

# Analisis Ketepatan Model CNN dalam Deteksi Asap Berbasis Citra

<sup>1</sup>Juanto Simangunsong, <sup>2</sup>Mutiara S. Simanjuntak, <sup>3</sup>Nurmala Dewi Simanjuntak

<sup>1</sup>Akademi Manajemen Informatika dan Komputer Universal, <sup>2</sup>D4 Teknik Informatika Politeknik Negeri Lhokseumawe, <sup>3</sup>Universitas Nomensen

[juantosmg@gmail.com](mailto:juantosmg@gmail.com), [mutiara@pnl.ac.id](mailto:mutiara@pnl.ac.id), [nurmaladewisimanjuntak06@gmail.com](mailto:nurmaladewisimanjuntak06@gmail.com)

Submit : 29 Nov 2025 | Diterima : 21 Des 2025 | Terbit : 25 Des 2025

## ABSTRAK

Deteksi asap merupakan tahap kritis dalam sistem peringatan dini kebakaran, karena keberadaan asap biasanya muncul lebih dahulu sebelum api terlihat. Penelitian ini bertujuan untuk menganalisis ketepatan model Convolutional Neural Network (CNN) dalam mengklasifikasikan citra asap dan non-asap menggunakan *Smoke Detection Dataset*. Proses penelitian meliputi praproses citra, pelatihan model CNN, serta evaluasi performa menggunakan metrik akurasi, precision, recall, F1-score, dan Area Under Curve (AUC). Hasil penelitian menunjukkan bahwa model CNN mencapai akurasi sebesar 0.994, precision 0.69, recall 0.78, dan F1-score 0.73, sementara nilai AUC sebesar 0.992 menegaskan kemampuan diskriminatif model yang sangat tinggi. Confusion matrix mengungkapkan bahwa model efektif dalam mengidentifikasi citra non-asap maupun asap, meski masih terdapat kesalahan pada citra dengan intensitas asap rendah dan kondisi visual menyerupai asap. Secara keseluruhan, CNN terbukti menjadi metode yang andal dan efisien untuk deteksi asap berbasis citra, serta berpotensi dikembangkan lebih lanjut untuk aplikasi sistem deteksi kebakaran berbasis visi komputer.

Kata Kunci: Convolutional Neural Network, Deteksi Asap, Computer Vision, Smoke Detection Dataset, Klasifikasi Citra, Deteksi Kebakaran, AUC, Confusion Matrix.

## PENDAHULUAN

Deteksi asap merupakan salah satu komponen krusial dalam sistem peringatan dini kebakaran. Keterlambatan mendeteksi keberadaan asap dapat menyebabkan eskalasi api yang cepat dan berpotensi menimbulkan kerugian material, kerusakan lingkungan, serta ancaman keselamatan manusia. Pada sistem konvensional, deteksi asap umumnya mengandalkan sensor fisik berbasis kimia atau optik. Meskipun teknologi tersebut telah digunakan secara luas, sistem sensor tradisional memiliki sejumlah keterbatasan, seperti sensitivitas yang rendah terhadap variasi kondisi lingkungan, keterlambatan respons, serta tingginya tingkat *false alarm* pada kondisi tertentu. Oleh karena itu, dibutuhkan pendekatan alternatif yang lebih adaptif, akurat, dan mampu mengenali pola visual asap secara langsung.

Perkembangan teknologi *Computer Vision* dan *Deep Learning*, khususnya Convolutional Neural Network (CNN), menawarkan peluang besar untuk meningkatkan efektivitas deteksi asap berbasis citra. CNN memiliki kemampuan untuk mengekstraksi fitur visual secara otomatis pada berbagai tingkat kedalaman, sehingga mampu membedakan citra yang mengandung asap maupun tidak dengan tingkat ketepatan yang tinggi. Pendekatan berbasis citra ini dapat mendeteksi pola tekstur, intensitas, bentuk, dan dinamika asap yang sulit ditangkap oleh sensor tradisional. Selain itu, CNN telah terbukti unggul dalam berbagai bidang seperti klasifikasi gambar, segmentasi objek, dan deteksi pola visual kompleks, sehingga relevan untuk diterapkan pada skenario deteksi asap.

