



**FAKULTA  
INFORMAČNÍCH  
TECHNOLOGIÍ  
ČVUT V PRAZE**

## ZADÁNÍ DIPLOMOVÉ PRÁCE

<b>Název:</b>	Detekce disrupcí na tokamaku pomocí strojového učení
<b>Student:</b>	Bc. Petr Prokop
<b>Vedoucí:</b>	Ing. Jakub Urban, Ph.D.
<b>Studijní program:</b>	Informatika
<b>Studijní obor:</b>	Znalostní inženýrství
<b>Katedra:</b>	Katedra aplikované matematiky
<b>Platnost zadání:</b>	Do konce letního semestru 2018/19

### Pokyny pro vypracování

Úkolem je aplikovat metody pro těžbu dat a strojového učení na experimentální data z tokamaku COMPASS.

Seznamte se s problematikou těžby dat, strojového učení a jejich využití ve výzkumu termojaderné fúze. Ve spolupráci s vedoucím práce vyberte vhodné charakteristiky experimentálních dat z tokamaku COMPASS.

Navrhňte vhodný algoritmus, využívající náhodné lesy nebo neuronové sítě, pro klasifikaci výbojů (učení s učitelem) pro detekci disrupcí.

Navržené algoritmy aplikujte na dostupná experimentální data. Z experimentálních dat vytvořte relační databázi se zvolenými příznaky. Diskutujte přesnost a spolehlivost algoritmů na vhodně vybraném validačním vzorku.

Uvedené úlohy implementujte jako knihovnu s vhodným aplikačním rozhraním. Programovacím jazykem je Python.

### Seznam odborné literatury

Dodá vedoucí práce.

Ing. Karel Klouda, Ph.D.  
vedoucí katedry

doc. RNDr. Ing. Marcel Jiřina, Ph.D.  
děkan

V Praze dne 29. ledna 2018





**FAKULTA  
INFORMAČNÍCH  
TECHNOLGIÍ  
ČVUT V PRAZE**

Diplomová práce

## **Detekce disrupcí na tokamaku pomocí strojového učení**

*Bc. Petr Prokop*

Katedra teoretické informatiky

Vedoucí práce: Ing. Jakub Urban, Ph.D.

7. května 2018



---

## Poděkování

Především bych rád poděkoval vedoucímu této práce za vedení a cenné konzultace z oblasti jaderné fúze. Dále bych rád poděkoval Danielovi Vašatovi a Pavlu Kordíkovi za konzultace z oblasti strojového učení a data miningu. V neposlední řadě bych také rád poděkoval přítelkyni, přátelům a rodině za podporu při studiu a tvorbě této práce.



---

## Prohlášení

Prohlašuji, že jsem předloženou práci vypracoval(a) samostatně a že jsem uvedl(a) veškeré použité informační zdroje v souladu s Metodickým pokynem o etické přípravě vysokoškolských závěrečných prací.

Beru na vědomí, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorského zákona, ve znění pozdějších předpisů. V souladu s ust. § 46 odst. 6 tohoto zákona tímto uděluji nevýhradní oprávnění (licenci) k užití této mojí práce, a to včetně všech počítačových programů, jež jsou její součástí či přílohou, a veškeré jejich dokumentace (dále souhrnně jen „Dílo“), a to všem osobám, které si přejí Dílo užít. Tyto osoby jsou oprávněny Dílo užít jakýmkoli způsobem, který nesnižuje hodnotu Díla, a za jakýmkoli účelem (včetně užití k výdělečným účelům). Toto oprávnění je časově, teritoriálně i množstevně neomezené. Každá osoba, která využije výše uvedenou licenci, se však zavazuje udělit ke každému dílu, které vznikne (byť jen zčásti) na základě Díla, úpravou Díla, spojením Díla s jiným dílem, zařazením Díla do díla souborného či zpracováním Díla (včetně překladu), licenci alespoň ve výše uvedeném rozsahu a zároveň zpřístupnit zdrojový kód takového díla alespoň srovnatelným způsobem a ve srovnatelném rozsahu, jako je zpřístupněn zdrojový kód Díla.

V Praze dne 7. května 2018

.....

České vysoké učení technické v Praze  
Fakulta informačních technologií

© 2018 Petr Prokop. Všechna práva vyhrazena.

*Tato práce vznikla jako školní dílo na Českém vysokém učení technickém v Praze, Fakultě informačních technologií. Práce je chráněna právními předpisy a mezinárodními úmluvami o právu autorském a právech souvisejících s právem autorským. K jejímu užití, s výjimkou bezúplatných zákonných licencí a nad rámec oprávnění uvedených v Prohlášení na předchozí straně, je nezbytný souhlas autora.*

### **Odkaz na tuto práci**

Prokop, Petr. *Detekce disrupcí na tokamaku pomocí strojového učení*. Diplomová práce. Praha: České vysoké učení technické v Praze, Fakulta informačních technologií, 2018.



---

# Abstrakt

Práce se zabývá několika metodami pro detekci disrupcí v plazmatu v jaderně-fúzních zařízeních zvaných tokamak, konkrétně jejich využití na zařízení COMPASS. První metoda je replikací slibného stávajícího přístupu využívajícího náhodné lesy a aktuální hodnoty diagnostických signálů pro predikci blížící se disrupce ve výboji. Druhý přístup je rozšířením prvního přístupu o použití předchozích hodnot diagnostických signálů. Třetí přístup pro predikci nevyužívá aktuální hodnoty diagnostických signálů, ale statistiky napočítané z časových oken těchto signálů. Poslední zkoumaná metoda využívá pro predikci pouze informace o konfiguraci experimentu a stavu tokamaku. Nejlepších výsledků bylo dosaženo druhým přístupem, který dosáhl  $F_1$ -skóre 0,867. Poslední zkoumaný přístup pak představuje zajímavou alternativu s potenciálem identifikovat klíčové parametry experimentů, které mají vliv na stabilitu plazmatu.

**Klíčová slova** autoenkodéry, COMPASS, disrupce, disperzní entropie, konfigurace výboje, tokamak, umělé neuronové sítě, jaderná fúze, náhodné lesy, strojové učení

---

# Abstract

The thesis explores several methods for disruption detection in plasma in nuclear fusion devices called tokamak, specifically their usage on COMPASS device. The first method is a replication of promising state-of-the-art approach using random forests and realtime values of diagnostic signals for prediction of imminent shot disruptions. The second method is an enhancement of the first method by inclusion of previous values of diagnostic signals as well. The third method is based on statistics computed from rolling windows of said diagnostic signals. The last method uses only configuration data of experiments and information about state of tokamak, which are available before experiments for disruption prediction. The best results were reached by the second method, with  $F_1$ -score 0,867. The last method represents an interesting alternative with potential to find key parameters of experiments that have impact on plasma stability.

**Keywords** autoencoders, COMPASS, disruptions, dispersion entropy, shot configuration, tokamak, artificial neural networks, nuclear fusion, random forest, machine learning

---

# Obsah

<b>1 Úvod</b>	<b>1</b>
1.1 Termojaderná fúze . . . . .	1
1.2 Disrupce v plazmatu . . . . .	2
1.3 Cíle práce . . . . .	3
<b>2 Současný stav</b>	<b>5</b>
2.1 Dynamické neuronové sítě . . . . .	5
2.2 SVM - APODIS . . . . .	5
2.3 Neuronové sítě . . . . .	6
2.4 Hluboké rekurentní neuronové sítě . . . . .	7
2.5 Náhodné lesy . . . . .	7
<b>3 Zdroj dat a základní předzpracování</b>	<b>9</b>
3.1 Zdroj dat . . . . .	9
3.2 Předzpracování dat . . . . .	10
3.3 Výběr vhodných výbojů . . . . .	11
3.4 Identifikace klíčových událostí během výboje . . . . .	11
3.5 Chybějící hodnoty . . . . .	14
3.6 Tvorba trénovací a testovací množiny výbojů . . . . .	14
<b>4 Replikace přístupu pomocí náhodných lesů</b>	<b>15</b>
4.1 Tvorba databáze a předzpracování . . . . .	15
4.2 Průzkum dat . . . . .	18
4.3 Tvorba modelu . . . . .	20
4.4 Vyhodnocení modelu . . . . .	22
4.5 Zhodnocení přístupu . . . . .	23
<b>5 Náhodné lesy s časovou závislostí</b>	<b>25</b>
5.1 Předzpracování dat . . . . .	25
5.2 Průzkum dat . . . . .	28

5.3	Tvorba a vyhodnocení modelů . . . . .	29
5.4	Zhodnocení přístupu . . . . .	31
<b>6</b>	<b>Přístup pomocí statistik plovoucích oken</b>	<b>33</b>
6.1	Předzpracování dat . . . . .	33
6.2	Průzkum dat . . . . .	39
6.3	Tvorba a vyhodnocení modelu . . . . .	40
6.4	Zhodnocení přístupu . . . . .	47
<b>7</b>	<b>Predikce na základě konfigurací výbojů</b>	<b>49</b>
7.1	Zdroj a předzpracování dat . . . . .	49
7.2	Průzkum dat . . . . .	53
7.3	Tvorba a vyhodnocení modelu . . . . .	54
<b>Závěr</b>		<b>55</b>
	Možná navazující práce . . . . .	56
<b>Literatura</b>		<b>57</b>
<b>A</b>	<b>Seznam použitých zkratk</b>	<b>61</b>
<b>B</b>	<b>Schéma databáze učicích vzorů</b>	<b>63</b>
<b>C</b>	<b>Obsah příloženého CD</b>	<b>65</b>

---

## Seznam obrázků

1.1	Schéma tokamaku . . . . .	2
2.1	Struktura APODIS . . . . .	6
3.1	Detekce klíčových okamžiků výboje . . . . .	12
3.2	Vývoje derivace proudu při detekci klíčových okamžiků . . . . .	13
4.1	Vývoj úspěšnosti vzhledem k pozici okna . . . . .	18
4.2	Vývoj úspěšnosti vzhledem k pozici okna . . . . .	19
4.3	Vývoj úspěšnosti při změně pozice i velikosti okna . . . . .	19
4.4	Rozdělení hodnot příznaků v závislosti na třídě . . . . .	20
4.5	Vývoj klasifikace vzorků nedisruptivního výboje v čase . . . . .	23
4.6	Vývoj klasifikace vzorků disruptivního výboje v čase. . . . .	24
5.1	Princip činnosti „SMOTE – borderline1“ . . . . .	27
5.2	Vývoj relativní důležitosti příznaků . . . . .	28
6.1	Odhadování složitosti signálu – intuice . . . . .	35
6.2	Příklad izolace dvou vzorů izolačním stromem . . . . .	38
6.3	Vývoj relativní důležitosti příznaků . . . . .	41
6.4	Příklad architektury autoenkodéru . . . . .	43
7.1	Příklad struktury konfiguračního souboru. . . . .	50
7.2	Vývoj relativní důležitosti příznaků . . . . .	53



---

## Seznam tabulek

4.1	Použité signály - náhodný les . . . . .	16
4.2	Důležitost příznaků - náhodný les . . . . .	20
4.3	Výsledky - náhodný les . . . . .	24
5.1	Popis nově vytvořených příznaků . . . . .	26
5.2	Rozšíření náhodných lesů – tabulka použitých příznaků . . . . .	29
5.3	Výsledky – převzorkování . . . . .	30
5.4	Výsledky – Wilsonova editace + SMOTE . . . . .	30
5.5	Výsledky – převzorkování + PCA . . . . .	31
6.1	Nově přidané signály . . . . .	34
6.2	Příznaky vytvořené z DFT . . . . .	36
6.3	Příznaky ze statistik hodnot časového okna . . . . .	37
6.4	Důležitost jednotlivých velikostí časových oken . . . . .	40
6.5	Důležitost jednotlivých typů statistik . . . . .	40
6.6	Důležitost jednotlivých signálů . . . . .	41
6.7	Vybraná podmnožiny příznaků . . . . .	42
6.8	Výsledky – podmnožina příznaků + náhodné lesy . . . . .	45
6.9	Výsledky – podmnožina příznaků + neuronová síť . . . . .	46
6.10	Výsledky – autoenkodér + neuronová síť . . . . .	47
7.1	Použité příznaky pro predikci . . . . .	52
7.2	Vybraná podmnožiny příznaků . . . . .	54
7.3	Výsledky - náhodný les . . . . .	54





# Úvod

Požadavky současné civilizace na množství vyráběné energie rok od roku stoupají, přičemž většina současných způsobů získávání energie využívá neobnovitelné zdroje a elektrárny využívající obnovitelných zdrojů narážejí především na problém s malou výtěžností jednoho metru čtverečního zastavěného elektrárnou nebo na problém s geografickými omezeními (geotermální a přílivové elektrárny). Z výše uvedených důvodů mají lidé potřebu hledat stále nové zdroje energie.

Jedním ze slibných přístupů je pak využívání řízené termojaderné fúze.

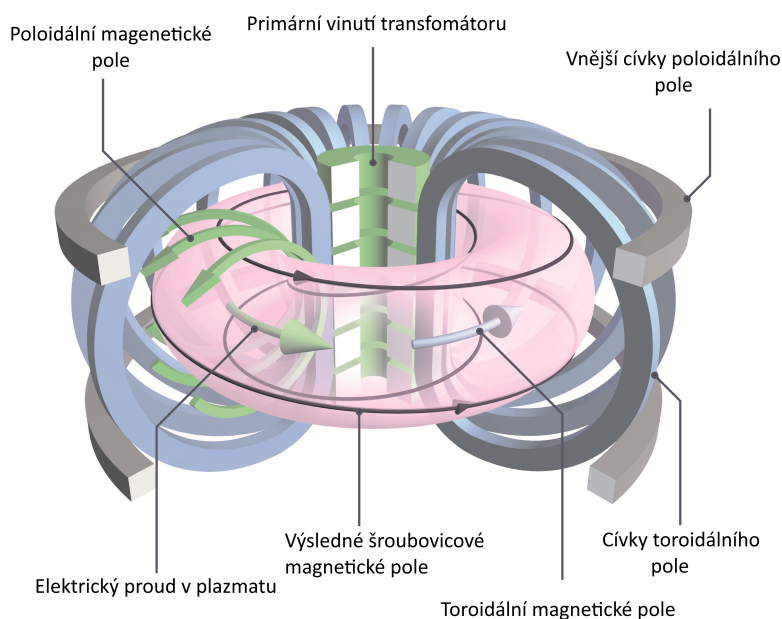
## 1.1 Termojaderná fúze

Termojaderná fúze je přírodní jev, při kterém dochází ke slučování lehkých atomových jader (typicky deuteria a tritia), který se běžně děje ve hvězdách. Pro navození fúze je třeba dosáhnout velmi vysokých teplot v řádech stovek miliónů stupňů Celsia. Na Zemi se tento proces nejčastěji snažíme uskutečnit v zařízeních zvaných tokamak (z ruského *toroidalnaja kamera s magnitnymi katuskami*), kde je plazma vytvářeno a pomocí magnetického pole udržováno v toroidálních vakuových komorách tak, aby se nedotýkalo stěn.[1]

Samotné plazma se vytváří hybridní formou ohřevu plynné palivové směsi složené z deuteria a tritia. Postupně se aplikuje ohmický ohřev (opírající se o nenulový odpor plazmatu), který plazma dokáže zahřát na několik desítek miliónů stupňů Celsia. Posléze následuje dodatečný ohřev realizovaný pomocí vstříku svazků neutrálních částic nebo je použit vysokofrekvenční ohřev.[1]

Klíčovou výhodou termojaderné fúze je skutečnost, že palivem jsou zde izotopy vodíku, které jsou na naší planetě prakticky nevyčerpatelné<sup>1</sup>. V porovnání s jaderným štěpením má fúze výhodu také v menším poločasu rozpadu tritia (12,6 let) v porovnání s izotopem uranu <sup>235</sup>U (710 milionů let). Za

<sup>1</sup>Deuterium i tritium se v přírodě vyskytují ve vodě. Nicméně tritium pouze ve stopovém množství a musí se tedy vyrábět např. štěpením lithia.



