

Deteksi Api pada Video menggunakan Metode *Multi-Feature Fusion* dan CNN

1st Farhan Bary Maruanaya
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia

farhanmry@student.telkomuniversity.ac.id

2nd Febryanty Sthevanie
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia

sthevanie@telkomuniversity.ac.id

3rd Kurniawan Nur Ramadhani
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia

kurniawannr@telkomuniversity.ac.id

Abstrak—Kebakaran merupakan bencana yang memiliki dampak buruk bagi lingkungan dan juga menyebabkan kerugian yang signifikan terhadap harta benda serta kehidupan manusia. Deteksi api dengan perangkat sensor memiliki kelemahan di mana api harus berada dalam area tertentu untuk dapat memicu alarm. Pemanfaatan *computer vision* untuk mendeteksi api dalam video menunjukkan performa yang lebih baik dari pada deteksi menggunakan perangkat sensor. Deteksi api dengan *computer vision* memanfaatkan karakteristik api seperti warna, gerakan dan perpindahan tempat. Karakter warna api menunjukkan performa yang lebih baik dibandingkan dengan karakter lainnya, namun masih memiliki *false positive* yang tinggi saat ada objek yang memiliki warna menyerupai warna api. Pemanfaatan *deep learning* untuk menggantikan eksplorasi karakteristik api telah diteliti dan mampu menghasilkan prediksi yang lebih baik. Penelitian ini mencoba menggabungkan metode deteksi api dengan karakteristik gerak dan warna (*multi-feature fusion*) dengan metode *deep learning* CNN. Sistem yang dibangun memiliki akurasi 96,67% saat training dan mampu mengurangi deteksi *false positive* dari *multi-feature fusion*.

Kata kunci—*multi-feature fusion*, CNN, deteksi api, *computer vision*, deteksi warna, deteksi gerak

Abstract—Fire is a disaster that yield many negative impact for environment as well for human. Fire detection using sensor device has fundamental flaw where the fire must be in certain range to trigger the sensor. Application of computer vision shows superior performance against the conventional devices. It utilize natural feature such as color and movement. Fire color feature is the one that shows better accuracy than the other, although the rate of false positive in this case are still considerably high when there are objects that have color resembling fire. Use of deep learning in order to automatize the exploration of fire feature has been studied and shows better prediction. This study try to combine movement detection and color detection (*multi-feature fusion*) with deep learning CNN. Proposed system shows accuracy of 96,67% on training and help reducing false positive rate of *multi-feature fusion*.

Keywords— *multi-feature fusion*, CNN, fire detection, color detection, movement detection

I. PENDAHULUAN

Kebakaran memiliki dampak buruk bagi lingkungan dan menyebabkan kerugian yang signifikan terhadap harta benda dan kehidupan manusia. Pada 2019 *The International Association of Fire and Rescue Services* (CTIF) menerbitkan laporan yang mengemukakan terdapat 23,535 kebakaran bangunan di delapan belas kota terpilih dari seluruh dunia pada tahun 2017 dan 6581 korban kebakaran di empat puluh empat kota terpilih dari seluruh dunia pada rentang waktu 4 tahun (2013-2017) [2]. Kerusakan yang disebabkan kebakaran dapat memakan waktu hinggatahun untuk bisa dipulihkan.

Dengan cepatnya perkembangan teknologi, berbagai perangkat sensor telah dimanfaatkan sebagai alat deteksi dini kebakaran [5]. Berbagai sensor yang digunakan antara lain sensor asap, sensor temperatur, dan sensor infra merah [3, 9, 10, 13]. Meski sering digunakan dan dapat diandalkan, sensor-sensor ini memiliki kelemahan yang mendasar. Partikel asap perlu melakukan kontak langsung dengan sensor asap untuk memicu alarm. Sedangkan pada sensor temperatur, api harus berada pada jarak tertentu yang memungkinkan sensor membaca temperatur dari radiasi panas yang dipancarkan sumber api [6]. Selain itu berbagai sensor ini hanya efektif digunakan pada lingkungan yang tertutup, contohnya dalam bangunan. Hal ini menjadi kontra-produktif dengan tujuan awal penggunaan sensor ini sebagai alat deteksi dini kebakaran.

