= \frac{1}{2} \cdot \sum_{i=1}^m e_{i(k)}^2 = \frac{1}{2} \cdot \mathbf{e}_{(k)}^T \cdot \mathbf{e}_{(k)} \\
 &= \frac{1}{2} \cdot \sum_{i=1}^m (y_{ref\ i(k)} - y_{i(k)})^2 \\
 &= \frac{1}{2} \cdot \sum_{i=1}^m (y_{ref(k)} - \mathbf{w}_{(k)} \cdot \mathbf{colx}_{i(k)})^2
 \end{aligned} \tag{4.11}$$


Pro učení HONU jako modelu řízeného systému lze pak odvodit následující vztah pro normalizovaný koeficient učení, kde je vypočítáno dle 4.13:

$$\mu_{(k)} = \mu_{norm} \cdot \frac{\mathbf{e}_{(k)}^T \cdot \mathbf{J} \cdot \mathbf{J}^T \mathbf{e}_{(k)}}{\mathbf{e}_{(k)}^T \cdot (\mathbf{J} \cdot \mathbf{J}^T)^2 \mathbf{e}_{(k)} + \epsilon} \tag{4.12}$$

$$\mathbf{J}_{(k)} = \frac{\partial \mathbf{y}_{(k)}}{\partial \mathbf{w}_{(k)}} = \begin{bmatrix} \mathbf{colx}_{i=1(k)}^T \\ \vdots \\ \mathbf{colx}_{i=m(k)}^T \end{bmatrix} \tag{4.13}$$


4.5. Řízení se sériově-paralelním referenčním modelem

Referenční model (RM) slouží k nastavení parametrů regulátoru nebo přímo k výpočtu akčního zásahu. Při použití paralelního referenčního modelu (obr.2) se jedná o úlohu vnucování trajektorie v čase uzavřenému regulačnímu obvodu (URO). Paralelní referenční model je dynamický, jeho výstup záleží pouze na žádané hodnotě d , čase a počátečních podmínkách. Nezávislost jeho výstupu na okolí ho činí vhodným pro úlohy, kdy je žádaná hodnota funkcí času. Jsou to úlohy kooperujících systémů, jako například navádění rakety na vesmírnou stanici obíhající kolem země, navádění rakety k sestřelení jiné letící rakety, nebo kooperující roboti.



Obr. 2: Paralelní referenční model

Tato práce je zaměřena na sériově-paralelní referenční model (obr.3b). Kde RM slouží ke vnučování chování RM uzavřenému regulačnímu obvodu (URO). Na základě vzniklé odchylky mezi výstupem z RM a řízeného systému v daném čase, adaptační algoritmus upraví parametry regulátoru s cílem referenční odchylku minimalizovat v následujících časových krocích. Sériově-paralelní referenční model provádí reinicializaci v každém časovém kroku. Výstup ze sériově-paralelního RM je funkcí žádané hodnoty a předchozích výstupů z URO. Referenční odchylka v daném časovém kroku je tedy závislá pouze na odlišné odezvě URO a RM, nikoli na historii referenční odchylky a historii poruch vstupujících do URO.



Obr. 3: Sériově-paralelní referenční model

4.6. Matematický popis HONU jako MRAC regulátor

Diskrétní regulátor s jedním vstupem a jedním výstupem (SISO) se skládá z jednotky HONU. V uvedeném případě jako LNU (4.14) nebo obecně pro HONU (4.15) [1].

$$u_{(k)} = \nu_{(k)} \cdot \xi_{(k)} = \sum_{g=1}^m \xi_{g(k)} \cdot \nu_{g(k)} \quad (4.14)$$

$$u_{(k)} = \nu \cdot \text{col}\xi_{(k)} \quad (4.15)$$

Kde ν je vektor vah HONU jako regulátor. Jedná se podstatě o parametry regulátoru, kterými lze nastavit chování URO. ξ je vstupním vektorem dávající informaci o aktuálním stavu řízeného systému a žádané hodnoty. V případě, má-li systém pouze jeden stupeň volnosti a je-li říditelný a pozorovatelný, může se jednat o zpožděné regulační veličiny a žádané hodnoty:

$$\xi_{(k)} = [1, y_{(k-m_y)}, \dots, y_{(k-1)}, d_{(k-m_d+1)}, \dots, d_{(k)}]^T \quad (4.16)$$

Vektor $\text{col}\xi$ (4.17) je sestaven kombinací prvků ze vstupního vektoru ξ stejným způsobem jako vektor $\text{col}x$ pro HONU (4.10) nebo pro T-S HONU (4.17).

$$\text{col}\xi_{g(k)} = \xi_{i(k)} \cdot \xi_{j(k)}; i = 1 \dots n, j = i \dots n \quad (4.17)$$

4.7. Matematický popis T-S HONU jako MRAC regulátor

Obdobně jako použití HONU jako regulátoru lze použít i Takagi-Sugeno model jako regulátor s HONU jako lokálními modely, a to následovně [5]:

$$\begin{aligned} u_{(k)} &= \Phi_{u(k)} \cdot \mathbf{V}_{(k)} \cdot \text{col}\xi_{(k)} \\ &= \nu_{(k)} \cdot \text{col}\xi_{TG(k)} \end{aligned} \quad (4.18)$$

$$\text{col}x_{TS(k)} = \left[\phi_{u1(k)} \cdot \text{col}\xi_{(k)}^T, \phi_{u2(k)} \cdot \text{col}\xi_{(k)}^T, \dots, \phi_{ud(k)} \cdot \text{col}\xi_{(k)}^T \right]^T \quad (4.19)$$

4.8. Učící algoritmus GD pro adaptaci vah HONU jako regulátoru

Samotný algoritmus GD (4.20) i kriteriální funkce (4.21) jsou stejné jako pro HONU jako model soustavy.

