

Deteksi Objek dan Pengenalan Karakter Plat Nomor Kendaraan dengan Metode Deep Learning

Ghina Salma Susilo*¹, Diyah Utami Kusumaning Putri ²

^{1,2}Departemen Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta, Indonesia

e-mail: *ghina.salma.susilo@mail.ugm.ac.id , diyah.utami.k@ugm.ac.id

Abstrak

Data Kementerian Perhubungan menunjukkan peningkatan jumlah kendaraan bermotor di Indonesia sebesar 4,30% pada tahun 2021. Seiring peningkatan jumlah kendaraan bermotor, Sistem Automatic Number Plate Recognition (ANPR) menjadi penting untuk mempermudah proses manajemen lalu lintas di Indonesia. Salah satu tantangan penerapan ANPR adalah kondisi cuaca. Untuk itu dalam penelitian ini dilakukan eksperimen mengenai pemanfaatan model deep learning dalam sistem ANPR yang dapat mengenali karakter plat nomor dalam kondisi cuaca panas, mendung dan hujan sedang.

Digunakan 2 modul deep learning, YOLOv5n untuk deteksi plat nomor dan framework TPS-ResNet-BiLSTM-Attn untuk pengenalan karakter. Masing-masing modul dilatih dengan 2 jenis dataset, Dataset 1 mencakup gambar dengan variasi kondisi cuaca panas dan mendung dan Dataset 2 mencakup gambar dengan variasi kondisi panas, mendung dan hujan sedang. Hasil dari variasi pelatihan model kemudian diuji menggunakan 1 dataset yang mencakup gambar plat nomor dalam kondisi cuaca panas, mendung dan hujan. Penelitian menghasilkan model dan metode pelatihan yang efisien. Metode pelatihan dengan performa terbaik untuk model YOLOv5n adalah dengan menggunakan Dataset 2 dan hyperparameter evolution. Didapatkan hasil pengujian berupa nilai mAP 0,893 dan f1-score 0,887. Metode pelatihan dengan performa terbaik pada framework TRBA adalah dengan menggunakan Dataset 2 (3200 data). Didapatkan hasil pengujian model berupa nilai akurasi sebesar 83,08%.

Kata kunci—deteksi objek, pengenalan karakter, YOLOv5, framework TRBA

Abstract

The Ministry of Transportation reported a 4.30% increase in the number of motorized vehicles in Indonesia in 2021, making the Automatic Number Plate Recognition (ANPR) system increasingly important for traffic management. However, implementing ANPR in different weather conditions is challenging. To address this issue, a study used two deep learning modules, YOLOv5n for license plate detection and the TPS-ResNet-BiLSTM-Attn framework for character recognition. Each module was trained with two types of datasets, Dataset 1, which included images with variations in sunny and cloudy weather conditions, and Dataset 2, which included images with variations in sunny, cloudy, and moderate rainy weather conditions. The best-performing training method for the YOLOv5n model was using Dataset 2 and evolution hyperparameters, with a testing result of mAP 0.893 and f1-score 0.887. The best-performing training method for the TRBA framework was using Dataset 2 (3200 data), with a testing result of 83.08% accuracy. The ANPR system has various applications in sectors such as command forces, parking management, and road safety. The combination of object detection and character recognition allows for the development of an end-to-end AI solution for automatic license plate recognition.

Keywords—object detection, character recognition, YOLOv5, framework TRBA

1. PENDAHULUAN

Pengenalan Plat Nomor Otomatis atau *Automatic Number Plate Recognition* (ANPR) memiliki peran penting dalam Sistem Transportasi Cerdas [1]. Hal ini dikarenakan umumnya plat nomor digunakan sebagai tanda pengenal kendaraan. Di Indonesia plat nomor memiliki fungsi sebagai identitas serta syarat suatu kendaraan melaju di jalan. Plat nomor juga digunakan untuk membantu polisi dalam mengidentifikasi kendaraan jika terjadi sesuatu pada kendaraan tersebut. ANPR digunakan secara luas di beberapa aplikasi seperti manajemen lalu lintas, pengawasan keamanan digital, pengenalan kendaraan, manajemen parkir, pemantauan lintas batas dan mencari kendaraan yang mencurigakan [2].

Masing-masing pengaplikasian ANPR memiliki tantangan tersendiri dalam proses deteksi dan pengenalan karakter plat nomor. Resolusi gambar rendah, sudut kamera berbeda, kondisi pencahayaan yang buruk, deformasi, orientasi, waktu pengambilan gambar, cuaca dan latar belakang lingkungan yang kompleks merupakan contoh tantangan dalam penerapan sistem ANPR [2]. Untuk mengatasi permasalahan tersebut, penelitian sebelumnya melatih model deep learning YOLOv3 menggunakan dataset AOLP dengan komposisi gambar kendaraan dalam variasi sudut pandang dan latar yang berbeda, didapatkan pengenalan rate-nya 96,1% [3]. Penelitian lain menggunakan augmentasi dengan teknik random blur untuk melatih model menghadapi ketajaman gambar yang buruk akibat sudut kamera atau kecepatan kendaraan dan didapatkan nilai Recall untuk akhir proses pengenalan karakter plat nomor adalah 97,72% [4]. Di Indonesia sendiri, selain kondisi cahaya terang, langit mendung dan cahaya gelap, kondisi alam yang perlu diperhatikan adalah kondisi hujan. Untuk itu pada penelitian ini akan dilakukan penelitian mengenai deteksi plat nomor dan pengenalan karakter pada kondisi cuaca panas terik, mendung dan hujan sedang.

