



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

## ÚSTAV AUTOMOBILNÍHO A DOPRAVNÍHO INŽENÝRSTVÍ

INSTITUTE OF AUTOMOTIVE ENGINEERING

## OPTIMALIZACE TVARU MAZACÍ MEZERY HYDRODYNAMICKÉHO LOŽISKA S VYUŽITÍM METAMODELOVÁNÍ

LUBRICANT GAP SHAPE OPTIMIZATION OF THE HYDRODYNAMIC THRUST BEARING USING  
THE METAMODELING

### DIPLOMOVÁ PRÁCE

MASTER'S THESIS

### AUTOR PRÁCE

AUTHOR

**Bc. Lukáš Kukla**

### VEDOUCÍ PRÁCE

SUPERVISOR

**Ing. Martin Jonák Ph.D.**

# Zadání diplomové práce

Ústav:	Ústav automobilního a dopravního inženýrství
Student:	<b>Bc. Lukáš Kukla</b>
Studijní program:	Strojní inženýrství
Studijní obor:	Automobilní a dopravní inženýrství
Vedoucí práce:	<b>Ing. Martin Jonák, Ph.D.</b>
Akademický rok:	2019/20

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma diplomové práce:

## **Optimalizace tvaru mazací mezery hydrodynamického ložiska s využitím umělých neuronových sítí**

### **Stručná charakteristika problematiky úkolu:**

Práce se zabývá optimalizací tvaru mazací mezery axiálního ložiska za účelem zajištění požadované únosnosti a minimalizaci třecích ztrát. Práce zahrnuje tvorbu výpočtového modelu, metamodelu a následné hledání globálního extrému v rámci vytvořeného metamodelu. Konkrétně, při tvorbě metamodelů bude využito algoritmů strojového učení. Za účelem ověření získaných výsledků bude v práci provedena i kontrolní optimalizace přímo nad výpočtovým modelem.

### **Cíle diplomové práce:**

Zpracujte rešerši zabývající se problematikou modelování proudění viskózních tekutin tenkými mezerami.

Dále zpracujte rešerši na téma plánování experimentů a metamodelování. Pozornost také věnujte vhodným algoritmům strojového učení.

Vytvořte základní výpočtový model proudění oleje v mazací vrstvě axiálního ložiska turbodmychadla.

Nad výpočtovým modelem vytvořte vhodný metamodel a pokuste se nalézt globální extrém.

Proveďte zhodnocení dopadu výsledků na reálné aplikace.

### **Seznam doporučené literatury:**

STACHOWIAK, G. W., BATCHELOR, A. W. Engineering Tribology. 3. vyd. Boston: Elsevier Butterworth-Heinemann, 2005. ISBN 0-7506-7836-4.

NGUYEN-SCHÄFER, H. Rotordynamics of Automotive Turbochargers. Second Edition. Ludwigsburg, Germany: Springer, 2015. ISBN 978-3-319-17643-7.

SIMPSON, T. W., POPLINSKI, J. D., KOCH, P. N., ALLEN, J. K. Metamodels for Computer-based Engineering Design: Survey and recommendations. In Engineering with Computers. Volume 17, Issue 2, Jul 2001, Pages 129-150. ISSN 1435-5663.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2019/20

V Brně, dne

L. S.

---

prof. Ing. Josef Štětina, Ph.D.  
ředitel ústavu

---

doc. Ing. Jaroslav Katolický, Ph.D.  
děkan fakulty

---

## **ABSTRAKT**

Práce se zabývá popisem hlavních částí turbodmychadla a vysvětlením pojmu optimalizace. Dále se práce zabývá popisem proudění skutečných kapalin a mazání u hydrodynamického ložiska. Je zde popsána tvorba výpočtového modelu, metamodelu a následné hledání globálního extrému. Konkrétně, při tvorbě metamodelů je použita technika neuronové sítě.

## **KLÍČOVÁ SLOVA**

Turbodmychadlo, optimalizace, axiální segmentové ložisko, metamodel, neuronová síť

## **ABSTRACT**

The thesis deals with the description of the main parts of the turbocharger and explains the concept of optimization. Furthermore, the work deals with the description of the flow of real fluids and lubrication of the hydrodynamic bearing. The work deals with the creation of a computational model, metamodel and subsequent search for a global extreme. In particular, the neural network metamodel technique is used in metamodel formation.

## **KEYWORDS**

Turbocharger, optimization, axial segment bearing, metamodel, neural network

## **BIBLIOGRAFICKÁ CITACE**

KUKLA, Lukáš. Optimalizace tvaru mazací mezery hydrodynamického ložiska s využitím umělých neuronových sítí. Brno, 2020. 65s. Dostupné také z: <https://www.vutbr.cz/studenti/zav-prace/detail/121596>. Diplomová práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav automobilního a dopravního inženýrství. Vedoucí práce Martin Jonák.

## ČESTNÉ PROHLÁŠENÍ

Prohlašuji, že tato práce je mým původním dílem, zpracoval jsem ji samostatně pod vedením Ing. Martina Jonáka, Ph.D. a s použitím literatury uvedené v seznamu.

V Brně dne 26. června 2020

.....

Lukáš Kukla

## PODĚKOVÁNÍ

Za věcné připomínky, cenné rady, ochotu a věnovaný čas děkuji vedoucímu práce Ing. Martinovi Jonákovi Ph.D. Dále bych chtěl poděkovat rodině a přátelům za jejich podporu během studia.

## Obsah

<b>Úvod.....</b>	<b>10</b>
<b>1. Optimalizace .....</b>	<b>11</b>
<b>2. Turbodmychadlo .....</b>	<b>12</b>
2.1 Turbínová a kompresorová část .....	14
2.2 Ložisková část .....	15
2.3 Axiální ložiska turbodmychadla .....	16
2.3.1 Hydrostatická ložiska .....	16
2.3.2 Hydrodynamická ložiska.....	17
<b>3. Mazání ložisek .....</b>	<b>18</b>
3.1 Hydrostatické mazání:.....	18
3.2 Hydrodynamické mazání: .....	18
<b>4. Proudění skutečných kapalin .....</b>	<b>20</b>
4.1 Rovnice kontinuity .....	21
4.2 Navier-Stokesova rovnice .....	21
4.3 Bernoulliho rovnice.....	22
4.4 Proudění viskózních tekutin tenkými mezerami .....	22
<b>5. Návrh experimentů .....</b>	<b>25</b>
5.1 Metamodelování.....	26
5.2 Neuronové sítě .....	27
5.2.1 Vícevrstvá neuronová síť .....	30
5.2.2 Samoorganizující se neuronové sítě.....	31
5.2.3 Hopfieldovy sítě.....	32
5.2.4 RBF sítě.....	32
<b>6. Výpočtový model .....</b>	<b>33</b>
<b>7. Metamodel .....</b>	<b>37</b>
<b>8. Výsledky .....</b>	<b>41</b>
8.1 Neuronová síť (Full faktoriál).....	41
8.2 Neuronová síť (Halton).....	43
<b>9. Diskuze .....</b>	<b>45</b>
9.1 Neuronová síť .....	45
<b>Závěr.....</b>	<b>46</b>
<b>Použité informační zdroje .....</b>	<b>47</b>



---

<b>Seznam použitých zkratek a symbolů .....</b>	<b>51</b>
<b>Seznam příloh:.....</b>	<b>53</b>

---

# Úvod

Práce se zabývá popisem turbodmyhadla a jeho hlavních částí, které mají největší vliv na jeho samotnou optimalizaci.

Optimalizace je operace, při které se snažíme najít optimální cestu k výsledku, který bude vždy co nejvíce efektivní, kvalitní a cesta k jeho dosažení bude co nejkratší a nejlevnější [1]. V matematice optimalizaci rozumíme, že je to hledání takových hodnot proměnných daného systému, které leží v blízkosti globálního extrému účelové funkce, při současné podmínce, že systém bude dosahovat požadovaných parametrů. Optimalizace může být obecně využita pro zlepšení parametrů všech systémů ve světě techniky. S ohledem na rozvoj je optimalizace nedílnou součástí každodenního života. V této práci se zabývám optimalizací hydrodynamického ložiska turbodmyhadla [1][2].

Turbodmyhadlo je druh turbokompresoru poháněný výfukovými plyny s kompresním poměrem do 2 [2]. V rámci stále většího znečišťování životního prostředí a zákona o emisích zájem o vývoj a optimalizaci turbodmychadel vzrůstá. Pokusy překonat fenomén hysterze, problémy s klepáním a vysokou ztrátou se tyto problémy staly impulsem pro vývoj nových turbodmychadel[1].

S rychlým vývojem softwaru pro výpočtovou dynamiku tekutin a rychlé rozšíření optimalizačních algoritmů se vývojový cyklus turbodmychadel výrazně zkrátil a náklady byly sníženy odpovídajícím způsobem. Problémy s optimalizacemi jsou rozšířené v teoretické, výzkumné a inženýrské rovině. Jejich výpočetní složitosti se zvyšují s nárůstem počtu optimalizovaných parametrů [1].

Dále práce popisuje proudění viskózních tekutin tenkými mezerami a řeší aplikaci této teorie na popis problému proudění oleje mazací mezerou hydrodynamického ložiska.

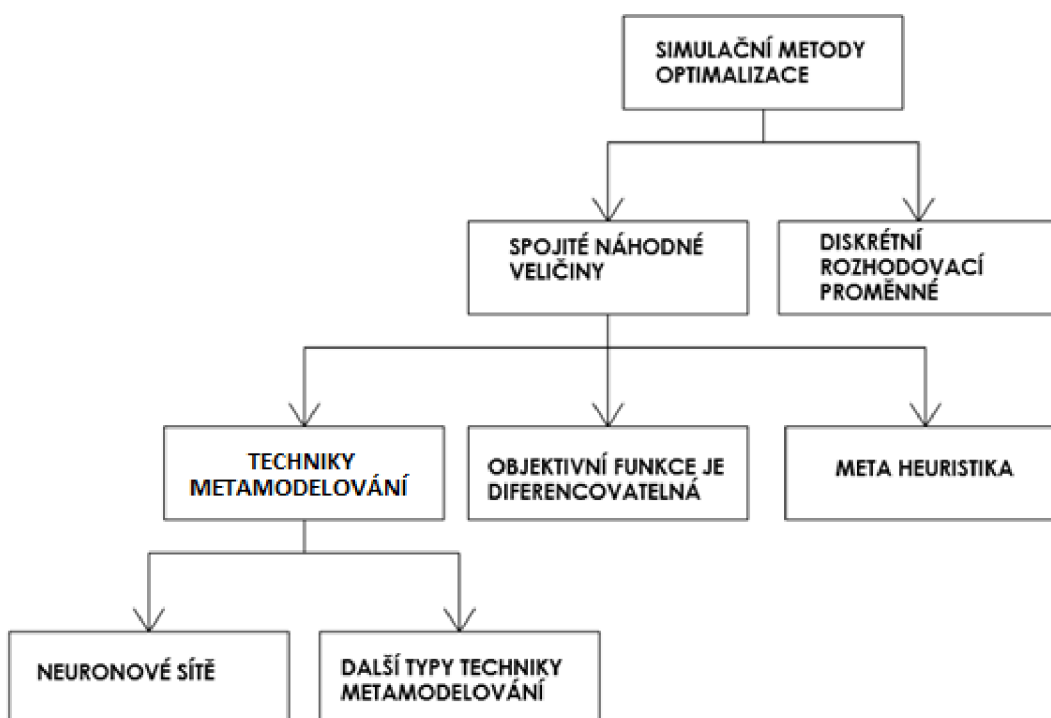
Poslední teoretická část práce ukazuje sestavení plánu experimentu a popis techniky metamodelování neuronovými sítěmi. U metodiky plánování experimentu je nutné se zabývat strategickým výběrem z návrhového prostoru pro provedení experimentu tak, aby bylo možné dosáhnout co nejlepších parametrů aproximačního modelu za co nejkratší dobu a s co největší úspěšností. Kombinace uvedených přístupů je většinou nazývána jako metamodelování (metamodeling). To lze také chápat jako nádstavbu modelování s výraznými prvky abstrakce. Modelování chápeme jako abstrakci a zjednodušení skutečnosti.

