

KLASIFIKASI CITRA KEBAKARAN DAN NON KEBAKARAN MENGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*

Zaky Farhan Abror

*Fakultas Teknologi Industri Universitas Gunadarma
Jl. Margonda Raya No. 100, Depok 16424, Jawa Barat
zakyfarhan114@gmail.com*

Abstrak

Kebakaran menimbulkan kerugian yang dapat membahayakan jiwa maupun harta benda. Lokasi dan waktu terjadinya kebakaran sulit untuk diprediksi. Citra dari kamera CCTV dapat digunakan untuk memantau terjadinya kebakaran pada suatu lokasi. Dengan pemanfaatan perkembangan teknologi saat ini, data citra tersebut dapat diolah sehingga memberikan informasi terjadinya kebakaran pada suatu lokasi dengan lebih cepat dibandingkan secara manual. Salah satu metode yang dapat digunakan dalam pengolahan citra kebakaran adalah deep learning. Salah satu model deep learning yang memiliki kinerja terbaik dalam pengenalan dan klasifikasi citra yaitu Convolutional Neural Network (CNN). Penelitian terdiri dari beberapa tahap yaitu pengumpulan data, pra-pemrosesan data, pembagian data, perancangan arsitektur model CNN, pelatihan, pengujian, dan hasil. Jumlah data citra yang digunakan pada penelitian ini yaitu 950 citra yang terdiri dari 700 data pelatihan, 170 data validasi, dan 80 data pengujian. Arsitektur model CNN yang digunakan terdiri dari dua lapisan konvolusi dan dua lapisan pooling. Pada pelatihan, model dikenalkan dengan pola citra kebakaran dan non kebakaran kemudian divalidasi. Pada tahap pengujian, model mengklasifikasikan citra kebakaran dan non kebakaran. Tingkat akurasi model pada tahap pelatihan sebesar 98.8% dan pada tahap pengujian sebesar 90%.

Kata Kunci: CNN, deep learning, kebakaran, klasifikasi.

Abstract

Fires cause losses that can endanger lives and property. The location and time of the fire are difficult to predict. The image from a CCTV camera can be used to monitor the occurrence of a fire at a location. By utilizing current technological developments, the image data can be processed so as to provide information on the occurrence of fires at a location faster than manually. One method that can be used in fire image processing is deep learning. One of the deep learning models that has the best performance in image recognition and classification is Convolutional Neural Network (CNN). The study consisted of several stages, namely data collection, data pre-processing, data sharing, architectural design of the CNN model, training, testing, and results. The amount of image data used in this study is 950 images consisting of 700 training data, 170 validation data, and 80 testing data. The CNN architecture model used consists of two convolution layers and two pooling layers. In training, the model is introduced to fire and non-fire image patterns and then validated. In the testing phase, the model classifies fire and non-fire images. The accuracy of the model at the training stage was 98.8% and at the testing stage it was 90%.

Keywords: classification, CNN, deep learning, fire.

PENDAHULUAN

Kebakaran merupakan salah satu bencana nonalam yang dapat terjadi di hutan, lahan, perumahan atau pemukiman padat penduduk. Definisi kebakaran hutan dan lahan menurut Badan Nasional Penanggulangan Bencana (BNPB) adalah suatu keadaan di mana hutan dan lahan dilanda api, sehingga mengakibatkan kerusakan hutan dan lahan yang menimbulkan kerugian ekonomis dan atau nilai lingkungan. Definisi kebakaran secara umum menurut BNPB adalah situasi dimana bangunan pada suatu tempat seperti rumah atau pemukiman, pabrik, pasar, gedung, dan lain-lain dilanda api yang menimbulkan korban dan/atau kerugian [1]. Berdasarkan definisi kebakaran tersebut, kebakaran menimbulkan kerugian yang dapat membahayakan jiwa maupun harta benda.

Lokasi dan waktu terjadinya kebakaran sulit untuk diprediksi. Pemberian info terjadinya kebakaran di suatu tempat pada pihak berwenang yang dapat menanggulangi kebakaran memerlukan waktu jika dilakukan secara manual. Saat ini, kamera CCTV pada beberapa lokasi telah banyak dipasang untuk memantau setiap saat kejadian di lokasi tersebut. Citra dari kamera CCTV dapat digunakan untuk memantau terjadinya kebakaran pada suatu lokasi. Dengan pemanfaatan perkembangan teknologi saat ini, data citra tersebut dapat diolah sehingga memberikan informasi terjadinya kebakaran pada suatu lokasi dengan lebih cepat dibandingkan secara manual.