Pemanfaatan *computer vision* untuk mendeteksi keberadaan api memiliki performa yang dapat diandalkan dengan akurasi yang lebih baik [12]. Penelitian terdahulu telah mencoba menggunakan berbagai pendekatan untuk

mendeteksi api pada video atau gambar seperti deteksi tepian api dan identifikasi karakter warna. Penelitian menunjukkan bahwa deteksi api menggunakan *computer vision* dengan pendekatan karakter warna memiliki akurasi yang paling baik daripada metode lainnya [1, 15]. Senthil membahas penggunaan model warna *YCrCb*, *RGB*, *CIE Lab* dan menyimpulkan bahwa meskipun memiliki akurasi yang lebih baik daripada metode lainnya, deteksi api dengan pendekatan model warna belum memiliki akurasi yang baik. Zaidi et al. melakukan analisis untuk mendapatkan model warna yang paling akurat antara *RGB*, *Grayscale*, dan *YCrCb* untuk mendeteksi api. Penelitian ini menyimpulkan *YCrCb* mendeteksi api lebih akurat daripada *RGB*. Model warna *RGB* yang digabungkan dengan *YCrCb* mampu mendeteksi 100% api dalam gambar. Gong et al. mencoba menggabungkan deteksi *RGB* dan *HSI* (karakter statis) dari area video yang sudah dipilih dengan deteksi gerak (karakter dinamis). Metode ini mampu mendeteksi dengan akurasi 95.29%, namun metode ini masih memiliki *false positive* saat terdapat objek atau orang yang mengenakan warna seperti warna api. Deteksi api dari fitur statis dan dinamis sulit dilakukan karena membutuhkan informasi yang luas tentang karakter api dalam berbagai kondisi.

A. Latar Belakang

Penggunaan *deep learning* yang dapat menggantikan proses eksplorasi dan eksploitasi yang dibutuhkan untuk mengumpulkan informasi api dengan *training*. Deteksi dengan *deep learning* memiliki perbedaan dengan metode konvensional. Eksplorasi dan eksploitasi tidak dilakukan secara manual namun secara otomatis dihitung setelah *training* dengan *dataset*. Berbagai penelitian dengan pendekatan *deep learning* menggunakan metode *CNN* menunjukkan hasil yang jauh lebih baik daripada deteksi dengan metode konvensional [4, 7, 11, 17]. Namun metode ini masih memiliki kekurangan dalam menentukan lokasi dari objek yang bergerak untuk diidentifikasi sebagai api [8]. Penelitian ini akan menggabungkan deteksi gerak dan warna (*multi-feature fusion*) untuk menentukan area dari gambar yang dicurigai sebagai api, kemudian menjadikannya sebagai input untuk model *CNN*. Deteksi warna dengan kombinasi warna model *RGB* dan *YCrCb* akan digunakan karena memiliki akurasi yang baik. Area hasil identifikasi ini akan diinputkan ke model *CNN* dengan harapan dapat mengurangi *false positive* yang ada pada metode konvensional.

B. Topik dan Batasannya

Penelitian ini akan membahas penggunaan *multi-feature fusion* sebagai metode untuk menentukan area yang berisi api dalam suatu gambar yang akan digunakan sebagai input untuk *CNN* yang akan melakukan klasifikasi apakah area tersebut benar adalah area yang berisi api. Fitur api yang digunakan dalam metode *multi-feature fusion* adalah fitur gerak dan warna. Metode *three-frame differencing* akan digunakan untuk

mendeteksi gerak. Untuk deteksi warna api akan digunakan aturan yang menggunakan model warna *RGB* dan *YCbCr*. Model warna *RGB* digunakan karena mudah mengidentifikasi warna merah pada api. Namun model warna *RGB* memiliki *false alarm* yang tinggi untuk mendeteksi api karena model *RGB* tidak dapat membedakan tingkat iluminasi dari api. Aturan dengan menggunakan model warna *YCbCr* digunakan validasi terhadap hasil deteksi yang didapatkan model warna *RGB*. Hasil deteksi dari dua metode ini kemudian digunakan sebagai input untuk model *CNN* untuk menentukan apakah benar hasil deteksi tersebut adalah api. Dalam penelitian ini akan digunakan video offline untuk *train* dan menguji sistem yang dibangun.

C. Tujuan

Penelitian ini akan mengukur tingkat akurasi sistem untuk mendeteksi api. Sistem yang dibangun akan menggunakan metode *multi-feature fusion* dan *CNN*. Dalam metode *multi-feature fusion*, eksperimen akan dilakukan untuk mendapatkan parameter yang dapat menghasilkan akurasi yang lebih baik sebelum diteruskan ke sistem *CNN*.

D. Organisasi Tulisan

Terdapat lima bagian dalam penelitian ini. Bagian 2 akan membahas mengenai penelitian terdahulu yang telah dilakukan. Bagian 3 dan 4 akan membahas lebih detail mengenai hasil dan evaluasi dari penelitian yang dilakukan. Dalam bagian 5 akan disampaikan kesimpulan dari penelitian.