V praktické části jsou nejprve popsány všechny použité algoritmy. Je navržen experimentální plán a neuronová síť je použita na testovací funkci. Poté, co je neuronová síť vyzkoušena, je použita na výpočtový model. Výsledky a hodnocení úspěšnosti metamodelu jsou hodnoceny v diskusi.

# 1. Optimalizace

Optimalizace je proces hledání alternativy s nejvyšším dosažitelným výkonem za daných omezení, maximalizací požadovaných faktorů a minimalizací nežádoucích faktorů. Maximalizace oproti optimalizaci znamená snahu získat „nejvyšší“ výsledek bez ohledu na cenu nebo náklady [1].

V počítačové simulaci (modelování) se optimalizace provádí pomocí lineárních programovacích technik. Obecný příklad optimalizace lze popsat jako hledání funkce  $f(x)$  a jejího minima, kde cílem je najít návrhové proměnné  $x$ , které minimalizují funkci  $f(x)$ . Obecný problém je většinou omezen vektory, vyjadřujícími podmínky rovnosti nebo nerovnosti. Pokud problém neobsahuje omezení, problém je považován za neomezený. Návrhové proměnné se mohou lišit mezi horním a dolním limitem, nazvaným maximum a minimum, který definuje návrhový prostor [1].




Obr.1.1: Optimalizační proces [4], upraveno

## 2. Turbodmychadlo

Turbodmychadlo bylo vynalezeno švýcarským konstruktérem Alfredem Búchim. Ze začátku o něj nebyl moc velký zájem, ale před II. světovou válkou se turbo dostalo do letadel a lodních motorů, které následně byly použity ve válce a ukázaly se jako velmi účinné. Prvními auty s turbodmychadly se staly Chevrolet Corvaire Monza a Oldsmobile Jetfire v sedmdesátých letech. Pro velkou poruchovost musela být ale stažena z trhu. Poté se turbodmychadla dostala do závodu Formule 1 a do motoristického světa velkých, středních i malých závodů, kde se stala velmi oblíbenými a potřebnými [7].


Turbodmychadlo je plynový, turbínový motor, který se skládá z odstředivého kompresoru, zvaného dmychadlo a odstředivé turbíny. Jsou spojeny mechanicky hřídelem. Dmychadlo se roztáčí, tím pádem saje vzduch a vzduch je tlačěn dále do spirální skříně, která funguje jako bezlopatkový difuzor. Ve spirále roste průtočná plocha, a tím klesá rychlost proudícího vzduchu a roste tlak. Pokud neuvážíme regulaci odpouštěním, tak vzduch postupuje do spalovacího motoru a prostoru válce, kde spolu s palivem během expanze vykoná práci, a odletí výfukovým kanálem a nakonec je veden na rozváděcí lopatky turbíny. U lopatek by se měl nastavit takový úhel, který zajistí co možná největší efektivitu [7].

Kompresor v turbodmychadlu zvyšuje tlak vzduchu hnaného přes filtr do válců motoru, a tím i jeho měrnou hmotnost. Při tomto procesu je možné do motoru dostat při stejných otáčkách a objemu více směsi paliva a vzduchu. Při tomto zvyšování množství vzduchu je nutné zvýšit i přísun paliva pro větší účinnost. Pro správné a účinné hoření by měl být dodržen stechiometrický poměr směsi vzduchu a paliva, který je označován jako  $\lambda$  (lambda), která se při tomto poměru rovná 1. Stechiometrický poměr je poměr, který určuje kolik kg vzduchu je potřeba pro spálení 1 kg paliva. Pro benzín je to okolo 14,8 kg vzduchu a pro naftu je to okolo 14,5 kg vzduchu. Převědeme-li hmotnostní poměr na objemy, ke spálení 1 litru paliva budeme potřebovat okolo 10.000 litrů vzduchu [3][7].



Obr.2.1: Princip turbodmychadla [6]

Velký nárůst tlaku se většinou u turbodmychadla měří v pascálech, barech nebo PSI. Například při teoretické účinnosti 100 % by turbodmychadlo produkující nárůst tlaku 100 kPa zdvojnásobilo výkon motoru. Vlastní rotor turbodmychadla je brzděn kvůli vznikajícím zpětným tlakům. Ani turbína ani motor, ani ložiska nemají 100 % účinnost kvůli všem mechanickým částem, které odebírají část energií. Turbodmychadla dosahují účinnosti okolo 70 - 85 % [5].




Obr.2.2: Popis Turbodmychadla [7]

- 1) kompresorová skříň – sací, studená část turbodmychadla
- 2) kompresorové kolo – zdroj stlačeného vzduchu
- 3) axiální olejové ložisko – zadržuje axiální síly
- 4) zadní stěna kompresorové skříně
- 5) turbínová skříň – slouží jako rozvaděč turbíny
- 6) turbína – hnaná výfukovými plyny, roztáčí kompresor
- 7) radiální olejová ložiska – zadržují radiální síly
- 8) ložisková skříň

## 2.1 Turbínová a kompresorová část

Hlavními komponenty turbínové části je turbínová skříň a oběžné kolo turbíny. Turbínové kolo je jednou z nejdůležitější součástí turbodmychadla. Jeho rotací získává celý agregát energii pro práci kompresorové části. Pro výkonnou práci turbodmychadla a ideální otáčky je velmi důležitý tvar a velikost turbínové skříň. Při jejím návrhu se řídíme A/R poměrem. A/R je poměr plochy průtočného poměru a vzdálenost středu plochy v daném místě od pomyslného středu voluty turbínové skříň. Turbínová skříň přivádí výfukové plyny z výfukových svodů v radiálním směru. Maximální využití kinetické energie plynu nastává v případě tangenciálního dopadu výfukového plynu na lopatky oběžného kola. Jestliže plocha průřezu A bude menší, pak budou plyny proudit rychleji, pokud bude poloměr R větší, pak bude síla plynu proudící na lopatku působit na větší páce, tím pádem bude udělen větší točivý moment. Poměr A/R má tedy významný vliv na chování pohybu rotorové části. Výfukové plyny odchází z turbíny v axiálním směru [8].

Nejčastěji se oběžné kolo kompresoru vyrábí ze slitin hliníku. Někdy se vyrábí se slitin titanu. Titanová kola se používají pro vysokotlaké přeplňování za vysokých otáček, protože mají vyšší únavovou pevnost [2]. Protože kolo rotuje vysokou rychlostí, je pro správný chod a životnost kola důležité vyvažování. Většinou se vyvažuje tak, že se ve dvou rovinách ubírá materiál na přední a zadní stěně. Oběžné kolo s vyvrtanou dírou se nasazuje na čep společné hřídele a je zajištěn maticí tak, aby se utahovala ve směru rotace. Průchozí otvor však představuje velký koncentrátor napětí. Firma Honeywell vyřešila tento závažný problém tím, že vyřezala závit do kola a našroubovala hřídel před oblast, kde je kolo nejvíce zatíženo [8].



Obr.2.3 Popis turbínové části. [9]

- |                             |   |
|-----------------------------|---|
| 1) výstup oběžného kola     | 6) čep pro nasazení kompresorového kola     |
| 2) kontura kola             | 7) turbínové kolo                           |
| 3) vstup oběžného kola      | 8) hřídel                                   |
| 4) pístní a těsnící kroužky | 9) osazení hřídele                          |
| 5) plochy pro ložiska       | 10) závit pro zajištění kompresorového kola |


Problém kola s plnými lopatkami ve vysokých otáčkách řeší kolo s dělenými nebo dělicími lopatkami. Jedná se běžně o používaný typ kola, kde je mezi každé dvě plné lopatky umístěna lopatka kratší. Kola, která mají zakřivené lopatky, jsou dnes nejpoužívanějšími na trhu. Konstrukce dozadu proti směru otáčení zakřivených lopatek v blízkosti velkého průměru kola umožňuje kompresoru zpomalit a stlačit vzduch již při postupu kolem [9].



Obr.2.4: Ukázka lopatek turbodmychadla [9], upraveno

## 2.2 Ložisková část

U turbodmychadla může být ložiskový systém uspořádán několika způsoby. Nejvíce zastoupena konfigurace je s ložisky umístěnými mezi koly obr.2.5A. Další velmi používaná konfigurace jsou kola umístěná mezi ložisky obr.2.5B [42].




Obr.2.5: Nejčastěji používané konfigurace ložiskového uložení u turbodmychadla [42], upraveno

## 2.3 Axiální ložiska turbodmychadla

Ložiska jsou strojní součásti, které umožňují hřídelům a čepům točivý pohyb kolem vlastní osy a přenášejí z nich zatížení na jiné části stroje. Rozdělujeme je podle toho, jaký druh tření vzniká mezi stykovými plochami. Rozdělujeme ložiska do dvou základních skupin, a to jsou kluzná ložiska a valivá ložiska. Ložiska mohou být radiální nebo axiální. Radiální síla působí kolmo na osu hřídele/čepu a axiální působí ve směru osy hřídele nebo čepu [8][10].

### 2.3.1 Hydrostatická ložiska

Hydrostatická ložiska jsou vnější tlaková kapalinová ložiska, která používají olej, vodu nebo vzduch a jsou natlakovaná čerpadlem. Tento typ ložiska je tvořen dvěma povrchy a tekutinou, která je tlakovým čerpadlem tlačena mezi povrchy, aby je udržovala od sebe. Protože hydrostatické mazání nezávisí na relativním pohybu pro udržení mazacího filmu, může pojmout velké zatížení při nízkých rychlostech. Nevýhodou tohoto typu fluidního ložiska je výkon požadovaný od čerpadla, který přispívá ke ztrátě energie systému. Výhodou je však dlouhá životnost bez opotřebení povrchů. Hydraulická ložiska navíc patří mezi ložiska s nejnižším třením [11].




Obr.2.6: Hydrostatické mazání ložiska [12], upraveno

- |                   |                          |
|-------------------|--------------------------|
| 1) hřídelový čep  | 3) hydrostatická komora  |
| 2) těleso         | 4) zdroj tlakového oleje |
| 5) reduktor tlaku |                          |



## 2.3.2 Hydrodynamická ložiska

Hydrodynamická ložiska se spoléhají na vysokou rychlost čepu. Toto otáčení ložiska s vysokou rychlostí v podstatě táhne tekutinu na vnitřní povrch ložiska a vytváří mazací klín pod nebo kolem hřídele. Po spuštění se hydrodynamická ložiska vznášejí na tomto samoobnovujícím filmu maziva. Hydrodynamická ložiska se používají v rotačních aplikacích a mohou vyžadovat vnější tlak na jednu z ložiskových podložek nebo na sekundární ložisko, aby se zabránilo nadměrnému tření při spouštění otáčení [11].



Obr.2.7: Hydrodynamické mazání kluzného ložiska [13], upraveno

$F$  – vnější síla

$\omega$  – úhlová rychlost

1) mazací médium

2) pánev ložiska

$h$  – minimální tloušťka vrstvy mazacího oleje

3) hřídel

4) rozložení tlaku na pánev ložiska

### 3. Mazání ložisek

Důležité pro všechna ložiska je mazání. Správné mazání má vliv na trvanlivost a životnost. Mazivo vytváří mezi kluznými plochami mazací film, který brání vzájemnému styku třecích ploch. Použitím správné techniky mazání a oleje určeného k mazání, dojde ke snížení teploty kluzné dvojice a výkonnostních ztrát. Správná teplota oleje je velmi důležitá pro provozní vlastnosti ložiska. Segmentová ložiska u turbodmychadla mohou být mazána hydrostaticky nebo hydrodynamicky [15].