*Smoke Detection Dataset* digunakan sebagai sumber data utama dalam penelitian ini karena menyediakan kumpulan citra yang merepresentasikan berbagai kondisi visual terkait keberadaan asap. Dataset ini mencakup beragam skenario lingkungan, variasi intensitas asap, latar belakang, serta kondisi pencahayaan. Kompleksitas tersebut menuntut model CNN untuk memiliki kemampuan generalisasi yang baik agar mampu mendeteksi asap secara akurat di dunia nyata.

Analisis performa model pada dataset ini menjadi penting untuk memahami tingkat ketepatan maupun batasan CNN dalam mendeteksi asap berbasis citra.

Namun demikian, efektivitas model CNN tidak hanya ditentukan oleh arsitektur jaringan, tetapi juga faktor lain seperti kualitas dataset, metode augmentasi, parameter pelatihan, serta penanganan *overfitting* dan *class imbalance*. Oleh karena itu, diperlukan suatu penelitian komprehensif yang tidak hanya membangun model CNN, tetapi juga menganalisis ketepatan model secara menyeluruh melalui evaluasi metrik seperti akurasi, *precision*, *recall*, *F1-score*, kurva ROC, dan confusion matrix. Analisis ini akan memberikan gambaran mendalam mengenai kemampuan CNN dalam melakukan deteksi asap berbasis citra serta menentukan sejauh mana model dapat diimplementasikan pada sistem deteksi kebakaran modern.

Dengan latar belakang tersebut, penelitian ini dilakukan untuk mengkaji ketepatan model CNN dalam mendeteksi asap menggunakan Smoke Detection Dataset, sehingga dapat memberikan kontribusi bagi pengembangan teknologi deteksi kebakaran yang lebih responsif, cerdas, dan akurat. Penelitian ini menggunakan pendekatan kuantitatif berbasis *experimental research* untuk mengevaluasi ketepatan model Convolutional Neural Network (CNN) dalam mendeteksi asap pada citra. Tahapan metode penelitian disusun secara sistematis meliputi pengumpulan data, praproses citra, perancangan model, pelatihan, evaluasi performa, serta analisis hasil.

## TINJAUAN PUSTAKA

Tinjauan pustaka ini membahas teori-teori, konsep dasar, dan penelitian terdahulu yang menjadi landasan dalam analisis ketepatan model Convolutional Neural Network (CNN) dalam mendeteksi asap berbasis citra menggunakan *Smoke Detection Dataset*. Pembahasan meliputi definisi deteksi asap, pendekatan berbasis citra, arsitektur CNN, teknik evaluasi model klasifikasi citra, serta perkembangan penelitian terkait.

### 1. Deteksi Asap dalam Sistem Peringatan Dini Kebakaran

Deteksi asap merupakan tahap awal dalam sistem peringatan dini kebakaran (*fire early warning system*). Asap biasanya muncul sebelum nyala api sehingga mampu memberikan waktu respons lebih cepat. Deteksi asap secara umum terbagi menjadi dua pendekatan utama:

#### 1. Berbasis Sensor Fisik, seperti:

- Sensor optik
- Sensor ionisasi
- Sensor gas (CO, CO<sub>2</sub>, VOC)

Pendekatan ini sederhana namun sering mengalami keterbatasan, seperti *false alarm* akibat debu, uap air, atau kondisi lingkungan tertentu.

#### 2. Berbasis Citra (*Vision-Based Smoke Detection*)

Pendekatan ini menggunakan kamera pengawas untuk menganalisis pola visual asap. Keunggulannya:

- Deteksi lebih cepat dalam ruangan luas
- Tidak bergantung pada aliran udara
- Mampu bekerja pada area terbuka (*open space*)

Penelitian modern menunjukkan bahwa deteksi berbasis citra lebih unggul karena memungkinkan sistem melihat bentuk, tekstur, dan dinamika asap secara langsung.

