

Pemodelan Wilayah Titik Api Kebakaran Hutan Menggunakan Deep Learning

Saruni Dwiasnati*¹, Yudo Devianto², Sutan Mohammad Arif³, Reza Avrizal⁴

^{1,2} Fakultas Ilmu Komputer, Universitas Mercu Buana, Jakarta, Indonesia

^{3,4} Fakultas Teknik dan Ilmu Komputer, Universitas Indraprasta PGRI, Jakarta, Indonesia

¹saruni.dwiasnati@mercubuana.ac.id, ²yudo.devianto@mercubuana.ac.id,

³cutans.muhars@gmail.com, ⁴avrizale.pln@gmail.com

*) Corresponding author

(received: 20-03-24, revised: 23-03-24, accepted: 30-04-24)

Abstract

Indonesia is a tropical country that experiences forest fires every year. Forest fires occur because of the prolonged hot season. Forests are a habitat for many animals and fauna. Forest fires are an environmental problem that occurs very often and is considered important so that it is of local and global concern. This paper presents a study of the classification of forest fire hotspot areas using one of the Deep Learning (DL) algorithms, namely the Convolutional Neural Network (CNN) method. This is very much needed for an introduction to early warning of forest fires in the area. The forest fire hotspot areas used in this research were collected from the East Nusa Tenggara (NTT) area, especially islands such as Sumba and Timor. The CNN method consists of two stages. The first stage is image classification using feedforward. The second stage is the learning stage using the backpropagation method. The CNN model used in the dataset training process tested the images with several optimizers and obtained high accuracy results. The similarity of the burned area to other bright features reduces the certainty of forest fire detection. The research results show that the CNN model used for the detection and segmentation of burned areas using the selected algorithm, the best performance with deep learning reported in the literature is 89%. The proposed technique is trained using variant regions (data sets) and evaluates the precision based on the recall threshold, with overall accuracy 89%.

Keyword: Hotspots, Forest fires, Deep Learning, Convolutional Neural Networks

Abstrak

Indonesia merupakan negara tropis yang mengalami kebakaran hutan setiap tahunnya. Kebakaran hutan terjadi disebabkan oleh durasi musim panas yang terlalu lama dari waktu semestinya. Hutan merupakan tempat tinggal berbagai jenis satwa dan fauna yang memiliki banyak kekayaan hayati yang dapat membuat mereka bertahan hidup. Sering terjadinya kebakaran hutan menjadi isu lingkungan yang dianggap krusial dan mendapatkan perhatian baik dari tingkat lokal maupun internasional. Penelitian yang dilakukan ini menyajikan kajian klasifikasi wilayah titik api kebakaran hutan menggunakan salah satu algoritma Deep Learning (DL) yaitu metode Convolutional Neural Network (CNN), hal ini sangat dibutuhkan untuk pendahuluan mengenai peringatan dini kebakaran hutan yang ada di daerah tersebut. Wilayah titik api kebakaran hutan yang digunakan dalam penelitian ini dikumpulkan dari daerah Nusa Tenggara Timur (NTT), terutama pulau-pulau seperti Sumba dan Timor. Metode CNN melibatkan dua langkah utama. Langkah pertama adalah pengklasifikasian gambar melalui proses feedforward. Langkah kedua adalah fase pembelajaran menggunakan teknik backpropagation. Model CNN yang digunakan dalam proses pelatihan dataset menguji citra dengan beberapa pengoptimal dan diperoleh hasil akurasi yang tinggi. Kemiripan area yang terbakar dengan fitur terang lainnya mengurangi kepastian deteksi kebakaran hutan. Hasil penelitian menunjukkan bahwa Model CNN yang digunakan Untuk deteksi dan segmentasi area terbakar menggunakan algoritma terpilih, kinerja terbaik dengan pembelajaran mendalam yang dilaporkan dalam literatur adalah 89%. Teknik yang diusulkan dilatih menggunakan wilayah varian (kumpulan data) dan mengevaluasi presisi berdasarkan ambang recall, dengan akurasi keseluruhan 89%.

Kata Kunci: Hotspot, Kebakaran hutan, Pembelajaran Mendalam, Convolutional Neural Network

I. Pendahuluan

Indonesia, yang merupakan negara tropis di Asia, menghadapi kebakaran hutan yang berulang setiap tahun dan tahun di berbagai wilayah yang tersebar. Kebakaran hutan di Indonesia mengalami peningkatan, terutama pada tahun 2019 meningkat sebesar 200,94% dari tahun 2018[1]. Kebakaran hutan adalah peristiwa yang signifikan dan rumit yang melibatkan berbagai aspek kompleks [2]. Akibat yang ditimbulkan dari kebakaran hutan salah satunya adalah gangguan pernafasan yang dialami baik manusia maupun hewan di sekitar tempat kejadian. Asap dari kebakaran hutan yang disebabkan oleh angin juga merugikan negara-negara di sekitar Indonesia, seperti Malaysia, Singapura, dan Brunei Darussalam. Kebakaran hutan disebabkan oleh beberapa faktor, antara lain alam dan manusia. Sebagian besar kebakaran disebabkan oleh manusia, meskipun faktor-faktor lain seperti kekeringan, angin, sambaran petir, dan topografi mempunyai pengaruh penting terhadap terjadinya dan penyebaran kebakaran. Kebakaran hutan menghadirkan tantangan pemantauan yang serius. Perilakunya tidak jelas dan sulit diprediksi, terutama kebakaran hutan yang besar dan hebat karena kejadian ini mungkin merupakan gabungan dari skenario meteorologi yang rumit, topografi yang rumit, dan struktur bahan bakar yang rumit. Pemodelan dan prediksi perilaku kebakaran hutan merupakan tantangan multidisiplin yang ditangani oleh banyak peneliti dari berbagai latar belakang di bidang teknik, ekologi, fisika, ilmu komputer, kimia, matematika, kehutanan, dan bidang lainnya. Selain itu, memprediksi terjadinya kebakaran hutan besar merupakan tantangan komputasi karena proses terjadinya kebakaran hutan mencakup berbagai skala spasial dan temporal yang berkontribusi besar terhadap kebakaran hutan.

