

Technická univerzita v Košiciach
Fakulta elektrotechniky a informatiky

**Predikcia ionosferických scintilácií
pomocou hlbokého učenia**

Diplomová práca

2023

Bc. Adrián Kandrát

Technická univerzita v Košiciach
Fakulta elektrotechniky a informatiky

**Predikcia ionosferických scintilácií
pomocou hlbokého učenia**

Diplomová práca

Študijný program: Hospodárska informatika
Študijný odbor: Informatika
Školiace pracovisko: Katedra kybernetiky a umelej inteligencie (KKUI)
Školiteľ: doc. Ing. Peter Butka, PhD.
Konzultant: Ing. Viera Krešňáková, PhD.
RNDr. Šimon Mackovjak, PhD.

Košice 2023

Bc. Adrián Kandrát

Abstrakt v SJ

Ionosféra Zeme predstavuje rozhranie medzi vesmírnym prostredím a Zemou. Zároveň je to vrstva atmosféry, ktorá obsahuje nabité častice (elektróny a ióny), ktoré môžu výrazne ovplyvniť prenos signálu z kozmických satelitov. Narušenie amplitúdy a fázy rádiových vln vplyvom porúch v ionosfére sa nazýva ionosférická scintilácia. Prvým cieľom diplomovej práce je vytvorenie teoretického prehľadu aplikácií hlbokého učenia v oblasti predikcie ionosférických scintilácií a vytvorenie prehľadu relevantných dát pre predikciu ionosférických scintilácií. Druhým cieľom je vyvinutie modelu s využitím hlbokých neurónových sietí, schopného poskytovať časovo-priestorové predikcie ionosférických scintilácií s hodinovým predstihom.

Kľúčové slová

ionosférická scintilácia, hlboké učenie, atmosféra, neurónové siete, vesmírny výskum

Abstrakt v AJ

The Earth's ionosphere is the interface between the space environment and the Earth. It is also the layer of the atmosphere that contains charged particles (electrons and ions) that can significantly affect the transmission of signals from space satellites. The disturbance of the amplitude and phase of radio waves due to disturbances in the ionosphere is called ionospheric scintillation. The first objective of this thesis is to provide a theoretical overview of deep learning applications in the field of ionospheric scintillation prediction and to develop a survey of relevant data for ionospheric scintillation prediction. The second objective is to develop a model using deep neural networks capable of providing spatio-temporal predictions of ionospheric scintillations with an hourly lead time.

Kľúčové slová v AJ

ionospheric scintillation, deep learning, atmosphere, neural networks, space research

TECHNICKÁ UNIVERZITA V KOŠICIACH
FAKULTA ELEKTROTECHNIKY A INFORMATIKY
Katedra kybernetiky a umelej inteligencie

ZADANIE
DIPLOMOVEJ PRÁCE

Študijný odbor: **Informatika**
Študijný program: **Hospodárska informatika**

Názov práce:

Predikcia ionosferických scintilácií pomocou hlbokého učenia

Prediction of ionospheric scintillations by deep learning

Študent: **Bc. Adrián Kunderát**
Školiteľ: **doc. Ing. Peter Butka, PhD.**
Školiace pracovisko: **Katedra kybernetiky a umelej inteligencie**
Konzultant práce: **RNDr. Šimon Mackovjak, PhD., Ing. Viera Maslej
Krešňáková, PhD.**
Pracovisko konzultanta: **Ústav experimentálnej fyziky SAV**

Pokyny na vypracovanie diplomovej práce:

1. Podať teoretický prehľad problematiky metód hlbokého učenia, s dôrazom na vhodné metódy pre predikciu ionosférických scintilácií.
2. Získať a predspracovať dáta pre predikciu ionosférických scintilácií.
3. Navrhnuť, realizovať a vyhodnotiť experimenty s predikciou ionosférických scintilácií pomocou hlbokého učenia na pripravenej množine dát.
4. Vypracovať dokumentáciu podľa pokynov katedry a vedúceho práce.

Jazyk, v ktorom sa práca vypracuje: slovenský
Termín pre odovzdanie práce: 21.04.2023
Dátum zadania diplomovej práce: 31.10.2022



prof. Ing. Liberios Vokorokos, PhD.

dekan fakulty

Čestné vyhlásenie

Vyhlasujem, že som diplomovú prácu vypracoval samostatne s použitím uvedenej odbornej literatúry.

Košice 21. 4. 2023

.....

Vlastnoručný podpis

Podakovanie

Chcel by som sa poďakovať vedúcemu práce, doc. Ing. Petrovi Butkovi, PhD. za hodnotné rady a pripomienky ku práci. Zároveň vďaka patrí dvojici konzultantov, RNDr. Šimonovi Mackovjakovi, PhD. a Ing. Viere Krešňákovej, PhD. za ich čas, ochotu a trpezlivosť pri konzultáciách aj mimo nich. Taktiež ďakujem aj tímu ASPIS za spoluprácu. Nekonečná vďaka patrí aj mojej rodine za podporu bez ohľadu na situáciu a Pánu Bohu za všetko.

Obsah

Úvod	1
1 Predikcia ionosférických scintilácií	3
1.1 Analýza literatúry	4
1.1.1 Výskumy zaoberajúce sa doménou	5
2 Dáta	10
2.1 Analýza dostupných dát	10
2.1.1 Vstupná analýza a popis hodnôt	10
2.1.2 Rozdelenie dát do binov	18
2.1.3 Popis scintilačných dát	19
2.2 Selekcia relevantných hodnôt na tréning	21
2.2.1 ANOVA	22
2.2.2 Korelačná matica	25
3 Vývoj modelov strojového učenia	28
3.1 Metódy použité na vyhodnotenie a nájdenie optimálnej prahovej hodnoty	28
3.2 Príprava dát na modelovanie	34
3.2.1 Normalizácia	34
3.2.2 Okná a horizonty	35
3.2.3 Chýbajúce hodnoty	37
3.2.4 Určovanie veľkosti okien	37
3.3 Hlboké učenie	41
3.3.1 Autoregresná predikcia časových radov	42
3.3.2 Multivariačná predikcia časových radov	44
3.3.3 Základná architektúra multivariačného modelu	45
4 Vyhodnotenie modelov	48

4.1	Kvantitatívne vyhodnotenie	48
4.1.1	Predikcia perzistencie	49
4.1.2	Predikcia časových radov pomocou autoregresného modelu . .	51
4.1.3	Predikcia časových radov pomocou multivariačného modelu . .	57
4.1.4	Porovnanie predchádzajúceho výskumu na dátach CHAIN . .	62
4.2	Kvalitatívne vyhodnotenie	64
4.2.1	Predikcia časových radov pomocou autoregresného modelu . .	65
4.2.2	Predikcia časových radov pomocou multivariačného modelu . .	66
4.3	Vyhodnotenie modelov na IMPC dátovom sete	68
5	Záver	76
	Zoznam príloh	83

Zoznam obrázkov

1–1	Škála účinkov ionosféry a jej nepravidelnosti na príjem signálu (SWC, (accessed June 22, 2022)	4
2–1	Boxplot pre F10.7 index pre každý rok v rozsahu 2000 až 2021. Zdroj: OMNIWeb (<i>NASA/OMNIWeb</i> , n.d.).	13
2–2	Boxplot pre rýchlosť slnečného vetra (<i>SW speed</i>) pre každý rok v rozsahu 2000 až 2021. Zdroj: OMNIWeb (<i>NASA/OMNIWeb</i> , n.d.).	15
2–3	Všetky uvažované siete monitorovacích prijímačov ionosférických scintilácií zakreslené na mape.	20
2–4	Ukážka fázového scintilačného javu nad Kanadou pre bin 13616. Farba predstavuje hodnotu parametra σ_ϕ	21
2–5	Graf dostupnosti údajov z monitorovacej služby CHAIN. Zdroj: http://chain.physics.unb.ca/chain/pages/data_availability	22
2–6	Príklad merania lokálnych scintilačných indexov v jednej z lokalít IMPC - Kiruna (SE). Merania sú farebne označené podľa PRN kódu satelitov GNSS. Archivované údaje a údaje v reálnom čase sú k dispozícii prostredníctvom https://swe.ssa.esa.int/swaci-federated	23
2–7	Poradie ukazovateľov vesmírneho počasia na základe analýzy ANOVA pre bin č. 13839. Hodnoty σ_ϕ sú 60 minút pred časom klasifikovaných prvkov. Zobrazené sú len prvky s Fisherovým skóre vyšším ako 500, pretože sú najrelevantnejšie.	24
2–8	Vývoj Fisherovho skóre v závislosti od časového posunu medzi časom prvkov a časom sledovanej hodnoty – σ_ϕ . Maximálny zobrazený časový posun je 720 minút (t. j. 12 hodín). Uvedené sú len prvky s Fisherovým skóre vyšším ako 1000.	26

2–9	Hodnotenie prvkov podľa korelačnej matice pre bin č. 13839. Použité boli hodnoty σ_ϕ a hodnoty σ_ϕ , ktoré sú 60 minút pred časom ostatných prvkov. Analýza je vytvorená s použitím údajov NRLMSISE-00.	27
3–1	Štruktúra <i>confusion matrix</i> pre binárnu klasifikáciu pre pozitívnu hodnotu triedy 1 (scintilácia) a negatívnu hodnotu triedy 0 (bez scintilácie).	29
3–2	Príklady kriviek ROC a Precision-Recall.	31
3–3	Metóda posuvného okna. Pri tomto prístupe sa celý časový rad údajov rozdelí do čiastočne sa prekrývajúcich okien, pričom každé okno predstavuje podmnožinu údajov. Jedna vstupná postupnosť trénovaných údajov pozostáva z okna s predchádzajúcimi hodnotami (znázornené žltou farbou) a cieľovými hodnotami (nazývanými aj horizont, znázornené modrou farbou), ktoré sú oddelené zvoleným časovým posunom.	36

- 3–4 Prístup zvolený na vyváženie tried je založený na znovuo značovaní na základe kontextu. Pri výbere prahu pre detekciu anomálií bolo dôležité zohľadniť kontext dát a okolité hodnoty. Tento kontext označenia má svoju šírku definovanú parametrom `y_look_side` (v tomto príklade rovná sa 3). Predstavme si, že máme okná predchádzajúcich hodnôt a ich cieľové horizonty pre zvolený časový posun, s označením šírky 3. V prvom prípade (zelená farba) hodnoty naznačujú scintiláciu na cieľovom horizonte (čierna šípka reprezentuje časový posun), aj keď stred označenia cieľového horizontu je nízky (pre `scintillation_threshold` na úrovni 0,1). Rozhodnutie sa opiera o existenciu aspoň 3 hodnôt (alebo všeobecne `y_count_win`) nad prahom scintilácie v označenom kontexte. Preto by sme mali považovať hodnotu cieľového horizontu (zobrazenú v modrej farbe) za výskyt scintilácie (pozitívnu triedu) namiesto normálnej hodnoty (negatívna trieda), aj keď má sama o sebe malú hodnotu. V druhom prípade (červená farba) hodnoty neindikujú scintiláciu na cieľovom horizonte, pretože hodnoty v označenom kontexte sú väčšinou pod prahom. Preto sme v druhom príklade neoznačili cieľovú hodnotu horizontu ako scintiláciu. 40
- 3–5 Zhrnutie architektúry použitého autoregresného neurónového modelu. Model sa skladá z vstupnej vrstvy, konvolučnej vrstvy, dvoj-*smerného* LSTM, troch *Dense* vrstiev a vrstvy *dropout*. Počet parametrov modelu je 286 273, všetky sú trénovateľné. Výsledný výstup modelu je jedna hodnota reprezentujúca predikované ionosférické scintilácie. 44

3–6	Architektúra multivariačného modelu. Základná architektúra multivariačného modelu sa skladá z dvoch vetiev, pričom každá z nich prijíma jeden vstup, nasledovaný dvojsmernou LSTM vrstvou, <i>Dense</i> vrstvou a aktivačnou funkciou ReLU. Výstupy oboch vetiev sú potom spojené a prechádzajú niekoľkými <i>Dense</i> vrstvami a vrstvami <i>dropout</i> , aby sa vytvorila finálna predikcia. Celkový počet parametrov je 79 009, pričom všetky parametre sú trénovateľné.	45
4–1	Zobrazenie výkonnosti modelu podľa umiestnenia binu a množstva údajov. Farba hodnoty TSS v každom bine označuje výkonnosť modelu, pričom tmavšie farby znamenajú nižšiu metriku TSS. Veľkosť kruhov predstavuje počet dátových bodov v každom bine. Obrázok naznačuje, že výkonnosť modelu môže byť ovplyvnená skôr počtom dátových bodov v bine ako umiestnením binu.	54
4–2	Na obrázku je zobrazené skóre AUC-PR výkonnosti modelu po následnom spracovaní („Vyhodnotenie 3“), ktoré je na geografickej mape znázornené rôznymi farbami. Tmavšia farba znamená nižšie skóre AUC-PR, čo zároveň znamená najhorší výkon modelu v danej oblasti. Mapa poskytuje intuitívne vizuálne znázornenie výkonnosti modelu v rôznych binoch.	55
4–3	Príklad grafov pre predikciu multivariačného modelu s prvkom <i>Electric Field</i> . Na časovej osi je možné rozpoznať periódy obsahujúce chýbajúce hodnoty. Na hornom paneli sú zobrazené namerané hodnoty. Na ostatných paneloch sú uvedené predikcie pre rôzne typy vyhodnotení. Výkonnosť predikcií je farebne označená. Podrobnejší opis grafu je uvedený v texte v časti 4.2.	62
4–4	Predikcia autoregresného modelu (posun o 15 minút) pre obdobie 15. marca – 20. marca 2019.	66
4–5	Predikcia autoregresného modelu (posun o 15 minút) pre obdobie 31. mája – 6. júna 2019.	67

4–6	Predikcia autoregresného modelu (posun o 15 minút) pre obdobie 2. augusta – 9. augusta 2019.	68
4–7	Predikcia autoregresného modelu (posun o 15 minút) pre obdobie 29. augusta – 6. septembra 2019.	69
4–8	Predikcia autoregresného modelu (posun o 60 minút) pre obdobie 14. marca – 19. marca 2019.	70
4–9	Predikcia autoregresného modelu (posun o 60 minút) pre obdobie 30. augusta – 11. septembra 2019.	71
4–10	Predikcia autoregresného modelu (posun o 60 minút) pre obdobie 25. októbra – 31. októbra 2019.	72
4–11	Predikcia autoregresného modelu (posun o 60 minút) pre obdobie 19. novembra – 25 novembra 2019.	72
4–12	Predikcia autoregresného modelu (shift-15-windows-45) pre obdo- bie 22. október – 28. október 2019.	73
4–13	Predikcia multivariačného modelu s prvkom Kp index (shift-15- windows-45) pre obdobie 22. október – 28. október 2019.	73
4–14	Predikcia multivariačného modelu s prvkom Kp index (shift-15- windows-45) pre obdobie 22. október – 28. október 2019.	74

Zoznam tabuliek

2-1	Zoznam všetkých analyzovaných parametrov pripravených na prístup založený na dátach (King and Papitashvili, 2005).	10
2-2	Zoznam uvažovaných sietí prijímačov na monitorovanie ionosféry. .	19
4-1	Príklad výsledkov predikcie perzistencie na 15 minút dopredu. . . .	50
4-2	Zoznam skúmaných modelov s rôznymi časovými posunmi a ich metriky pre testovací súbor (veľkosť okna bola stanovená na 45). .	52
4-3	<i>Confusion matrix</i> pre autoregresný model s posunom 15 a veľkosťou okien 45 (pozri riadok Eval 3 pre model s parametrami shift-15-windows-45 v Tabuľke 4-2 pre výpočet metrík vyhodnotenia z jeho hodnôt).	54
4-4	Zoznam skúmaných modelov s rôznymi časovými posunmi a ich metriky pre testovací súbor (veľkosť okna bola stanovená na 45). .	56
4-5	Zoznam preskúmaných multivariačných modelov NN s jednou ďalšou položkou a ich metriky pre testovaciu množinu. Zvýraznené hodnoty (tučným písmom) sú lepšie ako naša referenčná hodnota (autoregresný model, prvý riadok v tabuľke), čo znamená, že vybrané konfigurácie týchto modelov priniesli lepšie výsledky v porovnaní s rovnakými metrikami referenčnej hodnoty.	58
4-6	<i>Confusion matrix</i> pre multivariačný model kombinujúci autoregresiu s Kp indexom (pozri riadok Eval 3 pre model „Kp index“ v Tabuľke 4-5 pre hodnotiace metriky vypočítané z jeho hodnôt). .	60
4-7	Výsledky multivariačného modelu NN s pridaním niekoľkých najdôležitejších prvkov podľa analýzy ANOVA. Zvýraznené hodnoty (tučne) poskytujú hodnotiace metriky vyššie ako náš referenčný model (autoregresný model), čo naznačuje, že zvolené konfigurácie týchto modelov priniesli lepšie výsledky v porovnaní s rovnakými metrikami referenčného modelu.	63

4–8	Výsledky predikcií na hodinu vopred pomocou SVM na súbore vybraných prvkov pre rôzne typy postprocesingu; prevzaté z McGraghan et al. (2018).	63
4–9	Vyhodnotenie 15-minútových predikcií pomocou základného modelu perzistencie na súbore údajov IMPC.	74
4–10	Výsledky vyhodnotenia autoregresného a multivariačného modelu s K_p indexom (s časovým posunom 15 a veľkosťou okna 45) na testovacej podmnožine pre množinu dát IMPC.	75

Slovník termínov

ACC *Accuracy*

ASPIS *Autonomous Service for Prediction of Ionospheric Scintillations*

ANOVA *Analysis of Variance*

AUC *Area Under the Curve*

CHAIN *Canadian High Arctic Ionospheric Network*

CNN *Convolutional Neural Network*

DBF *Deep Belief Network*

ESA *European Space Agency*

FN *False Negative*

FP *False Positive*

FPR *False Positive Rate*

GNSS *Global Navigation Satellite System*

I-ESC *Ionospheric Weather Expert Service Centre*

IMPC *Ionosphere Monitoring and Prediction Center*

LSTM *Long Short-Term Memory*

ML *Machine Learning*

MLP *Multilayer Perceptron*

NN *Neural Network*

PECS *Plan for European Cooperating States*

P *Precision*

R *Recall*

RNN *Recurrent Neural Network*

ROC *Receiver Operating Characteristic*

SVM *Support Vector Machine*

SWE *Space Weather*

S2P *Space Safety Programme*

TEC *Total Electron Content*

TN *True Negative*

TNR *True Negative Rate*

TP *True Positive*

TPR *True Positive Rate*

TSS *True Skill Score*

Úvod

Ionosféra Zeme je kritická vrstva atmosféry, ktorá obsahuje nabité častice schopné ovplyvniť prenos signálov z vesmírnych satelitov. Rušenie rádiových vln spôsobené týmito nabitými časticami je známe ako ionosférická scintilácia, ktorá môže výrazne ovplyvniť satelitné komunikačné a navigačné systémy. Na zmiernenie účinkov ionosférickej scintilácie je nevyhnutné vyvinúť presné predpovedné modely. Cieľom tejto diplomovej práce je vyvinúť model založený na strojovom učení s využitím hlbokých neurónových sietí na poskytovanie priestorovo-časových predpovedí ionosférickej scintilácie s hodinovým predstihom. Využitie strojového učenia pri predpovedaní ionosférickej scintilácie je sľubná oblasť, ktorá v posledných rokoch zaznamenala významný rozvoj. Na vývoj a testovanie navrhovaného modelu sa použijú knižnice TensorFlow a Keras v jazyku Python.

Táto diplomová práca je realizovaná v spolupráci s Ústavom experimentálnej fyziky Slovenskej akadémie vied, v. v. i. a spoločnosťou GlobalLogic Slovakia s.r.o. v rámci prebiehajúceho projektu ASPIS (Autonomous Service for Prediction of Ionospheric Scintillations), ktorý je podporovaný cez program Európskej vesmírnej agentúry Plan for European Cooperating States (PECS). Cieľom projektu ASPIS je vyvinúť autonómny systém schopný poskytovať presné predpovede ionosférickej scintilácie, čo umožní zlepšiť satelitnú komunikáciu a navigáciu. Táto diplomová práca bude cenným príspevkom k projektu prostredníctvom vývoja modelu schopného predpovedať ionosférickú scintiláciu s vysokou mierou presnosti.

Navrhovaný model založený na strojovom učení bude využívať širokú škálu zdrojov údajov vrátane historických údajov o ionosférickej scintilácii, údajov o slnečnom vetre a ďalších parametrov vesmírneho počasia. Model bude vycvičený tak, aby sa naučil komplexný vzťah medzi týmito vstupnými parametrami a ionosférickou scintiláciou, čo mu umožní poskytovať presné predpovede úrovne scintilácie. Priestorovo-časové predpovede poskytované modelom budú základným nástrojom pre prevádzkovateľov satelitov a iné zainteresované strany, ktorý im umožní plánovať

a optimalizovať ich prevádzku v oblastiach ovplyvnených ionosférickou scintiláciou. Celkovo táto diplomová práca prispeje k vývoju účinnejších nástrojov na riadenie a elimináciu účinkov ionosférických scintilácií na satelitné, komunikačné a navigačné systémy.


1 Predikcia ionosférických scintilácií

Procesy v blízkom vesmíre a na Zemi oddeľuje takzvaná horná atmosféra Zeme. Táto je ovplyvňovaná či už zdola (atmosférickým počasím a rôznymi výbojmi), tak aj z vonkajšej strany (slnečným žiarením a kozmickým počasím). Skladá sa z niekoľkých vrstiev, mezosféra a termosféra, ale aj z vrstvy, ktorú tvoria ióny a elektróny - ionosféra. Ionosféra je najdôležitejšou atmosférickou vrstvou na prenos rádiového signálu medzi vesmírnymi a pozemnými stanicami. Jej náhle zmeny ovplyvňujú signál, keďže sa nárazovo mení fáza a amplitúda rádiových vln. Tieto modifikácie ionosféry sa nazývajú ionosférické scintilácie. Tieto zmeny predstavujú taktiež riziko pre globálny navigačný satelitný systém (*Global Navigation Satellite System* (GNSS)), ktorý môže byť počas scintilácie nielen upravený, ale aj stratený (Pfaff, 2012; Hlubek et al., 2014).

Princíp problémov vyplývajúcich z ionosférických scintilácií sa postupom posledných desaťročí znásobil vzhľadom na exponenciálny nárast používania GNSS. GNSS systémy vysielajú na frekvenciách okolo 1 GHz. Tieto frekvencie sú dostatočne vysoké na to, aby sa dokázali cez ionosféru prepraviť, no nie na to, aby boli odolné voči ionosférickým scintiláciám. Na základe týchto faktov je možné zhodnotiť, že ionosférické scintilácie majú vysoký vplyv na veľkú škálu dopravných systémov, ale aj satelitov na orbite. Prehľad ionosférických účinkov na príjem rádiového signálu je zobrazený na Obrázku 1–1 (SWC, (accessed June 22, 2022; Little and Maxwell, 1952).

Z pohľadu vplyvu môže mať ionosférická scintilácia vplyv ako na amplitúdu, tak aj na fázu signálu. Hoci amplitúdová scintilácia predstavuje problém slabnutia signálu, fázová scintilácia môže ovplyvniť prepojenie pozemných snímačov so satelitmi. V horších prípadoch sa môže toto prepojenie stratiť a tým pádom znefunkčniť GNSS až do obnovenia spojenia (Spogli et al., 2009).

Z geografického pohľadu súvisia ionosférické scintilácie s konkrétnymi lokalitami. Vyskytujú sa najmä v rovníkovej zóne s nízkou zemepisnou šírkou a hlavnou aktivi-



Obrázok 1 – 1 Škála účinkov ionosféry a jej nepravidelnosti na príjem signálu (SWC, (accessed June 22, 2022))

tou počas slnečného maxima po súmraku a pred polnocou. Je potrebné poznamenať, že pre stredné zemepisné oblasti sú scintilačné efekty veľmi zriedkavé (Spogli et al., 2009).

