


8.9.2022 Technical Computing Camp 2022

Prediktivní údržba, detekce anomálií a vizuální inspekce



Jaroslav Jirkovský
jirkovsky@humusoft.cz

www.humusoft.cz
info@humusoft.cz

www.mathworks.com

Několik pojmů na úvod

- Prediktivní analytika (Predictive Analytics)

- využívá historická data k předpovídání budoucích událostí
- <https://www.mathworks.com/discovery/predictive-analytics.html>



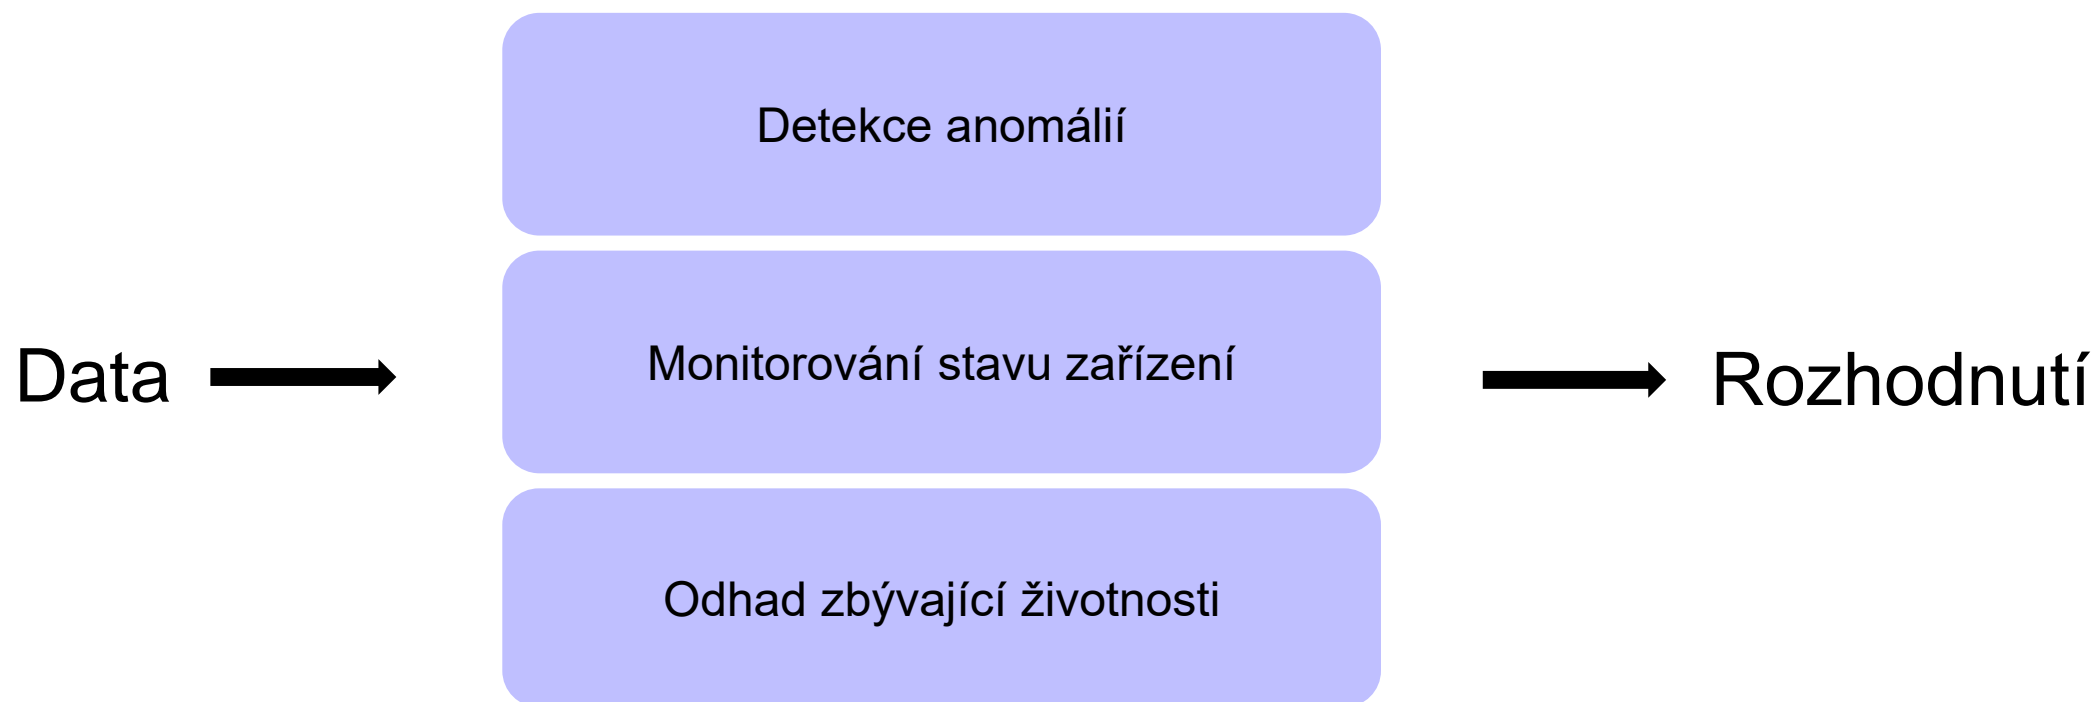
- průmyslová aplikace: Prediktivní údržba systémů

- Preskriptivní analytika (Prescriptive Analytics)

- využívá prediktivních modelů k navržení vhodné akce pro dosažení optimálních výstupů
- <https://www.mathworks.com/discovery/prescriptive-analytics.html>

Několik pojmů na úvod

- Prediktivní údržba (Predictive Maintenance)
 - údržba provozních průmyslových systémů a zařízení s využitím prediktivních modelů
 - <https://www.mathworks.com/discovery/predictive-maintenance-matlab.html>



Několik pojmů na úvod

- Detekce anomálií (Anomaly Detection)
 - identifikuje neočekávané události a odchylky od běžného chování
 - <https://www.mathworks.com/discovery/anomaly-detection.html>
- Monitorování stavu zařízení (Condition Monitoring)
 - analyzuje data ze senzorů a vyhodnocuje stav zařízení během provozu
 - <https://www.mathworks.com/discovery/condition-monitoring.html>
- Prognostika (Prognostics) – odhad zbývající životnosti (RUL)
 - předvídání potenciální poruchy zařízení
 - <https://www.mathworks.com/discovery/prognostics.html>

Několik pojmů na úvod

- Vizualní inspekce (Visual Inspection)
 - kontrola dílů na základě obrazu
 - kamera skenuje testovaný díl na závady a nedostatky v kvalitě
 - <https://www.mathworks.com/discovery/visual-inspection.html>

Postup vývoje algoritmů v uvedených aplikacích

Sběr dat

Příprava dat

Vývoj prediktivních
a klasifikačních modelů

Nasazení a
integrace

Soubory




Databáze



Snímače



Práce se
surovými daty



Redukce dat/
transformace



Extrakce
příznaků



Tvorba modelu
např. strojové učení



Optimalizace
parametrů



Validace
modelu



Aplikace pro PC



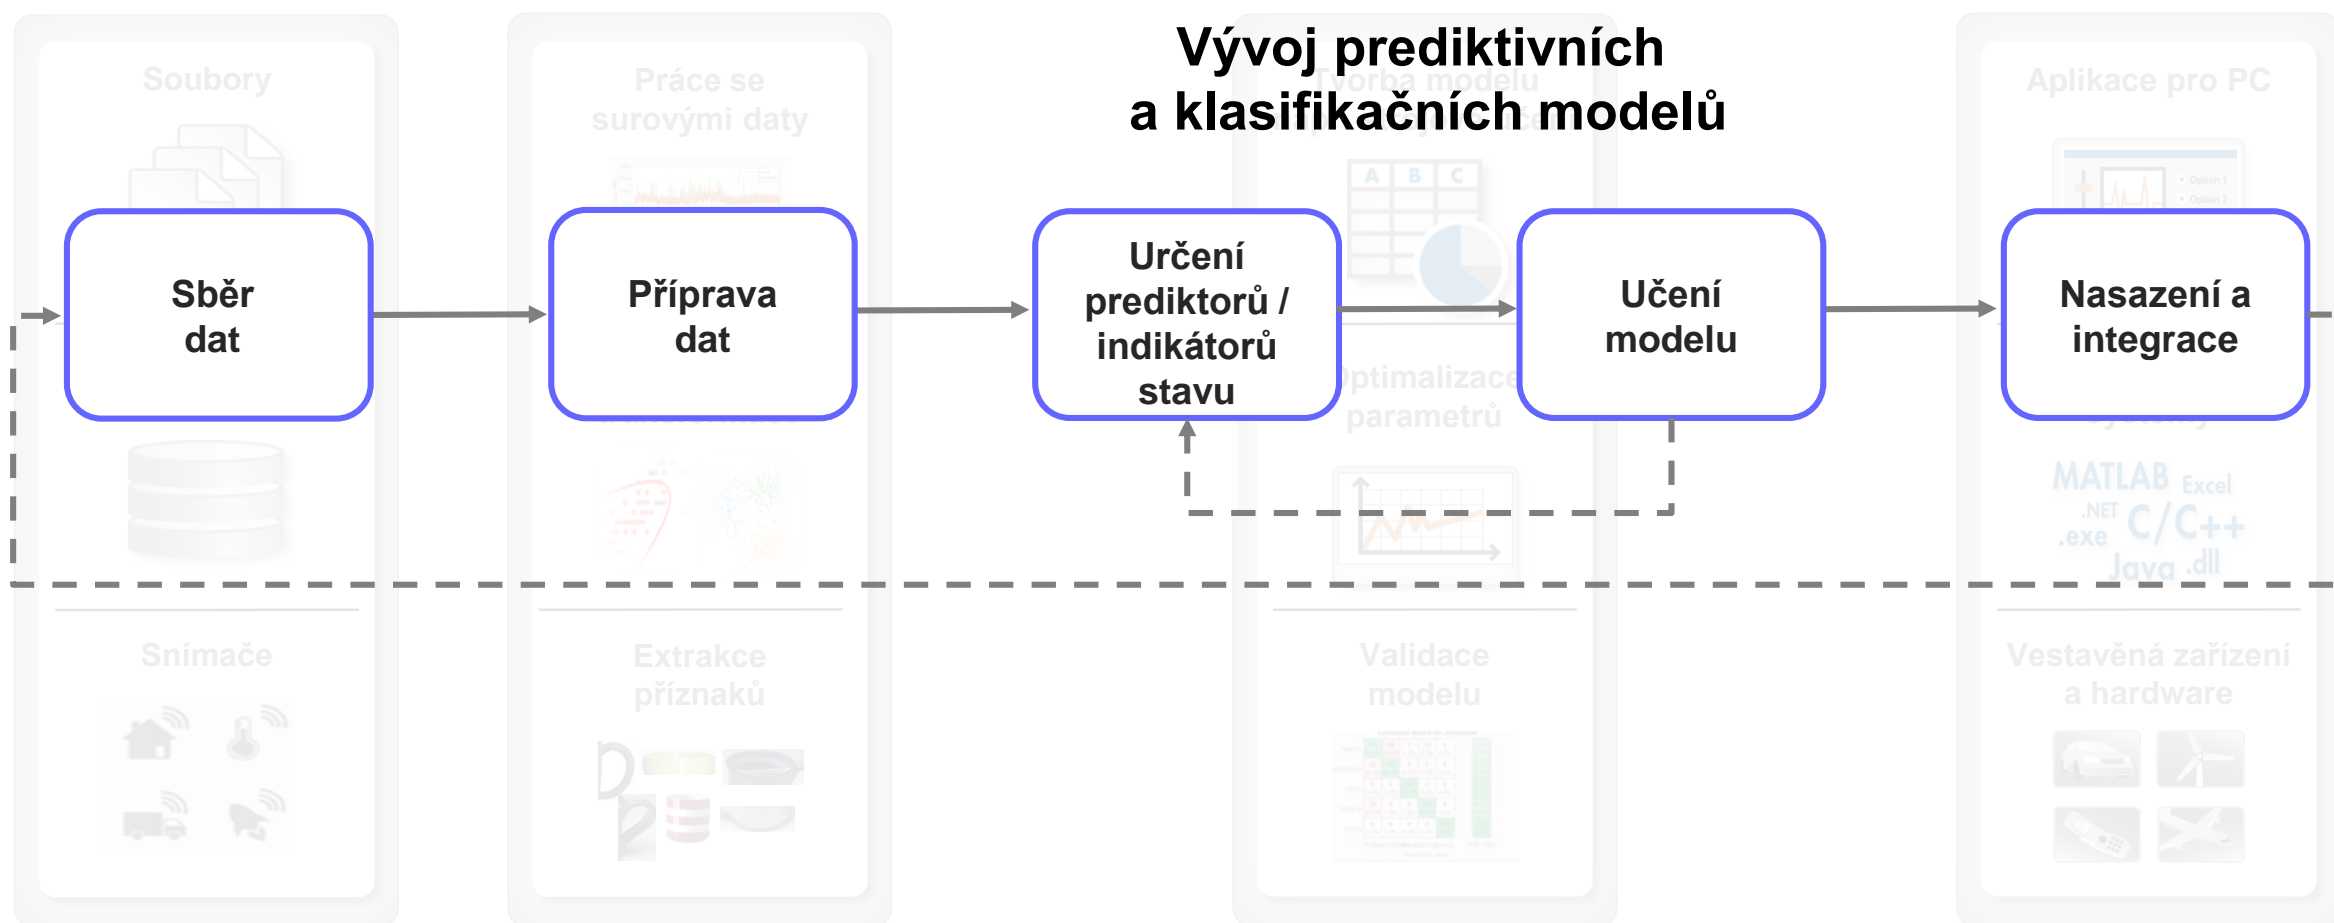
Podnikové
systémy

MATLAB Excel
.NET C/C++
.exe Java .dll

Vestavěná zařízení
a hardware



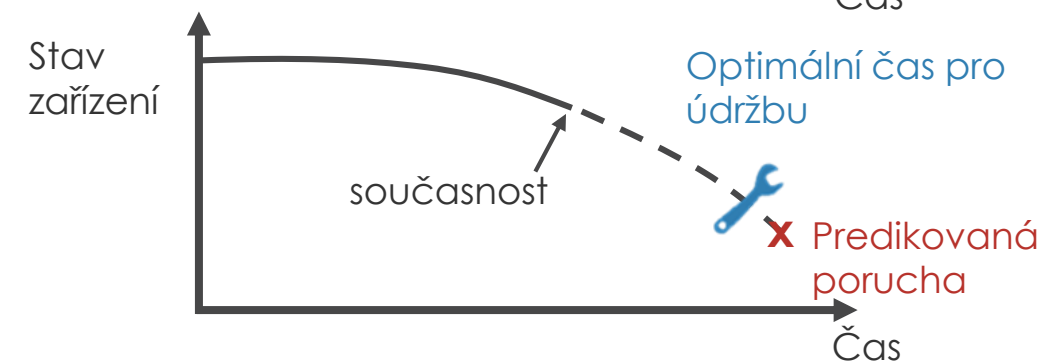

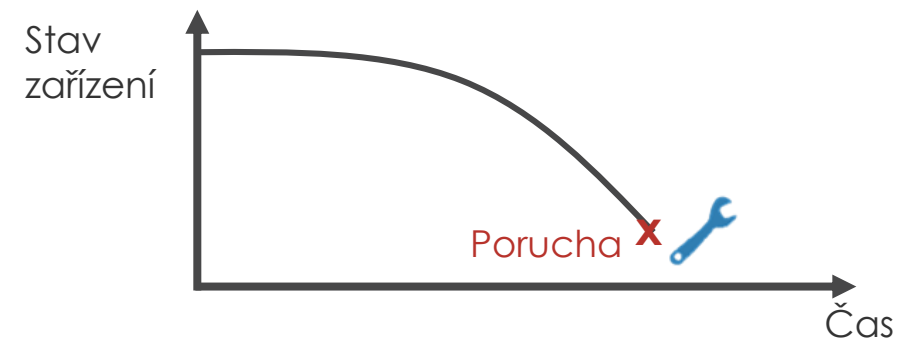
Postup vývoje algoritmů v uvedených aplikacích



PREDIKTIVNÍ ÚDRŽBA

Typy údržby

- **Reaktivní** – údržba při výskytu poruchy
- **Plánovaná** – údržba v pravidelných intervalech
- **Prediktivní** – předpověď, kdy porucha nastane





Co předchází prediktivní údržbě

- Analýza **FMEA** (Failure Mode and Effect Analysis)
- Analýza **MSA** (Measurement System Analysis)
- Plánování experimentu metodou **DoE** (Design of Experiment)

Co je cílem algoritmů pro prediktivní údržbu?

