



SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
MATERIÁLOVOTECHNOLOGICKÁ FAKULTA SO SÍDLOM V TRNAVE

Ing. Jozef Magdolen

Autoreferát dizertačnej práce

**Využitie metód strojového učenia pri štúdiu periodických signálov v
astrofyzike**

na získanie akademického titulu: doktor (philosophiae doctor, PhD.)

v doktorandskom študijnom programe: Automatizácia a informatizácia procesov

v študijnom odbore: Kybernetika

Forma štúdia: denná

Miesto a dátum: Trnava, 31.8.2023



Dizertačná práca bola vypracovaná na Ústave výskumu progresívnych technológií

Predkladateľ: Ing. Jozef Magdolen
Ústav výskumu progresívnych technológií
Materiálovotechnologická fakulta so sídlom v Trnave
Slovenská technická univerzita v Bratislave
Jána Bottu 2781/25
917 01, Trnava

Školiteľ: Mgr. Andrej Dobrotka, PhD.
Ústav výskumu progresívnych technológií
Materiálovotechnologická fakulta so sídlom v Trnave
Slovenská technická univerzita v Bratislave
Jána Bottu 2781/25
917 01, Trnava

Oponenti:
.....
.....
.....
.....
.....

Autoreferát bol rozoslaný:

Obhajoba dizertačnej práce sa bude konať dňa **o** **h.**

**na Materiálovotechnologickej fakulte fakulte STU so sídlom v Trnave, J. Bottu 25, 917 24,
Trnava**

.....
prof. Ing. Miloš Čambál, CSc.
dekan MTF STU

Obsah

Úvod	5
1 Modelovanie a simulácia signálov	7
1.1 Periodicita v astrofyzike	7
1.2 Motivácia	7
1.3 Spracovanie a simulácia dát.....	9
1.4 Tvorba časových máp	14
1.5 Monte Carlo simulácie.....	16
2 Použité architektúry strojového učenia a príprava dát	17
2.1 Použité architektúry	17
2.2 Príprava dát	21
3 Výsledky	23
4 Záver	37
Zoznam použitej literatúry	41

Úvod

Analýza signálov sa používa v mnohých vedných disciplínach za účelom získať prvotné informácie o skúmanom systéme. Jedná sa o základný prístup k identifikácii systému použitím matematických metód. Jednou zo základných metód spracovania signálu je Fourierova transformácia, ktorej výsledkom je získanie frekvenčnej charakteristiky systému. Tá ponúka dodatočné informácie o signáli, konkrétne, z akých frekvenčných zložiek sa signál skladá a aké významné je ich zastúpenie. Aj na základe týchto poznatkov dokážeme určiť povahu skúmaného systému.

Jednou z hlavných vlastností, ktoré charakterizujú správanie sa systému, je variabilita. Tá hovorí o tom, ako sa skúmaný signál mení v čase. Variabilita môže byť spôsobená;

- 1) na úrovni amplitúdy,
- 2) na úrovni frekvencie,

respektíve kombináciou oboch prípadov. Uvedené typy variability sa vyskytujú v nami skúmaných objektoch – novách.

Jedná sa o fenomén interagujúcich dvojhviezd, kedy hmota z menej hmotnej hviezdy dopadá (priamo alebo akréciou) na povrch hmotnejšej hviezdy (bieleho trpaslíka) a následkom toho prichádza k termonukleárnemu vzplanutiu. Novy sú dobrým zdrojom periodického respektíve kvázi periodického signálu, na ktorého analýzu sa v tejto práci zameriavame. Variabilita na úrovni amplitúdy je spôsobená priamymi zmenami jasnosti telesa, a tým pádom množstva vyžiarenej energie. Naopak, variabilita na úrovni frekvencie môže byť spôsobená termonukleárnymi reakciami a poukazuje na komplikovanejšie fyzikálne mechanizmy. Na základe týchto poznatkov a správnej interpretácie signálu je potom možné určiť pravdepodobné procesy, ktoré takúto variabilitu spôsobujú.

Hlavným cieľom našej práce je zodpovedať otázku, či je možné na základe analýzy signálu s určitou povedať aký typ variability skúmaný systém vykazuje. Vychádzame pritom z publikácie [1] v ktorej autori ukázali, že štandardné metódy frekvenčnej analýzy signálu nám odpoveď na takúto otázku nemusia poskytnúť.

Existuje viacero prístupov ako daný problém riešiť. V posledných rokoch kvôli nárastu výpočtového výkonu v zariadeniach sa čoraz viac dostávajú do popredia algoritmy strojového učenia, ktoré vykazujú pre isté aplikácie vysokú úspešnosť riešenia. Preto sa aj my pokúsime aplikovať takýto prístup. Zameriame na viaceré algoritmy strojového učenia, konkrétne na konvulčné neurónové siete a rekurentné neurónové siete. Tieto algoritmy patria v súčasnosti medzi najpoužívanejšie pri práci so signálmi (časovými radmi).

Algoritmy strojového učenia vyžadujú pre úspešné fungovanie veľké množstvo dát, na ktorých sa môžu učiť. Kvôli nedostatku pozorovaných dát ktoré by sme mohli použiť na tréning neurónovej siete, Monte-Carlo simuláciami nasimulujeme rôzne typy časových radov – nova systémov. Tie následne spracujeme do podoby vhodnej pre daný algoritmus strojového učenia či už ako signál v časovej doméne, signál transformovaný do frekvenčnej podoby, alebo vytvorením takzvaných časových máp, ktorých tvorbou sa zaoberáme v kapitole 1.4. Takto nasimulovanými dátami natrénujeme vybrané modely neurónových sietí, ktoré by mohli nájsť nejaký skrytý vzorec pre každý typ variability a na základe neho schopné rozlíšiť aký typ procesu spôsobuje pozorovanú variabilitu v pozorovaných nova systémoch.

Pre úspešné splnenie vytýčeného cieľa, boli stanovené nasledovné úlohy:

1. Zhodnotiť problematiku analýzy signálu a časových radov
2. Navrhnuť metódu pre simuláciu časových radov s premenlivou amplitúdou a/alebo periódou
3. Popísať aktuálny stav algoritmov strojového učenia
4. Navrhnuť možnú architektúru strojového učenia a porovnať ju s najpoužívanejšími v tejto oblasti
5. Aplikovať vybrané architektúry strojového učenia na študované dáta
6. Zhodnotiť dosiahnuté výsledky

1 Modelovanie a simulácia signálov

1.1 Periodicita v astrofyzike

Astrofyzika predstavuje široký priestor pre skúmanie a analýzu časovo-závislých signálov. Množstvo stelárnych objektov nám poskytuje na základe ich povahy, pohybu či elektromagnetickému vyžarovaniu obrovské množstvo dát, ktoré sú vďaka pozemským a vesmírnym teleskopom zaznamenávané. Ako sme si povedali v prvej kapitole, použitím matematickej analýzy signálov vieme z týchto dát získať dôležité informácie o správaní sa skúmaného telesa alebo systému. V tejto práci sa sústreďujeme predovšetkým na periodicky správajúce sa systémy. Použitím frekvenčnej analýzy potom dokážeme povedať či daný systém vykazuje známky variability alebo nie.

Je úplne bežné, že pozorovaná hviezda alebo hviezdny systém vykazujú známky variability. Zdrojom takejto variability môže byť napríklad zmena jasnosti pozorovaného systému či už v dôsledku reálnej zmeny vyžiareného elektromagnetického žiarenia, alebo zdanlivou zmenou jasnosti spôsobenou dočasným zablokovaním tohto žiarenia iným telesom (dvoj a viac hviezdne systémy, planéta a i.). Oba spomenuté typy zmeny jasnosti sa vyskytujú napríklad v novách, ktoré sú dobrým zdrojom periodického, respektíve kvázi periodického signálu. Aj v tomto dôsledku sú základom tejto práce.


Nova

Nova je udalosť, ktorá nastáva v dvojhviezdnych systémoch, kedy sa hmota z pridruženej hviezdy akumuluje na povrch bieleho trpaslíka. Po dosiahnutí kritického množstva takto naakumulovanej hmoty, ktorá je bohatá na vodík, nastáva reakcia termonukleárnej fúzie. Vtedy exploduje takzvaná obálka bieleho trpaslíka, čo má za následok výrazný nárast luminozity (energie) v röntgenovej oblasti. Okrem zmeny vyžiarenej energie v dôsledku horenia vodíka na povrchu bieleho trpaslíka zaznamenávame aj inú variabilitu, ktorá je spôsobená tým, že sa jedná o zákrytový systém.

Pozorovanie takéhoto dvojhviezdneho systému v röntgenovej oblasti má veľký význam. Keďže hustota bieleho trpaslíka je veľmi vysoká, vysoká je aj intenzita jeho gravitačného poľa. Počas procesu akrecie sa tak transformuje gravitačná potenciálna energia na röntgenové žiarenie. Niektoré novy boli taktiež pozorované v takzvanej SSS fáze, kedy samotné termonukleárne horenie je zdrojom röntgenového žiarenia v nízkych energiách, nazývaného aj mäkký röntgen. Preto sú takéto systémy viditeľnejšie v röntgenovej oblasti. [1] Práve novami nachádzajúcimi sa v SSS fáze sa v tejto práci zaoberáme, konkrétne ide o systémy KT Eri a Cal 83.

1.2 Motivácia

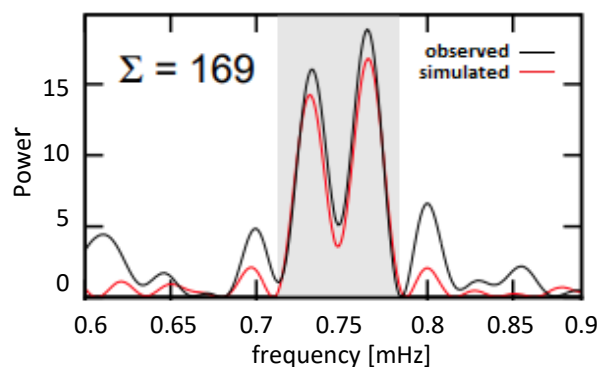
Dopadajúce röntgenové žiarenie z nov je možné pozorovať teleskopmi, ktoré sa zameriavajú na snímanie objektov v tejto oblasti (napríklad XMM-Newton, Chandra). Výsledkom pozorovania je potom takzvaná svetelná krivka zaznamenávajúca počet dopadnutých fotónov na detektor v čase, ktorá môže vykazovať určité známky variability. Následným spracovaním takto pozorovaného systému frekvenčnou analýzou vieme zistiť z akých frekvencií sa skúmaný systém skladá a rovnako tak určiť ich významnosť a povahu. Príklad svetelnej krivky novy KT Eri zachytenej v röntgenovej oblasti a následný periodogram môžeme vidieť na Obr. 1.



Obr. 1 (Vľavo) Svetelná krivka pozorovaného systému KT Eri teleskopom Chandra. (Vpravo) Periodogram vytvorený metódou Lomb-Scargle, sivá čiara znázorňuje 99% významnosť signálu (FAP = 0.01, vid' kapitolu **Chyba! Nenašiel sa žiaden zdroj odkazov.**). Viditeľný dvoj-vrchol okolo frekvencie 28.57 mHz (35s). naznačuje, že signál je ovplyvnený dvoma blízkymi frekvenciami okolo tejto frekvencie.


Správna interpretácia výsledného periodogramu je rozhodujúca z hľadiska určenia charakteru zistenej variability skúmaného systému. Vtedy je dôležité zistiť či je frekvencia stála alebo premenlivá, či je signál ovplyvnený jednou frekvenciou alebo viacerými atď.

Avšak môže nastať situácia, že aj očividné riešenie nemusí byť správne. Klasickou interpretáciou periodogramu na Obr. 1 by bolo možné povedať, že výsledný signál je ovplyvnený dvoma blízkymi frekvenciami s periódou okolo 35 sekúnd, čo by vysvetľovalo prítomnosť dvoch vrcholov blízko seba, takzvaný dvoj-vrchol. K takémuto záveru dospeli [2]. Avšak v článku [3] početnými simuláciami ukázali, že prítomnosť takéhoto dvoj-vrcholu nemusí nutne znamenať aj prítomnosť dvoch blízkych frekvencií. Podobný vzor môže vykazovať aj signál modulovaný jednou konštantnou frekvenciou ovplyvnený zmenami v amplitúde (vid' Obr. 2). Jedná sa tak o dve nerozlíšiteľné interpretácie.



Obr. 2 Lomb-Scargle periodogram pozorovaného (čiernou) a simulovaného (červenou) signálu. [3]

Podobná analýza bola vykonaná v článku [4] kde ukázali, že periodogram zo signálu modulovaného konštantnou frekvenciou a variabilnou amplitúdou dokáže do značnej miery napodobniť signál s variabilnou frekvenciou, čo je možné vidieť na Obr. 3.



Obr. 3 Porovnanie periodogramu z pozorovaného signálu družicou XMM-Newton/PN (čiernou) a simulovaného signálu (červenou). [4]

Vidíme, že sa jedná o komplikovaný problém a určenie povahy signálu nie je triviálna záležitosť. Na základe týchto poznatkov sa v mojej práci venujem otázke či je vôbec možné rozlíšiť medzi signálom s variabilnou frekvenciou a signálom s konštantnou frekvenciou ale s variabilnou amplitúdou.

Simuláciu dát sme vykonávali použitím programovacieho jazyka Python a s využitím niektorých dostupných knižníc ako Numpy, Scipy a Astropy, ktoré nám uľahčili prácu so spracovaním dát a pri vytváraní periodogramov. Tie sme potom vykresľovali použitím knižnice Mplotlib resp. softvéru Gnuplot. Postup, akým sme k danej problematike pristupovali, je popísaný v ďalších kapitolách tejto práce.

1.3 Spracovanie a simulácia dát


Ako bolo spomenuté, našou motiváciou je zistiť či je možné rozlíšiť medzi variabilitou spôsobenou zmenou frekvencie, zmenou amplitúdy, zmenou oboch zložiek, alebo či aj konštantný signál (konštantná amplitúda aj frekvencia) môže za určitých podmienok vykazovať v periodograme prvky variability. V tejto časti si ukážeme, ako sme postupovali pri simulovaní svetelných kriviek nova systémov s rozličnými druhmi variability. Variabilitu systému, resp. zobrazenie toho ako sa mení v čase, vieme dostať z takzvanej časovej mapy (bližšie v kapitole 1.4).

