



PERNYATAAN KESANGGUPAN PENYUSUNAN DAN MENGUSULKAN PROPOSAL PENELITIAN/PENGABDIAN KEPADA MASYARAKAT PENDANAAN EKSTERNAL

Saya yang bertanda-tangan di bawah ini:

Nama : DWI PEBRIANTI
NIDN : 170037
Fakultas : FAKULTAS TEKNOLOGI INFORMASI (MAGISTER ILMU KOMPUTER)
Judul Penelitian/PKM : EnviroScan HeatMap: Sistem Pemantauan Lingkungan Berbasis Citra Satelit dan Deep Learning untuk Deteksi Distribusi Anomali Panas
Skema : UTAMA
Periode Pelaksanaan : Semester Genap TA 2024/2025

Dengan ini menyatakan bahwa Saya sanggup menyusun dan mengusulkan proposal Penelitian/Pengabdian kepada Masyarakat untuk mendapatkan pendanaan di luar Universitas Budi Luhur, baik pendanaan hibah dalam negeri maupun luar negeri.

Demikian surat pernyataan ini dibuat dengan sebenarnya.

Jakarta, 4 JULI 2025

Materai+ttd

(Dr. Eng., Ir., Dwi Pebrianti, Eng. Tech., SMIEEE, IPU (Ph.D))



ISIAN SUBSTANSI PROPOSAL PENELITIAN

Petunjuk: Pengusul hanya diperkenankan mengisi di tempat yang telah disediakan sesuai dengan petunjuk pengisian dan tidak diperkenankan melakukan modifikasi template atau penghapusan di setiap bagian.

JUDUL

Tuliskan judul penelitian

EnviroScan HeatMap: Sistem Pemantauan Lingkungan Berbasis Citra Satelit dan Deep Learning untuk Deteksi Distribusi Anomali Panas

RINGKASAN

Isian ringkasan penelitian tidak lebih dari 300 kata yang berisi urgensi, tujuan, metode, dan luaran yang ditargetkan.

Meningkatnya suhu global dan kejadian cuaca ekstrem seperti gelombang panas, kebakaran hutan, dan pulau panas perkotaan menimbulkan risiko besar terhadap ekosistem, kesehatan manusia, dan infrastruktur. Selain itu, anomali panas juga berkaitan dengan banjir, hujan lebat, dan perubahan pola cuaca. Saat ini, metode pemantauan lingkungan masih bergantung pada sensor darat dan pengumpulan data manual yang terbatas dari segi cakupan, resolusi, dan efisiensi.

Sebagai respons terhadap tantangan tersebut, proyek ini mengusulkan pengembangan *Environmental Monitoring System* (EMS) berbasis citra satelit dan pembelajaran mendalam (*deep learning*) untuk memantau distribusi anomali panas. EMS ini akan menggunakan satelit observasi Bumi dengan sensor termal guna mengumpulkan data distribusi panas dari berbagai wilayah. Data kemudian diproses melalui koreksi radiometrik, geometrik, pengurangan noise, serta penghapusan awan dan bayangan guna meningkatkan kualitas citra.

Setelah pra-pemrosesan, data dianalisis menggunakan algoritma deep learning seperti *Convolutional Neural Networks* (CNN) dan *Recurrent Neural Networks* (RNN). CNN akan mengekstrak fitur spasial dari citra satelit, sedangkan RNN menangkap pola temporal, memungkinkan deteksi anomali panas secara lebih akurat dari waktu ke waktu. Model yang telah dilatih akan digunakan untuk menganalisis data satelit secara real-time dan mendeteksi lokasi anomali panas.

Luaran dari proyek ini mencakup sistem deteksi panas dan distribusi anomali panas dan publikasi ilmiah di jurnal *Scopus* seperti *Journal of Applied Remote Sensing (SPIE)*. Sistem ini diharapkan dapat memberikan manfaat signifikan, termasuk penghematan biaya, peningkatan produktivitas, serta dukungan terhadap pengambilan keputusan oleh pemangku kepentingan. Selain itu, proyek ini turut mendukung prioritas nasional dalam bidang kecerdasan buatan dan pemantauan lingkungan berkelanjutan.

KATA KUNCI

Isian kata kunci maksimal 5 kata yang dipisahkan dengan tanda titik koma (;)

Pembelajaran Mendalam (deep learning), citra satelit, anomali panas, peantauan lingkungan, kecerdasan buatan (artificial intelligence)

PENDAHULUAN

Pendahuluan penelitian tidak lebih dari 1000 kata yang terdiri dari:

1. Latar belakang dan rumusan permasalahan yang akan diteliti
2. Pendekatan pemecahan masalah
3. *State of the art* dan kebaruan
4. Peta jalan (*road map*) penelitian 5 tahun

Situs disusun dan ditulis berdasarkan sistem nomor sesuai dengan urutan pengutipan, mengikuti format Vancouver

1. LATAR BELAKANG DAN RUMUSAN MASALAH

Fenomena anomali panas di permukaan Bumi yang dipengaruhi oleh perubahan iklim menjadi tantangan besar dalam pemantauan dan pengelolaan lingkungan. Anomali panas seperti kebakaran hutan, pulau panas perkotaan, dan gelombang panas berdampak negatif terhadap ekosistem, kesehatan manusia, dan infrastruktur. Indonesia sebagai negara tropis yang padat penduduk sangat rentan terhadap fenomena ini. Salah satu contohnya adalah kebakaran hutan di perkebunan kelapa sawit seperti terlihat pada Gambar 1.



2.

3. Gambar 1. Kebakaran Hutan di Perkebunan Kelapa Sawit

Anomali panas kini terjadi lebih sering dan dengan intensitas yang meningkat. Kebakaran hutan tidak hanya merusak ekosistem tetapi juga melepaskan gas rumah kaca. Pulau panas perkotaan menyebabkan peningkatan penyakit terkait panas dan lonjakan penggunaan energi. Gelombang panas, yakni periode suhu tinggi yang berkepanjangan, membahayakan kelompok rentan seperti lansia dan masyarakat berpenghasilan rendah. Gambar 2 menunjukkan dampak anomali

panas yang terjadi di berbagai belahan dunia. Dampak yang timbul tidak hanya bagi lingkungan tetapi juga bagi kehidupan manusia.



Gambar 2. Dampak Anomali Panas

Metode tradisional pemantauan anomali panas bergantung pada sensor darat dan pengumpulan data manual, yang terbatas dari segi cakupan dan efisiensi. Pemasangan dan pemeliharaan sensor juga memerlukan biaya besar. Gambar 3 memperlihatkan sistem berbasis darat yang menggunakan sensor suhu, kelembapan, tekanan barometrik, dan tekanan udara.

Sensor ini mampu mencatat anomali selama gelombang panas atau pulau panas perkotaan, namun cakupannya terbatas pada lokasi pemasangan. Oleh karena itu, dibutuhkan strategi pemantauan yang lebih efisien, luas, dan adaptif untuk mengurangi dampak anomali panas.



Gambar 3. Metode Tradisional untuk Deteksi Anomali Panas Menggunakan Sensor Suhu, Kelembapan, Barometrik, dan Tekanan

4. PENDEKATAN PEMECAHAN MASALAH

Penelitian ini mengusulkan pengembangan Sistem Pemantauan Lingkungan (Environmental Monitoring System/EMS) berbasis citra satelit dan algoritma pembelajaran mendalam (deep learning) untuk mendeteksi dan menganalisis distribusi panas. Teknologi satelit menawarkan cakupan luas dengan resolusi tinggi, sedangkan deep learning mampu mengotomatisasi proses identifikasi anomali secara presisi dan efisien. Kombinasi ini menjadi alternatif yang menjanjikan dibandingkan metode tradisional.

Hipotesis

Integrasi citra satelit dan algoritma pembelajaran mendalam dapat secara efektif mendeteksi anomali dalam distribusi panas di permukaan Bumi.

Pertanyaan Penelitian

- 1) Bagaimana citra satelit dapat dimanfaatkan secara efektif untuk memantau dan mendeteksi anomali panas?
- 2) Algoritma pembelajaran mendalam apa yang paling sesuai untuk menganalisis citra satelit dalam mendeteksi anomali panas?
- 3) Bagaimana perbandingan EMS yang diusulkan dengan metode tradisional dari segi akurasi, efisiensi, dan cakupan?

5. STATE OF THE ART DAN KEBARUAN

Penelitian sebelumnya telah mengeksplorasi berbagai pendekatan untuk memantau dan mendeteksi anomali panas menggunakan citra satelit dan teknik penginderaan jauh. Berbagai studi telah meneliti penggunaan sensor termal pada satelit observasi Bumi untuk menangkap radiasi inframerah termal yang dipancarkan oleh permukaan Bumi, sehingga memungkinkan deteksi anomali panas seperti kebakaran hutan dan pulau panas perkotaan.

Platform penginderaan termal seperti Argo float pernah digunakan untuk mengamati anomali suhu dan salinitas laut dalam terkait letusan bawah laut Havre 2012 [2]. Argo float mendeteksi sinyal signifikan pada tingkat >3 sigma dibanding variabilitas laut normal (noise) di kedalaman sekitar 1750-2000 m, lebih dalam dari ventilasi erupsi. Namun, penerapannya terbatas pada area tertentu dan memerlukan biaya tinggi untuk pemasangan sensor di lokasi.

