

Primena ConvLSTM modela za predikciju optičke debljine aerosola

Uzahir R. Ramadani, Dušan P. Nikezić, Dušan S. Radivojević, Nikola Mirkov i Ivan Lazović

Apstrakt—Napravljen je ConvLSTM model sa ConvLSTM2D slojevima za predviđanje optičke debljine aerosola. Ulazni skup podataka čine satelitski snimci optičke debljine aerosola na 8 dana od 2000. godine. Kada je model obučen dato je predviđanje optičke debljine aerosola kao i evaluacija modela. Razvijen je i primenjen nad istim podacima i CNN LSTM model i dato je poređenje oba modela. Za evaluaciju je korišćena Srednja kvadratna greška (MSE) kao i Srednja apsolutna greška (MAE). ConvLSTM model je pokazao manju grešku i rezultati su pokazali da može da se koristi za predviđanje optičke debljine aerosola.

Ključne reči — Optička debljina aerosola; ConvLSTM; satelitski snimci; CNN LSTM.

I. UVOD

MAŠINSKO učenje kao deo veštačke inteligencije omogućuje napredovanje nauke u raznim oblastima. Savremeni tehnološki razvoj preko Interneta i velikih količina podataka omogućuje jednostavan pristup i korišćenje tih velikih baza podataka. Satelitski snimci kao skup podataka preko daljinske detekcije postali su dostupni naučnicima što omogućuje njihovo istraživanje. NASA pruža preko 50 različitih globalnih skupova podataka satelitskih snimaka. Jedan od tih skupova podataka je MODAL2_E_AER_OD koji predstavlja optičku debljinu aerosola snimanu svaki 8 dan od 2000. godine.

Odranije je poznato da aerosoli igraju važnu ulogu u oblikovanju vremena i klime, a novo istraživanje pokazalo je da i najsitnije čestice imaju nesrazmerno veliko dejstvo. Aerosoli iako mali su proizvođači snažnih kiša. Računarskim simulacijama naučnici su pokazali dejstvo tih čestica na olujne oblake. Iako su te čestice male, ima ih mnogo, i mogu da formiraju male kapi, na koje se kondenzuje isparavanje vode. To rezultuje oslobađanjem veće količine toplote koja

Uzahir R. Ramadani - Institut za nuklearne nauke „Vinča“ - Institut od nacionalnog značaja za Republiku Srbiju, Univerzitet u Beogradu, Mike Petrovića Alasa bb., 1100 Beograd, Srbija (e-mail: uzahir@vin.bg.ac.rs).

Dušan P. Nikezić - Institut za nuklearne nauke „Vinča“ - Institut od nacionalnog značaja za Republiku Srbiju, Univerzitet u Beogradu, Mike Petrovića Alasa bb., 1100 Beograd, Srbija (e-mail: dusan@vin.bg.ac.rs).

Dušan S. Radivojević - Institut za nuklearne nauke „Vinča“ - Institut od nacionalnog značaja za Republiku Srbiju, Univerzitet u Beogradu, Mike Petrovića Alasa bb., 1100 Beograd, Srbija (e-mail: dusanr@vin.bg.ac.rs).

Nikola Mirkov - Institut za nuklearne nauke „Vinča“ - Institut od nacionalnog značaja za Republiku Srbiju, Univerzitet u Beogradu, Mike Petrovića Alasa bb., 1100 Beograd, Srbija (e-mail: nmirkov@vin.bg.ac.rs).


Ivan Lazović - Institut za nuklearne nauke „Vinča“ - Institut od nacionalnog značaja za Republiku Srbiju, Univerzitet u Beogradu, Mike Petrovića Alasa bb., 1100 Beograd, Srbija (e-mail: ivan.lazovic@vin.bg.ac.rs).

osnažuje vazdušne mase. Više toplog vazduha ulazi u oblake i time stvara više leda, snega, munja i kiše.

II. METOD

Spektroradiometar umerene rezolucije (MODIS - Moderate Resolution Imaging Spectroradiometer) je satelitski senzor koji se koristi za merenja zemlje i klime. MODIS instrumenti hvataju podatke u 36 spektralnih opsega u talasnim dužinama od 0.4 mm do 14.4 mm i u različitim prostornim rezolucijama (2 opsega na 250 m, 5 opsega na 500 m i 29 opsega na 1 km). Sa svojom visokom prostornom rezolucijom, ali niskom vremenskom rezolucijom, MODIS podaci su korisni za praćenje promena u globalnoj koncentraciji aerosola tokom vremena.

