Technická univerzita v Košiciach

Fakulta elektrotechniky a informatiky

Segmentácia ionosferických štruktúr na snímkach z celooblohových kamier

Bakalárska práca

2026 **Kristína Gvozdiaková**

Technická univerzita v Košiciach

Fakulta elektrotechniky a informatiky

Segmentácia ionosferických štruktúr na snímkach z celooblohových kamier

Bakalárska práca

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

Košice 2026 **Kristína Gvozdiaková**

Abstrakt v SJ

Ekvatoriálne plazmové bubliny (EPB) sú oblasti zníženej hustoty plazmy vznikajúce v ionosfére, ktoré ovplyvňujú šírenie rádiových vĺn a spoľahlivosť navigačných systémov. Cieľom práce je automatizovaná segmentácia EPB štruktúr na snímkach celooblohovej kamery s využitím metód hlbokého učenia. Keďže pre túto úlohu neexistoval verejne dostupný anotovaný dataset, bol vytvorený vlastný a natrénovaný segmentačný model na základe architektúry SCSS-Net (Solar Corona Structures Segmentation Network). Finálny model bol zvolený po konzultácii s odborníkmi a aplikovaný na rozsiahlu časovú sériu snímok. Získané segmentačné masky predstavujú podklad pre nadväzujúce analýzy a výskum EPB štruktúr.

Kľúčové slová

Ekvatoriálne plazmové bubliny, segmentácia obrazu, hlboké učenie, konvolučné neurónové siete, celooblohová kamera, airglow, ionosféra

Abstrakt v AJ

Equatorial plasma bubbles (EPBs) are regions of reduced plasma density forming in the ionosphere that affect radio wave propagation and the reliability of navigation systems. The aim of this thesis is the automated segmentation of EPB structures in all-sky camera images using deep learning methods. Since no publicly available annotated dataset existed for this task, a custom dataset was created and the segmentation model was trained based on the SCSS-Net (Solar Corona Structures Segmentation Network) architecture. The final model was selected in consultation with domain experts and applied to an extensive time series of images. The resulting segmentation masks provide a basis for further analysis and research of EPB structures.

Kľúčové slová v AJ

Equatorial plasma bubbles, image segmentation, deep learning, convolutional neural networks, all-sky camera, airglow, ionosphere

80810

TECHNICKÁ UNIVERZITA V KOŠICIACH

FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Katedra kybernetiky a umelej inteligencie

ZADANIE
BAKALÁRSKEJ PRÁCE

Študijný odbor: **Informatika**

Študijný program: **Hospodárska informatika**

Názov práce:

Segmentácia ionosferických štruktúr na snímkach z celooblohových kamier

Segmentation of ionospheric structures in images from all-sky cameras

Študent: **Kristína Gvozdiaková**

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

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

Konzultant práce: **RNDr. Šimon Mackovjak, PhD.**

Pracovisko konzultanta: **Ústav experimentálnej fyziky SAV**

Pokyny na vypracovanie bakalárskej práce:

1. Podať teoretický prehľad problematiky metód hlbokého učenia, s dôrazom na vhodné metódy pre segmentáciu ionosferických štruktúr na snímkach z celooblohových kamier.
2. Získať a predspracovať vhodné dáta pre riešenie zvoleného problému.
3. Navrhnúť, realizovať a vyhodnotiť experimenty so segmentáciou zvolených štruktúr.
4. Vypracovať dokumentáciu podľa pokynov katedry a vedúceho práce.

Jazyk, v ktorom sa práca vypracuje: slovenský

Termín pre odovzdanie práce: 29.05.2026

Dátum zadania bakalárskej práce: 31.10.2025

TECHNICKÁ UNIVERZITA V KOŠICIACH FAKULTA ELEKTROTECHNIKY A INFORMATIKY -02-

n.z. Butka

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 29. 5. 2026 .....

Vlastnoručný podpis

Poďakovanie

Chcela by som sa poďakovať vedúcemu mojej bakalárskej práce doc. Ing. Petrovi Butkovi, PhD. a konzultantovi RNDr. Šimonovi Mackovjakovi, PhD. za rady, pripomienky a odbornú pomoc. Ďakujem tiež Ing. Silvii Kostárovej a všetkým, ktorí akýmkoľvek spôsobom prispeli k vzniku tejto práce.

Obsah

Úvod **1**

1 Hlboké učenie **2**

1.1 Neurónové siete 2

1.1.1 Aktivačné funkcie 4

1.1.2 Chybová funkcia 6

1.1.3 Optimalizácia 7

1.1.4 Regularizácia 7

1.2 Vyhodnocovacie metriky 9

1.3 Konvolučné neurónové siete 10

1.4 U-Net 12

2 Ekvatoriálne plazmové bubliny a metódy ich automatickej analýzy **15**

2.1 Airglow 15

2.2 Ekvatoriálne plazmové bubliny 15

2.3 Celooblohová kamera 16

2.4 Analýza súčasného stavu 18

3 Segmentácia ekvatoriálnych plazmových bublín **23**

3.1 Pochopenie cieľa práce 23

3.2 Analýza a charakteristika dát 24

3.3 Príprava datasetu 27

3.4 Modelovanie 35

3.5 Vyhodnotenie modelov 39

3.6 Nasadenie modelu 43

4 Záver **45**

Zoznam príloh **49**

Zoznam obrázkov

1 – 1 Architektúra perceptrónu. 2
1 – 2 Príklad architektúry neurónovej siete. 3
1 – 3 Priebeh funkcie sigmoid. 5
1 – 4 Priebeh funkcie ReLU. 6
1 – 5 Podučený, optimálny a preučený model. 8
1 – 6 Ukážka regularizácie pomocou techniky dropout. 8
1 – 7 Proces konvolúcie. 11
1 – 8 Max-pooling. 11
1 – 9 Klasifikácia, detekcia, segmentácia. Zdroj: Loy (2019) 12
1 – 10 Architektúra U-Net. Zdroj: Ronneberger et al. (2015) 13
2 – 1 Airglow pozorovaný z Medzinárodnej vesmírnej stanice ISS. Zdroj: NASA 16
2 – 2 EPB na snímke zo stanice El Leoncito z 2. októbra 2023. 17
2 – 3 Rozmiestnenie staníc celooblohových kamier, ktoré prevádzkuje Bostnoská Univerzita. Zdroj: `https://sirius.bu.edu/aeronomy/` 18
2 – 4 Ukážka segmentovanej snímky EPB s označeným geometrickým centrom západnej steny a polohou najsevernejšieho bodu EPB zo stanice Qujing v Číne. Zdroj: Zhong et al. (2025) 20
3 – 1 Príklad pôvodnej snímky z archívu SIRIUS a snímky s alfa kanálom. 25
3 – 2 Príklad snímky s výraznými EPB štruktúrami (El Leoncito, 13.10.2023). 26
3 – 3 Príklad snímky s horšie viditeľnými EPB štruktúrami (El Leoncito, 8.10.2023). 26
3 – 4 Pôvodná snímka – K-means – Prahovanie – Algoritmus Canny. . . 28
3 – 5 Snímka so zvýšeným kontrastom – Predikcia modelu SCSS-Net – Overlay. 30
3 – 6 Invertovaná snímka so zvýšeným kontrastom – Predikcia modelu SCSS-Net – Overlay. 30

3 – 7 Prostredie Label Studio. 31
3 – 8 Manuálne anotácie. 32
3 – 9 Architektúra SCSS-Net. Zdroj: Mackovjak et al. (2021) 36
3 – 10 Priebeh trénovania prvého modelu. Ľavý graf zobrazuje vývoj metrík Dice a IoU na trénovacej a validačnej množine. Pravý graf zobrazuje vývoj stratovej funkcie. 37
3 – 11 Ukážka dobrých predikcií prvého modelu. 38
3 – 12 Ukážka vyradených predikcií prvého modelu. 39
3 – 13 Priebeh trénovania druhého modelu – 2. iterácia. Ľavý graf zobrazuje vývoj metrík Dice a IoU na trénovacej a validačnej. Pravý graf zobrazuje vývoj stratovej funkcie. 40
3 – 14 Ukážka predikcií finálneho modelu. 44

Zoznam tabuliek

3 – 1 Prehľad datasetov použitých v jednotlivých fázach práce. 27
3 – 2 Rozdelenie datasetu s manuálne vytvorenými anotáciami. 33
3 – 3 Prehľad augmentácií. 34
3 – 4 Porovnanie modelov. 40
3 – 5 Porovnanie výsledkov modelov na validačnej množine. 41
3 – 6 Porovnanie výsledkov modelov na testovacej množine. 41
3 – 7 Vyhodnotenie finálneho modelu na manuálne anotovaných snímkach. 42

Zoznam symbolov a skratiek

Adam Adaptive Moment Estimation

ASI All-sky Imager

CA Coordinate Attention

CBAM Convolutional Block Attention Module

CNN Convolutional Neural Network

EPB Equatorial plasma bubble

ESF Equatorial spread F

FN False Negative

FP False Positive

GNSS Globálne navigačné satelitné systémy

IoU Intersection over Union

ReLU Rectified Linear Unit

RGB Red Green Blue

SCSS-Net Solar Corona Structures Segmentation Network

SDO The Solar Dynamics Observatory

SOHO The Solar and Heliospheric Observatory

TP True Positive

Úvod

Ionosféra, vrstva zemskej atmosféry, je dynamickým prostredím kde vznikajú rôzne plazmové štruktúry ovplyvňujúce šírenie rádiových vĺn a spoľahlivosť navigačných systémov. Jednou z týchto štruktúr sú ekvatoriálne plazmové bubliny – oblasti zníženej hustoty plazmy vznikajúce v ionosfére po západe slnka. Ich výskyt, veľkosť a časový vývoj sú predmetom prebiehajúceho vedeckého výskumu. Celooblohové kamery sledujúce airglow žiarenie poskytujú dlhodobé pozorovacie záznamy vhodné na štúdium týchto štruktúr, avšak manuálne spracovanie tisícok snímok pokrývajúcich dlhé časové obdobia nie je časovo realizovateľné.

Cieľom tejto práce je navrhnúť a realizovať model hlbokého učenia pre automatizovanú segmentáciu ekvatoriálnych plazmových bublín na snímkach celooblohovej kamery. Práca nadväzuje na existujúce prístupy k segmentácii astronomických štruktúr pomocou konvolučných neurónových sietí, pričom sa zameriava na špecifické výzvy spojené s charakterom vstupných dát – čiernobiele snímky s nízkym kontrastom a neostro definovanými hranicami segmentovaných štruktúr.

Práca je členená do troch kapitol. Prvá kapitola poskytuje teoretický prehľad metód hlbokého učenia so zameraním na konvolučné neurónové siete a architektúru U-Net, ktorá tvorí základ použitého segmentačného modelu. Druhá kapitola opisuje fenomén airglow a ekvatoriálnych plazmových bublín, princíp fungovania celooblohovej kamery a analyzuje súčasný stav výskumu v oblasti automatickej analýzy ionosférických štruktúr. Tretia kapitola tvorí praktickú časť práce – opisuje celý proces od získania a prípravy datasetu, cez návrh a trénovanie segmentačného modelu, až po vyhodnotenie jeho výkonnosti a aplikáciu na rozsiahlu časovú sériu snímok.

1 Hlboké učenie

Hlboké učenie predstavuje moderný prístup v oblasti umelej inteligencie a patrí medzi najvýznamnejšie oblasti strojového učenia. Na rozdiel od tradičných metód strojového učenia, ktoré pracujú s explicitne definovanými pravidlami, hlboké učenie umožňuje modelom extrahovať dôležité vzory a informácie priamo z dát a používa na to umelé neurónové siete (LeCun et al., 2015).

1.1 Neurónové siete

Neurónové siete sú inšpirované ľudským mozgom a môžu pozostávať z miliónov alebo dokonca miliárd neurónov. Perceptrón (Obrázok 1 – 1) predstavuje najjednoduchší typ umelého neurónu a slúži ako základný stavebný prvok pre komplexnejšie architektúry hlbokého učenia. Využíva sa primárne na úlohy binárnej klasifikácie. Perceptrón prijíma n vstupov $(x_1, x_2, \ldots, x_n)$, pričom každému vstupu je priradená váha $(w_1, w_2, \ldots, w_n)$. Výstup perceptrónu sa vypočíta ako vážený súčet vstupov plus bias b, ktorý následne prechádza aktivačnou funkciou (Nielsen, 2015).

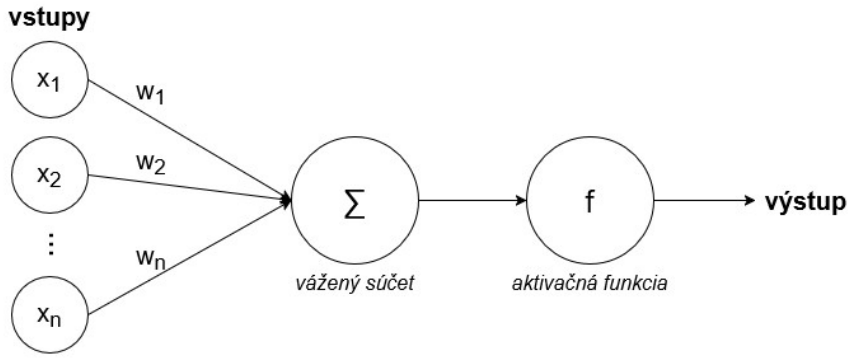

Obrázok 1 – 1 Architektúra perceptrónu.

Neuróny sú v neurónovej sieti organizované v rôznych vrstvách. Táto štruktúra im umožňuje rozpoznať a naučiť sa ešte zložitejšie vzťahy v dátach. Každá vrstva neurónov berie výstup z predchádzajúcej vrstvy a transformuje ho do novej reprezentácie dát. Posledná vrstva neurónov vytvára výstup modelu (Obrázok 1 – 2).

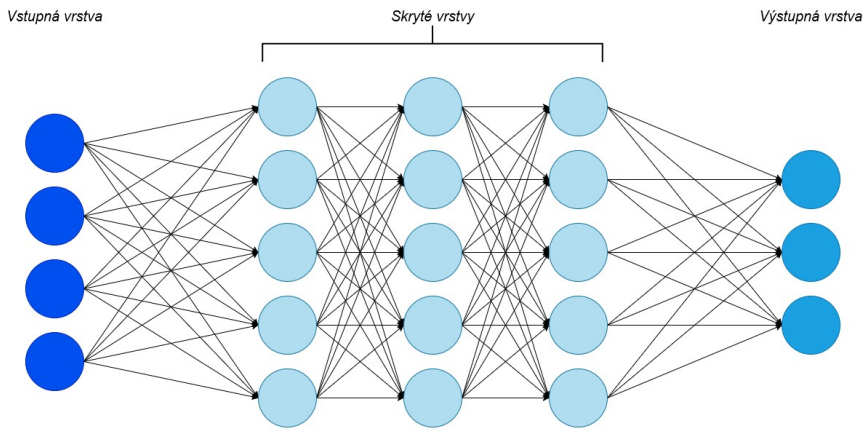

Obrázok 1 – 2 Príklad architektúry neurónovej siete.

Počet vrstiev v modeli hlbokého učenia sa nazýva hĺbka modelu. Čím viac vrstiev model má, tým zložitejšie vzory sa dokáže naučiť. Hlbšie modely sú však aj náročnejšie na trénovanie (Goodfellow et al., 2016).

Pri neurónových sieťach poznáme tri základné typy vrstiev:

1. **Vstupná vrstva** – Prijíma vstupné dáta do siete. Každý neurón v tejto vrstve zvyčajne zodpovedá jednému príznaku vstupného vektora.