Deteksi anomali panas di Bumi umumnya didasarkan pada radiasi elektromagnetik yang terbagi menjadi resolusi rendah dan sedang. Sensor beresolusi rendah (LR; ≥ 100 m) dengan pita inframerah menengah (MIR, 3-5 μm) dan inframerah termal (TIR, 8-14 μm) digunakan untuk mendeteksi kebakaran, seperti pada sensor Terra/Aqua MODIS [3], Suomi-NPP VIIRS [4], Himawari-8 AHI [5], dan FY-3C VIRR [6]. Namun, elemen detektor LR memiliki keterbatasan dalam mendeteksi anomali panas skala kecil karena resolusi kasar dan kesulitan mendapatkan informasi spasial seperti lokasi, ukuran, dan bentuk.

Sensor beresolusi sedang (MR), seperti Landsat-8 Operational Land Imager (OLI) dan Sentinel-2A/2B Multispectral Instrument (MSI), memberikan informasi spasial lebih rinci dan berguna dalam studi anomali panas, terutama untuk pemetaan area terdampak kebakaran [7][8][9]. Citra MR melengkapi LR karena kemampuannya yang lebih baik dalam mendeteksi anomali panas kecil/lemah serta menyajikan informasi spasial lebih akurat, berguna untuk manajemen kebakaran dan pemantauan vulkanik [10][11].

Dalam analisis citra satelit, metode machine learning banyak digunakan. Model supervised learning konvensional meliputi decision tree, random forest, dan support vector machine (SVM) [12][13]. Namun, metode ini memiliki keterbatasan dalam menghadapi hamburan cahaya, mekanisme hamburan kompleks, kesamaan antar kelas, dan variasi dalam kelas yang membuat proses analisis rumit.

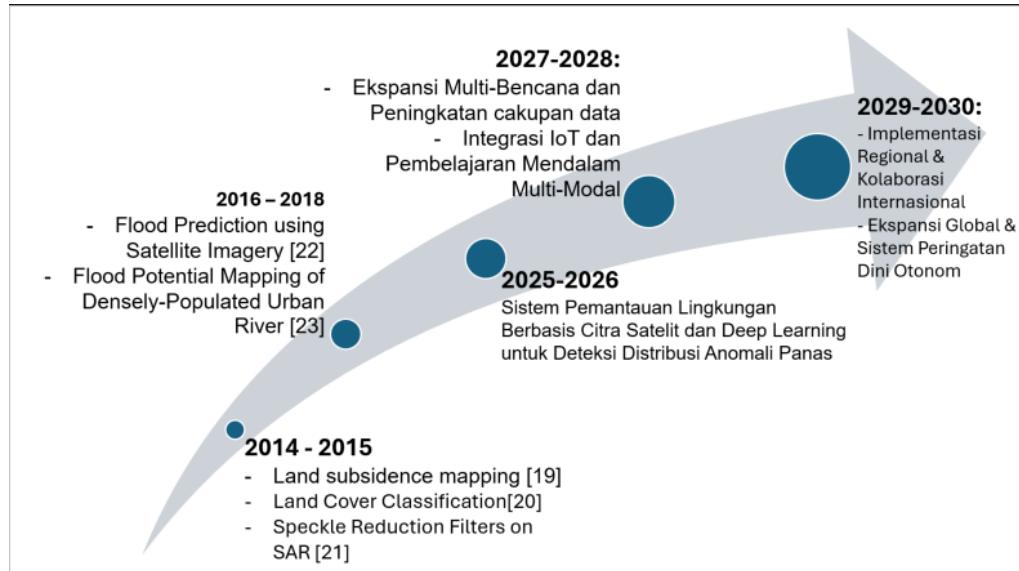
Dalam beberapa tahun terakhir, teknik *deep learning* semakin berkembang di bidang penginderaan jauh, menawarkan pendekatan menjanjikan untuk deteksi dan analisis anomali panas dengan akurasi serta efisiensi lebih tinggi. Metodologi *deep learning*, khususnya *Convolutional Neural Networks* (CNN) [14][15][16][17] dan *Recurrent Neural Networks* (RNN) [18], menunjukkan kemampuan kuat mengekstraksi pola spasial dan temporal dari citra satelit untuk deteksi anomali panas.

Selain itu, integrasi data dari berbagai sensor satelit telah menjadi praktik umum untuk meningkatkan ketahanan dan keandalan sistem deteksi anomali panas. Kerangka kerja *deep learning* memungkinkan penggabungan data dari berbagai sumber seperti citra optik, termal, dan radar, sehingga memungkinkan analisis komprehensif pada berbagai skala spasial dan temporal.

Salah satu tantangan dalam penerapan *deep learning* pada citra satelit untuk deteksi anomali panas adalah pemilihan model dan parameter yang tepat guna mencapai akurasi serta ketahanan tinggi. *Transfer learning*, yakni pemanfaatan model *deep learning* yang telah dilatih pada dataset besar, menjadi strategi bernilai untuk mengatasi keterbatasan data dan adaptasi domain. Dengan *fine-tuning* menggunakan dataset citra satelit spesifik, peneliti berhasil meningkatkan akurasi dan kemampuan generalisasi dalam deteksi anomali panas.

Penelitian terkait penerapan *deep learning* pada citra satelit telah menunjukkan hasil menjanjikan dalam akurasi dan efisiensi, serta menyoroti potensi integrasi citra satelit dan *deep learning* untuk pemantauan lingkungan. Namun, masih dibutuhkan penelitian lanjutan untuk mengeksplorasi metode optimal dalam pra-pemrosesan citra, pemilihan algoritma, serta evaluasi kinerja EMS di dunia nyata. Dalam konteks deteksi anomali panas di Bumi, aplikasi yang dilaporkan masih terbatas. Oleh karena itu, studi ini diharapkan memberi kontribusi nyata bagi masyarakat dan pengambil kebijakan dalam menangani permasalahan anomali panas.

6. PETA JALAN PENELITIAN



Gambar 4. Peta Jalan Penelitian

Gambar 4 menunjukkan peta jalan penelitian. Para peneliti yang bergabung di dalam penelitian ini telah memiliki pengalaman di bidang citra satelite sejak tahun 2007. Ketua peneliti memulai penelitian di bidang citra satelit sejak 2014. Dengan kemajuan di bidang kecerdasan buatan dan juga Internet of Things, penelitian ini menjadi sangat penting untuk dikembangkan.

METODE

Isian metode atau cara untuk mencapai tujuan yang telah ditetapkan ditulis tidak melebihi 1000 kata. Bagian ini dapat dilengkapi dengan diagram alir penelitian yang menggambarkan apa yang sudah dilaksanakan dan yang akan dikerjakan selama waktu yang diusulkan. Metode penelitian harus dibuat secara utuh dengan penahapan yang jelas, mulai dari awal bagaimana proses dan luarannya, dan indikator capaian yang ditargetkan yang tercermin dalam Rencana Anggaran Biaya (RAB).

Metodologi pengembangan Sistem Pemantauan Lingkungan (Environmental Monitoring System/EMS) untuk Deteksi Distribusi Anomali Panas menggunakan Citra Satelit dan Deep Learning disusun dalam beberapa fase, masing-masing mencakup rentang waktu tertentu dalam jangka waktu satu tahun (12 bulan). Penjelasan rinci metodologi adalah sebagai berikut:

Fase 1 : Akuisisi dan Pra-pemrosesan Data (Bulan 1-2)

Data akan dibeli dari provider citra satelit melalui koordinasi dengan lembaga satelit, organisasi penelitian, atau penyedia citra satelit komersial seperti Sentinel Hub, Planet, atau ASTER.



Gambar 4. Contoh Citra Satelit

Data citra satelit yang diperoleh akan menjalani proses pra-pemrosesan untuk meningkatkan kualitas citra dan mengekstraksi fitur-fitur yang relevan. Tahapan ini mencakup koreksi radiometrik, koreksi geometrik, reduksi noise, serta penghapusan awan dan bayangan. Kegiatan persiapan data meliputi pengorganisasian, pembersihan, dan pelabelan data citra untuk keperluan pelatihan dan validasi model.

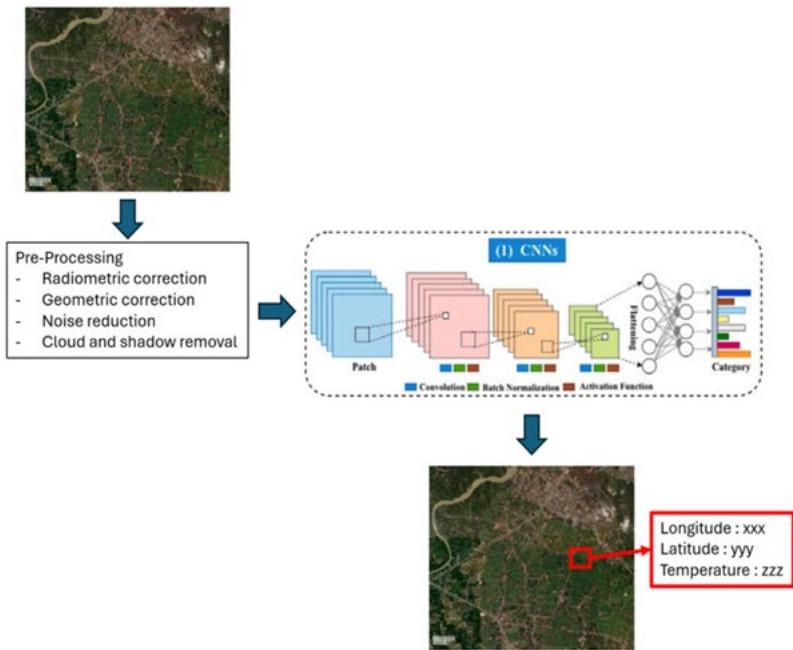


Gambar 5. Citra Satelit setelah Pra-pemrosesan

Anggota peneliti yang akan bertanggung jawab adalah Rusdah dibantu mahasiswa Aditio Pra Utama.

