

REDUKCE DIMENSIONALITY PRAVDĚPODOBNOSTNÍCH MODELŮ PRO FDI

J. Jirkovský¹, M. Hofreiter²

¹Humusoft s.r.o., Praha

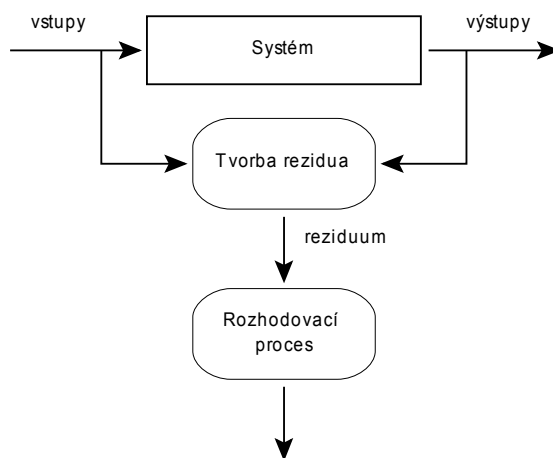
²Ústav Přístrojové a řídicí techniky, Fakulta strojní, ČVUT v Praze

Abstrakt

Příspěvek se věnuje problematice detekce a lokalizace poruch technických systémů s využitím pravděpodobnostního modelu založeného na bayesovském přístupu k pravděpodobnosti. Přístup je vhodný k nasazení detekce a lokalizace poruch u lineárních i nelineárních systémů. Problémem pro reálné nasazení je však rozměrnost modelu a z toho plynoucí náročnost na výpočetní zdroje. Proto byla navržena redukce dimensionalit, která rozkládá identifikovaný pravděpodobnostní model na několik submodelů. Výsledky dílčích modelů jsou pak skládány opět za využití bayesovského přístupu k pravděpodobnosti.

1 Diagnostika poruch využívající pravděpodobnostní model

Systémy detekce a lokalizace poruch (FDI) slouží k tomu, abychom na základě měřitelných veličin systému rozhodli o tom, zda systém pracuje v bezporuchovém režimu nebo došlo k poruše, případně o jakou poruchu se jedná [1, 2, 3, 4]. V případě pravděpodobnostního přístupu zakládáme své rozhodování na určení pravděpodobnosti výskytu dané poruchy v čase t za podmínky znalosti současných a minulých hodnot měřitelných veličin.



Obr 1: Princip diagnostiky poruch

Realizace FDI je obvykle prováděna ve dvou krocích. Prvním krokem je tvorba rezidua. Jejím účelem je vytvořit signál, který indikuje vznik poruchy z dostupných vstupů a výstupů daného systému. Druhým krokem je rozhodovací proces. V této části se na základě residua rozhodne, zda se jedná o danou poruchu, či nikoli. Obecně vzato se však většina pozornosti soustředí na tvorbu rezidua, protože s dobře postaveným reziduem je rozhodování o vzniku poruchy v zásadě jednoduchou záležitostí.

Pravděpodobnostní model, který je předmětem disertační práce, představuje generátor residua. Na jeho základě pak rozhodovací proces pouze volí poruchový stav soustavy podle maximální hodnoty pravděpodobnosti.

Detekci a lokalizaci poruch rozdělíme do dvou fází. V první fázi dochází k identifikaci pravděpodobnostního modelu. Tuto fázi nazveme fáze **učení**. Tento proces může probíhat jen po dobu, kdy máme kromě měřených veličin D_i k dispozici i explicitně určený poruchový stav f_i . Fáze učení probíhá do času t_R . Při následném provozu systému již hodnotu poruchového stavu k dispozici

nemáme, naopak hlavním cílem je odhad pravděpodobnostního rozdělení poruchových stavů v systému v daném časovém okamžiku. Tuto fázi nazveme fází **diagnostiky**.