Keďže potrebujeme referenčné dáta na základe ktorých budeme takéto signály simulovať, vybrali sme si práve spomenuté nova systémy Kt Eri (pozorovanie ObsID = 12203, teleskop Chandra) a Cal 83 (pozorovanie ObsID = 0506531701, teleskop XMM-Newton). Pre správne nasimulovanie nova systémov, ktoré by sa podobali tomu referenčnému, potrebujeme najskôr zistiť jeho základné vlastnosti. Z periodogramu pre systém KT Eri vidíme, že daný systém vykazuje periodicitu na úrovni ~35s. Keďže sa jedná o periodický signál, ktorého matematický predpis je definovaný ako: $y(t) = A \sin(2\pi f t + \varphi) + \psi$, okrem frekvencie f potrebujeme zdefinovať aj hodnoty amplitúdy – A a vertikálneho posunu – ψ . Polynomickou regresiou referenčných dát dokážeme nájsť polynóm, ktorý dostatočne dobre opíše tieto dáta (viď Obr. 4). V našom prípade sme zvolili polynóm 13-teho stupňa. Takto sme zistili, okolo akých hodnôt referenčné dáta oscilujú, čo predstavuje hodnoty vertikálneho posunu ψ .

Týmto spôsobom dokážeme opísať osciláciu dát na dlhšej časovej škále, čo by použitím konštanty nebolo možné. Hodnotu amplitúdy zase môžeme nájsť:

- 1) preložením funkcie sínus cez referenčné dáta

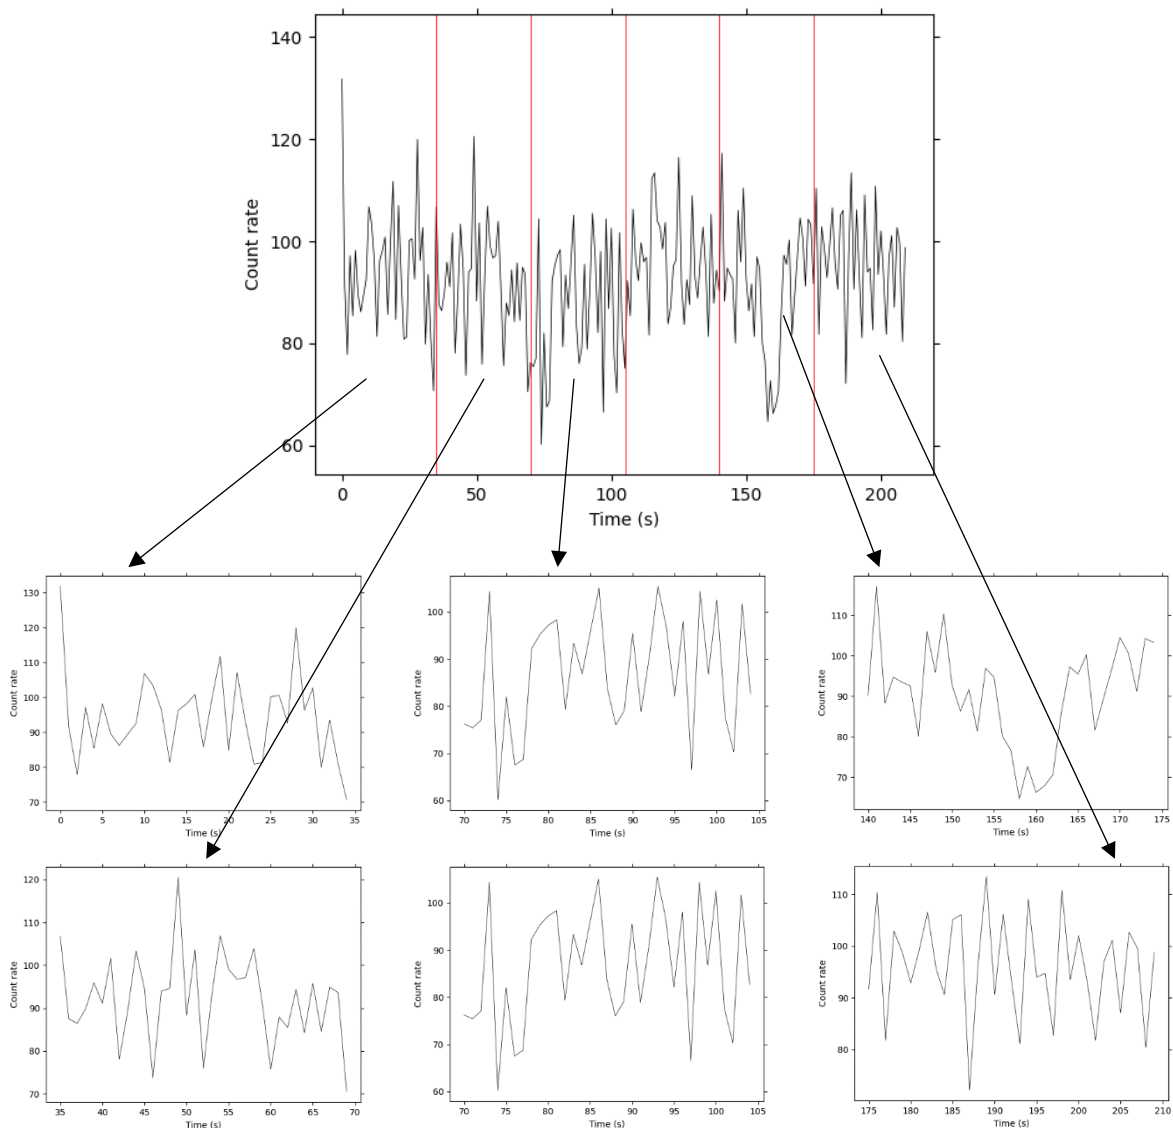
- 2) výberom hodnoty amplitúdy tak, aby stredný kvadratický priemer simulovaných dát sa zhodoval s referenčnými dátami
- 3) použitím vytvorenia takzvanej fázovanej svetelnej krivky.



Obr. 4 Pozorované dáta s polynómom ktorý ich opisuje a bude použitý ako hodnota vertikálneho posunu ψ .

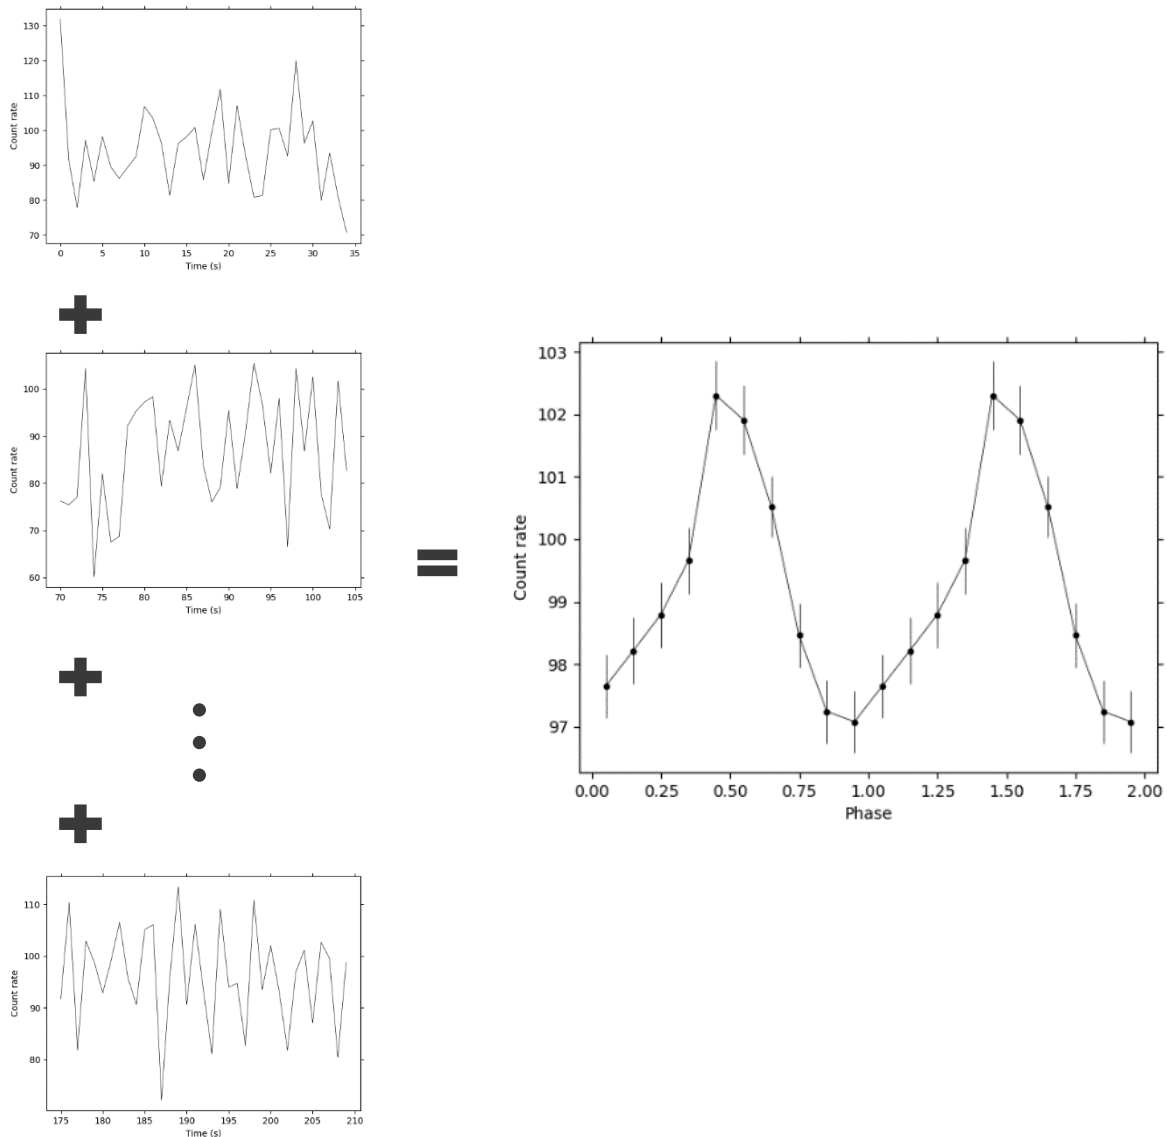
My sme najskôr použili metódu č. 2, čo však viedlo k nepresným výsledkom pri následnej klasifikácii použitím algoritmu konvolučných neurónových sietí. Stredný kvadratický priemer je totižto náchylný na šum v dátach. Preto aj pri menšej variabilite amplitúdy a vysokom šume môžeme dostať rovnakú hodnotu, ako by sme dostali pri vyššej variabilite amplitúdy a menšom zašumení dát. To sa potvrdilo aj pri analýze periodogramov, kedy hodnota hlavného 35s signálu v simulovaných dátach nebola v mnohých prípadoch podobná hodnote hlavného signálu z reálnych dát.

Po identifikovaní tohto problému sme si preto zvolili metódu č. 3, pri ktorej vieme najpresnejšie odmerať hodnotu amplitúdy a nájsť aj hodnotu chyby merania. Pri tejto metóde rozdelíme svetelnú krivku na segmenty s dĺžkou, ktorá zodpovedá hodnote periódy T (v našom prípade pre systém KT Eri 35s) ako je zobrazené na Obr. 5.



Obr. 5 Ukážka rozdelenia časti svetelnej krivky systému KT Eri na segmenty, z ktorých bude vytvorená fázovaná svetelná krivka.

Následne hodnoty jednotlivých segmentov na osi y spriemerujeme a vypočítame štandardnú odchýlku priemeru podľa vzťahu 1.2.4. Tak získame hodnotu signálu pomocou ktorej budeme môcť opísať našim dátam funkciu sínus. Rovnako môžeme spriemerovať aj hodnoty v určitom časovom kroku, čím vizuálne vyhladíme priebeh skúmaného signálu. Takto vytvoríme jednu svetelnú krivku s dĺžkou T . Keďže popisujeme fázu, hodnoty z časovej osi preškálujeme do intervalu $\langle 0, 1 \rangle$ (niekedy sa pre lepšiu vizualizáciu zobrazujú dva cykly fázovanej svetelnej krivky). Z takto vytvorenej fázovanej krivky (viď Obr. 6) vieme odčítať hodnotu hľadanej amplitúdy signálu.



Obr. 6 Vytvorenie fázovanej svetelnej krivky systému KT Eri.

Takto sme dospeli k hodnotám:

$$A = 2.3; \psi = P_{13}(t); f = 1/T = 1/35 = 28.57 \text{ mHz}$$

Dosadením hodnôt do vzťahu pre predpis oscilácie konštantného sínusového signálu dostávame nasledovnú funkciu:

$$y(t) = 2.3 * \sin(2\pi t * 28.57 * 10^{-3}) + P_{13}(t), \quad (1)$$

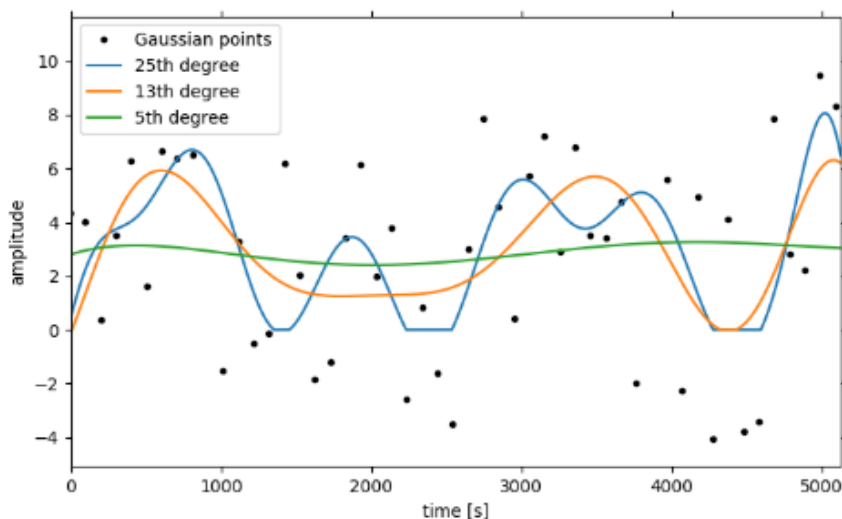
Časová zložka signálu t je rovná časovej zložke pozorovaného systému. Počet častíc, ktoré dopadnú na detektor teleskopu za každý časový okamžik je však Poissonov náhodný proces. Preto hodnoty, ktoré nadobúda funkcia $y(t)$ v čase t je potrebné nahradiť náhodnými hodnotami Poissonovho rozdelenia okolo každého bodu $y(t)$. Takto dostávame nasimulovanú svetelnú krivku novy s **konštantnou amplitúdou a konštantnou frekvenciou**, na základe referenčného nova systému KT Eri.

