

MAPBIOMAS
INDONESIA | FIRE

Algorithm Theoretical Basis Document (ATBD)

MapBiomass Fire

Koleksi 1.0

Versi 1

Agustus 2024

Daftar Isi

Daftar Isi.....	1
1.Pendahuluan.....	2
1.1. Sekilas tentang MapBiomass Fire.....	2
1.2. Bagaimana MapBiomass Fire Terorganisir?.....	2
1.3. Perspektif historis: Eksistensi Peta dan Inisiatif Pemetaan.....	3
2. Metodologi.....	3
2.1 Definisi dari Region.....	5
2.2 Mosaic Tahunan.....	5
2.3 Training Sample.....	7
2.4 Klasifikasi.....	7
2.5 Post-classification.....	8
2.6 Evaluasi Hasil Klasifikasi.....	9
3. Produk MapBiomass Fire.....	9
3.1 Kebakaran Tahunan/Annual Burned Area.....	9
3.2 Kebakaran Bulanan/Monthly Burned Area.....	9
3.3 Kebakaran secara Kumulatif.....	9
3.4 Jumlah Kebakaran Berulang/Fire Frequency data.....	10
3.5 Tahun Terjadinya Kebakaran Terakhir/Year of Last Fire Occurrence.....	10
Daftar Pustaka.....	11

1. Pendahuluan

1.1. Sekilas tentang MapBiomass Fire

Tujuan dari dokumen ini adalah sebagai gambaran terhadap kerangka dari teori, dasar pemikiran, dan metodologi yang digunakan dalam menghasilkan peta kebakaran di Indonesia pada rentang tahun 2013 hingga 2023 di Koleksi 1.0.

Mapbiomas Fire project merilis koleksi peta tahunan pertamanya dengan memetakan areal bekas terbakar sepanjang 2013 hingga 2023. Koleksi ini menggunakan metode yang lebih efektif dibandingkan dengan teknik semi-automatic yang umum digunakan dalam pemetaan kebakaran di Indonesia. Memanfaatkan citra satelit Landsat, dengan resolusi spasial 30 meter, proses pemetaan kemudian disempurnakan sehingga pemetaan terhadap lanskap Indonesia dapat dilakukan secara komprehensif.

Upaya kolaborasi antar institusi jejaring MapBiomass berperan penting dalam penyempurnaan algoritma machine learning, khususnya algoritma deep learning, dan diterapkan pada platform seperti Google Earth Engine (GEE) dan Google Cloud Storage. Platform ini menawarkan kapasitas pemrosesan yang besar memanfaatkan ekosistem cloud, memfasilitasi pengolahan data berukuran besar secara efisien.

Proses klasifikasi kebakaran telah diatur secara sistematis berdasarkan region, merujuk pada kepulauan besar di Indonesia, untuk mengakomodir perbedaan tipe kebakaran pada tiap region. Sampel kebakaran dan non-kebakaran yang dikumpulkan kemudian digunakan untuk melatih algoritma, digabungkan dengan referensi peta lain seperti Area Kebakaran MODIS (MCD64A1) dengan resolusi spasial 500 meter

Produk MapBiomass Fire Indonesia pada Koleksi 1.0 berupa:

- Peta kebakaran bulanan dan tahunan di Indonesia pada 2013 hingga 2023;
- Frekuensi area terbakar di Indonesia;
- Akumulasi dari kebakaran sepanjang 2013 hingga 2023;
- Areal kebakaran pada kelas tata guna lahan (Land Use Land Cover) MapBiomass Collection 2

1.2. Bagaimana MapBiomass Fire Terorganisir?

MapBiomass adalah inisiatif multi-institusional dari Climate Observatory (jejaring NGO pada isu perubahan iklim di Brazil - <http://www.observatoriodoclima.eco.br/en/>). MapBiomass terbentuk dari keterlibatan NGO, universitas/akademisi, dan perusahaan teknologi. Untuk MapBiomass Fire, IPAM melakukan pengembangan terhadap teknologi dan operasional yang kemudian diadaptasi oleh Tim Mapbiomas Fire Indonesia. Kami melakukan pengambilan sampel, evaluasi, dan penyempurnaan pemetaan sebagai Tim MapBiomass Indonesia. Jejaring MapBiomass Indonesia tersebar di seluruh region terdiri dari HAKA (Hutan Alam dan

Lingkungan Aceh), HaKI (Hutan Kita Institute), dan Genesis Bengkulu di Sumatera; Sampan Kalimantan, Green of Borneo, dan Save Our Borneo di Kalimantan; Auriga Nusantara dan Woods & Wayside International di Jawa, Bali dan Nusa, serta Maluku; Komiu di Sulawesi, Jerat Papua dan Mnuqwar di Papua. Perusahaan teknologi geospasial *Ecostage* bertanggung jawab atas back-end, dashboard, website, dan pengembangan front-end MapBiomias.