### 2. Deteksi Asap Berbasis Citra (*Smoke Image Analysis*)

Deteksi asap berbasis citra melibatkan analisis pola visual seperti:

- Tekstur kabur (*hazy texture*)
- Gradien intensitas
- Pola penyebaran asap
- Warna abu-abu keputihan

Metode non-deep learning yang pernah digunakan antara lain:

- Analisis warna (RGB/HSV)

2. Deteksi tepi (*edge detection*)
3. Model statistik tekstur (GLCM, LBP)
4. Model latar belakang (*background subtraction*)

Namun, metode tersebut memiliki performa terbatas karena asap tidak memiliki bentuk yang konsisten.

### 3. *Convolutional Neural Network* (CNN)

CNN adalah *deep learning model* yang paling umum digunakan dalam analisis citra. CNN bekerja dengan cara mengekstraksi fitur visual secara bertingkat melalui beberapa komponen utama:

1. *Convolutional Layer*  
Menangkap fitur-fitur seperti tepi, tekstur, bentuk, dan pola asap.
2. *Activation Function (ReLU)*  
Memperkenalkan non-linearitas untuk menangkap hubungan kompleks.
3. *Pooling Layer*  
Mengurangi dimensi fitur untuk meningkatkan efisiensi dan menghindari overfitting.
4. *Fully Connected Layer*  
Berperan sebagai classifier pada tahap akhir.
5. *Output Layer*  
Menggunakan *sigmoid* untuk klasifikasi biner (smoke vs non-smoke).

CNN unggul pada tugas deteksi asap karena mampu mengenali variasi bentuk asap yang tidak teratur dan sulit dipetakan oleh metode tradisional.

### 4. Teknik Praproses Citra untuk Deteksi Asap

Praproses citra penting untuk meningkatkan kualitas input ke CNN. Beberapa teknik umum meliputi:

1. Normalisasi ukuran citra (misal 128×128)
2. Normalisasi piksel (0–1 atau -1–1)
3. Data augmentation, seperti:
  - a. Rotasi
  - b. Flipping
  - c. Adjust brightness
  - d. Random zoom/crop
4. Noise reduction untuk mengurangi gangguan visual

Augmentasi sangat penting dalam penelitian ini karena dataset asap biasanya imbalanced dan memiliki variasi terbatas.

## METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif berbasis *experimental research* untuk mengevaluasi ketepatan model Convolutional Neural Network (CNN) dalam mendeteksi asap pada citra. Tahapan metode penelitian disusun secara sistematis meliputi pengumpulan data, praproses citra, perancangan model, pelatihan, evaluasi performa, serta analisis hasil.

### 1. *Desain Penelitian*

Penelitian ini menggunakan desain eksperimen komputasional (*computational experiment*) dengan langkah-langkah utama:

1. Persiapan dataset citra asap dan non-asap.
2. Pelatihan model CNN pada subset data pelatihan.
3. Pengujian model pada data uji terpisah.
4. Evaluasi performa model menggunakan metrik kuantitatif.
5. Analisis ketepatan model berdasarkan hasil evaluasi.

Pendekatan ini dipilih karena CNN merupakan model *data-driven* yang membutuhkan eksperimen terkontrol untuk memperoleh kinerja optimal.

### 2. *Dataset Penelitian*

Dataset yang digunakan adalah Smoke Detection Dataset, yang terdiri dari dua kelas utama:

- a. Citra dengan asap (smoke)
- b. Citra tanpa asap (non-smoke)

Dataset mencakup variasi:

- a. Intensitas asap ringan hingga pekat
- b. Kondisi pencahayaan berbeda
- c. Latar belakang dan lingkungan beragam
- d. Jarak kamera dan perspektif bervariasi

Dataset dibagi menjadi tiga subset:

Tabel 1 Tiga Subset Dataset

Subset	Persentase	Fungsi
Training	70%	Pelatihan model CNN
Validation	15%	Tuning parameter & monitoring overfitting
Testing	15%	Evaluasi akhir performa model

### 3. *Praproses Citra*

Sebelum digunakan untuk pelatihan model, citra perlu diproses menjadi format yang seragam. Tahapan praproses:

#### a. *Normalisasi Ukuran Citra*

Citra diubah ke resolusi tetap, misalnya 128×128 piksel, agar sesuai dengan input layer CNN.