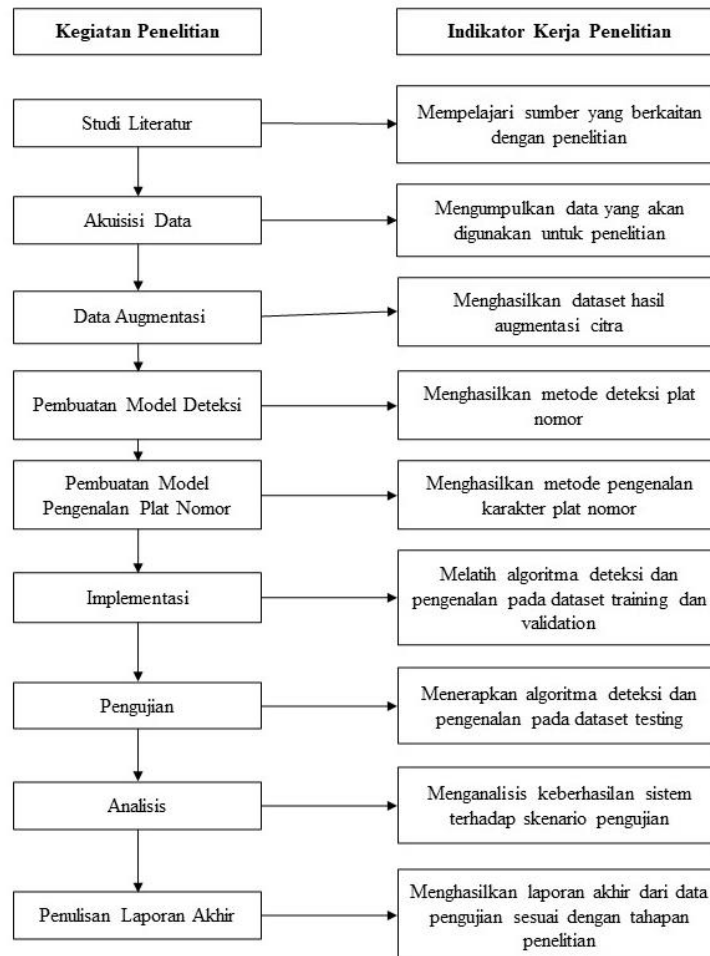
Proses ANPR umumnya dibagi menjadi dua tahap, deteksi plat nomor dan pengenalan karakter plat nomor. Tahap deteksi plat nomor digunakan model *deep learning* dengan kemampuan deteksi. Pada penelitian sebelumnya digunakan model YOLOv5 untuk deteksi plat nomor dalam sistem identifikasi nomor kendaraan dan didapatkan hasil baik, yaitu nilai *rate* deteksi plat nomor sebesar 98,60% [5]. Pada penelitian lain, YOLOv5 juga digunakan pada sistem pengenalan plat nomor untuk lokalisasi plat nomor [6].

Tahap selanjutnya adalah pengenalan karakter. Penelitian yang dilakukan Hengliang Shi dan Dongnan Zhao (2023) melakukan proses pengenalan karakter tanpa segmentasi, digunakan metode kombinasi modul yang terdiri dari feature extraction (CNN), sequence modelling (GRU) dan prediction (CTC). Penelitian lain yang dilakukan oleh Baek et al [7] digunakan framework Scene Text Recognition (STR) 4 tahap untuk melatih pengenalan karakter pada gambar natural, seperti teks nama tempat wisata atau teks nama toko. Dalam penelitian ini dilakukan perbandingan penggunaan model untuk tiap tahapnya. Ditemukan performa *framework* terbaik dengan komposisi model Thin Plate Spline pada tahap *transformation*, Residual Network pada tahap *feature extraction*, Bi-LSTM pada tahap *sequence modelling*, dan *Attention Network* pada tahap *prediction*. Kombinasi ini kemudian disingkat TRBA. Model tersebut mengungguli model lain seperti VGG dan RCNN dalam modul feature extraxtion dan CTC dalam modul prediction.

Berdasarkan hasil pada penelitian sebelumnya, dalam penelitian ini akan digunakan model YOLOv5 pada tahapan deteksi plat nomor dan model TRBA pada tahapan pengenalan karakter plat nomor. Kombinasi penggunaan model YOLO dan TRBA kemudian diujicobakan pada dataset plat nomor Indonesia yang didapatkan dari CCTV UGM. Untuk melatih model dalam mengenali plat nomor saat keadaan hujan sedang, digunakan dataset yang diambil saat keadaan hujan dan gambar yang di-augmentasi dengan menambah *noise* yang menyerupai bentuk hujan.

2. METODE PENELITIAN

Penelitian ini memiliki tahapan penelitian yang ditunjukkan pada diagram yang terdapat dalam Gambar 2.1.



Gambar 2. 1 Tahapan Penelitian

2.1 Akuisisi Data

Data yang digunakan untuk pelatihan model merupakan dataset plat nomor Indonesia yang didapatkan dari video CCTV di pintu masuk dan pintu keluar Boulevard UGM dan video YouTube. Terdiri dari gambar kendaraan dalam kondisi cuaca panas terik, mendung dan hujan sedang. Gambar plat nomor diambil dari sisi depan dan belakang kendaraan. Jenis kendaraan yang terdapat dalam dataset ini adalah kendaraan motor dan mobil pribadi dengan warna plat nomor hitam tulisan putih ataupun plat nomor putih tulisan hitam.

Gambar yang telah terkumpul kemudian dilakukan proses anotasi gambar. Pada penelitian ini dilakukan dua kali anotasi gambar untuk dua dataset yang berbeda. Anotasi gambar dataset pada tahap training deteksi digunakan tools berupa aplikasi labelImg. Hasil dari proses anotasi menggunakan labelImg untuk model YOLOv5 menghasilkan file .txt yang didalamnya terdapat informasi lokasi objek dalam gambar. Format anotasi YOLOv5 menggunakan koordinat x_center , y_center , $width$, dan $height$ untuk menentukan bounding box dan juga terdapat informasi mengenai kelas dari objek yang dideteksi, dalam tahap ini hanya digunakan satu kelas yaitu license plate.

