Modelovanie airglowu pomocou strojového učenia

Fakulta elektrotechniky a informatiky TU v Košiciach
Katedra kybernetiky a umelej inteligencie

Matej Varga

Bezovec 2021

Motivácia

- Airglow je netermálna svetelná emisia pochádzajúca z excitovaných atómov alebo molekúl

Motivácia

- Airglow je netermálna svetelná emisia pochádzajúca z excitovaných atómov alebo molekúl
- Vzniká vo vrchných vrstvách zemskej atmosféry, takže je neustále ovplyvňovaný kozmickým počasím zhora a atmosférickým počasím zospodu

Motivácia

- Airglow je netermálna svetelná emisia pochádzajúca z excitovaných atómov alebo molekúl
- Vzniká vo vrchných vrstvách zemskej atmosféry, takže je neustále ovplyvňovaný kozmickým počasím zhora a atmosférickým počasím zospodu
- Poskytuje efektívny spôsob ako monitorovať tieto procesy a ich vzájomné interakcie

Motivácia

- Airglow je netermálna svetelná emisia pochádzajúca z excitovaných atómov alebo molekúl
- Vzniká vo vrchných vrstvách zemskej atmosféry, takže je neustále ovplyvňovaný kozmickým počasím zhora a atmosférickým počasím zospodu
- Poskytuje efektívny spôsob ako monitorovať tieto procesy a ich vzájomné interakcie
- Dostupnosť 30 rokov kalibrovaných meraní z observatória v Abastumani, Gruzínsko (41.75°N, 42.82°E)

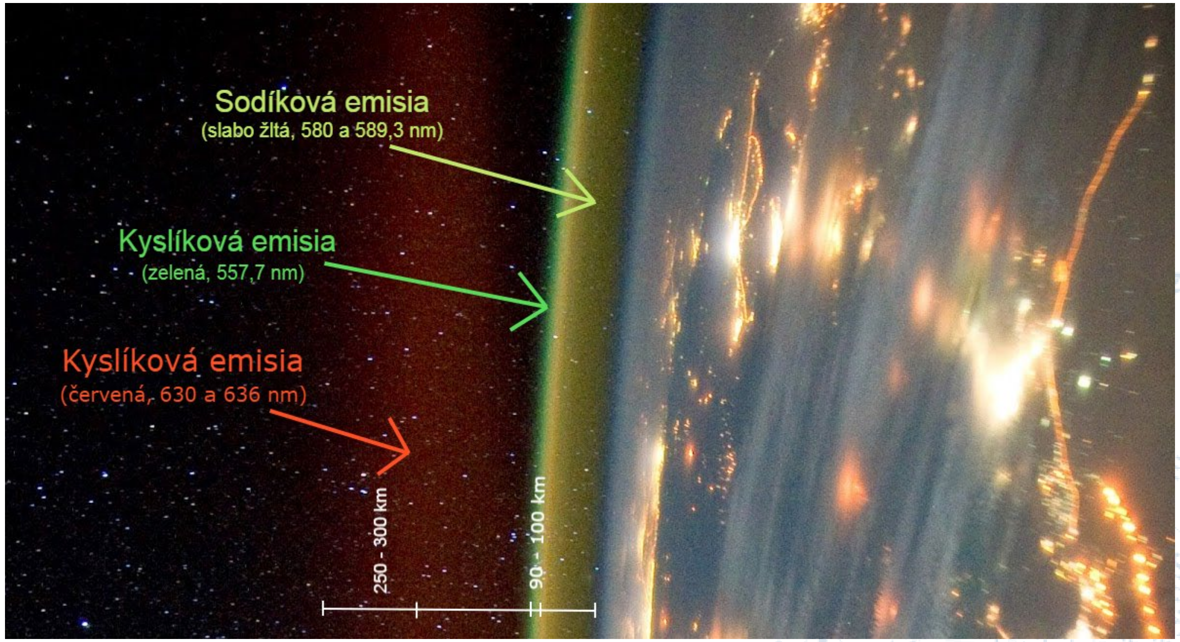

Pohľad na vrstvy airglow-u z ISS. Zdroj: NASA

Autor: Marián Dujnič

Autor: Y. Beletsky (LCO)/ESO

Dáta

- Dostupnosť 30 rokov meraní z observatória v Abastumani, Gruzínsko (41.75°N, 42.82°E)
- Merania 557.7, 630, 579.3 nm a iOH
- Celkový počet dát je ~ 3850 meraní (8% tmavých nočných hodín)
- Vstupné dáta boli vybraté z:
    - indexov kozmického počasia
    - parametrov termosféry
    - parametrov ionosféry
    - vzdialenosti a pozície Slnko-Zem