$$\nu_{(k+1)} = \nu_{(k)} - \mu_{norm(k)} \cdot \frac{\partial Q_{(k)}}{\partial \nu_{(k)}} \quad (4.20)$$

$$Q_{(k)} = \frac{1}{2} (y_{ref(k)} - y_{(k)})^2 \quad (4.21)$$

Předpokládá se, že chování modelu je blízké chování řízeného systému, tedy že pro libovolný diskrétní čas k platí:

$$y_{(k)} \approx y_n(k) \quad (4.22)$$

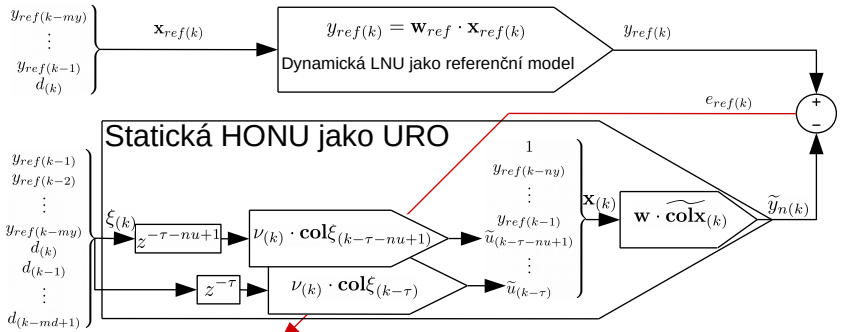
Jelikož je řízený systém vždy alespoň o jeden diskrétní časový krok zpožděn, výstup z regulátoru (4.15) nemá vliv na regulovanou veličinu. Tedy ani váhy HONU jako regulátoru $\nu_{(k)}$ se na $y_{(k)}$ nepodílejí, není na nich závislá ani kriteriální funkce (4.21). Gradient v (4.20) je proto nulový. Daným způsobem

nelze proto korektně váhy $\nu_{(k)}$ učit. Regulovaná veličina $y_{(k)}$ je funkcí zpožděných akčních zásahů $u_{(k-\tau)}$ až $u_{(k-\tau-m_u+1)}$, což je dáno vstupním vektorem $\mathbf{x}_{(k)}$ (4.1). Regulovaná veličina $y_{(k)}$ je proto závislá na vahách z časového kroku $k - \tau$ a starší.

Jako řešení výše zmíněného problému je počítán tzv. fiktivní výstup z řízeného systému $\tilde{y}_{(k)}$, který by nastal, kdyby i v předchozích časových krocích byly použity váhy $\nu_{(k)}$ pro výpočet akčních zásahů $u_{(k-\tau)}$ až $u_{(k-\tau-m_u+1)}$. Fiktivní výstup $\tilde{y}_{(k)}$ není použit pro samotné řízení, ale pouze pro optimalizaci vah regulátoru. Kriteriační funkce je pak z (4.23) upravena následovně [2]:

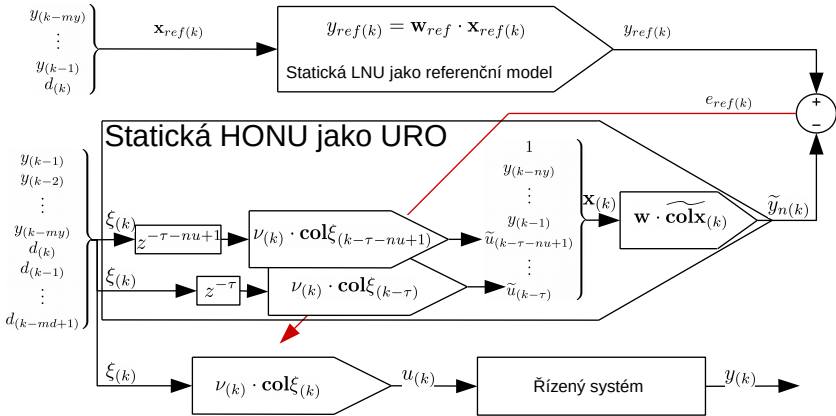
$$Q_{(k)} = \frac{1}{2} (y_{ref(k)} - \tilde{y}_{n(k)})^2 \quad (4.23)$$

Samotné učení je rozděleno na tzv. předučení a učení za provozu v reálném čase. Pro předučení regulátoru je zvoleno učící schéma *obr.4* [3], kde je použit dynamický referenční model a statický HONU jako URO.



Obr. 4: Předučení vah HONU jako regulátoru v zapojení referenčního modelu jako dynamická LNU

Při učení vah $\nu_{(k)}$ za provozu je známa regulovaná veličina a je požadováno, aby se regulátor adaptoval na aktuální změny chování řízeného systému. Referenční model proto přejde na statickou LNU, v jehož vstupu je zpožděná regulační veličina (*obr.5*) [6].



Obr. 5: Učení vah HONU jako regulátoru během procesu v zapojení referenčního modelu jako statická LNU

4.9. Gradient v GD pro HONU jako regulátor a LNU jako model systému

Kriteriální funkce (4.23) závisující na fiktivním výstupu z modelu (4.24) je vypočítán ze vstupního vektoru závisujícího na vahách regulátoru pouze z předchozího časového kroku (4.25).

$$\tilde{y}_n(k) = \mathbf{w} \cdot \tilde{\mathbf{x}}(k) = \sum_{i=1}^n \tilde{x}_i(k) \cdot w_i \quad (4.24)$$

$$\tilde{\mathbf{x}}(k) = \begin{bmatrix} 1 \\ y(k-ny) \\ \vdots \\ y(k-1) \\ \tilde{u}_{(k-nu)} = \sum_{g=1}^m \text{col}\xi_{g(k-\tau-nu+1)} \cdot v_g(k) \\ \vdots \\ \tilde{u}_{(k-1)} = \sum_{g=1}^m \text{col}\xi_{g(k-\tau)} \cdot v_g(k) \end{bmatrix} \quad (4.25)$$