#### 3.1 Hydrostatické mazání:

Hydrostatické mazání je charakteristické tím, že vrstva maziva je vytvořena pomocí vysokotlakého čerpadla, které vytlačuje olej mezi kluzné plochy. Kvůli tomuto mazání je zapotřebí vytvořit na každém segmentu ložiska takzvanou „Hydrostatickou komoru“. Vysokotlaký olej je potom vtlačěn do této komory, nadzvedne běhoun a olej se protlačí mezi plochy. Mazací olej se přivádí z vnějšího zdroje pod dostatečně silným tlakem mezi třecí plochy, například ložiska a hřídele. Dochází k jejich vzájemnému oddělení relativně tlustým mazacím filmem. U tohoto mazání není podmínkou relativní pohyb třecích ploch. Pokud se hřídelový čep zatíží, přiškrtí se průřez, kterým olej obtéká čep z hydrostatické komory. Tím dojde k nárůstu tlaku oleje v reduktoru a v hydrostatické komoře. Dále dojde k nadzvednutí čepu a dojde k celkovému ustavení v poloze, kde bude zatěžující síla v rovnováze s hydrostatickou silou [14][15].

#### 3.2 Hydrodynamické mazání:

Ložiska, která jsou mazána hydrodynamicky, musí projít před dosažením podmínek pro hydrodynamické mazání třemi fázemi. To označujeme jako mezní mazání, která většinou vznikají při rozběhu nebo doběhu stroje, tedy při malé kluzné rychlosti. U tohoto režimu není mezi segmentem a běhounem vytvořena dostatečná velikost mazacího filmu. Dojde tedy k přímému styku jak makrogeometrických, tak mikrogeometrických nerovností. Dále následuje takzvané smíšené mazání, kde mazivo už zcela vyplnilo mezeru mezi kluznými povrchy, ale ještě není dostatečně silné pro požadovanou únosnost. Stále může dojít k občasnému styku mezi plochami. Poslední fáze je kapalinové mazání, kde už zcela kapalina zaplnila mezery mezi plochami a mazání je optimální [14][15].

U hydrodynamického mazání se povrchy musí navzájem relativně pohybovat s dostatečnou rychlostí pro generování mazací vrstvy schopné přenášet zatížení. Povrchy jsou navzájem nakloněny pod úhlem. Pokud jsou povrchy paralelní, tak tlakové pole přenesení zatížení nebude v mazací vrstvě vznikat [17].



Obr.3.1: Mazání v hydrodynamickém ložisku [17], upraveno

Dnes axiální ložiska používají pro vytvoření klínu olejového filmu tzv. „pad“. Je to zešíkmená sektorová ploška v dané vzdálenosti od středu. Axiální ložisko používá čtyři až sedm takovýchto plošek. Plošky jsou uspořádány po obvodu kruhu a směřují k rotujícímu disku. Pro výpočet se používá Reynoldsova rovnice ve válcových souřadnicích [39].

Je zde uvažován stacionární tok nestlačitelné viskózní kapaliny. Rovnováha sil působící na malý objemový prvek ve válcových souřadnicích  $(r, \theta, z)$  je vyjádřena:

$$\mu \frac{\delta^2 v_r}{\delta z^2} = \frac{\delta p}{\delta r} - \frac{\rho v_\theta^2}{r} \quad (3.1)$$

$$\mu \frac{\delta^2 v_\theta}{\delta z^2} = \frac{1}{r} \frac{\delta p}{\delta \theta}, \quad 0 = \frac{\delta p}{\delta r} \quad (3.2)$$


Po úpravách [43] získáme finální Reynoldsovu rovnici:

$$\frac{\delta}{\delta r} \left( r h^3 \frac{\delta p}{\delta r} \right) + \frac{1}{r} \frac{\delta}{\delta \theta} \left( h^3 \frac{\delta p}{\delta \theta} \right) = 6 \mu r \omega \frac{\delta h}{\delta \theta} \quad (3.3)$$


Kde  $p$  je tlak,  $\mu$  je koeficient viskozity,  $v_r$  je rychlost v radiálním směru,  $v_\theta$  je rychlost v obvodovém směru,  $\frac{\rho v_\theta^2}{r}$  je odstředivá síla,  $\omega$  je úhlová rychlost rotujícího disku a  $h$  je výška olejového filmu.

## 4. Proudění skutečných kapalin


U skutečných kapalin rozlišujeme dva druhy proudění, a to laminární nebo turbulentní. U laminárního proudění dochází k pohybu částic kapaliny ve vrstvách. Částice jedné vrstvy se nepromíchávají. Pokud nastane turbulentní proudění částice, kromě postupné rychlosti, mají rychlost turbulentní a přecházejí z jedné vrstvy do druhé. Důsledkem je výměna kinetické energie mezi částicemi, čímž se vyrovnávají rychlosti po průřezu. Dále dochází ke změně hybnosti při přemístění částic, což se projevuje brzdícím účinkem. Tím je výsledný hydraulický odpor proti pohybu větší než odpor při laminárním proudění, který odpovídá smykovému napětí od vazkosti. U laminárního proudění má hydraulický odpor proti pohybu lineární závislost na rychlosti. U turbulentního proudění vykazují závislost na druhé mocnině rychlosti [18].



Obr. 4.1 Laminární proudění kapaliny  $Re < Re_{kr}$  [38], upraveno



Obr. 4.2 Turbulentní proudění kapaliny  $Re > Re_{kr}$  [38], upraveno



Obr. 4.3 Rychlostní profil laminárního a turbulentního proudění [19], upraveno

K určení, zda se jedná o laminární nebo turbulentní proudění, slouží Reynoldsovo číslo. Reynoldsovo číslo je bezrozměrná veličina, která dává do souvislosti setrvačné síly a viskozitu [18]. Pokud Reynoldsovo číslo nepřesáhne kritickou hodnotu  $Re < Re_{kr}$ , jedná se o proudění laminární. Pokud kritickou hodnotu přesáhne  $Re > Re_{kr}$ , nastává proudění turbulentní. V kruhovém potrubí je kritická hodnota Reynoldsova čísla  $Re_{kr} = 2320$ .

$$Re = \frac{v \cdot d}{\nu} \quad (4.1)$$

Kde  $Re$  je Reynoldsovo číslo [-],  $d$  je hydraulický průměr trubice [m],  $v$  je střední rychlost v daném průřezu [ $\text{m} \cdot \text{s}^{-1}$ ],  $\nu$  je kinematická viskozita [ $\text{m}^2 \cdot \text{s}^{-1}$ ] [18].

Proudění tekutin vychází ze tří základních principů. Zákon zachování hmotnosti, hybnosti a energie. U skutečných tekutin zákon zachování hmotnosti popisuje rovnice kontinuity, Navier-Stokesova rovnice a Bernoulliho rovnice pro skutečnou tekutinu [18].

## 4.1 Rovnice kontinuity

Rovnice kontinuity je fyzikální rovnice, která popisuje ustálené proudění ideální kapaliny v uzavřené trubici a popisuje vztah mezi rychlostí proudění  $v$  a obsahem průřezu  $S$  v jednom místě trubice.

$$Q_{m1} = Q_{m2} \quad (4.2)$$

Dále rovnici můžeme rozepsat jako:

$$S_1 v_1 \rho_1 = S_2 v_2 \rho_2 \quad (4.3)$$

kde  $Q$  je hmotnostní tok [ $\text{kg} \cdot \text{s}^{-1}$ ],  $S$  je plocha průřezu [ $\text{m}^2$ ],  $v$  je rychlost proudění kapaliny [ $\text{m} \cdot \text{s}^{-1}$ ] a  $\rho$  je hustota [ $\text{kg} \cdot \text{m}^{-3}$ ].

Obecná rovnice pro neustálené prostorové proudění stlačitelné tekutiny ve vektorovém tvaru je

$$\iiint_V \frac{\delta(\rho)}{\delta t} dV + \iint_S \rho \mathbf{v} \cdot \mathbf{n} dS = 0 \quad (4.4)$$

kde  $t$  je čas [s] a  $\mathbf{v}$  je vektor rychlosti proudění kapaliny [ $\text{m} \cdot \text{s}^{-1}$ ].

## 4.2 Navier-Stokesova rovnice

Navier-Stokesova rovnice pro nestlačitelnou tekutinu zahrnuje vliv setrvačných sil  $F_s$  [N], vnějších sil  $F_o$  [N], tlakových sil, spojených s vlastním pohybem částic tekutiny  $F_p$  [N], a také vliv třecích sil způsobených viskozitou tekutiny  $F_t$  [N]. Rovnováhu sil lze zapsat ve tvaru

$$F_s = F_o + F_p + F_t \quad (4.5)$$

Zavedením elementárního objemu a stanovením rovnováhy sil na elementární objem lze zapsat Navier-Stokesovu rovnici ve vektorovém tvaru.

$$\frac{\delta \mathbf{v}}{\delta t} + \mathbf{v} \cdot \text{grad} \mathbf{v} = \mathbf{a} - \frac{1}{\rho} \text{grad} p + \frac{\mu}{\rho} \Delta \mathbf{v} \quad (4.6)$$

kde  $\frac{\delta v}{\delta t}$  je lokální derivace nezávislá na přemístování tekutiny,  $\mathbf{v} \cdot \text{grad} \mathbf{v}$  je konvektivní člen závislý na rychlosti přemístění částice tekutiny,  $\frac{\mu}{\rho} \Delta \mathbf{v}$  je vazký člen představující třecí sílu v důsledku viskozity tekutiny a  $\mathbf{a}$  je vnější zrychlení [ $\text{m} \cdot \text{s}^{-2}$ ][18].

### 4.3 Bernoulliho rovnice

Bernoulliho rovnice pro skutečnou tekutinu vychází z Navier-Stokesovy rovnice, kdy předpokládáme ustálené proudění  $\frac{\delta v}{\delta t} = 0$  a působení pouze tíhového zrychlení, ve tvaru

$$\frac{p_1}{\rho} + \frac{v_1^2}{2} + g h_1 = \frac{p_2}{\rho} + \frac{v_2^2}{2} + g h_2 + Y_z \quad (4.7)$$

kde  $p$  je tlak v kapalině [Pa],  $\rho$  je hustota kapaliny [ $\text{kg} \cdot \text{m}^{-3}$ ],  $\mathbf{v}$  je rychlost proudění kapaliny [ $\text{m} \cdot \text{s}^{-1}$ ],  $g$  je tíhové zrychlení [ $\text{m} \cdot \text{s}^{-2}$ ],  $h$  je poloha [m] a  $Y_z$  je měrná ztrátová energie [ $\text{J} \cdot \text{kg}^{-1}$ ].

Měrnou ztrátovou energii  $Y_z$  lze vyjádřit pomocí polohové, tlakové nebo kinematické energie

$$Y_z = g \cdot h_z = \frac{p_z}{\rho} = \xi \cdot \frac{v^2}{z} \quad (4.8)$$

kde  $h_z$  je ztrátová výška [m],  $p_z$  je tlaková ztráta [Pa] a  $\xi$  je ztrátový součinitel [-][18].

### 4.4 Proudění viskózních tekutin tenkými mezerami

Při proudění viskózních kapalin v tenkých mezerách se většinou můžeme setkat se třemi základními stavy. První proudění, které bylo popsáno, je proudění mezi rotujícími součástmi a plochou. Toto proudění popsal Cole, Keller a Saffman. V dalším případě proudění se jedná o proudění mazací vrstvou krátkého radiálního ložiska, která byla popsána Horim. Posledním z těchto stavů je olejový film u axiálního ložiska, který byl popsán Stachoviakem a Batchelorem [21].