Ďalší typ variability ktorým sa zaoberáme, je signál s **konštantnou frekvenciou a variabilnou amplitúdou**. Podstata simulácie zostáva rovnaká, avšak tentokrát sa naša amplitúda bude meniť v čase. To docielime nasledovným spôsobom. Na výber náhodných hodnôt amplitúd použijeme

Gaussovú distribúciu so strednou hodnotou $\mu = 2.3$ ktorú sme dostali z predošlej simulácie a so smerodajnou odchýlkou $\sigma = 40$. Tú sme vybrali tak, aby rozptyl dát ktoré dostaneme týmito hodnotami bol podobný rozptylu referenčných dát. Tieto hodnoty (viď čierne body na Obr. 7) boli rozložené na celom časovom intervale a následne preložené polynómom 25 stupňa, ktorý popisuje ako sa amplitúda mení v čase. Tento stupeň polynómu bol vybraný zámerné, keďže hodnoty variabilnej amplitúdy sme dostali použitím Gaussového náhodného rozdelenia a použitie vyššieho stupňa polynómu na modelovanie dát nám vráti v niektorých prípadoch záporné hodnoty (viď Obr. 7 a opísanie dát rôznymi stupňami polynómu). Vtedy všetky záporné hodnoty nahradíme nulovou hodnotou čo predstavuje scenár, že variabilita amplitúdy zmizne čo môže zodpovedať realite. Takto sme dostali predpis funkcie $y(t)$ pre signál s konštantnou frekvenciou a variabilnou amplitúdou generovanou polynómom $P_A(t)$. Hodnota ψ zostáva rovnaká ako v predošlom prípade.

$$y(t) = P_A(t) * \sin(2\pi * 28.57 * 10^{-3} * t) + P_{13}(t), \quad (2)$$

Nakoniec, rovnako aj tu nahradíme hodnoty funkcie $y(t)$ hodnotami z Poissonovho rozdelenia (vzťah 1.2.7) tak, že $\lambda_i = y(t)_i$.



Obr. 7 Znáznornenie modelovania variabilnej amplitúdy polynómom 5, 13 a 25-teho stupňa. Vyšší stupeň polynómu dokáže vrátiť záporné hodnoty, ktoré nahradením nulovou hodnotou predstavujú situáciu, kedy variabilita amplitúdy zmizne.

Pri simulácií signálu s **konštantnou amplitúdou a variabilnou frekvenciou** postupujeme podobne ako v predchádzajúcich dvoch prípadoch. Budeme však generovať náhodné hodnoty frekvencií. Rovnako použijeme Gaussovú distribúciu, tentokrát so strednou hodnotou $\mu = 0$ a so smerodajnou odchýlkou $\sigma = 2 * 10^{-3}$. Ku každej takto vygenerovanej frekvencii nakoniec pripočítame hodnotu frekvencie f , čo je obdobný spôsob ako pri generovaní hodnôt variabilnej amplitúdy. Hodnotu σ sme si určili tak, aby variabilita bola viditeľná, ale v zhode s pozorovanými dátami. Na to sme vykonali niekoľko simulácií s rôznymi hodnotami, vytvorili spomenutú časovú mapu a porovnali ju s tou z referenčných dát. Výsledné hodnoty sme podobne ako pri variabilnej amplitúde preložili polynómom P_f 25-teho stupňa, ktorý sme použili vo funkcii $y(t)$ miesto konštantnej frekvencie. Hodnota ψ zostala rovnaká a predpis výslednej funkcie je:

$$y(t) = A * \sin(2\pi * P_f(t) * t) + P_{13}(t) \quad (3)$$

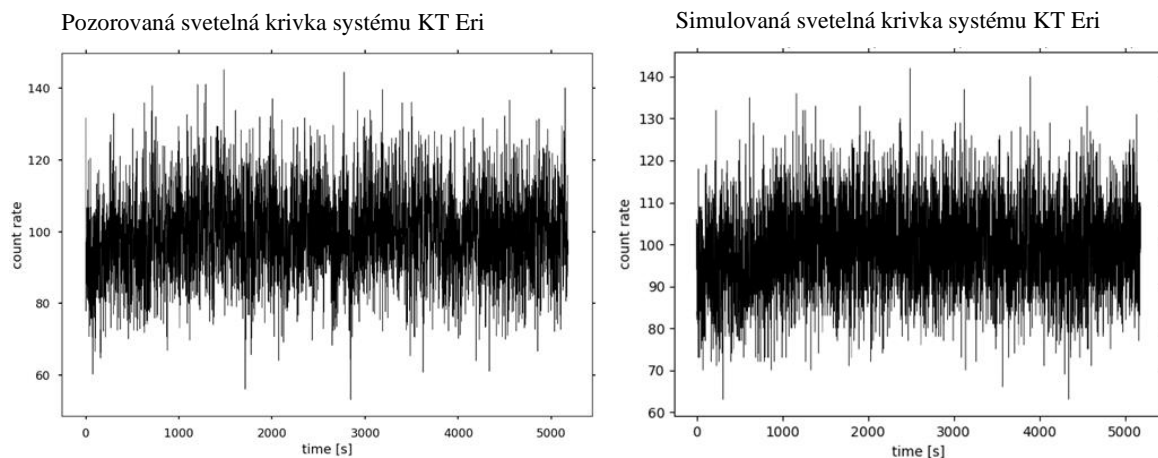
Podobne ako v predchádzajúcich prípadoch, aj tu nahradíme hodnoty $y(t)$ hodnotami z Poissonovho rozdelenia s priemernou hodnotou ktorá pripadá každému z bodov.

Nakoniec nasimulujeme signál s **variabilitou v amplitúde aj vo frekvencii**. Tu spojíme simulovanú variabilitu z predošlých dvoch prípadov, teda za hodnotu amplitúdy A dosadíme polynóm $P_A(t)$ a za hodnotu frekvencie f polynóm $P_f(t)$. Takto dostaneme predpis funkcie signálu $y(t)$:

$$y(t) = P_A(t) * \sin(2\pi * P_f(t) * t) + P_{13}(t) \quad (4)$$

Hodnoty $y(t)$ potom nahradíme hodnotami z Poissonovej distribúcie zo vzťahu 1.2.7 tak, ako v predošlých prípadoch.


Takýmto spôsobom sme dokázali nasimulovať signál s rôznymi druhmi variability podľa referenčného systému KT Eri. Príklad svetelnej krivky z referenčného systému v kontraste s nasimulovanými dátami s variabilnou amplitúdou aj frekvenciou môžeme vidieť na Obr. 8.



Obr. 8 Porovnanie pozorovaných systému KT Eri so simulovanými dátami s konštantnou amplitúdou a variabilnou frekvenciou.


1.4 Tvorba časových máp

Ako bolo načrtnuté v predošlej časti, úlohou časových máp je grafické vyobrazenie toho, ako sa signál vyvíja v čase. Vtedy nevytvárame jeden periodogram z celého setu dát, avšak dáta rozdelíme na niekoľko častí dostatočne dlhých na to, aby sa očakávaná variabilita mohla prejaviť. Následne, z každej časti vytvoríme periodogram a umiestnime ich pod seba. Vtedy bude na osi X frekvencia/perióda, na osi Y čas a významnosť signálu bude kódovaná farebne. Inak povedané, každý riadok časovej mapy je reprezentovaný jedným periodogramom. Príklad časovej mapy môžeme vidieť na Obr. 9.



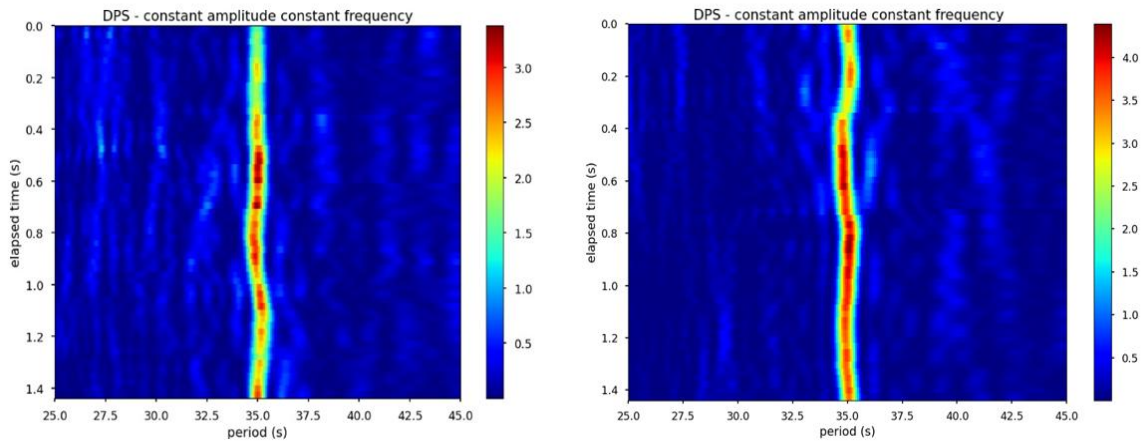
Obr. 9 Príklad časovej mapy nasimulovaného periodického signálu, ktorého frekvencia sa mení funkciou sínus okolo hodnoty 25Hz.

V našom prípade sme časové mapy vytvárali z nasimulovaných dát spôsobom opísaným v predchádzajúcej časti. Zaujímá nás či a akým spôsobom sa prejaví variabilita nasimulovaných systémov. Na rozdiel od spomínaného článku [1], kde časové mapy vytvárali z 10 periodogramov pozostávajúcich z 1000s časových úsekov a s prekrytím 500s, my sme ich vytvárali zo 60-tich periodogramov pozostávajúcich z 1500s dlhých úsekov a s prekrytím 62s. Takto sme dosiahli vyššie rozlíšenie časovej mapy, ktoré budeme potrebovať pri nasledujúcom použití konvulčných neurónových sietí pri detekcii variability. Aj keď za cenu vyššieho výpočtového času (6-násobne viac periodogramov a o polovicu dlhšie časové úseky). Príklady časovej mapy z každého typu variability a referenčného systému KT Eri je možné vidieť na Obr. 10.



Obr. 10 Časové mapy. Zľava hore: KT Eri – 10 periodogramov po 1000s, obdobne ako v [1]; KT Eri – 60 periodogramov po 1500 sekúnd; simulovaný systém s konštantnou amplitúdou aj frekvenciou; Zľava dole: simulovaný systém s variabilnou amplitúdou a konštantnou frekvenciou; simulovaný systém s konštantnou amplitúdou a variabilnou frekvenciou; simulovaný systém s variabilnou amplitúdou aj frekvenciou.

Z Obr. 10 by sa mohlo zdať, že rozdiel medzi konštantnou a variabilnou frekvenciou je zjavný. Ukázalo sa však, že aj signál modulovaný konštantnou frekvenciou a konštantnou amplitúdou vie vykazovať v časovej mape známky variability (viď Obr. 11). To je hlavný dôvod v použití algoritmov strojového učenia, ktoré by mohli nájsť nejaké špecifické znaky a klasifikovať tak typ variability v skúmanom systéme.



Obr. 11 Príklad simulovanej časovej mapy s konštantnou frekvenciou a konštantnou amplitúdou na základe referenčného systému KT Eri. Signál vykazuje známky variabilnej frekvencie.

1.5 Monte Carlo simulácie

Hlavná myšlienka simulačnej metódy Monte Carlo pozostáva z transformácie nepravdepodobnostných problémov na pravdepodobnostné, ktoré sa dajú riešiť štatistickými metódami s využitím počítačov. Používa sa ako model, kedy je potrebné predpovedať pravdepodobnosť výstupu rôznych náhodných procesov závislých na náhodných veličinách, ktoré tento výstup ovplyvňujú. [5] MC simulácia teda vytvára model možných výsledkov využívaním rozdelenia pravdepodobnosti (rovnorné, normálové, a i.) pre každú z náhodných premenných. Pri každej zmene náhodných čísel sa výsledky niekoľko krát prepočítajú (typicky desaťtisíc až stotisíc krát), a tak sa získa množstvo možných výstupov spolu s pravdepodobnosťou, že nastanú. MC technika pozostáva z troch krokov: [6]

1. nastavenie modelu a identifikácia fixných a náhodných premenných,
2. špecifikácia v akom rozsahu sa budú náhodné premenné meniť,
3. opakované spúšťanie simulácií pokým nie je získané dostatočné množstvo výsledkov pre každú z kombinácií.

V sekcii 1.3, kde opisujeme simuláciu systémov s rôznymi typmi variability bolo spomenuté, že variabilitu amplitúdy a frekvencie generujeme použitím Gaussoveho náhodného rozdelenia a následným preložením polynómom 15 stupňa. Rovnako, aj výsledné hodnoty signálu sú náhodne pozmenené Poissonovským rozdelením. Výsledok teda do vysokej miery ovplyvňuje náhoda. Preto musíme vykonať pre každý prípad variability niekoľko tisíc simulácií, aby naše výsledky boli relevantné a mohli sme určiť mieru spoľahlivosti. Pre každý prípad variability sme preto spustili simuláciu 100 000 krát, čo by malo zachytiť aj menej pravdepodobné udalosti. Na klasifikáciu potom použijeme rôzne algoritmy neurónových sietí, ktorých úspešnosť následne porovnáme.