Pomoci přijímat rozhodnutí ohledně údržby na základě velkých objemů komplexních dat






English Spanish French Čerpadlo



Čeština English Greek

Translate



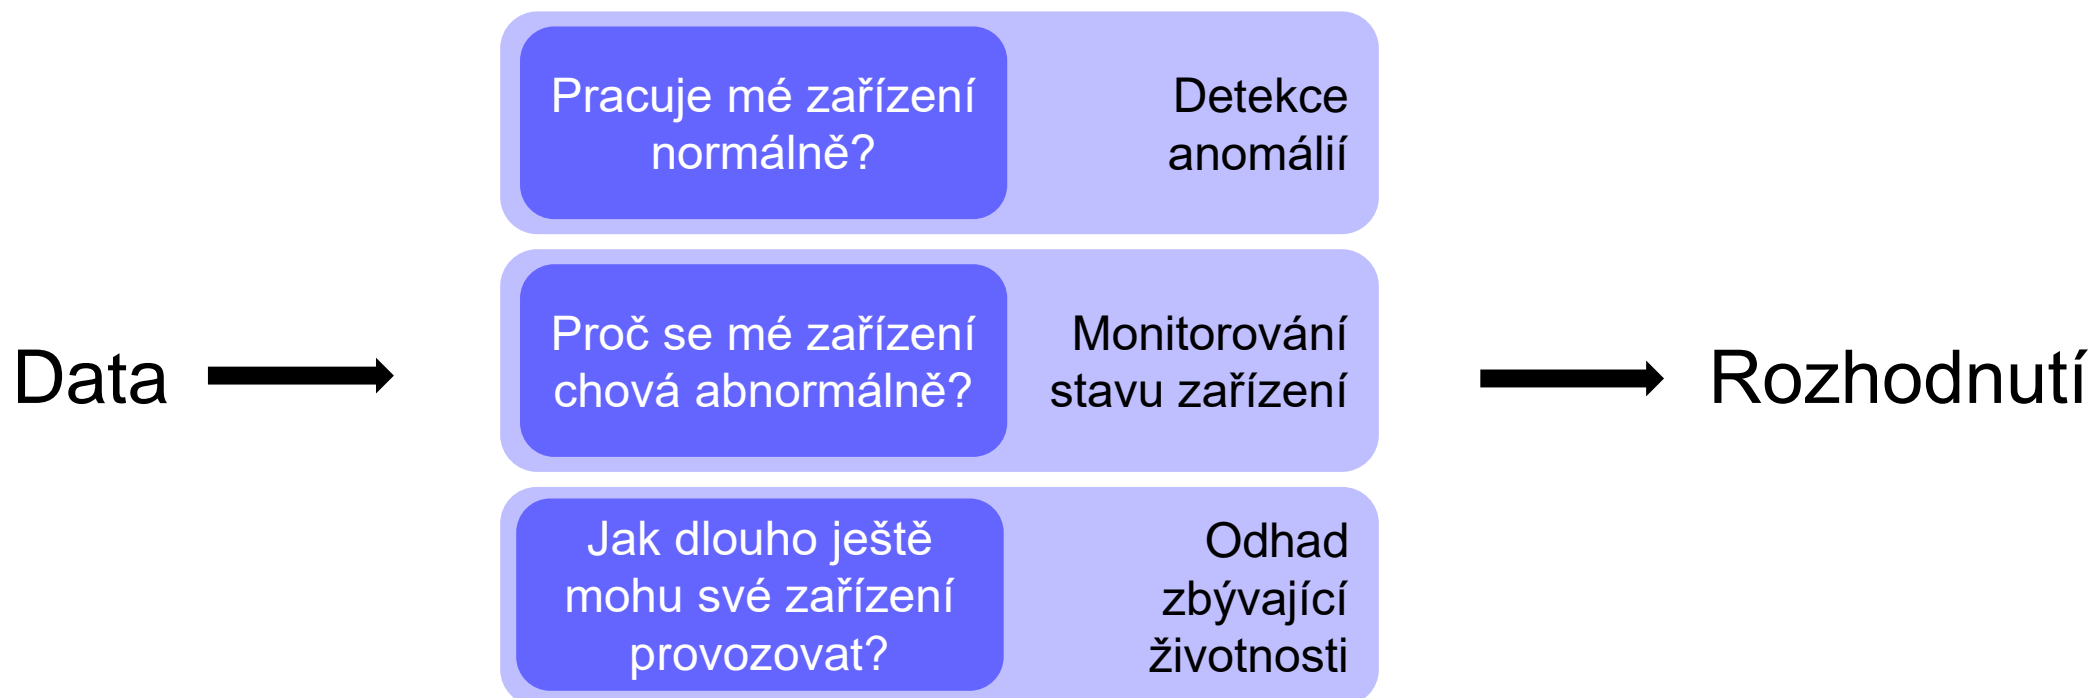
1/5000

Potřebuji pomoc. Jeden z
mých válců je blokováný.
Zastavím vaši výrobní linku
za 15 hodin.

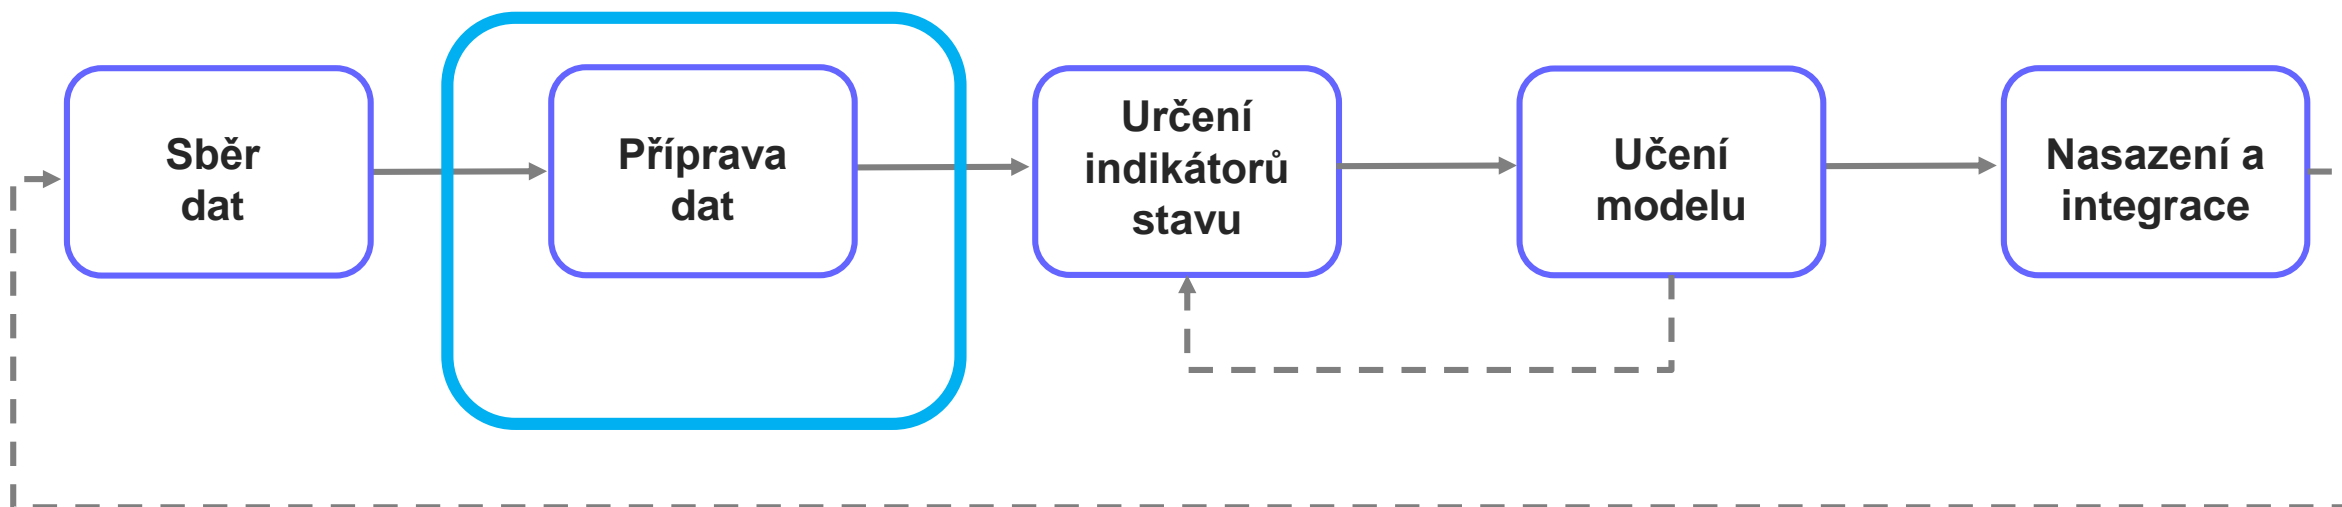
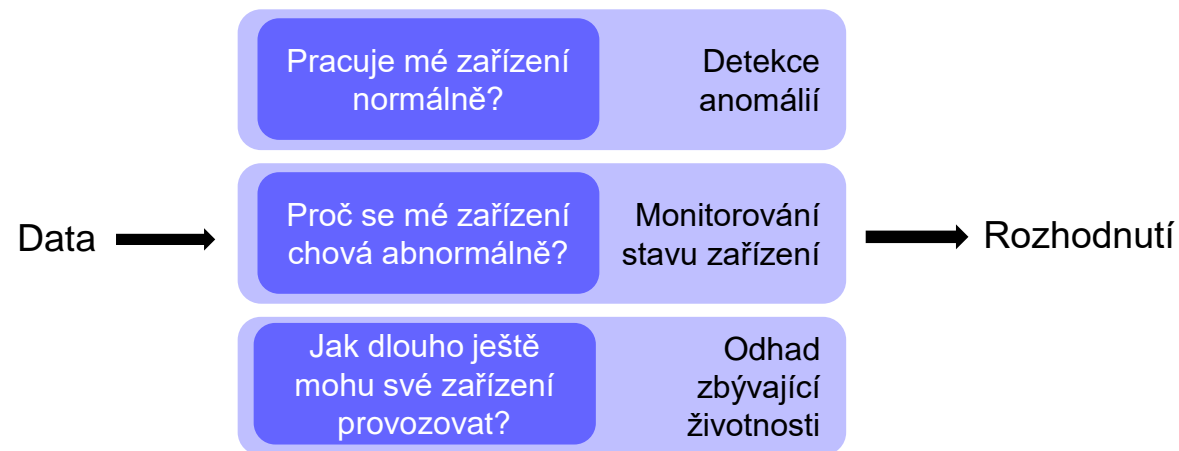


Co je cílem algoritmů pro prediktivní údržbu?

Pomáhá přijímat rozhodnutí o údržbě na základě velkých objemů komplexních dat



Postup vývoje algoritmů pro prediktivní údržbu

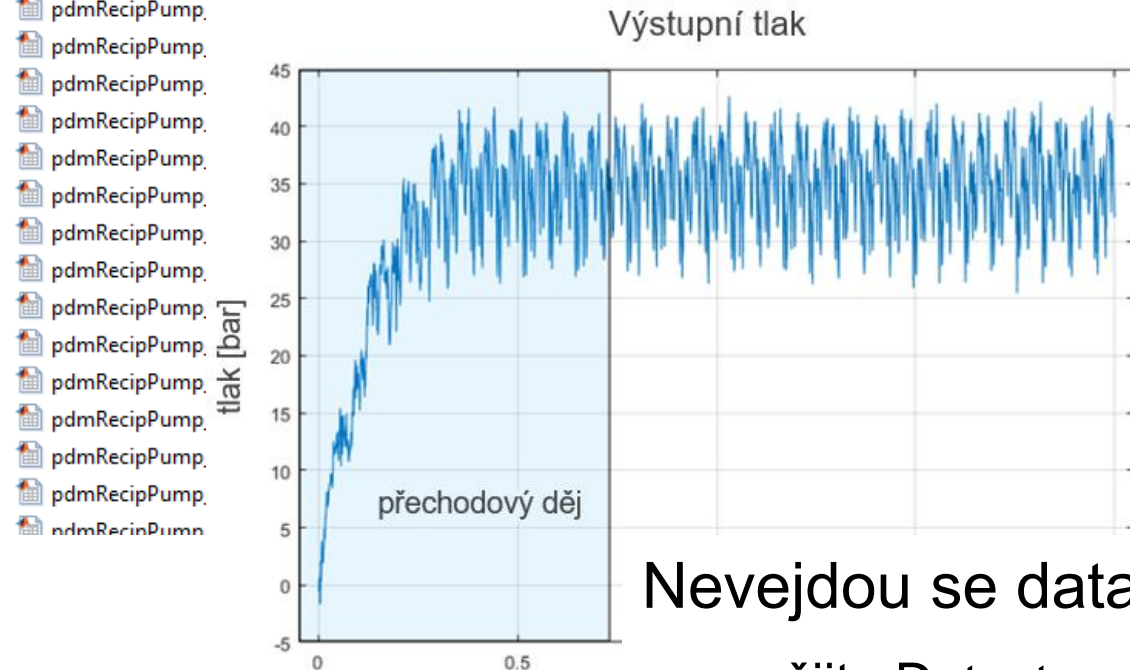


Správa a příprava dat

Home Share View

« PumpMaintenance » Fault_Classification » DataSmall

Name	Status	Date modified	Type	Size
pdmRecipPump_log_1	✔	12/27/2019 10:25 ...	MATLAB Data	1,201 KB
pdmRecipPump_log_2	✔	12/27/2019 10:25 ...	MATLAB Data	1,201 KB
pdmRecipPump_log_3	✔	12/27/2019 10:25 ...	MATLAB Data	1,201 KB
pdmRecipPump_log_4	✔	12/27/2019 10:25 ...	MATLAB Data	1,201 KB
pdmRecipPump_log_5	✔	12/27/2019 10:25 ...	MATLAB Data	1,201 KB



pumpDataInMemory x pumpDataInMemory.flow{1,1} x

240x3 table


	1 flow	2 pressure	3 faultCode
1	1201x1 timetable	1201x1 timetable	0
2	1201x1 timetable	1201x1 timetable	0
3	1201x1 timetable	1201x1 timetable	100
4	1201x1 timetable	12	
5	1201x1 timetable	12	
6	1201x1 timetable	12	
7	1201x1 timetable	12	
8	1201x1 timetable	12	
9	1201x1 timetable	12	
10	1201x1 timetable	12	

	Time	Data
1	0 sec	41.3169
2	0.001 sec	37.0092
3	0.002 sec	35.1916
4	0.003 sec	35.1433
5	0.004 sec	31.4554
6	0.005 sec	32.3917
7	0.006 sec	35.9270
8	0.007 sec	38.7898
9	0.008 sec	40.0606
10	0.009 sec	39.6802


Nevejdou se data do paměti?