1.1 Analýza literatúry

Doména ionosférických scintilácií je už dlhšiu dobu považovaná za slabo prebádanú oblasť. Primárne oblasť ich predikcie, kedy ešte neexistuje predikčný model ani publikácia, ktorá by sa zaoberala touto problematikou v dostatočnej hĺbke a s dostatočne presnými výsledkami. Realita je taká, že väčšina publikácií, s ktorými sme pri tejto analýze pracovali mala za výsledok len relatívnu funkčnosť, ktorej spoľahlivosť nebola použiteľná. V tejto analýze literatúry si zdefinujeme koncepty, s ktorými sme pri výbere literatúry pracovali a na základe ktorých sme dohľadávali podklady k našej práci. Ďalej si rozoberieme tie z nich, ktoré sme vyhodnotili ako najviac

smerodajné.

Naše koncepčné rámce spolu s ich kľúčovými slovami vyzerali nasledovne:

- **Vesmír - ionosféra, scintilácia, predikcia scintilácií, inosférická scintilácia, atmosféra**

Tento koncept nám popisuje pointu diplomovej práce z dátového hľadiska. Tento pohľad je založený na obsahu vesmíru, časových javov zobrazujúcich scintilácie v ionosfére. Toto je základný zdroj dát našej práce a na ňom budú vykonávané predikcie obsahujúce údaje o budúcich scintiláciách.

- **Predikcia javov – hlboké učenie, neurónové siete, predikcia scintilácií**

Technologickú časť diplomovej práce bude tvoriť predikcia javov na základe známej dátovej množiny. Tým pádom nám tento koncept popisuje technologickú (a teda realizačnú) rovinu danej diplomovej práce.

1.1.1 Výskumy zaoberajúce sa doménou

A Framework of Integrated Service System of Ionospheric Scintillation Information

Výskum Zhang et al. (2018) pojednáva o komplexnej analýze ionosférických scintilácií a techník použiteľných na ich predikciu. Ionosférické scintilácie sú problémom pre široký rozsah satelitných systémov, primárne pre ich signál. V tejto rovine sa pojednáva o radarových, komunikačných a globálnych navigačných systémoch (GNSS) s frekvenciou pod 4 GHz. Problematika je rozdelená do niekoľkých rovín. Jedná sa o koncept, plánovanie, dizajnovanie, testovanie a funkčnú prevádzku. V rovine konceptu, plánovania a dizajnovania sú potrebné klimatické modely na evaluáciu efektov ionosférických scintilácií a dizajnovanie vlastných riešení systémovými dizajnérmí. Skrze testovaciú a operačnú fázu sú modely počasia potrebné na popísanie a predpoveď údalostí ionosférických scintilácií a ich efektov na redukciu degradácie aplikovaných systémov.

Na základe špecifickejších požiadaviek bol očakávaný výstup služieb nasledovný:

- služba na zdieľanie dát pre študentov, výskumných pracovníkov a podobne,
- online prevádzka systému na dopyt pre systémových designerov,
- klientský softvér koncového PC pre operátorov zariadení, ktorý by bol určený na popis aktuálneho stavu scintilácií a udalostí s nimi spojenými,
- oblastné notifikácie a služby varujúce o udaní sa scintilačnej udalosti vopred, použiteľné na manažment rizík napríklad pre letecké a lodné misie.

Systemová architektúra by sa skladala zo štyroch vrstiev, a to dátovej, výpočtovej, vrstvy služieb a aplikačnej. Systémoví dizajnéri pracovali so scintilačnými klimatickými modelmi v záujme analýzy scintilácií na špecifické frekvencie. Konkrétne používali empirický klimatický model pravdepodobnosti scintilácie, popisný a krátkodobo predpovedajúci scintilačný model ionosférických scintilácií a metódu predikcie scintilačných udalostí za pomoci umelej inteligencie.

Prvý menovaný model berie v úvahu časové, sezónne, zemepisné variácie scintilácií a taktiež solárnu a geomagnetickú aktivitu. Druhý sa zaoberal regionálnou špecifikáciou a krátkodobými predikciami scintilácií v 400 MHz rozsahu signálu. Tretí model pracoval s algoritmom hlbokého učenia, ktorý používal neurónovú sieť typu *Deep Belief Network* (DBF) dosahoval metriku *precision* v hodnotách vyšších ako 0,55, *recall* vo vyšších ako 0,60 a *accuracy* vyššiu ako 0,80.

Celý tento zdroj analyzuje základný priebeh tvorby softvéru a obsahu jeho zdroja dát a vieme ho použiť ako primárne odrazenie sa v základných veličinách nášho výskumu. Bohužiaľ ale reálny produkt výskumu tejto publikácie nie je k dispozícii.

Ionospheric scintillation

Publikácia Crane (1977) ponúka hlbší teoretický základ k ionosférickým scintiláciám. Tento teoretický základ je podložený matematickým pochopením danej domény a vysvetlením, resp. analýzou jednotlivých fyzikálnych javov, ktoré predchádzajú a zapríčiňujú scintilácie. Vysvetľuje jednotlivé typy scintilácií, rozdiely medzi nimi, ich priebehy a sprievodné javy. Ako výsledok môžeme považovať komplexnú

analýzu danej problematiky. Článok pomáha poukázať na to, že daná problematika je aktuálna už dlhší čas, keďže o týchto výpadkoch rádiového signálu zapríčineného fyzikálnymi javmi sme vedeli už dlhšie.

Survey on signal processing for GNSS under ionospheric scintillation: Detection, monitoring, and mitigation

Publikácia Vilà-Valls et al. (2020) má taktiež čo povedať o aktuálnosti skúmanej domény, keďže pochádza z roku 2020. Primárne sa táto práca zaoberá skúmaním, detekciou, monitorovaním a predikciou scintilácií pre konkrétny satelit GNSS a oblasti, ktorú pokrýva. Na začiatku práca skúma hlbšie teoretické súvislosti spojené so scintiláciami a ich matematické vyjadrenie. Na základe týchto bodov je vykonaná komplexná analýza vstupných dát spolu s ich ďalším vyhodnotením a správnym určením na ďalšiu prácu. Zaujímavé je použitie manuálnej anotácie dát, ktorá je nasledovaná prahovaním (*thresholding*), bezindexovými technikami a nakoniec strojovým učením. Na základe tohto komplexného porovnania je v práci vidieť teoretický rozdiel medzi týmito technikami a ich ďalšími vyjadreniami. Táto práca vo všeobecnosti ponúka teoretický prehľad danej problematiky spojený s aktuálnymi dátami a ich vyjadrením. Vďaka tomu je možné čerpať informácie aj do našej práce, keďže sa jedná o relatívne aktuálny výskum.

Survey and prediction of the ionospheric scintillation using data mining techniques

Publikácia Rezende et al. (2010) pokračuje v práci s dolovaním v dátach a ich technikami, pomocou ktorých je možné predikovať ionosférické scintilácie na základe vstupných dát. Táto práca disponuje komplexnou vstupnou analýzou obsahujúcou rozobranie problematiky ionosférických scintilácií na základe už existujúcich štúdií. Na začiatku publikácia zľahka analyzuje, ktoré konkrétne satelity a prístroje sú ovplyvňované ionosférickými scintiláciami, na čo sa v prácach, s ktorými sme pracovali doteraz neprihliadalo v tak vysokej miere, keďže sa spomenuté publikácie zameriavali skôr na prácu s existujúcimi dátami a ich predikciu. V úvode analyzuje všetky existujúce modely popisujúce scintilácie a ich predikcie. Ďalej sú vysvetlené

dáta a ich pochopenie. Táto práca berie v úvahu niekoľkodňové okná dátových záznamov obsahujúce primárne S4 index, ktorý sa považuje za scintilačnú hodnotu. Konkrétne sa berie v úvahu január a marec z roku 2000 a február, marec, november a december z roku 2001. Dáta, s ktorými bolo v publikácii pracované pochádzali z mesta Sao Luis v Brazílii. Atribúty použité v práci boli Hm_{AP}, S4 Eq, S4 AP, F10.7 index, *Drift velocity* a Kp index. Ako výsledok predikcie bol použitý index S4 AP. Publikácia porovnáva niekoľko predikčných techník: *Bagging* a rozhodovacie stromy. Ako výstup tejto práce bola použitá technika *Bagging-CART*, ktorá bola schopná predpovedať scintiláciu jednou alebo viacerými hodinami predchádzajúcimi ionosférickej nepravidelnosti. Problém však nastal keď bolo potrebné predikovať hodnotu indexu S4 s detekčným časom 1 deň. Napriek správnej technike Baggingu s hodnotou 95,5% nebolo možné predikovať neprítomnosť scintilácie a teda dochádzalo k vysokej falošnej pozitívite.

Prediction of the level of ionospheric scintillation at equatorial latitudes in Brazil using a neural network

Ďalšia publikácia De Lima et al. (2015) sa zaoberala taktiež predikciou ionosférických scintilácií na základe obdobného zdroja dát, ktorým bol magnetický snímač nachádzajúci sa v Sao Luís. Táto práca taktiež disponovala istou vstupnou analýzou dát a jej pochopením. Ako dátovú množinu ale používala už širší rozsah dát z daného zdroja. Konkrétne sa jednalo o roky 2001 až 2003 a 2010 až 2013. Čo sa týka mesiacov použitých v práci, bol pokrytý približne celý rozsah mesiacov počas každého roka s výnimkou rokov 2010 a 2013. Medzi atribútmi, ktorými sa práca zaoberala boli aj atribúty uvažované v našom výskume, ako M S4 a F10.7. Znamená to, že v porovnaní s predchádzajúcou prácou, táto publikácia použila inú metodológiu výberu dát na vstupe. Na predikciu dát bola pri tejto práci použitá technológia neurónovej siete *Multilayer Perceptron* (MLP), ktorá bola skomponovaná z dvoch podsietí, z ktorých každá bola napĺňaná 13 vstupmi korešpondujúcimi s 13 neurónmi v úvodnej vrstve. Takto postavená neurónová sieť predikovala hodnoty v obmedzenom časovom intervale 4 hodín s veľmi dobrou presnosťou (približne

97%). Problém nastal pri predikcii v širšom časovom rozsahu, kedy táto neurónová sieť nebola schopná poskytnúť dostatočne presné a spoľahlivé výsledky, rovnako ako predchádzajúca publikácia.

New Capabilities for Prediction of High-Latitude Ionospheric Scintillation: A Novel Approach With Machine Learning

Posledná analyzovaná publikácia McGranaghan et al. (2018) sa taktiež zaoberala problematikou predikcie ionosférických scintilácií a vplyvom vesmírneho počasia na transionosférické signály. Využívajúc veľké množstvo údajov z globálnych navigačných satelitných systémov (GNSS), sofistikované nástroje na zisťovanie údajov a algoritmus strojového učenia, *Support Vector Machine* (SVM), vytvorili nový predikčný model pre fázovú scintiláciu ionosféry vo vysokých zemepisných šírkach. Táto práca predstavuje prvý prípad použitia SVM na predpovedanie fázovej scintilácie. Práca sa zaoberá veľkým objemom údajov z GNSS, využíva sa pri tom SVM na vývoj predikčného modelu pre fázovú scintiláciu ionosféry vo vysokých zemepisných šírkach. Jedna z metrík na vyhodnotenie bola *True Skill Score* (TSS), ktorá je podobná ako pri predchádzajúcich hodnoteniach. Ukázalo sa, že model SVM výrazne prekonáva predikciu perzistencie. Publikácia brala v úvahu aj podobné fyzikálne hodnoty ako my, no nepoužívala ich na priamu predikciu. Zistenia a výsledky boli použité na priame porovnanie s našou prácou pri vyhodnotení. Výsledky, ktoré sme použili je možné nájsť v Tabuľke 4–8.

Z uplynulej analýzy môžeme vyhodnotiť, že nami skúmaná doména už bola niekoľkokrát využitá podobným spôsobom. Problém ale je, že žiaden z aktuálnych spôsobov nebol schopný doručiť výsledky, ktoré sa budeme snažiť doručiť my pri danej presnosti a preto je namieste povedať, že je naša práca aktuálna a poukazuje na oblasť, ktorá takýmto spôsobom ešte vyriešená nebola.

2 Dáta

2.1 Analýza dostupných dát

2.1.1 Vstupná analýza a popis hodnôt

Vzhľadom na to, že náš výskum bol dátovo orientovaný bolo potrebné si na začiatku uvedomiť, že pri takomto type prístupu, ktorý je založený na údajoch, sú najdôležitejšie tzv. čisté a konzistentné dáta. Pod týmito pojmami môžeme rozumieť dáta, ktoré neobsahujú odchýlky (známe aj ako *outliery*), alebo prázdne údaje a nulové hodnoty. V tejto kapitole bude popísaný všeobecný prehľad potenciálnych dát použitých na výskum. Prehľadný zoznam parametrov je obsiahnutý v Tabuľke 2–1. Pri všetkých dátach boli zohľadnené časové záznamy v rozsahu od 1. januára 2000 do 31. decembra 2021. Ako unifikovanú časovú jednotku pre všetky parametre bola určená hodnota 1 hodina, ktorá bola dostupná pre všetky zvolené údaje. Nasledujúce podkapitoly budú obsahovať názvy, krátke popisy, referenciu a vizualizáciu dát pre jednotlivé údaje, alebo len stručný popis skupiny údajov.

Tabuľka 2–1: Zoznam všetkých analyzovaných parametrov pripravených na prístup založený na dátach (King and Papitashvili, 2005).

Parameter	Popis	Zdroj
F10.7 index [sfu]	Žiarenie generované Slnkom s vlnovou dĺžkou $\lambda = 10,7$ cm	OMNIWeb ^a
R No.	Počet slnečných škvŕn na Slnku	OMNIWeb ^a
Lyman [W/(m ² nm)]	Alpha Hodnota slnečného spektrálneho žiarenia	OMNIWeb ^a
SW speed [km/s]	Rýchlosť slnečného vetra (<i>Solar Wind</i>)	OMNIWeb ^a
Plasma beta	Pomer tlaku slnečného vetra a tlaku magnetického poľa Slnka	OMNIWeb ^a

Parameter	Popis	Zdroj
Alfven Mach No.	Sila medziplanetárneho magnetického poľa	OMNIWeb ^a
Quasi Invariant	Charakteristika prúdenia slnečného vetra	OMNIWeb ^a
MS Mach No.	Pomer slnečného vetra a magnetosonickej rýchlosti	OMNIWeb ^a
SW flow lat., long. [deg]	Vesmírne zemepisné súradnice toku zdroja slnečného vetra	OMNIWeb ^a
Proton Density [N/cm ³]	Hustota protónov v slnečnom vetre	OMNIWeb ^a
Alpha Proton r.	Pomer Alfa častíc k hustote protónov	OMNIWeb ^a
Proton Temp. [K]	Teplota protónov v slnečnom vetre	OMNIWeb ^a
Flow Pressure [nPa]	Tlak slnečného vetra	OMNIWeb ^a
Electric Field [mV/m]	Electrické pole slnečného vetra	OMNIWeb ^a
Vx, Vy, Vz [km/s]	x, y a z komponenty rýchlosti slnečného vetra	OMNIWeb ^a
Kp index	Geomagnetický planetárny K-index	OMNIWeb ^a
Dst index [nT]	Geomagnetický rovníkový index	OMNIWeb ^a
Ap index	Geomagnetický planetárny Ap-index	OMNIWeb ^a
AU indexes	Horná zložka geomagnetického AE indexu (<i>Auroral Upper</i>)	OMNIWeb ^a
AL indexes	Dolná zložka geomagnetického AE indexu (<i>Auroral Lower</i>)	OMNIWeb ^a
AE indexes	Geomagnetický <i>Auroral Electrojet</i> index	OMNIWeb ^a
IMF [nT]	Sila medziplanetárneho magnetického poľa (<i>Interplanetary Magnetic Field</i>)	OMNIWeb ^a
Bx, By, Bz GSE [nT]	x, y a z komponenty pre index IMF	OMNIWeb ^a


Parameter	Popis	Zdroj
BSNx, BSNy, BSNz GSE [Re]	x, y a z komponenty Zemskej polohy v geocentrickej sústave slnečného ekliptického systému	OMNIWeb ^a
SYM/D, ASY/D [nT]	Symetrické / asymetrické geomagnetické rušenie kolmé na os dipólu	OMNIWeb ^a
SYM/H, ASY/H [nT]	Symetrické / asymetrické geomagnetické rušenie paralelné s osou dipólu	OMNIWeb ^a
PC(N) index [mV/m]	Polar Cap Index	OMNIWeb ^a

^aDostupné na: <https://omniweb.gsfc.nasa.gov/form/dx1.html>

Solárne indexy

Medzi solárne indexy, ktoré sme uvažovali patria nasledujúce parametre:

- **F10.7 index** popisuje slnečný rádiový tok pri vlnovej dĺžke 10,7 cm alebo frekvencii 2800 MHz (*NOAA, F10.7 index*, n.d.). Je definovaná v jednotkách slnečného toku (*solar flux unit* - sfu = $10^{-22} \text{Wm}^{-2}\text{Hz}^{-1}$) (*Space Weather Canada - Solar Flux data*, n.d.). Na Obrázku 2 – 1 je možné vidieť boxplot použitý na analýzu tejto hodnoty na dátach z daného rozsahu.
- **R sunspot number** popisuje počet slnečných škvŕn na Slnku. Pracuje s časovými intervalmi od niekoľkých hodín až po roky (*NOAA, Sunspot Numbers*, n.d.). Index je definovaný ako $R = K * (10 * G + I)$, kde G popisuje skupiny slnečných škvŕn na Slnku, I popisuje počet všetkých viditeľných miest a K je faktor zadefinovaný kvôli zohľadneniu rozdielov medzi pozorovateľmi a observatóriami.
- **Lyman alpha index** popisuje intenzitu slnečného žiarenia s vlnovou dĺžkou 121–122 nm, ktorej dominuje najjasnejšia slnečná emisná čiara HI 121,6nm (*Lyman alfa*) v UV spektre.



Obrázok 2–1 Boxplot pre F10.7 index pre každý rok v rozsahu 2000 až 2021. Zdroj: OMNIWeb (*NASA/OMNIWeb*, n.d.).

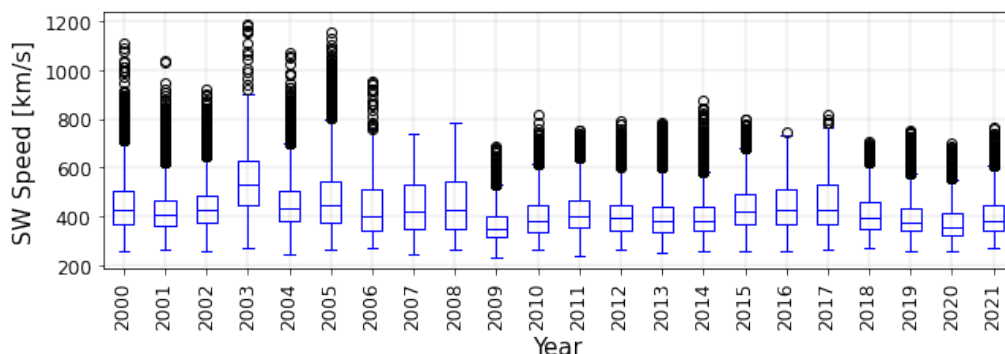
Heliosférické indexy

Slnečný vietor je vytváraný tým, že slnečná koróna expanduje plazmu, ktorej teplota sa zvyšuje zahrievaním, až ju gravitácia Slnka neudrží. Slnečná plazma môže unikáť po otvorených siločiarach magnetického poľa smerom von. Po každej rotácii Slnka sa z magnetických siločiar vytvorí veľká rotujúca špirála nad polárnymi oblasťami, ktorá vytvára konštantný prúd - slnečný vietor (*NASA/The Solar Wind*, n.d.). Táto podkapitola stručne popíše heliosférické indexy použité pri analýze vstupného dátového setu, ktoré úzko súvisia a popisujú už spomenutý slnečný vietor.

- **SW speed** (*Solar Wind speed*) je hodnota popisujúca rýchlosť ako fyzikálnu veličinu slnečného vetra. Na Obrázku 2–2 je možné vidieť boxplot jej hodnôt vo vybranom časovom rozsahu. Je daná v jednotkách kilometrov za sekundu [km/s]. Jej zdrojom je slnečná koróna a jej prúdenie zo Slnka je v rýchlostiach okolo 400 km/s (*NASA/The Solar Wind*, n.d.).
- **Plasma beta** je veličina odvodená z kolekcie viacerých zdrojov. Používa sa na zdôraznenie predpokladu, že pri extrapolácii magnetického poľa je potrebné brať vyšší ohľad na magnetický tlak nad tlakom plazmy (Gary, 2001).
- **Alfven Mach number** sa používa na vyhodnotenie sily interplanetárneho magnetického poľa (IMF). Hodnota *Alfven Mach number* je pomer celkového

slniečného vetra k Alfvénovej rýchlosti podľa Machovho čísla, ktoré priamo riadi kompresný pomer rázovej vlny (*bow shock*) a hodnotu plazmy beta (Mathioudakis et al., 2013).

- **Quasi invariant** je odvodený od hodnoty *Alfven Mach*, ktorý disponuje lepšími charakteristikami popisujúcimi solárnu aktivitu v porovnaní so separovateľnými parametrami slnečného vetra (Osherovich et al., 1999).
- **Magnetosonic Mach number** je hodnota vypočítaná ako pomer rýchlosti slnečného vetra a magnetosonickej rýchlosti (Edberg et al., 2010).
- Hodnoty **SW plasma flow latitude** a **SW plasma flow longitude** popisujú geografické súradnice toku plazmy slnečného vetra. Hodnoty sú uvedené v stupňoch [deg].
- Veličina **Proton Density** popisuje hustotu protónov v plasmе slnečného vetra. Je udávaná v jednotkách počtu častíc na centimeter kubický [n/cc].
- **Alpha Proton ratio** popisuje elementárnu početnosť protónov vzhľadom na Alpha častice.
- **Proton Temperature** popisuje teplotu protónov v plasmе slnečného vetra. Je udávaná v jednotkách Kelvinov [K].
- **Flow Pressure** popisuje tlak prietoku protónov s plasmе slnečného vetra. Je daná v nano Pascaloch [nPa].
- **Electric Field** popisuje elektrické pole plazmy slnečného vetra a je udávaná v jednotkách mili Voltov na meter [mV/m].
- **V_x, V_y a V_z Velocity** popisujú komponenty x, y a z osí rýchlostí slnečného vetra. Sú dané v [km/s] (*NASA/The Solar Wind*, n.d.).



Obrázok 2–2 Boxplot pre rýchlosť slnečného vetra (*SW speed*) pre každý rok v rozsahu 2000 až 2021. Zdroj: OMNIWeb (*NASA/OMNIWeb*, n.d.).

Geomagnetické indexy

Ako ďalšia časť dátovej množiny boli vybrané geomagnetické parametre, ktoré sú popísané v tejto podkapitole.

- **Kp index**, tiež známy ako geomagnetický planetárny K index je rozšírenie pre K-index. Tieto indexy sú používané na charakteristiku rozsahu geomagnetických búrok. Jeho hodnoty pochádzajú z rozsahu 0-9 s hodnotou 1 znamenajúcou pokojnú geomagnetickú búrku (*NOAA, PLANETARY K-INDEX*, n.d.).
- **Dst index** (*Disturbance storm time index*), známy aj ako geomagnetický rovníkový index popisuje spriemernenú časť vonkajšieho poľa na základe zemepisnej dĺžky meranej na geomagnetickom dipólovom rovníku na povrchu Zeme. Je udávaný v jednotkách nano Tesla [nT]. Dst index je taktiež používaný na kategorizáciu intenzity slnečných búrok s hodnotami od -30 nT pre slabé búrky až po menej ako -350 nT pre veľmi silné búrky (*NOAA, The Disturbance Storm Time Index*, n.d.; Borovsky and Shprits, 2017).
- **Ap index** je miera všeobecnej úrovne geomagnetickej aktivity po celom svete pre daný deň. Je získavaný z hodnôt Kp indexu (*NOAA, Geomagnetic kp and ap Indices*, n.d.; *NWRA/Geomagnetic Disturbance Index*, n.d.);

NASA/OMNIWeb Data Documentation, n.d.).

