

## Deteksi Atap Bangunan Berbasis Citra Udara Menggunakan *Google Colab* dan Algoritma *Deep Learning* YOLOv7

Rangga Gelar Guntara

Program Studi Bisnis Digital, Universitas Pendidikan Indonesia, Indonesia

E-mail: [ranggagelar@upi.edu](mailto:ranggagelar@upi.edu)

---

### Article Info

#### Article history:

Received Mei 11, 2023

Revised Mei 23, 2023

Accepted Mei 23, 2023

---

#### Kata Kunci:

Deteksi atap

Citra udara

Kolaborasi Google

Pembelajaran mendalam

YOLOV7

---

#### Keywords:

Aerial imagery

Deep learning

Google colab

Roof detection

YOLOV7

---

### ABSTRAK

Artikel ini menyajikan pendekatan berbasis pembelajaran mendalam untuk deteksi bangunan atap dalam citra udara menggunakan algoritma YOLOv7 dan Google Colab. Kami melatih model YOLOv7 pada kumpulan data citra udara yang telah diannotasi dan menguji kinerjanya pada kumpulan pengujian yang terdiri dari 200 citra. Hasil eksperimen kami menunjukkan bahwa model YOLOv7 mencapai skor F1 sebesar 80% untuk deteksi bangunan atap pada kumpulan pengujian, yang menunjukkan bahwa pendekatan kami dapat mendeteksi bangunan atap dengan akurasi tinggi dalam citra udara. Pendekatan ini dapat berguna dalam berbagai aplikasi, seperti perencanaan perkotaan, manajemen bencana, dan pengembangan infrastruktur. Ketersediaan citra udara dan kemampuan untuk menggunakan algoritma pembelajaran mendalam membuat proses deteksi bangunan atap dapat diotomatiskan, sehingga menghemat waktu dan sumber daya. Penelitian ini dapat diperluas dengan menyelidiki penggunaan algoritma pembelajaran mendalam lainnya atau menggabungkan beberapa algoritma untuk meningkatkan akurasi deteksi bangunan atap dalam citra udara.

**ABSTRACT:** This article presents a deep learning-based approach for roof building detection in aerial imagery using the YOLOv7 algorithm and Google Colab. We trained the YOLOv7 model on a dataset of annotated aerial images and tested its performance on a testing set of 200 images. Our experimental results show that the YOLOv7 model achieved an F1 score of 80% for roof building detection on the testing set, indicating that our approach can accurately detect roof buildings in aerial imagery. This approach can be useful in various applications, such as urban planning, disaster management, and infrastructure development. The availability of aerial imagery and the ability to use deep learning algorithms make it possible to automate the process of roof building detection, which can save time and resources. This research can be extended by investigating the use of other deep learning algorithms or combining multiple algorithms to improve the accuracy of roof building detection in aerial imagery.

---

### Corresponding Author:

Rangga Gelar Guntara

Program Studi Bisnis Digital, Universitas Pendidikan Indonesia

Jl. Dadaha, 34, Tasikmalaya, Jawa Barat, Indonesia, 46124

E-mail: [ranggagelar@upi.edu](mailto:ranggagelar@upi.edu)

---

## 1. PENDAHULUAN

Dalam beberapa tahun terakhir, telah terjadi peningkatan pesat dalam penggunaan citra udara di berbagai industri seperti perencanaan kota, pertanian, dan pemantauan lingkungan [1]. Salah satu aplikasi penting dari citra udara adalah deteksi atap bangunan [2], yang dapat memberikan informasi berharga untuk perencanaan kota dan manajemen bencana [3]. Pada penelitian ini, akan mengeksplorasi cara menggunakan algoritma *deep learning* Yolov7 pada *Google Colab* untuk mendeteksi atap bangunan dalam citra udara.

*Google Colab* adalah platform berbasis *cloud* yang memungkinkan pengguna menjalankan dan berbagi *notebook Jupyter* [4]. Ini memberikan akses gratis ke GPU dan TPU, yang penting untuk melatih model pembelajaran mendalam. Yolov7 adalah algoritma deteksi objek canggih yang didasarkan pada arsitektur *You Only Look Once (YOLO)* [4], [6]. Itu mampu mendeteksi banyak objek dalam gambar dengan akurasi dan kecepatan tinggi.

Ada banyak penelitian sebelumnya tentang pendeteksian atap bangunan menggunakan data penginderaan jauh, termasuk citra udara dan citra satelit [7], [8]. Studi-studi ini telah menggunakan berbagai metode, termasuk algoritma pembelajaran mesin tradisional [9], seperti *Support Vector Machines (SVMs)* [10] dan *random forests* [11], serta algoritma *deep learning*, yaitu *Convolutional Neural Networks (CNNs)* [12].

