Technická univerzita v Košiciach

Fakulta elektrotechniky a informatiky

Metódy strojového učenia pre včasnú predikciu geomagnetických búrok

Diplomová práca

2026 **Bc. Terézia Drengubiaková**

Technická univerzita v Košiciach

Fakulta elektrotechniky a informatiky

Metódy strojového učenia pre včasnú predikciu geomagnetických búrok

Diplomová práca

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

Košice 2026 **Bc. Terézia Drengubiaková**

Abstrakt v SJ

Diplomová práca sa zaoberá využitím metód strojového učenia pre včasnú predikciu geomagnetických búrok prostredníctvom predikcie indexu Dst. Teoretická časť práce približuje problematiku kozmického počasia, geomagnetických búrok, predikcie časových radov, rekurentných neurónových sietí typu LSTM, regresie pomocou Gaussových procesov a problematiku perzistentnosti v prediktívnych modeloch. Praktická časť je zameraná na získanie a prípravu dát, návrh a implementáciu modelov, realizáciu experimentov a vyhodnotenie výsledkov pre rôzne predikčné horizonty, vstupné atribúty a typy dát. V práci sú porovnávané modely LSTM a hybridný model LSTM + Gaussian Process, pričom sa skúma ich predikčná presnosť, schopnosť prekonať perzistentný model a možnosť kvantifikovať neistotu predikcie pomocou intervalov spoľahlivosti. Výsledky ukázali, že hybridný prístup predstavuje perspektívne riešenie pre predikciu geomagnetickej aktivity, najmä pri kratších predikčných horizontoch, a zároveň poskytuje doplnkovú informáciu o spoľahlivosti predikcie. Práca poukazuje na význam vhodného výberu vstupných atribútov a potvrdzuje, že navrhnuté modely dokážu dosiahnuť lepšie výsledky než jednoduchý perzistentný prístup.

Kľúčové slová

geomagnetické búrky, kozmické počasie, index Dst, strojové učenie, LSTM, Gaussian Process Regression, predikcia časových radov, perzistentnosť modelu, intervaly spoľahlivosti

Abstrakt v AJ

This diploma thesis focuses on the application of machine learning methods for the early prediction of geomagnetic storms through forecasting the Dst index. The theoretical part of the thesis introduces the concepts of space weather, geomagnetic storms, time series forecasting, recurrent neural networks of the LSTM type,

Gaussian Process Regression, and the issue of persistence in predictive models. The practical part is devoted to data acquisition and preprocessing, model design and implementation, experimental evaluation, and comparison of results for different forecasting horizons, input attributes, and data types. The thesis compares LSTM models with a hybrid LSTM + Gaussian Process model, while examining their predictive accuracy, their ability to outperform a persistence model, and their capability to quantify predictive uncertainty using confidence intervals. The results indicate that the hybrid approach represents a promising solution for geomagnetic activity forecasting, especially for shorter prediction horizons, while also providing additional information about prediction reliability. The thesis highlights the importance of appropriate input attribute selection and confirms that the proposed models are able to achieve better results than a simple persistence-based approach.

Kľúčové slová v AJ

geomagnetic storms, space weather, Dst index, machine learning, LSTM, Gaussian Process Regression, time series forecasting, model persistence, confidence intervals

78556

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:

Metódy strojového učenia pre včasnú predikciu geomagnetických búrok

Machine learning methods for early prediction of geomagnetic storms

Študent: **Bc. Terézia Drengubiaková**

Školiteľ: **doc. Ing. Peter Butka, PhD.**

Školiace pracovisko: **Katedra kybernetiky a umelej inteligencie**

Konzultant práce: **Ing. Viera Krešňáková, PhD., RNDr. Šimon Mackovjak, PhD.**

Pracovisko konzultanta: **Ústav experimentálnej fyziky SAV**

Pokyny na vypracovanie diplomovej práce:

1. Podať teoretický prehľad problematiky metód strojového učenia, s dôrazom na vhodné metódy pre včasnú predikciu geomagnetických búrok.
2. Získať a predspracovať vhodné dáta pre riešenie zvoleného problému.
3. Navrhnúť, realizovať a vyhodnotiť experimenty s včasnou predikciou geomagnetických búrok.
4. Vypracovať dokumentáciu podľa pokynov katedry a vedúceho práce.

Jazyk, v ktorom sa práca vypracuje: slovenský

Termín pre odovzdanie práce: 24.04.2026

Dátum zadania diplomovej práce: 31.10.2025

TECHNICKÁ UNIVERZITA V KOŠICIACH FAKULTA ELEKTROTECHNIKY A INFORMATIKY -12- 2025

.....

prof. Ing. Liberios Vokorokos, PhD.

dekan fakulty

Čestné vyhlásenie

Vyhlasujem, že som záverečnú prácu vypracoval(a) samostatne s použitím uvedenej odbornej literatúry, ako aj s využitím nástrojov generatívnej umelej inteligencie v súlade s Metodickým pokynom o záverečných a kvalifikačných prácach a Etickým kódexom študenta Technickej univerzity v Košiciach. Umelá inteligencia bola použitá ako podporný nástroj bez porušenia zásad akademickej etiky a autorskej integrity.

Košice 24. 4. 2026 .....

Vlastnoručný podpis

Poďakovanie

Chcela by som poďakovať vedúcemu diplomovej práce doc. Ing Petrovi Butkovi, PhD. a mojim konzultantom, pani Ing. Viere Krešňákovej, PhD. a RNDr. Šimonovi Mackovjakovi, PhD. za ich ústretovosť, vedenie a čas, ktorý mi venovali pri písaní tejto práce. Taktiež by som sa rada poďakovala svojej rodine a priateľom za ich podporu počas celého štúdia.

Obsah

Zoznam obrázkov **10**

Zoznam tabuliek **11**

Zoznam symbolov a skratiek

Úvod **1**

1 Kozmické počasie a geomagnetické búrky **3**

1.1 Kozmické počasie 3

1.2 Geomagnetické búrky 4

1.3 Dopady geomagnetických búrok 6

1.4 Význam predikcie geomagnetických búrok 7

2 Prediktívne modely a strojové učenie v spracovaní časových radov **9**

2.1 Umelá inteligencia a strojové učenie 10

2.2 Neurónové siete pre časové rady 13

2.3 Rekurentné neurónové siete 15

2.4 Long Short-Term Memory 18

3 Perzistentnosť v prediktívnych modeloch časových radov **21**

3.1 Definícia perzistentnosti 21

3.2 Prejavy perzistentnosti v neurónových sieťach 21

3.3 Prístupy k potláčaniu perzistentnosti 22

4 Gaussian Process Regression v predikcii kozmického počasia **24**

4.1 Základy Gaussian Process Regression 24

4.2 Kernel funkcie a využitie Gaussian Process Regression 26

5 Analýza súčasného stavu **28**

5.1 Predikcia indexu Dst pomocou hybridného modelu LSTM–Gaussian Processes . . . 28
5.2 Predikcia indexu Dst pomocou GRU s multimodálnymi vstupnými dátami . . . 30
5.3 Predikcia geomagnetických búrok pomocou fyzikálneho modelovania CME . . . 34
5.4 Porovnanie prístupov a identifikácia obmedzení súčasných model . . . 36

6 Praktická časť **38**
6.1 Získanie a príprava dát . . . 38
6.2 Použité metriky . . . 41
6.3 Modelovanie . . . 45
6.3.1 BiLSTM . . . 46
6.3.2 BiLSTM a Gaussian Process . . . 48
6.3.3 BiLSTM a Gaussian Process na dátach udalostí . . . 52
6.4 Experimenty . . . 56
6.5 Vyhodnotenie . . . 59

7 Záver **68**

Zoznam príloh **73**

Zoznam obrázkov

1 – 1 Interakcia medzi slnečným vetrom a magnetickým poľom Zeme . . 4

1 – 2 Priebeh geomagnetickej búrky 5

2 – 1 Prehľad hlavných oblastí umelej inteligencie a ich vzájomných vzťahov 11

2 – 2 Rozdelenie modelov strojového učenia na klasické a moderné prístupy 12

2 – 3 Rekurentná neurónová sieť 16

2 – 4 LSTM model 18

3 – 1 Ilustrácia perzistentného modelu pri predikcii časového radu 22

4 – 1 Ilustrácia regresie pomocou Gaussovského procesu s intervalom spoľahlivosti 25

6 – 1 Architektúra modelu BiLSTM 48

6 – 2 Porovnanie kontinuálneho a eventového prístupu počas vybranej geomagnetickej búrky pre horizont DST+1. 65

6 – 3 Porovnanie kontinuálneho a eventového prístupu počas vybranej geomagnetickej búrky pre horizont DST+6. 66

Zoznam tabuliek

6 – 1 Zlepšenie najlepších kontinuálnych konfigurácií oproti perzistentnému modelu 60
6 – 2 Priemerné výsledky na kontinuálnych dátach podľa vstupných atribútov a typu modelu 62
6 – 3 Priemerné výsledky na eventových dátach podľa setu 63
6 – 4 Najlepšie výsledky na eventových dátach podľa predikčného horizontu 63

Zoznam symbolov a skratiek

ACE z ang. *Advanced Composition Explorer*

AI z ang. *Artificial Intelligence*, umelá inteligencia

AIA z ang. *Atmospheric Imaging Assembly*

ARD z ang. *Automatic Relevance Determination*

Bz_GSM zložka medziplanetárneho magnetického poľa v smere osi z v súradnicovom systéme GSM

CEC z ang. *Constant Error Carousel*

CELIAS z ang. *Charge, Element, and Isotope Analysis System*

CME z ang. *Coronal Mass Ejections*, výron koronálnej hmoty

DL z ang. *Deep Learning*, hlboké učenie

DONKI z ang. *Database Of Notifications, Knowledge, Information*

DSCOVR z ang. *Deep Space Climate Observatory*, satelit na monitorovanie slnečného vetra a kozmického počasia

Dst z ang. *Disturbance Storm Time index*

DTW z ang. *Dynamic Time Warping*

EIT z ang. *Extreme ultraviolet Imaging Telescope*

ELEvo z ang. *Ellipse Evolution model*

EUV z ang. *Extreme Ultraviolet*, extrémne ultrafialové žiarenie

FITC z ang. *Fully Independent Training Conditional*

GIC z ang. *Geomagnetically Induced Currents*, geomagneticky indukované prúdy

GP z ang. *Gaussian Process*

GPNN z ang. *Gaussian Process Neural Network*

GPR z ang. *Gaussian Process Regression*, regresia pomocou Gaussových procesov

GPS z ang. *Global Positioning System*

GRU z ang. *Gated Recurrent Unit*

GRU-Attn-IEC z ang. *Gated Recurrent Unit with Attention-based Input Encoding and Correction*

GRU-IE z ang. *Gated Recurrent Unit with Input Encoding*

GSM z ang. *Geocentric Solar Magnetospheric*

IMF z ang. *Interplanetary Magnetic Field*, medziplanetárne magnetické pole

ISOMAP z ang. *Isometric Mapping*

keV kiloelektrónvolt, jednotka energie

kNN z ang. *k-Nearest Neighbors*

L1 Lagrangeov bod 1

LASCO C2 z ang. *Large Angle and Spectrometric Coronagraph C2*

LLE z ang. *Locally Linear Embedding*

LOO-CV z ang. *Leave-One-Out Cross-Validation*

LSTM z ang. *Long Short-Term Memory*

MAE z ang. *Mean Absolute Error*

MCC z ang. *Matthews Correlation Coefficient*

ML z ang. *Machine Learning*, strojové učenie

MSE z ang. *Mean Squared Error*

NASA z ang. *National Aeronautics and Space Administration*

NOAA z ang. *National Oceanic and Atmospheric Administration*

OMNI súbor kozmicko-fyzikálnych dát z rôznych satelitných a pozemných meraní

nT nanotesla

PCA z ang. *Principal Component Analysis*

PITC z ang. *Partially Independent Training Conditional*

PMU z ang. *Phasor Measurement Unit*

RMSE z ang. *Root Mean Squared Error*

RNN z ang. *Recurrent Neural Network*

ROC z ang. *Receiver Operating Characteristic*

RTN z ang. *Radial-Tangential-Normal*, súradnicový systém používaný v heliosférickej fyzike

SDO z ang. *Solar Dynamics Observatory*

SOHO z ang. *Solar and Heliospheric Observatory*

SYM-H z ang. *Symmetric-H*, index symetrickej horizontálnej zložky geomagnetického poľa

t-SNE z ang. *t-distributed Stochastic Neighbor Embedding*

UI umelá inteligencia

Úvod

Geomagnetické búrky patria medzi významné prejavy kozmického počasia, ktoré môžu negatívne ovplyvniť technologické systémy na Zemi aj vo vesmíre. Ich dôsledky sa prejavujú napríklad v narušení prevádzky satelitov, navigačných a komunikačných systémov, energetických sietí či ďalších prvkov kritickej infraštruktúry. S rastúcou závislosťou spoločnosti od digitálnych a vesmírnych technológií nadobúda včasná a spoľahlivá predikcia geomagnetických búrok čoraz väčší význam.

V súčasnosti sa pri modelovaní a predikcii javov kozmického počasia čoraz viac uplatňujú metódy strojového učenia, najmä modely určené na spracovanie časových radov. Tieto prístupy umožňujú efektívne analyzovať veľké objemy historických a satelitných dát, zachytávať nelineárne vzťahy medzi premennými a vytvárať presnejšie krátkodobé aj strednodobé predikcie. Medzi perspektívne prístupy patria najmä rekurentné neurónové siete typu Long Short-Term Memory (LSTM), ktoré sú vhodné na modelovanie časových závislostí, ako aj hybridné modely rozšírené o probabilistické metódy, napríklad Gaussian Process (GPR), umožňujúce odhad neistoty predikcie.

Táto diplomová práca nadväzuje na predchádzajúci výskum v oblasti predikcie indexu Dst, ktorý je jedným z najvýznamnejších ukazovateľov intenzity geomagnetickej búrky. Na základe výsledkov predchádzajúcej práce bola identifikovaná potreba hlbšie preskúmať viacero otvorených problémov, najmä vplyv typu vstupných dát, význam jednotlivých atribútov, otázku perzistentnosti modelov a možnosti doplnenia bodovej predikcie o intervaly spoľahlivosti.

Hlavným cieľom práce je analyzovať možnosti využitia metód strojového učenia pre včasnú predikciu geomagnetických búrok a experimentálne overiť, ako výber modelu, dĺžka vstupného časového okna, kombinácia vstupných atribútov a typ dát ovplyvňujú presnosť predikcie indexu Dst (Disturbance Storm Time). Osobitná pozornosť je venovaná porovnaniu samostatného modelu LSTM s hybridným modelom LSTM + Gaussian Process, a to nielen z pohľadu bodovej presnosti, ale aj z pohľadu

schopnosti kvantifikovať neistotu predikcie prostredníctvom predikčných intervalov.

Práca je rozdelená na teoretickú a praktickú časť. V teoretickej časti sa venuje problematike kozmického počasia, geomagnetických búrok, strojového učenia v spracovaní časových radov, perzistentnosti prediktívnych modelov a regresii pomocou Gaussových procesov. Praktická časť je zameraná na získanie a prípravu dát, návrh modelov, realizáciu experimentov a vyhodnotenie dosiahnutých výsledkov pri predikcii indexu Dst v rôznych časových horizontoch.

1 Kozmické počasie a geomagnetické búrky

Kozmická fyzika sa zaoberá štúdiom interakcií medzi Slnkom a Zemou. Poznatky získané v tejto oblasti viedli k vzniku novej aplikovanej vedeckej disciplíne známej ako kozmické počasie. V posledných desaťročiach došlo k výraznému technologickému pokroku, pričom moderná spoločnosť je čoraz viac závislá od technológií, ako sú napríklad satelity a rôzne komunikačné či navigačné systémy. Keďže tieto technológie môžu byť ovplyvňované procesmi prebiehajúcimi v kozmickom priestore, je dôležité tieto procesy skúmať s cieľom lepšie porozumieť ich vplyvom a zabezpečiť spoľahlivé fungovanie technologických systémov Echer et al. (2005).

1.1 Kozmické počasie

Kozmické počasie je definované ako fyzikálny a fenomenologický stav prírodného vesmírneho prostredia. Prostredníctvom pozorovania, monitorovania, tvorbou analýz a modelovania sa snažíme pochopiť a predpovedať stav Slnka, medziplanetárneho a planetárneho prostredia a poruchy, ktoré z daných javov vznikajú. Kľúčové aspekty kozmického počasia zahŕňajú:

- **Pôvod a spúšťače** - Podmienky prostredia Zeme sú určované predovšetkým premenlivou solárnou aktivitou. Medzi konkrétne procesy môžeme zaradiť zmeny v medziplanetárnom magnetickom poli, výrony koronálnej hmoty (CME) zo Slnka a následné poruchy v magnetickom poli Zeme.

- **Časový rámec** - Kozmické počasie popisuje fyzikálny stav vesmíru v krátkodobom až strednodobom meradle (minúty - dni). Tým sa odlišuje od "kozmickej klímy", ktorá sa zaoberá strednodobým až dlhodobým časovým horizontom (mesiace - roky).

- **Dopady** - Kozmické počasie môže mať významný vplyv na biologické a technologické systémy. To zahŕňa poškodenie satelitov, narušenie prevádzky elektrických rozvodných sietí na Zemi a rušenie komunikačných, lokalizačných a navi-

gačných služieb. Ionizujúce žiarenie môže mať vplyv na zdravie astronautov, ak sú prekročené určité prahové hodnoty Lilensten et al. (2008).

1.2 Geomagnetické búrky

Geomagnetická búrka je časový interval, počas ktorého dochádza k interakcii medzi medziplanetárnym magnetickým poľom, plazmou slnečného vetra a magnetosférou Zeme čím dochádza k nárastu energie v systéme magnetosféra-ionosféra. Tento nárast energie sa prejavuje zosilnením prstencového prúdu v magnetosfére natoľko, že prekročí stanovenú prahovú hodnotu indexu Dst, ktorý slúži na meranie intenzity geomagnetickej búrky. Primárnym spúšťačom je magnetická rekonexia, cez ktorú sa energia zo slnečného vetra efektívne prenáša do zemskej magnetosféry, ako ako je znázornené na Obrázku 1 – 1.

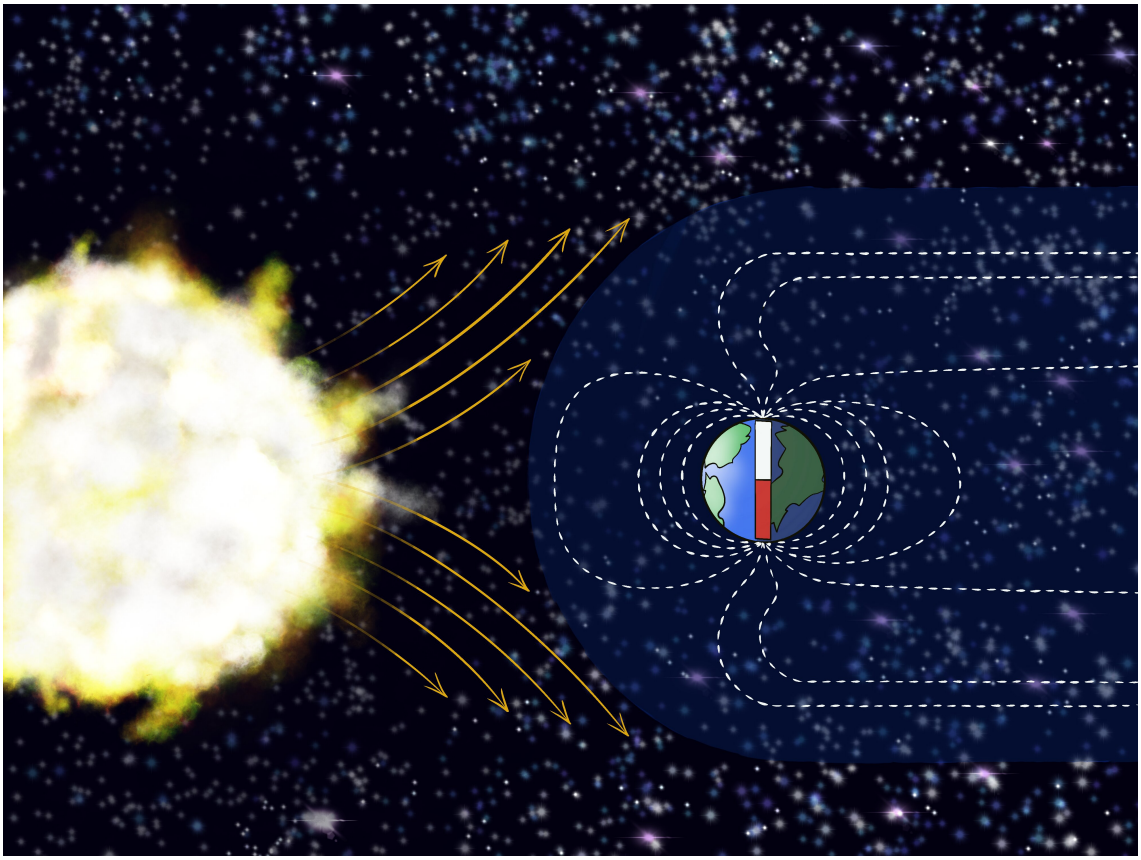

Obrázok 1 – 1 Interakcia medzi slnečným vetrom a magnetickým poľom Zeme

Prstencový prúd je tvorený najmä iónmi (predovšetkým protónmi a iónmi kyslíka) a elektrónmi s energiami približne v rozsahu 10 až 300 keV. Tento prúd sa nachádza vo vzdialenosti približne 2 až 7 zemských polomerov od stredu Zeme a vytvára magnetické pole, ktoré pôsobí proti dipólovému magnetickému poľu Zeme.