2. **Skryté vrstvy** – Umožňujú modelu identifikovať vzory a závislosti v dátach. Týchto vrstiev môže byť veľké množstvo a predstavujú hlavnú časť výpočtového procesu neurónovej siete.

3. **Výstupná vrstva** – Posledná vrstva neurónovej siete, ktorá poskytuje výsledok spracovania dát. Počet neurónov vo výstupnej vrstve závisí od typu riešeného problému.

Spolupráca týchto troch typov vrstiev umožňuje neurónovým sieťam efektívne spracovávať vstupné informácie a vytvárať predikcie na základe naučených vzorov z dát.

1.1.1 Aktivačné funkcie

Aktivačná funkcia je matematická funkcia, ktorá sa používa v neurónových sieťach a rozhoduje o tom, či je neurón aktivovaný alebo nie. Spracováva vážený súčet vstupov neurónu a vypočítava novú hodnotu, aby určila, ako silno sa signál prenesie do ďalšej vrstvy v sieti. Aktivačná funkcia teda určuje silu reakcie neurónu na vážené vstupné hodnoty, hrá kľúčovú úlohu pri trénovaní neurónových sietí a umožňuje modelovanie nelineárnych vzťahov (Rasamoelina et al., 2020).

Bližšie sa budeme venovať funkciám, ktoré boli využité v praktickej časti. Konkrétne sa jedná o funkciu sigmoid, aplikovanú na výstupnej vrstve a aktivačnú funkciu ReLU, ktorá bola použitá vo všetkých skrytých vrstvách.

Sigmoid

Funkcia Sigmoid (Obrázok 1 – 3) je nelineárna aktivačná funkcia, ktorá je matematicky definovaná takto:

$$f(x) = \frac{1}{1 + e^{-x}} \tag{1.1}$$

Táto funkcia zabezpečuje, že vstupná hodnota je pretransformovaná na rozsah medzi 0 a 1. Najčastejšie je využívaná ako aktivačná funkcia na výstupnej vrstve pre binárnu klasifikáciu, kde je výstup interpretovaný ako pravdepodobnosť príslušnosti (Rasamoelina et al., 2020).

Hlavnou nevýhodou sigmoidnej funkcie je, že sa pri jej použití môže vyskytnúť tzv. problém miznúceho gradientu (angl. *vanishing gradient problem*). Pri veľmi veľkých alebo minimálnych vstupných hodnotách sa hodnota gradientu môže počas derivácie blížiť k nule. V dôsledku toho sa váhy neurónov počas spätného šírenia (angl. *backpropagation*) vôbec neupravujú alebo sa upravujú len veľmi mierne, čo spôsobuje pomalé a neefektívne trénovanie (Goodfellow et al., 2016).

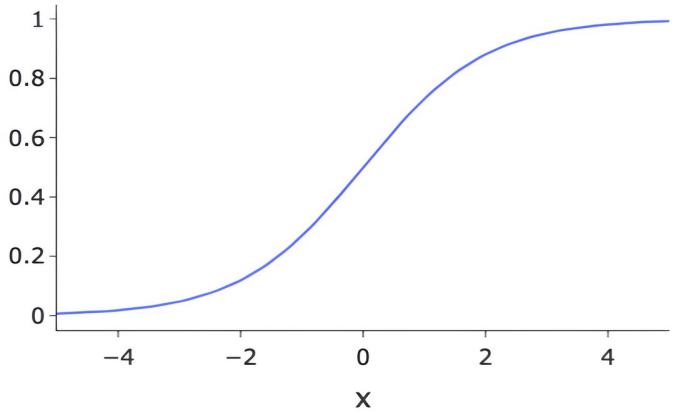

Obrázok 1 – 3 Priebeh funkcie sigmoid.

ReLU

Funkcia ReLU (angl. *Rectified Linear Unit*) (Obrázok 1 – 4) je jednou z najčastejšie používaných aktivačných funkcií v skrytých vrstvách. Táto funkcia s nelineárnym priebehom je definovaná vzťahom:

$$f(x) = max(0, x) \tag{1.2}$$

Pre záporné hodnoty vstupu nadobúda nulovú hodnotu a pre nezáporné hodnoty je výstup identický so vstupom. ReLU je výpočtovo menej náročná, pretože zahŕňa jednoduchšie matematické operácie a naraz je aktivovaných iba niekoľko neurónov (Glorot et al., 2011).

S používaním tejto funkcie je spojený aj tzv. umierajúci ReLU problém (angl. *dying ReLU problem*). Nastane keď počas učenia začne neurón produkovať pre všetky vstupy nulový výstup. Keďže gradient je nulový, váhy neurónu sa už ďalej neaktualizujú a neurón prestáva prispievať k učeniu modelu. Na zmiernenie tohto problému sa používajú upravené varianty aktivačných funkcií, ako napríklad Leaky ReLU (1.3), ktorá umožňuje malý gradient aj pre záporné hodnoty vstupu (Maas et al., 2013).

$$f(x) = max(0.01, x) \tag{1.3}$$

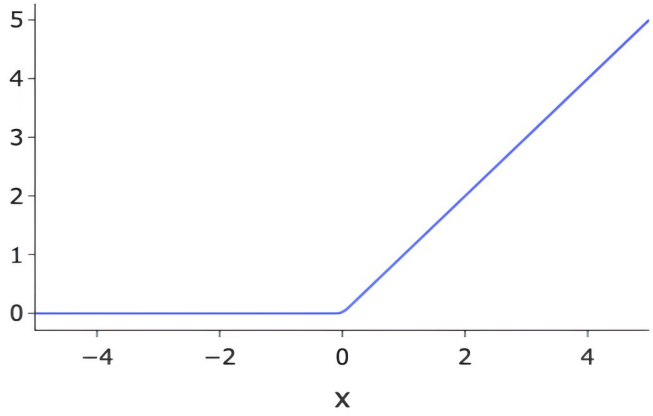

Obrázok 1 – 4 Priebeh funkcie ReLU.

1.1.2 Chybová funkcia

Chybová funkcia (angl. *loss function*) hodnotí celkovú presnosť modelu na základe rozdielu medzi predikovanými a skutočnými hodnotami. Cieľom trénovania je ju minimalizovať. Nižšia hodnota chybovej funkcie znamená, že predikcie modelu sú presnejšie, zatiaľ čo vyššia hodnota indikuje nepresné predpovede. Voľba konkrétnej chybovej funkcie závisí od typu riešenej úlohy a má zásadný vplyv na priebeh učenia aj výslednú kvalitu modelu (Goodfellow et al., 2016).

Pri klasifikačných úlohách sa často využíva krížová entropia (angl. *cross-entropy*), ktorá meria rozdiel medzi skutočným a predikovaným pravdepodobnostným rozdelením. V prípade binárnej klasifikácie sa využíva binárna krížová entropia (angl. *binary cross-entropy*) definovaná vzťahom

$$L = -(y\ log(\hat{y}) + (1 - y)\ log(1 - \hat{y})) \tag{1.4}$$

kde y predstavuje skutočnú triedu a $\hat{y}$ pravdepodobnosť predikovanú modelom (Murphy, 2012).

V kontexte segmentácie snímok je jej použitie vhodné, keďže segmentáciu možno formulovať ako klasifikačný problém na úrovni jednotlivých pixelov.

1.1.3 Optimalizácia

Optimalizácia pri učení neurónových sietí označuje proces úpravy parametrov modelu (váh a biasov) tak, aby sa minimalizovala chybová funkcia. Tento proces prebieha iteratívne počas trénovania modelu na základe dostupných dát. Cieľom optimalizácie je minimalizovať chybu na trénovacích dátach, ideálne pri zachovaní dobrej generalizácie na nových, doposiaľ neznámych dátach (Goodfellow et al., 2016).

Najčastejšie sa používajú metódy založené na gradientoch, ktoré využívajú informáciu o tom, ako sa chyba mení pri zmene parametrov. Aby optimalizačný algoritmus vedel, ktoré parametre a akým smerom ich upravovať, potrebuje informáciu o tom, ako jednotlivé váhy ovplyvňujú výslednú chybu. Túto informáciu poskytuje spätné šírenie chyby (angl. *backpropagation*), ktoré vypočíta potrebné gradienty tým, že šíri chybu od výstupu siete smerom dozadu cez jednotlivé vrstvy (Rumelhart et al., 1986).

V praktickej časti je využitý optimalizačný algoritmus Adam (*Adaptive Moment Estimation*). Využíva momenty gradientu (t. j. informáciu z predchádzajúcich krokov) a adaptívne nastavuje veľkosť kroku učenia pre jednotlivé parametre. Medzi jeho hlavné výhody patrí, že je výpočtovo efektívny, má nízke pamäťové nároky a je vhodný najmä pre úlohy s veľkým množstvom dát a vysokým počtom parametrov (Kingma and Ba, 2014).

1.1.4 Regularizácia

Pri učení sa dáta zvyčajne delia na trénovaciu množinu, na ktorej sa model priamo učí (upravujú sa jeho parametre), validačnú množinu, ktorá slúži na priebežné hodnotenie počas tréningu a na ladenie hyperparametrov, a testovaciu množinu, ktorá sa používa až po dokončení tréningu na finálne, čo najobjektívnejšie zhodnotenie modelu na nových, doposiaľ nevidených dátach.

Regularizácia predstavuje súbor postupov, ktorých cieľom je zlepšiť generalizáciu modelu a znížiť riziko preučenia (angl. *overfitting*). Preučenie nastáva vtedy,

keď si model okrem všeobecných vzťahov začne zapamätávať aj špecifické detaily a šum prítomný v trénovacej množine. Výsledkom je, že model dosahuje veľmi dobré výsledky na trénovacích dátach, ale jeho výkon na validačných alebo testovacích dátach sa zhoršuje. Opačným problémom je podučenie (angl. *underfitting*), pri ktorom model nedokáže dostatočne zachytiť vzťahy v dátach a má slabý výkon už na trénovacích dátach (Obrázok 1 – 5) (Goodfellow et al., 2016).

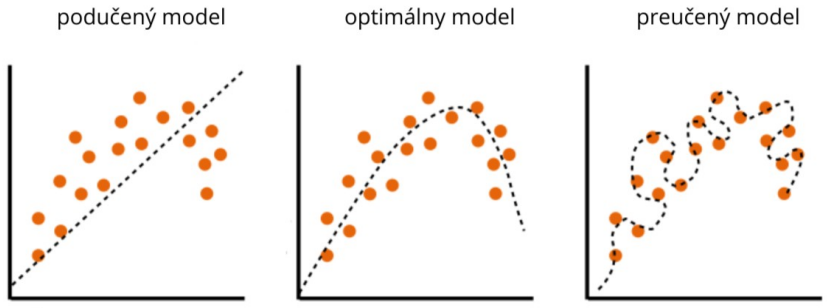

Obrázok 1 – 5 Podučený, optimálny a preučený model.

Dropout je technika, pri ktorej sa počas tréningu náhodne deaktivuje časť neurónov (Obrázok 1 – 6). Tým sa znižuje závislosť modelu na konkrétnych neurónoch a podporuje sa robustnejšie učenie (Srivastava et al., 2014).

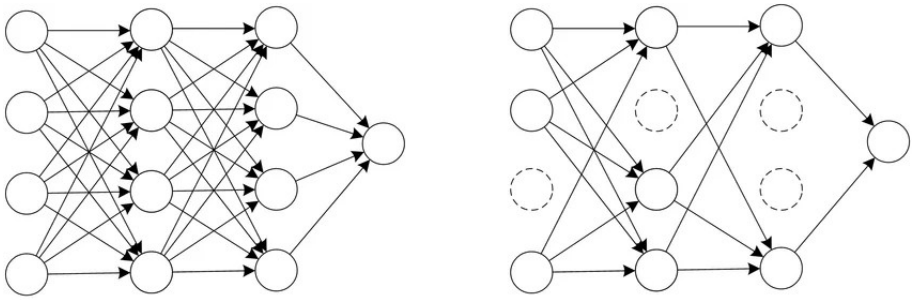

Obrázok 1 – 6 Ukážka regularizácie pomocou techniky dropout.

Early stopping je metóda založená na sledovaní výkonu na validačnej množine. Ak sa validačná strata prestane zlepšovať (alebo sa začne zhoršovať), tréning sa ukončí, aby sa obmedzilo ďalšie preučovanie (Goodfellow et al., 2016).

Pri úlohách spracovania obrazu je dôležitou regularizačnou stratégiou **augmentácia dát**, pri ktorej sa tréningové dáta umelo rozširujú transformáciami (napr. rotácia, preklopenie či zmena jasu). Model sa tak učí zvládať prirodzené variácie vstupov, čo zlepšuje generalizáciu (Shorten and Khoshgoftaar, 2019).

1.2 Vyhodnocovacie metriky

Vyhodnocovacie metriky slúžia na objektívne posúdenie kvality modelu. V úlohách segmentácie obrazu je cieľom správne určiť triedu pre každý pixel. Z tohto dôvodu sa používajú metriky, ktoré porovnávajú prekryv (zhodu) medzi predikovanou maskou a referenčnou (ground truth) maskou.

Označme:

- TP (*true positive*) – počet správne predikovaných pixelov objektu,
- FP (*false positive)* – počet pixelov, ktoré model nesprávne označil ako objekt,
- FN (*false negative*) – počet pixelov, ktoré v referencii patria objektu, ale model ich neoznačil.

IoU (*Intersection over Union*) tiež označovaný ako Jaccardov index (angl. *Jaccard index*) je definovaný ako pomer prieniku a zjednotenia masiek (Legendre and Legendre, 2012). Hodnota IoU nadobúda interval od 0 do 1, pričom vyššia hodnota znamená lepšiu segmentáciu.

$$IoU = \frac{TP}{TP + FP + FN} \tag{1.5}$$

Dice koeficient (*Dice Similarity Coefficient*) vyjadruje podobnosť masiek (Sφrensen, 1948). Nadobúda hodnoty od 0 do 1, kde 1 predstavuje dokonalú zhodu masiek.

$$Dice = \frac{2TP}{2TP + FP + FN} \tag{1.6}$$

V prípade nevyvážených tried (malý objekt a veľké pozadie) sa často sleduje najmä Dice, keďže je citlivý na prekryv aj pri malých oblastiach.

1.3 Konvolučné neurónové siete

Konvolučné neurónové siete (angl. *Convolutional Neural Networks*, skr. CNN) sú typ neurónových sietí navrhnutý najmä na spracovanie dát so štruktúrou mriežky, napr. obrazových dát. Využívajú priestorovú štruktúru obrazu (vzťahy medzi susednými pixelmi), vďaka čomu dokážu efektívne určiť vizuálne príznaky, ako sú hrany, rohy alebo textúry (LeCun et al., 2015).

Typická CNN je zložená z viacerých typov vrstiev (Goodfellow et al., 2016):

- **Vstupná vrstva** (angl. *input layer*) slúži na vloženie vstupných dát. V prípade obrázkov ide o dáta s rozmermi výška × šírka × počet kanálov, napr. RGB má tri kanály.

- **Konvolučná vrstva** (angl. *convolutional layer*) je základný stavebný prvok CNN, ktorého hlavnou úlohou je extrahovať príznaky zo vstupného obrazu.

