



Prediksi Wilayah Rawan Kebakaran Menggunakan *Deep Learning*

Ahmad Zuhdi*¹, Muhamad Septa Utama Sp²

^{1,2}Institut Informatika dan Bisnis Darmajaya; JL.ZA Pagar Alam No 93 Gedung Meneng.0721-787214

*Email Penulis Korespondensi: ahmadzuhdi.az2314@gmail.com

Abstrak

Kebakaran hutan dan lahan merupakan masalah serius yang dapat merusak ekosistem, mengancam satwa liar, dan menyebabkan kerugian ekonomi. Penelitian ini bertujuan untuk mengembangkan prediksi wilayah rawan kebakaran menggunakan teknologi remote sensing dan deep learning. Dataset gambar wilayah Kanada yang terbakar sebelumnya digunakan untuk melatih model Convolutional Neural Network (CNN). Model-model CNN diperbandingkan dan dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1 Score. Hasil penelitian menunjukkan bahwa model MobileNet mencapai akurasi tertinggi sebesar 0,9640 dan waktu pelatihan yang singkat sebesar 114,04 detik. Model MobileNet juga berhasil melewati tahap validasi dengan akurasi sebesar 0,979, presisi sebesar 0,986, recall sebesar 0,973, dan F1 Score sebesar 0,978. Temuan ini menunjukkan bahwa model memiliki kinerja yang sangat baik dalam mengklasifikasikan wilayah yang berpotensi mengalami kebakaran di Kanada. Penelitian ini memberikan kontribusi penting dalam upaya mitigasi risiko kebakaran dan pengelolaan sumber daya alam di wilayah tersebut. Integrasi teknologi remote sensing dan deep learning menjadi solusi yang efektif untuk mengidentifikasi dan memprediksi daerah rawan kebakaran di masa depan.

Kata kunci—Kebarakan Hutan, Penginderaan Jarak Jauh, CNN, Deep Learning


Abstract

Forest and land fires are a serious environmental issue that can cause ecosystem damage, threaten wildlife, and result in economic losses. This research aims to develop fire-prone area prediction using remote sensing technology and deep learning. A dataset of previous regions in Canada was used to train Convolutional Neural Network (CNN) models. The CNN models were compared and evaluated by using accuracy, precision, recall, and F1 Score metrics. The results show that the MobileNet model achieved the highest accuracy of 0.9640 and a short training time of 114.04 seconds. The MobileNet model also successfully in passing the validation stage with an accuracy of 0.979, precision of 0.986, recall of 0.973, and F1 Score of 0.978. These findings indicate that the model performs exceptionally well in classifying fire-prone areas in Canada. This research provides a significant contribution to fire risk mitigation and natural resource management in the region. The integration of remote sensing technology and deep learning proves to be an effective solution for identifying and predicting fire-prone areas in the future.