Obrázek 1.1: Schéma tokamaku [2] (upraveno)

zmínku také stojí, že k jadernému štěpení v přírodě svévolně nedochází, zatím co termojaderná fúze probíhá ve hvězdách kontinuálně po miliardy let.

Mezi hlavní důvody, které brání využití fúze pro generování energie, patří i problém s udržení vytvořeného plazmatu ve stabilní podobě po dostatečně dlouhou dobu, což úzce souvisí s předmětem této diplomové práce.

## 1.2 Disrupce v plazmatu

Disrupce jsou kritické události, kdy plazma magneticky udržované ve vakuové nádobě přestane být stabilní, dojde k jeho prudkému ochlazení, což vede ke zvýšení rezistivity plazmatu a s ním souvisejícímu prudkému poklesu elektrického proudu. Tato posloupnost událostí má za následek indukci velkých elektromagnetických sil, které spolu s prudkými změnami teploty mohou vést k vážnému poškození zařízení, nemluvě o energii nutné pro opětovnou tvorbu plazmatu. [3]

Nestability, které mohou vyústit v disrupci, se v plazmatu vyskytují přirozeně, což spolu s absencí hlubšího teoretického pochopení důvodů jejich vzniku přimělo vědce sáhnout po algoritmech strojového učení.

V ideálním případě by aplikace metod strojového učení na problém detekce disrupcí v plazmatu poskytly následující výstupy.

V první řadě by to byl systém včasného varování před nadcházející disrupcí, který ale není závislý na konkrétním typu zařízení, tj. vstupy algoritmu

jsou bezrozměrné nebo na zařízení nezávislé. Dalším požadavkem je, aby byl systém schopný generovat varování s dostatečným předstihem (v případě zařízení JET se uvádí alespoň 30 ms před očekávanou disrupcí [4]), aby bylo možné na nadcházející událost zareagovat.

Druhým žádaným výstupem by bylo odhalení dosud neznámých závislostí mezi stavem plazmatu popsaným diagnostickými signály a disrupcemi, které by v konečném důsledku vedly k lepšímu teoretickému popisu mechanismů disrupcí.

## 1.3 Cíle práce

Prvním cílem této práce je rešerše stávajících přístupů k predikci disrupcí v plazmatu na tokamacích s využitím metod strojového učení.

Následujícím cílem je výběr vhodného stávajícího postupu, jeho aplikace na data získaná z tokamaku COMPASS (COMPact ASSEMBly) a zhodnocení použitelnosti takového přístupu na tomto konkrétním zařízení.

Třetím cílem je navázání na stávající výzkum a vytvoření nového přístupu k řešení detekce disrupcí a ověření jeho funkčnosti na datech tokamaku COMPASS.



---

## Současný stav

V této kapitole se pokusím stručně shrnout dosavadní nejzajímavější a nejnovější přístupy použité pro řešení problému detekce disrupcí v plazmatu. Většina zde uvedených přístupů využívala data tokamaku JET (Joint European Torus), což je doposud největší operující zařízení.

### 2.1 Dynamické neuronové sítě

V [3] se autoři pokusili zmíněný problém řešit pomocí dynamických neuronových sítí. Přístup se opírá o predikci hodnot osmi diagnostických signálů plazmatu a o hypotézu, že zvyšující se chybovost predikce může značit blížící se disrupci.

K predikci hodnot signálů se používá dynamicky adaptovaná neuronová síť, která se na rozdíl od klasických neuronových sítí neučí z trénovací množiny, ale z předchozích vstupů. Tento přístup má tu výhodu, že nedochází ke „stárnutí“ modelu, tj. přesnost modelu nedegraduje časem. Stárnutí modelu je podle autorů způsobeno odlišnými operačními charakteristikami výbojů mimo původní trénovací data, což vede k horší úspěšnosti predikce.

Trénovací a testovací množiny výbojů jsou použity pro nastavení několika hyperparametrů modelu. Nejdůležitějšími hyperparametry byly rychlost adaptace modelu na změny signálů a práh, při kterém se označí výboj za disruptivní.

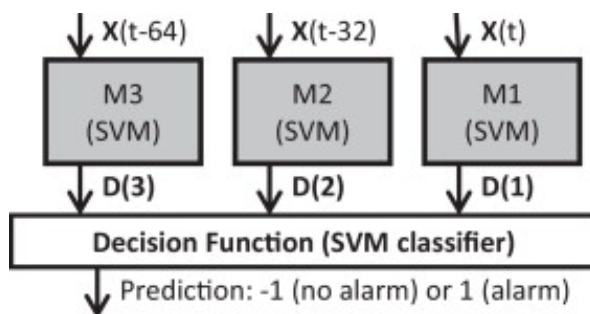
Autoři využívali data ze zařízení JET, přičemž nejlepší prezentované výsledky pro predikci disrupce s alespoň 100 ms předstihem byly 76% přesnost detekce stabilních a disruptivních výbojů při 27 % falešných poplachů.

### 2.2 SVM - APODIS

Prvním v praxi úspěšně otestovaným přístupem je APODIS [5] (Advance Predictor Of DISruptions), jehož hlavní myšlenka byla autory prvně prezentovaná

v [6].

Tento přístup se opírá o sedm vstupních signálů a čtyři SVM (Support Vector Machine) klasifikátory, které jsou organizovány do dvou vrstev (viz obr. 2.1).



Obrázek 2.1: Struktura APODIS [5]

Vstupem do SVM v první vrstvě architektury jsou data signálů rozdělená po 32 ms při 1 ms vzorkování. Z každého původního diagnostického signálu autoři počítají pro každé časové okno rozptyl složek Fourierovy transformace (vyjma prvního členu) a jejich střední hodnotu.

SVM v druhé vrstvě kombinuje výstupy první vrstvy jako vstup a provádí samotnou klasifikaci stavu plazmatu.

Autoři se v průběhu času dále věnovali rozšiřování a vylepšování tohoto přístupu například aplikací genetického algoritmu pro výběr vhodných parametrů modelu [7]. Tímto způsobem se autorům podařilo dosáhnout 91,77 % úspěšnosti detekce disrupcí s 10 ms předstihem při 3,55% chybě prvního typu (tj. falešných poplachů).

Autoři v obou případech využívali data získaná ze zařízení JET.

## 2.3 Neuronové sítě

V [9] se autoři zaměřili na predikci disrupcí s důrazem na přenositelnost modelu mezi jednotlivými zařízeními. K tomuto účelu využívali sedm vstupních signálů a jednovrstvou neuronovou síť.

Přístup byl demonstrován na tokamacích JET a ASDEX Upgrade, přičemž neuronové sítě byly učeny na datech zařízení JET a testovány na druhém zařízení. Celkem bylo použito 89 výbojů (z toho 59 s disrupcí) ze zařízení ASDEX Upgrade a 86 výbojů ze zařízení JET (z toho 68 s disrupcí).

Autoři tímto přístupem dosáhli přesnosti 67 %. Při aplikaci modelu na testovací data stejného zařízení dosáhli úspěšnosti 86 % pro tokamak JET a 90 % pro ASDEX Upgrade.

V případě zařízení ASDEX Upgrade se autoři snažili o predikci s 10 ms předstihem a v případě zařízení JET pak s 40 ms předstihem.

## 2.4 Hluboké rekurentní neuronové sítě

V [8] autoři aplikovali vrstvené LSTM (long short term memory) rekurentní neuronové sítě na obrovské množství trénovacích dat (přes 350 TB) zařízení JET a dosáhli tak dosud nejlepších výsledků.

Místo skalárních hodnot signálů jakožto vstupů do neuronové sítě se používají vektory hodnot, které jsou navíc funkcí  $\rho$  (normalizovaná radiální souřadnice), což zlepšuje možnosti přenositelnosti modelu mezi zařízeními.

Nejlepší dosažené výsledky, při predikci s alespoň 30 ms předstihem, jsou 93,5 % správně klasifikovaných výbojů, kde 7,5 % výbojů, bylo mylně označeno za disruptivní, tj. jednalo se o falešný poplach.

## 2.5 Náhodné lesy

Nejnovější zkoumaný přístup byl prezentován v [10]. Autoři zde pro detekci disruptí používají 10 bezrozměrných nebo potenciálně na konkrétním zařízení nezávislých signálů, které tvoří vstup do algoritmu náhodný les. Celkem bylo analyzováno 392 výbojů (z toho 195 s flattop disruptí) z tokamaku DIII-D.

Jakožto vstup do algoritmu autoři používají pouze hodnoty dostupné v daný okamžik, čímž se tento přístup liší, s výjimkou přístupu popsaného v [9], od všech výše zmíněných přístupů.

Autoři tímto přístupem dosáhli úspěšnosti 93,1 % u klasifikace stabilních výbojů a 87,3 % u klasifikace disruptivních výbojů.

Tento přístup byl zvolen jako první metoda použitá k predikci a je detailněji popsán dále v textu.





---

# Zdroj dat a základní předzpracování

V této kapitole se nachází popis zdroje dat použitého k tvorbě prediktivních modelů a jeho základní předzpracování.

Všechny v této práci popsané přístupy využívají data předzpracovaná níže popsaným způsobem, a případně si dále data zpracovávají podle požadavků konkrétního modelu (např. normalizace oborů hodnot příznaků nebo vyvažování tříd).

## 3.1 Zdroj dat

Jak už bylo dříve zmíněno, tak cílem této práce je využití dat získaných na tokamaku COMPASS, který je v době psaní umístěn v Ústavu fyziky plazmatu Akademie věd České republiky. [11]

Surová data, nad kterými budou probíhat datové analýzy, jsou v databázi uložena měření různých signálů získaných při realizaci jednotlivých výbojů. Jednotlivé signály jsou v databázi reprezentovány jako číselné časové řady patřící nějakému výboji, který je v databázi identifikován číselným identifikátorem. Většinu výbojů připadá zhruba tisíc signálů (např. elektrický proud plazmatem, hustota plazmatu, vyzářený výkon, atp.) vzorkovaný většinou frekvencí 2 MHz po dobu několika stovek milisekund. V surové podobě každý výboj vyžaduje řádově desítky gigabyte prostoru, což je skutečnost, která se musí řešit během předzpracování dat.

Mimo výše zmíněné databáze jsou k dispozici i data o naprogramovaných parametrech výboje, které předem zvolil operátor iniciující experiment (např. maximální proud, délka výboje nebo tvar proudu).

## 3.2 Předzpracování dat

V projektech zabývajících se analýzou dat fáze předzpracování zabere většinu úsilí a provádí se během ní kroky, které transformují surová data do podoby vhodné pro učicí algoritmy. Platí také, že předzpracování není většinou jednorázová činnost, jelikož různé přístupy a algoritmy vyžadují rozdílnou formu předzpracování.

Mezi typické kroky, které se v této fázi provádí, patří:

- ověřování konzistence dat,
- kontrola a případné nahrazování chybějících hodnot,
- odstraňování odlehlých hodnot a šumu,
- tvorba nových příznaků,
- transformace stávajících příznaků (např. normalizace, diskretizace),
- výběr vhodné podmnožiny příznaků a pozorování<sup>2</sup>,
- vyvažování tříd.

Jednotlivé v této práci prezentované přístupy k tvorbě modelů vyžadují různé způsoby předzpracování, nicméně značná část předzpracování prováděného pro účely replikovaného přístupu je shodná i pro zbývající metody.

Úkony prováděné v rámci předzpracování by se daly v této práci rozdělit do dvou hlavních skupin. První skupina úkonů souvisí s transformací surových dat do podoby relační databáze (výběr vhodných výbojů, kontrola chybějících signálů, interpolace, atp.) Druhá skupina úkonů pak souvisí s kontrolou a transformací dat, která jsou již ve standardní maticové podobě, tj. v podobě, kde sloupce tvoří příznaky a řádky jednotlivá pozorování (sem spadá detekce odlehlých hodnot, kontrola chybějících hodnot, normalizace, atp.)

### 3.2.1 Vyhlazování, interpolace a převzorkování

Jedním z prvních problémů, který bylo nutné v surových datech řešit, bylo odstraňování vysokofrekvenčního šumu, interpolace u signálů s nízkou vzorkovací frekvencí, převod na společné jednotky času (v našem případě milisekundy) a následné převedení signálů na společnou vzorkovací frekvenci.

Pro účely odfiltrování vysokofrekvenčních složek signálu byl použit Butterworthův filtr [12] s parametry nastavenými tak, aby se zachovaly frekvence nižší nebo rovny 200 kHz. Vzhledem povaze řešeného problému, tj. predikce budoucích událostí na základě aktuálního vstupu, byla jedna z požadova-

---

<sup>2</sup>Pojmy „pozorování“ a „učicí vzor“ se v této práci používají jakožto synonyma. Vždy se tím rozumí vektor s hodnotami příznaků a k němu příslušící cílová proměnná (v našem případě informace, zda pozorování patří disruptivnímu výboji.)

ných vlastností, aby filtr nevyžadoval ke své funkcionalitě data z budoucnosti (tj. aby se, v řeči zpracování signálů, jednalo o kauzální filtr).

U některých používaných signálů (signály, které se neměří přímo) byla frekvence vzorkování nižší než u ostatních. U těchto signálů bylo provedeno převzorkování na společnou frekvenci 2 MHz za použití lineární interpolace hodnot, alternativně by bylo možné použít například kubickou interpolaci.

Po provedení filtrace a interpolace bylo provedeno převzorkování z původní frekvence 2 MHz na 200 kHz.

### 3.3 Výběr vhodných výbojů

Dalším krokem předzpracování dat, jenž bylo nutné provést, byl výběr identifikátorů výbojů, které jsou vhodné pro následné učení modelu. V době psaní bylo v databázi k dispozici 16 126 výbojů, přičemž identifikátory jsou chronologicky vzestupně seřazeny (výboj č. 16 126 byl uskutečněn jako poslední).

Po domluvě s vedoucím této práce byla nastavena následující pravidla pro filtrování:

- Bylo použito pouze 7000 nejnovějších výbojů, jelikož u starších experimentů nejsou některé signály k dispozici.
- Výboje s dosaženým proudem větším než -150 kA byly zahozeny.
- Výboje s kladným proudem byly zahozeny.
- Výboje s kladným toroidálním polem byly zahozeny.
- Výboje se zapnutou rezonanční magnetickou pertubací byly zahozeny.
- Výboje s nedostupnými signály pro kontrolu výše uvedených podmínek.

Po tomto kroku zbylo 3203 výbojů pro další zpracování.

### 3.4 Identifikace klíčových událostí během výboje

Dalším krokem v předzpracování dat byla identifikace klíčových okamžiků během výboje. Jedná se o okamžik začátku a konce výboje, začátek a konec flattop fáze, případný čas disrupce a její pozici. Na grafu 3.1 je vidět průběh proudu plazmatem pro jeden výboj a jeho identifikované, výše zmíněné, okamžiky.