1.3. Perspektif Historis: Eksistensi Peta dan Inisiatif Pemetaan

Hanya terdapat beberapa produk global yang memetakan kebakaran pada skala yang luas dengan resolusi temporal tinggi (contoh: dua hari sekali), seperti produk berbasis MODIS (Moderate Resolution Imaging Spectroradiometer), MCD64A1 Koleksi 6, dengan resolusi piksel 500 m, disediakan oleh *National Aeronautics and Space Administration* (NASA). Kami menggunakan produk ini sebagai referensi data area terbakar (Giglio dkk., 2016). Kami juga menggunakan data Global Annual Burned Area Map (GABAM) dengan resolusi 30 m yang didefinisikan sebagai luas spasial kebakaran yang terjadi dalam satu tahun penuh dengan menggunakan pendekatan pemetaan area terbakar otomatis secara global berdasarkan semua gambar Landsat yang tersedia pada platform GEE (Long, 2019). Referensi lain yang menjadi rujukan utama kami adalah areal terbakar yang dikeluarkan oleh Kementerian Lingkungan Hidup dan Kehutanan (KLHK) pada rentang data 2015 hingga 2022. Data tersebut dibuat menggunakan citra landsat dengan pendekatan semi-otomatis.

Data pemetaan areal terbakar yang telah ada ini menjadi referensi penting untuk mendukung keakuratan data Kebakaran yang dihasilkan oleh MapBiomias Fire, sehingga berkontribusi pada pemahaman komprehensif tentang dinamika kawasan terbakar di Indonesia.

2. Metodologi

Kami menggunakan seluruh Koleksi Landsat 8 yang tersedia dan Deep Neural Network (DNN) model untuk mendeteksi dan memetakan kebakaran secara regional antara Januari 2013 hingga Desember 2023. DNN model menggunakan kecerdasan buatan dan algoritma machine learning untuk melakukan klasifikasi deep learning terhadap fenomena yang kompleks sehingga menghasilkan hasil yang lebih baik, termasuk untuk pemetaan kebakaran (Langford, 2018).

Citra Landsat 8 diproses pada GEE hingga dihasilkan mosaic Landsat tahunan, yang digunakan untuk mengumpulkan nilai spektral dari kebakaran dan non-kebakaran, untuk dijadikan training sample guna melatih model klasifikasi. Training sample dan mosaic tahunan kemudian diekspor ke penyimpanan berbasis google, yaitu *google drive*, kemudian training sampel tersebut diproses menggunakan DNN model pada *local server*. Hasil dari pemrosesan ini berupa peta area terbakar pada 2013 hingga 2023.

Pemrosesan *image* dan prosedur klasifikasi wilayah terbakar di Indonesia mengikuti enam langkah, berupa:

(1) Mendefinisikan region: Indonesia dibagi menjadi 7 region untuk pemrosesan guna meningkatkan keakuratan klasifikasi.

(2) Konstruksi citra Landsat tahunan: Mosaik tahunan berkualitas tinggi dihasilkan dari citra Landsat sebagai dataset yang digunakan dalam klasifikasi.