Abastunami v Gruzínsku – miesto merania airglow dát
Zdroj: Google Maps

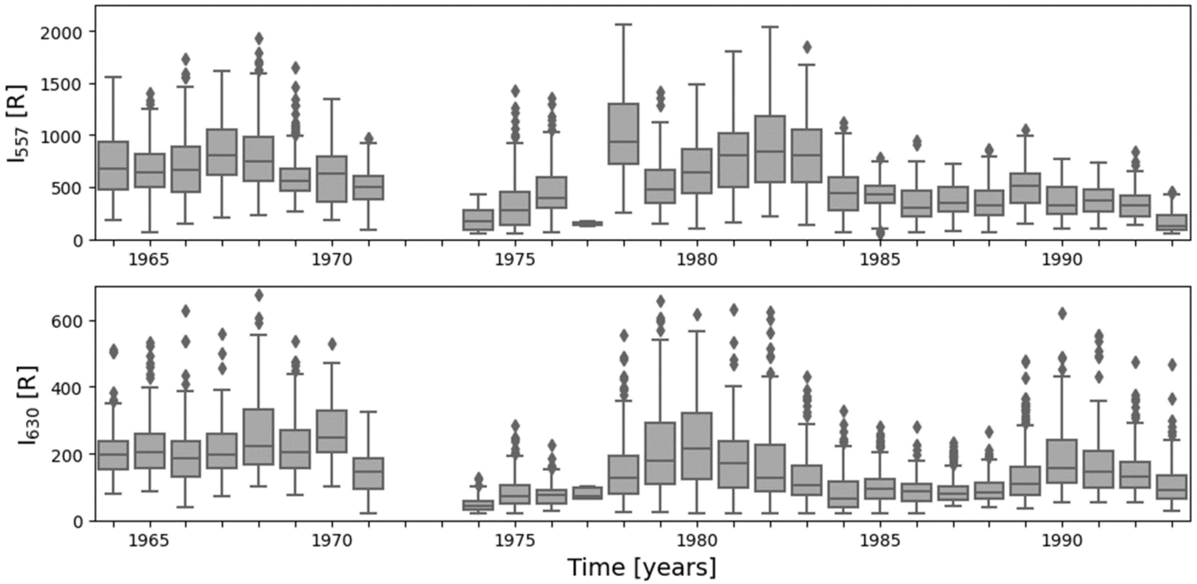

Box plot hodinových priemerov intenzít airglow-u

Dáta kozmického počasia – databáza NASA OMNIWeb

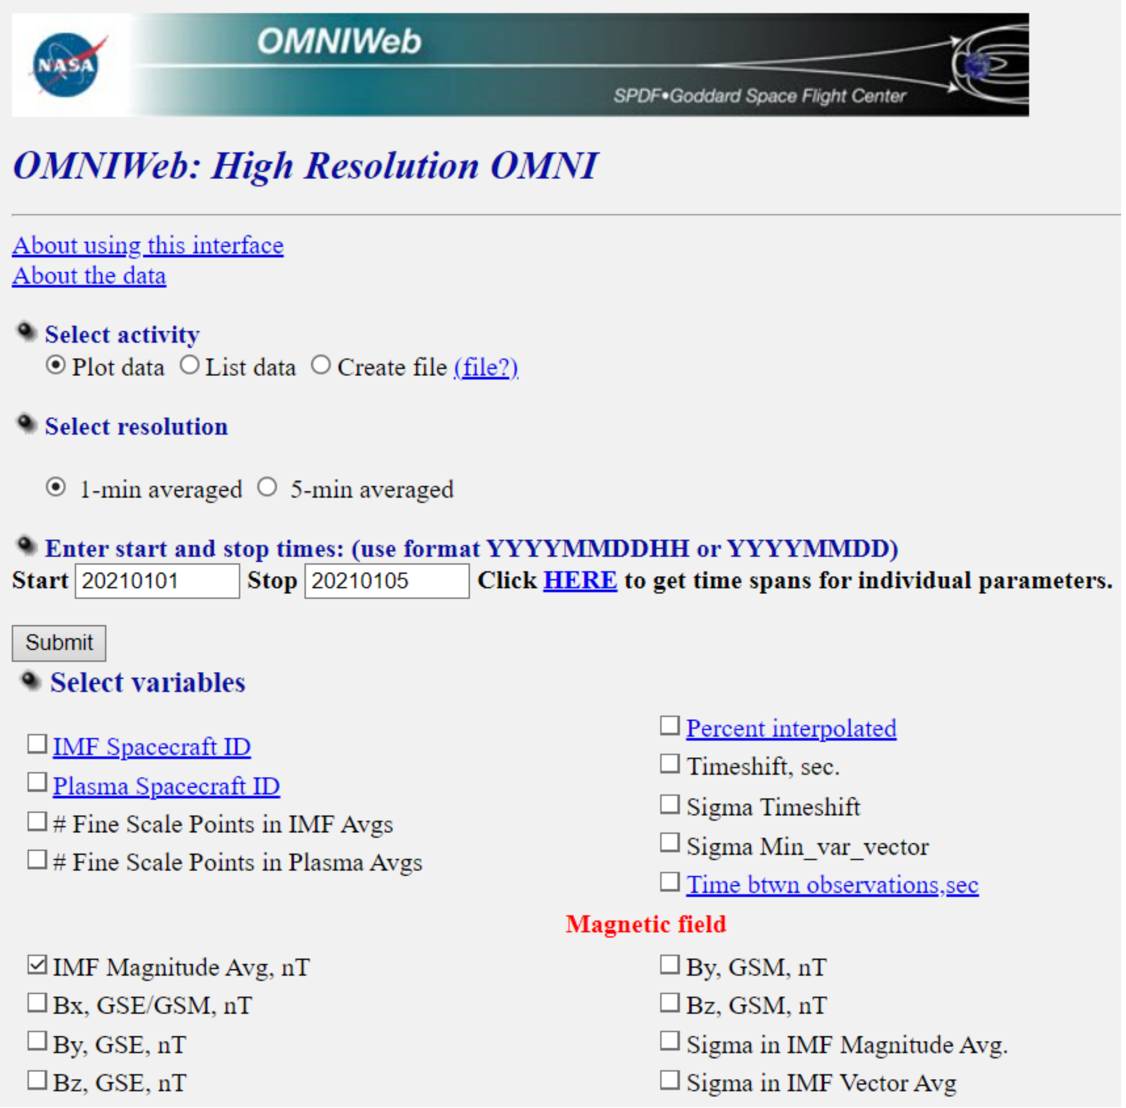

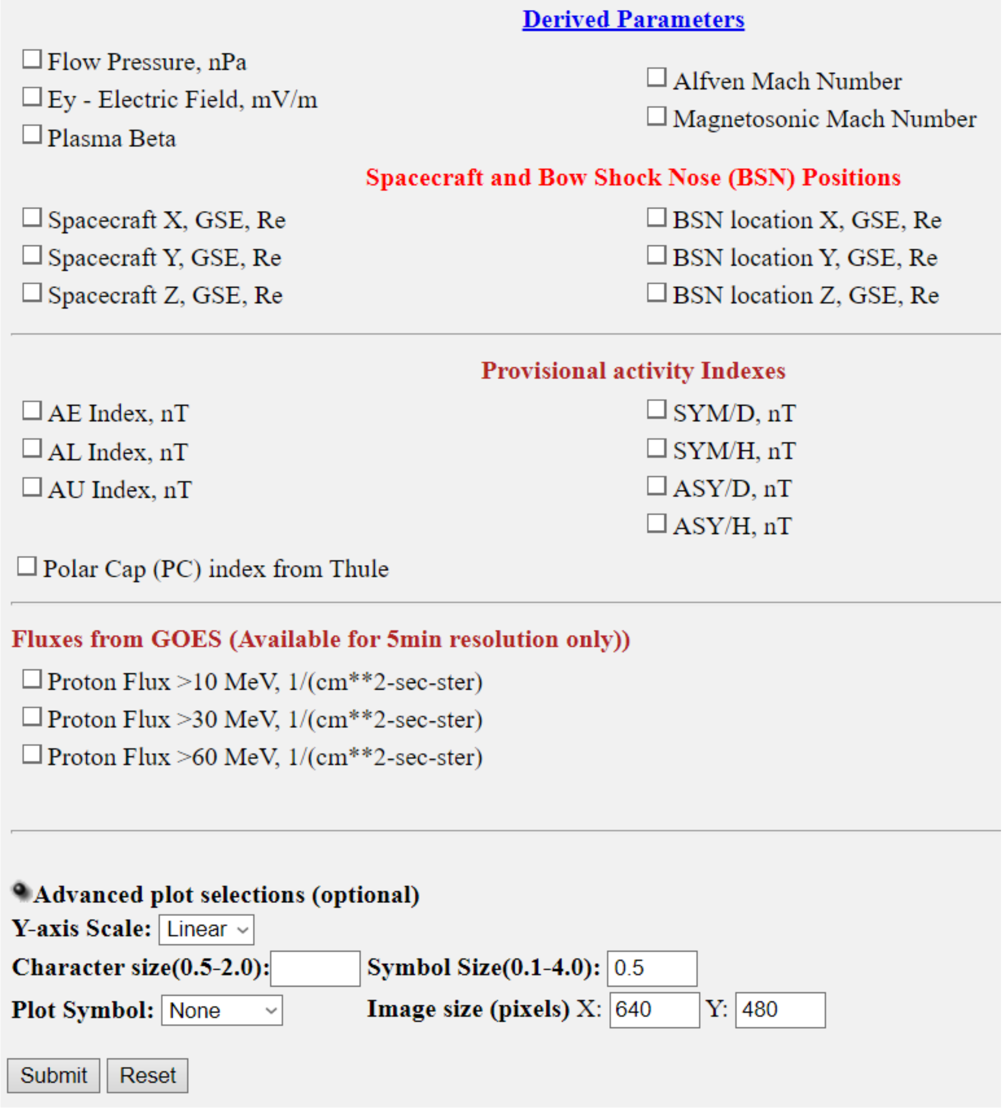

OMNIWeb: https://omniweb.gsfc.nasa.gov/form/omni_min.html

Parametre termosféry a ionosféry vo výškach 97 a 250 km

NRLMSISE-00 Atmosphere Model

This page enables the computation and plotting of any subset of MSIS parameters: neutral temperature, exospheric temperature, densities of He, O, N2, O2, Ar, H, N, and total mass density.

Select Date: (1960/02/14 - 2021/05/27 New: End date updating monthly) and Time
Year 2021 **Month:** January **Day(1-31):** 01
Time Universal **Hour of day** (e.g. 1.5): 1.5
Select Coordinates
Coordinates Type Geographic
Latitude(deg.,from -90. to 90.): 55. **Longitude**(deg.,from 0. to 360.): 45.
Height (km, from 0. to 1000.): 100.
Select a Profile type and its parameters:
Height,km [0. - 1000.] Start 0. Stop 1000. Stepsize 50.

Optional Input parameters:
Note :If user does not specify these parameters,they will be taken from real data base
F10.7(daily) **F10.7(3-month avg)** **ap(daily)**

Select output form:
- (•) List model data
- ( ) Create model data file in ASCII format for downloading
- ( ) Plot model data

Note 1: The first selected parameter below always will be along the X-axis, the other selections will be along Y-axis (e.g. if you want a Height profile, you may specify Height as the first parameter in the listing below.)
Note 2: User may get scatter plot if he specifies any two parameters below and changes the "connect type" in the "Advanced plot selections" to "show points only"

Submit Clear

Select desired parameters

Independent Variables
- ☑ Year
- ☑ Month
- ☑ Day of month
- ☑ Day of year
- ☑ Hour of day
- ☑ Height, km
- ☐ Geographic/Geomagnetic Latitude, deg. (depend on user's choice above)
- ☐ Geographic/Geomagnetic Longitude, deg. (depend on user's choice above)

Calculated MSIS Model Parameters
- ☑ Atomic Oxygen (O), cm^{-3}
- ☑ Nitrogen (N2), cm^{-3}
- ☑ Oxygen O_2, cm-3
- ☑ Total Mass Density, g/cm-3
- ☑ Neutral Temperature, K
- ☑ Exospheric Temperature, K
- ☑ Helium (He), cm^{-3}
- ☑ Argon (Ar), cm^{-3}
- ☑ Hydrogen (H), cm^{-3}
- ☑ Nitrogen (N), cm^{-3}
- ☑ Anomalous Oxygen, cm^{-3}

Indices taken from user's input or from data base
- ☑ F10.7(daily)
- ☐ F10.7(3-month avg)
- ☑ ap(daily)
- ☐ ap(00-03 hours prior used)
- ☐ ap(03-06 hours prior used)
- ☐ ap(06-09 hours prior used)
- ☐ ap(09-12 hours prior used)
- ☐ ap(12-33 hours prior used)
- ☐ ap(33-59 hours prior used)