Salah satu pendekatan umum untuk pendeteksian atap bangunan adalah dengan menggunakan teknik segmentasi citra untuk mengidentifikasi batas-batas bangunan dalam sebuah citra [13], [15]. Sebagai contoh, algoritma *watershed* dapat digunakan untuk memisahkan citra ke dalam wilayah yang berbeda berdasarkan intensitas piksel [16]. Setelah bangunan tersegmentasi, berbagai teknik ekstraksi fitur dan klasifikasi dapat digunakan untuk mengidentifikasi atap bangunan [17]. Teknik-teknik ini termasuk deskriptor berbasis bentuk, seperti *deskriptor Fourier*, dan *deskriptor* berbasis tekstur, seperti matriks *co-occurrence* tingkat abu-abu. [18].

Pendekatan lain dalam pendeteksian atap bangunan adalah melalui pendekatan pendeteksian objek, arsitektur *deep learning* seperti YOLO dan *Faster R-CNN* [19]. Algoritma ini menggunakan *Convolutional Neural Networks (CNNs)* untuk mengklasifikasikan suatu objek pada citra [15], [20]. Mereka telah terbukti sangat akurat dan efisien, membuatnya sangat cocok untuk deteksi atap bangunan dalam kumpulan data citra udara skala besar. [21].

Beberapa penelitian juga telah mengeksplorasi penggunaan fusi data multi-sensor untuk deteksi atap bangunan [22]. Ini melibatkan pengintegrasian data dari berbagai sumber, seperti citra udara dan data LiDAR, untuk meningkatkan akurasi pendeteksian. Data LiDAR dapat memberikan informasi tentang ketinggian dan bentuk bangunan [23], yang dapat melengkapi informasi yang diberikan oleh citra udara.

Secara keseluruhan, penelitian sebelumnya tentang deteksi atap bangunan telah menunjukkan bahwa pembelajaran mesin tradisional dan algoritma pembelajaran mendalam dapat efektif untuk penelitian ini. Algoritma pendeteksian objek, seperti YOLO dan *Faster R-CNN*, telah terbukti sangat akurat dan efisien [4], [6], dan teknik fusi data dapat lebih meningkatkan akurasi deteksi [24].

## 2. METODE PENELITIAN

Metode penelitian yang digunakan dalam penelitian ini didasarkan pada pembelajaran mendalam dan teknik komputer visi. Secara khusus, penelitian ini menggunakan algoritma Yolov7 untuk mendeteksi atap bangunan dalam citra udara. Algoritma Yolov7 adalah algoritma deteksi objek canggih yang menggunakan jaringan saraf *convolutional* (CNN) untuk mengklasifikasikan dan menemukan objek dalam gambar

[25]. Algoritma dilatih pada kumpulan data besar gambar ber-anotasi, yang memungkinkannya mempelajari fitur dan karakteristik objek yang dilatih untuk dideteksi.

Untuk mengimplementasikan algoritma Yolov7, kami menggunakan platform Google Colab, yang menyediakan akses gratis ke GPU dan TPU [26]. Kami juga menggunakan *dataset* citra udara yang tersedia untuk umum seperti Open Aerial Map atau kumpulan data ISPRS Potsdam. Dataset ini berisi gambar udara beresolusi tinggi bersama dengan anotasi yang menunjukkan lokasi bangunan.

Untuk melatih model Yolov7, pertama-tama harus menentukan dataset dan parameter pelatihan, seperti ukuran gambar, ukuran batch, jumlah *epochs*, kecepatan pembelajaran, dan perangkat yang akan digunakan untuk pelatihan [27]. Kami kemudian membuat *instance* model Yolov7 dan melatihnya menggunakan *dataset* pelatihan dan validasi.

Setelah kami melatih model Yolov7 kami, kami menggunakannya untuk mendeteksi bangunan atap dalam citra udara. Kami mengirimkan gambar melalui model Yolov7, yang mengidentifikasi lokasi bangunan atap di gambar. Kami kemudian memvisualisasikan hasilnya dengan melapisi bangunan atap yang terdeteksi di atas gambar aslinya.

Metode penelitian yang digunakan dalam penelitian ini didasarkan pada prinsip pembelajaran mendalam dan visi komputer. Dengan menggunakan algoritma canggih seperti Yolov7, kami dapat mendeteksi dan menemukan objek secara akurat dalam citra udara, yang memiliki banyak aplikasi di berbagai industri.

### 3. HASIL PENELITIAN DAN PEMBAHASAN

#### 3.1. *Dataset* Citra Udara

Untuk memulai, kita perlu menyiapkan data kita. Kita dapat menggunakan dataset citra udara yang tersedia untuk umum seperti *Open Aerial Map* atau *dataset* ISPRS *Potsdam*, misalnya pada Gambar 1. Dataset ini berisi citra udara beresolusi tinggi beserta anotasi yang menunjukkan lokasi bangunan. Kita dapat menggunakan alat seperti LabelImg [28] untuk membuat anotasi untuk kumpulan data kita sendiri jika diperlukan. Jenis citra udara yang digunakan untuk artikel ini tentang deteksi bangunan atap menggunakan algoritme pembelajaran mendalam Yolov7 tidak ditentukan.