Pravděpodobnost poruchového stavu soustavy $f_i = \phi$ v čase t , za předpokladu aktuální hodnoty regresního vektoru $z_t = \zeta$ dat D_t^R, f_t^R získaných ve fázi učení a platnosti hypotézy H , určující tvar regresního vektoru, je dána prvkem matice pravděpodobnosti poruch, který leží v řádku příslušném hodnotě regresního vektoru ζ a sloupci příslušném poruchovému stavu ϕ [5, 6]. Hodnota tohoto prvku je určena vztahem

$$p(f_t = \tilde{\phi} | z_t = \tilde{\zeta}, D^{t_R}, f^{t_R}, H) = \frac{i n_{\tilde{\zeta}, \tilde{\phi}}(t_R)}{\sum_{\phi=1}^{m_f} i n_{\tilde{\zeta}, \phi}(t_R)} \quad (1)$$

kde hodnota n je definována jako počet výskytů dvojice $[\zeta, \phi]$ ve fázi učení navýšený o počet těchto událostí v časech před fází učení předpokládaný apriorně.

Počet hypotéz o tvaru regresního vektoru není obecně omezen a společně tvoří množinu φ_H . Určíme aposteriorní pravděpodobnost těchto hypotéz po ověření reálnými daty ve fázi učení [7]. Můžeme ji vypočítat dle průběžného vztahu

$$p({}_i H | D^\tau, f^\tau) = \frac{p({}_i H | D^{\tau-1}, f^{\tau-1}) \frac{i n_{z_\tau, f_\tau}(\tau-1)}{\sum_{\phi=1}^{m_f} i n_{z_\tau, \phi}(\tau-1)}}{\sum_{j: H \in \varphi_H} \left(p({}_j H | D^{\tau-1}, f^{\tau-1}) \frac{j n_{z_\tau, f_\tau}(\tau-1)}{\sum_{\phi=1}^{m_f} j n_{z_\tau, \phi}(\tau-1)} \right)} \quad (2)$$

Výsledné rozdělení pravděpodobnosti pro všechny poruchové stavy soustavy určuje vztah

$$p(f_t | \tilde{z}_t, D^{t_R}, f^{t_R}) = \sum_{j: H \in \varphi_H} p(f_t | z_t, D^{t_R}, f^{t_R}, {}_j H) p({}_j H | D^{t_R}, f^{t_R}) \quad (3)$$

Kde z_t představuje sjednocení hodnot z_t pro všechny hypotézy H z φ_H . V případě, že některý model má o několik řádů nižší aposteriorní pravděpodobnost než ostatní, můžeme tento model z výpočtu vynechat. Výsledkem je tedy znalost pravděpodobnosti, která není závislá na volbě konkrétního pravděpodobnostního modelu.

2 Redukce dimensionality

Největší překážkou reálného nasazení těchto modelů je přílišná rozměrnost suficientní statistiky. Rozměr suficientní statistiky roste exponenciálně s délkou regresního vektoru. Pro výraznou redukci velikosti pravděpodobnostního modelu je tedy třeba sáhnout do jeho struktury [8].

Každý pravděpodobnostní model využitý v předchozím vztahu, který je dán regresním vektorem z_t určeným hypotézou H , **dekomponujeme** na m_M dílčích pravděpodobnostních modelů s regresními vektory určenými hypotézami ${}^q H_s$. Délka regresních vektorů dílčích modelů je stejná a jejich prvky jsou dány výběrem z prvků původního regresního vektoru. Počet dílčích modelů je dán počtem všech kombinací, které lze z prvků původního regresního vektoru vytvořit. Výsledky dílčích modelů jsou následně **agregovány** do výsledného rozdělení pravděpodobnosti poruchových stavů soustavy.

Matice pravděpodobnosti poruch dílčích pravděpodobnostních modelů jsou dány vztahem

$$p(f_t = \tilde{\phi} | z_t = \tilde{\zeta}, D^{t_R}, f^{t_R}, {}^q H_s) = \frac{q n_{\tilde{\zeta}, \tilde{\phi}}(t_R)}{\sum_{\phi=1}^{m_f} q n_{\tilde{\zeta}, \phi}(t_R)} \quad (4)$$

Minimální délka regresních vektorů dílčích modelů je rovna 2. Tato délka přináší největší redukci rozměrnosti. Ke zvýšení této délky přistupujeme až v případě, že výsledný systém modelů poskytuje výrazně horší přesnost než původní model.