Keywords—Wildfire, Remote Sensing, CNN, Deep Learning

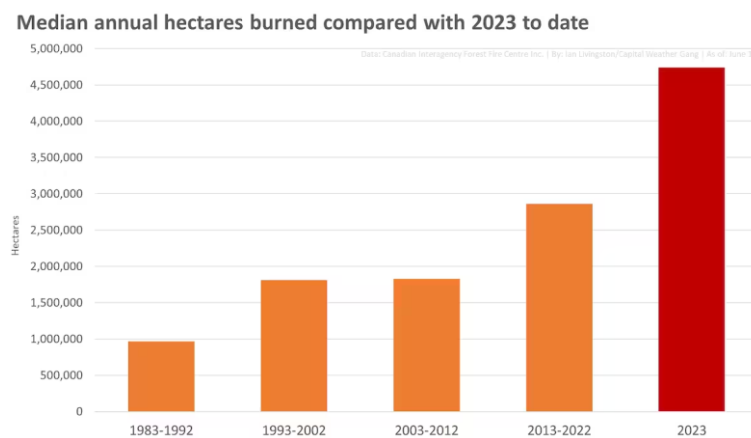
1. PENDAHULUAN

Kebakaran hutan dan lahan merupakan masalah lingkungan yang serius di seluruh dunia. Dampaknya dapat merusak ekosistem, mengancam kehidupan satwa liar, mengurangi kualitas udara, serta menimbulkan kerugian ekonomi dan sosial yang signifikan. Di Kanada, Lebih dari 4,7 juta hektar (11,6 juta *acre*) lahan telah terbakar, menjadikannya jumlah yang tertinggi yang pernah tercatat pada awal musim kebakaran ini. Hal ini mengejutkan mengingat fakta bahwa musim kebakaran baru saja dimulai, dan terdapat lebih banyak area yang terbakar dibandingkan dengan hampir semua musim kebakaran sejak pencatatan modern dimulai pada tahun 1983, kecuali tiga musim kebakaran sebelumnya[1].



Gambar 1. Jumlah Emisi Karbon Dalam Atmosfer

Ilustrasi yang diberikan dalam Gambar 1 menggambarkan besarnya jumlah karbon yang terlepas ke atmosfer sebagai akibat dari kebakaran yang terjadi tahun ini. Data tersebut konsisten dengan fakta bahwa luas lahan yang terbakar mencapai 4,7 juta hektar, dibandingkan dengan rata-rata 310.000 hektar pada tanggal 11 Juni, seperti yang dilaporkan oleh Pusat Kebakaran Hutan Antar-Lembaga Kanada.



Gambar 2. Trend Rata-rata Luas Lahan Yang Terbakar

Jumlah lahan yang terbakar dapat mengalami fluktuasi yang signifikan dari tahun ke tahun selama beberapa dekade terakhir. Namun, ada beberapa tahun di mana jumlah lahan yang terbakar cenderung stabil. Dalam rentang waktu antara tahun 1983 hingga 1992, selama musim kemarau, jumlah lahan yang terbakar kurang dari 1 juta hektar. Namun, angka ini hampir dua kali lipat pada periode 10 tahun berikutnya. Setelah mengalami sedikit penurunan, rata-rata luas lahan yang terbakar pada musim kemarau mencapai 2,8 juta hektar pada periode 2013-2022. Setiap tahun dalam dekade terakhir ini, lebih dari 1,4 juta hektar lahan terbakar, kecuali pada tahun 2020[2].

Data-data tersebut menunjukkan perlunya upaya mitigasi dan prediksi terhadap lahan-lahan yang rentan terhadap kebakaran. Salah satu solusi yang dapat digunakan adalah dengan mengintegrasikan teknologi *remote sensing* dan *deep learning*. Integrasi ini memungkinkan pengumpulan data dari jarak jauh menggunakan sensor di pesawat udara atau satelit, serta penerapan algoritma *deep learning* untuk menganalisis dan memprediksi wilayah-wilayah yang berpotensi mengalami kebakaran.

Dalam penelitian ini, kami mengembangkan prediksi wilayah rawan kebakaran menggunakan *dataset* gambar dari wilayah Kanada yang sebelumnya mengalami kebakaran. Kami menggunakan metode *deep learning* dengan *Convolutional Neural Network* (CNN) dan membandingkan 27 model berbeda serta menguji performanya dari sisi akurasi.

Kami melatih model-model tersebut menggunakan data gambar wilayah Kanada yang terbakar sebelumnya. Model-model CNN diperoleh dengan variasi arsitektur dan parameter yang berbeda guna mencapai prediksi yang akurat. Setelah tahap pelatihan, kami melakukan evaluasi kinerja setiap model dengan membandingkan hasil prediksi mereka dengan data sebenarnya wilayah yang terbakar di masa lalu.

Dalam menguji performa model, kami mempertimbangkan berbagai metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score*. Pendekatan ini membantu kami memilih model yang memberikan prediksi paling akurat dan dapat diandalkan dalam mengidentifikasi wilayah yang berpotensi mengalami kebakaran di masa depan.

Beberapa penelitian terdahulu yang serupa antara lain adalah penelitian yang berjudul *Soft-Weighted-Average Ensemble Vehicle Detection Method Based on Single-Stage and Two-Stage Deep Learning Models* yang dilakukan oleh Hai Wang dkk, 2020[3]. Kemudian penelitian yang dilakukan oleh Nivedhitha Mahendran dkk, 2019, yang berjudul *Sensor-Assisted Weighted Average Ensemble Model for Detecting Major Depressive Disorder*[4]. Penelitian ini memiliki tujuan penting dalam membantu pihak terkait seperti pemadam kebakaran dan pengelola sumber daya alam untuk mengambil langkah pencegahan yang efektif dan tepat. Dengan menggunakan metode *deep learning* dan analisis performa yang teliti, kami berharap dapat memberikan kontribusi positif dalam upaya mitigasi risiko kebakaran di wilayah Kanada dan sekitarnya.

