

Software pro predikci nestability a sledování napěťových událostí

Identifikační číslo výsledku: TK01030094-V2

Daniel Kováč, Vysoké učení technické v Brně

Viktor Jurák, Vysoké učení technické v Brně

Jaroslava Orságová, Vysoké učení technické v Brně



Tento software byl vytvořen se státní podporou
Technologické agentury ČR.

Číslo projektu: TK01030094


Název projektu: Inteligentní energetické sítě

Popis programu

Tento software analyzuje distribuční síť a v reálném čase predikuje z napěťových událostí stabilitu jejího chodu, aby bylo zamezeno vzniku nebezpečných provozních stavů. Predikce je prováděna z měřených hodnot napětí ve dvou bodech sítě. Výstupem predikčního algoritmu je informace, zda je obvyklá manipulace pro udržení stabilního chodu bezpečná, či nikoli. Program ukládá výsledek predikce, přesný čas události a popis, jednalo-li se během události o zkrat v síti, anebo byl pokles napětí způsoben jejím přetížením.

Popis trénovací sítě

Síť je napájena ze síťového napaječe na úrovni 110 kV se zkratovým proudem 11 kA. Následuje trojvinutový transformátor VVN/VN s regulátorem odboček. Uzel transformátoru je na straně 22 kV uzemněn přes 1 kA odporník (12Ω). Z rozvodny vedou dva vývody. První má celkovou délku 45 km a je tvořen venkovním vedením. Druhý je dlouhý 50 km a je tvořen venkovním vedením a 20 km kabelovým úsekem. Venkovní vedení je uvažováno AIFe 150/22 v rovinném uspořádání. Kabelové vedení je uvažováno AXEKCY 240 v těsném trojúhelníkovém uspořádání. Oba vývody z rozvodny jsou chráněny reálnou ochranou REX 640, která je připojena k perifériím simulátoru.



Obrázek 1 Modelová síť pro trénování predikčního algoritmu

Pro trénování modelu strojového učení bylo pomocí simulátoru vytvořeno 200 událostí, při kterých se náhodně měnily hodnoty zátěží, případně byla aplikována porucha. Typ změny zátěže byl vybírán náhodně jako dvojfázový nebo trojfázový. Hodnoty změny zátěže byly měněny náhodně v rozsahu 2,5 – 7,5 MW v případě dvojfázové změny a v rozsahu 7,5 – 22,5 MW v případě

trojfázové změny. Typ zkratu byl volen náhodně jako jednofázový, dvojfázový, nebo trojfázový s odporem poruchy v rozmezí 10 – 40 Ω. Z těchto událostí došlo k signifikantní změně napětí ve 181 případech, které byly využity k natrénování predikčního algoritmu.

Model strojového učení

Pro trénování klasifikátoru bylo použito 181 událostí, ve kterých došlo v jakémkoli čase k signifikantní změně napětí ať už z důvodu přetížení sítě nebo výskytu zkratu. Z každé takové události bylo získáno časové okno o délce 150 ms. S vzorkovací frekvencí $f_s = 4$ kHz se v každém okně nachází 15 segmentů nesoucí informaci o průběhu krátkodobé energie:

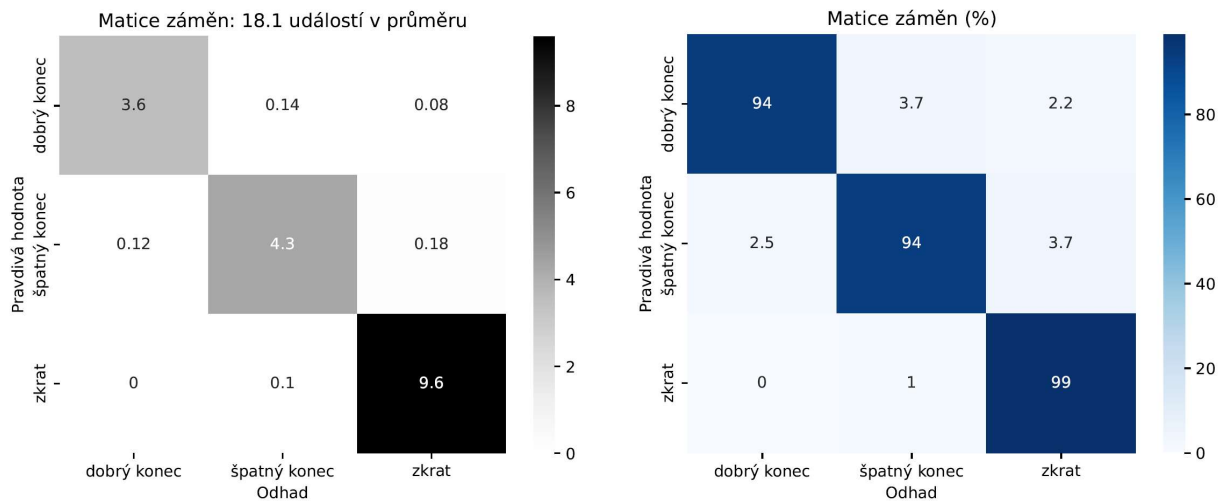
$$E_{xy} = \sum_{n=0}^N \mathbf{s}[n]^2,$$

kde x reprezentuje měřící bod, y značí fázi, index n udává pořadí vzorku signálu \mathbf{s} a konstanta N značí počet vzorků v segmentu. Hodnoty energií v segmentech se poté normalizují podle segmentu s nejvyšší energií, jehož hodnota je po normalizaci rovna 1 a ostatní nabývají hodnoty od 0 do 1. Z průběhu energie v časovém okně nacházejícím se těsně před signifikantní změnou v napětí je pak predikováno, jaký bude výsledek po provedení obvyklé manipulace pro udržení stabilního chodu. Po provedení manipulace při přetížení může nastat dobrý konec (přetížení je eliminováno), nebo špatný konec (přetížení po provedení manipulace trvá). Pokud je vyhodnocen zkrat, nejsou manipulace uvažovány. Pro tyto účely byl vybrán model strojového učení XGBoost, nastaven pro multinomiální klasifikaci (multi: softmax). Optimalizace hyperparametrů proběhla za využití metody náhodného vyhledávání (random search). Natrénovaný model je uložen ve formátu `.json`, který je čitelný jak počítačem, tak člověkem.