Submit Clear

NRLMSISE-00: https://ccmc.gsfc.nasa.gov/modelweb/models/nrlmsise00.php
IRI-2016: https://ccmc.gsfc.nasa.gov/modelweb/models/iri2016_vitmo.php

Vybrané atribúty

Feature	Units	Description	Source
F10.7 index	SFU	Solar radio flux per frequency ($\lambda = 10.7$ cm)	OMNIWeb[a]
Kp index		Geomagnetic planetary K-index	OMNIWeb[a]
Dst index	nT	Geomagnetic equatorial index	OMNIWeb[a]
Neutral Temperature	K	Temperature of neutral atmosphere	NRLMSISE-00[b]
Total Mass Density	g/cm^3	Total mass density of neutral atmosphere	NRLMSISE-00[b]
O	N/cm^3	Atomic oxygen density	NRLMSISE-00[b]
O_2	N/cm^3	Molecular oxygen density	NRLMSISE-00[b]
N	N/cm^3	Atomic nitrogen density	NRLMSISE-00[b]
N_2	N/cm^3	Molecular nitrogen density	NRLMSISE-00[b]
H	N/cm^3	Atomic hydrogen density	NRLMSISE-00[b]
T_e	K	Temperature of electrons	IRI-2016[c]
n_e	N/m^3	Density of electrons	IRI-2016[c]
h_mF_2	km	F_2 layer peak height	IRI-2016[c]
N_mF_2	N/m^3	F_2 layer peak density	IRI-2016[c]
Sun-Earth	AU	Sun-Earth distance	PyEphem[d]

Modelovanie

- Použité metódy:
  - Lineárna regresia
  - Polynomiálna regresia
  - Neurónové siete
  - Random Forest
  - XGBoost

- Použité metriky:
  - $MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^{n} \left| y_i - \hat{y}_i \right|$
  - $MAPE(y, \hat{y}) = \frac{100\%}{n} \sum_{i=1}^{n} \frac{\left| y_i - \hat{y}_i \right|}{y_i}$

