

# VYUŽITÍ NEURONOVÉHO MODELU TURBOGENERÁTORŮ JADERNÉ ELEKTRÁRNY TEMELÍN PRO NALEZENÍ ROZDÍLŮ V CHOVÁNÍ JEDNOTLIVÝCH SOUSTROJÍ

## NEURAL MODEL APPROACH TO IDENTIFY ANOMALIES IN TEMELÍN NUCLEAR POWER PLANT TURBINE SETS

Marek Bělohoubek, Karel Liška, Marek Bobčík, Zdeněk Kubín a Petr Polcar

Výzkumný a zkušební ústav Plzeň, s.r.o., Tylova 1581/46, 301 01 Plzeň

### Abstrakt

Príspevek popisuje využití umělé inteligence a strojového učení pro vytvoření a trénink neuronového modelu turbosoustrojí jaderné Elektrárny Temelín na základě dostupných diagnostických dat za účelem detekce odlišností v chování turbín TG1 a TG2. Následně jsou uvedeny výsledky neuronového modelování a na nich demonstrovány možnosti využití umělé inteligence v energetických aplikacích, doporučení pro praxi a upozornění na související úskalí.

### Abstract

The paper describes the use of artificial intelligence and machine learning to build and train a neural model of the turbine sets of the Temelín nuclear power plant based on available diagnostic data in order to detect anomalies and differences in the behavior of TG1 and TG2 turbines. Subsequently, the results of neural modeling are presented and they demonstrate the possibilities of using artificial intelligence in power engineering applications and recommendations for practice.

### Neuronové modelování

*Neuronové modelování (umělá inteligence, strojové učení, datová věda)* se díky dostupnosti výkonného výpočetního hardware v současnosti dynamicky rozvíjí a nalézá uplatnění v široké nejen technické praxi. Období nazývané jako „Winter AI“ je dávno pryč [1]. Vzhledem k tomu, že aplikací v energetice je v České republice doposud nemnoho, v úvodní stati čtenáři přiblížíme (s určitým technickým zjednodušením) tento moderní přístup k modelování srovnáním s modelováním fyzikálním.

Princip fyzikálního modelování je dobře známý – řešitel identifikuje technický problém, s využitím znalosti fyzikálních principů jej popíše odpovídajícími vztahy (rovnicemi) a následně využije matematický aparát, aby našel odpovídající řešení těchto rovnic. Výpočetní výkon hardware je zde využit pro řešení získaných rovnic popisujících tento fyzikální model (často s využitím některé z numerických metod – např. metody konečných prvků). Můžeme zjednodušit, že známe vstupy, známe fyziku, formulujeme rovnice a hledáme výsledek.

Princip *neuronového modelování* je odlišný. Vychází ze znalosti velkého množství vstupů a odpovídajících výstupů (řešení). Výpočetní výkon hardware je následně využit k tomu, aby hledal vztah, který odpovídá všem dostupným sadám vstupů a výstupů. Tento proces hledání odpovídajícího modelu se nazývá *strojové učení*. Získaný model lze použít k řešení souvisejících úloh, modely získané tímto způsobem se někdy nazývají *digitální dvojčata* (digitální dvojče nějakého zařízení je ale obecně možné vytvořit i na základě fyzikálního modelu, případně kombinací obou přístupů). Pokud opět shrneme, lze říct, že známe vstupy, známe výsledek a hledáme rovnice (pozorný čtenář si porovnáním souhrnů přístupů všimne, že zdánlivě nemůžeme znát fyziku).

Využití datové vědy pro tvorbu modelů, které mohou následně predikovat chování nějakého zařízení je tedy vhodné tam, kde známe dostatečné množství kombinací podmínek provozu a výsledného chování. Klíčová energetická zařízení jsou obvykle vybavena pokročilou diagnostikou, která sbírá provozní data (z pohledu modelu jak vstupní, tak výstupní), a to dlouhodobě.

Potenciál využití datové vědy k tvorbě digitálních dvojčat klíčových zařízení a následné predikce jejich chování (abnormality, poruchy, životnost, optimalizace chodu, ...) je tedy značný.