Na základě identifikovaných okamžiků se provádí další sada filtrování identifikátorů výbojů, konkrétně:

- Výboje s dobou trvání méně než 100 ms byly zahozeny.
- Výboje s chybějící flattop fází byly zahozeny.

### 3. ZDROJ DAT A ZÁKLADNÍ PŘEDZPRACOVÁNÍ

---

- Výboje s flattop fází kratší 30 ms byly zahozeny.
- Výboje s disrupcí mimo flattop fázi výboje (tj. během náběhu nebo poklesu proudu).



Obrázek 3.1: Detekce klíčových okamžiků výboje č. 14665. Žlutě je vyznačená detekovaná flattop fáze. Červené tečky značí začátek/konec výboje a červený křížek značí okamžik disrupce.

Detekované časy začátku a konce výboje slouží pro oříznutí přebytečných měření, která jsou přítomná u výbojů v různých délkách před a po výboji (na grafu 3.1 nalevo od první červené tečky a napravo od druhé červené tečky). Tyto hodnoty jsou rovněž použity pro synchronizaci začátku měření jednotlivých signálů – různé signály mívají různé začátky měření.


Informace o času disrupce je použita pro anotaci výboje (tj. zda se jedná o výboj s disrupcí nebo bez ní), jelikož tato informace není v surových datech přítomná a dále pro stanovení okamžiku, od kterého se budou vzorkovat učící vzory (viz další podkapitola).

#### 3.4.1 Implementační detaily

Zjišťování výše uvedených informací probíhá na základě signálu o proudu v plazmatu, a to pomocí detekce prudkých změn hodnot proudu, konkrétně

pomocí aproximace první derivace.

Na grafu 3.2 je vidět průběh proudu pro jeden konkrétní disruptivní výboj a k němu příslušící aproximace první derivace a vyznačené klíčové body.



Obrázek 3.2: Vývoj hodnoty aproximace první derivace proudu plazmatem výboje č. 14665. Žlutě je vyznačená detekovaná flattop fáze. Červené tečky značí začátek/konec výboje a červený křížek značí okamžik disrupce.

Okamžik začátku výboje je identifikován jakožto první bod, kde dojde rázově k prudkému vzrůstu velikosti proudu. Okamžik konce výboje je identifikován stejným postupem, ale při procházení hodnot v chronologicky opačném směru.

Flattop fáze byla v této práci identifikována jako nejdelší souvislá posloupnost okamžiků mezi začátkem a koncem výboje, ve kterých proud plazmatem nevykazuje žádné prudší změny. Maximální velikost povolené změny je odvozena od maximálního dosaženého proudu výboje.

Disrupce se pak detekuje pomocí prudkého poklesu proudu potenciálně nastávající někde mezi identifikovaným začátkem flattop fáze a koncem výboje.

#### 3.5 Chybějící hodnoty

Během předzpracování bylo zjištěno, že u řádově stovek výbojů nejsou k dispozici všechny signály, které by měly být vstupem do modelu, což vedlo na vyřazení patřičného výboje z další analýzy.

Mimo absence celých signálů byl v datech identifikován i menší počet výbojů, kterým chyběla část hodnot některého signálu. V tomto případě se neodstraňovaly celé výboje, ale pouze jednotlivá pozorování.

#### 3.6 Tvorba trénovací a testovací množiny výbojů

Před dalším zpracováním dat byly výboje rozděleny v poměru 80:20 na trénovací a testovací množiny pro pozdější měření kvality modelu, čímž vznikla množina 1364 učicích výbojů a množina 340 výbojů pro testování. Výboje v testovací množině se na závěr každého přístupu použijí pro nezávislý odhad kvality modelu pro porovnávání jednotlivých přístupů.

Trénovací množina je některými přístupy ještě dále dělena na množinu validační, která se použije například pro hledání vhodných hyperparametrů modelu nebo včasné zastavení učení modelu.

# Replikace přístupu pomocí náhodných lesů

Cílem této kapitoly je replikace postupu popsaného v [10], který řeší detekci disrupcí v plazmatu pomocí deseti diagnostických signálů a náhodných lesů.

Tento přístup byl zvolen ze dvou hlavních důvodů. Prvním důvodem je skutečnost, že v době psaní tohoto textu se jedná o nejnovější publikovaný přístup, který rovněž dosahuje jedněch z dosud nejlepších prezentovaných výsledků.

Dalším důvodem je, že postup využívající hluboké rekurentní neuronové sítě dosahuje pouze relativně malého zlepšení v přesnosti a vyžaduje masivní výpočetní výkon pro vytvoření modelu. Výsledný model je také prakticky nemožné analyzovat a zjišťovat tak interakce mezi vstupními příznaky.

## 4.1 Tvorba databáze a předzpracování

Autoři [10] ve svém přístupu používali k predikcím následujících deset signálů, o kterých jsou přesvědčeni, že mají velkou vypovídací hodnotu o (ne)stabilitě plazmatu. Jak už bylo dříve zmíněno, jedním z hlavních cílů je tvorba na zařízení nezávislých modelů, což se odráží i na výběru vhodných signálů, které se mohou použít (tj. signály musejí být bezrozměrné nebo jsou na bezrozměrné signály snadno převoditelné). V tabulce 4.1 se nachází seznam autory použitých signálů. Signály jsou sestupně seřazeny podle důležitosti, která byla získána z výsledného modelu.

Bohužel signály `prad_frac` a `Te_HWHM` nebyly v době psaní tohoto textu na tokamaku COMPASS k dispozici, takže veškeré následující analýzy byly prováděny na dostupných osmi signálech. Nicméně absence `prad_frac` by neměla mít zásadní negativní vliv, jelikož v autory prezentované tabulce relativních důležitostí příznaků tento signál, spolu s `n1amp`, výrazně zaostával za ostatními.

Tabulka 4.1: Použité signály

Pořadí	Název příznaku	Popis
1	q95	Bezpečnostní faktor na 95 % vedlejšího poloměru.
2	n/nG	Průměrná hustota ku Greenwaldově hustotě
3	li	Vnitřní induktance
4	betap	Poloidální beta
5	Te_HWHM	Pološířka profilu elektronové teploty v polovině maxima.
6	Wmhd	Termální energie plazmatu (poznámka: příznak není bezrozměrný a nelze jej snadno učinit bezrozměrným)
7	ip_error_frac	Poměr rozdílu proudu a předem naprogramovaného proudu ku naprogramovanému proudu.
8	Vloop	indukované napětí v plazmatu
9	prad_frac	poměr celkového vyzářeného výkonu plazmatu ku výkonu ohřevu.
10	n1amp	velikost první Fourierovy složky signálu

Z dostupných, výše uvedených, signálů byla po předzpracování vygenerována databáze učicích vzorů odpovídající schématu v příloze B (schéma poskytli autoři replikovaného přístupu).

Samotné generování učicích vzorů bylo prováděno v souladu s postupem prezentovaným autory, což v našem případě znamenalo:

- U nedisruptivních výbojů se vzorkovalo během flattop fáze každých 5 ms.
- U výbojů s disrupcí se vzorkovalo každých 5 ms až do okamžiku 80 ms před disrupcí. V tomto okamžiku se vzorkovalo každou 1 ms.

Autoři ve své práci použili jiné (několikrát větší) časové konstanty, ale pro použití jejich postupu na data menšího tokamaku COMPASS bylo nutné časy patřičně upravit.

#### 4.1.1 Odlehlé hodnoty

Po vygenerování relační databáze byl proveden další krok pro ověření kvality dat. V prvé řadě se jednalo o kontrolu přítomnosti odlehlých hodnot.

Pro detekci a odstraňování odlehlých hodnot jednotlivých signálů bylo použito pravidlo založené na mezikvartilové vzdálenosti (*interquartile range*) definované jako

$$IQR = Q_{75} - Q_{25},$$



kde  $Q_n$  je patřičný kvantil příznaku. Veškeré hodnoty menší  $Q_{25} - 3 \cdot IQR$ , respektive větší  $Q_{75} + 3 \cdot IQR$  byly z dat odstraněny.

Odlehlé hodnoty byly v našem případě způsobeny nejspíše chybami při měření signálů, ukládání dat nebo kvůli nedokonalé detekci klíčových okamžiků ve výbojích. Typickými identifikovanými problémy byly hodnoty času řádově  $9.969 \cdot 10^{39}$  nebo hodnota signálu 181 směrodatných odchylek od průměru.

Celkem bylo z dat odstraněno 4780 pozorování patřících 485 různým nedisruptivním výbojům a 349 disruptivním výbojům.

### 4.1.2 Výběr časového okna a vyvažování

Pro účely trénování modelu byla vybrána data v intervalu 40 až 85 milisekund před disrupcí u disruptivních výbojů. Z dat nedisruptivních výbojů byla vybrána náhodná podmnožina pozorování tak, aby nedošlo k nevyváženosti tříd.

Výše uvedené hodnoty byly zvoleny na základě experimentů s různými kombinacemi délek oken a pozicí okna, tj. jak daleko od okamžiku disrupce začínáme brát hodnoty v úvahu.

Na grafu 4.1 je vidět vývoj úspěšnosti predikce výbojů při změně pozice okna při zachování jeho délky 10 ms.

Na grafu 4.2 je vidět vývoj úspěšnosti predikce výbojů při změně délky okna při zachování počátečního bodu okna v okamžiku 1 ms před disrupcí.

Na grafu 4.3 je vidět vývoj úspěšnosti predikce výbojů při změně obou parametrů zároveň.

Pro účely generování grafů byla množina trénovacích výbojů rozdělena v poměru 80:20 a novou trénovací množinu a na množinu validační, na které se počítala úspěšnost jakožto průměr dvaceti  $F_1$ -skóre získaných z dvaceti modelů.

Nová trénovací data byla pro každou pozici/velikost a pro každý z dvaceti modelů v dané iteraci rozdělena stratifikovaným dělením<sup>3</sup> na 20 částí, přičemž 19 z nich se použilo k tvorbě modelu a zbylý kus se nepoužil. Toto se opakovalo dvacetkrát v každé iteraci.


Výše uvedený postup odpovídá modifikaci běžné k-násobné křížové validaci, kde se výsledné modely ověřují na nezávislé množině výbojů a ne na podmnožině dat výbojů použitých pro učení modelu.

Detaily, jakým způsobem byly jednotlivé výboje klasifikovány jsou popsány dále v části 4.4.

### 4.1.3 Závěr po předzpracování

Po provedení všech kroků předzpracování (vyjma vyvažování) zbylo v datech 41 234 pozorování z 1704 výbojů, přičemž 50 % pozorování je z disruptivních výbojů.

<sup>3</sup>Dělení, které zachovává původní poměry tříd i v podmnožinách.



Obrázek 4.1: Vývoj úspěšnosti predikce výbojů na validační množině při změně pozice okna. Na ose  $x$  jsou hodnoty odstupů od času disrupce. Prudký propad po čase 75 ms je nejpravděpodobněji způsoben prudkým úbytkem počtu disruptivních trénovacích dat.


## 4.2 Průzkum dat

Před samotnou tvorbou modelu byla provedena zběžná explorativní analýza dat za účelem odhalení vazeb mezi jednotlivými příznaky a mezi příznaky a predikovanou třídou. Nejzajímavější zjištěné výsledky jsou uvedeny níže.

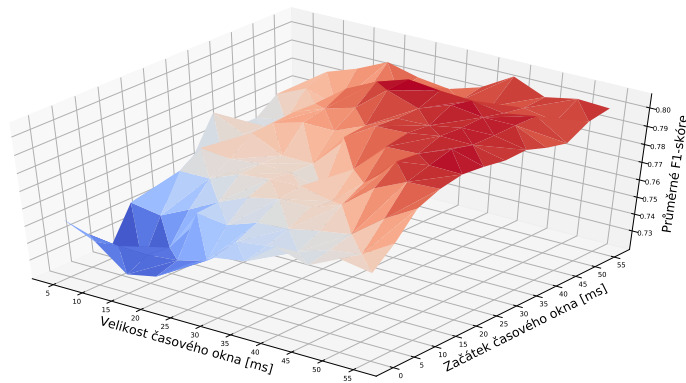
Mezi prováděné úkony patří:

- kontrola velikosti rozptylu příznaků,
- tvorba histogramů a boxplotů příznaku v závislosti na třídě,
- výpočet korelačních koeficientů příznaků Pearsonovou a Spearmanovou metodou,
- měření vzájemné informace mezi příznaky a třídou,
- odhadování užitečnosti příznaku pomocí logistické regrese (na malé podmnožině dat byly trénovány lineární modely s použitím pouze jednoho příznaku pro klasifikaci pozorování).

V tabulce 4.2 je uvedeno pořadí důležitosti jednotlivých příznaků podle kritéria vzájemné informace a podle kritéria přesnosti predikce použitím logistické regrese.

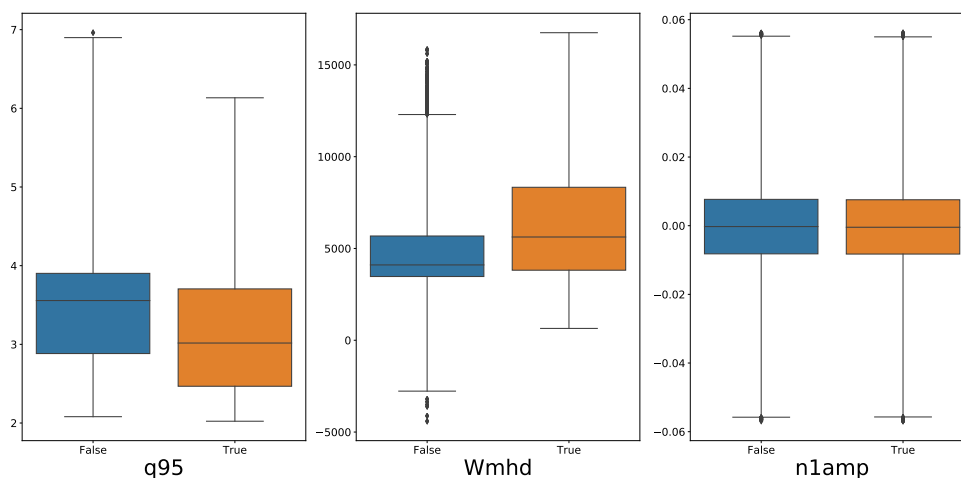


Obrázek 4.2: Vývoj úspěšnosti predikce výbojů na validační množině při změně délky okna.



Obrázek 4.3: Vývoj úspěšnosti predikce výbojů na validační množině při změně délky i pozice okna.

#### 4. REPLIKACE PŘÍSTUPU POMOCÍ NÁHODNÝCH LESŮ



Obrázek 4.4: Vizualizace rozdělení hodnot příznaků `q95`, `Wmhd` a `n1amp` v závislosti na třídě (tj. zda se jedná o disruptivní/nedisruptivní pozorování).

Na grafu 4.4 jsou pak vidět boxploty pro příznaky `q95`, `Wmhd` a `n1amp`. Na základě grafů se dá odhadnout, že `q95` a `Wmhd` mají při klasifikaci velkou diskriminační sílu, zatímco `n1amp` nikoliv.

Tabulka 4.2: Důležitost příznaků podle kritéria vzájemné informace a klasifikační úspěšnosti.