Tabel 2. Dataset Ringkas Smoke Detection Dataset

No	Nama File	Kelas	Intensitas Asap	Kondisi Pencahayaan	Lingkungan	Keterangan
1	smoke_001.jpg	Smoke	Pekat	Normal	Indoor	Asap terlihat jelas mendominasi area tengah gambar
2	smoke_015.jpg	Smoke	Sedang	Terang	Outdoor	Asap tertiuip angin, bentuk swirl tampak jelas
3	smoke_032.jpg	Smoke	Tipis	Redup	Outdoor	Asap sulit dibedakan dari background langit
4	smoke_041.jpg	Smoke	Sedang	Normal	Indoor	Asap muncul di sisi kiri gambar
5	smoke_076.jpg	Smoke	Tipis	Terang	Outdoor	Pola asap bercampur cahaya matahari
6	nonsmoke_010.jpg	Non-Smoke	–	Terang	Outdoor	Awan tipis terlihat, mirip asap ringan
7	nonsmoke_024.jpg	Non-Smoke	–	Redup	Indoor	Banyak noise pada sensor kamera
8	nonsmoke_037.jpg	Non-Smoke	–	Normal	Outdoor	Debu pada lensa menyebabkan kesalahan FP
9	nonsmoke_052.jpg	Non-Smoke	–	Terang	Indoor	Pantulan cahaya putih menyerupai kabut
10	nonsmoke_089.jpg	Non-Smoke	–	Normal	Outdoor	Background jelas tanpa indikasi asap

## HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil eksperimen pembangunan dan evaluasi model Convolutional Neural Network (CNN) untuk deteksi asap berbasis citra. Evaluasi dilakukan menggunakan *Smoke Detection Dataset* dengan membandingkan performa pelatihan dan pengujian berdasarkan metrik-metrik utama, termasuk akurasi, precision, recall, F1-score, ROC-AUC, serta analisis confusion matrix.

### 1. Hasil Pelatihan Model CNN

Model CNN dilatih selama 10 epoch dengan memanfaatkan data augmentasi untuk meningkatkan generalisasi. Kinerja pelatihan diamati melalui *training loss* dan *validation loss*, serta *training accuracy* dan *validation accuracy*.

#### a. Performa Loss

Kurva loss menunjukkan penurunan signifikan pada awal pelatihan. *Training loss* menurun dari 0.62 pada epoch pertama menjadi 0.22 pada epoch kesepuluh. Pola penurunan yang konsisten juga terlihat pada *validation loss*, yaitu dari 0.70 menjadi 0.37. Ketidakterpautan yang kecil antara kedua kurva menunjukkan bahwa model tidak mengalami *overfitting* yang berarti, dan mampu mempelajari pola-pola visual asap secara stabil.

#### b. Performa Akurasi

Akurasi meningkat secara konsisten pada tahap pelatihan. *Training accuracy* meningkat dari 0.78 menjadi 0.96, sedangkan *validation accuracy* meningkat dari 0.76 menjadi 0.95. Kedekatan nilai akurasi pelatihan dan validasi mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik.

### 2. Evaluasi Model Menggunakan Data Uji

Evaluasi performa dilakukan terhadap 15% data uji yang tidak digunakan selama pelatihan. Hasil evaluasi menunjukkan bahwa model CNN mampu mengklasifikasikan citra asap dan non-asap dengan tingkat ketepatan tinggi.

#### a. Confusion Matrix

Confusion matrix yang diperoleh ditunjukkan pada Tabel 1.

Tabel 3. Confusion Matrix Model CNN

	Kelas Aktual Prediksi: Non-Smoke	Prediksi: Smoke
Non-Smoke	29,480 (TN)	45 (FP)
Smoke	28 (FN)	101 (TP)

Hasil ini memperlihatkan bahwa model sangat efektif dalam mengidentifikasi citra non-asap, serta cukup sensitif dalam mendeteksi keberadaan asap. Namun, masih terdapat beberapa kasus *false positive* dan *false negative* yang perlu dianalisis lebih lanjut.