Anotasi gambar untuk tahap pengenalan karakter adalah dengan memberi label atau nama pada file gambar plat nomor sesuai dengan teks yang terdapat pada gambar plat nomor

tersebut. Nantinya nama file ini digunakan untuk membuat dataset dalam bentuk LMDB (Lightning Memory-Mapped Database), yaitu format dataset yang digunakan pada model pengenalan karakter plat nomor. Dataset LMDB menggunakan teknik memory-mapping untuk mengakses data, sehingga memungkinkan akses data yang cepat dan efisien.

2. 2 Augmentasi Data

Augmentasi data merupakan proses memodifikasi data asli dengan tujuan menambah sampel baru pada data latih [8]. Augmentasi data pada penelitian ini memiliki tujuan khusus yaitu untuk meniru perubahan alami citra plat nomor dalam suatu kondisi cuaca. Digunakan augmentasi dengan penambahan noise yang menyerupai bentuk hujan seperti pada Gambar 2.2.



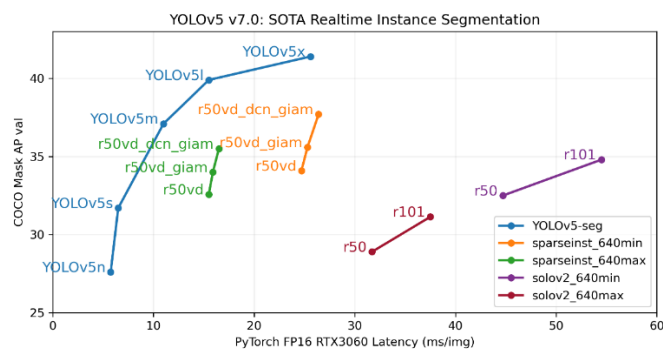
Gambar 2. 2 Hasil Augmentasi Citra [9]

2. 3 Perancangan Sistem

2. 3.1 Model Deteksi Plat Nomor

Model deteksi plat nomor yang digunakan dalam penelitian ini adalah model YOLOv5. YOLOv5 merupakan model dalam rangkaian model computer vision You Only Look Once (YOLO). Model YOLOv5 dipilih karena memiliki arsitektur yang didesain untuk deteksi objek. Arsitektur ini meliputi pembuatan fitur dari gambar masukan. Fitur-fitur ini kemudian dimasukkan melalui sistem prediksi untuk membuat bounding box objek dan memprediksi kelasnya. Model YOLOv5 yang telah dilatih pada dataset Plat Nomor Indonesia kemudian digunakan untuk mendeteksi bounding box objek plat nomor pada dataset. Hasil deteksi bounding box ini kemudian digunakan sebagai acuan untuk melakukan cropping gambar sesuai objek yang dideteksi.

Terdapat lima versi YOLOv5 diantaranya: *nano* (*n*), *small* (*s*), *medium* (*m*), *large* (*l*), dan *extra-large* (*x*) dengan perbedaan performa tiap variasinya dapat dilihat pada grafik dalam Gambar 2.3. Pada penelitian ini dipilih variasi yang paling ringan yaitu YOLOv5n untuk mendeteksi plat nomor.



Gambar 2. 3 Perbandingan performa keluarga YOLOv5 [10]

Arsitektur dari model YOLOv5n yang digunakan dalam penelitian dapat dilihat pada Tabel 2.1.

Tabel 2. 1 Tabel parameter arsitektur YOLOv5n

C	From	n	Parameters	Module	Arguments
0	-1	1	3520	Conv	[3, 16, 6, 2, 2]
1	-1	1	18560	Conv	[16, 64, 3, 2]
2	-1	1	18816	C3	[32, 32, 1]
3	-1	1	73984	Conv	[32, 64, 3, 2]
4	-1	2	115712	C3	[64, 64, 2]
5	-1	1	295424	Conv	[64, 128, 3, 2]
6	-1	3	625152	C3	[128, 256, 3]
7	-1	1	1180672	Conv	[128, 256, 3, 2]
8	-1	1	1182720	C3	[256, 256, 1]
9	-1	1	656896	SPPF	[256, 256, 5]
10	-1	1	131584	Conv	[256, 128, 1, 1]
11	-1	1	0	Upsampling	[None, 2, 'nearest']
12	[-1,6]	1	0	Concat	[1]
13	-1	1	361984	C3	[256, 128, 1, False]
14	-1	1	33024	Conv	[128, 64, 1, 1]
15	-1	1	0	Upsampling	[None, 2, 'nearest']
16	[-1,4]	1	0	Concat	[1]
17	-1	1	90880	C3	[128, 64, 1, False]
18	-1	1	147712	Conv	[64, 64, 3, 2]
19	[-1,14]	1	0	Concat	[1]
20	-1	1	296448	C3	[128, 128, 1, False]
21	-1	1	590336	Conv	[128, 128, 3, 2]
22	[-1,10]	1	0	Concat	[1]
23	-1	1	1182720	C	[256, 256, 1, False]
C	From	n	Parameters	Module	Arguments
24	[17, 20, 23]	1	16182	Detect	[1, [[10, 13, 16, 30, 33, 23], [30, 61, 62, 45, 59, 119], [116, 90, 156, 198, 373, 326]], [64, 128, 256]]

2. 3.2 Model Pengenalan Karakter Plat Nomor

Model yang digunakan dalam tahap pengenalan karakter merupakan scene text recognition (STR) framework 4 tahap yang digunakan pada penelitian [6]. STR merupakan framework yang digunakan untuk pengenalan teks pada gambar dengan kondisi tidak sempurna. Kondisi gambar yang tidak sempurna, sering ditemukan pada pengambilan gambar di jalan, dimana kondisi ini sesuai dengan penggunaan model dalam penelitian ini. Pada penelitian ini, model digunakan untuk mengenal karakter plat nomor yang terdapat pada gambar dari CCTV dan juga dashcam. Gambar yang didapatkan dari CCTV dan juga dashcam memiliki peluang yang besar untuk terkena noise. Noise yang terjadi disebabkan oleh beberapa faktor diantaranya; kecepatan kendaraan sehingga gambar sedikit blur, cahaya yang berubah-ubah sehingga terdapat perbedaan tingkat pencahayaan, kondisi plat nomor yang rusak sehingga ada karakter yang tebal atau karakter yang memudar.