- **AE, AU a AL indexy** geomagnetickej aktivity sa používajú na charakteristiku magnetických výkyvov v polárnej zóne, ktorých príčina je nárast prúdov v ionosfére pozdĺž hranice aurorálneho oválu. Nemajú žiadne jednotky a ich hodnoty sú dostupné iba do 30-06-2018 (*World Data Center for Solar-Terrestrial Physics/AE AU AL AO*, n.d.).
- **Interplanetary magnetic field (IMF)** je časť slnečného magnetického poľa. Je prenášaný do interplanetárneho priestoru slnečným vetrom. Interplanetárne magnetické pole má špirálovitý tvar, čo je výsledkom Slnka točiaceho sa okolo vlastnej osi. Je to kombinovaná miera pre silu magnetického poľa v smeroch sever-juh, západ-východ a k Slnku-od Slnka. Čím vyššia hodnota IMF je, tým sú geomagnetické podmienky lepšie. Je daná v jednotkách nano Tesla [nT] (*The Interplanetary Magnetic Field (IMF)*, *Space weather live*, n.d.; *What is Interplanetary Magnetic Field (IMF)?*, n.d.). IMF pozostáva z troch komponentov - Bx, By a Bz.
- **Bx, By a Bz** sú komponenty osí IMF. Dva z nich - Bx a By sú orientované paralelne na ekliptiku. Tretí Bz je orientovaný kolmo na ekliptiku a je tvorený vlnami a inými odchýlkami v slnečnom vetre. Tieto hodnoty sú dané v jednotkách nano Tesla [nT].
- **BSN X, Y, Z** popisuje hodnotu *Bow Shock*. *Bow Shock* popisuje miesto, kde slnečný vietor emitovaný zo Slnka narazí na magnetické pole Zeme. Následkom toho sa vytvorí oblak plazmy známy ako *Bow Shock*. Tieto tri hodnoty popisujú súradnice X (smerujúca od Zeme k Slnku), Y (smerujúca proti pohybu planét) a Z (rovnobežná s ekliptickým pólom) polohy *Bow Shock* v systéme GSE (*The location of the Earth's bow shock*, n.d.).
- **SYM/D, SYM/H, ASY/D, ASY/H** popisujú geomagnetické poruchy v stredných zemepisných šírkach z hľadiska pozdĺžne asymetrických (ASY) a

symetrických (SYM) porúch. Popis je vytvorený pre H a D zložku - rovnobežnú a kolmú na os dipólu (*ISGI/ASY/SYM INDICES*, n.d.).

- **PC(N) index** (*Polar Cap Index*) monitoruje geomagnetickú aktivitu v oblastiach *Polar Caps* a určuje sa z magnetických údajov získaných na geomagnetickom observatóriu v Thule. Index sa udáva v mili Voltoch na meter [mV/m] (*PCN index*, n.d.; *NASA/OMNIWeb Data Documentation*, n.d.).

Termosférické a ionosférické indexy

Vzhľadom na fakt, že sme sa v našej práci snažili čo najkomplexnejšie analyzovať atmosféru a ionosféru, sme okrem solárnych, heliosférických a geomagnetických indexov používali aj ďalšie indexy. Konkrétne sme používali termosférické hodnoty z modelu NRLMSISE-00 a ionosférické hodnoty z modelu IRI-2016. Tieto modely poskytujú veľmi detailné informácie o rôznych fyzikálnych procesoch, ktoré sa odohrávajú v atmosfére a ionosfére.

Analýzu na týchto zdrojoch sme vykonávali spoločne s ďalšími dátovými expertmi v rámci projektu *Autonomous Service for Prediction of Ionospheric Scintillations* (ASPIS). Na základe ich analýz sme boli schopní náš dátový rámec rozšíriť o tieto ďalšie hodnoty. Použitie týchto dát nám umožnilo získať presnejšie a dôveryhodnejšie výsledky, čo je veľmi dôležité pri takýchto vedeckých projektoch. Celkové výsledky našej analýzy nám umožnili lepšie pochopiť zmeny v atmosfére a ionosfére a vytvoriť model, ktorý by mohol byť v budúcnosti použitý na predpovedanie týchto zmien.

Rozpis ďalších indexov, ktoré boli použité v rámci vstupného dátového setu a boli analyzované dátovými expertmi:

- **Hustoty neutrálnych atómov a molekúl:** He, Ar, H, N, O, N₂, O₂, Anomalous Oxygen Density, Mass Density, Neutral Temperature, Exospheric Temperature
- **Teploty a hustoty iónov a elektrónov:** T_i, T_e, n_e, O⁺, O₂⁺, N⁺, NO⁺, Cluster ions, N_mE, h_mF₁, h_mF₂, N_mF₁, N_mF₂, F_oF₂, TEC

2.1.2 Rozdelenie dát do binov

Ako ďalší krok v príprave dát bolo použité rozdelenie dát do tzv. binov. Ionosférické merania použité v našej analýze boli získané z pozemných prijímačov. Každé meranie pozostávalo z prenosu signálu medzi pozemnou stanicou a družicou GNSS na obežnej dráhe. Výška obežnej dráhy je od 20 000 km do 37 000 km nad zemským povrchom. Prenos údajov sa uskutočňuje pozdĺž priamky. Nás zaujímala časť atmosféry, kde sa vyskytuje väčšina ionosférických scintilácií. Pre ňu sme stanovili pevné hranice $R_{\downarrow} = 150km$ nad hladinou mora pre spodnú časť a $R_{\uparrow} = 400km$ nad hladinou mora pre hornú časť. Problémom bolo nájsť (alebo predpovedať), v ktorom mieste v sledovanej časti atmosféry sa scintilácia prejavuje. Pre použiteľnosť kdekoľvek na Zemi bolo dôležité vedieť vypočítať hodnotu vektora z ktoréhokoľvek miesta na Zemi smerujúceho v smere scintilácie. Preto náš tím doménových expertov použil sférický súradnicový systém so stredom v strede Zeme, ktorý bol rovný sférickým súradniciam Zeme.

Podarilo sa im nájsť spôsob, ako prepočítať polohy ionosférickej scintilácie v sledovanej časti atmosféry. Najprv rozdelili oblohu na prstence s rôznymi výškami nad horizontom h . Potom každý prstenec rozdelili samostatne na biny s ohľadom na azimut A . Pre prvé delenie na h zvolili systém popisujúci, že pre každý prstenec existuje aspoň jeden vektor, ktorý spája pozemnú stanicu a družicu a neprechádza cez iný prstenec. Tento prístup bol zvolený lebo umožňoval ľahšie kontrolovať hodnotu priradenú každému binu. Následne zvolili prvú hranicu $h = 20^\circ$ a všetko pod $h = 20^\circ$ ignorovali, pretože atmosféra je príliš hustá na efektívne meranie scintilácií. Na základe týchto skutočností boli dáta rozdelené v binoch. Na týchto binoch boli tvorené základné analýzy s tým, že pre budúcu hlbšiu analýzu sme vybrali bin s najlepšimi predispozíciami na tréning modelu.

2.1.3 Popis scintilačných dát

Údaje o ionosférickej scintilácii boli získané zo sietí prijímačov na monitorovanie ionosféry, ktoré prevádzkujú rôzne ústavy a vedecké skupiny. Prehľad týchto sietí je uvedený v Tabuľke 2–2, na Obrázku 2–3 a tie, ktoré sme použili sú popísané v nasledujúcich podkapitolách.

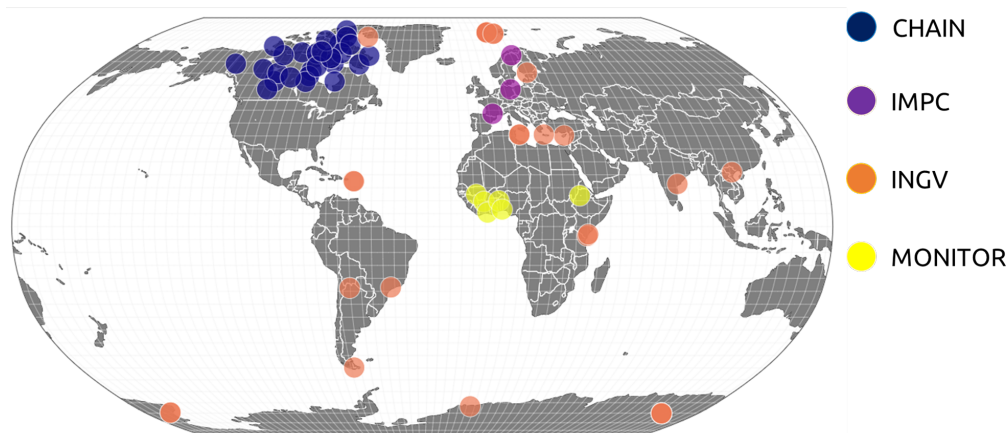
Tabuľka 2–2 Zoznam uvažovaných sietí prijímačov na monitorovanie ionosféry.

Skratka	Názov	Počet staníc	Oblasť
CHAIN	Canadian High Arctic Ionospheric Network	26	Canada
IMPC	Ionosphere Monitoring and Prediction Center, DLR	5	Europe
INGV	National Institute of Geophysics and Volcanology	28	Europe, South America, Antarctica, Asia
NMA	Norwegian Mapping Authority	8	North Europe
MONITOR	Network of scintillation receivers by ESA	12	Europe, Africa

CHAIN

Kanadská vysokoarktická ionosférická sieť - *Canadian High Arctic Ionospheric Network* (CHAIN) je konštelácia pozemných rádiových prístrojov rozmiestnených vo vysokých severných zemepisných šírkach Kanady. Podľa oficiálneho opisu projektu¹ je CHAIN navrhnutá tak, aby pomohla pochopiť polárnu ionosféru. Zameraný je najmä na prepojenie slnečného vetra, magnetosféry a ionosféry. Spôsob pozorovania je 30s konvekčné meranie a 60s merania 6 CADI (Canadian Advanced Digital Iono-

¹<http://chain.physics.unb.ca/chain/>



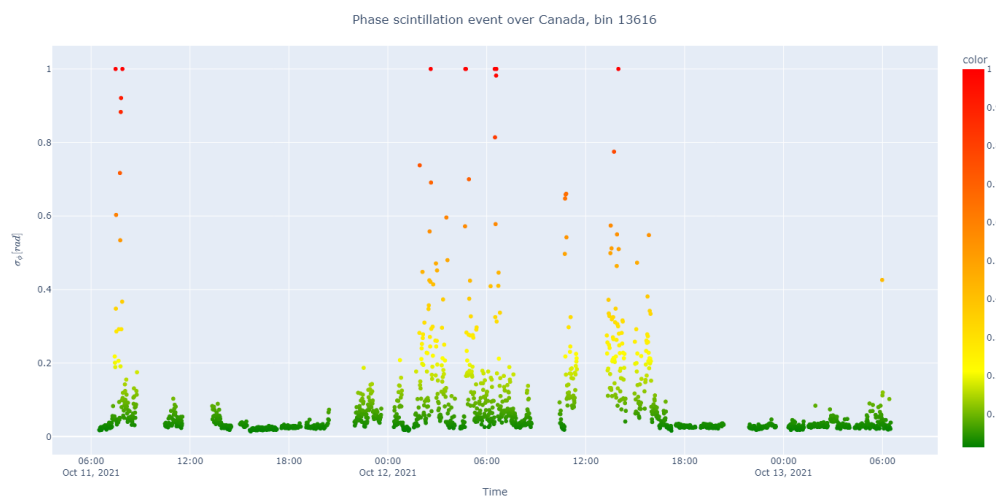
Obrázok 2–3 Všetky uvažované siete monitorovacích prijímačov ionosférických scintilácií zakreslené na mape.

sonde), merania na báze GNSS a merania *Total Electron Content* (TEC) a scintilácie so vzorkovaním 50Hz . Celkovo 26 staníc (bohužiaľ nie všetky sú funkčné) poskytuje údaje vo formáte .ismr so 62 stĺpcami². Pre našu činnosť boli najdôležitejšie čas, zemepisná dĺžka a šírka prijímača, elevácia a azimut satelitu GPS, TEC, dTEC, S_4 , σ_ϕ a pod. Získavajú sa pomocou GPS monitorov ionosférickej scintilácie a TEC monitorov (GISTM). Týchto 26 staníc sa nachádza medzi 55° a 80° severnej zemepisnej šírky a -125° a -65° západnej zemepisnej dĺžky. Príklady údajov z CHAIN sú zobrazené na Obrázku 2–4. Dostupnosť údajov v priebehu rokov pre jednotlivé prijímače je znázornená na Obrázku 2–5.

SWESNET

Sieť služieb kozmického počasia (*Space Weather Service Network* - SWESNET) je kľúčovou aktivitou Programu Vesmírnej Bezpečnosti - *Space Safety Programme* (S2P) Európskej Vesmírnej Agentúry. Pozostáva z piatich odborných servisných centier: slnečné počasia, heliosférické počasia, kozmické žiarenie, ionosférické počasia a geomagnetické podmienky. V rámci Odborného strediska pre ionosférické počasia - *Ionospheric Weather Expert Service Centre* (I-ESC) tieto organizácie prevádzkujú ionosférické monitorovacie scintilačné prijímače.

²Dostupné na <http://chain.physics.unb.ca/data/>.



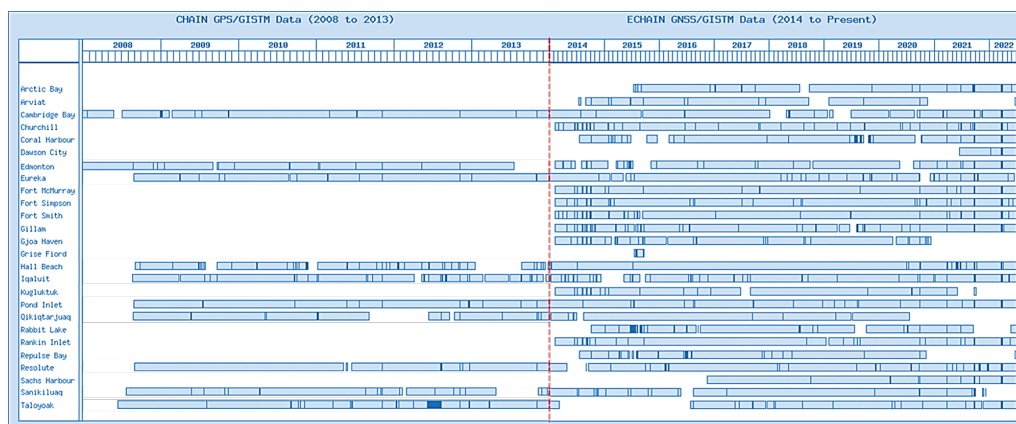
Obrázok 2 – 4 Ukážka fázového scintilačného javu nad Kanadou pre bin 13616. Farba predstavuje hodnotu parametra σ_ϕ .

Ionosphere Monitoring and Prediction Center (IMPC) - Centrum pre monitorovanie a predpovede ionosféry, DLR (Nemecké centrum pre letectvo a kozmonautiku - *German Aerospace Center*) sa nachádza v Neustrelitz v Nemecku. Poskytuje informačné a dátové služby takmer v reálnom čase o aktuálnom stave ionosféry, súvisiace predpovede a varovania³. V súčasnosti prevádzkuje vlastnú sieť na scintilačné merania v týchto lokalitách v Európe: Kiruna (SE), Neustrelitz (DE) a Toulouse (FR). Príklad jednodňových meraní je uvedený na Obrázku 2–6. Treba poznamenať, že tieto verejne dostupné údaje neobsahujú potrebné informácie o výške a azimute satelitov GNSS, ktoré poskytujú signál.

2.2 Selekcia relevantných hodnôt na tréning

V kapitole Dáta (2) boli spomenuté všetky relevantné hodnoty, ktoré mohli byť použité ako vstup pre strojové učenie. Vzhľadom na to, že počet parametrov bol pomerne obsiahly, zamerali sme sa na výber čo najdôležitejších parametrov. Bolo tiež potrebné odfiltrovať nadbytočné vstupné parametre, pretože neposkytovali informá-

³<https://impc.dlr.de/>



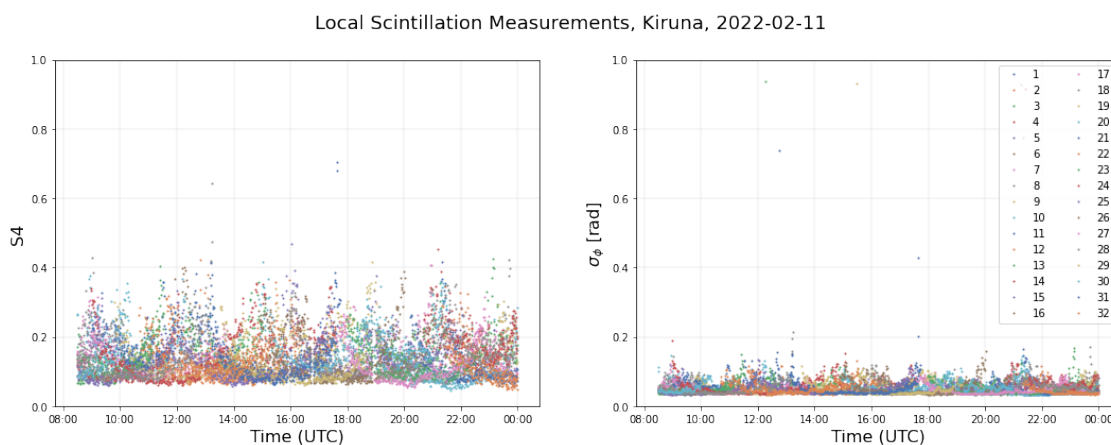
Obrázok 2–5 Graf dostupnosti údajov z monitorovacej služby CHAIN. Zdroj: http://chain.physics.unb.ca/chain/pages/data_availability

cie pre model a zvyšovali tak výpočtové požiadavky. Na výber vhodných vlastností sme použili analýzu rozptylu *Analysis of Variance* (ANOVA) a analýzu korelačnej matice.

2.2.1 ANOVA

ANOVA je štatistická metóda, ktorá sa používa na porovnanie dvoch alebo viacerých skupín údajov. Táto metóda sa používa na overenie faktu, či sa priemery skupín navzájom výrazne líšia. Vďaka tomu je možné otestovať, či sú rozdiely medzi skupinami spôsobené náhodne alebo či sú spôsobené skutočnými rozdielmi v priemeroch ich hodnôt. Na vykonanie analýzy ANOVA je potrebné zozbierať údaje z každej skupiny dát a potom vypočítať priemery a súčty druhých mocnín rozdielov pre skupiny. Tieto hodnoty sa potom použijú na výpočet F-štatistiky na zistenie, či sú rozdiely medzi priermi skupín významné.

F-štatistika je štatistická miera, ktorá sa vypočítava pomocou priemerov a súčtov druhých mocnín rozdielov porovnávaných skupín. F-štatistika nasleduje po F-distribúcii, čo je rozdelenie pravdepodobnosti, ktoré sa často používa pri testovaní hypotéz. Je to spojené rozdelenie s dvoma parametrami: stupňami voľnosti čitateľa a menovateľa. Tieto hodnoty sa používajú na určenie kritickej hodnoty F-štatistiky



Obrázok 2–6 Príklad merania lokálnych scintilačných indexov v jednej z lokalít IMPC - Kiruna (SE). Merania sú farebne označené podľa PRN kódu satelitov GNSS. Archivované údaje a údaje v reálnom čase sú k dispozícii prostredníctvom <https://swe.ssa.esa.int/swaci-federated>.

porovnávajúcej sa s vypočítanou F-štatistikou na zistenie, či sú rozdiely medzi priemermi skupín významné. Dá sa s istotou povedať, že veľká F-štatistika naznačuje, že rozdiely medzi priemermi skupín sú významné a nie sú pravdepodobne spôsobené náhodne. Malá F-štatistika na druhej strane naznačuje, že rozdiely medzi priemermi skupín nie sú významné a sú pravdepodobne spôsobené náhodnými variáciami.

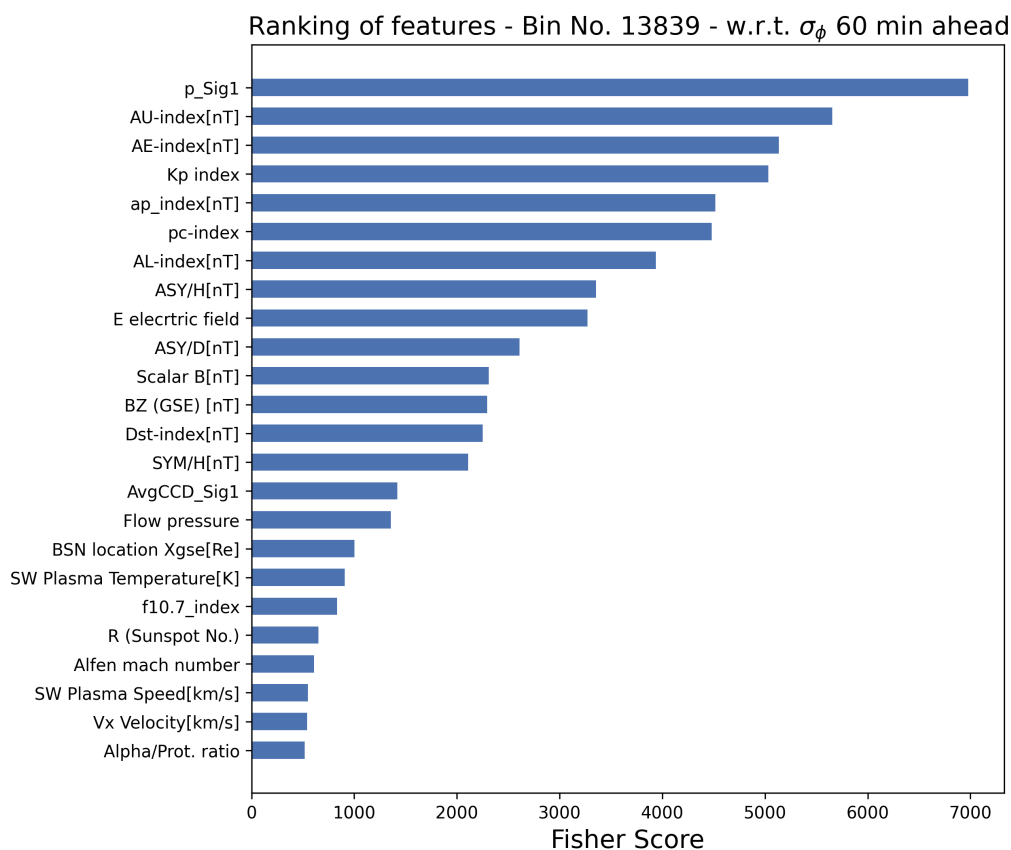
F-štatistika je reprezentovaná Fisherovým skóre. Na použitie výpočtu Fisherovho skóre musí dátový set obsahovať dve alebo viac tried dát, pričom každá trieda potrebuje mať aspoň jednu vzorku. Fisherovo skóre sa vypočíta ako rozdiel medzi priemermi rôznych tried vydelený súčtom rozptylov tried. Na výpočet Fisherovho skóre možno použiť Rovnicu 2.1, kde \bar{m}_1 a \bar{m}_2 sú priemery dvoch tried a V_1 a V_2 sú rozptyly týchto dvoch tried (Fisher, 1992; Scheffe, 1999; Iversen et al., 1987; Larson, 2008; Gu et al., 2012).