Vzájemná informace		Logistický model	
Příznak	Hodnota [nat]	Příznak	Klasifikační úspěšnost [%]
q95	0,0597	Wmhd	64,48
Wmhd	0,0442	q95	60,90
beta_p	0,0335	beta_p	60,35
Greenwald_fraction	0,0254	ip_error	57,79
ip_error	0,0176	Greenwald_fraction	57,59
v_loop	0,0089	li	56,97
li	0,0088	v_loop	52,90
n1amp	0,0001	n1amp	52,28

V této kapitole uvedená zjištění korespondují s výsledky prezentovanými v původní práci ([10]).

### 4.3 Tvorba modelu

Tato kapitola se zabývá tvorbou a vyhodnocením modelu. Jak model, tak jeho parametry parametry i metodologie učení byly převzaty od autorů replikova-

ného přístupu.

### 4.3.1 Náhodné lesy

Jakožto klasifikátor zvolili autoři algoritmus zvaný náhodný les, který byl prvně představen v [13]. Jedná se o kombinaci mnoha rozhodovacích stromů do jednoho modelu pomocí techniky založené na bagging (*bootstrap aggregating*), kde cílem kombinování modelů je především snížení „přeučení“ (vysokého rozptylu) modelu.

Každý z rozhodovacích stromů je učen na bootstrapovaném vzorku učicích dat (náhodně s opakováním vybíráme  $N$  učicích vzorů z původní množiny  $N$  učicích vzorů) a výsledkem je, v případě klasifikace, modus odpovědí. Oproti obyčejnému baggingu se navíc při každém dělení uzlu stromu bere v potaz pouze náhodná podmnožina příznaků, což dále zvyšuje rozmanitost vytvářených stromů.

### 4.3.2 Trénování modelu

Prvním krokem tvorby modelu bylo nalezení vhodných hyperparametrů algoritmu pomocí trojnásobné křížové validace (3-fold cross validation). Jediný autory uvedený hyperparametr byl počet stromů v lese, a to 500.

Nejlépšeho výsledku bylo dosaženo s následujícími hyperparametry<sup>4</sup>:

- `criterion`: `gini` (kritérium dělení vnitřních uzlů stromů)
- `max_depth`: `None` (bez omezení na maximální hloubku stromu)
- `max_features`: `5` (maximální počet náhodně vybraných příznaků v každém uzlu pro štěpení)
- `min_samples_leaf`: `15` (minimální počet pozorování v listu)
- `min_samples_split`: `15` (minimální počet pozorování potřebných pro štěpení uzlu)

Různé kombinace hyperparametrů dosahovaly  $F_1$ -skóre v intervalu od 0,65 do 0,84. Obecně se dá říci, že kritérium štěpení má na výslednou kvalitu modelu zanedbatelný vliv, zatímco vysoké hodnoty (50 a více) `min_samples_split` a omezování maximální hloubky stromů má vliv negativní.

---

<sup>4</sup>Pro vytváření modelů byla použita knihovná verze algoritmu. Konkrétně se jedná o Python balík *scikit-learn* a jeho třídu `sklearn.ensemble.RandomForestClassifier` - v následujícím seznamu byla tedy použita terminologie převzatá ze *scikit-learn*. Detailnější informace o implementaci jsou k dispozici na <http://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>

## 4.4 Vyhodnocení modelu

Vyhodnocení kvality vytvořeného modelu probíhalo na testovací sadě výbojů, kterou tvořilo 209 nedisruptivních a 131 disruptivních výbojů (tj. 38,53 % výbojů bylo s disrupcí).

Z této sady se braly vždy všechny časové okamžiky, nikoliv pouze interval 40-85 ms před disrupcí, jelikož informaci o pozici disrupce by v reálném provozu nebyla k dispozici. Vstupem do algoritmu byly jednotlivé vzorky vygenerované z výbojů (v průměru 48 vzorků z výboje), ale výstupem algoritmu byly klasifikované výboje.

Klasifikace výbojů byla provedena následujícím způsobem:

- Pokud alespoň 10 vzorků patřičného výboje bylo označeno za disruptivní, tak výboj byl označen za disruptivní.
- V opačném případě byl výboj označen za nedisruptivní.

Výše uvedený postup, kdy se výboj označí za disruptivní až při desátém disruptivním vzorku, byl zvolen jako nástroj, jak snížit vysokou míru falešně pozitivních výbojů – u drtivé většiny výbojů náhodný les označil několik jednotek vzorků za disruptivní, nehlédě na skutečnou třídu.

Na grafech 4.5 a 4.6 jsou zobrazeny klasifikace jednotlivých vzorků pro dva výboje z testovací množiny v průběhu flattop fáze. Na těchto grafech je vidět, jakým způsobem se liší množství a pozice vzorků klasifikovaných jako disruptivní pro výboj s disrupcí a bez disrupce.

Alternativně by šlo tento problém řešit zvýšením pravděpodobnostního prahu klasifikátoru pro predikci pozitivní (tj. disruptivní) třídy. V současnosti je použita hodnota 0,5, tj. klasifikátoru stačí, aby si byl „jistý“ na 50 %, že se jedná o disruptivní pozorování.

V tabulce 4.3 jsou prezentovány dosažené výsledky<sup>5</sup>.

### 4.4.1 Použité metriky kvality modelu

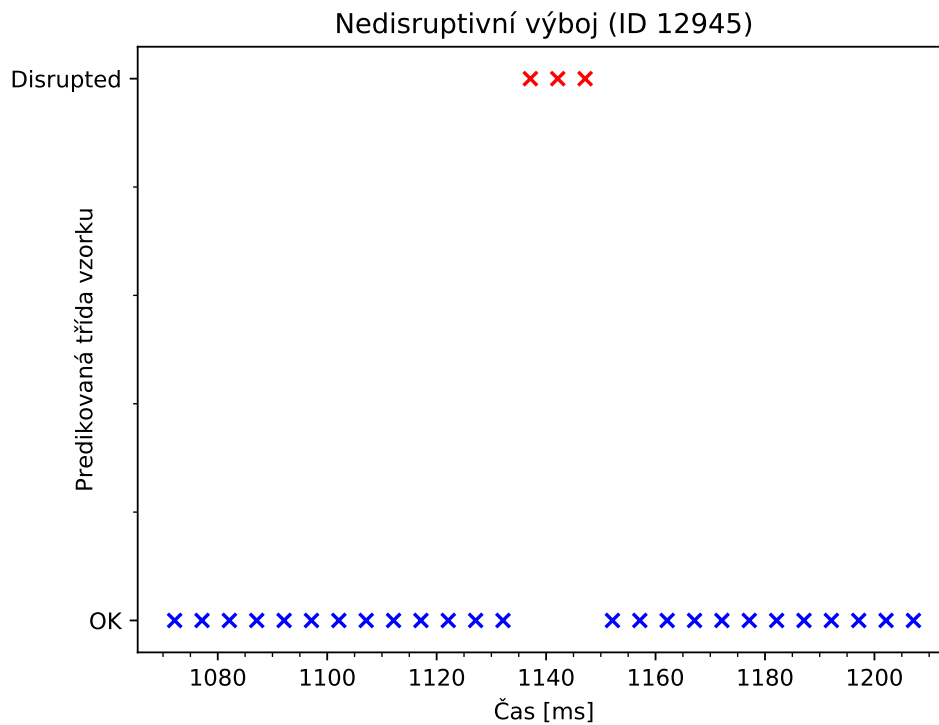
Pro vyhodnocení kvality modelu byla použita kombinace šesti standardních indikátorů, které jsou zde pro úplnost stručně představeny.

V následujícím textu je použito následující značení:

- $P$  je počet skutečně pozitivních (tj. disruptivních) výbojů
- $N$  je počet skutečně negativních (tj. nedisruptivních) výbojů
- $TP$  je počet správně predikovaných disruptivních výbojů

---

<sup>5</sup>Hodnota „celková správnost“ nemá u naší, silně nevyvážené testovací množiny velkou vypovídající hodnotu a je uváděna pouze pro úplnost. Směrodatnější v tomto ohledu je  $F_1$ -skóre.



Obrázek 4.5: Vývoj klasifikace vzorků nedisruptivního výboje během flattop fáze.

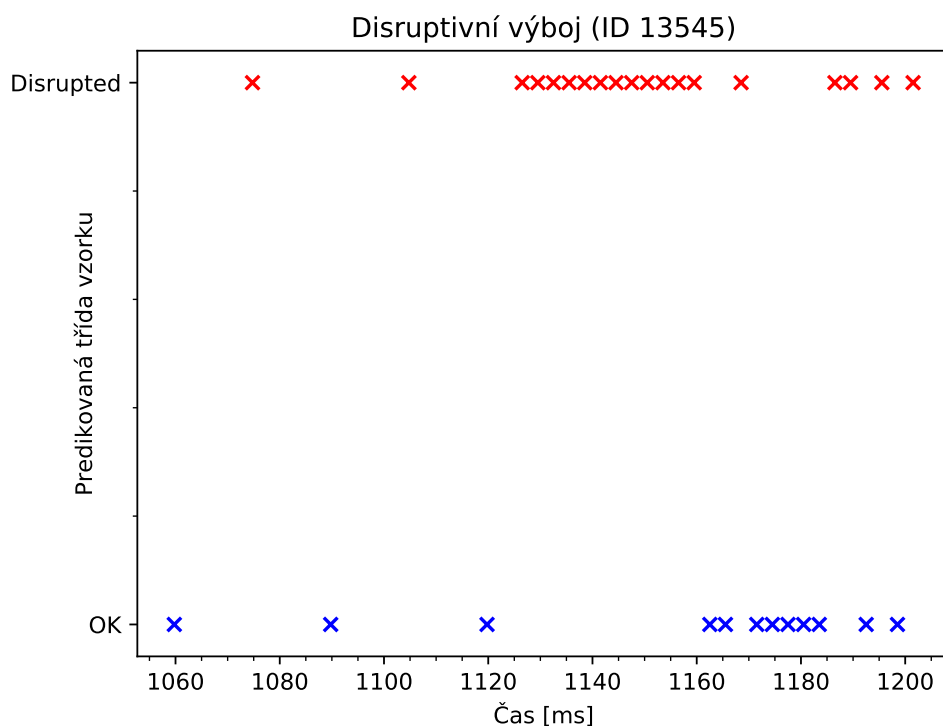
- $TN$  je počet správně predikovaných nedisruptivních výbojů

Šest použitých metrik je pak definováno následovně:

- celková správnost =  $\frac{TP+TN}{P+N}$
- úplnost =  $\frac{TP}{P}$
- přesnost =  $\frac{TP}{TP+FP}$
- falešně pozitivní =  $\frac{FP}{N}$
- falešně negativní =  $\frac{FN}{P}$
- $F_1$ -skóre =  $2 \cdot \frac{\text{úplnost} \cdot \text{přesnost}}{\text{úplnost} + \text{přesnost}}$

## 4.5 Zhodnocení přístupu

I přes dva chybějící signály se podařilo přiblížit výsledkům, které byly prezentované původními autory (při porovnávání prezentovaného  $F_1$ -skóre 0,8965).



Obrázek 4.6: Vývoj klasifikace vzorků disruptivního výboje během flattop fáze. Disrupce se u tohoto výboje nachází v čase 1206 ms.

Tabulka 4.3: Různé metriky kvality modelu a jejich hodnoty.

Kritérium	Hodnota
celková správnost (accuracy)	84,37 %
úplnost (senzitivita/recall)	89,13 %
přesnost (precision)	81,13 %
falešně pozitivní	20,57 %
falešně negativní	10,69 %
$F_1$ -skóre	0,8511

Výsledky tohoto přístupu budou v dalších kapitolách sloužit jako referenční pro další zoumané přístupy.



# Náhodné lesy s časovou závislostí

Prvním zkoumaným rozšířením replikovaného přístupu bylo přidání časové závislosti. Rozšíření bylo realizováno použitím hodnot našich 8 signálů i v časech  $t_{-3 \text{ ms}}$  a  $t_{-5 \text{ ms}}$ , ze kterých byly vytvořeny nové příznaky.

Cílem tohoto rozšíření bylo ověřit, zda se dá predikovat aktuální stav plazmatu čistě na základě aktuálních hodnot diagnostických signálů, nebo zda úspěšnost predikce benefituje z hodnot minulých.

Mimo přidání nových příznaků se v této kapitole zkoumá několik různých kombinací předzpracování za účelem zvýšení úspěšnosti modelu.

## 5.1 Předzpracování dat

Předzpracování dat je prakticky identické s postupem uvedeným v předchozí kapitole s několika výjimkami, které jsou popsány detailněji níže. Jedná se především o použití jiných technik vyvažování tříd, odstraňování šumu a redukce dimenzionality.

### 5.1.1 Tvorba nových příznaků

Z hodnot signálů v časech  $t$ ,  $t_{-3 \text{ ms}}$  a  $t_{-5 \text{ ms}}$  byly vypočítány tři nové příznaky pro každý signál, tj. z původních 8 signálů se dimenze rozšířila na 32 příznaků. Pro každý signál  $X$  byly vytvořeny příznaky, jejichž název a význam je uveden v tabulce 5.1.

### 5.1.2 Normalizace hodnot

Některé níže uvedené metody vyžadují ke své správně funkčnosti, aby jednotlivé příznaky měly řádově stejné hodnoty. Obecně jde o to, aby příznaky s velkými hodnotami v absolutní hodnotě nezastínili příznaky s malými hod-

Tabulka 5.1: Popis nově vytvořených příznaků a jejich název v programu.

Popis příznaku	Název v programu
Rozdíl hodnot $X$ v čase $t$ a $t_{-5}$ ms	$X\_diff\_t2\_t$
Rozdíl hodnot $X$ v čase $t$ a $t_{-3}$ ms	$X\_diff\_t1\_t$
Rozdíl hodnot $X$ v čase $t_{-3}$ ms a $t_{-5}$ ms	$X\_diff\_t2\_t1$

notami, což se typicky může stát u metod založených na porovnávání eukleidovské vzdálenosti.

Pro účely této práce byla zvolena  $Z$ -skóre normalizace definovaná předpisem:

$$X' = \frac{X - \bar{X}_n}{\bar{s}_n},$$

kde  $\bar{X}_n$  a  $\bar{s}_n$  jsou výběrová střední hodnota a výběrová směrodatná odchylka.

Transformovaný příznak  $X'$  má po transformaci nulovou středí hodnotu a rozptyl jedna.

### 5.1.3 Převzorkování

V předchozím přístupu byla pro vyvažování tříd použita technika, kdy se vybere z majoritní třídy náhodná podmnožina pozorování tak, aby vznikla vyvážená množina.

Problém tohoto přístupu je, že podvzorkováním majoritní třídy dochází potenciálně k zahazování užitečné informace, což může mít negativní vliv na výsledný model.

Alternativním přístupem je převzorkování (angl. oversampling) minoritní třídy, tj. výběr s opakováním tolika pozorování z minoritní třídy, aby byla množina pozorování vyvážená.


### 5.1.4 SMOTE

*Synthetic Minority Over-sampling Technique* (dále jen SMOTE) je technika pro vyvažování tříd v datech, která generuje nové instance na základě svých  $K$  nejbližších sousedů. Pro každou minoritní instanci a jejího souseda se vygeneruje nová pozorování na spojnici mezi těmito dvěma pozorováními následujícím vztahem:

$$x_{\text{new}} = x_1 + r \cdot (x_2 - x_1),$$

kde  $r \sim \text{Unif}(0, 1)$  je náhodná veličina s rovnoměrným rozdělením od 0 do 1.