Tahapan yang digunakan dalam penelitian ini diantaranya tahap transformasi, tahap ekstraksi fitur, tahap sequencing model, dan tahap prediksi. Tahap transformasi menggunakan modul transformasi *thin-plate spline* (TPS), tahap ekstraksi fitur menggunakan model ResNet, tahap sequencing model menggunakan model Bi-LSTM, dan pada tahap prediksi menggunakan model Attn. Masing-masing arsitektur model yang digunakan pada penelitian ini dapat dilihat pada Gambar 2.4.

Layer (type:depth-idx)	Output Shape	Param #
Model_Summary	[1, 26, 256]	--
└─TPS_SpatialTransformerNetwork: 1-1	[1, 1, 32, 100]	--
└─LocalizationNetwork: 2-1	[1, 20, 2]	--
└─Sequential: 3-1	[1, 512, 1, 1]	1,550,784
└─Sequential: 3-2	[1, 256]	131,328
└─Linear: 3-3	[1, 40]	10,280
└─ResNet_FeatureExtractor: 1-2	[1, 512, 1, 26]	--
└─ResNet: 2-2	[1, 512, 1, 26]	--
└─Conv2d: 3-4	[1, 32, 32, 100]	288
└─BatchNorm2d: 3-5	[1, 32, 32, 100]	64
└─ReLU: 3-6	[1, 32, 32, 100]	--
└─Conv2d: 3-7	[1, 64, 32, 100]	18,432
└─BatchNorm2d: 3-8	[1, 64, 32, 100]	128
└─ReLU: 3-9	[1, 64, 32, 100]	--
└─MaxPool2d: 3-10	[1, 64, 16, 50]	--
└─Sequential: 3-11	[1, 128, 16, 50]	230,144
└─Conv2d: 3-12	[1, 128, 16, 50]	147,456
└─BatchNorm2d: 3-13	[1, 128, 16, 50]	256
└─ReLU: 3-14	[1, 128, 16, 50]	--
└─MaxPool2d: 3-15	[1, 128, 8, 25]	--
└─Sequential: 3-16	[1, 256, 8, 25]	2,099,712
└─Conv2d: 3-17	[1, 256, 8, 25]	589,824
└─BatchNorm2d: 3-18	[1, 256, 8, 25]	512
└─ReLU: 3-19	[1, 256, 8, 25]	--
└─MaxPool2d: 3-20	[1, 256, 4, 26]	--
└─Sequential: 3-21	[1, 512, 4, 26]	22,555,648
└─Conv2d: 3-22	[1, 512, 4, 26]	2,359,296
└─BatchNorm2d: 3-23	[1, 512, 4, 26]	1,024
└─ReLU: 3-24	[1, 512, 4, 26]	--
└─Sequential: 3-25	[1, 512, 4, 26]	14,161,920
└─Conv2d: 3-26	[1, 512, 2, 27]	1,048,576
└─BatchNorm2d: 3-27	[1, 512, 2, 27]	1,024
└─ReLU: 3-28	[1, 512, 2, 27]	--
└─Conv2d: 3-29	[1, 512, 1, 26]	1,048,576
└─BatchNorm2d: 3-30	[1, 512, 1, 26]	1,024
└─ReLU: 3-31	[1, 512, 1, 26]	--
└─AdaptiveAvgPool2d: 1-3	[1, 26, 512, 1]	--
└─Sequential: 1-4	[1, 26, 256]	--
└─BidirectionalLSTM: 2-3	[1, 26, 256]	--
└─LSTM: 3-32	[1, 26, 512]	1,576,960
└─Linear: 3-33	[1, 26, 256]	131,328
└─BidirectionalLSTM: 2-4	[1, 26, 256]	--
└─LSTM: 3-34	[1, 26, 512]	1,052,672
└─Linear: 3-35	[1, 26, 256]	131,328
Total params: 48,848,584		
Trainable params: 48,848,584		
Non-trainable params: 0		
Total mult-adds (G): 5.29		
Input size (MB): 0.01		
Forward/backward pass size (MB): 38.82		
Params size (MB): 195.39		
Estimated Total Size (MB): 234.23		

Gambar 2. 4 Arsitektur framework STR

2. 4 Pelatihan Model

Proses training model deteksi dan pengenalan karakter plat nomor dilakukan secara terpisah. Pada penelitian ini, pelatihan model YOLOv5 menggunakan 2 variasi *hyperparameter* dan 3 variasi dataset. *Hyperparameter* yang digunakan adalah *hyperparameter default* dari developer YOLOv5 dan *hyperparameter evolution*. *Hyperparameter evolution* merupakan metode optimasi *hyperparameter* menggunakan *Genetic Algorithm* (GA). Selanjutnya, 3 variasi dataset yang digunakan dalam proses ini diantara: (1)Dataset dengan komposisi gambar dalam kondisi cuaca panas terik dan mendung. (2)Dataset dengan komposisi gambar dalam kondisi cuaca panas terik, mendung dan hujan yang diwakilkan dengan gambar yang diberi augmentasi noise menyerupai kondisi hujan. (3)Dataset dengan komposisi gambar dalam kondisi cuaca hujan yang diwakilkan dengan gambar yang diberi augmentasi noise menyerupai kondisi hujan