Random Forest

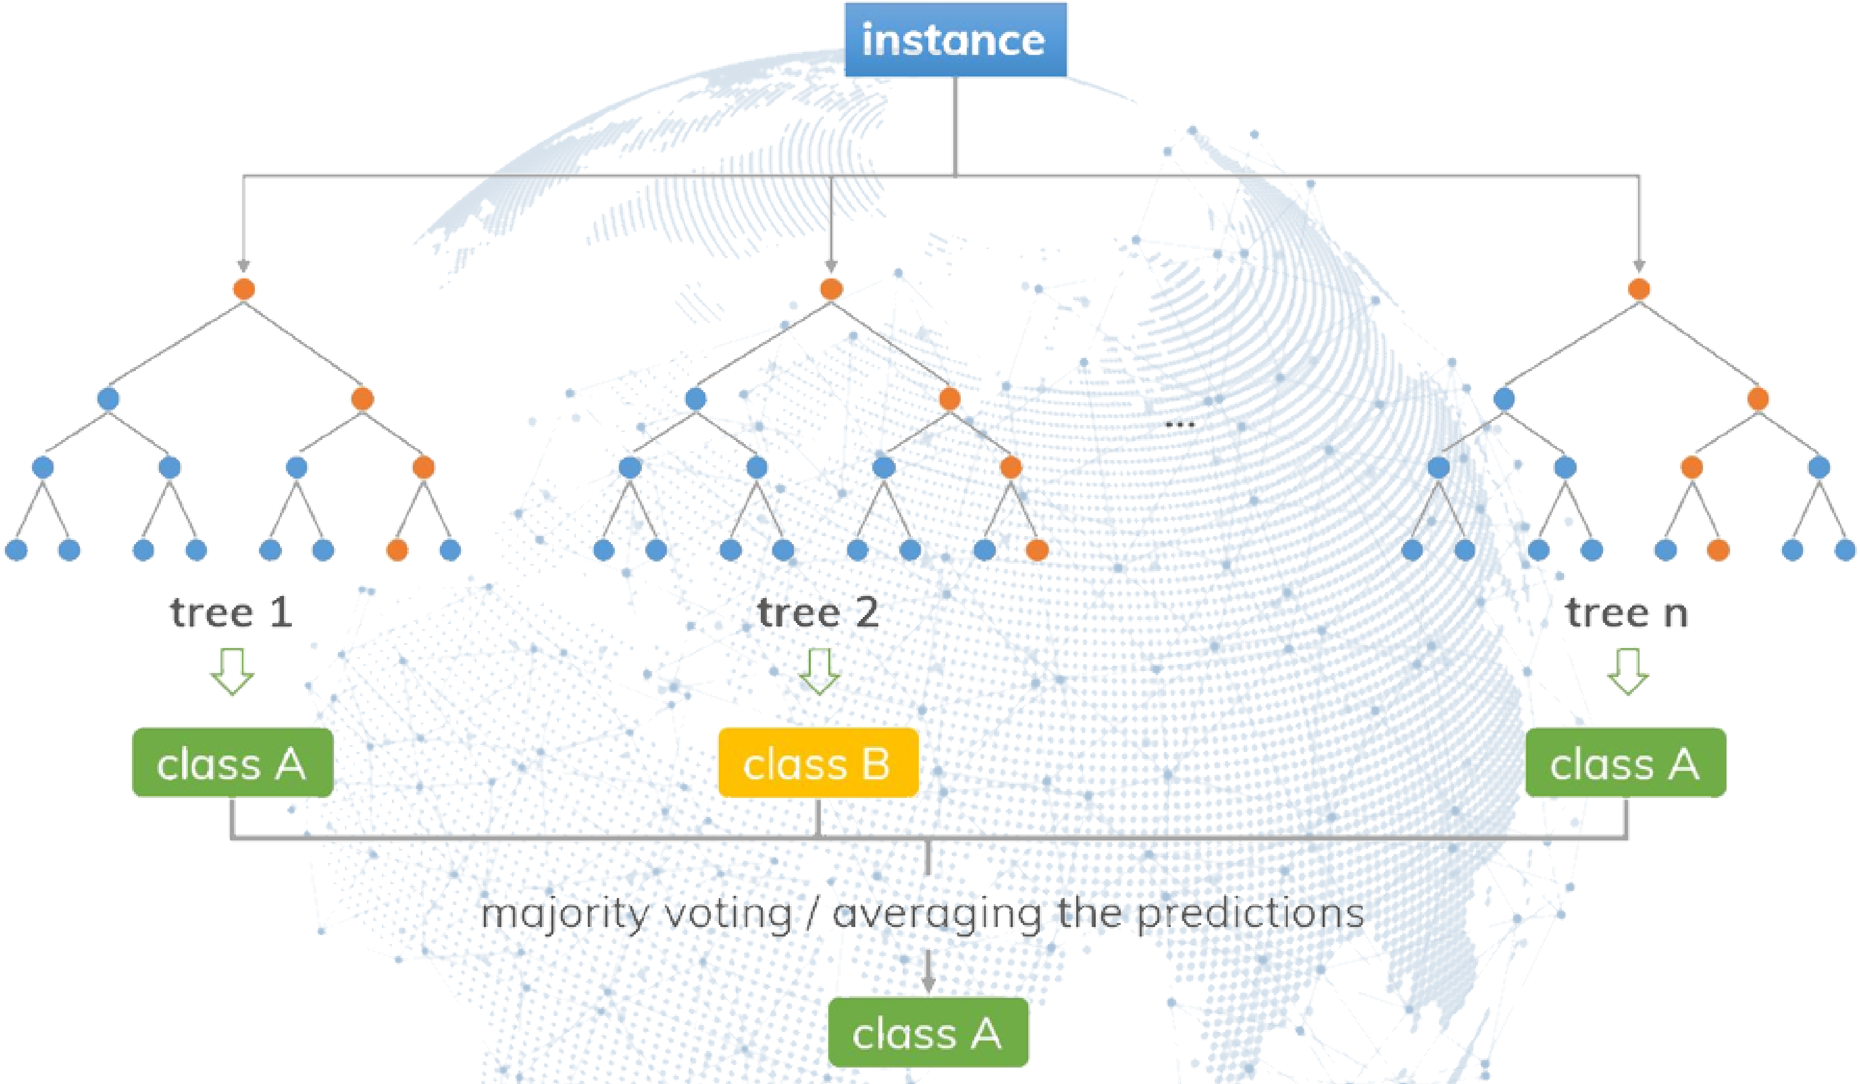

https://dinhanhthi.com/random-forest/

XGBoost

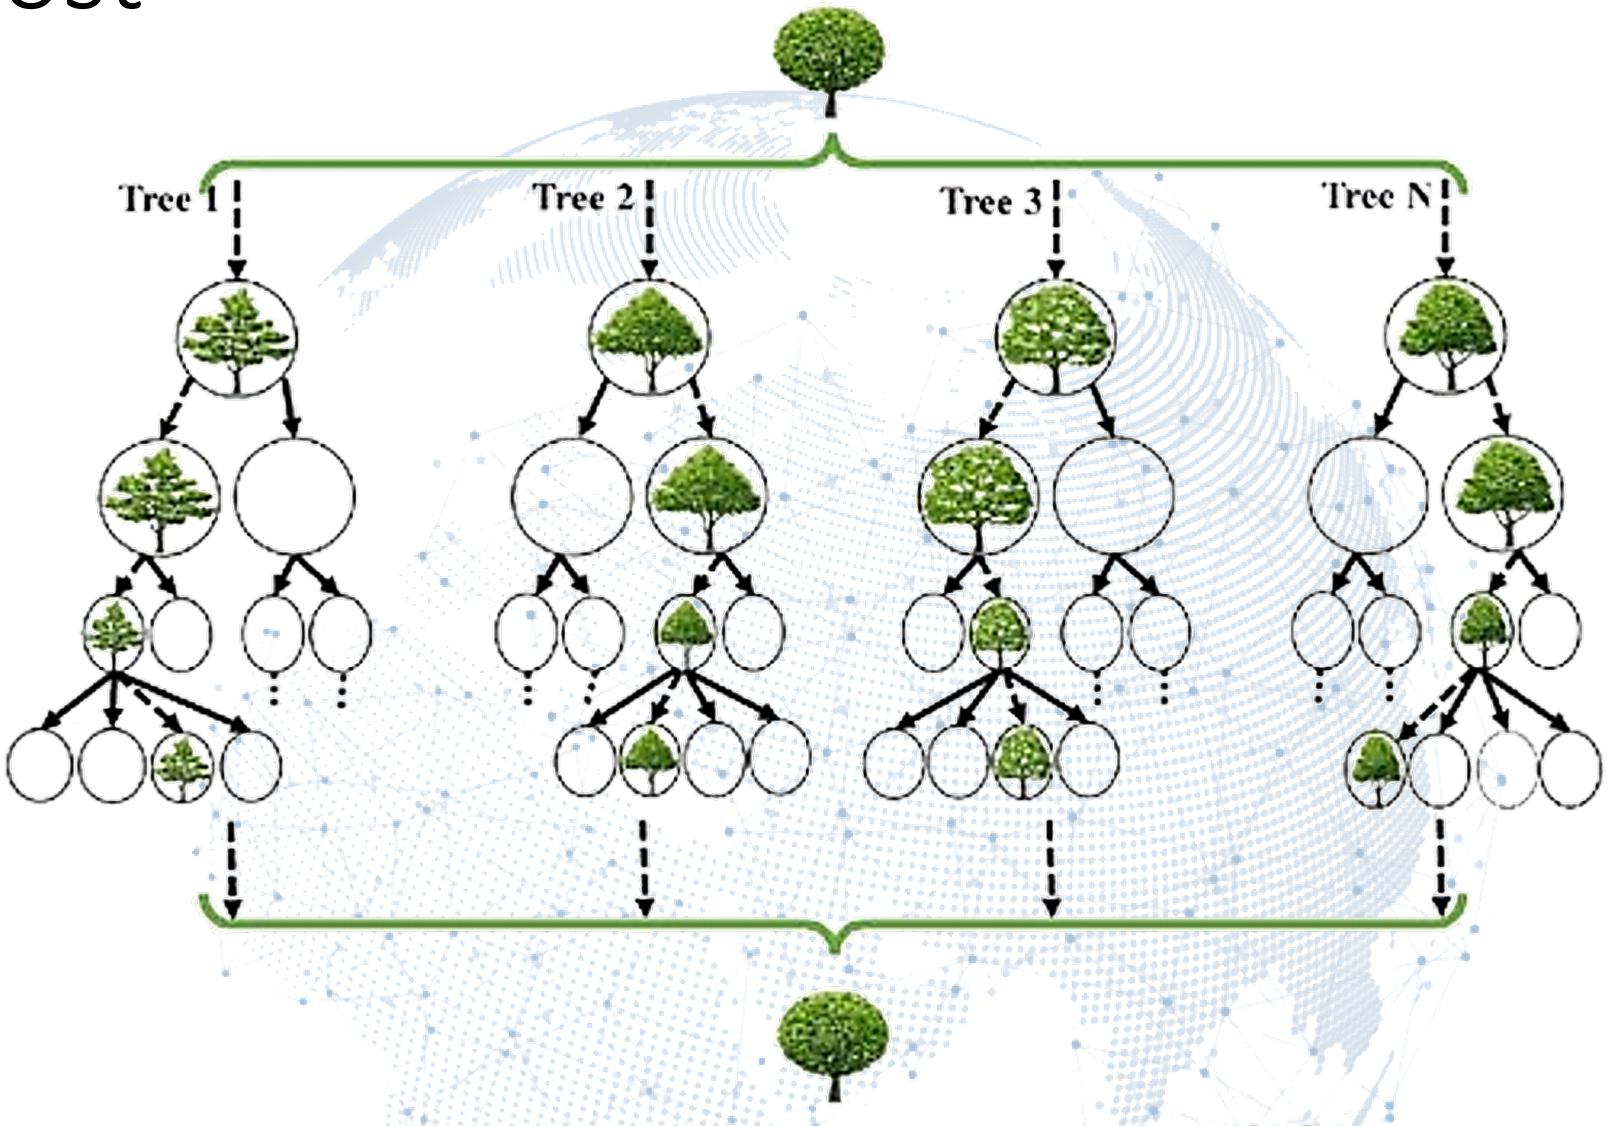

https://www.researchgate.net/publication/344683182_Environmental_Pollution_Prediction_of_sediment_heavy_metal_at_the_Australian_Bays_using_newly_developed_hybrid_artificial_intelligence_models