NASA skupovi podataka dostupni su kao RGB i kao PNG fajlovi i u rezoluciji 3600 x 1800 piksela. Sl. 1 prikazuje jedan snimak iz skupa podataka MODAL2_E_AER_OD koji predstavlja globalni AOT (aerosol optical thickness) na svakih 8 dana [12, 13] što predstavlja 993 slike do 14.09.2021.



Sl. 1. Snimak od 2021-07-12 globalnog AOT.

Optička debljina manja od 0.1 (bledožuta) ukazuje na kristalno čisto nebo sa maksimalnom vidljivošću, dok vrednost od 1 (crvenkasto smeđa) ukazuje na veoma maglovite uslove.

Preko MODIS-a na NASA-inim satelitima Terra i Aqua prati se AOT kao i distribucija aerosola, u većem delu sveta (okeani i vlažni delovi kontinenata) na dnevnom nivou, svakih 8 dana i mesečno. MODIS se koristi za praćenje masene koncentracije aerosola, optičkih svojstava i zračenja. MODIS-ove informacije o aerosolu se koriste za proučavanje klimatologije aerosola, za praćenje izvora i ponora specifičnih tipova aerosola (kao što su sulfati i drugi industrijski/urbani

aerosol i aerosol sagorevanja biomase), i služe kao ulazni podaci za klimatsko modeliranje [7]. MODIS-ove informacije o aerosolu mogu se koristiti za predviđanje PM [11].

Satelitski snimci MODAL2_E_AER_OD predstavljaju ulazne podatke u modelu mašinskog učenja ConvLSTM. Tradicionalne metode predviđanja vremenskih serija fokusiraju se na univarijantne podatke sa linearnim odnosima i fiksnom i ručno dijagnostikovanom vremenskom zavisnošću. Neuronske mreže dodaju mogućnost učenja potencijalno nelinearnih odnosa sa proizvoljno definisanim, ali fiksnim brojem ulaza i izlaza koji podržavaju multivarijantno i višestepeno predviđanje.

Duboko učenje (DL – Deep Learning) je deo ML zasnovan na veštačkim neuronskim mrežama (ANN - Artificial Neural Networks). U DL konvolucionna neuronska mreža (CNN - Convolutional Neural Network) je klasa ANN, koja se najčešće primenjuje za analizu vizuelnih slika. U CNN-u ulaz je tenzor sa oblikom (broj ulaza) x (visina) x (širina) x (kanali). [17, 18]. Jedna od primena CNN-a je izdvajanje prostornih informacija iz slika.

LSTM - Long Short-Term Memory je tip Rekurentne neuronske mreže (RNN - Recurrent Neural Networks) dizajniran tako da nema problem sa nestajućim gradijentom. LSTM mreže imaju povratne veze koje daju neuronima mogućnost odluke na temelju ne samo trenutne već i prethodnih vrednosti [19].

Prostorno-vremensko predviđanje može da se uradi CNN i LSTM, gde CNN (Convolution2D) služi za ekstrahovanje prostornih karakteristika, dok se LSTM koristi za otkrivanje korelacija tokom vremena [20]. Međutim, slaganjem ovih vrsta slojeva, korelacija između prostornih i vremenskih karakteristika možda neće biti pravilno ekstrahovana. Rešenje je mrežna struktura sposobna da uhvati prostorno-vremenske korelacije ConvLSTM [21]. U Kerasu je napravljena klasa (sloj) ConvLSTM2D, koja izračunava konvolucione operacije i u ulaznoj i u rekurentnoj transformaciji da bi istovremeno uhvatila prostorno-vremenske podatke. ConvLSTM2D je rekurentni sloj, baš kao i LSTM, ali interna množenja matrice se razmenjuju sa operacijama konvolucije. Kao rezultat toga, podaci koji teku kroz ConvLSTM ćelije zadržavaju ulaznu dimenziju umesto da budu samo 1D vektor [21 - 23]. Glavna razlika između ConvLSTM i LSTM je broj ulaznih dimenzija. Pošto su LSTM ulazni podaci jednodimenzionalni, nisu pogodni za podatke o prostornoj sekvenci kao što je video, satelitske slike itd. ConvLSTM je dizajniran za 3D podatke na ulazu.