- využijte Datastore a Tall Array


Správa a příprava dat




Odstranění trendu



Vyhazení



Transformace



Filtrace

pumpDataInMemory x pumpDataInMemory.flow{1,1} x

240x3 table

	1 flow	2 pressure	3 faultCode
1	1201x1 timetable	1201x1 timetable	0
2	1201x1 timetable	1201x1 timetable	0
3	1201x1 timetable	1201x1 timetable	100
4	1201x1 timetable	1201x1 timetable	1201x1 timetable
5	1201x1 timetable	1201x1 timetable	1201x1 timetable
6	1201x1 timetable	1201x1 timetable	1201x1 timetable
7	1201x1 timetable	1201x1 timetable	1201x1 timetable
8	1201x1 timetable	1201x1 timetable	1201x1 timetable
9	1201x1 timetable	1201x1 timetable	1201x1 timetable
10	1201x1 timetable	1201x1 timetable	1201x1 timetable

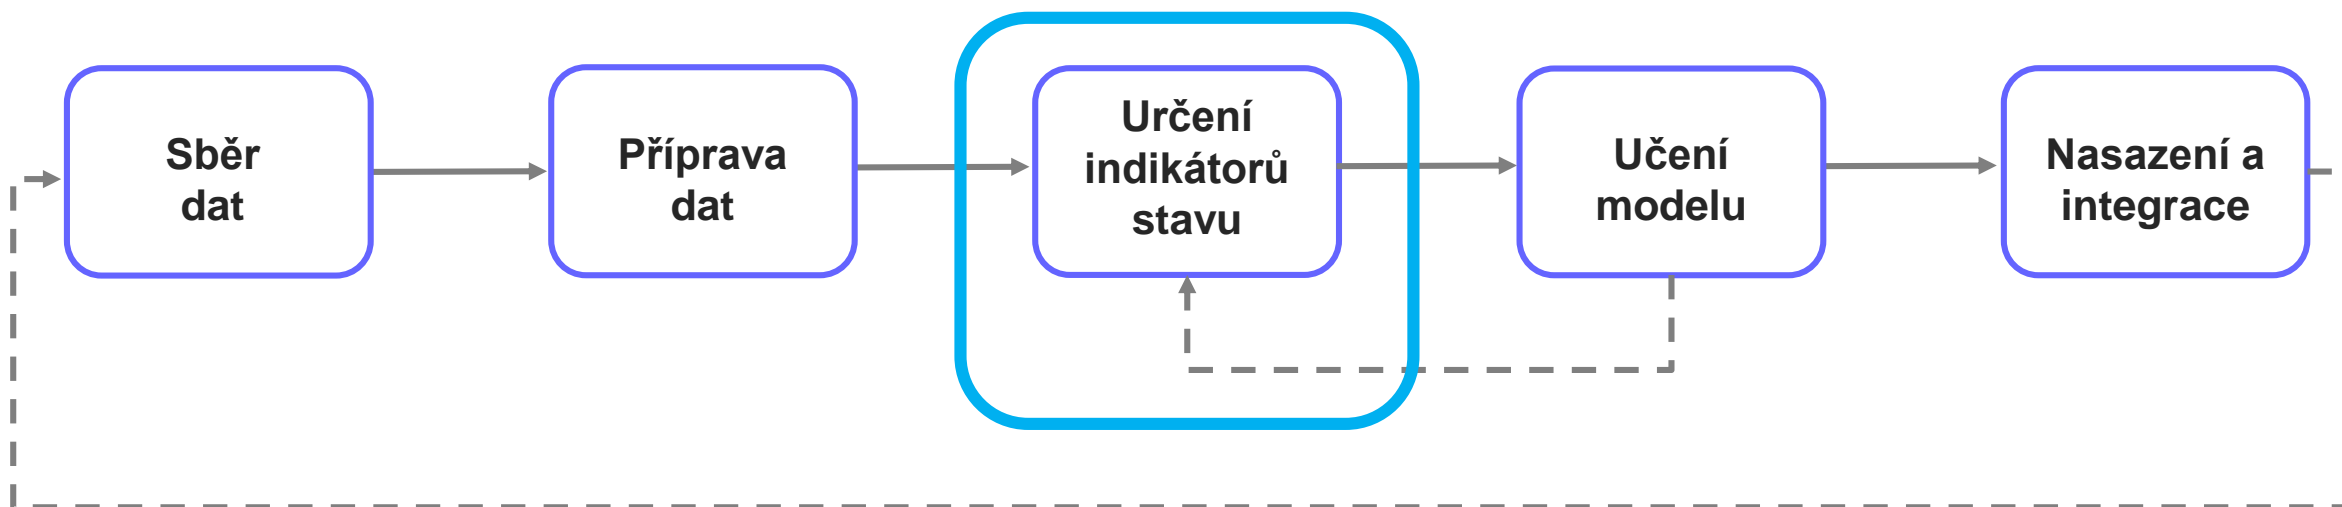
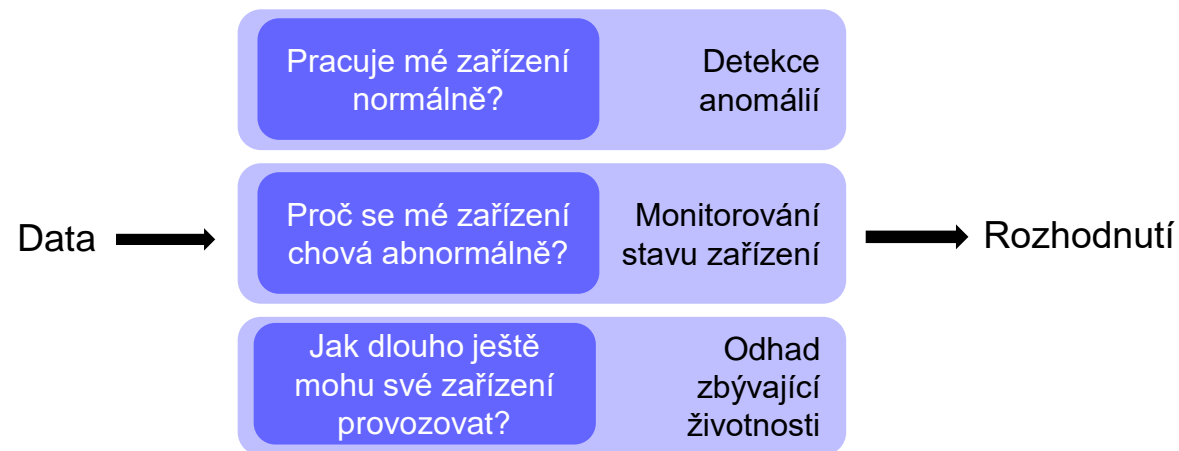
pumpDataInMemory x pumpDataInMemory.flow{1,1} x

pumpDataInMemory.flow{1,1}

	Time	1 Data	2
1	0 sec	41.3169	
2	0.001 sec	37.0092	
3	0.002 sec	35.1916	
4	0.003 sec	35.1433	
5	0.004 sec	31.4554	
6	0.005 sec	32.3917	
7	0.006 sec	35.9270	
8	0.007 sec	38.7898	
9	0.008 sec	40.0606	
10	0.009 sec	39.6803	




Postup vývoje algoritmů pro prediktivní údržbu



Určení indikátorů stavu zařízení

	1 flow	2 pressure	3 faultCode
1	1201x1 timetable	1201x1 timetable	0
2	1201x1 timetable	1201x1 timetable	0
3	1201x1 timetable	1201x1 timetable	100
4	1201x1 timetable	1201x1 timetable	100
5	1201x1 timetable	1201x1 timetable	100
6	1201x1 timetable	1201x1 timetable	100
7	1201x1 timetable	1201x1 timetable	100
8	1201x1 timetable	1201x1 timetable	100
9	1201x1 timetable	1201x1 timetable	100
10	1201x1 timetable	1201x1 timetable	100



- Statistiky o signálu
 - střední hodnota
 - odstup signálu od šumu
 - obsažené frekvence
 - ...



- Fúze a transformace dat
 - analýza hlavních komponent
 - regresní analýza
 - normalizace
 - ...

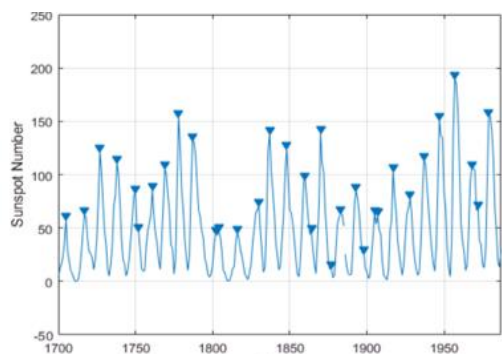
**Indikátory stavu
zařízení
(prediktory)**

Určení indikátorů stavu zařízení

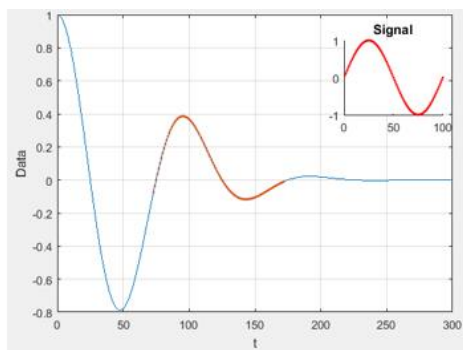
„Feature Engineering“

Časová oblast


Frekvenční oblast




hledání vrcholů



hledání vzorů



měření šířky pásma



spektrální statistiky

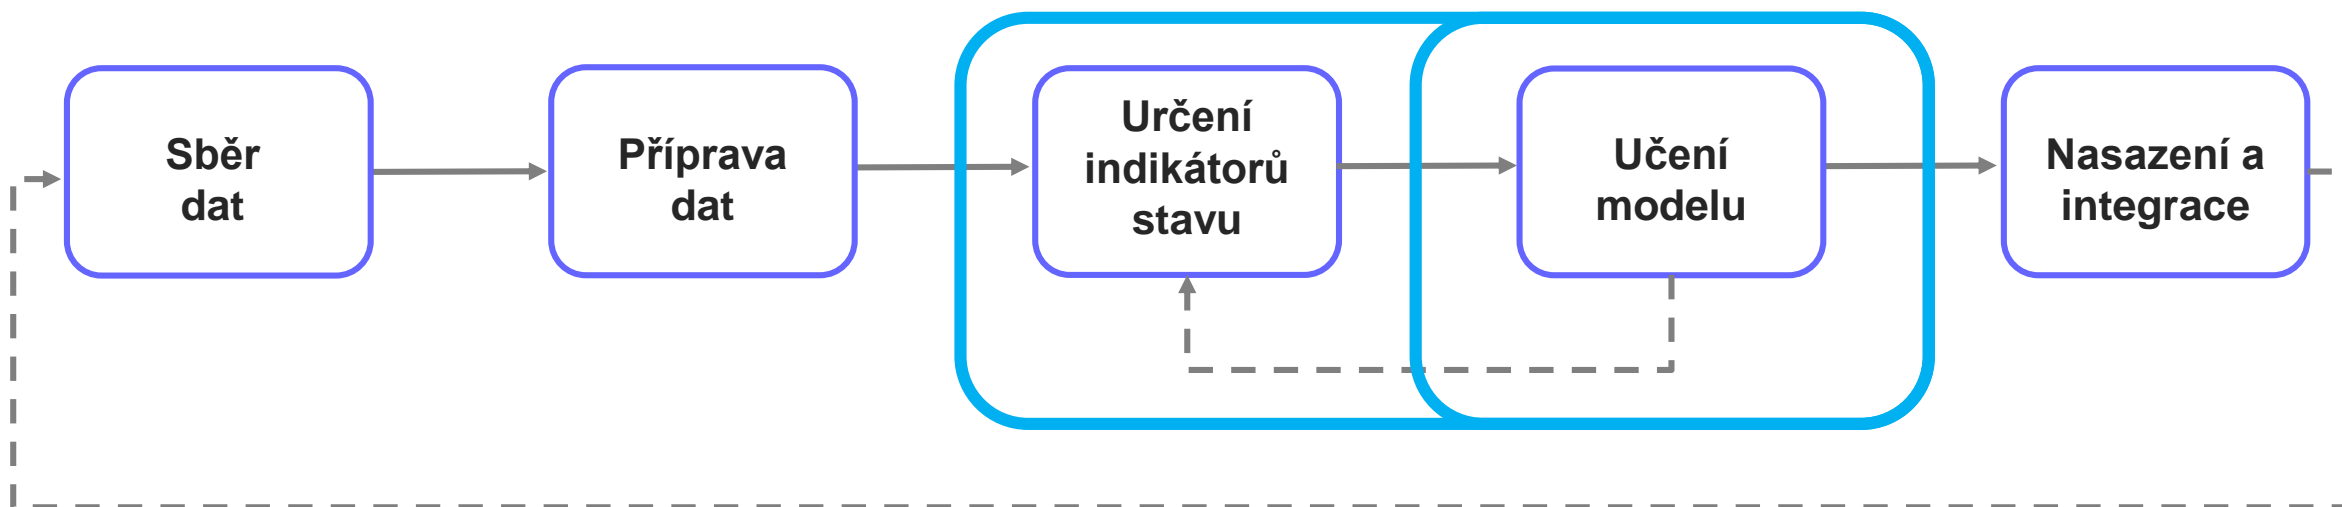
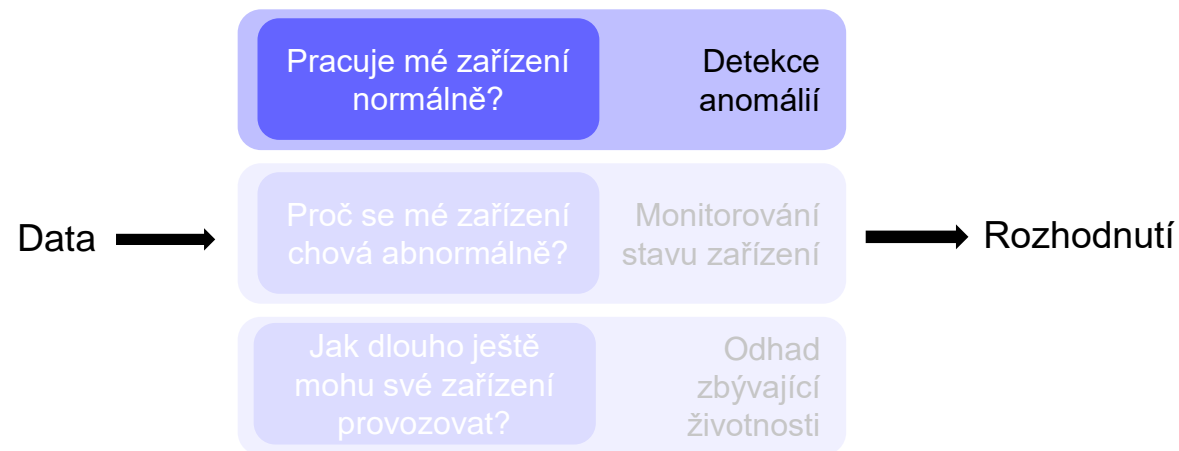
Grafická aplikace Diagnostic Feature Designer

(Predictive Maintenance Toolbox)

- Extrakce, vizualizace a hodnocení příznaků ze snímaných dat
- Využití metod statistického i dynamického modelování
- Pracuje i s daty, která se nevejdou do paměti
- Interaktivní práce bez nutnosti zápisu příkazů a skriptů




Postup vývoje algoritmů pro prediktivní údržbu


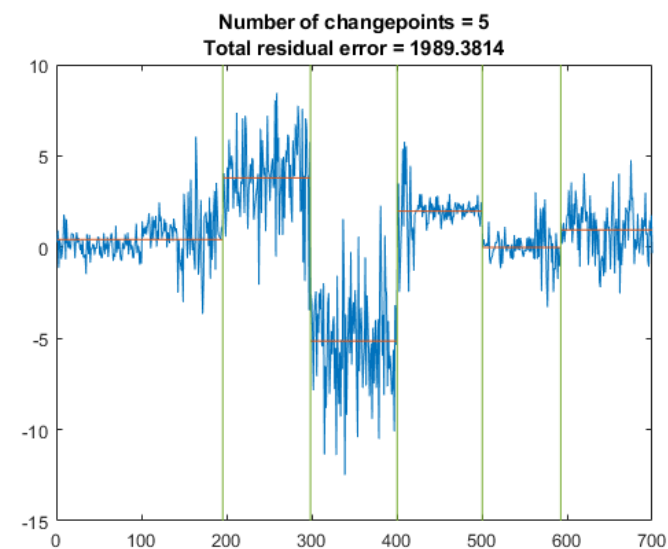


Detekce anomálií – otázky a řešení

- Jsou anomálie rozeznatelné v surových datech?