Fase 2: Pengembangan Model Deep Learning (Bulan 3-6)

Algoritma deep learning, khususnya Convolutional Neural Networks (CNNs) dengan arsitektur seperti VGG16 dan ResNet50, akan digunakan untuk mendeteksi anomali dalam distribusi panas. Selain itu, Recurrent Neural Networks (RNNs) juga akan diimplementasikan untuk mengevaluasi kinerjanya dalam mendeteksi anomali panas. Model deep learning yang dipilih akan dikembangkan dan diimplementasikan menggunakan kerangka kerja seperti TensorFlow atau PyTorch. Desain arsitektur model, penyesuaian hyperparameter, dan optimisasi akan dilakukan untuk memaksimalkan kinerja dan efisiensi.



Gambar 6. Model Pembelajaran Mendalam untuk Distribusi Anomali Pnas dengan Menggunakan Citra Satelit

Seperti yang disebutkan dalam Fase 1, citra satelit akan diperoleh dari mitra industri. Data citra satelit ini akan memiliki resolusi tinggi dengan citra multispektral atau hiperspektral. Setelah data diperoleh, proses selanjutnya adalah mengekstraksi informasi yang berkaitan dengan suhu, menghitung indeks vegetasi, mengidentifikasi kelas penutup lahan, mengekstraksi fitur tekstur, dan melakukan agregasi spasial.

- a) Suhu dapat diekstraksi dari pita inframerah termal yang terdapat dalam data citra satelit.
- b) Indeks vegetasi mencakup Normalized Difference Vegetation Index (NDVI) dan Enhanced Vegetation Index (EVI). Kedua parameter ini akan dihitung menggunakan Persamaan (1) dan Persamaan (2).

$$NDVI = \frac{NIR-R}{NIR+R} \quad (1)$$

Di mana NIR adalah pita Near-Infrared (dekat inframerah) yang menangkap cahaya pantulan dalam spektrum dekat inframerah, di mana vegetasi yang sehat memantulkan cahaya NIR dengan kuat. Selain itu, R adalah pita Merah yang menangkap cahaya pantulan dalam spektrum merah yang terlihat, di mana klorofil dalam vegetasi hijau

menyerap cahaya merah. Nilai NDVI berkisar antara -1 hingga 1, di mana nilai yang lebih tinggi menunjukkan vegetasi yang lebih sehat dan lebih melimpah.

$$EVI = G \left(\frac{NIR-R}{NIR+C_1R-C_2B+L} \right) \quad (2)$$

Di mana NIR adalah pita Near-InfraRed (dekat inframerah), R adalah pita Merah, B adalah pita Biru, L adalah faktor yang memperhitungkan pantulan latar belakang kanopi, C_1 dan C_2 adalah koefisien yang digunakan untuk menyesuaikan kontribusi dari pita biru, dan G adalah faktor penguat untuk menyesuaikan sensitivitas EVI.

- a) Mengidentifikasi jenis tutupan lahan, misalnya kawasan perkotaan, hutan, dan badan air. Dalam hal ini, anomali panas akan muncul berbeda pada berbagai kelas tutupan lahan.
- b) Menghitung metrik tekstur, seperti entropi dan deviasi standar, untuk menangkap pola spasial. Anomali akan menunjukkan tekstur unik dibandingkan dengan area sekitarnya.
- c) Agregasi spasial dilakukan dengan menghitung statistik zonasi (rata-rata, maksimum, minimum) dalam wilayah yang telah ditentukan, seperti blok perkotaan atau lahan pertanian. Pada langkah ini, area dengan deviasi suhu ekstrem akan diidentifikasi secara lebih halus.

Convolutional Neural Networks (CNNs) atau Recurrent Neural Networks (RNNs) sebagai model deep learning akan digunakan untuk mempelajari pola spasial yang kompleks. Model ini akan dilatih untuk mengidentifikasi ketidaknormalan dalam distribusi suhu. Deep learning memiliki beberapa parameter yang dapat disesuaikan untuk memperoleh akurasi tinggi dalam performa sistem, yang disebut sebagai hiperparameter. Ini mencakup *learning rate*, *batch size*, jumlah *epoch*, fungsi aktivasi, dan *dropout rate*. Masing-masing parameter akan dianalisis untuk menentukan model deep learning terbaik dalam mendeteksi anomali panas.

Penanggung jawab untuk Fase 2 adalah Dwi Pebrianti (PI) dan Luhur Bayuaji.

Fase 3: Pelatihan Model dan Validasi (Bulan 7-9)

Data citra satelit yang telah diberi label akan digunakan untuk melatih dan memvalidasi model deep learning yang dikembangkan. Dataset pelatihan akan dibagi menjadi tiga bagian: data pelatihan, data validasi, dan data pengujian untuk mengevaluasi performa model.

Iterasi pelatihan model akan dilakukan untuk mengoptimalkan akurasi, generalisasi, dan ketahanan model. Karena proses pengambilan keputusan dalam proyek ini adalah antara kategori API (FIRE) atau TIDAK API (NON-FIRE), kurva ROC (Receiver Operating Characteristic) dan AUC (Area Under the Curve) akan digunakan sebagai metrik evaluasi model yang dikembangkan.

Kurva ROC memvisualisasikan trade-off antara sensitivitas dan spesifisitas pada berbagai ambang klasifikasi, sementara AUC memberikan nilai skalar tunggal yang merepresentasikan performa model tanpa bergantung pada ambang yang dipilih. Nilai AUC yang lebih tinggi menunjukkan performa klasifikasi yang lebih baik.

Penanggung jawab untuk Fase 3 adalah Indra Riyanto dan Indah Dwijayanti.

Fase 4: Penulisan Laporan dan Publikasi Penelitian

Fasa akhir adalah fasa dokumentasi. Pertama, akan dilakukan pendokumentasian metodologi, algoritma, detail implementasi, dan hasil eksperimental secara rinci. Kemudian, kesimpulan, temuan baru dari penelitian dan rekomendasi untuk penelitian dan pengembangan masa depan.

Langkah selanjutnya adalah penulisan laporan akhir yang komprehensif serta presentasi untuk merangkum temuan penelitian.

JADWAL PENELITIAN

Jadwal penelitian disusun berdasarkan pelaksanaan penelitian, ditulis dengan mengisi langsung tabel berikut dan diperbolehkan menambahkan baris sesuai banyaknya jenis kegiatan.

No	Nama Kegiatan	Bulan											
		1	2	3	4	5	6	7	8	9	10	11	12
1	Pembelian Data Citra satelit	✓											
2	Pra-Pemrosesan Data: koreksi radiometrik/geometrik, reduksi noise, penghapusan awan	✓	✓	✓									
3	Pengembangan Model Deep Learning: VGG16, Resnet50		✓	✓	✓	✓	✓	✓					

4	Pelatihan Model dan Validasi						✓	✓	✓			
5	System Deployment							✓	✓	✓		
6	Penulisan Laporan penelitian dan jurnal publikasi									✓	✓	✓

DAFTAR PUSTAKA

Situs disusun dan ditulis berdasarkan sistem nomor sesuai dengan urutan pengutipan, mengikuti format Vancouver. Sumber pustaka mengutamakan hasil penelitian pada jurnal ilmiah yang terkini (maksimal 5 tahun terakhir). Hanya pustaka yang disitasi pada usulan penelitian yang dicantumkan dalam Daftar Pustaka.

- [1] K. H. Yong, Y. N. Teo, M. Azadbakht, H. Phung, and C. Chu, "The Scorching Truth: Investigating the Impact of Heatwaves on Selangor's Elderly Hospitalisations," *Int J Environ Res Public Health*, vol. 20, no. 10, May 2023, doi: 10.3390/ijerph20105910.
- [2] T. Mittal and B. Delbridge, "Detection of the 2012 Havre submarine eruption plume using Argo floats and its implications for ocean dynamics," *Earth Planet Sci Lett*, vol. 511, pp. 105-116, Apr. 2019, doi: 10.1016/j.epsl.2019.01.035.
- [3] L. Giglio, W. Schroeder, and C. O. Justice, "The collection 6 MODIS active fire detection algorithm and fire products," *Remote Sens Environ*, vol. 178, pp. 31-41, Jun. 2016, doi: 10.1016/j.rse.2016.02.054.
- [4] I. Csizsar et al., "Active fires from the suomi NPP visible infrared imaging radiometer suite: Product status and first evaluation results," *J Geophys Res*, vol. 119, no. 2, pp. 803-816, Jan. 2014, doi: 10.1002/2013JD020453.
- [5] X. Zhang, L. Liu, X. Chen, S. Xie, and Y. Gao, "Fine land-cover mapping in China using Landsat datacube and an operational SPECLib-based approach," *Remote Sens (Basel)*, vol. 11, no. 9, May 2019, doi: 10.3390/rs11091056.
- [6] Z. Lin et al., "An active fire detection algorithm based on multi-temporal FengYun-3C VIRR data," *Remote Sens Environ*, vol. 211, pp. 376-387, Jun. 2018, doi: 10.1016/j.rse.2018.04.027.
- [7] A. I. R. Cabral, S. Silva, P. C. Silva, L. Vanneschi, and M. J. Vasconcelos, "Burned area estimations derived from Landsat ETM+ and OLI data: Comparing Genetic Programming with Maximum Likelihood and Classification and Regression Trees," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 142, pp. 94-105, 2018, doi: <https://doi.org/10.1016/j.isprsjprs.2018.05.007>.
- [8] T. J. Hawbaker et al., "Mapping burned areas using dense time-series of Landsat data," *Remote Sens Environ*, vol. 198, pp. 504-522, 2017, doi: <https://doi.org/10.1016/j.rse.2017.06.027>.
- [9] E. Roteta, A. Bastarrika, M. Padilla, T. Storm, and E. Chuvieco, "Development of a Sentinel-2 burned area algorithm: Generation of a small fire database for sub-Saharan Africa," *Remote Sens Environ*, vol. 222, pp. 1-17, Mar. 2019, doi: 10.1016/j.rse.2018.12.011.