Penelitian mengenai pengolahan citra untuk identifikasi titik api telah dilakukan oleh Hardiyanto dan Sartika. Pada penelitian tersebut, pengolahan citra yang dilakukan adalah melakukan konversi citra foto udara dari UAV (*Unmanned Aerial Vehicle*) pada ruang warna RGB ke HSV. Hasil penelitian menunjukkan bahwa sistem deteksi api dari citra digital foto udara memiliki akurasi yang rendah jika objek api terlalu tinggi, titik api yang tertutup oleh asap tebal, dan titik api yang terlalu kecil [2].

Metode lain yang dapat digunakan dalam pengolahan citra kebakaran adalah *Machine Learning* (ML). ML adalah metode yang dapat belajar dari data (*data-driven method*) sehingga menjadi cerdas. Cerdas dalam artian memiliki kemampuan generalisasi terhadap data baru yang belum dipelajari sebelumnya. *Deep learning* adalah salah satu kelas dari algoritma *machine learning* yang memiliki *multiple layer* yang terdiri dari unit-unit *processing* yang nonlinier [3]. Salah satu model *deep learning* yang memiliki kinerja terbaik dalam pengenalan dan klasifikasi citra yaitu *Convolutional Neural Network* (CNN) [4,5]. CNN mampu melakukan proses pembelajaran mandiri untuk pengenalan objek, ekstraksi objek dan klasifikasi citra [6]. CNN merupakan arsitektur yang terinspirasi oleh sistem safaf biologi yang terdiri dari konvolusi, *pooling*, dan *fully-connected layers* [7]. Pada CNN setiap neuron dipresentasikan dalam bentuk dua dimensi, sehingga metode ini cocok untuk pemrosesan dengan *input* berupa citra [8].

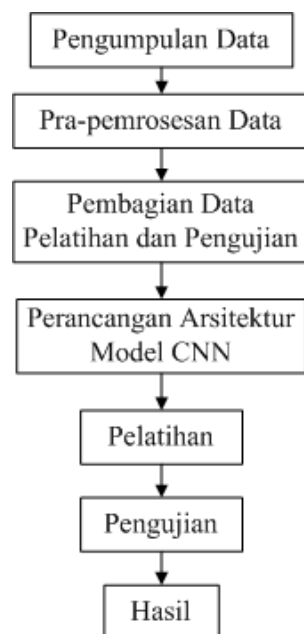
Penelitian menggunakan CNN dalam mengklasifikasi citra telah dilakukan oleh beberapa peneliti. Pada penelitian yang dilakukan oleh Suartika, Wijaya, dan Soelaiman membahas mengenai klasifikasi citra menggunakan CNN pada basis data Caltech 101. Hasil penelitian menunjukkan bahwa CNN cukup handal dalam mengklasifikasi citra pada basis data Caltech 101 [9]. Setiawan melakukan penelitian mengenai klasifikasi penyakit pada citra daun menggunakan CNN. Hasil penelitian yang dilakukan oleh Setiawan menunjukkan bahwa CNN dapat mengklasifikasi 9 jenis penyakit pada citra daun secara otomatis dengan akurasi yang baik [10]. Implementasi CNN terhadap citra instrumen alat musik gamelan menggunakan *keras* dilakukan oleh Pradana.

Hasil uji coba menunjukkan bahwa klasifikasi terhadap citra instrumen alat musik gamelan yaitu bonang, gambang dan kendang memiliki akurasi yang baik [11].

Oleh karena itu, pada penelitian ini dilakukan klasifikasi pada citra kebakaran dan non kebakaran menggunakan CNN. Hasil klasifikasi citra diharapkan dapat mendeteksi dini terjadinya kebakaran pada lokasi tertentu sehingga dapat ditanggulangi dengan lebih cepat.

METODE PENELITIAN

Penelitian ini bertujuan untuk mengklasifikasikan citra kebakaran dan non kebakaran menggunakan *Convolutional Neural Network*. Adapun tahapan penelitian dapat dilihat pada Gambar 1.