II. KAJIAN TEORI

Berbagai penelitian yang membahas sistem untuk mendeteksi api melalui video atau citra telah dilakukan. Senthil membahas berbagai model warna dan implikasinya ketika digunakan untuk mendeteksi fitur warna api. Penelitiannya menyimpulkan bahwa masing-masing model warna memiliki kelebihan dan kekurangan masing-masing. *YCbCr* memiliki persebaran warna api yang lebih merata. Meski begitu model warna *RGB* memiliki kelebihan dalam mendeteksi warna merah pada api, namun sangat tergantung dengan nilai dari warna lain sehingga lebih tidak stabil dalam melakukan prediksi. Model *CIE Lab* memiliki kelebihan karena tidak bergantung pada perangkat.

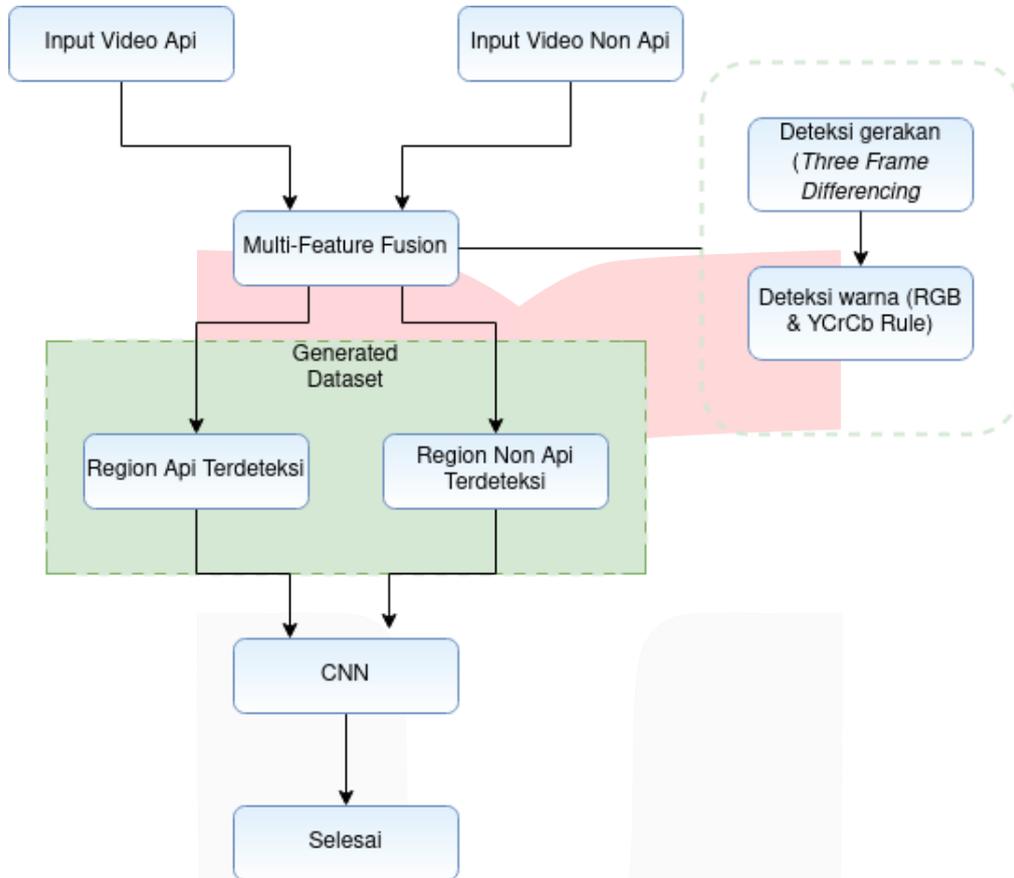
Zaidi et al. mencoba menggunakan model warna *RGB* dan *YCbCr* untuk mendeteksi api dengan mengaplikasikan sejumlah aturan terhadap setiap *pixel* pada gambar.

Gong et al. menggunakan gabungan metode *frame differencing* dan deteksi warna yang dikombinasikan dengan fitur api lain seperti pergerakan api dan titik tengah api. Namun metode ini masih memiliki tingkat *false alarm* yang tinggi. Dalam penelitiannya, sistem masih mendeteksi objek yang berwarna seperti api.