- [10] F. Marchese, N. Genzano, M. Neri, A. Falconieri, G. Mazzeo, and N. Pergola, "A multi-channel algorithm for mapping volcanic thermal anomalies by means of sentinel-2 MSI and Landsat-8 OLI data," *Remote Sens* (Basel), vol. 11, no. 23, Dec. 2019, doi: 10.3390/rs11232876.
- [11] N. Genzano, N. Pergola, and F. Marchese, "A google earth engine tool to investigate, map and monitor volcanic thermal anomalies at global scale by means of mid-high spatial resolution satellite data," *Remote Sens* (Basel), vol. 12, no. 19, pp. 1-22, Oct. 2020, doi: 10.3390/rs12193232.
- [12] G. Camps-Valls, D. Tuia, L. Bruzzone, and J. A. Benediktsson, "Advances in hyperspectral image classification: Earth monitoring with statistical learning methods," *IEEE Signal Process Mag*, vol. 31, no. 1, pp. 45-54, 2014, doi: 10.1109/MSP.2013.2279179.
- [13] Y. Oulad Sayad, H. Mousannif, and H. Al Moatassime, "Predictive Modeling of Wildfires: A New Dataset and Machine Learning Approach Predictive Modeling of Wildfires: A New Dataset Approach," 2019. [Online]. Available: <https://www.elsevier.com/open-access/userlicense/1.0/>
- [14] W. Hu, Y. Huang, L. Wei, F. Zhang, and H. Li, "Deep convolutional neural networks for hyperspectral image classification," *J Sens*, vol. 2015, 2015, doi: 10.1155/2015/258619.
- [15] H. Liu, K. Wu, H. Xu, and Y. Xu, "Lithology classification using TASI thermal infrared hyperspectral data with convolutional neural networks," *Remote Sens* (Basel), vol. 13, no. 16, Aug. 2021, doi: 10.3390/rs13163117.
- [16] Q. X. Zhang, G. H. Lin, Y. M. Zhang, G. Xu, and J. J. Wang, "Wildland Forest Fire Smoke Detection Based on Faster R-CNN using Synthetic Smoke Images," in *Procedia Engineering*, Elsevier Ltd, 2018, pp. 441-446. doi: 10.1016/j.proeng.2017.12.034.
- [17] P. Barmpoutis, K. Dimitropoulos, K. Kaza, and N. Grammalidis, "Fire detection from images using Faster R CNN and multidimensional texture analysis," in *2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019, pp. 8301-8305.
- [18] H. Lyu, H. Lu, and L. Mou, "Learning a transferable change rule from a recurrent neural network for land cover change detection," *Remote Sens* (Basel), vol. 8, no. 6, 2016, doi: 10.3390/rs8060506.



ISIAN LAPORAN KEMAJUAN PENELITIAN

Petunjuk: Pengusul hanya diperkenankan mengisi di tempat yang telah disediakan sesuai dengan petunjuk pengisian dan tidak diperkenankan melakukan modifikasi template atau penghapusan di setiap bagian.

JUDUL

Tuliskan judul penelitian

EnviroScan HeatMap: Sistem Pemantauan Lingkungan Berbasis Citra Satelit dan Deep Learning untuk Deteksi Distribusi Anomali Panas

RINGKASAN

Isian ringkasan penelitian tidak lebih dari 300 kata yang berisi urgensi, tujuan, metode, dan luaran yang ditargetkan.

Meningkatnya suhu global dan kejadian cuaca ekstrem seperti gelombang panas, kebakaran hutan, dan pulau panas perkotaan menimbulkan risiko besar terhadap ekosistem, kesehatan manusia, dan infrastruktur. Selain itu, anomali panas juga berkaitan dengan banjir, hujan lebat, dan perubahan pola cuaca. Saat ini, metode pemantauan lingkungan masih bergantung pada sensor darat dan pengumpulan data manual yang terbatas dari segi cakupan, resolusi, dan efisiensi.

Sebagai respons terhadap tantangan tersebut, proyek ini mengusulkan pengembangan *Environmental Monitoring System* (EMS) berbasis citra satelit dan pembelajaran mendalam (*deep learning*) untuk memantau distribusi anomali panas. EMS ini akan menggunakan satelit observasi Bumi dengan sensor termal guna mengumpulkan data distribusi panas dari berbagai wilayah. Data kemudian diproses melalui koreksi radiometrik, geometrik, pengurangan noise, serta penghapusan awan dan bayangan guna meningkatkan kualitas citra.

Setelah pra-pemrosesan, data dianalisis menggunakan algoritma deep learning seperti *Convolutional Neural Networks* (CNN) dan *Recurrent Neural Networks* (RNN). CNN akan mengekstrak fitur spasial dari citra satelit, sedangkan RNN menangkap pola temporal, memungkinkan deteksi anomali panas secara lebih akurat dari waktu ke waktu. Model yang telah dilatih akan digunakan untuk menganalisis data satelit secara real-time dan mendeteksi lokasi anomali panas.

Luaran dari proyek ini mencakup sistem deteksi panas dan distribusi anomali panas dan publikasi ilmiah di jurnal *Scopus* seperti *Journal of Applied Remote Sensing (SPIE)*. Sistem ini diharapkan dapat memberikan manfaat signifikan, termasuk penghematan biaya, peningkatan produktivitas, serta dukungan terhadap pengambilan keputusan oleh pemangku kepentingan. Selain itu, proyek ini turut mendukung prioritas nasional dalam bidang kecerdasan buatan dan pemantauan lingkungan berkelanjutan.

KATA KUNCI

Isian kata kunci maksimal 5 kata yang dipisahkan dengan tanda titik koma (;)

Pembelajaran Mendalam (deep learning), citra satelit, anomali panas, peantauan lingkungan, kecerdasan buatan (artificial intelligence)

PENDAHULUAN

Pendahuluan penelitian tidak lebih dari 1000 kata yang terdiri dari:

1. Latar belakang dan rumusan permasalahan yang akan diteliti
2. Pendekatan pemecahan masalah
3. *State of the art* dan kebaruan
4. Peta jalan (*road map*) penelitian 5 tahun

Situs disusun dan ditulis berdasarkan sistem nomor sesuai dengan urutan pengutipan, mengikuti format Vancouver

1. LATAR BELAKANG DAN RUMUSAN MASALAH

Fenomena anomali panas di permukaan Bumi yang dipengaruhi oleh perubahan iklim menjadi tantangan besar dalam pemantauan dan pengelolaan lingkungan. Anomali panas seperti kebakaran hutan, pulau panas perkotaan, dan gelombang panas berdampak negatif terhadap ekosistem, kesehatan manusia, dan infrastruktur. Indonesia sebagai negara tropis yang padat penduduk sangat rentan terhadap fenomena ini. Salah satu contohnya adalah kebakaran hutan di perkebunan kelapa sawit seperti terlihat pada Gambar 1.



Gambar 1. Kebakaran Hutan di Perkebunan Kelapa Sawit

Anomali panas kini terjadi lebih sering dan dengan intensitas yang meningkat. Kebakaran hutan tidak hanya merusak ekosistem tetapi juga melepaskan gas rumah kaca. Pulau panas perkotaan menyebabkan peningkatan penyakit terkait panas dan lonjakan penggunaan energi. Gelombang panas, yakni periode suhu tinggi yang berkepanjangan, membahayakan kelompok rentan seperti lansia dan masyarakat berpenghasilan rendah. Gambar 2 menunjukkan dampak anomali panas yang terjadi di berbagai belahan dunia. Dampak yang timbul tidak hanya bagi lingkungan tetapi juga bagi kehidupan manusia.



Gambar 2. Dampak Anomali Panas

Metode tradisional pemantauan anomali panas bergantung pada sensor darat dan pengumpulan data manual, yang terbatas dari segi cakupan dan efisiensi. Pemasangan dan pemeliharaan sensor juga memerlukan biaya besar. Gambar 3 memperlihatkan sistem berbasis darat yang menggunakan sensor suhu, kelembapan, tekanan barometrik, dan tekanan udara.

Sensor ini mampu mencatat anomali selama gelombang panas atau pulau panas perkotaan, namun cakupannya terbatas pada lokasi pemasangan. Oleh karena itu, dibutuhkan strategi pemantauan yang lebih efisien, luas, dan adaptif untuk mengurangi dampak anomali panas.



Gambar 3. Metode Tradisional untuk Deteksi Anomali Panas Menggunakan Sensor Suhu, Kelembapan, Barometrik, dan Tekanan

2. PENDEKATAN PEMECAHAN MASALAH

Penelitian ini mengusulkan pengembangan Sistem Pemantauan Lingkungan (Environmental Monitoring System/EMS) berbasis citra satelit dan algoritma pembelajaran mendalam (deep learning) untuk mendeteksi dan menganalisis distribusi panas. Teknologi satelit menawarkan cakupan luas dengan resolusi tinggi, sedangkan deep learning mampu mengotomatisasi proses

identifikasi anomali secara presisi dan efisien. Kombinasi ini menjadi alternatif yang menjanjikan dibandingkan metode tradisional.

Hipotesis

Integrasi citra satelit dan algoritma pembelajaran mendalam dapat secara efektif mendeteksi anomali dalam distribusi panas di permukaan Bumi.

Pertanyaan Penelitian

- 1) Bagaimana citra satelit dapat dimanfaatkan secara efektif untuk memantau dan mendeteksi anomali panas?
- 2) Algoritma pembelajaran mendalam apa yang paling sesuai untuk menganalisis citra satelit dalam mendeteksi anomali panas?