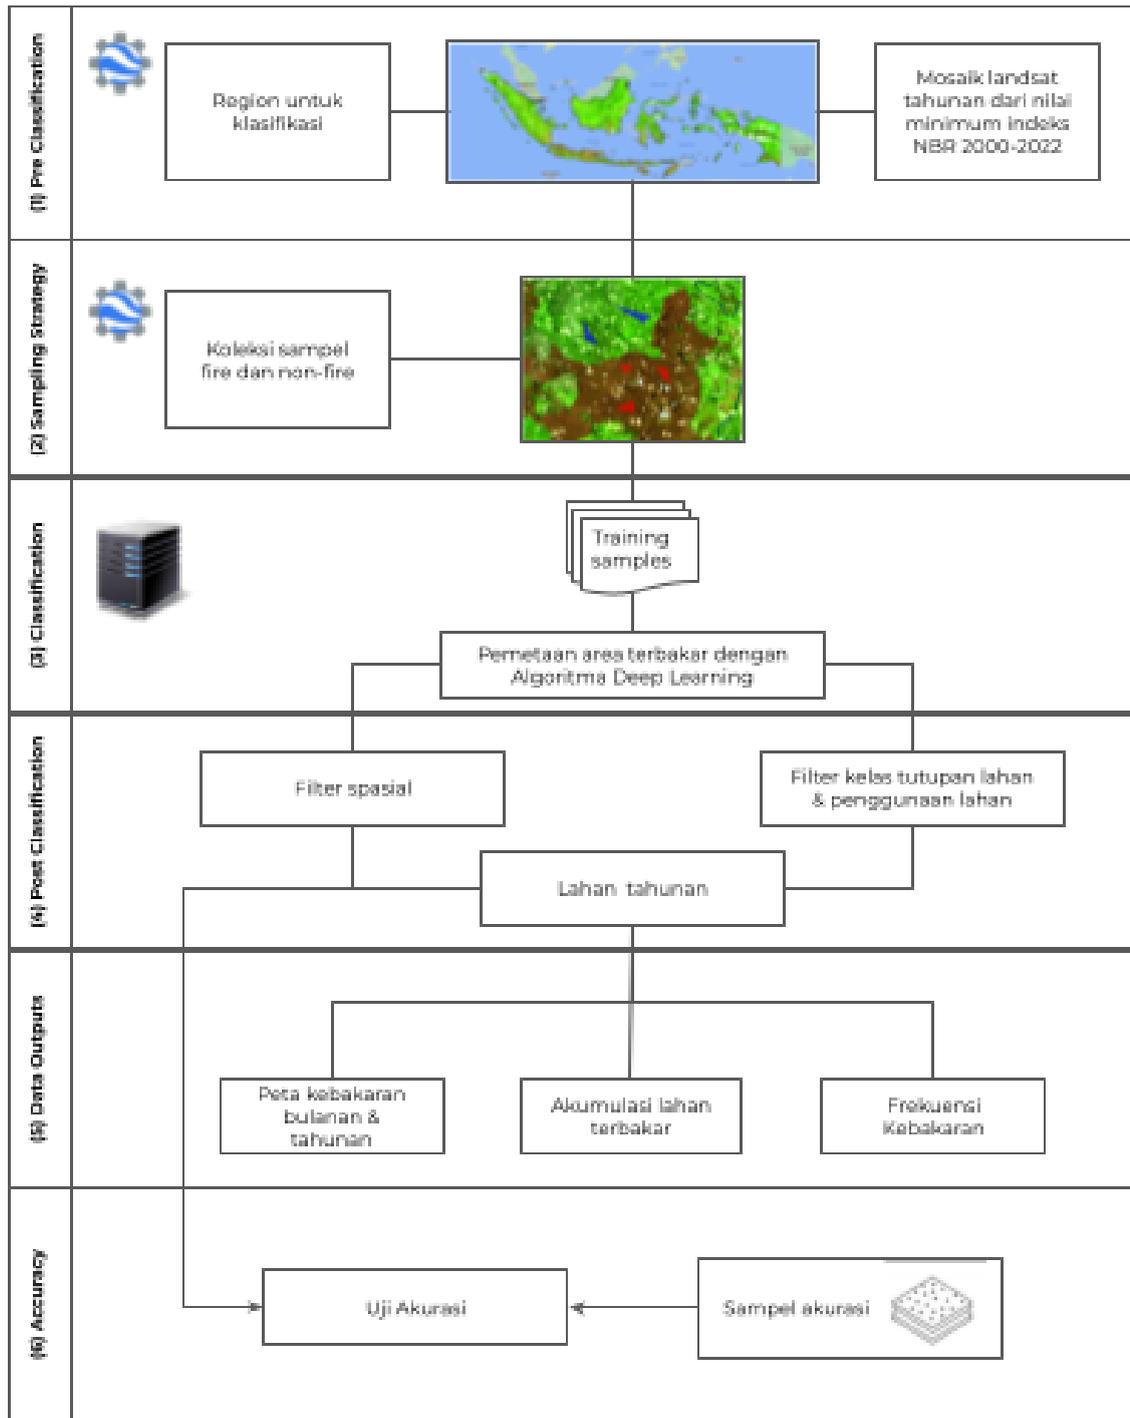
(3) Koleksi training sample: pengumpulan nilai spektral kebakaran dan non-kebakaran dikumpulkan dari mosaic citra Landsat tahunan sebagai *training sample*.

(4) Melatih dan mengembangkan klasifikasi kebakaran pada DNN prediction model: DNN model dilatih menggunakan sampel yang telah dikumpulkan dan citra tahunan local server.

(5) Post-klasifikasi: pada hasil klasifikasi area terbakar dilakukan masking dan menerapkan spasial filter untuk meningkatkan akurasi dan mengurangi kesalahan pada hasil klasifikasi.

(6) Evaluasi dan validasi hasil klasifikasi kebakaran dengan pengamatan visual. Hasil dari klasifikasi divalidasi dengan menggunakan data referensi, validasi ini digunakan menggunakan pengecekan visual terhadap peta areal terbakar untuk memastikan akurasi data yang ada.

Pendekatan kami menggabungkan kemampuan *deep learning* dengan data satelit yang komprehensif, sehingga memungkinkan terciptanya peta area terbakar di Indonesia yang terperinci dan andal, seperti yang diilustrasikan pada Gambar 1.



Gambar 1. Bagan alur metode klasifikasi kebakaran MapBiomass Fire Indonesia Koleksi 1.0

2.1 Definisi dari Region

Mengingat adanya perbedaan karakteristik serta nilai spektral kebakaran karena perbedaan kondisi klimatis serta jenis penutupan dan penggunaan lahan, kami mengkombinasikan data faktor edafik dan morphoclimatic dengan peta tahunan MapBiomass Land Use & Land Cover koleksi 2.0 (Gambar 2). Selain itu, kami mempertimbangkan

pembagian wilayah berdasarkan pulau-pulau besar di Indonesia. Proses ini menghasilkan 7 klasifikasi wilayah, mengatasi pola regional dan memberikan klasifikasi wilayah terbakar yang lebih akurat.



Gambar 2. Indonesia dibagi ke dalam 7 region yaitu Sumatera, Kalimantan, Jawa, Bali-Nusa, Sulawesi, Maluku dan Papua dalam pengumpulan training sampel dan klasifikasi areal kebakaran pada MapBiomas Indonesia Fire Koleksi 1.0.

2.2 Mosaic Tahunan

Klasifikasi dilakukan dengan menggunakan mosaic Landsat Koleksi 2 (Tier 1) Surface reflectance oleh USGS dengan resolusi spasial 30m x 30m. Mosaic dibuat setiap tahun dari 2013 hingga 2023. Kami memiliki seluruh citra Landsat 8 yang tersedia (2013 hingga 2023) dengan resolusi temporal 16 hari.