V našom výskume sme použili analýzu ANOVA na nájdenie najrelevantnejších parametrov na predikciu ionosférických scintilácií. Ako vstupné parametre sme použili zoznam uvedený v kapitole Dáta (2). Zjednodušene môžeme povedať, že ANOVA testovala rovnosť priemerov medzi rôznymi skupinami údajov. Výstupom bola čiastočná odpoveď, či je pravdepodobné, že rozdiel v parametroch medzi skupinami bol

len náhodný, alebo preto, že skupiny sú skutočne rozdielne, resp. podobné.

$$FisherScore = \frac{(\bar{m}_1 - \bar{m}_2)}{(V_1 + V_2)} \quad (2.1)$$

Pre oblasť vysokých zemepisných šírok bola skúmaná závislosť medzi všetkými dostupnými parametrami a indexom σ_ϕ . Príklad výsledkov analýzy ANOVA s ohľadom na hodnoty σ_ϕ , ktoré sú v 60 minútovom doprednom časovom posune voči vybraným údajom (t. j. parametrom kozmického počasia) pre bin č. 13839 je uvedený na Obrázku 2–7.



Obrázok 2–7 Poradie ukazovateľov vesmírneho počasia na základe analýzy ANOVA pre bin č. 13839. Hodnoty σ_ϕ sú 60 minút pred časom klasifikovaných prvkov. Zobrazené sú len prvky s Fisherovým skóre vyšším ako 500, pretože sú najrelevantnejšie.

Pozorovanie ukázalo, že sa poradie prvkov mení s ohľadom na časový posun medzi časom porovnávaných prvkov a časom sledovanej veličiny (t. j. σ_ϕ). Vývoj

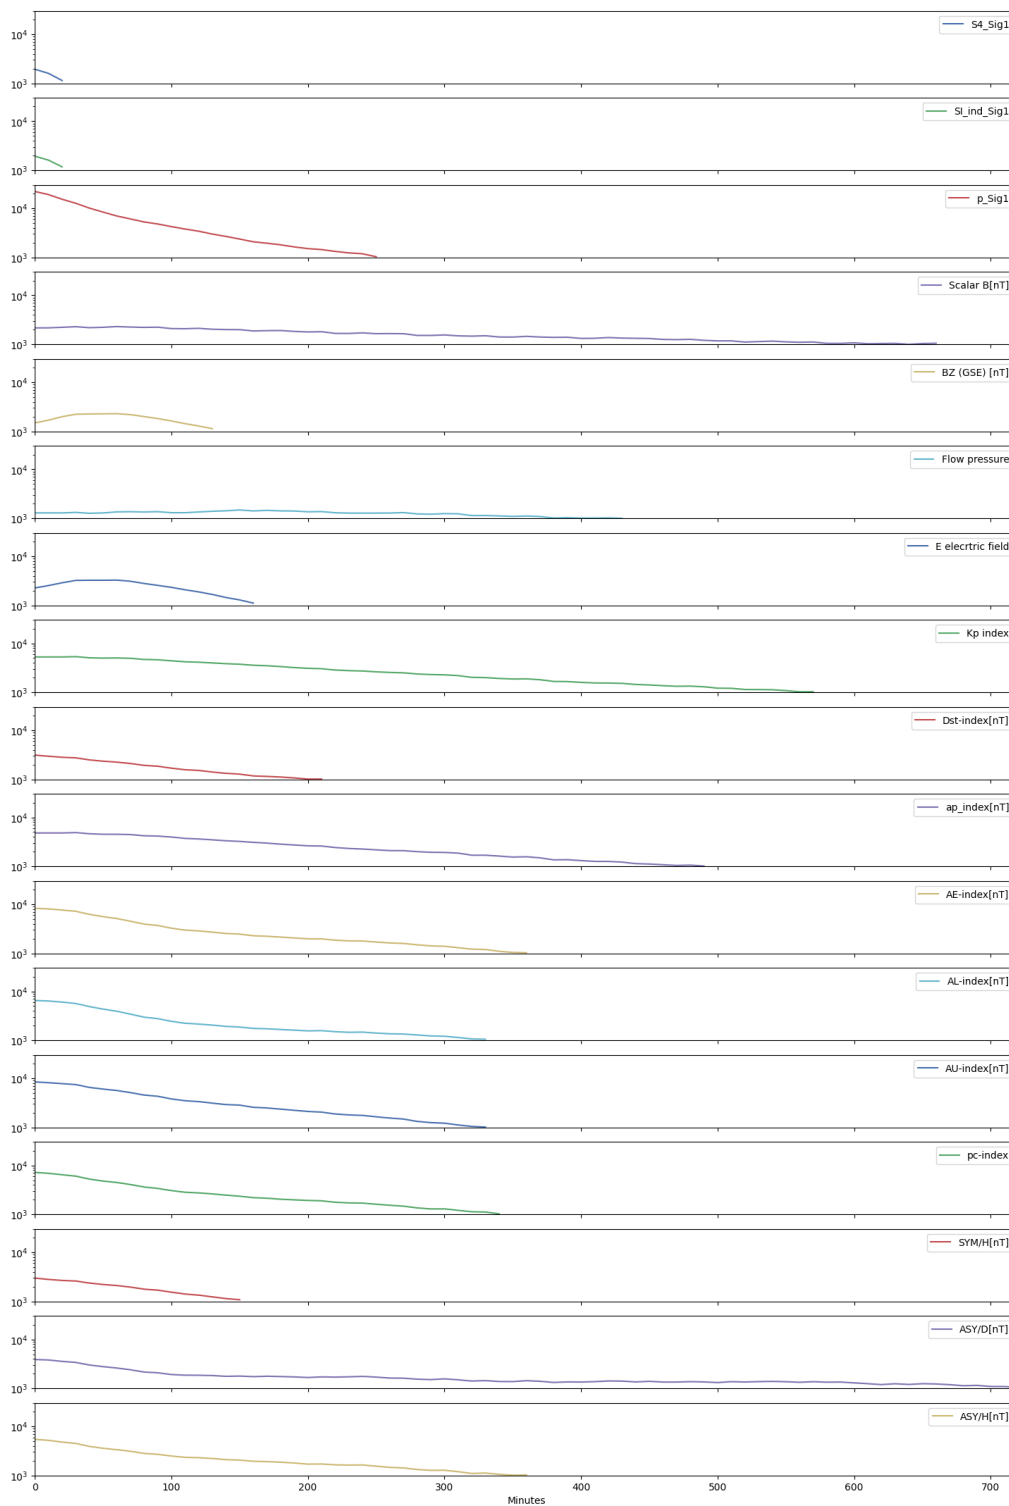
Fisherovho skóre v závislosti od časového posunu je znázornený na Obrázku 2–8. Pre väčšinu funkcií ich význam na základe tejto skutočnosti časom klesá. To sa očakávalo a znamená to, že pri použití týchto hodnôt môže byť ťažké predikovať ionosférické scintilácie viac ako niekoľko hodín dopredu.

2.2.2 Korelačná matica


Korelačná matica je tabuľka zobrazujúca korelačné koeficienty medzi súborom premenných. Matica je symetrická, pričom korelácia medzi akýmkoľvek dvoma premennými sa objavuje v riadku aj v stĺpci týchto premenných. Uhlopriečka matice začínajúca v ľavom hornom rohu sa skladá z jednotiek, pretože každá premenná je dokonale korelovaná sama so sebou. Hodnota každého prvku v matici udáva silu a smer vzťahu medzi dvoma premennými. Hodnota 1 označuje perfektný pozitívny vzťah, kde jedna premenná rastie v prípade že sa zvyšuje druhá. Hodnota -1 označuje dokonalý negatívny vzťah (antikoreláciu), kde jedna premenná rastie v prípade že druhá klesá. Hodnota 0 znamená, že medzi týmito dvoma premennými neexistuje žiaden vzťah. Hodnoty v matici možno použiť na identifikáciu vzťahov medzi premennými a na pochopenie miery, v akej jednotlivé premenné súvisia medzi sebou.

Príklad korelačnej matice pre termosférické dáta (dostupné z modelu NRLMSISE-00) je uvedený na Obrázku 2–9. Vizualizuje krížovú koreláciu medzi vlastnosťami (termosférické údaje) a hodnotou σ_ϕ a tiež krížovú koreláciu samotných prvkov. Je potrebné poznamenať, že podobná analýza korelačnej matice bola vykonaná aj pre iné parametre (indexy kozmického počasia a ionosférické parametre).

V dôsledku analýzy vykonanej v tejto časti boli ponechané len najdôležitejšie a neredundantné parametre. Tieto parametre (hodnoty) majú štatistickú významnosť a môžu prispieť k predikcii parametra σ_ϕ v oblastiach s vysokou zemepisnou šírkou. Je potrebné poznamenať, že na výber parametrov na predikciu ionosférických scintilácií v rovníkových oblastiach by bolo potrebné túto analýzu zopakovať a použiť údaje z rovníkovej oblasti.



Obrázok 2–8 Vývoj Fisherovho skóre v závislosti od časového posunu medzi časom prvkov a časom sledovanej hodnoty – σ_ϕ . Maximálny zobrazený časový posun je 720 minút (t. j. 12 hodín). Uvedené sú len prvky s Fisherovým skóre vyšším ako 1000.



Obrázok 2–9 Hodnotenie prvkov podľa korelačnej matice pre bin č. 13839. Použité boli hodnoty σ_ϕ a hodnoty σ_ϕ , ktoré sú 60 minút pred časom ostatných prvkov. Analýza je vytvorená s použitím údajov NRLMSISE-00.

3 Vývoj modelov strojového učenia

3.1 Metódy použité na vyhodnotenie a nájdenie optimálnej prahovej hodnoty

V rámci nášho projektu sme museli analyzovať vytvorené *Machine Learning* (ML) modely z hľadiska ich účinnosti pri predikovaní ionosférických scintilácií. Podľa poskytnutých usmernení *European Space Agency* (ESA) *Space Weather* (SWE)⁴ a analýzy nami riešeného problému majú modely a výstupy strojového učenia tieto hlavné charakteristiky:

- Hoci sme disponovali časovými rádmi rôznych číselných atribútov, naším hlavným cieľom bola dichotomická klasifikácia pre dve triedy (0 - bez scintilácie, 1 - scintilácia). Preto vyhodnocovanie modelov viedlo k problému binárnej klasifikácie s hodnotami definovanými pomocou zvoleného prahu na σ_ϕ meraniach alebo predikciách.
- V súlade s usmerneniami ESA SWE sme postupovali podľa nepravdepodobnostnej binárnej predikcie (so špecifikovaným prahom na definovanie výskytu udalosti). V probléme sme disponovali aj priestorovým prvkom založeným na možnosti výberu podmnožín meraní (tzv. biny) v rámci oblohy na hlbšiu analýzu predikcií a ich aplikácií. Modely strojového učenia sa vytvárali podľa týchto podmnožín údajov alebo sa aplikovali s využitím takýchto informácií.
- Výskyt udalosti (ionosférická scintilácia ako trieda 1) bol veľmi zriedkavý a vysoko nevyvážený voči nevýskytu (trieda 0), preto niektoré z hodnotiacich metrík neboli užitočné.
- V prípade potenciálnych budúcich aplikácií by tento typ služby mohol byť

⁴Dostupné v ESA SWE Technical Library <https://swe.ssa.esa.int/documents/20182/25484/ssa-swe-escdef-tn-5401-i2r2a%2BValidationGuidelines.pdf/412d58e6-6643-433e-934b-1b10beba82da>.

dôležitý na analýzu a zmiernenie špecifickej chyby v predikciách. Používateľ bude napríklad pripravený a upozornený na problémy s navigáciou (niekedy aj falošne) namiesto toho, aby nebol upozornený vôbec. To nás viedlo k uprednostňovaniu metrík, ktoré poskytujú diagnostiku modelov práve na takéto typy chýb.

Základnou technikou analýzy predikcie v porovnaní s referenciou (pravdou alebo pozorovaním) pri binárnej klasifikácii je použitie *confusion matrix* (2x2 kontingenčná tabuľka), ktorá zobrazuje vzťah medzi predikovanými a pravdivými hodnotami na testovacej podmnožine našich údajov. Existujú prípady kombinácií medzi predikciami (1 alebo 0) a pozorovaniami (1 alebo 0):

- **True Positive (TP)**: udalosť, o ktorej sa predikovalo, že nastane (1) a skutočne nastala (1)
- **False Negative (FN)**: udalosť nebola predikovaná (0), ale nastala (1)
- **False Positive (FP)**: udalosť, ktorej výskyt bol predikovaný (1), ale nenastala (0)
- **True Negative (TN)**: udalosť nebola predikovaná (0) a nenastala (0)

	Predicted 0	Predicted 1
Actual 0	TN	FP
Actual 1	FN	TP

Obrázok 3–1 Štruktúra *confusion matrix* pre binárnu klasifikáciu pre pozitívnu hodnotu triedy 1 (scintilácia) a negatívnu hodnotu triedy 0 (bez scintilácie).

Na Obrázku 3–1 je znázornená *confusion matrix* s konkrétnymi hodnotami popísanými vyššie. Základnou metrikou hodnotenia binárnej klasifikácie je správnosť (*Accuracy* (ACC), možné preložiť aj ako presnosť), ktorá udáva pomer správne klasifikovaných prípadov ($TP + TN$) ku všetkým prípadom v *confusion matrix*. Táto metrika bola pre náš účel nevhodná vzhľadom na veľmi nevyvážený súbor údajov. V prípade nevyváženého súboru údajov so zriedkavými pozitívnymi predikciami udalostí ($TP \ll TN$) je v strojovom učení štandardom analyzovať výsledky pomocou presnosti a návratnosti konkrétnych pozitívnych predikcií tried alebo podobných metrík.

Presnosť (*Precision* (P), známa aj ako pomer úspešnosti (*Success Ratio*) - SR alebo pozitívna prediktívna hodnota (*Positive Predictive Value*) - PPV) ukazuje, ako často klasifikátor správne identifikuje pozitívnu triedu, keď ju predikuje.

- Vzťah 3.1 sa teda používa na výpočet presnosti. Metrikou sa teda diagnostikuje chyba FP.
- Okrem toho existuje pomer falošných poplachov (FAR alebo *False Alarm Rate*), ktorý je v podstate $1 - P$, alebo v prípade *confusion matrix* Vzťah 3.2.

$$P = \frac{TP}{TP + FP} \quad (3.1)$$


$$FAR = \frac{FP}{TP + FP} \quad (3.2)$$

Návratnosť (*Recall* (R), známa aj ako pravdepodobnosť detekcie, citlivosť alebo miera skutočnej pozitivity: *True Positive Rate* (TPR)) nám ukazuje, koľko skutočných pozitívnych príkladov je možné poskytnúť v predikciách. Vypočíta sa ako Vzťah 3.3. Chyba FN je teda taká, ktorá sa diagnostikuje pomocou tejto metriky.

$$R = \frac{TP}{TP + FN} \quad (3.3)$$

Vzhľadom na povahu problému a nevyvážený súbor dát sú *Precision* a *Recall* hlavnými metrikami na analýzu našich výstupných ML modelov. **F1-skóre** sa používa aj na analýzu presnosti a návratnosti v jednej výstupnej metrike, ktorá je harmonickým priemerom P a R definovaným ako:

$$F1 = \frac{2PR}{P + R} \quad (3.4)$$



Obrázok 3–2 Príklady kriviek ROC a Precision-Recall.

Na podrobnejšiu analýzu výkonnosti klasifikátora sa často používa **Receiver Operating Characteristic (ROC) krivka** na vykreslenie závislosti *False Positive Rate* (FPR) (*fall-out*) od TPR (*Recall*) s použitím súboru rastúcich prahových hodnôt pravdepodobnosti na rozhodnutie áno/nie (pozri podobrázok a Obrázka 3–2). Ako skóre sa používa plocha pod krivkou ROC, známa ako *Area Under the Curve* (AUC), môžeme ju nazvať aj **AUC-ROC**. Jednou z výhod je aj možnosť nájsť optimálne nastavenie rozhodovacieho prahu pre jednotlivé triedy, čo poskytuje lepšie výsledky klasifikácie pre ten istý model. Optimálny prah je bod na krivke ROC, ktorý je najbližšie k ľavému hornému rohu, čo predstavuje najvyššie TPR a najnižšie FPR. AUC-ROC meria schopnosť modelu správne identifikovať zriedkavé pozitívne príklady a zároveň minimalizovať počet falošne negatívnych príkladov (zriedkavé pozitívne príklady klasifikované ako príklady dominantnej negatívnej triedy) (Hoo et al., 2017).

Hlavnou nevýhodou krivky ROC je, že funguje dobre najmä pri vyváženejších dátových množinách, pretože sa pozerá rovnako na pozitívne aj negatívne triedy. V nevyvážených prípadoch, keďže počet negatívnych záznamov je oveľa väčší ako pozitívnych, to môže viesť k príliš optimistickému pohľadu na výkonnosť (podobne ako pri metrike presnosti). V takom prípade sa odporúča vyskúšať namiesto, alebo spolu s ROC aj (podobne vytvorenú) **Precision-Recall curve** (príklad na podobrázku **b** Obrázka 3–2). To by mohlo jasnejšie analyzovať presnosť a návratnosť zriedkavo pozitívnych tried. Taktiež môžeme použiť plochu pod krivkou na skórovaciu metriku konkrétnych modelov; definovanú ako **AUC-PR**. Podobne ako krivku ROC môžeme krivku P-R použiť na výber optimálneho prahu pre binárnu klasifikáciu, ktorý optimalizuje kritériá (F-1 skóre, rozdiel presnosti a návratnosti, atď.). PR-AUC môže pomôcť (v nevyvážených dátových množinách) správne identifikovať pozitívne príklady (zriedkavé pozitívne výskyty triedy) a zároveň minimalizovať počet falošne pozitívnych prípadov (dominantné negatívne príklady triedy klasifikované ako pozitívne výskyty triedy) (Narkhede, 2018).

Existujú aj iné prístupy pre optimálny výber prahu. Okrem bežných metód optimalizácie krivky ROC a krivky P-R sme uvažovali aj o optimalizácii ROC pomocou **Youdenovej J štatistiky** alebo **Youdenovho indexu** na ROC. Ide o skalárnu metriku, ktorá je založená na TPR (senzitivita alebo návratnosť) a *True Negative Rate* (TNR) (špecifickosť) a používa sa na určenie prahu, ktorý maximalizuje súčet týchto dvoch metrik. Experimenty ukázali malý rozdiel v použití Youdenovho indexu na výber prahu v ROC podľa iných výberov pre naše dátové množiny. Podobné porovnanie modelov však poskytuje metrika **TSS**, ktorá je menej citlivá na nevyvážené dátové množiny. Preto je táto metrika populárna v oblastiach, ktoré sa zaoberajú extrémne nevyváženými dátami, ako je napríklad predpoveď počasia alebo odhalovanie podvodov. V článku McGranaghan et al. (2018), ktorý by sa mohol použiť na porovnanie niektorých našich výsledkov, autori použili na vyhodnotenie túto metriku, definovanú nasledovne:

$$TSS = \frac{TP}{TP + FN} - \frac{TN}{TN + FP}. \quad (3.5)$$

TSS môže nadobúdať hodnoty od -1 (všetky udalosti sú nesprávne predikované) do 1 (všetky udalosti sú správne predikované), pričom hodnoty pod nulou znamenajú horšiu klasifikáciu ako náhodná a hodnoty nad nulou znamenajú, že predikcia prekonáva náhodný výber (Allouche et al., 2006; Ruopp et al., 2008).

Existuje aj možnosť použiť techniku **Grid-Search**, ktorá je založená na testovaní výkonnosti modelu pre rôzne nastavenia prahových hodnôt a výbere prahu, ktorý poskytuje najlepší výkon podľa zvolenej hodnotiacej metriky. Často však neprinesie lepšie výsledky ako niektoré z predchádzajúcich prístupov, pretože tie sa už snažia optimalizovať prah v zmysle nejakej metriky. Preto môže ísť o časovo náročný postup bez skutočného zlepšenia výsledkov.

Jednou z dôležitých metód na rozhodovanie o optimálnom prahu je aj **Analýza nákladov a výnosov**, ktorá hodnotí kompromis medzi nákladmi a výnosmi rôznych rozhodnutí. V kontexte hľadania optimálneho prahu pre model predikcie časových radov sa môže použiť na vyhodnotenie kompromisu medzi nákladmi na falošne pozitívne a falošne negatívne výsledky. V našom prípade je dôležité minimalizovať počet falošne negatívnych prípadov, čo znamená maximalizovať návratnosť pozitívnej triedy, a to z praktických dôvodov uprednostnenia minimalizácie chýbajúcich poplachov pred falošnými poplachmi, ako bolo uvedené na začiatku kapitoly. Táto metóda vykazovala dobré výsledky počas všetkých experimentov a v záverečných experimentoch sme sa rozhodli použiť krivku ROC optimalizovanú smerom k návratnosti.

Na zhrnutie odporúčaní pre hodnotenie modelov, výber prahových hodnôt v našom projekte a tiež podľa našich poznatkov počas experimentov, pri záverečnom hodnotení a jeho dokumentácii sme postupovali nasledovne:

- Hodnoty **confusion matrix** sú hlavnými vstupmi pre výpočet hodnotiacich metrík. Pre jednoduchosť uvádzame iba matice pre vybrané najlepšie modely.

- Vzhľadom na nevyváženosť dátového setu sa ako dôležité metriky uvádzajú presnosť - **Precision (P)** a návratnosť - **Recall (R)** pre zriedkavo pozitívne triedy. Kombinácia P a R sa použila aj na porovnanie modelov s **F1-skóre**.
- Vzhľadom na vysoko nevyvážené triedy so zriedkavou pozitívnou triedou sme spolu s tradične používanými analýzami **ROC krivky** a **AUC-ROC** analyzovali aj **P-R krivku** a jej **AUC-PR**.
- Ako ďalšiu metriku uvádzame aj **TSS**, ktoré bolo použité aj v predchádzajúcom súvisiacom článku, s ktorým môžeme porovnať niektoré naše výsledky.
- Na aplikačnej úrovni sa zdá byť dôležité čo najviac redukovať chybu FN, pretože je lepšie nadobudnúť falošnú notifikáciu (chyba FP) a pripraviť sa na potenciálne problémy, napr. s navigačnou službou, ako nebyť oboznámený vôbec (FN) a naraziť na prerušenie služby bez určitých možností prípravy zmiernenie dopadu. Preto sme sa po experimentovaní s prahovými technikami rozhodli v záverečných experimentoch použiť **ROC krivku pre optimálny výber prahu**, pretože **minimalizovala FN** lepšie ako iné prístupy.

3.2 Príprava dát na modelovanie

Metóda predspracovania je rovnaká pre všetky typy tréovaných modelov (autoregresné alebo multivariačné). Multivariačná predikcia analýzy časových radov znamená, že máme viacero premenných na základe ktorých potrebujeme predikovať cieľovú premennú (σ_ϕ).

3.2.1 Normalizácia

Normalizácia časových radov je proces transformácie hodnôt časového radu určitým štandardným spôsobom, aby boli údaje vhodné na modelovanie a analýzu. Tento proces je užitočný aj pre vyhodnotenie, poskytuje robustnejšie modely vzhľadom na rozsah vstupných údajov a uľahčuje modelu naučiť sa štruktúry v údajoch.

Použili sme **Min-Max normalizáciu**. Táto technika škáluje údaje medzi definovanými minimálnymi a maximálnymi hodnotami. Ako minimálne a maximálne hodnoty sme použili 0 a 1, pričom pôvodné hodnoty sme v tomto rozsahu proporcionálne preškálovali. Najmä pri architektúrach hlbokého učenia sa ukázala dôležitosť takejto normalizácie pre robustný a efektívny proces učenia.