Bagaimana perbandingan EMS yang diusulkan dengan metode tradisional dari segi akurasi, efisiensi, dan cakupan?

3. STATE OF THE ART DAN KEBARUAN

Penelitian sebelumnya telah mengeksplorasi berbagai pendekatan untuk memantau dan mendeteksi anomali panas menggunakan citra satelit dan teknik penginderaan jauh. Berbagai studi telah meneliti penggunaan sensor termal pada satelit observasi Bumi untuk menangkap radiasi inframerah termal yang dipancarkan oleh permukaan Bumi, sehingga memungkinkan deteksi anomali panas seperti kebakaran hutan dan pulau panas perkotaan.

Platform penginderaan termal seperti Argo float pernah digunakan untuk mengamati anomali suhu dan salinitas laut dalam terkait letusan bawah laut Havre 2012 [2]. Argo float mendeteksi sinyal signifikan pada tingkat >3 sigma dibanding variabilitas laut normal (noise) di kedalaman sekitar 1750–2000 m, lebih dalam dari ventilasi erupsi. Namun, penerapannya terbatas pada area tertentu dan memerlukan biaya tinggi untuk pemasangan sensor di lokasi.

Deteksi anomali panas di Bumi umumnya didasarkan pada radiasi elektromagnetik yang terbagi menjadi resolusi rendah dan sedang. Sensor beresolusi rendah (LR; ≥ 100 m) dengan pita inframerah menengah (MIR, 3–5 μm) dan inframerah termal (TIR, 8–14 μm) digunakan untuk mendeteksi kebakaran, seperti pada sensor Terra/Aqua MODIS [3], Suomi-NPP VIIRS [4], Himawari-8 AHI [5], dan FY-3C VIRR [6]. Namun, elemen detektor LR memiliki keterbatasan dalam mendeteksi anomali panas skala kecil karena resolusi kasar dan kesulitan mendapatkan informasi spasial seperti lokasi, ukuran, dan bentuk.

Sensor beresolusi sedang (MR), seperti Landsat-8 Operational Land Imager (OLI) dan Sentinel-2A/2B Multispectral Instrument (MSI), memberikan informasi spasial lebih rinci dan berguna dalam studi anomali panas, terutama untuk pemetaan area terdampak kebakaran [7][8][9]. Citra MR melengkapi LR karena kemampuannya yang lebih baik dalam mendeteksi anomali panas

kecil/lemah serta menyajikan informasi spasial lebih akurat, berguna untuk manajemen kebakaran dan pemantauan vulkanik [10][11].

Dalam analisis citra satelit, metode machine learning banyak digunakan. Model supervised learning konvensional meliputi decision tree, random forest, dan support vector machine (SVM) [12][13]. Namun, metode ini memiliki keterbatasan dalam menghadapi hamburan cahaya, mekanisme hamburan kompleks, kesamaan antar kelas, dan variasi dalam kelas yang membuat proses analisis rumit.

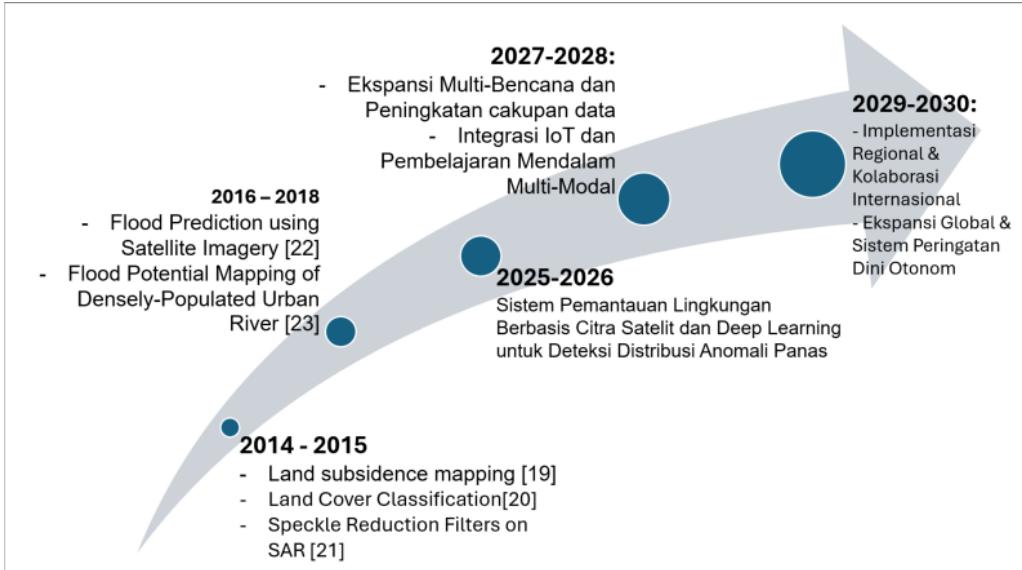
Dalam beberapa tahun terakhir, teknik *deep learning* semakin berkembang di bidang penginderaan jauh, menawarkan pendekatan menjanjikan untuk deteksi dan analisis anomali panas dengan akurasi serta efisiensi lebih tinggi. Metodologi *deep learning*, khususnya *Convolutional Neural Networks* (CNN) [14][15][16][17] dan *Recurrent Neural Networks* (RNN) [18], menunjukkan kemampuan kuat mengekstraksi pola spasial dan temporal dari citra satelit untuk deteksi anomali panas.

Selain itu, integrasi data dari berbagai sensor satelit telah menjadi praktik umum untuk meningkatkan ketahanan dan keandalan sistem deteksi anomali panas. Kerangka kerja *deep learning* memungkinkan penggabungan data dari berbagai sumber seperti citra optik, termal, dan radar, sehingga memungkinkan analisis komprehensif pada berbagai skala spasial dan temporal.

Salah satu tantangan dalam penerapan *deep learning* pada citra satelit untuk deteksi anomali panas adalah pemilihan model dan parameter yang tepat guna mencapai akurasi serta ketahanan tinggi. *Transfer learning*, yakni pemanfaatan model *deep learning* yang telah dilatih pada dataset besar, menjadi strategi bernilai untuk mengatasi keterbatasan data dan adaptasi domain. Dengan *fine-tuning* menggunakan dataset citra satelit spesifik, peneliti berhasil meningkatkan akurasi dan kemampuan generalisasi dalam deteksi anomali panas.

Penelitian terkait penerapan *deep learning* pada citra satelit telah menunjukkan hasil menjanjikan dalam akurasi dan efisiensi, serta menyoroti potensi integrasi citra satelit dan *deep learning* untuk pemantauan lingkungan. Namun, masih dibutuhkan penelitian lanjutan untuk mengeksplorasi metode optimal dalam pra-pemrosesan citra, pemilihan algoritma, serta evaluasi kinerja EMS di dunia nyata. Dalam konteks deteksi anomali panas di Bumi, aplikasi yang dilaporkan masih terbatas. Oleh karena itu, studi ini diharapkan memberi kontribusi nyata bagi masyarakat dan pengambil kebijakan dalam menangani permasalahan anomali panas.

4. PETA JALAN PENELITIAN



Gambar 4. Peta Jalan Penelitian

Gambar 4 menunjukkan peta jalan penelitian. Para peneliti yang bergabung di dalam penelitian ini telah memiliki pengalaman di bidang citra satelite sejak tahun 2007. Ketua peneliti memulai penelitian di bidang citra satelite sejak 2014. Dengan kemajuan di bidang kecerdasan buatan dan juga Internet of Things, penelitian ini menjadi sangat penting untuk dikembangkan.

METODE

Isian metode atau cara untuk mencapai tujuan yang telah ditetapkan ditulis tidak melebihi 1000 kata. Bagian ini dapat dilengkapi dengan diagram alir penelitian yang menggambarkan apa yang sudah dilaksanakan dan yang akan dikerjakan selama waktu yang diusulkan. Metode penelitian harus dibuat secara utuh dengan penahapan yang jelas, mulai dari awal bagaimana proses dan luarannya, dan indikator capaian yang ditargetkan.

Metodologi pengembangan Sistem Pemantauan Lingkungan (Environmental Monitoring System/EMS) untuk Deteksi Distribusi Anomali Panas menggunakan Citra Satelite dan Deep Learning disusun dalam beberapa fase, masing-masing mencakup rentang waktu tertentu dalam jangka waktu satu tahun (12 bulan). Penjelasan rinci metodologi adalah sebagai berikut:

Fase 1 : Akuisisi dan Pra-pemrosesan Data (Bulan 1–2)

Data akan dibeli dari provider citra satelite melalui koordinasi dengan lembaga satelite, organisasi penelitian, atau penyedia citra satelite komersial seperti Sentinel Hub, Planet, atau ASTER.



Gambar 4. Contoh Citra Satelit

Data citra satelit yang diperoleh akan menjalani proses pra-pemrosesan untuk meningkatkan kualitas citra dan mengekstraksi fitur-fitur yang relevan. Tahapan ini mencakup koreksi radiometrik, koreksi geometrik, reduksi noise, serta penghapusan awan dan bayangan. Kegiatan persiapan data meliputi pengorganisasian, pembersihan, dan pelabelan data citra untuk keperluan pelatihan dan validasi model.



