



**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA STROJNÍHO INŽENÝRSTVÍ**

FACULTY OF MECHANICAL ENGINEERING

**ÚSTAV MECHANIKY TĚLES, MECHATRONIKY A  
BIOMECHANIKY**

INSTITUTE OF SOLID MECHANICS, MECHATRONICS AND BIOMECHANICS

**APLIKACE ALGORITMŮ PREDIKTIVNÍ ÚDRŽBY  
NA ODHAD RUL**

APPLICATION OF ALGORITHMS OF PREDICTIVE MAINTANENCE FOR RUL ESTIMATION

**BAKALÁŘSKÁ PRÁCE**

BACHELOR'S THESIS

**AUTOR PRÁCE**

AUTHOR

Jan Dvořák

**VEDOUCÍ PRÁCE**

SUPERVISOR

Ing. Barnabás Dobossy

BRNO 2022



# Zadání bakalářské práce

Ústav:	Ústav mechaniky těles, mechatroniky a biomechaniky
Student:	<b>Jan Dvořák</b>
Studijní program:	Aplikované vědy v inženýrství
Studijní obor:	Mechatronika
Vedoucí práce:	<b>Ing. Barnabás Dobossy</b>
Akademický rok:	2021/22

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 bakalářské práce:

## Aplikace algoritmů prediktivní údržby na odhad RUL

### Stručná charakteristika problematiky úkolu:

V době Industry 4.0 je snaha vyvinout zařízení, která jsou vybavena širokou škálou senzorů za účelem monitorování jejich aktuálního stavu a v případě potřeby naplánovat nutnou údržbu. Prediktivní údržba je relativně nová oblast, která se zabývá pozorováním stavu komponent s účelem předcházet poruše a v případě potřeby správně načasovat nutnou údržbu. Tato práce se zabývá přezkoumáním algoritmů na odhad RUL (zbývající doba použitelnosti) a implementací vybraných algoritmů na vybraných datových sadách.

### Cíle bakalářské práce:

1. V rámci rešeršního studia představte oblast prediktivní údržby, a přitom se soustředte na algoritmy určené na odhad RUL.
2. Seznamte se se softwarovým nástrojem Predictive Maintenance Toolbox v MATLAB.
3. Vyzkoušíte si jednotlivé metody na datových sadách, které jsou dostupné na stránkách Mathworks.
4. Sestavte experimentální soustavu pro testování RUL algoritmů.
5. Provedte odhad RUL na datech získaných na sestavě z bodu 4.

### Seznam doporučené literatury:

VALÁŠEK, Michael. Mechatronika. Vydavatelství ČVUT, 1995. ISBN 80-01-01276-X.

ISERMANN, Rolf. Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance. 1. Springer-Verlag Berlin Heidelberg, 2006. ISBN 978-3-540-24112-6.

Termín odevzdání bakalářské práce je stanoven časovým plánem akademického roku 2021/22

V Brně, dne

L. S.

---

prof. Ing. Jindřich Petruška, CSc.  
ředitel ústavu

---

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

# **ABSTRAKT**

Cílem této práce je seznámit čtenáře s oblastí prediktivní údržby a jejími algoritmy především v rámci její prognostické části. Na datových sadách a provedeném experimentu dojde k určení zbývající životnosti daného systému pomocí vytvořených modelů v souladu s algoritmy popsány v rešeršní části. Ke zpracování dat a tvorbě modelů bylo využito nástroje MATLAB a jeho dalších aplikací popsanych v práci.

# **ABSTRACT**

The aim of this thesis is to acquaint the reader with the areas of predictive maintenance and its algorithms within its prognostic part. The remaining useful life of the system will be determined on the data sets and the performed experiment using prognostic models in accordance with the algorithms described in the research section. MATLAB and its other applications described in the work were used for data processing and modeling.

## **Klíčová slova**

Prediktivní údržba, Průmysl 4.0, zbývající doba použitelnosti, RUL, příznaky, extrahování příznaků, atributy, extrahování atributů, prognostika, Diagnostic Feature Designer, Predictive maintenance toolbox

## **Keywords**

Predictive maintenance, Industry 4.0, remaining useful life, RUL, features, feature extraction, prognostics, Diagnostic Feature Designer, Predictive maintenance toolbox

## BIBLIOGRAFICKÁ CITACE

DVOŘÁK, Jan. *Aplikace algoritmů prediktivní údržby na odhad RUL* [online]. Brno, 2022 [cit. 2022-05-10]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/136942>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav mechaniky těles, mechatroniky a biomechaniky. Vedoucí práce Barnabás Dobossy.

## Čestné prohlášení

Prohlašuji, že jsem bakalářskou práci na téma *Aplikace algoritmů prediktivní údržby na odhad RUL* vypracoval samostatně s použitím odborné literatury a pramenů, uvedených v seznamu, který tvoří přílohu této práce.

---

Datum

---

Jméno a příjmení

## **Poděkování**

Tímto způsobem děkuji Ing. Barnabáši Dobbosymu, za vedení při práci na tomto bakalářském projektu. Děkuji za trpělivý a vstřícný přístup a poskytnuté cenné rady. V neposlední řadě bych chtěl poděkovat své rodině a spolubydlícím za podporu během celého studiu.

# Obsah

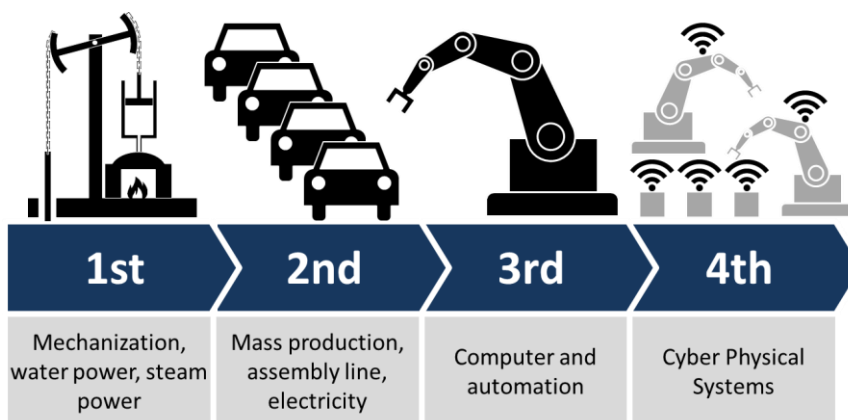
1. Úvod.....	11
2. Rešerše .....	13
2.1. Druhy údržeb, jejich vlastnosti a porovnání .....	13
2.1.1. Reaktivní údržba .....	14
2.1.2. Preventivní údržba .....	14
2.1.3. Prediktivní údržba.....	15
2.1.4. Srovnání jednotlivých údržeb .....	15
2.2. Oblasti vyhodnocování dat.....	16
2.3. Obecný algoritmus prediktivní údržby.....	17
A. Předzpracování naměřených dat.....	18
B. Extrahování zvolených příznaků .....	18
C. Zpracování příznaků podle další potřeby .....	19
D. Vyhodnocování vhodnosti příznaků.....	19
E. Případná redukce dimenzí příznaků .....	21
F. Trénování modelů v rámci prognostiky .....	22
2.4. Predictive maintenance toolbox v prostředí MATLAB.....	24
2.4.1. Diagnostic Feature Designer.....	24
2.4.2. Modely na odhad RUL v prostředí MATLAB .....	25
3. Určení zbývající životnosti na již naměřených datech obsažených v datových sadách.....	29
3.1. Podobnostní modely.....	29
A. Vizualizace problému a předzpracování naměřených dat .....	29
B. Extrahování zvolených příznaků .....	30
C. Zpracování příznaků podle další potřeby .....	30
D. Vyhodnocování vhodnosti příznaků.....	31
E. Případná redukce počtu příznaků .....	31
F. Trénování modelů ze zvolených či redukovaných příznaků a jejich následná validace .....	31
G. Vyhodnocení vhodnosti vytrénovaných modelů a výběr nejpřesnějšího z nich.....	35
3.2. Degradací model .....	36
A. Vizualizace problému a předzpracování dat.....	36
B. Extrahování zvolených příznaků .....	37
C. Zpracování příznaků podle další potřeby .....	37
D. Vyhodnocování vhodnosti příznaků.....	38

E.	Případná redukce počtu příznaků a určení mezní hranice .....	38
F.	Trénování modelů ze zvolených či redukovaných příznaků a jejich následná validace.....	39
G.	Vyhodnocení vhodnosti vytrénovaných modelů a výběr nejpřesnějšího z nich .....	41
3.3.	Modely sledující míru přežití .....	43
4.	Sestavení experimentální soustavy a následný odhad zbývající životnosti .....	47
4.1.	Cíl experimentu .....	47
4.2.	Návrh a sestavení experimentální soustavy, měření požadovaných veličin.....	47
4.2.1.	Návrh a sestavení soustavy .....	47
4.2.2.	Měření příslušných veličin .....	48
4.3.	Určení zbývající životnosti baterie na datech z experimentální soustavy .....	49
A.	Vizualizace problému a předzpracování dat .....	49
B.	Extrahování zvolených příznaků.....	51
C.	Zpracování příznaků podle další potřeby.....	51
D.	Vyhodnocování vhodnosti příznaků .....	52
E.	Případná redukce počtu příznaků a určení mezní hranice .....	52
F.	Trénování modelů ze zvolených či redukovaných příznaků a jejich následná validace.....	53
G.	Vyhodnocení vhodnosti vytrénovaných modelů a výběr nejpřesnějšího z nich .....	57
5.	Závěr.....	61
	Reference.....	63
	Seznam obrázků .....	69
	Seznam tabulek .....	70
	Seznam příloh.....	71
	Přílohy .....	72

# 1. Úvod

V době rozmachu internetu a jemu podobných metod pro sdílení informací došlo k dalšímu kroku potřebnému k vytvoření tzv. chytrých továren [1]. Podle obrázku 1 se tento vývoj nazývá čtvrtá průmyslová revoluce a je obecně označována jako Průmysl 4.0 [1]. Ten se vyznačuje masivní digitalizací a propojováním jednotlivých členů v daném výrobním postupu tak, aby došlo k co nejlepší optimalizaci do podoby bezchybného celku. Jedním z možných způsobů takovéto optimalizace a současně jedním z nejdůležitějších prvků zmíněného průmyslu 4.0 je tzv. prediktivní údržba [2]. Ta slouží jako pomocný nástroj k monitorování stavu zařízení či k řešení dalších problémů v podobě odhadu vzniku chyby či určení zbývající životnosti neboli RUL [2, 3].

Nasazením prediktivní údržby dochází k optimalizaci provozu v podobě využití maximální možné doby životnosti systému či možnosti dalšímu předcházení poruchových stavů. Jejím hlavním úkolem je snižování nákladů v průběhu samotného procesu výroby.



Obrázek 1: Vývoj průmyslu ve smyslu průmyslových revolucí (převzato z [4])

Práce je rozdělena na část rešeršní a praktickou. Rešeršní část obsahuje stručné představení údržby obecně s dalším zaměřením na již zmíněnou prediktivní údržbu. Dojde k vysvětlení jejích hlavních částí s konkrétním záměrem seznámit čtenáře s algoritmy a modely na odhad zbývající životnosti. Dalším bodem je představení konkrétních modelů z nabídky prostředí MATLAB obsažených v jeho pomocném toolboxu [5].

Praktická část obsahuje dvě oblasti. První je aplikace algoritmů z rešeršní části na naměřená data obsažená v již připravených sadách za účelem ověření nabytých poznatků a vyzkoušení si nasazení vhodných modelů podle příslušného problému.

V druhé části praktického řešení je vytvořeno možné provedení kompletního postupu prediktivní údržby. Konkrétně od návrhu měřicí soustavy pro získání potřebných dat Ni–MH baterií až po finální odhad zbývajícího počtu cyklů.

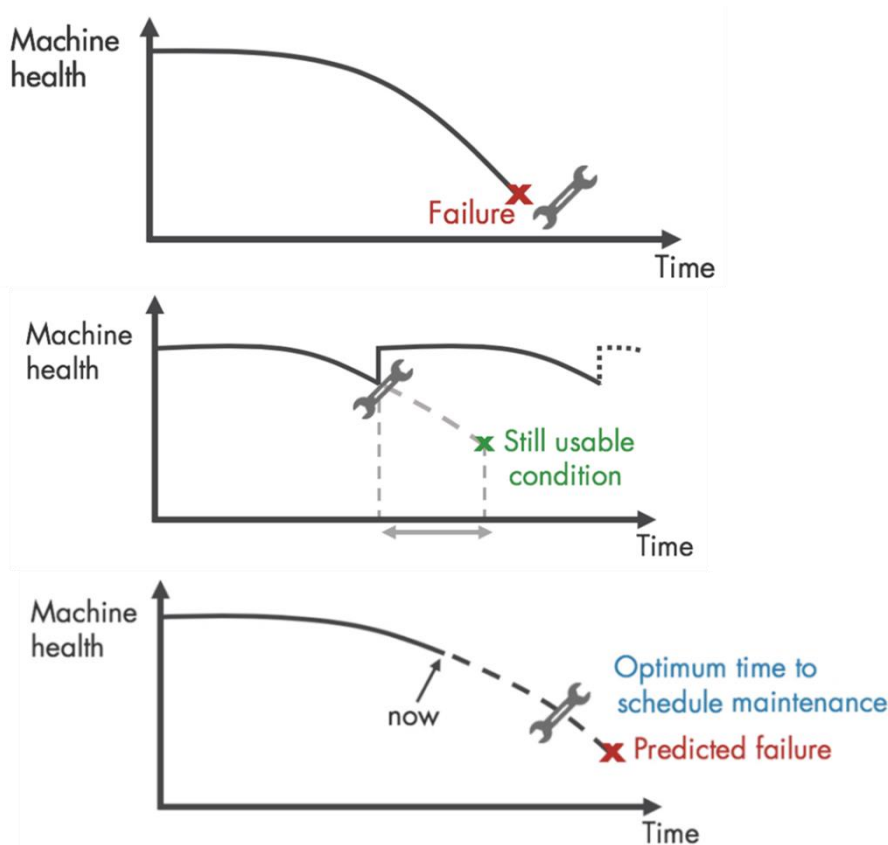


## 2. Rešerše

### 2.1. Druhy údržeb, jejich vlastnosti a porovnání

Pojem údržba sdružuje široké spektrum úkonů, pomocí kterých je dosaženo optimalizace daného procesu tak, aby bylo docíleno jistého standardu. Typické úkony mohou být například výměna porouchané komponenty, seřízení stroje, promazání pohyblivých částí či jiná preventivní kontrola [6, 7].

V závislosti na tom, jak se přistupuje k poruše, se rozlišují tři základní druhy údržeb [8]. Podle obrázku 2 je lze rozdělit na tři základní druhy kterými jsou (shora) údržba reaktivní, preventivní a prediktivní.



Obrázek 2: Základní tři druhy údržeb (upraveno z [9])

### 2.1.1. Reaktivní údržba

Nejstarší používanou údržbou je reaktivní údržba. Jak již název napovídá, hlavním principem je reakce na poruchový stav. Firmy v současném průmyslu upouští od této metodiky a nahrazují ji těmi, které jsou finančně výhodnější. Reaktivní údržba se využívá u zařízení či systémů, kde nedochází k ovlivnění důležitých částí provozu a navíc, kdy je žádoucí využití maximální životnosti. Následující vlastnosti údržby byly vyhodnoceny na základě [2] a [8].

#### Výhody:

- Využití maximálního provozního času.

#### Nevýhody:

- Nepředvídatelnost vývoje a vzniku chyby.
- U komplexních systému možnost nahromadění dalších problémů.
- Vyšší náklady na správu zařízení.
- Možnost „rozladění“ zařízení jako následek poruchy.

### 2.1.2. Preventivní údržba

Údržba s proaktivním přístupem, jejíž snahou je eliminace poruchového stavu předčasným plánovaným zásahem. Její základní vlastnosti byly zaznamenány podle [2] a [8].

#### Výhody:

- Eliminace vzniku poruchového stavu.

#### Nevýhody:

- Časová náročnost z důvodu plánování odstávek provozu pro provedení údržby.
- Nevyužití maximální životnosti zařízení.
- Nejasnost nasazení údržby z důvodu rozmanitosti jednotlivých systémů stejného druhu. Jde o statický nástroj sledující průměrnou životnost těchto systémů.

Na základě poslední uvedené nevýhody se preventivní údržba dá rozlišit na **dva hlavní přístupy** [2]:

- **Statistické plánování** využívá znalostí systému po předchozím používání. Z historie jsou k dispozici předchozí životnosti zařízení operujících v určitých podmínkách.
- **Plánování na základě doporučení** výrobce součástí, který deklaruje určitou životnost v daných podmínkách.

Cílem preventivní údržby je dosažení kompromisu mezi náklady na správu systému či zařízení a časovou náročností úkonů. Své využití v historii našla například u dopravních prostředků, konkrétně v leteckém průmyslu, kde nebylo využití reaktivní údržby ze zcela zřejmých důvodů možné.

### 2.1.3. Prediktivní údržba

Nejstarším typem prediktivní údržby byla prostá důvěra v lidské smysly. Pracovník pověřený údržbou a znalostmi daného zařízení například v průběhu provozních hodin pozoroval chod zařízení a v případě potřeby provedl potřebné seřízení. Tím se mohla doplnit preventivní údržba s cílem dosažení dokonalejšího nástroje.

Následkem pokročilejšího a finančně přístupnějšího sběru, zpracování a vizualizace dat mohlo dojít k rozvoji prediktivní údržby do datové podoby. Dokonalejší technické vybavení navíc umožnilo vznik automatizovaných metod využívaných v oblasti prediktivní údržby.

**Hlavní myšlenkou** prediktivní údržby dle [8] a [10] **je aplikace algoritmů** na data nesoucí informaci o degradaci sledovaného systému. Za pomoci těchto algoritmů lze následně rozhodnout o jaký typ nebo kde porucha vznikne, popřípadě zbývající čas bezporuchového provozu. Výhody a nevýhody údržby byly vyhodnoceny z [2], [8] a [10].

#### Výhody:

- Eliminace poruchových stavů.
- Využití téměř maximální možné životnosti.
- Není potřeba plánovat preventivní odstávky provozu.
- Možnost sledování životnosti zařízení v reálném čase.

#### Nevýhody:

- Vysoká finanční náročnost z důvodu nemalé ceny senzorů.
- Komplexnost modelů pro složitější systémy.
- Velký objem měřených dat. Často potřeba zpracování softwaru na cloud serverech.

### 2.1.4. Srovnání jednotlivých údržeb

V tabulce 1 je provedeno srovnání jednotlivých údržeb dle různých kritérií. Pro každé kritérium je pro příslušnou údržbu uvedena její vhodnost.


Tabulka 1: Porovnání jednotlivých údržeb podle specifických hledisek

Hledisko	Údržba		
	Reaktivní	Preventivní	Prediktivní
Finanční náročnost na správu zařízení	Nevhodná	Méně vhodná	Vhodná
Pořizovací náklady	Vhodná	Vhodná	Nevhodná
Finanční náročnost na provoz údržby	Vhodná	Méně vhodná	Nevhodná
Bezpečnost	Nevhodná	Vhodná	Vhodná
Využití maximální životnosti	Vhodná	Nevhodná	Vhodná
Časová náročnost	Méně vhodná	Nevhodná	Vhodná
Komplexnost sledování stavu zařízení	Nevhodná	Méně vhodná	Vhodná

## 2.2. Oblasti vyhodnocování dat

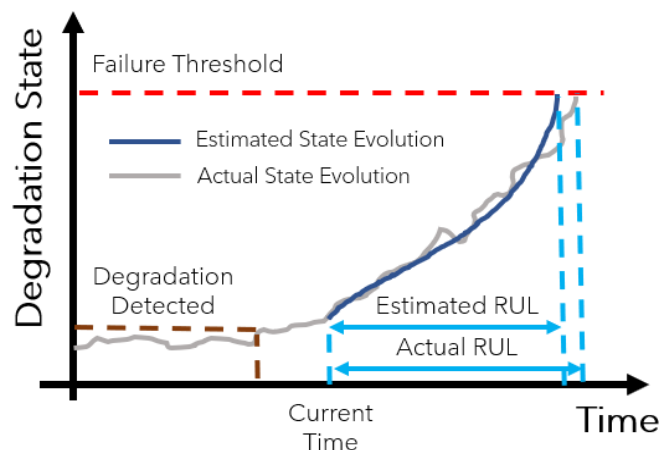
Prediktivní údržbu lze dle [11] rozdělit na tři hlavní skupiny podle významu zpracování jejich dat. Bez zahrnutí monitorování stavu zařízení v reálném čase jde o diagnostiku a prognostiku.