2 Použité architektúry strojového učenia a príprava dát

2.1 Použité architektúry

Použitie správnej architektúry je kľúčové z hľadiska úspešnej siete. Je nutné poznať význam a rozumieť všetkým premenným, ktoré v jednotlivých vrstvách siete vystupujú a majú vplyv na konečnú výkonnosť. Ako sme opísali v kapitole 1.2, našou motiváciou je vytvoriť taký model strojového učenia, ktorý by vedel na základe nasimulovaných dát povedať aký typ variability sa v týchto dátach vyskytuje. Vychádzame pritom z článku [1] kde bolo ukázané, že variabilita v amplitúde sa môže javiť ako variabilita vo frekvencii, a tak je možná nesprávna interpretácia fyzikálnych javov v skúmanom systéme.


V kapitole 3 sme opísali viaceré modely a typy algoritmov strojového učenia. Jedna zo základných otázok ktorá nám dá odpoveď na otázku aký algoritmus strojového učenia je vhodné použiť je, či sa jedná o problém regresie alebo klasifikácie. Z uvedenej problematiky je zjavné, že sa snažíme zistiť typ variability v dátach z čoho vyplýva, že sa jedná o klasifikačný problém. Preto nás budú zaujímať algoritmy vhodné na klasifikáciu. Ďalšia z otázok je, v akej podobe budú dáta vstupovať do neurónovej siete aby dávali zmysel. Tu máme v podstate 2 možnosti: dáta ako číselný rad a dáta ako obrázok vo forme spomínaných časových máp. Prienikom týchto dvoch množín vidíme, že je možné použiť algoritmy ako konvolučné neurónové siete či LSTM neurónové siete. Je však nutné si uvedomiť, že dáta ktoré budeme používať obsahujú značne zašumený signál a nájsť malé odchýlky vo variabilite je komplikovaná úloha. Každý z algoritmov však pristupuje k trénovaniu iným spôsobom a tak je možné, že niektorý z modelov bude úspešnejší ako iné.

2D Konvolučná neurónová sieť


Pri práci s obrazovými dátami, patria konvolučné neurónové siete k tým najlepším. Základom pre úspešné natrénovanie a klasifikáciu siete sú vlastnosti ako rozlíšenie samotných obrázkov, nastavenie a umiestnenie jednotlivých vrstiev, počet skrytých vrstiev a neurónov v nich, nastavenie normalizácie, rýchlosti učenia, koľko krát prejde učiaci sa algoritmus celým setom dát a tak ďalej. Robustná, ale zle navrhnutá sieť nám neponúkne dobré výsledky. Rovnako každá ďalšia vrstva spôsobuje nemalé zvýšenie výpočtového času, čo taktiež treba vziať do úvahy keďže nemáme k dispozícii výpočtový grafický klaster. Mnohé IT spoločnosti sa už roky snažia navrhnúť čo najlepšiu sieť, ktorá by bola schopná ponúknuť vysokú mieru presnosti na rôzne problémy. Najznámejšími sú AlexNet, GoogLeNet, VGGNet či ResNet. Tieto neurónové siete boli už niekoľko krát predtrénované na veľkých a mnohých setoch dát (napríklad ImageNet) a ukázali ich výbornú presnosť. Použitie už predtrénovanej siete nesie niekoľko výhod, ako napríklad rýchlosť učenia sa či zlepšenú presnosť, keďže tieto modely si v sebe už nesú niektoré naučené informácie a tie môžu byť použité pri novom trénovaní. Avšak obrázky na ktorých boli predtrénované sa dramaticky líšia od tých, ktoré budeme používať my. Rovnako tak ImageNet zahrňuje 1000 možných kategórií a my využívame len 4. Preto použitie už predtrénovaného modelu nie je najvhodnejšie a budeme musieť trénovať našu sieť nanovo, čo môže znamenať dlhší učiaci čas. [7]

V našom prípade sme sa rozhodli pre dva už existujúce modely ktoré dlhodobo vykazujú vysokú presnosť pri spracovaní obrazových vstupov a jednu vlastnú navrhnutú architektúru CNN. Z existujúcich sú to konkrétne AlexNet a ResNet-50. Architektúra AlexNet (vid' Obr. 12), ktorá aj napriek svojej jednoduchosti (5 konvolučných vrstiev, 2 plne prepojené skryté vrstvy a jedna plne prepojená výstupná vrstva) ponúka vysokú mieru presnosti. Rovnako tak je pomerne jednoduchá na implementáciu, keďže neobsahuje veľa vrstiev. Bude sa jednať o základ ktorý nám môže povedať či konvolučná neurónová sieť má potenciál klasifikovať naše

dáta. Druhá architektúra – ResNet-50 (viď Obr. 13). je už značne komplikovanejšou sieťou (48 konvolučných vrstiev, jedna vrstva MaxPooling, jedna AveragePooling a výstupná vrstva) a v teórii by mala vďaka svojej väčšej hĺbke poskytnúť vyššiu úspešnosť.




Obr. 12 Architektúra AlexNet konvolučnej neurónovej siete. [22]



Obr. 13 Architektúra konvolučnej neurónovej siete ResNet-50. Sieť sa skladá z niekoľkých blokov ktoré na seba nadväzujú. [9]

Nami navrhnutá architektúra je zobrazená na Obr. 14. Po vstupe nasledujú 3 konvolučné siete s 32 filtermi a po každej nasleduje takzvaná normalizácia (batch normalization), ktorá nastaví hodnoty všetkých vnútorných parametrov siete na nový priemer a rozptyl. To by malo zabezpečiť rýchlejšiu konvergenciu k minimu. Max pooling vrstva vyberie najdôležitejšie hodnoty a zníži výpočtovú záťaž. Na konci sú dve plne prepojené vrstvy s 1024 neurónmi a hodnotou dropout na 0.5, aby sa zabránilo pretrénovaniu siete, a výstupnú vrstvu zo 4 neurónmi, keďže dáta klasifikujeme do 4 tried. Počet konvolučných vrstiev a filtrov sme vybrali tak, aby sa sieť naučila do hĺbky. Viac vrstiev pomáha sieti naučiť sa rozoznávať detaily v komplikovaných dátach, viac filtrov zas pomôže sieti ísť viac do hĺbky. Pri rozhodovaní sa medzi počtom filtrov a vrstiev treba mať na pamäti, že veľa vrstiev zvyšuje náročnosť na pamäť a veľa filtrov je zas náchylných na pretrénovanie siete a zvýšený výpočtový výkon. [10] Ďalší parameter ktorý je potrebné nastaviť, je veľkosť filtra (kernelu). Kým filtre určujú hĺbku pri učení, veľkosť filtra určuje okno ktoré sa bude posúvať pri konvulúcii (typicky nepárne číslo do veľkosti 15, ale záleží od rozlíšenia obrázka). Menšie okno zachytí viac lokálnych detailov a sú rýchlejšie na výpočet, väčšie zas vedia zachytiť viac globálnych informácií. Preto sme pri prvej konvolučnej vrstve použili veľkosť filtra 11x11 a pri ostatných 3x3 Podobné je to s plne prepojenou vrstvou.



Obr. 14 Architektúra nami navrhutej CNN siete. Skladá sa zo vstupnej vrstvy, 6 konvolučných vrstiev, 3 vrstiev max pooling a 3 plne prepojených vrstiev (spolu s výstupom).


Pri vytváraní našej architektúry sme vyskúšali mnohé variácie (dokopy viac než 20), od 2-10 konvolučných vrstiev a 8-512 filtrov, avšak táto vykazovala najlepší pomer medzi výkonom a rýchlosťou učenia sa. Keďže sa jedná o klasifikáciu, ako aktivačnú funkciu na výstupe sme zvolili softmax.

1D Konvolučná sieť

Jedná sa o sieť založenú na 2D konvolučnej sieti, avšak ako vstup sa používa 1D signál. Tieto siete zaznamenali obrovský úspech pri klasifikácii signálu z biomedicínskych dát, detekcii anomálií v elektronickom signáli či pri detekcii chybovosti motorov zo zaznamenaného signálu. Na výpočet používajú 1D konvolúciu ktorá je jednoduchšia na výpočet oproti 2D konvolúcii, keďže namiesto výpočtov s maticami používajú násobenie skalárov. [11]

Idea za použitím 1D konvolučnej siete stojí v myšlienke, že pri vytváraní 2D obrázkov vkladáme do nich nové informácie (farba, odtieň, či samotné vytvorenie obrázku), ktoré môžu byť zbytočné a len komplikujú výpočet (diskusia s Brunom Merinom – vedúci skupiny pre ML aplikácie vo vedeckom operačnom stredisku ESAC Európskej vesmírnej agentúry). To, čo my vidíme ako variabilitu signálu v obrázku, je pre počítač len zhluk čísel, z ktorých musí potrebnú informáciu vyextrahovať. Preto sme sa rozhodli ísť o krok späť a využiť možnosť tréningu siete na 1D signáli – periodogramoch.

Pre vytvorenie vhodnej architektúry siete sme použili KerasTuner z Python knižnice Keras. Jedná sa o optimalizačný algoritmus, kedy je možné nastaviť si počet vrstiev, typ optimalizácie, počet plne prepojených sietí a množstvo neurónov v nich, veľkosť filtrov, či ich počet. Následne algoritmus spustí niekoľko iterácií na časti dát a pomocou zvolenej techniky nájde vhodné parametre pre všetky možnosti, ktoré sme si určili. Tak si môžeme vybrať architektúru, ktorá ukázala najlepšiu presnosť na prvých n iteráciách. Jedná sa však len o prvotný odhad a zvolená architektúra nemusí byť v konečnom dôsledku aj tá najlepšia. My sme nakoniec použili architektúru zobrazenú na Obr. 15.



Obr. 15 Architektúra 1D konvolučnej siete zložená z troch 1D konvolučných vrstiev, po každej nasleduje max pooling a na konci sú 2 plne prepojené vrstvy a výstup.

Zo samotnej architektúry vidíme, že sa jedná o pomerne jednoduchú sieť v porovnaní s 2D konvolučnou sieťou. Môže za to fakt, že sieť sa nemusí naučiť toľko informácií o dátach ako pri obrázkoch. V prvých dvoch konvolučných vrstvách sme použili veľkosť filtra 4×4 , v tretej


3×3. Ako výstupnú aktivačnú funkciu sme zvolili softmax, rovnako ako v prípade 2D konvolučnej siete.

LSTM sieť

Keď hovoríme o tom, že spracovaním dát do formy obrázkov môžeme do nich vkladať ďalšie informácie, automaticky sa naskytá otázka prečo neskúsiť ísť o dva kroky späť. To znamená, klasifikovať naše systémy nie na periodogramoch, ale na samotných surových dátach – svetelných krivkách. Vtedy nevkladáme do dát žiadnu nadbytočnú informáciu (ako farbu) a ani dáta netransformujeme do inej podoby (periodogramy).

LSTM siete obsahujú „pamäť“, a tak si vedia uchovať informáciu o predošlých sekvenciách v dátach a predpovedať nasledujúcu sekvenciu. Preto sa používajú pri spracovaní reči či, trhoch či iných dátach meniacich sa v čase. To je presne náš prípad. LSTM sieť sa bude snažiť naučiť sa z predošlej, nami definovanej sekvencie dát, a následne skúsiť predpovedať ako bude vyzeráť nasledujúca hodnota pri každej z možností variability signálu. Vychádzame z článku [12], kde pomocou LSTM siete klasifikovali svetelné krivky z viacerých stelárnych zdrojov s úspešnosťou modelu 90% na testovacích dátach.

My sme skúsili sme viacero architektúr LSTM siete, najlepšie výsledky na tréningových dátach sme však dosiahli pri architektúre zobrazenej na . Pri tomto type sietí je potrebné nastaviť počet LSTM vrstiev, počet neurónov v nich a hodnotu spätnej sekvencie, teda dĺžky dát z ktorej sa bude učiť. Pre nás je dôležité v prvotnej fáze hlavne zistiť či sieť dokáže klasifikovať, či je daný systém variabilný v perióde alebo nie. Jedná sa totižto o variabilitu v rámci len cca 1-2 sekúnd, a takú malú zmenu nemusí byť sieť schopná zachytiť. Ak sa ukáže že áno, môžeme skúsiť klasifikovať všetky 4 typy variability signálu.




Obr. 16 Architektúra LSTM siete, ktorá dosiahla najvyššiu úspešnosť. Skladá sa z 5 LSTM vrstiev (posledná je výstup) medzi ktorými sa nachádza vrstva Dropout s hodnotou 0,2.

ConvLSTM sieť

Ako z názvu vypovedá, jedná sa o sieť ktorá kombinuje výhody LSTM a konvolučnej siete, teda naučiť sa vzory v dátach a ich následnosť. Ide v podstate o LSTM sieť, avšak namiesto násobenia matíc vnútri siete tu prebieha operácia konvolúcie. Tento typ siete bol navrhnutý v článku [13] na predikciu zrážok a používa sa predovšetkým na problémy, kde je okrem vnútornej štruktúry dát si potrebné zapamätať aj časový sled. Naša architektúra je zobrazená na Obr. 17.

Aby naše modely konvergovali čo najbližšie ku globálnemu minimu, rýchlosť učenia lr sme nastavili ako parameter meniaci sa v čase, ktorý po určitých iteráciách znižuje svoju hodnotu. Na začiatku sme túto hodnotu nastavili na $lr = 0,01$ a každých 5 iterácií sme ju znižovali o polovicu.



Obr. 17 Architektúra nami použitej ConvLSTM siete. Skladá sa zo 4 po sebe nasledujúcich ConvLSTM vrstiev s batch normalizáciou a dvomi plne prepojenými vrstvami (spolu s výstupnou), medzi ktorými je vrstva Dropout s hodnotou 0.2.