2. METODE PENELITIAN

2.1 Instruments

Dataset yang digunakan dalam penelitian ini merupakan dataset publik yang berasal dari situs *Kaggle*[5]. Pada penelitian ini, dilakukan penggunaan *dataset* gambar yang berasal dari wilayah di Kanada yang sebelumnya pernah mengalami kebakaran. Dataset ini terdiri dari 42.850 gambar dengan ukuran 350x350 piksel, yang dibagi menjadi dua kelas, yaitu kebakaran hutan (*wildfire*) dan tidak terjadi kebakaran hutan (*no wildfire*). Dari total 42.850 gambar tersebut, sebanyak 70% digunakan untuk pelatihan (*training*), 15% untuk pengujian (*testing*), dan sisanya 15% digunakan untuk validasi data. Dalam proses pengolahan datanya, penelitian ini menggunakan bahasa pemrograman *Python*.

2.2 Remote Sensing

Penginderaan jarak jauh, atau *remote sensing*, adalah proses pengumpulan informasi tentang objek atau fenomena di permukaan Bumi menggunakan sensor yang terpasang pada pesawat atau satelit[6]. Teknologi *remote sensing* memungkinkan kita untuk mendapatkan data

tentang bumi yang luas secara cepat dan efisien tanpa harus berada di lokasi fisiknya. Data yang dikumpulkan dapat berupa gambar, spektrum elektromagnetik, atau parameter lain yang terkait dengan objek yang diamati[7].

2.3 Deep Learning

Deep learning merupakan salah satu cabang dari *machine learning* yang menggunakan struktur jaringan saraf tiruan (*artificial neural network*) dengan berbagai lapisan (*layer*) untuk mempelajari representasi *hierarkis* dari data [8]. Tujuan utama *deep learning* adalah untuk menggali fitur-fitur yang lebih kompleks dan abstrak dari data input, sehingga memungkinkan sistem untuk melakukan tugas-tugas seperti pengenalan gambar, pengenalan suara, pemrosesan bahasa alami, dan sebagainya dengan tingkat akurasi yang lebih tinggi. Pada klasifikasi, ada beberapa metrik yang dapat digunakan untuk mengevaluasi performa sebuah model. *Confusion Matrix* adalah sebuah matriks yang digunakan untuk mengevaluasi performa dari sebuah model klasifikasi, umumnya berisi *True Positive*(TP), *True Negative*(TN), *False Positive*(FP), dan *False Negative*(FN). Performa dengan menggunakan *confusion matrix* digunakan untuk melihat akurasi adalah persentari prediksi yang benar dengan rumus $TP+TN/TP+FP+TN+FN$, presisi adalah untuk menampilkan nilai prediksi positif dengan rumus $TP/TP+FP$, *recall* adalah gberfokus pada bagian dataset yang positif dengan rumus $TP/TP+FN$ dan *F1 score* adalah menggabungkan presisi dan recall dengan rumus $2TP/2TP+FN+FP$.



Gambar 3. Model Penelitian *Deep Learning*

2.4 Convolutional Neural Networks (CNN)

Convolutional Neural Networks (CNN) merupakan jenis arsitektur jaringan saraf tiruan (*artificial neural network*) yang dikhususkan untuk memproses data berbentuk citra [9]. Operasi konvolusi adalah operasi matematis yang digunakan untuk menggabungkan dua set data, yaitu *input* (sering kali dalam bentuk matriks) dan *kernel* (juga dikenal sebagai filter atau matriks bobot). Pada CNN, konvolusi digunakan untuk menerapkan filter pada citra input [10]. Filter bergerak melalui citra dengan langkah (*stride*) tertentu dan melakukan perkalian dan penjumlahan untuk menghasilkan peta fitur (*feature map*) yang merepresentasikan fitur-fitur penting dalam citra.