III. CONV LSTM MODEL

Ulaz kod LSTM je 3D tenzor sa oblikom: broj uzoraka, vremenski korak, karakteristike (samples, time steps, features). Ulaz konvolucionog sloja je 4D tenzor sa oblikom: uzorci, redovi, kolone, kanali (samples, rows, cols, channels). Ulaz za ConvLSTM model je 5D tenzor sa oblikom: uzorci, vremenski koraci, redovi, kolone, kanali (samples, time steps, rows, cols, channels).

Izlaz ćelije LSTM zavisi od atributa return_sekuence. Kada


je postavljeno na True, izlaz je sekvenca tokom vremena (jedan izlaz za svaki ulaz). U ovom slučaju, izlaz je 3D tenzor sa oblikom: uzorci, vremenski koraci, karakteristike. Kada je return_sekuences podešen na False, izlaz je poslednja vrednost niza, odnosno 2D tenzor sa oblikom (uzorci, karakteristike). Izlaz ConvLSTM sloja je kombinacija Convolution i LSTM izlaza. Baš kao i LSTM, ako je return_sekuences = True, onda vraća niz kao 5D tenzor sa oblikom: uzorci, vremenski koraci, redovi, kolone, filteri. Kada je return_sekuences = False, onda vraća samo poslednju vrednost niza kao 4D tenzor sa oblikom (uzorci, redovi, kolone, filteri).

ML model koji se koristi u ovoj studiji sastoji se od 3 sloja ConvLSTM2D i krajnjeg sloja Conv3D kao izlaza. Conv3D sloj stvara konvoluciono jezgro koje je konvoluirano sa ulazom sloja da bi se proizveo tenzor izlaza, tj. visina, širina, kanal slike. ML model je napravljen u Kerasu.

CNN LSTM model ima prvi ulazni sloj koji prima niz od 10 slika rezolucije 144x288 piksela sa tri RGB kanala. Obzirom da Conv2D sloj može da funkcioniše samo sa jednom slikom, njemu i u narednih 5 slojeva dodat je sloj TimeDistributed koji omogućava rad sa nizom ulaznih podataka. Drugi sloj Conv2D ima 32 filtera radi boljih performansi modela. BatchNormalization u trećem i petom sloju se koristi radi prevecije takozvane eksplozije loss funkcije i ravnomernijeg napredovanja odnosno normalizacije tokom procesa učenja, sprečavanjem prevelikog napredovanja pojedinih težina u odnosu na ostale u neuralnoj mreži odnosno svakom sloju zasebno. Četvrti sloj Conv2D sa tri filtera vraća format na tri RGB kanala. Šesti sloj Reshape vrši poravnanje 2D formata slike u 1D format zbog pripreme za sledeći sedmi LSTM memorijski sloj. Osmi Dropout sloj vrši prevenciju preteranog učenja kod koga se javlja veoma dobro procesiranje poznatih, ali loše procesiranje novih podataka. Deveti Dense sloj formira konačan broj piksela izlazne predikovane slike koji se u desetom Reshape sloju transformišu u odgovarajući format.

Skup ulaznih podataka bio je MODAL2_E_AER_OD, skup satelitskih slika od 18.02.2000. do 14.09.2021. na svakih 8 dana. Odnos train/test bio je 70/30, 80/20 i 90/10. Optimum je postignut podelom 80/20. Najbolje rezultate dala je funkcija aktivacije 'hard_sigmoid' za Conv3D sloj i optimizator 'adam' (learning_rate=0,001). Problem prediktivnog modeliranja regresije uključuje predviđanje veličine realne vrednosti, tako da je za funkciju gubitka korišćen 'mse', a za metriku RootMeanSkuaedError (RMSE). Sl. 2 prikazuje korišćeni ConvLSTM model (slika je dobijena komandom: plot_model(model, to_file='model.png', show_shapes=True, show_layer_names=True)).

<https://www.kaggle.com/code/dusan75/convlstm-notebook09a46b0eb3>




Sl. 2. Prikaz ConvLSTM modela.

iz test skupa podataka.

Nakon obuke ML modela, urađeno je predviđanje prve slike iz skupa test podataka i upoređeno je sa originalnom prvom slikom iz skupa podataka testa.