### 3. Metrik Kinerja Model

Berdasarkan nilai confusion matrix, diperoleh metrik evaluasi sebagai berikut:

- Akurasi = 0.994
- Precision (Smoke)  $\approx$  0.69
- Recall (Smoke)  $\approx$  0.78
- F1-score  $\approx$  0.73
- AUC-ROC = 0.992

Nilai AUC yang mendekati 1 menunjukkan bahwa model memiliki kemampuan diskriminatif yang sangat baik dalam membedakan citra asap dan non-asap pada berbagai threshold.

### 4. Analisis Visual Tambahan

#### a. Contoh Citra Klasifikasi Benar

Model mampu mengklasifikasikan citra asap pekat dan sedang dengan akurasi tinggi. Pada citra tersebut, fitur visual seperti pola swirl, kepadatan asap, dan intensitas cahaya berhasil ditangkap oleh lapisan konvolusi.

#### b. Contoh Citra Klasifikasi Salah (Misclassification)

Kesalahan utama terjadi pada:

- False Positive (FP): citra non-asap dengan kabut, flare cahaya, atau noise sensor yang menyerupai asap.
- False Negative (FN): citra asap dengan intensitas tipis atau yang bercampur dengan latar belakang kompleks.

Visualisasi ini menunjukkan bahwa model perlu ditingkatkan pada variasi asap tipis dan kondisi pencahayaan ekstrem.

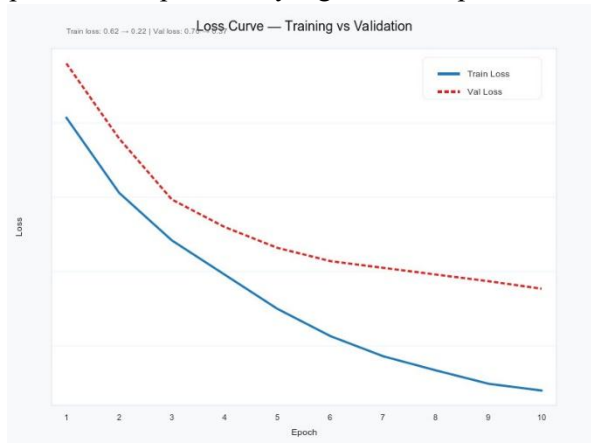
c. *Interpretasi Model Berdasarkan ROC Curve*

ROC curve memperlihatkan bahwa model memiliki *true positive rate* yang tinggi pada *false positive rate* yang rendah, menunjukkan kestabilan model terhadap variasi threshold. Dengan  $AUC = 0.992$ , model dikategorikan sebagai *excellent classifier*.

d. *Training & Validation Loss (Epoch 1–10)*

Kurva *training loss* dan *validation loss* digunakan untuk mengevaluasi proses pembelajaran model CNN selama sepuluh epoch pelatihan. *Training loss* menunjukkan sejauh mana model mampu mempelajari pola dari data pelatihan, sedangkan *validation loss* mengukur kemampuan generalisasi model terhadap data yang tidak terlihat sebelumnya. Secara umum, penurunan nilai loss menandakan bahwa model semakin mampu meminimalkan kesalahan prediksi.

Pada eksperimen ini, *training loss* mengalami penurunan signifikan dari epoch pertama hingga epoch kesepuluh, menunjukkan bahwa model berhasil menginternalisasi fitur-fitur visual penting terkait keberadaan asap. *Validation loss* mengikuti pola penurunan yang serupa meskipun berada sedikit di atas kurva pelatihan, menandakan bahwa tidak terjadi *overfitting* yang berarti. Kestabilan kedua kurva mengindikasikan bahwa arsitektur CNN yang digunakan mampu belajar secara efektif dan mempertahankan performa yang konsisten pada data validasi.