2.5 Residual Network Model

Model ResNet (*Residual Network*) adalah jenis arsitektur CNN yang dikembangkan oleh Kaiming tahun 2015[11]. *ResNet* terkenal karena kemampuannya dalam melatih jaringan saraf yang sangat dalam dengan lebih efisien dan mengatasi masalah degradasi yang terjadi pada jaringan yang semakin dalam.

Ide utama di balik *ResNet* adalah penggunaan blok residu (*residual block*) yang memperkenalkan *shortcut connections* (*skip connections*) dalam arsitektur CNN[12]. *Shortcut connections* memungkinkan aliran langsung dari input ke *layer output*, memungkinkan informasi asli untuk melintasi beberapa lapisan tanpa adanya penurunan yang signifikan.

2.6 Mobile Network Model

Model MobileNet adalah jenis arsitektur CNN yang dirancang khusus untuk penggunaan pada perangkat bergerak dengan sumber daya terbatas seperti *smartphone* atau perangkat *embedded*[13]. *MobileNet* bertujuan untuk memberikan keseimbangan antara akurasi dan kecepatan komputasi yang tinggi dalam jaringan yang lebih ringan.

Salah satu karakteristik utama *MobileNet* adalah penggunaan *depthwise separable convolution* yaitu membagi operasi konvolusi menjadi dua tahap terpisah: *depthwise convolution* dan *pointwise convolution*[14]. *Depthwise convolution* menerapkan *kernel* terpisah untuk setiap

saluran *input* secara independen, sedangkan *pointwise convolution* menggabungkan *output depthwise convolution* melalui konvolusi 1x1 untuk menghasilkan *output* akhir. Pendekatan ini mengurangi jumlah parameter dan operasi yang diperlukan, sehingga menjadikan *MobileNet* lebih efisien secara komputasional.

2.7 Visual Geometry Group Model

Model VGG (*Visual Geometry Group*) adalah jenis arsitektur CNN yang dikembangkan oleh tim peneliti VGG pada tahun 2014. Arsitektur VGG dikenal karena kedalaman lapisan yang dalam dan konfigurasi yang seragam[15].

Ciri khas utama dari model VGG adalah penggunaan konvolusi 3x3 dengan *stride* 1 dan penggunaan *pooling* maksimum 2x2 dengan *stride* 2. Dalam arsitektur VGG, *layer* konvolusi dan *pooling* ditempatkan secara berurutan untuk secara bertahap mengekstraksi fitur dari input[16]. VGG menunjukkan bahwa dengan menggunakan filter konvolusi kecil secara berulang, model dapat mempelajari representasi yang lebih kaya dan lebih kompleks dari data *input*.

2.8 Efficient Network Model

Model *EfficientNet* adalah jenis arsitektur CNN yang dikembangkan oleh Mingxing Tan et al. pada tahun 2019[17]. *EfficientNet* dirancang untuk mencapai tingkat akurasi yang tinggi dengan menggunakan jumlah parameter dan komputasi yang lebih efisien. *EfficientNet* menggabungkan tiga teknik utama untuk mencapai efisiensi yang tinggi: *scaling*, *compound scaling*, dan *neural architecture search* (NAS).

Teknik *scaling* mengukur kedalaman, lebar, dan resolusi gambar secara proporsional untuk mencari keseimbangan optimal antara efisiensi dan akurasi. Dengan memperbesar atau memperkecil model dalam skala yang terukur, *EfficientNet* dapat mencapai kinerja yang baik dengan jumlah parameter yang lebih sedikit. Lalu teknik *compound scaling* menggunakan faktor skala tunggal untuk memperbesar atau memperkecil kedalaman, lebar, dan resolusi secara proporsional. Dengan menggabungkan faktor skala ini, *EfficientNet* dapat mencapai tingkat efisiensi yang lebih tinggi. Teknik NAS digunakan untuk mencari struktur arsitektur yang optimal secara otomatis. Dalam kasus *EfficientNet*, teknik NAS digunakan untuk mencari blok-blok dasar yang optimal dan kemudian mengulangi blok-blok tersebut secara bertahap untuk membentuk arsitektur yang lebih dalam dan efisien[18].