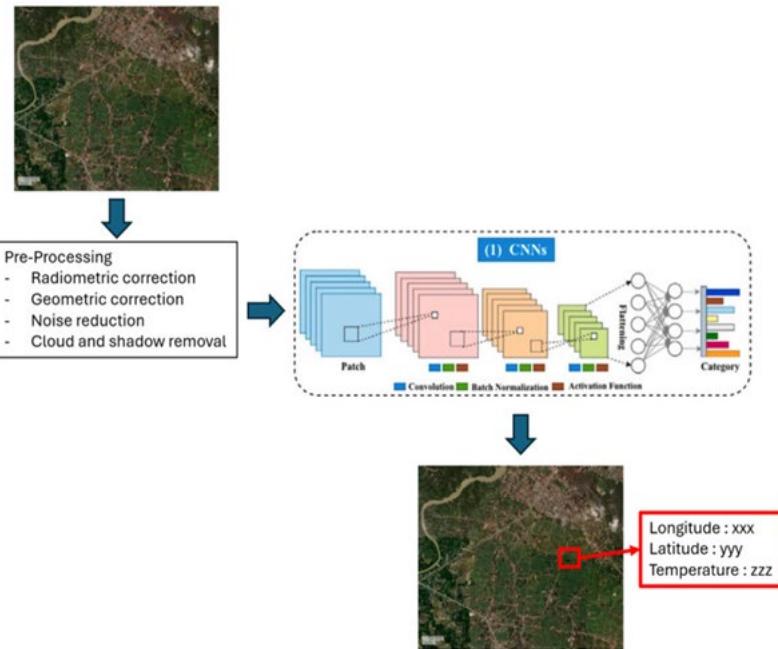
Gambar 5. Citra Satelit setelah Pra-pemrosesan

Anggota peneliti yang akan bertanggung jawab adalah Rusdah dibantu mahasiswa Aditio Pra Utama.

Fase 2: Pengembangan Model Deep Learning (Bulan 3-6)

Algoritma deep learning, khususnya Convolutional Neural Networks (CNNs) dengan arsitektur seperti VGG16 dan ResNet50, akan digunakan untuk mendeteksi anomali dalam distribusi panas. Selain itu, Recurrent Neural Networks (RNNs) juga akan diimplementasikan untuk mengevaluasi kinerjanya dalam mendeteksi anomali panas. Model deep learning yang dipilih akan

dikembangkan dan diimplementasikan menggunakan kerangka kerja seperti TensorFlow atau PyTorch. Desain arsitektur model, penyesuaian hyperparameter, dan optimisasi akan dilakukan untuk memaksimalkan kinerja dan efisiensi.



Gambar 6. Model Pembelajaran Mendalam untuk Distribusi Anomali Pnas dengan Menggunakan Citra Satelit

Seperti yang disebutkan dalam Fase 1, citra satelit akan diperoleh dari mitra industri. Data citra satelit ini akan memiliki resolusi tinggi dengan citra multispektral atau hiperspektral. Setelah data diperoleh, proses selanjutnya adalah mengekstraksi informasi yang berkaitan dengan suhu, menghitung indeks vegetasi, mengidentifikasi kelas penutup lahan, mengekstraksi fitur tekstur, dan melakukan agregasi spasial.

- Suhu dapat diekstraksi dari pita inframerah termal yang terdapat dalam data citra satelit.
- Indeks vegetasi mencakup Normalized Difference Vegetation Index (NDVI) dan Enhanced Vegetation Index (EVI). Kedua parameter ini akan dihitung menggunakan Persamaan (1) dan Persamaan (2).

$$NDVI = \frac{NIR - R}{NIR + R} \quad (1)$$

Di mana NIR adalah pita Near-Infrared (dekat inframerah) yang menangkap cahaya pantulan dalam spektrum dekat inframerah, di mana vegetasi yang sehat memantulkan cahaya NIR dengan

kuat. Selain itu, R adalah pita Merah yang menangkap cahaya pantulan dalam spektrum merah yang terlihat, di mana klorofil dalam vegetasi hijau menyerap cahaya merah. Nilai NDVI berkisar antara -1 hingga 1, di mana nilai yang lebih tinggi menunjukkan vegetasi yang lebih sehat dan lebih melimpah.

$$EVI = G \left(\frac{NIR-R}{NIR+C_1R-C_2B+L} \right) \quad (2)$$

Di mana NIR adalah pita Near-InfraRed (dekat inframerah), R adalah pita Merah, B adalah pita Biru, L adalah faktor yang memperhitungkan pantulan latar belakang kanopi, C_1 dan C_2 adalah koefisien yang digunakan untuk menyesuaikan kontribusi dari pita biru, dan G adalah faktor penguatan untuk menyesuaikan sensitivitas EVI.

- a) Mengidentifikasi jenis tutupan lahan, misalnya kawasan perkotaan, hutan, dan badan air. Dalam hal ini, anomali panas akan muncul berbeda pada berbagai kelas tutupan lahan.
- b) Menghitung metrik tekstur, seperti entropi dan deviasi standar, untuk menangkap pola spasial. Anomali akan menunjukkan tekstur unik dibandingkan dengan area sekitarnya.
- c) Agregasi spasial dilakukan dengan menghitung statistik zonasi (rata-rata, maksimum, minimum) dalam wilayah yang telah ditentukan, seperti blok perkotaan atau lahan pertanian. Pada langkah ini, area dengan deviasi suhu ekstrem akan diidentifikasi secara lebih halus.

Convolutional Neural Networks (CNNs) atau Recurrent Neural Networks (RNNs) sebagai model deep learning akan digunakan untuk mempelajari pola spasial yang kompleks. Model ini akan dilatih untuk mengidentifikasi ketidaknormalan dalam distribusi suhu. Deep learning memiliki beberapa parameter yang dapat disesuaikan untuk memperoleh akurasi tinggi dalam performa sistem, yang disebut sebagai hiperparameter. Ini mencakup *learning rate*, *batch size*, jumlah *epoch*, fungsi aktivasi, dan *dropout rate*. Masing-masing parameter akan dianalisis untuk menentukan model deep learning terbaik dalam mendeteksi anomali panas.

Penanggung jawab untuk Fase 2 adalah Dwi Pebrianti (PI) dan Luhur Bayuaji.

Fase 3: Pelatihan Model dan Validasi (Bulan 7-9)

Data citra satelit yang telah diberi label akan digunakan untuk melatih dan memvalidasi model deep learning yang dikembangkan. Dataset pelatihan akan dibagi menjadi tiga bagian: data pelatihan, data validasi, dan data pengujian untuk mengevaluasi performa model.

Iterasi pelatihan model akan dilakukan untuk mengoptimalkan akurasi, generalisasi, dan ketahanan model. Karena proses pengambilan keputusan dalam proyek ini adalah antara kategori API (FIRE) atau TIDAK API (NON-FIRE), kurva ROC (Receiver Operating Characteristic) dan AUC (Area Under the Curve) akan digunakan sebagai metrik evaluasi model yang dikembangkan.

Kurva ROC memvisualisasikan trade-off antara sensitivitas dan spesifisitas pada berbagai ambang klasifikasi, sementara AUC memberikan nilai skalar tunggal yang merepresentasikan performa model tanpa bergantung pada ambang yang dipilih. Nilai AUC yang lebih tinggi menunjukkan performa klasifikasi yang lebih baik.

Penanggung jawab untuk Fase 3 adalah Indra Riyanto dan Indah Dwijayanti.

Fase 4: Penulisan Laporan dan Publikasi Penelitian

Fasa akhir adalah fasa dokumentasi. Pertama, akan dilakukan pendokumentasi metodologi, algoritma, detail implementasi, dan hasil eksperimental secara rinci. Kemudian, kesimpulan, temuan baru dari penelitian dan rekomendasi untuk penelitian dan pengembangan masa depan.