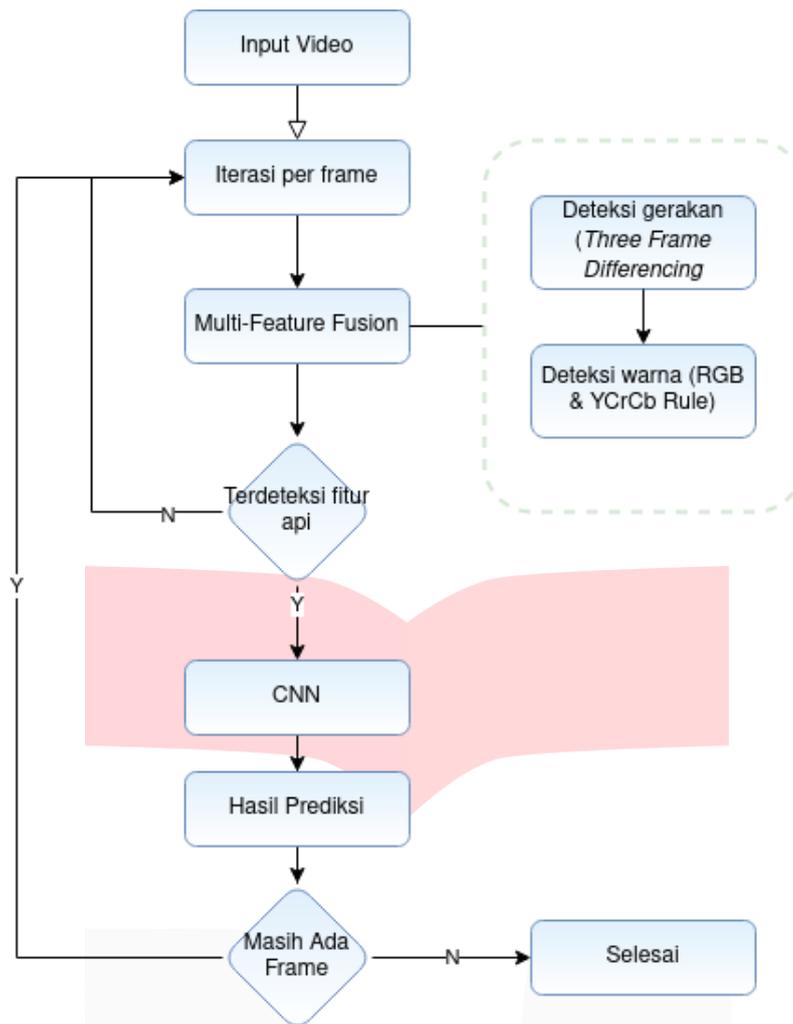
Deteksi api dengan *multi-feature fusion* yang

diverifikasi metode *KNN* [14] mampu memberikan akurasi sebesar 98.4%. Namun hasil deteksi untuk fitur lokal kurang baik sehingga sistem belum efektif untuk mendeteksi api dengan jarak yang jauh.

III. METODE



GAMBAR 1
ALUR TRAINING MODEL CNN



GAMBAR 2 ALUR SISTEM DETEKSI API

Tujuan dari penelitian ini adalah membangun sistem untuk mendeteksi api menggunakan metode *multi-feature fusion* yang digabungkan dengan CNN. Dataset untuk melakukan training pada model CNN akan dibuat dengan memberikan video yang hanya berisi api dan video yang tidak berisi api ke sistem *multi-feature fusion*. Hasil deteksi tersebut akan dikelompokkan menjadi kelas api dan non-api untuk digunakan sebagai dataset. Sistem ini terdiri dari dua tahap. Pada tahap pertama, metode *multi-feature fusion* digunakan untuk mendapatkan area dalam frame yang dicurigai sebagai api. Karakter api yang diamati dalam metode *multi-feature fusion* adalah gerakan dari api dan warna dari api. Algoritma *three-frame differencing* digunakan untuk mendeteksi gerakan dalam frame. Untuk mendapatkan warna api,

model warna RGB dan YCbCr akan digunakan dengan menerapkan aturan aturan yang mendeskripsikan warna api.

A. *Three frame differencing*

Gerakan pada video dapat dideteksi dengan membandingkan perubahan nilai *pixel* dari satu *frame* terhadap *frame* lainnya. Algoritma *three frame differencing* membandingkan lokasi *pixel* dari tiga *frame* berbeda untuk menentukan gerakan. *Frame* yang sedang diidentifikasi saat ini akan dibandingkan dengan *frame* di depannya yang ditentukan dengan *step*. Hasil perbandingan tiap *pixel* yang melebihi batas (*threshold*) tertentu akan dianggap sebagai gerakan.

$$F(x, y) = \begin{cases} 1, & |F_{c+s}(x, y) - F_c(x, y)| \cap |F_{c+(s*2)}(x, y) - F_{c+s}(x, y)| \geq T \\ 0, & |F_{c+s}(x, y) - F_c(x, y)| \cap |F_{c+(s*2)}(x, y) - F_{c+s}(x, y)| < T \end{cases} \quad (1)$$

di mana F_c adalah posisi *frame* saat ini.