Geomagnetická búrka prebieha v niekoľkých charakteristických fázach. Počiatočná fáza často začína náhlym impulzom, ktorý signalizuje príchod medziplanetárnej rázovej vlny a zvýšenie dynamického tlaku slnečného vetra pôsobiaceho na magnetosféru. Nasleduje hlavná fáza, počas ktorej dochádza k výraznému poklesu horizontálnej zložky zemského magnetického poľa. Tento pokles je meraný indexom Dst a súvisí so zvýšením populácie energetických častíc zachytených v prstencovom prúde magnetosféry. Po dosiahnutí minimálnej hodnoty indexu Dst nastáva fáza zotavenia, počas ktorej sa magnetické pole postupne vracia k normálnemu stavu v dôsledku postupného rozpadu prstencového prúdu.

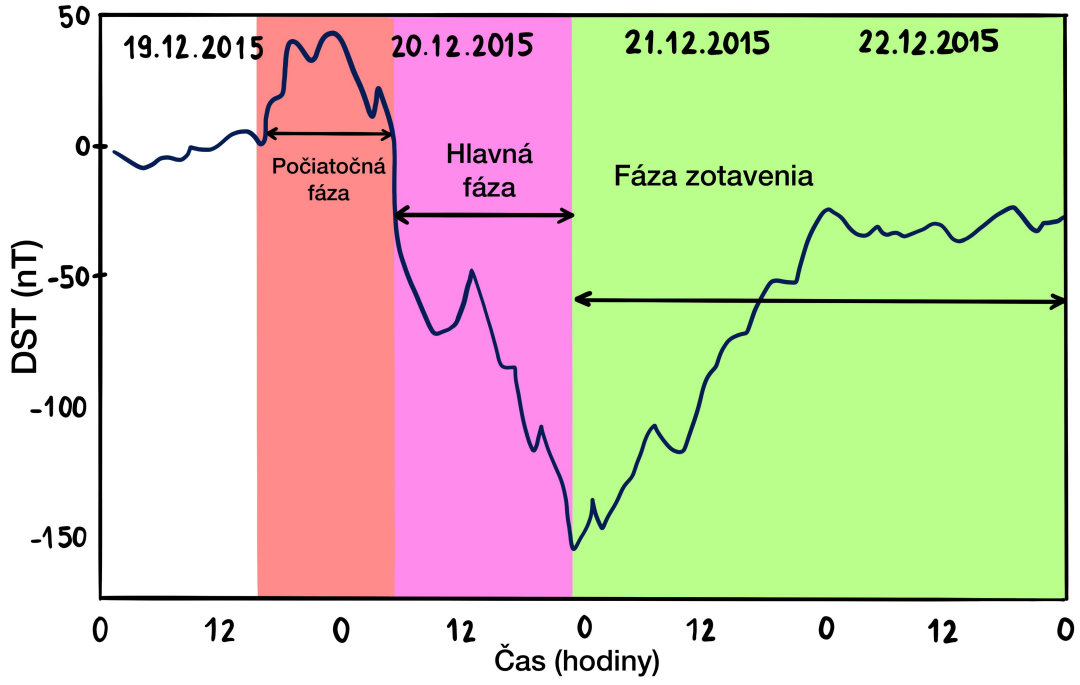

Obrázok 1 – 2 Priebeh geomagnetickej búrky

Geomagnetické búrky možno klasifikovať podľa ich intenzity určenej hodnotou

indexu Dst. Slabé búrky dosahujú minimálne hodnoty Dst v intervale približne od -30 do -50 nT, stredne silné búrky od -50 do -100 nT a intenzívne alebo veľké búrky majú hodnoty Dst menšie ako -100 nT Gonzalez et al. (1994).

1.3 Dopady geomagnetických búrok

Dopady geomagnetických búrok sú rozsiahle a ovplyvňujú predovšetkým technologickú infraštruktúru na Zemi aj vo vesmíre, čo môže mať vážne sociálno-ekonomické dôsledky. Hlavným mechanizmom týchto vplyvov je vznik geomagneticky indukovaných prúdov v dlhých vodivých systémoch. Nakoľko tieto prúdy pretekajú transformátormi a spôsobujú polcyklovú saturáciu, môžu viesť k prehrievaniu transformátorov a ich možnému poškodeniu v dôsledku rozptylového striedavého magnetického toku zo saturovaného jadra. Ďalším dôsledkom je odchýlka od takmer sínusového priebehu elektrického prúdu a napätia v systéme, čo vedie k vzniku harmonických zložiek. Zároveň dochádza k výraznému zvýšeniu magnetizačného prúdu transformátora, čo narúša rovnováhu medzi činným výkonom dostupným pre napájanie záťaže a jalovým výkonom, ktorý kolíše v rámci prenosovej sústavy. Keďže jalový výkon úzko súvisí s napätím v systéme, jeho výrazné zmeny môžu viesť k nestabilite napätia a v extrémnych prípadoch až k napäťovému kolapsu. Harmonické zložky v systéme môžu zároveň spôsobiť vypínanie ochranných relé a následné odpojenie vedení z prevádzky. Geomagneticky indukované prúdy však neovplyvňujú iba elektrické siete, ale môžu ovplyvniť ropovody, plynovody, železničné systémy alebo iné pozemné vodivé systémy dlhšie ako 1 kilometer. Vplyv geomagnetických búrok sa prejavuje aj v oblasti moderných technológií a tzv. inteligentných elektrických sietí. Geomagnetické poruchy môžu narušiť časovú synchronizáciu získavanú zo systému GPS, ktorú využívajú meracie jednotky PMU (Phasor Measurement Units) na monitorovanie a riadenie moderných elektrických sietí v reálnom čase. Problémy sa môžu vyskytnúť aj pri niektorých obnoviteľných zdrojoch energie. Napríklad veterné elektrárne na mori a ich prenosové linky môžu byť vystavené tzv. pobrežnému efektu,

ktorý zosilňuje lokálne elektromagnetické polia.

Rozsiahly a dlhotrvajúci výpadok elektrickej energie by zároveň mohol mať výrazné sociálno-ekonomické dôsledky. Takýto výpadok by mal kaskádový efekt na ďalšie sektory kritickej infraštruktúry, ako sú komunikačné systémy, zásobovanie vodou, zdravotníctvo alebo finančné služby. V extrémnych scenároch sa uvádzajú aj riziká sociálnych nepokojov a veľkých makroekonomických strát Pulkkinen et al. (2017).

1.4 Význam predikcie geomagnetických búrok

Predpovedanie geomagnetických búrok je v súčasnosti považované za jednu z kľúčových oblastí výskumu vzťahov medzi Slnkom a Zemou, predovšetkým kvôli ich vplyvu na modernú spoločnosť, ktorá sa stáva čoraz viac závislá technológií. Preto je dôležité vedieť dostatočne včasne a presne predpovedať či a aká silná búrka nastane. Medzi už spomínané dopady geomagnetických búrok patria poškodenia energetickej infraštruktúry. Do tejto kategórie popri saturácií transformátorov je dôležité zaradiť aj riziko výpadkov, ku ktorým môže počas búrok dôjsť. Autori uvádzajú, že správna predpoveď umožňuje prevádzkovateľom sietí vykonať preventívne opatrenia, medzi ktoré patrí aj cielené odpojenie vysokonapäťových prenosových vedení, aby sa predišlo kaskádovým výpadkom energie. Zaujímavé je, že výskumy poukazujú na fakt, že búrky strednej intenzity môžu byť štatisticky spojené s vyššími maximálnymi hodnotami telurických prúdov než pri extrémnych búrkach, čo nám zdôrazňuje potrebu predpovedať všetky typy búrok a nie len tie najsilnejšie. Nakoľko je vesmírna technológia vystavená vplyvom nepriaznivého vesmírneho prostredia počas geomagnetických búrok, je veľmi dôležité predchádzať možným škodám. Slnečné kozmické žiarenie a energetické častice môžu trvalo poškodiť citlivé prístroje na palubách satelitov. Počas silných búrok taktiež dochádza k zahrievaniu termosféry, čo má za následok zvýšenie hustoty horných vrstiev atmosféry. Takéto navýšenie hustoty môže viesť k zmene dráhy satelitov. Príkladom takejto udalosti je Gannonova búrka, ktorá nastala v máji 2024. Ďalším príkladom, prečo je predpoveď geomagne-

tických búrok dôležitá je udalosť z februára 2022, kedy počas búrky strednej intenzity došlo k strate 38 komerčných satelitov Starlink, čo nám len dokazuje, že aj menej intenzívne javy môžu mať ničivé následky. Ako sme už spomínali, geomagnetické búrky vedia ovplyvňovať aj šírenie signálov. To môže mať za dôsledok narušenie rádiových vĺn a spojenie so satelitmi, čo negatívne ovplyvňuje presnosť a dostupnosť GPS signálov a vysokofrekvenčnej komunikácie. Extrémne udalosti, ktoré vedú k vzniku geomagnetických búrok, môžu vyradiť z prevádzky aj samostatné monitorovacie sondy v bode L1, ako ACE alebo DSCOVR, ktoré poskytujú kritické dáta pre predpovede, čím by sa mohol zastaviť varovný systém pre iné subjekty. Hlavnou výzvou v danom výskume stále zostáva potreba zvýšiť čas varovania. Súčasné modely poskytujú varovania približne 60 minút vopred, čo je často nedostatočné na implementáciu účinných opatrení. Schopnosť predpovedať búrky v horizonte 3 hodín až 3 dní by umožnila spoločnosti lepšie sa pripraviť a zmierniť potencionálne infraštrukturálne škody, ktoré môžu mať obrovské ekonomické následky Khabarova and Price (2024)

2 Prediktívne modely a strojové učenie v spracovaní časových radov

Predikcia časových radov je proces predpovedania budúcich hodnôt cieľovej premennej $\hat{y}_{i,t+1}$ pre danú entitu i v čase t na základe historických pozorovaní a súvisiacich údajov. Z technického hľadiska ide o učenie predikčnej funkcie $f(.)$, ktorá mapuje historické informácie na budúce odhady. Model typicky pracuje so vstupmi, ako sú historické pozorovania cieľovej premennej, externé premenné pozorované v minulosti, ktoré ovplyvňujú cieľovú premennú, statické metadáta a známe budúce vstupy. Význam predikcie časových radov však presahuje samotný odhad budúcich hodnôt a predstavuje dôležitý nástroj podpory rozhodovania v mnohých oblastiach. V medicíne môžu predikčné modely pomáhať pri prioritizácii vyšetrení alebo pri odhade priebehu liečby, zatiaľ čo v hospodárskej a obchodnej praxi nachádzajú uplatnenie napríklad pri optimalizácii zásob, plánovaní výroby alebo riadení dopytu. Predikcia časových radov tak umožňuje prijímať informovanejšie rozhodnutia založené na očakávanom budúcom vývoji.

Dôležitým aspektom tejto disciplíny je aj schopnosť pracovať s neistotou. Moderné prístupy sa často neobmedzujú iba na bodové odhady, ale poskytujú aj pravdepodobnostné výstupy, ktoré umožňujú lepšie posúdiť mieru spoľahlivosti predikcie. Takýto prístup je mimoriadne dôležitý v oblastiach, kde môžu mať zriedkavé alebo extrémne udalosti závažné dôsledky, napríklad pri geomagnetických búrkach alebo výkyvoch na finančných trhoch. Informácia o neistote predikcie umožňuje používateľovi alebo operátorovi zvoliť opatrnejší postup v situáciách, keď je model menej spoľahlivý.

Predikcia časových radov má zároveň význam aj z hľadiska analýzy rôznych scenárov budúceho vývoja. Pokročilé modely umožňujú simulovať budúci vývoj sledovanej veličiny pri rôznych vstupných podmienkach, čím poskytujú odpoveď na otázky typu „čo ak“. Takéto analýzy sú cenné najmä pri plánovaní, porovnávaní alternatívnych rozhodnutí a hodnotení možných dôsledkov rôznych zásahov alebo udalostí.

Súčasné metódy navyše prispievajú aj k lepšiemu pochopeniu dynamiky dát, keďže dokážu identifikovať, ktoré časové okamihy alebo vstupné premenné zohrávajú pri predikcii najvýznamnejšiu úlohu. To je dôležité nielen z hľadiska samotnej presnosti modelu, ale aj z pohľadu interpretácie skrytých vzťahov v dátach. V neposlednom rade predikcia časových radov podporuje automatizáciu a zvyšovanie efektivity analytických procesov, keďže moderné prístupy hlbokého učenia dokážu automaticky extrahovať komplexné reprezentácie zo vstupných dát bez potreby rozsiahleho manuálneho návrhu príznakov Lim and Zohren (2021).

2.1 Umelá inteligencia a strojové učenie

Umelá inteligencia (UI) je v odbornej literatúre charakterizovaná ako schopnosť digitálneho počítača alebo počítačom riadeného systému vykonávať úlohy, ktoré sa zvyčajne spájajú s ľudskou inteligenciou. V širšom ponímaní zahŕňa softvérové aj hardvérové prístupy, ktorých cieľom je napodobňovať alebo reprodukovať ľudské myslenie a správanie. Ide pritom o dynamicky sa rozvíjajúci súbor technológií určených na riešenie širokého spektra aplikačných problémov v rôznych oblastiach spoločnosti.

Vzťah medzi umelou inteligenciou (AI), strojovým učením (ML) a hlbokým učením (DL) má hierarchický charakter, pričom každá nasledujúca oblasť predstavuje užšie špecializovanú podmnožinu tej predchádzajúcej. Umelá inteligencia tvorí najširší pojem a okrem strojového učenia zahŕňa aj oblasti, ako sú spracovanie prirodzeného jazyka, počítačové videnie, robotika či expertné systémy. Strojové učenie predstavuje jadro umelej inteligencie a zahŕňa súbor algoritmov a metód určených na riešenie úloh, ako sú klasifikácia, zhlukovanie a predikcia. Hlboké učenie možno chápať ako špecifickú podoblasť strojového učenia, ktorá využíva hlboké neurónové siete, teda siete obsahujúce dve alebo viac skrytých vrstiev. Jeho význam spočíva najmä v schopnosti riešiť úlohy end-to-end spôsobom, pri ktorom model automaticky identifikuje dôležité črty a zákonitosti priamo zo vstupných dát bez potreby

rozsiahleho manuálneho predspracovania.

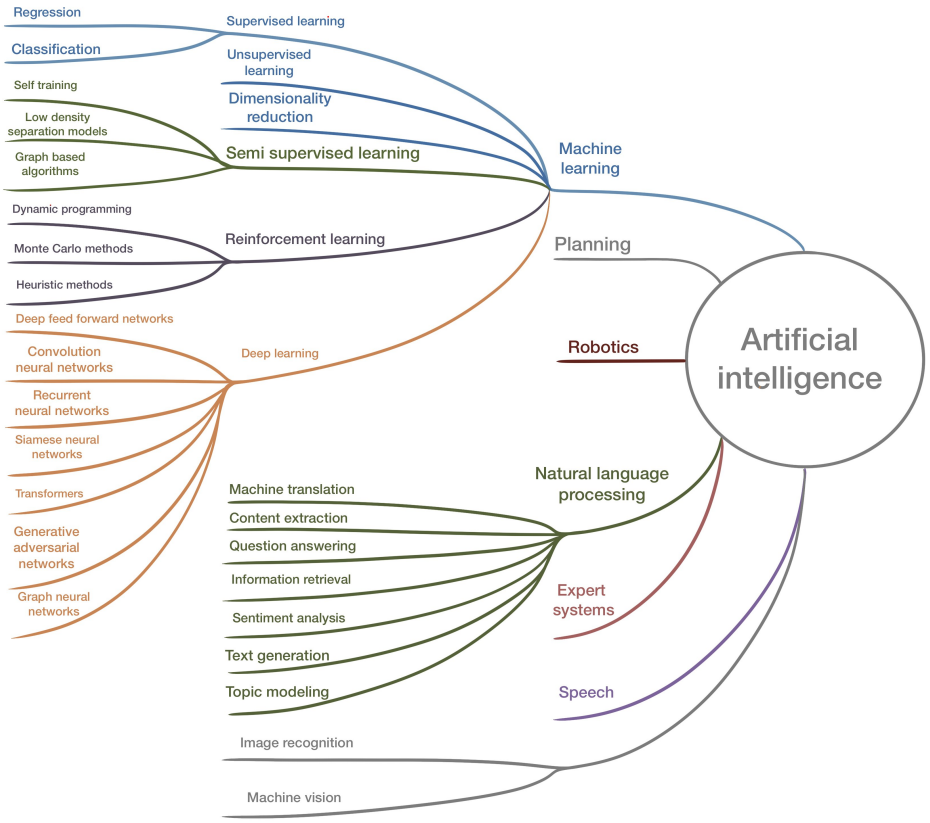

Obrázok 2 – 1 Prehľad hlavných oblastí umelej inteligencie a ich vzájomných vzťahov

Metódy strojového učenia sa v odbornej literatúre spravidla rozdeľujú do viacerých základných kategórií podľa spôsobu učenia a cieľa algoritmu. Medzi hlavné prístupy patria učenie s učiteľom, učenie bez učiteľa a posilňované učenie. Osobitné postavenie má aj čiastočne monitorované učenie, ktoré kombinuje vlastnosti viacerých prístupov.

Učenie s učiteľom predstavuje prístup určený na riešenie úloh klasifikácie a regresie. Model v tomto prípade pracuje s konečnou množinou objektov, ktoré sú vopred označené, pričom sa na základe týchto príkladov učí priraďovať označenia aj novým, neoznačeným objektom. Klasifikácia sa využíva v situáciách, keď sú objekty označené celými číslami reprezentujúcimi jednotlivé triedy, zatiaľ čo regresia sa uplatňuje vtedy, keď sú objekty označené reálnymi číslami a cieľom algoritmu je predpovedanie

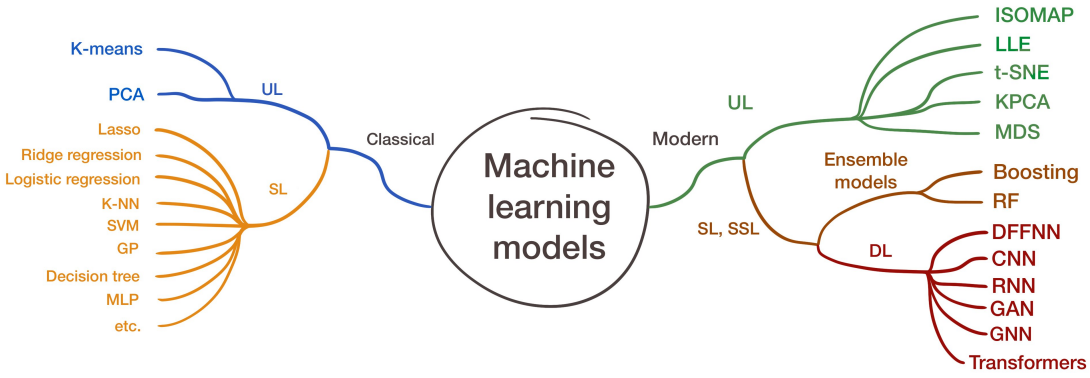

Obrázok 2 – 2 Rozdelenie modelov strojového učenia na klasické a moderné prístupy

hodnôt alebo dopĺňanie chýbajúcich údajov. Medzi klasické modely učenia s učiteľom patria lineárna a logistická regresia, k-najbližších susedov, rozhodovacie stromy, metóda podporných vektorov a dopredné neurónové siete.

Učenie bez učiteľa je zamerané na identifikáciu skrytých štruktúr v dátach bez potreby ich predchádzajúceho označenia. Jeho hlavnou úlohou je zhluková analýza, teda rozdelenie množiny neoznačených objektov do izolovaných alebo čiastočne sa prekrývajúcich skupín na základe ich vlastností. Tento prístup umožňuje odhaľovať skryté vzorce v dátach, ako aj anomálie a nerovnováhy. Medzi najčastejšie používané metódy patria algoritmus k-means a analýza hlavných komponentov. Medzi modernejšie prístupy možno zaradiť metódy ISOMAP, LLE, t-SNE a kernel PCA.

Posilňované učenie predstavuje špecifickú triedu metód, v ktorej sa agent učí prostredníctvom interakcie s okolím a spätnej väzby. Algoritmus vykonáva rozhodnutia a na základe ich výsledkov získava odmeny alebo tresty, čím postupne optimalizuje svoje správanie. V rámci tohto prístupu sa využívajú metódy, ako sú dynamické programovanie, metódy Monte Carlo a heuristické metódy. V súčasnosti tvoria tieto prístupy jeden zo základov moderných modelov strojového učenia. V praxi sa možno stretnúť aj s čiastočne monitorovaným učením, ktoré predstavuje hybridný prístup kombinujúci vlastnosti učenia s učiteľom a učenia bez učiteľa. Tento spôsob učenia využíva malé množstvo označených dát spolu s veľkým množstvom neoznačených

dát.

Predikcia časových radov sa v rámci strojového učenia zaraďuje medzi úlohy učenia s učiteľom, keďže model sa učí na základe historických dát, pri ktorých sú vstupy aj zodpovedajúce cieľové hodnoty známe. Ide teda o situáciu, v ktorej sú dvojice vstup–výstup vopred definované a model sa z nich učí vzťah medzi minulými pozorovaniami a budúcimi hodnotami. Tento typ úlohy má zároveň charakter regresného problému, pretože cieľom nie je priradenie objektu do triedy, ale odhad konkrétnej číselnej hodnoty v budúcom časovom okamihu. Pri predikcii časových radov, napríklad pri odhade budúcej hodnoty indexu Dst, sú preto cieľové premenné reprezentované reálnymi číslami. Proces učenia spočíva v hľadaní predikčnej funkcie, ktorá na základe historických pozorovaní dokáže vytvárať odhady budúceho vývoja. V praxi sa na tento účel využívajú rôzne modely učenia s učiteľom, medzi ktoré patria aj dopredné neurónové siete alebo architektúry typu LSTM Mukhamediev et al. (2022).