Pada tahun 2023, terjadi 2,906 insiden kebakaran hutan dan lahan, jumlah ini 30,80% lebih rendah dibandingkan dengan tahun 2019 yang memiliki kondisi El-Nino serupa. Meskipun tahun 2023 memiliki kondisi yang lebih kering, KLHK mencatat bahwa luas kebakaran hutan dan lahan hingga Oktober 2023 mencapai 994.313,18 hektar. Kebakaran hutan yang menyebar terlalu luas membuat petugas pemadam kebakaran hutan kesulitan memadamkan api. Luasnya hutan di Indonesia juga membuat penjaga hutan seringkali tidak menyadari tanda-tanda kebakaran hutan. Selain itu, kebakaran hutan memiliki konsekuensi yang parah terhadap emisi karbon global. Rata-rata, emisi karbon tahunan bersih dari kebakaran hutan tropis bernilai sekitar 7,5 hingga 70 Mg ha Antara tahun 2003 dan 2012, kehilangan tutupan hutan tahunan akibat kebakaran mencapai sekitar 67 juta ha, yang merupakan sekitar 1,7% dari kawasan hutan dunia[3]. Kebakaran hutan dan lahan umumnya terjadi selama musim kemarau yang panjang di beberapa daerah seperti Pulau Sumatera dan Kalimantan [4]. Informasi tentang hotspot didapatkan melalui proses penerimaan dan pengolahan data, yang menghasilkan informasi titik panas serta menginterpretasikan kepercayaan terhadap data tersebut [4]. Hasil identifikasi yang di dapatkan pada tahun 2019, Indonesia mengalami kebakaran hutan dan lahan yang mencakup area seluas 1,64 juta hektar, yang terdiri dari 1,15 juta hektar (70%) di tanah mineral dan 0,49 juta hektar (30%) di tanah gambut. Dari analisis berdasarkan fungsi kawasan, area terbakar dalam kawasan hutan mencapai 912.924 hektar (55%), sedangkan area terbakar di luar kawasan hutan (penggunaan lahan lain) adalah 736.334 hektar (45%). Secara rinci, area terbakar dalam kawasan hutan meliputi Hutan Produksi Tetap sebesar 325.970 hektar (36%); Hutan Konservasi sebesar 226.559 hektar (25%); Hutan Produksi Konversi sebesar 159.138 hektar (17%); Hutan Lindung sebesar 122.740 hektar (13%); dan Hutan Produksi Terbatas sebesar 78.517 hektar (9%). Menurut analisis penutupan lahan, kebakaran terjadi di lahan tidak berhutan seluas 1.551.749 hektar (94%), sedangkan lahan berhutan yang terbakar adalah 97.508 hektar (6%). Kebakaran hutan dan lahan di Indonesia, yang terjadi hampir setiap tahun, telah menarik perhatian masyarakat global dan para peneliti karena dampak besar yang dihasilkannya. Salah satu insiden terbesar kebakaran hutan di dunia terjadi pada tahun 1997/1998, mencakup area seluas 25 juta hektar, termasuk di Indonesia, di mana kebakaran ini terutama disebabkan oleh praktik pembukaan lahan yang bertepatan dengan fenomena El Nino [5]. Kebakaran hutan dan lahan sering terjadi dan dianggap sebagai masalah lingkungan yang penting, sehingga mendapatkan perhatian baik dari tingkat lokal maupun internasional [6]. Setiap tahun, masalah kebakaran hutan semakin bertambah parah. Penyebab utamanya meliputi peningkatan aktivitas penebangan liar, penggunaan lahan untuk pemukiman, pertanian, perkebunan berskala besar, pembuatan hutan tanaman yang mudah terbakar, serta kondisi iklim yang mendukung terjadinya kebakaran, termasuk periode dengan curah hujan yang rendah [7]. Kebakaran hutan biasanya dimulai dari titik api kecil yang kemudian meluas menjadi besar karena kondisi di lapangan. Langkah-langkah antisipatif diperlukan untuk mencegah penyebaran api lebih lanjut, sehingga kerugian dan dampak negatif dapat diminimalkan. Salah satu tindakan pencegahan tersebut adalah dengan mengidentifikasi jenis titik api sejak awal agar dapat ditangani segera. Kebakaran hutan menyebabkan dampak signifikan terhadap manusia, terutama dalam bentuk kerugian ekonomi akibat kehilangan berbagai manfaat yang ditawarkan oleh hutan. Ini termasuk kehilangan pohon-pohon yang sering digunakan untuk bahan bangunan, makanan, obat-obatan, serta kehilangan satwa liar yang penting untuk asupan protein dan kegiatan rekreasi. Selain itu, terdapat juga kerugian ekologis, seperti pengurangan area hutan, berkurangnya ketersediaan