B. Color detection

Beberapa aturan telah diteliti untuk menentukan karakteristik api berdasarkan warnanya. Dalam penelitian ini 2 model warna

akan digunakan, model warna RGB dan YCbCr. Dalam penelitian ini akan digunakan aturan sebagai berikut [16]

TABEL 1
ATURAN WARNA API

Model Warna	Rules
RGB	1) $R > G > B$
	2) $if R > Rmean \cap G > Gmean \cap B < Bmean$
YCbCr	3) $Y(x,y) >= Cb(x,y)$
	4) $Cr(x,y) >= Cb(x,y)$
	5) $Y(x,y) \geq Ymean \cap Cb(x,y) \leq Cbmean \cap Cr(x,y) \geq Crmean$
	6) $Cb(x,y) - Cr(x,y) \geq Th$
	7) $(Cb(x,y) \leq 120) \cap (Cr(x,y) \geq 150)$

1. CNN

CNN Klasik akan digunakan dalam penelitian ini karena area dari frame yang dicurigai telah ditentukan melalui metode multi-feature fusion. Pengembangan CNN seperti Faster R-CNN tidak didesain untuk menerima input Region proposal secara manual, sehingga CNN ini yang dipilih dalam penelitian ini.

Step	Threshold		
	20	25	30
1	0.167	0.417	0.667
3	0.083	0.083	0.167
5	0.083	0.167	0.167
10	0.250	0.333	0.333

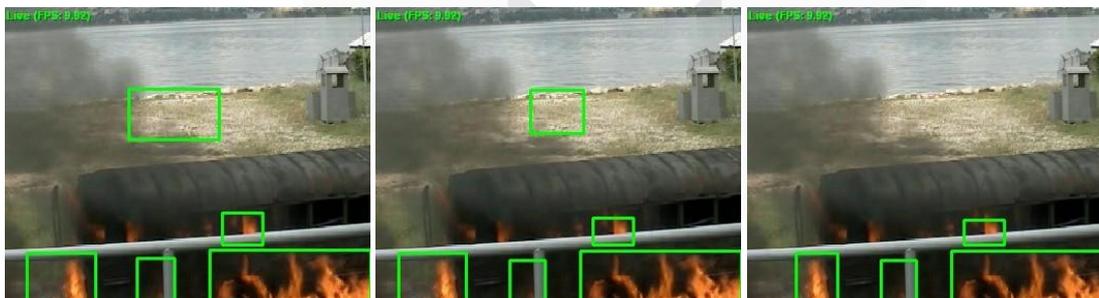
Percobaan dilakukan dengan mengamati hasil deteksi tiap parameter step dan threshold. Hasil deteksi ke- mudian diberi skor 1 - 3 dengan kriteria 1; tidak berhasil mendeteksi gerakan api atau banyak mendeteksi objek lain selain api. 2; berhasil mendeteksi pergerakan api namun masih banyak mendeteksi objek lain. 3; berhasil mendeteksi api dan tidak mendeteksi objek bergerak lainnya.

IV. HASIL DAN PEMBAHASAN

A. Three-Frame Differencing

TABEL 2
HASIL PERCOBAAN UNTUK MENENTUKAN STEP DAN THRESHOLD

Dari hasil percobaan didapatkan bahwa parameter frame differencing yang paling baik adalah dengan parameter step = 1 dan threshold = 30