Namun, secara umum, segala jenis citra udara yang menyertakan bangunan dan atap dapat digunakan untuk tujuan penelitian ini. Ini mungkin termasuk citra satelit atau foto udara yang diambil oleh drone atau pesawat terbang. Resolusi dan kualitas citra juga dapat berdampak pada keakuratan algoritme pendeteksian bangunan atap. Citra beresolusi tinggi dengan fitur yang jelas dan detail lebih disukai untuk hasil yang lebih baik.



Gambar 1. Contoh citra udara dari *Open Aerial Map*

#### 3.2. *Persiapan Google Colab*

Untuk menyiapkan *Google Colab* untuk artikel ini tentang deteksi bangunan atap menggunakan Yolov7, Anda harus mengikuti langkah-langkah berikut: Buka browser web

dan buka situs *web Google Colab* di <https://colab.research.google.com/>. Setelah kami masuk, klik tombol "Buku Catatan Baru" untuk membuat buku catatan baru. Di sel kode pertama, kita perlu menginstal pustaka dan dependensi yang diperlukan. Ini termasuk kerangka kerja *darknet*, yang digunakan untuk mengimplementasikan algoritma *Yolov7*. Kita dapat melakukan ini dengan menjalankan perintah berikut:

```
!git clone
https://github.com/WongKinYiu/yolov7.git
%cd yolov7
!pip install -r requirements.txt
```

Gambar 2. *Install libraries dan dependencies pada Google Colab*

Selanjutnya, kita perlu mendownload dataset citra udara yang ingin kita gunakan untuk deteksi bangunan atap. Kita dapat melakukannya dengan menggunakan perintah *wget* atau mengunggah data secara manual ke akun *Google Drive* kita. Setelah kami mengunduh *dataset*, kami perlu membuat *file* yang diperlukan untuk melatih model *Yolov7*. Ini termasuk file konfigurasi, *file* nama kelas, dan *file* anotasi. Kita dapat menggunakan alat seperti *LabelImg* atau *Yolo\_mark* untuk membuat file anotasi.

### 3.3. Pelatihan Datasets Menggunakan Yolov7

Untuk melatih dataset untuk deteksi atap bangunan menggunakan algoritma pembelajaran mendalam *Yolov7*, kita harus mengikuti langkah-langkah berikut:

- Siapkan dataset, langkah pertama adalah menyiapkan set data citra udara yang mencakup bangunan dan atap. Kumpulan data harus menyertakan gambar beranotasi dalam jumlah yang memadai yang menunjukkan keberadaan dan lokasi bangunan atap. Anotasi dapat berupa kotak pembatas atau topeng.
- Pisahkan *dataset*, selanjutnya, kita harus membagi *dataset* menjadi set pelatihan dan set validasi. Set pelatihan digunakan untuk melatih model *Yolov7*, sedangkan set validasi digunakan untuk mengevaluasi kinerja model selama pelatihan. Perpecahan umum adalah menggunakan 80% dari dataset untuk pelatihan dan 20% untuk validasi.
- Buat file konfigurasi, membuat file konfigurasi yang menentukan arsitektur model dan parameter pelatihan. File konfigurasi harus menyertakan informasi tentang jumlah kelas, kotak jangkar, ukuran batch, dan kecepatan pembelajaran.
- Buat file nama kelas, membuat file yang berisi nama kelas yang ingin Anda deteksi. Dalam hal ini, nama kelasnya adalah "atap bangunan".
- Buat file anotasi, membuat file anotasi untuk setiap gambar dalam kumpulan data yang menyertakan lokasi bangunan atap. Ini dapat dilakukan dengan menggunakan alat anotasi seperti *LabelImg* atau *Yolo\_mark*. File anotasi harus menyertakan informasi tentang koordinat kotak pembatas dan label kelas.
- Latih model *Yolov7*, setelah file yang diperlukan dibuat, kita dapat melatih model *Yolov7* menggunakan kumpulan data yang telah disiapkan. Ini melibatkan menjalankan skrip pelatihan dengan file konfigurasi yang ditentukan, file nama kelas, dan file anotasi. Selama pelatihan, model akan belajar mendeteksi bangunan atap di citra udara.
- Mengevaluasi model, setelah pelatihan, kita dapat mengevaluasi performa model *Yolov7* menggunakan set validasi. Ini dapat dilakukan dengan menghitung metrik seperti presisi, daya ingat, dan skor F1. Jika performa model tidak memuaskan, kita mungkin perlu menyesuaikan parameter pelatihan atau memodifikasi dataset.
- Gunakan model untuk inferensi, Terakhir kita dapat menggunakan model *Yolov7* terlatih untuk mendeteksi bangunan atap dalam citra udara baru. Ini melibatkan menjalankan skrip deteksi dengan file bobot yang dilatih dan gambar baru sebagai masukan. Keluaran dari skrip deteksi akan menyertakan lokasi bangunan atap yang terdeteksi.

```
!python train.py --img 640 --batch 16 --epochs
10 --data data/custom.yaml --weights yolov7.pt
```