Landsat Surface Reflectance disertai oleh 2 penilaian kualitas Bitwise (*Bitwise Quality Assessment*) Band (QA_PIXEL dan QA_RADSAT) yang akan menunjukkan piksel dengan radiometri dan instrumen bermasalah, termasuk kemungkinan penandaan pada band dan piksel. Kami menggunakan band QA_PIXEL untuk memilih dan memilah piksel berupa “cloud” dan “shadow” dengan tingkat kepercayaan tinggi (67-100%). Kemudian kami menggunakan QA_RADSAT untuk menghindari piksel dengan saturasi radiometrik pada seluruh *Surface Reflectance band*. Terakhir, kami membuang piksel dengan nilai negatif pada surface reflectance untuk menghilangkan anomali dan *noise* pada mosaic tahunan.

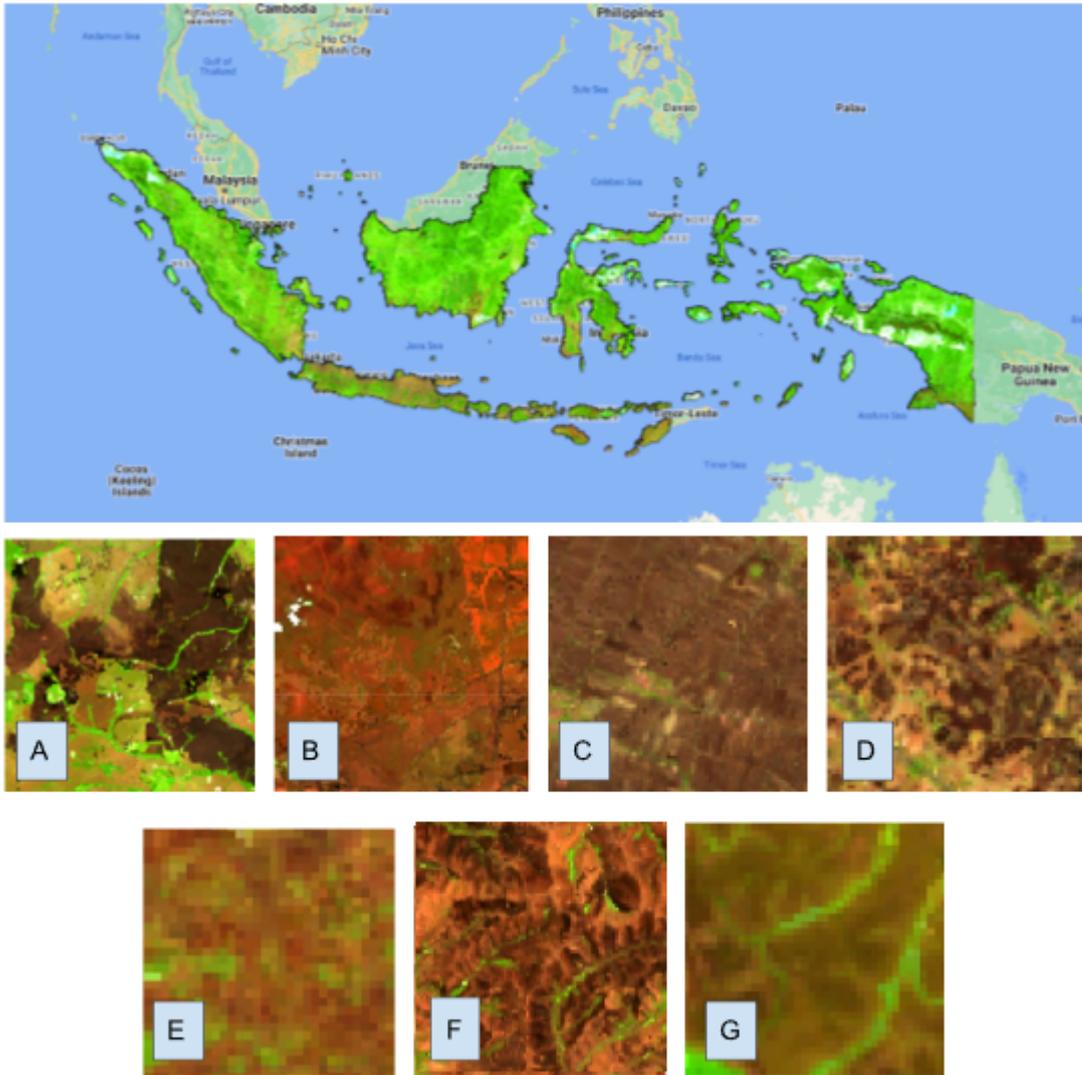
Kami menggunakan pendekatan statistik secara tahunan untuk merangkum seluruh data dan mengoptimalkan proses klasifikasi tanpa membuang informasi spektral yang dimiliki oleh data piksel. Pendekatan ini memungkinkan kami membuat mosaic tahunan dengan menggabungkan seluruh citra beresolusi temporal 16 hari menjadi satu *quality mosaic* (QM), menggunakan fungsi pengurutan piksel, minimum NBR (Normalized Burn Ratio) *spectral index* (rumus — Key and Benson, 2006), piksel dengan nilai NBR paling rendah akan terpilih beserta seluruh karakteristik reflektansi spektralnya, termasuk metadata tiap scene berupa tanggal piksel, digunakan untuk membuat mosaic tahunan.