2.2 Neurónové siete pre časové rady

Umelá neurónová sieť predstavuje model využívaný v rámci hlbokého učenia, ktorého cieľom je simulovať a zároveň lepšie pochopiť princípy fungovania ľudského mozgu. Ide o viacvrstvový systém, ktorý prostredníctvom prepojení medzi jednotlivými vrstvami a im priradených váh dokáže reprezentovať komplexné vzťahy v dátach. Počas procesu trénovania sa tieto váhy postupne upravujú na základe vstupných údajov. Z funkčného hľadiska sú neurónové siete určené na identifikáciu vzorov a charakteristík v dátach, čo im umožňuje vykonávať presné klasifikácie a predikcie. Ich významným prínosom je schopnosť automaticky extrahovať a reprezentovať užitočné informácie priamo zo vstupných dát bez potreby rozsiahleho manuálneho návrhu príznakov. V porovnaní s tradičnými štatistickými metódami dokážu neurónové siete efektívnejšie modelovať komplexnú nelineárnu dynamiku a dlhodobé závislosti, ktoré sú typické pre reálne časové rady.

Základná štruktúra umelej neurónovej siete pozostáva z troch základných typov vrstiev, a to vstupnej vrstvy, skrytých vrstiev a výstupnej vrstvy, ktoré sú navzájom prepojené váhami. Vstupná vrstva predstavuje miesto, cez ktoré vstupujú dáta do modelu. Pri predikcii časových radov spravidla prijíma chronologicky usporiadanú sekvenciu pozorovaní, ktorá môže byť jednorozmerná alebo viacrozmerná. Vstupy sa matematicky reprezentujú ako vektory alebo matice, pričom jednotlivé hodnoty zodpovedajú konkrétnym časovým krokom a sledovaným ukazovateľom. Úlohou vstupnej vrstvy nie je vykonávať samotné výpočty, ale sprostredkovať surové dáta na ďalšie spracovanie v skrytých vrstvách.

Skryté vrstvy tvoria jadro neurónovej siete, v ktorom prebieha učenie a modelovanie nelineárnych vzťahov. Ak sieť obsahuje dve alebo viac skrytých vrstiev, hovoríme o hlbokej neurónovej sieti. Práve v týchto vrstvách sa vytvára reprezentácia komplexných vzťahov v dátach, pričom hodnoty váh sa počas trénovania postupne upravujú. Významnou vlastnosťou skrytých vrstiev je schopnosť automaticky extrahovať a reprezentovať dôležité črty priamo zo surových vstupov bez potreby manuálneho zásahu. Konkrétna forma skrytých vrstiev závisí od typu architektúry. Konvolučné neurónové siete využívajú konvolučné vrstvy na extrakciu lokálnych časových vzorov, rekurentné neurónové siete vrátane architektúr LSTM a Gated Recurrent Unit (GRU) obsahujú rekurentné prepojenia umožňujúce uchovávanie informácií z minulosti a transformer architektúry využívajú mechanizmus self-attention, ktorý umožňuje paralelné spracovanie celých sekvencií.

Výstupná vrstva generuje konečný výsledok predikcie na základe informácií spracovaných v predchádzajúcich vrstvách. Výstupom môže byť odhad jednej budúcej hodnoty alebo celej sekvencie budúcich hodnôt v závislosti od zvoleného horizontu predikcie. Pri jednokrokovej predikcii model vytvára odhad nasledujúcej hodnoty v čase $t + 1$, zatiaľ čo pri viackrokovej predikcii generuje viacero budúcich hodnôt naraz. Moderné modely zároveň umožňujú produkovať viacero výstupov súčasne, čím dokážu zachytiť vzťahy medzi viacerými premennými v čase.

Kľúčovým prvkom celej siete sú váhy medzi jednotlivými vrstvami, ktoré určujú

silu ich vzájomných prepojení. Počas procesu trénovania sa tieto váhy optimalizujú tak, aby sa minimalizoval rozdiel medzi predpovedanou hodnotou na výstupe siete a skutočnou historickou hodnotou.

Podľa architektúry a zamerania možno neurónové siete rozdeliť do viacerých základných skupín. Rekurentné neurónové siete využívajú rekurentnú konektivitu, vďaka ktorej dokážu uchovávať informácie z minulosti a pracovať s časovými závislosťami. Konvolučné neurónové siete sú založené na konvolučných operáciách a sú vhodné na extrakciu lokálnych čŕt. Grafové neurónové siete sa špecializujú na spracovanie štruktúrovaných relačných dát a na zachytávanie priestorovo-časových vzťahov. Osobitnú skupinu predstavujú transformery, ktoré nahrádzajú rekurentné spojenia mechanizmom self-attention, čím umožňujú paralelné spracovanie sekvencií a zachytenie lokálnych aj globálnych vzorov Lu et al. (2025).

2.3 Rekurentné neurónové siete

Rekurentné neurónové siete (RNN) predstavujú špecifickú triedu modelov hlbokého učenia, ktoré sú navrhnuté na spracovanie sekvenčných údajov, pri ktorých je poradie jednotlivých prvkov podstatné. Na rozdiel od bežných dopredných neurónových sietí disponujú schopnosťou udržiavať si informáciu o predchádzajúcich vstupoch prostredníctvom vnútorného stavu, čím vytvárajú určitú formu pamäti. Práve táto vlastnosť ich predurčuje na úlohy, v ktorých je dôležité zohľadniť časový kontext, napríklad pri predikcii časových radov.

Základný princíp fungovania RNN spočíva v tom, že vstupná sekvencia je spracovávaná postupne, krok po kroku. V každom časovom kroku model nepracuje iba s aktuálnym vstupom, ale zároveň zohľadňuje aj informáciu prenesenú z predchádzajúceho kroku. To je umožnené prostredníctvom rekurentných prepojení, ktoré zabezpečujú, že výstup alebo vnútorný stav z predchádzajúceho časového kroku vstupuje do výpočtu v kroku nasledujúcom. Vďaka tomu RNN vykazujú dynamické temporálne správanie a dokážu modelovať závislosti medzi hodnotami v čase.

Z architektonického hľadiska pozostáva základná RNN zo vstupnej vrstvy, skrytej vrstvy a výstupnej vrstvy. Vstupná vrstva prijíma vstupný vektor v každom časovom kroku, skrytá vrstva udržiava a aktualizuje skrytý stav a výstupná vrstva generuje výsledný výstup na základe spracovaných informácií. Kľúčovým prvkom celej architektúry je práve skrytý stav, ktorý predstavuje vnútornú pamäť siete. Jeho úlohou je zachytávať a uchovávať informácie o predchádzajúcich vstupoch v sekvencii a prenášať ich do ďalších časových krokov. V každom kroku vzniká aktualizáciou na základe aktuálneho vstupu a predchádzajúceho skrytého stavu, čím integruje novú informáciu s historickým kontextom.

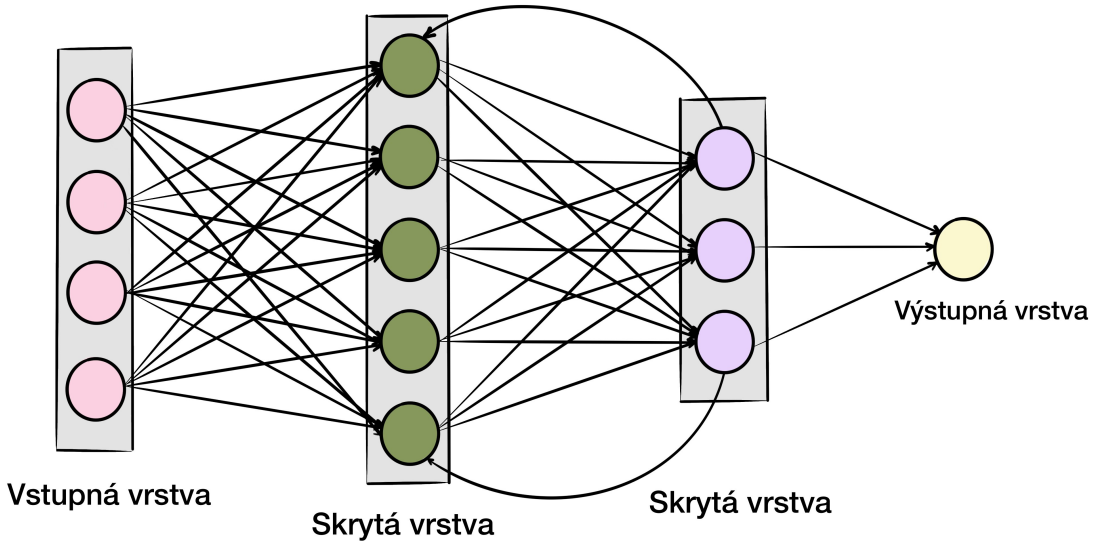

Obrázok 2 – 3 Rekurentná neurónová sieť

Význam skrytého stavu spočíva v tom, že umožňuje modelu rozlišovať nielen hodnotu vstupu, ale aj jeho pozíciu v sekvencii a vzťah k predchádzajúcim údajom. RNN tak dokážu reprezentovať časové závislosti, ktoré sú pri modelovaní časových radov kľúčové. Práve vďaka tejto vlastnosti sa rekurentné neurónové siete považujú za vhodné nástroje na spracovanie sekvenčných dát, pretože ich architektúra od začiatku zohľadňuje, že poradie dátových bodov a ich historický kontext ovplyvňujú budúci vývoj systému.

V článku Mienye et al. (2024) sa rozlišujú aj rôzne formy realizácie rekurencie. Interná rekurencia prebieha v rámci samotných neurónov, zatiaľ čo externá rekurencia sa realizuje medzi jednotlivými vrstvami siete. Bez ohľadu na konkrétnu implementáciu však zostáva základný princíp rovnaký, a to prenos informácie z minulých časových krokov do aktuálneho výpočtu.

Napriek svojim výhodám majú štandardné RNN viacero významných obmedzení. Najzásadnejším problémom je miznúci a explodujúci gradient, ktorý vzniká počas trénovania pomocou algoritmu spätného šírenia v čase. Pri spätnom šírení gradientov cez dlhšiu sekvenciu môže dochádzať k ich exponenciálnemu zmenšovaniu alebo naopak k ich nekontrolovanému rastu. V prípade miznúceho gradientu sa gradient postupne znižuje natoľko, že prestáva efektívne ovplyvňovať aktualizáciu váh v skorších častiach sekvencie. To vedie k tomu, že sieť stráca schopnosť učiť sa dlhodobé závislosti a nedokáže si uchovať dôležité informácie z dávnejšej minulosti. V prípade explodujúceho gradientu dochádza k opačnému javu, keď gradienty rastú príliš rýchlo, čo spôsobuje numerickú nestabilitu a môže viesť až k zlyhaniu trénovania.

Tieto problémy majú priamy vplyv na praktické využitie štandardných RNN. Okrem obmedzenej schopnosti učiť sa dlhodobé závislosti sú tieto siete aj výpočtovo náročné, keďže ich sekvenčný charakter znemožňuje paralelné spracovanie dát. Trénovanie na dlhých sekvenciách a rozsiahlych datasetoch je preto časovo aj hardvérovo náročné. Ďalším obmedzením je ich nižšia interpretovateľnosť, keďže vnútorná dynamika modelu je zložitá a často pôsobí ako čierna skrinka. Pri hlbších architektúrach sa zároveň môže prejaviť aj náchylnosť na preučenie.

Práve obmedzenia štandardných RNN viedli k vývoju pokročilejších variantov, najmä architektúr LSTM a GRU. Na zmiernenie problémov trénovania sa v článku Mienye et al. (2024) uvádzajú aj ďalšie prístupy, napríklad orezávanie gradientu, použitie vhodných aktivačných funkcií alebo architektúry typu Independently Recurrent Neural Networks. Napriek tomu však zostáva základným faktom, že klasické RNN majú pri veľmi dlhých sekvenciách prirodzené limity. Aj z tohto dôvodu sa v súčasnosti pri spracovaní sekvenčných údajov čoraz častejšie využívajú

aj modernejšie architektúry Mienye et al. (2024).

2.4 Long Short-Term Memory

Long Short-Term Memory (LSTM) predstavuje špeciálnu architektúru rekurentnej neurónovej siete navrhnutú na spracovanie sekvenčných dát a zachytávanie dlhodobých závislostí v časových radoch. Vznikla ako odpoveď na hlavné obmedzenia klasických rekurentných neurónových sietí, predovšetkým na problém miznúceho a explodujúceho gradientu, ktorý sťažuje učenie pri dlhších sekvenciách. Vďaka svojej architektúre dokáže LSTM uchovávať relevantné informácie počas veľkého počtu časových krokov a efektívne pracovať aj s časovými oneskoreniami, ktoré presahujú stovky až tisíce diskrétnych krokov.

Základným stavebným prvkom LSTM je pamäťová bunka (memory cell), ktorá nahrádza tradičné skryté jednotky používané v štandardných RNN. Táto bunka obsahuje vnútorný stav, ktorý slúži ako nositeľ dlhodobej pamäti, a zároveň mechanizmy riadiace tok informácií do bunky aj z bunky. Kľúčovým prvkom architektúry je tzv. Constant Error Carousel (CEC), teda lineárne samo-prepojenie s váhou 1, ktoré umožňuje, aby sa chyba pri spätnom šírení prenášala v čase bez výrazného zoslabovania alebo nekontrolovaného rastu. Práve tento mechanizmus umožňuje sieti udržiavať stabilný tok informácií a učiť sa dlhodobé časové závislosti.

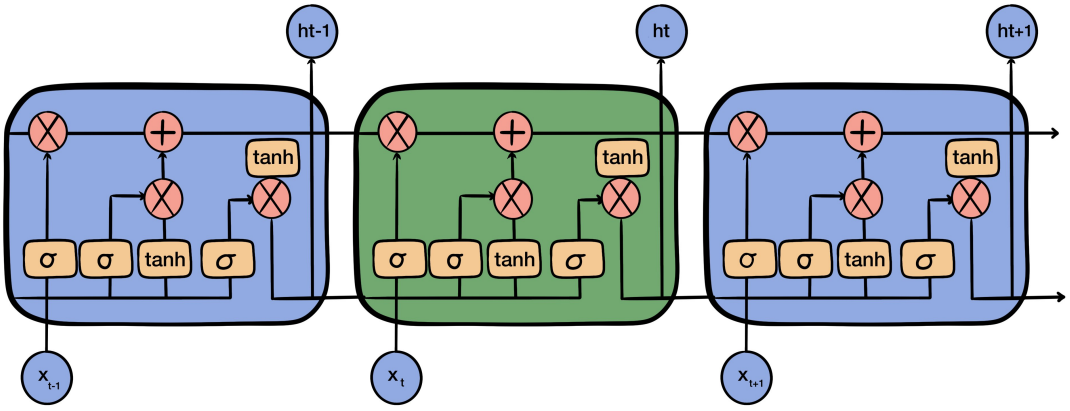

Obrázok 2 – 4 LSTM model

Riadenie toku informácií v LSTM je zabezpečené pomocou multiplikatívnych hradiel. Vstupná brána (input gate) rozhoduje o tom, ktoré nové informácie budú zapísané do pamäťovej bunky, a zároveň chráni jej obsah pred nepodstatnými alebo rušivými vstupmi. Výstupná brána (output gate) určuje, kedy sa informácia uložená v bunke sprístupní ďalším častiam siete, čím zabraňuje tomu, aby momentálne nepodstatný obsah pamäte negatívne ovplyvňoval výstup modelu. Tieto mechanizmy spoločne umožňujú selektívne uchovávanie dôležitých informácií a potláčanie šumu alebo menej relevantných vstupov.

Význam LSTM spočíva najmä v tom, že dokáže efektívne pracovať so sekvenčnými údajmi, pri ktorých budúca hodnota závisí od komplexnej histórie predchádzajúcich pozorovaní. Pri predikcii časových radov tak model nie je obmedzený iba na krátke časové okno, ale dokáže zohľadniť aj udalosti, ktoré sa odohrali výrazne skôr a stále ovplyvňujú budúci vývoj systému. Táto vlastnosť je dôležitá napríklad pri finančných, medicínskych alebo geofyzikálnych časových radoch, kde môžu mať minulé stavy oneskorený, no stále významný vplyv na budúce hodnoty.

LSTM je vhodné aj na spracovanie spojitých numerických hodnôt, a preto nachádza uplatnenie nielen pri klasifikačných úlohách, ale aj pri regresii a predikcii reálnych veličín v čase. Vďaka bránovým mechanizmom dokáže filtrovať irelevantné výkyvy v dátach a sústrediť sa na tie informácie, ktoré sú pre budúcu predpoveď rozhodujúce. Táto vlastnosť je zvlášť dôležitá pri reálnych časových radoch, ktoré bývajú zašumené a obsahujú viacero krátkodobých aj dlhodobých fluktuácií.

V porovnaní s klasickými RNN prináša LSTM viacero významných výhod. Najdôležitejšou z nich je schopnosť prekonať problém miznúceho a explodujúceho gradientu. Okrem toho vykazuje vyššiu stabilitu učenia, lepšiu robustnosť voči šumu a vo viacerých úlohách aj lepšiu generalizačnú schopnosť. Výhodou je aj to, že dokáže efektívne pracovať s reálnymi číselnými hodnotami a modelovať komplexné nelineárne vzťahy v čase. Na druhej strane je však architektúra LSTM výpočtovo náročnejšia než jednoduché RNN, pretože obsahuje väčší počet parametrov a zložitejší vnútorný mechanizmus.

Z uvedených dôvodov patria siete typu LSTM medzi najvýznamnejšie modely používané pri predikcii časových radov. Ich schopnosť uchovávať dôležité informácie počas dlhších časových intervalov, filtrovať nepodstatné vstupy a zachytávať nelineárne dynamické vzťahy z nich robí vhodný nástroj aj pre úlohy predikcie geomagnetickej aktivity a ďalších javov vesmírneho počasia Hochreiter and Schmidhuber (1997).

3 Perzistentnosť v prediktívnych modeloch časových radov

3.1 Definícia perzistentnosti

Perzistentný model (označovaný aj ako naivný model) predstavuje najjednoduchší prístup k predikcii časových radov. Vychádza z predpokladu, že najlepším odhadom budúcej hodnoty je posledná známa hodnota sledovanej veličiny. Matematicky možno tento princíp zapísať ako

$$\hat{x}_{t+1} = x_t$$

kde predikovaná hodnota v čase $t+1$ sa rovná pozorovanej hodnote v čase t.

Variantom tohto prístupu je sezónny naivný model, pri ktorom sa budúca hodnota odhaduje na základe hodnoty z rovnakého obdobia v minulosti. Pri hodinových dátach tak môže byť predikcia napríklad založená na hodnote spred 24 hodín Haugsdal et al. (2023).

3.2 Prejavy perzistentnosti v neurónových sieťach

V kontexte tejto práce sa perzistentnosť modelu chápe ako nežiaduce správanie pri predikcii časových radov, keď sa neurónová sieť správa podobne ako naivný perzistentný model. Tento jav sa prejavuje najmä tým, že model predpovedá významné zmeny v časovom rade s oneskorením, teda s časovým posunom vzhľadom na ich skutočný výskyt. Pri predikcii geomagnetických búrok to znamená, že pokles indexu Dst je modelom zachytený až po tom, čo sa už reálne začal prejavovať. Hoci takýto model môže dosahovať priaznivé hodnoty klasických metrík, ako sú korelačný koeficient alebo Root Mean Squared Error (RMSE) , tieto výsledky môžu byť zavádzajúce, pretože odrážajú skôr vysokú autokoreláciu dát než skutočnú schopnosť včasnej predikcie. Perzistentné správanie sa preto považuje za závažný problém, keďže model neposkytuje dostatočne skoré varovanie pred náhlou zmenou stavu

systému. Pri analýze pomocou Dynamic Time Warping sa tento jav prejavuje systematickým časovým posunom medzi predikovaným a skutočným priebehom Laperre et al. (2020).

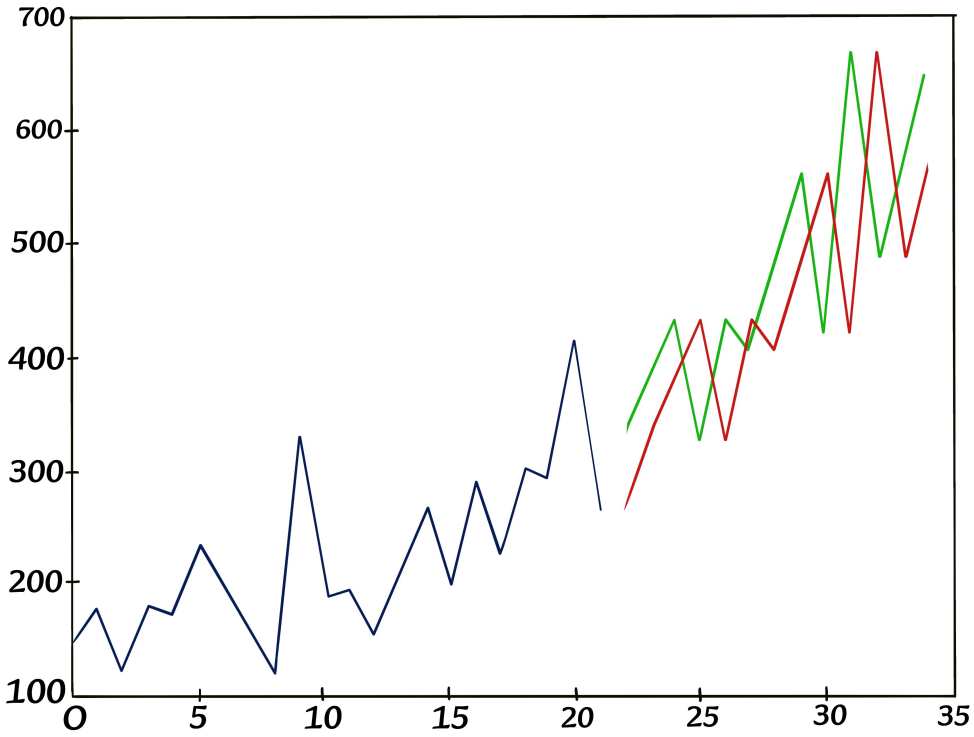

Obrázok 3 – 1 Ilustrácia perzistentného modelu pri predikcii časového radu

3.3 Prístupy k potláčaniu perzistentnosti

Na obmedzenie perzistentného správania predikčných modelov sa v odbornej literatúre navrhuje viacero metodických prístupov. Významné postavenie má trénovanie na diferencovaných dátach, pri ktorom sa model učí predikovať zmenu indexu namiesto jeho absolútnej hodnoty. Takýto postup redukuje vplyv autokorelácie a znižuje tendenciu modelu kopírovať posledné pozorovanie. Ďalšou stratégiou je modifikácia vstupného vektora, predovšetkým odstránenie historických hodnôt predikо-

vanej veličiny, aby bol model nútený opierať sa o externé fyzikálne parametre. Pri vzácnych extrémnych javoch sa zároveň odporúča augmentácia dát s cieľom lepšie reprezentovať málo zastúpené situácie v trénovacej množine. Na odhalenie perzistentného správania je vhodné doplniť klasické metriky o metódy citlivé na časový posun, napríklad Dynamic Time Warping. Určitý potenciál má aj využitie vzdialenejších meraní vstupných dát, ktoré môžu predĺžiť predikčný horizont a zlepšiť schopnosť modelu zachytiť zmenu skôr, než nastane Laperre et al. (2020).