Při agregaci předpokládáme, že jednoduchý dílčí pravděpodobnostní model umožní správně identifikovat pouze jediný poruchový stav soustavy, pro který je charakteristické odlišné chování právě těch veličin, které jsou obsaženy v jeho regresním vektoru. Při určování ostatních poruchových stavů soustavy poskytuje model neurčité výsledky a nedokáže je navzájem odlišit.

Zavedeme předpoklad, že pro určení aposteriorní pravděpodobnosti hypotézy ${}^i H_s$ využitě při odhadu pravděpodobnosti poruchového stavu soustavy f_t má smysl uvažovat pouze schopnost příslušného dílčího pravděpodobnostního modelu správně určovat, zda soustava JE či NENÍ v daném čase τ v poruchovém stavu $f_\tau = f_t$. Tento předpoklad označíme $As(f_t)$. Odhad pravděpodobnosti daného poruchového stavu soustavy f_t určíme dle vztahu

$$p({}^q H_s | D^\tau, f^\tau, As(f_t)) = \frac{p({}^q H_s | D^{\tau-1}, f^{\tau-1}, As(f_t)) \frac{{}^q n_{i z_\tau, f_t}(\tau-1)}{\sum_{\phi=1}^{m_f} {}^q n_{i z_\tau, \phi}(\tau-1)}}{\sum_{r: {}^r H_s \in \varphi_{iH_s}} \left(p({}^r H_s | D^{\tau-1}, f^{\tau-1}, As(f_t)) \frac{{}^r n_{r z_\tau, f_t}(\tau-1)}{\sum_{\phi=1}^{m_f} {}^r n_{r z_\tau, \phi}(\tau-1)} \right)} \quad \text{pro } f_\tau = f_t \quad (5)$$

$$p({}^q H_s | D^\tau, f^\tau, As(f_t)) = \frac{p({}^q H_s | D^{\tau-1}, f^{\tau-1}, As(f_t)) \left(1 - \frac{{}^q n_{i z_\tau, f_t}(\tau-1)}{\sum_{\phi=1}^{m_f} {}^q n_{i z_\tau, \phi}(\tau-1)} \right)}{\sum_{r: {}^r H_s \in \varphi_{iH_s}} \left(p({}^r H_s | D^{\tau-1}, f^{\tau-1}, As(f_t)) \left(1 - \frac{{}^r n_{r z_\tau, f_t}(\tau-1)}{\sum_{\phi=1}^{m_f} {}^r n_{r z_\tau, \phi}(\tau-1)} \right) \right)} \quad \text{pro } f_\tau \neq f_t \quad (6)$$

Výpočet celkového rozdělení pravděpodobnosti poruchových stavů soustavy provedeme spojením pravděpodobností jednotlivých stavů f_t . Protože jsou tyto pravděpodobnosti podmíněny odlišnými položkami vyplývajícími z odlišných předpokladů $As(f_t)$ pro různá f_t , musíme provést úpravu měřítka těchto výsledků. Celkový výsledek pak budeme považovat za odhad pravděpodobnostního rozdělení poruchových stavů soustavy dle původního modelu a vypočteme jej dle vztahu

$$\hat{p}(f_t | z_t, D^{t_r}, f^{t_r}, {}_i H) = \frac{\hat{p}(f_t | z_t, D^{t_r}, f^{t_r}, {}_i H, As(f_t))}{\sum_{\bar{f}_t \in \varphi_f} \hat{p}(\bar{f}_t | z_t, D^{t_r}, f^{t_r}, {}_i H, As(\bar{f}_t))} \quad (7)$$