**Diagnostika** [11] systému v rámci prediktivní údržby je oblast zabývající se klasifikací dat. Na základě měřených dat dochází k rozhodování, k jakému druhu poruchy zařízení směřuje, či v jaké části systému se porucha objeví. Princip klasifikace dat podle rozhodovacího stromu [11] je patrný z obrázku 3. Jde o klasifikaci podle předem určených podmínek. Pokud některá z dat splňují dané podmínky jsou následně zařazena do příslušné skupiny.



Obrázek 3: Klasifikace dat: diagnostika (převzato z [11])

**Prognostika** [3, 11] je metodika jejímž cílem je určení zbývající životnosti daného zařízení či systému. Na naměřených datech je sledována jeho postupná degradace. Podle obrázku 4 tak dochází, za pomoci určitých metod, k možnému napodobení způsobu průběhu této degradace. Na základě postupu namodelované degradace pak může být určena zbývající hodnota životnosti jako doba do překročení mezní hranice, v obrázku označené jako *Failure Threshold*.



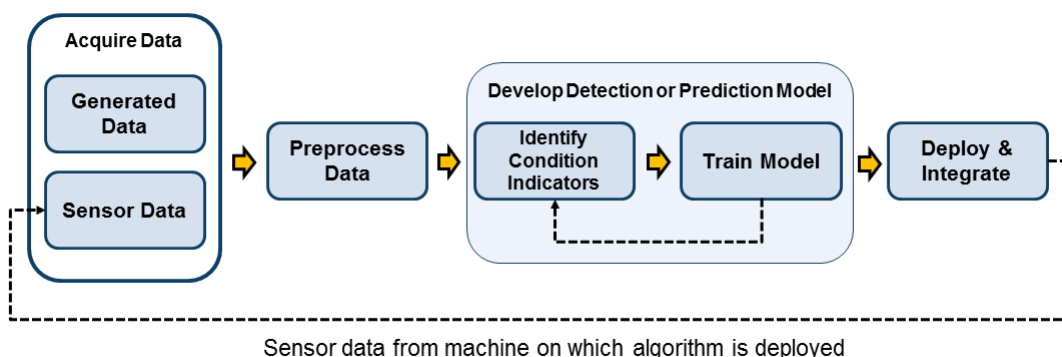
Obrázek 4: Odhad zbývající životnosti: prognostika (převzato z [11])

### 2.3. Obecný algoritmus prediktivní údržby

Obecný algoritmus, viditelný na obrázku 5, je pro diagnostiku i prognostiku do jisté míry společný a podle [3] a [12], bez zahrnutí kolekce dat za použití senzorů, obsahuje následující kroky:

- A. Vizualizace problému a předzpracování naměřených dat (viz A).
- B. Extrahování zvolených příznaků neboli atributů (viz B).
- C. Zpracování příznaků podle další potřeby (viz C).
- D. Vyhodnocování vhodnosti příznaků za použití příslušných metod (viz D).
- E. Případná redukce počtu vhodných příznaků do jediného profilu (viz E).
- F. Trénování modelů ze zvolených či zredukovaných atributů (viz F).
- G. Vyhodnocení vhodnosti vytrénovaných modelů a výběr nejpřesnějšího z nich (viz F).
- H. Integrace vytrénovaného modelu přímo do zařízení či nasazení modelu na cloud [12].

Pro určité kroky, A až G došlo k podrobnějšímu rozepsání daného procesu.



Obrázek 5: Bloková podoba obecného algoritmu prediktivní údržby (převzato z [12])

Proces obecného algoritmu podle bodů popsaných výše není závazný. Jeho postup se liší podle toho, v jaké podobě jsou získaná data k dispozici. Pokud jsou například naměřená data bez šumu a není potřeba dalšího zpracování, dochází tak k přeskočení tohoto konkrétního kroku. Kroky D až G je v drtivé většině případů potřeba opakovat (obrázek 5) z důvodu možné nevhodnosti vybraných příznaků pro daný model, která by způsobila nepřesné chování modelu.

Je nutno doplnit informaci, že takovýto proces je platný pouze při tvorbě modelů založených na datovém zpracování. V dalších kapitolách práce, kapitoly F a 2.4.2, dojde k představení různých druhů modelů, kdy pro některé z nich tento proces v uvedené podobě platný není. Jde hlavně o modely založené na dokonalých znalostech dynamiky a dalších procesů v systému dle [3], [13] a [14].

---

## A. Předzpracování naměřených dat

Získaná data v surové podobě často přímo neukazují aktuální stav systému nebo jeho degradaci. Data také mohou být nekompletní či s přítomností šumu, popřípadě v jiné podobě, která znemožňuje další přímé zpracování. Je tedy žádoucí data upravit do přijatelné podoby. Z [3], [15] a [16] byly vybrány určité způsoby zpracování dle základních požadavků a seskupeny do následujících bodů s případným odkazem na reference:

- Doplnění chybějících nebo odstranění nevhodných úseků či přetvoření odlehlých hodnot [16].
- Odstranění trendu s cílem zaměřením se na případné harmonické či jiné průběhy [16].
- Odstranění šumu, vyhlazování a filtrace s cílem odstranění potenciálně škodlivých informací [17, 18].
- Předzpracování v konkrétní oblasti dat a transformace mezi časovou a frekvenční oblastí [16]:
  - časová oblast
    - časově synchronního průměrování,
    - řádová analýza v oblasti rotačních systémů,
    - získání profilu otáček za minutu ze signálu vibrací,
    - určení obálkového spektra u rotačních systémů,
  - frekvenční oblast
    - vytvoření výkonového spektra,
    - vytvoření obálkového spektra,
  - frekvenčně–časová oblast
    - vytvoření spektrogramu pomocí rychlé Fourierovy transformace,
    - vytvoření průběhu spektrální špičatosti.

## B. Extrahování zvolených příznaků

Vhodně předzpracovaná data jsou připravena k dalšímu kroku. Tím je extrakce příznaků, které dále fungují jako ukazatele životnosti (*condition indicators*) [19]. Z důvodu komplexnosti a obsáhlosti není vhodné pracovat s masivními balíky dat. Příznaky značně snižují objem zpracovávaných dat, zjednodušují a zrychlují vytváření modelů.

Příznakem může být téměř cokoli, od ukazatelů typu kapacita baterie až po průměrnou hodnotu a její směrodatnou odchylku. V závislosti na datové oblasti se rozlišují základní příznaky, kdy nejčastěji používané z nich jsou uvedené v tabulce 25 obsažené v příloze této práce. Při vytváření tabulky se vycházelo z: [3], [20], [21] a [22]. Tabulka obsahuje název daného příznaku, matematickou podobu a přiřazení k příslušné datové oblasti, které jsou v tomto případě časová (T), frekvenční (F) a frekvenčně–časová (T–F).

### C. Zpracování příznaků podle další potřeby

Vybrané atributy mohou, tak jako signály v kapitole A, projít procesy dalšího zpracování, mezi které se dle [15], [16] a [23] řadí:

- Doplnění chybějících nebo odstranění nevhodných úseků, přetvoření odlehlých hodnot s cílem dosažení ideálního průběhu daného příznaku.
- Vyhlazování či filtrace dle kapitoly A [17].
- Možná normalizace dat, která je vhodná například pro případné použití metod na snížení dimenzí příznaků (kapitola E). Normalizace se zavádí pro sjednocení rozměrů vybraných příznaků při zachování jejich tvaru. Příkladem je normalizace typu min–max [24] do rozmezí hodnot v intervalu  $<0; 1>$  založená na principu viditelném z rovnice (1). Případně další metody v [23] a [24].

$$x = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

### D. Vyhodnocování vhodnosti příznaků

Z extrahovaných příznaků je následně potřeba získat ty, které stav systému vyjadřují nejlépe a jsou tedy vhodné k tvorbě modelu. V závislosti na oblasti zpracování dat (2.2) se volí výběrové metody.

Výběru atributů v oblasti **diagnostiky** se docílí pomocí algoritmů dělených do tří základních skupin [25, 26, 27].

- **Filtry** [28] mohou být založené například na principu korelace příznaků. Jak již název napovídá, dochází k odfiltrování nejméně vhodných příznaků. Filtrace probíhá na základě ohodnocování příznaků podle jejich schopnosti rozlišit stavy či data. Hlavní výhodou filtračních metod je jejich rychlost. Nedochozí totiž k určení příznaků v rámci algoritmu trénování modelu.
- **Obálkové metody** [29] jsou obecně přesnější než filtrační. Jejich rychlost výběru příznaků je však omezená z důvodu složitějšího výběru příznaků a následného trénování modelu. Tento proces je iterační z důvodu zisku nejlepší možné podoby klasifikačního modelu. Hlavní výhodou je výběr ukazatelů rozdělených do podskupin, kdy dochází k dalšímu hledání interakcí mezi těmito skupinami.
- **Vložené metody** [30] na výběr příznaků v diagnostice se řadí mezi ty nejpřesnější. Hlavní důvod je zahrnutí výběrů příznaku do procesu trénování modelu. Složitější proces znamená však i větší časové nároky.

V oblasti **prognostiky** se uplatňují tři hlavní algoritmy [31, 32]. Každý z algoritmů přiřadí danému příznaku podle jeho vhodnosti určité skóre v rozmezí 0 – nevhodný až 1 – ideální příznak.

- **Monotónnost** [32] charakterizuje trend příznaků s postupnou degradací systému. Určuje, v jakém měřítku je zvolený degradační profil monotónní ve smyslu kladného nebo negativního trendu. Jeho matematická podoba v prostředí MATLAB [33] je následující:

$$\text{monotonicity} = \frac{1}{M} \cdot \sum_{i=1}^M \left| \sum_{j=1}^{N_i-1} \frac{\text{sgn}(x_j^{(k+1)} - x_j^{(k)})}{N_i-1} \right| \quad (2)$$

kde  $x_j$  reprezentuje sledovaný příznak  $i$ -tého systému,  $M$  je počet měřených systémů a  $N_i$  je počet měření  $i$ -tého systému.

- **Trendovatelnost** [32] sleduje podobnost jednotlivých degradačních profilů systémů typu normální stav – porucha. Hodnota trendu je definována jako nejmenší absolutní hodnota korelace [34] mezi jednotlivými měřeními. Matematická podoba v prostředí MATLAB [35]:

$$\text{trendability} = \min_{i,j}^M |\text{corr}(x_i, x_j)| \quad (3)$$

kde  $x_i$  a  $x_j$  reprezentují sledovaný příznak  $i$ -tého respektive  $j$ -tého systému,  $M$  je počet měřených systémů.

- **Prognózovatelnost** [32] určuje míru předvídatelnosti či variability příznaků při dosažení konce životnosti vzhledem k počátku a konci degradace. Příznak s vyšší hodnotou předvídatelnosti se vyznačuje nižším rozptylem hodnot při dosažení poruchy pro více stejných systémů vzhledem k rozsahu hodnot v celé oblasti životnosti. Matematická podoba v prostředí MATLAB [36]:

$$\text{prognosability} = e^{\left( -\frac{\text{std}_i(x_i(N_i))}{\text{mean}_i|x_i(1) - x_i(N_i)|} \right)} \quad (4)$$

kde  $x_i$  reprezentuje sledovaný příznak  $i$ -tého systému,  $M$  je počet měřených systémů a  $N_i$  je  $i$ -tý systém.

## E. Případná redukce dimenzí příznaků

Příznaky mohou v ideálním případě sloužit jako samostatná životnostní křivka. V situaci, kdy je k dispozici více méně vhodných atributů, je možné tyto atributy sloučit pomocí metod na snížení dimenzí do jednoho kvalitnějšího profilu. Tyto algoritmy se dělí na lineární a nelineární [37].

### Lineární metody [37]:

- Analýza faktoru (FA)
- Lineární diskriminační analýza (LDA)
- Zkrácený rozklad singulární hodnoty (SVD)

### Nelineární metody [37]:

- Kernel PCA
- Vícerozměrné škálování (MDS)
- Izometrické mapování (Isomap)

**Analýza hlavních komponent (PCA)** [38] je jeden z nejpoužívanějších optimalizačních lineárních algoritmů k redukci dimenzí příznaků. Používá se ke snížení počtu korelovaných proměnných na menší počet nekorelovaných. Toho je dosaženo za pomoci projekce původních hodnot do zmenšeného prostoru PCA pomocí vlastních vektorů kovarianční matice neboli hlavních komponent PCA. Projektovaná data jsou lineární kombinací původních proměnných. Dochází tedy k vytvoření skupin nových proměnných, kdy první skupina obsahuje nejkvalitnější informace o původních proměnných a každá další skupina méně kvalitní. Hodnotícím kritériem je pak rozptyl výsledných proměnných jako celku a rozptyl skupin podle proměnných. V případě nasazení PCA na jedinou proměnnou dochází k filtračnímu procesu.

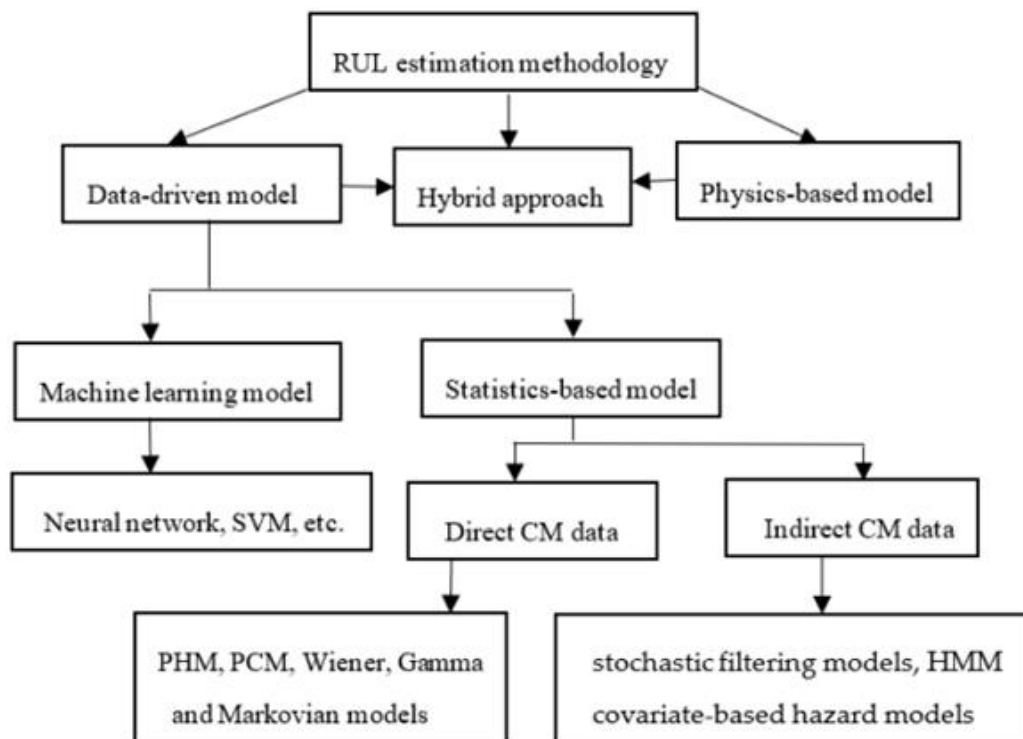
Z obrázku 6 je patrný význam použití metody PCA pro klasifikaci dat. Po nasazení algoritmu došlo k viditelnému zlepšení odlišení klasifikovaných skupin, kdy podle hodnotícího kritéria vyššího rozptylu vychází lépe skupina PC1.



Obrázek 6: Metoda PCA: obecný význam (převzato z [38])

## F. Trénování modelů v rámci prognostiky

V oblasti prognostiky se rozlišují tři základní druhy modelů. Modely tvořené na datech, modely založené na matematickém popsání systému a jejich případně kombinace [3, 14]. Možné rozdělení modelů je pak patrné z obrázku 7.



Obrázek 7: Možné rozdělení prognostických modelů (převzato z [14])

**Modely tvořené na datech** se vyznačují, jak již bylo zmíněno, zpracováním naměřených dat podle obecného algoritmu 2.3. Dochází tedy ke zpracování naměřených dat, extrakci a výběru nejlepších atributů s následným trénováním modelů. Jsou vhodné pro neznámou či komplikovanou degradační dynamiku systému. Jde o rychlý, levný a přesný přístup určení zbývající životnosti. Výhodou takovýchto modelů je také možnost monitorování stavu zařízení v reálném čase. Dle obrázku 7 je lze dále dělit na statistické modely a modely založené na strojovém učení. Jednotlivé modely a jejich principy jsou uvedeny v [3], respektive [14].

Statistické modely zpracovávají informace v podobě časů poruch či údržeb a pomocí různých metodik určují zbývající životnost. Jednou z těchto metod je Weibullovo rozdělení. Jsou vhodné pro nekomplexní systémy [3].

Modely založené na strojovém učení často pracují s kompletními daty ze senzorů. Na rozdíl od statistických modelů jsou pro komplexní systémy vhodné. Sdružují regresní metody a neuronové sítě [3]. RUL se vyhodnocuje na základě zpracování dat podle obecného algoritmu 2.3.

**Modely založené na matematickém popsání systému** fungují na principu soustav diferenciálních a algebraických rovnic. U složitých systémů je velice obtížné dosáhnout vhodného chování těchto modelů. Je totiž potřeba dokonalé znalosti kompletní dynamiky a všech možných vnitřních procesů (fyzikální, chemické a biologické) probíhajících ve sledovaném zařízení [13, 14].

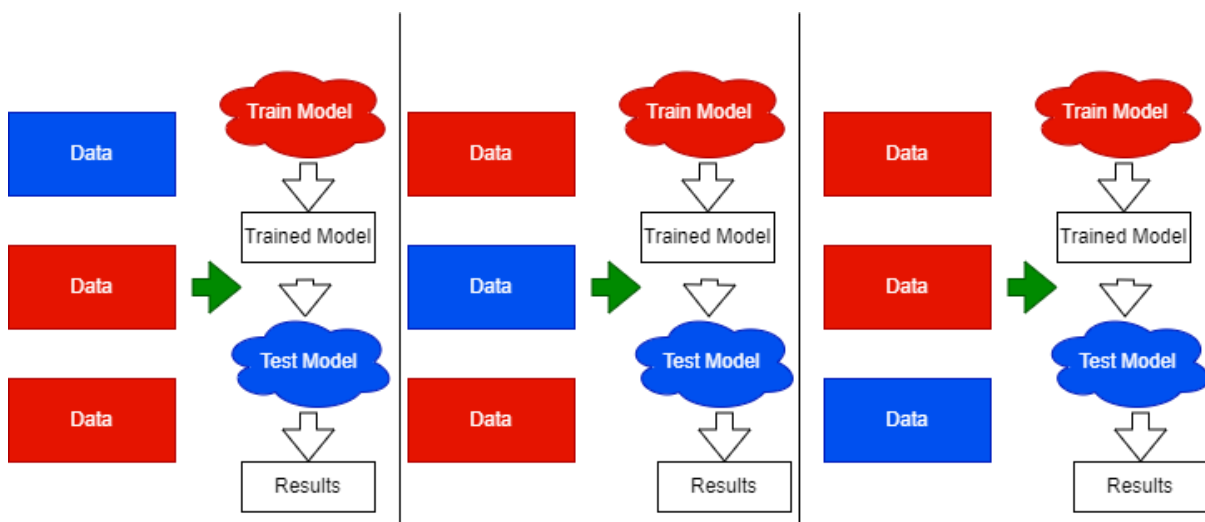
Po získání určitých znalostí systémů následně nepotřebují dalšího učení a odhadují další chování reálného systému bez potřeby sběru dat. Modely jsou schopny, na rozdíl od datových modelů, objasnit degradaci systému či vznik blížící se poruchy. Dle [13] je lze rozdělit na analytické a metody založené na hlubokých znalostech.

U analytických metod jejich trénování probíhá paralelním chodem rekonstrukčního algoritmu s reálným systémem. Po vzniku poruchy dochází k neplatnosti určených rovnic a vzniku reziduí mezi modelem a reálným systémem, které následně označují poruchy [13].

Metody založené na hlubokých znalostech chápou chování systému ve smyslu podmínek *if-then*, kvalitativního chování či pravděpodobnostních podmínek. Tyto modely pomocí rovnic zpracovávají vstupní informace do podoby případného odhadu vzniku poruchy či zbývající životnosti [13].

**Hybridní přístupy** kombinují přístupy datových a matematických modelů k dosažení potenciálně nejlepších výsledků z obou možných metod [13].