Výsledný vzorec pro učení vah HONU jako regulátoru dosazením (4.24) do (4.23) a následně do (4.20) je následující:

$$\nu_{(k+1)} = \nu_{(k)} + \mu_{norm(k)} \cdot \tilde{e}_{ref(k)} \cdot \mathbf{w}_{(k)} \cdot \mathbf{J}_{(k)} \quad (4.26)$$

$$J_{(k)} = \frac{\partial \tilde{\mathbf{x}}_{(k)}}{\partial \mathbf{v}_{(k)}} = \begin{bmatrix} \frac{\partial \tilde{x}_{1(k-\tau)}}{\partial v_{1(k)}} & \dots & \frac{\partial \tilde{x}_{1(k)}}{\partial v_{m(k)}} \\ \vdots & & \vdots \\ \frac{\partial \tilde{x}_{n(k-\tau)}}{\partial v_{1(k)}} & \dots & \frac{\partial \tilde{x}_{n(k-\tau-n_u+1)}}{\partial v_{m(k)}} \end{bmatrix} \quad (4.27)$$

$$= \left[\vec{0}, \vec{0}, \dots, \vec{0}, \mathbf{col}_{\xi_{(k-\tau-n_u+1)}}^T, \dots, \mathbf{col}_{\xi_{(k-\tau)}}^T \right]^T$$

Normalizovaný koeficient učení je vypočítán metodou nejmenších čtverců (4.28) Výsledný vztah je (4.29) kde $\mu_{Cnorm} \in < 0, 1 >$.

$$\frac{\partial \hat{Q}_{(k)}}{\partial \mu_{C(k)}} = 0 \quad (4.28)$$

$$\mu_{C(k)} = \frac{\mu_{Cnorm}}{\mathbf{w} \cdot J_{(k)} \cdot (\mathbf{w} \cdot J_{(k)})^T + \epsilon} \quad (4.29)$$

4.10. Gradient v GD pro HONU jako regulátor a HONU jako model systému

Pro HONU jako regulátor je postupováno analogicky jako v kap.4.9. Například pro QNU bude fiktivní výstup z modelu počítán podle (4.30) se vstupním vektorem (4.25).

$$\tilde{y}_{(k)} = \sum_{i=1}^n \sum_{j=i}^n \tilde{x}_{i(k)} \cdot \tilde{x}_{j(k)} \cdot w_{ij} \quad (4.30)$$

Gradient v (4.20) pak bude vypočítán následovně:

$$\begin{aligned} \frac{\partial Q_{(k)}}{\partial v_{g(k)}} &= \frac{1}{2} \frac{\partial}{\partial v_{g(k)}} \left(y_{ref} - \sum_{i=1}^n \sum_{j=i}^n \tilde{x}_{i(k)} \cdot \tilde{x}_{j(k)} \cdot w_{ij} \right)^2 \\ &= -e_{ref} \cdot \sum_{i=1}^n \sum_{j=i}^n \left(\frac{\partial \tilde{x}_{i(k)}}{\partial v_{g(k)}} \cdot \tilde{x}_{j(k)} + \tilde{x}_{i(k)} \cdot \frac{\partial \tilde{x}_{j(k)}}{\partial v_{g(k)}} \right) \cdot w_{ij} \end{aligned} \quad (4.31)$$

Analogicky jsou počítány i regulátoru sestaveny jako vyšší řády HONU.

4.11. Gradient v GD pro HONU jako regulátor a T-S HONU jako model systému

T-S HONU model se skládá z lokálních modelů, jejichž výstupy budou sčítány podle normalizované míry příslušnosti Φ . Gradient kritériální funkce (4.23) pro LNU pak bude podle (4.32) a pro QNU podle (4.33).

$$\frac{\partial Q_{(k)}}{\partial v_{mg(k)}} = -\tilde{e}_{ref(k)} \cdot \phi_{m(k)} \cdot \sum_{i=1}^n \frac{\partial \tilde{x}_{i(k)}}{\partial v_{mg(k)}} \cdot w_{mi(k)} \quad (4.32)$$

$$\begin{aligned} \frac{\partial Q_{(k)}}{\partial \nu_{mg(k)}} &= \frac{1}{2} \frac{\partial}{\partial \nu_{mg(k)}} \left(y_{ref} - \sum_{m=1}^M \Phi_{m(k)} \sum_{i=1}^n \sum_{j=i}^n \tilde{x}_{i(k)} \cdot \tilde{x}_{j(k)} \cdot w_{ij} \right)^2 \\ &= -e_{ref} \cdot \phi_{m(k)} \cdot \sum_{i=1}^n \sum_{j=i}^n \left(\frac{\partial \tilde{x}_{i(k)}}{\partial \nu_{mg(k)}} \cdot \tilde{x}_{j(k)} + \tilde{x}_{i(k)} \cdot \frac{\partial \tilde{x}_{j(k)}}{\partial \nu_{mg(k)}} \right) \cdot w_{mij} \end{aligned} \quad (4.33)$$

4.12. Rozšíření kritériální funkce o statické zesílení a posunutí

Pokud je možné explicitně vypočítat offset, statické zesílení nebo statickou charakteristiku uzavřeného regulačního obvodu, pak tyto informace mohou být použity k rozšíření kritériální funkce. Neboť statické zesílení a offset referenčního modelu jsou známy, protože vždy požadujeme statické zesílení RM rovno 1 a nulový offset. Statické zesílení LNU lze zapsat ve tvaru (4.34) a offset ve tvaru (4.35).

$$K_{st} = \frac{\partial y_{st}}{\partial u_{st}} = \frac{\sum_{ny+2}^n w_i}{1 - \sum_{i=2}^{ny+1} w_i} \quad (4.34)$$

$$offset = \frac{w_1}{1 - \sum_{i=2}^{ny+1} w_i} \quad (4.35)$$

Obecně pak pro HONU lze v daném diskretním časovém kroku linearizovat (4.36) a pro lineární model pak bude statické zesílení (4.34) a offset (4.35).