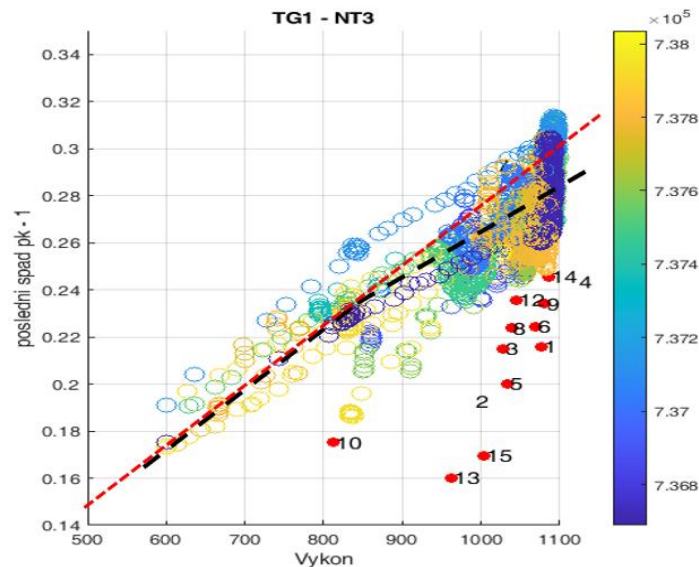
Datová věda a metody strojového učení jsou v současnosti vyučovány na řadě vysokých škol. Určitým rizikem pro vhodné nasazení datové vědy na energetických zařízeních je skutečnost, že řada datových vědců jsou profesí IT specialisté, finanční matematici apod. Přestože pro nasazení strojového učení do technické praxe není třeba znát fyzikální podstatu řešené problematiky, je vhodné, aby byly do řešitelských týmů začleňováni i odborníci na danou technickou oblast minimálně v roli odborné supervize. Kvalita vytvořených neuronových modelů je totiž silně podmíněna jak vhodnou volbou množiny vstupních parametrů, tak jejich odpovídající úpravou (filtrace dat, korekce chyb měřících přístrojů, ...). A právě tyto postupy, společně s fyzikální interpretací výsledků, již vyžadují technicky odbornou znalost zkoumaného fenoménu.

### **Motivace pro využití datové vědy na jaderné Elektrárně Temelín**

Na temelínském turbosoustrojí 1100 MW byly na nízkotlakých dílech dlouhodobě (od r. 2017) pozorovány teplotní a tlakové anomálie. Jaderná elektrárna (JE) využívá dvojici stejných parních turbín vybavených celkem šesti konstrukčně shodnými nízkotlakými (NT) díly, přesto turbína TG1 dlouhodobě dodávala nižší výkon. Turbosoustrojí je vybaveno pokročilou diagnostikou a dlouhodobě je sbíráno velké množství dat ukládané do Centrálního úložiště technických dat (CÚTD). Vzhledem k existenci podmínek nutných pro aplikaci neuronového modelu (dostupnost velkého množství vstupních a výstupních dat) bylo rozhodnuto o nasazení datové vědy s cílem porovnat chování jednotlivých soustrojí a identifikovat veličiny s negativním vlivem na chod stroje pro následnou optimalizaci. Zároveň, pro korektní sestavení a trénink neuronového modelu, byly k dispozici HBD (*Heat Balance Diagram*, teplotní bilance) soustrojí a též úzký kontakt s expertním Týmem Turbína na JE Temelín. Řešitelský tým ze společnosti Výzkumný a zkušební ústav Plzeň s.r.o. byl sestaven z pracovníků s dlouhodobými zkušenostmi s problematikou parních turbín.


### **Analýza stavu turbogenerátoru**

V prvním kroku bylo nutné provést analýzu chování obou bloků. K tomu byla natrénována první jednoduchá neuronová síť se sedmi vstupy odpovídajícími výkonu turbogenerátoru, vstupním tlakům páry na NT dílech a jedním výstupem, kterým bylo číslo HBD. Tento jednoduchý model nám dovolil rychle a efektivně porovnat oba bloky z pohledu fázování (zvyšování výkonu na intervalu 0 až 1100 MW). Mimo jiné bylo zjištěno odlišné chování TG1 NT3 během tohoto fázování. Jak ukazuje obr. 1, při 800 MW docházelo k odklonu průběhu výkonu a tlakového spádu na posledním stupni od lineárního trendu.



Obr. 1: Výstup: Tlak a výkon TG1 NT3 (barva reprezentuje čas pod dobu 3 let)

Na obdobných grafech (obr. 2) bylo dále ukázáno, že toto chování je typické zejména pro TG1 NT3, méně pak pro ostatní NT díly na TG1 a vůbec pro TG2. Již tato jednoduchá studie potvrdila předpoklady provozovatele o abnormálním chování stroje TG1.