$$\lambda_{QM} = [Blue, Green, Red, NIR, SWIR1, SWIR2] = \text{date in with } \min \left(\frac{\lambda_{NIR} - \lambda_{SWIR1}}{\lambda_{NIR} + \lambda_{SWIR1}} \right) [xi... j]$$

Dimana λ melambangkan nilai reflektansi dari kualitas band yang membentuk *quality mosaic* (QM), dimana tanggal dari tiap piksel dengan nilai minimum NBR pada tahun tertentu (x) diambil, mempertimbangkan kumplan dari seluruh citra yang tersedia, sejak awal (i) hingga akhir (j); λ_{NIR} (Near-Infrared surface reflectance) dan λ_{SWIR1} (Short-Wave Infrared surface reflectance) digunakan untuk menghitung NBR spectral indeks. Dengan kata lain, kami menghitung nilai NBR untuk mengamati tiap piksel pada tahun tertentu dan menumpuknya menjadi citra multi-band. Piksel dengan nilai NBR paling rendah pada citra multi-band akan dipilih beserta informasi spektralnya (tabel 1) untuk menyusun *quality mosaic* (QM) tahunan. Selain informasi spektral, kami menyimpan informasi metadata gambar termasuk tanggal di tiap piksel yang ditampilkan, piksel dengan nilai NBR terendah. Mosaic dibuat dengan informasi minimum NBR, menunjukkan kinerja yang baik dalam membedakan kebakaran dan non-kebakaran pada penutupan dan penggunaan lahan di Indonesia (gambar 3).

Tabel 1. Band yang digunakan pada Mosaic untuk memprediksi dan mengklasifikasi area kebakaran.

Spectral band	Landsat 8	
	Band number	Band width (μm)
Red	4	0.64 - 0.67
NIR	5	0.85 - 0.88
SWIR ₁	6	1.57 - 1.65
SWIR ₂	7	2.11 - 2.29



Gambar 3. Annual mosaic 2023 Indonesia (RGB SWIR-1, NIR, RED), konstruksi berdasarkan informasi spektral yang diambil dari piksel dengan minimum NBR dalam setahun, contoh keberagaman bekas terbakar di tiap region: a) Sumatera, b) Kalimantan, c) Jawa, d) Sulawesi, e) Maluku, g) Bali-Nusa, dan h) Papua.

2.3 Training Sample

Kami membuat *spectral library* berdasarkan deliniasi manual pada areal kebakaran dan non-kebakaran untuk digunakan sebagai training sample. Sampel kebakaran dan non-kebakaran distratifikasi menggunakan mosaic Landsat di setiap region. Sampel yang dikumpulkan pada koleksi 1 ini berasal dari annual mosaic pada 2015 dan 2019 di 7 region. Sample ini kemudian digunakan sebagai input pada tahap klasifikasi.

Mengingat karakteristik kebakaran yang beragam, maka pengambilan sampel diprioritaskan pada tipe penutupan lahan: gambut, hutan, agrikultur, areal persawahan, areal savana, dan pegunungan. Sedangkan sampel non-kebakaran diambil pada areal dengan kenampakan menyerupai kebakaran seperti: pemukiman, areal pertambangan, lahan

terbuka, dan penutupan lahan lainnya. Sampel yang telah dikumpulkan kemudian digunakan sebagai input dalam proses klasifikasi.

2.4 Klasifikasi

Model klasifikasi yang digunakan adalah *Deep Neural Network* (DNN), yang terdiri dari komputasi berdasarkan model perhitungan matematis yang mampu melakukan deep learning dan pengenalan pola visual. Struktur yang kami gunakan adalah *Multi-Layer Perceptron Network* (MLPN) yang menggabungkan beberapa lapisan unit komputasi yang saling berhubungan, dalam setiap mode (neuron) pada suatu lapisan terhubung ke node di lapisan berikutnya (Hu, Wenk, 2009). Lapisan tersebut dibagi menjadi: input, hidden, dan output.

Input yang digunakan untuk model DNN adalah band spektral RED, SWIR1, dan SWIR2, dan output yang dihasilkan adalah kelas kebakaran dan non-kebakaran. Pemetaan kebakaran ini menggunakan algoritma yang terdiri dari dua langkah yaitu pelatihan (*training phase*) dan prediksi (*prediction phase*).

○ Training Phase:

Dalam tahap training, parameter berikut ditentukan, berdasarkan pengujian sebelumnya: *learning rate* (0,001), ukuran *batch* (1000), jumlah interaksi (7000), dan input untuk klasifikasi (Arruda dkk. 2021). Input pada proses klasifikasi yang digunakan dalam model ini adalah data spektral SR yang diambil dari mosaik kualitas tahunan menggunakan training sampel areal kebakaran dan non-kebakaran.