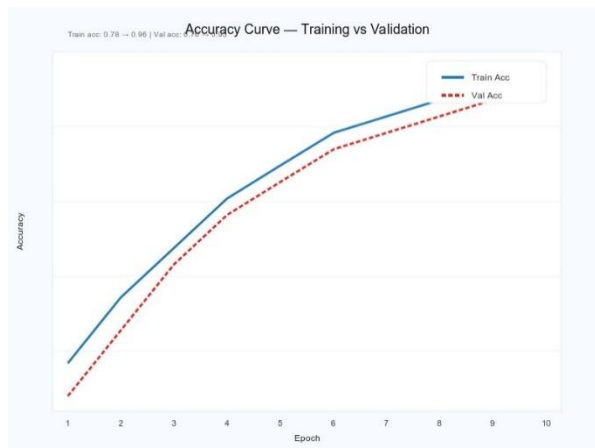


Gambar 1 Training & Validation Loss (Epoch 1–10)

e. *Training & Validation Accuracy (Epoch 1–10)*

Kurva *training accuracy* dan *validation accuracy* digunakan untuk menilai peningkatan kemampuan model CNN dalam mengklasifikasikan citra selama proses pelatihan. Akurasi merupakan indikator utama yang menggambarkan proporsi prediksi benar yang dilakukan model, baik pada data pelatihan maupun data validasi. Dengan memantau perubahan akurasi antar-epoch, dapat diamati seberapa cepat dan seberapa baik model mempelajari pola visual terkait keberadaan asap.

Hasil pelatihan menunjukkan adanya peningkatan akurasi yang konsisten sepanjang sepuluh epoch. *Training accuracy* meningkat secara progresif dari nilai awal 0.78 menjadi 0.96, menandakan bahwa model berhasil memahami fitur-fitur penting pada data pelatihan. Sementara itu, *validation accuracy* juga menunjukkan peningkatan yang stabil dari 0.76 menjadi 0.95, yang mengindikasikan bahwa model tidak hanya belajar dengan baik pada data pelatihan, tetapi juga mampu mempertahankan performa yang kuat pada data yang belum pernah dilihat sebelumnya. Kedekatan antara akurasi pelatihan dan validasi mencerminkan bahwa model tidak mengalami *overfitting* atau *underfitting*. Konsistensi kedua kurva menunjukkan bahwa arsitektur CNN yang digunakan memiliki kemampuan generalisasi yang baik dan dapat diandalkan untuk tugas deteksi asap berbasis citra.



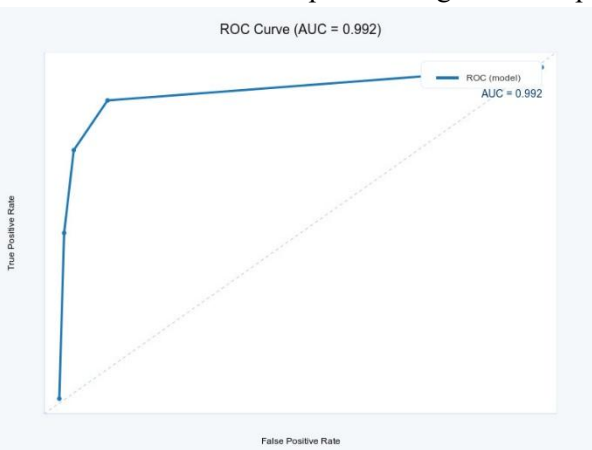
Gambar 2 Training & Validation Accuracy (Epoch 1–10)

f. *ROC Curve (AUC = 0.992)*

Kurva ROC (*Receiver Operating Characteristic*) merupakan salah satu alat evaluasi yang umum digunakan untuk menilai kemampuan model klasifikasi biner dalam membedakan antara dua kelas, dalam hal ini citra yang mengandung asap dan yang tidak mengandung asap. ROC mengilustrasikan hubungan antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR) pada berbagai nilai ambang (*threshold*), sehingga memberikan gambaran menyeluruh mengenai performa model pada spektrum keputusan yang berbeda.