V případě přístupu k vyššímu množství trénovacích dat je žádoucí jejich rozdělení na trénovací a validační skupiny, které slouží k ověření vhodnosti a správnosti modelu. K tomu je používána statistická metoda tzv. **křížová validace** [39]. Základní formou je tzv. *k-fold křížová validace*, která rozdělí soubor do *k* ideálně stejně velkých skupin, kdy většina je využita k trénování a zbytek k validaci modelů podle principu patrného z obrázku 8.



Obrázek 8: Křížová validace: základní princip

---

## 2.4. Predictive maintenance toolbox v prostředí MATLAB

Predictive maintenance toolbox [40] je soubor rozšiřujících aplikací do prostředí MATLAB. Své uplatnění nachází v oblasti prediktivní údržby. Jeho aplikace uživateli, do jisté míry, umožňují v interaktivní podobě projít obecným algoritmem 2.3 bez potřeby psaní kódu.

Aplikace obsažené v toolboxu:

- Diagnostic Feature Designer (DFD) [41]
  - bližší představení v samostatné podkapitole 2.4.1.
- Classification Learner (CL) [42], který umožňuje:
  - trénování různých druhů klasifikačních modelů.
  - trénování modelů na základě různé kombinace atributů, či zpřesňování modelů dle dalších požadavků.
  - vizualizaci přesností jednotlivých klasifikátorů.
  - export modelů do pracovního prostředí MATLAB, či vytvoření funkce pro další trénování modelu.

### 2.4.1. Diagnostic Feature Designer

Aplikace uživateli poskytuje v grafickém prostředí možnost zpracování dat podle 2.3. Konkrétně se jedná o body A až D bez možnosti aplikace metod na snižování dimenzí.

Aplikace v následujících bodech podle [41] umožňuje:


- Vizualizaci naměřených nebo nasimulovaných dat.
- Předzpracování dat jako je filtrace a zprůměrování signálů.
- Vytvoření výkonového spektra a amplitudové charakteristiky.
- Extrakci atributů z vybraných signálů v časové oblasti, pro rotační systémy, nelineární systémy a v oblastech výkonového spektra či dalších.
- Vizualizaci extrahovaných příznaků pomocí histogramů
- Možnost ohodnocení vybraných atributů podle sledované oblasti vyhodnocování dat za pomoci určitých metod.
- Export vybraných atributů do pracovního prostředí MATLAB či dalších aplikací.

Aplikace společně s toolboxem obecně pro zpracování většího počtu dat vyžaduje specifickou řádkovou strukturu, patrnou z obrázku 9. Soubor se v prostředí MATLAB nazývá **ensemble**. Každý řádek v takovéto struktuře obsahuje tři základní druhy proměnných [43].

Nezávislé proměnné (*independent variables*), které rozlišují jednotlivé řádky. Jde například o časy či příslušný cyklus porízení datové sekvence získané senzorem.

Datové proměnné (*data variables*) jsou druhým typem proměnných. Jedná se o sekvence měřených dat většinou v časové oblasti. Příkladem mohou být průběhy vibrací v čase získané z akcelerometrů.

Posledním druhem jsou proměnné vyjadřující stav systému (*condition variables*). Může jít o identifikátory reprezentující příslušný druh poruchy nebo označení aktuálního stavu systému v možné podobě: normální – přechodový – poruchový. Proměnné dále mohou sloužit k determinaci operačních podmínek jako je teplota okolí nebo tlak. Tyto proměnné se v rámci DFD obecně používají ke klasifikaci dat či k jinému odlišení jednotlivých režimů a stavů.

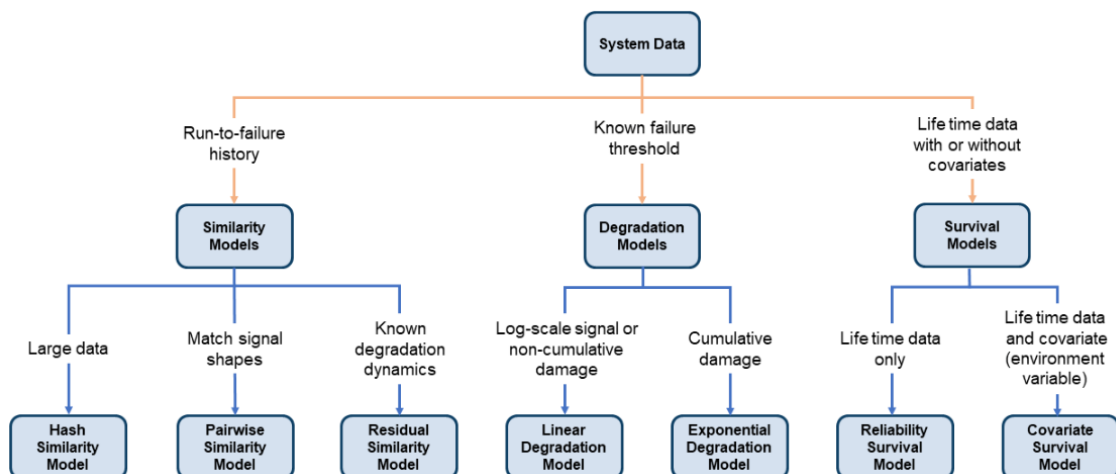


Obrázek 9: Uspořádání dat v ensemble: blokové schéma

## 2.4.2. Modely na odhad RUL v prostředí MATLAB

MATLAB a jeho soubor nástrojů pro zpracování dat v prediktivní údržbě nabízí předpřipravené modely (obrázek 10) na odhad RUL [5]. Modely jsou založené na datovém zpracování (viz kapitola F) a jejich nasazení je různé podle druhu dat, která mohou být v následujících podobách:

- Od normálního stavu do poruchy, kdy data nesou informaci o normálním a poruchovém provozu.
- Data někde mezi nasazením komponenty a poruchou, je však nezbytná přítomnost prahové hodnoty, po jejímž překročení je nutné provést údržbu.
- Čas k události, respektive informace o časech poruch či údržeb.



Obrázek 10: Modely na odhad zbyvající životnosti z nabídky MATLAB (převzato z [5])

---

**Podobnostní modely** [5] se používají, pokud jsou k dispozici data pro více podobných systémů operujících v obdobných podmínkách a obsahují kompletní historii až do poruchy. Zbývající životnosti testované komponenty je určována jako střední statistická hodnota životnosti nejpodobnějších profilů minus aktuální hodnota životnosti.

Modely se dle obrázku 10 dále dělí na:

- Modely pracující na principu křížení příznaků (*Hashed-feature similarity models*) umožňují vložení většího počtu degradačních profilů. Následně dochází k transformaci [44] historických dat každého člena modelu do pevně krokovaného profilu obsahující hodnoty jako je průměrná či maximální hodnota. RUL vzniká porovnáním takto transformovaných dat členů modelu s ve stejném smyslu transformovanými daty sledovaného systému.
- Párové modely (*Pairwise similarity models*), tak jako ty založené na principu křížení znaků, umožňují vložení více degradačních profilů pro každého člena v rámci trénování. RUL se určuje na základě nejpodobnějšího profilu s profilem sledovaného systému. Párové metody sdružují dvě základní porovnávací metody:
  - Korelační metoda (viz [34]).
  - Dynamické zakřivení času (*dtw*) s bližším představením v [45].
- Modely porovnávací rezidua (*Residual similarity models*) vypočítávají rezidua mezi trénovacími daty a profilem zkoumaného systému. Trénovací profil s nejnižší hodnotou rezidua s nejvyšší pravděpodobností odpovídá i tomu sledovanému. Na takovémto profilu je pak určován RUL. Tyto modely umožňují trénování pouze jediným profilem. Často se tedy využívá metod na snížení dimenzí popsaných v kapitole E. Modely sdružují více možných metod od lineární a exponenciální funkce, přes polynomy různých řádů až po metodiky založené na regresivních metodách [34].

**Degradační modely** [5] své uplatnění nacházejí u systémů, u kterých není dostatečný počet profilů s kompletní životností, či pro stav, kdy se systém ještě nedostal do oblasti poruchy. Oproti tomu je známa mezní hodnota, *threshold*, a datová série schopná popsat degradaci. Modely fungují na principu předpovídání budoucího chování na základě historických dat.

Podle druhu degradace se modely dělí na:

- Lineární degradační modely používané pro systémy s nekumulovaným poškozením. Modely jsou popsány rovnicí přímky.
- Exponenciální degradační model je popsán rovnicí exponenciály a podle smyslu této funkce se používá u systémů, kde dochází ke kumulaci poškození.

---

Zbývající životností u degračních modelů se rozumí doba, než modelový profil dosáhne předem zvolené hranice.

V případě použití degračních modelů z nabídky MATLAB je potřeba vždy, když dojde k získání dalších dat, modelové parametry zaktualizovat pomocí funkce *update* [46]. Díky *update* funkci model dokáže věrohodněji předpovědět RUL.

**Modely sledující míru přežití** [5] se používají, pokud jediný údaj, který je dispozici, je čas poruchy či údržby. V závislosti na přítomnosti tzv. kovariantů se modely dále dělí na:

- Spolehlivostní modely (*Reliability survival models*) vyhodnocují zbývající životnost zařízení na základě pravděpodobnostního rozložení stejných systémů ze záznamů poruch či údržeb. Umožňují zpracovávat takováto data v různých podobách pravděpodobnostních rozdělení.
- Kovariantní modely sledující míru přežití (*Covariate survival models*) se od spolehlivostních odlišují přítomností kovariantů. V případě kovariantů jde o proměnné sloužící k odlišení jednotlivých členů v modelu. Tyto proměnné sdružují podmínky, ve kterých zařízení či systém operoval, či jsou jinak důležité pro vyhodnocení RUL. Konkrétně může jít o veličiny jako je teplota prostředí, tlak, výrobce daného zařízení nebo zátěžný faktor ve smyslu zátěžného proudu či momentu. Modely se vyznačují tzv. funkcí míry přežití, která vyjadřuje, s jakou pravděpodobností daná komponenta při těchto podmínkách „přežije“ daný časový bod [47].



### 3. Určení zbývající životnosti na již naměřených datech obsažených v datových sadách

Na datových sadách dostupných z [48] byl proveden odhad zbývající životnosti podle tří základních skupin modelů z nabídky MATLAB [5]. Postup zpracování dat byl v souladu se základní podobou obecného algoritmu, body A až F, zmíněného v rešeršní části v kapitole 2.3.


#### 3.1. Podobnostní modely

##### Cíl datové sady

Na datové sadě [48] obsahující sedm ložisek s kompletní životností bylo cílem určit zbývající použitelný čas komponenty ve zvolených okamžicích. Každé ložisko obsahovalo určitý počet souborů, který odpovídal počtu měření vibrací pomocí akcelerometrů se vzorkovací frekvencí 25600 Hz a časovým krokem deseti sekund. Data vibrací byla měřena ve dvou kanálech a každý záznam vibrací obsahoval 2560 datových bodů, ze kterých po nanesení vzorkovací frekvence vznikl průběh trvající 0,1 sekund.

##### A. Vizualizace problému a předzpracování naměřených dat

Na obrázku 11 je viditelný vykreslený průběh životnosti ložiska od přibližného začátku patrnější degradace až po konec jeho životnosti. Průběh vznikl jako kombinace průběhů vibrací z jednoho kanálu, kdy došlo k vykreslení jednoho 0,1 sekundového záznamu a ihned za něj došlo k vykreslení následujících 0,1 sekundových průběhů. Degradace ložiska probíhala ve třech fázích. Fáze klidu, při které degradace patrná vůbec nebyla, na obrázku oblast od červené vertikální přímky směrem vlevo. Fáze mírné degradace, oblast mezi přímkami, následovaná degradací velmi rychlou, oblast od zelené přímky vpravo, která značně přibližovala ložisko k poruše. Dle [49] byla dvě ložiska z důvodu nedodržení tohoto smyslu průběhu životnosti vyřazena.



Obrázek 11: Degradace ložiska: datová sada ložisek – průběh zrychlení

## URČENÍ RUL NA DATOVÝCH SADÁCH

Data byla následně uspořádána do ensemble a v rámci předzpracování došlo k vytvoření spektrální špičatosti a výkonového spektra. V dalším kroku následovala extrakce příznaků.

**B. Extrahování zvolených příznaků**

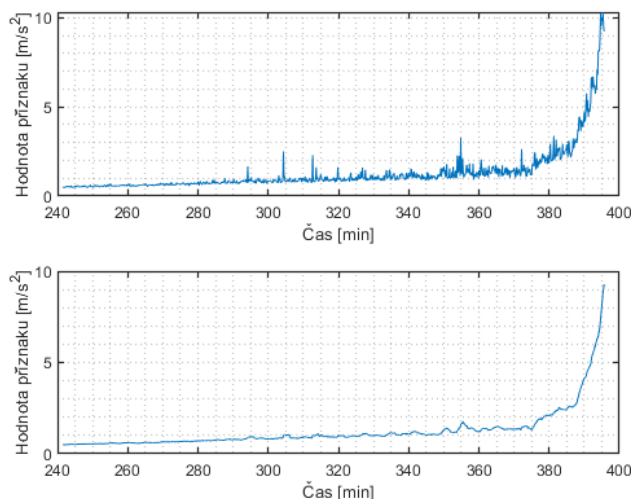
Zvolené příznaky, viditelné v tabulce 2, byly určovány pro oba kanály vibrací.

Tabulka 2: Extrakce příznaků: datová sada ložisek

Extrahovaný příznak	Datová oblast
Průměrná hodnota	Časová, Spektrální špičatost, Výkonové spektrum
Standardní odchylka od průměrné hodnoty	Časová, Spektrální špičatost
Šikmost	Časová, Spektrální špičatost
Špičatost	Časová, Spektrální špičatost
Hodnota maximum – minimum	Časová
Střední kvadratická hodnota	Časová
Činitel výkyvu	Časová
Tvarový faktor	Časová
Činitel impulsu	Časová
Činitel marže	Časová
Energie	Časová
První tři nejvyšší hodnoty amplitud	Výkonové spektrum
Frekvence k příslušné amplitudě	Výkonové spektrum
Šířka pásma	Výkonové spektrum

**C. Zpracování příznaků podle další potřeby**

V rámci zpracování atributů došlo k jejich vyhlazení pomocí příkazu *movmean* [50]. Rozdíl mezi původním a vyhlazeným průběhem atributu standardní odchylky od průměrné hodnoty vibrací je viditelný na obrázku 12.



Obrázek 12: Vliv vyhlazení příznaku: datová sada ložisek

Nejvhodnější příznaky prošly procesem normalizace, která byla typu min–max, do rozmezí hodnot v intervalu  $\langle 0; 1 \rangle$ . Proces normalizace nijak neovlivnil výsledný průběh viditelný na obrázku 12. Došlo pouze ke sjednocení hodnot průběhů příznaků do rozmezí 0 až 1 při zachování jejich tvaru.

#### D. Vyhodnocování vhodnosti příznaků

Výběru vhodných atributů pro trénování modelu bylo dosaženo ve více krocích. Prvním bylo určení lepšího z dvojice atributů z obou kanálů. Toho bylo dosaženo pomocí již zmíněných metod *monotónnost*, *prognózovatelnost* a *trendovatelnost*, a to nasazením na všechny atributy. Každý z atributů obdržel určitou míru vhodnosti. Tyto hodnoty byly použity pro rozhodování v rámci výběru lepšího z dvojice stejných příznaků podle přístupu větší menší. Z celkového počtu 46 atributů pro oba kanály v rámci jedné metody výběru jednoho ložiska došlo k získání jejich poloviny.

V druhém kroku byl vybrán určitý počet prvních příznaků s nejvyšší mírou vhodnosti pro každou ze tří metod. Tyto tři skupiny po několika příznacích, které mohly být v rámci z každé ze skupin různé, prošly dalším krokem, kterým byl výběr všech společných příznaků z těchto skupin.

#### E. Případná redukce počtu příznaků

Z obrázku 12 je patrný fakt, že nebylo potřeba zavést metodiku PCA ani jinou podobnou. Podobnostní modely navíc umožňují zavedení většího počtu profilů, čehož bylo využito. V případě modelu sledujícího rezidua došlo k trénování modelů vždy za použití jediného profilu příznaku.

#### F. Trénování modelů ze zvolených či redukováných příznaků a jejich následná validace

V případě trénování modelů došlo k vytvoření všech nabízených podobnostních modelů v kapitole 2.4.2. V tabulce 3 jsou zaneseny příznaky podle výběrového algoritmu D. Pojem *validace* označuje příslušnou skupinu *modelů* trénovaných v rámci křížové validace pro konkrétní řádek příznaků. Z důvodu trénování podobnostních modelů docházelo vždy k trénování modelů za pomoci čtyř ložisek a validace probíhala pátým. Zdůvodněním je snaha vytvoření hustší podobnostní sítě pro přesnější odhady.

Každý model určoval RUL po dosažení 20, 35, 50, 70, 80 a 90 % dat z jeho životnosti. Z aktuální životnosti příslušné procentuální sekvenci dat byl určený skutečný RUL. Pro modely byly v těchto okamžicích také určeny chyby v odhadech jako skutečná životnost zmenšená o určenou hodnotu RUL, a to pro každý z uvedených časových bodů. Z těchto chyb byly následně vytvořeny medián a průměr pro jeden model v rámci validace, které sloužily jako jedno z kritérií k výběrům vhodného modelu podle zvolených příznaků a kombinací ložisek v křížové validaci. Dalším kritériem bylo nepřekročení skutečné životnosti komponenty jednotlivými odhady.

## URČENÍ RUL NA DATOVÝCH SADÁCH

Tabulka 3: Příznaky pro trénování podobnostních modelů: datová sada ložisek

Model	Příznak						
	Standardní odchylka	Hodnota min-max	Střední kvadratická hodnota	Tvarový faktor	Činitel marže	Průměrná hodnota spektrální křivosti	Činitel výkyvu
1	ANO	ANO	ANO	ANO	ANO	ANO	ANO
2	ANO	ANO	ANO	ANO	ANO	NE	NE
3	ANO	ANO	NE	ANO	NE	NE	NE
4	NE	ANO	NE	NE	NE	NE	NE

Modely založené na principu křížení příznaků

U modelu pracujícím na principu křížení příznaků došlo k vytvoření křížených příznaků jako je průměrná hodnota, standardní odchylka, medián a špičatost. V případě použití příznaků v prvních dvou řádcích tabulky 3 modely poskytovaly stejné výsledky.

Tabulka 4: Chyby v odhadech RUL pro modely křížící příznaky: datová sada ložisek

Vali- dace	Sedm příznaků		Pět příznaků		Tři příznaky		Jeden příznak	
	Průměr	Medián	Průměr	Medián	Průměr	Medián	Průměr	Medián
1	5,7	5,7	5,7	5,7	5,7	5,7	2.4	2.4
2	1,3	1,3	1,3	1,3	3,8	1,3	-0.04	8.8
3	69,8	69,8	69,8	69,8	70,2	69,8	66.9	64.3
4	-33,3	-33,3	-33,3	-33,3	-33,8	-33,3	-31.7	-31.7
5	-14,7	-14,7	-14,7	-14,7	-14,7	-14,7	-19.9	-12.6

Z tabulky 4 vyplývá fakt, že nejlepšími modely, nezávisle na různém množství příznaků, byla trénovací skupina číslo dva. Vykazovala totiž nejmenší hodnoty průměrných chyb a chybových mediánů. Celkově nejlepšími modely byly v rámci druhé validační skupiny ty, co obsahovaly nejvíce příznaků a následně ten, co obsahoval jediný příznak v první validační skupině.

V tabulce 5 jsou uvedeny odhadnuté hodnoty zbývající životnosti po dosažení procentuální hodnoty datové série validačního ložiska s uvedením skutečné hodnoty RUL pro daný okamžik.

## URČENÍ RUL NA DATOVÝCH SADÁCH

Tabulka 5: Výsledné odhady RUL pro modely křížící příznaky: datová sada ložisek

Vali- dace	Sedm příznaků		Pět příznaků		Tři příznaky		Jeden příznak		Skutečná hodnota RUL	
	35	80	35	80	35	80	35	80	35	80
1	261	76,3	261	76,3	261	76,3	264,2	79,6	266,7	82
2	263,9	80,2	263,9	80,2	263,9	72,7	256,4	72,7	265,2	81,5
3	233,7	23,6	233,7	23,6	233,7	23,6	231,3	29,1	303,5	93,3
4	277,9	108,4	277,9	108,4	277,9	108,4	276,3	106,8	244,7	75,2
5	271,8	93,8	271,8	93,8	271,8	93,8	269,8	135,6	257,2	79,2

Párové modely

U párových modelů došlo k vytvoření *korelačního* i modelu s *dynamickým zakřivením času* (dtw) za použití příznaků v tabulce 3. V případě korelačního modelu došlo k vysokým chybám v odhadech. Druhý model určoval hodnoty, až na nepatrné rozdíly v tisícinách, prakticky identické jako modely pro sedm a pět příznaků v tabulkách 6 a 7. Z tohoto důvodu byly do práce, v podobě další tabulky, zaneseny odhady méně přesného *korelačního* modelu (tabulka 6 a 7).