$$y_{(k)} = \mathbf{w}_{LIN(x_{(k)})} \cdot \mathbf{x}_{(k)} \quad (4.36)$$

Analogicky lze pak sestavit statické zesílení (4.38) a offset (4.39) uzavřeného regulačního obvodu s použitím linearizovaného HONU jako regulátor (4.37).

$$u_{(k)} = \mathbf{v}_{LIN(\xi_{(k)})} \cdot \xi_{(k)} \quad (4.37)$$

$$K^{CL} = \frac{\partial y_{st}}{\partial d_{st}} = \frac{\sum_{i=my+2}^m v_i \cdot \sum_{i=ny+2}^n w_i}{1 - \sum_{i=2}^{ny+1} w_i - \sum_{i=2}^{my+1} v_i \cdot \sum_{i=ny+2}^n w_i} \quad (4.38)$$

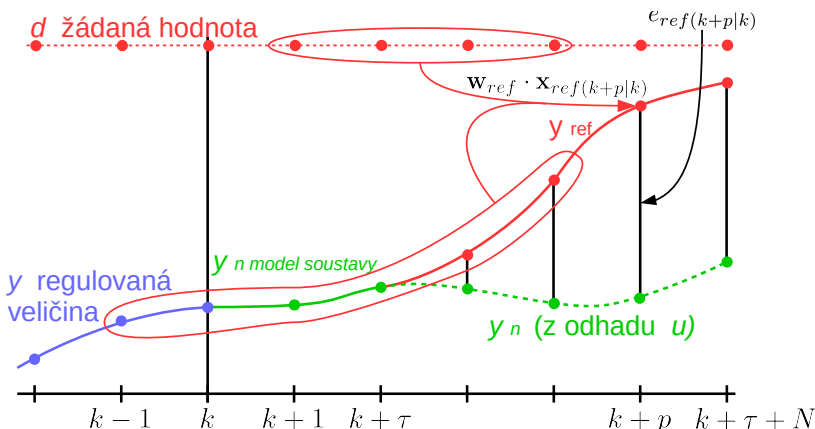
$$offset^{URO} = w_1 + v_1 \cdot \sum_{ny+2}^n w_i \quad (4.39)$$

Rozšíření kritériální funkce pak bude následující [4]:

$$\begin{aligned} Q_{(k)} &= \frac{\alpha_1}{2} (y_{ref(k)} - y_{n(k)})^2 \\ &+ \frac{\alpha_2}{2} (1 - K_{(k)}^{CL})^2 + \frac{\alpha_3}{2} (offset_{(k)}^{CL})^2 \end{aligned} \quad (4.40)$$

4.13. Řízení adaptivním regulátorem MPC se sériově-paralelním referenčním modelem

Požadujeme-li, aby uzavřený regulační obvod měl námi požadované chování, obdobně jako u zpětnovazebné stavové regulace, lze využít sériově-paralelní referenční model, jaký byl použit i u strategie řízení MRAC kap.4.6 Zvolený postup výpočtu MPC je ukázán na obr.:



Obr. 6: Příklad predikce statického referenčního modelu

Nachází-li se řízený systém v diskrétním čase k , je nejprve provedena predikce pomocí modelu systému do času $k + \tau$. Od tohoto času je pak vypočítána predikce řízeného systému a také referenčního modelu do horizontu $k + \tau + N$. Rozdíl těchto predikcí (4.41) je následně použit v kritériální funkci (4.42) akčních zásahy u [5].

$$E(k) = \begin{bmatrix} y_{ref}(k+\tau+1) \\ \vdots \\ y_{ref}(k+\tau+N) \end{bmatrix} - \begin{bmatrix} y_n(k+\tau+1) \\ \vdots \\ y_n(k+\tau+N) \end{bmatrix} = Y_{ref}(k) - Y_n(k) \quad (4.41)$$

$$Q(k) = \frac{1}{2} \cdot E(k)^T \cdot E(k) = \frac{1}{2} \sum_{p=\tau}^{\tau+N-1} e_{(k+p|k)}^2 \quad (4.42)$$

$$= \frac{1}{2} \sum_{p=\tau}^{\tau+N-1} (y_{ref}(k+p|k) - y_n(k+p|k))^2$$

Nové predikované hodnoty akčních zásahů jsou vypočítány metodou gradient descent následovně:

$$\hat{U}_{(k)} = U_{(k)} - \mu_{C(k)} \cdot \frac{\partial Q_{(k)}}{\partial U_{(k)}} \quad (4.43)$$

5. Experimentální část


Adaptivní regulátory se sériově-paralelním referenčním modelem byly sestaveny pro řízení simulačního modelu sestaveného v prostředí Matlab/SIMULINK. Výsledný regulátor byl pak použit pro reálné řízení hydraulického standu. Nejvýznamnější parametry simulačního modelu jsou schodné s parametry hydraulického standu tab.2. V modelu byla uvažována hysterese ventilů i mrtvá pásma šoupátka (offset).

Tabulka 2: Parametry hydraulického standu

Veličina	Proměnná
Vstupní tlak	$p_0 = 50[\text{bar}]$
Součinitel tlumení hydromotoru	$b = 1.81 \cdot 10^{-3} [\text{kg}/\text{s}^2]$
Objem přívodního potrubí	$V_0 = 300 \cdot 10^{-6} [\text{m}^3]$
Modul pružnosti oleje	$E_k = 1,3 \cdot 10^9 [\text{N}/\text{m}^2]$
Redukovaná pohybující se hmota	$m = 50 [\text{kg}]$
Činná plocha pístnice	$S = 132,7 [\text{mm}^2]$
Zdvih hydromotoru	$H = 1 [\text{m}]$

5.1. Identifikace

Při řízení s referenčním modelem byla nejprve provedena identifikace. Jako HONU modely byly vybrány LNU, QNU, CNU a HONU 5. řádu s redukovaným vstupním vektorem $colx$ podle se vstupním vektorem (4.7) a s $n = 10$, $m = 2$ a $\tau = 4$. Déle byl testován T-S HONU model s lineárními vnitřními modely LNU (T-S LNU) sestavený strategií LOLIMOT. Ze všech modelů prokázal nejlepší schopnost identifikovat Simulační model hydraulického standu s hysterezi a offsety T-S LNU model.