udara bersih yang biasanya disediakan oleh vegetasi hutan, dan hilangnya kemampuan hutan dalam mengatur siklus air serta mencegah erosi. Proses identifikasi titik api dalam kebakaran hutan bisa dilaksanakan melalui metode klasifikasi titik api, yang bertujuan sebagai langkah pencegahan untuk menghindari perluasan area yang terbakar [8]. Penelitian yang dilakukan oleh [9] yaitu mengevaluasi hubungan antara curah hujan dan hotspot untuk mengidentifikasi pola kejadian kebakaran hutan dan lahan di Pulang Pisau, Kalimantan Tengah, dari tahun 2017 hingga 2021. Hasilnya diharapkan memberikan data penting kepada pemerintah tentang tingkat keparahan kebakaran yang terjadi di wilayah tersebut selama periode tersebut, membantu dalam pengambilan kebijakan pengendalian dan sistem peringatan dini kebakaran hutan dan lahan. Penelitian selanjutnya yang diangkat oleh [10] membahas mengenai daerah mempunyai reflektansi pasca kebakaran yang berbeda karena perbedaan tanah, topografi, tingkat keparahan kebakaran dan faktor lainnya, istilah ini pada dasarnya adalah efek acak yang menjelaskan variabilitas spasial dalam NDVI yang diamati dalam beberapa minggu atau bulan pertama setelah kebakaran. Ini adalah solusi yang elegan dan baru terhadap permasalahan koreksi reflektansi tanah yang mengganggu studi fraksi tutupan vegetasi.

Hutan adalah ekosistem yang kompleks dan luas yang terdiri dari pohon-pohon tinggi dan berbagai jenis flora serta fauna lainnya yang saling berinteraksi dalam suatu area yang cukup besar. Hutan berperan penting dalam menjaga keseimbangan ekologis dan lingkungan planet kita. Hutan mempunyai banyak fungsi, antara lain: Penyimpan Karbon, Produsen Oksigen, Penyedia Habitat, Pengatur Siklus Air, dan Perlindungan Tanah. Dampak lingkungan dari kebakaran hutan dan gambut telah dilaporkan dalam berbagai penelitian [11][12].

Pembelajaran mesin (ML) berkinerja baik dalam memecahkan masalah kompleks dalam aplikasi teknik dan penelitian ilmiah. Kecerdasan Buatan adalah salah satu cabang dari ilmu komputer yang berfokus pada pengembangan perangkat lunak dan perangkat keras yang memiliki kemampuan untuk beroperasi dan berpikir layaknya manusia [13]. Kecerdasan buatan diterapkan dalam berbagai bidang untuk mengatasi berbagai masalah, termasuk bisnis [14], robotika, pemrosesan bahasa alami, matematika, gaming, persepsi sensoris, diagnostik medis, teknik, analisis keuangan, penelitian ilmiah, dan penalaran. [15]. Deep Learning adalah cara untuk mengotomatisasi pekerjaan untuk memprediksi dan mengklasifikasikan data menggunakan jaringan saraf tiruan (artificial neural networks) dengan banyak lapisan (atau "deep") untuk memodelkan abstraksi data yang kompleks [16]. Proses pemasukan data, pengolahan dan penyajiannya akan dilakukan secara otomatis oleh mesin. Nilai positif dari penelitian ini adalah berkurangnya sumber daya manusia profesional yang harus mengoperasikannya dan efisiensi dalam bekerja. Metode deep learning yang paling sederhana dan umum digunakan adalah Convolutional Neural Network (CNN) [17]. Adapun proses pembelajaran yang dimaksud adalah suatu usaha dalam memperoleh kecerdasan yang melalui dua tahap antara lain latihan (training) dan pengujian (testing) [18]. Deep learning adalah cabang dari machine learning yang algoritmanya terinspirasi oleh struktur otak manusia dan saat ini sangat populer di kalangan ahli data. Karena teknologi deep learning diintegrasikan dalam berbagai produk berteknologi canggih seperti mobil otonom, serta hadir dalam produk dan layanan yang digunakan sehari-hari seperti asisten digital, Google Translate, dan perangkat yang diaktifkan suara. Deep learning melibatkan jaringan dari beberapa jaringan saraf tiruan yang terhubung satu sama lain.