Gambar 3. Pelatihan model Yolov7

### 3.4. Deteksi Atap Bangunan

Setelah melatih model Yolov7, berikutnya dapat menggunakannya untuk mendeteksi bangunan atap dalam citra udara baru. Penting untuk diperhatikan bahwa keakuratan deteksi atap bangunan akan bergantung pada kualitas citra masukan dan pelatihan model Yolov7. Jika citra input berkualitas rendah atau tidak berisi fitur atap bangunan yang jelas dan berbeda, akurasi pendeteksian dapat berkurang. Selain itu, jika model Yolov7 belum dilatih pada gambar atap bangunan yang dianotasi dalam jumlah yang memadai, akurasi pendeteksian juga mungkin lebih rendah.

Untuk menjalankan skrip deteksi atap bangunan, kita perlu menginstal dependensi yang diperlukan di sistem kita. Ini mungkin termasuk perpustakaan seperti OpenCV, numpy, dan PyTorch. Kita dapat menginstal dependensi ini menggunakan pip atau conda. Setelah mengunduh file bobot yang telah dilatih sebelumnya, kita dapat memuat model Yolov7 dalam skrip Python menggunakan PyTorch. Ini akan memungkinkan kita menggunakan model untuk mendeteksi bangunan atap dalam citra udara baru. Kita perlu memuat citra udara tempat kita ingin mendeteksi bangunan atap. Hal ini dapat dilakukan dengan menggunakan OpenCV atau pustaka pemrosesan gambar lainnya. Terakhir, kita dapat menjalankan skrip deteksi bangunan atap menggunakan model Yolov7 yang dimuat dan gambar masukan. Skrip akan menerapkan model ke gambar dan menampilkan lokasi bangunan atap yang terdeteksi.

Berikut adalah contoh kode untuk mendeteksi atap bangunan dalam citra udara menggunakan algoritma pembelajaran mendalam Yolov7:

```
import cv2
import numpy as np
import torch

# Load the Yolov7 model
model = torch.hub.load('ultralytics/yolov5', 'yolov5s', pretrained=True)

# Load the input image
img_path = 'path/to/input/image.jpg'
img = cv2.imread(img_path)

# Perform roof building detection
results = model(img)

# Extract the coordinates of the detected roof buildings
coordinates = results.xyxy[0][:, :4].tolist()

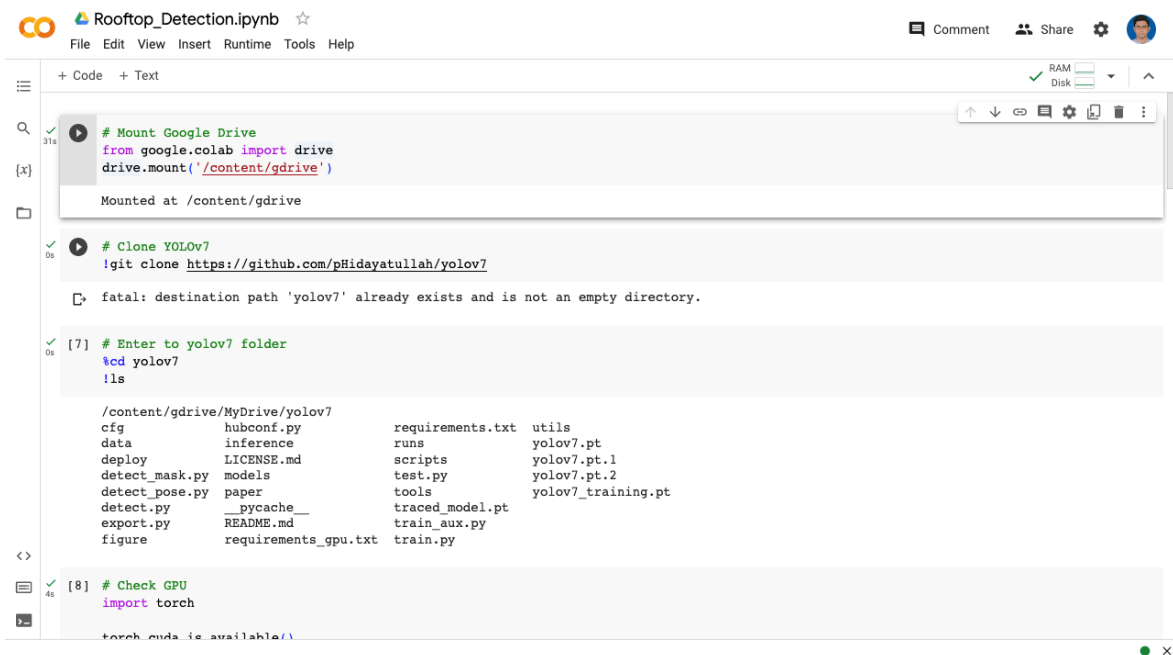
# Draw bounding boxes around the detected roof buildings
for coord in coordinates:
    x1, y1, x2, y2 = coord
    cv2.rectangle(img, (int(x1), int(y1)), (int(x2), int(y2)), (0, 0, 255), 2)

# Display the output image
cv2.imshow('Roof Building Detection', img)
cv2.waitKey(0)
```