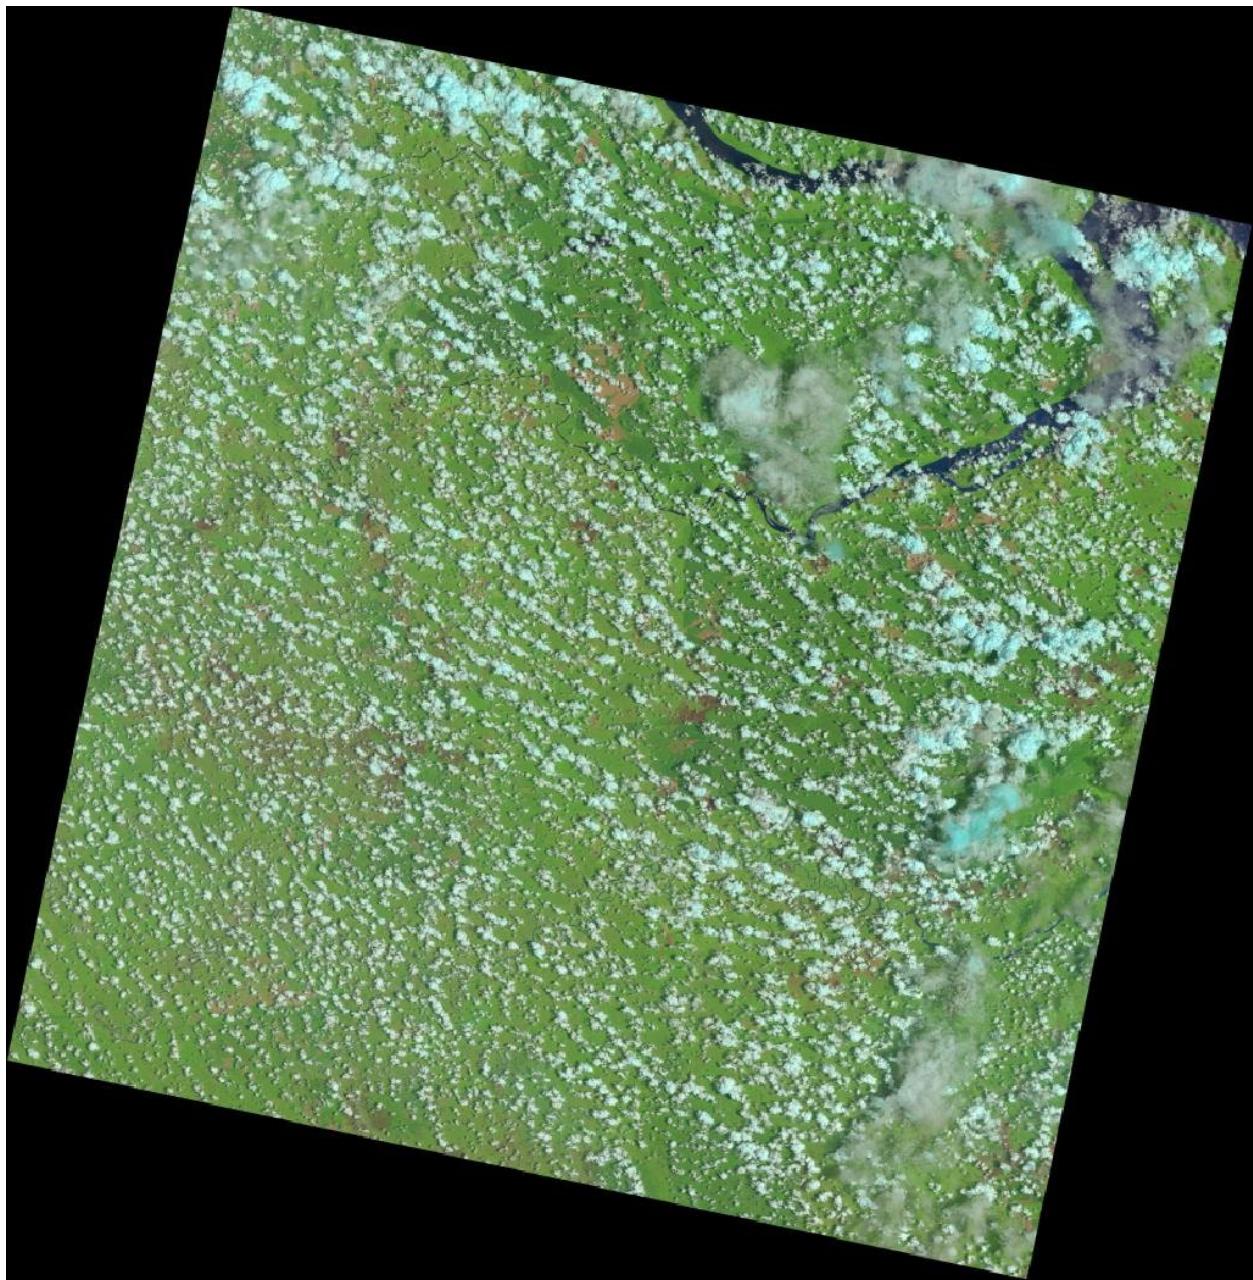
Langkah selanjutnya adalah penulisan laporan akhir yang komprehensif serta presentasi untuk merangkum temuan penelitian.

Hasil pelaksanaan penelitian yang telah dicapai meliputi data dan hasil analisis. Seluruh hasil atau capaian yang dilaporkan harus berkaitan dengan tahapan pelaksanaan penelitian sebagaimana direncanakan pada proposal. Penyajian data dapat berupa gambar, tabel, grafik, dan sejenisnya, serta analisis didukung dengan sumber pustaka primer yang relevan dan terkini.

HASIL PELAKSANAAN PENELITIAN

Penelitian ini bertujuan untuk mengembangkan sistem pemantauan lingkungan berbasis citra satelit dan deep learning guna mendeteksi distribusi anomali panas yang berkaitan dengan aktivitas perubahan lingkungan, seperti deforestasi, kebakaran lahan, dan pertambangan terbuka. Sampai saat laporan ini disusun, sejumlah capaian telah berhasil diraih sesuai dengan tahapan dalam proposal.

Tahap pertama yang telah diselesaikan adalah pengumpulan dan pengelolaan dataset citra satelit. Data yang digunakan meliputi citra Landsat-8 dan MODIS yang diperoleh dari repositori publik seperti USGS Earth Explorer dan NASA LAADS DAAC. Gambar 7 menunjukkan gambar satelite yang digunakan dalam penelitian ini.



Gambar 7. Contoh Data Satellite

Dalam penelitian ini, citra satelit Sentinel-2 dari wilayah Riau pada tahun 2019 telah dianalisis menggunakan Google Colab dan pustaka Python seperti rasterio, numpy, dan matplotlib. Proses dimulai dengan memuat file citra .tif yang telah diunduh dari Google Earth Engine dan disimpan di Google Drive. Citra ini memiliki resolusi spasial tertentu dan terdiri daripada beberapa band spektral. Pada tahap awal, citra dibaca menggunakan fungsi *rasterio.open()* dan diambil subset ukuran *1024x1024 piksel* sebagai jendela pengamatan untuk efisiensi pemrosesan.

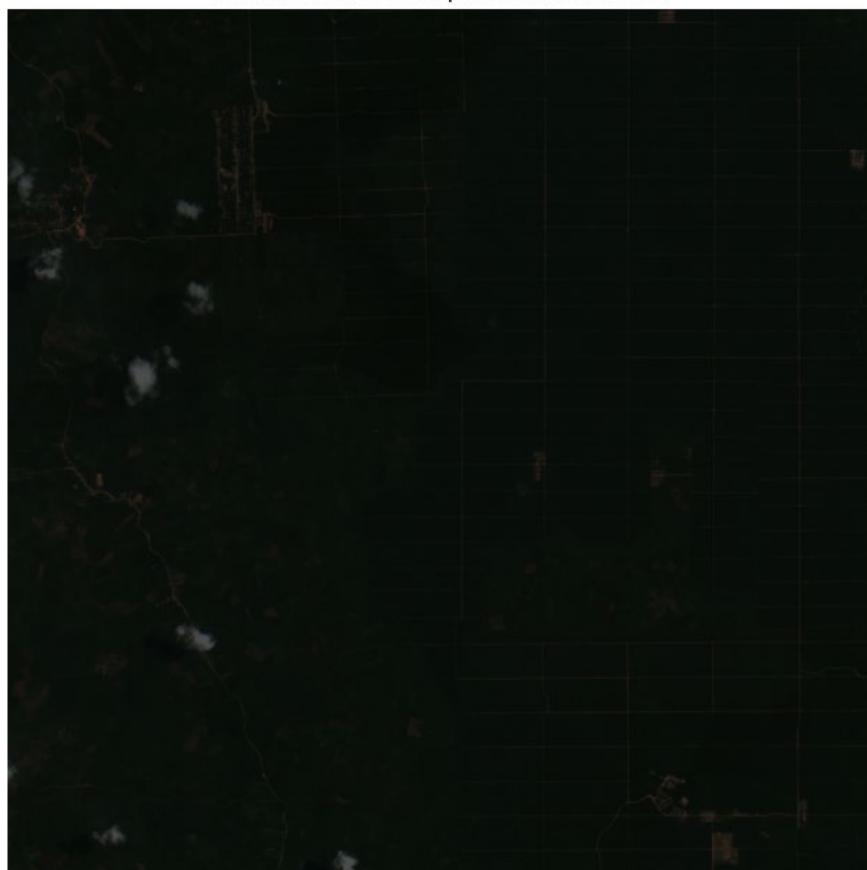
Selanjutnya, data citra yang telah dibaca dikonversi ke format *float32* dan dilakukan proses normalisasi menggunakan fungsi *np.clip()* untuk membatasi nilai piksel dalam rentang 0 hingga 0.3. Hal ini bertujuan untuk menyesuaikan skala reflektansi yang umum digunakan pada citra hasil pemrosesan Google Earth Engine. Kemudian, dilakukan pembentukan komposit RGB dengan menyusun band 4 (*Red*), band 3 (*Green*), dan band 2 (*Blue*) yang menghasilkan representasi visual mendekati tampilan alami. Citra RGB ini kemudian ditampilkan menggunakan matplotlib untuk memudahkan interpretasi visual.

Hasil yang diperoleh berupa citra komposit RGB Sentinel-2 wilayah Riau tahun 2019 yang dapat digunakan untuk analisis lanjutan, seperti deteksi perubahan tutupan lahan atau kejadian kebakaran hutan. Tahapan ini merupakan bagian penting dari preprocessing dalam pipeline deteksi kebakaran berbasis citra satelit, karena membantu memahami distribusi spasial elemen-elemen visual seperti vegetasi, permukaan terbakar, dan awan.

Band count: 4

Image shape: (4, 1024, 1024)

Sentinel-2 RGB Composite (Riau, 2019)



Gambar 8. Hasil Komposit RGB Riau 2019.

Gambar 8 menunjukkan hasil dari proses yang dijalankan. Dari hasil awal ini terlihat bahwa gambar masih belum menunjukkan hasil yang diharapkan. Perbedaan antara awan, titik panas dan juga vegetasi masih belum terlihat dengan jelas. Hal ini menjadi titik untuk melakukan perbaikan algoritma pra-pemrosesan selanjutnya.

Untuk meningkatkan keterbacaan citra Sentinel-2 komposit RGB wilayah Riau tahun 2019, dilakukan penyesuaian terhadap rentang tampilan nilai piksel pada proses visualisasi. Hal ini dilakukan dengan menggunakan parameter *vmin* dan *vmax* pada fungsi *plt.imshow()*, di mana nilai minimum diatur ke 0.02 dan maksimum ke 0.15. Rentang ini dipilih berdasarkan asumsi nilai reflektansi permukaan yang umum pada kanal merah, hijau, dan biru untuk menghindari tampilan citra yang terlalu gelap akibat dominasi nilai reflektansi rendah, seperti dari vegetasi lebat atau area berawan. Dengan penyesuaian ini, fitur-fitur permukaan seperti badan air, vegetasi, dan area terbuka menjadi lebih jelas dan dapat dibedakan secara visual.