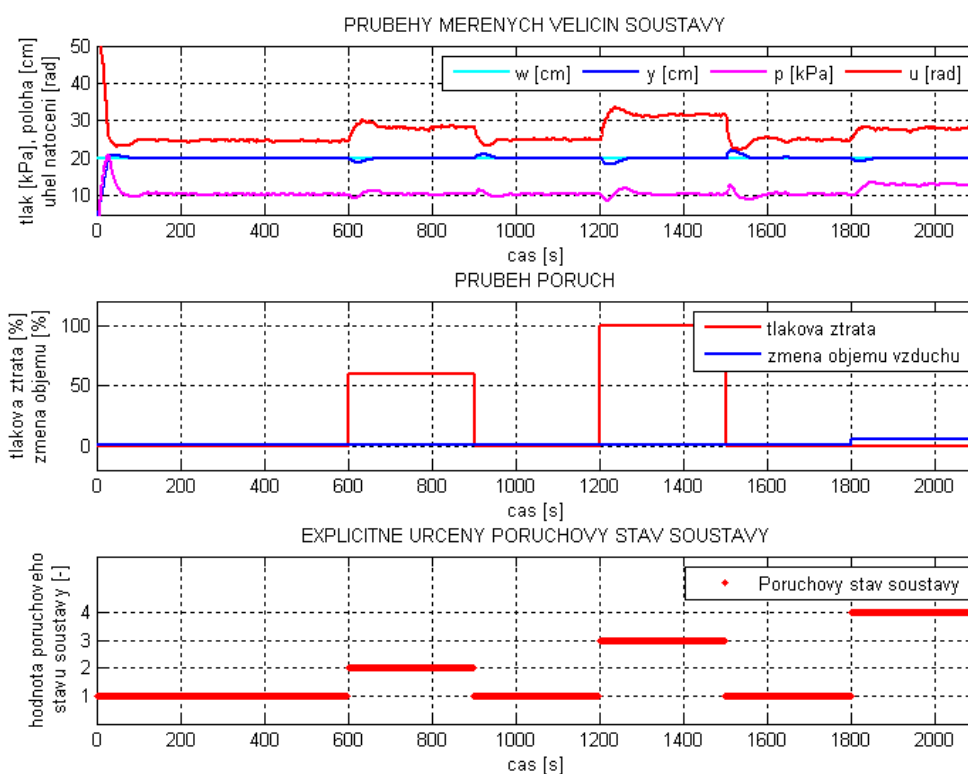
3 Ilustrativní příklad

Detekce a lokalizace poruch byla aplikována na soustavu „Batyskař“ s PI regulací [9].




Obr 2: Laboratorní soustava Batyskaf

Soustava byla naučena a následně testována na diagnostiku tří poruch, které se liší zdrojem poruchy a její velikostí. Jednotlivé poruchy byly vždy vyvolány v rovnovážném stavu bez poruchy, kdy plováček setrval v zadané pozici.



Obr 3: Průběh měřených veličin a poruch ve fázi učení

Měřenými veličinami byla poloha plováčku y , akční zásah servomotoru u a tlak v systému p . Hodnoty veličin byly následně kvantovány. Kvantizační intervaly lineárně rozdělily rozsah hodnot dané veličiny do 20 úrovní.

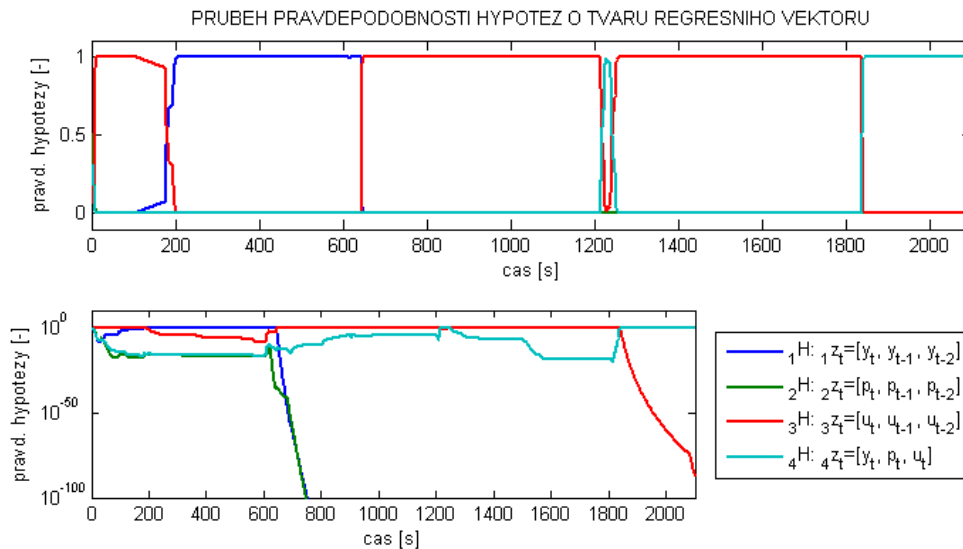


Obr 4: Průběhy kvantizovaných hodnot měřených veličin soustavy

Diagnostika poruch byla nejprve testována s modely 3. řádu.