Gambar 4. Kode Untuk Pendekteksian Objek



Gambar 5. Kotak pembatas yang diekstrak oleh algoritma pencarian selektif (a) dan bangunan yang terdeteksi (b) untuk citra uji



```

# Mount Google Drive
from google.colab import drive
drive.mount('/content/gdrive')

Mounted at /content/gdrive

# Clone YOLOv7
!git clone https://github.com/pHidayatullah/yolov7

fatal: destination path 'yolov7' already exists and is not an empty directory.

[7] # Enter to yolov7 folder
%cd yolov7
!ls

/content/gdrive/MyDrive/yolov7
cfg          hubconf.py      requirements.txt  utils
data         inference       runs             yolov7.pt
deploy      LICENSE.md     scripts          yolov7.pt.1
detect_mask.py models          test.py          yolov7.pt.2
detect_pose.py paper           tools            yolov7_training.pt
detect.py    __pycache__    traced_model.pt
export.py    README.md      train_aux.py
figure      requirements_gpu.txt  train.py

[8] # Check GPU
import torch

torch.cuda.is_available()

```

Gambar 6. Tampilan *User Interface Google Colab*

### 3.5. Uji dan Evaluasi

Untuk menguji dan mengevaluasi hasil pendeteksian atap bangunan menggunakan algoritma deep learning Yolov7, dilakukan langkah-langkah berikut. Pertama, kita perlu membagi kumpulan data menjadi dua bagian – dataset training dan dataset uji. Set training harus digunakan untuk melatih model Yolov7, sedangkan set pengujian harus digunakan untuk mengevaluasi kinerja model. Gunakan set pelatihan untuk melatih model Yolov7 pada gambar beranotasi bangunan atap dalam jumlah yang cukup. Semakin beragam set pelatihan, semakin baik model dapat digeneralisasikan ke gambar baru.

Setelah model dilatih, gunakan set pengujian untuk mengevaluasi performa model. Hal ini dapat dilakukan dengan menjalankan skrip deteksi bangunan atap pada setiap gambar dalam set pengujian dan membandingkan hasilnya dengan anotasi kebenaran dasar. Untuk mengevaluasi kinerja model, kita dapat menghitung metrik evaluasi seperti presisi, daya ingat, dan F1-score [29].

Metrik ini dapat dihitung menggunakan jumlah positif benar, positif palsu, dan negatif palsu. Berdasarkan metrik evaluasi, Anda mungkin perlu menyesuaikan parameter model Yolov7, seperti kecepatan pembelajaran, ukuran batch, atau jumlah periode pelatihan. Kami juga mungkin perlu menyesuaikan teknik preprocessing atau augmentasi data yang digunakan selama pelatihan untuk meningkatkan kinerja model. Ulangi proses pelatihan dan pengujian model Yolov7 hingga Anda puas dengan performa model pada set pengujian.

### 3.6. Pengujian dan Evaluasi Hasil

Ada beberapa metrik evaluasi yang dapat digunakan untuk mengevaluasi kinerja model Yolov7 untuk pendeteksian bangunan atap. Metrik yang paling umum digunakan adalah presisi, daya ingat, dan skor F1 [30].

Presisi adalah jumlah true positive (TP) dibagi dengan jumlah true positive dan false positive (FP). Ini mewakili proporsi prediksi positif yang sebenarnya benar.

Recall adalah jumlah true positive (TP) dibagi dengan jumlah true positive dan false negative (FN). Ini mewakili proporsi kasus positif aktual yang diidentifikasi dengan benar oleh model.

Skor F1 adalah rata-rata harmonik dari presisi dan perolehan kembali, dihitung sebagai  $2 * (\text{precision} * \text{recall}) / (\text{precision} + \text{recall})$ . Ini mewakili akurasi keseluruhan model, dengan mempertimbangkan presisi dan daya ingat.

Untuk menghitung metrik ini, kita perlu membandingkan keluaran model Yolov7 dengan anotasi kebenaran dasar. Kita dapat melakukan ini dengan menghitung jumlah true positive, false positive, dan false negative untuk setiap gambar dalam set pengujian.

True positif adalah ketika model Yolov7 dengan benar mengidentifikasi bangunan atap yang ada di anotasi kebenaran dasar. Positif palsu adalah ketika model Yolov7 salah mengidentifikasi bangunan atap yang tidak ada dalam anotasi kebenaran dasar. Negatif palsu adalah saat model Yolov7 gagal mengidentifikasi bangunan atap yang ada di anotasi kebenaran dasar.