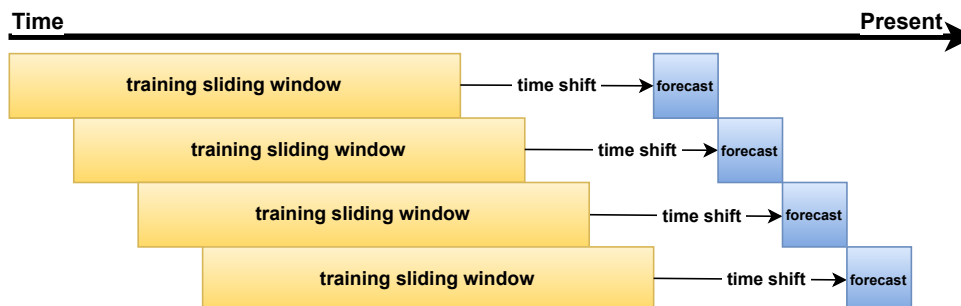
3.2.2 Okná a horizonty

Pri modelovaní časových radov sa údaje často analyzujú pomocou prístupu *windowing*. Dôvodom, prečo sme chceli v našom súbore údajov časových radov vytvoriť okná, bolo zmeniť predikciu na problém kontrolovaného učenia. Preto sme formátovovali a pripravili údaje časových radov s oknami a horizontmi:

- **Okná - *Windows***: Okno označuje súvislú podmnožinu údajov časového radu s pevnou dĺžkou, ktorá sa používa ako vstup do modelu na vytvorenie predikcie o ďalšom časovom kroku. Veľkosť okna je určená počtom minulých krokov, ktoré sa používajú ako vstup do modelu.
- **Horizonty - *Horizons***: Horizont označuje počet časových krokov, na ktorých predikciu sa model trénuje.

Veľkosť okna a veľkosť horizontu sú dôležité parametre, ktoré môžu ovplyvniť presnosť predikcií. Výber vhodných veľkostí oboch parametrov závisí od vlastností údajov časového radu a riešeného problému. A teda, vždy je dobré preskúmať rôzne kombinácie veľkosti okna a veľkosti horizontu a posúdiť výkonnosť modelu, aby sa našli najlepšie hodnoty.

Prístup posuvného okna (pozri Obrázok 3–3) je technika používaná na formátovanie a spracovanie údajov časových radov do okien (znázornených žltou farbou) a horizontov (znázornených modrou farbou) na použitie pri modelovaní a predikcii. Tento prístup zahŕňa rozdelenie údajov časového radu do viacerých okien pevnej dĺžky a posúvanie okna pozdĺž časového radu, po jednom kroku, s cieľom vytvoriť viacero vzoriek údajov.



Obrázok 3–3 Metóda posuvného okna. Pri tomto prístupe sa celý časový rad údajov rozdelí do čiastočne sa prekrývajúcich okien, pričom každé okno predstavuje podmnožinu údajov. Jedna vstupná postupnosť trébovaných údajov pozostáva z okna s predchádzajúcimi hodnotami (znázornené žltou farbou) a cieľovými hodnotami (nazývanými aj horizont, znázornené modrou farbou), ktoré sú oddelené zvoleným časovým posunom.

Pri tomto prístupe sa zvolí veľkosť okna a okno sa posúva pozdĺž časového radu údajov, pričom každá pozícia okna predstavuje novú vzorku. Veľkosť okna určuje počet minulých časových krokov, ktoré sa používajú ako vstup do modelu, zatiaľ čo horizont určuje počet budúcich časových krokov, ktoré by mal model predikovať. Tento prístup umožňuje trénovať model na viacerých vzorkách údajov časového radu, čím sa zvyšuje množstvo údajov dostupných na trébovanie, čo vedie k robustnejším a presnejším predikciám.

Pri vytváraní horizontov s časovým posunom sa model tréboje na súbore okien, ktoré sú posunuté o určitý počet časových krokov od cieľového horizontu. Napríklad, ak sú údaje časového radu posunuté o 1 hodinu, model bude trébovaný na oknách minulých údajov, ktorých veľkosť je určená zvolenou veľkosťou okna, a príslušný horizont bude posunutý o 1 hodinu, čo predstavuje ďalšiu hodinu údajov. Model použije minulé údaje v rámci veľkosti okna ako vstup a použije tieto informácie na predikovanie toho, čo sa stane o hodinu neskôr (Chu, 1995).

Na vytvorenie posuvných okien sú potrebné nasledujúce parametre:

- `window_size`: veľkosť okna prvkov (v minútach),
- `time_shift`: o koľko minút dopredu sa má urobiť predikcia,
- `multi_label`: určuje počet hodnôt, ktoré majú reprezentovať horizont.

3.2.3 Chýbajúce hodnoty

Pri prístupe s klzavým oknom je dôležité správne spracovať chýbajúce hodnoty. Pri vytváraní okien ho nie je možné použiť na tréovanie alebo testovanie modelu, ak obsahuje jednu alebo viac chýbajúcich hodnôt.

Jedným z bežných prístupov je potom jednoducho odstrániť tie okná, ktoré obsahujú jednu alebo viac chýbajúcich hodnôt. Týmto spôsobom sa model bude tréovať a testovať len na kompletných oknách dát. Tento prístup má však nevýhodu, môže byť príčinou zníženia množstva dát dostupných na tréovanie a testovanie, čo môže mať negatívny vplyv na výkonnosť modelu. V našom prípade sme však mali dostatok dát, takže aj po odstránení okien s chýbajúcimi hodnotami sme mali stále k dispozícii značné množstvo údajov na tréovanie a testovanie.

Dobrym postupom je použiť len podmnožinu údajov na počiatočné predspracovanie a konfiguráciu modelu. Po určení najlepších nastavení predspracovania a hyperparametrov je možné tréovať konečný model na celej množine údajov. Tento prístup môže ušetriť výpočtové zdroje a čas pri doladovaní modelu.

3.2.4 Určovanie veľkosti okien

Veľkosť okna pre predikciu časových radov je dôležitým parametrom, ktorý môže ovplyvniť ich presnosť. Výber vhodnej veľkosti okna vie byť náročný, pretože závisí od vlastností údajov časového radu a od daného problému. Tu je niekoľko faktorov, ktoré je potrebné zvážiť:

- **Stacionárnosť**: Ak je časový rad nestacionárny (t. j. jeho štatistické vlastnosti sa v čase menia), môže byť vhodnejšia menšia veľkosť okna. Dôvodom je, že

menšia veľkosť okna zachytí viac aktuálnych informácií o časovom rade, ktoré budú s väčšou pravdepodobnosťou relevantné pre predikcie budúcich hodnôt.

- **Sezónnosť:** Ak má časový rad výraznú sezónnosť, dostatočne veľká veľkosť okna na zachytenie sezónneho vzoru môže byť vhodnejšia.
- **Autokorelácia:** Ak má časový rad vysoký stupeň autokorelácie (t. j. je silne korelovaný so svojimi minulými hodnotami), môže byť vhodnejšia väčšia veľkosť okna. Je to preto, lebo väčšia veľkosť okna zachytí viac minulých informácií o časovom rade, ktoré budú s väčšou pravdepodobnosťou relevantné pre predikcie budúcich hodnôt.
- **Zložitosť modelu:** Väčšia veľkosť okna zvýši počet vstupných prvkov, čo vedie k zložitejším modelom. To môže viesť k nadmernému prispôsobeniu a znížiť schopnosť modelu zovšeobecniť sa na nové údaje.

Je zvykom začať s menšou veľkosťou okna a potom ju postupne zväčšovať a zároveň sledovať výkonnosť modelu.

Nevyvážené časové rady

Pomer nevyváženosti 1:X v súbore údajov znamená, že na každých X negatívnych príkladov pripadá len 1 pozitívny príklad. To môže modelu sťažiť presné predikovanie pozitívnej triedy, pretože počas tréningu nie je vystavený dostatočnému množstvu pozitívnych príkladov.

Problém nevyváženosti v predikcii časových radov sa vzťahuje na problém presného predikovania zriedkavých udalostí alebo anomálií v súbore dát časových radov. Môže to byť spôsobené skresleným rozdelením údajov, kde väčšina pozorovaní je normálna alebo neanomálna a malý počet pozorovaní je abnormálny alebo anomálny. Pre model môže byť ťažké presne identifikovať a predikovať zriedkavé udalosti, pretože je často tréningovaný na väčšine údajov, ktoré nie sú anomálne. Na riešenie tohto problému sa môžu použiť techniky ako nadmerný výber (*oversampling*), podvýber (*undersampling*) a opakovaný výber (*re-sampling*), aby sa súbor údajov vyvážil.

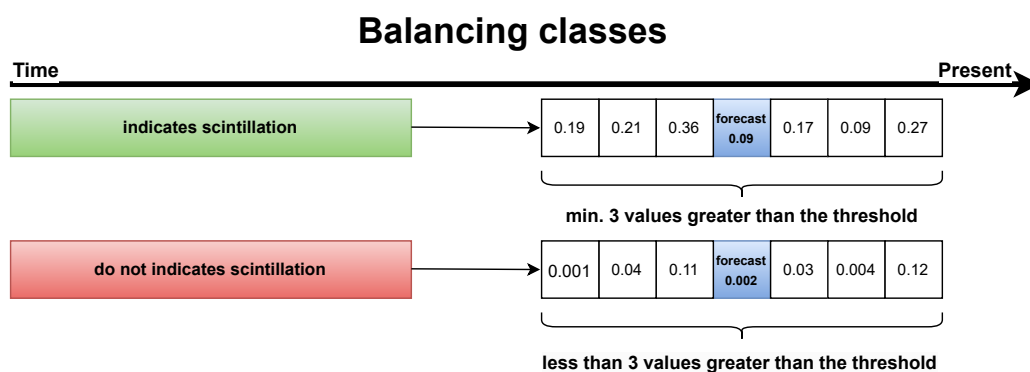
Počas vyvažovania je jedným z prístupov skúmanie, či hodnoty v danom okne indikujú hodnoty nad zvoleným prahom v horizonte. Toto sa zvyčajne robí pri problémoch klasifikácie časových radov, kde je cieľom predikovať kategorickú značku (napr. „hore“ alebo „dole“) na základe hodnôt v okne. Ak je napríklad prahová hodnota nastavená na určitú hodnotu a model je natrénovaný na predikciu, či hodnota v horizonte bude nad alebo pod touto prahovou hodnotou, údaje možno vyvážiť tak, že sa zabezpečí približne rovnaký počet príkladov, v ktorých je hodnota v horizonte nad a pod prahovou hodnotou. Môžeme to chápať ako metódu opätovného výberu vzoriek alebo presnejšie opätovného označenia scintilačných indikácií jednotlivých hodnôt časového radu v aktuálnom časovom kroku na základe hodnôt z celého okna.

V našom prípade namiesto jednoduchého sledovania, či je daná hodnota v horizonte nad alebo pod prahovou hodnotou, sme kontrolovali špecifický vzor v okolí horizontu (pozri Obrázok 3–4). Napríklad, ak bol prah nastavený na určitú hodnotu a podmienka bola nastavená okolo horizontu, museli existovať aspoň 3 hodnoty nad daným prahom, aby bolo okno označené ako vzťahujúce sa na pozitívnu triedu. Tento prístup nám mohol pomôcť zabrániť zaujatosti modelu voči jednej triede a pomôcť zvýšiť schopnosť modelu odhaliť zložitejšie vzory v údajoch.

Na vyváženie tried sme potrebovali nasledovné parametre:

- `scintillation_threshold`: prah σ_ϕ , od ktorého signál sa považoval za scintilačný,
- `y_look_side`: koľko hodnôt vpravo a vľavo v horizonte sa má zobrazit na označenie scintilácie (napríklad hodnota 3 vytvára okno o veľkosti 7),
- `y_count_win`: koľko hodnôt v označovacom kontextovom okne musí byť nad prahom scintilácie, aby sa hodnota považovala za scintiláciu.

Museli sme však mať na pamäti, že cieľom modelu bolo dobre zovšeobecniť v prípade doposiaľ neznámych dát, preto bolo dôležité vyhodnotiť výkonnosť modelu na nezávislom testovacom súbore. Na testovanie sme používali podmnožinu z roku



Obrázok 3–4 Prístup zvolený na vyvázenie tried je založený na znovuo značovaní na základe kontextu. Pri výbere prahu pre detekciu anomálií bolo dôležité zohľadniť kontext dát a okolité hodnoty. Tento kontext označenia má svoju šírku definovanú parametrom `y_look_side` (v tomto príklade rovná sa 3). Predstavme si, že máme okná predchádzajúcich hodnôt a ich cieľové horizonty pre zvolený časový posun, s označením šírky 3. V prvom prípade (zelená farba) hodnoty naznačujú scintiláciu na cieľovom horizonte (čierna šípka reprezentuje časový posun), aj keď stred označenia cieľového horizontu je nízky (pre `scintillation_threshold` na úrovni 0,1). Rozhodnutie sa opiera o existenciu aspoň 3 hodnôt (alebo všeobecne `y_count_win`) nad prahom scintilácie v označenom kontexte. Preto by sme mali považovať hodnotu cieľového horizontu (zobrazenú v modrej farbe) za výskyt scintilácie (pozitívnu triedu) namiesto normálnej hodnoty (negatívna trieda), aj keď má sama o sebe malú hodnotu. V druhom prípade (červená farba) hodnoty neindikujú scintiláciu na cieľovom horizonte, pretože hodnoty v označenom kontexte sú väčšinou pod prahom. Preto sme v druhom príklade neoznačili cieľovú hodnotu horizontu ako scintiláciu.

2019 (nezávislú od tréningovej množiny, ktorá bola vybraná z iných rokov), na ktorú sme aplikovali len prístup posuvného okna bez vyvažovania na základe opätovného označovania. Testovacia množina teda nebola vyvážená, čo znamená, že môže obsahovať viac príkladov väčšinovej triedy ako menšinovej triedy, čo však bolo dôležité pre vyhodnotenie a bol to jeden zo základných predpokladov pri rozdelení train-test (testovacie časti nemenia svoje rozdelenie pomocou vyvažovania).

3.3 Hlboké učenie

Vzhľadom na našu predchádzajúcu analýzu sme sa rozhodli pracovať s architektúrou hlbokého učenia, o ktorej je známe, že je dobrá v úlohách predikcie. Pri výbere optimálnej architektúry je bežným prístupom pri vývoji prognostických modelov časových radov použitie základnej architektúry modelu a porovnanie výsledkov na rôznych veľkostiach okien, časových posunoch a horizontoch. To nám umožňuje posúdiť vplyv rôznych techník predspracovania na výkonnosť modelu a identifikovať najlepšie nastavenia pre náš konkrétny problém a dáta.

Všeobecný prehľad metodiky vývoja, ktorú sme použili:

- **Definovanie architektúry základného modelu:** Vybrali sme si vhodný model hlbokého učenia: autoregresný alebo multivariačný.
- **Predspracovanie dát:** Použili sme rôzne veľkosti okien, časové posuny a horizonty na vytvorenie viacerých súborov predspracovaných dát.
- **Trénovanie a vyhodnotenie modelu:** Natrénovali sme model na každom súbore predspracovaných dát a vyhodnotili výkonnosť modelu pomocou vhodných metrík s použitím prahovej metódy.
- **Porovnanie výsledkov:** Porovnali sme výkonnosť modelu na rôznych súboroch predspracovaných dát a identifikovali najlepšie nastavenia veľkosti okna, časového posunu a horizontu, ktoré poskytujú najlepšiu výkonnosť.
- **Nastavenie hyperparametrov:** Po určení najlepších nastavení veľkosti okna, časového posunu a horizontu sme sa pokúsili vyladiť hyperparametre modelu, aby sme ešte viac zlepšili jeho výkonnosť.
- **Výber modelu:** Vybrali sme najlepší model z výsledkov získaných pomocou rôznych nastavení veľkosti okna, časového posunu, horizontu a ladenia hyperparametrov.

3.3.1 Autoregresná predikcia časových radov

Autoregresná predikcia časových radov je metóda využívajúca minulé hodnoty časového radu na modelovanie a predpovedanie budúcich hodnôt. Základným predpokladom tejto metódy je, že minulé správanie časového radu možno použiť na predikciu jeho budúceho správania.

Autoregresné predikovanie časových radov pomocou hlbokého učenia sa týka používania techník hlbokého učenia, ako sú napríklad rekurentné neurónové siete (*Recurrent Neural Network* (RNN), popísanej v Grossberg (2013)) a *Long Short-Term Memory* (LSTM) siete (popísanej v Hochreiter and Schmidhuber (1997)), na modelovanie a vytváranie predikcií o údajoch časových radov. Tieto techniky možno použiť na zachytenie nelineárnych závislostí v časových radoch, vďaka čomu sú flexibilnejšie a výkonnejšie ako tradičné autoregresné modely.

Predikcia časových radov pomocou LSTM a jednej vrstvy *Convolutional Neural Network* (CNN) je hybridný prístup, ktorý kombinuje silné stránky LSTM (tréning založený na pamäti, ktorý je lepší na extrakciu dlhších sekvenčných vzorov) a CNN (dobré na extrakciu lokálnych vzorov) na modelovanie a predpovedanie údajov časových radov. Príkladom takejto architektúry je použitie vrstvy LSTM na spracovanie sekvenčných informácií a jednorozmernej vrstvy CNN na extrakciu vlastností z každého časového kroku.

Architektúra autoregresného modelu

Model, ktorý sme použili bol definovaný ako postupnosť vrstiev, ktoré spracovávajú vstup a vytvárajú výstup. Vstup do modelu je definovaný ako pole s tvarom `(Phi60_Sig1.shape[1],1)` a toto pole sa odovzdáva ako vstup do prvej vrstvy modelu.

- Prvá vrstva je 1D konvolučná vrstva so 128 filtrami a veľkosťou jadra 2. Parameter „*kernel size*“ určuje veľkosť okna, nad ktorým sa vykonáva konvolučná operácia, a v tomto prípade je nastavený na hodnotu 2. Parameter „*padding*“ je nastavený na hodnotu „*same*“, čo znamená, že na vstup sa pridá nulový

padding tak, aby výstup mal rovnakú dĺžku ako vstup.

- Výstup konvolučnej vrstvy sa odovzdá ako vstup do obojsmernej vrstvy LSTM so 128 jednotkami. Obojsmerná vrstva LSTM spracováva vstup v priamom aj spätnom smere, čím poskytuje modelu viac kontextu na učenie. Parametre dropout a recurrent dropout sú nastavené na 0,1 čo znamená, že počas tréningu sa pri každej aktualizácii náhodne vyradí 10% neurónov, aby sa zabránilo nadmernému prispôsobeniu modelu - *overfitting*.
- Výstup vrstvy LSTM prechádza cez *Dense* vrstvu popísanú v Dileep et al. (2020), so 64 jednotkami a aktivačnou funkciou ReLU. Aktivačná funkcia ReLU sa používa na zavedenie nelinearity do modelu a je definovaná ako $f(x) = \max(0, x)$, kde x je vstup do aktivačnej funkcie (Ramachandran et al., 2017).
- Výstup *Dense* vrstvy prechádza cez *Dropout* vrstvu s mierou 0,2, aby sa opäť znížil *overfitting* (Baldi and Sadowski, 2013).
- Výstup *Dropout* vrstvy prejde cez ďalšiu *Dense* vrstvu so 64 jednotkami a aktivačnou funkciou ReLU.
- Výstup *Dense* vrstvy prechádza cez ďalšiu *Dense* vrstvu s 32 jednotkami a ReLU aktivačnou funkciou.
- Výstup poslednej *Dense* vrstvy prechádza cez záverečnú *Dense* vrstvu s 1 hodnotou a lineárnou aktivačnou funkciou. Lineárna aktivačná funkcia sa používa preto, lebo model sa snaží predpovedať spojitú hodnotu pred jej transformáciou v následnom spracovaní na konečné označenie scintilácie alebo nescintilácie.

Podrobné zhrnutie modelu je znázornené na Obrázku 3–5. Model je zostavený s *loss* funkciou *mean squared error*, optimalizátorom Adam a metrikou *mean absolute error*. *Loss* funkcia sa používa na meranie rozdielu medzi predikovaným výstupom a

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 45, 1)]	0
conv1d (Conv1D)	(None, 45, 128)	384
bidirectional (Bidirectional)	(None, 256)	263168
dense (Dense)	(None, 64)	16448
dropout (Dropout)	(None, 64)	0
dense_1 (Dense)	(None, 64)	4160
dense_2 (Dense)	(None, 32)	2080
dense_3 (Dense)	(None, 1)	33
=====		
Total params: 286,273		
Trainable params: 286,273		
Non-trainable params: 0		

Obrázok 3–5 Zhrnutie architektúry použitého autoregresného neurónového modelu. Model sa skladá z vstupnej vrstvy, konvolučnej vrstvy, dvojsmerného LSTM, troch *Dense* vrstiev a vrstvy *dropout*. Počet parametrov modelu je 286 273, všetky sú trénovateľné. Výsledný výstup modelu je jedna hodnota reprezentujúca predikované ionosférické scintilácie.

skutočným výstupom a optimalizátor sa používa na aktualizáciu váh modelu počas tréovania. Metrika sa používa na hodnotenie výkonnosti modelu počas tréovania (Wang and Bovik, 2009; Zhang, 2018).

3.3.2 Multivariačná predikcia časových radov

Pri viacrozmernej alebo viacvstupovej (multivariačnej) predikcii sa na predpovedanie jednej výstupnej premennej používa ako vstup viac premenných. Tento typ predikcie sa bežne používa pri problémoch, pri ktorých sa predpokladá, že na výsledok má vplyv viacero premenných.

Viacrozmerná predikcia môže byť zložitejšia ako jednorozmerná predikcia, pretože zahŕňa predpovedanie vzťahu medzi viacerými premennými. Môže však po-

skytnúť aj presnejšie a informatívnejšie predikcie, pretože zohľadňuje vzťah medzi viacerými premennými, ktoré by mohli ovplyvniť výsledok.

3.3.3 Základná architektúra multivariačného modelu

Model preberá dva vstupy. Tieto vstupy prechádzajú dvoma samostatnými vetvami modelu, z ktorých každá pozostáva z obojsmernej vrstvy LSTM a následne z *Dense* vrstvy.

Layer (type)	Output Shape	Param #	Connected to
input_2 (InputLayer)	[(None, 45, 1)]	0	[]
input_1 (InputLayer)	[(None, 45, 1)]	0	[]
bidirectional (Bidirectional)	(None, 128)	33792	['input_2[0][0]']
bidirectional_1 (Bidirectional)	(None, 128)	33792	['input_1[0][0]']
dense (Dense)	(None, 32)	4128	['bidirectional[0][0]']
dense_1 (Dense)	(None, 32)	4128	['bidirectional_1[0][0]']
concatenate (Concatenate)	(None, 64)	0	['dense[0][0]', 'dense_1[0][0]']
dense_2 (Dense)	(None, 32)	2080	['concatenate[0][0]']
dropout (Dropout)	(None, 32)	0	['dense_2[0][0]']
dense_3 (Dense)	(None, 32)	1056	['dropout[0][0]']
dense_4 (Dense)	(None, 1)	33	['dense_3[0][0]']

=====
 Total params: 79,009
 Trainable params: 79,009
 Non-trainable params: 0
 =====

Obrázok 3–6 Architektúra multivariačného modelu. Základná architektúra multivariačného modelu sa skladá z dvoch vetiev, pričom každá z nich prijíma jeden vstup, nasledovaný dvojsmernou LSTM vrstvou, *Dense* vrstvou a aktivačnou funkciou ReLU. Výstupy oboch vetiev sú potom spojené a prechádzajú niekoľkými *Dense* vrstvami a vrstvami *dropout*, aby sa vytvorila finálna predikcia. Celkový počet parametrov je 79 009, pričom všetky parametre sú trénovateľné.