Gambar 1. Skema Penelitian

Berdasarkan Gambar 1, tahap awal penelitian dilakukan pengumpulan data citra

kebakaran dan non kebakaran. Setelah data dikumpulkan lalu dilakukan pra-pemrosesan

data citra. Tahap selanjutnya adalah pembagian data citra yaitu data untuk pelatihan dan pengujian. Setelah pembagian data selesai maka dilanjutkan dengan perancangan model *Convolutional Neural Network* (CNN). Model CNN yang telah dirancang lalu digunakan untuk proses pelatihan dan dilanjutkan untuk proses pengujian.

Pengumpulan Data

Dataset penelitian ini adalah citra kebakaran dan non kebakaran. Data tersebut diperoleh dengan cara *crawling* pada situs pencarian Google [12]. Jumlah citra yang terdapat pada *dataset* adalah 950 citra dengan *format* jpg.

Pra-pemrosesan Data

Sebelum dilakukan proses klasifikasi menggunakan CNN, citra terlebih dahulu dilakukan pra-pemrosesan. Citra kebakaran dan non kebakaran yang telah dikumpulkan memiliki ukuran piksel yang berbeda-beda. Oleh karena itu, tahapan pra-pemrosesan data yang dilakukan adalah mengubah ukuran piksel citra asli sehingga setiap citra memiliki ukuran yang sama yaitu 150×150 piksel.

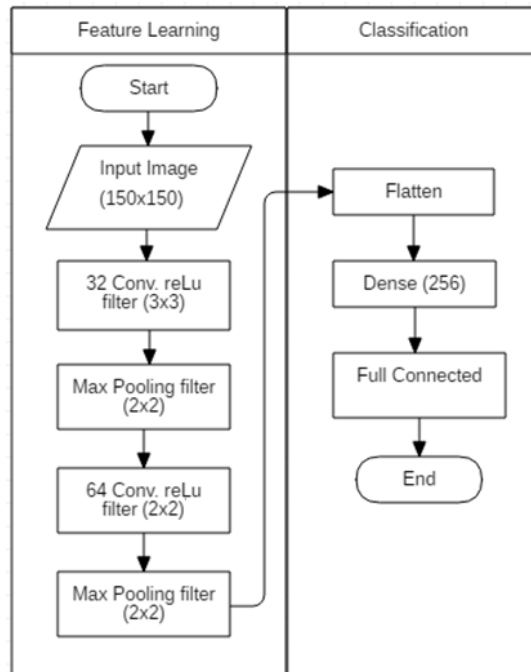
Pembagian Data

Data citra kebakaran dan non kebakaran selanjutnya dibagi menjadi tiga jenis, yaitu data pelatihan, data validasi, dan data pengujian. Data pelatihan digunakan untuk melakukan pembelajaran, data validasi

digunakan untuk melakukan pengujian terhadap hasil pembelajaran pada tahap pelatihan dan data pengujian digunakan untuk melakukan pengujian setelah pelatihan. Data pelatihan sebanyak 700 citra, data validasi sebanyak 170 citra, dan data pengujian sebanyak 80 citra.

Perancangan Arsitektur Model CNN

Pada rancangan model CNN yang digunakan pada penelitian ini, citra masukan yang digunakan berukuran $150 \times 150 \times 3$. Dengan 150×150 merupakan panjang dan lebar citra serta 3 merupakan komponen warna yang dimiliki yaitu RGB (*Red, Green, Blue*). CNN yang digunakan terdiri dari 2 lapisan konvolusi dan 2 lapisan *pooling*. Citra masukan akan dikonvolusi pada langkah pertama dengan ukuran *filter layer* 3×3 , dimana proses konvolusi ini akan mereduksi baris dan kolom pada citra. Tahap selanjutnya adalah melakukan operasi *maxpooling*. Operasi yang dilakukan yaitu perkalian matriks antara hasil dari konvolusi sebelumnya yang berukuran 3×3 dengan *filter pooling* 2×2 . Pada tahap kedua dilakukan operasi konvolusi dengan ukuran *filter layer* 2×2 dan *filter pooling* 2×2 . Setelah proses konvolusi dan *pooling* telah selesai dilakukan selanjutnya proses *flatten* dan *fully connected*. Proses ini bertujuan untuk mengubah *feature map* hasil *pooling layer* ke dalam bentuk vektor. Gambar 2 merupakan rancangan dari model *Convolutional Neural Network* yang digunakan pada penelitian ini.