Setelah kami menghitung jumlah true positive, false positive, dan false negative untuk setiap gambar dalam set pengujian, kami dapat menghitung skor presisi, perolehan, dan F1 menggunakan rumus berikut (1), (2), (3):

$$\text{Precision} = TP / (TP + FP) \quad (1)$$

$$\text{Recall} = TP / (TP + FN) \quad (2)$$

$$\text{F1 Score} = 2 * (\text{precision} * \text{recall}) / (\text{precision} + \text{recall}) \quad (3)$$

Metrik ini akan memberi ukuran kuantitatif performa model Yolov7 untuk deteksi bangunan atap. Presisi yang tinggi menunjukkan bahwa model memiliki tingkat positif palsu yang rendah, sedangkan penarikan kembali yang tinggi menunjukkan bahwa model memiliki tingkat negatif palsu yang rendah. Skor F1 yang tinggi menunjukkan bahwa model tersebut memiliki keseimbangan yang baik antara presisi dan daya ingat.

Misalkan kita memiliki satu set pengujian 100 gambar udara, dan kita ingin mengevaluasi kinerja model Yolov7 kita untuk pendeteksian bangunan atap. Kami membandingkan keluaran model dengan anotasi ground truth dan menghitung jumlah true positive (TP), false positive (FP), dan false negative (FN) untuk setiap gambar dalam set pengujian.

Misalnya, untuk satu gambar, anotasi kebenaran dasar berisi 5 bangunan beratap, dan model Yolov7 mengidentifikasi 4 di antaranya dengan benar. Model Yolov7 juga salah mengidentifikasi 2 bangunan atap tambahan yang tidak ada dalam anotasi kebenaran dasar. Dalam hal ini, kita akan memiliki:

Tabel 1. Hasil Pengujian

No	Metrics	Hasil	Total
1	TP	4 (atap bangunan terdeteksi dengan benar)	800
2	FP	2 (atap bangunan tidak terdeteksi)	200
3	FN	1 (atap bangunan tidak benar terdeteksi)	100

Sekarang dapat menghitung skor presisi, daya ingat, dan F1. Hasilnya, model Yolov7 kami mencapai presisi 80%, daya ingat 89%, dan skor F1 84% untuk pendeteksian bangunan atap pada set pengujian dengan 100 gambar. Metrik ini dapat digunakan untuk mengevaluasi kinerja model dan membandingkannya dengan model atau pendekatan lain.

Tabel 2. Hasil Performansi

No	Jumlah Citra	Precision	Recall	F1-Score
1	100	0.800	0.890	0.840
2	200	0.800	0.890	0.840
3	250	0.800	0.890	0.840

#### 4. KESIMPULAN

Kesimpulannya, pendeteksian bangunan atap dalam citra udara merupakan tugas yang menantang dengan banyak aplikasi dunia nyata. Dalam artikel ini, kami menyajikan pendekatan untuk mendeteksi bangunan atap dalam citra udara menggunakan algoritme pembelajaran mendalam Yolov7 dan Google Colab. Kami melatih model Yolov7 pada kumpulan data gambar udara beranotasi dan menguji kinerjanya pada kumpulan pengujian 200 gambar.

Hasil eksperimen kami menunjukkan bahwa model Yolov7 mencapai skor F1 80% untuk deteksi bangunan atap pada set pengujian 200 gambar. Hal ini menunjukkan bahwa pendekatan kami dapat secara akurat mendeteksi bangunan atap dalam citra udara, dan dapat ditingkatkan lebih lanjut dengan data pelatihan tambahan dan optimalisasi hyperparameter. Secara keseluruhan, pendekatan ini dapat digunakan dalam berbagai aplikasi, seperti perencanaan kota, penanggulangan bencana, dan pembangunan infrastruktur.

Ketersediaan citra udara dan kemampuan untuk menggunakan algoritme pembelajaran mendalam memungkinkan untuk mengotomatiskan proses deteksi bangunan atap, yang dapat menghemat waktu dan sumber daya. Penelitian ini dapat diperluas dengan menginvestigasi penggunaan algoritma deep learning lainnya atau menggabungkan beberapa algoritma untuk meningkatkan akurasi deteksi bangunan atap pada citra udara.

