


Možnosti využití neuronových sítí při provozu tepelného čerpadla

Radim Kundrata
Energetický ústav







Jsou neuronové sítě schopné identifikovat poruchy TČ?

- Jak náročná je implementace? Kolik je zapotřebí dat? Jaká je spolehlivost, výpočetní čas?
→ Je možné si pro vlastní potřeby vytvořit diagnostický nástroj?
- Bylo nutné získat trénovací data (simulace/použit dostupný dataset/naměřit vlastní).
→ Sestrojení experimentálního TČ.
→ Osazení čidly, sběr Arduinem do notebooku.
→ Měření běžného provozu i simulovaných poruchových stavů.
→ Měření probíhalo 3 měsíce, záznam každých 6 sekund.
- Feature engineering – nové závislosti z naměřených veličin (rozdíly, součiny, ...).



Poruchy

- Poruch je velká spousta, zaměřeni na úzkou část – poruchy mají podobné projevy.
→ Zaměřeni na výparník (zakrytí výparníku, změna přehřátí, odpojení ventilátoru).
- Další zaznamenané poruchy: porucha expanzního ventilu, snížení průtoku otopné vody, ...



Identifikace poruchy – Rekurentní neuronová síť (RNN)


- Síť byla naučena na polovině datasetu.
- Každá porucha v ní byla jednou ukázána (učení s učitelem).
- Vyhodnocení probíhalo na druhé polovině datasetu.
- Postupné zpracování přináší problém mizejícího gradientu.
→ částečné řešení LSTM – long short term memory neurony.



Tabulka výsledků RNN


Skutečný stav	Vyhodnocení (data nepoužitá pro trénování)	celkem
Bez poruchy	139560	140395
Zakrytí výparníku	1189	1847
Odklonění ventilátoru	78	1305
Změna přehřátí	4147	14650
Indikovaný stav	Bez poruchy	158197

Detail porovnání – běžný náběh TČ



Identifikace poruchy – Transformer


- Proces trénování i vyhodnocení shodný s RNN.
- Neuronová síť využívající attention (přímo hledá vzájemnou spojitost veličin).
- Možnost paralelizace (→ velké jazykové modely).
- Lepší přesnost než RNN, ale vyšší podíl falešných poplachů.



Tabulka výsledků Transformeru



Skutečný stav	Vyhodnocení (data nepoužitá pro trénování)	celkem
Bez poruchy	138454	140395
Zakrytí výparníku	7	1847
Odklonění ventilátoru	0	1305
Změna přehřátí	75	14536
Indikovaný stav	Bez poruchy	158197

Detail porovnání – zakrytí výparníku



Hledání anomálií - autoenkodér


- Síť je složena z enkodéru a dekodéru.
- Principem je replikace sekvencí vstupních dat na výstup.
- Síť je trénována na čtvrtině datasetu bez výskytu poruch.
- Vyhodnocení dle hodnoty anomálie (zvýšená anomálie = porucha).
- Některé konfigurace vykazovaly řádově vyšší hodnoty anomálie, především u poruchy EEV.



Závěrem...

- Využití knihovny strojového učení není složité.
- Pro sběr dat stačí běžně dostupné senzory.
- Pro trénování sítí postačí běžný notebook, evaluace je rychlá.

Vývoj přesnosti trénování Transformeru



- Transformer dosáhl lepší přesnosti než RNN.
- Na výsledky se nedá zcela spolehnout.
- Hledání anomálií může doplnit současné řídicí algoritmy.
- Data jsou cenná, vše měřit a ukládat jistě stojí za to!

Možná vylepšení:

- Rozšíření datasetu (delší čas, více veličin)
- Další optimalizace sítí (hloubka, šířka, ...)
- Fokus na postupné poruchy místo náhlých

Další možné směřování:

- Vibradiagnostika
- Physics-informed neural networks
- Predikce údržby/spotřeby/výkonu
- Řízení s pomocí neuronových sítí

Histogram frekvence kompresoru datasetu