Model YOLOv5n dengan performa terbaik kemudian digunakan untuk mendeteksi *bounding box*. Selanjutnya gambar dipotong sesuai dengan *bounding box* hasil prediksi. Dataset yang telah dipotong sesuai dengan prediksi *bounding box* membentuk dataset untuk pelatihan framework TRBA. Pada tahap ini, model dilatih dengan menggunakan 2 variasi dataset. Variasi yang digunakan seperti variasi dataset 1 dan 2 pada pelatihan model YOLOv5. Untuk melatih framework TRBA digunakan model *pre-trained*. Model *pre-trained* merupakan model yang telah dilatih sebelumnya pada dataset yang besar dan kompleks, pada penelitian ini digunakan

model pre-trained yang telah dilatih pada dataset MJSynth dan SynthText dengan jumlah data sebanyak 14.4 juta gambar.

2. 4 Pengujian Model

Deteksi plat nomor merupakan proses untuk menemukan area plat nomor pada gambar kendaraan. Tujuannya adalah untuk memperoleh area plat nomor yang tepat sehingga dapat digunakan untuk proses pengenalan karakter plat nomor. Pada penelitian ini model deteksi yang telah dilatih dengan beberapa skenario kemudian diuji menggunakan data uji yang sama, digunakan metrik evaluasi *mAP*, *Precision*, dan *Recall* untuk mengukur performa model deteksi plat nomor. Selanjutnya, model pengenalan karakter plat nomor yang telah dilatih dengan 2 variasi dataset diuji menggunakan data set yang sama. Untuk menilai performa modelnya digunakan matrik evaluasi *accuracy*. Model pengenalan dikatakan berhasil jika teks hasil prediksinya sama dengan teks pada ground truth.

3. HASIL DAN PEMBAHASAN

3. 1 Dataset

Terdapat 2 jenis dataset berdasarkan fungsinya, yaitu dataset untuk model YOLOv5n pada tahap deteksi plat nomor dan dataset untuk *framework TRBA* pada tahap pengenalan karakter plat nomor. Berdasarkan kombinasi kondisi dalam dataset, model YOLOv5n memiliki 3 variasi dataset latih dan 1 dataset uji seperti yang ditunjukkan pada Tabel 3.1, sedangkan *framework TRBA* memiliki 2 variasi dataset latih dan 1 dataset uji seperti yang ditunjukkan pada Tabel 3.2.

Tabel 3. 1 Variasi dataset model YOLOv5n

Nama	Set	Kondisi Cuaca	Jumlah	Keterangan
Dataset 1	<i>Train</i>	Cerah	600	Sumber: CCTV pintu masuk dan keluar <i>Boulevard</i> UGM
		Mendung	600	
	<i>Validation</i>	Cerah	200	
		Mendung	200	
Dataset 2	<i>Train</i>	Cerah	600	Sumber: CCTV pintu masuk dan keluar <i>Boulevard</i> UGM Augmentasi: digunakan augmentasi <i>noise</i> yang menyerupai rintik hujan, digunakan <i>library imgaug</i> .
		Mendung	600	
		Hujan – dengan augmentasi	1200	
	<i>Validation</i>	Cerah	200	
		Mendung	200	
		Hujan – dengan augmentasi	400	
Dataset 3	<i>Train</i>	Hujan – dengan augmentasi	1200	Digunakan augmentasi <i>noise</i> yang menyerupai rintik hujan (<i>library imgaug</i>)
	<i>Validation</i>	Hujan – dengan augmentasi	400	
Dataset Test	<i>Test</i>	Cerah	100	Sumber: CCTV pintu masuk dan keluar <i>Boulevard</i> UGM dan <i>YouTube</i> Augmentasi: digunakan augmentasi <i>noise</i> yang menyerupai rintik hujan, digunakan <i>library imgaug</i>
		Mendung	100	
		Hujan – dengan augmentasi	100	
		Hujan	100	

Tabel 3. 2 Variasi dataset framework TRBA

Nama	Set	Kondisi Cuaca	Jumlah	Keterangan
Dataset 1	<i>Train</i>	Cerah	600	Sumber: Potongan gambar plat nomor hasil proses deteksi plat nomor.
		Mendung	600	
	<i>Validation</i>	Cerah	200	
		Mendung	200	
Dataset 2	<i>Train</i>	Cerah	600	
		Mendung	600	
		Hujan – dengan augmenatsi	1200	
	<i>Validation</i>	Cerah	200	
		Mendung	200	
		Hujan – dengan augmenatsi	400	
Dataset Test	<i>Test</i>	Cerah	100	
		Mendung	100	
		Hujan – dengan augmenatsi	100	
		Hujan	100	

3. 2 Hasil Pelatihan dan Pengujian Model Deteksi Plat Nomor

Pelatihan model YOLOv5n menggunakan 2 jenis *hyperparameter*, *hyperparameter default* dan *hyperparameter evolution*. Perbedaan kedua jenis *hyperparameter* ini disajikan dalam Tabel 3.3.