IV. REZULTATI I DISKUSIJA

Sa ConvLSTM modelom je predikovana prva slika iz test skupa podataka, Sl. 3a. Sl. 3b prikazuje originalnu prvu sliku



Sl. 3. Globalni AOT a) predikovani; b) realni.

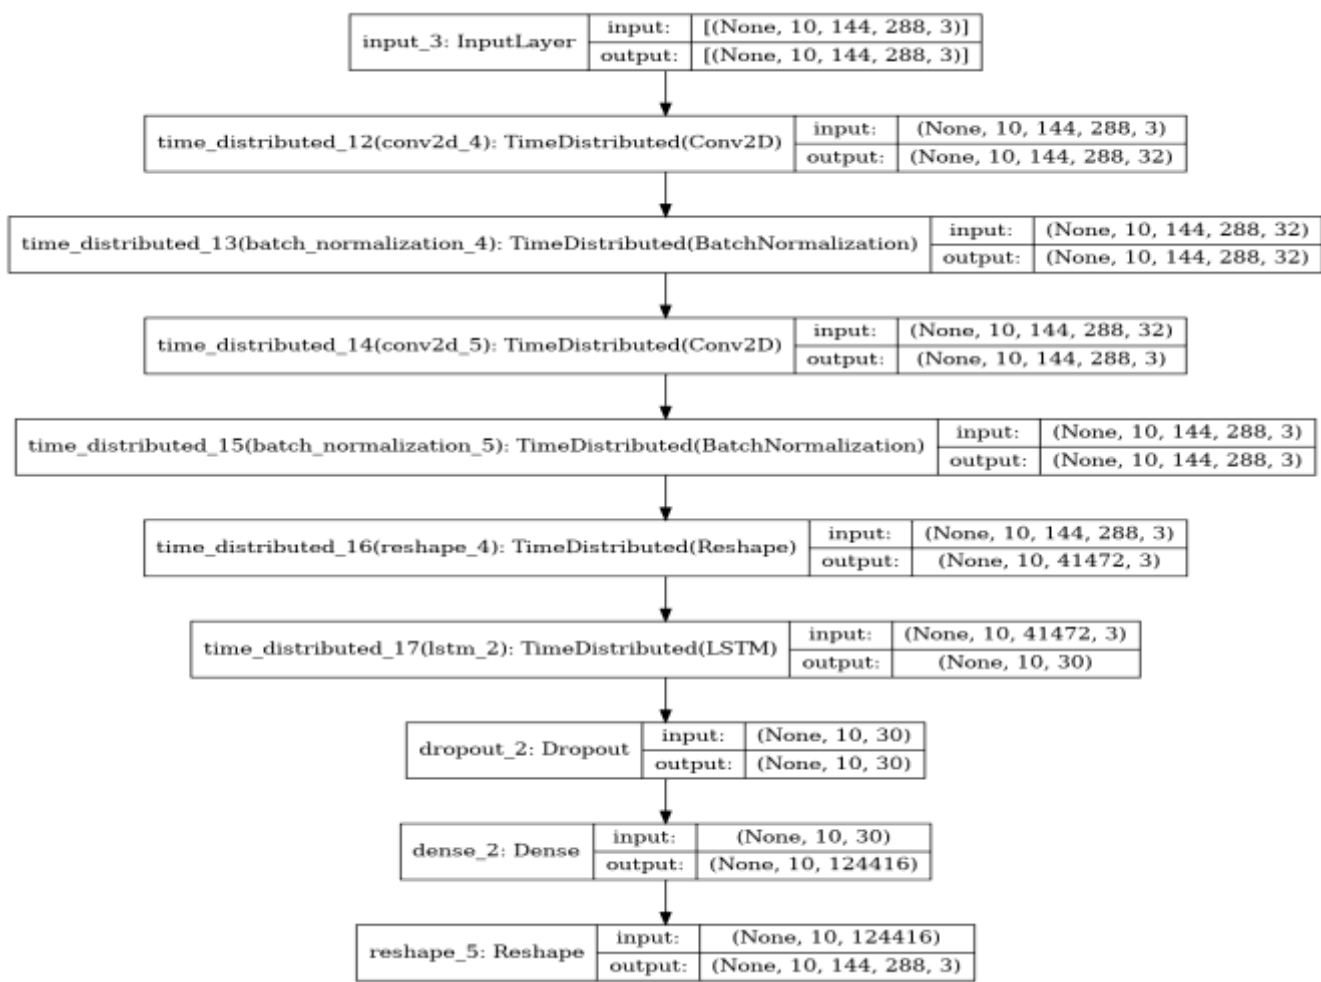
Validacija ML modela je zasnovana na metrici evaluacije, tj. mse 0,0116 (mean squared error). Ovi rezultati dokazuju da se predloženi ML model može koristiti za AOT prognoze. Sl. 4 prikazuje grafikon gubitka tokom 50 epoha obuke.