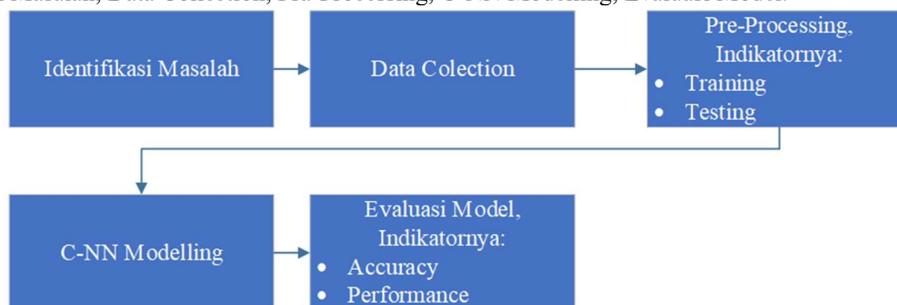
CNN merupakan salah satu metode yang dapat mengklasifikasikan data berupa gambar. Metode CNN telah banyak digunakan pada penelitian-penelitian sebelumnya dalam klasifikasi jenis gambar atau suara. Metode CNN pada dasarnya hanya mampu mengolah data berupa gambar atau visual. Nilai akurasi yang tinggi akan memberikan kesimpulan terhadap metode yang diterapkan dalam klasifikasi data [19]. Convolutional Neural Network (CNN) saat ini digunakan secara luas untuk aplikasi seperti identifikasi citra satelit, pengolahan citra medis, prediksi seri waktu, dan pendeteksi anomali. CNN dirancang untuk mengolah data yang terstruktur dalam bentuk array, seperti gambar berwarna yang terbagi menjadi tiga array 2D yang merepresentasikan intensitas piksel di tiga saluran warna. CNN mengoptimalkan pengolahan sinyal dengan memanfaatkan konektivitas lokal, pembagian bobot, teknik pooling, dan penerapan berbagai lapisan. Dalam struktur CNN, terdapat empat lapisan utama yaitu Convolution Layer, Pooling Layer, Dropout Layer, dan Fully Connected Layer [20][21]. Dalam Convolutional Neural Network (CNN), empat komponen utama bertanggung jawab atas pemrosesan citra. Pertama, citra akan difilter melalui Convolution Layer yang menggunakan filter untuk mendeteksi karakteristik objek. Proses ini menghasilkan output linear dari citra masukan, di mana parameter seperti filter, stride, dan padding dapat diatur untuk memodifikasi lapisan. Stride mengontrol cara filter bergerak sepanjang ukuran piksel yang ditentukan, sedangkan padding menambahkan piksel tertentu di sekitar citra input untuk mencegah hasil yang terlalu kecil dan kehilangan informasi. Kedua, citra yang telah difilter akan direduksi ukurannya di Pooling Layer, yang memilih nilai terbesar dari setiap grid untuk mengurangi dimensi data. Ketiga, Dropout Layer digunakan untuk mencegah overfitting. Keempat, Fully Connected Layer mengubah data menjadi dimensi yang cocok untuk klasifikasi. Agar proses klasifikasi dapat memberikan hasil yang akurat, setiap model harus dilatih dengan data yang berkualitas tinggi [22][23]. 2) ReLu Layer, atau Rectified Linear Unit, adalah lapisan yang

mengintroduksi non-linearitas dalam jaringan untuk meningkatkan representasi model, menghasilkan peta fitur yang ditingkatkan. Selanjutnya, 3). Pooling Layer berfungsi untuk mengambil dan mengurangi dimensi fitur yang telah diperbaiki, dengan menggabungkan fitur-fitur tersebut untuk menghasilkan fitur terpadu. Terakhir, 4). Fully Connected Layer menghubungkan semua neuron yang masing-masing memiliki koneksi lengkap ke semua aktivasi dari lapisan sebelumnya, memungkinkan jaringan untuk mengklasifikasikan data berdasarkan fitur yang telah dipelajari dan disintesis sebelumnya. Penelitian yang dilakukan oleh [24], mengenali salah satu dari berbagai spesies memerlukan waktu yang signifikan jika dilakukan secara manual. Oleh karena itu, fitur prediksi jenis hewan yang telah dikembangkan diharapkan dapat membantu peneliti dalam mengidentifikasi makhluk yang mereka temukan. Fitur ini juga bertujuan untuk memudahkan peneliti dalam mengklasifikasikan apakah hewan yang ditemui sudah dikenal atau belum. Metode yang akan digunakan untuk mengolah citra hewan tersebut adalah Convolutional Neural Network (CNN), yang telah terbukti efektif dalam mengenali objek dalam gambar berdasarkan penelitian sebelumnya.

Penelitian yang dilakukan ini bertujuan untuk mendeteksi dan mensgmentasi area hutan yang terbakar menggunakan model klasifikasi yang dilatih dengan data dari situs penyedia dataset terbuka, Kaggle[25]. Data tersebut diambil dari daerah Nusa Tenggara Barat dan diproses menggunakan algoritma CNN.

II. Metodologi Penelitian

Gambar 1 menggambarkan prosedur penelitian. Ada lima fase yang berbeda, dan fase adalah sebagai berikut: Identifikasi Masalah, Data Collection, Pra-Processing, C-NN Modelling, Evaluasi Model.



Gambar 1. Tahapan Penelitian

a. Identifikasi Masalah

Implementasi pemodelan wilayah titik api kebakaran hutan menggunakan data image digital menggunakan metode deep learning.

b. Data Collection

Data citra satelit merupakan sumber data utama untuk memodelkan wilayah titik api kebakaran hutan. Citra satelit yang tersedia dapat mencakup citra multispektral dengan resolusi spasial yang beragam, yang dapat memberikan informasi tentang kondisi lahan, vegetasi, dan kebakaran. Data cuaca seperti suhu udara, kelembaban udara, kecepatan dan arah angin, dan curah hujan dapat membantu dalam memahami kondisi lingkungan yang berkontribusi terhadap potensi terjadinya kebakaran hutan. Proses membangun dataset adalah mengumpulkan data terkait yang dapat mewakili munculnya kebakaran hutan, banyak komponen parameter yang dapat digunakan dalam identifikasi masalah yang diangkat. Hal ini parameter terkait dengan keadaan tanaman, keadaan tanah dan berbagai meteorology data yang mempengaruhi kebakaran hutan. Dalam penelitian ini, kami memilih tiga parameter yang terkait dengan tiga aspek (kesehatan tanaman, suhu tanah, dan indikator kebakaran). Parameter pertama adalah Normalized Difference Vegetation Index (NDVI) yaitu dianggap sebagai indeks vegetasi paling populer dan paling banyak digunakan untuk tanaman, yang kedua parameternya adalah LST (Land Surface Temperature) yang merupakan suhu tanah, dan terakhir adalah api indikator (Anomali Termal).