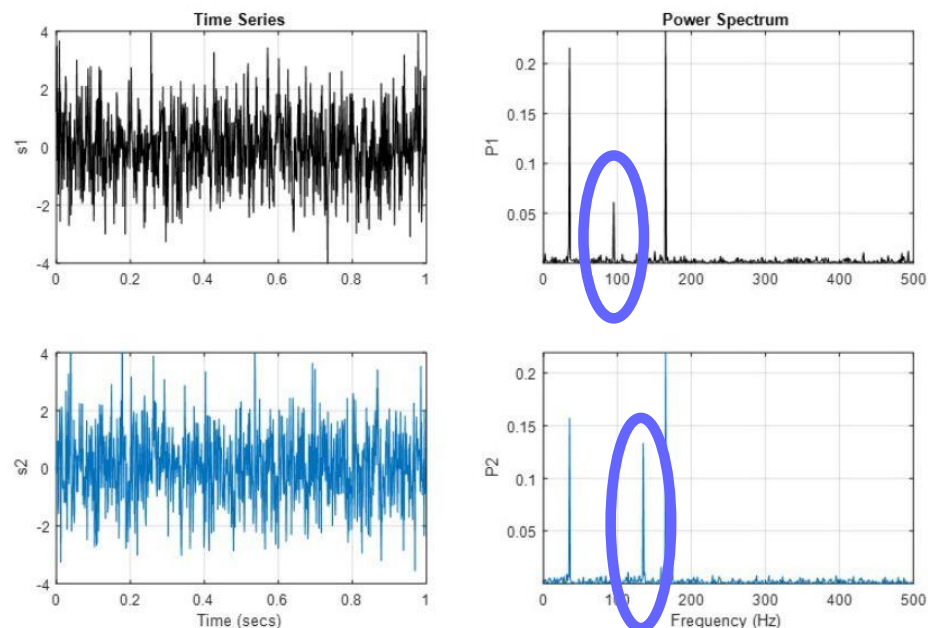


- Může postačovat jednoduchý algoritmus, např.:
 - detekce náhlých změn v signálu (`findchangepts`)
 - regulační diagram (`controlchart`)
 - . . .



Detekce anomálií – otázky a řešení

- Jsou anomálie rozeznatelné odvozených proměnných?

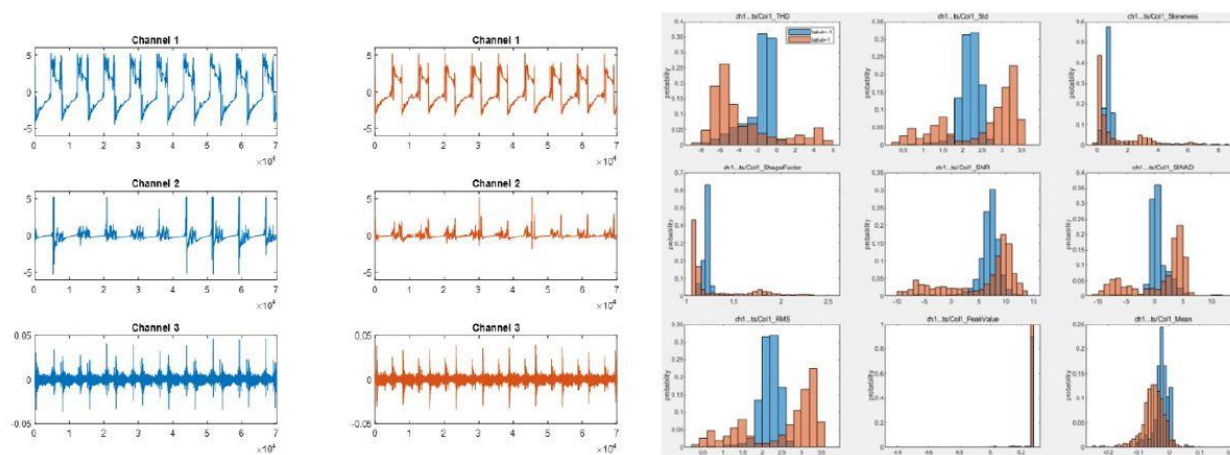


– např. frekvenční transformace

- Použít odvozené proměnné jako prediktory pro klasifikační algoritmy
 - označená data z normálního i abnormálního provozu + machine learning / deep learning

Detekce anomálií – otázky a řešení

- **Je možné statisticky separovat data z normálního provozu od anomálií?**
 - anomálie nemusí být rozeznatelné z jediného signálu




- Anomálie mohou být rozeznatelné v kombinaci několika signálů
 - výpočet nových proměnných odvozených z několika měřených signálů
 - označená data z normálního i abnormálního provozu
 - použít odvozené proměnné jako prediktory pro klasifikační algoritmy (ML / DL)

Detekce anomálií – otázky a řešení

- **Co když nevíme, jak anomálie vypadají?**
 - k poruchám a anomáliím dochází v nákladných provozech zřídka
 - údajů o anomáliích je málo nebo nejsou k dispozici vůbec
- Lze využít metody pro „pouze normální“ data
 - **Prahování**
 - **One-Class Support Vector Machine**
 - **Isolation Forest**
 - **Autoencoder**


Detekce anomálií – metody pro pouze normální data

- **Prahování**
- Identifikuje anomálii když data překročí zvolený práh na statistické metrice
 - směrodatná odchylka v datových oknech z časové řady
 - regulační diagram signálu
 - detekce náhlých změn
 - robustní odhad pravděpodobnostního rozdělení (anomálie je vzorek na okraji)



Detekce anomálií – metody pro pouze normální data

- **One-Class Support Vector Machine**
- Klasifikační algoritmus SVM trénovaný jen na normálních datech se chová jako model normálního chování
- Sleduje se výstupní metrika (score) přiřazení vzorku této třídě
 - klasifikace se vzorkem z normálního chování má vysokou hodnotu score
 - klasifikace se vzorkem z abnormálního chování má nízkou hodnotu score




Detekce anomálií – metody pro pouze normální data

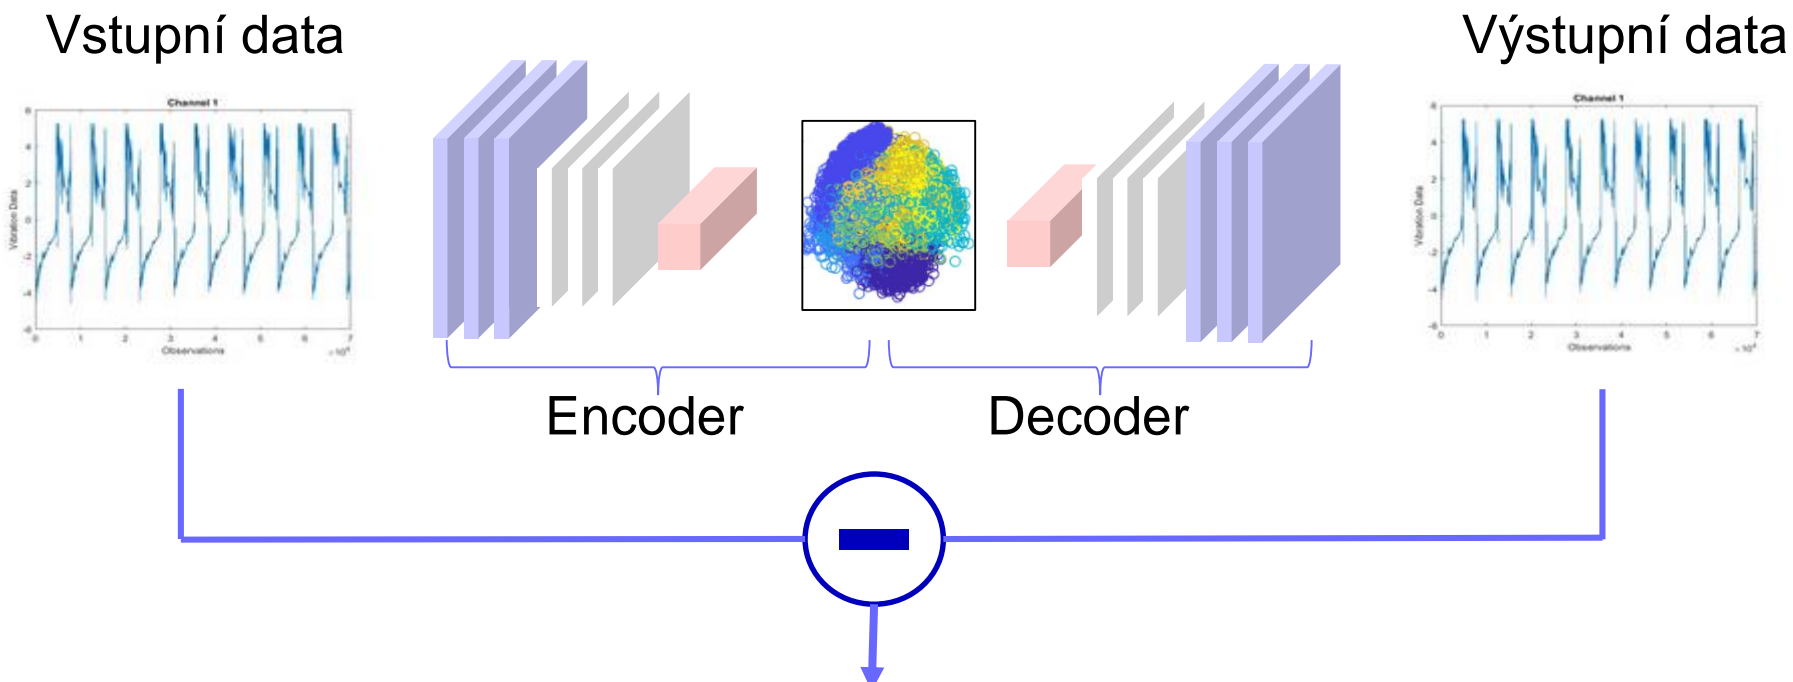
- **Isolation Forest**
- Algoritmus Isolation Forest izoluje každé pozorování až do úrovně listu
- Měřítko anomálie je průměrná hloubka vzorku
 - počet rozhodování při průchodu vzorku stromem
- Normální vzorky prochází méně rozhodnutími než anomální

Detekce anomálií – metody pro pouze normální data

- **Autoencoder**
- Hluboká neuronová síť složená ze 2 částí: encoder a decoder
- Učení pouze s normálními daty, kdy je cílem rekonstruovat vstupní data
 - normální data rekonstruována věrně
 - velká odchylka v rekonstrukci indikuje anomálii




Detekce anomálií – nasazení autoencoderu




Normální data

- rekonstruována korektně
- rozdíl jde k nule



Odchylka


Detekce anomálií – nasazení autoencoderu



Abnormální data


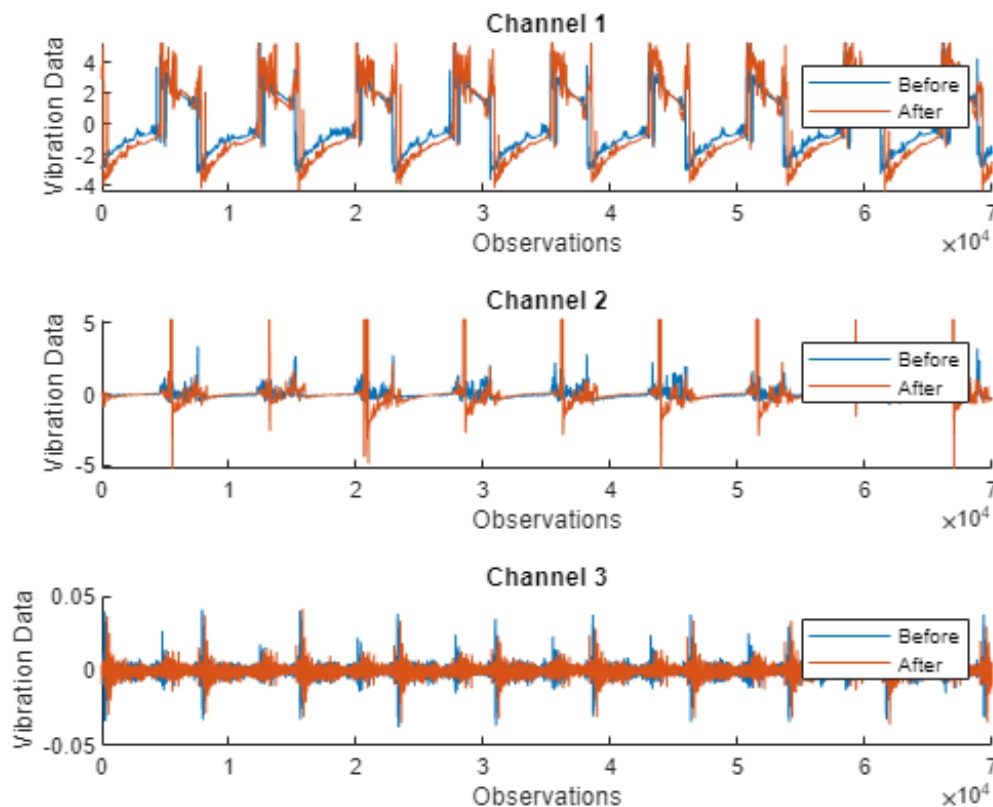
→ rekonstrukce není korektní

→ rozdíl je nenulový



Odchylka

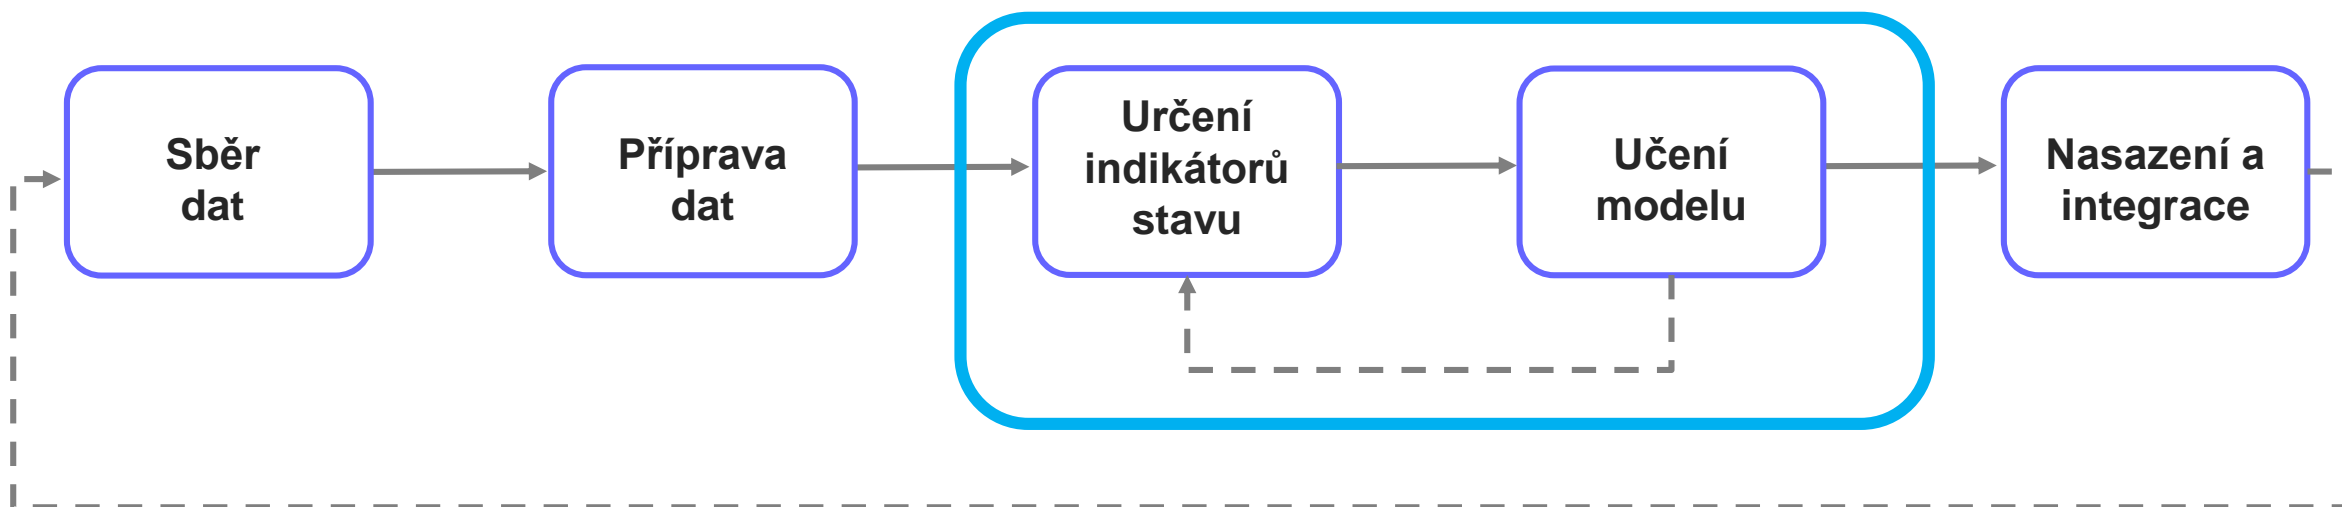
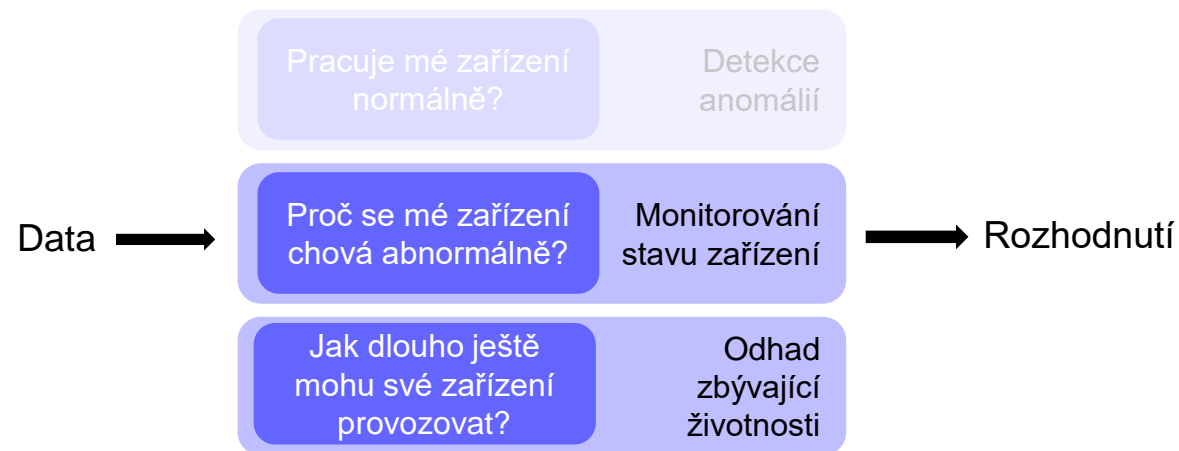
Příklad: Detekce anomálií pomocí analýzy vibrací