Obr. 7: Porovnání identifikace HONU_{r5} a T-S LNU modelu


5.2. Řízení modelu hydraulického systému

Pro řízení byly použity regulátory s parametry dle *tab.3*. Jako regulátor nebyly testovány neuronové jednotky QNU a CNU z důvodu vysokého počtu prvků ve vstupním vektoru ξ . První 2 experimenty se zabývají chováním uzavřeného regulačního obvodu při změně vlastností řídicího ventilu, změně hystereze ventilu a změně mrtvého pásma ventilu. Aby změny byly patrné,

jsou zde tyto změny testovány skokově, a to jako změna statické rychlostní charakteristiky na statickou charakteristiku s hysterezí a na statickou charakteristiku s mrtvými pásmi šoupátka (*obr.8*). První experiment byl zaměřen na řízení hydraulického systému s hysterezí šoupátka ventilu. Na *obr.8* byl řízený model hydraulického systému do času 30 s bez hystereze, od tohoto času byla pak hystereze skokově zapnuta. Po změně hystereze není vidět žádná změna na průbězích regulované veličiny. Jsou však patrné změny v akčním signálu, kde došlo k posunutí akčního signálu u . K posunutí musí dojít pokud dojde k změně akčního signálu z kladného na záporný nebo naopak. Což se také ve všech případech stalo, protože došlo k přejetí žádané hodnoty u MRAC o 0,01mm a u MPC o 0,15mm.


Tabulka 3: Regulátory pro experimentální řízení

Typ regulátoru	HONU jako model	Vlastnosti referenčního modelu	Značení regulátoru v grafech
MRAC	LNU	$G_{ref}(s) = \frac{1}{0.027s^3 + 0.27s^2 + 0.9s + 1}$	y_{LNU}
	HONU $r=5$		$y_{HONU r=5}$
	T-S LNU		$y_{T-S LNU}$
MPC	LNU	póly: $p_{1,2,3} = -3.3$	y_{MPC}




Obr. 8: Řízení modelu hydraulického systému se skokovou změnou hysterese šoupátka ventilu

Na obr.2 je ukázána simulace, ve které bylo v čase 30 s změněno mrtvé pásmo šoupátka z 0 na 0,3 v obou směrech vysouvání (z normalizovaného rozsahu $\leftarrow 1,1 \rightarrow$). Při změně požadovaného akčního signálu musí tedy šoupátko ujet dráhu 0,6 nežli dojde k opětovnému otevírání kanálů ventilu. To se v simulaci projevilo jednak posunutím akčního signálu pro nulovou rychlost pístnice a také zpožděním oproti teoretické referenční trajektorii.



Obr. 9: Řízení hydraulického systému se skokovou změnou statické charakteristiky ventilu, změna mrtvého pásma šoupátka

Třetí simulace byla zaměřena na poruchu způsobenou silou působící na pístnici (*obr.10*). Při lisování hydraulickým lisem jede obvykle v první fázi horní část lisu s pístnicí na prázdno a až v určitém místě dojde k nárazu na polotovar a k samotnému lisování. Proto bylo testováno řízení polohy pístnice, kde zátěžná síla působí pouze pokud je pístnice vysunuta více než 60 mm. Test byl proveden se statickou charakteristikou ventilu, která má mrtvá pásma i hysterezi. Při nárazu, kdy dojde k působení zátěžné síly, je vidět jednak zakmitání pístnice a též snížení maximální rychlosti při vysouvání. Jinak však regulace u všech testovaných regulátorů probíhala obdobně.



Obr. 10 Řízení modelu hydraulického systému se zátěží působící proti pístnici. Síla $F = 2000\text{N}$ působí, pokud je vysunutí pístnice větší než $y > 60\text{mm}$


5.3. Řízení hydraulického standu

Řízení bylo testováno na hydraulickém standu [5] s hydraulickým obvodem zapojeným podle obr.11. Spodní lineární hydro-motor V1 byl řízen pomocí 4-cestného proporcionálního ventilu Hydraforce SP08-20A se statikou průtokovou charakteristikou (obr.2) a se vstupním řídicím signálem u . Regulovanou veličinou je poloha pístnice y . Horní hydromotor V2 slouží jako zátěž a simuluje lisování materiálu. Při provádění simulací se ukázalo, že nejjednodušší navrhovaná metoda řízení s LNU jako regulátorem a LNU jako modelem řízeného systému s permanentním doučováním vah dosahuje rovnocenných výsledků regulace, tak jako ostatní regulátory. Proto byl LNU

jako MRAC regulátor vybrán jako nejvhodnější pro řešenou úlohu a byla pro něj provedena i zkouška na reálném hydraulickém systému.


Tabulka 4: Vlastnosti hydraulického standu

Tlak v řízeném spodním hydromotoru	$p_1 = 50\text{bar}$
Tlak v horním zátěžovém hydromotoru	$p_2 = 20\text{bar}$
Síla řízeného spodním hydromotoru	$F_{v1} = 1100\text{N}$
Síla horního zátěžového hydromotoru	$F_{v2} = 400\text{N}$
Maximální rychlost spodního hydromotoru	$v_{1max} = 150\text{mm/s}$



Obr. 11: Zjednodušené hydraulické schéma zkušebního hydraulického systému

Na obr.12 je ukázán průběh řízení. Při řízení reálných lisů je obvykle požadováno kromě rychlosti dosažení žádané hodnoty také přesnost dosažení a velikost maximálního překmitu. Velikost překmitu a přesnost dosažení žádané hodnoty je obvykle 0,1 mm při řízení s proporcionálními ventily, a této přesnosti bylo i dosaženo.