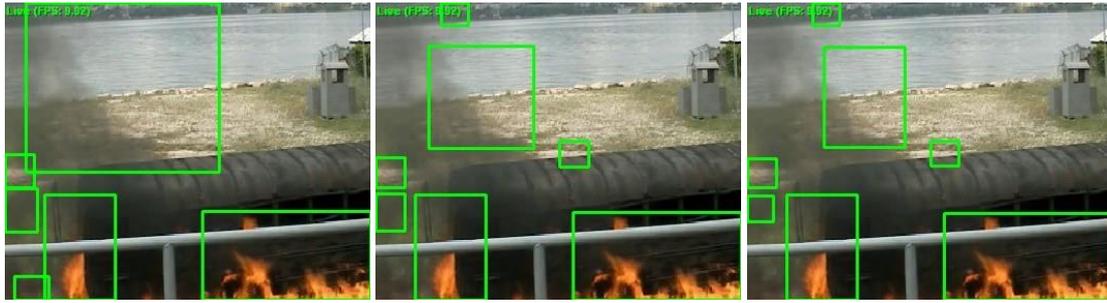


Threshold 20

Threshold 25

Threshold 30

Percobaan dengan step 1

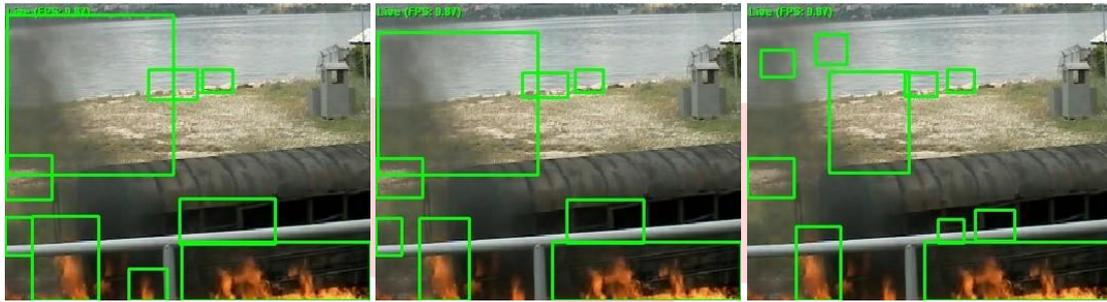


Threshold 20

Threshold 25

Threshold 30

Percobaan dengan step 5

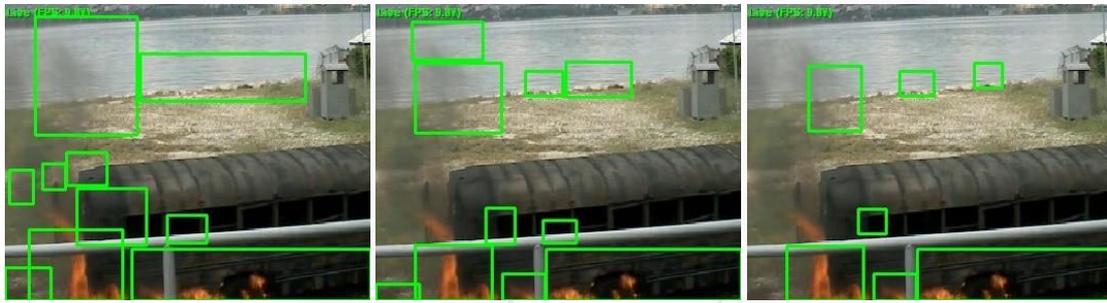


Threshold 20

Threshold 25

Threshold 30

Percobaan dengan step 3



Threshold 20

Threshold 25

Threshold 30

Percobaan dengan step 10

B. Color Detection



GAMBAR 7
HASIL DETEKSI WARNA

Dari hasil pengujian, didapatkan bahwa rule RGB yang digabungkan dapat mendeteksi lebih banyak pixel yang merupakan api dan lebih sedikit mendeteksi pixel yang mirip warna api. Perbandingan dari hasil deteksi warna dapat dilihat pada gambar 7.

bagian image yang berhasil dideteksi oleh multi-feature fusion.

Metode multi-feature fusion diaplikasikan terhadap video yang hanya berisi api dan video yang tidak berisi api sama sekali. Hasil deteksi kemudian disimpan sesuai kelasnya masing masing, dalam hal ini api dan non api. Hasil deteksi yang didapatkan adalah 38,948 file gambar api dan 9,056 gambar non api.

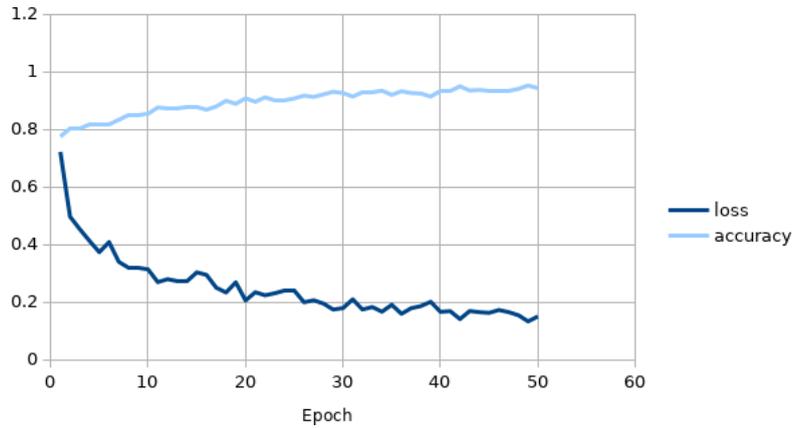
C. Hasil Pengujian Penjelasan dataset
Dataset yang digunakan adalah kumpulan