Gambar 2. Rancangan Arsitektur Model CNN

Pelatihan

Pada proses pelatihan, ada beberapa nilai parameter yang diinisialisasi antara lain jumlah *epoch* dan *learning rate*. Jumlah *epoch* dan *learning rate* yang memberikan akurasi optimum tidak diketahui. Oleh karena itu, pada penelitian ini dilakukan pelatihan menggunakan beberapa jumlah *epoch* dan beberapa nilai *learning rate* sehingga diperoleh jumlah *epoch* dan *learning rate* yang memberikan akurasi yang optimum.

Pengujian

Setelah melakukan proses pelatihan pada model, dilakukan proses pengujian untuk menguji model tersebut mengklasifikasi citra sesuai dengan kelasnya. Proses pengujian akan dilakukan menggunakan data pengujian sebanyak 80 citra.

Hasil Klasifikasi

Penentuan baik atau tidaknya performa suatu model klasifikasi dapat dilihat dari parameter pengukuran performanya, yaitu tingkat akurasi, sensitivitas, dan presisi. Untuk menghitung faktor-faktor tersebut diperlukan sebuah matriks yang biasa disebut *confusion matrix*. Beberapa nilai di dalam *confusion matrix* yaitu: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Seluruh kemungkinan kejadian sebenarnya positif (P) dan seluruh kemungkinan kejadian sebenarnya negatif (N). Nilai tersebut dapat digunakan untuk menghitung akurasi dengan Persamaan (1).

$$\text{Akurasi} = \frac{TP + TN}{P + N} \quad (1)$$

Sementara untuk menghitung tingkat presisi prediksi kejadian dapat digunakan Persamaan (2).

$$\text{Presisi} = \frac{TP}{TP + FP} \quad (2)$$

Sensitivitas dapat dihitung dengan menggunakan Persamaan (3).

$$\text{Sensitifitas} = \frac{TP}{TP + FN} \quad (3)$$

HASIL DAN PEMBAHASAN

Hasil Pengumpulan Data

Data yang telah dikumpulkan untuk klasifikasi citra kebakaran dan non kebakaran berjumlah 950 citra. Contoh data citra yang telah dikumpulkan dapat dilihat pada Gambar 3.



Gambar 3. Contoh Data Citra

Hasil Pra-pemrosesan Data

Data citra yang terkumpul memiliki ukuran yang berbeda sehingga dilakukan pra-pemrosesan data agar seluruh citra masukan memiliki ukuran yang sama. Gambar 4(a) merupakan contoh citra asli sebelum

dilakukan perubahan ukuran citra dan Gambar 4(b) adalah citra yang sudah dilakukan perubahan ukuran. Ukuran citra asli yaitu 2800×1866 piksel dan ukuran citra setelah dilakukan perubahan ukuran yaitu 150×150 piksel.



(a)



(b)

Gambar 4. Hasil Perubahan Ukuran Citra

Hasil Pembagian Data

Setelah pra-pemrosesan data citra dilakukan lalu data tersebut dibagi menjadi tiga jenis data dengan jumlah yang berbeda.

Data pelatihan sebanyak 700 citra, data validasi sebanyak 170 citra, dan data pengujian sebanyak 80 citra yang dapat dilihat pada Tabel 1.

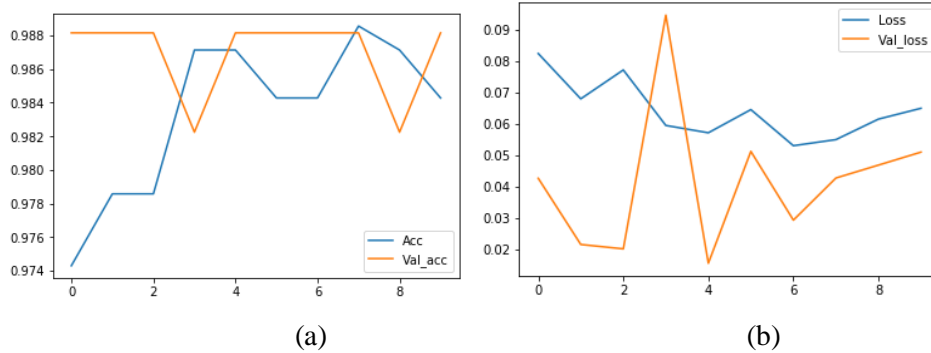
Tabel 1. Jumlah Data Pelatihan, Validasi, dan Pengujian

<i>Dataset</i>	Data Pelatihan	Data Validasi	Data Pengujian	Jumlah
Citra Kebakaran	350	85	40	475
Citra Non Kebakaran	350	85	40	475
Jumlah	700	170	80	950