Výsledky trénovania

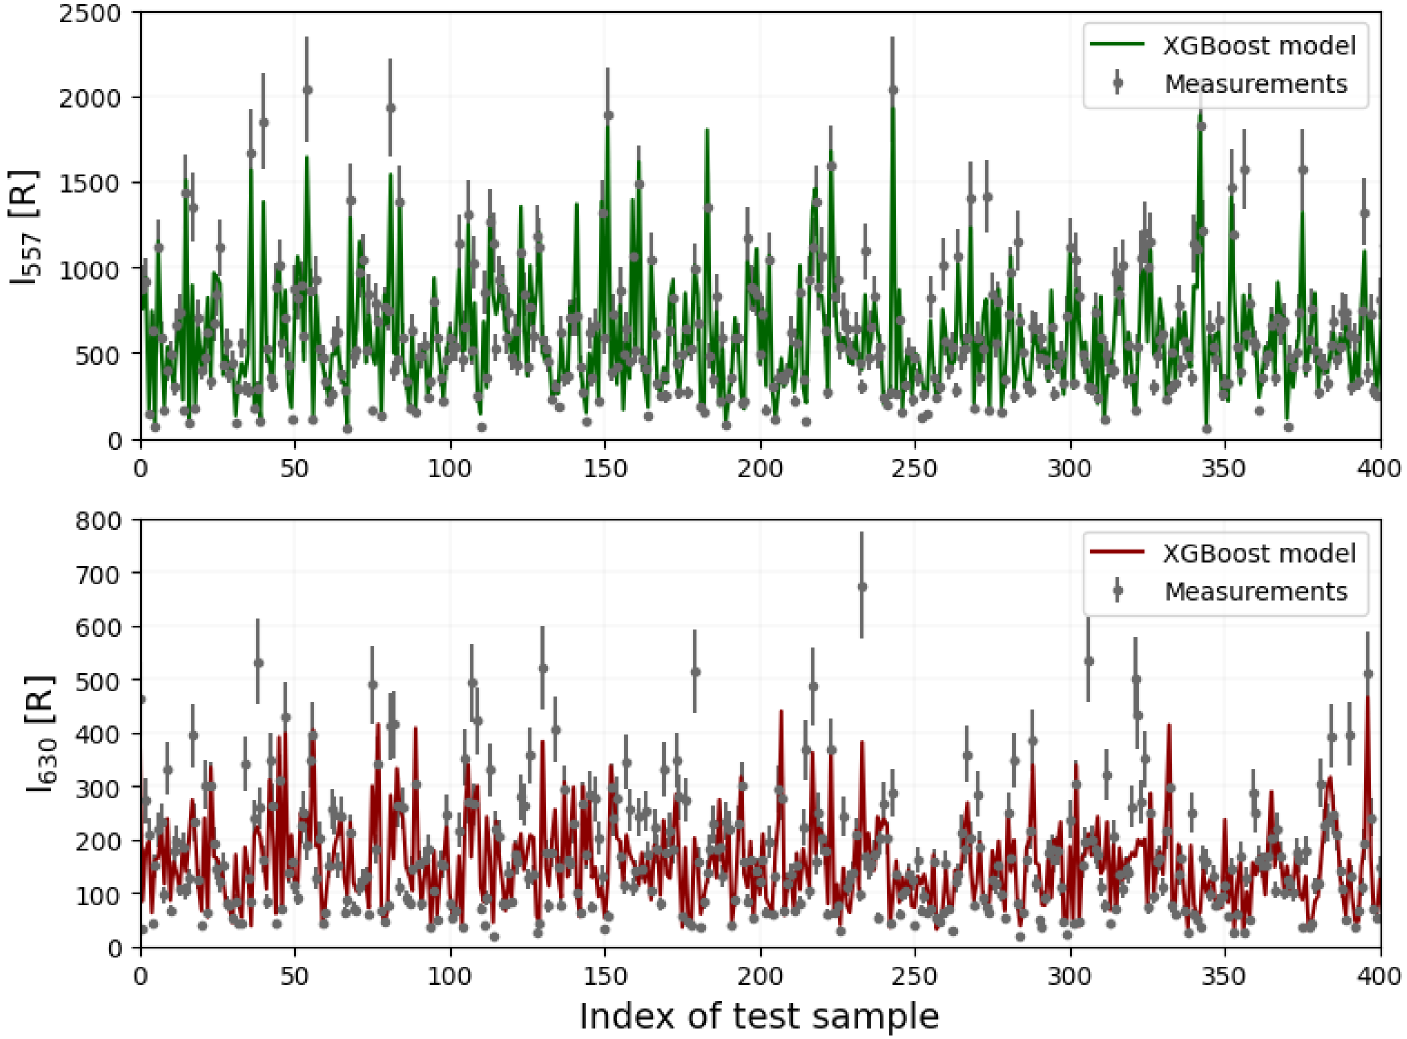

Porovnanie nameraných intenzít s výstupom XGBoost modelu na testovacej množine dát

	I 557		I 630	
	MAE	MAPE	MAE	MAPE
Baseline	265 R	78 %	84 R	86 %
Lin. Regression	247 R	65 %	77 R	72 %
Neural Network	146 R	95 %	63 R	90 %
Random Forest	102 R	23 %	53 R	41 %
XGBoost	88 R	16 %	48 R	32 %

MAE, mean absolute error; MAPE, mean absolute percentage error; XGBoost, Extreme Gradient Boosting.

Vyhodnotenie úspešnosti jednotlivých metód

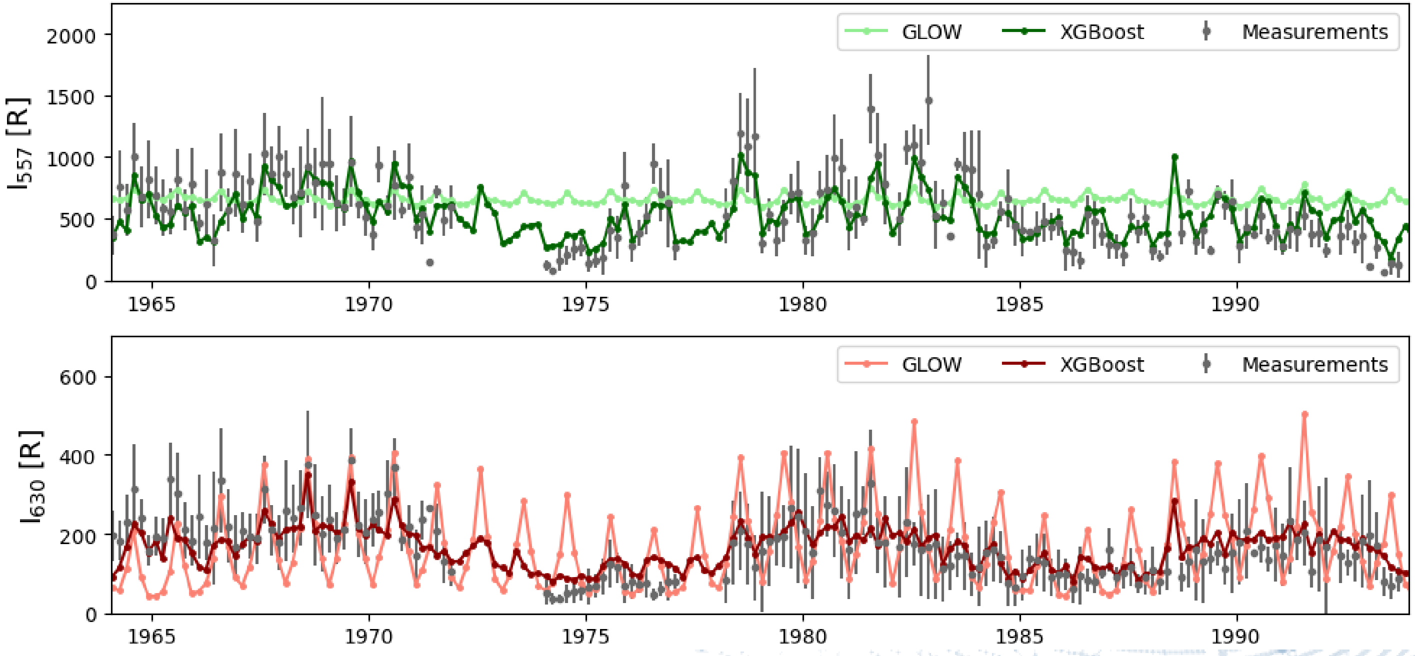

Porovnanie 2-mesačných priemerov intenzít airglow-u získaných fyzikálnym modelom GLOW a modelom XGBoost s reálnymi meraniami

Porovnanie 2-mesačných priemerov intenzít airglow-u získaných fyzikálnym modelom GLOW a modelom XGBoost s reálnymi meraniami