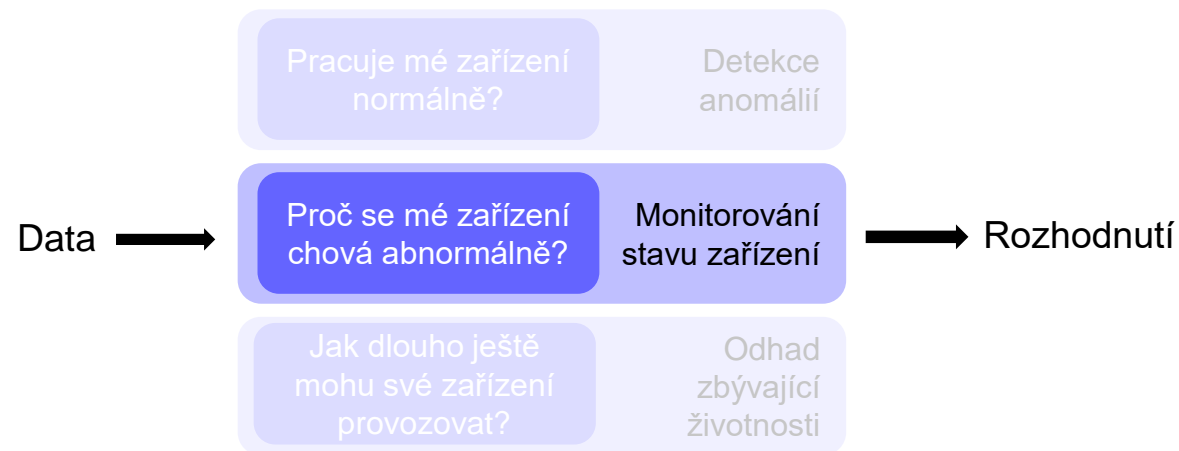
Detekce anomálií – souhrn

- Detekce anomálií pomáhá detekovat
 - odlehlé hodnoty
 - odchylky od normálního chování
 - neočekávané chování
- Před detekcí anomálií je často třeba extrahovat z dat prediktory
- Pokud je k dispozici dostatečné množství označených dat včetně anomálií
 - lze využít supervised learning
- Pokud jsou k dispozici převážně jen data z normálního provozu
 - je vhodná aplikace jedné ze specializovaných technik pro pouze normální data



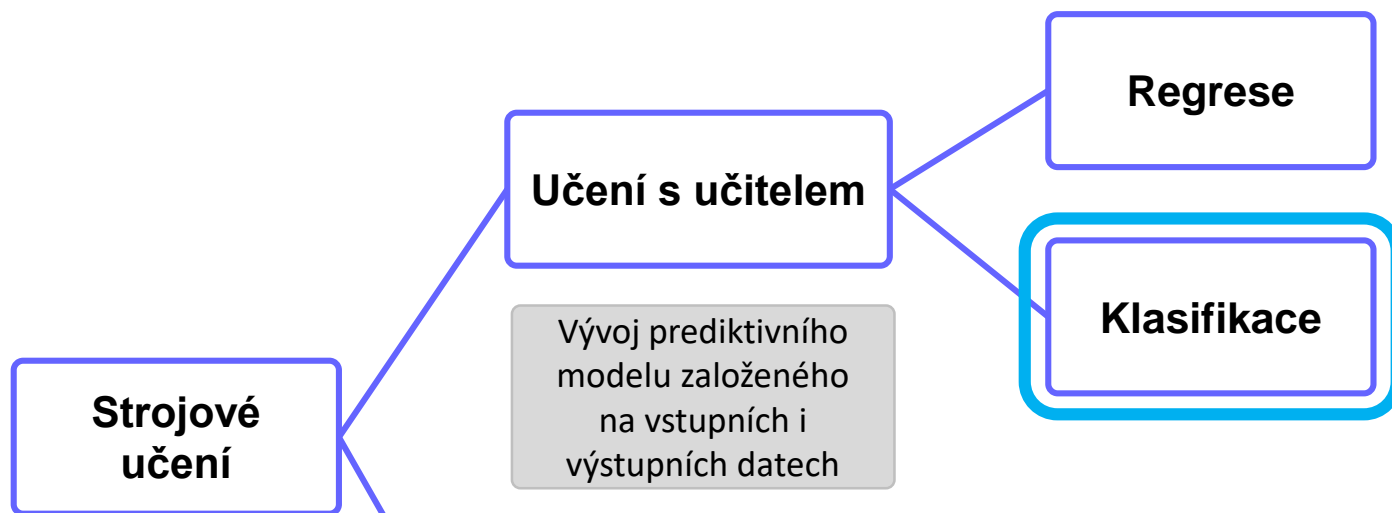
Postup vývoje algoritmů pro prediktivní údržbu



Scénář 1: Klasifikace poruchových stavů



Klasifikace poruchových stavů s využitím strojového učení (AI)






3 cesty k vytvoření AI modelu v prostředí MATLAB

```
inputSize = 12;
numHiddenUnits = 100;
numClasses = 9;

layers = [ ...
    sequenceInputLayer(inputSize)
    biLstmLayer(numHiddenUnits,'OutputMode','last')
    fullyConnectedLayer(numClasses)
    softmaxLayer
    classificationLayer]
```

fitcauto / fitrauto



Funkce, psaní skriptů

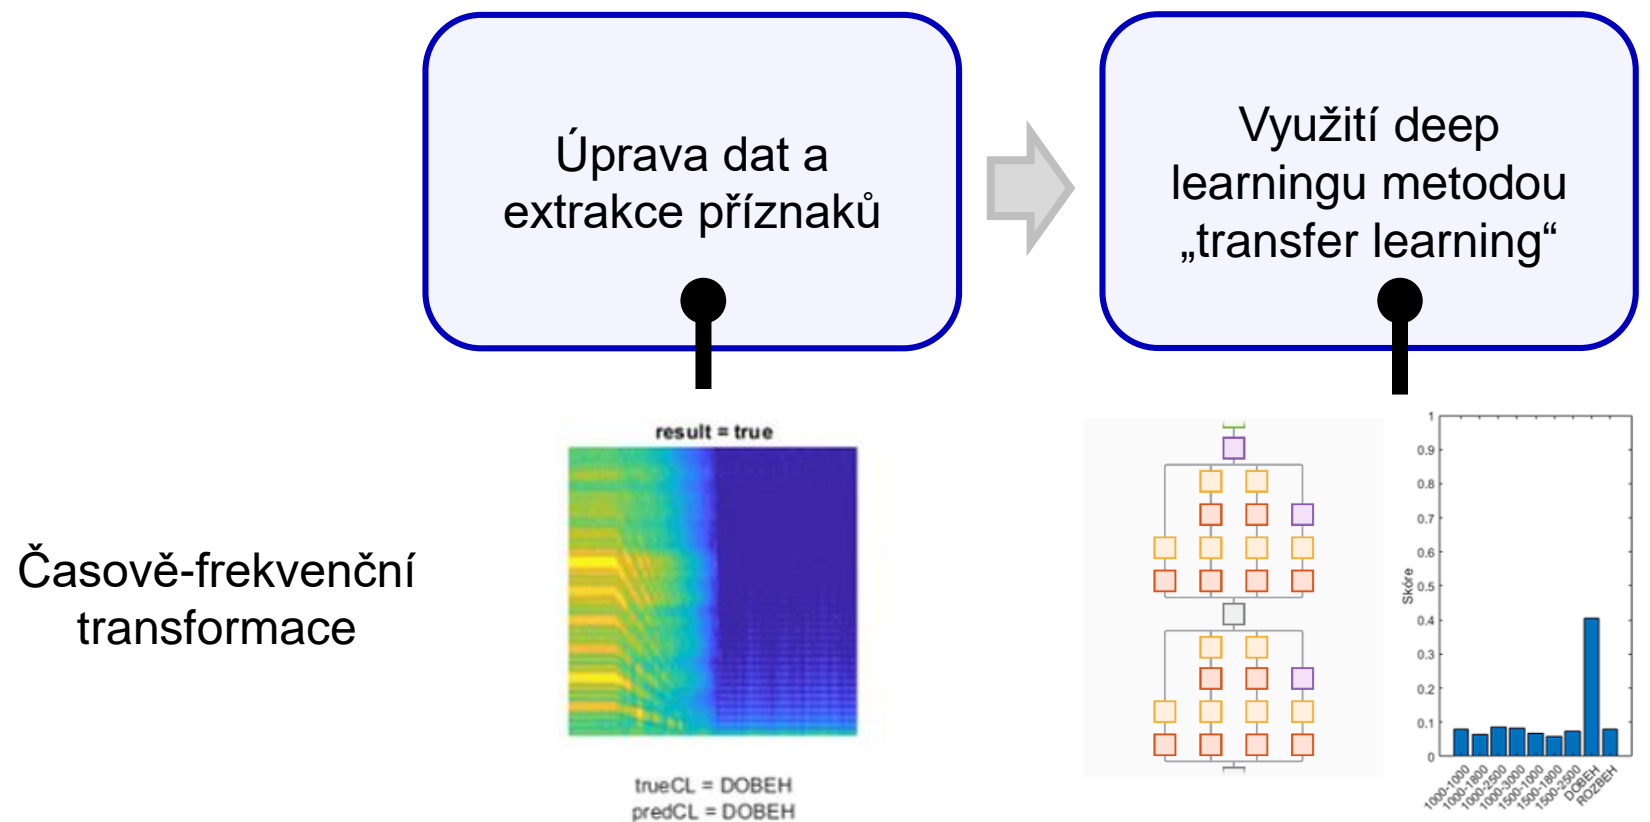
Interaktivní návrh
prostřednictvím
grafických aplikací

Transfer learning
s existujícími modely


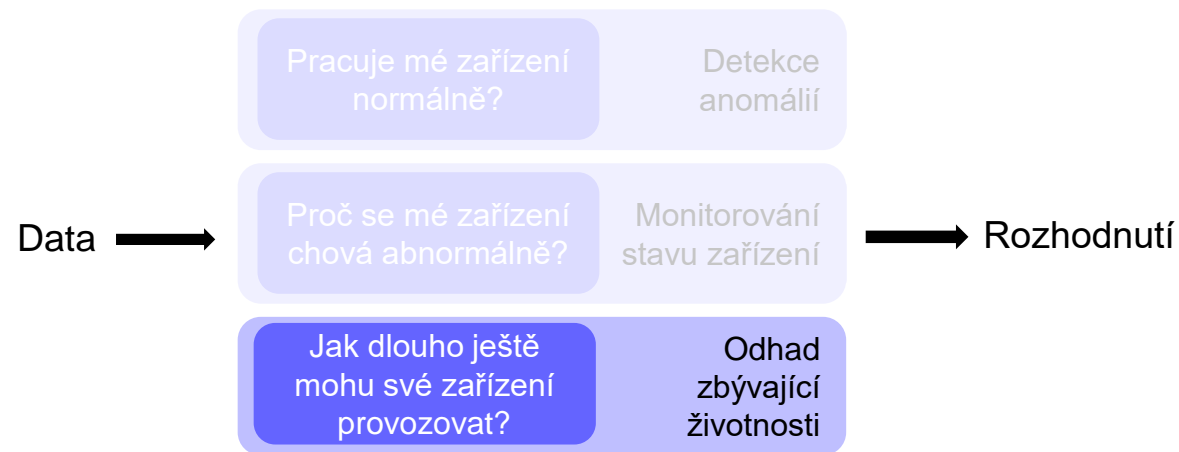
Příklad: Umělá inteligence pro on-line vibrodiagnostiku

- Wikov MGI, Jan KŘEPELA


– <https://www.humusoft.cz/blog/20210826-umela-intelligence-pro-vibrodiagnostiku/>



Scénář 2: Předpověď zbyvající životnosti zařízení (RUL)



Co je zbývající životnost zařízení (RUL)?