Tabulka 6: Chyby v odhadech RUL pro párové modely – korelační model: datová sada ložisek

Vali- dace	Sedm příznaků		Pět příznaků		Tři příznaky		Jeden příznak	
	Průměr	Medián	Průměr	Medián	Průměr	Medián	Průměr	Medián
1	10,5	7,9	11,8	8	7,7	7,9	4,9	7,1
2	0,4	-0,5	-0,9	-1,3	-1,8	-3,2	-7,2	-6,5
3	72,3	71,7	72,4	72,2	72,8	72,7	75,5	76,2
4	-49,5	-36,9	-56,8	-55,2	-59	-58,4	-61,2	-61,9
5	-28	-16,9	-30,3	-16,7	-29,1	-18,2	-34,6	-39,1

Tabulka 7: Výsledné odhady RUL pro párové modely – korelační model: datová sada ložisek

Vali- dace	Sedm příznaků		Pět příznaků		Tři příznaky		Jeden příznak		Skutečná hodnota RUL	
	35	80	35	80	35	80	35	80	35	80
1	260	56,2	260	52,7	259,9	64	258,5	75,9	266,7	82
2	264,3	83,9	263,7	87,2	264,8	86,9	269	81,2	265,2	81,5
3	233,8	18,8	233,7	19	233,7	18,8	231,4	17,3	303,5	93,3
4	279	114,7	279	151,2	279,4	156,7	281,4	158,5	244,7	75,2
5	274,2	127,8	272,9	134,9	274	130,5	288,2	133,6	257,2	79,2

## URČENÍ RUL NA DATOVÝCH SADÁCH

Modely sledující rezidua

Dle kapitoly 2.4.2 MATLAB nabízí pro tyto modely více metod k určení RUL. V případě ložiska bylo využito modelů typu regresivních metod, polynomů a exponenciálních funkcí. Modely byly trénovány pro všechny možné metody s výslednými odhady, které se lišily pouze v řádech tisícin. Výsledky byly na základě smyslu degradace ložiska uvedeny pro exponenciální model.

Jako degrační profily byly zvoleny příznaky: hodnota min–max z průběhu vibrací, standardní odchylka, střední kvadratická hodnota a tvarový faktor. Jak je patrné z tabulek 8 a 9.

Tabulka 8: Chyby v odhadech RUL pro modely sledující rezidua – exponenciální model: datová sada ložisek

Vali- dace	Hodnota min–max		Standardní odchylka		Střední kvadratická hodnota		Tvarový faktor	
	Průměr	Medián	Průměr	Medián	Průměr	Medián	Průměr	Medián
1	5,7	5,7	5,7	5,7	5,7	5,7	5,7	5,7
2	1,3	1,3	1,3	1,3	1,3	1,3	1,3	1,3
3	69,8	69,8	69,8	69,8	69,8	69,8	69,8	69,8
4	-33,3	-33,3	-33,3	-33,3	-33,3	-33,3	-33,3	-33,3
5	-14,7	-14,7	-14,7	-14,7	-14,7	-14,7	-14,7	-14,7

Tabulka 9: Výsledné odhady RUL pro modely sledující rezidua – exponenciální model: datová sada ložisek

Vali- dace	Hodnota min–max		Standardní odchylka		Střední kvadratická hodnota		Tvarový faktor		Skutečná hodnota RUL	
	35	80	35	80	35	80	35	80	35	80
1	261	76,3	261	76,3	261	76,3	261	76,3	266,7	82
2	263,9	80,2	263,9	80,2	263,9	80,2	263,9	80,2	265,2	81,5
3	233,7	23,6	233,7	23,6	233,7	23,6	233,7	23,6	303,5	93,3
4	277,9	108,4	277,9	108,4	277,9	108,4	277,9	108,4	244,7	75,2
5	271,8	93,8	271,8	93,8	271,8	93,8	271,8	93,8	257,2	79,2

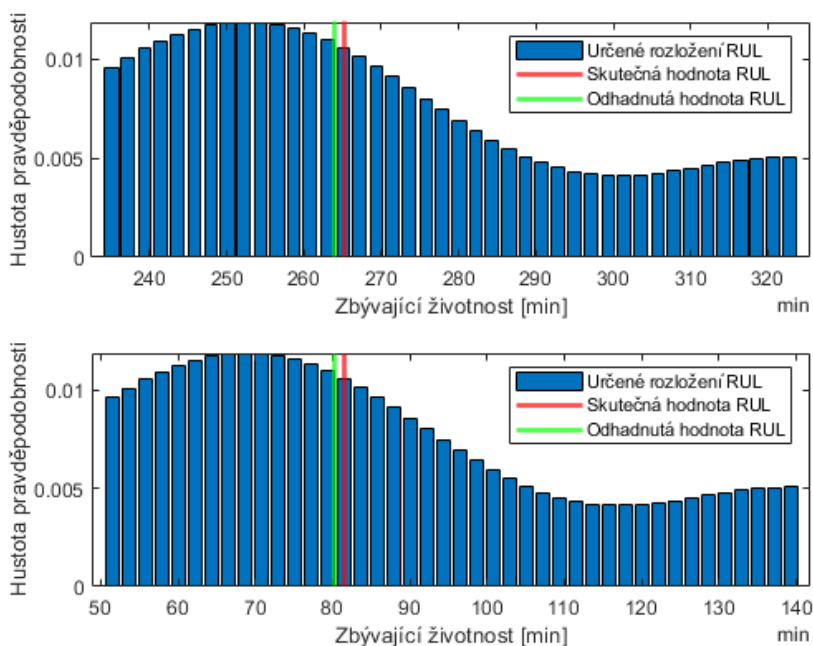
## G. Vyhodnocení vhodnosti vytrénovaných modelů a výběr nejpřesnějšího z nich

Z důvodu velkého množství možných kombinací různých modelů byly do práce vybrány pouze ty, co poskytovali nejlepší anebo zajímavé výsledky.

V rámci křížové validace proběhlo trénování a následné ověření jednotlivých modelů založených na různých metodách popsanych v rešeršní části. Na základě validace modelů byly určeny možné rozhodovací podmínky v podobách již zmíněných mediánů a chybových průměrných hodnot. Za pomoci těchto hodnot a také znalosti jednotlivých odhadů každého z modelů bylo rozhodnuto o zvolení exponenciálního modelu sledujícího rezidua jako toho nejlepšího. Dalšími kritérii výběru byla dynamika degradace ložiska a schopnost modelu předpovídat hodnoty, které by v ideálním případě nikdy nepřekročily skutečnou životnost.

Konkrétně zvoleným modelem byl druhý z tabulky 8. Podle dosažených výsledků a faktu, že model určoval RUL prakticky stejně, nezávisle na různých degradačních profilech, je potenciální kandidátem k nasazení do reálného provozu.

Na obrázku 13 je viditelné pravděpodobnostní rozdělení určeného RUL tohoto zvoleného exponenciálního modelu. Horní určení RUL je v okamžiku dosažení 35 % dat a druhé je pro 80 % dat. Je potřeba zmínit fakt, že pravděpodobnostní rozdělení je velice rozsáhlé. Hlavním důvodem je nedostatečný počet trénovacích prvků modelu, které by vytvořili hustší podobnosti síť s cílem zpřesnění výsledných odhadů.



Obrázek 13: Určení zbývající životnosti ložiska pomocí exponenciálního modelu porovnávacího rezidua: datová sada ložisek

### 3.2. Degradční model

#### Cíl datové sady

Na datové sadě [48], která obsahovala naměřená data pro čtyři Li-ion baterie [51], bylo cílem určení zbývajícího počtu cyklů baterií pro různé okamžiky. Mezní hodnota životnosti byla kapacita na specifikované hodnotě 1,4 Ah. Všechny baterie obsažené v datové sadě tuto hranici překročily.

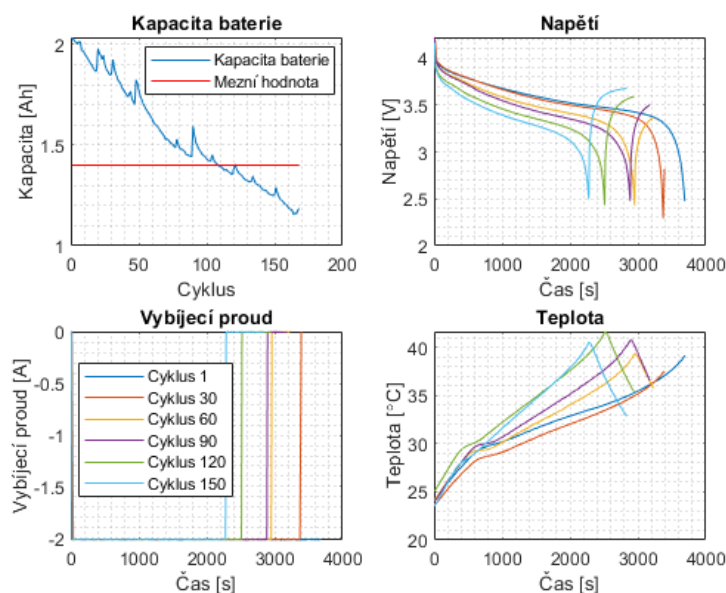
Baterie v sadě obsahovaly data roztržena do souborů pro příslušný cyklus. V případě nabíjení obsahovaly průběhy napětí, teplot a proudů. Při vybíjecích cyklech navíc došlo k určení kapacity baterie. Dalšími samostatnými záznamy byly hodnoty impedancí.

Baterie byly nabíjeny konstantním proudem do plné kapacity a následně vybity konstantním proudem hodnoty 2 A. Každá z baterií byla vybita do jiné hodnoty napětí, konkrétně 2,7 V, 2,5 V, 2,2 V a 2,7 V.

Při zpracovávání problematiky tvorby degradačního modelu v případě baterií se postupovalo ve smyslu obecného algoritmu prognostiky 2.3. Z důvodu přítomnosti mezní hodnoty v podobě prahové hodnoty kapacity a předpokládaného lineárního způsobu degradace došlo ke zvolení lineárního degradačního modelu.

#### A. Vizualizace problému a předzpracování dat

Baterie s každým nabitím a vybitím postupně degraduje a dochází tak k postupné ztrátě vlastnosti udržet energii. Baterie podle obrázku 14 s každým dalším cyklem dokáže udržet stále menší množství energie, to se projevuje například na časech vybití, které se snižují. Hodnota napětí ani proudu se však nijak nezmění. Tento způsob degradace je lineární a pokračoval by, dokud by baterie nedošla na konec své životnosti.



Obrázek 14: Degradace baterie: datová sada baterií

## URČENÍ RUL NA DATOVÝCH SADÁCH

Pro tvorbu modelů byly zvoleny vybíjecí cykly baterií obsahující informace o kapacitě, jako jednom z ukazatelů životnosti.

Data, jak je patrné z obrázku 14, nepotřebovala v této podobě dalšího předzpracování.

### B. Extrahování zvolených příznaků

Zpracovávaná data byla z časové oblasti. Z toho plyne tabulka 10 obsahující pouze příznaky z této oblasti. Dodatečným příznakem byla také samotná kapacita.

Tabulka 10: Extrahované příznaky pro degrační model: datová sada baterií

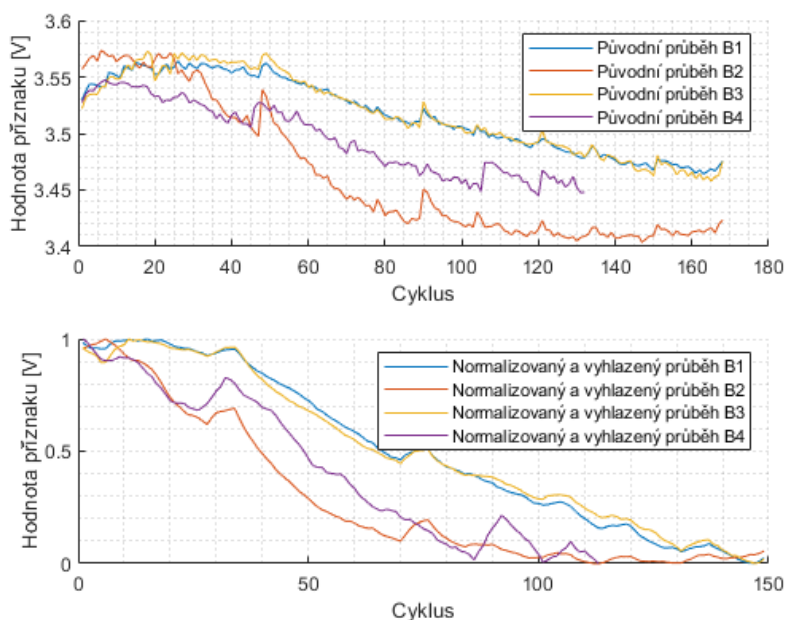
Extrahovaný příznak	Datový průběh
Průměrná hodnota	Napětí, Proud, Teplota
Standardní odchylka od průměrné hodnoty	Napětí, Proud, Teplota
Šikmost	Napětí, Proud, Teplota
Špičatost	Napětí, Proud, Teplota
Hodnota maximum–minimum	Napětí, Proud, Teplota
Střední kvadratická hodnota	Napětí, Proud, Teplota
Činitel výkyvu	Napětí, Proud, Teplota
Tvarový faktor	Napětí, Proud, Teplota
Činitel impulsu	Napětí, Proud, Teplota
Činitel marže	Napětí, Proud, Teplota
Energie	Napětí, Proud, Teplota
Maximální hodnota činného výkonu	Určena z napětí a proudu
Čas vybití	Napětí
Nejnižší hodnota napětí	Napětí
Nejvyšší hodnota teploty	Teplota

### C. Zpracování příznaků podle další potřeby

V tomto kroku byly extrahované atributy vyhlazeny stejným způsobem jako u podobnostních modelů v C pomocí příkazu *movmean* [50]. Baterie v prvních pár cyklech nevykazovali zřetelnou degradaci a příznaky tak prošly procesem *offsetu*, kdy došlo k odstranění prvních 20 cyklů.

Příznaky byly následně znormalizovány do rozmezí hodnot 0 až 1 podle metodiky zmíněné v C. Došlo tedy ke sjednocení rozměrů všech příznaků, ale také baterií, jelikož z důvodu dosažení různých hodnot napětí při vybití došlo k mírnému odlišení hodnot určitých příznaků s nimi souvisejících.

Důvod použití *offsetu* a normalizace je viditelný na obrázku 15, kde došlo k vyobrazení příznaku představujícího průměrnou hodnotu napětí v každém cyklu pro všechny čtyři baterie.



Obrázek 15: Rozdíl mezi nezpracovanými a zpracovanými příznaky: datová sada baterií

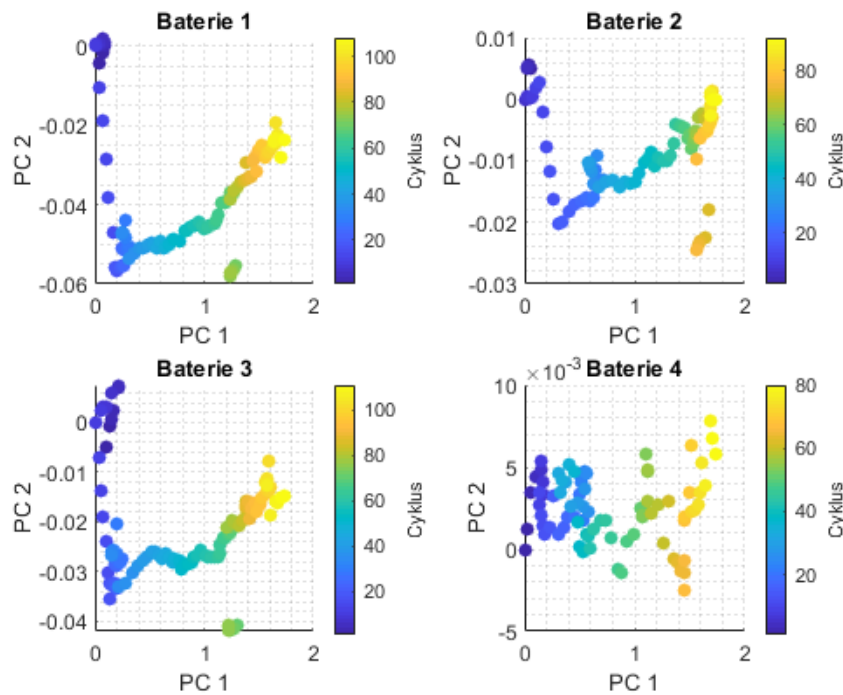
#### D. Vyhodnocování vhodnosti příznaků

Postup byl téměř obdobný tomu u podobnostních modelů v D. Bylo vybráno deset nejlepších příznaků a jediný rozdíl byl ve vynechání výběru z dvojice podle podmínky větší – menší, která zde neměla význam. Větší význam byl při výběru kladen na metodu *monotónnost*.

#### E. Případná redukce počtu příznaků a určení mezní hranice

Degradační modely pracují na principu reprodukce degradace za pomoci jediného profilu životnosti. Modely byly tedy tvořeny na samostatných profilech získaných z bodu výše, případně jejich kombinaci.

Metoda PCA byla použita na kombinace některých vybraných příznaků s cílem obdržení lepšího popisu degradace. Při výběru hlavních komponent se postupovalo podle požadavků popsanych v řešeršní části práce (kapitola E). V tomto případě byla snaha docílit ideálního rozlišení zredukovaných proměnných v co nejširším měřítku a zároveň ve smyslu jasné degradace, jak je patrné z obrázku 16, který zobrazuje oblast zredukovaných příznaků pro všechny baterie. Jako ukazatel degradace byla ve všech případech zvolena skupina hlavních komponent PC 1.



Obrázek 16:PCA metoda: datová sada baterií

Z důvodu přítomnosti mezní hodnoty došlo v tomto kroku také k vytvoření příslušného *thresholdu* reprezentující konec životnosti. K určení této hranice byla využita znalost mezní hodnoty kapacity 1,4 Ah a její příslušný cyklus pro každou z baterií. Za pomoci znalosti takového cyklu došlo k zaznamenání příslušné hodnoty sledovaného degračního profilu pro všechny baterie. Byly tedy získány čtyři hodnoty reprezentující mezní hranici, jejichž průměrná hodnota představovala konečnou mez degradace a začátek poruchového stavu. Při použití kapacity jako příkladného profilu, tak došlo ke zprůměrování hodnot kapacit příslušejících cyklům konců životností jednotlivých baterií.

## F. Trénování modelů ze zvolených či redukovanych příznaků a jejich následná validace

Na základě principu výběru příznaků popsaného v D byly vybrány nejvhodnější atributy obsažené v tabulce 11.

Tabulka 11: Nejlepší vybrané příznaky: datová sada baterií

Standardní odchylka proudu	Šikmost proudu	Střední kvadratická hodnota proudu	Špičatost proudu	Tvarový faktor napětí	Průměrná hodnota napětí
Kapacita	Činitel impulsu napětí	Činitel výkyvu napětí	Standardní odchylka teploty	Střední kvadratická hodnota napětí	Činitel marže napětí

## URČENÍ RUL NA DATOVÝCH SADÁCH

Modely na principu metody PCA

V případě nasazení metody PCA na různé kombinace příznaků se sledovaly vlastnosti nově vzniklých proměnných (viz obrázek 16). Pro nejvhodnější kombinace byly vytvořeny modely v rámci křížové validace, kdy jejich validace a zanesení výsledků probíhalo na stejném principu jako v F. Do práce tedy byly uvedeny pouze některé možné kombinace viditelné v tabulce 12.