Gambar 9 Hasil visualisasi menunjukkan peningkatan kontras dan kejelasan fitur spasial dibandingkan dengan visualisasi awal tanpa skala kecerahan yang disesuaikan. Area yang sebelumnya tampak gelap kini memiliki gradasi warna yang lebih baik, memungkinkan pengamat untuk mengidentifikasi struktur lanskap seperti pola lahan pertanian, jaringan sungai, dan kemungkinan area yang terdampak kebakaran hutan. Tahapan ini penting dalam penelitian berbasis pengolahan citra satelit karena memungkinkan interpretasi visual yang lebih akurat sebelum dilakukan ekstraksi fitur atau segmentasi otomatis menggunakan teknik pembelajaran mesin atau deep learning.

Meskipun hasil pada Gambar 9 sudah lebih baik daripada Gambar 8, tetapi keseluruhan gambar masih didominasi warna gelap yang mempengaruhi kualitas deteksi titik api. Pada tahap selanjutnya proses ini akan ditingkatkan lagi dengan melakukan langkah-langkah berikut.



Gambar 9. Hasil Komposit RGB Riau 2019 yang telah ditingkatkan

1. Koreksi Radiometrik untuk menghilangkan efek atmosfer dan pencahayaan yang tidak merata.
2. Stretching Histogram (e.g., Linear atau CLAHE) untuk meningkatkan kontras lokal. Hasil langkah ini dapat dilihat pada Gambar 10.
3. Konversi ke Indeks Spektral seperti NBR (Normalized Burn Ratio) atau NDVI untuk mempertegas area vegetasi dan area yang terbakar.
4. Filtering spasial (seperti median filter atau edge enhancement) untuk mempertegas kontur dan objek.

Tahapan-tahapan ini diharapkan dapat menghasilkan citra yang memiliki kualitas visual dan fitur yang cukup representatif untuk digunakan sebagai input dalam pelatihan model deep learning, khususnya model segmentasi seperti U-Net, untuk mendeteksi dan mengklasifikasikan area kebakaran hutan di wilayah Riau.



Gambar 10. Hasil Stretching Histogram Riau 2019

Pada tahap berikutnya, setelah langkah-langkah di atas dilakukan, maka analisis selanjutnya dapat mencakup segmentasi area terbakar, pelabelan data pelatihan untuk model deep learning (misalnya UNet), serta validasi spasial dengan data titik panas (hotspot) dari MODIS atau VIIRS.

Untuk menyelesaikan penelitian ini sejumlah langkah strategis telah dirancang. Algorithma pra-pemrosesan akan diperbaiki untuk mendapat data yang lebih bersih sebelum menjadi input untuk deep learning. Selanjutnya pengembangan model Convolution Neural Network untuk deteksi panas akan dikembangkan pada tahap selanjutnya. Validasi akan dilakukan dengan proses benchmark / perbandingan dengan hasil penelitian yang telah dikerjakan oleh peneliti lain. Dan penulisan laporan akhir serta jurnal artikel untuk publikasi ilmiah akan diselesaikan sampai dengan Desember 2025.

Dengan strategi ini, diharapkan seluruh komponen penelitian dapat diselesaikan tepat waktu dan menghasilkan luaran berupa sistem deteksi distribusi anomali panas berbasis deep learning yang efektif dan aplikatif untuk pemantauan lingkungan.

STATUS LUARAN

Uraikan jenis, identitas, dan status ketercapaian setiap luaran yang dijanjikan. Jenis luaran berupa publikasi, perolehan kekayaan intelektual, atau luaran lainnya yang telah dijanjikan pada proposal.

Hasil belum didapatkan, maish dalam pengerjaan. Luaran yang diharapkan adalah pengiriman jurnal artikel ke International Journal of Remote Sensing and Earth Sciences (IJReSES)

DAFTAR PUSTAKA

Situs disusun dan ditulis berdasarkan sistem nomor sesuai dengan urutan pengutipan, mengikuti format Vancouver. Sumber pustaka mengutamakan hasil penelitian pada jurnal ilmiah yang terkini (maksimal 5 tahun terakhir). Hanya pustaka yang disitasi pada usulan penelitian yang dicantumkan dalam Daftar Pustaka.

- [1] K. H. Yong, Y. N. Teo, M. Azadbakht, H. Phung, and C. Chu, “The Scorching Truth: Investigating the Impact of Heatwaves on Selangor’s Elderly Hospitalisations,” Int J Environ Res Public Health, vol. 20, no. 10, May 2023, doi: 10.3390/ijerph20105910.
- [2] T. Mittal and B. Delbridge, “Detection of the 2012 Havre submarine eruption plume using Argo floats and its implications for ocean dynamics,” Earth Planet Sci Lett, vol. 511, pp. 105–116, Apr. 2019, doi: 10.1016/j.epsl.2019.01.035.
- [3] L. Giglio, W. Schroeder, and C. O. Justice, “The collection 6 MODIS active fire detection algorithm and fire products,” Remote Sens Environ, vol. 178, pp. 31–41, Jun. 2016, doi: 10.1016/j.rse.2016.02.054.
- [4] I. Csiszar et al., “Active fires from the suomi NPP visible infrared imaging radiometer suite: Product status and first evaluation results,” J Geophys Res, vol. 119, no. 2, pp. 803–816, Jan. 2014, doi: 10.1002/2013JD020453.
- [5] X. Zhang, L. Liu, X. Chen, S. Xie, and Y. Gao, “Fine land-cover mapping in China using Landsat datacube and an operational SPECLib-based approach,” Remote Sens (Basel), vol. 11, no. 9, May 2019, doi: 10.3390/rs11091056.

- [6] Z. Lin et al., “An active fire detection algorithm based on multi-temporal FengYun-3C VIRR data,” *Remote Sens Environ*, vol. 211, pp. 376–387, Jun. 2018, doi: 10.1016/j.rse.2018.04.027.
- [7] A. I. R. Cabral, S. Silva, P. C. Silva, L. Vanneschi, and M. J. Vasconcelos, “Burned area estimations derived from Landsat ETM+ and OLI data: Comparing Genetic Programming with Maximum Likelihood and Classification and Regression Trees,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 142, pp. 94–105, 2018, doi: <https://doi.org/10.1016/j.isprsjprs.2018.05.007>.
- [8] T. J. Hawbaker et al., “Mapping burned areas using dense time-series of Landsat data,” *Remote Sens Environ*, vol. 198, pp. 504–522, 2017, doi: <https://doi.org/10.1016/j.rse.2017.06.027>.
- [9] E. Roteta, A. Bastarrika, M. Padilla, T. Storm, and E. Chuvieco, “Development of a Sentinel-2 burned area algorithm: Generation of a small fire database for sub-Saharan Africa,” *Remote Sens Environ*, vol. 222, pp. 1–17, Mar. 2019, doi: 10.1016/j.rse.2018.12.011.
- [10] F. Marchese, N. Genzano, M. Neri, A. Falconieri, G. Mazzeo, and N. Pergola, “A multi-channel algorithm for mapping volcanic thermal anomalies by means of sentinel-2 MSI and Landsat-8 OLI data,” *Remote Sens (Basel)*, vol. 11, no. 23, Dec. 2019, doi: 10.3390/rs11232876.
- [11] N. Genzano, N. Pergola, and F. Marchese, “A google earth engine tool to investigate, map and monitor volcanic thermal anomalies at global scale by means of mid-high spatial resolution satellite data,” *Remote Sens (Basel)*, vol. 12, no. 19, pp. 1–22, Oct. 2020, doi: 10.3390/rs12193232.
- [12] G. Camps-Valls, D. Tuia, L. Bruzzone, and J. A. Benediktsson, “Advances in hyperspectral image classification: Earth monitoring with statistical learning methods,” *IEEE Signal Process Mag*, vol. 31, no. 1, pp. 45–54, 2014, doi: 10.1109/MSP.2013.2279179.
- [13] Y. Oulad Sayad, H. Mousannif, and H. Al Moatassime, “Predictive Modeling of Wildfires: A New Dataset and Machine Learning Approach Predictive Modeling of Wildfires: A New Dataset Approach,” 2019. [Online]. Available: <https://www.elsevier.com/open-access/userlicense/1.0/>
- [14] W. Hu, Y. Huang, L. Wei, F. Zhang, and H. Li, “Deep convolutional neural networks for hyperspectral image classification,” *J Sens*, vol. 2015, 2015, doi: 10.1155/2015/258619.
- [15] H. Liu, K. Wu, H. Xu, and Y. Xu, “Lithology classification using TASI thermal infrared hyperspectral data with convolutional neural networks,” *Remote Sens (Basel)*, vol. 13, no. 16, Aug. 2021, doi: 10.3390/rs13163117.
- [16] Q. X. Zhang, G. H. Lin, Y. M. Zhang, G. Xu, and J. J. Wang, “Wildland Forest Fire Smoke Detection Based on Faster R-CNN using Synthetic Smoke Images,” in *Procedia Engineering*, Elsevier Ltd, 2018, pp. 441–446. doi: 10.1016/j.proeng.2017.12.034.
- [17] P. Barmpoutis, K. Dimitropoulos, K. Kaza, and N. Grammalidis, “Fire detection from images using Faster R CNN and multidimensional texture analysis,” in *2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019, pp. 8301–8305.

- [18] H. Lyu, H. Lu, and L. Mou, “Learning a transferable change rule from a recurrent neural network for land cover change detection,” *Remote Sens (Basel)*, vol. 8, no. 6, 2016, doi: 10.3390/rs8060506.