Obr. 2: Tlak v kondenzátorech TG1 (barva reprezentuje čas pod dobu 3 let)

Výsledkem této úvodní studie bylo vytipování 66 parametrů, které byly použity jako vstupy do hlavního neuronového modelu.

### Neuronový model turbosoustrojí


Ve chvíli, kdy byla vybrána vstupní množina 66 parametrů, bylo možné zahájit tvorbu hlavního neuronového modelu simulujícího chování jednotlivých NT dílů celého turbosoustrojí. Jako požadované výstupy byly zvoleny tlakové a teplotní veličiny na výstupech příslušných NT dílů. Cílem bylo vytvořit odpovídající neuronové modely všech 6 NT dílů, jejich následné kvalitativní a kvantitativní srovnání a též lokalizace vstupních parametrů, jež jsou klíčové z hlediska vlivu na hodnoty výstupních tlakových a teplotních veličin.

S ohledem na komplexnost modelovaného systému a konkrétní specifika řešené úlohy (regresní typ výstupu, systém s pamětí, učení s učitelem) byly zvoleny dvě kvalitativně odlišné architektury neuronové sítě – konkrétně neuronová síť typu LSTM (*Long Short Term Memory*) a dopředná neuronová síť s pamětí typu FNN (*Feedforward Neural Network with Memory*).

Neuronová síť typu LSTM je rekurentní síť, přičemž jejím hlavním rysem je schopnost pamatovat si krátkodobé i dlouhodobé závislosti. Tato speciální vrstva sítě je obvykle kombinována s klasickými perceptronovými vrstvami FCI (*Fully Connected Layers*) [2].

Síť typu FNN je oproti LSTM síti koncepčně starší a využívá pouze FCI vrstev, v nichž jsou propojeny neurony ve smyslu „každý s každým“. V tomto typu síti je systémová paměť vytvářena pomocí zpětných časových vzorků vstupujících do síťových vazeb [3].

V případě obou realizovaných sítí byly pro modelování turbosoustrojí voleny dvě skryté vrstvy. Pro zvýšení výkonu (a tedy přesnosti) sítí byly provedeny preprocesní úpravy vstupních dat a též iterační optimalizace hyperparametrů neuronových modelů. Referenčním NT dílem byly v tomto případě voleny vždy prostřední ze všech dílů, kritériem optimalizace pak byla zvolena hodnota RMSE (*Root Mean Square Error*). Celkový postup práce tvorby a optimalizace neuronového modelu je znázorněn na diagramu obr. 3.

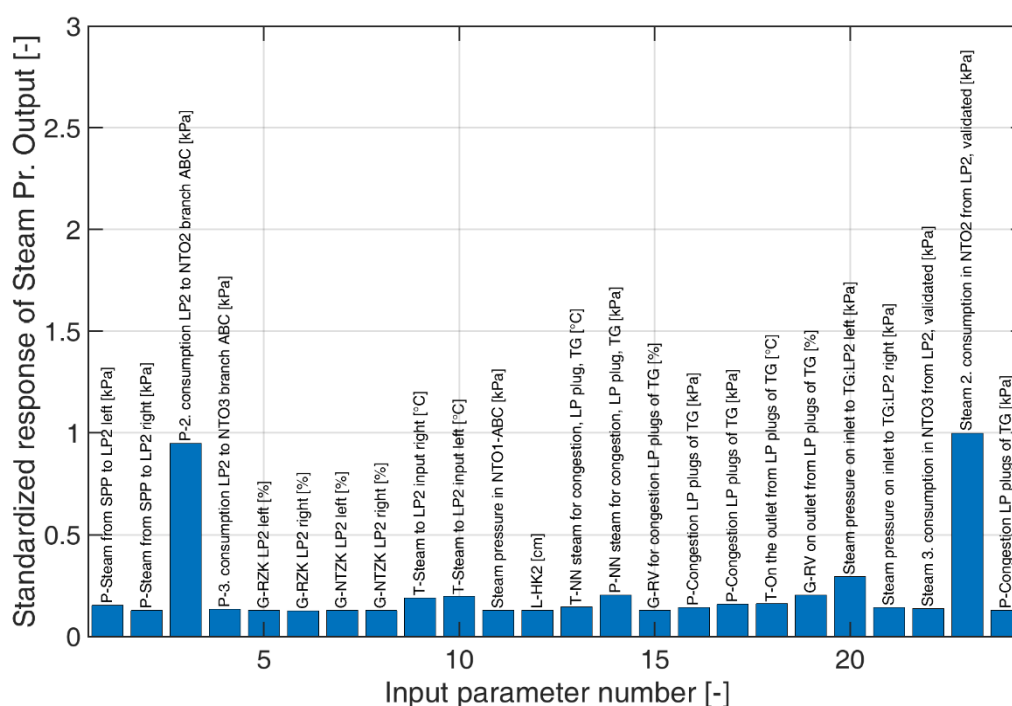


Obr. 3: Vývojový diagram pracovního postupu tvorby a optimalizace neuronového modelu