2.9 Ensemble Learning

Dalam penelitian ini, metode *ensemble average* digunakan untuk meningkatkan akurasi prediksi. *Ensemble average* adalah teknik yang menggabungkan hasil prediksi dari beberapa model pembelajaran mesin. Teknik ini telah terbukti efektif untuk meningkatkan akurasi prediksi dalam berbagai bidang, termasuk klasifikasi gambar, klasifikasi teks, dan peramalan. Dalam penelitian ini, kami menggunakan *ensemble average* sederhana. *Ensemble average* sederhana adalah teknik yang paling dasar, yang hanya menghitung rata-rata dari hasil prediksi dari setiap model.

Pada penelitian terdahulu, *ensemble average* telah terbukti efektif untuk meningkatkan akurasi prediksi klasifikasi gambar. Misalnya, dalam penelitian[19], *ensemble average* digunakan untuk meningkatkan akurasi prediksi klasifikasi gambar dari 96,77% menjadi 98,7%. Dalam penelitian ini, kami berharap bahwa *ensemble average* juga dapat meningkatkan akurasi prediksi klasifikasi gambar yang kami lakukan.

3. HASIL DAN PEMBAHASAN


Data citra satelit di Kanada dikumpulkan sebanyak 42.850 gambar, yang terbagi menjadi 22.710 gambar wilayah yang pernah mengalami kebakaran (*wildfire*) dan 20.140 gambar wilayah yang tidak mengalami kebakaran (*no wildfire*).

Gambar 4. *Dataset Wildfire*

Tabel 1. Komposisi Sampel Dataset


Kategori	Train	Test	Validasi
<i>Wildfire</i>	15.750	3.480	3.480
<i>No Wildfire</i>	14.500	2.820	2.820
Total	30.250	6.300	6.300

Dalam Tabel 1 dijelaskan mengenai komposisi sampel *dataset* yang akan digunakan dalam tahap pelatihan, pengujian, dan validasi. Berdasarkan tabel tersebut, terlihat bahwa 70 persen data digunakan sebagai data pelatihan, sedangkan 15 persen digunakan sebagai data pengujian dan 15 persen digunakan sebagai data validasi.




Gambar 5. Perbandingan Akurasi Model CNN

Dalam Gambar 5, terlihat histogram perbandingan akurasi dari berbagai model CNN yang telah dilatih dengan menggunakan 30.250 gambar. Dalam hasil tersebut, dapat dilihat bahwa model *MobileNet* mencapai akurasi tertinggi dibandingkan dengan model-model lainnya. Akurasi yang berhasil dicapai oleh model *MobileNet* mencapai 0,9640, menjadikannya sebagai model terbaik dalam penelitian ini. Selain memperhatikan tingkat akurasi, penelitian ini juga memperhitungkan waktu pelatihan (*training time*). Hal ini terlihat pada Gambar 10 yang menampilkan histogram waktu pelatihan dari setiap model.




Gambar 6. Perbandingan *Training Time Model CNN*

Selain mencapai akurasi yang tinggi, model *MobileNet* juga membutuhkan waktu pelatihan yang paling singkat dibandingkan dengan model-model lainnya (lihat Gambar 6). Dalam penelitian ini, waktu yang dibutuhkan untuk melatih model *MobileNet* tercatat sebesar 114,04 detik. Setelah menentukan model terbaik dalam penelitian ini, yaitu *MobileNet*, langkah selanjutnya adalah melakukan validasi pada *Model MobileNet* menggunakan *dataset* validasi.




Gambar 7. Perbandingan Akurasi saat *Training* dan Validasi *Model MobileNet*

Dalam Gambar 7 terlihat perbandingan akurasi model *MobileNet* antara saat *training* data dan saat validasi data. Terdapat dua garis yang berdekatan, menunjukkan bahwa akurasi yang dihasilkan pada saat *training* data dan validasi data hampir sama. Pada saat *training* data, akurasi yang tercapai adalah sebesar 0,9640, sedangkan pada saat validasi data, akurasi yang tercapai adalah sebesar 0,9646. Pada tahap validasi ini juga dihasilkan nilai *validasi loss*, yang digunakan untuk mengukur tingkat kehilangan atau kesalahan pada *dataset* validasi selama proses pelatihan atau evaluasi model. *Loss* merupakan perbedaan antara nilai target yang sebenarnya dan nilai prediksi yang dihasilkan oleh model. Semakin rendah validasi *loss*, semakin baik performa model dalam mempelajari pola-pola dari data validasi.