Validace modelu

Úspěšnost modelu klasifikovat události byla ověřena za pomoci desetinásobné stratifikované křížové validace s dvaceti opakováními. Všechny 181 událostí tak bylo rozděleno do 10 skupin. Data devíti skupin byla využita pro trénování modelu a data ze zbylé skupiny pro testování a výpočet klasifikační přesnosti. V dalším kroku bylo vybíráno jiných devět skupin pro trénování a zbylá skupina pro testování, dokud nebyla možná další kombinace. Tento celý proces se opakoval dvacetkrát a jednotlivé skupiny obsahovaly vždy jiné události. V každé testovací skupině bylo po stratifikaci v průměru 18,1 událostí. Výsledná vyvážená přesnost modelu v průměru dosahuje 98 % (true positive rate = 97 %, false positive rate = 2 %). Detailní zprůměrované výsledky klasifikace po křížové validaci jsou znázorněny maticemi záměn.

Model v průměru správně klasifikoval 99 % událostí se zkratem, jedno procento těchto událostí klasifikoval chybně jako přetížení se špatným koncem. Dále model správně klasifikoval 94 % událostí se špatným koncem (3,7 % událostí chybně odhadoval jako zkrat a 2,5 % chybně jako dobrý konec). Události, které obsahovaly přetížení s dobrým koncem, odhadoval správně v 94 % (3,7 % těchto událostí špatně odhadoval jako špatný konec a 2,2 % jako zkrat).



Obrázek 2 Matice záměn

Návod k použití

Software je používán s programovacím jazykem Python a je rozdělen do dvou souborů. Prvním z nich je skript `coupling_control.py`, který zahrnuje potřebnou funkci pro výpočet energie a predikci stability chodu. V druhém souboru `model.json` je uložen natrénovaný model strojového učení, který je automaticky načítán.

Načtení funkce:

- `from coupling_control import get_prediction`

Volání funkce:

- `Y = get_prediction(signal, event_number, folder_name)`

Funkci je nutné zavolat ve chvíli, kdy dojde k významnému poklesu napětí v síti.

Vstupní parametry:

- `signal = {ndarray: (6, 600)}`

Matice hodnot navzorkovaného signálu. První řádek v matici obsahuje vzorky první fáze prvního uzlu. S dalšími řádky navazují druhá a třetí fáze. Od třetího řádku jsou pak uloženy vzorky napětí jednotlivých fází na druhém uzlu v síti ve stejném pořadí. V posledním sloupci se nachází vzorky v čase významného poklesu napětí a v prvním sloupci vzorek nesoucí napětí v čase 0,15 vteřin před tímto poklesem. Šest set vzorků odpovídá vzorkovacímu kmitočtu 4 kHz, se kterým byl vzorkován signál využitý k trénování

predikčního algoritmu. Počet vzorků může být i větší, je však potřeba, aby zaznamenaný signál odpovídal čase 0,15 vteřin. Nižší počet vzorků negativně ovlivňuje úspěšnost predikce.

- `event_number = {int}`

Číselné označení události. Tato informace je zahrnuta v názvu souboru, který se ukládá po každém výskytu napěťové události, a jsou zde uloženy výsledky predikce s popisem.

- `folder_name = {str}`

Název složky, ve které se budou ukládat soubory s metadaty.

Výstupní parametr:

- `Y = {int}`

Pokud je výstupem nula, tak je predikováno přetížení v síti, které lze bezpečně řešit provozními manipulacemi. V případě hodnoty jedna jde o přetížení, v jehož případě je provádění manipulací nebezpečné a mělo by být blokováno. Pokud je výstup rovem dvěma, tak se jedná o zkrat a manipulace by rovněž neměly být prováděny.

Metadata:

Přesný čas výskytu události, výsledky predikce (jednotlivé pravděpodobnosti), klasifikovaná událost a její popis jsou následně uloženy ve formátu `.json` pojmenovaném jako `Ax-D`, kde `x` je pořadí události a `D` reprezentuje datum a čas výskytu. Soubory jsou ukládány do složky pojmenované podle vstupního parametru `folder_name`.

- Příkladový soubor `A1-13_08_2022-13_58_10.json`:

```
{ "time": "13/08/2022 13:58:10:821025",  
  "p0": 0.983,  
  "p1": 0.013,  
  "p2": 0.004,  
  "predicted class": 0,  
  "description": "Enable the coupling" }
```

Požadavky

Software:

- Programovací jazyk Python verze 3.10.2
- Externí knihovny a jejich verze:

numpy==1.23.2
scikit_learn==1.1.2
xgboost~=1.6.0

Licenční podmínky

Software je dostupný na základě dohody s pověřenou osobou:

Ing. Daniel Kováč
e-mail: xkovac41@vut.cz
pracovní telefon: +420 54114 6962