Pemilihan ketiga parameter tersebut dilakukan berdasarkan sifat permasalahan yang diangkat oleh kertas, yang memprediksi terjadinya kebakaran hutan yang disebabkan secara alami oleh panas atau petir, dalam kedua kasus keadaan tanaman, serta tanah, memainkan peran utama dan penting dalam terbakar; tanaman kering di tanah kering dan panas lebih mungkin terbakar daripada tanaman basah di tanah lembab. Setelah memvalidasi model, parameter tambahan akan ditambahkan pekerjaan masa depan untuk meningkatkan model pemantauan kebakaran akhir. Semua data ini dapat diambil dari satelit yang berbeda seperti Terra, Aqua, Landsat, dan Aster. Setiap satelit berisi produk yang berbeda, dan produk ini berbeda dalam ukurannya resolusi spasial, dan rentang spektral. Di bawah ini gambaran dari tiga parameter yang digunakan.

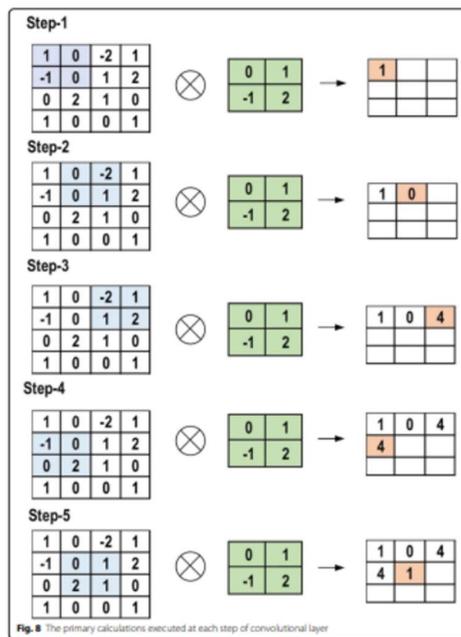
c. Pre-Processing

Pre-processing adalah sebuah tahapan penting yang ada didalam Data Mining hal itu melibatkan pembersihan data dari unsur-unsur yang mengganggu seperti duplikasi, ketidakkonsistenan, dan kesalahan ketik sebelum data tersebut dimasukkan ke dalam model. Dalam konteks machine learning, pre-processing data adalah langkah krusial untuk memastikan data yang digunakan memiliki kualitas yang optimal sebelum diterapkan pada model machine learning yang sedang dikembangkan [21]. Untuk penelitian ini, mengingat dataset telah terpisah menjadi dua bagian, yaitu data pelatihan dan pengujian, langkah pre-processing yang dilakukan adalah normalisasi resolusi gambar atau resize untuk memastikan model yang dibangun dapat mencapai akurasi yang maksimal.

d. C-NN Modelling

CNN, atau Convolutional Neural Network, adalah algoritma pembelajaran mendalam yang telah menjadi sangat populer belakangan ini karena kemampuannya yang efektif dalam mendeteksi objek secara otomatis tanpa perlu campur tangan langsung dari manusia atau pengguna yang menerapkan algoritma tersebut pada objek spesifik [26]. Struktur dari algoritma ini terilhami oleh mekanisme kerja neuron di otak hewan dan manusia, terutama berdasarkan cara kerja korteks visual pada otak kucing, yang mengatur rangkaian sel yang kompleks. Rangkaian ini kemudian direplikasi dalam operasi CNN [27]. Beberapa keuntungan dari penggunaan CNN termasuk fitur pembagian bobot, yang secara efektif mengurangi jumlah parameter dalam jaringan yang perlu dilatih, sehingga membantu mencegah overfitting. Keunggulan lainnya adalah proses belajar atau pemrosesan yang terjadi secara simultan pada setiap lapisan ekstraksi fitur dan klasifikasi, yang menghasilkan output model yang terstruktur dengan baik dan sangat relian pada fitur yang telah diekstraksi [23]. Berikut beberapa bagian yang termasuk dalam CNN, sebagai berikut:

1. Salah satu komponen penting dalam arsitektur CNN adalah Convolutional Layer. Lapisan ini memanfaatkan serangkaian filter konvolusi atau kernel yang bertujuan untuk menciptakan peta fitur keluaran. Selama proses ekstraksi fitur, gambar input dipecah menjadi beberapa segmen berdasarkan piksel yang ditetapkan oleh parameter tertentu. Hasil dari proses konvolusi ini bisa berupa gambar yang berukuran lebih kecil atau memiliki ukuran yang sama tetapi dengan tingkat kedalaman yang berubah [28]. Proses konvolusi pada gambar dapat diilustrasikan seperti yang ditunjukkan pada gambar 2 [23].