Tabel 3. 3 Perbedaan *hyperparameter default* dan *hyperparameter evolution*

<i>Hyperparameter</i>	<i>Default</i>	<i>Evolution</i>
<i>lr0</i>	0,01	0,014505
<i>lrf</i>	0,01	0,01078
<i>momentum</i>	0,937	0,96121
<i>weight_decay</i>	0,0005	0,00051
<i>warmup_epochs</i>	3,0	1,7172
<i>warmup_momentum</i>	0,8	0,49748
<i>warmup_bias_lr</i>	0,1	0,10346
<i>box</i>	0,05	0,0396
<i>cls</i>	0,5	0,4918
<i>cls_pw</i>	1,0	1,0125
<i>obj</i>	1,0	1,1858
<i>obj_pw</i>	1,0	1,0632
<i>anchor_t</i>	4,0	3,896
<i>hsv_h</i>	0,015	0,01589
<i>hsv_s</i>	0,7	0,72807
<i>hsv_v</i>	0,4	0,59911
<i>translate</i>	0,1	0,10551
<i>scale</i>	0,5	0,42144
<i>anchor</i>	3,0	2,0

Pelatihan model YOLOv5n pada penelitian ini menggunakan metode *early stop learning*. Dimana training model akan berhenti secara otomatis jika setelah 20 epoch tidak

terjadi perbaikan akurasi. Hasil dari proses training model deteksi plat nomor dengan YOLOv5n dapat dilihat pada Tabel 3.4.

Tabel 3. 4 Hasil pelatihan model YOLOv5n

Hyperparameter	Dataset	epoch	Precision	Recall	F1-Score	mAP	time
Default	1	98	0,961	0,951	0,956	0,986	39 m 50 s
Evolution	1	84	0,953	0,966	0,959	0,983	38 m 49 s
Default	2	100	0,971	0,959	0,965	0,989	1 h 23 m 6 s
Evolution	2	88	0,988	0,957	0,972	0,992	1 h 19 m 22 s
Default	3	78	0,972	0,933	0,952	0,981	37 m 45 s
Evolution	3	102	0,980	0,953	0,966	0,986	47 m 9 s

Tabel 3.4 menunjukkan tidak terdapat perbedaan yang berarti pada performa model yang dilatih dengan variasi dataset dan hyperparameter. Nilai performa model tertinggi pada proses training terjadi pada model yang dilatih menggunakan Dataset 2. Selanjutnya, penggunaan *hyperparameter evolution* mampu meningkatkan performa model. Namun pada penelitian ini peningkatan yang diraih tidak sebanding dengan proses yang perlu dilalui untuk mendapatkan *hyperparameter evolution*, sehingga penggunaan *hyperparameter default* lebih disarankan karena prosesnya yang lebih efisien. Model yang telah dilatih kemudian diuji menggunakan dataset test seperti yang dijelaskan dalam Tabel 3.1. Hasil pengujian model YOLOv5n dapat dilihat pada Tabel 3.5.

Tabel 3. 5 Hasil pengujian model YOLOv5n

Hyperparameter	Dataset	Precision	Recall	F1-Score	mAP
Default	1	0,920	0,781	0,845	0,838
Evolution	1	0,949	0,808	0,873	0,874
Default	2	0,942	0,806	0,869	0,877
Evolution	2	0,962	0,823	0,887	0,893
Default	3	0,911	0,749	0,822	0,801
Evolution	3	0,915	0,830	0,870	0,866

Hasil pengujian model YOLOv5 menunjukkan secara umum YOLOv5n mampu secara robust mendeteksi plat nomor kendaraan Indonesia dalam kondisi cuaca panas terik, mendung, dan hujan sedang. Model terbaik yang dihasilkan dari variasi training pada penelitian ini adalah model yang dilatih menggunakan Dataset2 dan hyperparameter evolution. Penggunaan dataset asli dan dataset yang diberi augmentasi noise secara bersamaan diperlukan untuk memaksimalkan performa model YOLOv5n.

3. 3 Hasil Pelatihan dan Pengujian Model Pengenalan Karakter Plat Nomor

Model pengenalan karakter plat nomor dalam penelitian ini digunakan untuk mengenali karakter plat nomor pada potongan gambar plat nomor. Potongan gambar plat nomor merupakan gambar dataset yang dipotong sesuai dengan prediksi bounding box yang dilakukan oleh model YOLOv5n. Hasil pelatihan framework TRBA dapat dilihat pada Tabel 3.6.

Tabel 3. 6 Hasil pelatihan framework TRBA

Model	Dataset	epoch	accuracy	waktu
TPS-ResNet-BiLSTM-Attn	1	100	93,50 %	27 h 30 m
TPS-ResNet-BiLSTM-Attn	2	100	85,79 %	59 h 41 m

Pelatihan model pengenalan karakter plat nomor menggunakan framework TRBA menunjukkan hasil akurasi pelatihan dengan dataset 1 memiliki akurasi yang lebih tinggi jika

dibandingkan dengan pelatihan dengan dataset 2. Hal ini menunjukkan bahwa augmentasi hujan yang digunakan dalam dataset 2 mempengaruhi kemampuan model dalam mengenali karakter plat nomor. Model lebih sulit mengenali dataset yang diberi augmentasi hujan. Model pengenalan karakter yang telah dilatih dengan dua macam dataset kemudian diuji dengan dataset test yang sama untuk dapat dibandingkan. Hasil pengujian dapat dilihat pada Tabel 3.7.

Tabel 3. 7 Hasil pengujian framework TRBA


Model	Dataset	accuracy
TPS-ResNet-BiLSTM-Attn	1	74,75 %
TPS-ResNet-BiLSTM-Attn	2	83,08 %

Tabel 3.7 menunjukan framework TRBA yang dilatih menggunakan Dataset 1 memiliki akurasi sebesar 74,75% sedangkan framework TRBA yang dilatih menggunakan Dataset 2 memiliki akurasi yang lebih tinggi yaitu sebesar 83,08%. Dari hasil pengujian dapat disimpulkan bahwa jumlah dataset yang digunakan untuk melatih model dapat mempengaruhi performa model yang dihasilkan, pada penelitian ini framework TRBA menghasilkan performa yang baik ketika dilatih menggunakan 3200 gambar. Metode yang digunakan untuk memperbanyak jumlah dan variasi data dapat menggunakan augmentasi noise yang dapat meniru kondisi hujan. Performa model saat proses training dan testing tidak jauh berbeda. Hal ini menunjukkan bahwa model yang dihasilkan tidak mengalami overfitting.