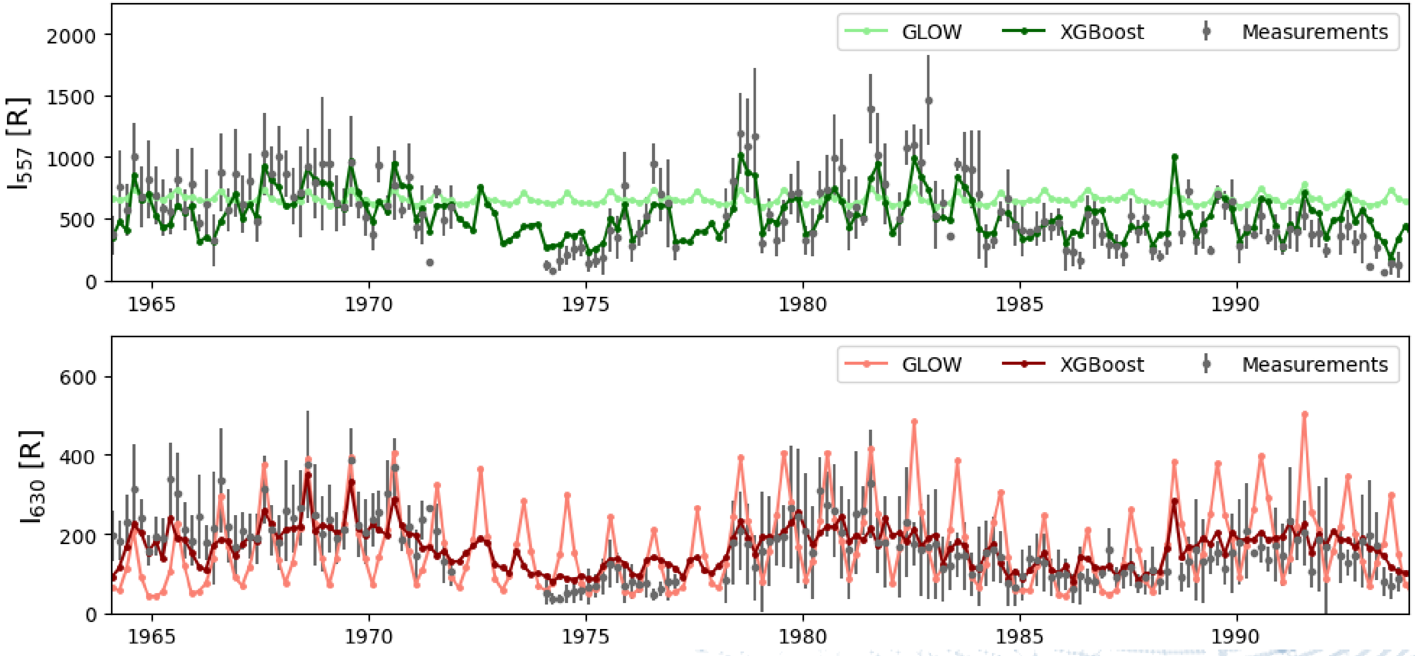

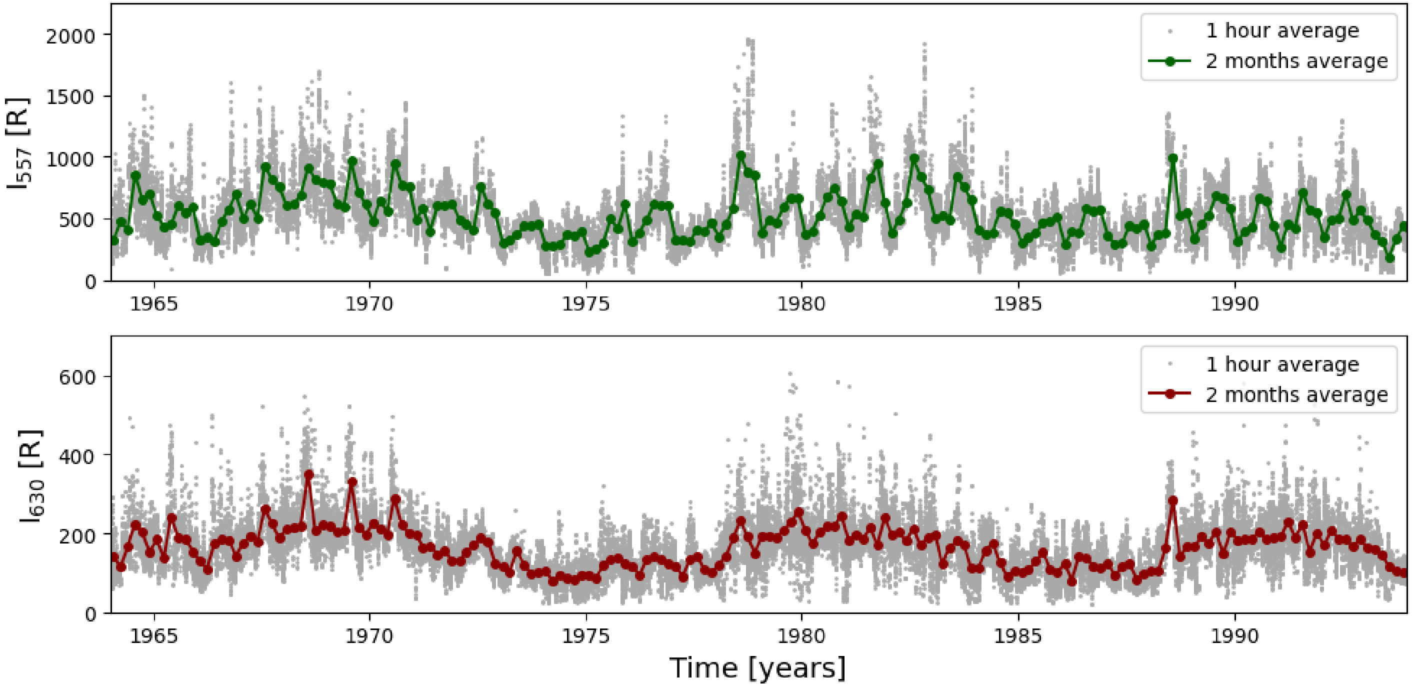

Vizualizácia intenzít airglowu získaných pomocou XGBoost modelu pre roky 1964-1993. Zobrazené sú hodinové a 2-mesačné priemery