  Na Obrázku 1 – 7 môžeme vidieť vstupnú maticu (vľavo), konvolučný filter (v strede) a výstup konvolúcie (vpravo). Konvolúcia prebieha tak, že sa na vstup aplikuje filter (angl. *kernel*) s malými rozmermi (napr. 3×3 alebo 5×5). Filter sa posúva po obraze a na každej pozícii vypočíta jednu hodnotu (váženú kombináciu hodnôt v danej lokálnej oblasti). Takto vzniká mapa príznakov (angl. *feature map*), ktorá vyjadruje, kde sa v obraze nachádza vzor, na ktorý je filter citlivý (napr. určitý typ hrany alebo textúry). Jedna konvolučná vrstva obsahuje viac filtrov, takže zároveň vytvára viac máp príznakov, pričom každá z máp môže reprezentovať iný typ naučeného vzoru.

  Na výsledok konvolúcie má výrazný vplyv nastavenie hyperparametrov. Veľkosť filtra (angl. *kernel size*) určuje, akú veľkú lokálnu oblasť filter spracúva. Posun (angl. *stride*) určuje krok posunu filtra. *Padding* ovplyvňuje spracovanie okrajových častí a tiež to, či sa zachová pôvodný rozmer vstupu. Počet filtrov určuje počet výstupných kanálov a tým aj kapacitu vrstvy zachytiť rôzne typy príznakov.

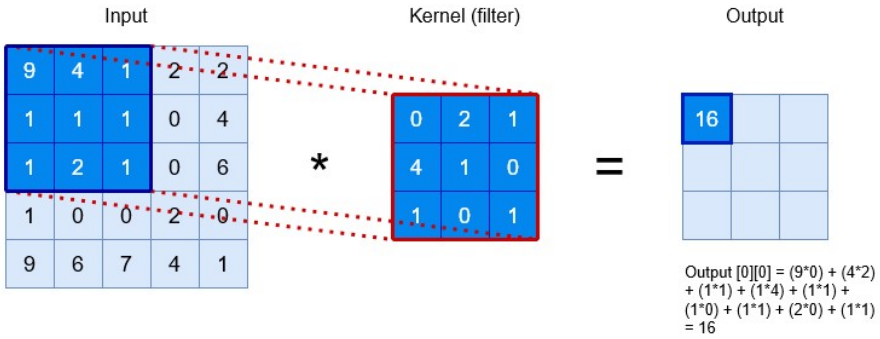

Obrázok 1 – 7 Proces konvolúcie.

- **Združovacia (vzorkovacia) vrstva** (angl. *pooling layer*) sa používa na zmenšenie rozmerov máp príznakov (*downsampling*). Princíp spočíva v nahradení viacerých hodnôt jednou reprezentatívnou hodnotou. Najčastejšie sa používa *max pooling* (Obrázok 1 – 8), pri ktorom sa z každej malej oblasti (napr. 2×2) vyberie maximálna hodnota. Používaný je aj *average pooling*, ktorý v danej oblasti počíta priemernú hodnotu. Vo výsledku zmenšíme náročnosť siete, pričom zachováme najdôležitejšie informácie.

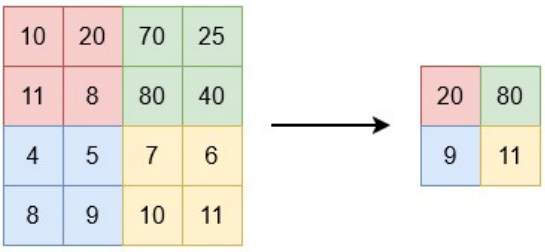

Obrázok 1 – 8 Max-pooling.

- **Plne prepojená vrstva** (angl. *fully connected layer* alebo *dense layer*) sa využíva ako výstupná vrstva CNN, v ktorej je každý neurón prepojený so všetkými výstupmi z predchádzajúcej vrstvy. Do tejto vrstvy vstupuje matica transformovaná na jednorozmerný vektor, ktorý je následne spracovaný aktivačnou funkciou podľa typu úlohy.

1.4 U-Net

V počítačovom videní rozlišujeme viacero úloh spracovania obrazu, ktoré sú znázornené na Obrázku 1 – 9:

- **Klasifikácia** určuje, aký objekt sa na obrázku nachádza. Výstupom je jedna trieda pre celý obraz.
- **Detekcia objektov** ohraničí detegovaný objekt obdlžníkom a tým určí jeho približnú polohu.
- **Segmentácia obrazu** priraďuje triedu každému pixelu obrazu, čím umožňuje presné určenie tvaru a hraníc objektov.

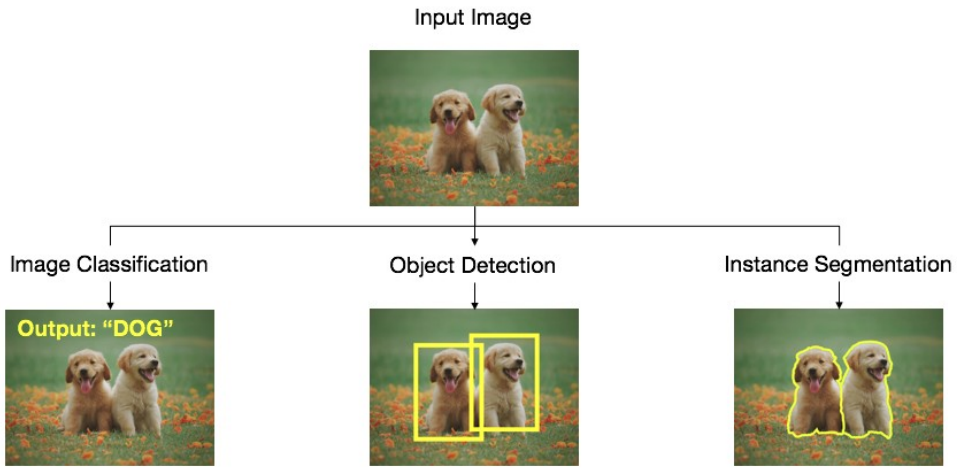

Obrázok 1 – 9 Klasifikácia, detekcia, segmentácia. Zdroj: Loy (2019)

Architektúra U-Net

U-Net je architektúra konvolučnej neurónovej siete určená pre segmentáciu obrazu, teda na predikciu triedy pre každý pixel (Ronneberger et al., 2015). Jej typický tvar „U“, ktorý môžeme vidieť na Obrázku 1 – 10, vychádza z toho, že sieť najprv postupne znižuje rozlíšenie a extrahuje príznaky (enkodér - ľavá časť) a následne

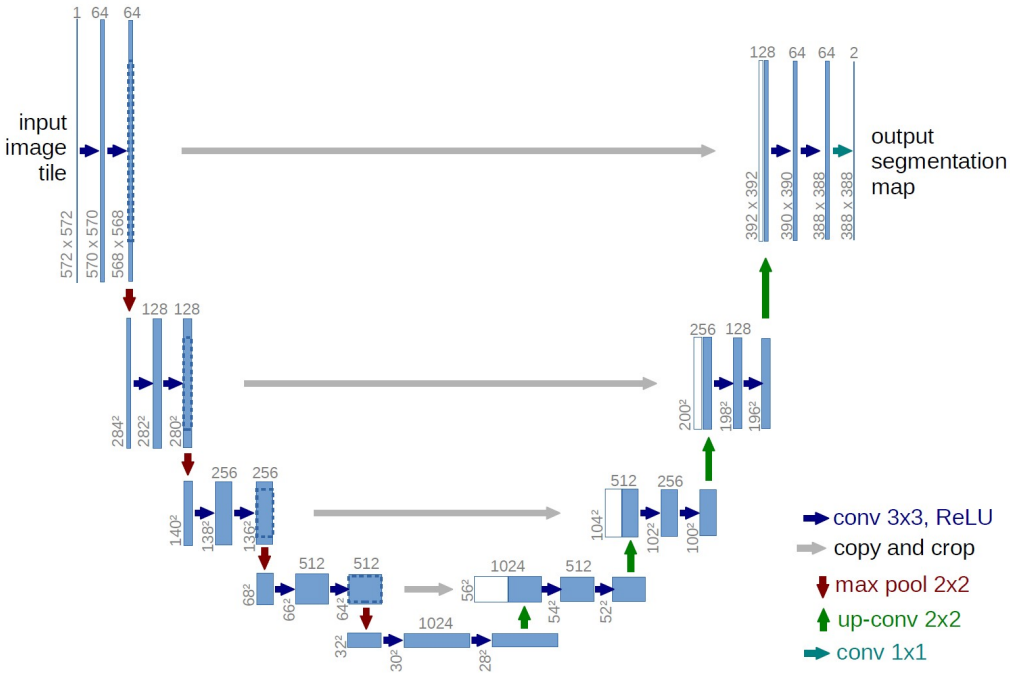

Obrázok 1 – 10 Architektúra U-Net. Zdroj: Ronneberger et al. (2015)

rozlíšenie opäť obnovuje (dekodér - pravá časť), aby vytvorila výstupnú segmentačnú masku.

V časti enkodér sa na každej úrovni typicky použijú dve konvolúcie 3×3, pričom za každou nasleduje aktivačná funkcia ReLU. Potom nasleduje *max pooling* 2×2 (so *stride* 2), ktorý zníži rozlíšenie na polovicu. Pri prechode do hlbších úrovní sa zároveň zvyčajne zvyšuje počet kanálov. V spodnej (*bottleneck*) časti sa opäť používajú konvolúcie 3×3 s ReLU, ktoré pracujú s najnižším rozlíšením, ale s najväčším počtom kanálov. Táto časť zachytáva najviac kontextovej informácie.

V časti dekodér sa rozlíšenie obnovuje pomocou *upsampling* (často transponovanou konvolúciou) a následne sa výstup spojí so zodpovedajúcimi mapami príznakov z enkodéru pomocou *skip connection*. Po spojení sa znovu aplikujú konvolúcie 3×3 s ReLU, ktoré skombinujú kontext z hlbších vrstiev s detailmi prenesenými zo *skip connection*. *Skip connections* sú dôležité najmä preto, že pomáhajú zachovať jemné priestorové informácie a zlepšujú presnosť hraníc segmentácie.

Na konci siete sa používa konvolúcia 1×1, ktorá prevedie počet kanálov na

požadovaný počet výstupných tried. Pri binárnej segmentácii sa typicky používa sigmoid, pri viac-triednej segmentácii softmax. Výstupom je výsledná segmentačná maska (resp. mapa pravdepodobností) v rozlíšení zodpovedajúcom vstupu.

2 Ekvatoriálne plazmové bubliny a metódy ich automatickej analýzy

2.1 Airglow

Airglow predstavuje slabé prirodzené žiarenie zemskej atmosféry, ktoré vzniká v dôsledku chemických reakcií prebiehajúcich v horných vrstách atmosféry vo výškach približne 80 až 300 km (Solomon and Abreu, 1989). Tieto procesy prebiehajú nepretržite počas celého dňa, preto rozlišujeme denné žiarenie (angl. *dayglow*) a nočné žiarenie (angl. *nightglow*), teda $Airglow = Dayglow + Nightglow$. Denné žiarenie je náročné na detekciu kvôli slnečnému svitu a vyžaduje špecializované optické systémy. Naopak, nočné žiarenie je oveľa jednoduchšie detegovať v čase medzi západom slnka a úsvitom.

Je potrebné rozlišovať airglow od polárnej žiary (angl. *aurora*). Polárna žiara je často viditeľná voľným okom a je typická pre vysoké zemepisné šírky (tzv. polárne oblasti). Airglow sa vyskytuje na všetkých zemepisných šírkach a patrí medzi tzv. sub-vizuálne emisie, to znamená, že jeho jas je príliš nízky pre ľudské oko a na jeho zachytenie sú potrebné citlivé detekčné prístroje (Obrázok 2 – 1) (Martinis et al., 2018).

2.2 Ekvatoriálne plazmové bubliny

Ekvatoriálne plazmové bubliny (angl. *Equatorial Plasma Bubbles*, skr. EPB) sú oblasti v nočnej ionosfére, ktoré sa vyznačujú výrazne nižšou hustotou plazmy v porovnaní s okolitým prostredím. Tento jav je často označovaný aj ako *equatorial spread F* (skr. ESF). EPB sú orientované pozdĺž geomagnetického poľa, pričom v severojužnom smere môžu dosahovať dĺžku stoviek kilometrov, zatiaľ čo ich východozápadný rozmer býva v desiatkach kilometrov (Bhattacharyya, 2022).

Airglow umožňuje tieto inak neviditeľné procesy vizualizovať. V celooblohových snímkach sa EPB javia ako tmavé štruktúry (tzv. *airglow depletions*) v jasnom at-



Obrázok 2 – 1 Airglow pozorovaný z Medzinárodnej vesmírnej stanice ISS. Zdroj: NASA

mosférickom pozadí (Obrázok 2 – 2). Snímky odhaľujú, že bubliny nie sú jednoduché útvary, ale majú komplexnú štruktúru, ktorá často zahŕňa vetvenia. Pre monitorovanie EPB sa najčastejšie využívajú emisie na vlnových dĺžkach 630,0 nm (vo výškach 250 – 300 km) a 777,4 nm (výšky nad 300 km) (Martinis et al., 2018).

Nepravidelnosti v hustote plazmy na okrajoch bublín narúšajú satelitnú komunikáciu a spôsobujú stratu signálu systémov GNSS (Globálne navigačné satelitné systémy) (Bhattacharyya, 2022).

2.3 Celooblohová kamera

Celooblohová kamera (angl. *All-sky Imager*, skr. ASI) je vedecký optický systém, ktorý využíva širokouhlý objektív typu „rybie oko“ (angl. *fish-eye lens*) na zaznamenávanie scény od horizontu po horizont, čo predstavuje zorné pole 180°. Takýto široký záber umožňuje snímať celú oblohu v jednom zábere a pokryť oblasť s priemerom až $\sim$ 2000 km.

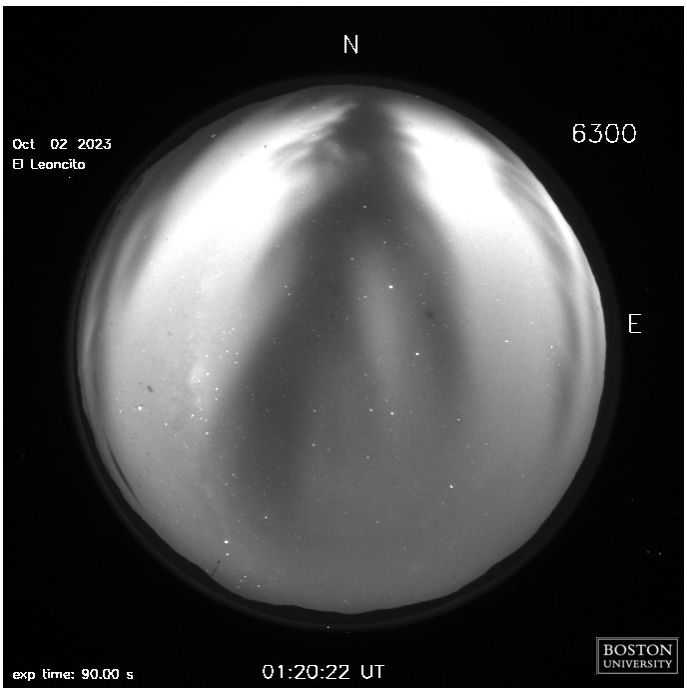

Obrázok 2 – 2 EPB na snímke zo stanice El Leoncito z 2. októbra 2023.