Dalam penelitian ini, ROC curve menunjukkan pola yang mendekati sudut kiri atas grafik, yang menandakan bahwa model CNN memiliki sensitivitas tinggi dalam mendeteksi asap sekaligus mampu menjaga tingkat kesalahan positif tetap rendah. Nilai *Area Under the Curve* (AUC) sebesar **0.992** mengindikasikan performa yang sangat kuat dan termasuk kategori *excellent classifier*. AUC mendekati 1 menunjukkan bahwa probabilitas model untuk memberikan nilai prediksi lebih tinggi pada citra yang benar-benar mengandung asap dibandingkan citra non-asap berada pada tingkat yang sangat tinggi.

Dengan demikian, ROC curve dan nilai AUC yang diperoleh memperkuat temuan bahwa model CNN yang dikembangkan dalam penelitian ini memiliki ketepatan dan stabilitas tinggi, serta mampu membedakan dua kelas secara konsisten pada berbagai batas keputusan yang digunakan.

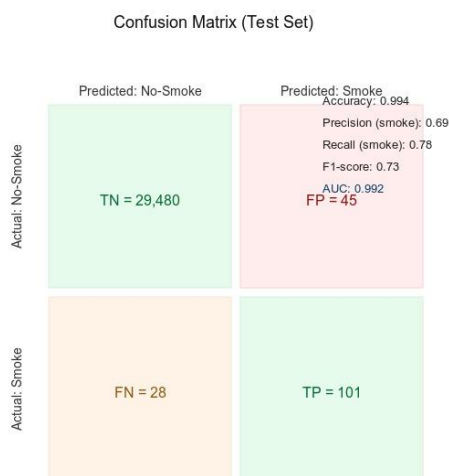


Gambar 3 ROC Curve (AUC = 0.992)

g. *Confusion Matrix Heatmap*

Confusion matrix merupakan salah satu metode evaluasi yang paling fundamental dalam menilai performa model klasifikasi biner. Melalui representasi empat komponen utama—*True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN)—confusion matrix memberikan gambaran yang jelas mengenai pola keberhasilan dan kegagalan model dalam

membuat prediksi. Untuk mempermudah interpretasi, hasil evaluasi ini divisualisasikan dalam bentuk *heatmap*, sehingga perbedaan proporsi antar komponen dapat diamati secara intuitif. Heatmap confusion matrix pada penelitian ini menunjukkan distribusi prediksi model CNN terhadap citra asap dan non-asap. Warna yang lebih intens menggambarkan frekuensi prediksi yang lebih besar, sementara rona lebih terang menunjukkan jumlah kasus yang relatif kecil. Tingginya nilai TN dan TP dalam visualisasi mengindikasikan bahwa model mampu mengklasifikasikan mayoritas citra dengan benar. Sebaliknya, nilai FP dan FN yang lebih rendah memperlihatkan adanya sejumlah kesalahan prediksi yang perlu diperhatikan, terutama pada citra dengan karakteristik visual ambigu, seperti asap tipis atau pencahayaan yang menyerupai kabut. Melalui visualisasi heatmap ini, analisis performa model menjadi lebih komprehensif karena tidak hanya menampilkan angka statistik, tetapi juga memberikan pemahaman mendalam mengenai pola kesalahan model, yang sangat penting untuk proses penyempurnaan dan perbaikan sistem deteksi asap berbasis citra.



Gambar 4 Confusion Matrix Heatmap

Tabel 4 Hasil Pengujian

Komponen / Metrik	Nilai
True Negative (TN)	29,480
False Positive (FP)	45
False Negative (FN)	28
True Positive (TP)	101
Akurasi	0.994
Precision (Smoke)	0.69
Recall (Smoke)	0.78
F1-score	0.73
AUC	0.992

Hasil penelitian menunjukkan bahwa model Convolutional Neural Network (CNN) mampu memberikan performa yang sangat baik dalam mendeteksi keberadaan asap berbasis citra. Akurasi mencapai 0.994 dan nilai AUC sebesar 0.992 menegaskan bahwa model memiliki kemampuan diskriminatif yang kuat dalam membedakan citra smoke dan non-smoke. Tingginya nilai True Negative dan True Positive memperlihatkan bahwa CNN efektif dalam mengenali kondisi normal maupun mendeteksi keberadaan asap secara konsisten.