Obr. 12: Řízení hydraulického standu

6. Závěr

Práce se zabývá identifikací a řízením hydraulického systému s využitím elektromagneticky řízených proporčních ventilů a úlohou řízení polohy pístnice hydromotoru. Z pohledu reálné aplikace byla uvažována úloha řízení hydraulických lisů. Z této úlohy plynuly i základní požadavky na kvalitu řízení, maximální překmit a rychlost dosažení žádané hodnoty.

Motivací samotné práce bylo snížení výsledné ceny hydraulického systému tím, že bude možné použití levných proporčních ventilů bez využití předřadných řídicích elektronik řídicích proud do cívek a tím, že regulátor uzpůsobí své chování v závislosti na chování pro každý proporční ventil bez nutnosti kvalifikované obsluhy a též bez nutnosti přeladovat regulátor během životnosti stroje. Pro vyhovění zmíněných požadavků, byla sestavena hypotéza: Pokud by byl sestaven učící algoritmus pro HONU jako regulátor, který by umožnil rychlou adaptaci regulátoru během procesu, tak takovýto adaptivní regulátor byl mohl splnit výše zmíněné požadavky na řízení.

V *kap. 4.5* je popsán princip sériově-parallelního referenčního modelu (statický referenční model) a ukázán rozdíl v použití oproti parallelnímu modelu (dynamický referenční model). Sériově-parallelní referenční model byl následně použit v *kap.4.8* při sestavení kritériální funkce k učení MRAC regulátoru s HONU jako regulátor (optimalizace parametrů regulátoru) v reálném čase. V *kap.4.13* je sériově-parallelní referenční model využit pro

sestavení kritériální funkce sloužící k výpočtu akčních zásahů strategií MPC. V *kap. 4.12* je vypočítáno statické zesílení a offset modelů HONU i uzavřeného regulačního obvodu skládajícího se z HONU jako regulátoru a HONU jako modelu řízené soustavy. Při řízení na žádanou polohu je vždy požadováno, aby statistické zesílení uzavřeného regulačního obvodu bylo rovno jedné a offset (trvalá regulační odchylka) byla nulová. Pomocí této znalosti a výpočtu aktuálního statického zesílení a offsetu byla rozšířena kritériální funkce sloužící k optimalizaci vah regulátoru. Schopnost učení byla testována na jednoduchém příkladu. Tím byl splněn 1. cíl práce *Vytvoření nového zrychleného algoritmu učení, pro regulátory s referenčním modelem, využívající polynomiální neuronové jednoty HONU*

V *kap.4.6* je sestaven matematický popis MRAC regulátoru s HONU a v *kap.4.11* T-S LNU jako regulátoru, a následně je řešena otázka sestavení kritériální funkce pro učení vah regulátoru v reálném čase. Byla řešena problematika, kde regulovaná veličina není závislá na vahách regulátoru v tomtéž diskretním čase, nýbrž na vahách různě zpožděných v závislosti na vstupním vektoru do modelu řízeného systému. Tento problém byl vyřešen sestavením kritériální funkce závisějící nikoli na reálně změřené regulované veličině, ale na fiktivním výstupu z modelu. Fiktivní výstup byl vypočítán pouze z aktuálních vah (parametrů) regulátoru a fiktivně by nastal pouze pokud by všechny zpožděné akční zásahy vstupující do modelu řízeného systému byly vypočítány právě z těchto aktuálních vah regulátoru. Tím byl splněn 2. cíl práce *Vytvoření postupu adaptace řízení, sestavení korektního učícího algoritmu pro HONU*

Strategie řízení MRAC i MPC vyžadují vhodný model řízeného systému s dostatečnou schopností identifikovat řízený systém. Proto byla v *kap.5.1* provedena identifikace modelu hydraulického systému pomocí modelů LNU, QNU, CNU a HONU 5. řádu s redukovaným vstupním vektorem. Jednotky HONU byly porovnávány s Takagi-Sugeno modelem s LNU lokálními modely sestavenými strategií LOLIMOT. Všechny uvedené modely jsou schopny se učit (provádět identifikaci) v reálném čase s použitím gradientních optimalizačních metod. Kvalita naučení modelů byla vyhodnocována na modelech v rekurentním (dynamickém) zapojení. Byl porovnáván průběh rychlostí a statická rychlostní charakteristika, která ukázala schopnosti modelů identifikovat systém s offsetem (zapříčiněn mrtvými pásmy šoupátka ventilu) a hysterezí. Ukázalo se, že těmto kritériím nejlépe vyhoví Takagi-Sugeno model, který je především nejlépe schopen postihnout offset. Dále vyplynulo, že nemá smysl využívat všechny možné kombinace vstupů v jednotkách HONU, ale že postačí vybrat ty

nejvýznamnější kombinace do vstupního vektoru $colx$. Redukcí vstupního vektoru je významně snížena výpočetní náročnost. V *kap.5.2* jsou porovnávány způsoby řízení MRAC a MPC. Testování probíhalo na úloze simulující hydraulický lis. Nejprve byly provedeny simulace řízení. Tyto simulace prokázaly schopnosti regulátorů adaptovat se v reálném čase na změny v řízeném systému. Bylo testováno řízení při změně hystereze šoupátka a změna mrtvých pásem šoupátka. Byla testována porucha: náraz pístnice do lisovaného polotovaru a skoková porucha regulované veličiny. Simulace prokázaly schopnost adaptace regulátoru při změnách zesílení rozváděče způsobených změnou teploty cívek elektromagnetů. Dále byla porovnávána kvalita regulace při vypnutém a zapnutém doučování HONU jako regulátoru. Ukázalo se, že žádný z testovaných regulátorů není schopen řídit hydraulický systém bez trvalých regulačních odchylek, aniž by nebylo zapnuto doučování vah. Z provedených simulací vyplynulo, že pokud je zapnuté doučování vah HONU jako regulátoru, není pro danou úlohu nutné využívat HONU vyšších řádů, ale postačí LNU jako regulátor i jako model řízeného systému. Právě pro LNU jako regulátor byl proveden experiment řízení *kap.5.3* hydraulického standu. Kvalita regulace vyhověla požadavkům při řízení hydraulických lisů. Tím byl splněn 2. cíl práce *Sestavení regulátoru se zvýšenou rychlostí učení pro řízení hydraulického lisu*.