- ${}_1H: {}_1z_t = [y_t, y_{t-1}, y_{t-2}]$
- ${}_2H: {}_2z_t = [p_t, p_{t-1}, p_{t-2}]$
- ${}_3H: {}_3z_t = [u_t, u_{t-1}, u_{t-2}]$
- ${}_4H: {}_4z_t = [y_t, p_t, u_t]$

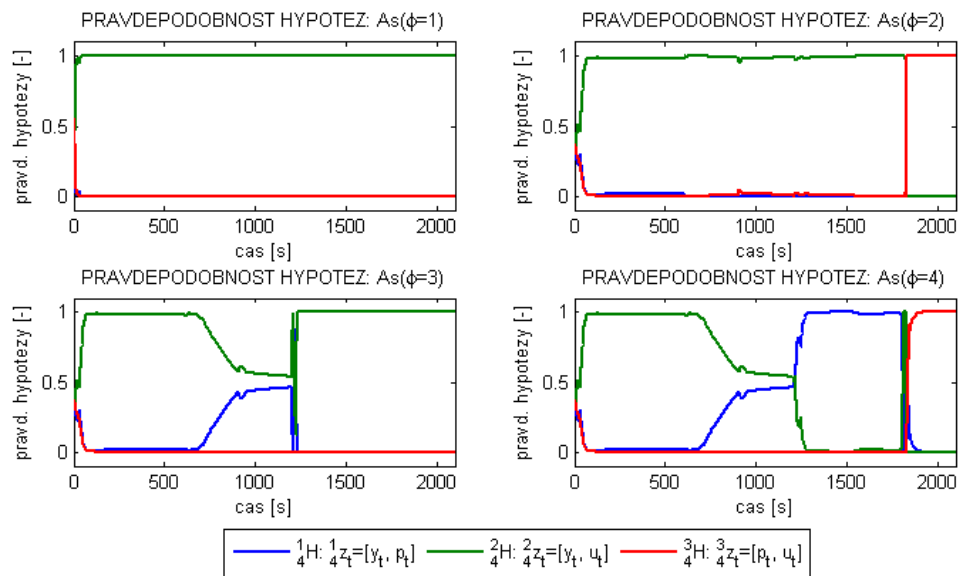
Aposteriorní pravděpodobnost 4. modelu byla o několik řádů vyšší než u ostatních, proto byly v dalších výpočtech zanedbány.



Obr 5: Průběh pravděpodobnosti hypotéz ve fázi učení v lineárních souřadnicích (nahore) a logaritmickeých souřadnicích (dole)


Model byl následně rozložen na 3 modely 2. řádu, jejichž regresní vektory obsahovaly různé kombinace veličin původního regresního vektoru 4. modelu:

- ${}_4^1H: {}_4^1z_t = [y_t, p_t]$
- ${}_4^2H: {}_4^2z_t = [y_t, u_t]$
- ${}_4^3H: {}_4^3z_t = [p_t, u_t]$



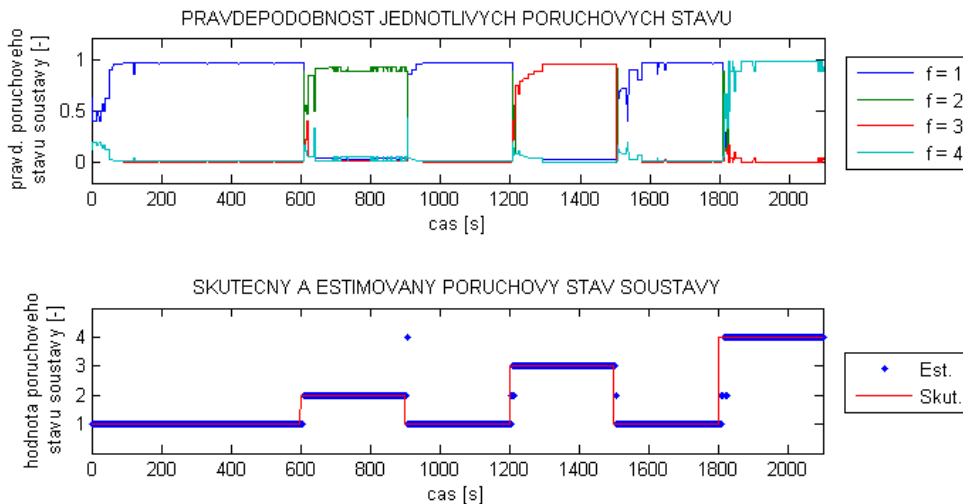
Obr 6: Vývoj aposteriorních pravděpodobností dílčích modelů ve fázi učení