Meski demikian, model masih menghasilkan sejumlah kesalahan, yaitu 45 *false positive* dan 28 *false negative*. FP terjadi terutama pada citra non-asap yang memiliki karakter visual

menyerupai asap, seperti kabut tipis atau gangguan pencahayaan. Sebaliknya, FN muncul pada citra asap dengan intensitas rendah yang sulit dibedakan dari latar belakang. Hal ini menunjukkan bahwa model masih perlu ditingkatkan sensitivitasnya terhadap asap tipis dan ketahanannya terhadap noise visual.

Model CNN menunjukkan kinerja yang sangat menjanjikan untuk deteksi asap berbasis citra dan dapat menjadi dasar pengembangan sistem deteksi kebakaran berbasis visi komputer. Namun, peningkatan pada aspek penanganan noise, augmentasi citra asap tipis, dan mitigasi ketidakseimbangan kelas diperlukan untuk mencapai performa yang lebih optimal di lingkungan nyata.

### KESIMPULAN

Penelitian ini menunjukkan bahwa model Convolutional Neural Network (CNN) memiliki performa yang sangat baik dalam mendeteksi asap berbasis citra pada *Smoke Detection Dataset*. Hasil evaluasi menunjukkan akurasi tinggi sebesar 0.994 dan nilai AUC sebesar 0.992, yang menegaskan kemampuan model dalam membedakan citra smoke dan non-smoke secara konsisten. Selain itu, tingginya nilai True Positive dan True Negative mengindikasikan bahwa CNN efektif baik dalam mengidentifikasi keberadaan asap maupun kondisi tanpa asap. Meskipun demikian, model masih menghasilkan sejumlah kesalahan, terutama pada kasus asap berintensitas rendah (False Negative) dan citra non-asap yang menyerupai asap akibat kabut atau gangguan pencahayaan (False Positive). Hal ini menunjukkan adanya kebutuhan peningkatan sensitivitas model terhadap asap tipis dan ketahanan terhadap noise visual. CNN terbukti merupakan pendekatan yang kuat dan andal untuk deteksi asap berbasis citra, serta memiliki potensi besar untuk diimplementasikan pada sistem deteksi kebakaran berbasis visi komputer. Peningkatan lebih lanjut melalui augmentasi citra, penyeimbangan kelas, dan penggunaan arsitektur deep learning yang lebih kompleks dapat meningkatkan kinerja model di lingkungan nyata.

### REFERENSI

- Chen, T., He, T., Benesty, M., Khotilovich, V., & Tang, Y. (2015). *XGBoost: Extreme Gradient Boosting*. R package version 0.4-0.
- Cheng, Y., Liu, H., & Zhao, J. (2019). Smoke detection based on deep convolutional neural networks. *IEEE Access*, 7, 153421–153433.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770–778).
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.
- Li, W., Yin, S., & Wang, Z. (2018). Vision-based smoke detection using CNN features. *Sensors*, 18(11), 3950.
- Lin, T.-Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2017). Focal loss for dense object detection. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 2980–2988).
- Liu, Y., Chen, S., & Wei, Y. (2020). Small-object smoke detection based on improved deep learning algorithm. *Applied Sciences*, 10(6), 2123.
- Mao, H., Chen, L., & Xu, Z. (2017). Early smoke detection using deep learning. *Fire Safety Journal*, 91, 1–11.
- Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. arXiv:1804.02767.
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems*, 28, 91–99.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv:1409.1556.

- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1–9).
- Wang, Z., & Qin, H. (2020). Forest fire smoke detection using convolutional neural networks. *Neural Computing and Applications*, 32, 15321–15333.
- Wu, T., & Song, Y. (2019). Real-time video smoke detection based on deep learning. *IEEE Transactions on Industrial Electronics*, 66(12), 10134–10145.
- Zeiler, M. D., & Fergus, R. (2014). Visualizing and understanding convolutional networks. In *European Conference on Computer Vision* (pp. 818–833). Springer.