Článok

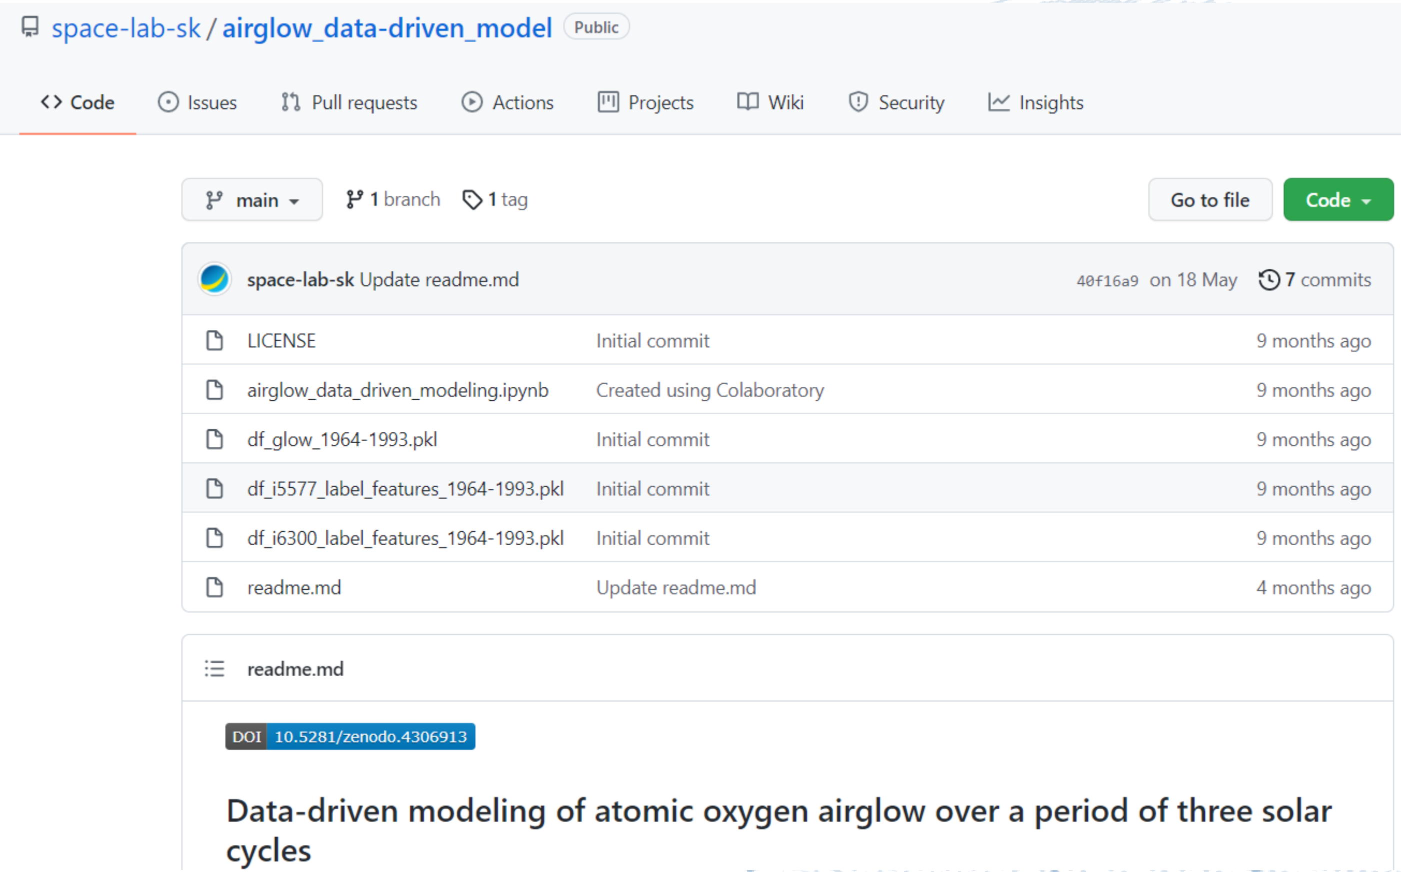

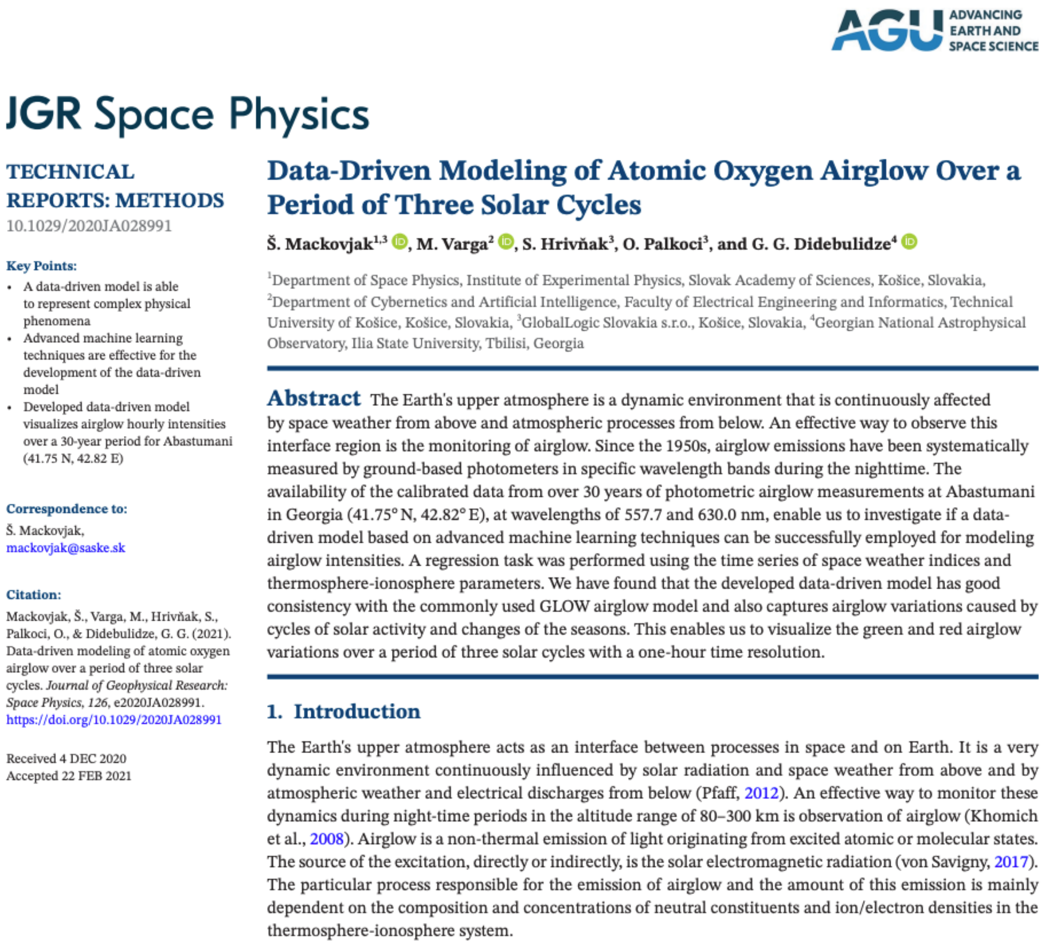

AGU ADVANCING EARTH AND SPACE SCIENCE

JGR Space Physics

TECHNICAL REPORTS: METHODS

10.1029/2020JA028991

Data-Driven Modeling of Atomic Oxygen Airglow Over a Period of Three Solar Cycles

Š. Mackovjak[1,3], M. Varga[2], S. Hrivňak[3], O. Palkoci[3], and G. G. Didebulidze[4]

[1]Department of Space Physics, Institute of Experimental Physics, Slovak Academy of Sciences, Košice, Slovakia, [2]Department of Cybernetics and Artificial Intelligence, Faculty of Electrical Engineering and Informatics, Technical University of Košice, Košice, Slovakia, [3]GlobalLogic Slovakia s.r.o., Košice, Slovakia, [4]Georgian National Astrophysical Observatory, Ilia State University, Tbilisi, Georgia

Key Points:

- A data-driven model is able to represent complex physical phenomena
- Advanced machine learning techniques are effective for the development of the data-driven model
- Developed data-driven model visualizes airglow hourly intensities over a 30-year period for Abastumani (41.75 N, 42.82 E)

Correspondence to:

Š. Mackovjak,
mackovjak@saske.sk

Citation:

Mackovjak, Š., Varga, M., Hrivňak, S., Palkoci, O., & Didebulidze, G. G. (2021). Data-driven modeling of atomic oxygen airglow over a period of three solar cycles. *Journal of Geophysical Research: Space Physics*, *126*, e2020JA028991. https://doi.org/10.1029/2020JA028991

Received 4 DEC 2020
Accepted 22 FEB 2021

Abstract The Earth's upper atmosphere is a dynamic environment that is continuously affected by space weather from above and atmospheric processes from below. An effective way to observe this interface region is the monitoring of airglow. Since the 1950s, airglow emissions have been systematically measured by ground-based photometers in specific wavelength bands during the nighttime. The availability of the calibrated data from over 30 years of photometric airglow measurements at Abastumani in Georgia (41.75° N, 42.82° E), at wavelengths of 557.7 and 630.0 nm, enable us to investigate if a data-driven model based on advanced machine learning techniques can be successfully employed for modeling airglow intensities. A regression task was performed using the time series of space weather indices and thermosphere-ionosphere parameters. We have found that the developed data-driven model has good consistency with the commonly used GLOW airglow model and also captures airglow variations caused by cycles of solar activity and changes of the seasons. This enables us to visualize the green and red airglow variations over a period of three solar cycles with a one-hour time resolution.

1. Introduction

The Earth's upper atmosphere acts as an interface between processes in space and on Earth. It is a very dynamic environment continuously influenced by solar radiation and space weather from above and by atmospheric weather and electrical discharges from below (Pfaff, 2012). An effective way to monitor these dynamics during night-time periods in the altitude range of 80–300 km is observation of airglow (Khomich et al., 2008). Airglow is a non-thermal emission of light originating from excited atomic or molecular states. The source of the excitation, directly or indirectly, is the solar electromagnetic radiation (von Savigny, 2017). The particular process responsible for the emission of airglow and the amount of this emission is mainly dependent on the composition and concentrations of neutral constituents and ion/electron densities in the thermosphere-ionosphere system.