Základní, výše popsany algoritmus se v průběhu času dočkal řady rozšíření. Jedním, v této práci použitým, rozšířením je i verze „SMOTE – borderline1“ popsaná v [15]. Tato verze nevzorkuje všechna pozorování minoritní třídy, ale pouze ta na rozhodovací hranici. Tímto způsobem se docílí snížení generování šumu a generování instancí, které se nepodílí na tvorbě rozhodovací hranice.



Obrázek 5.1: a) Původní nevyvážená data. b) Identifikace minoritních pozorování na rozhodovací hranici mezi třídami. c) Data s vygenerovanými novými instancemi minoritní třídy. [15]

Na obr. 5.1 je vidět ilustrace, jakým způsobem „SMOTE – borderline1“ generuje nová pozorování.

### 5.1.5 Odstraňování šumu

Některé z testovaných modelů byly vytvořeny z dat, která byla po aplikaci SMOTE očištěna o šum.

Šumem se v tomto případě rozumí pozorování, jejichž třída neodpovídá hodnotám příznaků a tím pádem tato pozorování zbytečně zesložitují rozhodovací hranici mezi třídami.

Jedním z přístupů, jak z dat šum automaticky odstranit je využití klasifikátorů citlivých na šum a pomocí nich identifikovat vadná pozorování.

V našem případě byla použita Wilsonova editace<sup>6</sup> [16], která využívá citlivosti klasifikátoru  $k$ -NN (*k*-nejbližších sousedů) při malých hodnotách  $k$  (typicky  $k = 3$ ). Pokud je instance mylně klasifikována svými  $k$  nejbližšími sousedy, tak se označí za šum.

### 5.1.6 Redukce dimenze pomocí PCA

Algoritmus PCA (*Principal Component Analysis*) je projekční metoda, která zadanou matici pozorování natočí takovým způsobem, že první osa otočeného prostoru odpovídá směru největšího rozptylu dat, druhá osa odpovídá druhému největšímu směru atd., což je dosaženo pomocí vlastních vektorů kovarianční matice příznaků (případně singulární dekompozicí matice pozorování).

Jedna z nejčastějších aplikací PCA v data miningu je redukce dimenzi-  
onalita. V tomto případě se po natočení původní datové matice ponechá  $K$

<sup>6</sup>Odstraňování šumových instancí se v data miningu nazývá editace.

dimenzí, které reprezentují nejvíce rozptylu v datech.

Na rozdíl od některých alternativních technik redukce dimenzionality, PCA nevyužívá informaci o třídě.

Interpreovatelnost výsledného modelu je i přes redukci dimenze z větší části zachována, jelikož nové osy dat odpovídají lineárním kombinacím původních příznaků.


## 5.2 Průzkum dat

Jediný rozdíl průzkumu dat, v porovnání s prvním přístupem, byl alternativní způsob hodnocení důležitosti příznaků a následný výběr vhodné podmnožiny nejužitečnějších příznaků.

Ani vzájemná informace, ani lineární model nebere v potaz vysokou korelovanost jednotlivých příznaků, a proto byla pro hodnocení užitečnosti příznaků vybrána technika založená na náhodných lesech.

V tabulce 5.2 je vidět 12 nejdůležitějších příznaků, které byly vybrány pro další práci.

Volba hodnoty 12 byla provedena na základě grafu relativních důležitostí jednotlivých příznaků, který je vidět na obr. 5.2.



Obrázek 5.2: Graf vývoje relativních důležitostí příznaků vzhledem k jejich pořadí.

K redukci dimenzionality bylo přistoupeno, jelikož velikost dimenze nově

Tabulka 5.2: Tabulka použitých příznaků pro rozšíření přístupu přes náhodné lesy a jejich pořadí vzhledem k relativní důležitosti.

Použité příznaky a jejich pořadí			
Pořadí	Název příznaku	Pořadí	Název příznaku
1.	q95	7.	ip_error
2.	Wmhd	8.	beta_p_diff_t1_t
3.	Greenwald_fraction	9.	beta_p_diff_t2_t1
4.	beta_p	10.	q95_diff_t2_t
5.	li	11.	Greenwald_fraction_diff_t2_t
6.	beta_p_diff_t2_t	12.	q95_diff_t1_t

vytvořených dat neodpovídá množství dostupných pozorování (množství pozorování by mělo s rostoucí dimenzí růst exponenciálně), což by mělo negativní důsledek na výsledný model.

## 5.3 Tvorba a vyhodnocení modelů

V této podkapitole se nachází popis a výsledky tří náhodných lesů, přičemž každý model byl vytvořen z odlišně předzpracovaných dat. Modely mají společné to, že po předzpracování byly hledány vhodné hyperparametry vždy pomocí randomizované 5-ti násobné křížové validace a vyhodnocování kvality probíhalo stejně jako v původním přístupu.

### 5.3.1 Hledání hyperparametrů randomizovanou křížovou validací

Při hledání vhodných hyperparametrů modelu byl v předchozím přístup, kdy se všechny kombinace hyperparametrů vyhodnocovaly k-násobnou křížovou validací a následně se vybrala ta kombinace, jež měla nejmenší průměrnou chybu na validačních datech. Tento přístup má nicméně nevýhodu v tom, že při větším množství hyperparametrů nebo dat začíná být procházení všech kombinací výpočetně náročné.

Další nevýhodou je, že v případě že jedna konkrétní hodnota jednoho hyperparametru dává špatné výsledky nehledě na zbytek hodnot hyperparametrů, tak se provádí zbytečné testování všech kombinací zahrnující tuto hodnotu. [17]

Alternativou k procházení všech kombinací je výběr nějaké, předem zvolené podmnožiny náhodných kombinací hyperparametrů a křížovou validaci provádět pouze na této podmnožině. Vyhneme se tak oběma výše zmíněným problémům, ale za cenu nalezení potenciálně suboptimální kombinace hyperparametrů.

### 5.3.2 Model 1 - převzorkování

První model byl vytvořen z převzorkovaných dat s použitím příznaků uvedených v tabulce 5.2, výsledky jsou pak uvedeny v tabulce 5.4.

Tabulka 5.3: Model 1: Různé metriky kvality modelu a jejich hodnoty.

Kritérium	Hodnota
celková správnost (accuracy)	85,96 %
úplnost (senzitivita/recall)	91,53 %
přesnost (precision)	82,35 %
falešně pozitivní	19,62 %
falešně negativní	8,46 %
$F_1$ -skóre	0,8670

### 5.3.3 Model 2 - Wilsonova editace + SMOTE

Druhý model byl vytvořen opět s příznaky z tabulky 5.2, ale vyvažování bylo provedeno technikou „SMOTE – borderline1“. Před vyvažováním dat byl odstraněn šum pomocí Wilsonovy editace využívající 3 nejbližší sousedy.

Výsledky jsou uvedeny v tabulce 5.4.

Tabulka 5.4: Model 2: Různé metriky kvality modelu a jejich hodnoty.

Kritérium	Hodnota
celková správnost (accuracy)	84,86 %
úplnost (senzitivita/recall)	90,77 %
přesnost (precision)	81,17 %
falešně pozitivní	21,05 %
falešně negativní	9,23 %
$F_1$ -skóre	0,8570

### 5.3.4 Model 3 - převzorkování + PCA

Poslední v této kapitole uvedený model byl opět vytvořen z dat vyvážených převzorkováním, ale tentokrát s použitím všech dostupných příznaků.

Po vyvážení byla redukována dimenze dat pomocí PCA takovým způsobem, aby se zachovalo alespoň 95 % rozptylu původních dat, což vedlo redukcí 32 dimenzí vektorů na 16.

Výsledky tohoto přístupu jsou uvedeny v tabulce 5.5.

Tabulka 5.5: Model 3: Různé metriky kvality modelu a jejich hodnoty.

Kritérium	Hodnota
celková správnost (accuracy)	81,70 %
úplnost (senzitivita/recall)	89,23 %
přesnost (precision)	77,55 %
falešně pozitivní	25,84 %
falešně negativní	10,77 %
$F_1$ -skóre	0,8298

## 5.4 Zhodnocení přístupu

Nejlepších, v této kapitole dosažených, výsledků bylo dosaženo modelem vytvořeným z dat, která byla vyvážena pomocí převzorkování.

Metoda založená na převzorkování spolu s metodou využívající metod SMOTE a Wilsonovy editace dosáhly zlepšení v  $F_1$ -skóre v porovnání s původním přístupem, nicméně druhá zmíněná pouze doáhla pouze marginálního zlepšení. Jedním z možných důvodů, proč metoda založená na použití SMOTE a Wilsonovy editace zaostává za obyčejným převzorkováním může být velké množství odstraněných vzorků při editaci.

Metoda založená na redukci dimenzionality pomocí PCA dosáhla výsledků o něco horších než původní metoda, což může být způsobeno vyšší dimenzí učících dat v porovnání s ostatními metodami, případně zanedbáním důležité dimenze.





---

## Přístup pomocí statistik plovoucích oken

Poslední v této práci prezentovaný přístup se od předchozích dvou odlišuje v několika směrech. Prvním z nich je použití několika nových signálů spolu s původními signály. Druhým rozdílem je použití statistik z plovoucích oken namísto samotných hodnot signálů. Třetím rozdílem je použití jiného modelu pro predikci disruptí.

### 6.1 Předzpracování dat

Stejně jako v předchozích kapitolách i tento přístup využívá data předzpracovaná způsobem, tak jak bylo popsáno v kapitole 3. Po tomto základním předzpracování navazuje předzpracování specifické pro tento přístup, jehož popis je detailněji popsán v následujícím textu.

#### 6.1.1 Použité signály

Množina, v tomto přístupu, použitých signálů je tvořena osmi původními signály a pěti nově použitými signály.

Z původních osmi signálů nebyl použit signál `n1amp`, jelikož byl v předchozích přístupech vyhodnocen jako nejméně užitečný, a navíc kvůli jeho absenci byly z analýzy vyřazeny stovky výbojů. Signál `n1amp` se dopočítává ze čtyř dalších signálů a absence jakéhokoliv z nich znemožňuje výpočet, což je i příčina vysokého počtu vyřazených výbojů.

V tabulce 6.1 je uvedeno pět nově použitých signálů a jejich stručný popis. Celkem se tedy do analýzy zapojí 12 signálů.

Tabulka 6.1: Tabulka nově přidávaných signálů pro účely přístupu využívajících statistiky časových oken. V prvním sloupci jsou názvy signálů v databázi COMPASSu. V druhém sloupci je stručný popis významu signálu.

Název signálu	Popis
SXR	Vyzařování v oblasti měkkých Rentgenů.
all_visible_light	Vyzařování plazmatu ve viditelném spektru.
H_alpha_HFS	Vyzařování odpovídající Balmer-alpha přechodu.
Bremsstrahlung (zkráceně <i>brems</i> )	Brzdné záření.
I_plasma_Rogowski_coil_RAW	Proud plazmatem

### 6.1.2 Tvorba příznaků

Z používaných signálů byly v tomto přístupu napočítávány různé statistiky a ty byly následně použity jako příznaky, a tedy i jako vstup do modelu.

Ve všech případech se statistiky počítaly z plovoucích oken o velikosti 5 ms, 10 ms, 25 ms a 50 ms s posunem okna 5 ms u nedisruptivních výbojů a 2 ms posunem u disruptivních výbojů. Rozdílný posun vede na generování více učicích dat pro disruptivní výboje, čímž se snižuje nevyváženost počtu vzorů disruptivních a nedisruptivních výbojů. Obdobná technika byla použita i autory replikovaného přístupu (kapitola 4).

Jednotlivé počítané statistiky jsou detailněji popsány níže.

#### Disperzní entropie

Jako jeden z potenciálně užitečných příznaků odvozených z naměřených dat byla zvolena disperzní entropie [18].

V jádru se jedná o aplikaci Shannonovy informační entropie na časovou řadu, která byla předem diskretizována v oboru hodnot (tj. byla provedena kvantizace).

Výpočet se skládá z následujících kroků:

1. Zobrazení vstupního vektoru  $\mathbf{x} = (x_1, x_2, \dots, x_N)$  na vektor  $\mathbf{y} = (y_1, y_2, \dots, y_N)$ , jehož hodnoty jsou z intervalu  $\langle 0, 1 \rangle$ . Zobrazení bylo v našem případě realizováno pomocí normální distribuční funkce, ale lze použít i výpočetně jednodušší lineární mapování.
2. Přirazení hodnot z  $\mathbf{y}$  do jedné z  $c$  tříd ( $c$  je parametr výpočtu), čímž vznikne nový vektor  $\mathbf{z}$ . V našem případě je tento krok realizován vztahem  $\mathbf{z} = \text{round}(c \cdot \mathbf{y} + 0, 5)$ .
3. Vytvoření posloupností délky  $m$  ( $m$  je parametr výpočtu), obsahující

čísla  $1, 2, \dots, c$ , z vektoru  $\mathbf{z}$ . Teoreticky tedy může ve vstupním vektoru existovat až  $c^m$  různých posloupností reprezentující dynamiku signálu.

4. Výpočet relativních počtů jednotlivých posloupností, získaných v předchozím kroce, v zadaném vektoru  $\mathbf{x}$ .
5. Výpočet entropie ze získaných pravděpodobností jednotlivých posloupností. Volitelně lze výslednou entropii normalizovat do intervalu  $\langle 0, 1 \rangle$  vydělením hodnoty maximální teoretickou hodnotou entropie, tj. hodnotou  $\log(c^m)$ .

Parametry výpočtu byly zvoleny na základě doporučení autorů přístupu, konkrétně  $c = 6$  a  $m = 4$ .

Příznaky vytvořené pomocí této statistiky jsou v programu označeny příponou `_dispersion_entropy` u názvu signálu, ze kterého byla disperzní entropie napočítána.


### Odhad složitosti signálu

Jako další příznak byl zvolen odhad složitosti (*Complexity Estimation*) signálu v daném časovém okně, který byl prezentován autory v [19] a je vypočítán vztahem 6.1, kde  $X$  je posloupnost hodnot délky  $n$ .

Podle autorů se dá složitost zkoumaného signálu odhadnout na základě vztahu 6.1, který se opírá o fyzikální intuici – po „roztažení“ dvou různě složitých signálů do podoby úsečky bude ten složitější delší. Tato intuice je znázorněna na obr. 6.1.

$$CE(X) = \sqrt[2]{\sum_{i=1}^{n-1} (x_i - x_{i+1})^2} \quad (6.1)$$

Příznaky vytvořené pomocí této statistiky jsou v programu označeny příponou `_ce` u názvu signálu, ze kterého byl odhad složitosti napočítán.



Obrázek 6.1: Intuice za výpočtem odhadu složitosti signálu. Vpravo jsou zobrazeny původní signály/časové řady. Vlevo pak jejich „roztažené“ verze spolu s hodnotou odhadu složitosti (na ose). [19]

Tabulka 6.2: V prvním sloupci je popis statistik, které byly vytvořeny ze složek diskrétní fourierovy transformace. V druhém sloupci je pak přípona příznaků, které byly vytvořeny z těchto statistik.