Nově sestavený algoritmus učení HONU jako regulátor, splnil hypotézu. Zvolený regulátor s nově sestaveným algoritmem učení je schopen řídit hydraulický systém bez použití předřadných elektronik a je schopen reagovat na změny řízeného systému v reálném čase.

Vlastní publikace

A, Vlastní publikace citované v tezi disertační práce

- [A1] VESELY, Martin, Ivo BUKOVSKY a Jan VRBA. Adaptivní gradientní systém s inverzním referenčním modelem (AGSIRM). In: Artep 2015: Automatizácia a riadenie v teórii a praxi 2015. Slovensko: Technická univerzita v Košiciach, 2015, s. 52-1-52-8.
- [A2] VESELY, Martin a Ivo BUKOVSKÝ. Adaptivni neuroregulátor se sériově-paralelním referenčním modelem. In: Artep 2016: Automatizácia a riadenie v teórii a praxi 2016. Slovensko: Technická univerzita v Košiciach, 2016, s. 38-1-38-10.
- [A3] BUKOVSKY, Ivo, Peter BENES a Martin VESELY. Introduction and Application Aspects of Machine Learning for Model Reference Adaptive Control With Polynomial Neurons. In: Artificial Intelligence and Machine Learning Applications in Civil, Mechanical, and Industrial Engineering. United States of America: IGI Global, Computational Intelligence and Robotics (ACIR) Book Series, s.59-83. ISBN 2327-0411
- [A4] VESELÝ, Martin. New learning opportunities for polynomial neural units as regulator. In: Konference Studentské Tvůrčí činnosti STČ 2016 Praha: ČVUT, Fakulta strojní, 2016, s.1-5. ISBN 978-80-01-05929-6
- [A5] VESELY, Martin a Ivo BUKOVSKY. Řízení hydraulického standu neuro-regulátorem. In: Automatizácia a riadenie v teórii a praxi 2019. Stara Lesna: Technická univerzita v Košiciach, 2019, s. 28.1-28.12. ISBN 978-80-553-3250-5.
- [A6] BUKOVSKY, I., P. BENES, M. VESELY, J. PITEL a M. M. GUPTA. Model reference multiple-degree-of-freedom adaptive control with HONUs. In: International Joint Conference on Neural Networks (IJCNN), 2016, s. 4895-4900. doi:10.1109/IJCNN.2016.7727843

B, Vlastní publikace necitované v tezi disertační práce

- [B1] VESELY, Martin. Adaptive Neuro-Controller for position control of a system of 2-way proportional valve and linear hydraulic motor. In: Konference Studentské Tvůrčí činnosti STČ 2014, Praha, ČVUT, Fakulta strojní, 2014, s.1–9, ISBN 978-80-01-05484-0
- [B2] BENES, Peter Mark, Miroslav ERBEN, Martin VESELY, Ondrej LISKA a Ivo BUKOVSKY. HONU and Supervised Learning Algorithms in Adaptive Feedback Control. In: Applied Artificial Higher Order Neural Networks for Control and Recognition, 2016, s.35–60. ISBN: 9781522500636
- [B3] VESELY, Martin. LNU-FUZZY Network as a Mathematical Adaptive Model of a Hydraulic System. MM Science Journal, 2018, (2), s.2573–2576. doi:10.17973/MMSJ.2018_11_201856
- [B4] BENES, Peter M., Ivo BUKOVSKY, Martin VESELY, Jan VORACEK, Kei ICHIJI a Noriyasu HOMMA. Framework for Discrete-Time Model Reference Adaptive Control of Weakly Nonlinear Systems with HONUs. In: Computational Intelligence: 9th International Joint Conference, IJCCI 2017 Funchal-Madeira, Portugal, 2017 s. 239–262. ISBN 978-3-030-16469-0

Publikace

- [1] VESELY, Martin, Ivo BUKOVSKY a Jan VRBA. Adaptivní gradientní systém s inverzním referenčním modelem (AGSIRM). In: Artep 2015: Automatizácia a riadenie v teórii a praxi 2015. Slovensko: Technická univerzita v Košiciach, 2015, s. 52-1-52–8.
- [2] VESELY, Martin a Ivo BUKOVSKÝ. Adaptivní neuroregulátor se sériově-paralelním referenčním modelem. In: Artep 2016: Automatizácia a riadenie v teórii a praxi 2016. Slovensko: Technická univerzita v Košiciach, 2016, s. 38-1-38–10.
- [3] BUKOVSKY, Ivo, Peter BENES a Martin VESELY. Introduction and Application Aspects of Machine Learning for Model Reference Adaptive Control With Polynomial Neurons. In: Artificial

Intelligence and Machine Learning Applications in Civil, Mechanical, and Industrial Engineering. United States of America: IGI Global, Computational Intelligence and Robotics (ACIR) Book Series, s.59–83. ISBN 2327-0411