## Výstupy neuronového modelu – identifikované parametry

Jak ukázaly výsledky srovnávacích analýz skutečných a predikovaných dat, naučené modely dosahovaly dostatečné úrovně prediktivních schopností a mohli tak být použity pro kvalitativní analýzu rozdílů jednotlivých NT dílů.

Uvedená kvalitativní analýza potvrdila původní předpoklady odlišného chování jednoho z NT dílů turbíny projevující se nižší hladinou tlaku vodní páry na výstupu z NT dílu. Na základě této skutečnosti byly provedeny testy citlivosti vstupních veličin, jejichž výsledkem byla identifikace 16 parametrů s klíčovým vlivem na odlišné chování zkoumaného zařízení. Citlivostní analýza byla prováděna ve smyslu metody SHAP (*Shapley Additive exPlanations*) a její kvantitativní výstup je možné vidět na obr. 4 [4].



Obr. 4: Normalizované výsledky citlivostní analýzy veličiny tlaku vodní páry na výstupu z NT dílu v závislosti na změně vstupních parametrů

## Závěr

Díky dostupnosti diagnostických dat na JE Temelín podpořenému technickou znalostí turbosoustrojí byly vytvořeny neuronové modely simulující její chování. Přestože jsou jedno-tlívé turbíny a trojice jejich NT dílů konstrukčně shodné, jejich chování se liší. Neuronový model z široké škály dostupných měřených dat identifikoval 16 parametrů s vlivem na odlišné chování zařízení včetně jejich míry ovlivnění (obr. 4).

S využitím datové vědy je možné zpracovat obrovské množství dat a identifikovat anomálie. Přestože zkušený technik znalý zařízení anomálii studiem diagnostických dat rovněž nalezne, datová věda mu může ušetřit spoustu času (a souvisejících prostředků) tím, že předem vybere veličiny, které vykazují nestandardní chování. Datová věda má potenciál stát se užitečným nástrojem inženýra stejně, jako je tomu u ostatních již v praxi zavedených metod počítačového modelování.

Platnost predikcí získaných aplikací popsaného neuronového modelu byla potvrzena při odstávce JE Temelín v roce 2021.

## Poděkování

Tento článek vznikl s podporou projektu Národní centrum pro energetiku, TAČR TN01000007, aplikačního Segmentu 1: Účinnost, spolehlivost, bezpečnost energetických celků, dílčího projektu TN01000007/18: Vývoj diagnostických metod pro charakterizaci klíčových komponent energetických celků, pracovního balíčku Vývoj pokročilých metod komplexního hodnocení životnosti turbín.

## Literatura

- [1] Crevier, D. (1993): *AI: The Tumultuous History of the Search for Artificial Intelligence*. BasicBooks, New York. ISBN 0-465-02997-3
- [2] Hochreiter, S., Schmidhuber, J. (1997): *Long short-term memory*. Neural computation, Vol. 9, pp. 1735-1780. ISSN 0899-7667
- [3] Schmidhuber, J. (2014): *Deep learning in neural networks: An overview*. Neural Networks, Vol. 61, pp. 85-117. ISSN 0893-6080
- [4] Lundberg, S., Lee, S. (2021): *A Unified Approach to Interpreting Model Predictions*, [online]. Available at: <https://arxiv.org/abs/1705.07874>
- [5] Kander, L., Polcar, P. (2018): *Determination of the basic mechanical properties of selected materials from the results of small punch tests by using neural networks*. Certified Method, Lloyd's Register Quality Assurance.
- [6] The MathWorks Inc. (2021): *Deep Learning Toolbox*, [Online]. Natick, Massachusetts, United State. Available at: <https://www.mathworks.com/help/deeplearning/>
- [7] Świrszcz, G., Naoki, A., Aurélie, C. L. (2009): *Grouped Orthogonal Matching Pursuit for Variable Selection and Prediction*. Advances in Neural Information Processing Systems, pp. 1150-1158.