ASI používa niekoľko filtrov, ktoré umožňujú selektívne snímať žiarenie na konkrétnych vlnových dĺžkach, a tým identifikovať emisie pochádzajúce z rôznych vrstiev atmosféry. Typicky ide o vlnové dĺžky 557,7 nm, 630,0 nm, 777,4 nm, 589,3 nm, >695,0 nm, 605,0 nm alebo 644,4 nm.

Centrum pre kozmickú fyziku na Bostonskej univerzite vyvinulo a spravuje rozsiahlu globálnu sieť týchto kamier, ktoré sú rozmiestnené v tzv. geomagneticky konjugovaných bodoch – teda na opačných koncoch tej istej magnetickej siločiary (Obrázok 2 – 3). Snímky získané pomocou fish-eye objektívu sú geometricky skreslené (tzv. *„warped“* snímky), následne sú softvérovo transformované na geografické mapy (*„unwarped“* snímky). Tento proces zahŕňa odhad výšky emisnej vrstvy (napr. 300 km pre airglow), na základe ktorého sa každému pixelu priradí geografická poloha (zemepisná šírka a dĺžka) (Martinis et al., 2018).

V tejto práci sme použili na trénovanie dataset tvorený snímkami získanými na vlnovej dĺžke 630,0 nm zo stanice El Leonicto v Argentíne.

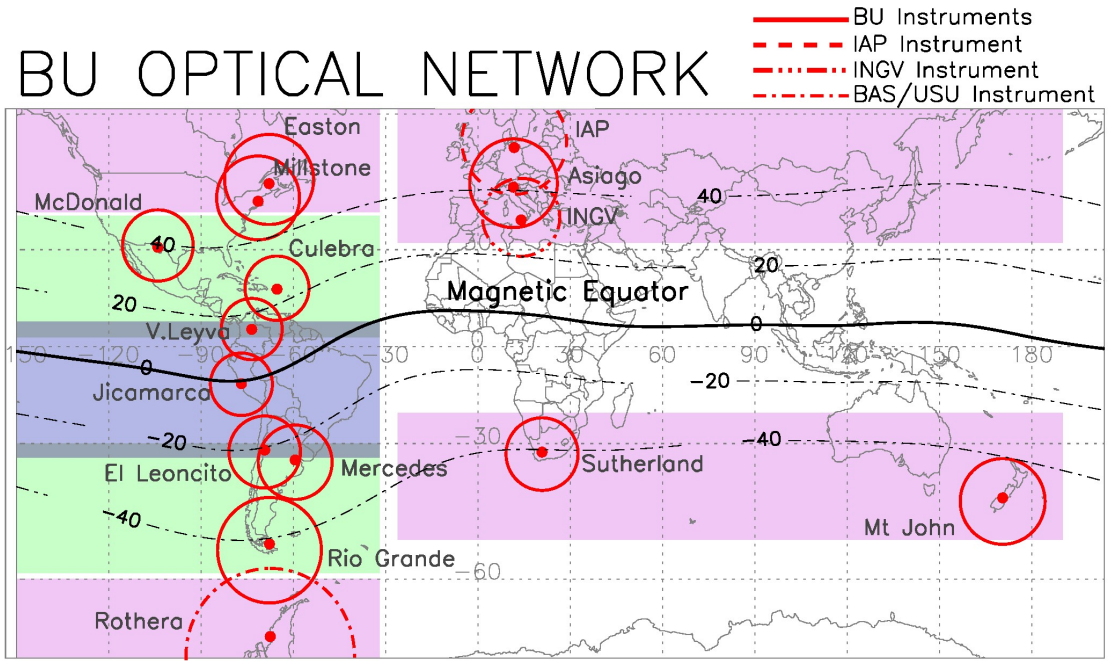

Obrázok 2 – 3 Rozmiestnenie staníc celooblohových kamier, ktoré prevádzkuje Bostnoská Univerzita. Zdroj: `https://sirius.bu.edu/aeronomy/`

2.4 Analýza súčasného stavu

V posledných rokoch zaznamenala automatizovaná analýza snímok z celooblohových kamier výrazný posun vďaka metódam hlbokého učenia.

Automatická detekcia a segmentácia EPB pomocou hlbokého učenia

Zhong et al. (2025) vyvinuli prvý komplexný systém automatickej detekcie, morfologickej segmentácie a extrakcie charakteristík EPB z celooblohových OI 630 nm airglow snímok zachytených na stanici Qujing v Číne v rokoch 2012 až 2022. Motiváciou pre vývoj tohto systému bol rastúci objem observačných dát, keďže jedna stanica s jednokanálovým vybavením v rámci *Chinese Meridian Project* (Wang, 2010) vyprodukuje približne 1 TB dát ročne. Manuálne spracovanie takéhoto objemu dát je prakticky nerealizovateľné.

Systém pozostáva z modelu rozpoznávania EPB (EPB-RM), modelu morfolo-

gickej segmentácie EPB (EPB-MSM) a programu na extrakciu charakteristík EPB (EPB-FEP). Na trénovanie modelov bol zostavený dataset obsahujúci 723 375 ručne označených snímok pokrývajúcich takmer jeden slnečný cyklus, z ktorých 4 664 obsahovalo EPB udalosti a 786 malo manuálne anotované obrysy morfológie EPB.

Pre úlohu binárnej klasifikácie, teda rozpoznania prítomnosti alebo neprítomnosti EPB na snímke, bol ako základ zvolený model ResNet18, doplnený o modul pozornosti CBAM (*Convolutional Block Attention Module*) a modul CA (*Coordinate Attention*). Najlepšie výsledky dosiahol model ResNet18+CBAM s presnosťou 99 %, čím prekonával ostatné testované konfigurácie. Autori zistili, že všetky modely dosahujú lepší výkon počas geomagneticky pokojných období a v časoch vysokej slnečnej aktivity.

Pre morfologickú segmentáciu, teda pixelovú klasifikáciu oblastí EPB, bol nasadený model DeepLabV3plus, ktorý dosiahol najlepší výsledok spomedzi všetkých porovnávaných prístupov (PSPNet, FCN, UPerNet) – hodnotu IoU 78,23 % a presnosť segmentácie 88,2 %.

Program na extrakciu charakteristík EPB-FEP využíva výstupy oboch predchádzajúcich modelov na automatický výpočet kvantitatívnych parametrov EPB. Konkrétne sa vypočítava tzv. *zonal drift velocity* EPB na základe zmeny polohy geometrického centra západnej steny bubliny v dvoch po sebe nasledujúcich snímkach, a poloha najsevernejšieho bodu EPB (Obrázok 2 – 4). Použitie západnej steny bubliny ako referenčného bodu vychádza z výskumu Pimenta et al. (2001), ktorý preukázal, že gradient intenzity 630,0 nm na západnej stene EPB je výrazne stabilnejší než na východnej. V dôsledku toho Pimenta et al. (2001) zistili, že merania rýchlosti odvodené zo západnej steny poskytujú vynikajúcu presnosť. Automaticky extrahované parametre EPB boli porovnané s hodnotami získanými manuálnou metódou a preukázali vysokú konzistenciu, čím bola overená spoľahlivosť celého automatizovaného systému.

Práca Zhong et al. (2025) predstavuje metodologický prístup priamo relevantný pre túto prácu. Zároveň však identifikuje kľúčovú výzvu: trénovacie dáta pochádzajú

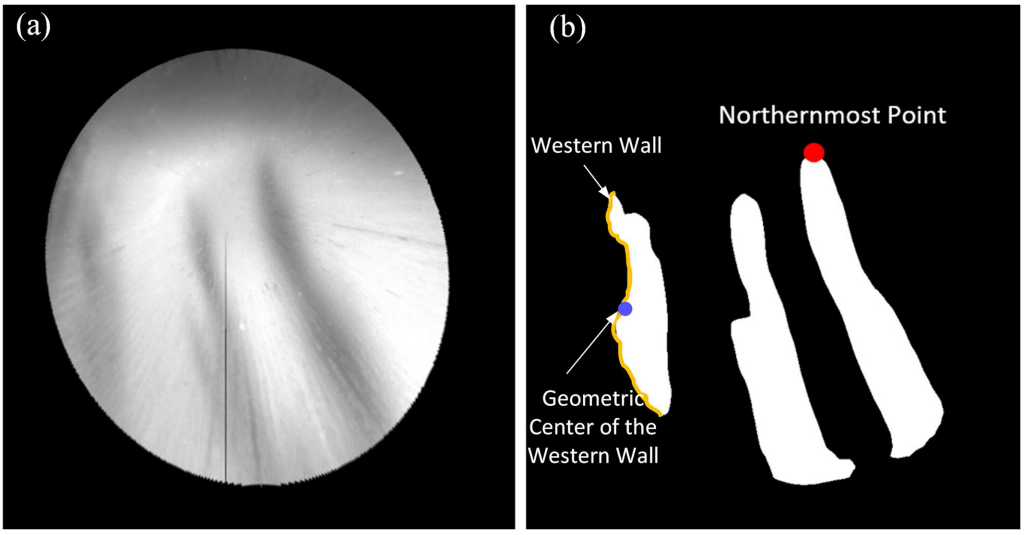

Obrázok 2 – 4 Ukážka segmentovanej snímky EPB s označeným geometrickým centrom západnej steny a polohou najsevernejšieho bodu EPB zo stanice Qujing v Číne. Zdroj: Zhong et al. (2025)

výlučne zo stanice Qujing na geomagnetickej šírke približne 15.1° N, zatiaľ čo stanica El Leoncito leží na južnej geomagnetickej šírke −18° v odlišnom geomagnetickom prostredí s inými sezónnymi vzormi výskytu EPB. Priamy prenos natrénovaného modelu bez adaptácie na lokálne podmienky preto nie je možné považovať za spoľahlivý prístup.

Metódy hlbokého učenia pre segmentáciu štruktúr vo vedeckých snímkach a ich aplikovateľnosť

Butka et al. (2026) vypracovali rozsiahly prehľad súčasného stavu v oblasti automatickej segmentácie a detekcie štruktúr slnečnej koróny – koronálnych dier a aktívnych oblastí – pomocou hlbokých neurónových sietí. Hoci sa táto práca tematicky zameriava na slnečné obrazy získané vesmírnymi teleskopmi SDO a SOHO, jej metodologické závery sú priamo prenositeľné do oblasti segmentácie ionosferických štruktúr na celooblohových airglow snímkach.

Autori systematicky rozlišujú tri úrovne analýzy obrazu – klasifikáciu, detekciu objektov a segmentáciu. Architektúra U-Net a jej varianty majú pretrvávajúci

význam ako základná architektúra v modernom výskume segmentácie.

Model SCSS-Net bol inšpirovaný U-Net a vyvinutý Mackovjak et al. (2021) priamo pre segmentáciu koronálnych štruktúr. SCSS-Net bol postavený na architektúre enkodér-dekodér s piatimi konvolučnými blokmi v enkodéri a štyrmi dekonvolučnými blokmi v dekodéri, doplnený o dropout regularizáciu. Kľúčovým zistením tejto práce je, že model SCSS-Net je schopný naučiť sa efektívne segmentačné vzory aj napriek chybám v manuálnych anotáciách. Pre segmentáciu koronálnych dier dosiahol SCSS-Net hodnotu Dice skóre 0,88 a IoU 0,78 na validačnej množine, pričom výkon modelu bol konzistentný aj na úplne nových dátach z roku 2017, kde hodnota Dice skóre prekročila 0,8 pre 90 % snímok. Tento výsledok má význam z hľadiska zvoleného prístupu, keďže ukazuje, že modely hlbokého učenia sú schopné dosahovať robustný výkon aj pri relatívne obmedzených a nedokonale anotovaných trénovacích datasetoch.

Pokiaľ ide o detekciu objektov, Butka et al. (2026) konštatujú, že pre detekciu slnečných štruktúr boli úspešne nasadené architektúry Faster R-CNN aj rôzne verzie YOLO. Zistenia naznačujú, že YOLO V3 vo všeobecnosti prekonáva Faster R-CNN v rýchlosti aj presnosti pri detekcii aktívnych oblastí, pričom spracováva snímky až osemkrát rýchlejšie, čo ho predurčuje pre aplikácie vyžadujúce spracovanie v reálnom čase.

Butka et al. (2026) ďalej identifikujú sériu otvorených výziev spoločných pre automatizovanú analýzu vedeckých snímok. Najzávažnejšou je nedostatok rozsiahlych, konzistentne anotovaných referenčných datasetov potvrdených viacerými odborníkmi, čo komplikuje objektívne porovnávanie algoritmov a trénovanie robustných modelov. Subjektivita expertného označovania pridáva ďalšiu vrstvu komplexnosti, keďže rôzni odborníci môžu hranice rovnakej štruktúry vyznačiť odlišne. Ďalšou výzvou je interpretovateľnosť modelov – komplexné neurónové siete fungujú ako uzavreté systémy, čo sťažuje pochopenie fyzikálnych príčin konkrétnych segmentačných výstupov. Pre operačné nasadenie v kontexte predpovede vesmírneho počasia je navyše kritická schopnosť modelov spracovávať dáta v reálnom čase pri zachovaní

vysokej robustnosti a konzistentnosti výstupov. Autori v tejto súvislosti upozorňujú na kompromis medzi zachovaním vysokého rozlíšenia vstupných dát a výpočtovou náročnosťou spracovania – nástroje typicky produkujú snímky vo formáte FITS s rozlíšením 4096×4096 pixelov, pričom pre mnohé úlohy je nevyhnutné redukovať rozlíšenie na 1024×1024 pixelov alebo menej.

Tieto výzvy sú rovnako relevantné pre oblasť automatickej segmentácie EPB. Absencia štandardizovaného benchmarkového datasetu pre EPB, subjektivita manuálnych anotácií a geografická obmedzenosť existujúcich trénovacích dát predstavujú hlavné metodologické bariéry, ktoré táto práca adresuje prostredníctvom tvorby nového anotovaného datasetu zo stanice El Leoncito a tréningu segmentačného modelu prispôsobeného lokálnym podmienkam.

3 Segmentácia ekvatoriálnych plazmových bublín

Praktická časť práce sa zaoberá návrhom, realizáciou a vyhodnotením segmentačného modelu pre automatickú detekciu ekvatoriálnych plazmových bublín na snímkach celooblohovej kamery.

Zdrojový kód bol vytvorený v programovacom jazyku Python v prostredí Jupyter Notebook. Na trénovanie a implementáciu segmentačného modelu boli použité knižnice TensorFlow a Keras. Spracovanie a augmentácia obrazových dát boli realizované pomocou knižníc Pillow (PIL), NumPy a Albumentations. Na rozdelenie datasetu bola využitá funkcia `train_test_split` z knižnice scikit-learn. Vizualizácia výsledkov a generovanie výstupných PDF dokumentov boli implementované pomocou knižnice Matplotlib. V počiatočnej fáze prípravy datasetu, pri testovaní klasických metód segmentácie, bola použitá knižnica OpenCV[1]. Na manuálnu anotáciu trénovacích snímok bol využitý open-source nástroj Label Studio[2].

3.1 Pochopenie cieľa práce

Ekvatoriálne plazmové bubliny sú štruktúry vznikajúce v ionosfére, ktorých výskyt a správanie sú predmetom prebiehajúceho vedeckého výskumu. Snímky celooblohovej kamery zachytávajúce airglow žiarenie poskytujú dlhodobé pozorovacie záznamy vhodné na štúdium týchto štruktúr, avšak ich manuálne spracovanie a anotácia vo veľkom rozsahu nie je časovo realizovateľná.

Existujúce metódy počítačového videnia založené na prahovaní a detekcii hrán sa ukázali ako nedostatočné pre spoľahlivú segmentáciu EPB štruktúr, čo je podrobnejšie diskutované v podkapitole 3.3.