Příznak	Označení (přípona)
Střední hodnota	<code>_dft_mean</code>
Směrodatná odchylka	<code>_dft_std</code>
Šikmost	<code>_dft_skew</code>
Špičatost	<code>_dft_kurtosis</code>

### Statistiky z diskrétní Fourierovy transformace

Autoři přístupu APODIS (který byl dříve popsán v 2.2) použili jakožto vstup do klasifikátoru střední hodnotu a směrodatnou odchylku složek z diskrétní Fourierovy transformace (vyjma první složky) a tyto statistiky byly zahrnuty i v tomto přístupu.

Kromě střední hodnoty a směrodatné odchylky byly navíc zahrnuty i statistiky šikmost a špičatost jakožto potenciálně užitečné.

V tabulce 6.2 jsou uvedeny názvy příznaků vygenerovaných na základě těchto statistik.

### Lineární trend

Jako další potenciálně užitečná statistika byla zvolena směrnice proložené přímkou hodnotami okna. Hodnota směrnice byla vypočtena pomocí metody nejmenších čtverců na datech daného časového okna.

Tato statistika je označena v programu příponou `_linear_coeff` u názvu signálu, ze kterého byla napočítána.

### Vzájemná informace

Mimo statistik počítaných pouze z hodnot jednoho signálu byly použity i hodnoty vzájemné informace mezi kombinacemi čtyř nejvýznamnějších signálů z předchozích přístupů (`q95`, `Whmd`, `beta_p` a `Greenwald_fraction`).

Příznaky vzniklé v tomto kroku mají tvar `MI_X_Y`, kde `X` a `Y` jsou výše zmíněné signály.

Celkem bylo takto vygenerováno 6 nových příznaků.

### Základní statistiky

Mimo výše zmíněné statistiky byly z oken napočítávány i jednodušší statistiky, které jsou uvedené v tabulce 6.3.

Tyto statistiky závisí na absolutní velikosti hodnot signálů a nejsou tedy napočítávány ze signálů, které nejsou bezrozměrné.

Tabulka 6.3: Základní statistiky vypočítávané z hodnot v časovém okně. Ve druhém sloupci jsou uvedeny přípony používané v programu pro odlišení příznaků vytvořených pomocí příslušné statistiky.

Příznak	Označení (přípona)
Průměrná hodnota	<code>_mean_value</code>
Rozptyl hodnot	<code>_variance_value</code>
5% kvantil hodnot	<code>_q5_value</code>
95% kvantil hodnot	<code>_q95_value</code>

### 6.1.3 Chybějící hodnoty

Chybějící hodnoty byly detekovány pouze na úrovni celých signálů, v rámci jednoho signálu nebyly identifikovány žádné chybějící hodnoty. Kvůli absenci některého ze signálů bylo vyřazeno celkem 142 výbojů (velkou měrou kvůli chybějícímu signálu *Bremsstrahlung*)

### 6.1.4 Výběr časového okna

Stejně jako v přechozích přístupech se pro účely tvorby modelu brala pouze pozorování z určitého intervalu před disrupcí (u nedisruptivních výbojů se ponechávají všechna pozorování).

Pomocí techniky představené v 4.1.2 bylo vybrán časový interval 20 ms až 75 ms před disrupcí.

### 6.1.5 Odlehlé hodnoty

Bezpochyby největší problém tvořily při předzpracování dat odlehlé hodnoty.

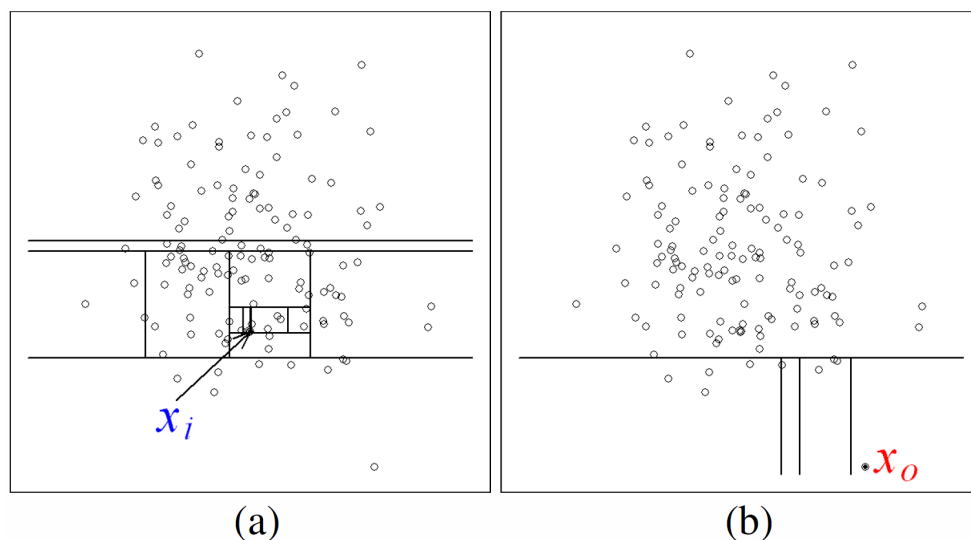
V případě použití přístupu pro detekci odlehlých hodnot pomocí metody založené na mezikvartilové vzdálenosti, která byla detailněji popsána v 4.1.1, bylo odstraněno 20 410 vzorů z celkem 1334 výbojů (celkem 84 % všech vzorů). Při použití benevolentnější hranice  $5 \cdot IQR$  tvořily odstraněné učící vzory 62 % původního počtu.

Tento problém vznikl z důvodu vysokého počtu příznaků – alespoň v jednom příznaku byla odlehlá naprostá většina učících vzorů. Další možný důvod je porušení předpokladu normality rozdělení hodnot, což bylo vizuálně zjištěno z histogramů některých příznaků.

### Izolační les

Z výše popsaných důvodů bylo přistoupeno k alternativní formě hledání odlehlých hodnot. Konkrétně byla zvolena technika *Isolation Forest*, která je detailněji popsána v [20].

Hlavní myšlenkou tohoto přístupu je využití průměrných délek cest rozhodovacích stromů náhodného lesa potřebných k izolaci každého učícího vzoru



Obrázek 6.2: Příklad izolace dvou vzorů pomocí izolačního stromu. Vlevo je příklad dělicích hranic potřebných k izolaci normálního vzoru. Vpravo je příklad rozhodovacích hranic potřebných pro izolaci odlehle hodnoty. [20](upraveno)

od zbytku vzorů. Izolace jednotlivých vzorů probíhá tvorbou speciální verze binárních rozhodovacích stromů – *izolačních stromů*, kde se uzly stěpí na základě hodnot jednoho, v každém uzlu náhodně vybraného, příznaku dokud nejsou všechny vzory izolovány (na obr. 6.2 je příklad izolace dvou vzorů).

Autoři algoritmu vychází z pozorování, že odlehle hodnoty mají tendenci mít kratší průměrnou délku cest než běžné hodnoty, což umožňuje jejich následnou detekci.

Nespornou výhodou algoritmu je skutečnost, že se neopírá o výpočet vzdálenosti vzorů, takže není nutné data předem normalizovat pomocí odhadů středních hodnot a směrodatných odchylek, které mohou být odlehlými hodnotami silně zkreslené.

Celkem bylo tímto způsobem z dat odstraněno 6567 pozorování patřících 321 různým nedisruptivním výbojům a 146 disruptivním výbojům.

### 6.1.6 Vyvažování tříd

Pro vyvažování dat byla použita technika převzorkování, jelikož se jednalo o techniku podílející se na modelu s doposud nejlepším  $F_1$ -skóre.

Původní data byla nevyvážena v neprospěch disruptivních vzorů, což bylo způsobeno především menším počtem disruptivních výbojů, ale také menší průměrnou délkou flattop fáze.

Před vyvažováním tříd obsahovala data 967 nedisruptivních výbojů a 348

disruptivních výbojů (procentálně 26.46 % všech výbojů). Celkem bylo v datech 16 933 nedisruptivních pozorování a 5574 disruptivních pozorování.

### 6.1.7 Závěr po předzpracování

Po předzpracování (před vyvažováním) obsahovala trénovací data 22 507 vzorů z 1315 výbojů. I přes vyřazení signálu `n1amp`, který byl v předchozích přístupech častou příčinou vyřazení výbojů pro jeho absenci, je celkový počet použitých výbojů nižší, než u předchozích dvou přístupů. To je způsobeno absencí některých nových signálů uvedených v 6.1 a odstraňováním odlehlých vzorů u výbojů s malým počtem vygenerovaných vzorů, které vedlo na odstranění celého výboje.

Oproti předchozím dvěma přístupům chybí data 389 výbojů, které nicméně chyběly zhruba stejným poměrem jak z původní trénovací množiny, tak z testovací množiny. Z tohoto důvodu nebylo nutné přistoupit k opětovnému dělení výbojů do nových trénovacích a testovacích množin a byly použity množiny z kapitoly 3.

Po vygenerování všech nových příznaků je dimenze jednotlivých vzorů 472. Toto velké číslo se v následujícím textu bude redukovat pomocí dvou odlišných metod.

## 6.2 Průzkum dat

V porovnání s předchozími přístupy byla explorativní analýza dat ztížena vysokou dimenzí dat, což znemožňovalo tvorbu např. korelačních diagramů (angl. pairwise scatter plot) a korelačních matic.

### 6.2.1 Důležitost příznaků

K určení důležitosti jednotlivých příznaků byl, stejně jako v předchozí kapitole, použit opět algoritmus založený na náhodných lesech, který byl použit i v předchozí kapitole.

Na základě získaných relativních důležitostí příznaků bylo vytvořeno několik souhrnných tabulek, které příznaky analyzují z různých aspektů. Pro účel tvorby tabulek bylo bráno v potaz vždy horních 100 příznaků (z celkových 528).

V tabulce 6.4 jsou procentuální zastoupení jednotlivých velikostí časových oken.

V tabulce 6.5 jsou k vidění procentuální zastoupení jednotlivých typů počítaných statistik.

V tabulce 6.6 jsou k dispozici procentuální zastoupení jednotlivých původních signálů, ze kterých se statistiky tvořily.

Tabulka 6.4: Procentuální zastoupení jednotlivých velikostí časových oken mezi horními sty příznaky s nejvyšší hodnotou relativní důležitosti.

Velikost okna	Procentuální zastoupení
50 ms	41 %
25 ms	29 %
10 ms	17 %
5 ms	13 %

Tabulka 6.5: Procentuální zastoupení jednotlivých typů počítaných statistik mezi horními sty příznaky s nejvyšší hodnotou relativní důležitosti.

Typ statistiky	Procentuální zastoupení
Průměrná hodnota	23 %
Statistiky z diskrétní Fourierovy transformace	20 %
5 % kvantil	20 %
95 % kvantil	18 %
Odhad složitosti signálu	9 %
Disperzní entropie	7 %
Rozptyl hodnot	2 %
Vzájemná informace	1 %
Lineární trend	0 %

### 6.2.2 Výběr podmnožiny příznaků

Velké množství příznaků pozorování je v této kapitole redukováno dvěma způsoby. Prvním z nich je výběr podmnožiny příznaků na základě grafu relativních důležitostí (obr. 6.3). Na základě tohoto grafu bylo vybráno pro další zpracování vybráno 14 příznaků, které jsou uvedeny v tabulce 6.7

Tyto příznaky jsou použity pro tvorbu prvních dvou modelů této kapitoly. Poslední prezentovaný model využíval všechny dostupné příznaky nehledě na jejich důležitost.


## 6.3 Tvorba a vyhodnocení modelu

V této kapitole byly celkem vytvořeny tři modely lišící se v použité technice redukce dimenzionality a použitém algoritmu strojového učení. Pro vyhodnocování kvality modelu byl použit stejný postup, jako v předchozích kapitolách (detailněji popsáno v 4.4). Jediný rozdíl je v potřebném počtu predikovaných disruptivních vzorů před označením celého výboje za disruptivní – v případě náhodného lesa byla použita hodnota 1 a v modelech založených na umělých neuronových sítích byla použita hodnota 2.



Tabulka 6.6: Procentuální zastoupení jednotlivých signálů, mezi horními sty příznaky s nejvyšší hodnotou relativní důležitosti.

Signál	Procentuální zastoupení
n_nG	17 %
Wmhd	16 %
q95	14 %
beta_p	13 %
Vloop	10 %
H_alpha_HFS	9 %
Bremsstrahlung	7 %
all_visible_light	7 %
li	4 %
ip_error_fraction	4 %
I_plasma_Rogowski_coil_RAW	0 %
SXR	0 %



Obrázek 6.3: Graf vývoje relativních důležitostí příznaků vzhledem k jejich pořadí. Pro přehlednost graf obsahuje pouze hodnoty prvních 75 příznaků.

Tabulka 6.7: Tabulka obsahuje 14 příznaků s nevyšší relativní důležitostí použitých pro první dva modely této kapitoly.

Názvy použitých příznaků	
Název příznaku	Název příznaku
brems_dft_mean_50ms	q95_q5_value_25ms
H_alpha_HFS_dft_mean_50ms	q95_q5_value_50ms
H_alpha_HFS_dft_std_50ms	beta_p_q95_value_50ms
all_visible_light_dft_mean_50ms	Wmhd_dft_mean_50ms
ip_error_fraction_q5_value_50ms	Wmhd_q5_value_50ms
Vloop_ce_50ms	Wmhd_q95_value_50ms
Vloop_q95_value_50ms	n_nG_q95_value_25ms

Vyhodnocení kvality vytvořeného modelu probíhalo na testovací sadě výbojů, kterou tvořilo 192 nedisruptivních a 72 disruptivních výbojů (tj. 27,3 % výbojů bylo s disruptcí).

Jedním z použitých algoritmů je umělá neuronová síť, která nebude dále popisována z teoretického hlediska, jelikož se jejich popis vyskytuje v nepřeberném množství literatury (tato práce čerpá především z [21]). Níže je nicméně detailněji popsán speciální příklad použití neuronových sítí pro redukci dimenzionality dat – autoenkodéry.

Dále stojí za zmínku, že fungování umělých neuronových sítí není v mnoha ohledech dosud plně pochopeno a jedná se tak o „černou skříňku“, která je nicméně velice úspěšná v mnoha doménách a často svou úspěšností překonává i dobře pochopené algoritmy, jako jsou náhodné lesy nebo SVM.


### 6.3.1 Autoenkodér

Autoenkodérem se rozumí speciální použití umělých neuronových sítí způsobem, kdy se hledá dvojice zobrazení  $f$  (enkodér) a  $g$  (dekodér) taková, že ztrátová funkce 6.2 je minimalizována. Jedna z nejčastějších ztrátových funkcí je pak definována jako průměrná čtvercová chyba mezi původními vzory a jejich rekonstrukcí (MSE – mean squared error).

$$L(\mathbf{x}, g(f(\mathbf{x}))) \quad (6.2)$$

Na obr. 6.4 je vidět příklad architektury autoenkodéru se třemi skrytými vrstvami.

V případě triviálního autoenkodéru, který má jednu skrytou vrstvu o stejném rozměru jako je vstup, se autoenkodér typicky naučí „jednotkovou matici“, tj. identické zobrazení, které přepokopíruje vstup na výstup a výsledná chyba je pak nulová. Bežně se nicméně využívají autoenkodéry s velikostí kódu (kódem se zde rozumí nízkorozměrná reprezentace vstupu po aplikaci  $f$ ) výrazně menší, než je počet vstupů (dimenze vektoru), čímž je autoenkodér



Obrázek 6.4: Příklad architektury autoenkodéru se třemi skrytými vrstvami. Prostřední vrstva reprezentuje komprimovanou formu vstupu a nazývá se často *kód*. [22] (upraveno)

nucen hledat v datech zajímavé vazby umožňující kompresi vstupu s minimální ztrátou informace.