Počet iterácií, teda koľko krát prejde algoritmus učenia sa celým súborom dát a aktualizuje svoje vnútorné hodnoty váh a filtrov, sa zvyčajne určuje na základe prvotného spustenia sa algoritmu. Pri dostatočnom počte dát a klasifikácii dobre odlišiteľných tried (napríklad rozpoznávanie písaných čísel) dokáže algoritmus vykazovať presnosť 90% po troch iteráciách, pri veľmi komplikovaných dátach nemusí stačiť ani 100. My sme nastavili počet iterácií na hodnotu $i=20$. Pokiaľ by sme zistili, že presnosť nejakého modelu nezlepšila ani po 20 iteráciách, túto hodnotu zvýšime alebo zmeníme model či rýchlosť učenia sa.

2.2 Príprava dát

Vytvorenie a natrénovanie modelov neurónových sietí sme naprogramovali v programovacom jazyku Python použitím knižnice Tensorflow na prácu s neurónovými sieťami, ktorá patrí medzi najpoužívanejšie nástroje na tvorbu algoritmov strojového učenia. Avšak predtým ako použijeme modely na klasifikáciu a hľadanie variability, je nutné upraviť a spracovať náš set dát nasimulovaných systémov nasledovne:

1. Najskôr je nutné rozdeliť dáta na tri časti: na **trénovanie**, **validáciu** a **testovanie**, väčšinou pomerom 70% ku 15% ku 15%. Rozdelenie dát má svoje opodstatnenie. Počas procesu učenia sa, algoritmus hľadá špecifické znaky a rozdiely v dátach na trénovanie a na základe validačných dát upravuje svoje vnútorné parametre ako váhy a hodnotu filtrov. Takto naučený model potom použijeme na klasifikáciu nových dát, pretože model sa už disponuje naučenými hodnotami z predošlých súborov dát. V kapitole 1.5 spomíname, že sme nasimulovali 100 000 systémov pre každý typ variability, to by znamenalo 75 000 obrázkov na trénovanie CNN sietí. To je však pre použitie CNN veľmi nákladné z hľadiska výpočtového výkonu. Preto sme pre tieto siete použili pre každý typ variability 5000 obrázkov na trénovanie, 1000 na validáciu a 1000 na testovanie. Pri 1D konvolučných sieťach sme použili 20 000 periodogramov pre každý typ variability a pre LSTM a ConvLSTM 2000 svetelných kriviek, taktiež z obmedzenia výpočtového výkonu.
2. Ďalším krokom je prispôbenie rozlíšenia dát. Naše nasimulované časové mapy mali základné rozlíšenie 672×672 pixelov čo je veľa, keďže vstup do siete AlexNet podporuje maximálne rozlíšenie 227×227 a ResNet-50 sieť 224×224 pixelov. Preto bolo nutné všetky nasimulované časové mapy zmenšiť na túto hodnotu, na čo sme použili Python knižnicu Pillow. Táto hodnota stále zabezpečuje dostatočné množstvo pixelov na zachytenie aj menšej variability na časovej mape. Úprava dát pre LSTM, ConvLSTM a 1D konvolučné siete nebola nutná.

3. Posledným krokom je nutnosť preškálovania dát. Jedná sa o krok, kedy pri obrázkoch vydelíme hodnoty všetkých pixelov hodnotou 255, čo je maximálna hodnota, ktorú môže pixel nadobúdať. To spôsobí, že všetky hodnoty budú v intervale $\langle 0, 1 \rangle$. Preškálovanie je dôležité z hľadiska rýchlejšej konvergenzie, teda učenia sa modelu. [8] Pre 1D konvolučné siete, LSTM a ConvLSTM siete tak isto preškálujeme dáta medzi hodnoty $\langle 0, 1 \rangle$.

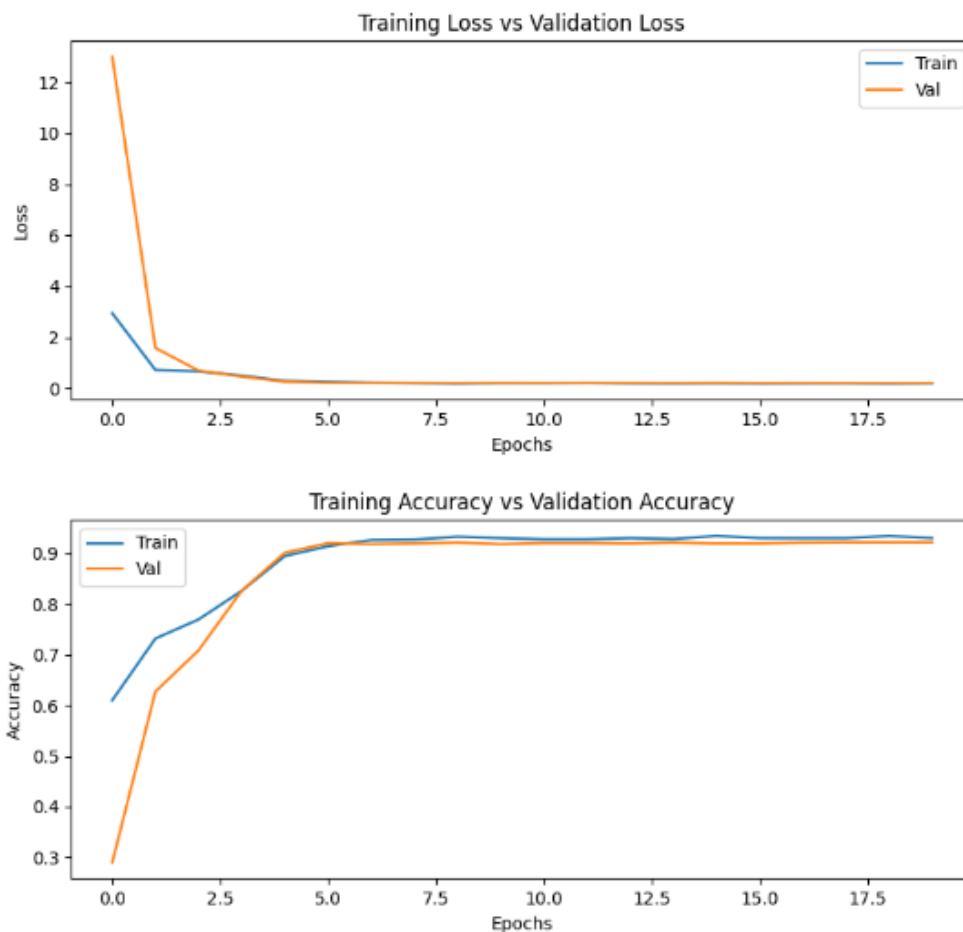
3 Výsledky

2D kovnolučná neurónová sieť

Ako sme spomenuli v kapitole 1.3, úspešnosť prvého CNN modelu nebola dobrá. Síce AlexNet sieť vykazovala pre systém Cal 83 úspešnosť na testovacích dátach ~90%, pre systém KT Eri to bolo len ~49%. Preto sme ani neskušali ďalšie architektúry, ale zanalyzovali dáta a vytvorili nové simulácie s presnejšou voľbou hodnoty amplitúdy.

Pre všetky dole spomenuté architektúry sme spustili tréning 3 krát. Mohlo by sa stať, že model počas učenia ostane zaseknutý v lokálnom minime čo by negatívne ovplyvnilo jeho presnosť.


Úspešnosť konvolučnej siete AlexNet na dátach systému KT Eri je zobrazený na Obr. 18. Vidíme, že model dosahoval úspešnosť ~91% už po 5-tich iteráciách a odvtedy stagnoval. Potvrďuje to aj graf výpočtu chyby, ktorá tiež dosiahla svoje minimum. Z toho vyplýva, že model už nie je schopný sa zlepšiť a dosiahol svoje maximum. Doba jednej iterácie bola približne 27 minút.



Obr. 18 AlexNet, systém Kt Eri. (hore) Porovnanie chyby počas procesu učenia sa na tréningových dátach (modrá) a validačných dátach (oranžová). (dole) Porovnanie úspešnosti architektúry na tréningových vs validačných dátach.


Úspešnosť siete AlexNet na simulované dáta s referenčným systémom Cal 83 je zobrazená na Obr. 19. Podobne ako pri systéme KT Eri, aj tu vidíme, že sieť sa naučila klasifikovať druhy variability pomerne rýchlo. Dokonca s presnosťou ~95% na validačných dátach. Tiež môžeme vidieť ako si model upravil svoje vnútorné váhy, keď po prvej iterácii jeho úspešnosť dramaticky klesla.

Pre model ResNet-50 a systém KT Eri, sme dosiahli nasledujúce výsledky (viď Obr. 20). Ako




Obr. 19 AlexNet, systém Cal 83. (hore) Porovnanie chyby počas procesu učenia sa na tréningových dátach (modrá) a validačných dátach (oranžová). (dole) Porovnanie úspešnosti architektúry na tréningových vs validačných dátach.

sme hovorili, jedná sa o komplikovanejší model, ktorý by mal vykazovať vyššiu úspešnosť, čo sa aj potvrdilo. Hodnota presnosti na validačné dáta dosiahla hodnotu takmer 95%, čo je približne o 4% viac ako pri modeli AlexNet, čo potvrdzuje aj nižšia hodnota chyby. Keďže sa jedná o komplikovanejší model, aj doba jednej iterácie bola dlhšia, a to približne 38 minút. Preto sme pri tomto modeli sme nastavili aj hodnotu pre predčasné ukončenie tréningovania, pokiaľ sa hodnota nebude meniť dlhší čas. Preto sa vykonalo len 12 iterácií. Z grafu vidíme, že model by sa naozaj už nezlepšoval, keďže hodnota chyby dosiahla svoj limit a už neklesala.





Obr. 20 ResNet-50, systém KT Eri. (*hore*) Porovnanie chyby počas procesu učenia sa na tréningových dátach (modrá) a validačných dátach (oranžová). (*dole*) Porovnanie úspešnosti architektúry na tréningových vs validačných dátach.

Pre simulované dáta zo systému Cal 83, mala architektúra ResNet-50 úspešnosť na validačných dátach až 98%, čo je približne 3% vyššia hodnota ako dosiahla architektúra AlexNet. Keďže podobné zlepšenie sme dosiahli aj na dátach simulovaných podľa referenčného systému KT Eri je zjavné, že architektúra ResNet-50 sa vie naučiť viac z vnútornej štruktúry dát. Vidíme aj, že nami nastavenie parametra rýchlosti učenia, kedy sme jej hodnotu postupne znižovali, má zmysel. Na začiatku model rýchlejšie konvergoval k minimu, avšak veľká hodnota ho penalizovala až príliš. Jej postupným znižovaním vedel teda model konvergovať k nájdenému minimu a ostať v ňom, o čom svedčí aj fakt, že model sa rozhodol predčasne ukončiť svoje učenie z dôvodu ustálenia. Výsledok tréningovania modelu je vidno na Obr. 21.




Obr. 21 ResNet-50, systém Cal 83. (hore) Porovnanie chyby počas procesu učenia sa na tréningových dátach (modrá) a validačných dátach (oranžová). (dole) Porovnanie úspešnosti architektúry na tréningových vs validačných dátach.

Úspešnosť nami navrhutej architektúry na systém KT Eri vidíme na Obr. 22. Pri prvom spustení bola presnosť na validačných dátach iba okolo 70%, čo bolo výrazné zhoršenie oproti obom existujúcim architektúram. Aby sme sa ubezpečili že model nezostal zaseknutý v jednom z lokálnych miním, spustili sme tréning viac krát (spolu 3x krát, ako uvádzame v úvode tejto kapitoly). Tento predpoklad sa aj naplnil, keďže pri ďalších dvoch tréningoch dosiahol model presnosť nad 90%. Presnosť najlepšieho modelu ~92% na validačných dátach je porovnateľná s modelom AlexNet. Môžeme teda povedať, že zvýšenie počtu vrstiev no zníženie počtu ich filtrov na dátach zo systému KT Eri zlepšenie neprinieslo.



Obr. 22 Nami vytvorená architektúra, systém KT Eri. (*hore*) Porovnanie chyby počas procesu učenia sa na tréningových dátach (modrá) a validačných dátach (oranžová). (*dole*) Porovnanie úspešnosti architektúry na tréningových vs validačných dátach.