4 Gaussian Process Regression v predikcii kozmického počasia

4.1 Základy Gaussian Process Regression

Regresia pomocou Gaussových procesov (Gaussian Process Regression, GPR) je flexibilná nelineárna metóda strojového učenia, ktorá na rozdiel od tradičných parametrických modelov definuje rozdelenie pravdepodobnosti priamo nad funkciami. V štatistike a strojovom učení sa využíva ako súčasť Bayesovského rámca pre riešenie regresných úloh so spojitými výstupmi. Gaussov proces je súbor náhodných premenných, pričom akýkoľvek konečný počet z nich má spoločné Gaussovo rozdelenie. Zatiaľ čo bežné Gaussovo rozdelenie pracuje s vektormi a maticami, Gaussov proces je jeho zovšeobecnením na funkcie a je plne určený funkciou strednej hodnoty $m(x)$ a kovariančnou funkciou $k(x, x')$.

Predikcia v rámci GPR je založená na Bayesovskej inferencii. Pred započítaním trénovacích dát model opisuje apriórne rozdelenie, ktoré vyjadruje predpokladané vlastnosti funkcií, napríklad ich hladkosť. Po získaní trénovacích príkladov sa toto rozdelenie aktualizuje na aposteriórne rozdelenie. Predpovede pre nové vstupy sa následne robia na základe podmieneného rozdelenia. Výsledkom nie je iba jedna predikovaná hodnota, ale opäť Gaussovo rozdelenie, ktoré je určené prediktívnou strednou hodnotou a prediktívnou kovarianciou, resp. varianciou.

Dôležitou vlastnosťou GPR je schopnosť pracovať s neistotou predikcie. Variancia aposteriórneho rozdelenia je vždy menšia ako variancia pôvodného apriórneho rozdelenia, keďže model pri aktualizácii využíva informáciu z dát. Neistota je najnižšia v blízkosti známych trénovacích bodov a zvyšuje sa v oblastiach, kde pozorovania chýbajú. V praxi sa táto neistota často vizualizuje ako tieňovaná oblasť predstavujúca napríklad 95% interval spoľahlivosti, čo môžeme vidieť na Obrázku 4 – 1. Model zároveň umožňuje zahrnúť aj neistotu spôsobenú šumom v meraniach, ktorý sa pridáva priamo do kovariančnej funkcie.

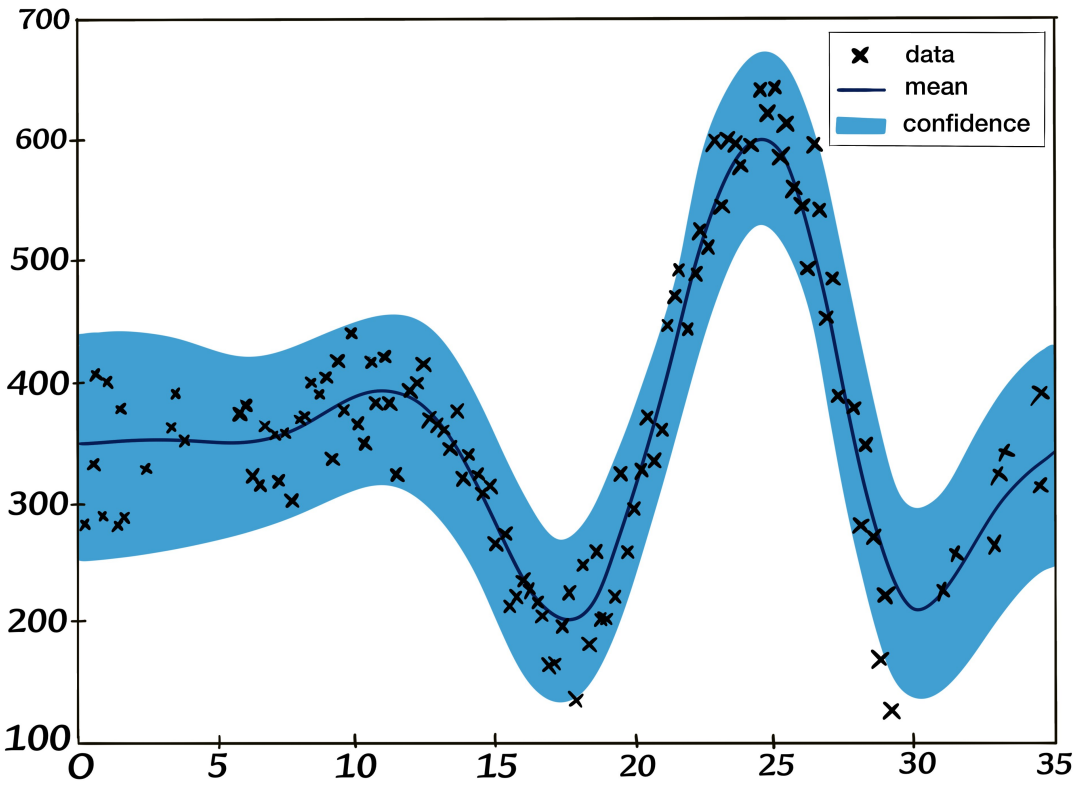

Obrázok 4 – 1 Ilustrácia regresie pomocou Gaussovského procesu s intervalom spoľahlivosti

Trénovanie modelu GPR v tomto kontexte znamená výber vhodnej kovariančnej funkcie a optimalizáciu jej hyperparametrov, napríklad úrovne šumu alebo dĺžkovej škály. Tento proces sa zvyčajne realizuje maximalizáciou marginálnej vierohodnosti. Jednou z praktických výhod GPR je, že marginálna vierohodnosť automaticky vyvažuje presnosť preloženia dát a penalizáciu zložitosti modelu. Tento mechanizmus, označovaný ako automatická Occamova britva, pomáha predchádzať nadmernému prispôsobeniu bez nutnosti externých validačných metód.

Výhodou GPR je možnosť špecifikovať zložité nelineárne vzťahy pomocou rôznych pozitívne definitných kovariančných funkcií. V porovnaní s parametrickými modelmi, ako sú dopredné neurónové siete, poskytuje výhodu v lepšej interpretovateľnosti neistoty a praktickejšej práci s komplexnými dátami pomocou jadrových metód. Hlavným obmedzením tejto metódy je však výpočtová náročnosť $O(n^3)$,

ktorá vyplýva z potreby inverzie kovariančnej matice, a preto limituje priame použitie modelu na datasety s veľkosťou niekoľko tisíc bodov Rasmussen (2003).

4.2 Kernel funkcie a využitie Gaussian Process Regression

Regresia pomocou Gaussových procesov využíva súbor matematických funkcií, ktoré definujú správanie modelu, jeho predikcie aj proces učenia. Gaussov proces je plne špecifikovaný dvoma základnými funkciami, ktoré tvoria jeho apriórne rozdelenie. Prvou je funkcia strednej hodnoty $\mu(x)$, ktorá určuje očakávanú hodnotu funkcie $f(x)$ v každom bode. V praxi sa táto funkcia často pre zjednodušenie nastavuje ako nulová, teda $\mu(x) \equiv 0$, Druhou je kovariančná funkcia $k(x, x')$ označovaná aj ako kernel alebo jadro, ktorá určuje mieru podobnosti medzi bodmi. Výber jadra pritom definuje vlastnosti výslednej funkcie, napríklad jej hladkosť.

Pri regresnej úlohe sa uvažuje tréningová množina dát $D = (x_i, y_i)_{i=1}^n$. Predpokladá sa, že pozorovania sú zaťažené šumom, ktorý sa modeluje pomocou Gaussovského likelihoodu $p(y_i \mid f_i) \sim \mathcal{N}(0, \sigma^2)$, kde σ^2 predstavuje rozptyl šumu. Keďže ide o Bayesovský prístup, dôležitú úlohu zohráva aj marginálna vierohodnosť $p(y \mid X, \theta)$, ktorá sa používa na výber modelu a optimalizáciu hyperparametrov. Jej logaritmická forma obsahuje členy pre presnosť preloženia dát a penalizáciu zložitosti modelu, čím funguje ako automatická Occamova britva.

Trénovanie modelu spočíva v optimalizácii hyperparametrov jadra a šumu. Najčastejšie sa využíva maximalizácia marginálnej vierohodnosti, napríklad pomocou gradientného zostupu. Tento proces vyvažuje presnosť preloženia dát a zložitosť modelu, čím pomáha brániť overfittingu. Ako alternatíva sa môže použiť aj krížová validácia, napríklad LOO-CV (Leave-One-Out Cross-Validation).

Po nastavení hyperparametrov sa pre nový vstupný bod vypočítajú prediktívne hodnoty. Prediktívna stredná hodnota $\bar{f}(x)$ sa určuje ako lineárna kombinácia kovariančných funkcií medzi testovacím bodom a tréningovými dátami:

$$\bar{f}(x) = \sum_{i=1}^{n} \alpha_i k(x, x_i),$$

kde vektor α je daný vzťahom

$$\alpha = (K + \sigma^2 I)^{-1} y.$$

Okrem prediktívnej strednej hodnoty model určuje aj prediktívnu varianciu, ktorá vyjadruje mieru neistoty predikcie v danom bode. Výpočet týchto veličín je založený na inverzii kovariančnej matice, a preto má zvyčajne časovú zložitosť $O(n^3)$.

V závislosti od typu dát môže GPR využívať rôzne typy kovariančných funkcií. Medzi najčastejšie patria squared exponential kernel, polynomial kernel a neural network covariance function. Okrem nich existujú aj špeciálne jadrá, napríklad string kernels pre textové reťazce, tree kernels pre stromové štruktúry alebo Fisher kernel. Osobitnú skupinu predstavuje ARD (Automatic Relevance Determination), ktoré umožňuje modelu identifikovať relevantnosť jednotlivých vstupných dimenzií.

Pri veľkých datasetoch sa vzhľadom na výpočtovú náročnosť používajú aproximačné metódy. Medzi ne patrí Subset of Data, pri ktorom sa využíva len náhodne vybraná časť dát, Subset of Regressors, kde sa model aproximuje pomocou obmedzeného počtu bázických funkcií, a metódy založené na inducing variables, ako napríklad FITC (Fully Independent Training Conditional) alebo PITC (Partially Independent Training Conditional), ktoré využívajú pomocné premenné na zníženie výpočtovej náročnosti Williams and Rasmussen (2006).

5 Analýza súčasného stavu

5.1 Predikcia indexu Dst pomocou hybridného modelu LSTM–Gaussian Processes

Štúdia Gruet et al. (2018) je zameraná na vývoj pokročilého modelu včasného varovania pred geomagnetickými poruchami, ktoré majú priamy vplyv na pozemskú aj vesmírnu infraštruktúru. Autori sa venujú predikcii geomagnetického indexu Dst, ktorý vyjadruje intenzitu prstencového prúdu v magnetosfére a používa sa na klasifikáciu sily geomagnetických búrok. V rámci výskumu je uvažovaný predikčný horizont 1 až 6 hodín. Na rozdiel od iných modelov, ktoré poskytovali iba bodový odhad, tento prístup modeluje aj distribúciu pravdepodobnosti. Operátorom tak neposkytuje len očakávanú hodnotu indexu Dst, ale aj chybové úsečky a intervaly spoľahlivosti, čo je kľúčové pre rozhodovacie procesy súvisiace s ochranou technológií. Štúdia zároveň reaguje na nedostatky predchádzajúcich modelov, ktoré boli založené na lineárnej filtrácii alebo jednoduchých neurónových sieťach a mali problémy s presnou predikciou fázy zotavenia búrky alebo so zachytením nelineárneho správania systému slnečný vietor – magnetosféra. Hoci bežné modely vykazujú dobrú celkovú presnosť, často zlyhávajú pri predpovedaní intenzívnych superbúrok, pri ktorých Dst dosahuje hodnoty nižšie ako -250 nT, najmä pri dlhšom časovom predstihu 6 hodín. Autori sa zároveň zaoberajú otázkou, či pridanie meraní magnetického poľa priamo z GPS satelitov môže zvýšiť presnosť predikcie v porovnaní s modelmi využívajúcimi výlučne parametre slnečného vetra z databázy OMNI.

V štúdii sú využité dve pokročilé techniky. Prvou je model LSTM, teda špecifický typ rekurentnej neurónovej siete navrhnutý tak, aby si dokázal uchovávať informácie z časových radov počas dlhšieho obdobia a zároveň sa vyhol problému miznúceho gradientu počas trénovania. V rámci modelu slúži LSTM na získanie presného bodového odhadu. Druhou použitou technikou sú Gaussovské procesy, ktoré využívajú predikciu z LSTM ako strednú hodnotu a dopĺňajú ju o štatistickú neistotu. Túto

kombináciu autori v štúdii označujú ako GPNN.

Na vývoj predikčného modelu GPNN bola použitá kombinácia dát z dvoch hlavných verejne dostupných databáz, pričom sledované obdobie zahŕňalo roky 2001 až 2016. Konkrétne boli využité údaje OMNI od NASA (National Aeronautics and Space Administration), z ktorých autori vybrali hustotu protónov (n), rýchlosť slnečného vetra (V), medziplanetárne magnetické pole (IMF) a index Dst. Ten slúžil nielen ako cieľová veličina predikcie, ale aj ako historický vstup do modelu. Ako druhý zdroj boli použité údaje z GPS satelitov NOAA (National Oceanic and Atmospheric Administration), konkrétne zo satelitu ns41, ktorý poskytoval najširšie časové pokrytie. Z tohto zdroja bol použitý parameter B_{satGPS}, merajúci magnetické pole priamo na palube satelitu. Tieto údaje sú dôležité, pretože kvalita GPS signálu býva počas búrok výrazne narušená.

Pri predikcii hodnôt Dst autori využívali historické hodnoty Dst za predchádzajúcich 1 až 6 hodín. Celkovo štúdia pracovala so 134 398 hodinovými záznamami, ktoré zahŕňali 49 konkrétnych búrkových udalostí vrátane extrémnej „Halloweenskej búrky“ z roku 2003. Na účely strojového učenia boli dáta rozdelené na trénovaciu množinu (70%), testovaciu množinu (20%) a validačnú množinu (10%).

Na vyhodnotenie modelu boli použité metriky pre bodovú aj pravdepodobnostnú predpoveď. pri bodovej predikcii autori využili korelačný koeficient (CC) a odmocninu priemernej štvorcovej chyby (RMSE). pri pravdepodobnostnom hodnotení boli použité ROC krivka a reliability diagram. pri predpovediach 1 až 6 hodín dopredu dosiahol model hodnotu korelačného koeficientu 0.873 a RMSE nižšiu ako 8,86 nT. pri 6-hodinovej predikcii prekonal staršie prístupy, napríklad model Lazzúsa (2017), ktorý dosiahol korelačný koeficient 0.826 a RMSE 13.09. Samotná neurónová sieť LSTM mala problém s presnou predikciou intenzívnych búrok pri 6-hodinovom predstihu, keď Dst dosahoval hodnoty nižšie ako -250 nT. Hybridný model GPNN však tento nedostatok zmiernil tým, že poskytoval intervaly spoľahlivosti, vďaka čomu dokázal zachytiť aj najvyššie vrcholy aktivity. Model vykazoval takmer dokonalú spoľahlivosť pri predikcii na 2 hodiny dopredu. pri dlhšom časovom horizonte však

mal tendenciu mierne nadhodnocovať pravdepodobnosť výskytu búrky. Zahrnutie magnetických meraní priamo zo satelitov zároveň preukázateľne zlepšilo presnosť predikcie počas vrcholov najsilnejších geomagnetických búrok.

Napriek tomu, že štúdia predstavuje inovatívny prístup k predikovaniu indexu Dst, autori otvorene pomenúvajú viaceré slabiny a obmedzenia svojho modelu. Uvádzajú, že samostatná neurónová sieť LSTM vykazuje slabú výkonnosť pri predikcii intenzívnych superbúrok so 6-hodinovým predstihom. Napriek veľmi dobrým globálnym metrikám totiž model pri tomto časovom horizonte nedokáže presne zachytiť najvyššie vrcholy aktivity. Zároveň platí, že pri predikciách dlhších ako 3 hodiny má hybridný model GPNN tendenciu nadhodnocovať pravdepodobnosť búrky, zatiaľ čo pri predikcii 1 hodinu dopredu riziko búrky mierne podhodnocuje. Diagramy spoľahlivosti ukázali, že model nie je dokonale kalibrovaný. Jednoduché riešenie spočívajúce vo vynásobení smerodajnej odchýlky faktorom 2 alebo 3 síce zlepšuje spoľahlivosť pri vysokých pravdepodobnostiach, no zároveň zhoršuje výsledky pri pravdepodobnostiach nižších ako 50%. V neposlednom rade môžu extrémne podmienky ohroziť samotné meracie prístroje na satelitoch, ktoré poskytujú vstupné dáta pre model, čo môže v reálnom čase viesť k zlyhaniu varovného systému Gruet et al. (2018).

5.2 Predikcia indexu Dst pomocou GRU s multimodálnymi vstupnými dátami

Štúdia Majirskỳ et al. (2025) sa rovnako zameriava na predikciu indexu Dst s čo najvyššou presnosťou a včasnosťou. Na rozdiel od štúdie Gruet et al. (2018) však kladie dôraz na problém perzistencie, ktorým konvenčné modely často trpia. Ide o jav, pri ktorom modely síce správne predpovedajú pokles indexu Dst z hľadiska magnitúdy, avšak s časovým oneskorením, teda až po tom, čo sa udalosť už odohrala. Cieľom štúdie je minimalizovať tento efekt, aby boli predpovede využiteľné v reálnom čase.

Väčšina súvisiacich prác využíva na predikciu Dst parametre slnečného vetra

a medziplanetárneho magnetického poľa merané v bode L1. Predmetná štúdia rieši otázku, ako efektívne kombinovať tieto merania s obrazovými dátami slnečnej koróny a koronografickými pozorovaniami, ktoré poskytujú dodatočné informácie o blížiacich sa výronoch koronálnej hmoty. Zároveň poukazuje na to, že pri vzácnych a extrémnych udalostiach existuje riziko, že náhodné rozdelenie dát na trénovaciu a testovaciu množinu povedie k zavádzajúcim výsledkom. Autori preto navrhujú novú metodológiu delenia dát založenú na Wassersteinovej vzdialenosti, aby zabezpečili, že testovacie a validačné množiny budú mať podobné a reprezentatívne charakteristiky.

Autori vo svojej práci predpovedajú budúce hodnoty indexu Dst v časovom horizonte 4 a 8 hodín. Ich dataset pozostáva z 39 najextrémnejších geomagnetických búrok v období rokov 1998 až 2024. Dáta boli prevzorkované tak, aby zodpovedali rytmu prístroja LASCO C2, čo predstavuje priemerný interval približne 23 minút medzi meraniami. Ako vstupné okno model spracováva sekvenciu 200 po sebe nasledujúcich pozorovaní, čo pokrýva približne 80 hodín histórie pred samotnou predikciou. Model využíva celkovo 13 parametrov, ktoré sú rozdelené do troch hlavných kategórií:

- Vizuálne signály z koronografu (Q1, Q2, Q3 a Q4) – percentuálny podiel zmenených pixelov v štyroch kvadrantoch snímok z prístroja LASCO C2. Tieto dáta indikujú výskyt a smer výronov koronálnej hmoty smerom k Zemi.
- Vizuálne signály z EUV snímok (N_CH, R_CH, S_CH, L_CG a C_CH) – percentuálne pokrytie slnečného disku koronálnymi dierami (CH) v piatich regiónoch: sever, vpravo, juh, vľavo a stred. Tieto dáta pochádzajú z prístrojov SOHO/EIT a SDO/AIA a súvisia s vysokorýchlostnými prúdmi slnečného vetra.
- In situ merania a geomagnetické indexy:
  - V_p (rýchlosť slnečného vetra) – meraná prístrojom CELIAS na družici

SOHO,

- N_p (hustota slnečného vetra) – meraná prístrojom CELIAS na družici SOHO,
- B_z (južná zložka IMF) – vertikálna zložka medziplanetárneho magnetického poľa meraná družicou WIND,
- Dst index – historické hodnoty samotného indexu, ktorý sa model snaží predpovedať.

Tieto dáta boli pred vstupom do modelu očistené od chýbajúcich hodnôt pomocou metódy k-NN (k najbližších susedov) pri krátkych výpadkoch, pričom pri dlhších medzerách boli úplne odstránené.