Metody výpočtu RUL a kdy je použít

Požadavek: je třeba vědět, co tvoří data o poruchách

Data ze zařízení



N: Normální stav

F: Porucha

Model odhadu RUL

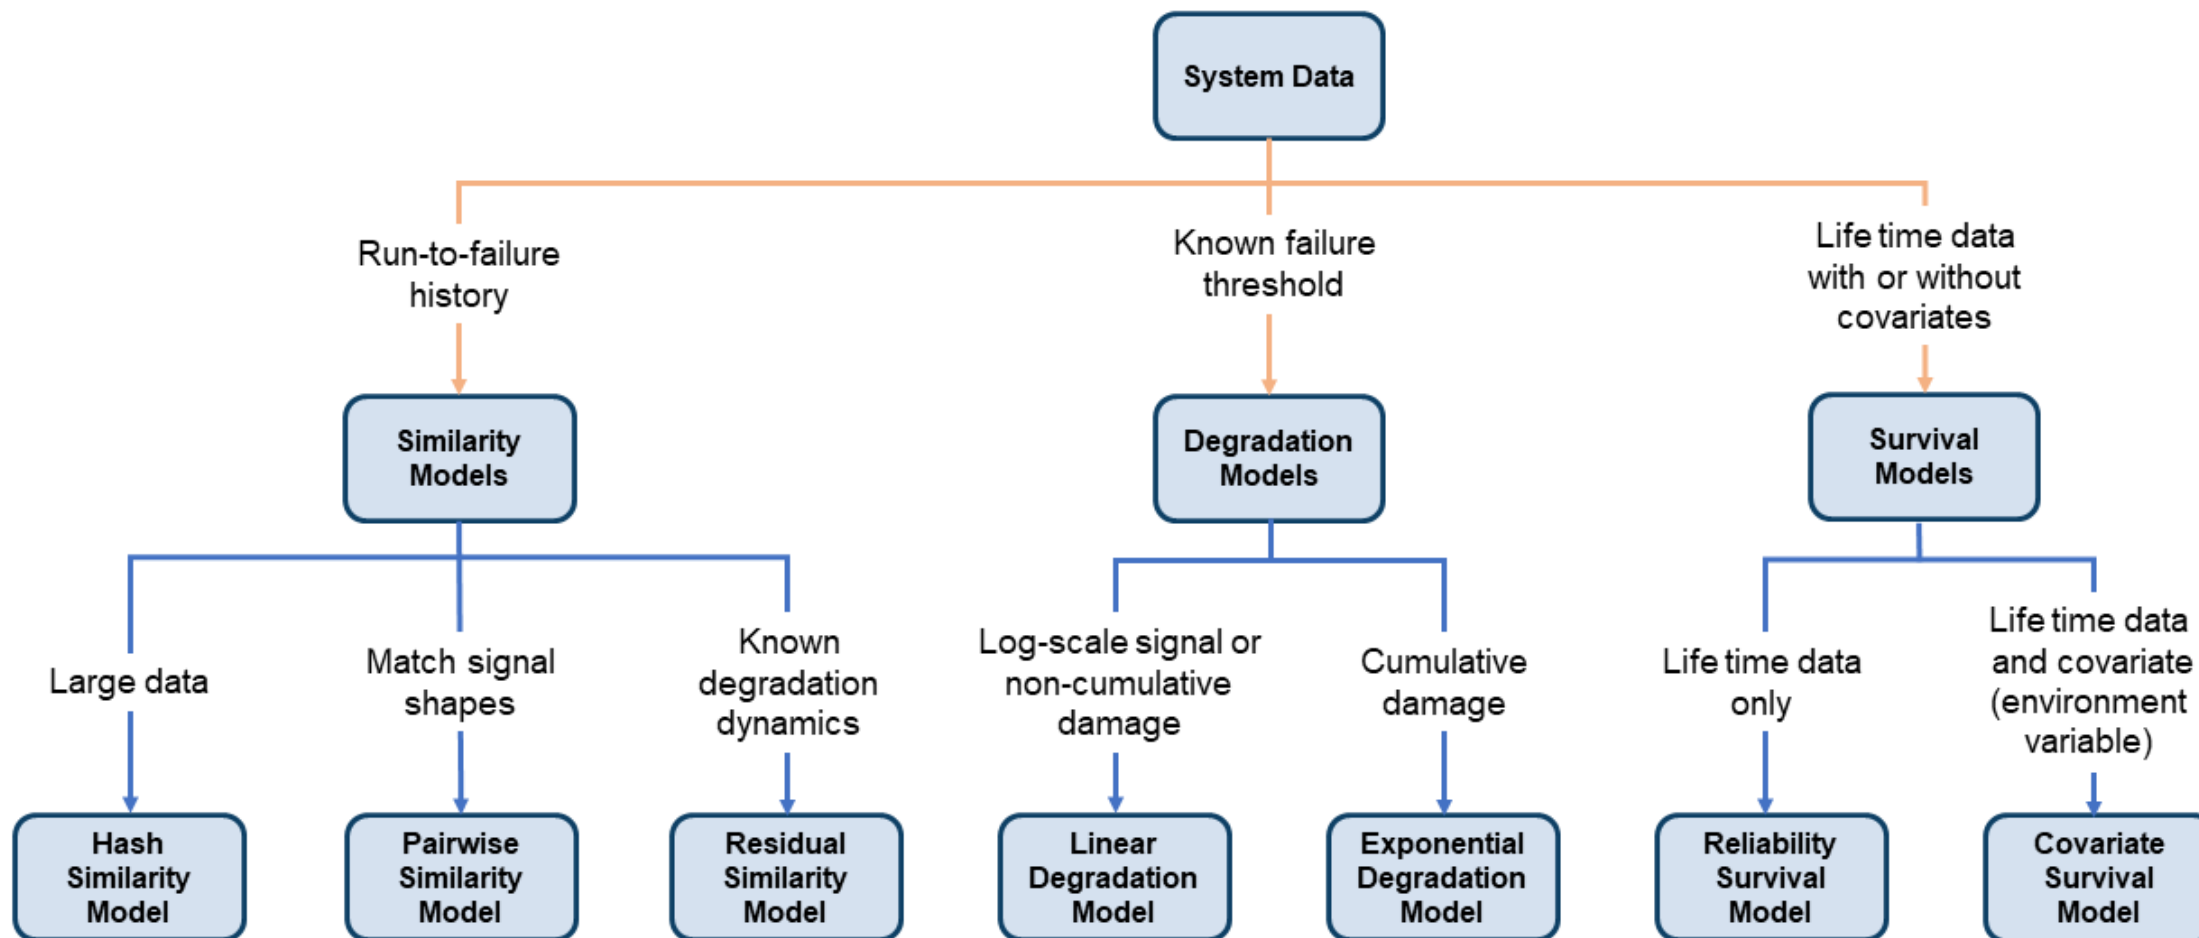
Modely podobnosti (similarity models)

Degradační modely (degradation models)

Modely přežití (survival models)

Metody výpočtu RUL a kdy je použít

Požadavek: je třeba vědět, co tvoří data o poruchách



Metody výpočtu RUL a kdy je použít

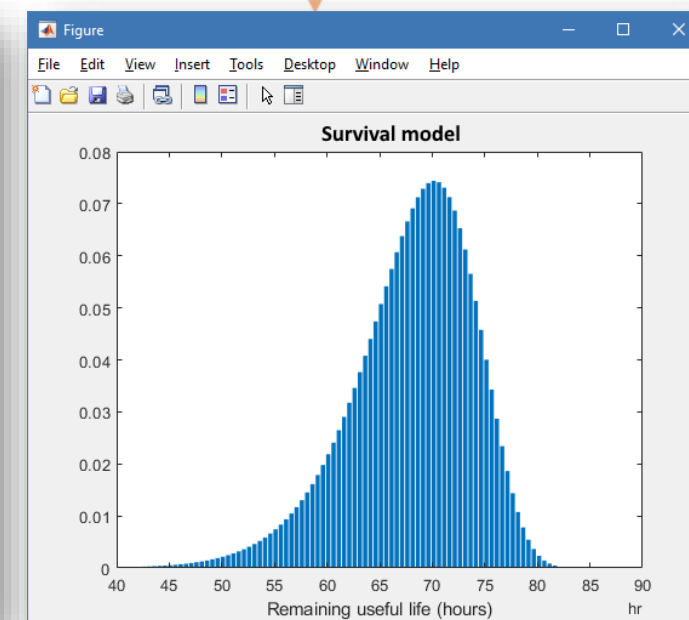

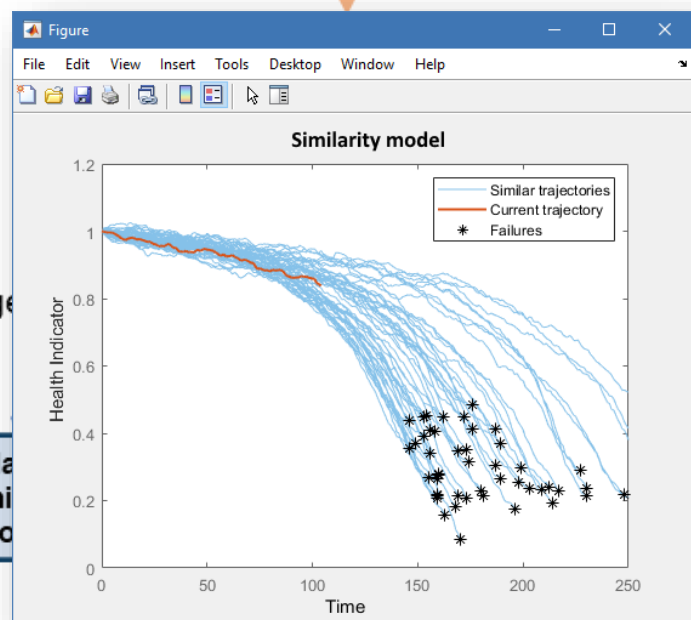
Požadavek: je třeba vědět, co tvoří data o poruchách

System Data

Run-to-failure history

Known failure threshold

Life time data with or without covariates



Large


own
ation
tics

Ha
Simi
Mo

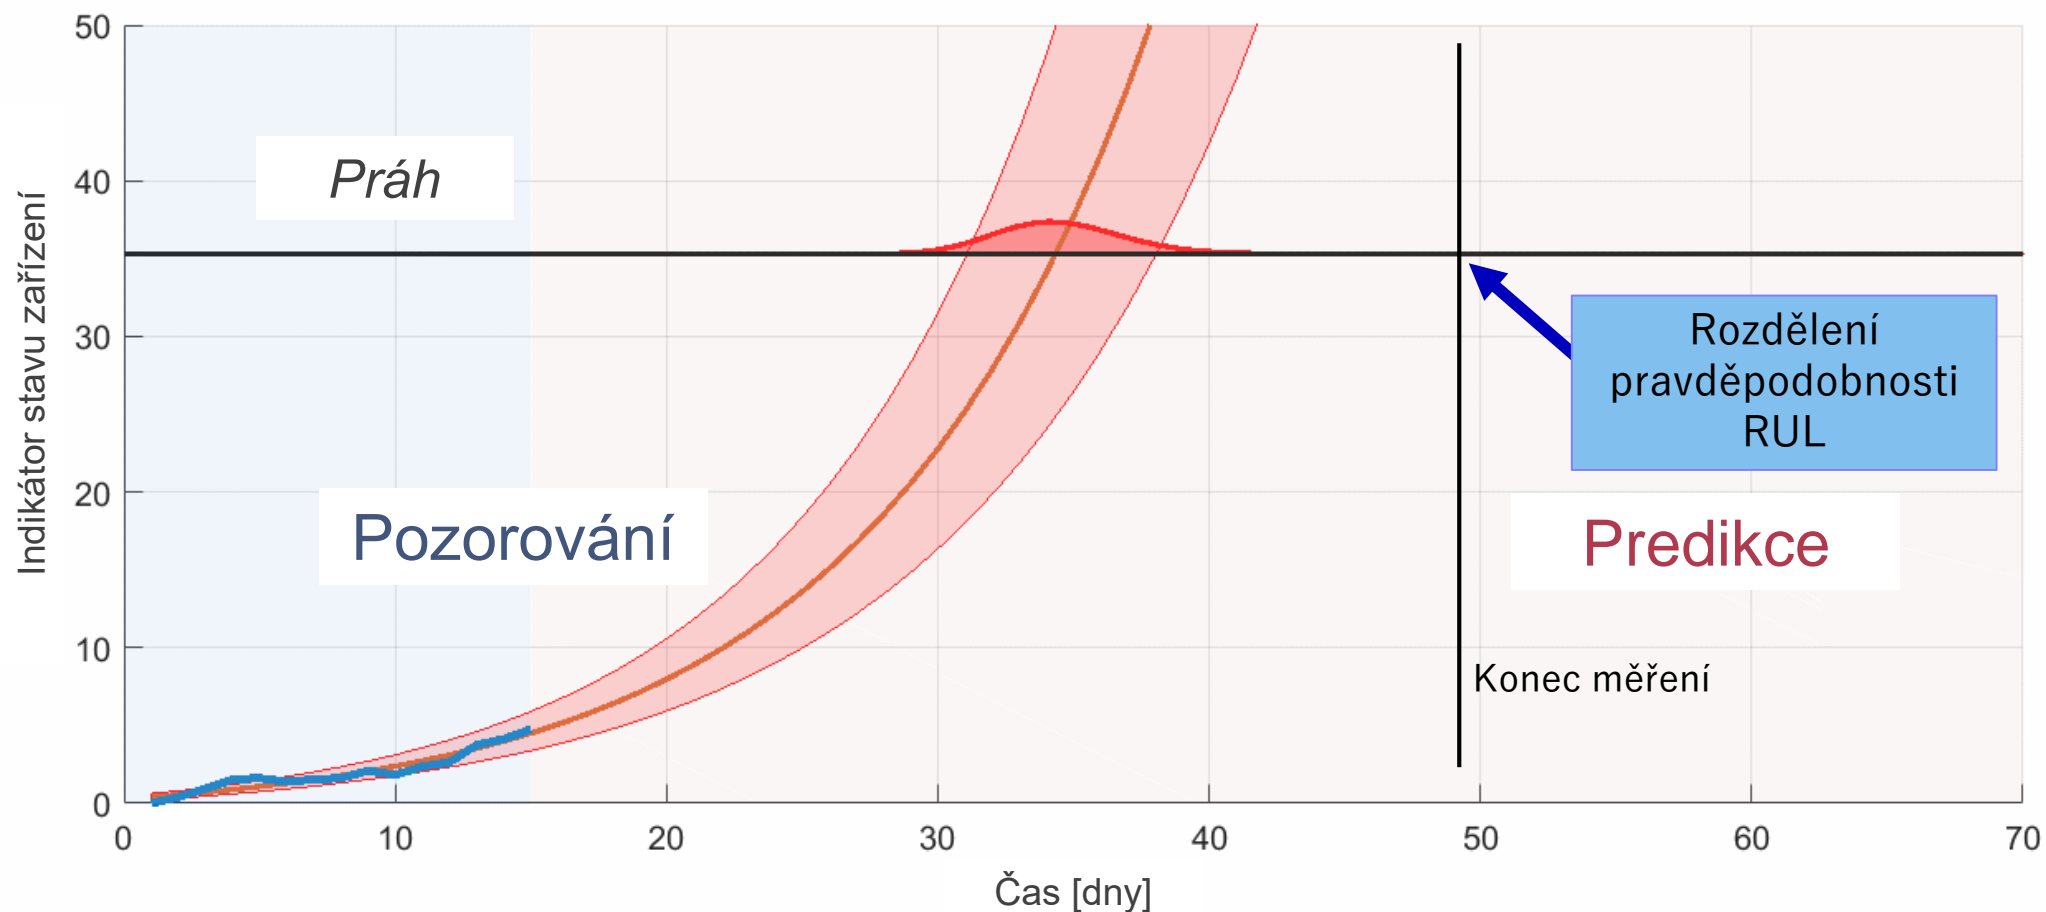
ual
rity
el

Odhad zbývající životnosti zařízení(RUL)

Slouží k určení, kdy je třeba provést údržbu




RUL: 459 hours
(95%CI: 374-558 hours)




Příklad: Analýza spolehlivosti a poruch v praxi

- Siemens, *Petr Semotam*
 - Analýza spolehlivosti a poruch v praxi
 - <https://www.linkedin.com/pulse/analýza-spolehlivosti-poruch-v-praxi-matlab-petr-semotam>
 - Analýza vibračního signálu v praxi
 - <https://www.linkedin.com/pulse/analýza-vibračního-signálu-v-praxi-matlab-petr-semotam>



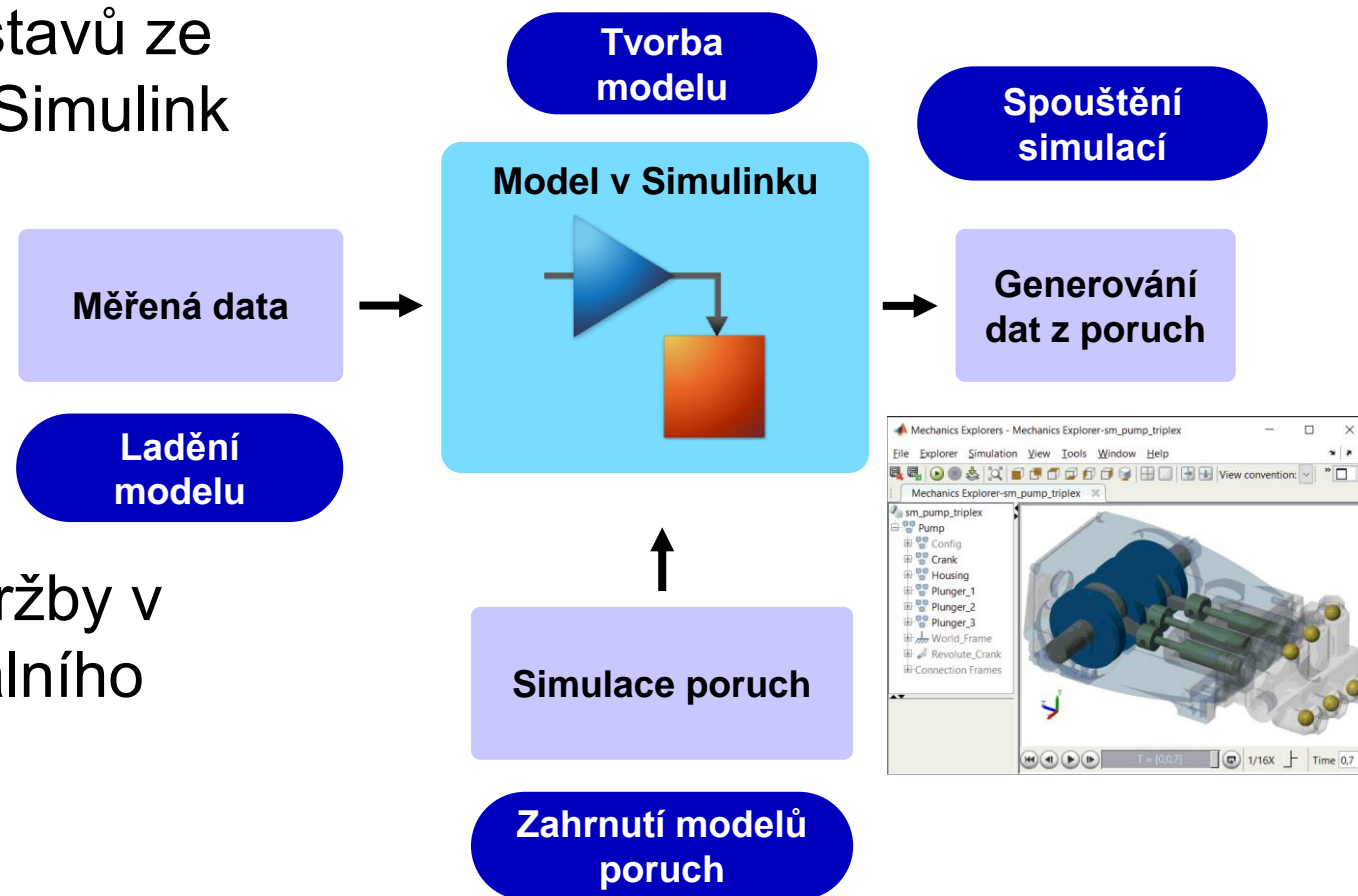
Nasazení modelů



Co když jsou k dispozici detailní znalosti o vašem zařízení?