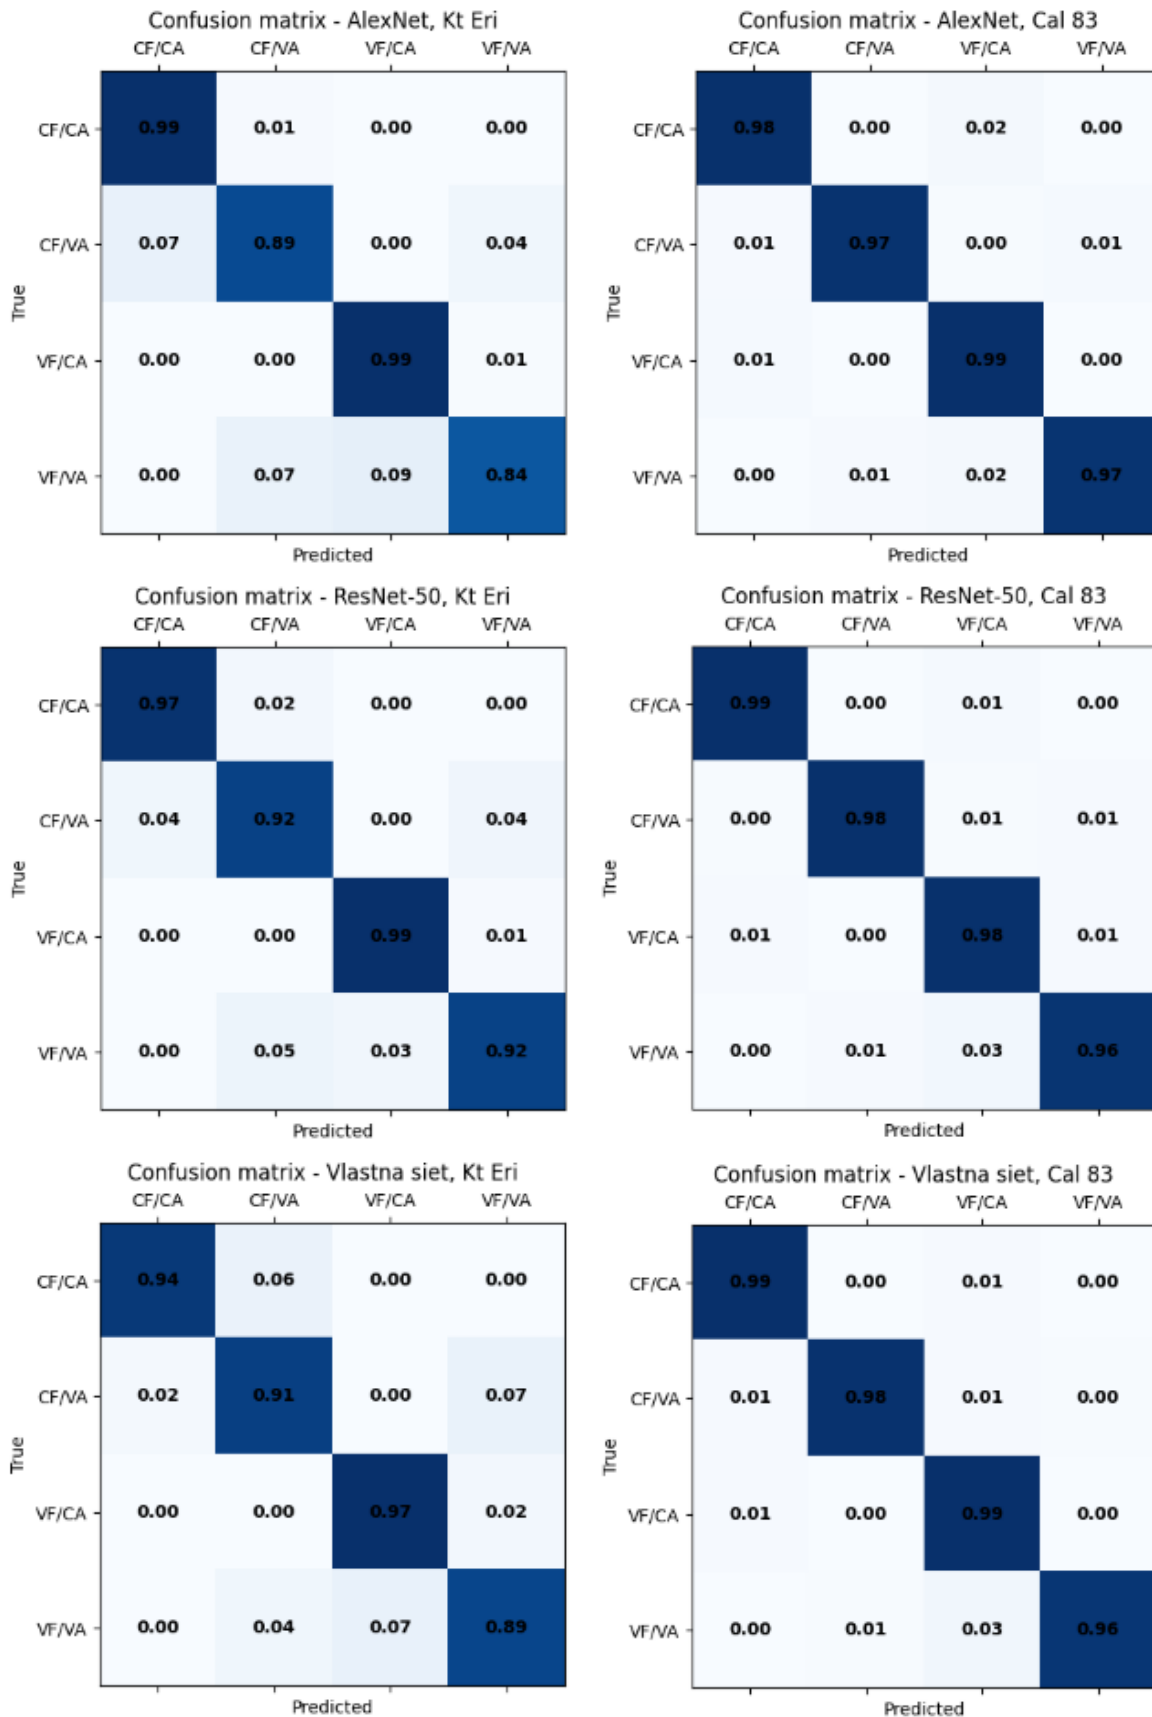
Priebeh učenia sa CNN na nami vytvorenej architektúre pre systém Cal 83 vidíme na Obr. 23. Vidíme, že zvýšený počet vrstiev oproti modelu AlexNet sa podpísal na úrovni presnosti na validačných dátach, a to na úrovni ~98%, čo je o približne 3% viac ako pri sieti AlexNet a podobná hodnota ako pri sieti ResNet-50. Z toho môžeme usudzovať, že použitie ešte komplikovanejšej architektúry CNN siete ako ResNet-50 by pravdepodobne výraznejšie zlepšenie neprinieslo. V porovnaní s použitím rovnakej architektúry na systém KT Eri je zaujímavé, že v tomto prípade model konvergoval k minimu omnoho rýchlejšie, keď už po 5-tich iteráciách bola jeho úspešnosť nad 96% na validačných dátach.



Obr. 23 Nami vytvorená architektúra, systém Cal 83. (*hore*) Porovnanie chyby počas procesu učenia sa na tréningových dátach (modrá) a validačných dátach (oranžová). (*dole*) Porovnanie úspešnosti architektúry na tréningových vs validačných dátach.

Z dosiahnutých výsledkov môžeme konštatovať, že najvyššiu presnosť vykazuje architektúra ResNet-50, ktorá oproti architektúre AlexNet priniesla zlepšenie o 3-4% pre obidva skúmané systémy. Architektúra našej siete síce priniesla úspešnosť na validačných dátach pre systém Cal 83 na úrovni siete ResNet-50 a pre systéme KT Eri na úrovni siete AlexNet. Môžeme teda skonštatovať, že sa nám podarilo vytvoriť architektúru schopnú klasifikovať typy variability v nasimulovaných systémoch. Ako by však obstála pri iných úlohách je otázne.


Krížové porovnanie medzi reálnymi a predikovanými typmi variability na použitých architektúrach CNN a testovacích dátach, ktoré majú najväčšiu výpovednú hodnotu ohľadom presnosti siete, vidíme na Obr. 24.



Obr. 24 Krížové porovnanie klasifikácie pre použité architektúry CNN na testovacích dátach. CF-konštantná frekvencia, VF-variabilná frekvencia, CA-konštantná amplitúda, VA-variabilná amplitúda.

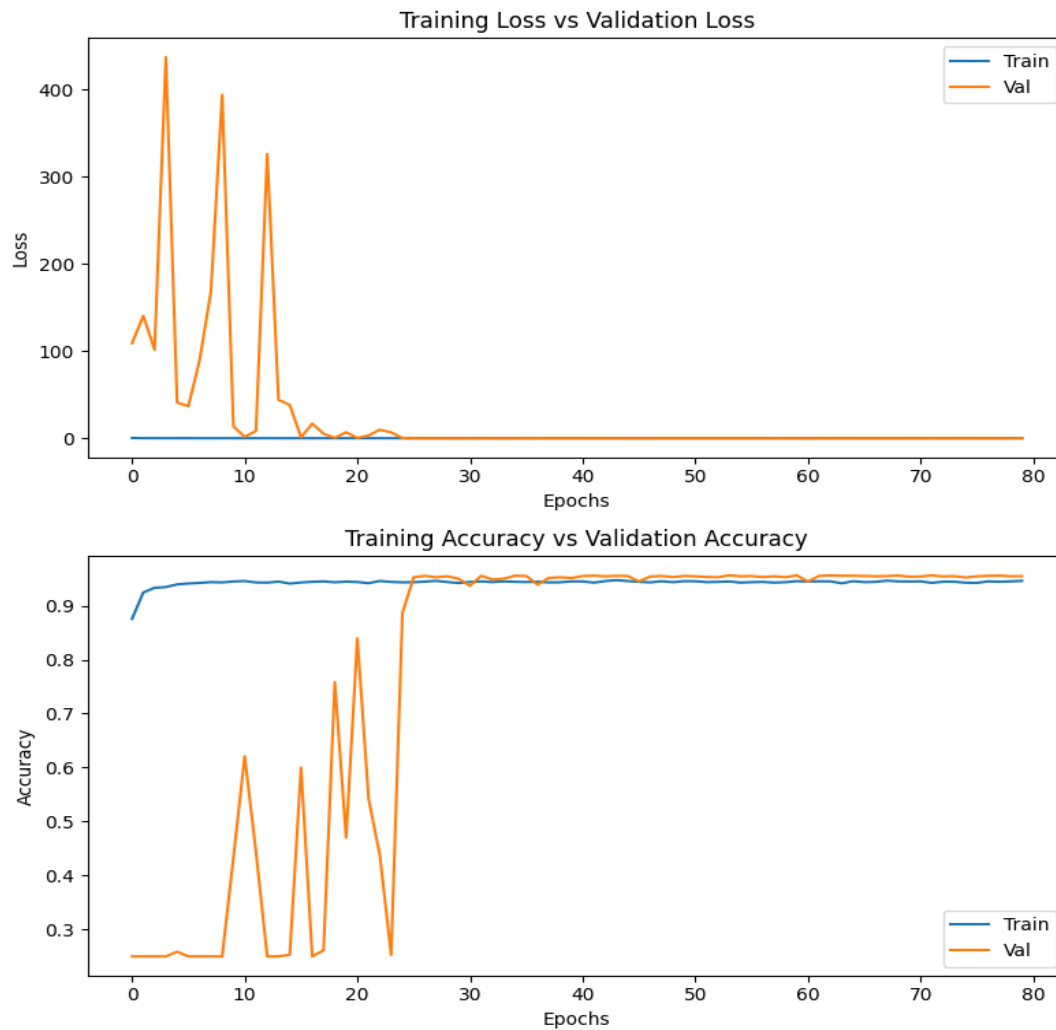
1D konvolučná sieť

Z Obr. 25 vidíme, že 1D konvolučná sieť sa trápila viac nájdením správnych vnútorných váh. Presnosť ~89% dosiahla až okolo dvadsiatej iterácie, čo je z doterajších modelov najdlhší čas, ale aj najnižšia presnosť. Treba však poznamenať, že nižšie nároky na výpočtový výkon boli zjavné, keďže doba jednej iterácie trvala približne 20 minút, čo je o tretinu rýchlejšie než v prípade siete AlexNet a takmer dvojnásobne rýchlejšie v porovnaní s modelom ResNet-50 pre systém KT Eri.



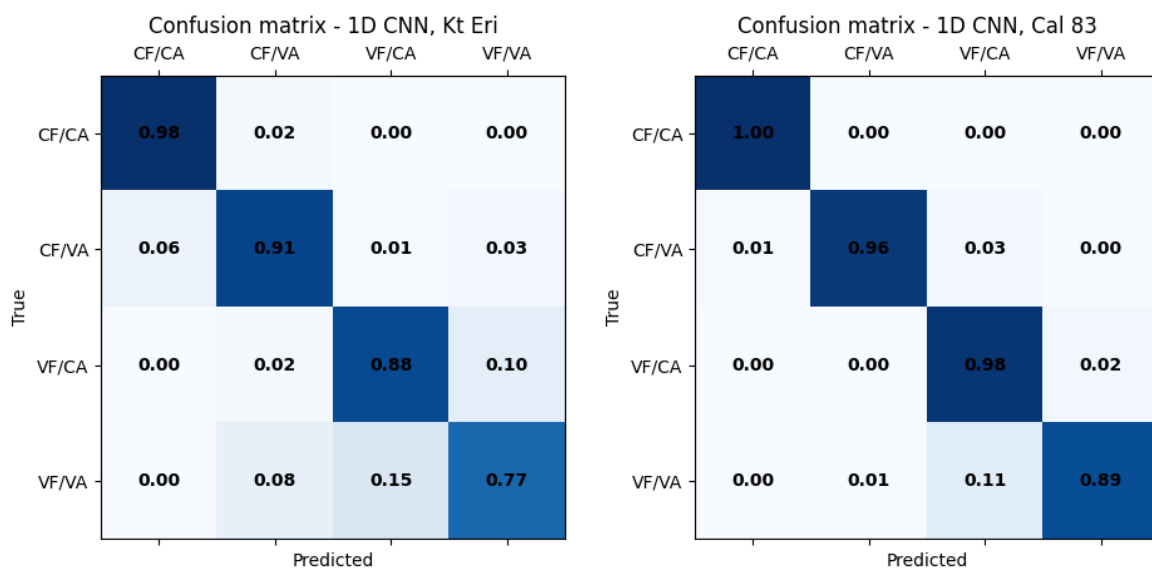
Obr. 25 1D konvolučná sieť, systém Kt Eri. (*hore*) Porovnanie chyby počas procesu učenia sa na tréningových dátach (modrá) a validačných dátach (oranžová). (*dole*) Porovnanie úspešnosti architektúry na tréningových vs validačných dátach.

Pre systém Cal 83 bola úspešnosť siete na úrovni ~94%, čo je porovnateľné s modelom AlexNet (viď Obr. 26). Aj tu však vidíme, že model dlhšie hľadal správne hodnoty váh a vyššia presnosť sa dostavila až okolo iterácie 25.



Obr. 26 1D konvolučná sieť, systém Cal 83. (*hore*) Porovnanie chyby počas procesu učenia sa na tréningových dátach (modrá) a validačných dátach (oranžová). (*dole*) Porovnanie úspešnosti architektúry na tréningových vs validačných dátach.

Křížové porovnanie na testovacích dátach medzi reálnymi a predikovanými triedami simulovaných systémov je zobrazené na Obr. 27.



Obr. 27 Krížové porovnanie klasifikácie pre 1D CNN architektúru na testovacích dátach. CF-konštantná frekvencia, VF-variabilná frekvencia, CA-konštantná amplitúda, VA-variabilná amplitúda.