Proudění mezi rotující součástí a plochou, za předpokladu teorie mazání a izotermického filmu, které splňují Boyleův- Mariottův zákon a Navier-Stokesovu rovnici, se můžou vyjádřit rovnicí pro tlak.

$$\frac{d}{d\phi} \left( \frac{p}{p_0} \right) = \beta \cos^2 \phi - \alpha \left( \frac{p_0}{p} \right) \cos^4 \phi \quad (4.9)$$

kde  $\phi$ , nebo  $x$  je nezávislá proměnná definována jako

$$x = (2Rh)^{1/2} \tan \phi \quad (4.10)$$

kde  $R$  je poloměr rotující součásti,  $h$  je výška (vzdálenost rotující části a plochou), dále  $\omega$  je úhlová rychlost rotující části a  $U$  je obvodová rychlost.

$$U = R\omega \quad (4.11)$$

Parametr  $\alpha$  je definována jako

$$\alpha = \frac{12\mu F}{p_0\rho_0} \left(\frac{2R}{h^5}\right)^{1/2} \quad (4.12)$$

Parametr  $\beta$  je definována jako

$$\beta = \frac{6\mu U}{p_0} \left(\frac{2R}{h^3}\right)^{1/2} \quad (4.13)$$

Kde  $\mu$  je koeficient viskozity a  $F$  je hmotnostní tok na jednotku v olejovém filmu,  $p_0$  je tlak a  $\rho_0$  je hustota. Za předpokladu splnění všech okrajových podmínek, kdy

$$p(-\pi/2) = p(\pi/2) = p_0 \quad (4.14)$$


Po dodržení všech podmínek a dosazení dostaneme svislý tah  $T$  na ložisku

$$T = \int (p - p_0) dx = p_0(2Rh)^{1/2} \int_{-(\frac{1}{2})\pi}^{(\frac{1}{2})\pi} \left(\frac{p}{p_0} - 1\right) \sec^2 \phi d\phi \quad (4.15)$$

Vzorec, který je uveden, lze po malých úpravách použít ve většině konfiguracích, které jsou podobné nebo stejné. Pokud je mazivo protlačováno mezerou tlakovým spádem, s tlakem na vstupu, kdy platí  $p_0$  ( $x < 0$ ) a tlakem na výstupu, kdy platí  $p_2 < p_0$  ( $x > 0$ ), stačí nám pouze poupravit okrajové podmínky naší rovnice. Naše úprava okrajových podmínek bude vypadat jako:

$$p(-\pi/2) = p_0, \quad p(\pi/2) = p_2 \quad (4.16)$$

Většinou se zjišťuje  $p(\phi)$  a  $\alpha$  tak, aby byly splněny rovnosti (4.9) podmínky (4.16) pokud jsou tyto podmínky splněny, bude proudění nazýváno buď volné proudění nebo nucené proudění [21].



Obr.4.4: Rovnováha sil na elementární objem [21], upraveno

U volného proudění je pro malé  $\beta$  problém u rovnice (4.9) s okrajovou podmínkou (4.16) pravidelný. Pro malé  $\beta$  je řešení vyjádřeno jako mocninová řada v  $\beta$ .

Rovnice druhého řádu:

$$\left(\frac{p(\phi)}{p_0}\right) = 1 - \frac{\beta}{3} \sin\phi \cos^3\phi + \frac{\beta^2}{18} \cos^8\phi + O(\beta^3) \quad (4.17)$$

$$\alpha = \frac{4}{3} \beta + O(\beta^3) \quad (4.18)$$

$$\frac{T}{p_0 \sqrt{2Rh}} = \frac{5\pi}{288} \beta^2 + O(\beta^3) \quad (4.19)$$

Pro řešení  $\beta \gg 1$  po zavedení podmínek dle [21].

$$y\left(\frac{\pi}{2}\right) = -y\left(\frac{\pi}{2}\right) = 1 \quad (4.20)$$

$$y(0) = \frac{p}{p_0} \quad (4.21)$$

Získáme tah na ložisku z (4.15):

$$\frac{T}{p_0 \sqrt{2Rh}^{1/2}} = \frac{1}{y(0)} \int_{-\frac{1}{2}\pi}^{\frac{1}{2}\pi} [y(\theta) - y(0)] \csc^2\theta d\theta \quad (4.22)$$

U nuceného proudění musíme řešit u rovnice (4.9) pro okrajové podmínky (4.16), kde  $p_2 < p_0$ . Pro  $\beta = 0$  v rovnici (4.9), kde je nucené proudění aplikováno na mezeru stacionární rotující části.

Integrace vede na:

$$\left(\frac{p(\phi)}{p_0}\right)^2 = 1 - \frac{\alpha}{2} \left[ \frac{3}{2} \left(\phi + \frac{\pi}{2}\right) + \sin 2\phi + \frac{\sin 4\phi}{8} \right] \quad (4.23)$$

Podmínka (4.17– 4.19) je splněna, pokud  $\alpha$ , určující hmotnostní tok má hodnotu:

$$\alpha = \frac{16}{3\pi} \left[ 1 - \left(\frac{p_2}{p_0}\right)^2 \right] \quad (4.24)$$

Pomocí tohoto řešení lze odvodit nucený průtok mřížkou nebo mřížkovým stacionárním válcem popsaným Kellerem pro nestlačitelnou kapalinu [44].



## 5. Návrh experimentů

Návrh experimentů je konstrukce jakéhokoli úkolu, který má za cíl popsat nebo vysvětlit změny. Změna jedné nebo více nezávislých proměnných se obecně označuje jako "proměnné proměnné" nebo "proměnné odezvy". Experimentální návrh může být proto schopen identifikovat faktory ovlivňující výsledky. Experimentální návrh předpokládá nejen výběr vhodných nezávislých a závislých proměnných, ale plánování experimentu a statisticky optimálních podmínek vzhledem k omezením dostupných zdrojů. Existuje několik přístupů k určení množiny návrhových bodů (jedinečné kombinace nezávislých proměnných), které mají být použity v experimentu. Výběr správné techniky metamodelování většinou probíhá těmito kroky [22][23].

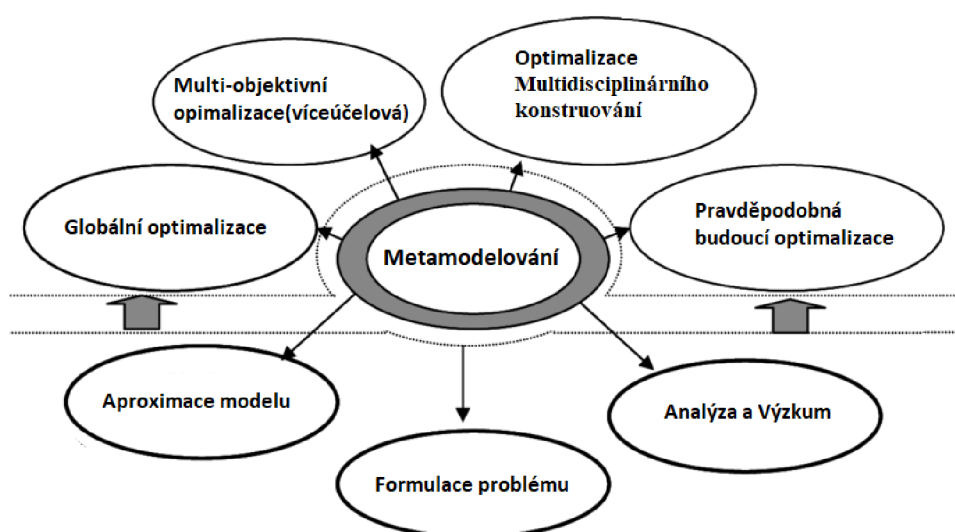
Dobře navržený experiment má za cíl, při co nejmenším počtu měření získat, co nejvíce informací o chování navrhovaného systému. Ke konstrukci tohoto přibližného popisu lze využít matematických aproximačních metod s metodami plánování experimentu. Tomuto celku se říká ve zkratce metamodelování. Metamodelování má mnoho možností a aplikací. Používá se ve strojírenství, kde jsou zkoušené optimalizační výrobky a výrobní plány navrhovány současně. [23].

Tab.5.1: Technika metamodelování [24], upraveno

VÝBĚR NÁVRHU	VÝBĚR MODELU	PŘÍZPŮSOBNÍ MODELU	TECHNIKY MODELOVÁNÍ
<b>Ruční výběr</b>	Síť neuronů	Zpětná propagace	Neuronové sítě
<b>Náhodný výběr</b>	Databáze pravidel nebo rozhodovací strom	Entropie	Strojové učení
<b>D - Optimální</b>	Realizace Stochastického procesu	Nejlepší nestranný lineární odhad	Kriging
<b>Centrálně složený</b>	Polynom (lineární, kvadratický)	Regrese nejmenších čtverců	Responzní plochy

## 5.1 Metamodelování

Multidisciplinární konstruování má mnoho možností a aplikací ve strojírenství, kde jsou zkoušené optimalizující produkty a výrobní plány navrhovány současně. Cílem je, aby mohl konstruktér zasahovat, opravovat, analyzovat problémy a provádět rychlé hodnocení návrhu, popřípadě měnit či vylepšovat. Pomocí počítačů tyto modely mohou sloužit k analýze mnoha složitých inženýrských systémů. Tyto modely mají výhodu v rychlosti a kvalitě, oproti časově náročným a nákladným experimentům na fyzických systémech. Současný výzkum přibližuje vstupní a výstupní vztah disciplinárního modelu se středním počtem počítačových experimentů, a poté použije přibližný vztah předpovědí (výsledků) na dalších nezpracovaných vstupních informacích. Tyto disciplinované specifické modely produktů a procesů jsou modely inženýrských modelů a nazývají se metamodely „model modelu“ [25][26].



Obr.5.1 Optimalizační okruh [27], upraveno

Metamodeling je proces zahrnující volbu experimentálního návrhu, typu metamodelu a jeho funkční podobu pro validační strategii pro posouzení vhodnosti metamodelu. S ohledem na tuto definici nyní diskutujeme o typech návrhů metamodelu a experimentů, které jsou využity v této studii. Pro náš experiment bylo zvoleno řešení pomocí neuronových sítí [28].

## 5.2 Neuronové sítě

Umělá neuronová síť je jeden z nejnovějších výpočtových modelů, který se používá v umělé inteligenci pro predikci a optimalizaci. Vzorem neuronových sítí je lidský a zvířecí nervový systém, kde základním stavebním prvkem tohoto nervového systému je neuron. U umělé neuronové sítě je to perceptron. Síť je struktura určena pro distribuované paralelní zpracování dat [31].

Warren McCulloch a Walter Pitts vytvořili první výpočetní model pro neuronové sítě, založený na matematice a algoritmech, který se nazývá prahová logika. Tento model následně pomohl popsat fungování neuronové sítě i pochopení lidského nervového systému. Jeden přístup byl zaměřen na aplikaci neuronových sítí na umělou inteligenci a druhý byl zaměřen na biologické procesy v mozku. Většina umělé inteligence se soustředila na modely, které byly zpracované pomocí algoritmů, které byly charakterizovány expertními systémy se znalostmi pravidel IF-THEN [31].

Jako největší výhodu umělých neuronových sítí můžeme považovat takzvaný paralelizmus. To je schopnost operačního systému dělat několik procesů současně. Jádro operačního systému velmi rychle střídá na procesoru běžící procesy. Umělé neuronové sítě se hlavně používají na problémové úlohy, jako jsou klasifikace, aproximace a predikce. Neuronová síť je většinou složena z mnoha jednoduchých procesů neuronů (perceptronů) [32].

Nejjednodušším modelem je dopředná neuronová síť perceptronů. Je vytvořena pouze z jednoho neuronu. Byla vynalezena Frankem Rosenblattem v roce 1957. Jeho použití je ale pouze pro množiny, které jsou lineárně separovatelné. Byl z ní vytvořen perceptron, který už mohl být použit pro složitější úlohy a problémy [32].

Perceptron je binární klasifikátor, který mapuje vektor vstupů  $\mathbf{x} = [x_1, x_2, \dots, x_n]$  na vstupní hodnoty  $f(\mathbf{x})$ .

$$f(\mathbf{x}) = \begin{cases} 1 & \text{pro } \omega \mathbf{x} + b > 0 \\ 0 & \text{jindy} \end{cases} \quad (5.1)$$

Kde omega je vektor vah a b je konstanta. Perceptron je jednovrstvená neuronová síť s dopředným šířením a tzv. učením s učitelem.