Výsledky byly agregovány na základě navržené metody. Poruchový stav soustavy byl volen na základě maxima pravděpodobnosti z pravděpodobnostního rozdělení pro všechny poruchové stavy soustavy.



Obr 7: Výstup po agregaci dílčích pravděpodobnostních modelů dává stejně dobré výsledky, jako původní model

Pro srovnání je na následujícím obrázkuobrazen výsledek s plného pravděpodobnostního modelu určeného hypotézou ${}_4H$.



Obr 8: Výstup plného pravděpodobnostního modelu

Z výsledků je vidět, že redukovaný model dosáhl stejně dobrých výsledků, jako původní model třetího řádu.

Počet prvků suficientní statistiky plně identifikovaného pravděpodobnostního modelu určeného hypotézou $4H$ je 32 000 prvků. Naproti tomu počet prvků všech suficientních statistik plně identifikovaných dílčích pravděpodobnostních modelů určených hypotézami 4^1Hs , 4^2Hs , 4^3Hs je 4 800 prvků, což je hodnota více než 6x nižší.

4 Závěr

Zavedení systematické redukce dimensionalit pravděpodobnostních modelů pro FDI, která využívá dekompozici původního pravděpodobnostního modelu na skupinu dílčích modelů nízkých řádů, poskytuje značnou redukci rozměrnosti a s tím související snížení požadavků na výpočetní zdroje, což usnadňuje reálné nasazení. Metoda využívá agregace výsledků dílčích pravděpodobnostních modelů, která byla navržena s využitím bayesovského přístupu k pravděpodobnosti a vychází ze specifických předpokladů vycházejících z FDI.

References

- [1] V. VENKATASUBRAMANIAN, et al.: *A review of process fault detection and diagnosis : Part I: Quantitative model-based methods*. Computers and Chemical Engineering. 2003, no. 27, s. 293-311.
- [2] V. VENKATASUBRAMANIAN, et al.: *A review of process fault detection and diagnosis : Part II: Qualitative models and search strategies*. Computers and Chemical Engineering. 2003, no. 27, s. 313-326.
- [3] V. VENKATASUBRAMANIAN, et al.: *A review of process fault detection and diagnosis : Part III: Process history based methods*. Computers and Chemical Engineering. 2003, no. 27, s. 327-346.
- [4] J. Chen, R.J. Patton: *Robust model-based fault diagnosis for dynamic systems*. Norwel (Massachusetts) : Kluwer Academic Publishers, 1999. 356 s. ISBN 0-7923-8411-3.
- [5] G. Garajayewa: *Bayesian approach to real-time fault detection and isolation with supervised training*. Praha, 2005. 179 s. ČVUT v Praze. Fakulta strojní. Vedoucí disertační práce Prof. Ing. Milan Hofreiter, CSc.
- [6] M. Hofreiter, G. Garajayewa: *Real-time fault detection and isolation with supervised training*. In IFAC. [s.l.] : [s.n.], 2006. s. 667-672.
- [7] M. Hofreiter: *Bayesovská identifikace technologických procesů*. Praha, 1998. 73 s. ČVUT v Praze. Fakulta strojní. Habilitační práce.
- [8] J. Jirkovský: *Detekce a lokalizace poruch s využitím pravděpodobnostních modelů a redukce jejich dimensionalit*. Praha, 2012. 119 s. ČVUT v Praze. Fakulta strojní. Vedoucí disertační práce Prof. Ing. Milan Hofreiter, CSc.

- [9] J. Jirkovský: *Počítačové modelování a řízení laboratorního modelu „Batyskaf“*. Praha, 2004. 110 s. ČVUT v Praze, Fakulta strojní. Vedoucí diplomové práce Prof. Ing. Milan Hofreiter, CSc.