3. 3 Analisis Kesalahan Pengenalan Karakter Plat Nomor


Terdapat 50 karakter yang gagal dikenali oleh model pada plat nomor tanpa noise, 3 diantaranya dianggap tidak ada dan sisanya salah mengenali karakter dengan karakter lain. Tiga karakter yang dianggap tidak ada adalah karakter ke-3 pada keterangan sub daerah plat nomor. Kegagalan model dalam mengenali digit ke-3 pada keterangan sub daerah, dikarenakan komposisi data training yang tidak seimbang dalam variasi jumlah digit terakhir. Hanya 8% dari total keseluruhan dataset yang memiliki 3-digit pada keterangan sub daerah plat nomor.

Dari 47 instances kesalahan, terdiri dari 6 angka dan 12 huruf dengan kesalahan terbanyak pada angka 6 yang terbaca 8. Baik angka 6 maupun angka 8 sama-sama memiliki jumlah yang cukup pada dataset train yaitu 550 instances untuk angka 6 dan 541 instances untuk angka 8, namun keduanya memiliki bentuk yang hampir sama jika dilihat dari jarak jauh. Pada beberapa kasus, sudut pandang dan jarak dapat membuat angka 6 terlihat seperti angka 8, hal ini seperti yang terlihat pada Gambar 3.1.



Gambar 3. 1 Angka 6 terlihat seperti angka 8

Selanjutnya, 5 karakter dengan akurasi terendah adalah Q (80,00%), W (83,33%), M (84,85%), Z (88,37%), dan I (93,33%). Huruf Q terbaca O atau D, umumnya huruf O dan Q pada plat nomor Indonesia memiliki bentuk yang sangat berbeda seperti pada Gambar 3.2, namun pada beberapa kasus, model salah mengenali huruf Q sebagai huruf O. Hal ini terjadi karena pada dataset train hanya terdapat sedikit instance untuk huruf O yaitu sebanyak 100 instances sehingga model belum robust dalam mengenali huruf O.



Gambar 3. 2 Huruf (a) O dan huruf (b)Q pada plat nomor Indonesia

Selanjutnya, pada beberapa font plat nomor Indonesia, jika dilihat dari jarak yang jauh, huruf Q memiliki kemiripan dengan huruf D seperti yang terlihat pada Gambar 3.3. Disisi lain, kegagalan model dalam mengenali huruf Q dikarenakan huruf Q termasuk dalam huruf yang jarang muncul di dataset train, hanya terdapat 97 instances dari total keseluruhan 12673 instances (0.76%).



Gambar 3. 3 Huruf Q dan D pada plat nomor Indonesia

Huruf selanjutnya adalah huruf W, terdapat 3 kesalahan pengenalan huruf W, huruf W salah dikenali model sebagai huruf H, M, dan N seperti yang terlihat pada Gambar 3.4. Huruf W juga termasuk dalam huruf yang jarang muncul dalam dataset, baik dataset train maupun dataset test, hanya 18 instance pada data train dan 64 instances pada data test.



Gambar 3. 4 Huruf (a) W, (b) H, (c) M, & (d) N dalam plat nomor Indonesia

Huruf selanjutnya adalah huruf M, terdapat 5 kesalahan pengenalan huruf M, huruf M salah dikenali dengan huruf H, N, dan W. Kemiripan keempat huruf ini dapat dilihat pada Gambar 6.4. Huruf M termasuk dalam huruf yang jarang muncul dalam dataset train, yaitu hanya sebanyak 132 instance dari total keseluruhan 12673 instances. Huruf selanjutnya adalah huruf Z, huruf Z salah dikenali sebagai angka 2 dan huruf L, kemiripan ketiga karakter ini dapat dilihat pada Gambar 3.5. Huruf Z termasuk huruf yang jarang muncul dalam dataset train, yaitu hanya sebanyak 103 instances dari total keseluruhan 12673 instances.



Gambar 3. 5 Huruf (a) Z, angka (b) 2, & huruf (c) L dalam plat nomor Indonesia

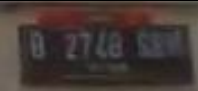





Huruf terakhir dalam 5 karakter dengan akurasi terendah adalah huruf I, terdapat 2 kesalahan pengenalan huruf I, huruf I salah dikenali dengan huruf T. Kemiripan kedua karakter ini dapat dilihat pada Gambar 3.6. Huruf I juga termasuk huruf yang jarang muncul dalam dataset train dan dataset test, yaitu hanya 145 instances pada dataset train dan 30 instances pada dataset test.



Gambar 3. 6 Huruf TI pada 2-digit terakhir plat nomor terbaca TT

Kesalahan model dalam mengenali karakter merata dalam tiga kondisi cuaca di Indonesia, yaitu panas, mendung, dan hujan sedang, artinya kondisi cuaca tidak begitu mempengaruhi kemampuan model dalam mengenali plat nomor. Model mampu mengenali karakter plat nomor dalam kondisi cuaca panas terik, mendung, dan hujan sedang, selama plat nomor mampu dibaca oleh manusia. Noise yang membuat model gagal dalam mengenali karakter plat nomor Indonesia seperti yang dijelaskan pada Tabel 3.8.