Tabulka 12: Chyby v odhadech RUL pro degradační model – metoda PCA: datová sada baterií

Vali- dace	Či. imp. nap., Či. výk. nap., Či. marže napětí		Činitel výkyvu napětí, Činitel marže napětí		Činitel impulsu napětí, Činitel marže napětí		Činitel marže napětí, Standardní odchylka teploty	
	Průměr	Medián	Průměr	Medián	Průměr	Medián	Průměr	Medián
1	17,9	19,8	17,6	19,7	17,6	19,7	2,1	4
2	-14,8	-4	-14,1	-3,3	-15,5	-4,1	-23,8	-9,7
3	7,7	6,6	6,7	6	6,3	5,9	6,8	7,2
4	-1,3	-3,5	-0,9	-3,3	-1,1	-3,1	0,9	-1

Tabulka 13: Výsledné odhady RUL pro degradační model – metoda PCA: datová sada baterií

Vali- dace	Činitel imp. nap., Činitel výk. nap., Čin. marže napětí		Činitel výkyvu napětí, Činitel marže napětí		Činitel impulsu napětí, Činitel marže		Činitel marže, Standardní odchylka teploty		Skutečná hodnota RUL	
	35	80	35	80	35	80	35	80	35	80
1	35,1	1,4	35,6	1,5	35,5	1,5	60,3	9	59	18
2	132,2	22,8	129,6	22,8	133,8	23,2	147,4	31	72	22
3	68,2	12,4	70,2	13	71	13,2	71,8	11,4	70	21
4	40,3	18,4	40	18,2	40,4	18,1	37,1	16	52	16

## URČENÍ RUL NA DATOVÝCH SADÁCH

Modely založené na jediném příznaku

V případě použití jediného příznaku, jako degradačního profilu, nebylo využito metody PCA ani v podobě dodatečného filtru. Data byla již vyhlazená dle principu v C.

Tabulka 14: Chyby v odhadech RUL pro degradační model – příznak jako profil: datová sada baterií

Vali- dace	Kapacita		Činitel marže napětí		Střední kvadratická hodnota napětí		Průměrná hodnota napětí	
	Průměr	Medián	Průměr	Medián	Průměr	Medián	Průměr	Medián
1	7,9	9,3	16,1	18,4	16,7	18,9	16,8	19
2	-0,9	1,2	-14,5	-2,9	-4,4	2,7	-6	2,3
3	-22,3	-18,6	2,8	4,5	-9,6	0,4	-8,2	1,5
4	4,5	4,4	-0,4	-2,3	3,9	2,8	3,5	2,8

Tabulka 15: Výsledné odhady RUL pro degradační model – příznak jako profil: datová sada baterií

Vali- dace	Kapacita		Činitel marže napětí		Střední kvadratická hodnota napětí		Průměrná hodnota napětí		Skutečná hodnota RUL	
	35	80	35	80	35	80	35	80	35	80
1	49,9	7,7	38,4	1,8	37,8	1,5	37,5	1,5	59	18
2	85,5	18	129,3	23,6	104,9	18,2	109,7	18,6	72	22
3	122,4	28,5	78,3	15,1	111	18,9	107,8	18,4	70	21
4	37,9	10,8	40	17,4	37	12,6	38,3	12,4	52	16

### G. Vyhodnocení vhodnosti vytrénovaných modelů a výběr nejpřesnějšího z nich


Modely byly vybírány podle kritérií stejných jako pro podobnostní modely. Sledovala se velikost průměrné hodnoty chyby celkového odhadu a také medián. Dalším kritériem výběrů byl opět fakt určení RUL v menší hodnotě, než byla ta skutečná. Podle těchto pravidel byl vybrán model slučující příznaky jako činitel marže napětí a standardní odchylka od průměrné hodnoty teploty v cyklu (model čtvrtý v tabulce 12) pomocí metody PCA. Jako samostatný profil se nejlépe osvědčila kapacita, průměrná hodnota napětí a střední kvadratická hodnota napětí v tabulce 14.

Z dosažených výsledků navíc vyplývá, že metoda PCA v jistých případech přinesla zlepšení. Tento fakt lze potvrdit porovnáním čtvrtých řádků pro modely obsahující činitel marže napětí v tabulce 15 a činitel marže napětí spojený se standardní odchylkou teploty v tabulce 13.

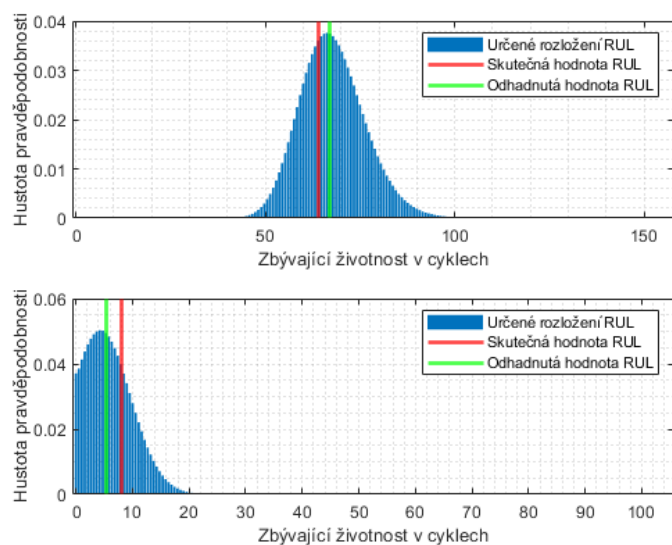
## URČENÍ RUL NA DATOVÝCH SADÁCH

Pro tyto modely došlo k přesnějšímu odhadu v pozdějších okamžicích, což je více než žádoucí. Tento fakt je navíc patrný u většiny modelů.

Pro model založený na principu PCA slučující standardní odchylku teploty a činitel marže napětí platí pravděpodobnostní rozdělení na obrázku 17. Obrázek 18 zobrazuje odhad RUL pomocí modelu používající jako degradační profil průměrnou hodnotu napětí v cyklu. Pro oba modely platí určení tohoto rozdělení pro 35, respektive 90 % skutečné životnosti. Dále je viditelný již zmíněný fakt zpřesňování odhadů s nárůstem historických dat.



Obrázek 17: Pravděpodobnostní odhad RUL – metoda PCA: datová sada baterií



Obrázek 18: Pravděpodobnostní odhad RUL – samostatný profil: datová sada baterií

### 3.3. Modely sledující míru přežití

#### Cíl datové sady

Pro datovou sadu [48] obsahující kompletní životnostní profily motorů čtyř různých typů, bylo požadavkem odhadnout zbývající životnost v podobě leteckých cyklů. Každý z příslušné skupiny motorů obsahoval blíže nespecifikovaná data až do okamžiku, kdy byl nutný zásah v podobě údržby.

#### Řešení problematiky podobnostních modelů

V rámci tvorby modelů zaměřujících se na statistické zpracování dat pouze ze záznamů okamžiků údržeb či poruch nebyla potřeba dodržet přesný postup obecného algoritmu prediktivní údržby podle 2.3.

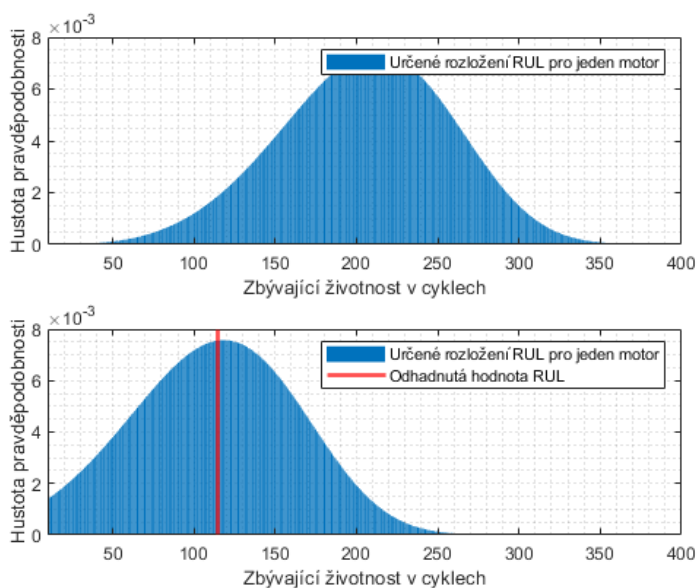
#### Příprava dat a trénování modelů

V rámci předzpracování dat nebyla potřeba žádného konkrétního procesu ani extrakce atributů. Z datové sady byly pouze extrahovány konečné hodnoty operačních cyklů každého z motorů, popřípadě přiřazení příslušné hodnoty cyklu k patřičnému motoru.

#### Spolehlivostní model

Byly vytrénovány dva modely. Jeden obsahoval konečné operační cykly pouze jednoho motoru, zatímco druhý byl vytrénován konečnými cykly všech čtyř motorů.

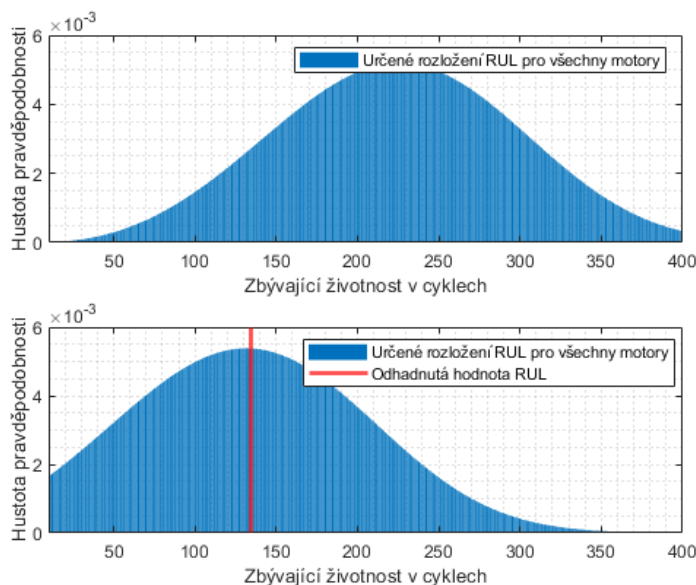
Na obrázku 19 je viditelné pravděpodobnostní rozdělení a následný odhad zbývající životnosti po dosažení 94 operačních cyklů.



Obrázek 19: Pravděpodobnostní rozdělení pro jeden motor: datová sada motorů

## URČENÍ RUL NA DATOVÝCH SADÁCH

Obrázek 20 platí pro model sdružující všechny čtyři motory. Jeho odhad zbývající životnosti je proveden opět po dosažení 94 cyklů.

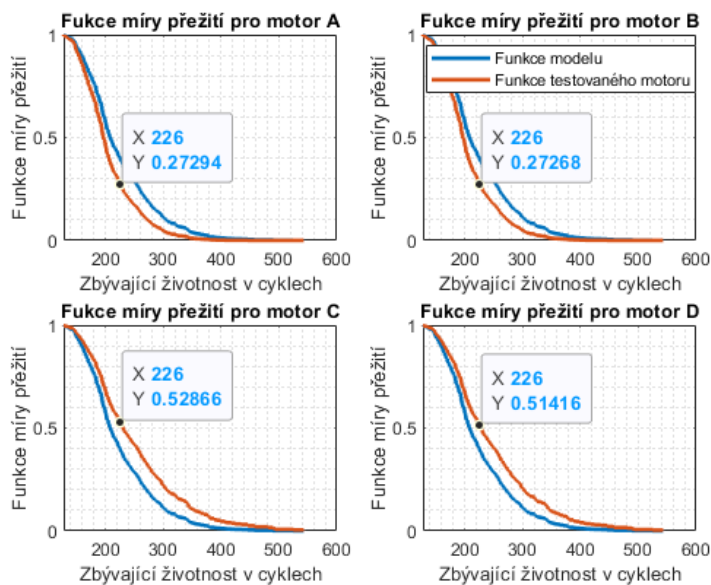


Obrázek 20: Pravděpodobnostní rozdělení pro čtyři motory: datová sada motorů

Kovariantní modely

Na základě konečných hodnot operačních cyklů a následného přiřazení jejich hodnoty k příslušnému typu motoru došlo k vytrenování kovariantního modelu s jediným kovariantem v podobě druhu motoru.

Výsledné funkce míry přežití pro všechny motory jsou viditelné na obrázku 21.



Obrázek 21: Výsledné funkce míry přežití pro jednotlivé motory: datová sada motorů

URČENÍ RUL NA DATOVÝCH SADÁCH

Z důvodu malého množství různých kovariantů je na obrázku 21 viditelná odchylka modelové funkce pro všechny motory od průběhu funkce konkrétního motoru. Motory A a B, respektive C a D, byly konečnými hodnotami svých životností v rámci datové sady velmi blízké. Z tohoto důvodu také vycházela odhadnutá zbývající životnost pro tyto páry prakticky stejná, jak je patrné z tabulky 16.

Tabulka 16: Odhadnuté hodnoty zbývajících cyklů: datová sada motory

Testovací cyklus	Zbývající odhadnuté cykly pro příslušný motor			
	A	B	C	D
10	184,6	184,9	218	215,6
35	159,6	159,9	193	190,6
60	134,6	134,9	168	165,6
80	114,6	114,9	148	145,6
120	74,6	74,9	108	105,6

**Zhodnocení:**

V případě spolehlivostního modelu bylo vhodné zpracovávat data pouze pro jeden motor samostatně. Došlo tak k získání přesnějších hodnot zbývajících životností.

U kovariantního modelu by bylo dosaženo přesnějších výsledných odhadů za použití vyššího počtu kovariantů. V případě datové sady jediným možným kovariantem byl pouze druh motoru.



## 4. Sestavení experimentální soustavy a následný odhad zbývající životnosti

### 4.1. Cíl experimentu

Cílem tohoto experimentu bylo aplikovat kompletní postup obecného algoritmu v takové podobě, jak byl popsán v rešeršní části v kapitole 2.3. Konkrétně tedy od samotné kolekce dat až po finální odhad zbývající životnosti vhodným modelem.

Experiment je inspirován zpracováním degradačního modelu použitého k určení zbývající životnosti Li-ion baterií popsaného v kapitole 3.2. V rámci experimentu došlo k návrhu jednoduché měřicí soustavy navržené pro Ni-MH baterie [51]. Z důvodu zpracování dat ve vybíjecích cyklech byla soustava navržena pouze pro tyto potřeby. Následně došlo k měření veličin zpracovávaných v již zmíněné kapitole degradačního modelu.

Při návrhu soustavy bylo potřeba vymyslet co nejrychlejší nabíjení a vybíjení baterie s cílem získání co největšího počtu dat. Dále se vycházelo z předpokladu co nejjednodušší verze možného měření jednotlivých klíčových veličin a v neposlední řadě také parametrů samotných měřených baterií.

Sledované baterie typu Ni-MH měly nominální hodnotu napětí 1,2 V. Podle výrobce baterie [52] měla minimální kapacitu 1000 mAh a umožňovala nabíjení konstantním proudem do 1 A. V případě vybíjení byla tato hodnota dvojnásobná.

### 4.2. Návrh a sestavení experimentální soustavy, měření požadovaných veličin

#### 4.2.1. Návrh a sestavení soustavy

Nabíjení bylo vyřešeno nabíječkou IPC-1L [53] umožňující nabíjení v maximálním rozsahu 700 mA.

V případě vybíjení se vycházelo z velikosti možného vybíjecího proudu. Požadavkem byla co nejvyšší možná hodnota tohoto proudu. Z Ohmova zákona byl proveden předběžný odhad možné ohmické hodnoty výkonového rezistoru. Tato hodnota byla finálně stanovena na 680 mΩ.

Z důvodu maximálního možného proudu o velikosti 2 A bylo k měření proudu využito senzoru proudu ACS712 ve variantě umožňující měřit proudy od -5 do 5 A [54]. Výstupem tohoto senzoru je pak napětí v podobě 0 V pro -5 A a 2,5 V pro 5 A.

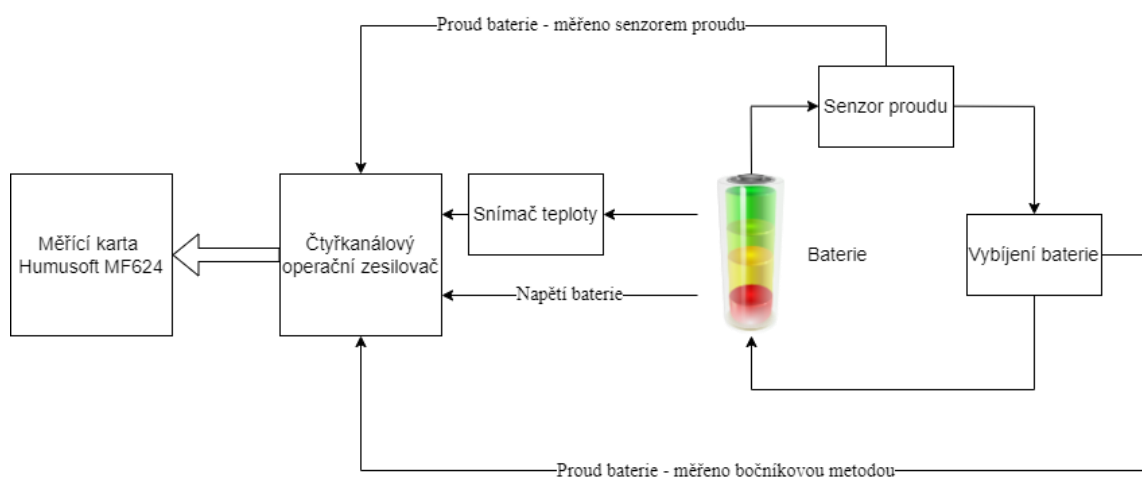
Výkonový rezistor v tomto případě sloužil také jako bočníková metoda měření proudu, z důvodu možných chyb měření proudu pomocí senzoru ACS712.

## URČENÍ RUL EXPERIMENTÁLNÍ SOUSTAVY

K měření teploty bylo využito snímače teploty PT1000 [55]. Z důvodu omezení hodnoty proudu snímačem bylo využito možnosti měření teploty v podobě napětí na tomto senzoru za pomoci napěťového děliče. Zařazením předřadného rezistoru byl proud omezen na požadovanou hodnotu stanovenou výrobcem. Snímač byl na baterii umístěn a zaizolován bavlnou z důvodu možného ochlazování vnějšími vlivy.

Každá měřená veličina byla z důvodů možné přítomnosti rušivých vlivů při měření příslušně zesílena. Toho bylo docíleno čtyřkanálovým operačním zesilovačem [56]. Zesilovač byl z důvodu kladné polaroty napětí jednotlivých veličin napájen pouze kladným napětím. Každý stupeň zesilovače byl zapojen jako neinvertující a signál zesiloval do určité hodnoty, která nesměla překročit 10 V, což vyplývá z řádků níže.

Konečná verze experimentální soustavy, v blokové podobě na obrázku 22.



Obrázek 22: Experimentální soustava: blokové schéma

Takto navržená soustava byla otestována na nepájivém poli s další realizací v podobě univerzálního plošného spoje. Celkem byly sestaveny čtyři tyto jednoduché vybíjecí soustavy pro určení veličin baterií usazených v jednoduchých držácích.

#### 4.2.2. Měření příslušných veličin

Signály zesílené pomocí operačních zesilovačů v neinvertujících zapojení byly následně měřeny pomocí měřicí karty MF624 [57], respektive MF634 [58], od výrobce Humusoft. Karta umožňovala měřit hodnoty maximálně do 10 V, z tohoto důvodu bylo zavedeno omezení maximálního zesíleného signálu v kapitole výše.

Za pomoci čtyř měřících soustav bylo měřeno deset baterií. Baterie byly vybíjeny do napětí 0,82 V. Každý vybíjecí cyklus trval přibližně 40 minut. Po každém vybití byly baterie následně vloženy do již zmíněné nabíječky k zahájení procesu nabíjení proudem 700 mA. V průběhu jejich nabíjení došlo k vybití další skupiny. Nabíjení trvalo asi 100 minut a tímto způsobem bylo změřeno 52 cyklů pro šest baterií a 48 cyklů pro další čtyři baterie.

URČENÍ RUL EXPERIMENTÁLNÍ SOUSTAVY

V průběhu měření se vyskytly problémy hlavně v prvních vybíjecích cyklech. Došlo totiž k záměně polarity proudu senzorem ACS712. Tato chyba byla po pár cyklech opravena. V jejím případě ani neznamenala závažnější problémy, protože stačilo provést korekce v procesu přepočtu napětí na proud, chybu ale způsoboval fakt rozdílnosti vlastností senzorů. Senzor by podle výrobce měl při nulovém proudu poskytovat hodnotu napětí 2,5 V, každý senzor měl ale tuto hodnotu trochu jinou. Došlo tedy k záznamu těchto hodnot z důvodu pozdějšího přepočtu napětí na proud.

V případě záznamů teplot baterií došlo k chybám v měření způsobených zahřátím baterií při nabíjecím cyklu. Baterie byly ihned po nabití přeloženy do vybíjecí soustavy, z tohoto důvodu nedošlo k potřebnému ustálení teplot.

Další chyby vznikly z důvodu zaizolování snímače teploty bavlnou a lepící páskou. Baterie byly tedy mohutnějších rozměrů a „vyskakovaly“ z jejich držáků, což způsobovalo výpadky měření.