Hasil

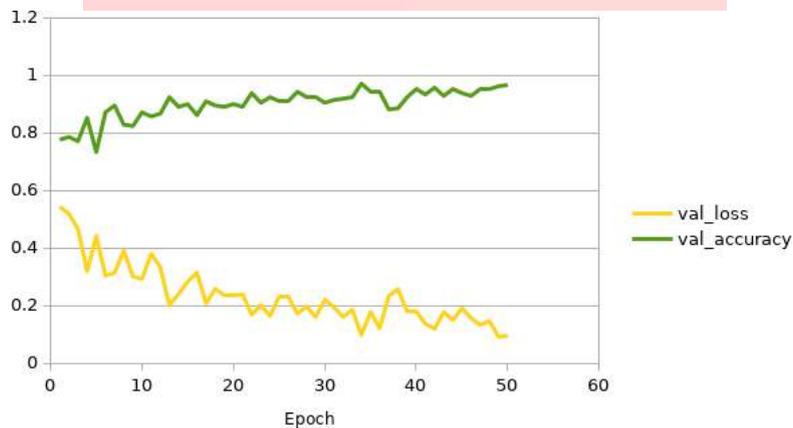
TABEL 3
HASIL TRAINING DAN TESTING CNN

Epoch	Loss	Accuracy	Val loss	Val Accuracy
1	0.7222	0.7755	0.543	0.7762
13	0.2719	0.8714	0.2006	0.9238
27	0.2061	0.9135	0.1719	0.9429
35	0.1906	0.9203	0.1775	0.9429
42	0.1408	0.95	0.1189	0.9571
50	0.1501	0.9438	0.0946	0.9667

GAMBAR 8
GRAFIK LOSS DAN AKURASI SAAT TRAINING



GAMBAR 9
GRAFIK LOSS DAN AKURASI SAAT TESTING



Tabel 3 adalah hasil training CNN dengan dataset yang telah dibuat. Untuk step setiap epoch adalah 15. Level akurasi terendah saat awal di train adalah 0.7755 sedangkan tertinggi adalah 0.95. Kolom Val loss dan Val Accuracy adalah hasil testing CNN.

Model yang telah di train ini mampu

mengurangi *false negative* dari metode multi-feature fusion. Pada gambar 10, kotak berwarna hijau adalah hasil deteksi dari metode multi-feature fusion, sedangkan kotak berwarna biru adalah hasil prediksi CNN. Namun CNN juga menurunkan sensitivitas dari deteksi.



GAMBAR 10
CNN MAMPU MENGURANGI FALSE NEGATIVE



GAMBAR 11
CNN MEMBUAT SISTEM KURANG SENSITIVE

C. Analisis Hasil Pengujian

Nilai step yang kecil pada metode *three frame differencing* menghasilkan deteksi yang lebih akurat terhadap posisi dari gerakan. Step yang kecil memiliki keuntungan karena sesuai dengan karakter api yang aktif bergerak namun cenderung tidak berpindah tempat. Nilai step yang besar cenderung dapat mendeteksi lebih banyak gerakan namun kurang akurat dalam menentukan posisi gerakan dikarenakan pada frame yang dibandingkan, objek yang bergerak dapat berada pada posisi yang jauh berbeda dari frame awal. Threshold dalam metode ini berperan untuk mengatur sensitivitas. Dengan threshold yang lebih besar, pergerakan yang tidak signifikan dapat diabaikan.

Dari grafik 9 didapatkan akurasi yang terus meningkat dalam tiap *epoch*. Namun nilai loss saat training cenderung stagnan setelah 40 *epoch* yang menandakan model tidak cukup bertambah baik. Model mampu mengurangi *false positive* pada sistem, namun juga menurunkan akurasi dalam mendeteksi api. Kualitas dataset bisa menjadi salah satu penyebab dari penurunan performa sistem

Masih banyak bagian yang bisa ditingkatkan dari sistem yang telah dibangun. Menggabungkan dua metode ini memiliki kelebihan dari waktu train yang relatif lebih singkat daripada langsung dengan satu frame berisi api. Namun meskipun ada penurunan nilai false positive, akurasi dari sistem belum bisa dikatakan baik karena menurunkan juga nilai *True positive* dari metode multi-feature fusion.

V. KESIMPULAN

Hasil training dan testing untuk model CNN yang telah dibangun memiliki tingkat akurasi hingga 96.67%. Dari hasil pengamatan, sistem mampu mengurangi *false positive* dari deteksi yang dilakukan metode multi-feature fusion. Namun deteksi terhadap api juga berkurang dikarenakan dataset yang digunakan untuk melatih model CNN merupakan gambar yang mempunyai resolusi relatif kecil sehingga sulit untuk mendapatkan fitur unik dari gambar tersebut. Masih banyak pengembangan yang bisa dilakukan terhadap sistem seperti mencoba mengubah jenis dataset. Pada penelitian di masa yang akan datang, nilai

dari parameter multi-feature fusion dalam penelitian ini dapat digunakan.