Autori využili a porovnávali dva hlavné modely hlbokého učenia založené na rekurentných neurónových sieťach typu GRU. Tieto modely boli navrhnuté na spracovanie sekvenčných dát a zachytávanie časových závislostí pri predikcii indexu Dst. Modely sa od seba líšia zložitosťou aj typom spracovávaných vstupov. Model GRU-IE využíva ako vstup iba in situ merania slnečného vetra a EUV vizuálne signály. Tento model má približne 40 000 trénovateľných parametrov a jeho architektúra pozostáva z GRU vrstvy so 64 skrytými neurónmi a 2 vrstvami, po ktorých nasleduje lineárna transformácia na výslednú predpoveď. Model GRU-Attn-IEC je komplexnejší a využíva všetky uvedené parametre. Obsahuje dve samostatné vetvy spracovania, pričom jedna spracováva in situ a EUV dáta a druhá sa špecializuje na koronografické snímky. Vetva určená pre koronografické snímky využíva mechanizmus self-attention, ktorý umožňuje modelu efektívne zachytiť dlhodobé závislosti v pohybe koronálnej hmoty. Tento model je výrazne robustnejší, disponuje približne 1,5 milióna trénovateľných parametrov a 256 skrytými neurónmi v oboch vrstvách. Na minimalizovanie rizika pretrénovania autori použili optimizér AdamW a regularizačné techniky, ako sú weight decay a dropout v GRU vrstvách.

Jedným z najvýznamnejších prínosov štúdie je metodika rozdelenia dát, ktorá má zabrániť skresleným výsledkom pri výskyte vzácnych javov. Autori rozdelili dáta po-

mocou päťnásobnej krížovej validácie na trénovaciu, testovaciu a validačnú množinu v piatich rôznych kombináciách. Vypočítali štatistické rozdiely medzi jednotlivými búrkami a pomocou tejto metriky zabezpečili, aby validačné a testovacie množiny boli v každom kroku navzájom čo najpodobnejšie. Z dôvodu reprezentatívnosti testovania každá testovacia množina obsahovala jednu búrku typu Halo, jednu Non-halo a jednu neklasifikovanú udalosť.

Ako hodnotiace metriky boli v štúdii použité RMSE, D_{on} (percento krokov na diagonále DTW matice) a D_{sum} (súčet hodnôt na diagonále DTW matice). pri predikcii geomagnetického indexu s horizontom 4 hodiny dosiahol jednoduchší model GRU-IE mierne lepší výkon než rozšírený model GRU-Attn-IEC. Konkrétne dosiahol nižšiu chybu RMSE = 17,0 nT (oproti 17,4 nT) a nižšiu hodnotu metriky D_{sum} (2,9$\times$ 10^7 nT oproti 3,21$\times$ 10^7 nT), pričom hodnota D_{on} bola v oboch prípadoch rovnaká, a to 5,3%. pri predikcii na 8 hodín sa rozdiely medzi modelmi zmenšili a mierne lepšie výsledky dosiahol model s mechanizmom pozornosti GRU-Attn-IEC, ktorý dosiahol nižšie RMSE = 24,1 nT (oproti 24,3 nT). Zároveň vykazoval lepšie časové zosúladenie predikovaných udalostí vyjadrené metrikou D_{on} (3,33% oproti 3,1%), hoci hodnota metriky D_{sum} bola mierne vyššia (4,34$\times$ 10^7 nT oproti 4,22$\times$ 10^7 nT). Autori však preukázali výrazne nižšiu perzistenciu a predpovede oboch modelov sa viac približovali cieľovým hodnotám Dst než benchmarkový model. Presnosť zároveň výrazne kolísala v závislosti od konkrétnej sady búrok. Najhoršie výsledky dosahovali modely v 5. folde.

Hlavnou slabinou vyvinutých modelov, teda GRU-IE aj GRU-Attn-IEC, je ich neschopnosť presne predpovedať hĺbku poklesu indexu Dst pri najsilnejších búrkach. pri testovacej udalosti z marca 2015 oba modely podhodnotili maximálnu intenzitu búrky približne o 60 nT. Napriek tomu, že štúdia dosiahla výrazné zníženie efektu perzistencie, nepodarilo sa ho úplne eliminovať Majirskỳ et al. (2025).

5.3 Predikcia geomagnetických búrok pomocou fyzikálneho modelovania CME

Štúdia Davies et al. (2025) sa zameriava na riešenie kritického problému predpovedania kozmického počasia, ktorým je veľmi krátky varovný čas poskytovaný monitormi v Lagrangeovom bode L1. Merania z tohto bodu poskytujú varovanie iba 10 až 80 minút pred nárazom výronu koronálnej hmoty (CME) do Zeme, čo nie je postačujúce na realizáciu ochranných opatrení pre satelity a energetické siete. Cieľom štúdie je preto predĺžiť varovný čas využitím sondy Solar Orbiter ako vzdialeného monitora umiestneného hlbšie v heliosfére.

Autori modelujú tri hlavné aspekty. Prvým je čas príletu CME k bodu L1 a k Zemi, pričom využívajú model ELEvo, ktorý predpokladá eliptický tvar čela CME a je založený na aerodynamickom odpore okolitého slnečného vetra. Tento model je priebežne spresňovaný podľa reálne pozorovaného času príletu k sonde Solar Orbiter. Druhým aspektom je magnetická štruktúra CME v bode L1. Keďže pre geoefektivitu búrky je rozhodujúca orientácia magnetického poľa, najmä južná zložka B_z, autori škálujú magnetické pole namerané sondou Solar Orbiter pomocou mocninového zákona $B \propto r^{\alpha}$ s koeficientom $\alpha = -1{,}64$ a zároveň modelujú časové natiahnutie profilu CME pomocou expanzného parametra $\zeta = 0{,}8$. Tretím aspektom je predikcia geomagnetických indexov SYM-H a Dst pomocou modelu Temerin & Li Temerin and Li (2006), ktorý na základe magnetického poľa a parametrov slnečného vetra poskytuje časový rad indexu SYM-H.

Na identifikáciu erupcií a počiatočné modelovanie autori využili vizuálne dáta zo sond SDO/AIA, SDO/HMI a SOHO/LASCO C3, ako aj údaje z katalógu DONKI, z ktorého prevzali čas štartu CME, heliografickú dĺžku a šírku, polovičnú šírku a počiatočnú rýchlosť. Dôležitým zdrojom boli aj in situ dáta zo sondy Solar Orbiter, konkrétne merania magnetického poľa z magnetometra MAG v 1-minútovom rozlíšení, transformované zo súradníc RTN do GSM. Na validáciu boli použité merania v bode L1 zo sond DSCOVR a ACE a oficiálne hodinové hodnoty indexu Dst

z NOAA SWPC.

Pre model ELEvo bol použitý fixný pomer strán elipsy 1,43 a variabilné parametre v rámci ensemble prístupu, konkrétne rýchlosť CME, rýchlosť okolitého slnečného vetra a parameter aerodynamického odporu. pri škálovaní magnetického poľa bol použitý koeficient $\alpha = -1{,}64$ s rozsahom neistoty od -1,2 do -2,0. Keďže zo Solar Orbiteru neboli dostupné plazmové dáta v reálnom čase, hustota plazmy bola v modeli Temerin & Li stanovená konštantne na 5 cm^{-3} a rýchlosť plazmy bola aproximovaná stupňovitým profilom odvodeným z modelu ELEvo. Na odhad neistoty autori využili ensemble prístup s 10 000 simuláciami. Tento reťazec modelov umožnil predpovedať vrchol geomagnetickej búrky s predstihom 10,3 až 33,9 hodiny.

Na hodnotenie úspešnosti modelu autori použili varovný čas, chybu času príletu Δt_{L1}, porovnanie fyzikálnych parametrov v bode L1 a rozdiel medzi predpovedaným minimom indexu SYM-H a pozorovaným minimom indexu Dst. Metrika RMSE bola použitá pri optimalizácii vstupných parametrov modelu ELEvo aj v modeli Temerin & Li.

Výsledky ukázali výrazné zlepšenie oproti monitorom v bode L1. pri vrchole búrky boli predpovede vytvorené s predstihom 33,9 hodiny pri Udalosti 1 a 10,3 hodiny pri Udalosti 2. pri prílete šoku k bodu L1 bolo varovanie vydané 15,3 hodiny pri Udalosti 1 a 4,5 hodiny pri Udalosti 2 pred nárazom rázovej vlny. pri Udalosti 1 bola dosiahnutá veľmi vysoká presnosť, keď model predpovedal minimum SYM-H na -77 ± 4 nT a skutočne pozorované minimum Dst bolo -77 nT. pri Udalosti 2 model intenzitu podhodnotil, keď predpovedal -88 ± 6 nT, zatiaľ čo reálna hodnota dosiahla -130 nT. Presnosť predikcie času príletu zostala zaťažená chybami v ráde hodín, konkrétne 7,3 hodiny pri Udalosti 1 a 2,6 hodiny pri Udalosti 2.

Napriek tomu, že štúdia predstavuje významný posun v oblasti predpovedania geomagnetických búrok s dlhším predstihom, autori uvádzajú viacero obmedzení. Najvýznamnejším problémom bola absencia plazmových dát v reálnom čase zo sondy Solar Orbiter, čo si vynútilo použitie idealizovaných vstupov v modeli Temerin & Li. Ďalším obmedzením boli pretrvávajúce chyby v čase príletu a nevhodnosť použitých

škálovacích zákonov pre obalovú vrstvu CME. Model ELEvo zároveň nezohľadňuje komplexné pozadie slnečného vetra ani interakcie viacerých CME. Za slabinu autori označujú aj potrebu manuálnych zásahov pri zohľadnení už prebiehajúcej geomagnetickej aktivity a pri spracovaní dát, čo znižuje čistý varovný čas. Tieto obmedzenia podľa autorov naznačujú potrebu budúcich misií, ktoré budú poskytovať magnetické aj plazmové dáta kontinuálne a v reálnom čase Davies et al. (2025).

5.4 Porovnanie prístupov a identifikácia obmedzení súčasných model

Z analyzovaných štúdií vyplýva, že pri predikcii geomagnetickej aktivity, najmä indexu Dst, sa najčastejšie využívajú modely hlbokého učenia určené na spracovanie časových radov, predovšetkým LSTM a GRU siete, prípadne ich hybridné kombinácie s pravdepodobnostnými alebo fyzikálnymi modelmi. V jednej práci bol použitý hybrid LSTM + Gaussovské procesy (GPNN), v ďalšej GRU modely s attention mechanizmom a v tretej kombinácia fyzikálneho modelu CME (ELEvo), škálovania magnetického poľa a modelu Temerin & Li Temerin and Li (2006). Spoločným trendom je snaha nielen zlepšiť samotnú presnosť predikcie, ale aj predĺžiť varovný čas a zohľadniť neistotu predpovede.

Najčastejšie používanými vstupnými dátami sú parametre slnečného vetra a medziplanetárneho magnetického poľa, najmä rýchlosť, hustota a zložka Bz, spolu s historickými hodnotami indexu Dst. Tieto údaje sú často dopĺňané o ďalšie zdroje, ako sú magnetické merania zo satelitov, koronografické snímky CME, EUV pozorovania koronálnych dier alebo in situ merania zo sond v heliosfére. Vidieť teda posun od modelov založených len na jednej skupine vstupov k multimodálnym prístupom, ktoré kombinujú numerické, obrazové aj fyzikálne dáta.

Napriek pokroku majú všetky prístupy viacero spoločných nedostatkov. Najvýraznejším problémom zostáva slabšia schopnosť modelov správne zachytiť extrémne geomagnetické búrky, najmä ich maximálnu intenzitu a presné časovanie. Modely

často trpia buď oneskorenou reakciou (perzistencia), alebo majú problém s kalibráciou pravdepodobnosti, prípadne podhodnocujú alebo nadhodnocujú silu udalostí pri dlhšom predikčnom horizonte. Ďalším obmedzením je závislosť od kvality a dostupnosti vstupných dát, pričom pri extrémnych udalostiach môžu byť merania neúplné, oneskorené alebo samotné prístroje zlyhávať. pri fyzikálnych modeloch sa navyše ukazuje, že zjednodušené predpoklady nedokážu úplne vystihnúť komplexné interakcie v slnečnom vetre a štruktúre CME.

Celkovo teda možno konštatovať, že súčasný výskum smeruje k kombinácii dátovo riadených a fyzikálne motivovaných modelov, pričom najväčšou výzvou naďalej zostáva spoľahlivá predikcia extrémnych udalostí, zníženie časového oneskorenia a lepšie vyjadrenie neistoty predpovede.

6 Praktická časť

V tejto časti diplomovej práce sa venujeme predikcii indexu Dst s využitím modelu LSTM a metódy Gaussian Process Regression. Cieľom je vytvoriť model, ktorý nebude poskytovať len bodové predikcie, ale aj intervaly spoľahlivosti predstavujúce rozsah hodnôt, v ktorom sa s danou pravdepodobnosťou nachádza skutočná hodnota predikovaného indexu Dst. K tomu je potrebné získanie a pripravenie dát, následné modelovanie a vyhodnotenie. V práci pristupujeme k úlohe dvojstupňovo: najskôr predikujeme hodnotu indexu Dst a následne prevádzame výsledok na binárnu klasifikáciu do tried „búrka nastala“ a „búrka nenastala“. Na trénovanie využívame GPUs TeslaK40c, Quadro RTX 4000 a Quadro P4000 s povolením KKUI TUKE[1].

6.1 Získanie a príprava dát

Dáta boli získané prostredníctvom rozhrania HAPI[2] (Heliophysics Data Application Programmer's Interface), ktoré slúži na prístup k časovým radom v oblasti heliofyziky a kozmického počasia. Ide o štandardizované API založené na princípoch REST, ktoré umožňuje jednotný prístup k rôznym dátovým zdrojom. Výhodou tohto prístupu je, že dáta možno získavať automatizovane bez potreby sťahovať samostatné súbory alebo vytvárať osobitné nástroje pre jednotlivé zdroje. HAPI tak uľahčuje načítanie, spracovanie a porovnávanie časových radov z rôznych zdrojov. Zároveň podporuje klientské knižnice vo viacerých programovacích jazykoch, vrátane Pythonu. Vďaka tomu je možné jednoduché sťahovanie dát priamo v našom použitom prostredí. Pri výbere vstupných parametrov sme vychádzali z predchádzajúcich prác, konkrétne z bakalárskej práce a z vedeckých článkov, ktoré boli použité ako východisko pri návrhu metodiky. Na základe týchto zdrojov boli už vopred identifikované parametre, ktoré budú využité pri ďalšom spracovaní a modelovaní. Išlo o nasledujúce premenné:

[1]Prístup umožňuje: `https://datalab.kkui.fei.tuke.sk/gpu`

[2]Dostupné na: `https://hapi-server.org/`

- time1 - tento atribút slúži len na časovú identifikáciu jednotlivých záznamov, a preto nebol predmetom ďalších analýz. Dataset je usporiadaný ako časový rad s hodinovým krokom. Prvý záznam je priradený k času 1. januára 1963 o 00:00:00 UTC a každý nasledujúci záznam reprezentuje ďalšiu hodinu. Z toho vyplýva, že počet záznamov v datasete zodpovedá počtu hodín, pre ktoré sú k dispozícii merania jednotlivých atribútov.

- DST - hlavný indikátor geomagnetickej búrky. Viac je popísaný v Kapitole 1.

- `Bz_GSM` - je zložka medziplanetárneho magnetického poľa (IMF) vyjadrená v geocentrických solárno-magnetosférických súradniciach. Táto premenná patrí medzi dôležité ukazovatele geomagnetickej aktivity, a preto sa často využíva pri predikcii indexu Dst.

- v - predstavuje rýchlosť slnečného vetra. Spolu s južnou zložkou medziplanetárneho magnetického poľa B_s jedným z dvoch hlavných faktorov, ktoré tvoria medziplanetárne konvekčné elektrické pole Gonzalez et al. (1994).

Na základe tohto výberu bol následne prostredníctvom rozhrania HAPI stiahnutý dataset v období od 1963-01-01T00:00:00Z do 2026-01-13T16:00:00Z. Takto získaný súbor obsahoval spolu 552 568 hodinových záznamov. Keďže išlo o časový rad s dlhým časovým pokrytím, bolo potrebné venovať pozornosť aj kvalite a úplnosti dát, najmä výskytu chýbajúcich hodnôt v jednotlivých premenných.

Dataset pre eventové experimenty bol vytvorený z kontinuálneho časového radu OMNI a DST indexu. Najprv bol použitý zoznam časových intervalov geomagnetických udalostí zoznam_udalosti_final.csv, ktorý obsahoval časovú stopu búrok, kedy Dst kleslo pod -50nT .Na základe tohoto zoznamu boli z pôvodného kontinuálneho datasetu vyseparované iba úseky patriace jednotlivým udalostiam. Každému záznamu bol priradený identifikátor udalosti event_no a boli zachované vybrané vstupné premenné Dst, rýchlosť slnečného vetra v a medziplanetárna zložka magnetického poľa bz_gsm. Takto vznikol dataset event_omni.csv, ktorý obsahuje po-

zorovania usporiadané podľa udalostí.

Pre potreby viac-krokovej predikcie bol následne vytvorený pripravený dataset event_omni_prepared.csv. V ňom boli v rámci každej udalosti dopočítané cieľové premenné DST+1 až DST+6, reprezentujúce hodnotu indexu DST o 1 až 6 hodín dopredu. Posun bol realizovaný samostatne v rámci každej udalosti, aby nedochádzalo k prepájaniu susedných eventov. Takto pripravený dataset bol následne použitý na trénovanie a vyhodnotenie multihorizontálnych modelov.

Pred samotným modelovaním preto prebehlo doplnenie chýbajúcich hodnôt. Na tento účel bola použitá kombinácia regresnej imputácie a časovej interpolácie. V prvom kroku bola aplikovaná regresná imputácia na premenné `Bz_GSM` a V. Chýbajúce hodnoty premennej `Bz_GSM` boli odhadované pomocou lineárnej regresie s využitím premenných t_num, Dst a V. Chýbajúce hodnoty premennej v boli analogicky odhadované pomocou lineárnej regresie z premenných t_num, Dst a Bz_GSM. Týmto spôsobom bolo možné doplniť časť chýbajúcich údajov na základe vzťahov medzi dostupnými premennými.

Po vykonaní regresnej imputácie zostali v dátach ešte ďalšie chýbajúce hodnoty, ktoré boli následne doplnené pomocou časovej interpolácie. Pri tejto metóde sa chýbajúce hodnoty určovali na základe časovej nadväznosti susedných záznamov, pričom interpolácia bola vykonaná v oboch smeroch. Výsledkom bol súvislý dataset pripravený na ďalšie spracovanie.

Po úprave dát na kontinuálnom datasete nasledovalo ich rozdelenie na trénovaciu a testovaciu množinu. Rozdelenie bolo vykonané na základe časového kritéria, aby sa zachovala chronologická postupnosť dát. Ako deliaci bod bol zvolený dátum 19. 11. 2003. Všetky záznamy pred týmto dátumom boli zaradené do trénovacej množiny a záznamy od tohto dátumu vrátane tvorili testovaciu množinu.

Takto vytvorená trénovacia množina bola ďalej rozdelená, pričom 20% trénovacej sady bolo vyčlenených ako validačná množina. Táto validačná sada bola použitá pri ďalšom nastavovaní a vyhodnocovaní modelu.

Celý postup prípravy dát teda zahŕňal výber vstupných premenných na základe

predchádzajúcich prác, získanie rozsiahleho časového radu prostredníctvom rozhrania HAPI, doplnenie chýbajúcich hodnôt kombináciou regresnej imputácie a časovej interpolácie a následné rozdelenie dát na trénovaciu, validačnú a testovaciu množinu. Takto pripravené dáta tvorili základ pre ďalšiu časť práce zameranú na tvorbu a hodnotenie predikčných modelov.

6.2 Použité metriky

Na objektívne zhodnotenie výkonnosti navrhnutých modelov boli použité viaceré hodnotiace metriky. Tieto metriky umožňujú analyzovať presnosť klasifikácie, charakter chýb modelu aj veľkosť odchýlky medzi skutočnými a predikovanými hodnotami. Na základe ich výsledkov je možné komplexne posúdiť kvalitu navrhnutého modelu.

Základné pojmy

Tieto veličiny vychádzajú z konfúznej matice a používajú sa pri hodnotení klasifikačných modelov.

- TP (True Positive) - model správne predpovedal kladnú triedu.
  Príklad: vzorka je pozitívna a model ju označil ako pozitívnu.
- TN (True Negative) - model správne predpovedal zápornú triedu.
  Príklad: vzorka je negatívna a model ju označil za negatívnu.
- FP (False Positive) - model nesprávne predpovedal kladnú triedu.
  Príklad: vzorka je v skutočnosti negatívna, ale model ju označil ako pozitívnu.
- FN (False Negative) - model nesprávne predpovedal zápornú triedu.
  Príklad: vzorka je v skutočnosti pozitívna, ale model ju označil ako negatívnu.

Úspešnosť - ACC

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}$$

Úspešnosť (angl. *Accuracy*) vyjadruje podiel všetkých správne klasifikovaných prípadov zo všetkých hodnotených prípadov. Ide o jednu z najjednoduchších a najčastejšie používaných metrík pri klasifikácii. Daná metrika nadobúda hodnoty na intervale od 0 do 1, často sa vyjadruje v percentách. Vyššia hodnota spravidla znamená presnejší model, avšak jej nevýhodou je, že pri nevyvážených triedach môže poskytovať skreslený obraz o kvalite modelu. Model môže dosahovať vysokú accuracy aj vtedy, keď jednu triedu predpovedá výrazne lepšie než druhú.

Matthewsov korelačný koeficient - MCC

Matthewsov korelačný koeficient (angl. *Matthews Correlation Coeffiecient*) je metrika určená na hodnotenie kvality binárnej klasifikácie. Zohľadňuje všetky štyri hodnoty konfúznej matice: TP, TN, FP, a FN.

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

MCC môže nadobúdať hodnoty na intervale od -1 po 1. Pri hodnote 1 hovoríme o perfektnej klasifikácii, okolo 0 máme klasifikáciu na úrovni náhody a pri -1 hovoríme o úplne nesprávnej klasifikácii. Výhodou MCC je, že poskytuje vyvážené hodnotenie aj pri nevyvážených dátach, pretože neberie do úvahy len správne predikcie, ale aj typy chýb. Z tohto dôvodu sa často považuje za spoľahlivejšiu metriku než accuracy pri problémoch s nevyrovnaným zastúpením tried.