-
- Prvá vetva začína hodnotou `input_Phi60`, ktorá predstavuje scintiláciu a prechádza cez obojsmernú vrstvu LSTM so 64 jednotkami. Parametre *dropout* a *recurrent dropout* sú nastavené na 0,1.
 - Výstup vrstvy LSTM prechádza cez *Dense* vrstvu s 32 jednotkami a aktivačnou funkciou ReLU pre nelineárnu transformáciu, pričom $f(x) = \max(0, x)$, kde x je vstup pre aktivačnú funkciu (Ramachandran et al., 2017).
 - Druhá vetva začína druhým vstupom, ktorý predstavuje pridané hodnoty, ako je Kp index, a prechádza cez obojsmernú vrstvu LSTM so 64 jednotkami, *dropoutom* a rekurentným *dropoutom* nastaveným na 0,1.
 - Výstup vrstvy LSTM prechádza cez *Dense* vrstvu s 32 jednotkami a aktivačnou funkciou ReLU.
 - Výstup týchto dvoch vetiev sa spojí dohromady, čím sa výstupy oboch vetiev spoja do jedného vektora. To umožňuje modelu učiť sa z oboch vstupov a robiť kvalifikovanejšie predpovede.
 - Zlúčený výstup potom prechádza cez *Dense* vrstvu s 32 jednotkami a aktivačnou funkciou ReLU.
 - Výstup z tejto vrstvy prechádza cez *Dropout* vrstvu (aby sa zabránilo overfittingu) s hodnotou 0,2, čo znamená, že počas tréningu sa 20% neurónov náhodne vyradí pri každej aktualizácii.
 - Výstup *Dropout* vrstvy prechádza cez ďalšiu *Dense* vrstvu s 32 jednotkami a aktivačnou funkciou ReLU.
 - Výstup tejto *Dense* vrstvy prechádza cez poslednú *Dense* vrstvu s 1 jednotkou a lineárnou aktivačnou funkciou na predikciu spojitej hodnoty (neskôr transformovanej pomocou prahu pre konečný výstup).

Na Obrázku 3–6 je znázornené vyššie uvedené podrobné zhrnutie modelu. Model je zostavený so stratovou funkciou *mean squared error*, optimalizátorom Adam a metrikou *mean absolute error*.

4 Vyhodnotenie modelov

Kvantitatívne vyhodnotenie modelov hlbokého učenia zahŕňa meranie výkonnosti modelu pomocou číselných metrík, ako je *precision*, *recall*, F1 skóre atď. (podrobnosti je možné nájsť v časti 3). V tejto časti uvádzame tieto metriky vypočítané pomocou dátového setu obsahujúceho pravdivostné hodnoty a poskytujeme spôsob objektívneho merania výkonnosti modelu.

Kvalitatívne vyhodnotenie modelov hlbokého učenia zahŕňa subjektívnu analýzu výstupu modelu a určenie jeho kvality. Môže to zahŕňať vizualizáciu výstupu modelu, analýzu uvažovania alebo rozhodovacieho procesu modelu alebo vykonávanie štúdií používateľov s cieľom získať spätnú väzbu na výkon modelu. Kvalitatívne vyhodnotenie môže poskytnúť komplexnejšie pochopenie silných a slabých stránok modelu. Takisto môže byť tento typ vyhodnotenia užitočný pri výbere modelov, ktoré môžu byť prínosné, aj keď ich metriky nie sú maximalizované.

Pri vyhodnocovaní výkonnosti modelov hlbokého učenia sú dôležité kvantitatívne aj kvalitatívne vyhodnotenia. Kvantitatívne vyhodnotenie poskytuje objektívne miery výkonnosti, zatiaľ čo kvalitatívne vyhodnotenie poskytuje hlbšie pochopenie správania modelu a môže pomôcť identifikovať oblasti, ktoré je potrebné zlepšiť. Na vyhodnotenie výkonnosti nášho modelu sme použili kombináciu kvantitatívnych a kvalitatívnych metód vyhodnocovania.

4.1 Kvantitatívne vyhodnotenie

Postprocessing je potrebný na zlepšenie účinnosti modelu a lepšiu detekciu scintilačných udalostí. Pomocou tohto kroku môžeme identifikovať falošne negatívne scintilačné udalosti (*missed alarms*), ktorých príčina sú zmeny v ich intenzite. Metóda kľzavého okna nám umožňuje vykonať komplexnejšie vyhodnotenie údajov a pomáha zohľadniť kolísanie intenzity scintilačných udalostí. Okrem toho použitie krivky ROC a optimálneho thresholdu pomáha vyvážiť kompromis medzi falošne pozitívnymi a falošne negatívnymi výsledkami a zlepšuje celkovú výkonnosť modelu.

Preto sme zostavili nasledujúce hodnotiace scenáre:

- **Vyhodnotenie I:** Bez dodatočného postprocesingu založeného na oknách sme našli optimálnu prahovú hodnotu len určením bodu krivky ROC, kde bol rozdiel medzi TPR a FPR najväčší. Mohli sme to jednoducho vnímať ako predikciu jednej hodnoty, pričom optimálny prah z krivky ROC sa použil ako konečný prah na priradenie scintilačných príznakov.
- **Vyhodnotenie II:** Použili sme klzavé okno, ktoré nadobudlo maximálnu hodnotu v okne veľkosti 5. Parameter minimálnej periódy bol nastavený na 1 čo znamená, že klzavé okno vrátilo platné výsledky, aj keď bola v okne len jedna hodnota. To sa používalo na vyhladenie pôvodných údajov časového radu a pomáhalo to znížiť vplyv šumu v údajoch. Potom sme našli optimálnu prahovú hodnotu rovnakým spôsobom ako pri prvom druhu vyhodnotenia.
- **Vyhodnotenie III:** Našli sme optimálnu prahovú hodnotu a potom sme použili metódu klzavého okna na kontrolu, či v okne veľkosti 6 existujú aspoň dve hodnoty nad prahovou hodnotou. Ak boli takéto dve hodnoty, konečná hodnota v tomto okne sa nastavila na 1; v opačnom prípade sa nastavila na 0. Týmto spôsobom sme mohli zabezpečiť, že aj keď bola konkrétna hodnota pod prahovou hodnotou, bola rozpoznaná ako scintilácia, ak je obklopená hodnotami nad prahovou hodnotou.

4.1.1 Predikcia perzistencie

Predikcia perzistencie je metóda na predikciu budúceho správania systému na základe jeho aktuálneho stavu. Je to jednoduchá, ale výkonná technika, ktorá sa široko používa v rôznych oblastiach, ako je meteorológia, financie a energetické systémy. Pri predikcii scintilácie sa predikcia perzistencie používa na predpovedanie budúceho scintilačného indexu na základe aktuálneho scintilačného indexu. Základnou myšlienkou predikcie perzistencie je, že budúci scintilačný index bude podobný aktuálnemu scintilačnému indexu. Predikciu perzistencie možno považovať za minimálny

základný model pre domény so zriedkavou pozitívnou triedou. Preto nám poskytoval minimálne základné metriky na porovnanie s predikčnými schopnosťami nami navrhnutého modelu.

Jedným zo spôsobov realizácie predikcie perzistencie je použitie prístupu klzavého okna. Na zachytenie aktuálneho indexu scintilácie sa používa okno pevnej veľkosti a index scintilácie sa v rámci tohto okna používa na predikciu budúceho indexu scintilácie. Okno sa potom posunie dopredu v čase a proces sa opakuje. Tento prístup možno použiť na predikciu scintilačných udalostí na niekoľko minút dopredu a často sa používa ako referenčná hodnota na porovnanie s inými metódami predikcie.

Jednou z hlavných výhod predikcie perzistencie je jej jednoduchosť. Nevyžaduje si zložité matematické modely ani veľké množstvo údajov a dá sa ľahko implementovať s minimálnymi výpočtovými zdrojmi. Okrem toho jej porovnanie s inými metódami predikcie môže pomôcť identifikovať silné a slabé stránky týchto metód. Jej presnosť je však obmedzená neschopnosťou zohľadniť iné faktory, ktoré môžu ovplyvniť scintilačný index. V Tabuľke 4–1 sú uvedené výsledky modelu predikcie perzistencie pre jeden bin v našom dátovom sete a časový posun 15 minút (so základným vyhodnotením). Ako vidíme, takýto model je schopný poskytnúť predikciu len o niečo lepšiu ako náhodná predikcia, s F1 skóre 0,12 a TSS 0,11. Model perzistencie sme použili aj v grafoch ako jeden z modelov v kvalitatívnej analýze, aby sme mali vizuálne porovnanie s našimi modelmi.

Tabuľka 4–1 Príklad výsledkov predikcie perzistencie na 15 minút dopredu.

Model	P	R	F1	AUC- ROC	AUC- PR	TSS
Persistence	0,12	0,12	0,12	0,70	0,13	0,11

4.1.2 Predikcia časových radov pomocou autoregresného modelu

Ako prvý sme použili autoregresný model, aby sme optimalizovali nastavenia na predikciu časových radov. Vďaka tomu sa vytvorilo viacero súborov predspracovaných údajov s použitím rôznych veľkostí okien a časových posunov. Model bol natrénovaný na každom sete predspracovaných dát a jeho výkonnosť bola vyhodnotená pomocou rôznych prístupov.

Výkonnosť modelov sa vyhodnotila na rôznych dátových množinách a identifikovali sa najlepšie nastavenia, ktoré sa použili v ďalšom kroku viacrozmernej predikcie časových radov. Tento prístup nám umožnil identifikovať ďalšie vlastnosti, ktoré pozitívne ovplyvňujú predikciu. Aplikácia iteračného procesu pomohla zlepšiť výkonnosť modelov.

Selekcia veľkosti okna

V tejto časti sme sa zamerali na určenie optimálnej veľkosti časového okna použitého na predspracovanie údajov pred tréňovaním autoregresného modelu. Ide o dôležitú úlohu, pretože veľkosť okna môže mať významný vplyv na výkonnosť modelu. Na určenie najlepšej veľkosti okna sme vyskúšali rôzne veľkosti okien (5, 10, 15, 30, 45, 60, 120, 180) a vyhodnotili sme výkonnosť modelu pomocou rôznych kvantitatívnych metrík.

Porovnaním výkonnosti modelu pri rôznych veľkostiach okien sme dokázali určiť veľkosť okna s najlepšimi výsledkami. Výber veľkosti okna je iteračný proces, ktorý pomáha zlepšiť výkonnosť modelu tým, že identifikuje najlepšiu veľkosť okna pre predikciu časového radu. Po určení najlepšej veľkosti okna sa použije v ďalšom kroku multivariačnej predikcie časových radov.

Ako je uvedené v Tabuľke 4–2, na testovacím súbore sme vyhodnotili výkonnosť rôznych modelov s rôznymi nastaveniami veľkosti okna. Z výsledku vyhodnotenia vyplýva, že najlepší výsledok merania má model s nastavením veľkosti okna 45, ktorý dosahuje TSS 0,80. Naše zistenia naznačujú, že veľkosť okna má významný vplyv na výkonnosť modelu. Zistili sme, že pri použití veľkosti okna 120 a 180

metriky výrazne klesli, čo naznačuje, že tieto veľkosti okien nie sú optimálne pre úlohu predikcie časových radov.

Tabuľka 4 – 2: Zoznam skúmaných modelov s rôznymi časovými posunmi a ich metriky pre testovací súbor (veľkosť okna bola stanovená na 45).

Model	Eval	P	R	F1	AUC-ROC	AUC-PR	TSS
shift-15-windows-5	1	0,05	0,77	0,09	0,88	0,41	0,63
	2	0,07	0,81	0,12	0,84	0,44	0,56
	3	0,05	0,86	0,10	0,90	0,46	0,67
shift-15-windows-10	1	0,07	0,74	0,13	0,89	0,41	0,65
	2	0,08	0,80	0,15	0,85	0,44	0,59
	3	0,09	0,83	0,16	0,90	0,46	0,71
shift-15-windows-15	1	0,07	0,78	0,13	0,90	0,42	0,68
	2	0,09	0,78	0,17	0,85	0,44	0,61
	3	0,08	0,86	0,15	0,91	0,47	0,73
shift-15-windows-30	1	0,07	0,80	0,13	0,91	0,43	0,71
	2	0,08	0,80	0,15	0,86	0,44	0,64
	3	0,08	0,86	0,15	0,91	0,47	0,75
shift-15-windows-45	1	0,10	0,83	0,18	0,93	0,46	0,76
	2	0,12	0,81	0,21	0,89	0,47	0,71
	3	0,12	0,87	0,22	0,93	0,50	0,80
shift-15-windows-60	1	0,08	0,84	0,15	0,93	0,46	0,77
	2	0,12	0,80	0,20	0,88	0,46	0,69
	3	0,11	0,90	0,19	0,94	0,50	0,82
shift-15-windows-120	1	0,05	0,84	0,09	0,84	0,44	0,58
	2	0,10	0,85	0,18	0,83	0,48	0,55

Model	Eval	P	R	F1	AUC-ROC	AUC-PR	TSS
	3	0,07	0,91	0,12	0,87	0,49	0,63
shift-15-windows-180	1	0,07	0,81	0,13	0,86	0,44	0,60
	2	0,13	0,82	0,22	0,85	0,48	0,56
	3	0,09	0,88	0,16	0,89	0,49	0,64

Hoci sa ako vhodný kandidát ukázala aj veľkosť okna 60, z dôvodu výpočtového času sme sa rozhodli použiť okno 45. Väčšie veľkosti okien si vyžadujú viac výpočtových zdrojov a môžu predĺžiť čas potrebný na tréning modelu. Okrem toho sme zohľadnili aj to, že väčšie okná majú väčšiu pravdepodobnosť, že budú obsahovať hodnoty *NaN*, čím by sa okno stalo nepoužiteľným. Preto sme zvolili veľkosť okna 45 ako optimálnu rovnováhu medzi výkonom a výpočtovým časom, pričom sme minimalizovali pravdepodobnosť výskytu hodnôt *NaN*.

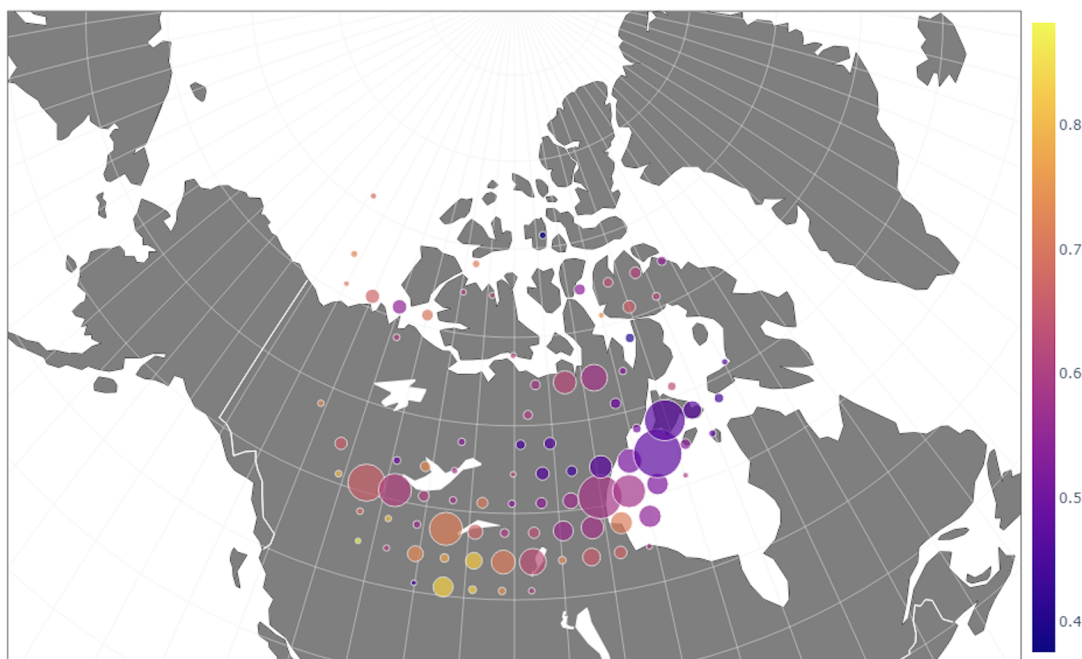
V Tabuľke 4–3 sa pre príklad *confusion matrix* použitej na vyhodnotenie metrík zobrazuje matica pre vybraný autoregresný model *Neural Network* (NN) s posunom 15 a veľkosťou okien 45 (shift-15-windows-45). Na ďalšie vyhodnotenie vybraného modelu sme sa tiež rozhodli pozrieť na jeho výkonnosť v jednotlivých binoch, a nie v celom dátovom sete. Tento krok nám umožnil zistiť, či existujú nejaké odchýlky súvisiace s umiestnením binov a či model dokázal presne odhaliť scintilačné udalosti vo všetkých binoch. Výsledky tejto analýzy poskytujú cenné poznatky o výkonnosti modelu a pomáhajú identifikovať oblasti, ktoré je potrebné zlepšiť. Obrázok 4–1 naznačuje, že výkonnosť modelu môže byť ovplyvnená skôr počtom dátových bodov v danom bine než umiestnením binu. Taktiež je možné povedať, že s rastúcim počtom dátových bodov v bine je farba hodnoty TSS tmavšia, čo znamená nižšie skóre TSS (podľa Vyhodnotenia 1). Veľkosť kruhu znázorňujúceho biny tiež ukazuje, že väčšie biny majú vyšší počet dátových bodov. To znamená, že so zvyšujúcim sa počtom dátových bodov v bine sa zvyšuje aj počet falošne pozitívnych údajov, čo má za

následok pokles výkonnostných ukazovateľov, ako sú TSS a AUC-PR. Napríklad Obrázok 4–2 predstavuje AUC-PR po postprocesingu (pre Vyhodnotenie 3).

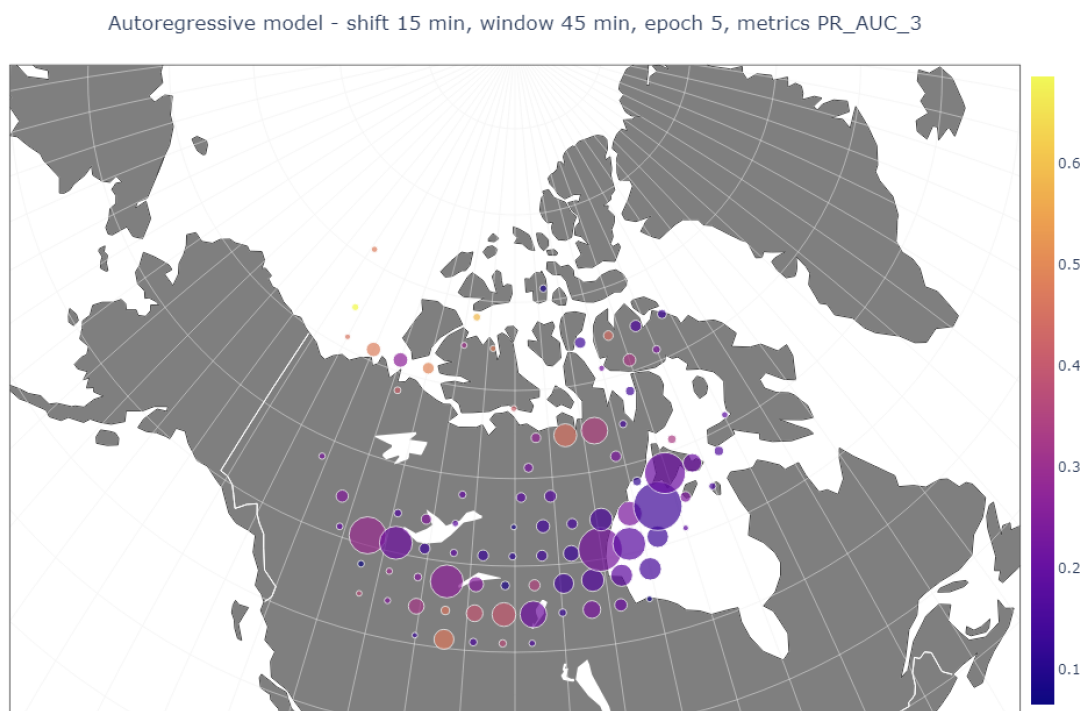
Tabuľka 4–3 *Confusion matrix* pre autoregresný model s posunom 15 a veľkosťou okien 45 (pozri riadok Eval 3 pre model s parametrami shift-15-windows-45 v Tabuľke 4–2 pre výpočet metrík vyhodnotenia z jeho hodnôt).

	Predicted 0	Predicted 1
Actual 0	231085	18636
Actual 1	379	2631

Autoregressive model - shift 15 min, window 45 min, epoch 5, metrics TSS_1



Obrázok 4–1 Zobrazenie výkonnosti modelu podľa umiestnenia binu a množstva údajov. Farba hodnoty TSS v každom bine označuje výkonnosť modelu, pričom tmavšie farby znamenajú nižšiu metriku TSS. Veľkosť kruhov predstavuje počet dátových bodov v každom bine. Obrázok naznačuje, že výkonnosť modelu môže byť ovplyvnená skôr počtom dátových bodov v bine ako umiestnením binu.



Obrázok 4–2 Na obrázku je zobrazené skóre AUC-PR výkonnosti modelu po následnom spracovaní („Vyhodnotenie 3“), ktoré je na geografickej mape znázornené rôznymi farbami. Tmavšia farba znamená nižšie skóre AUC-PR, čo zároveň znamená najhorší výkon modelu v danej oblasti. Mapa poskytuje intuitívne vizuálne znázornenie výkonnosti modelu v rôznych binoch.

Časový posun horizontu

V ďalšom kroku nášho procesu vyhodnocovania sme sa zamerali na parameter časového posunu. Časový posun sa vzťahuje na počet časových krokov, o ktoré je okno posunuté od cieľového horizontu. Tento parameter je dôležitý, pretože určuje úroveň granularity predikcií vykonaných modelom. Vykonali sme experimenty s použitím hodnôt časového posunu 1, 5, 10, 15, 20, 30, 40, 50 a 60 s pevnou veľkosťou okna 45. Náš model sme natrénovali na každom sete predspracovaných údajov a vyhodnotili sme jeho výkonnosť pomocou metrík.

Tabuľka 4–4 zobrazuje výkonnosť rôznych modelov s rôznymi nastaveniami časového posunu. Modely sú pomenované „shift-X-windows-45“, pričom „X“ predstavuje počet posunov aplikovaných na údaje. Podľa očakávania vidíme, že modely

s dlhšími časovými posunmi (napr. shift-50-windows-45, shift-60-windows-45) majú tendenciu mať nižšiu presnosť, návratnosť a skóre F1 v porovnaní s modelmi s nižším počtom posunov (napr. shift-1-windows-45, shift-5-windows-45). Skóre AUC-ROC a AUC-PR býva vyššie aj v prípade modelov s dlhšími posunmi, čo naznačuje, že tieto modely môžu byť lepšie pri identifikácii pozitívnych prípadov. Metrika TSS je vo všeobecnosti vysoké vo všetkých modeloch a hodnoteniach, čo je dobré znamenie, že modely celkovo fungujú podobne dobre.

Tabuľka 4 – 4: Zoznam skúmaných modelov s rôznymi časovými posunmi a ich metriky pre testovací súbor (veľkosť okna bola stanovená na 45).