Hasil Pelatihan dengan Beberapa Epoch

Pada tahap pelatihan dilakukan dengan beberapa jumlah *epoch* yaitu 10, 25, dan 50. Hasil pelatihan dengan *epoch* 10 dan nilai *learning rate* 0.0001 diperoleh nilai *loss* yaitu

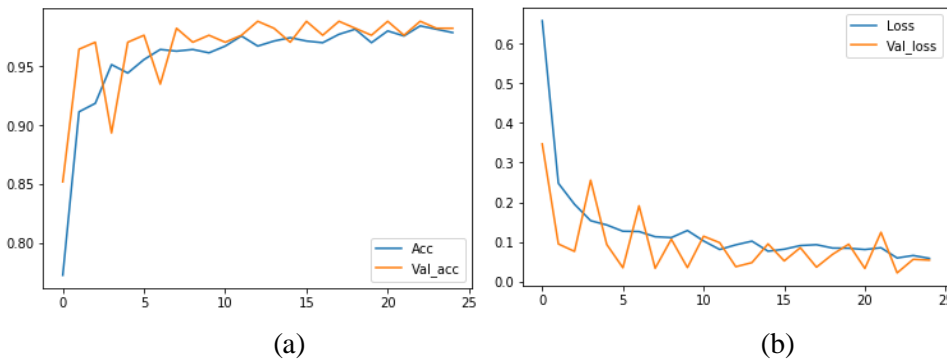
6.4%, nilai akurasi yaitu 98.4%, nilai validasi *loss* yaitu 51%, dan nilai validasi akurasi yaitu 98.8% dengan waktu 5 menit. Grafik hasil pelatihan dengan *epoch* 10 dapat dilihat pada Gambar 5.



Gambar 5. Grafik Hasil Pelatihan dengan Epoch 10

Gambar 5(a) merupakan grafik model akurasi dan Gambar 5(b) merupakan grafik model *loss*. Berdasarkan Gambar 5, akurasi


model hasil pelatihan dengan *epoch* 10 belum optimum karena grafik yang dihasilkan tidak konvergen.



Gambar 6. Grafik Hasil Pelatihan dengan Epoch 25

Selanjutnya dilakukan pelatihan dengan *epoch* 25 dan nilai *learning rate* 0.0001. Berdasarkan hasil pelatihan diperoleh nilai *loss* yaitu 7.5%, nilai akurasi yaitu 98.2%, nilai validasi *loss* yaitu 8.4% dan nilai validasi akurasi yaitu 98.8% dengan waktu 18 menit. Gambar 6 menunjukkan grafik hasil pelatihan dengan *epoch* 25. Berdasarkan Gambar 6, akurasi model hasil pelatihan dengan *epoch* 25 sudah optimum karena grafik yang

dihasilkan konvergen. Grafik hasil pelatihan dengan *epoch* 50 dan nilai *learning rate* 0.0001 dapat dilihat pada Gambar 7. Nilai *loss* hasil pelatihan yaitu 38.1%, nilai akurasi yaitu 98.4%, nilai validasi *loss* yaitu 2.6%, dan nilai validasi akurasi yaitu 98.8 dengan waktu 24 menit. Berdasarkan Gambar 7, akurasi model hasil pelatihan dengan *epoch* 50 juga optimum karena grafik yang dihasilkan konvergen.



Gambar 7. Grafik Hasil Pelatihan dengan *Epoch* 50

Tabel 2 merupakan perbandingan nilai *loss*, akurasi, validasi *loss*, dan validasi akurasi dengan beberapa jumlah *epoch* yaitu 10, 25, dan 50. Berdasarkan Tabel 2, *loss* terkecil terjadi pada *epoch* 50 yaitu 3.81%, akurasi tertinggi


terjadi pada saat *epoch* 10 dan 50, validasi *loss* terendah terjadi pada saat *epoch* 50, dan validasi akurasi tertinggi terjadi pada semua *epoch*. Oleh karena itu dapat disimpulkan bahwa pada *epoch* 50 memiliki akurasi yang optimum.