Zobrazení  $f$  a  $g$  jsou realizována dvojicí dopředných neuronových sítí, které se učí v tandemu stejnými technikami jako „obyčejné“ neuronové sítě. Po vytvoření autoenkodéru se využívá typicky pouze zobrazení  $f$  (enkodér), které promítá vektor do prostoru výrazně nižší dimenze.

### Teorie variet

Autoenkodéry se opírají o teorii variet (angl. manifold). Ve strojovém učení tato teorie vede k hypotéze, že vysokodimenzionální reálná data (obrázky, zvuk, atp.) se koncentrují kolem nízkorozměrné variety, a má tedy smysl pokoušet se hledat projekce dat do prostoru s výrazně nižší dimenzí při minimální ztrátě informace. Za algoritmus hledající takovou projekci se dá považovat

<sup>7</sup>Regularizací se zde rozumí uprava ztrátové funkce způsobem, který vyjadřuje naši preferenci ohledně výsledné funkce realizované umělou neuronovou sítí. Nejčastěji se tímto způsobem cílí na snížení chyby na testovacích datech při zachování stejné chyby na trénovacích datech (tj. eliminaci „přeučení“ modelu).

i metoda PCA, jejíž aproximace je výstupem autoenkodéru při jeho vhodně zvolených hyperparametrech. [21]

### Řídké autoenkodéry

Jednou z verzí základních autoenkodérů jsou i tzv. řídké autoenkodéry, které pomocí vhodné formy regularizace<sup>7</sup> cílí na řídkost kódu, tj. po zobrazení každého vektoru obsahuje kód jen malé množství nenulových prvků. Tímto způsobem je autoenkodér dále nucen hledat zajímavé vlastnosti (latentní faktory) dat, a to i v případě, že velikost kódu je větší než vstup/výstup.

Regularizace v tomto případě spočívá v přičtení penalizace za „neřídkost“ kódu ke ztrátové funkci, kterou autoenkodér minimalizuje. Tento typ regularizace se dá vyjádřit vztahem 6.3.

$$L(\mathbf{x}, g(f(\mathbf{x}))) + \Omega(\mathbf{h}), \text{ kde} \\ \Omega(\mathbf{h}) = \lambda \cdot \sum_i |h_i| \quad (6.3)$$

Za pozornost stojí, že tento typ penalizace je funkcí  $\mathbf{h}$  (výstup vrstvy) a nikoliv  $\mathbf{w}$  (vektor vah neuronů vrstvy), což je běžnější forma regularizace (např. Tichonovova regularizace). Hodnota  $\lambda$  se pak stává hyperparametrem regularizovaného modelu.

#### 6.3.2 Model 1 – Náhodné lesy

První v této kapitole vytvářený model je stejně jako v přechozích přístupech založen na algoritmu náhodný les. Model se vytváří z příznaků uvedených v tabulce 6.7.

Hyperparametry modelu byly hledány pomocí randomizované pětinašobné křížové validace a nejlepších dosažených výsledků bylo dosaženo pomocí následujících hyperparametrů:

- `criterion`: `gini` (kritérium dělení vnitřních uzlů stromů)
- `max_depth`: `None` (bez omezení na maximální hloubku stromu)
- `max_features`: `5` (maximální počet náhodně vybraných příznaků v každém uzlu pro štěpení)
- `min_samples_leaf`: `5` (minimální počet pozorování v listu)
- `min_samples_split`: `10` (minimální počet pozorování potřebných pro štěpení uzlu)

Výsledky, kterých bylo tímto přístupem dosaženo na testovacích datech, jsou uvedeny v tabulce 6.8.

Tabulka 6.8: Model 1: Různé metriky kvality modelu a jejich hodnoty.

Kritérium	Hodnota
celková správnost (accuracy)	79,64 %
úplnost (senzitivita/recall)	83,56 %
přesnost (precision)	77,48 %
falešně pozitivní	24,26 %
falešně negativní	16,44 %
$F_1$ -skóre	0,8041

### 6.3.3 Model 2 – Umělá neuronová síť

Druhý model představený v této kapitole využívá rovněž příznaky z tabulky 6.7, ale jakožto klasifikátor využívá umělou neuronovou síť.

Před použitím neuronové sítě byly hodnoty příznaků normalizovány pomocí  $F_1$ -skóre normalizace, aby se předešlo případným problémům při učení způsobených různými škálami jednotlivých příznaků (nicméně normalizace dat není v případě neuronových sítí nezbytně nutná).

Výsledný model byl vytvořen pomocí následujících hyperparametrů:<sup>8</sup>

- skryté vrstvy: 3 vrstvy, každá s 16 skrytými neurony (volba vychází z praktických poznatků využívání neuronových sítí – vícevrstvé modely s vysokou kapacitou a vhodně zvolenou regularizací mají tendenci překonávat jednovrstvé modely [21])
- algoritmus učení: *Adam* (upravená verze základního algoritmu gradientního sestupu, která se pomocí „setrvačnosti“ gradientu snaží řešit problémy s uváznutím ve špatném lokálním optimu.)
- aktivační funkce skrytých neuronů: *ReLU* (Rectified Linear Unit – po částech lineární funkce)
- aktivační funkce výstupního neuronu: *logistická funkce*
- regularizace vah:  $L^2$  s  $\lambda = 0,01$  (tj. ke ztrátové funkci se přičítá  $\lambda \mathbf{w}^T \mathbf{w}$ , kde  $\mathbf{w}$  je vektor vah neuronů).

Volba hyperparametrů byla prováděna experimentálně na základě všeobecných doporučení a vlastních zkušeností. Hledání optimálních hyperparametrů by bylo vzhledem obrovskému množství kombinací (počet a velikosti skrytých vrstev, aktivační funkce, typy a hodnoty regularizací, optimalizátory, atp.) výpočetně velice náročné.

Před tvorbou modelu byla trénovací data rozdělena v poměru 80:20 na nová

<sup>8</sup>Pro vytváření modelů byla použita knihovná verze algoritmu. Konkrétně se jedná o Python balík *keras*. Detailnější informace o implementaci jsou k dispozici na <https://keras.io>

Tabulka 6.9: Model 2: Různé metriky kvality modelu a jejich hodnoty.

Kritérium	Hodnota
celková správnost (accuracy)	80,53 %
úplnost (senzitivita/recall)	86,30%
přesnost (precision)	77,37 %
falešně pozitivní	25,24 %
falešně negativní	13,70 %
$F_1$ -skóre	0,8159

trénovací a validační data. Validační data byla použita pro včasné zastavení učícího procesu a skládala se z učících vzorů 142 nedisruptivních výbojů a 53 disruptivních výbojů.

V tabulce 6.9 jsou uvedeny dosažené výsledky tímto přístupem na testovacích datech.

### 6.3.4 Model 3 – Autoenkodér + umělá neuronová síť

Poslední vytvářený model využívá všechny dostupné příznaky (celkem 472) pozorování, jejichž dimenze je redukována řídkým autoenkodérem. Po redukcii dimenzionality byly učící vzory použity k učení umělé neuronové sítě.

Použitité hyperparametry autoenkodéru jsou následující:

- vrstvy a jejich velikost:  
472 (vstup) – 400 – 300 – 250 (velikost kódu) – 300 – 400 – 472 (výstup)
- algoritmus učení: *Adam*
- aktivační funkce skrytých neuronů: *ReLU*
- aktivační funkce výstupního neuronu: *lineární funkce*
- regularizace kódu:  $\lambda = 10^{-6}$

Hyperparametry neuronové sítě pro kalsifikaci byly zvoleny následovně:

- skryté vrstvy: 3 vrstvy, každá s 128 skrytými neurony
- algoritmus učení: *Adam*
- aktivační funkce skrytých neuronů: *ReLU*
- aktivační funkce výstupního neuronu: *logistická funkce*
- regularizace vah:  $L^2$  s  $\lambda = 0,01$

Jak pro učení autoenkodéru, tak pro tvorbu klasifikátoru byla použita

Tabulka 6.10: Model 3: Různé metriky kvality modelu a jejich hodnoty.

Kritérium	Hodnota
celková správnost (accuracy)	82,00 %
úplnost (senzitivita/recall)	86,30%
přesnost (precision)	79,47 %
falešně pozitivní	22,30 %
falešně negativní	13,70 %
$F_1$ -skóre	0,8274

validační množina dat stejně jako v přechozím přístupu.

V tabulce 6.10 jsou uvedeny dosažené výsledky tímto přístupem na testovacích datech.

## 6.4 Zhodnocení přístupu

Všechny modely této kapitoly dosáhly velice podobných výsledků s  $F_1$ -skóre přesahující hodnotu 0,8. Nejlepších výsledků pak bylo dosaženo přístupem využívajícím řídký autoenkodér a umělou neuronovou síť jako klasifikátor.

I přes použití několika nových signálů a neuronových sítí se ani v jednom případě nepodařilo překonat dosud nejlepší výsledek, kterého bylo dosaženo v 5.3.3.

Důvod, proč se nepodařilo předchozí přístupy překonat, by se dalo vysvětlit nejspíše výrazně menším počtem učicích vzorů. Zatímco předchozí přístupy měly k dispozici více než 40 tisíc učicích vzorů, tak modely této kapitoly měly k dispozici pouze 22 tisíc.

Úbytek pozorování lze vysvětlit především časovými okny, jejichž tvorba snížila průměrný počet pozorování na hodnotu 17,1 (u předchozích přístupů byl průměr 30,2).





# Predikce na základě konfigurací výbojů

Poslední v této práci zkoumaný přístup detekce disruptivních výbojů se oproti předchozím přístupům diametrálně odlišuje. Na rozdíl od předchodchodících přístupů se pro predikci disrupce nevyužívají diagnostické signály zpracovávané během výboje, ale pouze konfigurační parametry výboje a příznaky stavu tokamaku, které jsou známé před provedním výboje.

## 7.1 Zdroj a předzpracování dat

I tento přístup se v základu opírá o práci provedenou v kapitole 3. Konkrétně se jedná o využití 3203 výbojů splňujících podmínky uvedené v 3.3 (tj. omezení na velikost proudu, pozice disrupce, aj.), které spolu s informací o disrupci slouží jako základ pro další kroky.

### 7.1.1 Použité příznaky

Jak bylo zmíněno v úvodu kapitoly, predikce se bude opírat o informace známé před samotným výbojem. Použité příznaky se extrahovaly ze dvou hlavních zdrojů, které jsou popsány dále. Souhrn všech generovaných příznaků je uveden v tabulce 7.1.

#### Konfigurační soubory

První skupina příznaků byla extrahována z konfiguračních souborů, ve kterých operátoři tokamaku programují různé požadované parametry výboje.

Soubory s konfiguracemi výbojů jsou v COMPASSu ukládány v podobě verzovaných<sup>9</sup> textových strukturovaných souborů. Konfigurační soubory pro jednotlivé výboje jsou určeny značkami („tagy“) vytvořenými operátory při

<sup>9</sup>V době psaní práce byly soubory verzovány systémem Mercurial.

změně konfigurace, tj. dokud není pomocí tagu určeno jinak, tak platí poslední verzovaná konfigurace.

Extrakce informací z takto verzovaných souborů se pak skládala z následujících kroků:

1. Extrakce všech tagů z verzovacího nástroje. Názvy tagů zhruba odpovídají identifikátoru výboje (např. #9601 nebo 6700b). Během této fáze bylo nutné přistoupit k drobným korekcím dat, konkrétně k opravám sedmi případů, které nešly programově převést na identifikátor výboje. Jedná se například o tag #960, který byl po dohledání data a sousedních tagů opraven na #9602 nebo tag #1663416634, který byl opraven na #16634.
2. Dopředná propagace tagů pro výboje, které nemají vlastní tag.
3. Převod verzovaných souborů s konfigurací pro daný výboj na neverzovanou verzi.
4. Extrakce požadovaných informací ze strukturovaného souboru pomocí regulárních výrazů.

Výše popsaným postupem se z různých konfiguračních souborů extrahovaly informace o hodnotách předprogramovaném proudu, toroidálního magnetického pole, poloze magnetické osy ( $R_0$ ,  $Z_0$ ), hustotě proudu v plazmatu, zpětné vazbě vertikální polohy, tvaru a velikosti plazmatu. Tyto informace jsou v souborech reprezentovány jako posloupnosti intervalů, kde pro daný časový úsek jsou specifikovány hodnoty daného parametru, např. konstanta nebo lineární změna mezi začátkem a koncem intervalu. Příklad takto specifikovaného průběhu proudu plazmatem je k vidění na obrázku 7.1.

```

1 Waveform =
2 {
3     0 = { x0 = 0.0 x1 = 1010000.0
4           y0 = 0.0 y1 = 0.0
5           Interpolation = Constant }
6
7     1 = { x0 = 1010000.0 x1 = 1110000.0
8           y0 = -140000.0 y1 = -140000.0
9           Interpolation = Linear }
10
11     2 = {...}
12 ...

```

Obrázek 7.1: Příklad struktury konfiguračního souboru výboje 14043, který obsahuje předprogramovaný průběh proudu plazmatem. Hodnoty  $x$  označují časové meze intervalů. Hodnoty  $y$  pak obsahují cílové hodnoty v daném intervalu.

U většiny zkoumaných předprogramovaných veličin se jako potenciálně užitečné příznaky braly následující hodnoty:

- Maximální předprogramovaná hodnota ve flattop fázi (flattop fáze se detekovala opět z předprogramovaných hodnot a nikoliv z těch skutečných, jako tomu bylo v přechozích přístupech).
- Počet unikátních párů hodnot  $(y_0, y_1)$ , jakožto odhad složitosti předprogramovaného průběhu.

### Stav tokamaku

Druhá skupina extrahovaných informací by se dala nazvat jako stavové příznaky tokamaku. Všechny tyto příznaky byly pro každý výboj získávány ze dvou relačních databází.

Spadají sem následující příznaky:

- Počet dní uběhlých od poslední boronizace komory tokamaku.
- Počet výbojů provedených od poslední boronizace komory.
- Množství vytvořeného plazmatu ( $\int I_p dt$ ) od poslední boronizace komory.
- Počet dní od posledního otevření tokamaku.
- Tlak v komoře tokamaku.

Mimo výše zmíněné příznaky byly vytvořeny i tři další příznaky kombinací stávajících příznaků a další informace. První příznak byl indikátor, který typ polohy Z byl použit. Druhý příznak je indikátor, zda se jedná o výboj s novým zdrojem pro vertikální zpětnou vazbu. Poslední příznak je indikátor, zda je čas boronizace větší než čas otevření (tokamak je bez boronizace).

#### 7.1.2 Chybějící hodnoty

V datech získaných v předchozím kroce nebyly identifikovány žádné chybějící hodnoty na úrovni jednotlivých pozorování. Za chybějící hodnoty by se nicméně daly považovat výboje s identifikátorem menším než 10 949, jelikož pro tyto výboje chybí informace o času otevření tokamaku. Do výboje 10 830 navíc časy související s boronizací rostou nade všechny meze (výboj 10 830 má uvedeno 1129 dní a 7268 výbojů od poslední boronizace komory), což je způsobeno nejspíše chybějícími záznamy v databázi, kde se uchovávají informace o aktivitách na tokamaku.