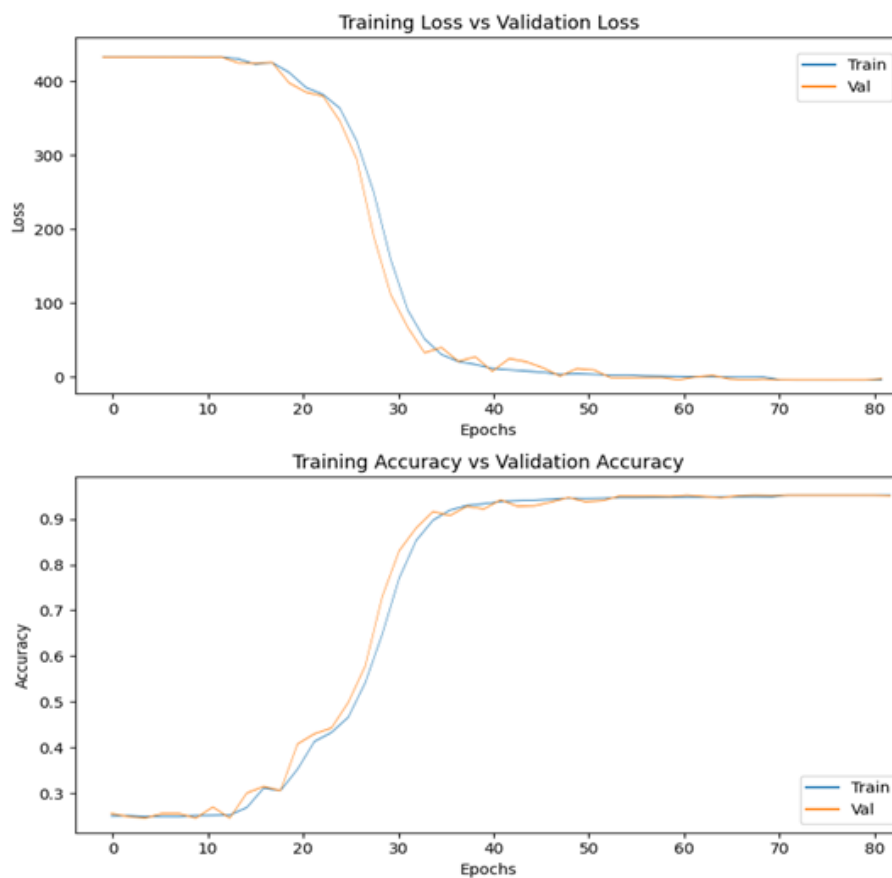
LSTM a ConvLSTM siete

Vyskúšali sme niekoľko variant LSTM siete, avšak žiadna z nich neprinesla požadovanú úspešnosť. Pre žiadny zo systémov sa hodnota úspešnosti nezdvihla nad ~25% ani po 50 iteráciách. To značí, že model nedokázal rozlíšiť jednotlivé typy variability a len hádal. Zlepšenie neprineslo ani klasifikácia systémov len do dvoch kategórií, teda či je prítomná variabilita vo frekvencii alebo je frekvencia konštantná. Hodnoty spätnej sekvencie sme nastavovali ako [1, 10, 35, 70, 140, 150, 200, 300, 500, 700, 1000, 1500, 2000, 3000, 3500, 4000, 4500]. Avšak použitím hodnoty spätnej sekvencie 150 sme dosiahli úspešnosť na úrovni 99.9% na tréningové aj validačné dáta sme dosiahli pre systém KT Eri (viď Obr. 28). Zdalo by sa, že LSTM sieť dokáže najlepšie popísať štruktúru dát a klasifikovať druhy variability s vysokou presnosťou. Tak vysoká úspešnosť je však prinajmenšom podozrivá. Preto sme na takto natrénovaný model použili aj testovacie dáta a úspešnosť klasifikácie klesla na ~25%. To značí spomínaný problém pretrénovania systému. Model našiel na tréningových a testovacích dátach nejaké vnútorné štruktúry, na základe ktorých sa naučil klasifikovať variabilitu v systémoch. Tu môžeme vidieť dôležitosť vyhodnocovania natrénovaného modelu na testovacích dátach, ku ktorým model počas tréningovania nemal prístup, čo značí pretrénovanie modelu čo značí pretrénovanie modelu. LSTM model s hodnotou spätnej väzby 150 sme potom použili na tréningové pre dáta zo systému KT Eri ešte 2x či dostaneme podobný výsledok, alebo sa naozaj jednalo o pretrénovanie modelu. Pri oboch pokusoch novo natrénovaný model nevykazoval úspešnosť vyššiu ako 27%, čo potvrdilo náš predpoklad.

Rovnako tak, ani model ConvLSTM neprinesol očakávanú úspešnosť a pre oba systémy vykazoval presnosť na úrovni ~25%, čo taktiež značí hádanie.

Vidíme teda, že aj keď sú architektúry LSTM a ConvLSTM považované za jedny z najlepších pri analyzovaní časových radov, pri našom probléme klasifikácie variability systémov neprinesli úspech. Môže za tým stáť fakt, že variabilita v systéme sa nevyskytuje na celej časovej škále, ale skôr sa zmení v určitom okamihu a zas sa ustáli. Ak sa teda spätná sekvencia počas tréningovania posúva v rámci jedného systému s variabilnou frekvenciou po jeho časovej škále, na určitých úsekoch je jeho frekvencia stála. Ak je však tento systém označený ako systém s variabilnou frekvenciou, model bude stále meniť svoje parametre a nebude

konvergovať k minimu. Ďalším problémom môže byť aj fakt, že tieto modely nie sú schopné zachytiť rozdiel vo frekvencii na tak malej časovej škále.



Obr. 28 Ukážka pretrénovania LSTM siete na simulovaných dátach referenčného systému Kt Eri.

Výsledné porovnanie použitých architektúr strojového učenia je zobrazené v

Tab. 1.

Úspešnosť modelov klasifikácie nasimulovaných systémov na validačných dátach sa potvrdila aj na dátach testovacích. Pri dátach simulovaných na základe referenčného systému KT Eri bola najúspešnejšia sieť ResNet-50, naopak najmenej úspešná bola architektúra ConvLSTM. Pri systéme Cal 83 vidíme, že aj keď bol rozdiel v úspešnosti modelov na trénovacích a validačných dátach pri jednotlivých modeloch pomerne veľký, na testovacích dátach majú všetky CNN modely veľmi podobnú úspešnosť.

Ako sme už spomínali, architektúra LSTM a ConvLSTM vykazujú úspešnosť na úrovni 25%, čo značí hádanie. Môžeme teda skonštatovať, že tieto dve siete nedokázali nájsť variabilitu v dátach, a teda v našom prípade neboli úspešné.

Tab. 1 Porovnanie úspešnosti použitých architektúr strojového učenia na testovacích dátach.

	AlexNet	ResNet-50	Naša sieť	1D CNN	LSTM	ConvLSTM
KT Eri	92,73%	94,92%	92,93%	88,67%	25,53%	24,46%
Cal 83	97,58%	97,7%	97,88%	95,57%	24,92%	25,17%

Nami navrhnutá sieť dosiahla na testovacích dátach pre systém Cal 83 najvyššiu úspešnosť zo všetkých, pre systém KT Eri úspešnosť na úrovni siete AlexNet. Môžeme teda skonštatovať, že sa nám podarilo vytvoriť sieť s pomerne vysokou úspešnosťou. Model ResNet-50 je však robustnejší, keďže v priemere oboch systémoch dosiahol najlepšie výsledky. Vložením referenčných časových máp do natrénovaných modelov dostávame výsledky ukázané v Tab. 2.

Tab. 2 Klasifikácia variability systému KT Eri a Cal 83 na vybrané modely.

KT Eri	CF/CA	CF/VA	VF/CA	VF/VA
AlexNet	0,2%	95,93%	0,09%	3,78%
ResNet-50	2,39%	97,35%	0,06	0,2%
Naša sieť	31,6%	49,72%	5,32%	13,36%
1D CNN	0,01%	2,77%	92,95%	4,27%
Cal 83				
AlexNet	0%	0%	99,81%	0,19%
ResNet-50	0,65%	2,05%	85,88	11,42
Naša sieť	3,12%	16,12%	42,59%	38,17%
1D CNN	0%	0,03%	0,04%	99,93%

Vidíme, že systém KT Eri bol modelmi AlexNet a ResNet-50 s vysokou pravdepodobnosťou klasifikovaný ako konštantný vo frekvencii a variabilný v amplitúde. Naša sieť nám dala rovnaký výsledok, však s pravdepodobnosťou približne 50%. Vidíme však, že aj keď je systém klasifikovaný 31,6% ako konštantný v amplitúde aj vo frekvencii, stále sa jedná o typ variability, kedy je frekvencia konštantná. To je v rozpore s článkom [1], kde bol na základe dvoj-vrcholov v periodograme klasifikovaný ako pravdepodobne variabilný vo frekvencii.

Systém Cal 83 bol klasifikovaný s najväčšou pravdepodobnosťou ako variabilný vo frekvencii všetkými modelmi konvolučných neurónových sietí. Aj keď ho naša sieť klasifikovala s 38% ako variabilný vo frekvencii aj v amplitúde vidíme, že sa stále jedná o variabilitu vo frekvencii. Tento výsledok je v súlade s článkom [1], kde bol rovnako tak označený ako variabilný vo frekvencii.

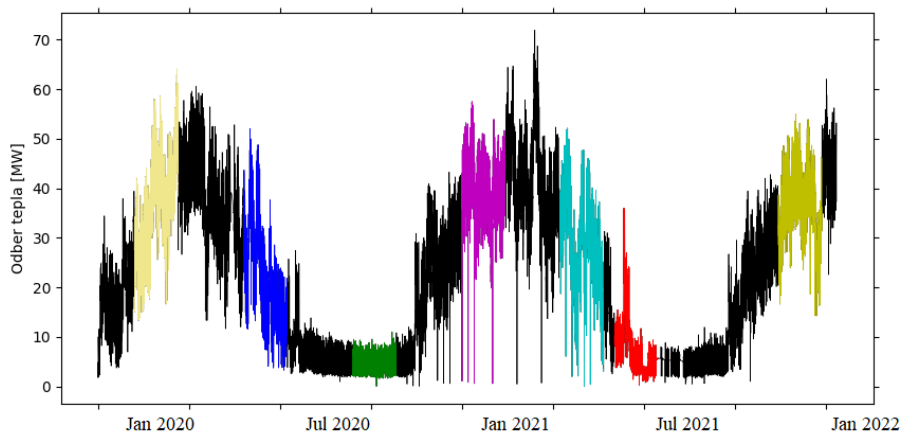
Zaujímavé je však porovnanie 2D s 1D konvolučnou sieťou. Vidíme, že hlavne pri systéme KT Eri sme dosiahli úplne odlišné výsledky vzhľadom k variabilite systému vo frekvencii. Čo prinieslo takýto rozdiel vo výsledku nie je známe. Zdá sa však, že časová informácia je pre

správne vyhodnotenie variability dôležitá a tá v periodogramoch chýba na rozdiel od časovej mapy.

Praktické využitie mimo oblasti astrofyziky

Zistiť povahu signálu a jeho variabilitu je dôležitou súčasťou v oblasti riadenia a predikcie systému. Prítomná variabilita vo frekvencii môže riadenie takéhoto systému značne skomplikovať. Preto je žiadúce zistiť či je variabilita v signáli spôsobená na úrovni amplitúdy alebo frekvencie.


Analýzou a predikciou odberu tepla a teploty spiatocky pre sústavu centrálného zásobovania teplom sa venuje autor v práci [14]. Z celého monitorovacieho obdobia o dĺžke 20 304 hodín sme náhodne vybrali 7 úsekov s dĺžkou 1200 hodín, čo je vidieť na Obr. 29.



Obr. 29 Poskytnuté dáta zobrazujúce odber tepla z elektrárne a nami náhodne vybrané skúmané úseky sú vyznačené farebne.


Porovnaním periodogramov (viď

Obr. 30) z týchto úsekov vidíme posun vo frekvencii v signáli vyznačeného červenou farbou na úrovni 3,6 minúty. Všetky ostatné periodogramy ukazujú jeden dominantný signál okolo $0,0415d^{-1}$. Tu nastáva otázka či je tento posun vo frekvencii reálny alebo sa jedná o posun v rámci chyby merania. Skúmaný červený signál však okrem posunu dominantného signálu obsahuje aj výraznú štruktúru medzi $0,0425d^{-1}$ a $0,045d^{-1}$ podobnú dvoj-vrcholu a menšiu medzi $0,039d^{-1}$ a $0,04d^{-1}$. Rovnako sa tak môžeme pýtať či je prítomný dvoj-vrchol výsledkom variabilnej frekvencie alebo variabilnej amplitúdy. Naskytá sa tak možné použitie nami opísanej metódy simulácie a klasifikácie signálu.



Obr. 30 Periodogramy z vybraných časových úsekov z Obr. 29.

Rovnakým spôsobom ako sme simulovali dáta pre nova systémy KT Eri a Cal 83 (kapitola 1.3), vytvorili sme simulované dáta aj pre tento skúmaný časový úsek (červený signál). Následne sme z týchto dát vytvorili časové mapy spôsobom opísaným v kapitole 1.4 tak, ako pre nova systémy. Časová mapa pre vybraný červený úsek signálu je zobrazená na Obr. 31. Na nej je jasne vidieť dva komponenty, čo by znamenalo prítomnosť dvoch signálov. V práci sme však ukázali, že takýto vzor môže zapríčiniť aj variabilná amplitúda pri konštantnej frekvencii.



Obr. 31 Vytvorená časová mapa pre skúmaný signál označený červenou farbou na Obr. 29.

Vytvorené časové mapy s rôznym typom variability (konštantná amplitúda aj frekvencia, konštantná frekvencia variabilná amplitúda, variabilná frekvencia konštantná amplitúda, variabilná frekvencia aj amplitúda) sme vložili do neurónovej siete ResNet-50, ktorá vykazovala najlepšiu presnosť pre oba nova systémy.

Úspešnosť siete na testovacích dátach bola 83% a signál klasifikovala podľa Tab. 3.

Tab. 3 Klasifikácia skúmaného signálu architektúrou ResNet-50.