	10	25	50
<i>Loss</i>	6.4%	7.5%	3.81%
<i>Accuracy</i>	98.4%	98.2%	98.4%
Validasi <i>Loss</i>	51%	8.4%	2.6%
Validasi <i>Accuracy</i>	98.8%	98.8%	98.8%

Hasil Pelatihan dengan Beberapa *Learning Rate*

Hasil pelatihan dengan nilai *learning rate* 0.01 diperoleh nilai *loss* yaitu 805.9%, nilai akurasi yaitu 50%, nilai validasi *loss* yaitu 810.67%, dan nilai validasi akurasi yaitu


49.7% dengan waktu 10.5 menit. Gambar 8 menunjukkan grafik hasil pelatihan dengan nilai *learning rate* 0.01. Akurasi model hasil pelatihan dengan nilai *learning rate* 0.01 belum optimum karena grafik yang dihasilkan tidak konvergen.



Gambar 8. Grafik Hasil Pelatihan dengan *Learning Rate* 0.01

Hasil pelatihan dengan nilai *learning rate* 0.001 diperoleh nilai *loss* yaitu 1.89%, nilai akurasi yaitu 96.2%, nilai validasi *loss* yaitu 2%, dan nilai validasi akurasi yaitu 98.8%


dengan waktu 13.2 menit. Akurasi model hasil pelatihan dengan nilai *learning rate* 0.001 juga belum optimum karena grafik yang dihasilkan tidak konvergen seperti terlihat pada Gambar 9.



Gambar 9. Grafik Hasil Pelatihan dengan *Learning Rate* 0.001

Hasil pelatihan dengan nilai *learning rate* 0.001 diperoleh nilai *loss* yaitu 7.5%, nilai akurasi yaitu 98.2%, nilai validasi *loss* yaitu 8.4%, dan nilai validasi akurasi yaitu 98.8%

dengan waktu 17.6 menit. Akurasi model hasil pelatihan dengan nilai *learning rate* 0.0001 sudah optimum karena grafik yang dihasilkan konvergen seperti terlihat pada Gambar 10.



Gambar 10. Grafik Hasil Pelatihan dengan *Learning Rate* 0.0001

Tabel 3 menunjukkan perbandingan nilai *loss*, akurasi, validasi *loss*, dan validasi akurasi beberapa *learning rate*, yaitu 0.01, 0.001 dan 0.0001. Berdasarkan Tabel 3, *loss* terkecil terjadi pada *learning rate* 0.001 yaitu 1.89%, akurasi tertinggi terjadi pada saat

learning rate 0.0001, validasi *loss* terendah terjadi pada saat *learning rate* 0.02, dan validasi akurasi tertinggi terjadi pada *learning rate* 0.001 dan 0.0001. Oleh karena itu, nilai *learning rate* 0.0001 sudah memberikan akurasi yang optimum dan grafik model yang konvergen.

Tabel 3. Perbandingan *Learning Rate*

	0.01	0.001	0.0001
<i>Loss</i>	805.9%	1.89%	7.5%
<i>Accuracy</i>	50%	96.2%	98.2%
Validasi <i>Loss</i>	810.67%	2%	8.4%
Validasi <i>Accuracy</i>	49.7%	98.8%	98.8%

Hasil Pengujian

Hasil dari proses pengujian akan ditampilkan dalam sebuah *confusion matrix* pada Tabel 4. Berdasarkan Tabel 4, hasil yang didapatkan dari pengujian terhadap model yang telah dilatih cukup baik. Hal ini dapat dilihat dengan prediksi benar yang didapatkan.

Prediksi citra kebakaran diklasifikasikan dengan benar ke dalam kebakaran sebanyak 36 citra dengan kesalahan sebanyak 4 citra yang diklasifikasikan ke dalam kelas non kebakaran. Prediksi citra non kebakaran dengan benar sebanyak 40 citra dan tidak terdapat kesalahan klasifikasi ke dalam kelas kebakaran.

Tabel 4. *Confusion Matrix*

Matriks		Kelas Prediksi	
		Kebakaran	Non Kebakaran
Kelas Sebenarnya	Kebakaran	36	4
	Non Kebakaran	0	40

Berdasarkan Tabel 4 dapat dihitung akurasi, presisi, dan sensitivitas yang didapat setelah melakukan proses pelatihan.

$$\text{Akurasi} = \frac{76}{80} \times 100\% = 90\%$$

$$\text{Presisi} = \frac{36}{36} \times 100\% = 100\%$$

$$\text{Sensitivitas} = \frac{36}{40} \times 100\% = 90\%$$

Berdasarkan Tabel 4, terlihat bahwa akurasi dari data citra non kebakaran lebih baik dibandingkan data citra kebakaran. Ini terjadi dikarenakan citra non kebakaran yang diuji memiliki kondisi citra yang berbeda. Pada citra non kebakaran, citra cenderung memiliki warna yang bervariasi dibandingkan warna citra kebakaran yang didominasi warna merah. Ketika citra memiliki warna merah yang sedikit maka hasilnya akan kurang baik, sehingga tingkat kecocokan model dengan citra yang diuji berkurang. Hal ini yang mempengaruhi hasil dari pengujian terhadap model sehingga tingkat akurasi yang didapatkan lebih kecil.