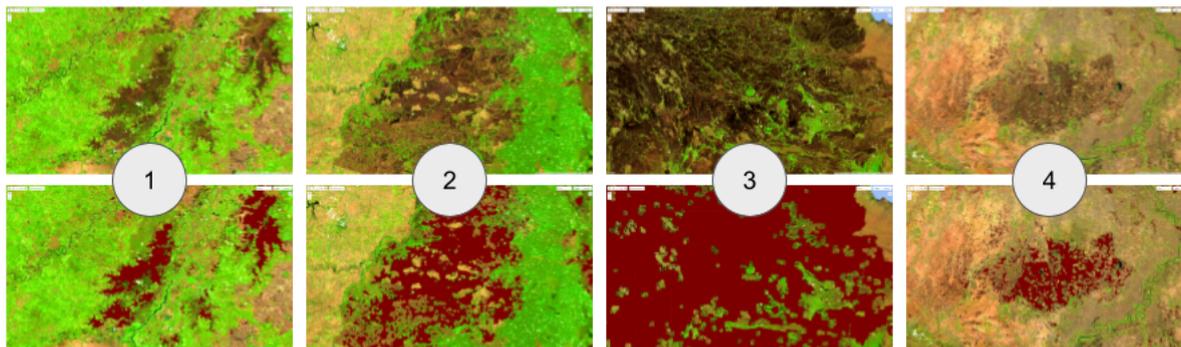
Berdasarkan *spectral library* dari *training sample* yang kebakaran dan non-kebakaran, band spektral berikut digunakan sebagai input untuk model klasifikasi area terbakar: red (RED—0.65 μm), near infrared (NIR—0.86 μm), dan short-wave infrared (SWIR 1—1.6 μm and SWIR 2—2.2 μm). Band spektrum Landsat ini dipilih berdasarkan sensitivitasnya terhadap kejadian kebakaran di antara penggunaan dan tutupan lahan yang berbeda.

Input data pelatihan dibagi menjadi dua dataset: 70% sampel digunakan untuk pelatihan dan 30% untuk pengujian, guna memperkirakan kemampuan algoritma DNN dalam memetakan area terbakar.

○ Prediction Phase:

Klasifikasi ini dilakukan dengan menggunakan mosaik Landsat tahunan masing-masing region, sehingga menghasilkan data kebakaran selama 11 tahun di Indonesia (Gambar 4). Pendekatan ini memungkinkan kami memanfaatkan kemampuan DNN yang canggih untuk memetakan area terbakar di berbagai wilayah di Indonesia secara akurat dan efisien.

Filter spasial diterapkan untuk menghilangkan *noise* dan mengisi celah/*gap* yang kosong, dimana areal terbakar yang lebih kecil dari atau sama dengan 1,4 ha (16 piksel) dihilangkan, dan celah kosong (di dalam area yang terbakar) lebih kecil dari atau sama dengan 5,8 ha (64 piksel) diklasifikasikan sebagai kebakaran (Padilla dkk. 2015). Metode ini memastikan penghapusan piksel *noise* yang terisolasi dan mengisi celah kecil, sehingga meningkatkan akurasi dan koherensi peta area terbakar secara keseluruhan.



Gambar 4. Contoh hasil klasifikasi area kebakaran di tiap region, dengan menggunakan mosaik tahunan Landsat 8, areal terbakar ditandai dengan warna merah. 1. Kebakaran di hutan ; 2. Kebakaran di tanah mineral ; 3. Kebakaran di sekitar gunung berapi ; 4. Sawah.

Karena metode *deep learning* memerlukan pemrosesan komputasi yang mumpuni, kami melakukan analisis menggunakan unit pemrosesan grafis (GPU) dan komponen perangkat keras khusus untuk menjalankan operasi aritmatika paralel. Infrastruktur komputasi yang digunakan berupa Personal Computer dengan spesifikasi perangkat: Processor Ryzen 9 750X, graphic card Nvidia RTX 4080, RAM 128 GB, SSD 1 Tb, HDD 16 Tb. Akses ke GPU di environment mesin virtual diimplementasikan pada lokas server tersebut.

2.5 Post-classification

Setelah mengevaluasi hasil klasifikasi, proses masking pada *post-classification* juga diterapkan untuk mengurangi *commission error* dari penggunaan lahan dengan ciri spektral yang serupa dengan area yang baru saja terbakar, seperti daerah budidaya perairan, dan areal pertambangan. Kami menetapkan aturan untuk menghilangkan piksel atau masking yang diklasifikasikan sebagai kebakaran di kelas tutupan lahan dan penggunaan lahan dari MapBiomas Koleksi 2 sesuai dengan rentang tahun kebakaran. Namun, mengingat rentang tahun Mapbiomas Koleksi 2 adalah 2000 hingga 2022, maka proses *post-classification* kebakaran pada 2023 menggunakan data MapBiomas Koleksi 2 tahun 2022. Kelas yang kami gunakan dalam proses masking adalah: Aquaculture, Mining, dan Permanent Water.

Selain itu, untuk menghilangkan kekeliruan klasifikasi kebakaran yang merupakan air, kami menggunakan dataset Global Surface Water, milik European Commission JRC pada kelas permanent water bodies. Penggunaan kelas ini digunakan untuk mengurangi bias masking akibat adanya badan air yang dipengaruhi oleh cuaca pada MapBiomas Koleksi 2.