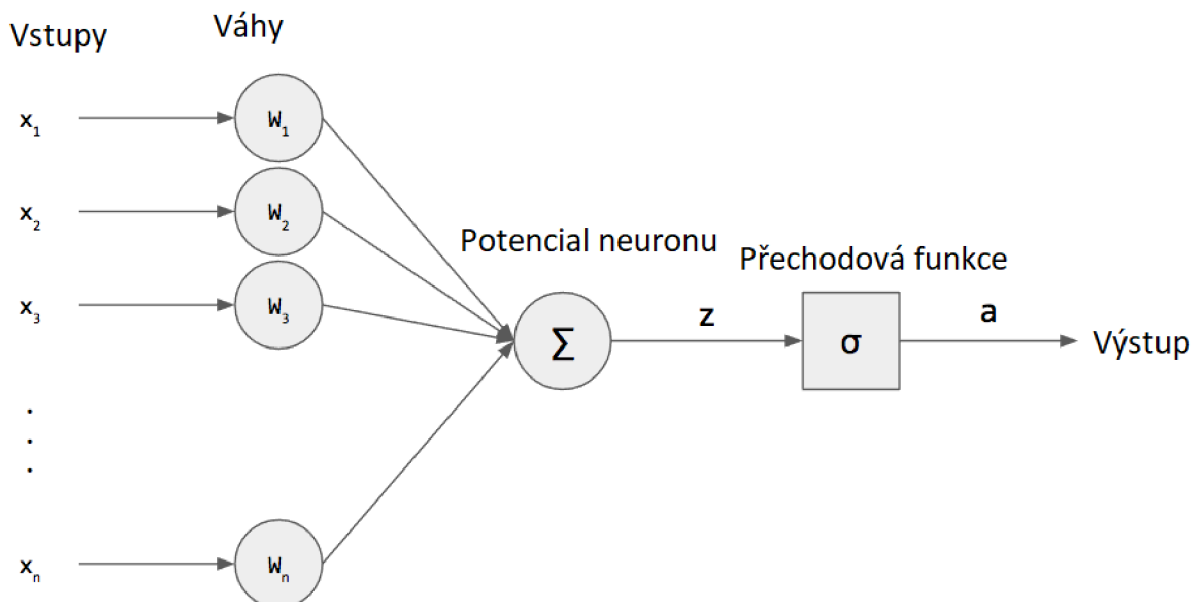
Celkový podnět neuronů udává vážený součet.

$$\varepsilon = \sum_{i=1}^N \omega_i - \theta \quad (5.2)$$

Tento celkový podnět bývá často označován jako potenciál neuronu. Na tento potenciál reaguje neuron výstupní odezvou

$$Z = S(\varepsilon) \quad (5.3)$$

Kde  $S$  je tzv. přenosová funkce. Když je přenosová funkce ve tvaru skokové, tak se jedná o zmíněný perceptron fungující jako binární klasifikátor [32].



Obr.5.2 Základní neuronová síť (jednoduchý perceptron) [31], upraveno

U perceptronu je základem rozlišit, o jaké vstupy se jedná, které identifikujeme z naší zadané úlohy. Vstupy mohou být podněty z vnějšího okolí nebo mohou být jako výstupy ze skryté vrstvy předešlých neuronů. Každý vstup je rozšířen o váhu tohoto vstupu. Vlastní perceptron obsahuje prahovou hodnotu, která se někdy nazývá potenciál neuronu. Při překonání tohoto potenciálu je neuron nabuzen a indikuje signál ve výstupu ve formě přechodové funkce viz Tab.5.2. [32].

U neuronových sítí se tyto přechodové funkce hojně používají. Při experimentování vyšlo najevo, že nejlepší využití má přechodová funkce sigmun, funkce sigmoidální a funkce lineární. Tyto přechodové funkce u nabuzeného neuronu modulují jeho výstupní signál, který je nadále směřován do úrovně neuronové sítě. Výběr vhodné přechodové funkce má vliv na konvergenci výpočtu a naučení neuronové sítě [32].

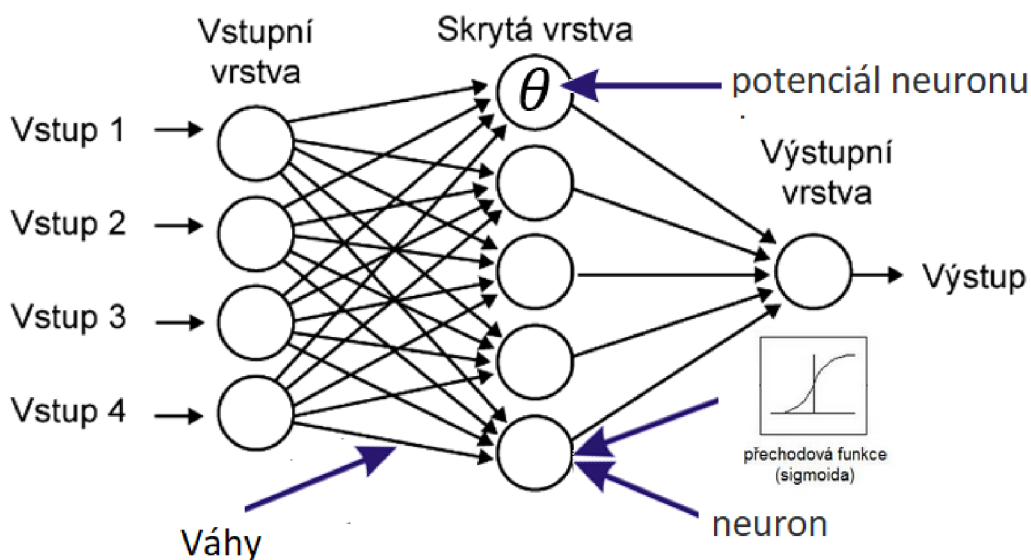
Tab.5.2 Nejčastěji používané přechodové funkce pro Neuronové sítě [32], upraveno

	<p>Funkce jednotkového skoku (<i>hardlim</i>).</p> <p>Standardní výstup nenabuzeného neuronu je hodnota 0, po nabuzení -1.</p>
	<p>Aktivační funkce signum (<i>hardlims</i>).</p> <p><math>Y(x) = \text{sign}(x) = 1</math> pro <math>x &gt; 0</math> a <math>Y(x) = \text{sign}(x) = -1</math> pro <math>x &lt; 0</math>.</p>
	<p>Lineární aktivační funkce (<i>purelin</i>).</p> <p><math>Y(x) = x</math></p>
	<p>Aktivační funkce hyperbolický tangens (<i>tansig</i>).</p> <p>Využití u Elmanových neuronových sítí.</p>
	<p>Sigmoidální aktivační funkce (<i>logsig</i>).</p> <p><math>Y(x) = 1/(1+e^{-x})</math></p> <p>Využití zejména u vícevrstevných perceptronových sítí.</p>
	<p>Saturační přenosová funkce (<i>satlins</i>).</p> <p>Využívána pro omezení velikosti vstupního signálu.</p>

## 5.2.1 Vícevrstvá neuronová síť

Jednou z nepoužívanějších neuronových sítí je vícevrstvá neuronová síť. Tato síť může mít několik skrytých vrstev neuronů, které leží mezi vstupní a výstupní vrstvou. Neuron vstupní vrstvy posílá svůj vstup ke všem ostatním neuronům vnitřní vrstvy. Výstupy vnitřní vrstvy jsou přivedeny na vstupy každého neuronu vyšší vrstvy a jsou vynásobeny váhami. Jedna z největších výhod vícevrstvé neuronové sítě je, že může být použita pro velmi složité úkoly. Jedna z vlastností je, že síť je tvořena opakováním základního stavebního prvku perceptronu. Počet vstupních neuronů je dán počtem vstupů matematického modelu. Počet výstupních neuronů je ovlivněn kódováním výstupu. Většinou se vícevrstvá síť učí systémem učení s učitelem. Jako základní přechodové funkce se volí lineární nebo sigmoidální funkce. Učícím algoritmem je nejčastěji algoritmus zpětné propagace (Back Propagation Error) [33].


Pro učení s učitelem je dobré mít vhodně vybraná učební data dostatečně reprezentující jednotlivé stavy úlohy. Ve výpočetním procesu by měla síť umět rozhodovat a popsat a popřípadě se ji naučit. Pokud v procesu korekcí sítě dojde k situaci, kdy síť nemá požadovanou klasifikační schopnost, tak se může přikročit k přidání neuronu do skryté vrstvy. Učící soubor se může případně rozšířit o stavy, kde neuronová síť má problémy s určením výsledku. V procesu tohoto učení většinou klesá hodnota chybové funkce do stavu, kdy se asymptoticky blíží k nule. Při stavu chybové funkce neuronové sítě rovnající se nule, se jedná o lineární klasifikátor. Toto je nežádoucí stav, neboť síť pak postrádá obecnou generalizační schopnost a již není schopna rozhodovat o jiných datech, než které se naučila [32].



Obr:5.3: Vícevrstvá neuronová síť [34], upraveno

## 5.2.2 Samoorganizující se neuronové sítě


Samoorganizující neuronová síť se v poslední době stala velmi oblíbenou sítí. Někdy je také nazývána Kohonenovou mapou, po svém tvůrci Kohenovi. Tato síť patří do skupiny samoučících se neuronových sítí s učením bez učitele. Tyto sítě nepotřebují ke svému nastavování ideální vzory. To znamená, že k učení sítě stačí jen velká skupina reálných signálů, z nichž většinou některé mají určitou společnou vlastnost nebo naopak výrazné odlišnosti. Již k nim nemusí být přiřazeny žádné ideální učící signály nebo informace. Ty udávají konečný cílový stav, do kterého se má síť svým učením dostat. U Kohonenovy mapy nám například stačí jen skupina nahraných řečových signálů a během učení si síť již sama nalezne společné znaky a odlišnosti, podle kterých se bude rozhodovat [32].



Obr.5.4 Samoorganizující neuronová síť [37], upraveno

### 5.2.3 Hopfieldovy sítě

Jedna z velmi důležitých neuronových sítí je Hopfieldova síť, která už byla navržena McCullochem a Pittsem [40]. Hopfieldova síť vychází z energetické funkce, ze které jsou odvozena pravidla pro učení a vybavování. Na následujícím obrázku je zobrazena základní topologie sítě. Výstup z každého neuronu je přiváděn na vstup všech ostatních neuronů. Všechny neurony jsou jak vstupní, tak výstupní. Míra vzájemné spojitosti neuronů je vyjádřena váhou. Žádný neuron není spojen sám se sebou, váha je nulová. A výstup sítě je obvykle binární, tedy 0 nebo 1 [34].



Obr.5.5 Hopfieldova síť [34], upraveno

### 5.2.4 RBF sítě

Neuronové sítě typu RBF jsou jedny z nejmladších modelů neuronových sítí. Tyto sítě mohou být využity jako alternativa ke klasickým modelům, například k vícevrstevným sítím. Radiální funkce bývá určena svým středem a její hodnota závisí na vzdálenosti. Pro argumenty se stejnou vzdáleností od tohoto středu dávají stejné funkční hodnoty [35][36][41].

V režimu vybavování se předkládají jednotlivé vstupní vektory a naučená RBF síť reaguje vystavením příslušné odezvy. Vystavením se rozumí výpočet nejbližšího vzoru a na výstupu je poté vážený součet vstupu výstupní vrstvy (výstupu RBF jednotek) [35][36].




## 6. Výpočtový model

Výpočtový model se týká hydrodynamického ložiska turbodmychadla a všechny potřebné rovnice a veličiny již byly popsány v práci. Výpočetní model byl vytvořen tak, že bylo definováno, o jaký typ hydrodynamického ložiska se jedná a definovány základní rozměry daného ložiska. Dále byl výpočetní model sestaven s použitím Reynoldsovy rovnice (3.3). Výpočtový model byl vytvořen v rámci řešení výzkumného projektu na FSI VUT ve spolupráci s průmyslovým partnerem a nemůže být zveřejněn.




Obr.6.1: Hydrodynamické ložisko turbodmychadla[39]

U vybraného ložiska byla určena výpočetní oblast. Tato výpočetní oblast byla definována jako střed axiálního ložiska, ve kterém vzniká olejový film. Dále byly popsány důležité rozměry této oblasti.