### 4.3. Určení zbývající životnosti baterie na datech z experimentální soustavy

Při tvorbě modelů na odhad zbývající životnosti měřených baterií bylo postupováno podle obecného algoritmu popsání v řešební části práce v kapitole 2.3.

#### A. Vizualizace problému a předzpracování dat

Prvním krokem bylo příslušné přepočtení naměřených veličin v podobě napětí do správných veličin a jednotek.

V případě měřeného napětí baterie stačilo signál pouze zeslabit podle smyslu zesílení neinvertujícího zesilovače [59].

Signály ze senzoru proudu byly zeslabeny ve stejném smyslu a podle přepočtu [54] v podobě zeslabené hodnoty napětí mínus hodnota napětí při nulovém proudu senzoru a následným dělením tohoto rozdílu konstantou senzoru stanovenou výrobcem byl obdržen proud.

Proud bočníkovou metodou byl získán jako zeslabená hodnota napětí na rezistoru dělená jeho ohmickou hodnotou.

Nejkomplikovanější přepočet byl proveden u snímače teploty. Zde došlo opět k zeslabení signálu podle smyslu neinvertujícího zesilovače a za pomoci vztahu 5 pro určení hodnoty odporu na nezátížením napěťovém děliči:

$$R_{pt} = \frac{R_o \cdot U_{R_{pt}}}{U_{CC} - U_{R_{pt}}} \quad (5)$$

kde  $R_{pt}$  je ohmická hodnota snímače teploty PT1000,  $R_o$  je ohmická hodnota omezovacího rezistoru,  $U_{CC}$  je napájecí napětí a  $U_{R_{pt}}$  je změřené zeslabené napětí snímače.

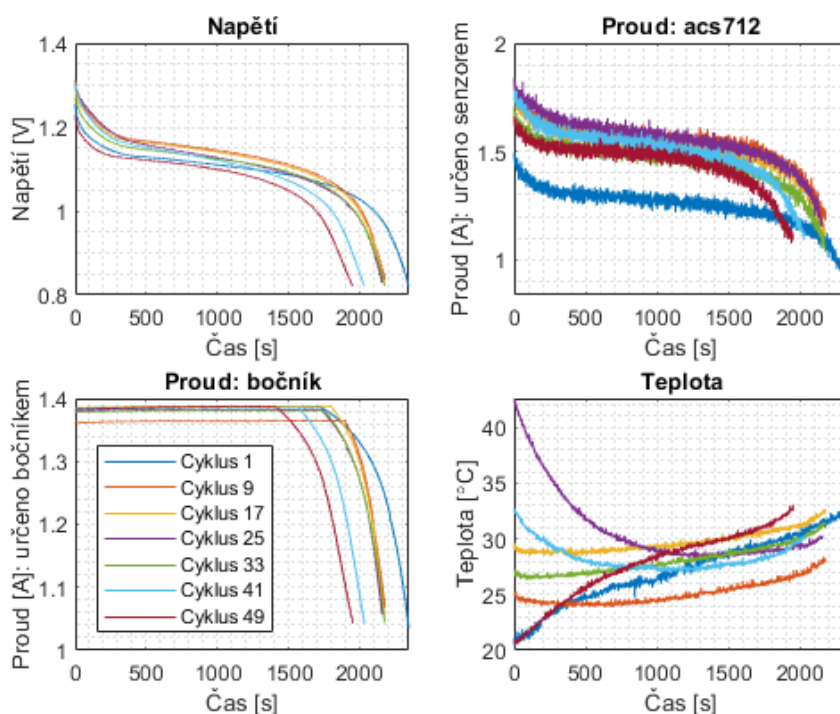
## URČENÍ RUL EXPERIMENTÁLNÍ SOUTAVY

Výsledná teplota byla pak určena podle vztahu 6 upraveného z [60]:

$$T = \sqrt{\frac{R_0^2 \cdot A^2 - 4 \cdot R_0^2 \cdot B + 4 \cdot R_0 \cdot B \cdot R_{pt} - R_0 \cdot A}{2 \cdot R_0 \cdot B}} \quad (6)$$

kde  $T$  je teplota příslušná dané ohmické hodnotě snímače,  $R_0$  je ohmická hodnota snímače při nula stupních celsia,  $R_{pt}$  je ohmická hodnota vypočtená z rovnice 5, a  $A$  i  $B$  jsou konstanty [60]:  $A = 3,9081 \cdot 10^{-3} \left[ \frac{1}{^\circ\text{C}} \right]$ ,  $B = -5,775 \cdot 10^{-7} \left[ \frac{1}{^\circ\text{C}^2} \right]$ .

Zeslabené a příslušně přepočtené veličiny jsou patrné z obrázku 23. Již zmíněný fakt neustálení teploty je viditelný z příslušné sekce obrázku. Dle předpokladu baterie lineárně degraduje (viz A).



Obrázek 23: Přepočtené hodnoty: degradace baterie – experiment

V rámci předzpracování došlo také k výpočtu kapacit pro příslušný cyklus. Kapacita baterie v Ah byla určena jako průměrná hodnota vybíjecího proudu bočníkem vynásobená časem vybití v daných jednotkách. Tento vztah je obecně nazýván *Coulomb counting* [51], kdy jeden coulomb se rovná náboji přenesenému proudem jednoho ampéru za jednu sekundu. Druhou kapacitou byla energetická ve Wh. Ta byla určena jako součin průměrných hodnot napětí a proudu bočníkem společně s časem vybití.

V případě průběhů proudů na obrázku 23 je patrný rozdíl mezi hodnotami proudů určených senzorem a bočníkovou metodou. Rozdíl je ve tvaru závislosti, ale i v samotných hodnotách. Možným odůvodněním může být nevhodné zvolení realizace na univerzální desku plošného spoje a dále vzniklé úbytky napětí,

## URČENÍ RUL EXPERIMENTÁLNÍ SOUTAVY

kteřé mohly takovéto chování způsobit. V případě stojáneků baterií také došlo k malému úbytku napětí mezi senzorem a tímto stojánkem.

## B. Extrahování zvolených příznaků

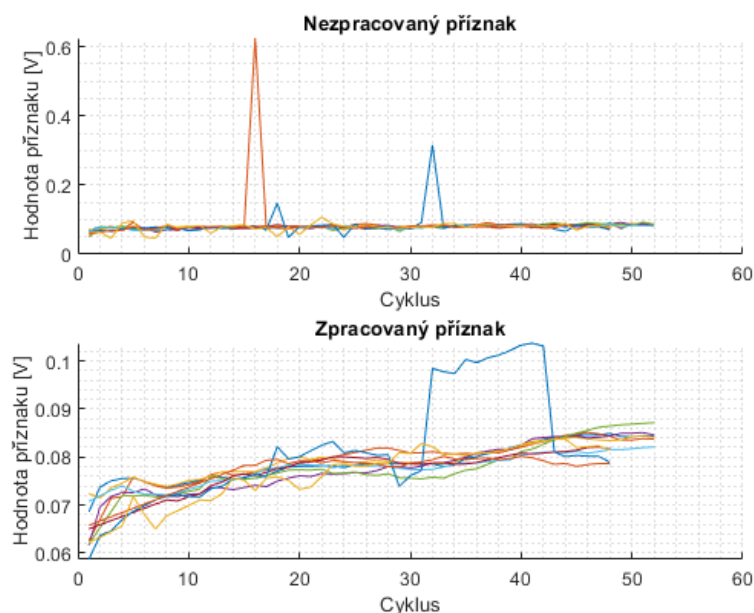
Naměřená data byla z časové oblasti. Jednotlivé příznaky, tabulka 17, byly extrahovány z průběhů napětí a obou průběhů proudů. Z důvodu chyby při měření teploty popsané výše, došlo pouze extrakci její poslední hodnoty v dané časové sérii. Dodatečnými příznaky byly obě vypočtené kapacity. Celkem tedy bylo extrahováno 38 příznaků.

Tabulka 17: Extrahované příznaky: experiment

Extrahovaný příznak	Datový průběh
Průměrná hodnota	Napětí, Proud bočником, Proud senzorem
Standardní odchylka od průměrné hodnoty	Napětí, Proud bočником, Proud senzorem
Šikmost	Napětí, Proud bočником, Proud senzorem
Špičatost	Napětí, Proud bočником, Proud senzorem
Hodnota maximum–minimum	Napětí, Proud bočником, Proud senzorem
Střední kvadratická hodnota	Napětí, Proud bočником, Proud senzorem
Činitel výkyvu	Napětí, Proud bočником, Proud senzorem
Tvarový faktor	Napětí, Proud bočником, Proud senzorem
Činitel impulsu	Napětí, Proud bočником, Proud senzorem
Činitel marže	Napětí, Proud bočником, Proud senzorem
Energie	Napětí, Proud bočником, Proud senzorem
Maximální hodnota činného výkonu	Určena z napětí a proudu bočником, respektive proudu senzorem
Konečná hodnota teploty	Teplota

## C. Zpracování příznaků podle další potřeby

V rámci zpracování prošly všechny atributy vyhlazením pomocí příkazu *movmean*. Z důvodu vysokého rozptylu hodnot u některých cyklů, bylo potřeba zavést korigující opatření v podobě přetvoření odlehlých hodnot za pomoci příkazu *filloutliers* [61]. Viditelný rozdíl mezi nezpracovaným průběhem atributu standardní odchylky od průměrné hodnoty napětí v cyklu a toho, který prošel zpracováním je zobrazený na obrázku 24.



Obrázek 24: Předzpracovaný průběh příznak pro všechny baterie: experiment

V kroku zpracování atributů došlo také k jejich normalizaci jako v případě degračného modelu baterie z datové sady C.

V tomto kroku také došlo k potenciálnímu rozhodnutí o nevhodnosti některých baterií, jak je vidět z již zmíněného obrázku 24. Tyto blíže nespecifikované baterie měly vliv na kvalitu odhadů, jak je viditelné v následujících tabulkách.

#### D. Vyhodnocování vhodnosti příznaků

Výběr probíhal obdobně jako u modelu tvořeného na datové sadě (viz D) s jediným rozdílem vynechání metody *prognosability* z důvodu nedosažení poruchového stavu.

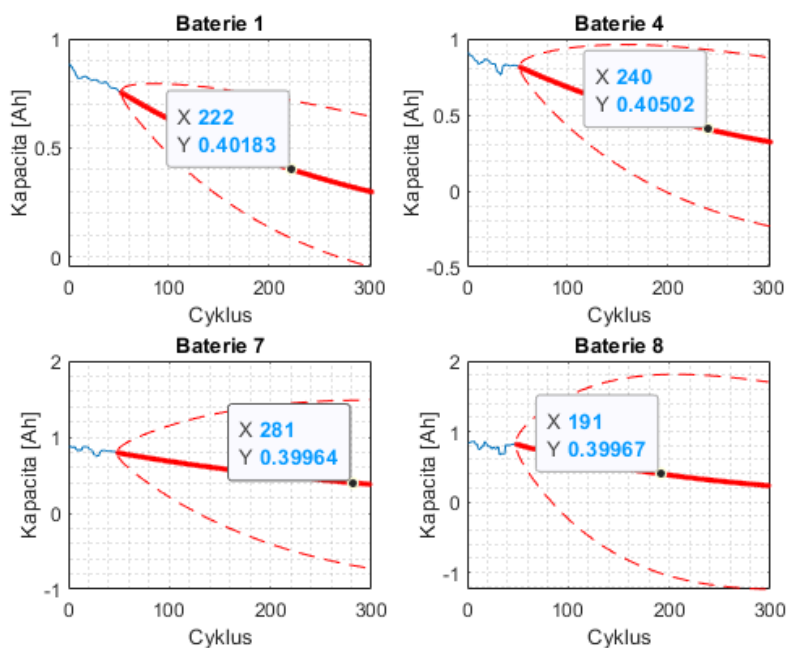
#### E. Případná redukce počtu příznaků a určení mezní hranice

V tomto kroku se postupovalo podle E u modelů baterií z datové sady. Z vybraných vhodných příznaků se podle stejného principu a následné vizuální kontroly zvolila vhodná PC skupina.

V případě určení hranice konce životnosti byla jako hlavní předpoklad zavedena konečná kapacita 0,4 Ah. Tato hodnota byla považována jako prvotní odhad před skutečným ověřením minimální možné použitelné hodnoty v reálném zařízení. Za pomoci průběhů získaných kapacit z bodu A došlo k vyobrazení možného způsobu jejich dalšího chování s narůstajícím počtem cyklů. Tento proces byl proveden na principu příkazu *forecast* [62]. Došlo k vytvoření modelu, který obdržel parametry charakterizující danou závislost kapacity a na tomto základě došlo k dalšímu vykreslení

## URČENÍ RUL EXPERIMENTÁLNÍ SOUTAVY

několikaset budoucích cyklů do hledané hodnoty kapacity 0,4 Ah, jak je patrné z obrázku 25. Šlo však pouze o odhady s možností vysoké chybovosti.



Obrázek 25: Předpovídaná degradace kapacity baterií: experiment

Za pomoci takto nabytých znalostí příslušných cyklů dané kapacity pro každou z baterií došlo ke zprůměrování hodnot těchto cyklů na stanovený mezní počet cyklů průměrné životnosti baterií. Touto hodnotou byl počet 250 cyklů.

Vyhodnocení mezní hodnoty v podobě hodnoty příznaku nebo kombinace příznaků proběhlo na základě předpokladu lineární degradace. Došlo tak k „protažení“ daného příznaku pomocí funkce přímky ve směrnicovém tvaru do hodnoty konečného cyklu. Na základě takto získaného počtu několika hodnot příslušejících počtu sledovaných baterií došlo k jejich zprůměrování pro získání jediné hodnoty představující aktuální mez životnosti. Tento proces byl proveden vždy pro všechny vybrané příznaky použitých pro konkrétní model.

## F. Trénování modelů ze zvolených či redukovanych příznaků a jejich následná validace

Podle výběru příznaků popsaného v D byly vybrány následující příznaky obsažené v tabulce 18 na další stránce.

Tabulka 18: Nejlepší vybrané příznaky: experiment

Průměrná hodnota proudu bočником	Hodnota min–max napětí	Hodnota min–max proudu bočником	Tvarový faktor proudu bočником	Standardní odchylka proudu senzorem
Střední kvadratická hodnota proudu bočником		Průměrná hodnota proudu bočником	Standardní odchylka proudu bočником	
Výkon určený z proudu bočником		Tvarový faktor napětí	Standardní odchylka napětí	

Modely na principu metody PCA: kombinace příznaků pro osm baterií

Podle postupu v F se v rámci PCA kombinovaly různé příznaky a baterie s cílem dosažení vhodnějšího profilu. Nejlepší výsledky byly zaneseny do tabulek.

Trénování probíhalo za pomoci šesti, respektive pěti baterií. Zbytek sloužil k validaci. V případě výpočtu chyb došlo vždy k určení průměrných chyb jako v případě podobnostního modelu (viz F). Jelikož validační skupina obsahovala více testovacích prvků, došlo k určení další průměrné hodnoty reprezentující celkový odhad modelu. Z tohoto důvodu často vznikaly vysoké chyby, i přestože jeden validační prvek byl odhadnut relativně dobře, jak je patrné z následujících tabulek.

V tabulce 19 příslušná zkratka označuje kombinaci příznaků (použité baterie 1, 2, 3, 4, 5, 6, 7, 9):

- A: průměrná hodnota proudu bočником, střední kvadratická hodnota proudu bočником, standardní odchylka napětí, hodnota min–max napětí, tvarový faktor napětí a výkon určený z proudu bočником a napětí
- B: průměrná hodnota proudu bočником, standardní odchylka napětí, tvarový faktor napětí a výkon určený z proudu bočником a napětí
- C: hodnota min–max proudu bočником, standardní odchylka napětí, tvarový faktor napětí
- D: standardní odchylky napětí a obou proudů, tvarový faktor napětí

Tabulka 19: Chyby v odhadech RUL pro degrační model – osm baterií metoda PCA: experiment

Vali-dace	A		B		C		D	
	Průměr	Medián	Průměr	Medián	Průměr	Medián	Průměr	Medián
1	-19,6	6,6	-28,6	-17,1	-129,9	138,3	14,8	12,9
2	49,6	66,3	35,7	39	12,2	17,9	44,1	35,2
3	-43,3	81	-17,1	67	80,1	92,9	58,1	70,1

## URČENÍ RUL EXPERIMENTÁLNÍ SOUTAVY

Tabulka 20: Výsledné odhady RUL pro degrační model – osm baterií metoda PCA: experiment

Vali- dace	A		B		C		D		Skutečná hodnota RUL	
	35	80	35	80	35	80	35	80	35	80
1	296,8	319,7	369,4	317,6	293,4	526	246,8	150,6	231	208
	184,8	125,6	167,3	123,4	252,2	280,4	222,4	207,5	231	208
2	164,4	141,3	191,1	163,8	246,7	214,5	221,3	191,5	231	208
	136,3	140,9	158,6	172,6	222,2	184,3	212,5	167,3	231	208
	165,3	187,6	175,4	174,2	218,2	164,6	143,3	101,6	233	211
3	165,8	116,1	190,4	129	150,8	110,5	232,8	163,6	231	208
	261,1	694,4	250,3	502,3	154,3	140,9	156,3	138,8	231	208
	159,5	126	186,9	141,1	141,5	102,9	149,2	110,2	233	211

Baterie se podle dosažených výsledků (tabulky 19 a 20) velice lišily, došlo tedy k vybrání těch nejpodobnějších s cílem vytvoření možné lepší podoby modelu, která ovšem nebyla tak komplexní jako podoba osmi baterií.

Příčina odlišnosti baterií může být odůvodněna růzností měřících soustav nebo případnou odlišností v rámci jednotlivých zesílení, kdy mohlo dojít k výraznějším rozdílům mezi použitými součástkami.

#### Modely na principu metody PCA: kombinace příznaků pro menší počet baterií

Postupovalo se stejným způsobem jako při kombinaci osmi baterií. Zároveň však probíhal výběr vhodných baterií v rámci skupiny několika nejpodobnějších.

V tabulce 2120 příslušná zkratka označuje kombinaci příznaků a baterií:

- A: standardní odchylka napětí a tvarový faktor napětí (baterie 3, 4, 5, 6, 7)
- B: standardní odchylka napětí, tvarový faktor napětí a tvarový faktor proudu bočníkem (baterie: 1, 3, 4, 5, 6, 7)
- C: standardní odchylka napětí a tvarový faktor napětí (baterie 1, 3, 4, 5, 6, 7, 10)
- D: standardní odchylky napětí a obou proudů, tvarový faktor napětí (baterie 3, 4, 5, 6, 7)

## URČENÍ RUL EXPERIMENTÁLNÍ SOUTAVY

Tabulka 21: Chyby v odhadech RUL pro degrační model – různý počet baterií  
metoda PCA: experiment

Vali- dace	A		B		C		D	
	Průměr	Medián	Průměr	Medián	Průměr	Medián	Průměr	Medián
1	-2,4	-2,4	-12,8	-12,5	2,8	23,1	2	2,1
2	56,5	58,6	47,9	55,4	61,3	65,1	89,1	100,1
3	45,5	50,2	14,3	15,2	59,6	63,5	21,5	2,5

Tabulka 22: Výsledné odhady RUL pro degrační model – různý počet baterií metoda  
PCA: experiment

Vali- dace	A		B		C		D		Skutečná hodnota RUL	
	35	80	35	80	35	80	35	80	35	80
1	225,2	216,3	226,8	208,4	213,9	178,3	229,2	205,5	231	208
	x	x	229,04	258,8	205,8	191,5	x	x	231	208
2	179,5	181,7	202,8	152,9	179,6	133,3	145,3	119,1	231	208
	165,4	121,8	201,4	132,4	163,1	141,8	142,6	97,6	233	211
	x	x	x	x	175	135,6	x	x	233	211
3	194,1	147,2	222,9	201,4	178,5	170	220	185,7	231	208
	174,6	157,6	207,9	184,2	171	122,9	211,4	179,7	231	208

Z výsledných hodnot v tabulkách 21 a 22 výše vyplývá, že nejlepšími ukazateli byly příznaky týkající se napětí a proudu bočníkem. Pro tyto příznaky také došlo k vytvoření příslušných modelů, kdy nejlepší z nich byly uvedeny v tabulkách 23 a 24.

Modely založené na jednom příznaku: standardní odchylka a tvarový faktor napětí

Modely založené na jediném příznaku byly nasazeny bez metodiky PCA. Tyto modely byly tvořeny na všech bateriích z důvodu vzniku nejobecnější podoby modelu. Výsledné chyby a odhady jsou patrné z tabulek 23 a 24.