Cieľom praktickej časti je navrhnúť a vytvoriť segmentačný model založený na hlbokom učení, ktorý umožní automatizovanú segmentáciu EPB štruktúr na snímkach celooblohovej kamery. Konkrétne úlohy zahŕňajú prípravu anotovaného tré-

[1] `https://opencv.org/`

[2] `https://labelstud.io/`

novacieho datasetu, trénovanie modelu a jeho aplikáciu na rozsiahlu časovú sériu snímok. Keďže konkrétne kvantitatívne kritériá úspešnosti neboli vopred stanovené, výkonnosť modelu je hodnotená kombináciou štandardných segmentačných metrík (Dice koeficient a IoU) a vizuálneho posúdenia kvality predikcií odborníkom.

3.2 Analýza a charakteristika dát

Dáta využívané v praktickej časti práce tvoria čiernobiele snímky získané celooblohovou kamerou, ktorú prevádzkuje Bostonská univerzita v areáli astronomického komplexu Complejo Astronómico El Leoncito v Argentíne. Dáta pochádzajú z nočných pozorovaní uskutočnených v rokoch 2019 až 2023 pri centrálnej vlnovej dĺžke 630,0 nm. Tieto snímky sú verejne dostupné prostredníctvom archívu projektu SIRIUS All-Sky Imager Data Archives[3].

Vstupné snímky sú uložené vo formáte PNG s rozmermi 682×682 pixelov. Snímky zobrazujú celú oblohu v kruhovej projekcii, pričom okraje snímky zodpovedajú horizontu a stred zenitu.

Snímky poskytnuté na anotáciu a trénovanie sa vizuálne líšia od pôvodných snímok dostupných v archíve SIRIUS. Pôvodné snímky z celooblohovej kamery obsahujú okrem kruhového výrezu oblohy aj okrajové oblasti s technickými informáciami kamery. V poskytnutých snímkach sú tieto oblasti prekryté pomocou alfa kanála, ktorý zachováva viditeľnosť výhradne v oblasti kruhového výrezu oblohy. Výsledkom je snímka s ostrým kruhovým výrezom a transparentným pozadím (Obrázok 3 – 1).

Z hľadiska segmentácie predstavujú EPB štruktúry niekoľko charakteristických výziev. Hranice jednotlivých štruktúr sú typicky neostré a plynulo prechádzajú do okolitého pozadia, čo sťažuje ich presné ohraničenie. EPB štruktúry sa výrazne líšia svojou veľkosťou – niektoré zaberajú značnú časť snímky, zatiaľ čo iné sú malé a sotva rozlíšiteľné. Líšia sa tiež svojím kontrastom voči pozadiu – výrazné EPB sú ľahko identifikovateľné, no slabé štruktúry sa len mierne odlišujú od okolitého

[3]Dostupné na: `https://sirius.bu.edu/data/`

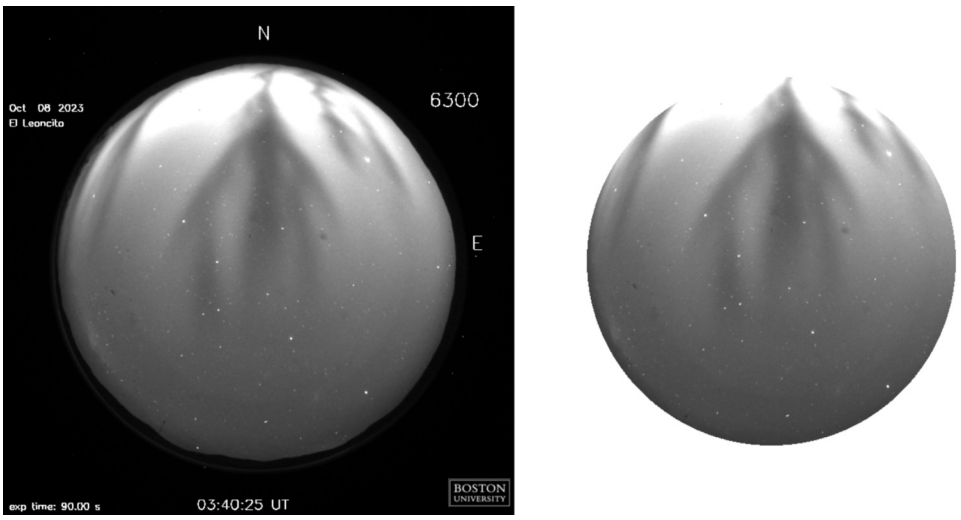

Obrázok 3 – 1 Príklad pôvodnej snímky z archívu SIRIUS a snímky s alfa kanálom.

airglow žiarenia (Obrázky 3 – 2 a 3 – 3). Na niektorých snímkach sa navyše vyskytujú artefakty, ako napríklad hviezdy, oblačnosť alebo tiene na oblohe, ktoré môžu komplikovať segmentáciu.

Dáta použité na generovanie predikcií a aplikáciu finálneho modelu boli poskytnuté konzultantom a boli predbežne vytriedené konvolučnou neurónovou sieťou klasifikujúcou prítomnosť EPB štruktúr, čím boli vylúčené snímky bez ich výskytu. Toto triedenie však nebolo dokonalé pretože niektoré snímky obsahujú okrem EPB aj vyššie spomínané artefakty. Snímky určené na manuálnu anotáciu boli vybrané s dôrazom na jasnú oblohu s viditeľnými EPB štruktúrami.

Uvedené vlastnosti vstupných dát významne komplikovali využitie tradičných metód segmentácie založených na prahovaní a detekcii hrán, čo viedlo k potrebe využitia prístupov založených na hlbokom učení.

V jednotlivých fázach práce boli použité rôzne sady snímok odlišujúce sa svojím rozsahom, časovým pokrytím a účelom. Prehľad týchto datasetov je uvedený v Tabuľke 3 – 1.

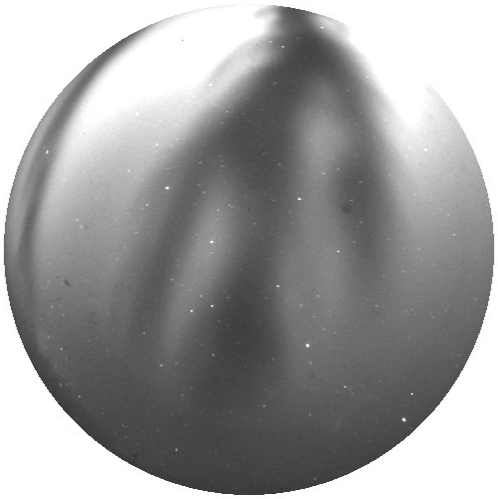

Obrázok 3 – 2 Príklad snímky s výraznými EPB štruktúrami (El Leoncito, 13.10.2023).



Obrázok 3 – 3 Príklad snímky s horšie viditeľnými EPB štruktúrami (El Leoncito, 8.10.2023).

Tabuľka 3 – 1 Prehľad datasetov použitých v jednotlivých fázach práce.

Dataset	Obdobie	Počet snímok	Účel
Manuálne anotované snímky	2. – 9.10.2023	111	Trénovanie 1. modelu
Predikcie 1. modelu	Okt. – Dec. 2023	605	Trénovanie 2. modelu
Celá časová séria	2019 – 2023	5 945	Segmentácia EPB štruktúr

3.3 Príprava datasetu

Nevyhnutným predpokladom trénovania segmentačného modelu bolo vytvorenie anotovaného datasetu. Keďže žiadny verejne dostupný dataset určený na segmentáciu EPB štruktúr zo snímok celooblohových kamier neexistuje, bolo potrebné príslušný dataset vytvoriť. Proces jeho tvorby prebiehal v troch fázach: pokus o automatickú segmentáciu metódami počítačového videnia, testovanie existujúceho natrénovaného modelu a manuálna anotácia.

Pokusy o automatickú segmentáciu

V prvej fáze boli otestované klasické metódy počítačového videnia dostupné v knižnici OpenCV s cieľom automaticky vygenerovať segmentačné masky. OpenCV je multiplatformová open-source knižnica určená pre úlohy počítačového videnia a strojového učenia. Využíva sa hlavne na spracovanie a analýzu vizuálnych dát, ako sú snímky a videa.

Boli aplikované nasledujúce prístupy (Obrázok 3 – 4):

- **K-means zhlukovanie** – rozdeľuje pixely snímky do vopred stanoveného počtu skupín podľa podobnosti ich intenzity (Hartigan and Wong, 1979).
- **Prahovanie (angl. Thresholding)** – klasifikuje každý pixel snímky ako popredie alebo pozadie podľa toho, či jeho intenzita prekračuje stanovenú hraničnú

hodnotu (Sahoo et al., 1988).

- **Canny Edge Detection** – detekuje hranice objektov na základe prudkých zmien intenzity medzi susednými pixelmi a produkuje binárnu mapu hrán (Canny, 1986).

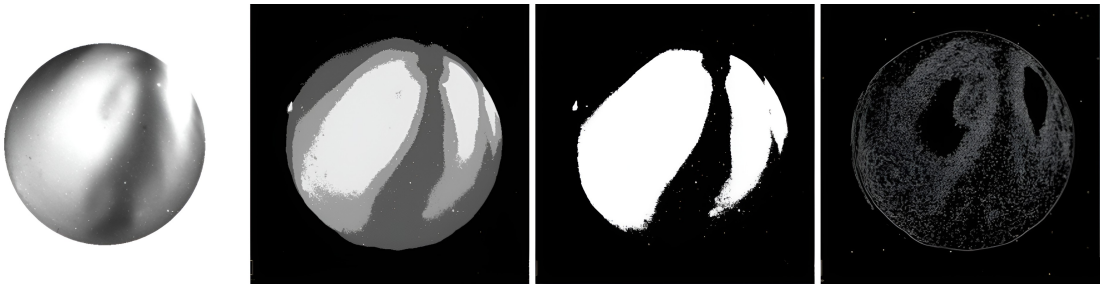

Obrázok 3 – 4 Pôvodná snímka – K-means – Prahovanie – Algoritmus Canny.

Žiadna z týchto metód však neposkytla výsledky použiteľné na trénovanie modelu. Primárnym obmedzením bol charakter vstupných dát: čiernobiele snímky s nízkym kontrastom, obzvlášť výrazným v prípade menších plazmových bublín. Okrem toho ekvatoriálne plazmové bubliny nemajú ostro definované hranice, čo znemožňuje ich spoľahlivú detekciu metódami založenými na hranách a prahovaní.

Použitie modelu SCSS-Net na tvorbu masiek

Keďže manuálna anotácia snímok je časovo náročná, bol ako ďalší krok otestovaný existujúci natrénovaný model SCSS-Net (Solar Corona Structures Segmentation Network) (Mackovjak et al., 2021), pôvodne vyvinutý a natrénovaný na segmentáciu štruktúr slnečnej koróny.

Keďže SCSS-Net bol natrénovaný na odlišnom type vstupných dát, boli otestované tri varianty predspracovania snímok s cieľom priblížiť charakter vstupných dát trénovacím snímkam modelu:

- **pôvodné snímky bez akýchkoľvek úprav**

- **snímky so zvýšeným kontrastom** – Bola upravená gamma krivka s cieľom zvýrazniť rozdiely medzi EPB štruktúrami a okolitým pozadím.
- **invertované snímky (výmena intenzít pozadia a štruktúr)** – EPB štruktúry, ktoré sa na pôvodných snímkach prejavujú ako tmavšie oblasti na svetlejšom pozadí, boli takto prevedené na svetlejšie oblasti na tmavom pozadí, čo zodpovedá charakteru koronálnych štruktúr. Pri tomto variante sa testovalo, či bude model lepšie označovať oblasti mimo EPB štruktúr, pričom neoznačené oblasti by boli následne interpretované ako EPB.

Vo všetkých prípadoch model generoval výstupné segmentačné masky, ktoré nevykazovali dostatočnú presnosť. Spoločným nedostatkom bolo označovanie oblastí mimo kruhového tvaru na snímkach. Ďalším nedostatkom bolo, že masky nezachytávali skutočný tvar a rozsah EPB, alebo model prítomnosť štruktúr vôbec neidentifikoval, čo bolo charakteristické najmä pre EPB s nižším kontrastom. Príklady výstupu modelu SCSS-Net sú znázornené na Obrázkoch 3 – 5 a 3 – 6.

Manuálna anotácia datasetu

Vzhľadom na nevyhovujúce výsledky predchádzajúcich prístupov bolo pristúpené k manuálnej anotácii snímok. Na tento účel bol využitý open-source nástroj Label Studio, ktorý poskytuje mnoho šablón pre rôzne druhy anotácií. Pre vytváranie presných segmentačných masiek bola využitá šablóna z kategórie Počítačové videnie: Sémantická segmentácia pomocou polygónov.

Proces manuálnej anotácie predstavoval časovo náročnú úlohu vzhľadom na charakter hraníc plazmových bublín. Celkovo bolo anotovaných 120 snímok z obdobia 2. až 9. október 2023. Ukážka anotačného prostredia Label Studio je zobrazené na Obrázku 3 – 7.

Po dokončení anotácií bola vykonaná kontrola ich kvality. Pri tejto kontrole bolo 9 snímok vyradených – dôvodom boli nejednoznačné alebo nepresné obrysy anotácií.

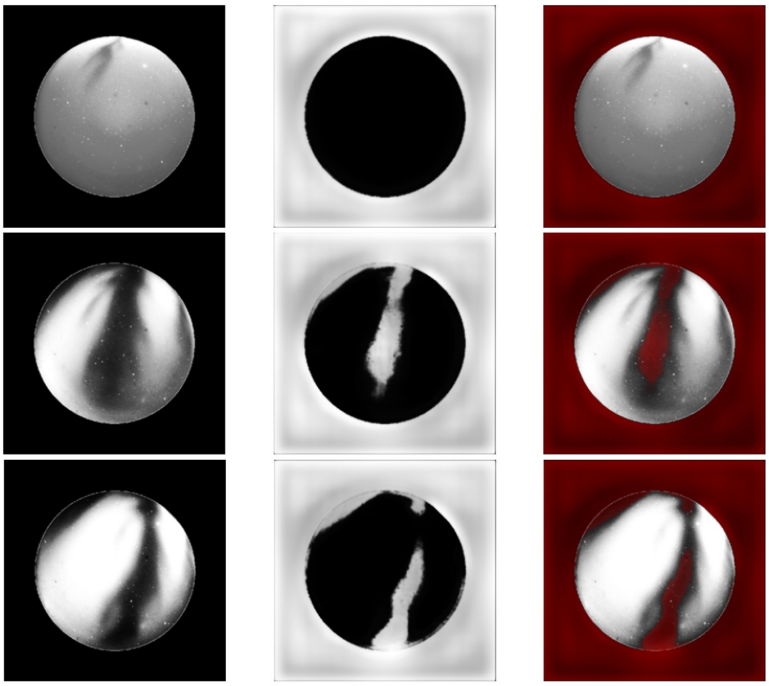

Obrázok 3 – 5 Snímka so zvýšeným kontrastom – Predikcia modelu SCSS-Net – Overlay.