Sl. 4. Grafikon gubitka u zavisnosti broja epoha.

Pre ConvLSTM2D za prostorno-vremensku zavisnost i predikciju se koristio CNN+LSTM model [24]. Za poređenje ConvLSTM i CNN LSTM razvijen je novi CNN LSTM model. Sl. 5 prikazuje novi model CNN LSTM.

Metrika evaluacije bila je za mse 0,1117 i u poređenju sa ConvLSTM modelom (mse 0,0116) je veća vrednost. Niže vrednosti mse ukazuju na manju grešku.



Sl. 5. Prikaz CNN LSTM modela.

0.02259231	0.2456902
0.02278301	0.24560421

Primena Mean Absolute Percent Error metrike na konkretnom primeru nije primenljiva, obzirom na činjenicu da se među y-true vrednotima nalazi i vrednost 0 zbog koje metoda ne daje vrednosti u predviđenom opsegu od 0 do 1. Testiranje modela nalazi se na adresi:

<https://www.kaggle.com/code/dusan75/test-of-convlstm-notebook09a46b0eb3?scriptVersionId=94940211>

Za bolje poređenje dva modela urađena je sledeća statistika. Srednja apsolutna greška (MAE - Mean Absolute Error) koristi se za predviđanja u segmentu od 9 frejmova po slici, Tabela 1.

TABELA I
PROSEČNA GREŠKA PREDVIĐANJA U SEGMENTU OD 9 FREJMOVA PO SLICI

ConvLSTM	CNN LSTM
0.02200718	0.24474642
0.02213584	0.2462145
0.02251104	0.24545886
0.02263835	0.2449535
0.0227564	0.24526556
0.02259156	0.24504275
0.02232519	0.24720876

Iz dobijenih rezultata može se zaključiti da je ConvLSTM model zahtevao dobro strukturirane ulazne podatke, pravi izbor i optimalno podešene hiperparametre modela pre nego što bi mogao da se koristi za pouzdana AOT predviđanja.

V. ZAKLJUČAK

Aerosoli su jedan od najvećih izvora nesigurnosti u modeliranju klime. Zračenje aerosolima može objasniti razliku između posmatranih i modelovanih trendova prosečne globalne temperature. U stvari, interakcija sa sunčevim i zemaljskim zračenjem pomoću aerosola remeti radijativni budžet rasejanjem i apsorpcijom sunčeve svetlosti. Mnoge nedavne studije pokazuju važnost uključivanja aerosola u klimatske modele za posmatranje i merenje ljudskog uticaja na atmosfersku hemiju i klimatske promene.

Ova studija je istraživala mogućnost ConvLSTM modela za predviđanje globalnog AOT-a sa MODIS satelitskih snimaka. Sloj ConvLSTM2D u Kerasu spaja prostornu i vremensku komponentu i omogućava predikciju. Satelitski snimci pomažu u sagledavanju globalnog transporta zagađivača.

Modeli mašinskog učenja kreirani su od strane autora, tj. originalne i inovativne su strukture, pa se i rezultati treniranja

i predviđanja modela, pored originalne strukture, mogu uzeti kao doprinos zajednici radi poređenja postignutih rezultata.

ZAHVALNICA

Ovaj rad je realizovan u okviru istraživačke teme 1002205 koga finansira Ministarstvo prosvete, nauke i tehnološkog razvoja Republike Srbije.