Tabulka 23: Chyby v odhadech RUL pro degrační model – jediný příznak:  
experiment

Vali- dace	Standardní odchylka napětí		Tvarový faktor napětí	
	Průměr	Medián	Průměr	Medián
1	79,7	85,7	93	105
2	27,9	30,3	33,4	35,3
3	85,6	86,8	103,7	103,3

## URČENÍ RUL EXPERIMENTÁLNÍ SOUTAVY

Tabulka 24: Výsledné odhady RUL pro degrační model – jediný příznak: experiment

Vali- dace	Standardní odchylka napětí		Tvarový faktor napětí		Skutečná hodnota RUL	
	35	80	35	80	35	80
1	188,9	105,1	158,3	87,8	231	208
	202,9	151,6	122,2	109,1	231	208
	90,7	87,3	197,4	90,6	233	211
2	207,9	215,8	189	191,6	231	208
	187,8	189,5	161,7	138,2	231	208
	178,8	172,8	182,2	196,7	233	211
	189,7	161,4	174,5	212,4	233	211
3	143,1	113,3	77,7	89,8	231	208
	139	175	193,2	93,1	231	208
	98,3	92,1	105,6	104,3	233	211

### G. Vyhodnocení vhodnosti vytrénovaných modelů a výběr nejpřesnějšího z nich

Modely byly trénovány v různých možných kombinacích příznaků a baterií. S vybíráním více podobných baterií často docházelo ke zvyšování přesnosti za cenu obecnosti modelů.

Nejpřesnějším modelem byl model D pro první a třetí validační skupinu z tabulky 21, který kombinoval příznaky pro pět baterií. Obecnější model, který kombinoval osm baterií a stejné příznaky a jevil se poměrně přesný, byl model D z tabulky 19. Konkrétně validační skupiny jedna a dvě z příslušné tabulky. Oba tyto modely využily metodiku PCA. Z důvodu obsažení podobných příznaků v obou těchto případech bylo vytvořeno modelů založených čistě na jediném příznaku v podobě standardní odchylky napětí, respektive tvarového faktoru napětí.

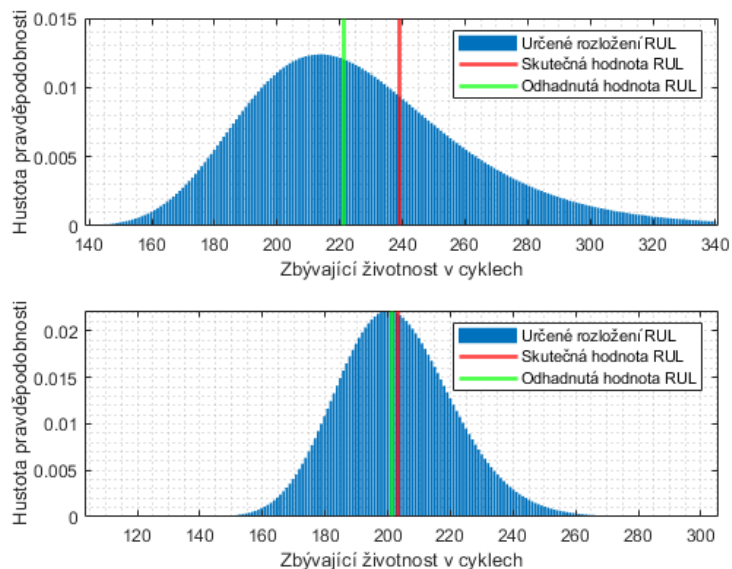
Mezi další a v práci neuvedené modely se řadí kombinační model, který spojoval příznaky standardní odchylky napětí, standardní odchylky proudu bočníkem a tvarový faktor napětí pro všech deset baterií. Výsledky byly podobné modelu založenému na standardní odchylce napětí. Model byl však méně přesný.

Modely vytvořené na zmíněných samostatných příznacích byly trénovány na všech měřených bateriích, došlo tak k vytvoření nejobecnější možné verze. Jeho obecnost byla však na úkor přesnosti, jak je patrné z tabulky 24.


Lepších výsledků bylo dosaženo u standardní odchylky napětí, kdy došlo k menším chybám v odhadech než u druhého případu. Tento model (druhá validační skupina v příslušné tabulce) byl tak zvolený jako finální pro jeho relativně dobrou přesnost,

## URČENÍ RUL EXPERIMENTÁLNÍ SOUTAVY

ale především pro jeho obecnost. Jeho následné odhady životností jsou vykresleny pro všechny validační baterie na sérii obrázků 26 až 29. Na těchto obrázcích je sledován odhad tohoto modelu po dosažení 35 % (horní část obrázků) a 90 % dat (spodní část obrázků) a také jedno z kritérií (G) výběru modelu v podobě nepřekročení skutečné životnosti tou odhadnutou. Z obrázků navíc plyne již zmiňovaný fakt zpřesňování odhadů ve smyslu vyšších hodnot pravděpodobností z důvodu nárůstu historických dat.

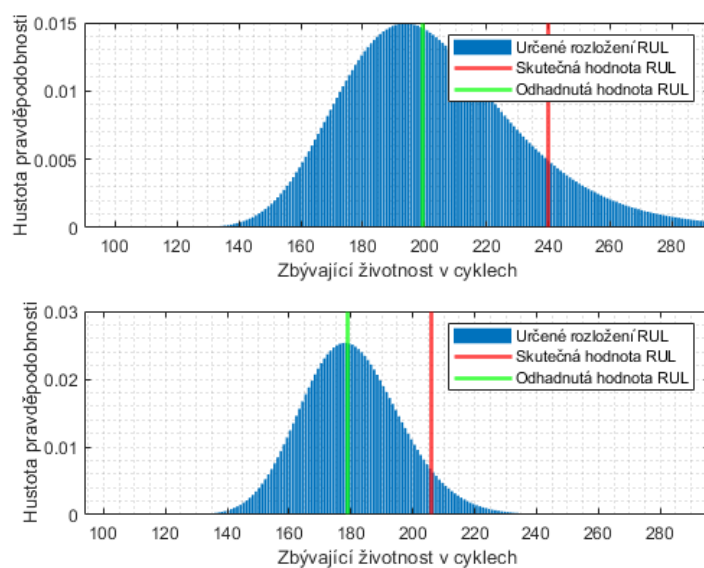


Obrázek 26: Validační baterie 1: finální model – experiment

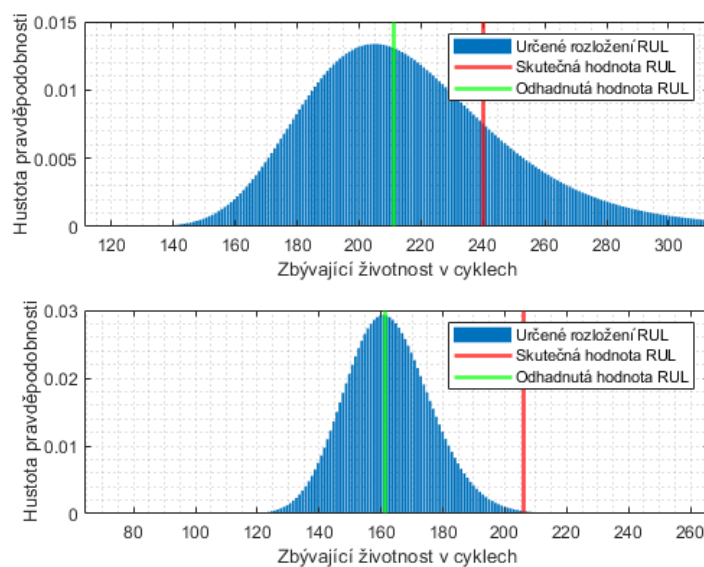


Obrázek 27: Validační baterie 2: finální model – experiment

## URČENÍ RUL EXPERIMENTÁLNÍ SOUTAVY



Obrázek 28: Validační baterie 3: finální model – experiment



Obrázek 29: Validační baterie 4: finální model – experiment



## 5. Závěr

Hlavním cílem této práce bylo seznámení se s oblastí prediktivní údržby s konkrétním zaměřením na část prognostickou a její algoritmy na odhad zbývající životnosti obecně a následným rozбором zpracování daných procesů v prostředí MATLAB. Praktickým závěrem bylo aplikování těchto znalostí na již naměřené datové sady a po vlastním návrhu a sestavení i na experimentální soustavu.

V rešeršní části došlo k představení oblasti údržby ať už obecně, nebo s širším zaměřením na tu prediktivní. V rámci konkrétně zmíněné byl zpracován postup aplikace jejího prognostického algoritmu na odhad zbývající životnosti. V specifických bodech to byly kolekce dat a jejich předzpracování, extrahování atributů příslušejících dané datové oblasti, jejich následné zpracování a výběr nejvhodnějších z nich. Z vhodných příznaků následné trénování modelů a výběr jejich nejlepších variant. Tyto body byly až na sběr dat podrobněji rozepsány v příslušných podkapitolách.

Dalším bodem rešeršní části bylo objasnění zpracování prognostické části prediktivní údržby v prostředí MATLAB. Byly představeny dvě aplikace umožňující v grafické podobě projít algoritmem tvorby modelů bez potřeby psaní kódu. Posledním bodem rešerše bylo představení modelů z nabídky MATLAB.

Praktická část byla formálně členěna na dvě. V první z nich došlo k aplikaci již zmíněného algoritmu na odhad zbývající životnosti systémů obsažených v datových sadách dostupných na internetu. Konkrétně byly provedeny odhady na datové sadě ložisek, motorů a Li-ion baterií. Každá datová sada byla zpracována za pomoci stejného algoritmu, ale na principu jiného vyhodnocovacího modelu.

Druhá část se soustředila na kompletní provedení algoritmu. Po samotném návrhu experimentální soustavy, umožňující měření Ni-MH baterií, došlo k jejímu sestavení. Následným krokem bylo měření napětí, proudů a teploty. Pro deset baterií stejného typu bylo naměřeno kolem padesáti cyklů.

V průběhu samotného měření se vyskytly problémy v podobě neustálení měřené teploty z důvodu neposkytnutí prostoru pro ochlazení po procesu nabíjení. Baterie byly ihned po nabití totiž vybíjeny.

Naměřené veličiny byly v podobě napětí. V rámci předzpracování bylo dosaženo jejich přepočtu do správných veličin. Z takto získaných veličin byly extrahovány příznaky z časové oblasti. Následným krokem bylo jejich patřičné zpracování a vyhodnocení jejich vhodnosti pro tvorbu modelů.

Vypracovávané modely byly tvořeny na základě aplikace metody PCA a také na samostatných příznacích. Výsledné modely byly vyhodnoceny podle určitých kritérií. Těmito kritérii byly výsledná průměrná chyba odhadu, medián chyby odhadu a také skutečnost nepřekročení skutečné zbývající životnosti tou odhadnutou. Dalším kritériem v případě vyššího počtu subjektů byla také obecnost jednotlivých modelů pro nasazení na více různých validačních členů s cílem přesného odhadu RUL (viz G).

Podle tohoto výběrů byl jako finální model v experimentální části zvolen ten, který umožňoval odhad nejvíce sledovaných baterií s poměrně dobrou přesností.

V průběhu zpracování algoritmů na datových sadách i experimentu byl problém s nedostatkem dat. V případě experimentu bylo dosaženo relativně dobrých výsledků. Jejich další zlepšení by nejspíše přineslo naměření více vybíjecích cyklů. Dalšími cíli tak může být získání většího množství dat pro další zpřesňování modelu nebo lepší provedení experimentální soustavy, která by umožňovala eliminaci popsaných chyb.

---

## Reference

- [1] LASI, Heiner, Peter FETTKE, Hans-Georg KEMPER, Thomas FELD a Michael HOFFMANN. Industry 4.0. *Business & Information Systems Engineering* [online]. 2014, **2014**(6), 261–264 [cit. 2022-03-06].  
Dostupné z: doi:10.1007/s11576-014-0424-4
- [2] RAN, Yongyi, Xin ZHOU, Yonggang WEN, Pengfeng LIN a Ruilong DENG. *A Survey of Predictive Maintenance: Systems, Purposes and Approaches* [online]. In: . New York: arXiv, 2019 [cit. 2022-03-06].  
Dostupné z: doi:10.48550/ARXIV.1912.07383
- [3] SAYYAD, Sameer, Arunkumar BONGALE, Arunkumar KAMAT, Shruti PATIL, Ketan KOTECHA a Satish KUMAR. Data-Driven Remaining Useful Life Estimation for Milling Process: Sensors, Algorithms, Datasets, and Future Directions. *IEEE Access* [online]. IEEE, 2021, **9**, 110255-110286 [cit. 2022-04-12]. ISSN 2169-3536.  
Dostupné z: doi:10.1109/ACCESS.2021.3101284
- [4] The Fourth Industrial Revolution. In: *Theenglishfarm* [online]. Auckland: Di, 2018 [cit. 2022-04-05].  
Dostupné z: <https://theenglishfarm.com/discussion/fourth-industrial-revolution>
- [5] RUL Estimation Using RUL Estimator Models. In: *MathWorks* [online]. Natick [cit. 2022-04-10].  
Dostupné z: <https://www.mathworks.com/help/predmaint/ug/rul-estimation-using-rul-estimator-models.html>
- [6] Maintenance: Definitions, Benefits, and Application. In: *SafetyCulture* [online]. Townsville: Pimping, 2022 [cit. 2022-05-01].  
Dostupné z: <https://safetyculture.com/topics/maintenance/>
- [7] Maintenance (technical). In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001 [cit. 2022-04-05].  
Dostupné z: [https://en.wikipedia.org/wiki/Maintenance\\_\(technical\)](https://en.wikipedia.org/wiki/Maintenance_(technical))
- [8] SWANSON, Laura. Linking maintenance strategies to performance. *International Journal of Production Economics* [online]. 2001, **70**(3), 237-244 [cit. 2022-04-05].  
Dostupné z: doi:[https://doi.org/10.1016/S0925-5273\(00\)00067-0](https://doi.org/10.1016/S0925-5273(00)00067-0)
- [9] Predictive Maintenance with MATLAB. In: *MathWorks* [online]. Natick: MathWorks [cit. 2022-04-05].  
Dostupné z: [https://www.mathworks.com/campaigns/offers/predictive-maintenance-with-matlab.html?s\\_tid=vid\\_pers\\_ofr\\_rec](https://www.mathworks.com/campaigns/offers/predictive-maintenance-with-matlab.html?s_tid=vid_pers_ofr_rec)

- 
- [10] DAILY, Jim a Jeff PETERSON, ed. Predictive Maintenance: How Big Data Analysis Can Improve Maintenance. WALTHER, Johannes a Klaus RICHTER. *Supply Chain Integration Challenges in Commercial Aerospace: A Comprehensive Perspective on the Aviation Value Chain* [online]. 1. Switzerland: Springer, 2016, s. 267–278 [cit. 2022-04-10]. ISBN 978-3-319-46155-7.  
Dostupné z: [https://link.springer.com/chapter/10.1007/978-3-319-46155-7\\_18](https://link.springer.com/chapter/10.1007/978-3-319-46155-7_18)
- [11] SHUAI, Guo. Data-Driven Predictive Maintenance In a Nutshell. In: *Towards Data Science* [online]. Toronto: Shuai, 2021 [cit. 2022-04-10].  
Dostupné z: <https://towardsdatascience.com/data-driven-predictive-maintenance-in-a-nutshell-ccc65a13b998>
- [12] Designing Algorithms for Condition Monitoring and Predictive Maintenance. In: *MathWorks* [online]. Natick [cit. 2022-04-11].  
Dostupné z: <https://www.mathworks.com/help/predmaint/gs/designing-algorithms-for-condition-monitoring-and-predictive-maintenance.html>
- [13] LI, Weijun, Hui LI, Sai GU a Tao CHEN. Process fault diagnosis with model- and knowledge-based approaches: Advances and opportunities. *Control Engineering Practice* [online]. 2020, **105** [cit. 2022-04-10]. ISSN 0967-0661.  
Dostupné z: [doi:https://doi.org/10.1016/j.conengprac.2020.104637](https://doi.org/10.1016/j.conengprac.2020.104637)
- [14] CHEN, Zhongzhe, Shuchen CAO a Zijian MAO. Remaining Useful Life Estimation of Aircraft Engines Using a Modified Similarity and Supporting Vector Machine (SVM) Approach. *Energies* [online]. MDPI, 2017, **11**(1) [cit. 2022-04-14]. ISSN 1996-1073.  
Dostupné z: [doi:https://doi.org/10.3390/en11010028](https://doi.org/10.3390/en11010028)
- [15] Preprocessing Data. In: *MathWorks* [online]. Natick [cit. 2022-04-11].  
Dostupné z: <https://www.mathworks.com/help/matlab/preprocessing-data.html>
- [16] Data Preprocessing for Condition Monitoring and Predictive Maintenance. In: *MathWorks* [online]. Natick [cit. 2022-04-11].  
Dostupné z: <https://www.mathworks.com/help/predmaint/ug/data-preprocessing-for-condition-monitoring-and-predictive-maintenance.html>
- [17] WODECKI, Jacek, Anna MICHALAK a Paweł STEFANIAK. Review of smoothing methods for enhancement of noisy data from heavy-duty LHD mining machines. *E3S Web of Conferences* [online]. EDP Sciences, 2018, **29** [cit. 2022-05-02]. ISSN 2267-1242.  
Dostupné z: [doi:https://doi.org/10.1051/e3sconf/20182900011](https://doi.org/10.1051/e3sconf/20182900011)
- [18] Filtering and Smoothing Data. In: *MathWorks* [online]. Natick [cit. 2022-05-02].  
Dostupné z: <https://www.mathworks.com/help/curvefit/smoothing-data.html>
- [19] Condition Indicators for Monitoring, Fault Detection, and Prediction. In: *MathWorks* [online]. Natick [cit. 2022-04-11].  
Dostupné z: <https://www.mathworks.com/help/predmaint/ug/condition-indicators-for-condition-monitoring-and-prediction.html>
-

- 
- [20] WANG, Xiang, Yuan ZHENG, Zhenzhou ZHAO a Jinping WANG. Bearing Fault Diagnosis Based on Statistical Locally Linear Embedding. *Sensors* [online]. 2015, **15**(7), 16225-16247 [cit. 2022-04-12]. ISSN 1424-8220.  
Dostupné z: doi:<https://doi.org/10.3390/s150716225>
- [21] Signal Features. In: *MathWorks* [online]. Natick [cit. 2022-04-13].  
Dostupné z: [https://www.mathworks.com/help/predmaint/ug/signal-features.html?searchHighlight=Clearance%20Factor&s\\_tid=srchtitle\\_Clearance%20Factor\\_3](https://www.mathworks.com/help/predmaint/ug/signal-features.html?searchHighlight=Clearance%20Factor&s_tid=srchtitle_Clearance%20Factor_3)
- [22] SOHAIB, Muhammad, M ISLAM, Jaeyoung JAEYOUNG KIM, Chan JEON a Jongmyon KIM. Leakage Detection of a Spherical Water Storage Tank in a Chemical Industry Using Acoustic Emissions. *Applied Sciences* [online]. 2019, **9**(1) [cit. 2022-04-13]. ISSN 2076-3417.  
Dostupné z: doi:[10.3390/app9010196](https://doi.org/10.3390/app9010196)
- [23] KOTSIANTIS, Sotiris, Dimitris KANELLOPOULOS a Panagiotis PINTELAS. Data preprocessing for supervised learning. *International journal of computer science* [online]. 2006, **1**(1), 111-117 [cit. 2022-04-15]. ISSN 1306-4428.  
Dostupné z: doi:[doi.org/10.5281/zenodo.1082415](https://doi.org/10.5281/zenodo.1082415)
- [24] Feature scaling. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2022 [cit. 2022-04-15].  
Dostupné z: [https://en.wikipedia.org/wiki/Feature\\_scaling](https://en.wikipedia.org/wiki/Feature_scaling)
- [25] URBANOWICZ, Ryan, Melissa MEEKER, William LA CAVA, Randal OLSON a Jason MOORE. Relief-based feature selection: Introduction and review. *Journal of Biomedical Informatics* [online]. 2018, **85**, 189-203 [cit. 2022-05-02]. Dostupné z: doi:<https://doi.org/10.1016/j.jbi.2018.07.014>
- [26] ŠŤASTNÝ, Petr. *Aplikace algoritmů prediktivní údržby na monitorování stavu experimentálního pneumatického zařízení*. Brno, 2021 [cit. 2022-05-02].  
Bakalářská práce. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ.  
Vedoucí práce Ing. Barnabás Dobossy.
- [27] Feature selection. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001 [cit. 2022-05-02].  
Dostupné z: [https://en.wikipedia.org/wiki/Feature\\_selection](https://en.wikipedia.org/wiki/Feature_selection)
- [28] BOMMERT, Andrea, Xudong SUN, Bernd BISCHL, Jörg RAHNENFÜHRER a Michel LANG. Benchmark for filter methods for feature selection in high-dimensional classification data. *Computational Statistics & Data Analysis* [online]. 2020, **143** [cit. 2022-05-02]. ISSN 0167-9473.  
Dostupné z: doi:<https://doi.org/10.1016/j.csda.2019.106839>
- [29] MALDONADO, Sebastián a Richard WEBER. A wrapper method for feature selection using Support Vector Machines. *Information Sciences* [online]. 2009, **179**(13), 2208-2217 [cit. 2022-05-03]. ISSN 0020-0255.  
Dostupné z: doi:<https://doi.org/10.1016/j.ins.2009.02.014>
-