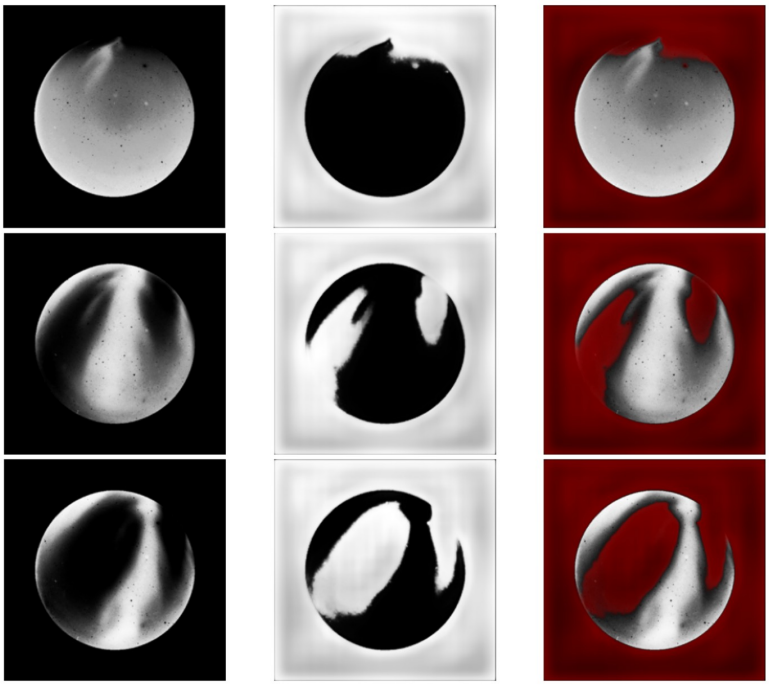

Obrázok 3 – 6 Invertovaná snímka so zvýšeným kontrastom – Predikcia modelu SCSS-Net – Overlay.

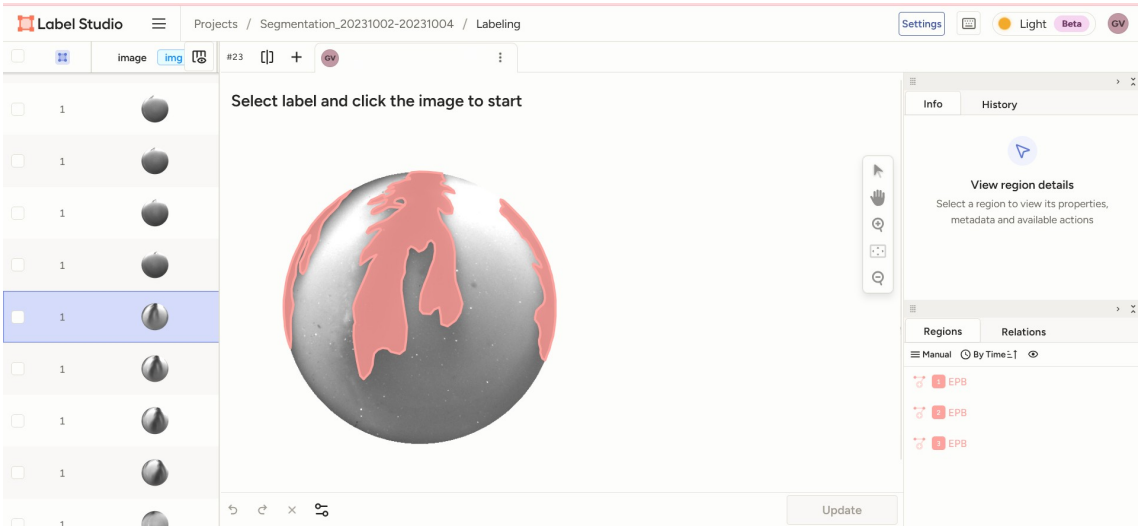

Obrázok 3 – 7 Prostredie Label Studio.

Finálny dataset tvorilo 111 anotovaných snímok. Ukážka manuálne vytvorených masiek je na Obrázku 3 – 8.

Rozdelenie datasetu

Dataset s 111 anotovanými snímkami bol pred trénovaním rozdelený do troch disjunktných množín: trénovacej, validačnej a testovacej. Rozdelenie prebehlo v dvoch krokoch. V prvom kroku bol dataset rozdelený na trénovaciu a testovaciu časť v pomere 90:10 pomocou funkcie `train_test_split` z knižnice scikit-learn. Testovacia množina bola fyzicky oddelená do samostatných priečinkov a slúžila výhradne na záverečné vyhodnotenie modelu.

Druhý krok rozdelenia prebehol po predspracovaní snímok popísanom v časti nižšie. Trénovacia množina bola pri každom trénovaní rozdelená v rovnakom pomere 90:10 na vlastnú trénovaciu a validačnú časť. Toto rozdelenie bolo vykonané náhodne pri každom spustení trénovania bez pevne stanoveného `random_state`, čo zavádza mieru variability medzi jednotlivými trénovaniami. Prehľad rozdelenia datasetu je uvedený v Tabuľke 3 – 2.

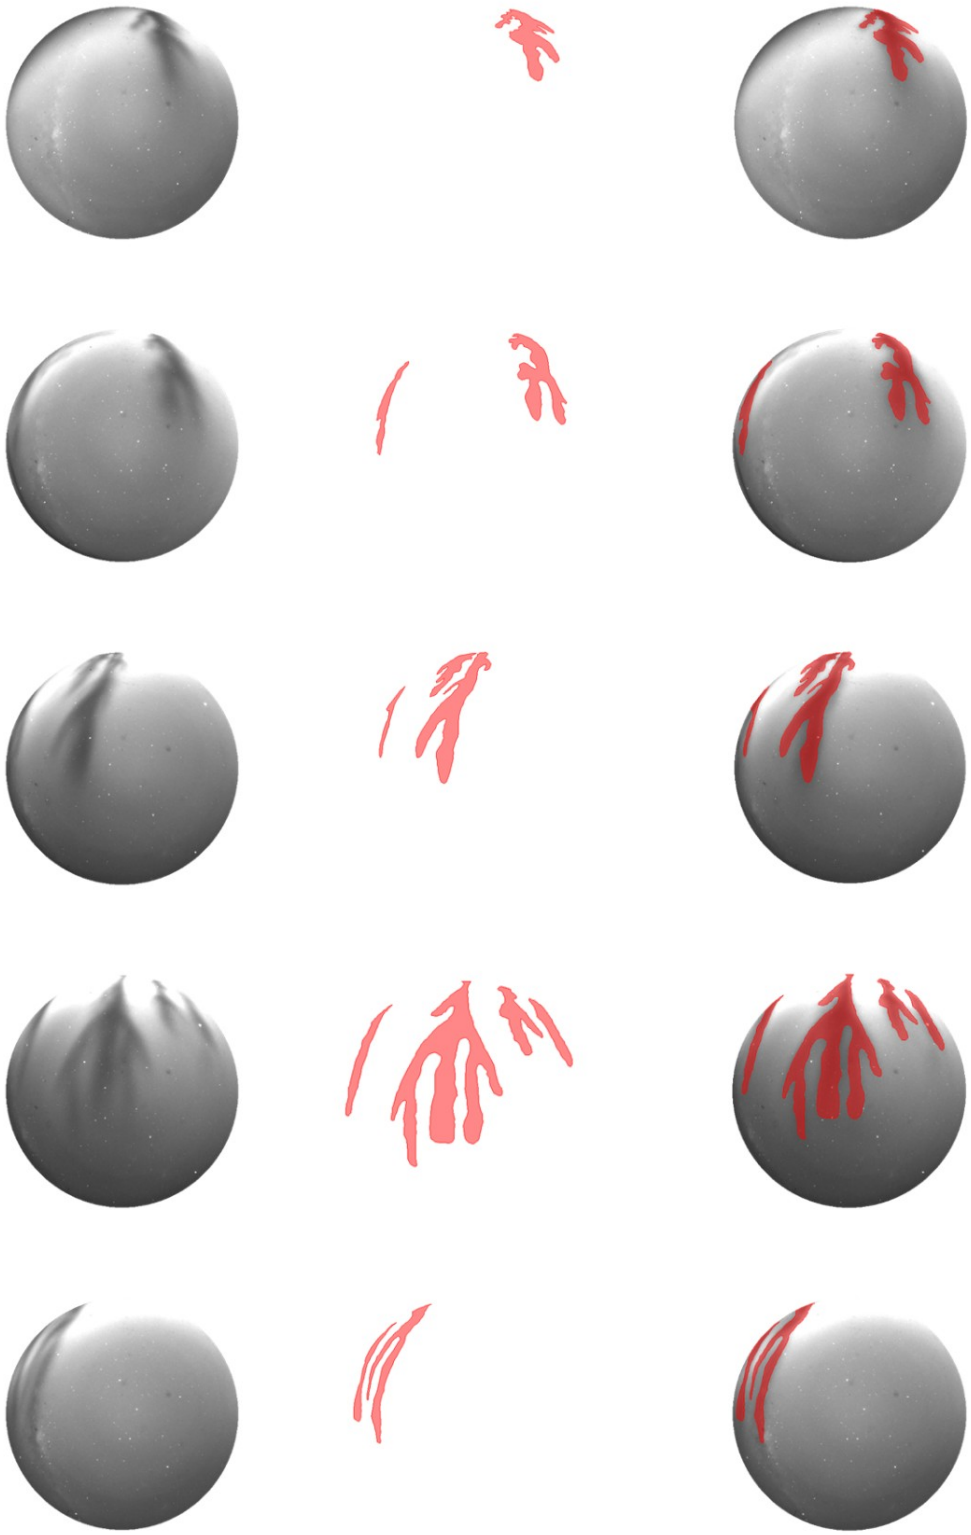

Obrázok 3 – 8 Manuálne anotácie.

Tabuľka 3 – 2 Rozdelenie datasetu s manuálne vytvorenými anotáciami.

Množina	Počet snímok
Trénovacia	89
Validačná	10
Testovacia	12

Predspracovanie snímok

Pred trénovaním boli snímky a masky načítané zo súborového systému v poradí zoradenom podľa názvu, čím bola zabezpečená správna korešpondencia každej snímky s príslušnou maskou. Táto korešpondencia bola pred načítaním explicitne overená porovnaním názvov súborov, keďže akýkoľvek nesúlad v poradí by viedol k nesprávnemu priradeniu masiek a znehodnoteniu trénovania.

Pri načítaní bol z každej snímky korektne odstránený alfa kanál. Snímky totiž obsahovali alfa vrstvu, ktorá prekrývala oblasti mimo kruhového výrezu. Bez jeho korektného spracovania by pri prevode do odtieňov šedej došlo k zobrazeniu okrajových artefaktov, ktoré by mohli negatívne ovplyvniť trénovanie modelu. Následne boli snímky zmenšené na rozmer zodpovedajúci vstupu modelu. Masky boli načítané a priamo prevedené do odtieňov šedej bez spracovania alfa kanála, keďže obsahujú len binárne hodnoty pixelov zodpovedajúce popredíu a pozadiu.

Hodnoty pixelov snímok aj masiek boli následne normalizované z pôvodného rozsahu $[0, 255]$ do rozsahu $[0, 1]$ vydelením hodnotou 255. Snímky aj masky boli uložené ako štvordimenzionálne polia s tvarom (počet snímok, výška, šírka, 1), kde posledná dimenzia zodpovedá jednému kanálu.

Augmentácia dát

Keďže veľkosť trénovacieho datasetu bola obmedzená, bola na jeho umelé rozšírenie použitá augmentácia dát. Augmentácie znižujú riziko preučenia tým, že model počas trénovania vidí pri každej epoche mierne odlišné varianty trénovacích snímok,

a zároveň zlepšujú jeho schopnosť generalizovať na nové, predtým nevidené dáta (Shorten and Khoshgoftaar, 2019).

Na augmentáciu trénovacích dát bol implementovaný vlastný generátor dát využívajúci knižnicu Albumentations.

Augmentácie boli rozdelené do dvoch skupín aplikovaných nezávisle:

- **Geometrické augmentácie** – horizontálne a vertikálne prevrátenie snímky. Rotácia nebola zahrnutá, keďže EPB štruktúry sa na snímkach celooblohových kamier vyskytujú výhradne v smere zhora nadol, a rotované vzorky by teda nezodpovedali reálnym pozorovaniam, čo by mohlo zhoršiť výkon modelu.
- **Farebné augmentácie** – náhodná úprava hodnoty gamma, jasu a kontrastu. Použité boli výlučne na obrazové snímky. Na masky neboli aplikované, aby sa predišlo znehodnoteniu anotácií.

Prehľad použitých augmentácií je uvedený v Tabuľke 3 – 3.

Tabuľka 3 – 3 Prehľad augmentácií.

Augmentácia	**Typ**	**Aplikovaná na**	**Parameter**
Horizontálne prevrátenie	Geometrická	Snímka + maska	$p = 0{,}5$
Vertikálne prevrátenie	Geometrická	Snímka + maska	$p = 0{,}5$
Gamma	Farebná	Snímka	gamma $[100, 150]$ $p = 0{,}5$
Jas a kontrast	Farebná	Snímka	jas $\pm 0{,}2$ kontrast $\pm 0{,}4$ $p = 0{,}5$

Poznámka: p označuje pravdepodobnosť aplikovania danej augmentácie na každú snímku počas trénovania – hodnota $p = 0{,}5$ znamená 50 %. Rozsah $[100, 150]$ udáva interval z ktorého je náhodne vybraná hodnota gamma korekcie. Hodnoty $\pm 0{,}2$ a $\pm 0{,}4$ označujú maximálnu odchýlku od pôvodnej hodnoty jasu a kontrastu.

3.4 Modelovanie

Segmentačný model bol vyvinutý na základe architektúry SCSS-Net (Solar Corona Structures Segmentation Network) (Mackovjak et al., 2021). SCSS-Net vychádza z enkóder-dekóder architektúry inšpirovanej sieťou U-Net a je implementovaný v prostredí TensorFlow a Keras. Implementácia bola prispôsobená pre segmentáciu EPB štruktúr na snímkach celooblohových kamier – konkrétne bola nahradená knižnica pre augmentáciu dát, upravená veľkosť vstupných snímok a `batch_size`. Trénovanie prebiehalo na grafickej karte NVIDIA Quadro RTX 4000.

Architektúra SCSS-Net

Architektúru SCSS-Net môžeme vidieť na Obrázku 3 – 9. Enkóder pozostáva z piatich konvolučných blokov. Každý blok obsahuje dve konvolučné vrstvy s jadrom 3×3 pixely, vrstvu batch normalizácie a aktivačnú funkciu ReLU. Batch normalizácia stabilizuje a urýchľuje trénovanie tým, že udržuje výstup každej vrstvy s nulovou strednou hodnotou a jednotkovou štandardnou odchýlkou (Ioffe and Szegedy, 2015).

Počet filtrov začína na hodnote 32 v prvom bloku a v každom ďalšom bloku sa zdvojnásobuje, čím sa postupne extrahujú čoraz abstraktnejšie príznaky. Medzi konvolučnými blokmi sa nachádzajú vrstvy `max-pooling` s veľkosťou okna 2×2 pixely, ktoré redukujú priestorové rozlíšenie príznakových máp. V troch hlbších konvolučných blokoch je použitá regularizácia vo forme vrstvy Dropout, ktorá náhodne vypína 50 % neurónov.

Dekóder pozostáva zo štyroch dekonvolučných blokov, ktoré postupne obnovujú priestorové rozlíšenie príznakových máp na pôvodný rozmer vstupnej snímky. Každý dekonvolučný blok obsahuje dve transponované konvolučné vrstvy s jadrom 3×3 pixely, batch normalizáciu a aktivačnú funkciu ReLU. Počet filtrov začína na hodnote 256 a v každom ďalšom bloku sa znižuje na polovicu. Bloky sú prepojené vrstvami `upsampling` s faktorom 2×2, ktoré zdvojnásobujú priestorové rozmery príznakových máp. Za prvými dvoma dekonvolučnými blokmi je opäť použitý Dropout.