LITERATURA

- [1] C.Q. Lin, G. Liu, A.K.H. Lau, Y. Li, C.C. Li, J.C.H. Fung, X.Q. Lao, High-resolution satellite remote sensing of provincial PM_{2.5} trends in China from 2001 to 2015, *Atmospheric Environment*, Volume 180, 2018, Pages 110-116, ISSN 1352-2310, <https://doi.org/10.1016/j.atmosenv.2018.02.045>.
- [2] Zhaoxi Wang, Yang Liu, Mu Hu, Xiaochuan Pan, Jing Shi, Feng Chen, Kebin He, Petros Koutrakis, David C. Christiani, Acute health impacts of airborne particles estimated from satellite remote sensing, *Environment International*, Volume 51, 2013, Pages 150-159, ISSN 0160-4120, <https://doi.org/10.1016/j.envint.2012.10.011>.
- [3] Shuaiyi Shi, Tianhai Cheng, Xingfa Gu, Hong Guo, Yu Wu, Ying Wang, Fangwen Bao, Xin Zuo, Probing the dynamic characteristics of aerosol originated from South Asia biomass burning using POLDER/GRASP satellite data with relevant accessory technique design, *Environment International*, Volume 145, 2020, 106097, ISSN 0160-4120, <https://doi.org/10.1016/j.envint.2020.106097>.
- [4] Xiaoli Wei, Ni-Bin Chang, Kaixu Bai & Wei Gao (2020) Satellite remote sensing of aerosol optical depth: advances, challenges, and perspectives, *Critical Reviews in Environmental Science and Technology*, 50:16, 1640-1725, DOI: 10.1080/10643389.2019.1665944.
- [5] Filonchik, M., Yan, H., Zhang, Z. et al. Combined use of satellite and surface observations to study aerosol optical depth in different regions of China. *Sci Rep* 9, 6174 (2019). <https://doi.org/10.1038/s41598-019-42466-6>.
- [6] Ian Colbeck, Mihalis Lazaridis, *Aerosol Science: Technology and Applications*, ISBN: 978-1-119-97792-6 December 2013, Wiley, <https://doi.org/10.1002/9781118682555.ch1>.
- [7] <https://neo.gsfc.nasa.gov/>
- [8] Dušan P. Nikezić, Zoran J. Gršić, Dragan M. Dramlić, Stefan D. Dramlić, Boris B. Lončar, Slavko D. Dimović, Modeling air concentration of fly ash in Belgrade, emitted from thermal power plants TNTA and TNTB, *Process Safety and Environmental Protection*, Volume 106, 2017, Pages 274-283, ISSN 0957-5820, <https://doi.org/10.1016/j.psep.2016.06.009>.
- [9] You, W.; Zang, Z.; Zhang, L.; Li, Y.; Pan, X.; Wang, W., National-Scale Estimates of Ground-Level PM_{2.5} Concentration in China Using Geographically Weighted Regression Based on 3 km Resolution MODIS AOD. *Remote Sens.* 2016, 8, 184. <https://doi.org/10.3390/rs8030184>.
- [10] Tov Elperin, Andrew Fominykh, Itzhak Katra, Boris Krasovtsov, Modeling of gas adsorption by aerosol plumes emitted from industrial sources, *Process Safety and Environmental Protection*, Volume 111, 2017, Pages 375-387, ISSN 0957-5820, <https://doi.org/10.1016/j.psep.2017.06.022>.
- [11] Naresh Kumar, Allen Chu, Andrew Foster, An empirical relationship between PM_{2.5} and aerosol optical depth in Delhi Metropolitan, *Atmospheric Environment*, Volume 41, Issue 21, 2007, Pages 4492-4503, ISSN 1352-2310, <https://doi.org/10.1016/j.atmosenv.2007.01.046>.
- [12] <https://neo.gsfc.nasa.gov/archive/rgb/>
- [13] https://neo.gsfc.nasa.gov/archive/rgb/MODAL2_E_AER_OD/
- [14] Song Tang, Yixin Mao, Rachael M. Jones, Qiyue Tan, John S. Ji, Na Li, Jin Shen, Yuebin Lv, Lijun Pan, Pei Ding, Xiaochen Wang, Youbin Wang, C. Raina MacIntyre, Xiaoming Shi, Aerosol transmission of SARS-CoV-2? Evidence, prevention and control, *Environment International*, Volume 144, 2020, 106039, ISSN 0160-4120, <https://doi.org/10.1016/j.envint.2020.106039>.
- [15] Maria A. Zoran, Roxana S. Savastru, Dan M. Savastru, Marina N. Tautan, Laurentiu A. Baschir, Daniel V. Tenciu, Exploring the linkage between seasonality of environmental factors and COVID-19 waves in Madrid, Spain, *Process Safety and Environmental Protection*, Volume 152, 2021, Pages 583-600, ISSN 0957-5820, <https://doi.org/10.1016/j.psep.2021.06.043>.