Využijte technické znalosti ke zlepšení prediktivní údržby

- Generování dat z poruchových stavů ze simulačních modelů v prostředí Simulink
- Identifikace příčin poruchy pomocí odhadu parametrů
- Ověření algoritmů prediktivní údržby v nových situacích s pomocí digitálního dvojčete reálného zařízení





VIZUÁLNÍ INSPEKCE

Vizuální inspekce

- Kontrola dílů na základě obrazových dat
- Kamera skenuje testovaný díl a detekuje závady a nedostatky v kvalitě


⇒ detekce anomálií

⇒ klasifikace vad




Uživatelské reference

AIRBUS



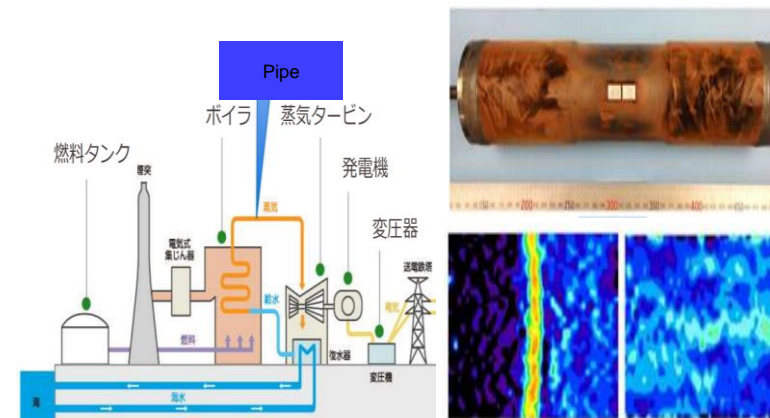
Automatická detekce defektů



Vizuální inspekce autodílů

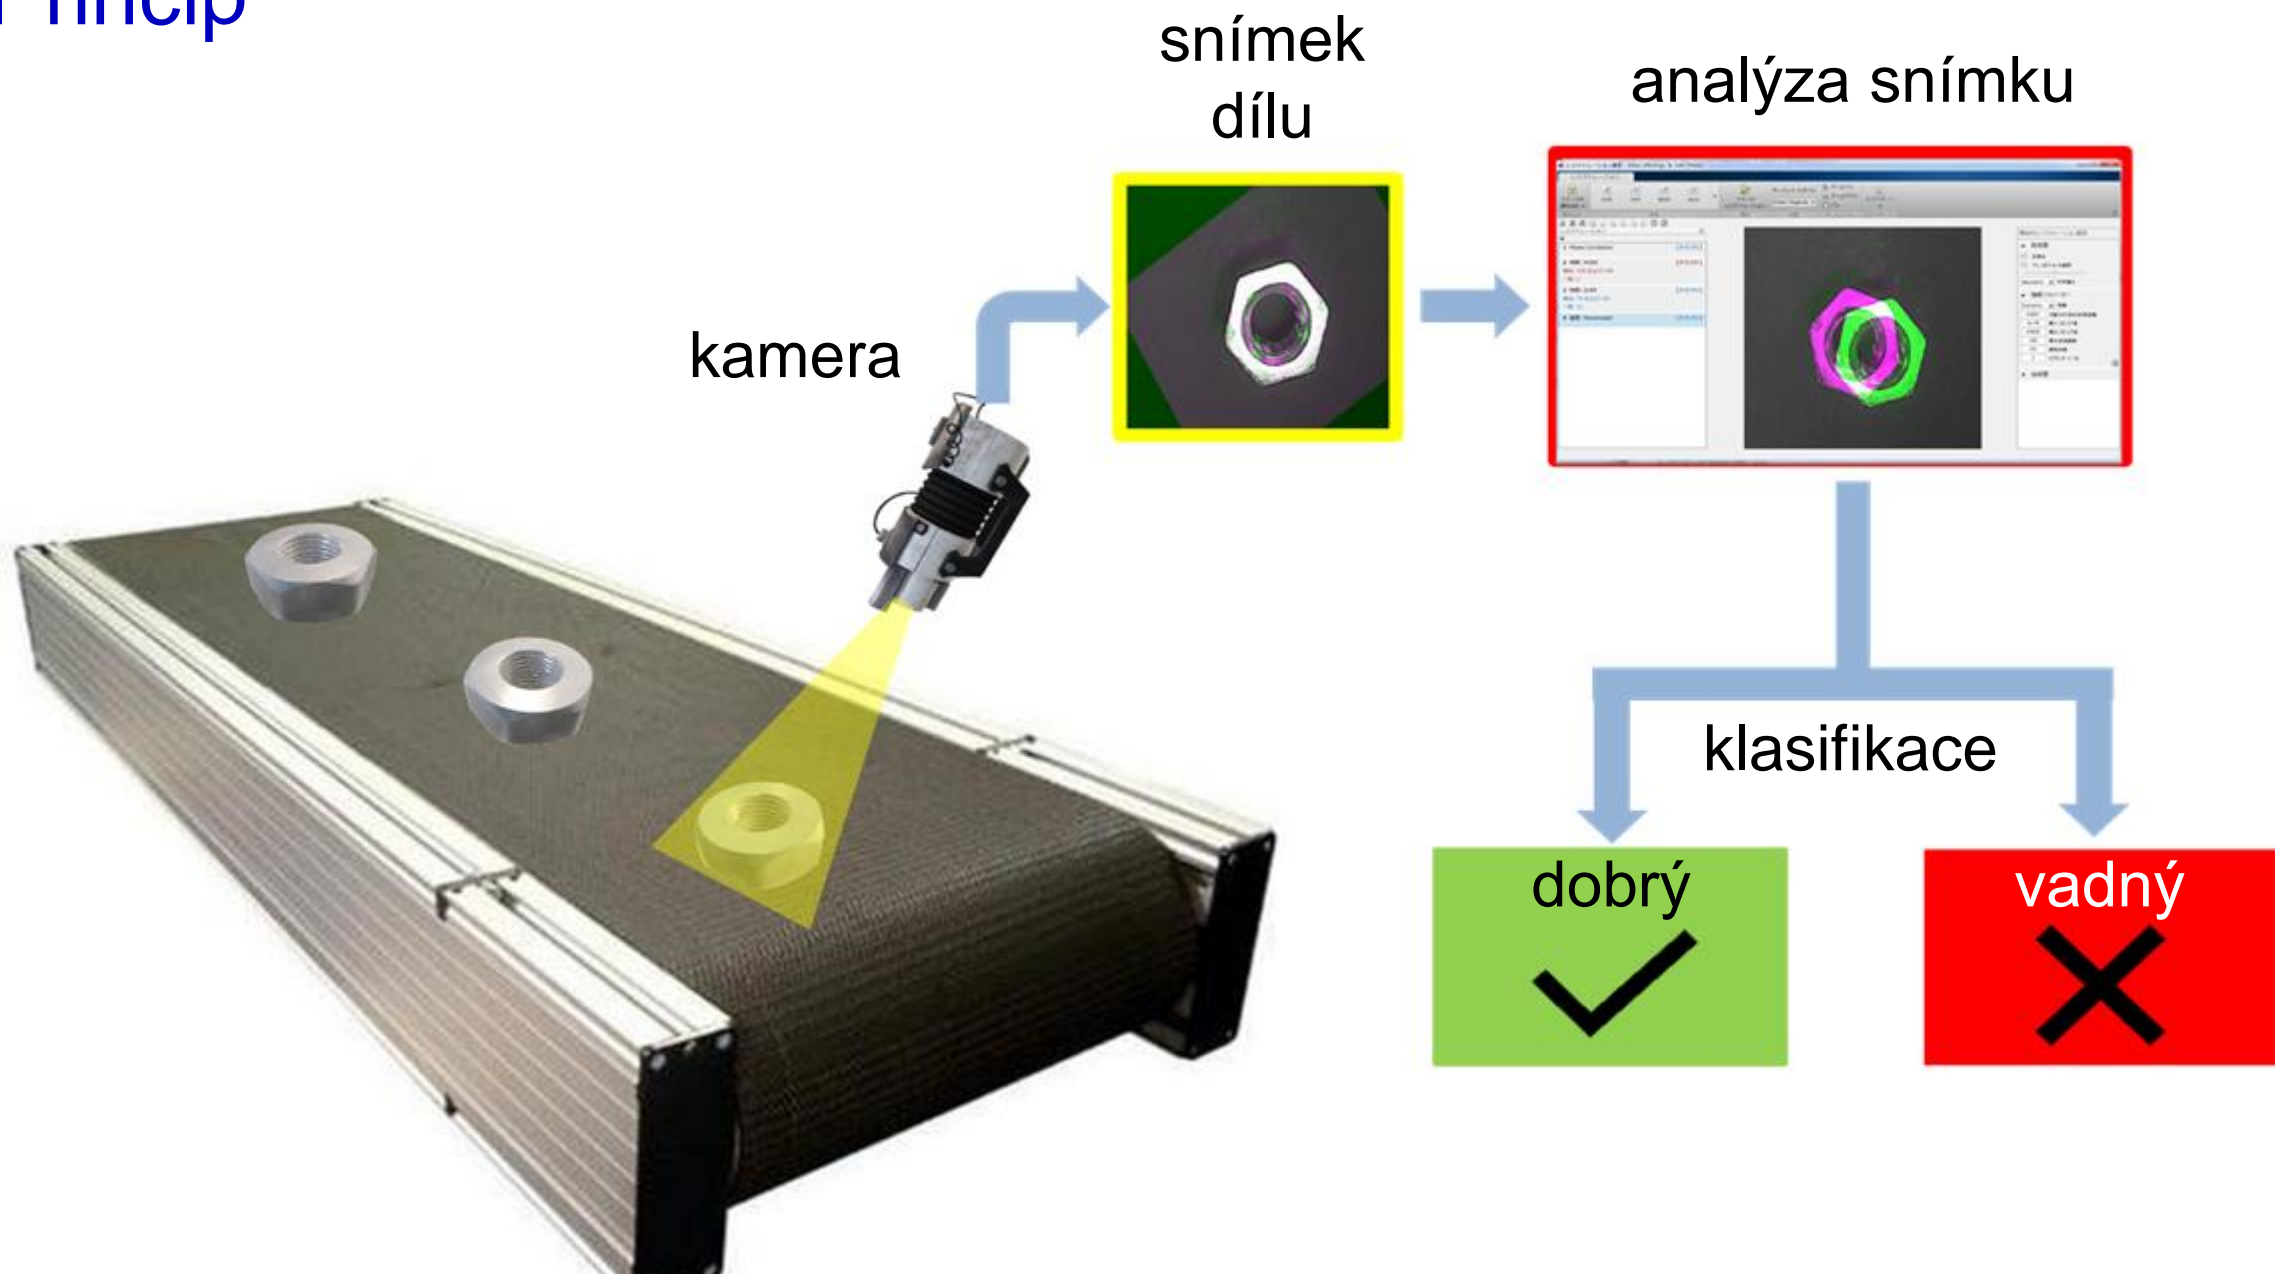


Detekce defektů v železniční dopravě











Detekce vad svarů v potrubí


Princip




Která matice je poškozená?