Obr.6.2: Umístění a vyvážení axiálního ložiska pro výpočtový model [38]



Obr.6.3: Hlavní rozměry padu na ložisku [38]

$\omega$ - úhlová rychlost

$D1$ - minimální průměr funkční plochy

$R_{min}$  - minimální poloměr vyústění kanálku

$S$  – poměr úhlu polohy kanálku k úhlu padu


$h$ - minimální tloušťka vrstvy mazacího oleje

$D0$ - maximální průměr funkční plochy

$R_{max}$ - maximální poloměr vyústění kanálku


$\Phi$ - velikost počítané funkční plochy

Definice okrajových podmínek na jednom z padu ložiska.




Obr.6.4: Definice okrajových podmínek [38]

Po definici okrajových podmínek, mezi které patřily také definované tlaky na hranicích počítané oblasti ( $R_0, R_1, \phi_0=\phi_1$ ) byl výpočtový model upraven tak, že pad byl rozdělen na síť bodů a převeden z kruhové výseče na ortogonální. Dále byl výpočtový model počítán pomocí metody konečných diferencí.



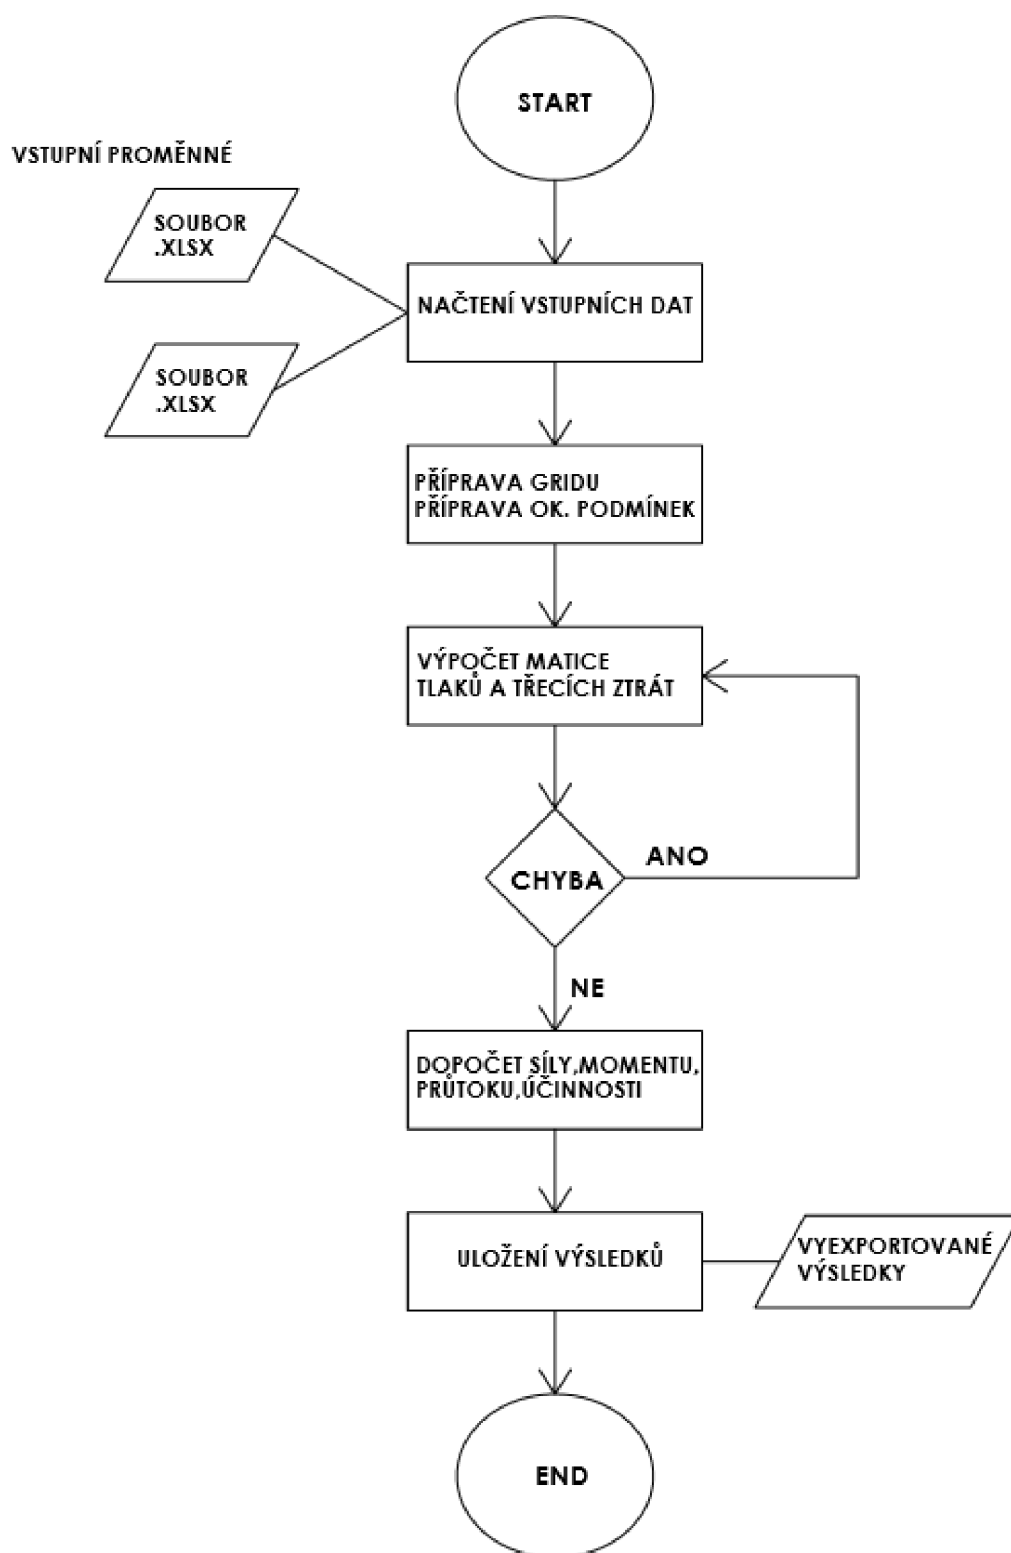
Obr.6.5: Převedení kruhové výseče na čtvercovou (ortogonální) pro metodu konečných diferencí [38]

Dále byl model počítán pomocí metody konečných diferencí, kde v jednotlivých uzlech byla provedena náhrada derivací příslušnými diferencemi a dále byla řešena soustava vzniklých algebraických lineárních diferenčních rovnic.



Obr.6.6: Výpočtová oblast s uzlovými body [38]

Iterativně byl propočítáván celý grid tak dlouho, dokud nebyla splněna ukončující podmínka (velikost chyby, nebo maximální počet iterací). Postup celého výpočtu je uveden ve vývojovém diagramu na obr 6.7.



Obr.6.7: Vývojový diagram programu [38]

## 7. Metamodel

Výpočtový model byl aproximován pomocí vícevrstvé neuronové sítě a tato síť byla sestavena pomocí Kerasu. Keras, „nastavba TensorFlow“ je API (Application programming interface), což je rozhraní pro programovací aplikaci, kde můžeme najít plno postupů a knihoven, které jsou schopny zjednodušit tvorbu umělých neuronových sítí. TensorFlow je end to end dostupná platforma pro strojové učení. Metamodel byl naprogramován v programovacím jazyku Python 3.7.

Při tvorbě neuronové sítě byl zvolen sekvenční model. Hlavními argumenty této neuronové sítě byly optimalizátor, přechodová funkce, počet vstupů, počet skrytých vrstev, výstup, epochy (perioda), batch\_size (objem várky), verbose (rozsah výpisu).

Jako optimalizátor byl vybrán SGD. Je to optimalizátor sestupného gradientu, který se vyznačuje tím, že podporuje rychlost učení. Přechodové funkce byly zvoleny tanh a sigmoid, protože po několika experimentech aproximace různých funkcí byly tyto přechodové funkce nejpřesnější a nejvíce dosahovaly potřebných výsledků. Počet vstupů byl volen podle požadované aproximované funkce. Počet skrytých vrstev byl volen dle výsledků a doporučení Kerasu. Obvykle byly voleny 3 skryté vrstvy neuronů. Počet výstupů byl dán zadáním. Epocha je iterace pro trénování modelu přes všechna vstupní data. Batch\_size je objem várky (počet vzorků na aktualizaci gradientu). Verbose lze chápat jako parametr pro „indikaci průběhu“.

```
1
2 import keras
3 from keras.datasets import mnist
4 from keras.models import Sequential
5 from keras.layers import Dense, Dropout, Flatten
6
7 def __init__(self, x, y):
8     self.x = x
9     self.y = y
10
11     input_shape = (2,)
12
13     self.model = Sequential()
14     self.model.add(
15         Dense(32, activation='tanh',
16              input_shape=input_shape))
17     self.model.add(
18         Dense(64, activation='sigmoid'))
19     self.model.add(Dense(32, activation='sigmoid'))
20     self.model.add(Dense(1, activation='tanh'))
21
22     sgd = keras.optimizers.RMSprop(lr=0.01)
23     self.model.compile(loss=keras.losses.mean_squared_error, optimizer=sgd, metrics=['mae'])
24     epochs = 500
25     batch_size = 20
26     history = self.model.fit(x, y, batch_size=batch_size, epochs=epochs, verbose=1, )
```

Obr.7.1: Neuronová síť část programu [38]

Potom, co byla neuronová síť vytvořena, bylo na ní zkoušeno několik funkcí. Po těchto zkouškách byl proveden výpočet hodnoty kvality aproximace pomocí koeficientu determinace. Koeficient nabývá hodnot 0 až 1, kde čím vyšší hodnoty, tím lepší jsou aproximační schopnosti neuronové sítě.

$$R^2 = \frac{SS_M}{SS_T} = \left(1 - \frac{SS_E}{SS_T}\right) 100[\%] \quad (7.1)$$

Kde  $SS_M$  je součet modelu,  $SS_T$  je celkový součet čtverců,  $SS_E$  je součet čtverců rezidiu a  $R^2$  je koeficient determinace

$$SS_M = \sum_{i=1}^n (Y'(\mathbf{X}_i) - Y')^2 \quad (7.2)$$

$$SS_T = \sum_{i=1}^n (Y(\mathbf{X}_i) - Y')^2 \quad (7.3)$$

$$SS_E = \sum_{i=1}^n (Y(\mathbf{X}_i) - Y'(\mathbf{X}_i))^2 \quad (7.4)$$


$$Y' = \frac{1}{n} \sum_{i=1}^n Y(\mathbf{X}_i) \quad (7.5)$$

Kde  $Y'$  je aproximace metamodelu,  $Y$  je aproximovaná funkce,  $\mathbf{X}_i$  jsou vstupní hodnoty.

Vytvořená neuronová síť byla nejdříve vyzkoušena na jednodušší funkci a to  $\sin(x)$  a poté byla provedena kontrola, jak dobře se neuronová síť naučila tuto funkci a jak dobře jí aproximuje.


$$Y_{(x)} = \sin(x) \quad (7.6)$$

Funkce, kterou se neuronová síť naučila:



Obr.7.2: Funkce  $\sin(x)$  [38]

Na obrázcích je naznačen průběh učení a jak se neuronová síť učila  $\sin(x)$ . Můžeme pozorovat, že čím více iterací, tím více se přibližujeme původní funkci.