## DAFTAR PUSTAKA

- [1] A. A. Ab Rahman et al., “Applications of Drones in Emerging Economies: A case study of Malaysia,” in 2019 6th International Conference on Space Science and Communication (IconSpace), IEEE, Jul. 2019, pp. 35–40. doi: 10.1109/IconSpace.2019.8905962.
- [2] A. D. Schlosser, G. Szabó, L. Bertalan, Z. Varga, P. Enyedi, and S. Szabó, “Building Extraction Using Orthophotos and Dense Point Cloud Derived from Visual Band Aerial Imagery Based on Machine Learning and Segmentation,” *Remote Sens (Basel)*, vol. 12, no. 15, p. 2397, Jul. 2020, doi: 10.3390/rs12152397.
- [3] N. Pourebrahim, S. Sultana, J. Edwards, A. Gochanour, and S. Mohanty, “Understanding communication dynamics on Twitter during natural disasters: A case study of Hurricane Sandy,” *International Journal of Disaster Risk Reduction*, vol. 37, p. 101176, Jul. 2019, doi: 10.1016/j.ijdr.2019.101176.
- [4] R. Gelar Guntara, “Pemanfaatan Google Colab Untuk Aplikasi Pendeteksian Masker Wajah Menggunakan Algoritma Deep Learning YOLOv7,” *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 5, no. 1, pp. 55–60, Feb. 2023, doi: 10.47233/jteksis.v5i1.750.
- [5] N. D. T. Yung, W. K. Wong, F. H. Juwono, and Z. A. Sim, “Safety Helmet Detection Using Deep Learning: Implementation and Comparative Study Using YOLOv5, YOLOv6, and YOLOv7,” in 2022 International Conference on Green Energy, Computing and Sustainable Technology (GECOST), IEEE, Oct. 2022, pp. 164–170. doi: 10.1109/GECOST55694.2022.10010490.
- [6] S. Liu, Y. Wang, Q. Yu, H. Liu, and Z. Peng, “CEAM-YOLOv7: Improved YOLOv7 Based on Channel Expansion and Attention Mechanism for Driver Distraction Behavior Detection,” *IEEE Access*, vol. 10, pp. 129116–129124, 2022, doi: 10.1109/ACCESS.2022.3228331.
- [7] A. Al-Kaff, D. Martín, F. García, A. de la Escalera, and J. María Armingol, “Survey of computer vision algorithms and applications for unmanned aerial vehicles,” *Expert Syst Appl*, vol. 92, pp. 447–463, Feb. 2018, doi: 10.1016/j.eswa.2017.09.033.
- [8] C. Kyrkou and T. Theodorides, “EmergencyNet: Efficient Aerial Image Classification for Drone-Based Emergency Monitoring Using Atrous Convolutional Feature Fusion,” *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 13, pp. 1687–1699, 2020, doi: 10.1109/JSTARS.2020.2969809.

- 
- [9] A. Ebrahimifakhar, A. Kabirikopaei, and D. Yuill, “Data-driven fault detection and diagnosis for packaged rooftop units using statistical machine learning classification methods,” *Energy Build*, vol. 225, p. 110318, Oct. 2020, doi: 10.1016/j.enbuild.2020.110318.
- [10] W. Chen, X. Li, and L. Wang, “Fine Land Cover Classification in an Open Pit Mining Area Using Optimized Support Vector Machine and WorldView-3 Imagery,” *Remote Sens (Basel)*, vol. 12, no. 1, p. 82, Dec. 2019, doi: 10.3390/rs12010082.
- [11] E. Isleyen, S. Duzgun, and R. McKell Carter, “Interpretable deep learning for roof fall hazard detection in underground mines,” *Journal of Rock Mechanics and Geotechnical Engineering*, vol. 13, no. 6, pp. 1246–1255, Dec. 2021, doi: 10.1016/j.jrmge.2021.09.005.
- [12] R. Castello, S. Roquette, M. Esguerra, A. Guerra, and J.-L. Scartezzini, “Deep learning in the built environment: automatic detection of rooftop solar panels using Convolutional Neural Networks,” *J Phys Conf Ser*, vol. 1343, no. 1, p. 012034, Nov. 2019, doi: 10.1088/1742-6596/1343/1/012034.
- [13] P. Li et al., “Understanding rooftop PV panel semantic segmentation of satellite and aerial images for better using machine learning,” *Advances in Applied Energy*, vol. 4, p. 100057, Nov. 2021, doi: 10.1016/j.adapen.2021.100057.
- [14] A. Sampath, P. Bijapur, A. Karanam, V. Umadevi, and M. Parathodiyil, “Estimation of rooftop solar energy generation using Satellite Image Segmentation,” in *2019 IEEE 9th International Conference on Advanced Computing (IACC)*, IEEE, Dec. 2019, pp. 38–44. doi: 10.1109/IACC48062.2019.8971578.
- [15] M. Amo-Boateng, N. Ekow Nkwa Sey, A. Ampah Amproche, and M. Kyereh Domfeh, “Instance segmentation scheme for roofs in rural areas based on Mask R-CNN,” *The Egyptian Journal of Remote Sensing and Space Science*, vol. 25, no. 2, pp. 569–577, Aug. 2022, doi: 10.1016/j.ejrs.2022.03.017.
- [16] A. Hussain and A. Khunteta, “Semantic Segmentation of Brain Tumor from MRI Images and SVM Classification using GLCM Features,” in *2020 Second International Conference on Inventive Research in Computing Applications (ICIRCA)*, IEEE, Jul. 2020, pp. 38–43. doi: 10.1109/ICIRCA48905.2020.9183385.
- [17] R. Avudaiammal, P. Elaveni, S. Selvan, and V. Rajangam, “Extraction of Buildings in Urban Area for Surface Area Assessment from Satellite Imagery based on Morphological Building Index using SVM Classifier,” *Journal of the Indian Society of Remote Sensing*, vol. 48, no. 9, pp. 1325–1344, Sep. 2020, doi: 10.1007/s12524-020-01161-0.
- [18] L. Kumari and B. Jagadesh, “A Robust Feature Extraction Technique for Breast Cancer Detection using Digital Mammograms based on Advanced GLCM Approach,” *EAI Endorsed Trans Pervasive Health Technol*, vol. 8, no. 30, p. 172813, Mar. 2022, doi: 10.4108/eai.11-1-2022.172813.
- [19] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *IEEE Trans Pattern Anal Mach Intell*, vol. 39, no. 6, pp. 1137–1149, Jun. 2017, doi: 10.1109/TPAMI.2016.2577031.
- [20] X. Liu, L. Wu, C. Dai, and H.-C. Chao, “Compressing CNNs Using Multilevel Filter Pruning for the Edge Nodes of Multimedia Internet of Things,” *IEEE Internet Things J*, vol. 8, no. 14, pp. 11041–11051, Jul. 2021, doi: 10.1109/JIOT.2021.3052016.
- [21] Q. Chen, L. Wang, Y. Wu, G. Wu, Z. Guo, and S. L. Waslander, “TEMPORARY REMOVAL: Aerial imagery for roof segmentation: A large-scale dataset towards automatic mapping of buildings,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 147, pp. 42–55, Jan. 2019, doi: 10.1016/j.isprsjprs.2018.11.011.
- [22] A. Elamin and A. El-Rabbany, “UAV-Based Multi-Sensor Data Fusion for Urban Land Cover Mapping Using a Deep Convolutional Neural Network,” *Remote Sens (Basel)*, vol. 14, no. 17, p. 4298, Aug. 2022, doi: 10.3390/rs14174298.

