

NEURONOVÉ SÍTĚ V DETEKCI PORUCH (NEURAL NETWORKS IN FAULT DETECTION)

Michal Kuchař¹

¹ Ústav přístrojové a řídicí techniky, Fakulta strojní ČVUT v Praze. Michal.Kuchar@fs.cvut.cz


Abstrakt: Příspěvek pojednává o základním rozdělení metod detekce poruch a následně o možných aplikacích neuronových sítí v této oblasti. Ukazuje metody učení s učitelem (vícevrstvá neuronová síť) i bez učitele (samo-organizační mapa).

Klíčová slova: Detekce poruch, umělá inteligence, neuronové sítě, analýza dat, detekce novosti

1. Úvod

Diagnostika poruch je stále se rozvíjející obor, který je aplikován čím dál více i na systémy, které nejsou kritické z hlediska bezpečnosti (jako například jaderné elektrárny, letadla apod.) [1]. V dnešní době internetu věcí a rostoucího výpočetního výkonu je umožněn sběr velkého množství dat z různých zařízení a aplikací, proto je čím dál snazší aplikovat statistické metody a metody umělé inteligence.

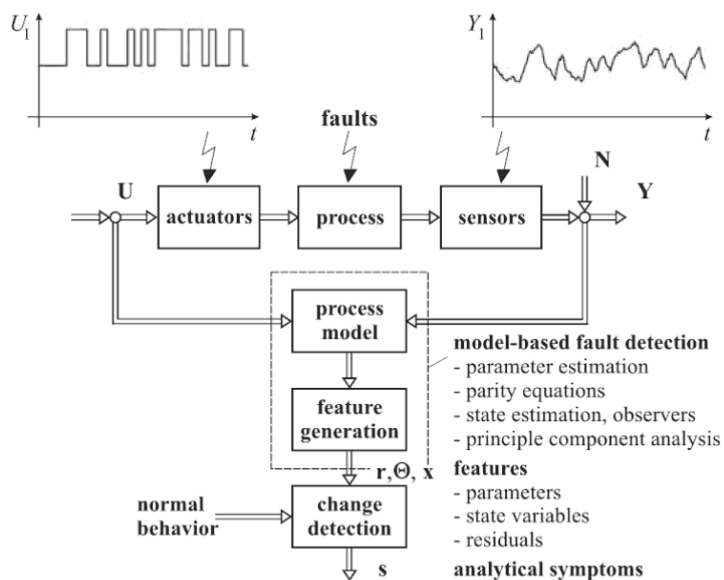
Pro přiblížení je na obr. 1 znázorněno základní rozdělení detekce poruch. Jednou skupinou je detekce poruch založena na porovnání modelu s měřením (obr. 2), druhou skupinou jsou metody detekce poruch na základě analýzy signálu bez znalosti modelu (obr. 3).



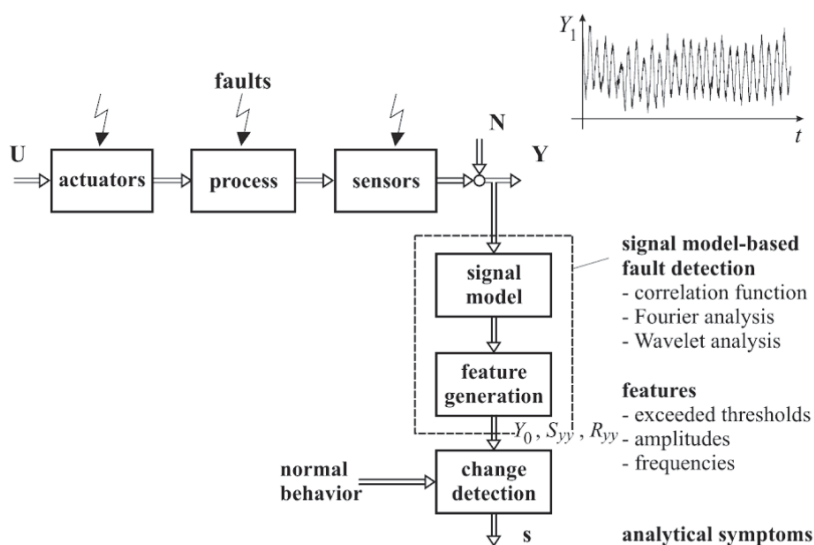
Obr. 1 Základní rozdělení metod detekce poruch [2].

Jak již z názvu plyne, tak pro detekce poruch na základě porovnání modelu s měřením je potřeba mít model, což je výhodné, pokud je model vůbec dostupný a pokud dostatečně popisuje realitu. V praxi se objevuje velké

množství systémů, pro které je velice obtížné odvodit uspokojivý model. Již v tomto bodě nastává prostor pro aplikace některých metod umělé inteligence. Analytický model může být nahrazen například neuronovým modelem, fuzzy modelem nebo jejich kombinací [3].



