

Využití strojového učení při diagnostice vodních strojů

Albert Kindl
Energetický ústav




MOTIVACE A CÍLE PRÁCE

- Motivace práce
- Algoritmy AI a strojového učení zažívají rozmach
- Příležitosti pro implementaci v hydroenergetice
- Prediktivní údržba vodních turbín, čerpadel atp.
 - Sledování a vyhodnocování stavu vodního stroje v reálném čase
 - Doplnění konvenčních metod diagnostiky
- Cíle práce
- Tvorba binárního klasifikátoru poruchy na vodním stroji za využití dat z čerpadla BETA 12YC
- Určení omezení navržených modelů




NAMĚŘENÁ DATA

- Data z hydraulické laboratoře VUT OFI
- Měření v čerpadlovém a turbínovém režimu
- Binární klasifikátor tvořen učním s dohledem
 - Měření dat bez vady a s umělou vadou
- Umělá vada vytvořena provrtáním lopatky
 - Simulace úbytku materiálu kavitací apod.
- Do neuronových sítí vstupováno především dynamickými senzory
 - Snímač akustické emise, piezoelektrické snímače tlaku na sání a ve spirále, mikrofon, akcelerometr na spirále
 - Jeden záznam → 4 sekundy, 200 kHz




VÝSLEDKY JEDNOTLIVÝCH PŘÍSTUPŮ V PREPROCESSINGU A VOLBĚ TYPU NEURONOVÉ SÍTĚ

- Do neuronových sítí bylo vstupováno primárně všemi dynamickými snímači najednou
- Konvoluční neuronová síť pracující se surovými daty
 - Přesnosti modelů 70 % až 94 %
- Plně propojená neuronová síť pracující se statistickými charakteristikami
 - Nad částmi signálu vypočteny: kurtosis, šikmost a různé percentily
 - Přesnosti modelů 60 % až 95 %
- Konvoluční neuronová síť pracující s MEL-spektrogramy
 - Přesnosti modelů se blíží 100 %
 - Vhodné také využití samotného senzoru akustické emise (98 % až 100 %)
- Nižší výkonnost lze předpokládat na vyšších otáčkách



OPTIMALIZACE NASTAVENÍ MODELU NEURONOVÉ SÍTĚ


- Kombinace optimalizace hyperparametrů a thresholdu → znatelné zlepšení výkonnosti
- Cíl → Pomocí MEL-spektrogramů z méně efektivního snímače tlaku ve spirále dosáhnout co nejlepších výsledků
 - Výsledná přesnost 97,7 % → zlepšení o necelá 3 % → Volba senzoru zůstává kritická



Průběh učení modelu za použití optimalizačního algoritmu

OPTIMALIZACE NASTAVENÍ HYPERPARAMETRŮ NEURONOVÉ SÍTĚ

- Optimalizace hyperparametrů multiobjektivní i jednoduchá
 - Knihovna Optuna
 - Dynamický počet skrytých vrstev a jejich nastavení, learning rate a další
- Vykreslováno do nástroje TensorBoard pro snazší analýzu
- Automatizace procesu tvorby modelu
- Umožňuje využití projektu na jiných strojích → Nutné k implementaci na konkrétní lokalitě
- Využíván algoritmus Bayesovské optimalizace



Známosti závislosti přesnosti a ztráty modelu na volbě hodnoty learning rate a počtu přidávaných konvolučních a plně propojených vrstev – Vykresleno v TensorBoard

	Hodnocení podle přesnosti	Hodnocení podle ztráty
Optimalizace přesnosti	Model A 97,16 % 0,1304	Model B 96,90 % 0,1068
Optimalizace přesnosti a ztráty	Model C 96,64 % 0,1499	Model D 95,61 % 0,1384

ZÁVĚR, BUDOUCÍ VÝVOJ A VÝZKUM

- Podařilo se navrhnout funkční klasifikátor
- Nejvýhodnější varianta → MEL-spektrogramy ze snímače akustické emise při použití konvoluční neuronové sítě
- Při aplikaci na reálných lokalitách může být získání dat obsahujících vadu problematické
 - Řešení → Učení bez dohledu např. Autoenkodéry
 - Moderní varianty → GWAE/GWVAE,
- Aplikace po dalším vývoji → Vodní i jiné elektrárny, čerpací stanice atd.
- Další aplikace algoritmů AI a strojového učení v hydroenergetice
 - Predikce spotřeby elektrické energie
 - Predikce přítoků a meteorologických jevů
 - Predikce kritických stavů v síti a koordinace nejen vodních zdrojů
 - Zabránění blackoutů