	CF/CA	CF/VA	VF/CA	VF/VA
ResNet-50	0%	0,08%	87,7%	12,22%

Z výsledkov klasifikácie vidíme, že neurónová sieť klasifikovala signál ako variabilný vo frekvencii, a teda posun signálu v periodograme na úrovni 3,6 minúty je pravdepodobne reálny. To, čomu tento posun zodpovedá je však nad rámec predkladanej dizertačnej práce. Ostatné signály boli klasifikované ako konštantné v amplitúde aj vo frekvencii na 93% a viac, čo je potvrdenie výsledkov z periodogramu.

4 Záver

Počiatok tejto práce spočíva v článku [3] kde autori na základe početných simulácií ukázali, že dvoj-vrchol v periodograme nemusí nutne znamenať prítomnosť dvoch blízkych frekvencií. Rovnaký dvoj-vrchol môže byť aj výsledkom jednej frekvencie s meniacou sa amplitúdou. Obe vysvetlenia sú relevantné a nie je možné s určitosťou povedať aký typ variability skúmaný systém vykazuje. Na základe takéhoto dvoj-vrcholu boli v publikácii [1] nova systémy KT Eri a Cal 83 označené ako pravdepodobne variabilné vo frekvencii.

Preto sme sa rozhodli tieto dva systémy preskúmať a aplikovať algoritmy strojového učenia pri odpovedi za otázkou, aký typ variability tieto systémy vykazujú.

V prvej časti práce sme sa venovali problematike časových radov. Tu sme zadefinovali základné používané pojmy z pravdepodobnosti, štatistiky a frekvenčnej analýzy signálov, ktoré sú potrebné z hľadiska analýzy signálu.

Monte Carlo simuláciami sme na základe skúmaných nova systémov nasimulovali desaťtisíce ďalších systémov s rôznymi typmi variability, konkrétne:

- s konštantnou frekvenciou a konštantnou amplitúdou
- s konštantnou frekvenciou a variabilnou amplitúdou
- s variabilnou frekvenciou a konštantnou amplitúdou
- s variabilnou frekvenciou a variabilnou amplitúdou

Vytvorením periodogramov a časových máp, symbolizujúcimi vývoj frekvencie systému v čase z nasimulovaných svetelných kriviek, sme vytvorili súbor dát potrebných pre použitie algoritmov strojového učenia. Tento proces je popísaný v druhej časti práce.

Tretia časť popisuje známe a najčastejšie používané algoritmy strojového učenia v oblasti regresie a klasifikácie. Postupne sme popísali princíp učenia sa, validácie a vyhodnocovania úspešnosti týchto algoritmov, rôzne techniky pre zlepšenie výkonnosti a ukázali sme rozdiel medzi strojovým učením a neurónovými sieťami, ktoré sme neskôr aj používali na klasifikáciu nami nasimulovaných systémov.

Použitím rôznych existujúcich modelov konvolučných a rekurentných neurónových sietí ako aj vytvorením vlastnej architektúry konvolučnej siete sme sa venovali vo štvrtej časti práce. Ukázali sme, že napriek popularite LSTM a ConvLSTM sietí pri riešení problémov s časovými radmi, nedokázali tieto algoritmy detegovať variabilitu, resp. zmenu vo frekvencii v nami skúmaných systémoch na rozdiel od publikácie [12]. Naopak, konvolučné neurónové siete vykazovali vysokú presnosť pre všetky skúmané architektúry a ich široké využitie v praxi pri úlohách s obrazovými dátami je opodstatnené.

V poslednej časti sa snažíme zodpovedať otázku či algoritmy strojového učenia dokážu identifikovať variabilitu v skúmaných nova systémoch a nájsť rozdiely medzi rôznymi druhmi variability - čo môže byť, ako sme ukázali, pri štandardných metódach frekvenčnej analýzy často zavádzajúce. Použitím úspešných modelov na systémoch KT Eri a Cal 83 sme zistili, že síce bol systém KT Eri klasifikovaný ako variabilný vo frekvencii, konvolučné neurónové siete ho klasifikovali ako konštantný vo frekvencii a variabilný v amplitúde. Tento výsledok naznačuje, že dvoj-vrchol v periodograme je pravdepodobne vytvorený variabilitou v amplitúde a nejedná sa o reálnu zmenu vo frekvencii ako je naznačené v článku [1]. Systém Cal 83 bol klasifikovaný ako variabilný vo frekvencii, čo je v súlade so spomínanou publikáciou. Podobnou analýzou na dátach z tepelnej sústavy sme ukázali že sa jedná o skutočný problém vyskytujúci sa aj v automatizácii a analýza zdanlivej variability signálu je dôležitá.

Hlavným cieľom dizertačnej práce bolo zistiť *či je možné na základe analýzy signálu s určitou povedať, aký typ variability skúmaný systém vykazuje*. Úspešné splnenie cieľa bolo podmienené čiastkovými cieľmi definovanými nasledovne:

1. Zhodnotiť problematiku analýzy signálu a časových radov
2. Navrhnuť metódu pre simuláciu časových radov s premenlivou amplitúdou a/alebo periódou
3. Popísať aktuálny stav algoritmov strojového učenia
4. Navrhnuť možnú architektúru strojového učenia a porovnať ju s najpoužívanejšími v tejto oblasti
5. Aplikovať vybrané architektúry strojového učenia na študované dáta
6. Zhodnotiť dosiahnuté výsledky

V tejto práci sme ukázali, že základná analýza signálu nemusí byť vždy dostatočná a výsledky ohľadom variability signálu získané z periodogramov treba vedieť správne interpretovať a podporiť aj inými metódami analýzy signálu, resp. simuláciami. Môžeme teda konštatovať, že aj na základe realizácie jednotlivých čiastkových cieľov predkladanej dizertačnej práce bol **stanovený cieľ dizertačnej práce splnený**.

ZOZNAM PUBLIKAČNEJ ČINNOSTI

V3 Vedecký výstup publikačnej činnosti z časopisu

1. MAGDOLEN, Jozef; DOBROTKA, Andrej; MIKOLAJEWSKA, J; VANDERBURG, A; MONARD, B; ALOISI, R; BEZÁK, P. Recurrent mini-outburst and a magnetic white dwarf in the symbiotic system FN Sgr, *Astronomy & Astrophysics*, 675. s. 1—9. 2023. DOI: 10.1051/0004-6361/202345935. ISSN: 0004-6361 (2023: 6.24 – IF, Q1)
2. ORIO, M.; GENDREAU, K.; GIESE, M.; LUNA, G. J. M.; MAGDOLEN, Jozef; STROHMAYER, T. E.; ZHANG, A. E.; ALTAMIRANO, D; DOBROTKA, Andrej; ENOTO, T; FERRARA, E. C.; IGNACE, R.; HEINZ, S.; MARKWARDT, C.; NICHOLS, J. S.; PARKER, M. L.; PASHAM, D. R.; PEI, S.; PRADHAN, P.; REMILLARD, R.; STEINER, J. F.; TOMBESCI, F. The RS Oph Outburst of 2021 monitored in X-rays with NICER *Astrophysical journal*, s. 1--38. 2023. DOI: 10.48550/arXiv.2307.11485. ISSN: 0004637X, 15384357 (2023: 5.521 – IF, Q1)
3. NESS, Jan-Uwe; BEARDMORE, A.P.; BODE, M.F.; DARNLEY, M.J.; DOBROTKA, Andrej; DRAKE, J.J.; MAGDOLEN, Jozef; MUNARI, U.; OSBORNE, Julian. P.; ORIO, M.; PAGE, K. L.; STARRFIELD, Sumner. High-resolution X-ray spectra of RS Ophiuchi (2006 and 2021): Revealing the cause of SSS variability. *Astronomy & Astrophysics*, 670. s. 1--18. 2023. DOI: 10.1051/0004-6361/202245269. ISSN: 0004-6361 (2023: 6.24 – IF, Q1)
4. ORIO, M.; GENDREAU, K.; GIESE, M.; LUNA, G. J. M.; MAGDOLEN, Jozef; PEI, Songpeng; SUN, B.; BEHAR, E.; DOBROTKA, Andrej; MIKOLAJEWSKA, J.; PASHAM, Dheera R.; STROHMAYER, T.E. NICER Monitoring of Supersoft of X-Ray Sources. *Astrophysical journal*, 932. s. 1--19. 2022. DOI: 10.3847/1538-4357/ac63be. ISSN: 0004637X, 15384357 (2022: 5.521 – IF, Q1)

V2 Vedecké práce v zahraničných recenzovaných vedeckých zborníkoch, monografiách

1. MAGDOLEN, Jozef; DOBROTKA, Andrej. Classification of system variability using a CNN. In: Springer, *Astrophysics and Space Science Proceedings: Machine Learning for Astrophysics: International Conference (ML4ASTRO)*, volume 60. Springer, 2023. ISBN: 978-3-031-34166-3

V2 Vedecký výstup publikačnej činnosti ako časť editovanej knihy alebo zborníka

1. DOBROTKA, Andrej; BEZÁK, Pavol; MAGDOLEN, Jozef; BENKA, Denis. Fast variability in accretion systems research group. In: REŠETOVÁ, Kvetoslava. *Bulletin vedeckých príspevkov: Bulletin vedeckých príspevkov z projektu Vedeckovýskumné centrum excelentnosti Slovakiion pre materiálový a interdisciplinárny výskum*. Bratislava : Spektrum, 2022, s. 35--40. ISBN 978-80-227-5220-6.

Citácia v publikácii registrovaná v citačných indexoch			
	Zahraničné		4
Súčet			4

Štatistika: indexované v databáze

SCOPUS	4
--------	---

Účasť na projektoch:

Názov: Použitie neurónových sietí na klasifikáciu variability signálu. Mladý výskumník
2022

Úloha: Zodpovedný riešiteľ

Názov: Hľadanie multikomponentného charakteru flickeringu v akrečných systémoch.
VEGA 1/0408/20

Úloha: riešiteľ

Názov: STU ako líder Digitálnej koalície. 2019

Úloha: riešiteľ

Zoznam použitej literatúry

- [1] NASA HEASARC. Introduction to Cataclysmic Variables (CVs), 2017. [online]. [cit. 7.4.2021]. Dostupné z <<https://heasarc.gsfc.nasa.gov/docs/objects/cvs/cvstext.html>>
- [2] J.-U. Ness at all. Short-period X-ray oscillations in super-soft novae and persistent super-soft sources. *Astronomy & Astrophysics*, 2018. [online]. [cit. 20.4.2021]. Dostupné z <<https://arxiv.org/pdf/1503.00186.pdf>>
- [3] A. Dobrotka, J.-U. Ness. Counter evidence against multiple frequency nature of 0.75 mHz oscillation in V4743 Sgr. *Royal Astronomical Society*, 2017. [online]. [cit. 6.4.2021]. Dostupné z <<https://academic.oup.com/mnras/article/467/4/4865/3043737>>
- [4] M. Orio, A. Dobrotka, C. Pinto, M. Henze, J.-U. Ness, N. Ospina, S. Pei, E. Behar, M. F. Bode, S. Her, M. Heranz, G. Sala. Nova LMC 2009a as observed with XMM-Newton, compared with other novae. *Monthly Notices of the Royal Astronomical Society*, 2021. [online]. [cit. 20.5.2023]. Dostupné z <<https://arxiv.org/abs/2105.05346>>
- [5] M. Kvet. Úvod do modelovania a simulácie, metóda Monte Carlo. Žilinská univerzita v Žiline, 2015. [online]. [cit. 10.4.2021]. Dostupné z <http://www.fsi.uniza.sk/ktvi/leitner/2_predmety/SMOA/04_StatistikaExcel/MCprednaska.pdf>
- [6] IBM Cloud Education. Monte Carlo Simulation. IBM Cloud Learn Hub, 2020. [online]. [cit. 10.4.2021]. Dostupné z <<https://www.ibm.com/cloud/learn/monte-carlo-simulation>>
- [7] K. Bressemer, L. Adams, Ch. Erxleben, B. Hamm, S. Niehues, J. Vahldiek. Comparing different deep learning architectures for classification of chest radiographs. *Nature*, 2020. [online]. [cit. 17.6.2023]. Dostupné z <<https://www.nature.com/articles/s41598-020-70479-z>>
- [8] J. Brownlee. How to Evaluate Pixel Scaling Methods for Image Classification With CNNs. *Machine Learning Mastery*, 2019. [online]. [cit. 26.4.2021]. Dostupné z <<https://machinelearningmastery.com/how-to-evaluate-pixel-scaling-methods-for-image-classification/>>
- [9] M. Jahromi, P. Buch-Cardona, E. Avots, K. nasrollahi. Privacy-Constrained Biometric System for Non-Cooperative Users. *Entropy*, 2021. [online]. [cit. 18.6.2023]. Dostupné z <https://www.researchgate.net/publication/336805103_Privacy-Constrained_Biometric_System_for_Non-Cooperative_Users>
- [10] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna. Rethinking the Inception Architecture for Computer Vision. Google, 2015. [online]. [cit. 17.6.2023]. Dostupné z <<https://arxiv.org/abs/1512.00567>>
- [11] S. Kiranyaz, O. Avci, O. Abdelijaber, T. Ince, M. Gabbouj, D. J. Inman. 1D Convolutional Neural Networks and Applications: A Survey. Elsevier, 2019. [online]. [cit. 22.6.2023]. Dostupné z <<https://arxiv.org/abs/1905.03554>>
- [12] U. F. Burhanudin at al., Light curve classification with recurrent neural networks for GOTO: dealing with imbalanced data. *Monthly Notices of the Royal Astronomical Society*, 2020. [online]. [cit. 28.3.2023]. Dostupné z <<https://ui.adsabs.harvard.edu/abs/2021MNRAS.505.4345B/abstract>>
- [13] X. Shi, Z. Chen, H. Wang, D.-Y. Yeung, Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. MIT Press, 2015. [online]. [cit. 15.5.2023]. Dostupné z <<https://arxiv.org/pdf/1506.04214v2.pdf>>
- [14] S. Kováč. Analýza, návrh a verifikácia metód riadenia energetických systémov. Materiálovotechnologická fakulta v Trnave, Slovenská technická univerzita v Bratislave. [cit. 15.8.2023]. Dizertačná práca v štádiu prípravy.