Gambar 8. Perbandingan Validasi Loss saat Training dan Validasi Model MobileNet

Dalam Gambar 8, terlihat bahwa garis validasi *Loss* berada di atas garis *Loss*. Pada saat *training* data, tercatat nilai *Loss* sebesar 0,0604, sementara pada saat validasi data, tercatat nilai *Loss* sebesar 0,0943. Ketika nilai *Loss* saat *training* lebih rendah dibandingkan dengan saat validasi, itu menunjukkan adanya indikasi model mengalami *overfitting* atau *overlearning*. *Overfitting* terjadi ketika model secara efektif "menghafal" data pelatihan, namun tidak mampu menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya, seperti data validasi. Ketika nilai *Loss* saat *training* lebih rendah, hal itu menunjukkan bahwa model berhasil mengurangi kesalahan dengan baik pada data pelatihan. Namun, jika nilai *Loss* saat validasi lebih tinggi, itu mengindikasikan bahwa model tidak dapat secara efektif meminimalkan kesalahan pada data validasi sebaik pada data pelatihan. Selanjutnya dilakukan evaluasi pengukuran performa dengan menggunakan *confusion matrix* untuk melihat akurasi, presisi, *recall* dan *F1 score*.




Gambar 9. Normalized Confusion Matrix

Gambar 9 merupakan representasi tabular dari hasil prediksi model yang membandingkan antara kelas yang sebenarnya dengan kelas yang diprediksi oleh model. Dalam *Normalized*

Confusion Matrix, setiap nilai dalam *Confusion Matrix* dinormalisasi terhadap jumlah total data dalam setiap kelas. Dengan demikian, matriks ini memberikan gambaran yang lebih rinci tentang tingkat keakuratan atau kesalahan dalam klasifikasi pada setiap kelas secara relatif.


Setelah mendapatkan nilai *True Positive*, *True Negative*, *False Positive*, dan *False Negative* maka dapat diketahui nilai pada metrik, maka didapatkan nilai *accuracy*, *precision*, *recall*, dan *f-1 score* untuk model *MobileNet* seperti pada Gambar 10.



Gambar 10. Evaluasi Performa Metrik pada *Model MobileNet*

Hasil perhitungan menunjukkan bahwa model memiliki tingkat akurasi yang sangat baik sebesar 0,979. Hal ini menandakan bahwa model mampu mengklasifikasikan data dengan tingkat keberhasilan yang tinggi. Model juga menunjukkan presisi yang tinggi sebesar 0,986, yang berarti kemampuan model untuk mengidentifikasi jumlah positif yang sebenarnya dari total yang diprediksi sebagai positif sangat akurat. Selain itu, *recall* model juga menunjukkan performa yang baik dengan nilai sebesar 0,973, menunjukkan kemampuan model untuk mengenali dengan tepat jumlah positif yang sebenarnya dari total yang sebenarnya positif.

Dengan nilai *F1 Score* sebesar 0,978, model menunjukkan keseimbangan yang baik antara presisi dan *recall*. *F1 Score* memberikan gambaran menyeluruh tentang kinerja model dalam memprediksi dengan akurat dan mengingat dengan baik. Secara keseluruhan, hasil perhitungan menunjukkan bahwa model memiliki kinerja yang sangat baik dalam melakukan klasifikasi, dengan tingkat akurasi tinggi, presisi yang baik, *recall* yang tinggi, dan *F1 Score* yang tinggi. Gambar 11 menunjukkan contoh hasil dari prediksi wilayah rawan kebakaran dengan menggunakan model *MobileNet*.