Tabulka 7.1: Souhrnná tabulka extrahovaných příznaků použitých pro poslední model. Příznaky mající v popisu „X“ se počítají z každého programovatelného parametru.

Popis příznaku	Název v programu
Hodnota X ve flattop	X_value
Počet unikátních párů X ( $y_0, y_1$ )	X_intervals_cnt
Rychlost náběhu proudu	Ip_rampup_dt
Typ polohy Z	Z2_used
Použití nového zdroje	new_feedback
Čas boronizace je větší než čas otevření	boro_time_gt_open_time
Počet dní od boronizace	days_from_boronization
Počet výbojů od boronizace	shots_from_boronization
Množství plazmatu od boronizace	plasma_from_boronization
Počet dní od otevření	days_from_opening
Tlak v komoře	vacuum_value

### 7.1.3 Odstranění šumu

Mimo dříve zmíněných výbojů s extrémními hodnotami časů související s boronizací bylo v datech identifikováno jedno pozorování se záporným tlakem ve vakuové komoře a jedno pozorování s hodnotou vertikální zpětné vazby vybočující o desítky směrodatných odchylek od průměru.

### 7.1.4 Vyvažování tříd

Stejně jako v předchozích přístupech byla použitá data nevyvážená v neprospěch disruptivních výbojů. Po předzpracování bylo v datech 866 nedisruptivních pozorování a 596 disruptivních pozorování (tj. 40,22% pozorování bylo disruptivních).

Tento problém byl řešen metodou převzorkování minoritní třídy.

### 7.1.5 Závěr po předzpracování

Po předzpracování (před vyvažováním) dat obsahovala učící data 1482 učících vzorů s 22 příznaky. V porovnání s přechodícími přístupy je počet vzorů výrazně nižší, jelikož z každého výboje je k dispozici pouze jeden učící vzor, zatímco v předchozích metodách se z každého výboje generovaly řádově desítky vzorů.

Tato data byla rozdělena v poměru 80:20 na trénovací a testovací množiny výbojů. Celkem tak vznikla množina s 1186 učícími vzory a množina s 296 testovacími vzory.


## 7.2 Průzkum dat

Stejně jako v předchozích přístupech byla provedena základní explorativní analýza dat, primárně za účelem identifikace nejužitečnejší podmnožiny příznaků s cílem snížit dimenzionalitu dat.

Prvním zjištěním byl nulový rozptyl u hodnot velikosti plazmatu (hodnota je vždy nula). Z tohoto důvodu byly příznaky (hodnota a počet intervalů) získané z tohoto parametru vyřazeny z analýzy.

Z analýzy byl rovněž vyřazen příznak s informací o počtu dní od poslední boronizace komory, jelikož měl spolu se zbylými dvěma příznaky založenými na času od boronizace Pearsonův korelační koeficient přes 0,9 a byl tedy vyřazen jakožto nadbytečný.

K určení důležitosti zbylých příznaků byla opět použita metoda založená na náhodných lesech. Na grafu 7.2 jsou vidět pořadí relativních důležitostí příznaků získaná z této metody. V tabulce 7.2 jsou uvedeny vybrané příznaky v pořadí jejich důležitostí.



Obrázek 7.2: Graf vývoje relativních důležitostí příznaků vzhledem k jejich pořadí. Na základě tohoto grafu bylo vybráno prvních osm příznaků.

Tabulka 7.2: Tabulka obsahuje 8 příznaků s nevyšší relativní důležitostí použitých pro vytvářený model.

Pořadí	Název příznaku
1.	plasma_from_boronization
2.	shots_from_boronization
3.	days_from_opening
4.	Ip_rampup_dt
5.	Ip_value
6.	Z0_value
7.	R0_value
8.	ne_value

### 7.3 Tvorba a vyhodnocení modelu

Jediný v této kapitole vytvářený model byl založen na náhodných lesech. Nejlepší hyperparametry modelu, které byly nalezeny pětinasobnou křížovou validací, jsou následující:

- `n_estimators`: 2000 (počet vytvářených rozhodovacích stromů)
- `criterion`: `gini` (kritérium dělení vnitřních uzlů stromů)
- `max_depth`: `None` (bez omezení na maximální hloubku stromu)
- `max_features`: 3 (maximální počet náhodně vybraných příznaků v každém uzlu pro štěpení)
- `min_samples_split`: 10 (minimální počet pozorování potřebných pro štěpení uzlu)

Výsledky dosažené na testovacích datech jsou uvedeny v tabulce 7.3.

Tabulka 7.3: Různé metriky kvality modelu a jejich hodnoty.

Kritérium	Hodnota
celková správnost ( <code>accuracy</code> )	72,64 %
úplnost (senzitivita/ <code>recall</code> )	63,87 %
přesnost ( <code>precision</code> )	66,67 %
falešně pozitivní	21,47 %
falešně negativní	36,13 %
$F_1$ -skóre	0,6524

---

## Závěr

V práci bylo ve třech kapitolách vytvořeno několik modelů, jejichž cílem byla predikce disrupcí v plazmatu na tokamaku COMPASS.

První aplikovaný přístup se pokoušel replikovat nejnovější prezentovaný přístup k tomuto úkolu, který se opíral o 8 diagnostických signálů a náhodné lesy. I přes dva chybějící signály v porovnání s replikovaným přístupem se podařilo dosáhnout  $F_1$ -skóre 0,8511.

Druhý přístup byl jednoduchým rozšířením přístupu prvního. Mimo aktuální hodnoty diagnostických signálů využíval i hodnoty těchto signálů v časech 3 a 5 milisekund v minulosti. Během tohoto přístupu byly vyzkoušeny tři různé přístupy předzpracování dat, přičemž nejlepšího výsledku ( $F_1$ -skóre 0,867) bylo dosaženo výběrem podmnožiny příznaků použitých pro učení a vyvažováním tříd pomocí převzorkování.

Třetí aplikovaný přístup se od prvních dvou lišil výrazněji. První změnou bylo použití statistik vypočítávaných z časových oken jakožto příznaků pro klasifikaci výbojů. Druhou změnou bylo použití několika dalších signálů v porovnání s původními 8 použitými v předchozích přístupech. Třetí rozdíl pak spočíval ve využití umělých neuronových sítí jakožto klasifikátoru. Tento přístup vedl k slabším výsledkům, s největší pravděpodobností kvůli výrazně menšímu počtu (zhruba 1/2) učících vzorů v porovnání s předchozími přístupy.

Poslední zkoumaný přístup se od zbylých odlišoval tím, že používal pouze informace informací dostupných ještě před zahájením výboje. Tento přístup nedosáhl výsledků porovnatelných s ostatními přístupy, ale jedná se rozhodně o zajímavý alternativní přístup, který by v případě použití většího množství dat a dalších příznaků mohl sloužit jako zdroj asociačních pravidel<sup>10</sup> použitelných při programování parametrů tokamaku.

---

<sup>10</sup>Asociační pravidla jsou pravidla ve formě implikace, např. Pokud `Z0_value < -0,12`, tak disrupce na 97,5 %. Tato pravidla lze vygenerovat například i z rozhodovacích stromů.

## Možná navazující práce

Jedním z řešení, jak nepochybně zlepšit klasifikační úspěšnost, je zvětšit množství a kvalitu dat. Vytvářené modely využívaly pro své učení necelé dva tisíce výbojů, přičemž se z každého generovaly řádově desítky vzorů. Výboje, které byly k dispozici, se navíc často lišily v parametrech, při kterých výboj probíhal, což nepochybně degraduje kvalitu výsledných modelů. Ideální, ač z ekonomického a časového hlediska těžce proveditelné, by bylo vygenerovat databázi výbojů s parametry, které se budou blížit těm v reaktoru případné elektrárny, a na těchto datech provádět datové analýzy.

Další potenciálně přínosné rozšíření by mohlo spočívat v hledání nových fyzikálních vstupů do generovaných modelů. Většina aktuálních přístupů využívá podmnožinu zhruba 13 signálů a rozšíření/zlepšování modelů probíhá na úrovni metod strojového učení.

Posledním zde zmíněným rozšířením je rozšíření detekce na více typů výbojů. Aktuálně se uvažují pouze výboje splňující podmínky uvedené v 3.3, což vyřazuje z analýz např. výboje s opačným směrem proudu nebo disrupcí mimo flattop fázi.



---

## Literatura

- [1] WAGNER, Vladimír. *Kdy se bude jaderná fúze využívat pro výrobu energie?*. OSEL.CZ [online]. Telč: Osel, 2008-3-12 [cit. 2018-02-18]. ISSN 1214-6307. Dostupné z: <http://www.osel.cz/4120-kdy-se-bude-jaderna-fuze-vyuzivat-pro-vyrobu-energie.html>
- [2] *Tokamak principle* [online]. EUROfusion, 2011 [cit. 2018-02-23]. Dostupné z: <https://www.euro-fusion.org/2011/09/tokamak-principle-2/>
- [3] CANNAS, Barbara, et al. *Dynamic Neural Networks for Prediction of Disruptions in Tokamaks*. In: Proceedings of the 10th International Conference on Engineering Applications of Neural Networks (EANN). 2007.
- [4] TANG, William, et al. *Big data machine learning for disruption predictions*. In: 26th IAEA Fusion Energy Conference-IAEA CN-234, Paper Number EX/P6-47. 2016.
- [5] VEGA, Jesús, DORMIDO-CANTO, Sebastián, et al. *Results of the JET real-time disruption predictor in the ITER-like wall campaigns*. Fusion Engineering and Design. 2013, 88(6), 1228-1231. ISSN 0920-3796.
- [6] RATTÁ, G.A., VEGA, Jesús, et al. *An advanced disruption predictor for JET tested in a simulated real-time environment*. Nuclear Fusion, 2010, 50(2).
- [7] RATTÁ, G.A., VEGA, Jesús, et al. *Global optimization driven by genetic algorithms for disruption predictors based on APODIS architecture*. Fusion Engineering and Design. 2016, 112, 1014-1018. ISSN 09203796.
- [8] TANG, William. *Deep Learning Acceleration of Progress Toward Delivery of Fusion Energy* [online]. Princeton: Princeton Plasma Physics Laboratory, 2017-05-10 [cit. 2018-01-15]. Dostupné z: [https://gputechconf2017.smarteventscld.com/connect/sessionDetail.wv?SESSION\\_ID=109997](https://gputechconf2017.smarteventscld.com/connect/sessionDetail.wv?SESSION_ID=109997)

- [9] WINDSOR, C. G., et al. *A cross-tokamak neural network disruption predictor for the JET and ASDEX Upgrade tokamaks*. Nuclear fusion, 2005, 45.5: 337.
- [10] REA, Cristina, GRANETZ, Robert, MENEGHINI, Orso. *Studies of the DIII-D disruption database using Machine Learning algorithms*. In: APS Meeting Abstracts. 2017.
- [11] PÁNEK, R., O. BILYKOVÁ, V. FUCHS, et al. *Reinstallation of the COMPASS-D tokamak in IPP ASCR*. Czechoslovak Journal of Physics [online]. 2006, 56(S2), B125-B137 [cit. 2018-04-10]. DOI: 10.1007/s10582-006-0188-1. ISSN 0011-4626.
- [12] BUTTERWORTH, Stephen. *On the Theory of Filter Amplifiers*. Wireless Engineer. 1930, (7), 536–541.
- [13] BREIMAN, Leo. *Random Forests*. Machine Learning. 2001, 45(1), 5-32. DOI: 10.1023/A:1010933404324. ISSN 08856125.
- [14] CHAWLA, Nitesh V., et al. *SMOTE: synthetic minority over-sampling technique*. Journal of artificial intelligence research, 2002, 16: 321-357.
- [15] HAN, Hui, WANG, Wen-Yuan, MAO, Bing-Huan. *Borderline-SMOTE: A New Over-Sampling Method in Imbalanced Data Sets Learning*. Advances in Intelligent Computing. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005, 878-887. Lecture Notes in Computer Science. ISBN 978-3-540-28226-6.
- [16] WILSON, Dennis L. *Asymptotic properties of nearest neighbor rules using edited data*. IEEE Transactions on Systems, Man, and Cybernetics, 1972, 3: 408-421.
- [17] BERGSTRA, James, BENGIO, Yoshua. *Random search for hyperparameter optimization*. Journal of Machine Learning Research, 2012, 13.Feb: 281-305.
- [18] ROSTAGHI, Mostafa, AZAMI, Hamed. *Dispersion entropy: A measure for time-series analysis*. IEEE Signal Processing Letters, 2016, 23.5: 610-614.
- [19] BATISTA, Gustavo, WANG, Xiaoyue, KEOGH, Eamonn J. *A complexity-invariant distance measure for time series*. In: Proceedings of the 2011 SIAM international conference on data mining. Society for Industrial and Applied Mathematics, 2011. p. 699-710.
- [20] LIU, Fei Tony, Kai Ming TING a Zhi-Hua ZHOU. *Isolation Forest*. 2008 Eighth IEEE International Conference on Data Mining. IEEE, 2008, 413-422. DOI: 10.1109/ICDM.2008.17. ISBN 978-0-7695-3502-9.

- [21] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. *Deep learning*. Cambridge, Massachusetts: The MIT Press, 2016. ISBN 978-026-2035-613.
  
- [22] KORDÍK, Pavel. *Soubor přednášek k předmětu MI-MVI.16 (Metody výpočetní inteligence)*. Praha: České vysoké učení technické v Praze. Fakulta informačních technologií, 2018 [cit. 2018-18-04]. Dostupné z: <https://edux.fit.cvut.cz/courses/MI-MVI.16/lectures/start>



## Seznam použitých zkratk

- CE** Complexity Estimation
- COMPASS** Compact Assembly
- DFT** Diskrétní Fourierova transformace
- JET** Joint European Torus
- k-NN** k-Nearest Neighbors
- MSE** Mean Squared Error
- PCA** Principal Component Analysis
- ReLU** Rectified Linear Unit
- SMOTE** Synthetic Minority Over-sampling Technique
- SQL** Structured Query Language



---

## Schéma databáze učících vzorů

```
CREATE TABLE disruption_warning
(
  dbkey int(11) not null auto_increment, shot int(11) not null, time float not null,
  time_until_disrupt float null, ip_error float null, beta_p float null, beta_n float null,
  li float null, n_equal_1_mode float null, z_error float null, v_z float null,
  z_times_v_z float null, kappa float null, pressure_peaking float null, H98 float null,
  q0 float null, qstar float null, q95 float null, ssep float null, v_0 float null,
  v_mid float null, v_edge float null, Greenwald_fraction float null, p_rad float null,
  p_oh float null, p_icrf float null, p_lh float null, p_nbi float null, radiated_fraction float null,
  power_supply_railed tinyint null, v_loop float null, r_dd float null, lower_gap float null,
  upper_gap float null, Wmhd float null, ip float null, zcur float null, n_e float null,
  dipprog_dt float null, Te_width float null, intentional_disruption tinyint null, PRIMARY KEY (dbkey)
);
```





---

## Obsah přiloženého DVD

readme.txt .....	stručný popis obsahu DVD
src	
├── Python.....	Python zdrojové kódy
├── SQL.....	SQL zdrojové kódy
text .....	text práce
├── DP_Petr_Prokop_2018.pdf .....	text práce ve formátu PDF
├── src.....	$\LaTeX$ kód textu
└── materialy.....	materiály (články a další) použité v práci