Obr. 2 Detekce poruch na základě porovnání modelu s měřením [2].



Obr. 3 Detekce poruch na základě analýzy signálu bez znalosti modelu [2].

Co se týče metod analýzy signálu, je možné aplikovat metody umělé inteligence na samotný signál, nebo na jeho vlastnosti. Výčet vybraných vlastností signálu je uveden v tabulce 1. Sledováním těchto vlastností lze nastavit prahy, které určují, zdali se v signálu neobjevují neobvyklé události. Prahly lze nastavit analyticky, pokud jsou známy limitní hodnoty pozorovaného systému, nebo je lze nastavit na základě statistické analýzy, nebo je možné použít například neuronovou síť.


V případě multidimenzionální analýzy dat je vhodné nějakým způsobem redukovat dimenze pro snazší vizualizaci. Mezi takové metody se řadí metoda hlavních komponent nebo Kohonenova samo-organizační mapa (dále SOM). SOM se řadí mezi neuronové sítě, které je možné učit bez učitele, což je výhoda, jelikož není zapotřebí mít k dispozici anotovaná data.

Tab. 1. Vybrané vlastnosti signálu [3].

Feature name	Feature definition	Value for the harmonic signal
Mean value	$\bar{x} = \frac{1}{T} \int_t^{t+T} x(u) du$	$\bar{x} = 0$
Absolute mean value	$x_{AVE} = \frac{1}{T} \int_t^{t+T} x(u) du$	$x_{AVE} = \frac{2}{\pi} X \cong 0,637X$
Root mean square value	$x_{RMS} = \sqrt{\frac{1}{T} \int_t^{t+T} x^2(u) du}$	$x_{RMS} = \frac{X}{\sqrt{2}} \cong 0,707X$
Absolute peak value	$x_{PEAK} = \max_{t < u \leq t+T} x(u) $	$x_{PEAK} = X$
Positive peak value	$x_{PEAK+} = \max_{t < u \leq t+T} x(u)$	$x_{PEAK+} = X$
Negative peak value	$x_{PEAK-} = \min_{t < u \leq t+T} x(u)$	$x_{PEAK-} = -X$
Peak to peak value	$x_{P-P} = x_{PEAK+} - x_{PEAK-}$	$x_{P-P} = 2X$
Form factor	$K = \frac{x_{RMS}}{x_{AVE}}$	$K = \frac{\pi}{2\sqrt{2}} \cong 1,111$
Crest factor	$C = \frac{x_{PEAK}}{x_{RMS}}$	$C = \sqrt{2} \cong 1,414$

2. Neuronové sítě

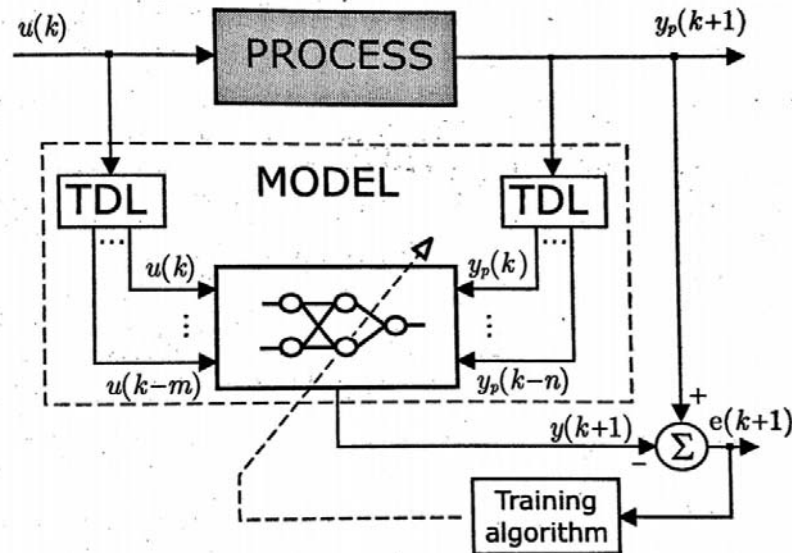
Neuronové sítě se dají použít pro tvorbu neuronového modelu, ale i pro samotnou klasifikaci a detekci poruch. Na obr. 4 je znázorněna vícevrstvá neuronová síť jejíž vstupy obsahují i určitou historii vstupních veličin. Tato síť může reprezentovat model systému. Celková reprezentace systému je znázorněna na obr. 5.



Obr. 4 Neuronový model dynamického systému [3].

Je nutno podotknout, že architektury neuronových sítí je velice mnoho, jejichž rozebrání je na celou knihu. To samé se dá říci i u učících algoritmů. Výchět nejčastějších architektur pro učení s učitelem je následovný:

- Vícevrstvá neuronová síť (MLP)
- Konvoluční neuronová síť (CNN)
- Síť s kruhovými funkcemi (RBF)
- Rekurentní neuronová síť (RNN)




Obr. 5 Schéma použití neuronového modelu [3].