Obr.7.3: Průběh učení funkce  $\sin(x)$  [38]

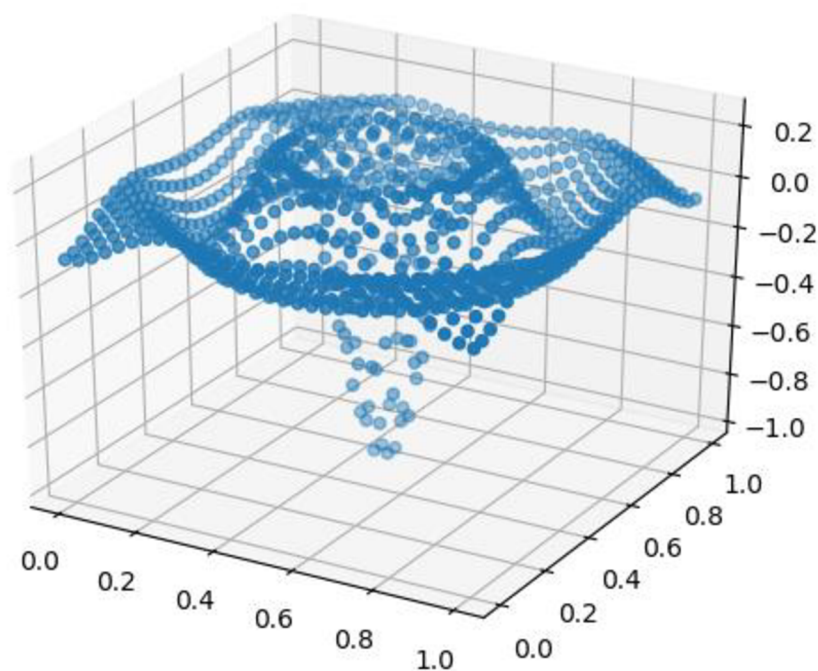
Zde vidíme průběh hodnocení pomocí koeficientu determinace pro jednotlivé iterace.

Tab.7.1: Průběh hodnocení pomocí koeficientu determinace [38]

n	1	2
R	$R_1^2=0,897$	$R_2^2=0,923$


Dále byla neuronová síť použita pro funkci „Rickerovy vlny“. Byl vytvořen experimentální plán 10x10, 20x20, 30x30 a byla použita neuronová síť, která byla vytvořena pro tento případ.

$$Z_{(x,y)} = \sin(\sqrt{x^2 + y^2})$$




Obr.7.4: Funkce Rickerovy vlna [38]


Zde můžeme vidět průběh učení Rickerovy vlny v závislosti na experimentálním plánu. U neuronové sítě můžeme pozorovat, že čím více počtu zadaných bodů v experimentálním plánu, tím lepší aproximace funkce. Hodnocení metamodelu bylo provedeno koeficientem determinace.




Obr.7.5: Experimentální plán 10x10 [38]



Obr.7.6: Aproximace první iterace [38]



Obr.7.7: Experimentální plán 20x20 [38]



Obr.7.8: Aproximace druhá iterace [38]

Dále byly zapsány výsledky pro funkci Rickerovy vlny: koeficient determinace, nalezený extrém,

Tab.7.2: Tabulka výsledků pro funkci Rickerovy vlny [38]


iterace	$R^2$	Extrém funkce (:,0)	Extrém funkce (:,1)	Exp.plán
1	0.08596	0.3254	0.8975	10x10
2	0.96896	0.5002	0.4879	20x20
3	0.99684	0.5000	0.4998	30x30




## 8. Výsledky

Byla provedena optimalizace pomocí Nelder-Mead metody, která je dostupná v Pythonu. Za účelem nalezení a určení globálního extrému byla optimalizace prováděna pro sérii náhodně generovaných bodů. Optimalizované parametry byly UPAD (Sklon funkční plochy) a SPAD (Poměr velikosti funkční plochy vůči celkové velikosti segmentu).


### 8.1 Neuronová síť (Full faktoriál)




Obr.8.1: Experimentální plán 5x5 [38]



Obr.8.2: Aproximace první iterace [38]




Obr.8.3: Experimentální plán 10x10 [38]



Obr.8.4: Aproximace šestá iterace [38]

Bylo sestaveno několik experimentálních plánů na principu full faktoriál od 5x5 do 20x20, od plánu 10x10 bylo zpozorováno, že výsledky už se výrazně neměnily. Tím se potvrdilo, že aproximace u plánu 10x10 byla úspěšná a další plány pro určení extrému už nebyly potřebné. Výsledky jsou zapsány v Tab.8.1.



Obr.8.5: Koefficient determinace v závislosti na počtu bodu [38]


Průběh determinačního koeficientu pro experimentální plán typu full faktoriál. K nalezení kvalitní aproximace dochází při plánu 10x10.

Tab.8.1: Nalezené hodnoty optimalizovaných parametrů pro UFP [38]


Počet bodů	R <sup>2</sup>	Optimalizovaný parametr		Třecí moment [N.m]
		SPAD	UPAD	
UFP5x5	0,713	1,969	0,715	0,118
UFP6x6	0,814	1,723	0,714	0,132
UFP7x7	0,886	0,919	0,826	0,159
UFP8x8	0,971	0,912	0,817	0,160
UFP9x9	0,932	0,998	0,568	0,478
UFP10x10	0,986	0,830	0,602	0,648
UFP20x20	0,990	0,915	0,572	0,549

## 8.2 Neuronová síť (Halton)


Bylo sestaveno několik experimentálních plánů na principu Haltonovy sekvence. Kvazináhodná sekvence, která se vyznačuje nízkou diskrepancí a je navržena tak, aby se body co nejvíce navzájem vyhýbaly. [39]




Obr.8.6: Experimentální plán Halton 16 [38]



Obr.8.7: Aproximace první iterace [38]




Obr.8.8: Experimentální plán Halton 256 [38]



Obr.8.9: Aproximace pátá iterace [38]

U Haltonovy sekvence byly pozorovány velké rozdíly mezi první a druhou iterací. Výsledky se využitím dalších experimentálních plánů ustálily.

Průběh determinačního koeficientu pro experimentální plán typu Halton. K nalezení kvalitní aproximace dochází už u první iterace. Ale toto může být bráno i jako náhoda. Po dalších iteracích se výsledky ustálily na hodnotě 0.94.



Obr.8.10: Koefficient determinace v závislosti na počtu bodu [38]

Tab.8.2: Nalezené hodnoty optimalizovaných parametrů pro Haltona [38]

Počet bodů	R <sup>2</sup>	Optimalizovaný parametr		Třecí moment [N.m]
		SPAD	UPAD	
H16	0,888	1,141	0,215	0,011
H32	1,000	0,901	0,739	0,648
H64	0,958	0,985	0,579	0,478
H128	0,937	0,975	0,651	0,436
H256	0,944	0,981	0,522	0,544

## 9. Diskuze

### 9.1 Neuronová síť

Neuronová síť byla použita pro úspěšnou tvorbu metamodelu nad výpočtovým modelem. Prezentovaná metoda dosáhla velmi zajímavých výsledků, protože byla aplikována na dva různé experimentální plány. U experimentálního plánu UFP lze pozorovat, že optimalizované výsledky se ustálily mezi experimentálním plánem 10x10 a 20x20. Hodnocení neuronové sítě pomocí determinančního koeficientu se pohybovalo v intervalu 0,9-1. U experimentálního plánu vytvořeného pomocí Haltonovy sekvence lze pozorovat, že výsledky byly ustálenější než u UFP, ale nakonec se při posledních iteracích taktéž blížily k výsledkům UFP.

Velká výhoda oproti ostatním metodám, popř. přístupům, jako je kriging nebo přímá optimalizace pomocí genetického algoritmu, byla časová úspora.

### 9.2 Přímá optimalizace pomocí genetického algoritmu

Pro účel kontroly našich hodnot, které byly vytvořeny pomocí našeho metamodelu techniky neuronových sítí. Byla s použitím genetického algoritmu provedena optimalizace na úrovni výpočtového modelu. Výsledky se v posledních iteracích podobaly, takže náš metamodel můžeme považovat za úspěšný.

Tab.9.1: Nalezené hodnoty přímé optimalizace pomocí genetického algoritmu [38]

Nejlepší jedinci	Optimalizovaný parametr		Třetí moment [N.m]
	SPAD	UPAD	
1	0,924	0,54	0,64144
2	0,919	0,54	0,64156
3	0,917	0,54	0,64159
4	0,921	0,52	0,64163
5	0,924	0,52	0,64164

---

## ZÁVĚR

Cílem práce je návrh výpočtového modelu proudění oleje v mazací vrstvě axiálního ložiska turbodmychadla s jeho následnou optimalizací. Proto se práce v rešeršní části zabývá popisem a pochopením optimalizace a jaké je její využití v praxi. Je zde popsána historie a na jakém principu funguje turbodmychadlo. Dále následuje popis hlavních částí turbodmychadla, které jsou důležité pro jeho optimalizaci jako celku. Nejvíce byl kladen důraz na popis hydrodynamického ložiska a popis principu jeho mazání. V další části rešerše se práce zabývá popisem proudění viskózní kapaliny tenkými mezerami. Popisují se zde jednotlivé rovnice užívané v mechanice tekutin.

V praktické části je vysvětlen výpočtový model, pro popis hydrodynamického ložiska turbodmychadla. V práci jsou vysvětleny a popsány hlavní rozměry výpočtového modelu. Poté následuje tvorba metamodelu, který je nejprve zkoušený na jednoduché funkci,  $\sin(x)$  a poté na složitější funkci, Rickerova vlna. Neuronová síť byla aplikována na výpočtový model pro dva různé typy experimentálních plánů. Výsledky jsou zhodnoceny v diskuzi a porovnány s výsledky provedeny pomocí přímé optimalizace pomocí genetického algoritmu.

## Použité informační zdroje

- [1] Wikipedia contributors. Program optimization. In *Wikipedia, The Free Encyclopedia*. Retrieved [cit. 03.05.2020], from [https://en.wikipedia.org/w/index.php?title=Program\\_optimization&oldid=890449967](https://en.wikipedia.org/w/index.php?title=Program_optimization&oldid=890449967)
- [2] Wikipedia contributors. Mathematical optimization. In *Wikipedia, The Free Encyclopedia*. Retrieved [cit. 03.05.2020], from [https://en.wikipedia.org/w/index.php?title=Mathematical\\_optimization&oldid=895597110](https://en.wikipedia.org/w/index.php?title=Mathematical_optimization&oldid=895597110)
- [3] Směšovací poměr a emise [online]. [cit. 03.05.2020]. Dostupné z: [http://www.skola-auto.cz/wp-content/uploads/2020/03/Smesovaci\\_pomer\\_a\\_emise.pdf](http://www.skola-auto.cz/wp-content/uploads/2020/03/Smesovaci_pomer_a_emise.pdf)
- [4] Wikipedia contributors. Simulation-based optimization. In *Wikipedia, The Free Encyclopedia*. Retrieved 20:16, [cit. 03.05.2020], from [https://en.wikipedia.org/w/index.php?title=Simulation-based\\_optimization&oldid=883533982](https://en.wikipedia.org/w/index.php?title=Simulation-based_optimization&oldid=883533982)
- [5] Wikipedia contributors. Turbocharger. In *Wikipedia, The Free Encyclopedia*. Retrieved 16:59, [cit. 05.05.2020], from <https://en.wikipedia.org/w/index.php?title=Turbocharger&oldid=895580984>
- [6] Turbodmychadla, opravy a repase turbodmychadel. *Turbodmychadla, opravy a repase turbodmychadel* [online]. Copyright © Copyright 2016 FlexaMi Auto s.r.o. Ceny jsou uvedeny vč. DPH [cit. 05.05.2020]. Dostupné z: <https://www.flexamiauto.cz/teorie/>
- [7] Turbodmychadlo I. *AutoZnalosti.cz* [online]. [cit. 05.05.2020] Dostupné z: <http://www.autoznalosti.cz/index.php/motor/8-turbodmychadlo.html>
- [8] BELL, Corky. Maximum boost: designing, testing, and installing turbocharger systems. Cambridge, MA: Robert Bentley Automotive Publishers, 1997, vi, 250 p. ISBN 08-376-0160-6.
- [9] MILLER, Jay Turbo: real world high-performance turbocharger systems. North Branch: MN:CarTech, 2008, 160 p. ISBN 978-1-932494-29-7
- [10] Wikipedia contributors. (2018, August 20). Thrust bearing. In *Wikipedia, The Free Encyclopedia*. Retrieved [05.05.2020], from [https://en.wikipedia.org/w/index.php?title=Thrust\\_bearing&oldid=855789774](https://en.wikipedia.org/w/index.php?title=Thrust_bearing&oldid=855789774)
- [11] Fluid Bearings and Types. *The Bearings Incorporated Blog* [online]. [05.05.2020]. Dostupné z: <https://www.bearingsinc.info/fluid-bearings-and-types.html>
- [12] Ložiska. - ppt stáhnout. *SlidePlayer - Nahrávejte a Sdílejte své PowerPoint prezentace* [online]. Copyright © 2020 SlidePlayer.cz Inc. [cit. 05.05.2020]. Dostupné z: <https://slideplayer.cz/slide/2921914/>