Tabel 3. 8 Noise yang terdapat pada plat nomor Indonesia

Plat Nomor	Noise
	Noise berupa tetesan hujan yang mengenai kaca yang menyebabkan karakter plat nomor <i>blur</i> sampai tidak terbaca manusia
	Noise berupa cacat pada plat nomor, goresan cat diluar karakter yang menyebabkan karakter menyerupai karakter lain
	Noise berupa cacat pada plat nomor, goresan karakter tidak utuh sehingga menyebabkan karakter menyerupai karakter lain
	Noise berupa karakter yang terlalu tebal sehingga menyerupai karakter lain
	Noise berupa karakter yang terpotong
	Noise berupa karakter yang pudar

4. KESIMPULAN

Dari hasil penelitian yang dilakukan terhadap kemampuan model YOLOv5 dan *framework* TRBA dalam mendeteksi dan mengenali karakter plat nomor Indonesia, didapatkan kesimpulan bahwa, model YOLOv5 dan *framework* TRBA mampu secara *robust* mendeteksi dan mengenali karakter plat nomor Indonesia dalam kondisi cuaca panas, mendung dan hujan sedang. Lebih lanjut, model YOLOv5n mampu secara *robust* mendeteksi plat nomor dalam kondisi cuaca panas, mendung, dan hujan sedang, tanpa perlu dilatih menggunakan dataset yang diambil dalam kondisi cuaca hujan. Model YOLOv5n dengan performa terbaik adalah model YOLOv5n yang dilatih menggunakan Dataset 2 dan hyperparameter evolution, didapatkan nilai precision 0,95, recall 0,85, F1-Score 0,897, dan mAP 0,910. Dataset 2 merupakan dataset yang berisi 3200 data dengan kombinasi 1600 data asli dan 1600 data yang diberi augmentasi noise. Penggunaan Dataset 2 dalam pelatihan model mampu meningkatkan performa model YOLOv5n. Penggunaan hyperparameter evolution pada pelatihan model YOLOv5n mampu meningkatkan performa model YOLOv5n.

Model pengenalan karakter menggunakan *framework* TRBA mampu secara baik mengenali karakter plat nomor Indonesia dalam kondisi cuaca panas terik, mendung, dan hujan sedang. Dataset augmentasi diperlukan dalam pelatihan *framework* TRBA untuk memenuhi jumlah ideal dataset yang digunakan dalam melatih *framework*. *Framework* yang hanya menggunakan dataset asli mengalami overfitting, sedangkan *framework* yang dilatih dengan tambahan data augmentasi menghasilkan nilai akurasi pengujian yang lebih baik yaitu sebesar 83,03%. Selanjutnya, *noise* yang menyebabkan model gagal mengenali karakter bukanlah kondisi cuaca panas terik, mendung ataupun hujan sedang, melainkan *noise* yang berupa cacat pada plat nomor dan tetesan air pada kaca yang menyebabkan blur.

DAFTAR PUSTAKA

- [1] Prajapati, R.K., Bhardwaj, Y., Jain, R.K., & Hiran, K.K. 2023. "A Review Paper on Automatic Number Plate Recognition using Machine Learning: An In-Depth Analysis of Machine Learning Techniques in Automatic Number Plate Recognition: Opportunities and Limitation". IEEE. <https://doi.org/10.1109/CICTN57981.2023.10141318>.

- [2] Selmi, Z., Halima, M.-B., Pal, U. & Alimi, M.A., 2020. "DELP-DAR system for license plate detection and recognition". Pattern Recognition Letters. vol. 129, pp. 213-223.
- [3] Riaz, W., Azeem, A., Chenqiang, G., Yuxi, Z., Saifullah & Khalid, W., 2020. YOLO Based Recognition Method for Automatic License Plate Recognition. IEEE AEECA. pp. 87-90.
- [4] Al-batat, R., Angelopoulou, A., Premkumar, S., Hemanth, J. & Kapetanios, E., 2022. An End-to-End Automated License Plate Recognition System Using YOLO Based Vehicle and License Plate Detection with Vehicle Classification. Sensors. vol.22, pp. 9477-9494 <https://doi.org/10.3390/s22239477> .
- [5] Gayana., Crast., A.J., Achary., S., Dsouza, C., Moras, D.C. & Singh, K., 2022. "Enhanced Vehicle Plate Id entification using YOLO". ICACRS. ISBN. 978-1-6654-6084-2.
- [6] Shi, H. & Zhao, D., 2023. License Plate Recognition System Based on Improved YOLOv5 and GRU. IEEE Access. vol. 11, pp. 10429-10439.
- [7] Baek, J., Kim, G., Lee, J., Park, S., Han, D., Yun, S., Oh, S.J., & Lee, H. 2019. What is Wrong with Scene Text Recognition Model Comparisons? Dataset and Model Analysis. Clova AI Research. <https://doi.org/10.48550/arXiv.1904.01906> .
- [8] Awan, A.A., 2022. "A Complete Guide to Data Augmentation". Data Camp. <https://www.datacamp.com/tutorial/complete-guide-data-augmentation>
- [9] Saxena, U., 2018. Image Augmentation: Make it rait, make it snow. How to modify photos to train self-driving cars. <https://www.freecodecamp.org/news/image-augmentation-make-it-rain-make-it-snow-how-to-modify-a-photo-with-machine-learning-163c0cb3843f/>. [Accessed: 30-March-2023]
- [10] Jocher, G.; Chaurasia, A.; Stoken, A.; Borovec, J.;NanoCode012; Kwon, Y.; Michael, K.; TaoXie; Fang, J.;imyhxy; Lorna; Yifu, Z.; Wong, C.; V, A.; Montes, D.;Wang, Z.; Fati, C.; Nadar, J.; Laughing; UnglvKitDe; Sonck,V.; tkianai; yxNONG; Skalski, P.; Hogan, A.; Nair, D.;Strobel, M.; and Jain, M. 2022. ultralytics/yolov5: v7.0 -YOLOv5 SOTA Realtime Instance Segmentation.