Klasifikačný report

Klasifikačný report (angl. *Classification report*) je súhrnný prehľad metrík klasifikačného modelu, zvyčajne generovaný pre každú triedu samostatne. Typicky obsahuje tieto ukazovatele:

- presnosť
- návratnosť
- F1 - skóre

Presnosť

Presnosť (angl. *Precision*) vyjadruje, aký podiel vzoriek označených modelom ako pozitívne bol naozaj pozitívny.

$$Precision = \frac{TP}{TP + FP}$$

Vyššia presnosť znamená menší počet falošne pozitívnych predikcií.

Návratnosť

Návratnosť (angl. *Recall*), nazývaná aj senzitivita, vyjadruje, aký podiel skutočne pozitívnych vzoriek model správne zachytil.

$$Recall = \frac{TP}{TP + FN}$$

Vyššia návratnosť znamená menší počet falošne negatívnych predikcií.

F1-skóre

F1-skóre (angl. *F1-score*) predstavuje harmonický priemer presnosti a návratnosti.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Používa sa najmä v prípadoch, keď je potrebné nájsť kompromis medzi presnosťou a návratnosťou.

Stredná kvadratická chyba - MSE

Stredná kvadratická chyba (angl. *Mean Squared Error*) je metrika používaná najmä pri regresných úlohách. Vyjadruje priemer štvorcov rozdielov medzi skutočnými a predikovanými hodnotami.

$$MSE = \frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2$$

kde:

- y_i je skutočná hodnota
- $\hat{y}_i$ je predikovaná hodnota
- n je počet vzoriek

MSE penalizuje väčšie chyby výraznejšie, pretože rozdiely sú umocnené na druhú. Z tohto dôvodu je citlivá na odľahlé hodnoty.

Odmocnina zo strednej kvadratickej chyby - RMSE

Odmocnina zo strednej kvadratickej chyby (angl. *Root Mean Squared Error*) je odvodená od MSE a vypočíta sa ako druhá odmocnina z jej hodnoty:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}$$

Výhodou RMSE je, že má rovnaké jednotky ako predikovaná veličina, a preto je interpretácia jednoduchšia než pri MSE. Aj táto metrika však silnejšie penalizuje väčšie chyby.

Stredná absolútna chyba - MAE

Stredná absolútna chyba (angl. *Mean Absolute Error*) predstavuje priemer absolútnych rozdielov medzi skutočnými a predikovanými hodnotami.

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i|$$

MAE udáva priemernú veľkosť chyby bez ohľadu na jej smer. V porovnaní s MSE a RMSE je MAE menej ovplyvnená extrémnymi odchýlkami, pretože nepriraďuje veľkým chybám neúmerne vysokú váhu. Vďaka tomu býva vhodná v prípadoch, keď nechceme extrémne veľké chyby nadmerne zvýhodniť alebo penalizovať.

6.3 Modelovanie

Modely na kontinuálnych dátach

Pri kontinuálnych dátach bola riešená úloha viacnásobnej jednorazovej predikcie hodnoty indexu DST v pevne zvolenom horizonte do budúcnosti. Modely boli trénované sada samostatných modelov pre jednotlivé predikčné horizonty. Konkrétne boli uvažované horizonty DST+1 až DST+6. Dĺžka vstupného časového okna, z ktorého model odvodzoval predikciu pozostávala z 6, 12, 18 a 24 hodín.

Každá kombinácia vstupných atribútov, predikčného horizontu a dĺžky vstupného okna bola teda trénovaná ako samostatný model. Pre jednu konfiguráciu vstupných premenných to predstavovalo 24 samostatných behov, keďže bolo testovaných 6 predikčných horizontov a 4 dĺžky vstupného okna. Tento prístup zvyšuje výpočtovú náročnosť experimentov, no zároveň umožňuje samostatne vyhodnotiť správanie modelu pre rôzne časové horizonty a rôzne množstvo historickej informácie.

Pri trénovaní boli použité súbory `train_omni.csv` ako trénovacia množina a `test_omni.csv` ako testovacia množina. Z trénovacej množiny bola následne vytvorená validačná časť bez náhodného premiešania dát. Validácia bola vytvorená ako posledných 20 % vzoriek trénovacej množiny, čím bolo zachované chronologické usporiadanie časového radu a nedošlo k porušeniu časového charakteru problému.

V experimentoch boli testované štyri základné konfigurácie vstupných premenných:

- **DST** – vstupným atribútom bol iba index DST,
- **DST+V** – vstupnými atribútmi boli DST a rýchlosť slnečného vetra `v`,
- **DST+BZ_GSM** – vstupnými atribútmi boli DST a zložka magnetického poľa `bz_gsm`,
- **DST+BZ_GSM+V** – vstupnými atribútmi boli DST, `v` a `bz_gsm`.

Cieľová premenná bola v každom behu definovaná ako jedna konkrétna budúca hodnota indexu DST, teda DST+1, DST+2, ..., DST+6. Pred vytvorením sekvencií boli pre každý beh vybrané iba potrebné stĺpce, konkrétne časová značka, zvolené vstupné premenné a cieľová premenná pre daný predikčný horizont. Vstupné aj cieľové hodnoty boli štandardizované pomocou metódy `StandardScaler`. Jeden scaler bol použitý pre vstupné atribúty a druhý pre cieľovú premennú. Štandardizácia bola fitovaná výhradne na trénovacích dátach a následne aplikovaná na validačnú a testovaciu množinu.

Po štandardizácii boli dáta prevedené na časové sekvencie pomocou triedy `TimeseriesGenerator` z knižnice TensorFlow/Keras. Dĺžka sekvencie bola určená parametrom `n_input`, ktorý nadobúdal hodnoty 6, 12, 18 alebo 24 hodín. Veľkosť dávky bola vo všetkých experimentoch nastavená na hodnotu 256.

6.3.1 BiLSTM

Základný model bol navrhnutý ako rekurentná neurónová sieť typu Bidirectional Long Short-Term Memory určená na spracovanie časových radov. Model produkoval jednu numerickú predikciu cieľovej premennej pre zvolený predikčný horizont. Architektúra modelu pozostávala z nasledujúcich vrstiev:

- **Vstupná vrstva** – vstup modelu mal tvar `(n_input, atr_count)`, kde `n_input` predstavuje dĺžku vstupného časového okna a `atr_count` počet použitých vstupných atribútov.
- **Bidirectional LSTM vrstva** – dvojsmerná LSTM vrstva so 128 jednotkami, ktorá vracia výstupy pre všetky časové kroky sekvencie. V tejto vrstve bol použitý `dropout` aj `recurrent_dropout` s hodnotou 0.1, čím sa obmedzuje riziko preučenia modelu. Dvojsmerné spracovanie umožňuje modelu učiť sa závislosti v dátach v doprednom aj spätnom časovom smere.
- **LSTM vrstva** – druhá LSTM vrstva so 128 jednotkami, ktorá taktiež vracia celú výstupnú sekvenciu. Táto vrstva nadväzuje na predchádzajúcu dvoj-

smernú vrstvu a slúži na hlbšie zachytenie časových závislostí vo vstupných údajoch.

- **TimeDistributed Dense vrstva** – časovo distribuovaná plne prepojená vrstva s jedným neurónom a lineárnou aktivačnou funkciou. Táto vrstva aplikuje rovnakú transformáciu na každý časový krok výstupnej sekvencie osobitne.
- **Flatten vrstva** – vrstva, ktorá transformuje viacrozmerný výstup predchádzajúcej vrstvy na jednorozmerný vektor, aby mohol byť ďalej spracovaný klasickou hustou vrstvou.
- **Dense vrstva** – výstupná hustá vrstva s jedným neurónom a lineárnou aktivačnou funkciou, ktorá produkuje finálnu predikovanú hodnotu. Z dôvodu lineárnej aktivácie je model vhodný na riešenie regresnej úlohy.

Pri kompilácii modelu bola použitá stratová funkcia Mean Squared Error (MSE), optimalizátor Adam a metrika Mean Absolute Error (MAE). Stratová funkcia MSE penalizuje väčšie chyby výraznejšie než menšie, čím vedie model k minimalizácii väčších odchýlok medzi predikovanými a skutočnými hodnotami. Optimalizátor Adam adaptívne upravuje veľkosť kroku učenia pre jednotlivé parametre modelu, čo prispieva k rýchlej a stabilnej konvergencii počas tréningu. Metrika MAE slúžila na priebežné hodnotenie kvality modelu, pričom poskytuje jednoducho interpretovateľnú informáciu o priemernej absolútnej chybe predikcie.

Model bol trénovaný maximálne 200 epoch. Počas trénovania sa pomocou callbacku `ModelCheckpoint` ukladal vždy model s najlepšou hodnotou validačnej metriky MAE. Na obmedzenie preučenia sa okrem dropout regularizácie využívala aj metóda `EarlyStopping`, ktorá zastavila tréning v prípade, že sa hodnota MAE na validačných dátach nezlepšila počas 25 po sebe nasledujúcich epoch. Kritériom výberu najlepšieho modelu bolo minimum hodnoty `val_mae`.

Sumarizácia architektúry modelu je uvedená na Obrázku 6 – 1.

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 6, 3)	0
bidirectional (Bidirectional)	(None, 6, 256)	135,168
lstm_1 (LSTM)	(None, 6, 128)	197,120
time_distributed (TimeDistributed)	(None, 6, 1)	129
flatten (Flatten)	(None, 6)	0
dense_1 (Dense)	(None, 1)	7

Total params: 332,424 (1.27 MB)

Trainable params: 332,424 (1.27 MB)

Non-trainable params: 0 (0.00 B)

Obrázok 6 – 1 Architektúra modelu BiLSTM

6.3.2 BiLSTM a Gaussian Process

Základný BiLSTM model bol následne rozšírený o Gaussian Process regresiu, čím vznikol hybridný model typu BiLSTM + GP. Cieľom tohto rozšírenia bolo nielen zlepšiť bodovú presnosť predikcie, ale aj získať informáciu o neistote predikovaných hodnôt vo forme intervalového odhadu.

Po natrénovaní základného BiLSTM modelu bol vytvorený embedding model, ktorý vracal vnútornú reprezentáciu zo skrytej vrstvy neurónovej siete. Táto embeddingová reprezentácia bola následne použitá ako vstup pre Gaussian Process regresiu. Oproti jednoduchému použitiu časového indexu tak GP nepracoval iba s informáciou o čase, ale s reprezentáciou, ktorú si BiLSTM model vytvoril počas učenia časových závislostí.

Najskôr boli pomocou natrénovaného BiLSTM modelu vygenerované predikcie

pre trénovaciu, validačnú a testovaciu množinu. Keďže vstupné sekvencie boli vytvárané pomocou `TimeseriesGenerator`, skutočné cieľové hodnoty bolo potrebné časovo zosúladiť s výstupmi generátora. Následne sa vypočítali reziduá modelu, teda rozdiel medzi skutočnými hodnotami a predikciami BiLSTM modelu. Tieto reziduá predstavujú časť informácie, ktorú samotný neurónový model nedokázal zachytiť.

Z embeddingov trénovacej a validačnej časti bola vytvorená spoločná trénovacia množina pre Gaussian Process. GP sa neučil predikovať pôvodnú cieľovú premennú, ale reziduálnu chybu základného BiLSTM modelu. Finálna hybridná predikcia potom vznikla ako súčet pôvodnej predikcie BiLSTM modelu a odhadu rezidua získaného pomocou GP:

$$\hat{y}_{\text{BiLSTM+GP}} = \hat{y}_{\text{BiLSTM}} + \hat{r}_{\text{GP}}.$$

Týmto spôsobom GP vykonáva korekciu výstupu neurónovej siete, čo môže viesť k zlepšeniu výslednej presnosti modelu.

Pre Gaussian Process bol použitý kernel zložený z konštantného jadra, RBF jadra a `WhiteKernel`:

$$\texttt{ConstantKernel} \times \texttt{RBF} + \texttt{WhiteKernel}.$$

Konštantné jadro umožňuje škálovať celkovú variabilitu modelu, RBF jadro zachytáva hladké nelineárne vzťahy v embeddingovom priestore a `WhiteKernel` modeluje šum prítomný v reziduách. Pri trénovaní GP boli použité nastavenia `alpha = 1e-2`, `normalize_y = True`, `n_restarts_optimizer = 2` a `random_state = 42`.

Z dôvodu výpočtovej a pamäťovej náročnosti Gaussian Process regresie bolo pri väčšom počte vzoriek použité náhodné podvzorkovanie trénovacích dát. Maximálny počet bodov použitých na trénovanie GP bol obmedzený na hodnotu 5000. Ak mala embeddingová trénovacia množina viac vzoriek, náhodne sa z nej vybralo najviac 5000 bodov.

Významnou výhodou použitia Gaussian Process je aj možnosť odhadu neistoty. GP okrem strednej hodnoty reziduálnej korekcie predikuje aj smerodajnú odchýlku, ktorá bola použitá na odvodenie intervalov spoľahlivosti okolo hybridnej predikcie.

Takto navrhnutý hybridný model teda neposkytuje iba bodovú predikciu, ale aj informáciu o miere neistoty, čo je pri modelovaní časových radov veľmi prínosné.

Model na dátach udalostí

Popri modeloch trénovaných na kontinuálnom časovom rade bol navrhnutý aj hybridný model typu BiLSTM + GP aplikovaný na dataset pozostávajúci z identifikovaných geomagnetických udalostí. Cieľom tohto prístupu bolo overiť kvalitu predikcie v prípade, keď model nepracuje so súvislým časovým radom, ale so samostatne vyčlenenými udalosťami. Zároveň tento prístup umožňuje analyzovať nielen bodovú presnosť predikcie, ale aj odhad neistoty a pravdepodobnostnú klasifikáciu vybraných stavov geomagnetickej aktivity.

Pri event-based prístupe bola riešená viac-horizontová regresná aj klasifikačná predikcia hodnôt indexu DST v rámci identifikovaných geomagnetických udalostí. Na rozdiel od kontinuálneho prístupu nebol trénovaný samostatný model pre každý predikčný horizont. Použitý bol jeden spoločný multihorizon model, ktorý pre každý vstupný úsek predikoval naraz šesť budúcich hodnôt indexu DST, konkrétne DST+1, DST+2, DST+3, DST+4, DST+5 a DST+6. Výstup modelu bol teda viacrozmerný a obsahoval predikcie pre všetky uvažované horizonty súčasne.

Ako vstupný dataset bol použitý súbor `event_omni_prepared.csv`. Dataset obsahoval identifikátor udalosti `event_no`, časovú značku `time1`, vstupné atribúty `dst`, `bz_gsm` a `v` a cieľové stĺpce `DST+1` až `DST+6`. Dáta boli zoradené podľa identifikátora udalosti a časovej značky, čím bolo zachované časové usporiadanie meraní v rámci jednotlivých udalostí.

V experimentoch boli testované štyri konfigurácie vstupných atribútov:

- **dst_only** – vstupným atribútom bol iba index `dst`,
- **dst_v** – vstupnými atribútmi boli `dst` a rýchlosť slnečného vetra `v`,
- **dst_bz** – vstupnými atribútmi boli `dst` a zložka magnetického poľa `bz_gsm`,

- **dst__bz__v** – vstupnými atribútmi boli `dst`, `bz_gsm` a `v`.

Pre každý set boli testované štyri dĺžky vstupného okna, a to 6, 12, 18 a 24 hodín. Základná experimentálna mriežka teda pozostávala zo 16 behov, keďže boli kombinované 4 konfigurácie vstupných atribútov a 4 dĺžky vstupného okna. Každý z týchto behov zároveň predikoval všetkých 6 horizontov naraz.

Rozdelenie dát bolo realizované na úrovni celých udalostí, nie na úrovni jednotlivých časových bodov. Tento postup je metodicky dôležitý, pretože merania patriace do jednej geomagnetickej udalosti nemajú byť rozdelené medzi trénovaciu, validačnú a testovaciu množinu. Takéto rozdelenie znižuje riziko úniku informácie medzi množinami a umožňuje realistickejšie hodnotenie schopnosti modelu generalizovať na doteraz nevidené udalosti.

Pre každú udalosť bol najskôr vytvorený sumarizačný záznam obsahujúci začiatok udalosti, koniec udalosti, počet riadkov a minimálnu hodnotu indexu DST. Na základe minimálnej hodnoty DST boli udalosti rozdelené do skupín závažnosti, napríklad `extreme`, `strong`, `moderate`, `mild` a `other`. Následné rozdelenie na trénovaciu, validačnú a testovaciu množinu bolo vykonané približne v pomere 70 %, 15 % a 15 %. Pri dostatočnej početnosti tried bolo rozdelenie stratifikované podľa skupiny závažnosti udalosti.

Sekvencie boli vytvárané osobitne v rámci každej udalosti. Pre každý časový krok bolo ako vstup použitých posledných n hodinových meraní, kde n predstavovalo zvolenú dĺžku vstupného okna. Tým sa zabezpečilo, že vstupné okná ani cieľové hodnoty nevznikali cez hranice rôznych udalostí. Na rozdiel od kontinuálneho prístupu bol cieľom pre každý vstupný úsek vektor šiestich budúcich hodnôt:

$$[DST + 1, DST + 2, DST + 3, DST + 4, DST + 5, DST + 6].$$

Výsledkom tvorby sekvencií bol vstupný tenzor tvaru

$$(\text{počet vzoriek}, \text{lookback}, \text{počet atribútov})$$

a cieľová matica tvaru

$$(\text{počet vzoriek}, 6).$$

Vstupné aj cieľové hodnoty boli štandardizované pomocou metódy `StandardScaler`. Scaler pre vstupné premenné bol fitovaný iba na trénovacích vstupoch a scaler pre cieľové premenné iba na trénovacích cieľoch. Následne boli rovnaké transformácie aplikované na validačnú a testovaciu množinu.

6.3.3 BiLSTM a Gaussian Process na dátach udalostí

Pre dáta udalostí bol použitý kompaktnejší multihorizon model typu BiLSTM. Architektúra modelu pozostávala z nasledujúcich vrstiev:

- **Vstupná vrstva** – vstup modelu mal tvar `(lookback, n_features)`, kde `lookback` predstavuje dĺžku vstupného časového okna a `n_features` počet použitých vstupných atribútov.
- **Bidirectional LSTM vrstva** – bidirekčná LSTM vrstva so 64 skrytými jednotkami. Táto vrstva spracúva vstupnú sekvenciu v doprednom aj spätnom smere, vďaka čomu môže zachytávať časové závislosti v rámci vstupného okna.
- **Dropout vrstva** – dropout vrstva s hodnotou 0.2, ktorá slúži ako regularizačný prvok a pomáha obmedziť riziko preučenia modelu.
- **Embedding Dense vrstva** – hustá vrstva so 64 neurónmi a aktivačnou funkciou ReLU. Táto vrstva vytvára latentnú reprezentáciu vstupnej sekvencie, ktorá je následne využitá aj pri hybridnej korekcii pomocou Gaussian Process regresie.
- **Výstupná Dense vrstva** – hustá výstupná vrstva so šiestimi neurónmi, ktorá produkuje predikcie pre horizonty DST+1 až DST+6.

Model bol kompilovaný s optimalizátorom Adam s krokom učenia 10^{-3}. Ako stratová funkcia bola použitá Huberova strata s parametrom `delta = 1.0` a ako hodnotiaca metrika Mean Absolute Error. Huberova strata je vhodná pri časových

radoch geomagnetickej aktivity, pretože je robustnejšia voči odľahlým hodnotám než samotná MSE, pričom stále zachováva vlastnosti regresnej stratovej funkcie.

Pri trénovaní boli použité hyperparametre `epochs = 50`, `batch_size = 256`, `hidden = 64`, `dropout = 0.2` a `patience = 8`. Na riadenie tréningu boli využité callbacky `EarlyStopping` a `ReduceLROnPlateau`, pričom oba monitorovali hodnotu validačnej metriky `val_mae`. Callback `EarlyStopping` bol použitý s nastavením `restore_best_weights = True`, aby boli po ukončení tréningu obnovené váhy modelu s najlepšou validačnou hodnotou. Callback `ReduceLROnPlateau` znižoval learning rate pri stagnácii validačnej chyby, pričom bol použitý faktor zníženia 0.5 a minimálna hodnota learning rate bola nastavená na 10^{-5}.

Ako referenčný benchmark bol použitý persistence model. Jeho predikcia vznikla tak, že posledná známa hodnota indexu DST vo vstupnom okne bola zopakovaná pre všetkých šesť budúcich horizontov. Tento jednoduchý a interpretovateľný baseline slúžil na porovnanie s neurónovým modelom aj hybridným modelom BiLSTM + GP.

Po natrénovaní základného BiLSTM modelu boli vypočítané predikcie v štandardizovanej škále a následne reziduá medzi skutočnými cieľovými hodnotami a predikciami modelu:

$$r = y_{\text{true}} - \hat{y}_{\text{BiLSTM}}.$$

Z embeddingovej Dense vrstvy bol zároveň získaný vnútorný reprezentačný priestor modelu. Tento latentný priestor slúžil ako vstup pre Gaussian Process regresiu. GP sa teda neučil závislosť reziduálnej chyby od časového indexu, ale od príznakov reprezentujúcich vnútorný opis vstupnej sekvencie vytvorený neurónovou sieťou.

Pre každý predikčný horizont bol trénovaný samostatný Gaussian Process model, ktorý predikoval reziduálnu chybu daného horizontu. Finálna hybridná predikcia vznikla ako súčet pôvodnej BiLSTM predikcie a korekcie rezidua odhadnutej pomocou GP:

$$\hat{y}_{\text{BiLSTM+GP}} = \hat{y}_{\text{BiLSTM}} + \hat{r}_{\text{GP}}.$$

Týmto spôsobom Gaussian Process vykonával korekciu výstupu základného neuró-

nového modelu osobitne pre každý z predikčných horizontov.