Gambar 11. Prediksi Wilayah Rawan Kebakaran Dengan Menggunakan *Model MobileNet*

Dalam penelitian ini, dilakukan pemodelan dengan menerapkan teknik *ensemble average* sebagai salah satu pendekatan untuk meningkatkan akurasi model. Meskipun demikian, hasil eksperimen menunjukkan bahwa penerapan *ensemble average* pada model yang sebelumnya memiliki akurasi sebesar 96,40 persen justru mengakibatkan penurunan menjadi 96,30 persen. Penurunan ini menarik untuk diperinci dan dipahami, terutama karena hasil yang tidak sesuai dengan ekspektasi awal.

Sejumlah penelitian sebelumnya telah mencatat bahwa hasil *ensemble* dapat bervariasi tergantung pada jenis data dan model yang digunakan. Dalam kaitannya dengan penurunan akurasi, temuan serupa telah diungkapkan dalam penelitian sebelumnya oleh Vahid Nourani, dkk, 2019[20], yang menyatakan bahwa *ensemble* mungkin tidak selalu menghasilkan peningkatan performa dan bahkan dapat menyebabkan penurunan akurasi dalam beberapa kasus. Dalam konteks ini, penurunan akurasi yang diamati mungkin disebabkan oleh fenomena serupa di mana kombinasi beberapa model tidak secara sinergis meningkatkan hasil, melainkan justru mengurangi performa keseluruhan.

4. KESIMPULAN

Hasil penelitian menunjukkan bahwa model *MobileNet* memiliki performa terbaik dengan akurasi 0,9640 dan waktu pelatihan yang singkat. Model ini juga berhasil melewati tahap validasi dengan akurasi, presisi, *recall*, dan *F1 Score* yang tinggi. Integrasi teknologi *remote sensing* dan *deep learning* memberikan kontribusi penting dalam upaya mitigasi risiko kebakaran dan pengelolaan sumber daya alam di wilayah Kanada.

Kesimpulan penelitian ini menunjukkan bahwa model *MobileNet*, yang dikembangkan dengan menggunakan teknologi *remote sensing* dan *deep learning*, mampu mengklasifikasikan wilayah-wilayah yang berpotensi mengalami kebakaran dengan tingkat akurasi yang tinggi. Hasil penelitian ini diharapkan memberikan landasan penting bagi pihak terkait, seperti pemadam kebakaran dan pengelola sumber daya alam, dalam mengambil langkah-langkah pencegahan yang efektif dan tepat. Dengan menggunakan metode *deep learning* dan analisis performa yang teliti, penelitian ini berpotensi menjadi dasar pengembangan sistem prediksi kebakaran yang lebih canggih dan dapat diandalkan di masa depan.

5. SARAN

Perlu ditekankan bahwa penurunan akurasi bukan selalu mengindikasikan kegagalan metode *ensemble average* secara mutlak. Namun, hasil ini menyoroti kompleksitas dan ketergantungan metode *ensemble* pada karakteristik khusus dataset dan model yang digunakan. Dengan demikian, penelitian lebih lanjut perlu dilakukan untuk menyelidiki faktor-faktor yang mungkin menyebabkan penurunan akurasi ini, sehingga dapat memberikan wawasan yang lebih mendalam tentang pengaruh *ensemble average* dalam konteks khusus penelitian ini.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Tim Redaksi Jurnal Teknik Politeknik Negeri Sriwijaya yang telah memberi kesempatan, sehingga artikel ilmiah ini dapat diterbitkan.