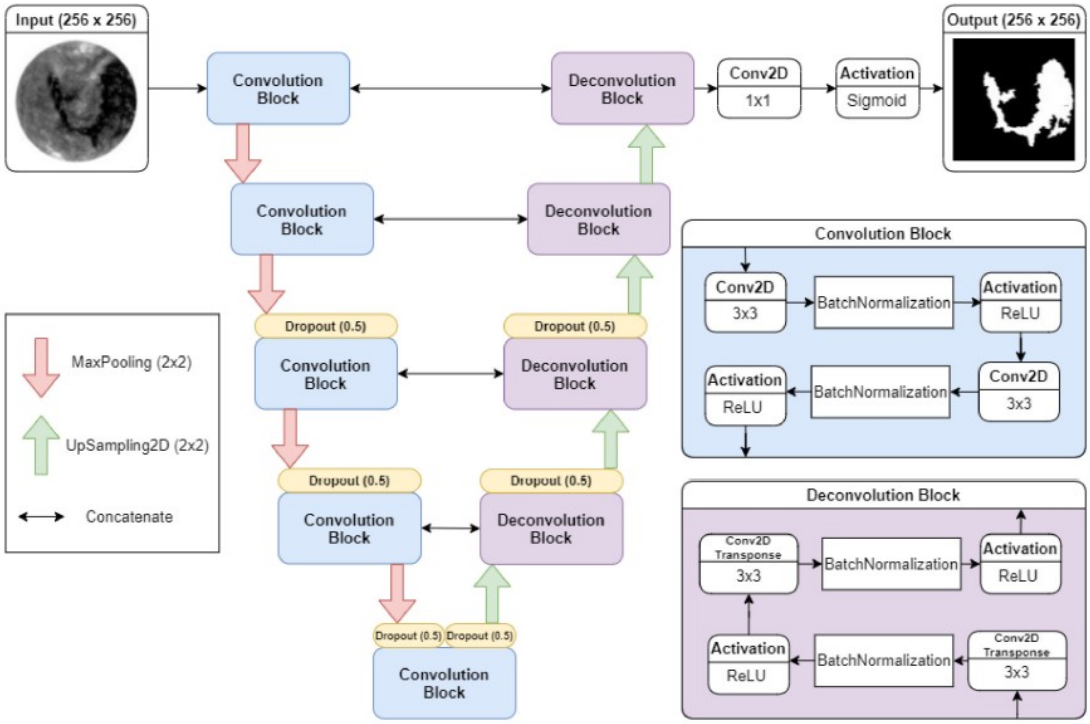

Obrázok 3 – 9 Architektúra SCSS-Net. Zdroj: Mackovjak et al. (2021)

Funkcia `concatenate` je vyžívaná na spájanie príznakových máp medzi jednotlivými úrovňami siete a umožňuje prenášanie lokalizačných informácii z enkodéra do dekodéra. Výstupná vrstva pozostáva z konvolučnej vrstvy o veľkosti 1×1 a aktivačnej funkcie sigmoid, ktorá produkuje pre každý pixel hodnotu v intervale [0,1] reprezentujúcu pravdepodobnosť príslušnosti k danej triede. Z výstupnej pravdepodobnostnej mapy následne vzniká binárna segmentačná maska.

Konfigurácia trénovania

Model bol trénovaný s optimalizačným algoritmom Adam s hodnotou `learning rate` $\alpha = 0,001$. Ako stratová funkcia bola použitá binárna krížová entropia. Výkon modelu bol počas trénovania sledovaný pomocou metrík Dice a IoU. `Batch-size` bola nastavená na 1, čo zodpovedalo pamäťovým obmedzeniam dostupného hardvéru pri danej veľkosti vstupných snímok.

Na ukladanie najlepšieho modelu počas trénovania bol použitý callback `ModelCheckpoint`, ktorý priebežne ukladal váhy modelu s najlepšou hodnotou validačnej straty.

Trénovanie prvého modelu

Prvý model bol natrénovaný na manuálne anotovanom datasete 111 snímok s veľkosťou vstupu 640 × 640 pixelov. Táto veľkosť bola zvolená ako najväčší rozmer pri ktorom bolo možné trénovanie spustiť bez chyby nedostatku pamäte grafickej karty pri danej `batch-size`. Trénovanie bolo nakonfigurované na maximálne 300 epoch s použitím callbackov `ModelCheckpoint` a `EarlyStopping`. EarlyStopping sledoval validačnú stratu s `patience=30` epoch – ak sa validačná strata nezlepšila počas 30 po sebe nasledujúcich epoch, trénovanie bolo predčasne ukončené. Model dosiahol najlepšiu hodnotu validačnej straty v epoche 109. Priebeh trénovania prvého modelu je zobrazený na Obrázku 3 – 10.

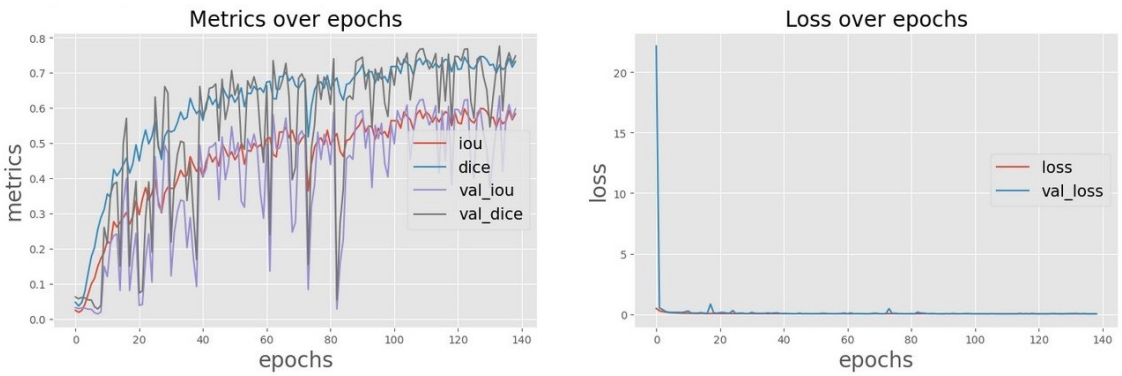

Obrázok 3 – 10 Priebeh trénovania prvého modelu. Ľavý graf zobrazuje vývoj metrík Dice a IoU na trénovacej a validačnej množine. Pravý graf zobrazuje vývoj stratovej funkcie.

Natrénovaný prvý model bol následne použitý na generovanie segmentačných predikcií pre 923 snímok z obdobia október až december 2023. Výstupy modelu boli vizuálne skontrolované konzultantom tejto práce a z nich bolo vybraných 605 kvalitných predikcií, ktoré tvorili rozšírený trénovací dataset pre druhý model. Pri vizuálnej kontrole boli vyradené predikcie na snímkach s nevyhovujúcimi pozorova-

cími podmienkami. Problémom boli artefakty t. j. oblačnosť alebo tiene na oblohe, ktoré boli nesprávne označované ako EPB. Príklady dobrých a vyradených predikcií sú zobrazené na Obrázkoch 3 – 11 a 3 – 12.

Tento postup, pri ktorom predikcie natrénovaného modelu slúžia ako pseudoanotácie (angl. *pseudo-annotations* alebo *pseudo-labels*) pre trénovanie ďalšieho modelu, umožnil výrazne rozšíriť trénovaciu množinu bez potreby ďalšej časovo náročnej manuálnej anotácie.

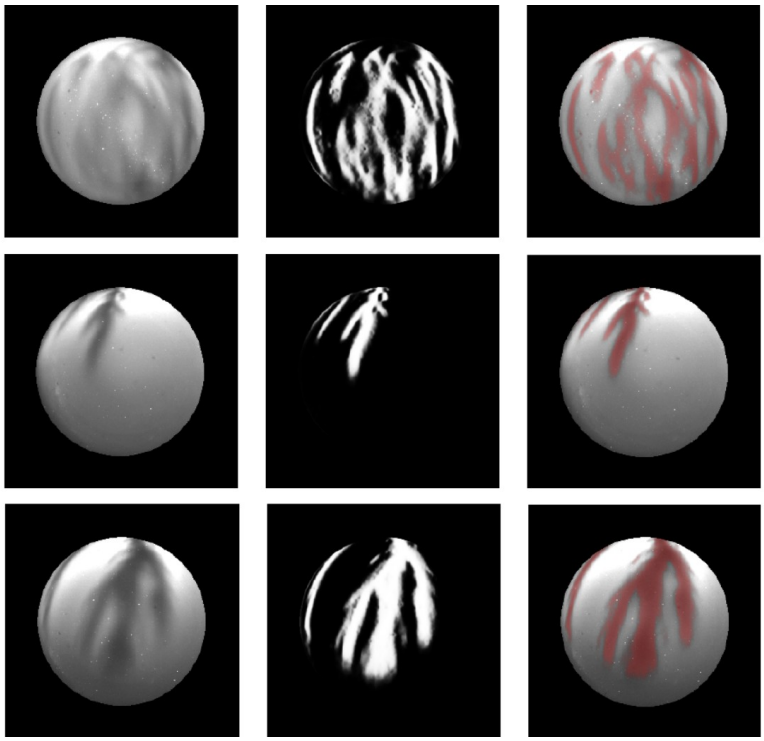

Obrázok 3 – 11 Ukážka dobrých predikcií prvého modelu.

Trénovanie druhého modelu

Druhý model bol natrénovaný na rozšírenom datasete 605 snímok s veľkosťou vstupu 512×512 pixelov. Menší rozmer vstupu oproti prvému modelu zodpovedá veľkostiam bežne používaným pri architektúrach typu U-Net. Hyperparametre zostali totožné s prvým modelom.

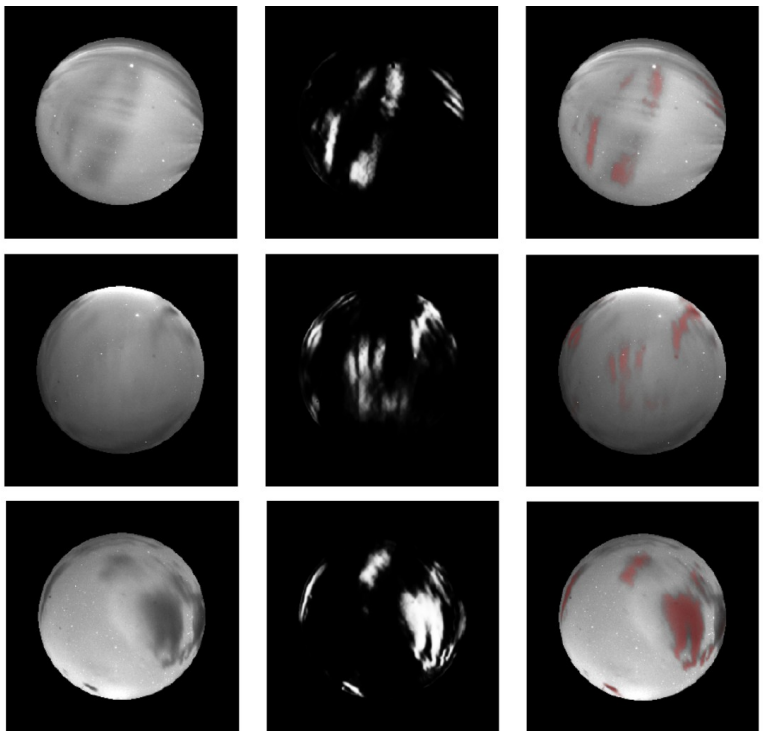

Obrázok 3 – 12 Ukážka vyradených predikcií prvého modelu.

Druhý model bol trénovaný v dvoch iteráciách. V prvej iterácii bolo trénovanie nakonfigurované s `EarlyStopping` identicky ako pri prvom modeli. Trénovanie bolo predčasne ukončené v epoche 67, pričom model obnovil váhy z epochy 37. Nízky počet dosiahnutých epoch naznačoval, že model mohol mať priestor na ďalšie zlepšenie pri dlhšom trénovaní, preto bola vykonaná druhá iterácia s pevne stanoveným počtom 100 epoch. Callback `ModelCheckpoint` naďalej priebežne ukladal váhy z epochy s najlepšou validačnou stratou. Priebeh trénovania druhého modelu – 2. iterácia je zobrazený na obrázku 3 – 13.

Prehľad trénovania jednotlivých modelov je zhrnutý v tabuľke 3 – 4.

3.5 Vyhodnotenie modelov

Výkonnosť natrénovaných modelov bola vyhodnotená pomocou metrík Dice koeficient a IoU, ktoré boli sledované počas trénovania na validačnej množine a po trénovaní vyhodnotené na testovacej množine. Metriky boli vypočítané dvojako – priamo

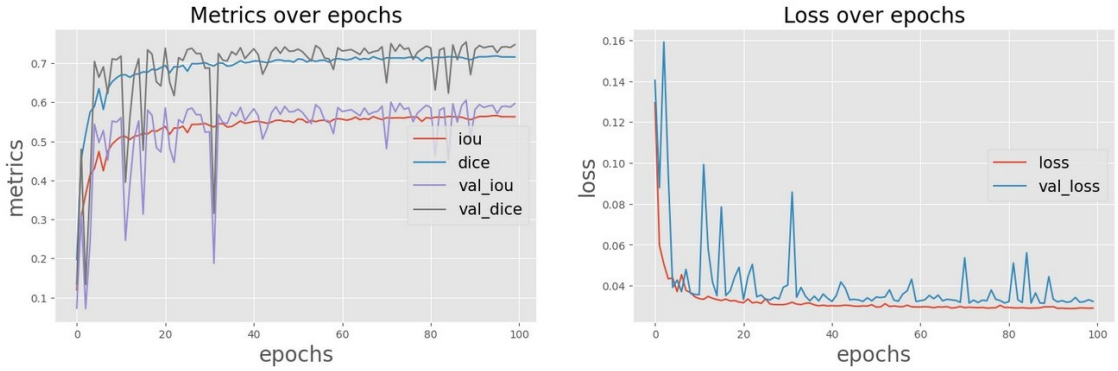

Obrázok 3 – 13 Priebeh trénovania druhého modelu – 2. iterácia. Ľavý graf zobrazuje vývoj metrík Dice a IoU na trénovacej a validačnej. Pravý graf zobrazuje vývoj stratovej funkcie.

Tabuľka 3 – 4 Porovnanie modelov.

	Prvý model	**Druhý model 1. iterácia**	**Druhý model 2. iterácia**
Veľkosť vstupu	640×640	512×512	512×512
Trénovací dataset	111 snímok	605 snímok	605 snímok
EarlyStopping	Áno (patience = 30)	Áno (patience = 30)	Nie
Max. počet epoch	300	300	100
Ukončené v epoche	139	67	100
Najlepšia epocha	109	37	89

z výstupných pravdepodobnostných máp modelu a po aplikovaní prahu 0,5, pri ktorom sa hodnoty menšie ako 0,5 zmenili na 0 a väčšie na 1. Prahované hodnoty (`Dice_thresh`, `IoU_thresh`) zodpovedajú reálnym výstupom modelu používaným pri segmentácii a sú preto primárnym ukazovateľom výkonnosti. Výsledky vyhodnotenia všetkých trénovaní na validačnej a testovacej množine sú zhrnuté v Tabuľkách 3 – 5 a 3 – 6.