Gambar 2. Proses Convolutional dalam Convolutional Layer

2. Pooling Layer merupakan komponen dalam arsitektur CNN dirancang untuk menghasilkan sub-sampel dari peta fitur yang dibuat oleh lapisan sebelumnya. Tujuan utama dari lapisan ini adalah untuk mengidentifikasi dan mengekstraksi keberadaan fitur-fitur tertentu dalam gambar masukan. Dalam Pooling Layer, terdapat beberapa teknik pooling yang bisa digunakan, termasuk max pooling, min pooling, global average pooling (GAP), dan global max pooling [23].

3. Loss Function merupakan salah satu metode yang dipakai untuk mengukur perbedaan atau penyimpangan antara kualitas aktual dari suatu produk dan nilai target atau standar yang diharapkan. Meskipun

penyimpangan tersebut kecil, kerugian masih akan terjadi. Perbedaan yang lebih besar antara kualitas produk dan nilai target akan menghasilkan kerugian yang lebih tinggi. Kerugian ini bisa dianggap sebagai "kerugian masyarakat" karena mencerminkan biaya sosial dari variasi karakteristik kualitas produk yang dialami oleh produsen dan konsumen. Fungsi kerugian ini digunakan untuk menilai seberapa efektif karakteristik kualitas dalam mencapai standar yang ditetapkan, dengan mengukur variasi yang terjadi dari nilai target tersebut.

4. Rectified Linear Unit (ReLU) merupakan transformasi nonlinier yang berfungsi mengonversi input menjadi output. Sebagai fungsi aktivasi, ReLU terkenal karena kemampuannya untuk mempercepat proses pelatihan [29]. Menurut sumber lain [30], Rectified Linear Unit (ReLU) adalah fungsi aktivasi yang memiliki kemampuan dalam perhitungan yang sederhana. Dengan ReLU, proses maju dan mundur dapat dilakukan hanya dengan menggunakan kondisi "jika". Ketika elemen inputnya negatif, nilai dapat direset menjadi 0 tanpa harus melakukan operasi perkalian atau pembagian, yang biasa terjadi pada operasi eksponensial. Ini merupakan bagian dari persamaan matematis untuk fungsi aktivasi Rectified Linear Unit (ReLU) [31].

e. Evaluasi Model, Evaluasi Model mempunyai 2 tahapan yaitu penentuan hasil dari Accuracy model yang digunakan dan performancenya. Evaluasi dari hasil klasifikasi terbakar/tidak terbakar wilayah titik api kebakaran hutan yang terjadi di NTB, Data tersebut di ambil dari link (<https://github.com/ouladsayadyounes/Wildfires>) dilakukan dengan confusion matrix. Metode ini merepresentasikan hasil klasifikasi menggunakan matriks yang dapat dilihat pada Tabel 1 [32][33].

Tabel 1. Confusion Matrix

		Actual Value	
		TP	FP
Predicted Value	TP		
	FN		

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} * 100\%$$

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

III. Hasil dan Pembahasan

A. Pengumpulan Data

Dataset yang diterapkan dalam penelitian ini berasal dari sistem SANTANU yang terletak di kantor PSTA, dan telah dikategorikan ke dalam dua kelas, yaitu kelas data normal dan kelas data.

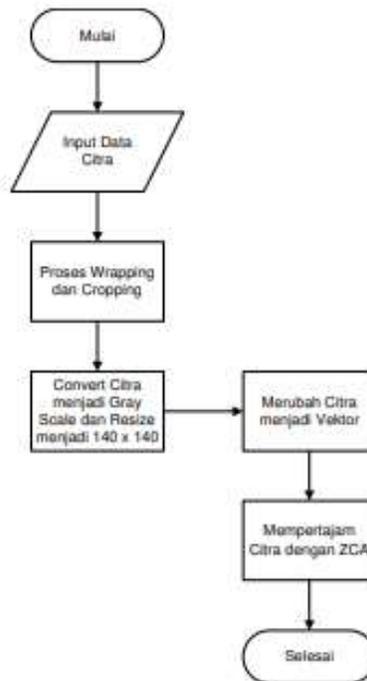
B. Pembagian Data

Data yang terkumpul dibagi menjadi dua segmen, yaitu data latih dan data uji, masing-masing dengan proporsi tertentu. Data latih digunakan untuk melatih model, sementara data uji diterapkan dalam pengujian model setelah model tersebut terbentuk.

C. Dalam tahap pra-proses dan pengolahan data citra masukan, akan dilakukan proses wrapping dan cropping. Wrapping melibatkan pengecekan terhadap tepian objek utama dalam citra untuk menentukan batas maksimalnya, memastikan bahwa objek tetap utuh dalam hasil cropping seperti pada Gambar 3. Tahap training dimulai dengan merubah citra menjadi bentuk vektor. Sehingga alur proses pertama berbentuk seperti Gambar 4.



Gambar 3. Pra Proses Data



Gambar 4. Alur Tahap Data Training

Proses pengolahan data citra dimulai dengan mengubah ukuran citra asal menjadi 140 x 140. Citra ini kemudian diubah ke grey scale untuk memudahkan pengolahan selama tahap pelatihan. Dalam perancangan CNN, ditetapkan jumlah lapisan yang akan digunakan, tipe fungsi aktivasi, jumlah batch, jumlah epoch, ukuran konvolusi, dan ukuran pooling.