Nadväzujúci výskum

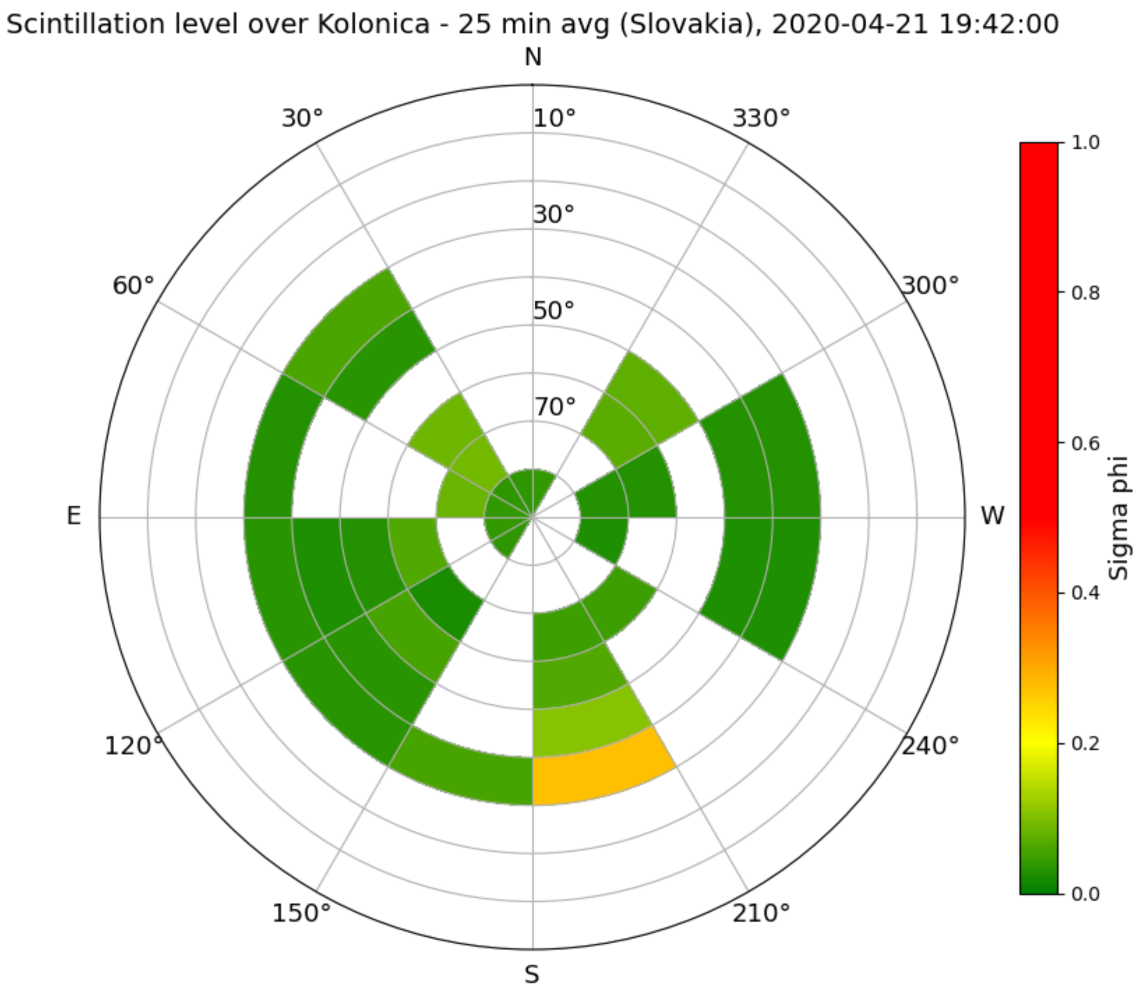

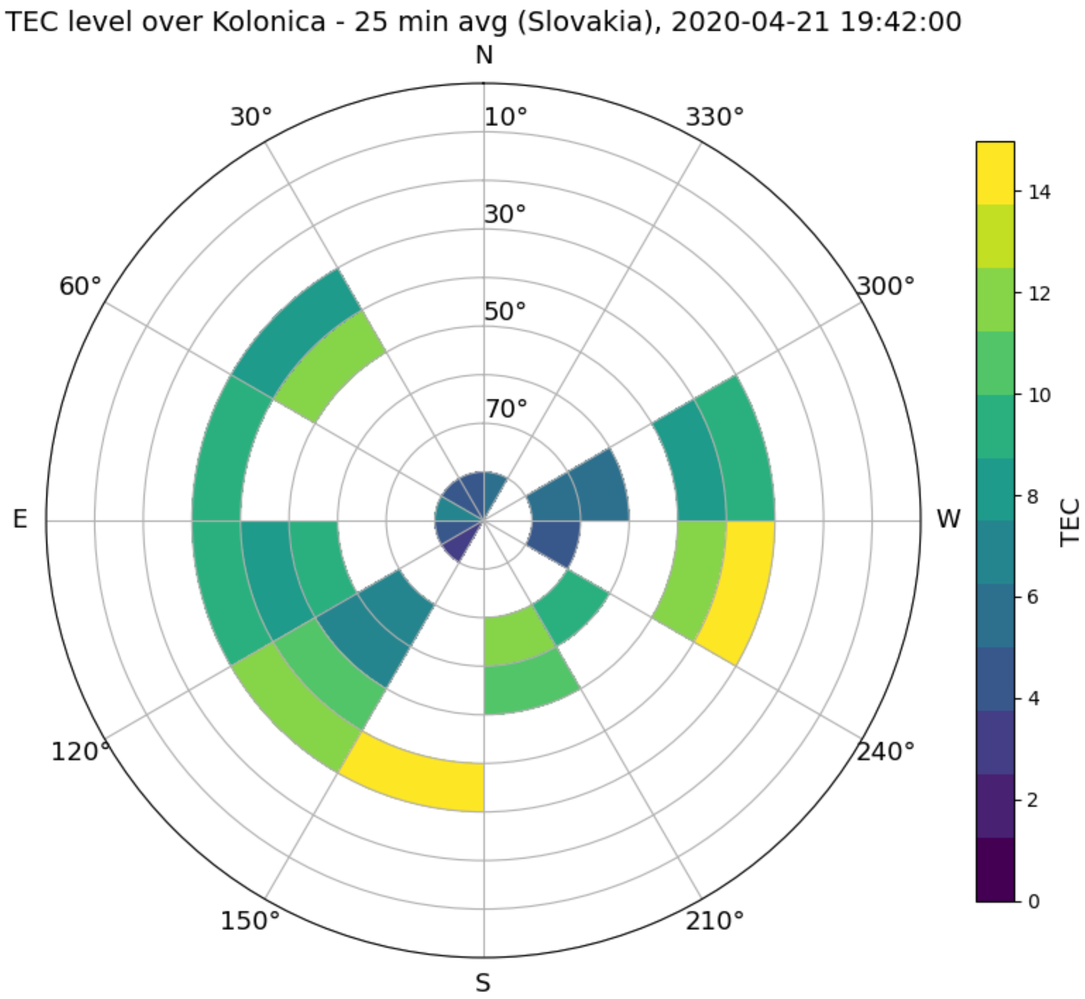

Zhrnutie

- Monitoring airglowu môže poskytnúť informácie o procesoch vo vrchných vrstvách atmosféry

Zhrnutie

- Monitoring airglowu môže poskytnúť informácie o procesoch vo vrchných vrstvách atmosféry
- Verejne dostupné databázy poskytujú cenné dáta využiteľné v rôznych oblastiach výskumu

Zhrnutie

- Monitoring airglowu môže poskytnúť informácie o procesoch vo vrchných vrstvách atmosféry
- Verejne dostupné databázy poskytujú cenné dáta využiteľné v rôznych oblastiach výskumu
- Jednoduché používanie metód strojového učenia vďaka open source knižniciam s podrobnou dokumentáciou

Zhrnutie

- Monitoring airglowu môže poskytnúť informácie o procesoch vo vrchných vrstvách atmosféry
- Verejne dostupné databázy poskytujú cenné dáta využiteľné v rôznych oblastiach výskumu
- Jednoduché používanie metód strojového učenia vďaka open source knižniciam s podrobnou dokumentáciou
- Pomocou strojového učenia je možné modelovať fyzikálne javy bez nutnosti zadania presného procesu

Ďakujem za pozornosť

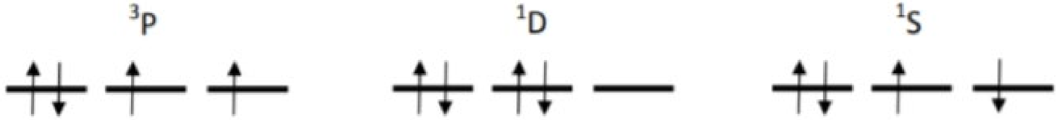

3P
1D
1S

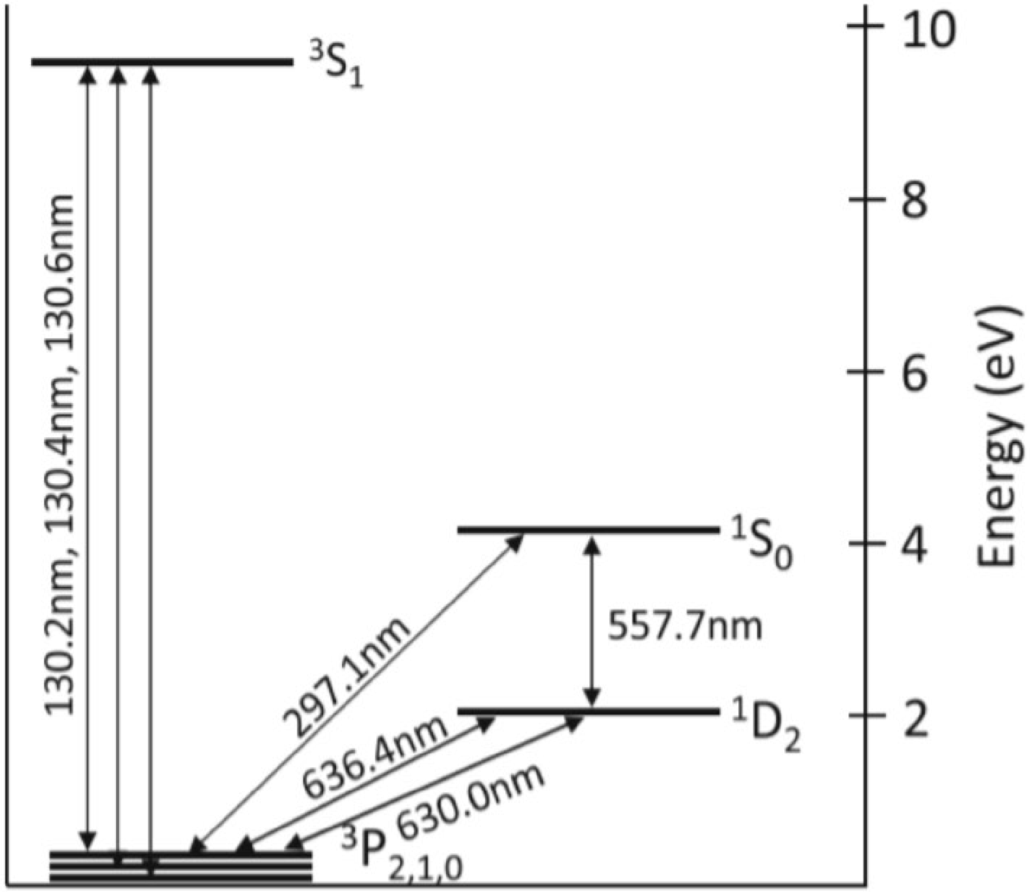

3S1
1S0
1D2
3P2,1,0
130.2nm, 130.4nm, 130.6nm
297.1nm
636.4nm
630.0nm
557.7nm
Energy (eV)
10
8
6
4
2