Tabuľka 3 – 5 Porovnanie výsledkov modelov na validačnej množine.

Model	**Množina**	**Dice**	**Dice_thresh**	**IoU**	**IoU_thresh**
Prvý model	Validačná	0,7671	0,8299	0,6221	0,7092
Druhý model 1. iterácia	Validačná	0,7503	0,8251	0,6003	0,7023
Druhý model 2. iterácia	Validačná	0,7534	0,8236	0,6044	0,7001

Tabuľka 3 – 6 Porovnanie výsledkov modelov na testovacej množine.

Model	**Množina**	**Dice**	**Dice_thresh**	**IoU**	**IoU_thresh**
Prvý model	Testovacia	0,7564	0,8299	0,6082	0,6990
Druhý model 1. iterácia	Testovacia	0,7450	0,8218	0,5936	0,6975
Druhý model 2. iterácia	Testovacia	0,7574	0,8276	0,6096	0,7059

Všetky tri modely dosiahli porovnateľné výsledky. Mierne vyššie kvantitatívne metriky prvého modelu sú pravdepodobne dôsledkom menšieho a menej variabilného trénovacieho datasetu, na ktorom sa model mohol ľahšie prispôsobiť. Druhý model z druhej iterácie dosiahol na testovacej množine mierne vyššie `IoU_thresh` ako prvý model, čo naznačuje lepšiu generalizáciu na nevidené dáta napriek porovnateľným validačným metrikám. Po konzultácii s odborníkmi Prof. Carlos Martinis z Boston-

skej univerzity a RNDr. Šimonom Mackovjakom, PhD. bol ako finálny model zvolený druhý model z druhej iterácie.

Finálny model bol dodatočne vyhodnotený na všetkých 111 manuálne anotovaných snímkach s cieľom porovnať odlišnosť predikovaných masiek od manuálne vytvorených. Predikcie boli generované s prahom 0,6, ktorý bol zvolený experimentálne s cieľom dosiahnuť konzervatívnejšiu segmentáciu. Pre každú snímku boli vypočítané hodnoty Dice a IoU, súhrnné výsledky sú uvedené v Tabuľke 3 – 7.

Tabuľka 3 – 7 Vyhodnotenie finálneho modelu na manuálne anotovaných snímkach.

Množina	**Počet snímok**	**Prah**	**Mean Dice**	**Mean IoU**
Manuálne anotované snímky	111	0,6	0,7978	0,6710

Pri vizuálnej kontrole vygenerovaných predikcií bolo v niektorých prípadoch pozorované, že výstupy modelu presnejšie zachytávali skutočný rozsah EPB štruktúr ako referenčné manuálne masky. Tento jav je dôsledkom inherentnej subjektivity manuálnej anotácie – pri štruktúrach s neostro definovanými hranicami závisí presné ohraničenie anotovanej oblasti od individuálneho úsudku anotátora. V takýchto prípadoch môžu byť hodnoty metrík Dice a IoU umelo znížené, keďže predikcia je porovnávaná s referenčnou maskou, ktorá nemusí byť sama o sebe úplne presná. Toto obmedzenie je charakteristické pre segmentačné úlohy kde neexistuje jednoznačná objektívna hranica segmentovaných štruktúr a bolo pozorované aj v pôvodnej práci SCSS-Net pri segmentácii koronálnych dier (Mackovjak et al., 2021).

Výkonnosť modelu je úzko prepojená s kvalitou vstupných dát a pozorovacími podmienkami. Model sa spolieha na to, že vstupná snímka zodpovedá podmienkam reprezentovaným v trénovacom datasete – pri výraznej odchýlke, ako bolo ilustrované na príkladoch problematických predikcií v podkapitole 3.4, môže produkovať nepresné predikcie. Rozšírenie datasetu o väčší počet anotovaných snímok pokrývajúcich rôzne pozorovacie podmienky by mohlo výkonnosť modelu v týchto prípadoch zlepšiť.

3.6 Nasadenie modelu

Finálny segmentačný model bol aplikovaný na dataset pozostávajúci z 5 945 snímok pokrývajúcich celé sledované obdobie rokov 2019 až 2023. Cieľom tohto kroku bolo automatizovane segmentovať EPB štruktúry na rozsiahlej časovej sérii snímok, čo by pri manuálnom prístupe nebolo časovo realizovateľné.

Výstupy modelu boli organizované do prehľadného PDF dokumentu. Pre každú snímku bola vygenerovaná trojica obrazov zobrazená v jednom riadku: pôvodná snímka, predikcia modelu a overlay predikcie na pôvodnú snímku. Keďže pre tieto snímky neexistujú referenčné masky, výstupy nebolo možné kvantitatívne vyhodnotiť pomocou metrík Dice a IoU – posúdenie kvality predikcií je v tomto prípade výhradne vizuálne. Ukážka predikcií je zobrazená na Obrázku 3 – 14.

Výsledné segmentácie boli odovzdané na ďalšie spracovanie v rámci výskumu ionosféry a predstavujú podklad pre nadväzujúcu analýzu EPB štruktúr v sledovanom období. Získané segmentačné masky pokrývajúce päťročné obdobie predstavujú základ pre potenciálne nadväzujúce štatistické analýzy EPB štruktúr, ako napríklad sledovanie zmien ich veľkosti, tvaru alebo frekvencie výskytu v čase v závislosti od slnečnej aktivity. Tieto analýzy však presahujú rámec tejto práce a môžu byť predmetom ďalšieho výskumu.

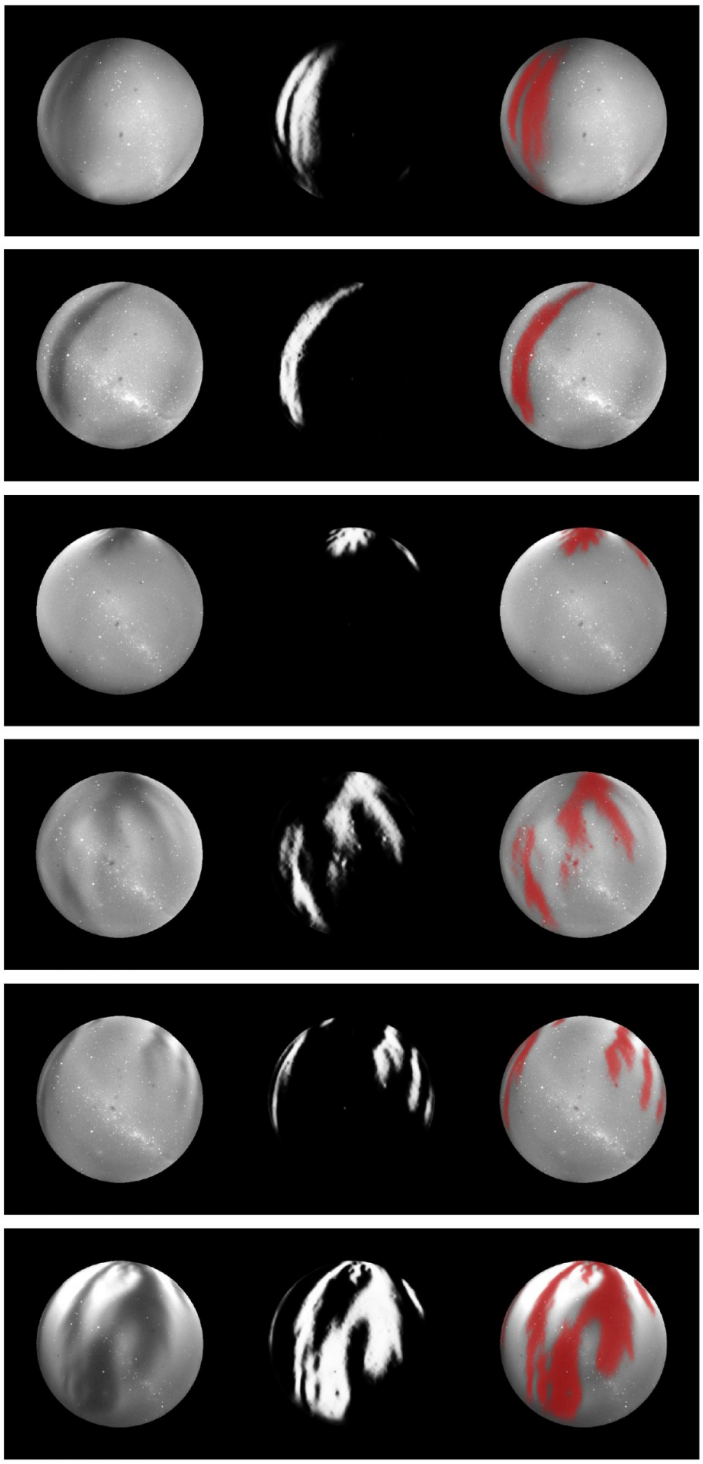

Obrázok 3 – 14 Ukážka predikcií finálneho modelu.

4 Záver

Cieľom práce bolo navrhnúť, realizovať a vyhodnotiť segmentačný model hlbokého učenia pre automatickú detekciu ekvatoriálnych plazmových bublín na snímkach celooblohovej kamery prevádzkovanej Bostonskou univerzitou v argentínskom observatóriu Complejo Astronómico El Leoncito.

V teoretickej časti bol podaný prehľad metód hlbokého učenia so zameraním na konvolučné neurónové siete a architektúru U-Net. Ďalej bola opísaná problematika airglow žiarenia a ekvatoriálnych plazmových bublín a analyzovaný súčasný stav výskumu v oblasti automatickej analýzy ionosférických štruktúr.

V praktickej časti bol realizovaný celý proces vývoja segmentačného modelu. Keďže pre segmentáciu EPB štruktúr neexistoval verejne dostupný anotovaný dataset, bol vytvorený vlastný manuálne anotovaný dataset. Na základe architektúry SCSS-Net boli natrénované dva segmentačné modely – prvý na manuálne anotovanom datasete, druhý na datasete rozšírenom pomocou predikcií prvého modelu. Finálny model bol úspešne aplikovaný na rozsiahlu časovú sériu snímok pokrývajúcich obdobie rokov 2019 až 2023. Získané segmentačné masky pokrývajúce päťročné obdobie predstavujú podklad pre nadväzujúce štatistické analýzy EPB štruktúr, ako napríklad analýzu ich geografického rozloženia, sezónnej variability alebo vzťahu k solárnej aktivite, čo môže byť predmetom ďalšieho výskumu.

Napriek dosiahnutým výsledkom existuje priestor na ďalšie zlepšenie. Dataset pre trénovanie druhého modelu bol síce rozšírený na 605 snímok, čo predstavuje zlepšenie oproti počiatočným 111 manuálne anotovaným snímkam, no pre úlohu segmentácie hlbokým učením ide stále o relatívne malý dataset. Model vykazoval nedostatky najmä pri snímkach s nevyhovujúcimi pozorovacími podmienkami - napríklad oblačnosť na horizonte alebo tiene na oblohe boli v niektorých prípadoch nesprávne označované ako EPB štruktúry. Rozšírenie trénovacieho datasetu o snímky pokrývajúce rôznorodejšie pozorovacie podmienky by mohlo tieto nedostatky redukovať.

Literatúra

Bhattacharyya, A. (2022). Equatorial plasma bubbles: A review, *Atmosphere* **13**(10).

Butka, P., Sarnovsky, M., Krešňáková, V., Mackovjak, S. and Kališková, L. (2026). Solar corona structures detection and segmentation using deep neural networks: A survey, *IEEE Access* **PP**: 1–1.

Canny, J. (1986). A computational approach to edge detection, *Pattern Analysis and Machine Intelligence, IEEE Transactions on* **PAMI-8**: 679 – 698.

Glorot, X., Bordes, A. and Bengio, Y. (2011). Deep sparse rectifier neural networks, *Proceedings of the fourteenth international conference on artificial intelligence and statistics*, JMLR Workshop and Conference Proceedings, pp. 315–323.

Goodfellow, I., Bengio, Y. and Courville, A. (2016). *Deep Learning*, MIT Press. `http://www.deeplearningbook.org`.

Hartigan, J. A. and Wong, M. A. (1979). Algorithm as 136: A k-means clustering algorithm, *Journal of the Royal Statistical Society. Series C (Applied Statistics)* **28**(1): 100–108.

Ioffe, S. and Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift.

Kingma, D. P. and Ba, J. (2014). Adam: A method for stochastic optimization.

LeCun, Y., Bengio, Y. and Hinton, G. (2015). Deep learning, *Nature* **521**(7553): 436–444.

Legendre, P. and Legendre, L. (2012). *Numerical ecology*, Vol. 24, Elsevier.

Loy, J. (2019). *Neural Network Projects with Python*, Packt Publishing, Birmingham, England.

Maas, A. L., Hannun, A. Y., Ng, A. Y. et al. (2013). Rectifier nonlinearities improve neural network acoustic models, *Proc. icml*, Vol. 30, Atlanta, GA, p. 3.

Mackovjak, , Harman, M., Maslej-Krešňáková, V. and Butka, P. (2021). Scss-net: solar corona structures segmentation by deep learning, *Monthly Notices of the Royal Astronomical Society* **508**(3): 3111–3124.

Martinis, C., Baumgardner, J., Wroten, J. and Mendillo, M. (2018). All-sky-imaging capabilities for ionospheric space weather research using geomagnetic conjugate point observing sites, *Advances in Space Research* **61**(7): 1636–1651.

Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*, MIT press.

Nielsen, M. A. (2015). *Neural networks and deep learning*, Vol. 25, Determination press San Francisco, CA, USA.

Pimenta, A., Fagundes, P., Bittencourt, J., Sahai, Y., Gobbi, D., Medeiros, A., Taylor, M. and Takahashi, H. (2001). Ionospheric plasma bubble zonal drift: a methodology using oi 630 nm all-sky imaging systems, *Advances in Space Research* **27**(6): 1219–1224.

Rasamoelina, A. D., Adjailia, F. and Sinčák, P. (2020). A review of activation function for artificial neural network, *2020 IEEE 18th world symposium on applied machine intelligence and informatics (SAMI)*, IEEE, pp. 281–286.

Ronneberger, O., Fischer, P. and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation.

Rumelhart, D. E., Hinton, G. E. and Williams, R. J. (1986). Learning representations by back-propagating errors, *nature* **323**(6088): 533–536.

Sahoo, P., Soltani, S. and Wong, A. (1988). A survey of thresholding techniques, *Computer Vision, Graphics, and Image Processing* **41**(2): 233–260.

Shorten, C. and Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning, *Journal of big data* **6**(1): 1–48.

Solomon, S. C. and Abreu, V. J. (1989). The 630 nm dayglow, *Journal of Geophysical Research: Space Physics* **94**(A6): 6817–6824.

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting, *The journal of machine learning research* **15**(1): 1929–1958.

Sφrensen, T. (1948). A method of establishing groups of equal amplitude in plant sociologybased on similarity of species content and its application to analyses of the vegettation on danish commons, *Biol. Skr., K. danske Vidensk* **5**: 1–34.

Wang, C. (2010). New chains of space weather monitoring stations in china, *Space Weather* **8**(8).

Zhong, J., Zou, Z., Wu, K., Xu, J., Lu, Y., Sun, L., Li, Q. and Yuan, W. (2025). Automatic detection and feature extraction of equatorial plasma bubbles from all-sky airglow image based on machine learning, *Space Weather* **23**(5): e2025SW004336.

Zoznam príloh

Príloha A CD médium – záverečná práca v elektronickej podobe

Príloha B Systémová príručka dostupná na `https://github.com/kkuichi/kg061rv`