Model	Eval	P	R	F1	AUC-ROC	AUC-PR	TSS
shift-1-windows-45	1	0,18	0,94	0,30	0,98	0,56	0,91
	2	0,15	0,97	0,26	0,95	0,56	0,89
	3	0,22	0,99	0,36	0,97	0,61	0,96
shift-5-windows-45	1	0,13	0,89	0,22	0,96	0,51	0,85
	2	0,13	0,89	0,23	0,92	0,51	0,79
	3	0,15	0,95	0,27	0,96	0,55	0,89
shift-10-windows-45	1	0,07	0,87	0,14	0,94	0,47	0,79
	2	0,11	0,86	0,19	0,90	0,48	0,73
	3	0,09	0,92	0,17	0,94	0,50	0,81
shift-15-windows-45	1	0,10	0,83	0,18	0,93	0,46	0,76
	2	0,12	0,81	0,21	0,89	0,47	0,71
	3	0,12	0,87	0,22	0,93	0,50	0,80
shift-20-windows-45	1	0,07	0,82	0,13	0,92	0,45	0,74
	2	0,11	0,80	0,19	0,88	0,45	0,67
	3	0,09	0,87	0,17	0,92	0,48	0,77

Model	Eval	P	R	F1	AUC-ROC	AUC-PR	TSS
shift-30-windows-45	1	0,08	0,77	0,14	0,90	0,42	0,69
	2	0,10	0,73	0,18	0,84	0,42	0,60
	3	0,10	0,84	0,18	0,90	0,47	0,75
shift-40-windows-45	1	0,04	0,76	0,08	0,87	0,40	0,63
	2	0,08	0,72	0,14	0,81	0,40	0,55
	3	0,05	0,83	0,10	0,87	0,44	0,67
shift-50-windows-45	1	0,04	0,73	0,08	0,85	0,39	0,59
	2	0,07	0,70	0,13	0,79	0,39	0,51
	3	0,05	0,78	0,10	0,85	0,42	0,61
shift-60-windows-45	1	0,05	0,70	0,09	0,85	0,37	0,59
	2	0,08	0,68	0,14	0,79	0,38	0,52
	3	0,06	0,77	0,11	0,86	0,42	0,64

4.1.3 Predikcia časových radov pomocou multivariačného modelu

Viacrozmerné predikcie časových radov sa vzťahujú na proces predikovania viacerých premenných súčasne. V našom prípade nás zaujíma predikcia ionosférických scintilácií, ktoré môžu byť ovplyvnené viacerými faktormi, ako je slnečná aktivita, parametre vesmírneho počasia, atmosférické podmienky a dynamika ionosféry, ako bolo prezentované v Kapitole 2. Na presné predikovanie ionosférických scintilácií je dôležité zohľadniť tieto viaceré faktory. Tabuľka 4–5 obsahuje výsledky rôznych multivariačných modelov natrénovaných pomocou kombinácie pôvodných časových radov (ako v prípade autoregresie) a jednej dodatočnej hodnoty z poskytnutého dátového setu uvedeného v Tabuľke 2–1 alebo vypísané v Zozname 2.1.1. V prvom stĺpci sú uvedené parametre, ktoré boli použité v každom modeli, zatiaľ čo v ostatných stĺpcoch sú uvedené rôzne metriky, ktoré boli použité na vyhodnotenie

výkonnosti modelov.

Výsledky autoregresného modelu s optimálnou konfiguráciou sú uvedené v prvom riadku Tabuľky 4–5. Tento riadok sa použil ako referenčná hodnota na porovnanie s ostatnými modelmi s ďalšími vstupnými funkciami. Zvýraznené hodnoty (tučným písmom) poskytujú výsledky vyhodnotenia lepšie ako naša referenčná hodnota, čo znamená, že vybrané konfigurácie takýchto modelov priniesli lepšie celkové výsledky v porovnaní s referenčnou hodnotou. Na základe výsledkov týchto predpovedí dosiahol najvyššie skóre TSS s hodnotou 0,82 model s dodatočnou hodnotou na vstupe Kp index, s veľkosťou okna 45 a časovým posunom 15. V Tabuľke 4–6 je uvedená *confusion matrix* pre model s Kp indexom (pre Eval 3). Tento model mal najlepšie výsledky aj v ďalších metrikách, ako sú AUC-ROC, AUC-PR a *Recall*. Preto tento model považujeme za najúspešnejší model spomedzi modelov kombinujúcich pôvodný časový rad a jeden dodatočný prvok.

Tabuľka 4–5: Zoznam preskúvaných multivariačných modelov NN s jednou ďalšou položkou a ich metriky pre testovaciu množinu. Zvýraznené hodnoty (tučným písmom) sú lepšie ako naša referenčná hodnota (autoregresný model, prvý riadok v tabuľke), čo znamená, že vybrané konfigurácie týchto modelov priniesli lepšie výsledky v porovnaní s rovnakými metrikami referenčnej hodnoty.

Model	Eval	P	R	F1	AUC-ROC	AUC-PR	TSS
shift-15-windows-45	1	0,10	0,83	0,18	0,93	0,46	0,76
	2	0,12	0,81	0,21	0,89	0,47	0,71
	3	0,12	0,87	0,22	0,93	0,50	0,80
SYM/H	1	0,09	0,82	0,15	0,93	0,45	0,75
	2	0,12	0,79	0,21	0,88	0,46	0,69
	3	0,11	0,86	0,19	0,93	0,48	0,77
T _i	1	0,08	0,84	0,14	0,93	0,46	0,75
	2	0,12	0,80	0,21	0,89	0,46	0,69

Model	Eval	P	R	F1	AUC-ROC	AUC-PR	TSS
N ₂	3	0,10	0,88	0,18	0,93	0,49	0,78
	1	0,10	0,81	0,18	0,93	0,46	0,75
	2	0,17	0,76	0,28	0,89	0,47	0,69
	3	0,14	0,85	0,23	0,93	0,49	0,78
ASY/H	1	0,09	0,84	0,17	0,94	0,47	0,77
	2	0,12	0,83	0,20	0,90	0,47	0,71
	3	0,13	0,88	0,22	0,94	0,50	0,80
N _m E	1	0,08	0,83	0,14	0,93	0,45	0,75
	2	0,11	0,81	0,19	0,87	0,46	0,69
	3	0,10	0,88	0,17	0,92	0,49	0,78
BSNx GSE	1	0,08	0,72	0,15	0,86	0,41	0,56
	2	0,15	0,76	0,24	0,83	0,46	0,53
	3	0,12	0,77	0,20	0,86	0,45	0,60
Electric Field	1	0,17	0,74	0,28	0,91	0,46	0,67
	2	0,17	0,81	0,28	0,85	0,49	0,61
	3	0,21	0,74	0,32	0,86	0,48	0,65
<i>pSig1</i>	1	0,09	0,81	0,17	0,93	0,45	0,74
	2	0,14	0,78	0,24	0,88	0,46	0,69
	3	0,12	0,85	0,21	0,93	0,49	0,78
ASY/D	1	0,11	0,73	0,19	0,87	0,42	0,60
	2	0,16	0,78	0,26	0,85	0,47	0,56
	3	0,14	0,77	0,24	0,88	0,46	0,63
Kp index	1	0,09	0,86	0,15	0,95	0,47	0,78
	2	0,13	0,83	0,23	0,91	0,48	0,73
	3	0,11	0,90	0,20	0,95	0,51	0,82
Ap index	1	0,08	0,87	0,14	0,95	0,47	0,78
	2	0,11	0,85	0,19	0,91	0,48	0,72
	3	0,10	0,91	0,18	0,96	0,51	0,82
S ₄	1	0,07	0,83	0,13	0,93	0,45	0,74
	2	0,12	0,79	0,21	0,88	0,46	0,69
	3	0,09	0,87	0,17	0,93	0,48	0,77
O ₂ ⁺	1	0,10	0,82	0,17	0,94	0,46	0,76

Model	Eval	P	R	F1	AUC- ROC	AUC- PR	TSS
	2	0,14	0,79	0,24	0,90	0,47	0,70
	3	0,13	0,86	0,22	0,94	0,49	0,79
n_e	1	0,08	0,82	0,15	0,93	0,45	0,75
	2	0,13	0,79	0,22	0,87	0,46	0,69
	3	0,11	0,86	0,19	0,92	0,48	0,77
PC(N) index	1	0,11	0,74	0,19	0,88	0,43	0,61
	2	0,15	0,79	0,26	0,85	0,48	0,57
	3	0,15	0,78	0,24	0,89	0,47	0,64
F10.7 index	1	0,09	0,82	0,16	0,93	0,45	0,75
	2	0,12	0,80	0,20	0,89	0,46	0,69
	3	0,11	0,86	0,20	0,93	0,49	0,78
Dst index	1	0,09	0,82	0,15	0,93	0,45	0,75
	2	0,11	0,81	0,20	0,89	0,46	0,69
	3	0,11	0,87	0,19	0,93	0,49	0,78
AE index	1	0,10	0,80	0,17	0,88	0,45	0,62
	2	0,19	0,78	0,30	0,86	0,49	0,57
	3	0,13	0,82	0,22	0,88	0,48	0,62
Bz GSE	1	0,11	0,73	0,19	0,87	0,42	0,60
	2	0,19	0,75	0,30	0,84	0,47	0,56
	3	0,15	0,78	0,25	0,88	0,47	0,63

Tabuľka 4–6 *Confusion matrix* pre multivariačný model kombinujúci autoregresiu s Kp indexom (pozri riadok Eval 3 pre model „Kp index“ v Tabuľke 4–5 pre hodnotiace metriky vypočítané z jeho hodnôt).

	Predicted 0	Predicted 1
Actual 0	228454	21269
Actual 1	287	2713

Okrem toho ANOVA analýza ukázala, že Kp aj Ap index boli jednými z prvkov s najvyššou koreláciou s hodnotami cieľového časového radu (pozri Obr. 2–7). To

naznačuje, že zahrnutie týchto vlastností do multivariačného modelu pomohlo účinnejšie odhaliť scintiláciu. Výsledky preukázali význam týchto objektov pri detekcii scintilácie a že sú v súlade s tým, čo sa očakávalo na základe analýzy ANOVA.

Jedným zo zameraní experimentov bolo dosiahnuť čo najvyššie skóre TSS, ktoré udáva schopnosť modelu presne predpovedať skutočné scintilačné udalosti. Kľúčovým cieľom bola minimalizácia falošne negatívnych výsledkov, keďže tým by sa zabezpečila najpresnejšia predikcia scintilácií. Na dosiahnutie tohto cieľa boli vybrané modely s najvyššími metrikami TSS a *Recall*. Ako vidíme vo výsledkoch, niektoré modely mali vyššiu presnosť, ale nižšiu návratnosť (*recall*), čo znamená, že mali menej falošne pozitívnych predikcií, ale stále prehliadli niektoré skutočné scintilačné udalosti. Ďalšie podrobnosti o analýze falošne pozitívnych udalostí sú opísané v časti týkajúcej sa kvalitatívneho hodnotenia (pozri časť 4.2).

Výsledky analýzy ANOVA ukázali, že Bz GSE, AE index, PC(N) index a *Electric Field* mali tiež významný vplyv na predikovanie ionosférickej scintilácie. Dôvodom, prečo sa tieto atribúty v experimentoch neosvedčili, je však vysoký počet chýbajúcich hodnôt. Pri vytváraní okien na tréning a testovanie má aj jediná chýbajúca hodnota za následok vylúčenie daného okna. To nám prináša otvorený problém, ale aj príležitosť na ďalší výskum. Mohli by sme sa zamerať na nájdenie vhodnej metódy interpolácie týchto hodnôt alebo na vytvorenie kombinovaného modelu, ktorý by v prípade chýbajúcich hodnôt dokázal predikovať hodnoty pomocou autoregresného modelu. Na Obrázku 4–3 je znázornený multivariačný model, ktorý zahŕňa prvok *Electric Field*. Časová os na obrázku nám poskytuje pohľad na medzery v grafe, ktoré naznačujú vysoký počet chýbajúcich hodnôt.

Analýza ANOVA naznačila, že PC(N) index, p_{Sig1} , Ap index a Bz GSE sú podstatnými vlastnosťami na predikciu scintilačných udalostí, vyskúšali sme aj multivariačný model s pridaním všetkých týchto vlastností k pôvodnému časovému radu. Výsledky sa však pre TSS a *Recall* výrazne nezlepšili. Na druhej strane, F1 skóre týchto modelov bolo najlepšie v rámci všetkých hodnotených modelov, čo potenciálnym používateľom poskytuje najlepší kompromis medzi presnosťou a návratnosťou.

Výsledky sú uvedené v Tabulke 4–7.



Obrázok 4–3 Príklad grafov pre predikciu multivariačného modelu s prvkom *Electric Field*. Na časovej osi je možné rozpoznať periódy obsahujúce chýbajúce hodnoty. Na hornom paneli sú zobrazené namerané hodnoty. Na ostatných paneloch sú uvedené predikcie pre rôzne typy vyhodnotení. Výkonnosť predikcií je farebne označená. Podrobnejší opis grafu je uvedený v texte v časti 4.2.

4.1.4 Porovnanie predchádzajúceho výskumu na dátach CHAIN

Ako sme už spomenuli, jednou z možností porovnania našich výsledkov je použiť výsledky predchádzajúcej práce publikovanej v Publikácii McGranaghan et al. (2018). Autori tohto článku použili dva roky údajov CHAIN na predikciu ionosférických scintilácií. V porovnaní s naším prístupom vykonali rôzne kroky predspracovania a použili jednoduchšiu metódu - SVM. Ako vstup pre algoritmus analyzovali dôležitosť prvkov (na základe analýzy ich schopnosti dodať vyššie skóre TSS) a tieto prvky použili spolu ako vektor s cieľovými príznakmi definovanými prahom $\sigma_\phi = 0,1 \text{ rad}$. Preto nakoniec vyriešili problém klasifikácie podobne ako náš prístup.

Na účely vyhodnotenia definovali niekoľko scenárov s cieľom dosiahnuť spoľahlivejšie výsledky. To znamená, že okrem základného scenára (s jednou predpovedanou

Tabuľka 4–7 Výsledky multivariačného modelu NN s pridaním niekoľkých najdôležitejších prvkov podľa analýzy ANOVA. Zvýraznené hodnoty (tučne) poskytujú hodnotiace metriky vyššie ako náš referenčný model (autoregresný model), čo naznačuje, že zvolené konfigurácie týchto modelov priniesli lepšie výsledky v porovnaní s rovnakými metrikami referenčného modelu.

Model	Eval	P	R	F1	AUC-ROC	AUC-PR	TSS
<i>pSig1</i> , Ap index, Bz GSE, PC(N) index	1	0,11	0,78	0,19	0,89	0,45	0,63
	2	0,18	0,78	0,30	0,86	0,49	0,59
	3	0,14	0,82	0,24	0,89	0,48	0,65

Tabuľka 4–8 Výsledky predikcií na hodinu vopred pomocou SVM na súbore vybraných prvkov pre rôzne typy postprocesingu; prevzaté z McGranaghan et al. (2018).

Výsledky z McGranaghan et al. (2018)	TSS
SVM, 1h, 1 point over threshold	0,49
SVM, 1h, 3 consecutive points over threshold	0,51
SVM, 1h, 6 consecutive points over threshold	0,54
SVM, 1h, 15 cons. points average over threshold	0,51

hodnotou) mali aj ďalšie rozšírenia. V ďalších dvoch scenároch očakávali, že 3, resp. 6 po sebe idúcich bodov prekročí prah pre predikciu scintilácie. V poslednom scenári predpovedali scintiláciu na základe priemeru 15 po sebe nasledujúcich hodnôt. Vo všeobecnosti boli naše vyhodnotenia podobné, ale neočakávali sme, že po sebe idúce hodnoty dosiahnu prekročenie prahu (kvôli predpokladu, že ak je ionosféra turbulentná a blízko prahu, predikcia nemusí byť úspešná pri po sebe idúcom spracovaní, ale scintilácia tam pravdepodobne je) a tiež sme neskúšali priemerovanie hodnôt (pretože by mohlo neočakávane regresovať k nejakej hodnote špecifickej pre šum v

údajoch). Ich základný scenár vyhodnotenia (1-bodová predpoveď) je porovnateľný s našou metódou Vyhodnotenia 1. Z ich výsledkov (pozri Tabuľku 4–8) vidíme, že náš základný autoregresný model (pozri Tabuľku 4–4, model shift-60-windows-45) mal $TSS = 0,59$ pre Vyhodnotenie 1 a prekonal ich porovnateľný základný scenár 1-bodovej predikcie o hodnotu 0,1. Ak porovnáme ich najlepšiu predikciu založenú na následnom spracovaní (so 6 po sebe idúcimi bodmi nad prahovou hodnotou, metriku $TSS 0,54$) s naším najlepším scenárom vyhodnocovania modelu (Vyhodnotenie 3, $TSS = 0,64$) vidíme, že náš najlepší model prekonal ich najlepší model tiež o hodnotu 0,1 v TSS . Treba poznamenať, že lepšie výsledky sme dosiahli aj s autoregresným modelom založeným na architektúre hlbokého učenia, zatiaľ čo ich prístup založený na SVM potreboval extrakciu viac ako 10 príznakov a ich kombináciu.

4.2 Kvalitatívne vyhodnotenie


Kvalitatívne vyhodnotenie nášho modelu multivariačnej predikcie časových radov zahŕňalo analýzu výstupu modelu a určenie jeho kvality. To zahŕňalo vizualizáciu výstupov modelu a analýzu modelového uvažovania alebo rozhodovacieho procesu. Predikcie modelu sme porovnali so skutočnými meraniami ionosférických scintilácií s cieľom určiť ich kvalitu. To zahŕňalo vykreslenie modelových predikcií spolu so skutočnými meraniami a vizuálnu kontrolu výsledkov. Okrem toho sme porovnávali modelové predikcie so skutočnými meraniami ionosférických scintilácií pri rôznych vyhodnoteniach. Porovnali sme skutočné merania s predikciami vykonanými modelom neurónovej siete (Vyhodnotenia 1, 2 a 3), ako aj s metódou predikcie perzistencie. Toto porovnanie nám pomohlo určiť kvalitu a spoľahlivosť predikcií modelu. Vizuálna kontrola výsledkov poskytla jasnú predstavu o výkonnosti modelu a pomohla identifikovať prípadné nezrovnalosti medzi predikciami a skutočnými meraniami. Celkovo kvalitatívne vyhodnotenie pomohlo hlbšie pochopiť výkonnosť modelu a poskytlo cenné poznatky na ďalšie zlepšovanie.

Ako sme už spomenuli, vykonali sme porovnanie rôznych predikcií s pravdivými

meraniami a predikciami perzistencie. Na obrázkoch nižšie je možné nájsť porovnanie týchto hodnôt pomocou grafov rozptylu (*scatter plot*). Každá konkrétna vizualizácia je rozdelená na päť grafov. Prvý graf poskytuje skutočné hodnoty. Ďalšie štyri grafy zobrazujú výsledky konkrétnych vyhodnotení (3 modely pre Vyhodnotenie 1, 2 a 3) a model perzistencie (ako minimálny základ, pozri Tabuľku 4–1 pre odkaz na metriky vyhodnotenia tohto modelu). Pre každý z týchto štyroch grafov používame štyri farby na opis predikcií konkrétnych dátových bodov podľa ich klasifikačného stavu. Každá farba teda znamená inú podmnožinu *confusion matrix*, pričom prípady sú známe ako TN, FP, FN a TP. To nám pomáha lepšie pochopiť, ako jednotlivé modely predikujú scintilácie rôznej sily, časový interval ich prítomnosti atď. Je potrebné povedať, že naše modely pre akékoľvek následné spracovanie výsledkov sú výrazne lepšie ako základný model perzistencie, resp. prekonávajú jeho výsledky v TSS minimálne o 0,4 a až o viac ako 0,7 pre najlepší model v TSS (multivariačný model kombinovaný s Kp indexom, s TSS 0,82 pre Vyhodnotenie 3).

4.2.1 Predikcia časových radov pomocou autoregresného modelu

Scintiláciu definujeme ako udalosť, ktorá prekročí určitú prahovú hodnotu, ktorá je v našom prípade $\sigma_\phi = 0,1 \text{ rad}$. Hoci naše modely majú vysoké TSS a *Recall*, stále vykazujú vysokú mieru falošne pozitívnych prípadov. Na účely kvalitatívnej kontroly výsledkov sú na Obrázkoch 4–4 – 4–7 pre predikcie na 15 minút dopredu a na Obrázkoch 4–8 – 4–11 pre predikcie na 60 minút dopredu uvedené príklady autoregresných modelov pre rovnaký bin dát, ale pre rôzne dátumy. Modely často označujú celý interval hodnôt ako scintiláciu, aj keď nie všetky hodnoty prekračujú prahovú hodnotu. Hoci správne zachytí väčšinu hodnôt nad 0,1, v tom istom intervale je stále veľa hodnôt pod prahovou hodnotou. Mnohé falošne pozitívne prípady z časového intervalu s aktívnou scintiláciou by sa však podľa kvalitatívnej kontroly mohli považovať za skutočne správne predpovede, pretože reprezentujú obdobie scintilácie a narušený stav ionosféry vo všeobecnosti. Preto má náš model uspokojujú výkonnosť na nezistených údajoch, aspoň na zachytenie intervalov so scintiláciou.



Obrázok 4–4 Predikcia autoregresného modelu (posun o 15 minút) pre obdobie 15. marca – 20. marca 2019.

Na zlepšenie presnosti modelu sa navrhuje vyhodnocovať tieto udalosti podľa týchto intervalov, a nie označovať celý interval podľa prahovej hodnoty. Tento prístup by viedol k menšiemu počtu falošne pozitívnych prípadov a presnejšiemu zobrazeniu scintilačných udalostí. Je potrebné poznamenať, že model dokáže zachytiť každú fluktuáciu v ionosfére, ktorá často indikuje blížiacu sa scintiláciu. To poukazuje na dôležitosť komplexného vyhodnotenia výstupov modelu s prihliadnutím na presnosť predpovedí, ako aj na fyzikálne pravidlá a kritériá detekcie scintilácie.

4.2.2 Predikcia časových radov pomocou multivariačného modelu


V prípade multivariačných modelov s prvkami ako Kp a Ap index sme zistili, že tieto modely mali dobrú návratnosť a TSS a prekonal autoregresné modely. Zistili sme však aj to, že tento model mal vysoký počet falošne pozitívnych prípadov. Na riešenie tohto problému sme navrhli vyhodnocovať výstupy modelu v intervaloch, nie priebežne. Tento prístup nám umožňuje lepšie určiť, či sú fluktuácie v ionosfére



Obrázok 4–5 Predikcia autoregresného modelu (posun o 15 minút) pre obdobie 31. mája – 6. júna 2019.

skutočne scintilačné udalosti alebo len normálne odchýlky, ktoré sú nad prahovou hodnotou. Vyhodnocovaním výstupov modelu v intervaloch môžeme znížiť počet falošne pozitívnych prípadov a zlepšiť presnosť modelu. Okrem toho intervalový prístup vyhodnocovania stále zachytáva významné scintilačné udalosti a môže poskytnúť presnejšie pochopenie výkonnosti modelu. Na záver možno konštatovať, že prístup intervalového vyhodnocovania bude cenným doplnkom nášho kvalitatívneho procesu vyhodnocovania a poskytne presnejšie posúdenie výkonnosti modelu.