2.1 Samo-organizační mapy

Jak bylo řečeno, SOM se řadí mezi neuronové sítě, které se učí bez učitele. Podobně jako u metody hlavních komponent je tedy cílem promítnutí vícerozměrných dat obvykle do roviny. Body v SOM, které leží u sebe, leží u sebe i v původním prostoru dat (což se obecně u metody hlavních komponent nemusí vždy povést). Další výhodou je i adaptivita tj. pokud chceme mapu obohatit o další pozorování, je doučení mapy mnohem méně náročné, než například přepočítat celou metodu hlavních komponent (to je důležité především u opravdu nadměrně velkém počtu dat). [4]

Základní architektura dvourozměrné SOM je znázorněna na obr. 6. Jednotlivé váhy neuronů se snaží přibližovat (dle zvolené metriky – např. Euklidovská) vstupním datům, čímž se tvoří shluky pozorování, které k sobě mají v prostoru blízko.



Obr. 6 Architektura SOM [5].



Obr. 7 Ukázka SOM. Obrázek vlevo ukazuje náhodné rozřazení jednotlivých vah reprezentovaných barvami (RGB). Obrázek vpravo ukazuje váhy po určité době učení, z čehož je názorné samo-organizování.

Vlastnosti SOM se dají použít jak při průzkumové analýze dat, tak při detekci i samotné diagnostice poruch. SOM tvoří během učení shluky a pokud se některé nové pozorování vyskytne mimo ně, je možné z tohoto pozorování vyvozovat poruchy. Vzhledem k tvorbě shluků je možné i jednotlivé poruchové shluky klasifikovat a vyvozovat z nich diagnózu.

2.2 Adaptivní filtry

Další z přístupů detekce poruch je použití adaptivních filtrů. Klasickým reprezentantem adaptivního filtru je LMS (least mean squares) filtr jehož přepis je vyjádřen dle rovnice (1). Jednotlivé váhy jsou vypočteny tak, aby střední hodnota kvadratických odchylek byla minimální. K tomu lze použít například metodu největšího spádu, z čehož se odvodí rovnice (2).

$$\tilde{y}(k) = w_1(k) \cdot x_1(k) + \dots + w_n(k) \cdot x_n(k) = \mathbf{w}^T(k) \cdot \mathbf{x}(k) \quad (1)$$

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \Delta \mathbf{w} = \mathbf{w}(k) + \eta(k) \mathbf{w}(k) e(k) \quad (2)$$

Jedním ze způsobů využití adaptivního filtru k detekci poruch jsou metody error and learning based novelty detection (ELBND) a learning entropy (LE) [6], které vyvozují novost na základě adaptace vah. Neobvyklá adaptace vah nad určité meze může být indikátorem poruchy v pozorovaném systému.

3. Závěr

Byly shrnuty základní metody detekce poruch a možné prostory pro využití neuronových sítí. Bylo uvedeno základní schéma neuronového modelu. Dále byla představena role samo-organizační mapy jako nástroje pro detekci poruch i klasifikaci symptomů. Posledním nástrojem byly uvedené metody detekce novosti (ELBND a LE) jako možné nástroje detekce poruch.

Poděkování

Práce byla podpořena grantem SGS18/177/OHK2/3T/12

Literatura

- [1] R. Patton, P. Frank a R. Clark, Issues of Fault Diagnosis for Dynamic Systems, London: Springer, 2000.

- [2] R. Isermann, *Fault-Diagnosis Systems, An introduction from Fault Detection to Fault Tolerance*, Berlin: Springer, 2006.
- [3] J. Korbicz, J. Kościelny, Z. Kowalczyk and W. Cholewa, *Fault Diagnosis, Models, Artificial Intelligence, Applications*, Berlin: Springer, 2004.
- [4] P. Hebák, *Statistické myšlení a nástroje analýzy dat*, Praha: Informatorium, 2013.
- [5] A. Ralhan, „Self Organizing Maps,“ 2018. [Online]. Available: <https://medium.com/@abhinavr8/self-organizing-maps-ff5853a118d4>. [Přístup získán 30 Srpen 2020].
- [6] M. Cejnek a I. Bukovský, „Concept drift robust adaptive novelty detection for data streams,“ *Neurocomputing*, pp. 46-53, 2018.



Selected article from

Tento dokument byl publikován ve sborníku

**Nové metody a postupy v oblasti přístrojové
techniky, automatického řízení a informatiky 2020
New Methods and Practices in the Instrumentation,
Automatic Control and Informatics 2020**

14. 9. – 16. 9. 2020, Zámek Lobeč

ISBN 978-80-01-06776-5

Web page of the original document:

<http://iat.fs.cvut.cz/nmp/2020.pdf>

Obsah čísla/individual articles:

<http://iat.fs.cvut.cz/nmp/2020/>

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