- [4] VESELÝ, Martin. New learning opportunities for polynomial neural units as regulator. In: Konference Studentské Tvůrčí činnosti STČ 2016 Praha: ČVUT, Fakulta strojní, 2016, s.1–5. ISBN 978-80-01-05929-6
- [5] VESELY, Martin a Ivo BUKOVSKY. Řízení hydraulického standu neuro-regulátorem. In: Automatizácia a riadenie v teórii a praxi 2019. Stara Lesna: Technická univerzita v Košiciach, 2019, s. 28.1-28.12. ISBN 978-80-553-3250-5.
- [6] VESELÝ, František. Návrh hydraulických řídicích prvků s využitím simulačních výpočtů, Disertační Práce. Vysoká škola báňská - Technická univerzita Ostrava, 2010. ISBN 978-80-248-2288-4.
- [7] OLSSON, H., K. J. ÅSTRÖM, C. CANUDAS DE WIT, M. GÄFVERT a P. LISCHINSKY. Friction Models and Friction Compensation. In: European Journal of Control. 1998, 4(3), s.176–195. ISSN 0947-3580
- [8] Datasheet SP08-47CL Spool-Type 4-Way 3-Position, Closed-Center, Electro-Proportional Hydraulic Valve. [vid. 2020-06-30]. Dostupné z: http://hydraforce.com/Proport/Prop_html/2-111-1_SP08-47CL/2-111-1_SP08-47CL.htm#view8
- [9] Datasheet EVDR-0201 A Dual/Single Valve Driver, Plug-In Style, General Purpose [online]. [vid. 2020-07-02]. Dostupné z: <https://www.hydraforce.com/products/electronic-vehicle-controls/valve-drivers/evdr-0201a/>
- [10] BUKOVSKY, Ivo, Zeng-Guang HOU, Jiri BILA a Madan M. GUPTA. Foundation of Notation and Classification of Nonconventional Static and Dynamic Neural Units. In: IEEE, 2007, s.401–407. ISBN 978-1-4244-1327-0.

- [11] BUKOVSKY, Ivo, Noriyasu HOMMA, Ladislav SMETANA, Ricardo RODRIGUEZ, Martina MIRONOVOVA a Stanislav VRANA. Quadratic neural unit is a good compromise between linear models and neural networks for industrial applications. In: 9th IEEE International Conference on Cognitive Informatics (ICCI'10), Beijing, China, 2010, s.556-560. doi: 10.1109/COGINF.2010.5599677.
- [12] BUKOVSKY, Ivo a Noriyasu HOMMA. An Approach to Stable Gradient Descent Adaptation of Higher-Order Neural Units. In: IEEE Transactions on Neural Networks and Learning Systems, 2016. doi:10.1109/TNNLS.2016.2572310.
- [13] TAKAGI, T a M SUGENO. Fuzzy identification of systems and its application to modeling and control. In: IEEE Trans. Systems, Man and Cybernetics, 1985 (15), s.116–162.
- [14] MAMDANI. Application of Fuzzy Logic to Approximate Reasoning Using Linguistic Synthesis. In: IEEE Transactions on Computers, 1977, C–26(12), s.1182–1191. ISSN 0018-9340
- [15] NELLES, O., S. SINSEL a R. ISERMANN. Local basis function networks for identification of a turbocharger. In: UKACC International Conference on Control. In: UKACC International Conference on Control, (No. 427), 1996, s.7–12 roč.1. doi:10.1049/cp:19960518
- [16] AMERONGEN, J. van. MRAS: Model Reference Adaptive Systems. IN: JournalA 1981 (Vol 22, No 4)
- [17] LANDAU, Ioan Doré, Rogelio LOZANO, Mohammed M'SAAD a Alireza KARIMI. Adaptive Control: Algorithms, Analysis and Applications. In: Springer Science & Business Media, 2011. ISBN 978-0-85729-664-1.

- [18] RICHALET, Jacques a Donal O'DONOVAN. Reference Trajectory. In: Predictive Functional Control. London: Springer-Verlag, s.19–21. ISBN 978-1-84882-493-5
- [19] SNYMAN, Jan A. Practical mathematical optimization: An introduction to basic optimization theory and classical and new gradient-based algorithms. In: Springer, Applied optimization, 2005, s.613-615 ISBN 0-387-24348-8.
- [20] MANDIC, Danilo. A Generalized Normalized Gradient Descent Algorithm. In: IEEE Signal Processing Letters, 2004, (Vol 11 No 2), s.115–118. ISSN 1070-9908
- [21] SRA, Suvrit, Tommi JAAKKOLA, Sebastian NOWOZIN, Stephen J. WRIGHT, Martin ANDERSEN, Yoshua BENGIO, Dimitri BERTSEKAS, Léon BOTTOU, Léon BOTTOU a Constantine CARAMANIS. Optimization for Machine Learning IN: Cambridge, MIT Press, 2011 ISBN 978-0-262-29877-3
- [22] KHIRIRAT, Sarit, Hamid Reza FEYZMAHDAVIAN a Mikael JOHANSSON. Mini-batch gradient descent: Faster convergence under data sparsity. In: IEEE 56th Annual Conference on Decision and Control (CDC), 2017 s. 2880–2887. doi:10.1109/CDC.2017.8264077
- [23] MATHEWS, V.J. a Z. XIE. A stochastic gradient adaptive filter with gradient adaptive step size. In: IEEE Transactions on Signal Processing, 1993, 41(6), s.2075–2087. ISSN 1941-0476
- [24] GUPTA, Madan M., Liang JIN a Noriyasu HOMMA. Static and dynamic neural networks: from fundamentals to advanced theory. In: New York: Wiley, 2003. ISBN 0-471-21948-7.

Curriculum Vitae

Jméno: Martin Veselý
Adresa: Horská 203, Horní Maršov
Telefon: +420 731 253 884
e-mail: mveselymartin@hotmail.com

Vzdělání: Fakulta strojní, ČVUT, Praha
2006 - 2012, Aplikovaná mechanika a mechatronika

SPŠ, Trutnov
2000 - 2004, Strojní

Zaměstnání: FMV-DESIGN s.r.o.
2009 - dosud
konstrukce hydraulických prvků a systémů
řízení hydraulických systémů

Jazykové znalosti:
Německý jazyk - Úplný začátečník (A1)
Anglický jazyk - Pokročilý (C1)

Zájmy: Horolezectví