KESIMPULAN DAN SARAN

Implementasi *Convolutional Neural Network* untuk klasifikasi citra kebakaran dan non kebakaran didapatkan hasil yang baik. CNN yang digunakan terdiri dari 2 lapisan konvolusi, 2 lapisan *pooling* 2×2, 1 lapisan *flatten* layer dan 1 lapisan *dense*. Tingkat akurasi yang diperoleh dari model *Convolutional Neural Network* dengan nilai *learning rate* 0,0001 dan jumlah *epoch* sebanyak 50 mendapatkan akurasi validasi

sebesar 98.8% dan validasi *loss* sebesar 2.6%. Oleh karena itu dapat disimpulkan bahwa implementasi *deep learning* menggunakan CNN mampu melakukan klasifikasi citra kebakaran dan non kebakaran dengan baik. Hasil klasifikasi pada data baru sebanyak 80 citra memiliki akurasi 90%.

Klasifikasi citra kebakaran dan non kebakaran pada penelitian ini belum bersifat *real time*. Pada pengembangan penelitian selanjutnya, proses klasifikasi citra ini dapat bersifat *real time* sehingga dapat diimplementasikan sehingga dapat digunakan oleh umum dalam bentuk aplikasi.

DAFTAR PUSTAKA

- [1] Badan Nasional Penanggulangan Bencana, *Definisi dan jenis bencana*, Jakarta, 2019.
- [2] D. Hardiyanto dan D. A. Sartika, "Identifikasi titik api menggunakan pengolahan citra foto udara," Simposium Nasional RAPI XVII, FT UMS, 2018, hal 51 – 58.
- [3] J. Schmidhuber, "Deep learning in neural networks: an overview," *Neural Networks*, vol. 61, hal. 85 – 117, 2015.
- [4] D. C. Ciresan, U. Meier, J. Masci, L. M. Gambardella, J. Schmidhuber, "Flexible, high performance convolutional neural networks for image classification," *Prosiding Twenty-Second International Joint*

- Conference on Artificial Intelligence, 2011, hal. 1237 – 1242.
- [5] A. Krizhevsky, I. Sutskever, dan G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” *Prosiding Advances in Neural Information Processing System (NIPS)*, 2012, hal. 1097 – 1105.
- [6] C. Zhang, I. Sargent, X. Pan, A. Gardiner, J. Hare, dan P. M. Atkinson, “VPRS-based regional decision fusion of CNN and MRF classifications for very fine resolution remotely sensed images,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 8, hal. 1 – 15, 2018.
- [7] F. Hu, G. S. Xia, J. Hu, dan L. Zhang, “Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery,” *Remote Sensing*, vol. 7, no. 11, hal. 14680 – 14707, 2015.
- [8] E. Maggiori, Y. Tarabalka, G. Charpiat, dan P. Alliez, “Convolutional neural networks for large scale remote-sensing image classification,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 5, no. 2, hal. 645 – 657, 2016.
- [9] I. W. E. P. Suartika, A. Y. Wijaya, dan R. Soelaiman, “Klasifikasi citra menggunakan *convolutional neural network* (CNN) pada caltech 101,” *Jurnal Teknik ITS*, vol. 5, no. 1, hal. 65 – 69, 2016.
- [10] M. Setiawan, “Klasifikasi penyakit pada citra daun menggunakan convolutional neural networks,” *Skripsi*, Institut Pertanian Bogor, Bogor, 2018.
- [11] S. C. Pradana, “Implementasi convolutional neural network terhadap instrumen alat musik gamelan menggunakan keras,” *Skripsi*, Universitas Islam Indonesia, Yogyakarta, 2018.
- [12] C. Olston dan M. Najork, “Web crawling,” *Foundations and Trends in Information Retrieval*, vol. 4, no. 3, hal. 176 – 246, 2010.