E. Klasifikasi CNN

Dalam proses ini, data yang telah disiapkan digunakan untuk pelatihan dengan kelas yang sudah ditentukan, guna menghasilkan model sesuai dengan algoritma yang diaplikasikan. Model ini nantinya akan diuji, dan jika hasilnya memuaskan, model tersebut dapat diterapkan dalam sistem untuk klasifikasi titik api kebakaran hutan. Hal ini membantu pihak-pihak terkait dalam membuat keputusan yang berdampak pada masyarakat sekitar.

F. Pengujian

Proses ini bertujuan untuk mengevaluasi model yang telah dibuat sebelumnya dengan menggunakan data uji yang sudah disiapkan. Data uji tersebut mewakili data baru yang akan dihasilkan oleh sistem, dengan tujuan utama untuk mengukur tingkat akurasi model saat diterapkan secara nyata. Pengujian akhir akan menggunakan

Confusion Matrix untuk menguji model tersebut, dengan total pengujian dilakukan pada 75 data. Data di jelaskan dengan gambar di bawah ini:

Tabel 2. Tabel Data

		Aktual	
Prediksi	Data	TRUE	FALSE
	TRUE	48	3
	FALSE	5	19

Dari tabel tersebut didapatkan hasil :

1. True : 48 dokumen
2. True False : 3 dokumen
3. False True : 5 dokumen
4. False False : 19 dokumen

Dengan hasil dari confusi matrix diperoleh akurasi:

$$\text{Akurasi} = (\text{True} + \text{False False}) / (\text{True} + \text{True False} + \text{False True} + \text{False False})$$

$$\text{Akurasi} = (48 + 19) / (48 + 3 + 5 + 19)$$

$$\text{Akurasi} = 0.89$$

$$\text{Akurasi} = 89\%$$

Akurasi algoritma CNN yang didapatkan dengan menggunakan adalah 0,89atau 89% dalam pengklasifikasian data titik api kebakaran hutan menjadi sebuah nilai dalam bentuk accuracy.

IV. Kesimpulan

Berdasarkan model yang telah dibuat, akurasi untuk data titik api kebakaran hutan mencapai 89,8%. Hal ini menunjukkan bahwa penggunaan Algoritma CNN dengan Tensorflow dalam klasifikasi memberikan hasil yang sangat memuaskan. Akurasi sebesar 89,8% ini membuktikan bahwa CNN dengan Tensorflow efektif dan memiliki performa yang sangat baik dalam teknik klasifikasi.

Daftar Pustaka

- [1] KLHK (2019) ‘Rekapitulasi Luas Kebakaran Hutan dan Lahan (Ha) Per Provinsi Di Indonesia Tahun 2014-2019’, SiPongi - Karhutla Monitoring Sistem, (1), pp. 26– 27. doi: 10.1103/PhysRevB.65.020504.
- [2] Rashkovetsky, D., Mauracher, F., Langer, M., Schmitt, M., 2021. Wildfire detection from multisensor satellite imagery using deep semantic segmentation. *IEEE J. Sel. Top Appl. Earth Obs. Remote Sens.* 14, 7001–7016.
- [3] Van Lierop, P., Lindquist, E., Sathyapala, S. and Franceschini, G., 2015. Gangguan kawasan hutan global akibat kebakaran, hama serangga, penyakit dan kejadian cuaca buruk. *Ekologi dan Pengelolaan Hutan*, 352,hlm.78-88.
- [4] Pinem A, Yulianto S, Dwiastuti R. 2022. Karakteristik spasial data hotspot modis tahun 2019 di Kota Palangka Raya Provinsi Kalimantan Tengah. *Jurnal Hutan Tropika*. 17(148):104–113.
- [5] Tacconi, L. (2003). Kebakaran hutan di Indonesia: Penyebab, Biaya dan Implikasi Kebijakan. *Center for International Forestry Research*, 38(i)
- [6] Cahyono SA, P Warsito S, Andayani W, H Darwanto D. 2015. Faktor-faktor yang mempengaruhi kebakaran hutan di Indonesia dan implikasi kebijakannya. *Jurnal Sylva Lestari*. 3(1):103-112.
- [7] Mardiani D. 2014. Hubungan curah hujan dan titik panas (hotspot) dalam kaitannya dengan terjadinya kebakaran di Provinsi Aceh [skripsi]. Bogor (ID): Institut Pertanian Bogor.
- [8] Saruni Dwiasnati and Yudo Devianto, “Classification of forest fire areas using machine learningalgorithm,” *World Journal of Advanced Engineering Technology and Sciences*, vol. 3, no. 1, 2021, doi: 10.30574/wjaets.2021.3.1.0048
- [9] Bambang Hero Saharjo dan Uswatun Hasanah. Analisis Faktor Penyebab Terjadinya Kebakaran Hutan Dan Lahan Di Kabupaten Pulang Pisau, Kalimantan Tengah. *Jurnal Sulvikultur Tropika*. Vol 14. No 01, April. 2023