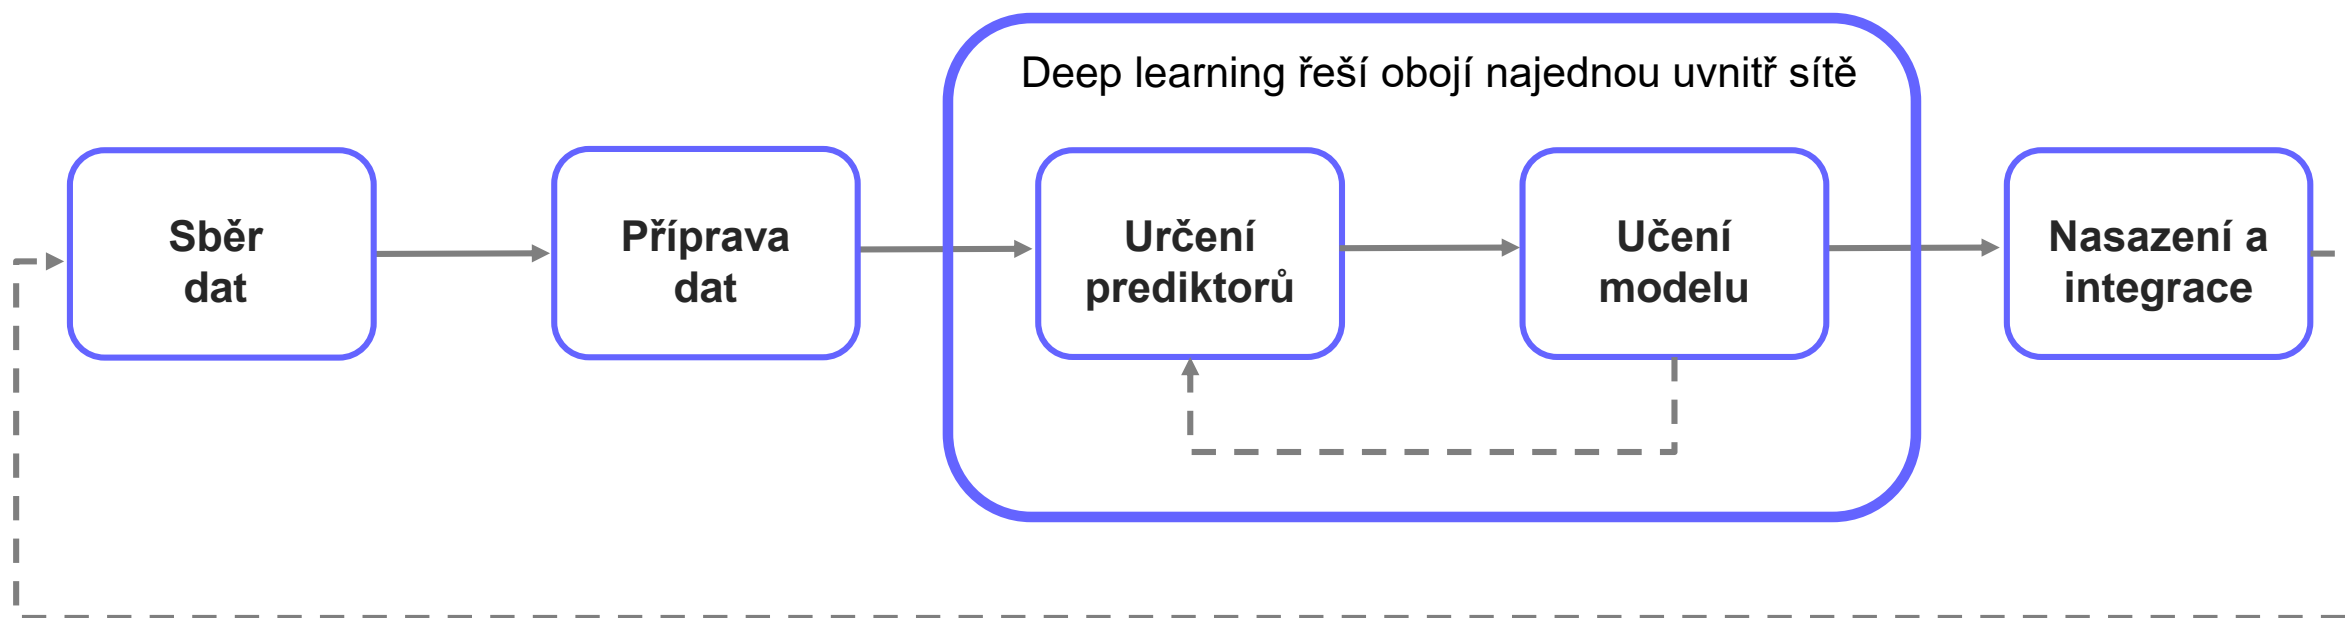






Postup vývoje algoritmů vizuální inspekce

Vývoj prediktivních a klasifikačních modelů

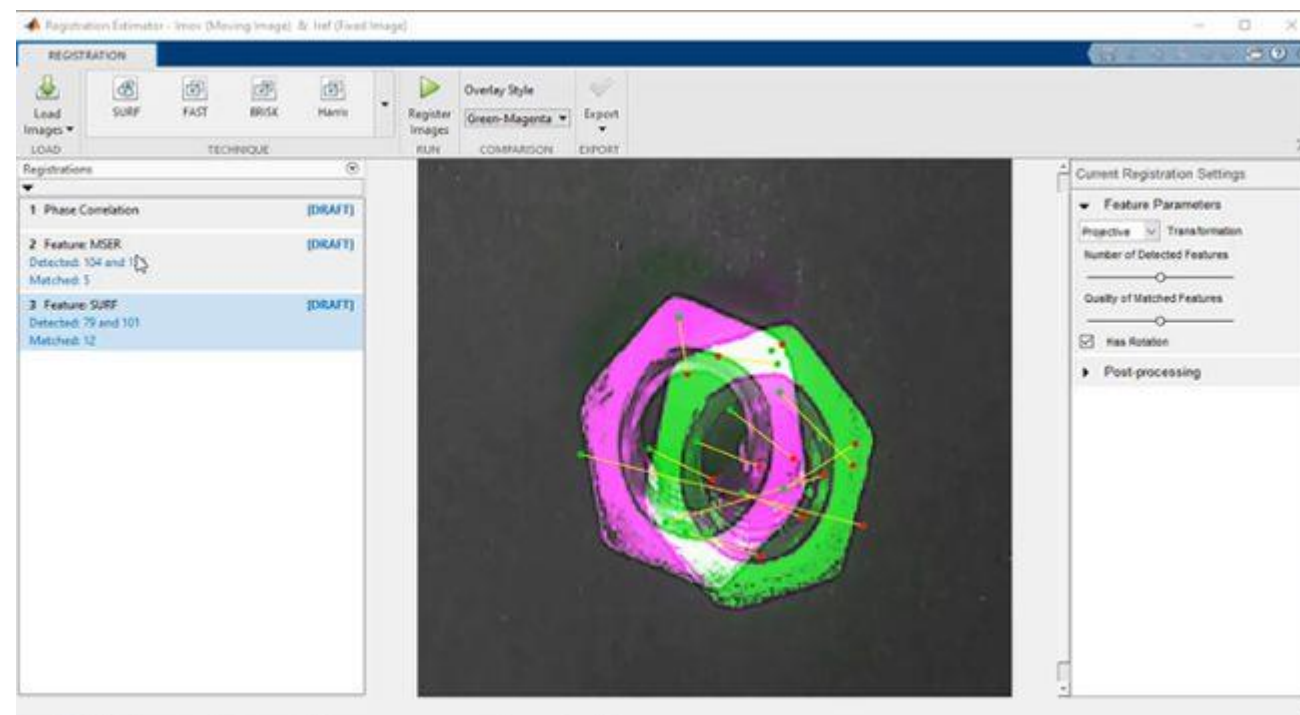


Příprava dat

- Data pocházejí z více zdrojů
 - jsou obvykle nestrukturovaná, obsahují šum
- Příprava snímků v datové sadě vede k vyšší přesnosti při detekci


- Funkce v prostředí MATLAB

- zpracování obrazu
- počítačové vidění




Model pro detekci anomálií – využití Autoencoderů

- Autoencoder je hluboká neuronová síť složená ze 2 částí: encoder a decoder



- Autoencoder se učí rekonstruovat vstupní snímek
 - zadání při učení: vstup == požadovaný výstup
 - uvnitř probíhá převod na vnitřní reprezentaci a zpět
- Učení autoencoderů nevyžaduje „defektní“ data
 - učení probíhá pouze na základě snímků dílů bez vady

Nasazení autoencoderu



Normální obrázek
 → rekonstruován korektně
 → rozdíl jde k nule



Abnormální obrázek
 → rekonstrukce není korektní
 → nalezení anomálie v rozdílovém obrázku

Model pro klasifikaci vad

- Učení modelu pro klasifikaci vad vyžaduje označená data různých typů vad
 - datová sada pro učení musí být vyvážená (podobný počet vzorků ve všech kategoriích)

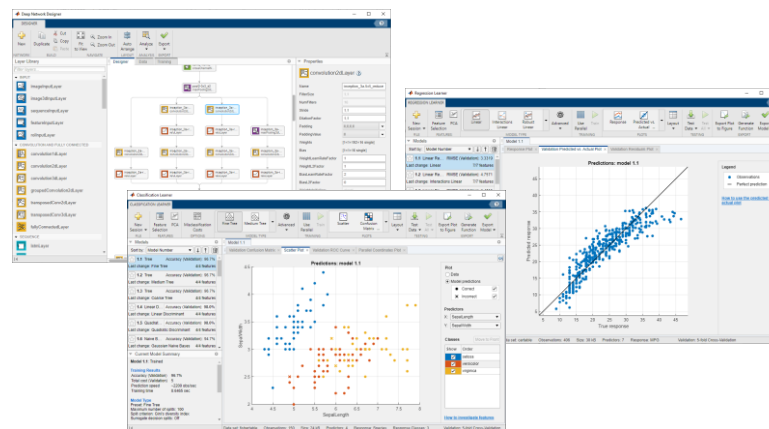
```

inputSize = 12;
numHiddenUnits = 100;
numClasses = 9;

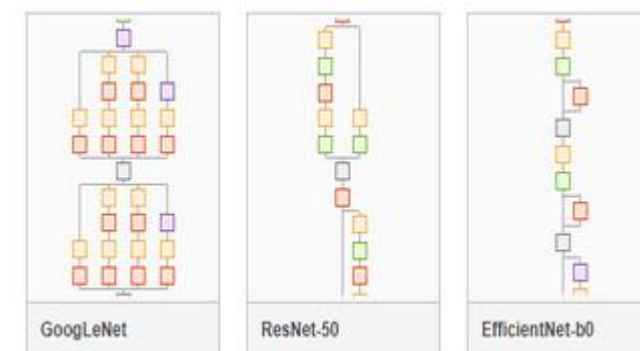
layers = [ ...
  sequenceInputLayer(inputSize)
  lstmLayer(numHiddenUnits, 'OutputMode', 'last')
  fullyConnectedLayer(numClasses)
  softmaxLayer
  classificationLayer]

```

Funkce, psaní skriptů



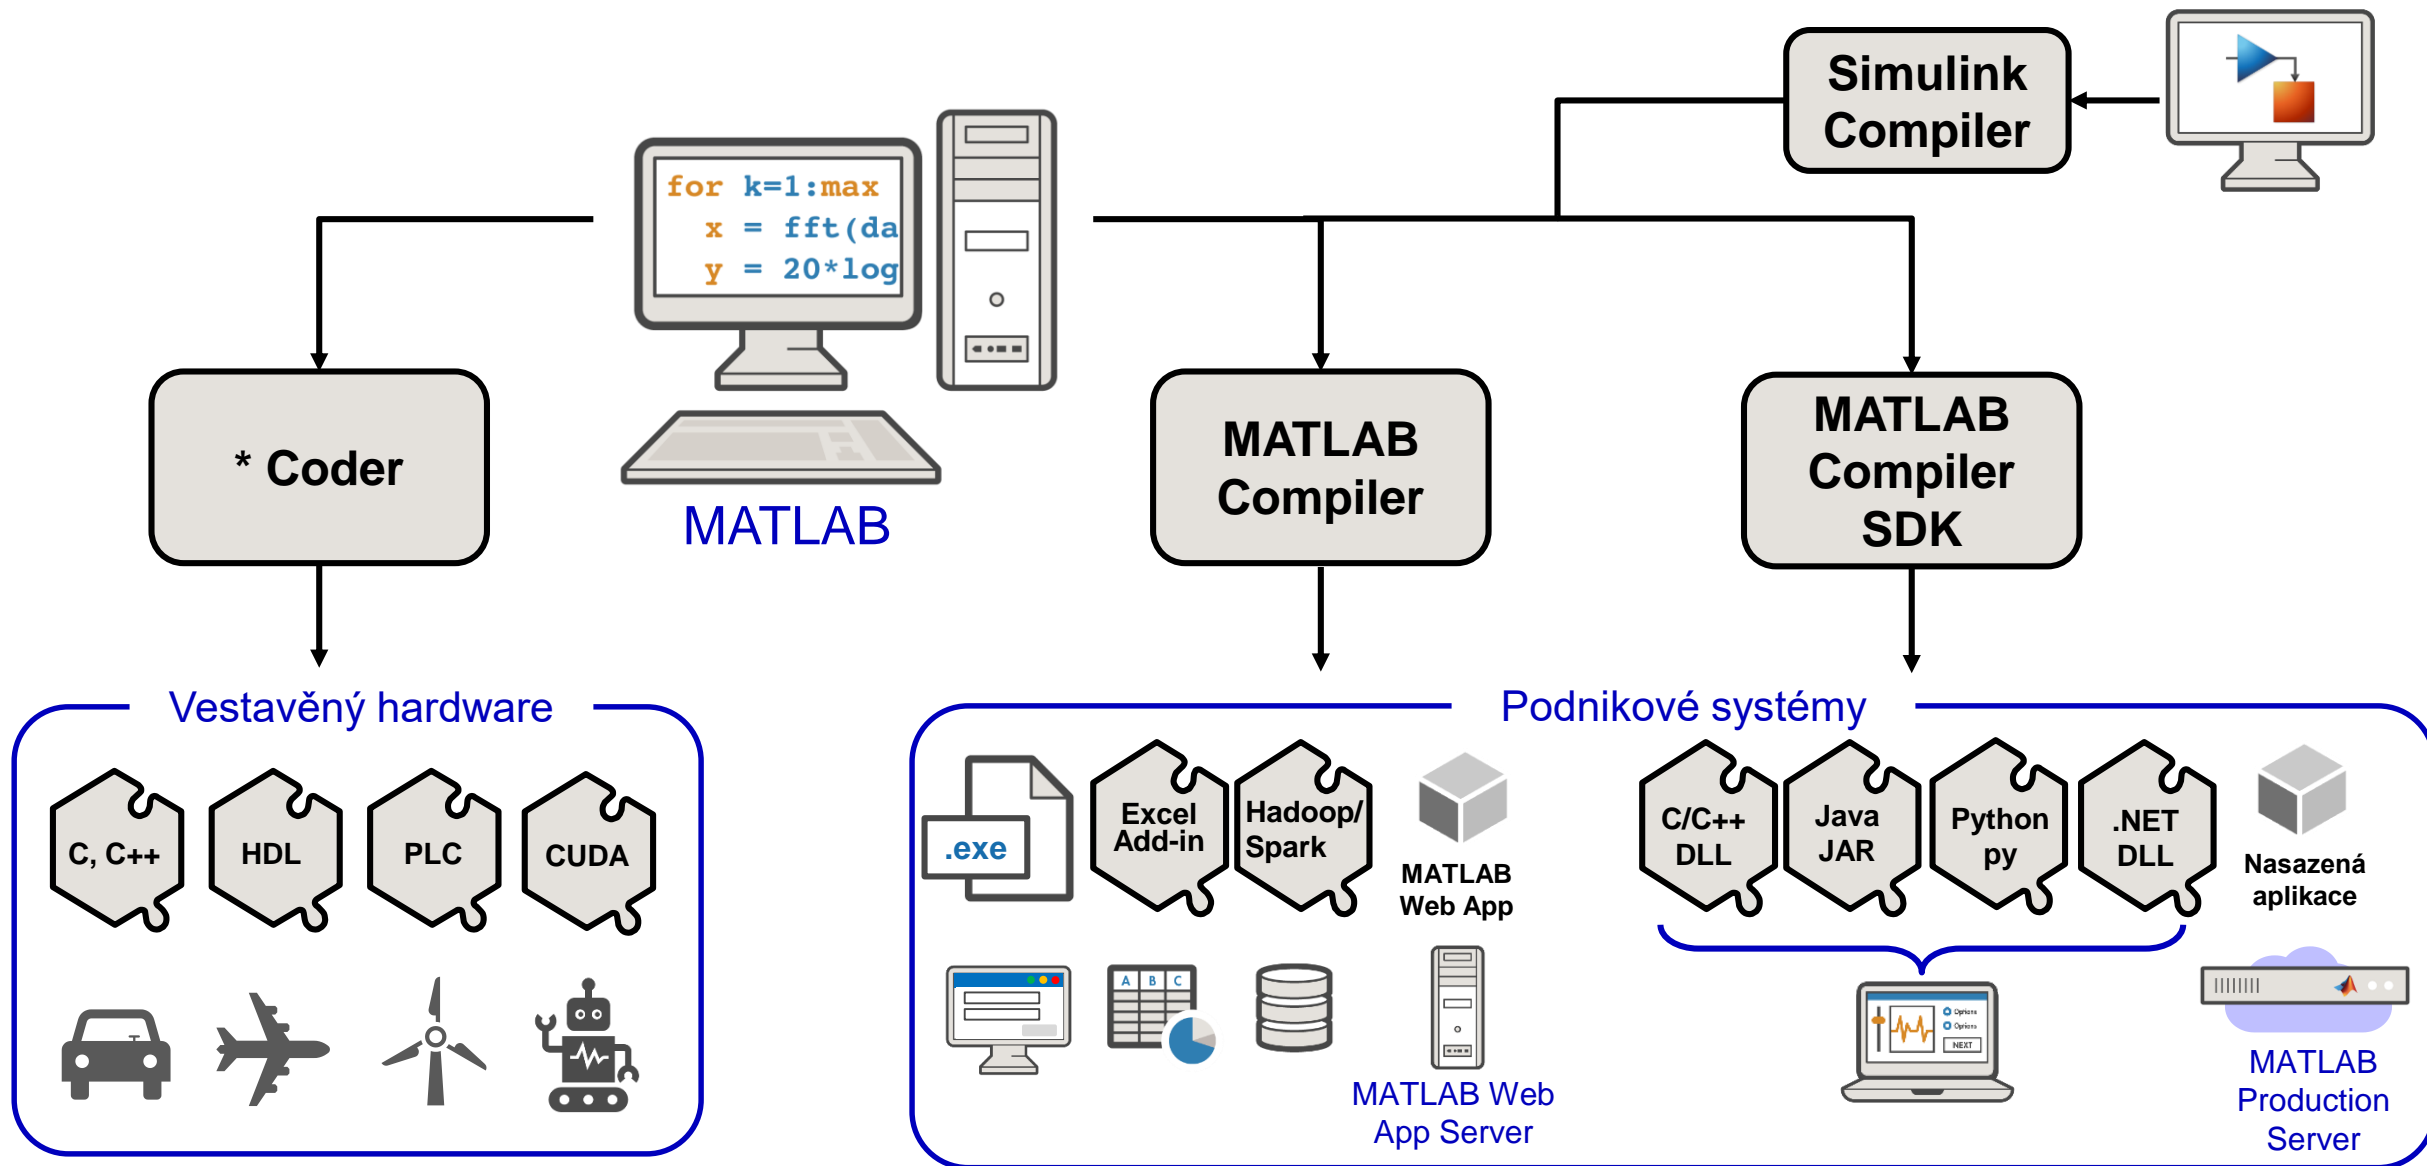
Interaktivní návrh pomocí grafických aplikací



Transfer learning s existujícími modely

- Při nedostatku dat může pomoci umělé rozšíření variability dat (`imageDataAugmenter`)

Nasazení modelů



Děkuji za pozornost