- [16] Eleftheriadis, K., Gini, M.L., Diapouli, E. et al., Aerosol microphysics and chemistry reveal the COVID19 lockdown impact on urban air quality., *Sci Rep* 11, 14477 (2021). <https://doi.org/10.1038/s41598-021-93650-6>.
- [17] M.V. Valueva, N.N. Nagornov, P.A. Lyakhov, G.V. Valuev, N.I. Chervyakov, Application of the residue number system to reduce hardware costs of the convolutional neural network implementation, *Mathematics and Computers in Simulation*, Volume 177, 2020, Pages 232-243, ISSN 0378-4754, <https://doi.org/10.1016/j.matcom.2020.04.031>.
- [18] Radheshyam Vaddi, Prabukumar Manoharan, Hyperspectral image classification using CNN with spectral and spatial features integration, *Infrared Physics & Technology*, Volume 107, 2020, 103296, ISSN 1350-4495, <https://doi.org/10.1016/j.infrared.2020.103296>.
- [19] Sepp Hochreiter, Jürgen Schmidhuber; Long Short-Term Memory. *Neural Comput* 1997; 9 (8): 1735-1780. doi: <https://doi.org/10.1162/neco.1997.9.8.1735>.
- [20] Weyn, J. A., Durran, D. R., & Caruana, R. (2020). Improving data-driven global weather prediction using deep convolutional neural networks on a cubed sphere. *Journal of Advances in Modeling Earth Systems*, 12, e2020MS002109. <https://doi.org/10.1029/2020MS002109>.
- [21] X. Shi, Z. Chen, H. Wang and D. Yeung, "Convolutional LSTM network: A machine learning approach for precipitation nowcasting", *Proc. Neural Inf. Process. Syst. (NIPS)*, pp. 802-810, 2015.
- [22] J. Donahue et al., "Long-Term Recurrent Convolutional Networks for Visual Recognition and Description," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 4, pp. 677-691, 1 April 2017, doi: 10.1109/TPAMI.2016.2599174.
- [23] W. Hu, H. Li, L. Pan, W. Li, R. Tao and Q. Du, "Spatial-Spectral Feature Extraction via Deep ConvLSTM Neural Networks for Hyperspectral Image Classification," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 58, no. 6, pp. 4237-4250, June 2020, doi: 10.1109/TGRS.2019.2961947.
- [24] X. Ding, L. Feng, Y. Zou and G. Zhang, "Deep Learning Aided Spectrum Prediction for Satellite Communication Systems," in *IEEE Transactions on Vehicular Technology*, vol. 69, no. 12, pp. 16314-16319, Dec. 2020, doi: 10.1109/TVT.2020.3043837.
- [25] Christof G. Beer, Johannes Hendricks, Mattia Righi, Bernd Heinold, Ina Tegen, Silke Groß, Daniel Sauer, Adrian Walser, Bernadett Weinzierl, Modelling mineral dust emissions and atmospheric dispersion with MADE3 in EMAC v2.54, *Geosci. Model Dev.*, 13, 4287-4303, 2020., doi.org/10.5194/gmd-13-4287-2020.
- [26] <https://aeronet.gsfc.nasa.gov/>
- [27] Weyn, J. A., Durran, D. R., Caruana, R., & Cresswell-Clay, N. (2021). Sub-seasonal forecasting with a large ensemble of deep-learning weather prediction models. *Journal of Advances in Modeling Earth Systems*, 13, e2021MS002502. <https://doi.org/10.1029/2021MS002502>.

ABSTRACT

ConvLSTM model was developed with ConvLSTM2D layers for predicting aerosol optical thickness. The input dataset was satellite images of aerosol optical thickness on 8-day beginning from 2000. When the model was trained, aerosol optical thickness prediction as well as model evaluation was given. The CNN LSTM model was developed and applied over the same dataset and a comparison of both models is given. Mean square error (MSE) as well as Mean absolute error (MAE) were used for evaluation. The ConvLSTM model showed less error and the results showed that it could be used to predict the aerosol optical thickness.

ConvLSTM Application for Prediction Aerosol Optical Thickness

Uzahir R. Ramadani, Dušan P. Nikezić, Dušan S. Radivojević, Nikola Mirkov i Ivan Lazović