- [13] Help. Autodesk Help [online]. Dostupné z: <http://help.autodesk.com/view/INVENTOR/2016/CSY/?guid=GUID-91C8761C-5021-4DF6-89FC-C67D659FC4A1>
- [14] Mazání ložisek | ZKL Group. ZKL Group [online]. Copyright © 2012 ZKL, a.s. [cit. 05.05.2020]. Dostupné z: <http://www.zkl.cz/cs/pro-konstruktery/9-mazani-lozisek>
- [15] ŠEVČÍK, V., KNOTEK, M. Segmentová ložiska, 1. vyd., SNTL., Praha 1985. 303 s.
- [16] MIKULA, A. M., GREGORY, R. S. A Comparison of Tilting Pad Thrust Bearing Lubricant Supply Methods, J. Lub. Tech. 105, 39 (1983), DOI:10.1115/1.3254540 L
- [17] STACHOWIAK, G. W. a A. W. BATCHELOR. Engineering tribology. 3rd ed. Boston: Elsevier Butterworth-Heinemann, 2005. ISBN 978-0-7506-7836-0.
- [18] BRECKL, L. Modelování mazací soustavy turbodmyhadla. Brno: Vysoké učení technické v Brně, Fakulta strojního inženýrství, 2018. 54 s. Vedoucí diplomové práce doc. Ing. Pavel Novotný, Ph.D.
- [19] JANALÍK, Jaroslav. Hydrodynamika a hydrodynamické stroje. Ostrava, 2008. Studijní opory. Vysoká škola Báňská - Technická univerzita Ostrava. L
- [20] Master of Science Thesis MMK 2013:06 MFM 149. Friction Characterization of Turbocharger. Bearings. Erik Sjöberg. Approved. 2013-03-07.
- [21] (2009) A higher-order Hele-Shaw approximation with application to gas flows through shallow micro-channels. Journal of Fluid Mechanics 638, 141. [cit. 05.05.2020]. [online]. Dostupné z: <https://epubs.siam.org/doi/abs/10.1137/0115051>
- [22] Wikipedia contributors. (05.05.2020). Design of experiments. In *Wikipedia, The Free Encyclopedia*. Retrieved 15:51 [cit. 05.05.2020]. from [https://en.wikipedia.org/w/index.php?title=Design\\_of\\_experiments&oldid=893526470](https://en.wikipedia.org/w/index.php?title=Design_of_experiments&oldid=893526470)
- [23] HODICKÝ, Jan. Použití experimentu ve vojenství. *Vojenské rozhledy*. 2018, 27 (2), 19-32. ISSN 1210-3292 (print), 2336-2995 (online). Available at: [www.vojenskerozhledy.cz](http://www.vojenskerozhledy.cz).
- [24] METAMODELS FOR COMPUTER-BASED ENGINEERING DESIGN: SURVEY AND RECOMMENDATIONS Timothy W. Simpson, Jesse Peplinski, Patrick N. Koch, and Janet K. Allen t, pp. 3
- [25] UCF Department of Mechanical and Aerospace Engineering [online]. Copyright © [cit. 05.05.2020]. Dostupné z: [http://mae.ucf.edu/pml/files/2014\\_AIAAJ.pdf](http://mae.ucf.edu/pml/files/2014_AIAAJ.pdf)
- [26] Wikipedia contributors. (05.05.2020). Metamodeling. In *Wikipedia, The Free Encyclopedia*. Retrieved 16:12, [cit. 05.05.2020], from <https://en.wikipedia.org/w/index.php?title=Metamodeling&oldid=889419521>



- [27] Metamodeling and its role in support of engineering design optimization. | Download Scientific Diagram. *ResearchGate* | Share and discover research [online]. Copyright©ResearchGate[cit.05.05.2020].Dostupné z: [https://www.researchgate.net/figure/Metamodeling-and-its-role-in-support-of-engineering-design-optimization\\_fig1\\_237453504](https://www.researchgate.net/figure/Metamodeling-and-its-role-in-support-of-engineering-design-optimization_fig1_237453504)
- [28] Wikipedia contributors. Metamodeling. In *Wikipedia, The Free Encyclopedia*. Retrieved 16:18, [cit. 05.01.2020]., from <https://en.wikipedia.org/w/index.php?title=Metamodeling&oldid=889419521>
- [29] Hopfield, J.J. & Tank, D.W. *Biol. Cybern.* (1985) 52: 141. <https://doi.org/10.1007/BF00339943L>
- [30] Wikipedia contributors. (2019, April 30). Artificial neural network. In *Wikipedia, The Free Encyclopedia*. Retrieved 16:32, [cit. 05.01.2020]., from [https://en.wikipedia.org/w/index.php?title=Artificial\\_neural\\_network&oldid=894828316](https://en.wikipedia.org/w/index.php?title=Artificial_neural_network&oldid=894828316)
- [31] Neural Representation of AND, OR, NOT, XOR and XNOR Logic Gates (Perceptron Algorithm). *Medium – a place to read and write big ideas and important stories* [online]. [cit. 05.05.2019]. Dostupné z: <https://medium.com/@stanleydukor/neural-representation-of-and-or-not-xor-and-xnor-logic-gates-perceptron-algorithm-b0275375fea1>
- [32] *University information system MENDELU* [online]. [cit. 05.01.2020]. Dostupné z: [https://is.mendelu.cz/eknihovna/opory/zobraz\\_cast.pl?cast=21471](https://is.mendelu.cz/eknihovna/opory/zobraz_cast.pl?cast=21471)
- [33] Neuronové sítě a koncept neuronové sítě [online] [cit. 05.01.2020]. Dostupné z: <http://portal.matematickabiologie.cz/index.php?pg=analiza-a-hodnoceni-biologickych-dat--umela-inteligence--neuronove-site-jednotlivy-neuron--uvod-do-neuronovych-siti--koncept-umele-neuronove-site>
- [34] Artificial Neural Network Hopfield Networks. *Java NIO, PyTorch, SLF4J, Parallax Scrolling, Java Cryptography, YAML, Python Data Science, Java i18n, GitLab, TestRail, VersionOne, DBUtils, Common CLI, Seaborn, Ansible, LOLCODE, Current Affairs 2018, Apache Commons Collections* [online]. Copyright © Copyright 2019. All Rights Reserved. [cit. 05.01.2020]. Dostupné z: [https://www.tutorialspoint.com/artificial\\_neural\\_network/artificial\\_neural\\_network\\_hopfield.htm](https://www.tutorialspoint.com/artificial_neural_network/artificial_neural_network_hopfield.htm)
- [35] Wikipedia contributors. (2019, March 7). Radial basis function network. In *Wikipedia, The Free Encyclopedia*. Retrieved 16:47, [cit. 05.01.2020]., from [https://en.wikipedia.org/w/index.php?title=Radial\\_basis\\_function\\_network&oldid=886676627](https://en.wikipedia.org/w/index.php?title=Radial_basis_function_network&oldid=886676627) L
- [36] Network structure of RBF neural network. | Download Scientific Diagram. *ResearchGate* | Share and discover research [online]. Copyright © ResearchGate [cit. 05.05.2020]. Dostupné z: [https://www.researchgate.net/figure/Network-structure-of-RBF-neural-network\\_fig10\\_299648791](https://www.researchgate.net/figure/Network-structure-of-RBF-neural-network_fig10_299648791)

- 
- [37] Kohonen Neural Network Basic Structure. | Download Scientific Diagram. *ResearchGate* | *Share and discover research* [online]. Copyright © ResearchGate [cit. 12.05.2020]. Dostupné z: [https://www.researchgate.net/figure/Kohonen-Neural-Network-Basic-Structure\\_fig4\\_41146320](https://www.researchgate.net/figure/Kohonen-Neural-Network-Basic-Structure_fig4_41146320)
- [38] Vytvořil Lukáš Kukla (Autor Práce)
- [39] PŘIBYL, J. Optimalizace tvaru mazací mezery hydrodynamického ložiska s využitím metamodelování. Brno: Vysoké učení technické v Brně, Fakulta strojího inženýrství, 2020. 60 s. Vedoucí diplomové práce Ing. Martin Jonák.
- [40] W.S. McCulloch and w. Pitts: A logical calculus of the ideas immanent in nervous activity. *Bulletin of mathematical biophysics*, 1943.
- [41] *Ústav informatiky Akademie věd České Republiky Ústav informatiky AV ČR* [online]. [cit. 05.05.2020]. Dostupné z: <http://www.cs.cas.cz/~petra/diplomka/text/node3.html>
- [42] SJÖBERG, E. Friction Characterization of Turbocharger Bearings, Master of Science Thesis MMK 2013:06 MFM 149, KTH Industrial Engineering and Management, Machine Design, SE-100 44 STOCKHOLM, pp. 5
- [43] HORI Y.: *Hydrodynamic Lubrication*. 2006. Springer-Verlag Tokyo Berlin Heidelberg New York. ISBN – 13 978-4-431-27898-6. Page 56,57.
- [44] Cole, J. D., et al. “The Flow of a Viscous Compressible Fluid Through a Very Narrow Gap.” *SIAM Journal on Applied Mathematics*, vol. 15, no. 3, 1967, pp. 605–617.

## Seznam použitých zkratk a symbolů

$Re$	[-]	Reynoldsovo číslo
$v$	$[m \cdot s^{-1}]$	rychlost
$d$	[m]	průměr
$\nu$	$[m^2 \cdot s^{-1}]$	kinematická viskozita
$Q_m$	$[kg \cdot s^{-1}]$	hmotnostní průtok
$\rho$	$[kg \cdot m^3]$	hustota
$S$	$[m^2]$	plocha
$V$	$[m^3]$	objem
$t$	[s]	čas
$\vec{F}_s$	[N]	setrvačná síla
$\vec{F}_0$	[N]	vnější síla
$\vec{F}_p$	[N]	tlaková síla
$\vec{F}_t$	[N]	třecí síla
$p$	[Pa]	tlak
$a$	$[m \cdot s^{-2}]$	zrychlení
$g$	$[m \cdot s^{-2}]$	gravitační zrychlení
$\xi$	[-]	ztrátový součinitel
$\tau$	[Pa]	tečné napětí
$\eta$	$[Pa \cdot s]$	dynamická viskozita
$\omega$	$[rad \cdot s^{-1}]$	kinematická viskozita
$L$	[m]	délka

---

$D$	[m]	velký průměr
$\varepsilon_{th}$	[m]	axiální vůle
$\beta$	[-]	parametr
$p$	[Pa]	tlak
$p_0$	[Pa]	tlak
$\phi$	[-]	nezávislá proměnná
$R$	[m]	průměr
$h$	[m]	výška
$U$	[m·s <sup>-1</sup> ]	obvodová rychlost
$\omega_i$	[-]	váha
$x$	[-]	všeobecný vstup
$\theta$	[-]	potencial
$\varepsilon$	[-]	podnět neuronů
$Z$	[-]	odezva

## **Seznam příloh:**



1. Příloha P1: Návrhové prostory a návrhové plány a výsledné grafy.




## **Přílohy**

## 1. Příloha P1: Návrhové prostory a návrhové plány a výsledné grafy.



Návrhové prostory:

UFP 5x5 až 20x20














## Návrhové plány:



### Halton 16 až 256










Výsledné grafy pro UFP :

UFP 5x5 až 20x20









**Výsledné grafy pro Halton :**

Halton 16 až 256