- 
- [30] BOLÓN-CANEDO, Verónica, Noelia SÁNCHEZ-MAROÑO a Amparo ALONSO-BETANZOS. A review of feature selection methods on synthetic data. *Knowledge and Information Systems* [online]. 2013, **34**, 483–519 [cit. 2022-05-04]. ISSN 0219-3116.  
Dostupné z: doi:<https://doi.org/10.1007/s10115-012-0487-8>
- [31] Feature Selection for Remaining Useful Life Prediction. In: *MathWorks* [online]. Natick [cit. 2022-04-16].  
Dostupné z: <https://www.mathworks.com/help/predmaint/ug/feature-selection-for-remaining-useful-life-prediction.html>
- [32] BARALDI, P, G BONFANTI a E ZIO. Differential evolution-based multi-objective optimization for the definition of a health indicator for fault diagnostics and prognostics. *Mechanical Systems and Signal Processing* [online]. 2018, **102**, 382–400 [cit. 2022-05-02]. ISSN 0888-3270.  
Dostupné z: doi:<https://doi.org/10.1016/j.ymsp.2017.09.013>
- [33] Monotonicity. In: *MathWorks* [online]. Natick [cit. 2022-04-14].  
Dostupné z: [https://www.mathworks.com/help/predmaint/ref/monotonicity.html?s\\_tid=srchtitle\\_monotonicity\\_1](https://www.mathworks.com/help/predmaint/ref/monotonicity.html?s_tid=srchtitle_monotonicity_1)
- [34] BEWICK, Viv, Liz CHEEK a Jonathan BALL. Statistics review 7: Correlation and regression. *Critical Care* [online]. Springer, 2003, **7**, 451–459 [cit. 2022-05-11]. ISSN 1364-8535.  
Dostupné z: doi:<https://doi.org/10.1186/cc2401>
- [35] Trendability. In: *MathWorks* [online]. Natick [cit. 2022-04-14].  
Dostupné z: <https://www.mathworks.com/help/predmaint/ref/trendability.html>
- [36] Prognosability. In: *MathWorks* [online]. Natick [cit. 2022-04-14].  
Dostupné z: <https://www.mathworks.com/help/predmaint/ref/prognosability.html>
- [37] RUKSHAN, Pramoditha. 11 Dimensionality reduction techniques you should know in 2021. In: *Towards Data Science* [online]. Toronto: Rukshan, 2021 [cit. 2022-05-10]. Dostupné z: <https://towardsdatascience.com/11-dimensionality-reduction-techniques-you-should-know-in-2021-dcb9500d388b>
- [38] SERAFEIM, Loukas. PCA clearly explained —When, Why, How to use it and feature importance: A guide in Python. In: *Towards Data Science* [online]. Toronto: Serafeim, 2020 [cit. 2022-05-10].  
Dostupné z: <https://towardsdatascience.com/pca-clearly-explained-how-when-why-to-use-it-and-feature-importance-a-guide-in-python-7c274582c37e>
- [39] MOHAMMED, Alhamid. What is Cross-Validation?. In: *Towards Data Science* [online]. Toronto: Mohammed, 2020 [cit. 2022-05-09].  
Dostupné z: <https://towardsdatascience.com/what-is-cross-validation-60c01f9d9e75>
- [40] Predictive Maintenance Toolbox. In: *MathWorks* [online]. Natick [cit. 2022-04-20].  
Dostupné z: <https://www.mathworks.com/products/predictive-maintenance.html>
-

- 
- [41] Diagnostic Feature Designer. In: *MathWorks* [online]. Natick: MathWorks [cit. 2022-04-20]. Dostupné z: <https://www.mathworks.com/help/predmaint/ref/featuredesigner-app.html>
- [42] Classification Learner. In: *MathWorks* [online]. Natick [cit. 2022-04-14]. Dostupné z: <https://www.mathworks.com/help/stats/classificationlearner-app.html>
- [43] Data Ensembles for Condition Monitoring and Predictive Maintenance. In: *MathWorks* [online]. Natick [cit. 2022-04-10]. Dostupné z: <https://www.mathworks.com/help/predmaint/ug/data-ensembles-for-condition-monitoring-and-predictive-maintenance.html>
- [44] Feature hashing. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2021 [cit. 2022-05-11]. Dostupné z: [https://en.wikipedia.org/wiki/Feature\\_hashing](https://en.wikipedia.org/wiki/Feature_hashing)
- [45] MÜLLER, Meinard. Dynamic Time Warping. *Information Retrieval for Music and Motion* [online]. Heidelberg: Springer, 2007, s. 69–84 [cit. 2022-05-12]. ISBN 978-3-540-74048-3. Dostupné z: [https://link.springer.com/chapter/10.1007/978-3-540-74048-3\\_4](https://link.springer.com/chapter/10.1007/978-3-540-74048-3_4)
- [46] Update RUL Prediction as Data Arrives. In: *MathWorks* [online]. Natick [cit. 2022-04-10]. Dostupné z: <https://www.mathworks.com/help/predmaint/ug/update-rul-prediction-as-data-arrives.html>
- [47] CovariateSurvivalModel. In: *MathWorks* [online]. Natick: MathWorks [cit. 2022-05-10]. Dostupné z: [https://www.mathworks.com/help/predmaint/ref/covariatesurvivalmodel.html#mw\\_82e650f2-80e7-4e31-810a-8725faa59bca\\_head](https://www.mathworks.com/help/predmaint/ref/covariatesurvivalmodel.html#mw_82e650f2-80e7-4e31-810a-8725faa59bca_head)
- [48] *Ti.arc.nasa.gov* [online]. [cit. 2022-04-10]. Dostupné z: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>
- [49] BEHZAD, Mehdi, Abbas ROHANI a Hesam ARGHAND. Remaining useful life prediction of ball-bearings based on high-frequency vibration features. *Proceedings of the Institution of Mechanical Engineers Part C Journal of Mechanical Engineering Science* [online]. SAGE Publications, 2017, **232**(18) [cit. 2022-04-20]. ISSN 2041-2983. Dostupné z: doi:10.1177/0954406217734885
- [50] Movmean. In: *MathWorks* [online]. Natick [cit. 2022-05-09]. Dostupné z: <https://www.mathworks.com/help/matlab/ref/movmean.html>
- [51] *Battery University* [online]. Richmond: Cadex Electronics [cit. 2022-05-13]. Dostupné z: <https://batteryuniversity.com/>
- [52] VARTA nabíjecí baterie Power AAA 1000 mAh, 4ks. In: *CZC* [online]. Ostrava: CZC [cit. 2022-05-14]. Dostupné z: <https://www.czc.cz/>
-

- 
- [53] *Nabíječka IPC-1L* [online]. Slaný: Battex [cit. 2022-05-1].  
Dostupné z: [https://www.battex.cz/ipc-1l-x19673?gclid=CjwKCAjw7IeUBhBbEiwADhiEMemJWJJoH\\_8pWM\\_Ca98qQz\\_naVHW9PoPXjKLNtGhWX8SVK8\\_G\\_ZzrxoCs6cQAvD\\_BwE](https://www.battex.cz/ipc-1l-x19673?gclid=CjwKCAjw7IeUBhBbEiwADhiEMemJWJJoH_8pWM_Ca98qQz_naVHW9PoPXjKLNtGhWX8SVK8_G_ZzrxoCs6cQAvD_BwE)
- [54] GME, electronics. 5A proudový senzor, analogový výstup. In: *Gme.cz* [online]. Praha: GM electronic [cit. 2022-05-1].  
Dostupné z: <https://www.gme.cz/5a-proudovy-senzor-analogovy-vystup>
- [55] TME, electronic components. TT-PT1000B-2050-11-AUNI TEWA TEMPERATURE SENSORS. In: *TME electronic components* [online]. Łódź: Transfer Multisort Elektronik [cit. 2022-05-1].  
Dostupné z: <https://www.tme.eu/cz/details/tt-pt1000b-2050-11/cidla-teploty-odporove/tewa-temperature-sensors/tt-pt1000b-2050-11-auni/>
- [56] TME, electronic components. LM324N TEXAS INSTRUMENTS. In: *TME electronic components* [online]. Łódź: Transfer Multisort Elektronik [cit. 2022-05-14]. Dostupné z: <https://www.tme.eu/cz/details/lm324n-ti/operacni-zesilovace-tht/texas-instruments/lm324n/>
- [57] HUMUSOFT. MF624 - PCI Multifunkční vstupně-výstupní karta. In: *Humusoft* [online]. Praha: Humusoft [cit. 2022-05-14].  
Dostupné z: <https://www.humusoft.cz/datacq/mf624/>
- [58] HUMUSOFT. MF634 - PCI Express Multifunkční vstupně-výstupní karta. In: *Humusoft* [online]. Praha: Humusoft [cit. 2022-05-14].  
Dostupné z: <https://www.humusoft.cz/datacq/mf634/>
- [59] Operational amplifier applications. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001 [cit. 2022-05-13].  
Dostupné z: [https://en.wikipedia.org/wiki/Operational\\_amplifier\\_applications](https://en.wikipedia.org/wiki/Operational_amplifier_applications)
- [60] KONGSBERG. Platinum resistance temperature sensors Pt100 (Pt1000). In: *Kongsberg* [online]. Kongsberg: Kongsberg [cit. 2022-05-14].  
Dostupné z: [https://www.kongsberg.com/globalassets/maritime/km-products/product-documents/tsiec751\\_ce.pdf](https://www.kongsberg.com/globalassets/maritime/km-products/product-documents/tsiec751_ce.pdf)
- [61] Filloutliers. In: *MathWorks* [online]. Natick [cit. 2022-05-14].  
Dostupné z: <https://www.mathworks.com/help/matlab/ref/filloutliers.html>
- [62] Forecast. In: *MathWorks* [online]. Natick: MathWorks [cit. 2022-05-15].  
Dostupné z: <https://www.mathworks.com/help/ident/ref/idmodel.forecast.html>
-

## Seznam obrázků

Obrázek 1: Vývoj průmyslu ve smyslu průmyslových revolucí (převzato z [4]).....	11
Obrázek 2: Základní tři druhy údržeb (upraveno z [9]).....	13
Obrázek 3: Klasifikace dat: diagnostika (převzato z [11]) .....	16
Obrázek 4: Odhad zbývající životnosti: prognostika (převzato z [11]).....	16
Obrázek 5: Blokova podoba obecného algoritmu prediktivní údržby (převzato z [12])	17
Obrázek 6: Metoda PCA: obecný význam (převzato z [38]).....	21
Obrázek 7: Možné rozdělení prognostických modelů (převzato z [14]) .....	22
Obrázek 8: Křížová validace: základní princip.....	23
Obrázek 9: Uspořádání dat v ensemble: blokové schéma .....	25
Obrázek 10: Modely na odhad zbývající životnosti z nabídky MATLAB (převzato z [5]).....	25
Obrázek 11: Degradace ložiska: datová sada ložisek – průběh zrychlení .....	29
Obrázek 12: Vliv vyhlazení příznaku: datová sada ložisek .....	30
Obrázek 13: Určení zbývající životnosti ložiska pomocí exponenciálního modelu porovnávacího rezidua: datová sada ložisek .....	35
Obrázek 14: Degradace baterie: datová sada baterií.....	36
Obrázek 15: Rozdíl mezi nezpracovanými a zpracovanými příznaky: datová sada baterií .....	38
Obrázek 16: PCA metoda: datová sada baterií .....	39
Obrázek 17: Pravděpodobnostní odhad RUL – metoda PCA: datová sada baterií .....	42
Obrázek 18: Pravděpodobnostní odhad RUL – samostatný profil: datová sada baterií .	42
Obrázek 19: Pravděpodobnostní rozdělení pro jeden motor: datová sada motorů .....	43
Obrázek 20: Pravděpodobnostní rozdělení pro čtyři motory: datová sada motorů .....	44
Obrázek 21: Výsledné funkce míry přežití pro jednotlivé motory: datová sada motorů	44
Obrázek 22: Experimentální soustava: blokové schéma .....	48
Obrázek 23: Přepočtené hodnoty: degradace baterie – experiment.....	50
Obrázek 24: Předzpracovaný průběh příznak pro všechny baterie: experiment .....	52
Obrázek 25: Předpovídaná degradace kapacity baterií: experiment.....	53
Obrázek 26: Validační baterie 1: finální model – experiment.....	58
Obrázek 27: Validační baterie 2: finální model – experiment.....	58
Obrázek 28: Validační baterie 3: finální model – experiment.....	59
Obrázek 29: Validační baterie 4: finální model – experiment.....	59

---

## Seznam tabulek

Tabulka 1: Porovnání jednotlivých údržeb podle specifických hledisek .....	15
Tabulka 2: Extrakce příznaků: datová sada ložisek .....	30
Tabulka 3: Příznaky pro trénování jednotlivých skupin modelů: datová sada ložisek ...	32
Tabulka 4: Chyby v odhadech RUL pro modely křížící příznaky: datová sada ložisek .	32
Tabulka 5: Výsledné odhady RUL pro modely křížící příznaky: datová sada ložisek ...	33
Tabulka 6: Chyby v odhadech RUL pro párové modely – korelační model: datová sada ložisek.....	33
Tabulka 7: Výsledné odhady RUL pro párové modely – korelační model: datová sada ložisek.....	33
Tabulka 8: Chyby v odhadech RUL pro modely sledující rezidua – exponenciální model: datová sada ložisek.....	34
Tabulka 9: Výsledné odhady RUL pro modely sledující rezidua – exponenciální model: datová sada ložisek.....	34
Tabulka 10: Extrahované příznaky pro degradační model: datová sada baterií .....	37
Tabulka 11: Nejlepší vybrané příznaky: datová sada baterií .....	39
Tabulka 12: Chyby v odhadech RUL pro degradační model – metoda PCA: datová sada baterií.....	40
Tabulka 13: Výsledné odhady RUL pro degradační model – metoda PCA: datová sada baterií.....	40
Tabulka 14: Chyby v odhadech RUL pro degradační model – příznak jako profil: datová sada baterií.....	41
Tabulka 15: Výsledné odhady RUL pro degradační model – příznak jako profil: datová sada baterií.....	41
Tabulka 16: Odhadnuté hodnoty zbývajících cyklů: datová sada motory .....	45
Tabulka 17: Extrahované příznaky: experiment .....	51
Tabulka 18: Nejlepší vybrané příznaky: experiment .....	54
Tabulka 19: Chyby v odhadech RUL pro degradační model – osm baterií metoda PCA: experiment.....	54
Tabulka 20: Výsledné odhady RUL pro degradační model – osm baterií metoda PCA: experiment.....	55
Tabulka 21: Chyby v odhadech RUL pro degradační model – různý počet baterií metoda PCA: experiment .....	56
Tabulka 22: Výsledné odhady RUL pro degradační model – různý počet baterií metoda PCA: experiment.....	56
Tabulka 23: Chyby v odhadech RUL pro degradační model – jediný příznak: experiment.....	56
Tabulka 24: Výsledné odhady RUL pro degradační model – jediný příznak: experiment.....	57
Tabulka 25: Příklady možných příznaků .....	72

## Seznam příloh

### TABULKY:

- Příklady možných příznaků: Tabulka 25

### Přílohy uvedené v externím souboru ZIP

### SLOŽKY:

- „data\_set\_bearings“ – funkce a kompletní kód pro tvorbu podobnostních modelů
- „data\_set\_batteries“ – funkce a kompletní kód pro tvorbu degradačního modelu
- „data\_set\_motors“ – kompletní kód pro tvorbu statistických modelů
- „data\_set\_experiment\_batteries“ – funkce a kompletní kód pro tvorbu degradačních modelů založených na datech z experimentální soustavy

## Přílohy

Tabulka 25: Příklady možných příznaků

Příznak	Matematická podoba	Oblast
Maximální hodnota	$x_{\max} = \max(x_i)$	T, F, T-F
Minimální hodnota	$x_{\min} = \min(x_i)$	T, F, T-F
Špičková hodnota	$x_p = \max x_i $	T, F, T-F
Průměrná hodnota	$\bar{x} = \frac{1}{N} \cdot \sum_{i=1}^N x_i$	T, F, T-F
Standardní odchylka od průměrné hodnoty	$\sigma = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (x_i - \bar{x})^2}$	T, F, T-F
Hodnota kořenu	$x_R = \left( \frac{1}{N} \cdot \sum_{i=1}^N \sqrt{ x_i } \right)^2$	T
Střední kvadratická hodnota	$x_{\text{RMS}} = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N  x_i ^2}$	T
Špičatost	$x_{\text{kurt}} = \frac{1}{N} \cdot \sum_{i=1}^N \left( \frac{x_i - \bar{x}}{\sigma} \right)^4$	T, F, T-F
Šikmost	$x_{\text{skew}} = \frac{1}{N} \cdot \sum_{i=1}^N \left( \frac{x_i - \bar{x}}{\sigma} \right)^3$	T, F, T-F
Faktor šikmosti	$x_{\text{skewf}} = \frac{\frac{1}{N} \cdot \sum_{i=1}^N (x_i - \bar{x})^3}{\left( \frac{1}{N} \cdot \sum_{i=1}^N (x_i - \bar{x})^2 \right)^{\frac{3}{2}}}$	T
Faktor špičatosti	$x_{\text{kurtf}} = \frac{\frac{1}{N} \cdot \sum_{i=1}^N (x_i - \bar{x})^4}{\left( \frac{1}{N} \cdot \sum_{i=1}^N (x_i - \bar{x})^2 \right)^2}$	T
Rozptyl	$\text{var} = \frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - \bar{x})^2$	T

Tabulka 25: Příklady možných příznaků – pokračování

Tvarový faktor	$x_{sf} = \frac{x_{RMS}}{\frac{1}{N} \cdot \sum_{i=1}^N  x_i }$	T
Činitel impulsu	$x_{if} = \frac{x_p}{\frac{1}{N} \cdot \sum_{i=1}^N x_i^2}$	T
Činitel výkyvu	$x_{crest} = \frac{x_p}{\sqrt{\frac{1}{N} \cdot \sum_{i=1}^N x_i^2}}$	T
Činitel vůle	$x_{clear} = \frac{x_p}{\left(\frac{1}{N} \cdot \sum_{i=1}^N \sqrt{ x_i }\right)^2}$	T
Činitel marže	$x_{marg} = \frac{\max( x_i )}{\left(\frac{1}{N} \cdot \sum_{i=1}^N \sqrt{ x_i }\right)^2}$	T
Průměrná hodnota frekvence	$\bar{F} = \frac{1}{N} \cdot \sum_{i=1}^N p_i$	F
Střední kvadratická hodnota frekvence	$F_{RMS} = \sqrt{\frac{\sum_{i=1}^N p_i \cdot f_i^2}{\sum_{i=1}^N p_i}}$	F
Centrum frekvence	$F_{fc} = \frac{\sum_{i=1}^N p_i \cdot f_i}{\sum_{i=1}^N p_i}$	F
Kořenový rozptyl frekvence	$F_{rvf} = \sqrt{\frac{\sum_{i=1}^N (f_i - \bar{F})^2 \cdot p_i}{\sum_{i=1}^N p_i}}$	F
Absolutní hodnota amplitudy	$x_{abs} =  x_i $	F, T-F
Rozdíl mezi maximem a minimem	$x_{pp} = \max(x_i) - \min(x_i)$	F, T, T-F
Energie	$E = \sum_{i=1}^N x_i^2$	T

Poznámka k tabulce 25:

- veličina  $x_i$  znamená signál v určité oblasti,
- veličina  $p_i$  znamená hodnotu výkonového spektra hodnot  $x_i$  pro příslušnou přímku spektra  $i$ ,
- veličina  $f_i$  znamená hodnotu frekvence příslušné přímky  $i$  výkonového spektra.