DAFTAR PUSTAKA

- [1] L. Ian, "Why Canada's wildfires are extreme and getting worse, in 4 charts," *washingtonpost*. <https://www.washingtonpost.com/Weather/2023/06/12/Canada-Record-Wildfire-Season-Statistics>.
- [2] Copernicus, "2023: A year of intense global wildfire activity | Copernicus," *Copernicus, Atmos. Monit. Serv.*, 2023, [Online]. Available: <https://atmosphere.copernicus.eu/2023-year-intense-global-wildfire-activity>.
- [3] H. Wang, Y. Yu, Y. Cai, X. Chen, L. Chen, and Y. Li, "Soft-Weighted-Average Ensemble Vehicle Detection Method Based on Single-Stage and Two-Stage Deep Learning Models," *IEEE Trans. Intell. Veh.*, vol. 6, no. 1, pp. 100–109, 2021, doi: 10.1109/TIV.2020.3010832.
- [4] N. Mahendran *et al.*, "Sensor-assisted weighted average ensemble model for detecting major depressive disorder," *Sensors (Switzerland)*, vol. 19, no. 22, 2019, doi: 10.3390/s19224822.
- [5] A. Aaba, "Wildfire Prediction Dataset (Satellite Images)." <https://www.kaggle.com/datasets/abdelghaniaaba/Wildfire-Prediction-Dataset>.
- [6] D. M. G. dela Torre, J. Gao, and C. Macinnis-Ng, "Remote sensing-based estimation of rice yields using various models: A critical review," *Geo-Spatial Inf. Sci.*, vol. 24, no. 4, pp. 580–603, 2021, doi: 10.1080/10095020.2021.1936656.
- [7] F. Wang, X. Yao, L. Xie, J. Zheng, and T. Xu, "Rice yield estimation based on vegetation index and florescence spectral information from UAV hyperspectral remote sensing," *Remote Sens.*, vol. 13, no. 17, pp. 1–19, 2021, doi: 10.3390/rs13173390.
- [8] D. A. Roberts, S. Yaida, and B. Hanin, "The Principles of Deep Learning Theory," *Princ. Deep Learn. Theory*, 2022, doi: 10.1017/9781009023405.
- [9] D. Bhatt *et al.*, "Cnn variants for computer vision: History, architecture, application, challenges and future scope," *Electron.*, vol. 10, no. 20, pp. 1–28, 2021, doi: 10.3390/electronics10202470.
- [10] L. Alzubaidi *et al.*, *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*, vol. 8, no. 1. Springer International Publishing, 2021.
- [11] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [12] Y. Lu, J. Graham, and J. Li, "Deep Learning Based Malware Classification Using Deep Residual Network," ... *2019 Model. Simul.*, no. May, 2019, [Online]. Available: https://www.researchgate.net/profile/Yan-Lu-7/publication/333058433_Deep_Learning_Based_Malware_Classification_Using_Deep_Residual_Network/links/5cd9aeaa299bf14d9594b7d5/Deep-Learning-Based-Malware-

- Classification-Using-Deep-Residual-Network.pdf.
- [13] Y. Kaya and E. Gürsoy, "A MobileNet-based CNN model with a novel fine-tuning mechanism for COVID-19 infection detection," *Soft Comput.*, vol. 27, no. 9, pp. 5521–5535, 2023, doi: 10.1007/s00500-022-07798-y.
 - [14] F. H. Tseng, K. H. Yeh, F. Y. Kao, and C. Y. Chen, "MiniNet: Dense squeeze with depthwise separable convolutions for image classification in resource-constrained autonomous systems," *ISA Trans.*, vol. 132, pp. 120–130, 2023, doi: 10.1016/j.isatra.2022.07.030.
 - [15] J. Amin, M. Almas Anjum, M. Sharif, S. Kadry, and R. Gonzalez Crespo, "Visual Geometry Group based on U-Shaped Model for Liver/Liver Tumor Segmentation," *IEEE Lat. Am. Trans.*, vol. 21, no. 4, pp. 557–564, 2023, doi: 10.1109/TLA.2023.10128927.
 - [16] J. Thomkaew and S. Intakosum, "Improvement Classification Approach in Tomato Leaf Disease using Modified Visual Geometry Group (VGG)-InceptionV3," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 12, pp. 362–370, 2022, doi: 10.14569/IJACSA.2022.0131244.
 - [17] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, 2019.
 - [18] S. Li *et al.*, "Hyperscale Hardware Optimized Neural Architecture Search," *Int. Conf. Archit. Support Program. Lang. Oper. Syst. - ASPLOS*, vol. 3, pp. 343–358, 2023, doi: 10.1145/3582016.3582049.
 - [19] W. Bakasa and S. Viriri, "Stacked ensemble deep learning for pancreas cancer classification using extreme gradient boosting," *Front. Artif. Intell.*, vol. 6, 2023, doi: 10.3389/frai.2023.1232640.
 - [20] V. Nourani, H. Gökçekuş, and I. K. Umar, "Artificial intelligence based ensemble model for prediction of vehicular traffic noise," *Environ. Res.*, vol. 180, p. 108852, 2020, doi: 10.1016/j.envres.2019.108852.