Na Obrázkoch 4–12 – 4–14 sú uvedené výsledky troch rôznych modelov pre rovnaký časový interval jedného konkrétneho binu. Obrázok 4–12 predstavuje autoregresný model, Obrázok 4–13 multivariačný model s Kp indexom a Obrázok 4–14 zobrazuje multivariačný model s Ap indexom. Ukazuje sa, že oba multivariačné modely majú menej falošne negatívnych prípadov v porovnaní s autoregresnými modelmi. To naznačuje, že začlenenie Kp a Ap indexov do multivariačných modelov zlepšilo ich výkonnosť pri detekcii scintilačných udalostí v porovnaní so spoliehaním



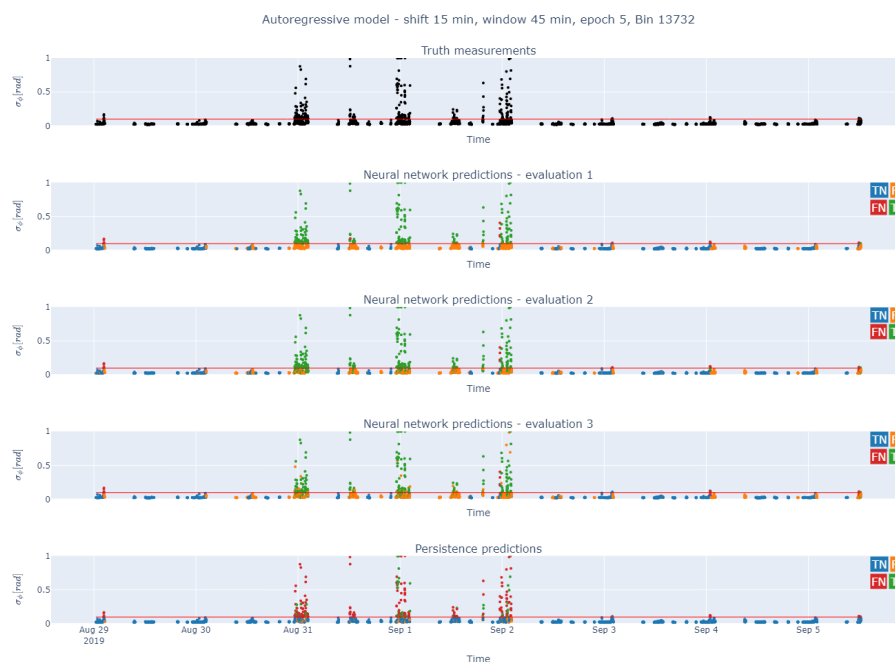
Obrázok 4–6 Predikcia autoregresného modelu (posun o 15 minút) pre obdobie 2. augusta – 9. augusta 2019.

sa výlučne na autoregresný model. Použitie týchto dodatočných prvkov viedlo k zníženiu počtu falošne negatívnych výsledkov, čo znamená, že multivariačné modely s väčšou pravdepodobnosťou správne identifikujú scintilačné udalosti.

4.3 Vyhodnotenie modelov na IMPC dátovom sete

Predchádzajúca analýza bola vykonaná na údajoch CHAIN. Naším zámerom je preskúmať vyvinuté techniky aj pre iné údaje, aby sme otestovali výkonnosť a robustnosť nášho prístupu. Na tento účel sme použili údaje IMPC uvedené v časti 2.1.3 doplnené o poznatky a dáta zo súkromnej komunikácie s expertmi z IMPC. V tejto časti uvádzame výsledky vyhodnotenia navrhnutých modelov aplikovaných na tieto IMPC dáta pre roky 2015–2016.

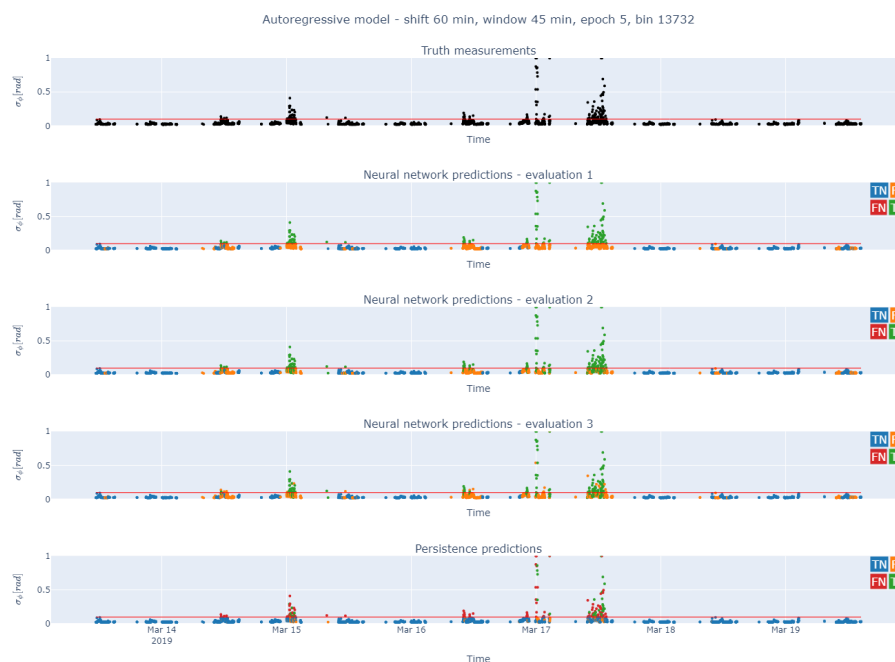
Na základné porovnanie, podobne ako v prípade použitia CHAIN dát, uvádzame aj model perzistencie ako základný minimálny model. Dáta a proces predikcie sa



Obrázok 4–7 Predikcia autoregresného modelu (posun o 15 minút) pre obdobie 29. augusta – 6. septembra 2019.

použili rovnakým spôsobom ako v prípade CHAIN dát (podrobnosti o tom, ako sa vytvára model perzistencie, nájdete v časti 4.1.1), pričom sa použila podmnožina založená na najväčšom bine. V Tabuľke 4–9 sú uvedené výsledky modelu perzistencie pre 15-minútové predikcie. Z výsledkov bolo zrejmé, že model perzistencie dokázal dosiahnuť pomerne vysoké skóre návratnosti, ale hlavným dôvodom je veľmi vysoká nerovnováha *true positive* prípadov voči negatívnej triede. Preto predikcia perzistencie poskytla taký dostatok falošne pozitívnych prípadov vo svojom jednoduchom pohľade do budúcnosti, že v podstate dokázala zasiahnuť aj veľa skutočne pozitívnych („*true positive*“) dátových bodov. Vďaka vyššiemu *recall* je aj skóre TSS pre tento model predikcie perzistencie pomerne vysoké.


Po vyhodnotení základného modelu perzistencie sme na IMPC dáta aplikovali predikciu pomocou autoregresnej NN. V tomto prípade sa na tréning modelu použila štruktúra autoregresného modelu s časovým posunom 15 minút a oknom veľkosti 45 minút (shift-15-windows-45). Rozhodli sme sa testovať len najlepšie mo-



Obrázok 4–8 Predikcia autoregresného modelu (posun o 60 minút) pre obdobie 14. marca – 19. marca 2019.

dely z predchádzajúcej analýzy CHAIN dát. Tieto experimenty však splnili aj účel overenia pripravenosti našich krokov predspracovania a modelov hlbokého učenia na poskytovanie predikcií na iných súboroch údajov, t. j. aby boli pripravené ako súčasť finálnej (proof-of-concept) služby na analýzu údajov.

Výsledky autoregresného modelu natrénovaného a otestovaného na údajoch IMPC sú uvedené v Tabuľke 4–10. Všetky vyhodnotenia poskytujú podobné výsledky a prekonávajú základné predikcie o takmer 30% v *recall*, poskytujú spoľahlivejšiu presnosť (podobne ako mnohé modely na CHAIN dátach) a TSS lepšie o viac ako 0,2 oproti základnému modelu perzistencie. Dôvodom podobných výsledkov pri troch vyhodnoteniach môže byť rovnaký alebo vyšší *recall* modelu perzistencie. Vzhľadom na vyššiu nerovnováhu skutočne pozitívnych výsledkov, nižšiu silu scintilácií a menšie intervaly aktivity poskytli vyhodnotenia 2 a 3 po spracovaní len menší prírastok účinnosti konečných predikcií. Výsledky pre multivariačný model kombinujúci autoregresiu a Kp index sú ešte o niečo lepšie.

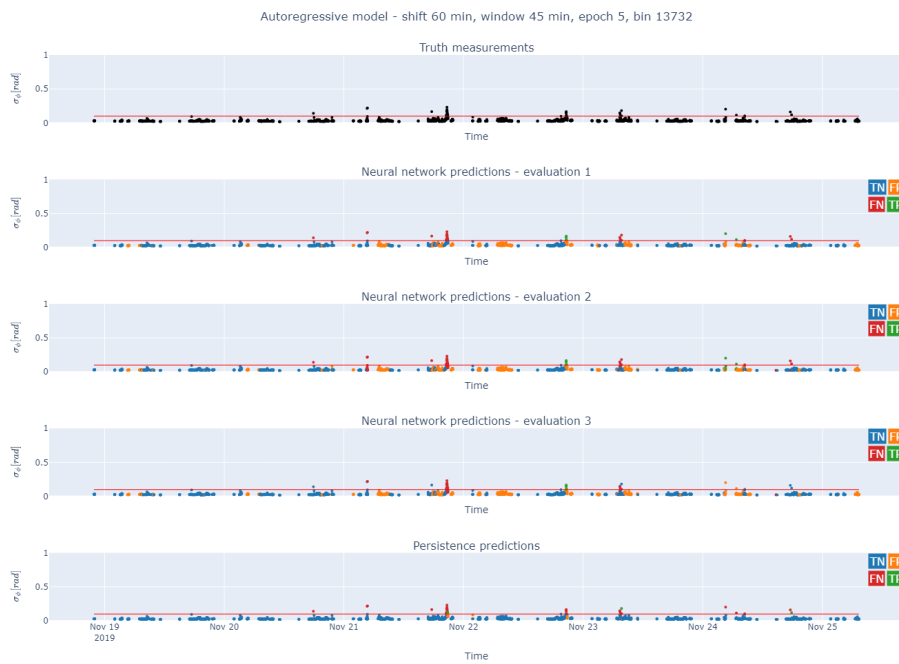


Obrázok 4–9 Predikcia autoregresného modelu (posun o 60 minút) pre obdobie 30. augusta – 11. septembra 2019.


V budúcnosti by sme mohli analyzovať ďalšie alternatívy k tvorbe modelu a následnému spracovaniu predikcií pre nové súbory údajov, t. j. hľadať lepšie nastavenie postupov vyhodnocovania (veľkosť okna, počet bodov v kontexte na prahovanie atď.). Pre budúce aplikácie by mohlo byť užitočné pochopiť takéto rozdiely s cieľom lepšie pripraviť nastavenie služby pre niektoré používateľsky špecifické súbory údajov. Experimenty s dátovým setom IMPC však dokázali overenie schopnosti našich modelov založených na hlbokom učení pre budúce aplikovanie v rámci služby.




Obrázok 4–10 Predikcia autoregresného modelu (posun o 60 minút) pre obdobie 25. októbra – 31. októbra 2019.




Obrázok 4–11 Predikcia autoregresného modelu (posun o 60 minút) pre obdobie 19. novembra – 25. novembra 2019.



Obrázok 4–12 Predikcia autoregresného modelu (shift-15-windows-45) pre obdobie 22. október – 28. október 2019.



Obrázok 4–13 Predikcia multivariačného modelu s prvkom Kp index (shift-15-windows-45) pre obdobie 22. október – 28. október 2019.



Obrázok 4–14 Predikcia multivariačného modelu s prvkom Kp index (shift-15-windows-45) pre obdobie 22. október – 28. október 2019.

Tabuľka 4–9 Vyhodnotenie 15-minútových predikcií pomocou základného modelu perzistencie na súbore údajov IMPC.

Model data)	(IMPC	P	R	F1	AUC- ROC	AUC- PR	TSS
Persistence		0,01	0,56	0,02	0,73	0,28	0,53

Tabuľka 4 – 10 Výsledky vyhodnotenia autoregresného a multivariačného modelu s Kp indexom (s časovým posunom 15 a veľkosťou okna 45) na testovacej podmnožine pre množinu dát IMPC.

Model (IMPC	Eval	P	R	F1	AUC- ROC	AUC- PR	TSS
Autoregresný model	1	0,09	0,81	0,17	0,91	0,45	0,74
	2	0,11	0,83	0,19	0,89	0,47	0,75
	3	0,10	0,84	0,18	0,91	0,47	0,76
Multivariačný model s Kp indexom	1	0,09	0,82	0,16	0,90	0,46	0,76
	2	0,11	0,87	0,20	0,89	0,48	0,78
	3	0,10	0,86	0,18	0,90	0,48	0,79

5 Záver

V tejto diplomovej práci bol predstavený model založený na strojovom učení na predikciu ionosférických scintilácií s hodinovým predstihom. Navrhovaný model využíva hlboké neurónové siete a širokú škálu zdrojov údajov vrátane historických údajov o ionosférickej scintilácii a parametrov vesmírneho počasia s cieľom poskytnúť presné predpovede úrovne scintilácie. Model bol vyvinutý a testovaný pomocou knižníc TensorFlow a Keras v jazyku Python.

Výsledky tejto diplomovej práce majú dôležité dôsledky pre satelitné komunikačné a navigačné systémy. Ionosférické scintilácie môžu významne ovplyvniť prenos signálov z vesmírnych satelitov a presné predpovede úrovne scintilácie sú nevyhnutné na optimalizáciu prevádzky satelitov v postihnutých oblastiach. Časopriestorové predpovede, ktoré poskytuje model, môžu využívať prevádzkovatelia satelitov a iné zainteresované strany na plánovanie a optimalizáciu svojej prevádzky, čo povedie k zlepšeniu výkonnosti a zníženiu nákladov.

Práca prezentovaná v tejto diplomovej práci bola vykonaná v spolupráci s Ústavom experimentálnej fyziky Slovenskej akadémie vied, v. v. i. a spoločnosťou Global-Logic Slovakia s.r.o. ako súčasť projektu ASPIS prebiehajúceho v rámci Programu Európskej vesmírnej agentúry pre spolupracujúce štáty (*ESA Plan for European Cooperating States* (PECS)). Cieľom projektu ASPIS je vyvinúť autonómny systém schopný poskytovať presné predpovede ionosférickej scintilácie a výsledky prezentované v tejto práci predstavujú významný krok k dosiahnutiu tohto cieľa.

Výsledky tejto diplomovej práce vo všeobecnosti dokazujú potenciál modelov založených na strojovom učení na predpovedanie ionosférickej scintilácie a zlepšenie výkonnosti satelitných komunikačných a navigačných systémov. Taktiež sa z výsledkov tejto práce pripravuje vedecký článok, ktorý by mal byť uverejnený v zahraničnom karentovanom časopise.

Priamym pokračovaním tejto práce je vývoj softvérového riešenia na nasadenie vyvinutého modelu skrze mikroslužbu, ktorá bude vytvorená pomocou frameworku

Flask v rámci cloudových služieb AWS. Mikroslužba umožní komunikáciu medzi vyvinutým modelom a ostatnými komponentmi v rámci projektu ASPIS prostredníctvom rozhrania REST API. Softvérové riešenie umožní jednoduché a efektívne nasadenie vyvinutého modelu na predpovedanie ionosférickej scintilácie v reálnom čase. Nasadenie modelu v rámci mikroslužby by malo umožniť bezproblémovú integráciu v rámci ďalších služieb pre monitorovanie a predikciu kozmického počasia a malo by zabezpečiť bezproblémovú prevádzku v produkčnom prostredí. Softvérové riešenie navyše umožní jednoduchú aktualizáciu vyvinutého modelu o nové zdroje údajov alebo vylepšenia algoritmu, čím sa zabezpečí, že bude naďalej poskytovať presné predpovede ionosférickej scintilácie.

Literatúra

- Allouche, O., Tsoar, A. and Kadmon, R. (2006). Assessing the accuracy of species distribution models: prevalence, kappa and the true skill statistic (tss), *Journal of applied ecology* **43**(6): 1223–1232.
- Baldi, P. and Sadowski, P. J. (2013). Understanding dropout, *Advances in neural information processing systems* **26**.
- Borovsky, J. E. and Shprits, Y. Y. (2017). Is the dst index sufficient to define all geospace storms?, *Journal of Geophysical Research: Space Physics* **122**(11): 11–543.
- Chu, C.-S. J. (1995). Time series segmentation: A sliding window approach, *Information Sciences* **85**(1-3): 147–173.
- Crane, R. K. (1977). Ionospheric scintillation, *Proceedings of the IEEE* **65**(2): 180–199.
- De Lima, G., Stephany, S., De Paula, E., Batista, I. and Abdu, M. (2015). Prediction of the level of ionospheric scintillation at equatorial latitudes in brazil using a neural network, *Space Weather* **13**(8): 446–457.
- Dileep, P., Das, D. and Bora, P. K. (2020). Dense layer dropout based cnn architecture for automatic modulation classification, *2020 national conference on communications (NCC)*, IEEE, pp. 1–5.
- Edberg, N. J., Lester, M., Cowley, S., Brain, D., Fränz, M. and Barabash, S. (2010). Magnetosonic mach number effect of the position of the bow shock at mars in comparison to venus, *Journal of Geophysical Research: Space Physics* **115**(A7).
- Fisher, R. A. (1992). *Statistical methods for research workers*, Springer.
- Gary, G. A. (2001). Plasma beta above a solar active region: rethinking the paradigm, *Solar Physics* **203**(1): 71–86.

-
- Grossberg, S. (2013). Recurrent neural networks, *Scholarpedia* **8**(2): 1888.
- Gu, Q., Li, Z. and Han, J. (2012). Generalized fisher score for feature selection, *arXiv preprint arXiv:1202.3725*.
- Hlubek, N., Berdermann, J., Wilken, V., Gewies, S., Jakowski, N., Wassaie, M. and Damtie, B. (2014). Scintillations of the GPS, GLONASS, and Galileo signals at equatorial latitude, *Journal of Space Weather and Space Climate* **4**: A22.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory, *Neural computation* **9**(8): 1735–1780.
- Hoo, Z. H., Candlish, J. and Teare, D. (2017). What is an roc curve?
- ISGI/ASY/SYM INDICES* (n.d.). http://isgi.unistra.fr/indices_asy.php. Accessed: 2022-07-05.
- Iversen, G. R., Norpoth, H. and Norpoth, H. P. (1987). *Analysis of variance*, number 1, Sage.
- King, J. H. and Papitashvili, N. E. (2005). Solar wind spatial scales in and comparisons of hourly wind and ace plasma and magnetic field data, *Journal of Geophysical Research: Space Physics* **110**(A2).
- Larson, M. G. (2008). Analysis of variance, *Circulation* **117**(1): 115–121.
- Little, C. and Maxwell, A. (1952). Scintillation of radio stars during aurorae and magnetic storms, *Journal of Atmospheric and Terrestrial Physics* **2**(6): 356–360. <https://www.sciencedirect.com/science/article/pii/0021916952900767>.
- Mathioudakis, M., Jess, D. B. and Erdelyi, R. (2013). Alfvén waves in the solar atmosphere, *Space Science Reviews* **175**(1): 1–27.
- McGranaghan, R. M., Mannucci, A. J., Wilson, B., Mattmann, C. A. and Chadwick, R. (2018). New capabilities for prediction of high-latitude ionospheric scintillation:
-

- A novel approach with machine learning, *Space Weather* **16**(11): 1817–1846.
URL: <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2018SW002018>
- Narkhede, S. (2018). Understanding auc-roc curve, *Towards Data Science* **26**(1): 220–227.
- NASA/OMNIWeb (n.d.). <https://omniweb.gsfc.nasa.gov/form/dx1.html>. Accessed: 2022-05-13.
- NASA/OMNIWeb Data Documentation (n.d.). https://omniweb.gsfc.nasa.gov/html/ow_data.html. Accessed: 2022-06-29.
- NASA/The Solar Wind (n.d.). <https://solarscience.msfc.nasa.gov/SolarWind.shtml>. Accessed: 2022-06-29.
- NOAA, *F10.7 index* (n.d.). <https://www.swpc.noaa.gov/phenomena/f107-cm-radio-emissions>. Accessed: 2022-05-13.
- NOAA, *Geomagnetic kp and ap Indices* (n.d.). https://www.ngdc.noaa.gov/stp/GEOMAG/kp_ap.html. Accessed: 2022-06-29.
- NOAA, *PLANETARY K-INDEX* (n.d.). <https://www.swpc.noaa.gov/products/planetary-k-index>. Accessed: 2022-06-29.
- NOAA, *Sunsplot Numbers* (n.d.). <https://www.ngdc.noaa.gov/stp/solar/ssndata.html>. Accessed: 2022-06-29.
- NOAA, *The Disturbance Storm Time Index* (n.d.). <https://www.ngdc.noaa.gov/stp/geomag/dst.html>. Accessed: 2022-06-29.
- NWRA/*Geomagnetic Disturbance Index* (n.d.). <https://spawx.nwra.com/spawx/ap.html>. Accessed: 2022-06-29.
- Osherovich, V. A., Fainberg, J. and Stone, R. G. (1999). Solar wind quasi-invariant as a new index of solar activity, *Geophysical Research Letters* **26**(16): 2597–2600.
URL: <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/1999GL900583>

-
- PCN index* (n.d.). https://www.space.dtu.dk/english/research/scientific_data_and_models/world_data_center_for_geomagnetism/pcn-index. Accessed: 2022-07-05.
- Pfaff, R. F. (2012). The Near-Earth Plasma Environment, *Space Sci. Rev.* **168**: 23–112.
- Ramachandran, P., Zoph, B. and Le, Q. V. (2017). Searching for activation functions, *arXiv preprint arXiv:1710.05941* .
- Rezende, L., De Paula, E., Stephany, S., Kantor, I., Muella, M., de Siqueira, P. and Correa, K. (2010). Survey and prediction of the ionospheric scintillation using data mining techniques, *Space Weather* **8**(6).
- Ruopp, M. D., Perkins, N. J., Whitcomb, B. W. and Schisterman, E. F. (2008). Youden index and optimal cut-point estimated from observations affected by a lower limit of detection, *Biometrical Journal: Journal of Mathematical Methods in Biosciences* **50**(3): 419–430.
- Scheffe, H. (1999). *The analysis of variance*, Vol. 72, John Wiley & Sons.
- Space Weather Canada - Solar Flux data* (n.d.). <https://www.spaceweather.gc.ca/forecast-prevision/solar-solaire/solarflux/sx-3-en.php>. Accessed: 2022-05-13.
- Spogli, L., Alfonsi, L., De Franceschi, G., Romano, V., Aquino, M. H. O. and Dodson, A. (2009). Climatology of gps ionospheric scintillations over high and mid-latitude european regions, *Annales Geophysicae* **27**(9): 3429–3437.
URL: <https://angeo.copernicus.org/articles/27/3429/2009/>
- SWC, NICT, J. ((accessed June 22, 2022)). User guide - space weather forecast, effects on infrastructure, <https://swc.nict.go.jp/en/knowledge/guide.html>.

The Interplanetary Magnetic Field (IMF), Space weather live (n.d.). <https://www.spaceweatherlive.com/en/help/the-interplanetary-magnetic-field-imf.html>. Accessed: 2022-07-05.

The location of the Earth's bow shock (n.d.). https://www.researchgate.net/publication/223340434_The_location_of_the_Earth%27s_bow_shock. Accessed: 2022-07-05.

Vilà-Valls, J., Linty, N., Closas, P., Dovic, F. and Curran, J. T. (2020). Survey on signal processing for gnss under ionospheric scintillation: Detection, monitoring, and mitigation, *NAVIGATION, Journal of the Institute of Navigation* **67**(3): 511–536.

Wang, Z. and Bovik, A. C. (2009). Mean squared error: Love it or leave it? a new look at signal fidelity measures, *IEEE signal processing magazine* **26**(1): 98–117.

What is Interplanetary Magnetic Field (IMF)? (n.d.). <https://www.spaceweather.ac.cn/chinese/knowledge/knowledge1.htm>. Accessed: 2022-07-05.

World Data Center for Solar-Terrestrial Physics/AE AU AL AO (n.d.). http://www.wdcb.ru/stp/geomag/geomagn_AE_AU_AL_A%D0%9E_ind.html. Accessed: 2022-06-29.

Zhang, H.-b., Liu, Y.-m. and Xu, L. (2018). A framework of integrated service system of ionospheric scintillation information, *2018 12th International Symposium on Antennas, Propagation and EM Theory (ISAPE)*, IEEE, pp. 1–3.

Zhang, Z. (2018). Improved adam optimizer for deep neural networks, *2018 IEEE/ACM 26th international symposium on quality of service (IWQoS)*, Ieee, pp. 1–2.

Zoznam príloh

Príloha A Systémová príručka

Príloha B Používateľská príručka

Príloha C CD médium obsahujúce zdrojové kódy, diplomovú prácu a prílohy v elektronickej podobe