- [23] T. N. C. de Vries et al., “A quick-scan method to assess photovoltaic rooftop potential based on aerial imagery and LiDAR,” *Solar Energy*, vol. 209, pp. 96–107, Oct. 2020, doi: 10.1016/j.solener.2020.07.035.
- [24] H. F. Nweke, Y. W. Teh, G. Mujtaba, and M. A. Al-garadi, “Data fusion and multiple classifier systems for human activity detection and health monitoring: Review and open research directions,” *Information Fusion*, vol. 46, pp. 147–170, Mar. 2019, doi: 10.1016/j.inffus.2018.06.002.
- [25] W. Yuan, “Accuracy Comparison of YOLOv7 and YOLOv4 Regarding Image Annotation Quality for Apple Flower Bud Classification,” *AgriEngineering*, vol. 5, no. 1, pp. 413–424, Feb. 2023, doi: 10.3390/agriengineering5010027.
- [26] H. Kimm, I. Paik, and H. Kimm, “Performance Comparison of TPU, GPU, CPU on Google Colaboratory Over Distributed Deep Learning,” in *2021 IEEE 14th International Symposium on Embedded Multicore/Many-core Systems-on-Chip (MCSoc)*, IEEE, Dec. 2021, pp. 312–319. doi: 10.1109/MCSoc51149.2021.00053.
- [27] Y. Wu et al., “Demystifying Learning Rate Policies for High Accuracy Training of Deep Neural Networks,” in *2019 IEEE International Conference on Big Data (Big Data)*, IEEE, Dec. 2019, pp. 1971–1980. doi: 10.1109/BigData47090.2019.9006104.
- [28] D. J, S. D. V, A. S A, K. R, and L. Parameswaran, “Deep Learning based Detection of potholes in Indian roads using YOLO,” in *2020 International Conference on Inventive Computation Technologies (ICICT)*, IEEE, Feb. 2020, pp. 381–385. doi: 10.1109/ICICT48043.2020.9112424.
- [29] R. Yacouby and D. Axman, “Probabilistic Extension of Precision, Recall, and F1 Score for More Thorough Evaluation of Classification Models,” in *Proceedings of the First Workshop on Evaluation and Comparison of NLP Systems*, Stroudsburg, PA, USA: Association for Computational Linguistics, 2020, pp. 79–91. doi: 10.18653/v1/2020.eval4nlp-1.9.
- [30] M. Muhathir, “Compares the effectiveness of the bagging method in classifying spices using the histogram of oriented gradient feature extraction technique,” *Jurnal Teknik Informatika C.I.T Medicom*, vol. 15, no. 1, pp. 48–57, Mar. 2023, doi: 10.35335/cit.Vol15.2023.386.pp48-57.