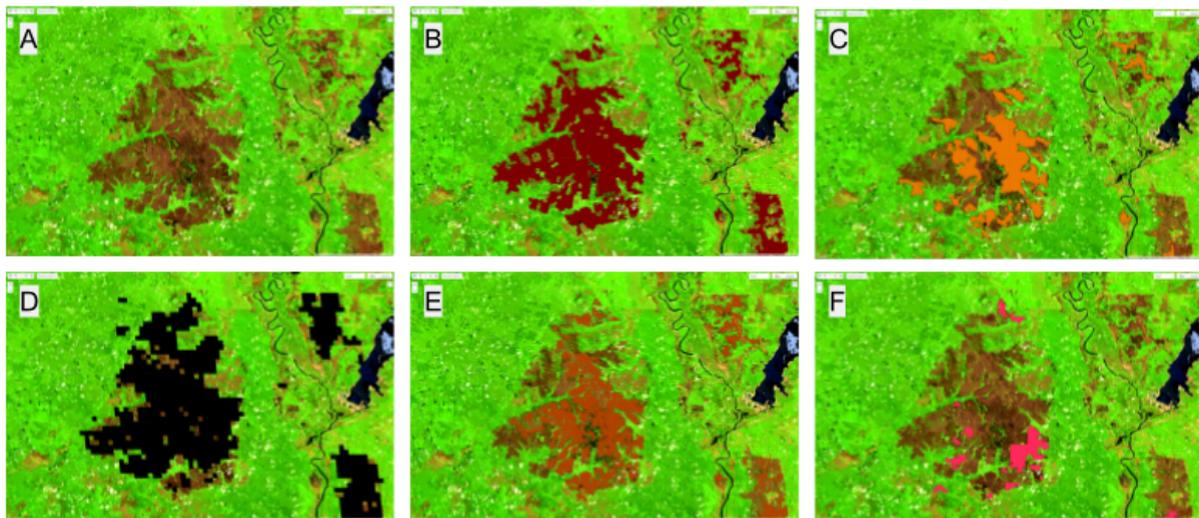
Untuk memperoleh informasi tentang bulan kebakaran terjadi, maka *post-classification* dilakukan untuk mengambil informasi tanggal piksel terbakar, tanggal piksel didapatkan dari citra tahunan yang dibangun dari nilai NBR minimum.

2.6 Evaluasi Hasil Klasifikasi

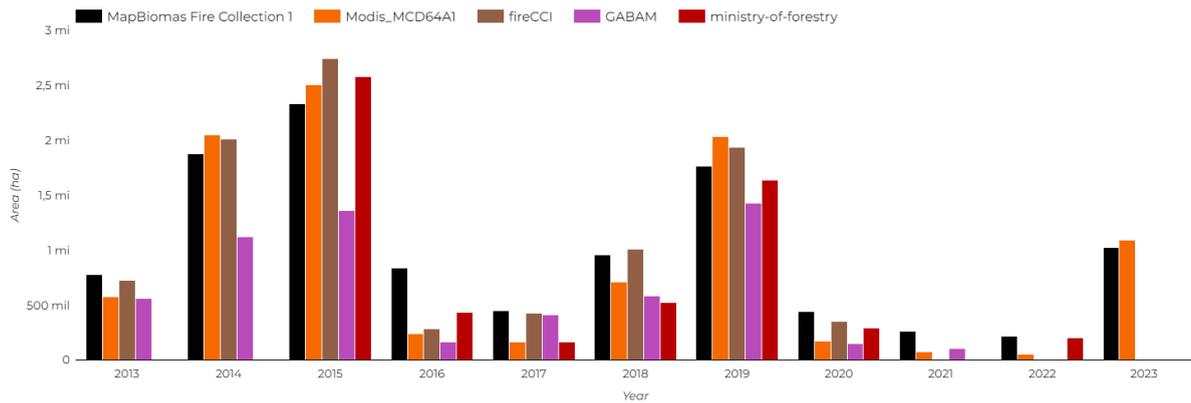
Evaluasi klasifikasi area terbakar dilakukan dengan menggunakan mosaik Landsat melalui inspeksi visual dan analisis statistik. Inspeksi visual dilakukan oleh para ahli dari

masing-masing region, yang secara menyeluruh memeriksa bekas luka bakar yang diklasifikasikan dengan mosaik Landsat untuk memastikan keakuratannya. Perbedaan yang diidentifikasi selama inspeksi ini dicatat dan digunakan untuk menyempurnakan sampel untuk algoritma. Analisis statistik dilakukan untuk memvalidasi hasil klasifikasi dengan membandingkannya dengan produk area yang terbakar.

Evaluasi klasifikasi area terbakar dilakukan dengan menggunakan mosaik Landsat melalui inspeksi visual dan analisis statistik. Inspeksi visual dilakukan oleh para ahli dari masing-masing wilayah, yang secara menyeluruh memeriksa area terbakar yang diklasifikasi dengan mosaik Landsat asli untuk memastikan keakuratannya. Perbedaan yang diidentifikasi selama inspeksi ini dicatat dan digunakan untuk menyempurnakan sampel untuk algoritma. Selain itu, areal terbakar yang dipetakan dibandingkan dengan peta referensi lainnya (Area Terbakar Kementerian Lingkungan Hidup dan Kehutanan, MODIS, GABAM, FIRMS, FireCCI, titik api) (Gambar 5). Proses evaluasi yang komprehensif ini memastikan kualitas dan keakuratan klasifikasi area terbakar yang tinggi, dengan mengintegrasikan penilaian otomatis dan berbasis ahli untuk menghasilkan hasil yang dapat diandalkan (Gambar 5 dan Gambar 6).