REFERENSI

- [1] P. Borges and E. Izquierdo. A Probabilistic Approach for Vision-Based Fire Detection in Videos. *Circuits and Systems for Video Technology, IEEE Transactions on*, 20:721 – 731, June 2010. doi: 10.1109/TCSVT.2010.2045813.
- [2] Brushlinsky N.N, M. Ahrens, and S. Sokolov. World fire statistics. Technical Report 24, Center of Fire Statistics of CTIF, State Fire Academy of Emercom of Russia, Russia.
- [3] J. Fonollosa, A. Solórzano, and S. Marco. Chemical Sensor Systems and Associated Algorithms for Fire Detection: A Review. *Sensors*, 18(2):553, Feb. 2018. ISSN 1424-8220. doi: 10.3390/s18020553. URL <http://www.mdpi.com/1424-8220/18/2/553>.
- [4] S. Frizzi, R. Kaabi, M. Bouchouicha, J.-M. Ginoux, E. Moreau, and F. Fnaiech. Convolutional neural network for video fire and smoke detection. *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*, pages 877–882, 2016. doi: 10.1109/IECON.2016.7793196.
- [5] A. Gaur, A. Singh, A. Kumar, K. S. Kulkarni, S. Lala, K. Kapoor, V. Srivastava, A. Kumar, and S. C. Mukhopadhyay. Fire Sensing Technologies: A Review. *IEEE Sensors Journal*, 19(9):3191–3202, May 2019. ISSN 1530-437X, 1558-1748, 2379-9153. doi: 10.1109/JSEN.2019.2894665. URL <https://ieeexplore.ieee.org/document/8625538/>.
- [6] F. Gong, C. Li, W. Gong, X. Li, X. Yuan, Y. Ma, and T. Song. A Real-Time Fire Detection Method from Video with Multifeature Fusion. *Computational Intelligence and Neuroscience*, 2019:1–17, July 2019. ISSN 1687-5265, 1687-5273. doi:

- 10.1155/2019/1939171. URL <https://www.hindawi.com/journals/cin/2019/1939171/>.
- [7] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer. - LEVEL ACCURACY WITH 50 X FEWER PARAMETERS AND < 0.5 MB MODEL SIZE. 2016.
- [8] B. Kim and J. Lee. A Video-Based Fire Detection Using Deep Learning Models. *Applied Sciences*, 9(14): 2862, July 2019. ISSN 2076-3417. doi: 10.3390/app9142862. URL <https://www.mdpi.com/2076-3417/9/14/2862>.
- [9] S. Krüger, M.-C. Despinasse, T. Raspe, K. Nörthemann, and W. Moritz. Early fire detection: Are hydrogen sensors able to detect pyrolysis of house hold materials? *Fire Safety Journal*, 91:1059–1067, 2017.
- [10] K. Lee, Y.-S. Shim, Y. Song, S. Han, Y.-S. Lee, and C.-Y. Kang. Highly Sensitive Sensors Based on Metal-Oxide Nanocolumns for Fire Detection. *Sensors*, 17(2):303, Feb. 2017. ISSN 1424-8220. doi: 10.3390/s17020303. URL <http://www.mdpi.com/1424-8220/17/2/303>.
- [11] K. Muhammad, J. Ahmad, Z. Lv, P. Bellavista, P. Yang, and S. W. Baik. Efficient Deep CNN-Based Fire Detection and Localization in Video Surveillance Applications. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 49(7):1419–1434, July 2019. ISSN 2168-2232. doi: 10.1109/TSMC.2018.2830099.
- [12] M. Senthil. Implications of Color Models in Image Processing for Fire Detection. *International Journal of Computer Applications*, 179(35):38–41, Apr. 2018. ISSN 09758887. doi: 10.5120/ijca2018916801. URL <http://www.ijcaonline.org/archives/volume179/number35/vadivu-2018-ijca-916801.pdf>.
- [13] R. Sowah, A. R. Ofoli, S. Krakani, and S. Fiawoo. Hardware module design of a real-time multi-sensor fire detection and notification system using fuzzy logic. In *2014 IEEE Industry Application Society Annual Meeting*, pages 1–6, Vancouver, BC, Canada, Oct. 2014. IEEE. ISBN 978-1-4799-2288-8. doi: 10.1109/IAS.2014.6978415. URL <http://ieeexplore.ieee.org/document/6978415/>.
- [14] X. Wang, Y. Li, and Z. Li. Research on flame detection algorithm based on multi-feature fusion. In *2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*, pages 184–189, Chongqing, China, June 2020. IEEE. ISBN 978-1-72814-390-3. doi: 10.1109/ITNEC48623.2020.9084825. URL <https://ieeexplore.ieee.org/document/9084825/>.
- [15] Z. Xu and J. Xu. Automatic Fire Smoke Detection Based on Image Visual Features. In *Proceedings of the 2007 International Conference on Computational Intelligence and Security Workshops, CISW '07*, pages 316–319, USA, 2007. IEEE Computer Society. ISBN 0-7695-3073-7.
- [16] N. Zaidi, N. Lokman, M. Daud, M. Achmad, and A. Khor. Fire recognition using RGB and YCbCr colorspace. 10:9786–9790, Jan. 2015.
- [17] Q. Zhang, J. Xu, L. Xu, and H. Guo. Deep Convolutional Neural Networks for Forest Fire Detection. 2016.doi: 10.2991/IFMEITA-16.2016.105.