Na modelovanie reziduí bol použitý kernel v tvare

$$\texttt{ConstantKernel} \times \texttt{RBF} + \texttt{WhiteKernel}.$$

Konštantné jadro umožňuje škálovať celkovú variabilitu modelu, RBF jadro modeluje hladké nelineárne vzťahy v priestore latentných reprezentácií a `WhiteKernel` zachytáva šumovú zložku reziduí. Pri trénovaní GP boli použité nastavenia `alpha = 1e-2`, `normalize_y = True`, `gp_restarts = 1` a `random_state = 42 + horizon`.

Vzhľadom na výpočtovú náročnosť Gaussian Process regresie bolo použité podvzorkovanie embeddingovej trénovacej množiny. Maximálny počet bodov pre trénovanie GP bol nastavený na hodnotu 4000. Ak mala trénovacia množina embeddingov viac bodov, náhodne sa vybrala podmnožina tejto veľkosti. Tento krok umožnil zachovať praktickú realizovateľnosť hybridného modelu aj pri väčšom počte vzoriek.

Každý Gaussian Process model poskytoval okrem strednej hodnoty reziduálnej korekcie aj smerodajnú odchýlku predikcie. Táto smerodajná odchýlka bola transformovaná späť do pôvodnej škály cieľovej premennej a použitá pri konštrukcii intervalov neistoty. Pri regresnom hodnotení hybridného modelu boli okrem bodových metrík vyhodnocované aj intervalové metriky PICP a MPIW pre 90 % a 95 % intervaly. Metrika PICP vyjadruje podiel skutočných hodnôt zachytených predikčným intervalom a metrika MPIW vyjadruje priemernú šírku týchto intervalov.

Regresné hodnotenie bolo realizované samostatne pre tri modelové prístupy: persistence, BiLSTM a BiLSTM + GP. Pre každý predikčný horizont boli počítané metriky MAE a RMSE. Takéto vyhodnotenie umožňuje porovnať výkonnosť jednoduchého referenčného modelu, základného neurónového modelu a hybridného modelu s reziduálnou korekciou.

Okrem regresného hodnotenia bola vykonaná aj klasifikačná interpretácia predikcie. Hodnotenie bolo realizované pre dva prahy geomagnetickej aktivity:

$$DST \leq -20 \text{ nT}$$

a

$$DST \leq -50 \text{ nT}.$$

Pri persistence modeli a samotnom BiLSTM modeli bola klasifikácia určená priamym porovnaním bodovej predikcie s daným prahom. Pri hybridnom modeli BiLSTM + GP bol použitý pravdepodobnostný prístup. Zo strednej hodnoty predikcie a odhadnutej smerodajnej odchýlky bola vypočítaná pravdepodobnosť, že hodnota DST bude menšia alebo rovná zvolenému prahu. Na validačnej množine bol následne hľadaný najlepší klasifikačný cutoff v intervale 0.10 až 0.90 a tento cutoff bol aplikovaný na testovaciu množinu.

Pri klasifikačnom hodnotení boli použité metriky precision, recall, F1-score, Matthews correlation coefficient, `positive_rate_true` a `positive_rate_pred`. Tieto metriky umožňujú posúdiť nielen celkovú presnosť klasifikačnej interpretácie, ale aj schopnosť modelu zachytávať prípady zodpovedajúce zvýšenej geomagnetickej aktivite.

Výstupom experimentu boli uložené modely, CSV súbory s predikciami, súhrnné regresné a klasifikačné metriky, prehľad jednotlivých behov a rozdelenia udalostí na trénovaciu, validačnú a testovaciu množinu. Predikčné CSV súbory obsahovali pre každý horizont skutočnú hodnotu, persistence predikciu, BiLSTM predikciu, BiLSTM + GP predikciu, hodnotu `sigma` z GP a pravdepodobnosti prekročenia prahov DST ≤ -20 nT a DST ≤ -50 nT.

Navrhnutý model na dátach udalostí sa metodicky odlišuje od kontinuálneho prístupu najmä tým, že používa jeden spoločný multihorizon model so šiestimi výstupmi. Sekvencie sú vytvárané samostatne v rámci jednotlivých geomagnetických udalostí a rozdelenie dát prebieha na úrovni celých eventov. Hybridná časť modelu využíva Gaussian Process regresiu nad latentnými reprezentáciami BiLSTM modelu, pričom pre každý horizont je trénovaný samostatný GP korektor reziduálnej chyby. Tento prístup umožňuje analyzovať presnosť bodovej predikcie, kvalitu odhadu neistoty aj klasifikačné správanie modelu pri nových geomagnetických udalostiach.

6.4 Experimenty

Experimentálna časť práce bola navrhnutá s cieľom systematicky overiť vplyv viacerých faktorov na kvalitu predikcie indexu Dst. Zamerali sme sa najmä na dĺžku vstupného časového okna, výber vstupných atribútov, použitie hybridného modelu LSTM + Gaussian Process a na porovnanie prístupu založeného na kontinuálnych dátach s prístupom založeným na dátach vybraných udalostí.

Vplyv dĺžky vstupného okna

V prvej sérii experimentov sme sa zamerali na vplyv dĺžky vstupného časového okna na schopnosť modelu predikovať budúci vývoj indexu Dst. Modely boli navrhnuté tak, aby predikovali hodnotu indexu Dst v horizonte 1 až 6 hodín dopredu. Pri každom predikčnom horizonte boli postupne testované vstupné sekvencie vytvorené z predchádzajúcich 6, 12, 18 a 24 hodín. Cieľom tejto série experimentov bolo overiť, či väčší časový kontext dokáže zlepšiť schopnosť modelu zachytiť dynamiku časového radu a či existuje vhodná dĺžka vstupného okna pre jednotlivé predikčné horizonty. Zároveň sme týmto postupom sledovali, ako sa mení náročnosť úlohy pri krátkodobej a dlhšej predikcii.

Porovnanie s perzistentným modelom

Druhá séria experimentov bola zameraná na porovnanie navrhnutých modelov s perzistentným prístupom. Cieľom tohto experimentu bolo overiť, či modely trénované na kontinuálnych dátach dokážu prekonať jednoduchú referenčnú stratégiu, pri ktorej sa budúca hodnota indexu Dst odhaduje na základe poslednej známej hodnoty. Takýto prístup predstavuje pri časových radoch naivný model, keďže pri vysokej autokorelácii dát môže dosahovať pomerne dobré výsledky aj bez zložitejšieho modelovania.

Porovnanie s perzistenciou bolo realizované pre tie isté predikčné horizonty a dĺžky vstupných okien ako pri ostatných experimentoch na kontinuálnych dátach. Sledo-

vali sme, do akej miery dokážu modely zachytiť budúce zmeny vývoja indexu Dst skôr, než by to umožnil perzistentný prístup. Zámerom teda nebolo iba porovnať číselné hodnoty chýb, ale aj overiť, či modely nevykazujú tendenciu správať sa podobne ako perzistentný model, teda či iba nekopírujú posledný známy stav časového radu s určitým oneskorením.

Tento experiment bol realizovaný iba na kontinuálnych dátach. Pri datasete udalostí sa samostatné porovnanie s perzistentným modelom nevykonávalo, keďže cieľom tejto časti bolo predovšetkým overenie hybridného prístupu LSTM + Gaussian Process na samostatne vyčlenených geomagnetických eventoch a analýza jeho predikčnej stability.

Vplyv Gaussian Process

Ďalšia séria experimentov bola zameraná na overenie prínosu Gaussian Process regresie v hybridnom modeli LSTM + GP. V tomto prípade bol základný LSTM model doplnený o Gaussian Process, ktorého úlohou bolo modelovať reziduálnu chybu LSTM predikcie. Cieľom tohto experimentu bolo preskúmať, či doplnenie Gaussian Process dokáže zlepšiť výslednú bodovú predikciu indexu Dst oproti samostatnému LSTM modelu. Súčasne sme sledovali aj druhý významný aspekt tohto prístupu, a to možnosť získať odhad neistoty predikcie vo forme intervalov spoľahlivosti. Hybridný model tak nebol navrhnutý iba ako nástroj na zlepšenie presnosti, ale aj ako prostriedok na rozšírenie interpretovateľnosti výsledkov o informáciu o ich spoľahlivosti.

Vplyv vstupných atribútov

Osobitnú skupinu experimentov tvorilo porovnanie rôznych kombinácií vstupných atribútov. Vychádzali sme z predpokladu, že samotná história indexu Dst nemusí byť jediným zdrojom informácie relevantným pre predikciu budúceho vývoja geomagnetickej aktivity. Preto boli postupne testované štyri varianty vstupov: samotný atribút Dst, kombinácia Dst a V, kombinácia Dst a Bz_GSM a napokon kombinácia Dst,

v a Bz_GSM. Cieľom tejto série experimentov bolo overiť, do akej miery doplnkové fyzikálne premenné prispievajú k lepšiemu zachyteniu vývoja indexu Dst a či ich zahrnutie vedie k zlepšeniu predikčných schopností modelu. Takto bolo možné porovnať, či model profituje len z historických hodnôt cieľovej premennej, alebo aj z informácie obsiahnutej v ďalších atribútoch súvisiacich s geomagnetickou aktivitou.

Experimenty na dátach udalostí

Popri experimentoch na kontinuálnom datasete sme navrhli aj experimentálny scenár založený na datasete udalostí. V tomto prípade išlo o hybridný model LSTM + Gaussian Process aplikovaný na dáta pozostávajúce z vybraných geomagnetických eventov. Na rozdiel od kontinuálneho časového radu boli vstupné sekvencie vytvárané samostatne pre jednotlivé udalosti, aby sa zabránilo prepájaniu rôznych eventov v rámci jednej sekvencie. V tomto nastavení sme opäť ako vstupné atribúty použili kombinácie premenných Dst, V a Bz_GSM. Cieľom tohto experimentu bolo overiť, či model trénovaný na osobitne vyčlenených udalostiach dokáže poskytovať kvalitnú predikciu alebo dokonca prekonať presnosť predikcie na kontinuálnych dátach.

Dôležitým aspektom navrhnutých experimentov bolo aj to, že všetky boli formulované ako regresná úloha, teda ako predikcia konkrétnej hodnoty indexu Dst. Následne bolo možné z týchto predikovaných hodnôt odvodiť aj binárnu klasifikáciu do tried „búrka nastala“ a „búrka nenastala“. Takýto dvojstupňový prístup umožnil analyzovať modely nielen z pohľadu presnosti numerickej predikcie, ale aj z pohľadu ich praktickej použiteľnosti pri identifikácii geomagnetických búrok.

Navrhnuté experimenty tak vytvárajú ucelený rámec na porovnanie viacerých faktorov, ktoré môžu ovplyvniť výslednú kvalitu predikcie. Ich cieľom nebolo len nájsť čo najpresnejší model, ale aj lepšie pochopiť, aký význam má rozsah historického kontextu, výber vstupných premenných, použitie hybridného prístupu a typ použitého datasetu. Konkrétne výsledky týchto experimentov a ich interpretácia sú uvedené v nasledujúcej časti práce.

6.5 Vyhodnotenie

V tejto časti práce vyhodnocujeme výsledky navrhnutých experimentov z pohľadu regresnej predikcie indexu Dst, následnej binárnej klasifikácie a v prípade hybridných modelov aj z pohľadu odhadu neistoty. Výsledky analyzujeme samostatne pre experimenty na kontinuálnych dátach a pre experimenty na dátach udalostí.

Vplyv dĺžky vstupného časového okna

Pri kontinuálnych dátach boli testované vstupné okná s dĺžkou 6, 12, 18 a 24 hodín pre horizonty 1 až 6 hodín dopredu. Z agregovaných výsledkov vyplýva, že s rastúcou dĺžkou vstupného okna sa priemerné chyby mierne znižovali, avšak tento efekt nebol absolútny a najlepšia konfigurácia sa menila podľa predikčného horizontu. Priemerná MAE naprieč všetkými kontinuálnymi konfiguráciami klesla z hodnoty 4.893 pri 6-hodinovom okne na 4.810 pri 24-hodinovom okne. Podobne priemerná MSE klesla z 62.519 na 60.565.

Z pohľadu najlepších konfigurácií podľa jednotlivých horizontov sa ukázalo, že 24-hodinové okno bolo najlepšie pre tri horizonty, 18-hodinové pre dva horizonty a 6-hodinové pre jeden horizont. To naznačuje, že väčší historický kontext býva vo všeobecnosti prínosný, ale jeho efekt nie je monotónny a optimálna dĺžka vstupu závisí od konkrétneho predikčného horizontu. Inými slovami, neplatí, že čím dlhšie vstupné okno model dostane, tým lepšie bude predikovať vo všetkých situáciách.

Pri eventových dátach sa ako najlepší set ukázal variant `dst_bz_v` a aj tu sa optimálne vstupné okno menilo podľa horizontu. Pre horizonty 1 a 2 hodiny bolo najlepšie 18-hodinové okno, pre horizonty 3 a 4 hodiny 6-hodinové okno, pre horizont 5 hodín 12-hodinové okno a pre horizont 6 hodín 24-hodinové okno. Zaujímavé je, že pri pohľade na priemernú MAE naprieč všetkými horizontmi bolo práve 6-hodinové okno najlepšie pre všetky testované eventové sety.

Porovnanie s perzistentným modelom

Porovnanie s perzistentným modelom ukázalo, že najlepšie kontinuálne konfigurácie prekonali perzistenciu vo všetkých skúmaných horizontoch. Percentuálne zlepšenie najlepších konfigurácií oproti perzistentnému modelu sa pri MAE pohybovalo od 13.37% do 16.55% a pri MSE od 18.33% do 31.64%. Z aktuálnych výsledkov teda vyplýva, že navrhnuté modely prinášajú voči perzistentnému prístupu stabilnú pridanú hodnotu.

Najlepšie kontinuálne konfigurácie podľa horizontu sú:

Horizont	Atribúty	Model	Okno [h]	Zlepšenie MAE [%]	Zlepšenie MSE [%]
1	Dst+V+Bz_GSM	LSTM+GP	6	13.37	18.33
2	Dst+V+Bz_GSM	LSTM	18	14.17	30.68
3	Dst+V+Bz_GSM	LSTM	24	14.57	31.64
4	Dst+Bz_GSM	LSTM	24	13.87	28.23
5	Dst+V+Bz_GSM	LSTM	24	15.68	31.33
6	Dst+V+Bz_GSM	LSTM	18	16.55	31.28

Tabuľka 6 – 1 Zlepšenie najlepších kontinuálnych konfigurácií oproti perzistentnému modelu

Pri eventových dátach bol hybridný model BiLSTM+GP v najlepších konfiguráciách lepší než perzistencia vo všetkých horizontoch. Zlepšenie najlepších konfigurácií oproti perzistentnému modelu sa pohybovalo od 7.92% do 17.91% podľa MAE. Najväčšie zlepšenie bolo dosiahnuté pri horizonte 6 hodín, kde najlepšia konfigurácia znížila MAE približne o 17.91%.

Prínos Gaussian Process regresie

Pri kontinuálnych dátach sa prínos Gaussian Process nepotvrdil ako všeobecne prospešný. Naopak, priemerné výsledky naznačujú, že vo všetkých štyroch vstupných variantoch dosiahol lepšie priemerné regresné aj klasifikačné výsledky samotný LSTM model než hybridný LSTM+GP. Napríklad pri sete Dst+V+Bz_GSM dosiahol LSTM priemernú MAE 4.619 a priemernú MSE 55.266, zatiaľ čo LSTM+GP

dosiahol priemernú MAE 4.803 a MSE 59.429. Podobný trend sa ukázal aj pri ostatných setoch.

Tento záver podporuje aj detailnejší pohľad na jednotlivé konfigurácie. Zo 96 porovnateľných dvojíc konfigurácií bol LSTM+GP lepší než LSTM podľa MAE iba v 10 prípadoch a podľa MSE iba v 4 prípadoch. Pri sete `dst_bz_v` bol hybridný model lepší v MAE len v 3 z 24 konfigurácií a v MSE ani v jednej. Z toho vyplýva, že na aktuálne nahratých kontinuálnych výsledkoch nemožno tvrdiť, že Gaussian Process vo všeobecnosti zlepšoval základný LSTM model. Korektnejšia formulácia je, že prínos GP sa objavil len v jednotlivých konkrétnych konfiguráciách, pričom najvýraznejšie sa prejavil pri horizonte 1 hodina dopredu.

Pri eventových dátach je situácia priaznivejšia, ale opäť nie úplne jednoznačná. Priemerné výsledky ukazujú, že BiLSTM+GP bol vo všetkých setoch lepší než samotný BiLSTM aj perzistencia. Najlepší priemerný výsledok dosiahol set `dst_bz_v`, kde priemerná MAE modelu BiLSTM+GP bola 8.418, priemerná F1 pri prahu -20 nT bola 0.926 a pri prahu -50 nT bola 0.775. Priemerné zlepšenie oproti perzistentnému modelu tu dosiahlo 9.59% a oproti samotnému BiLSTM 4.06%.

Zároveň však ani pri eventových dátach neplatí, že GP zlepšil výsledky v každej jednotlivej konfigurácii. Pri sete `dst_bz_v` bol BiLSTM+GP lepší než čistý BiLSTM podľa MAE v 9 z 24 konfigurácií, pri `dst_bz` v 13 z 24 konfigurácií, pri `dst_only` v 7 z 24 konfigurácií a pri `dst_v` tiež v 7 z 24 konfigurácií. Preto je vhodné v texte zdôrazniť, že prínos GP na eventových dátach bol v priemere pozitívny, ale závisel od setu a predikčného horizontu.

Bez ohľadu na tieto rozdiely ostáva dôležitým prínosom GP možnosť odhadu neistoty. Hybridný model neposkytuje len bodovú predikciu, ale aj intervaly spoľahlivosti, ktoré sú pri predikcii geomagnetických búrok prakticky cenné, pretože vyjadrujú mieru istoty modelu v jednotlivých časových úsekoch.

Vplyv vstupných atribútov

Pri kontinuálnych dátach boli porovnávané štyri varianty vstupov: Dst, Dst+V, Dst+Bz_GSM a Dst+V+Bz_GSM. Z aktuálnych výsledkov vyplýva, že najlepšie priemerné výsledky dosiahli kombinácie obsahujúce atribút Bz_GSM, konkrétne Dst+V+Bz_GSM a Dst+Bz_GSM. Najlepší priemerný výsledok dosiahol pri aktuálnych CSV samotný LSTM model s atribútmi Dst+V+Bz_GSM, a to s priemernou MAE 4.619, priemernou MSE 55.266, priemernou ACC 0.922 a priemernou MCC 0.763.

Priemerné výsledky na kontinuálnych dátach podľa vstupných atribútov a typu modelu:

Atribúty	Model	MAE	MSE	ACC	MCC
Dst	LSTM	4.906	63.650	0.917	0.745
Dst	LSTM+GP	5.127	68.760	0.911	0.731
Dst+Bz_GSM	LSTM	4.654	56.019	0.922	0.761
Dst+Bz_GSM	LSTM+GP	4.858	60.711	0.917	0.747
Dst+V	LSTM	4.833	62.074	0.917	0.748
Dst+V	LSTM+GP	5.070	67.157	0.912	0.735
Dst+V+Bz_GSM	LSTM	4.619	55.266	0.922	0.763
Dst+V+Bz_GSM	LSTM+GP	4.803	59.429	0.918	0.752

Tabuľka 6 – 2 Priemerné výsledky na kontinuálnych dátach podľa vstupných atribútov a typu modelu

Z týchto hodnôt vyplýva, že dominantný prínos mal atribút `Bz_GSM`. Samotné pridanie atribútu V bez `Bz_GSM` neviedlo k výraznému zlepšeniu. Naopak, kombinácie s `Bz_GSM` boli konzistentne lepšie než varianty bez neho.

Pri eventových dátach sa ako najsilnejší set ukázal `dst_bz_v`, nasledovaný variantom `dst_bz`. Naopak, najslabšie výsledky poskytoval variant `dst_only`. Priemerné výsledky pre eventové dáta boli:

Aj eventové výsledky teda podporujú záver, že `Bz_GSM` je významný vstupný

Set	ø MAE perz.	ø MAE BiLSTM	ø MAE BiLSTM+GP	ø RMSE BiLSTM+GP
dst_only	9.352	8.942	8.980	14.103
dst_v	9.352	8.849	8.893	13.949
`dst_bz`	9.352	8.650	8.533	13.332
dst_bz_v	9.352	8.590	8.418	13.073

Tabuľka 6 – 3 Priemerné výsledky na eventových dátach podľa setu

atribút. Pridanie v v kombinácii s `Bz_GSM` viedlo k ďalšiemu miernemu zlepšeniu, zatiaľ čo bez `Bz_GSM` bol jeho prínos slabší.

Porovnanie výsledkov podľa predikčného horizontu

Pri kontinuálnych dátach sa potvrdil očakávaný trend zhoršovania regresných a klasifikačných výsledkov s rastúcim horizontom predikcie. Najlepšia dosiahnutá MAE vzrástla z 2.2247 pri horizonte 1 hodina dopredu na 6.0117 pri horizonte 6 hodín dopredu. Podobný trend možno pozorovať aj pri MSE, ACC a MCC. Zaujímavé však je, že pri kratších horizontoch dominovala kombinácia Dst+V+Bz_GSM, zatiaľ čo pri horizonte 4 hodiny sa ako najlepšia ukázala kombinácia Dst+Bz_GSM. To potvrdzuje, že optimálne nastavenie modelu závisí od dĺžky predikcie.

Pri eventových dátach bol trend zhoršovania s rastúcim horizontom ešte výraznejší. Najlepšia MAE vzrástla z 3.868 pri horizonte 1 hodina na 11.015 pri horizonte 6 hodín. Napriek tomu sa set `dst_bz_v` ukázal ako najlepší pre všetky horizonty, pričom sa menila len optimálna dĺžka vstupného okna.