- [10] Gao, L., Wang, X., Johnson, B.A., Tian, Q., Wang, Y., Verrelst, J., Mu, X., Gu, X., 2020. Remote sensing algorithms for estimation of fractional vegetation cover using pure vegetation index values: A review. *ISPRS J. Photogramm. Remote Sens.* 159, 364–377.
- [11] Langman B. (2014) The effects of vegetation and peat fire emissions in Indonesia on air pollution and global climate. *Asian Journal of Water, Environment and Pollution* 11(1): 3–11.
- [12] Othman J., Sahani M., Mahmud M., Ahmad M. K. S. (2014) Transboundary smoke haze pollution in Malaysia: Inpatient health impacts and economic valuation. *Environmental Pollution* 189: 194–201. Crossref. PubMed.
- [13] Sunarya, A., Santoso, S., & Sentanu, W. (2015). Sistem Pakar Untuk Mendiagnosa Gangguan Jaringan Lan. *CCIT Journal*, 8(2), 1–11
- [14] Rahardja, U., Roihan, A., & others. (2017). Design of Business Intelligence in Learning Systems Using iLearning Media. *Universal Journal of Management*, 5(5), 227–235. Goldberg, D. E., & Holland, J. H. (1988). Genetic algorithms and machine learning. *Machine Learning*, 3(2), 95–99.
- [15] Russell, S. J., & Norvig, P. (2016). *Artificial intelligence: a modern approach*. Malaysia; Pearson Education Limited
- [16] Stowell, D., Wood, M. and Pamuła, H. (2018) ‘arXiv : 1807 . 05812v1 [cs . SD] 16 Jul 2018 Automatic acoustic detection of birds through deep learning : the first Bird Audio Detection challenge’, (15), pp. 1–21.
- [17] Florentin, J., Dutoit, T., Verlinden, O., 2020. Detection and identification of European woodpeckers with deep convolutional neural networks. *Ecol. Inf.* 55, 101023. <https://doi.org/10.1016/j.ecoinf.2019.101023>.
- [18] Huang, G.-B., Zhu, Q.-Y., & Siew, C.-K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1–3), 489–501.
- [19] Zottesso, R.H.D., Costa, Y.M.G., Bertolini, D., Oliveira, L.E.S., 2018. Bird species identification using spectrogram and dissimilarity approach. *Ecol. Inf.* 48, 187– 197. <https://doi.org/10.1016/j.ecoinf.2018.08.007>.
- [20] E. N. Arrofiqoh and H. Harintaka, “Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi,” *Geomatika*, vol. 24, no. 2, p. 61, 2018, doi: 10.24895/jig.2018.24-2.810
- [21] J. Han, M. Kamber, and J. Pei, *Data mining: Data mining concepts and techniques*. 2014. doi: 10.1109/ICMIRA.2013.45
- [22] Suyanto, K. N. Ramadhani, and S. Mandala, “Deep Learning Modernisasi Machine Learning untuk Big Data,” in *DEEP LEARNING Modernisasi Machine Learning untuk Big Data*, Informatika, 2019, pp. 33–41
- [23] L. Alzubaidi et al., *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021. doi: 10.1186/s40537-021-00444-8.
- [24] Dhika, H., Rahma Kurnianda, N., Ananta, W., Matematika, F. I., Alam, P., Komputer, F. I., & Mercu Buana, U. (n.d.). Model Prediksi Jenis Hewan dengan Metode Convolution Neural Network. <http://www.kaggle.com/c/dogs-vs>. Format. Volume 9 Nomor 1 Tahun 2020 :: ISSN : 2089 - 5615 :: E-ISSN : 2722 - 7162
- [25] N. Padia, P. Siddharth, A. Hirpara, and D. Jani, “Cataract dataset.” <https://www.kaggle.com/datasets/nandanp6/cataract-image-dataset>
- [26] Q. Zhang, M. Zhang, T. Chen, Z. Sun, Y. Ma, and B. Yu, “Recent advances in convolutional neural network acceleration,” *Neurocomputing*, vol. 323, pp. 37–51, 2019, doi: 10.1016/j.neucom.2018.09.038.
- [27] D. H. Hubel and T. N. Wiesel, “Receptive fields, binocular interaction and functional architecture in the cat’s visual cortex,” *J. Physiol.*, vol. 160, no. 1, pp. 106–154, 1962, doi: 10.1113/jphysiol.1962.sp006837.
- [28] M. W. Ilahi, C. N. Apriyani, A. Desiani, N. Gofar, Y. Andriani, and M. R. Halim, “Classification of Geometric Batik Motif Typical of Indonesian Using Convolutional Neural Network,” *J. Tek. Inform.*, vol. 15, no. 1, pp. 91–100, 2022, doi: 10.15408/jti.v15i1.24968
- [29] M. W. Ilahi, C. N. Apriyani, A. Desiani, N. Gofar, Y. Andriani, and M. R. Halim, “Classification of Geometric Batik Motif Typical of Indonesian Using Convolutional Neural Network,” vol. 15, no. 1, pp. 91–100, 2022
- [30] A. K. Putra and H. Bunyamin, “Pengenalan Simbol Matematika dengan Metode Convolutional Neural Network (CNN),” vol. 2, no. November, pp. 426–433, 2020.
- [31] A. Farhah, A. L. Prasasti, and M. W. Paryasto, “Implementasi Recurrent Neural Network dalam Memprediksi Kepadatan Restoran Berbasis LSTM,” *J. Media Inform. Budidarma*, vol. 5, no. 2, p. 524, 2021, doi: 10.30865/mib.v5i2.2916.
- [32] D. Normawati and S. A. Prayogi, “Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter,” *J. Sains Komput. Inform. (J-SAKTI)*, vol. 5, no. 2, pp. 697–711, 2021.

- [33] D. Putra and A. Wibowo, "Prediksi Keputusan Minat Penjurusan Siswa SMA Yadika 5 Menggunakan Algoritma Naïve Bayes," vol. 2, pp. 84–92, 2020.