Gambar 5. Dari kiri atas ke kanan dan resolusinya, A) Citra Landsat 8 (30 m), B) hasil klasifikasi MapBiomas Fire Koleksi 1 (30 m), C) Kebakaran oleh KLHK, D) MODIS (MCD64A1) (500 m), E) GABAM (30 m), dan F) FireCCI (250 m).



Gambar 6. Luas lahan terbakar berdasarkan koleksi data: MapBiomass Fire Koleksi 1 (30 m), GABAM (30 m), data kebakaran KLHK, MODIS (MCD64A1) (500 m), GABAM (30 m), dan FireCCI (250 m).

3. Produk MapBiomass Fire

3.1 Kebakaran Tahunan/Annual Burned Area

Data area terbakar tahunan dari tahun 2013 hingga 2023, menunjukkan areal yang dipetakan sebagai areal terbakar untuk masing-masing tahun. Hal ini juga mencakup Kebakaran Tahunan, yang mewakili luas area kebakaran tahunan setiap kelas penggunaan lahan dan tutupan lahan, dimana setiap piksel berisi nilai penutupan dan penggunaan lahan berdasarkan kode kelas sesuai dengan MapBiomass koleksi 2.

3.2 Kebakaran Bulanan/Monthly Burned Area

Data area terbakar bulanan mencakup periode 2013 hingga 2023, dengan data setiap piksel diambil dari mosaik tahunan berdasarkan tanggal citra satelit. *Monthly Burned Area* Data menunjukkan bulan (1 hingga 12) terjadinya kebakaran untuk setiap piksel.

3.3 Kebakaran secara Kumulatif

Data kumulatif ini merupakan akumulasi area terbakar setiap tahunnya, dengan menghitung luasan areal yang terbakar sebanyak satu kali, dan tidak menghitung pengulangan kebakaran di areal yang sama. Data ini berupa wilayah yang terbakar setidaknya satu kali pada periode tertentu. Luasan areal kebakaran kumulatif juga mewakili kebakaran pada areal penutupan dan penggunaan lahan pada periode tertentu.

3.4 Jumlah Kebakaran Berulang/Fire Frequency data

Peta frekuensi area yang terbakar menunjukkan berapa kali piksel yang sama dipetakan terbakar dalam jangka waktu tertentu. Data frekuensi kebakaran dikumpulkan menjadi satu peta dengan 11 kelas periode 2013 hingga 2023. Kelas 1 mewakili piksel yang terbakar satu kali, kelas 2 mewakili piksel yang terbakar dua kali, dan seterusnya. Data ini juga mencakup penutupan dan penggunaan lahan masing-masing kelas dari MapBiomass Koleksi 2.

Daftar Pustaka

Alencar, Ane A C, Vera L S Arruda, Wallace Vieira, Dhemerson E Conciani, Diego Pereira Costa, Natalia Crusco, Soltan Galano Duverger, et al. 2023. "Long-Term Landsat-Based Monthly Burned Area Dataset for the Brazilian Biomes Using Deep Learning." *Remote Sensing* 14 (2510): 29. <https://doi.org/10.3390/rs14112510>.

Arruda, V. L. S.; Piontekowski, V. J.; Alencar, A.; Pereira, R. S.; Matricardi, E. A. T. An alternative approach for mapping burn scars using Landsat imagery, Google Earth Engine, and Deep Learning in the Brazilian Savanna. *Remote Sensing Applications: Society and Environment*, [s. l.], v. 22, p. 100472, 2021.

Giglio, L., Schroeder, W., Justice, C.O., 2016. The collection 6 MODIS active fire detection algorithm and fire products. *Remote Sens. Environ.* 178, 31–41. <https://doi.org/10.1016/j.rse.2016.02.054>.

Hu, X.; Weng, Q. Remote Sensing of Environment Estimating impervious surfaces from medium spatial resolution imagery using the self-organizing map and multi-layer perceptron neural networks. *Remote Sens. Environ.* 2009, 113, 2089–2102.

Key, C., Benson, N., 2006. Landscape assessment: remote sensing measure of severity: the normalized burn Ratio. In: FIREMON: Fire Effects Monitoring and Inventory System. USDA Forest Service, Rocky Mountain Research Station, General Technical Report, RMRS-GTR-164-CD:LA1-LA51, Fort Collins, CO: U.S.

Langford, Z.; Kumar, J.; Hoffman, F. Wildfire mapping in interior Alaska using deep neural networks on imbalanced datasets. In *Proceedings of the 2018 IEEE International Conference on Data Mining Workshops (ICDMW)*, Singapore, 17–20 November 2018

Long, Tengfei, Zhaoming Zhang, Guojin He, Weili Jiao, Chao Tang, Bingfang Wu, Xiaomei Zhang, Guizhou Wang, and Ranyu Yin. 2019. "30 m Resolution Global Annual Burned Area Mapping Based on Landsat Images and Google Earth Engine" *Remote Sensing* 11, no. 5: 489. <https://doi.org/10.3390/rs11050489>

Padilla, M., Olofsson, P., Stehman, S. V., Tansey, K., Chuvieco, E., & York, R. (2015). "Comparing the accuracies of remote sensing global burned area products using stratified random sampling and estimation." *Remote Sensing of Environment*, 160, 114-121.