Najlepšie výsledky na eventových dátach podľa horizontu:

Horizont	Set	Okno [h]	MAE	RMSE	Zlepš. perz. [%]	Zlepš. BiLSTM [%]	F1 pri −20 nT	F1 pri −50 nT
1	dst_bz_v	18	3.868	5.957	12.53	25.58	0.9670	0.9026
2	dst_bz_v	18	6.381	9.855	11.51	8.48	0.9446	0.8360
3	dst_bz_v	6	8.068	12.664	9.01	2.80	0.9232	0.7826
4	dst_bz_v	6	9.486	14.705	7.92	-1.97	0.9101	0.7420
5	dst_bz_v	12	10.414	16.135	11.37	-2.22	0.9068	0.7150
6	dst_bz_v	24	11.015	17.426	17.91	2.08	0.9085	0.6992

Tabuľka 6 – 4 Najlepšie výsledky na eventových dátach podľa predikčného horizontu

Je vhodné explicitne uviesť, že pri horizonte 4 a 5 hodín bola najlepšia konfigurácia BiLSTM+GP síce stále lepšia než perzistencia, ale podľa MAE už nebola lepšia než samotný BiLSTM. To opäť ukazuje, že prínos GP nie je rovnaký vo všetkých horizontoch.

Výsledky na dátach udalostí

Eventové experimenty boli realizované pre štyri varianty vstupných atribútov a pre vstupné okná dĺžky 6, 12, 18 a 24 hodín. Z pohľadu priemerných výsledkov bol najlepší variant `dst_bz_v`, nasledovaný variantom `dst_bz`. Najslabší variant bol `dst_only`. Celkovo sa ukazuje, že pri eventových dátach zohráva `Bz_GSM` kľúčovú úlohu a jeho kombinácia s atribútom v vedie k najlepším priemerným výsledkom.

Priemerné F1 skóre pri prahu -20 nT sa pri najlepších eventových konfiguráciách pohybovalo približne okolo 0.926, zatiaľ čo pri prahu -50 nT bolo približne 0.775. To znamená, že modely dokázali pomerne spoľahlivo rozlišovať miernejšie aj silnejšie búrkové stavy, hoci klasifikácia pri prísnejšom prahu -50 nT bola prirodzene náročnejšia.

Zároveň sa ukazuje, že priemerná kvalita eventových modelov zostáva relatívne stabilná pri rôznych dĺžkach vstupného časového okna, avšak jednotlivé nastavenia nedosahujú úplne rovnaké výsledky. Priemerná MAE modelu BiLSTM+GP bola 8.545 pre 6-hodinové okno, 8.712 pre 12-hodinové okno, 8.718 pre 18-hodinové okno a 8.849 pre 24-hodinové okno. Z pohľadu priemeru teda najlepšie vychádza 6-hodinové vstupné okno, avšak pri jednotlivých predikčných horizontoch sa optimálna dĺžka vstupného okna mení.

Grafická analýza predikcie počas búrky

Na doplnenie číselných metrík bola vykonaná aj grafická analýza priebehu predikcie počas vybranej geomagnetickej búrky v intervale od 2024-12-31 do 2025-01-03. Jej priebeh možno vidieť na Obrázku 6 – 2 a Obrázku 6 – 3.

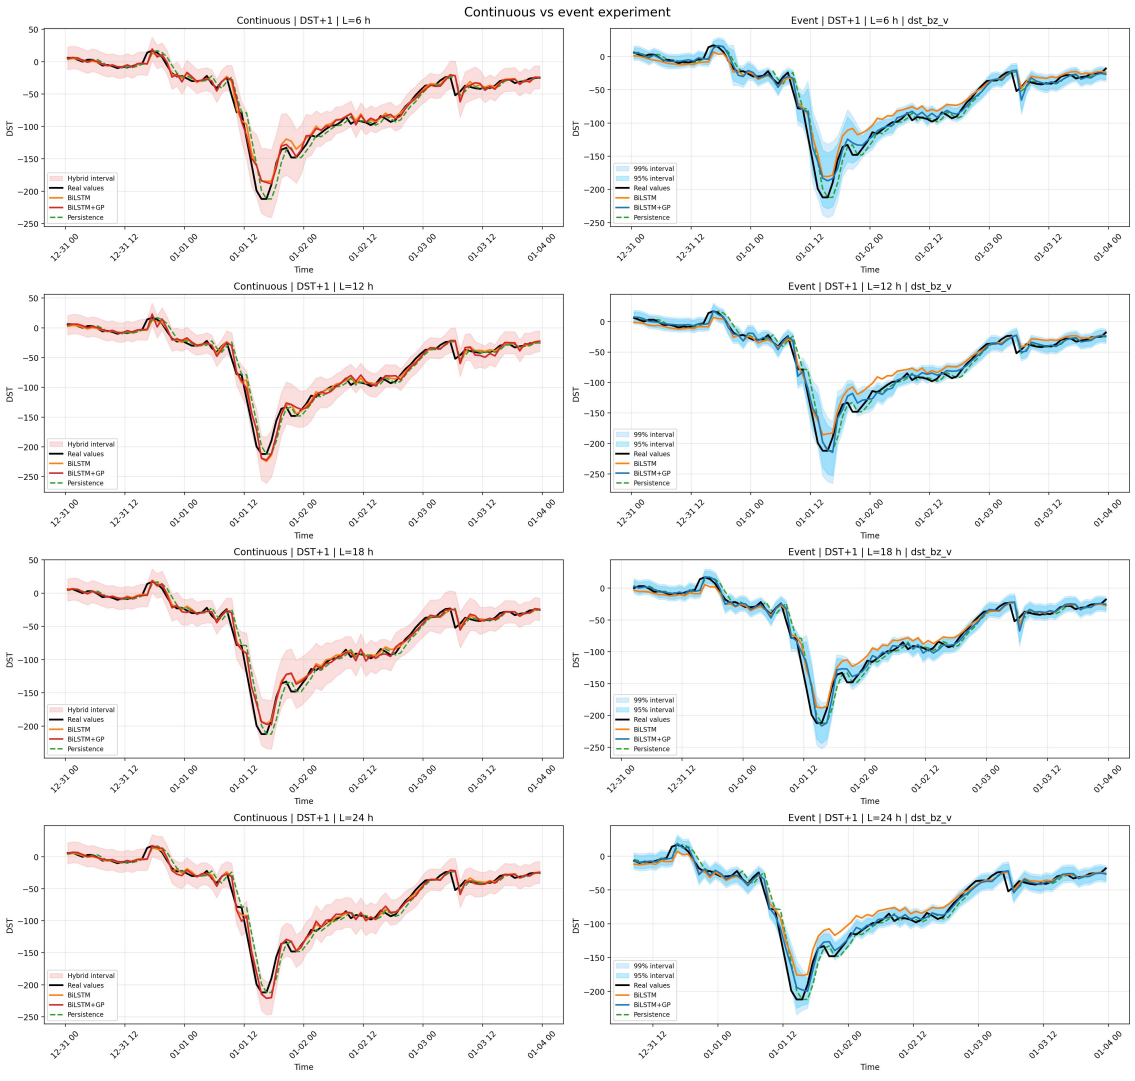

Obrázok 6 – 2 Porovnanie kontinuálneho a eventového prístupu počas vybranej geomagnetickej búrky pre horizont DST+1.

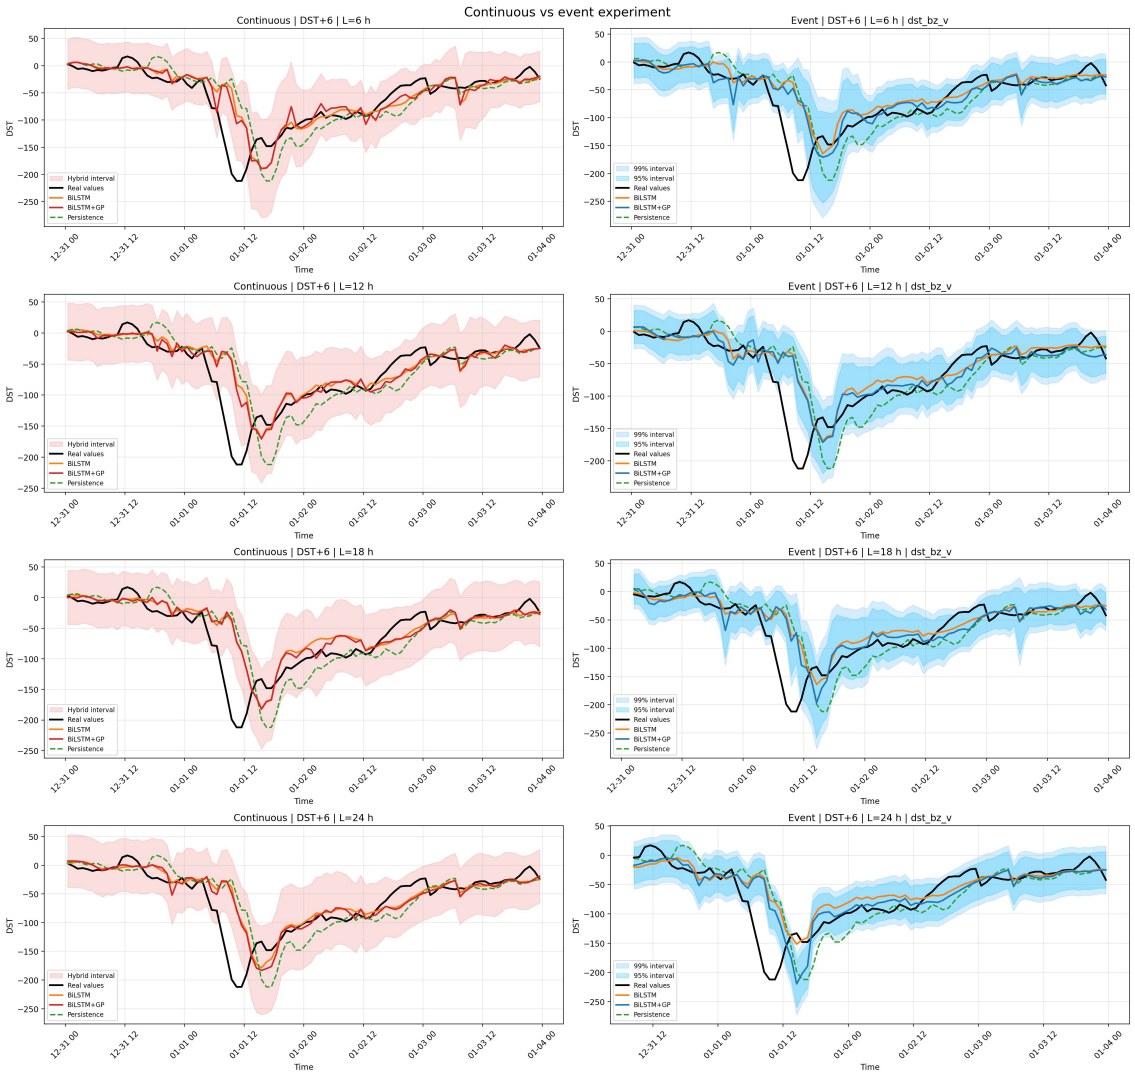

Obrázok 6 – 3 Porovnanie kontinuálneho a eventového prístupu počas vybranej geomagnetickej búrky pre horizont DST+6.

Pri horizonte 1 hodina dopredu dokážu oba prístupy vo všeobecnosti dobre sledovať priebeh skutočných hodnôt indexu Dst vrátane nástupu aj hlavnej fázy búrky. Kontinuálne modely pôsobia mierne vyhladenejšie, zatiaľ čo eventové modely presnejšie zachytávajú hlbšie minimum búrky, najmä pri kratších a stredných vstupných časových oknách. Na druhej strane eventové modely pracujú so širšími intervalmi neistoty, čo naznačuje vyššiu opatrnosť modelu pri odhade extrémnych hodnôt.

Pri horizonte 6 hodín dopredu je rozdiel medzi oboma prístupmi zreteľnejší. V oboch prípadoch dochádza k prirodzenému zhoršeniu presnosti, pričom modely už menej presne vystihujú presnú hĺbku minima aj následnú obnovu indexu Dst. Kontinuálne modely majú tendenciu priebeh viac vyhladzovať, zatiaľ čo eventové modely lepšie zachytávajú celkový tvar búrky, ale za cenu širších intervalov spoľahlivosti. Práve pri dlhšom horizonte je teda viditeľné, že eventový prístup môže byť výhodný z pohľadu stability tvaru predikcie a lepšieho zachytenia dynamiky búrky, hoci bodová chyba zostáva vyššia než pri horizonte 1 hodina.

Z grafickej analýzy preto vyplýva, že eventové modelovanie môže byť užitočné najmä v situáciách, kde je dôležité zachytiť priebeh extrémnej udalosti a zároveň kvantifikovať neistotu predikcie. Zároveň je však potrebné zdôrazniť, že ide o ilustráciu jednej konkrétnej búrky. Pri iných udalostiach sa môže charakter grafov meniť, a preto má grafická analýza slúžiť ako doplnok k numerickým výsledkom, nie ako ich náhrada.

7 Záver

V diplomovej práci sme sa venovali včasnej predikcii geomagnetických búrok prostredníctvom predikcie indexu Dst. Cieľom bolo navrhnúť a vyhodnotiť modely, ktoré dokážu predikovať hodnotu indexu Dst s časovým predstihom 1 až 6 hodín. Okrem samotnej bodovej predikcie sme sa zamerali aj na možnosť odhadu neistoty pomocou Gaussian Process regresie. Experimenty boli realizované na kontinuálnych dátach aj na dátach vybraných geomagnetických udalostí.

Pri kontinuálnych dátach sme testovali rôzne dĺžky vstupného časového okna, konkrétne 6, 12, 18 a 24 hodín, a viaceré kombinácie vstupných atribútov. Výsledky ukázali, že väčší historický kontext môže byť prínosný, avšak optimálna dĺžka vstupného okna sa líšila podľa predikčného horizontu. Najlepšou vstupnou kombináciou bola vo väčšine prípadov kombinácia `Dst+V+Bz_GSM`. Zároveň sa potvrdilo, že atribút `Bz_GSM` má pri predikcii významnú úlohu, keďže kombinácie obsahujúce tento atribút dosahovali lepšie výsledky než varianty bez neho.

Dôležitou súčasťou práce bolo porovnanie navrhnutých modelov s perzistentným modelom. Najlepšie kontinuálne konfigurácie prekonali perzistenciu vo všetkých skúmaných horizontoch. Zlepšenie podľa metriky MAE sa pohybovalo približne od 13% do 16% a podľa metriky MSE približne od 18% do 31%. Tieto výsledky ukazujú, že navrhnuté modely neprinášali iba oneskorené kopírovanie poslednej známej hodnoty, ale dokázali zachytiť časť dynamiky vývoja indexu Dst.

Prínos Gaussian Process regresie sa pri kontinuálnych dátach nepotvrdil ako všeobecne pozitívny. Samostatný LSTM model dosahoval v priemere lepšie výsledky než hybridný model LSTM+GP. Gaussian Process zlepšil výsledky iba v niektorých konkrétnych konfiguráciách, najmä pri kratšom predikčnom horizonte. Napriek tomu ostáva jeho významným prínosom schopnosť poskytovať intervaly spoľahlivosti, ktoré dopĺňajú bodovú predikciu o informáciu o neistote modelu.

Pri eventových dátach boli výsledky hybridného prístupu priaznivejšie. Najlepšie priemerné výsledky dosiahla kombinácia `dst_bz_v`, pričom model BiLSTM+GP

dosiahol priemernú MAE 8.418. Pri klasifikačnej interpretácii dosiahol priemerné F1 skóre 0.926 pri prahu -20 nT a 0.775 pri prahu -50 nT. Hybridný model bol v priemere lepší než samotný BiLSTM aj perzistentný model, hoci ani v tomto prípade nebol prínos GP rovnaký vo všetkých jednotlivých konfiguráciách.

Výsledky zároveň potvrdili, že so zvyšujúcim sa predikčným horizontom sa presnosť modelov znižuje. Tento jav bol pozorovaný pri kontinuálnych aj eventových dátach a je prirodzený vzhľadom na komplexnosť a dynamiku geomagnetických búrok. Pri grafickej analýze vybranej búrky sa ukázalo, že modely pri horizonte 1 hodina dokázali dobre sledovať priebeh indexu Dst, zatiaľ čo pri horizonte 6 hodín bola predikcia náročnejšia a neistota výraznejšia.

Na základe dosiahnutých výsledkov možno konštatovať, že modely strojového učenia majú potenciál pri krátkodobej predikcii geomagnetickej aktivity. Najvýznamnejším vstupným atribútom sa ukázal `Bz_GSM` a najstabilnejšie výsledky boli dosiahnuté pri jeho kombinácii s indexom Dst a rýchlosťou slnečného vetra. Hybridný model s Gaussian Process regresiou je vhodný najmä v prípadoch, keď je dôležité okrem samotnej predikcie získať aj informáciu o jej neistote.

Budúci výskum by sa mohol zamerať na rozšírenie vstupných atribútov, testovanie ďalších architektúr neurónových sietí a efektívnejšie modelovanie neistoty. Zaujímavým smerom by bolo aj podrobnejšie vyhodnotenie modelov na väčšom počte geomagnetických udalostí a optimalizácia hybridného prístupu tak, aby poskytoval presné predikcie pri nižšej výpočtovej náročnosti.

Do budúcnosti by bolo vhodné rozšíriť experimenty o ďalšie vstupné premenné súvisiace so slnečným vetrom a medziplanetárnym magnetickým poľom, prípadne o ďalšie architektúry neurónových sietí, ako sú GRU, attention mechanizmy alebo transformerové modely. Zaujímavým smerom ďalšieho výskumu by bolo aj detailnejšie vyhodnotenie predikčných intervalov, testovanie modelov na väčšom počte samostatných geomagnetických udalostí a optimalizácia hybridného modelu tak, aby bol výpočtovo efektívnejší pri zachovaní schopnosti kvantifikovať neistotu.

Literatúra

Davies, E. E., Weiler, E., Möstl, C., Majumdar, S., Rüdisser, H. T., Horbury, T. S., O'Brien, H., Morris, J. and Crabtree, A. (2025). Real-time prediction of geomagnetic storms using solar orbiter as a far upstream solar wind monitor, *arXiv preprint arXiv:2508.13892* .

Echer, E., Gonzalez, W., Guarnieri, F. L., Dal Lago, A. and Vieira, L. (2005). Introduction to space weather, *Advances in Space Research* **35**(5): 855–865.

Gonzalez, W., Joselyn, J.-A., Kamide, Y., Kroehl, H. W., Rostoker, G., Tsurutani, B. T. and Vasyliunas, V. (1994). What is a geomagnetic storm?, *Journal of Geophysical Research: Space Physics* **99**(A4): 5771–5792.

Gruet, M. A., Chandorkar, M., Sicard, A. and Camporeale, E. (2018). Multiple-hour-ahead forecast of the dst index using a combination of long short-term memory neural network and gaussian process, *Space weather* **16**(11): 1882–1896.

Haugsdal, E., Aune, E. and Ruocco, M. (2023). Persistence initialization: a novel adaptation of the transformer architecture for time series forecasting: E. haugsdal et al., *Applied Intelligence* **53**(22): 26781–26796.

Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory, *Neural computation* **9**(8): 1735–1780.

Khabarova, O. and Price, C. (2024). Importance and challenges of geomagnetic storm forecasting, *Frontiers in Astronomy and Space Sciences* **11**: 1493917.

Laperre, B., Amaya, J. and Lapenta, G. (2020). Dynamic time warping as a new evaluation for dst forecast with machine learning, *Frontiers in Astronomy and Space Sciences* **7**: 540918.

Lilensten, J., Sanahuja, B., Messerotti, M., Belehaki, A., Vainio, R. and Watermann, J. (2008). A european definition for space weather, *Developing the scientific basis*

for monitoring, modelling and predicting Space Weather, edited by: Lilensten, J., Belehaki, A., Messerotti, M., Vainio, R., Watermann, J., and Poedts, S., Office for Official Publications of the European Communities, Luxembourg pp. 302–305.

Lim, B. and Zohren, S. (2021). Time-series forecasting with deep learning: a survey, *Philosophical transactions of the royal society a: mathematical, physical and engineering sciences* **379**(2194).

Lu, G., Yang, O., Wang, Z., Qu, Y., Xia, Y., Tang, D., Kotenko, I. and Li, W. (2025). A survey of deep learning for time series forecasting: Theories, datasets, and state-of-the-art techniques, *Computers, Materials, & Continua* **85**(2): 2403.

Majirskỳ, A., Mackovjak, Š., Kostárová, S., Magli, E., Butka, P. and Longépé, N. (2025). Combining solar imagery and in situ data for prediction of geomagnetic storms, *The Astrophysical Journal* **995**(1): 50.

Mienye, I. D., Swart, T. G. and Obaido, G. (2024). Recurrent neural networks: A comprehensive review of architectures, variants, and applications, *Information* **15**(9): 517.

Mukhamediev, R. I., Popova, Y., Kuchin, Y., Zaitseva, E., Kalimoldayev, A., Symagulov, A., Levashenko, V., Abdoldina, F., Gopejenko, V., Yakunin, K. et al. (2022). Review of artificial intelligence and machine learning technologies: Classification, restrictions, opportunities and challenges, *Mathematics* **10**(15): 2552.

Pulkkinen, A., Bernabeu, E., Thomson, A., Viljanen, A., Pirjola, R., Boteler, D., Eichner, J., Cilliers, P., Welling, D., Savani, N. et al. (2017). Geomagnetically induced currents: Science, engineering, and applications readiness, *Space weather* **15**(7): 828–856.

Rasmussen, C. E. (2003). Gaussian processes in machine learning, *Summer school on machine learning*, Springer, pp. 63–71.

Temerin, M. and Li, X. (2006). Dst model for 1995–2002, *Journal of Geophysical Research: Space Physics* **111**(A4).

Williams, C. K. and Rasmussen, C. E. (2006). *Gaussian processes for machine learning*, Vol. 2, MIT press Cambridge, MA.

Zoznam príloh

Príloha A CD médium – záverečná práca v elektronickej podobe, zdrojový kód.

Príloha B Kód je dostupný ako DP_Drengubiakova_Terezia.zip alebo online - `https://github.com/terezbiak/Diplomova_praca`