

Tinjauan Literatur Teknik Pengenalan Plat Nomor Berbasis Deep Learning

Literature Review of License Plate Recognition Techniques Using Deep Learning

Nanang Cahyadi¹, Sherfina Salsabila², Sevierda Raniprima³, Vivi Monita⁴

^{1,2,3,4}Telecommunication Engineering Department, Telkom University

¹nanangcahyadi@telkomuniversity.ac.id

²sherfina@student.telkomuniversity.ac.id,

³sevierdar@telkomuniversity.ac.id,

⁴monitavivii@telkomuniversity.ac.id

Corresponding author: sherfina@student.telkomuniversity.ac.id

Abstrak. Artikel ini mengulas pengenalan plat nomor kendaraan (LPR) menggunakan teknik deep learning, yang kini menjadi penting dalam sistem transportasi cerdas, penegakan hukum, dan manajemen parkir. Deep learning, khususnya Convolutional Neural Networks (CNNs), telah menggantikan metode tradisional dengan sistem yang lebih akurat dan kuat, mampu menangani berbagai kondisi dunia nyata. Artikel ini membahas beberapa pendekatan *Deep Learning* dalam LPR, termasuk metode fusi, dua tahap, end-to-end, multi-cabang, dan generatif. Metode fusi menggabungkan *Deep Learning* dengan pemrosesan gambar tradisional untuk meningkatkan akurasi. Metode dua tahap memisahkan tugas deteksi dan pengenalan ke dalam model yang berbeda. Metode end-to-end menggunakan satu model untuk deteksi dan pengenalan, meningkatkan efisiensi dan mengurangi kesalahan. Metode multi-cabang menggunakan cabang jaringan saraf paralel untuk menangani berbagai tugas secara bersamaan, seperti deteksi plat dan pengenalan karakter. Metode generatif menggunakan Generative Adversarial Networks (GANs) untuk menciptakan gambar plat nomor yang realistis, meningkatkan kinerja pengenalan. Artikel ini mengevaluasi metode-metode tersebut pada dataset acuan dan mengidentifikasi tantangan, seperti meningkatkan ketahanan terhadap kondisi cuaca ekstrem, mengembangkan model ringan untuk pemrosesan real-time pada perangkat terbatas, serta menangani masalah privasi dan keamanan. Ulasan ini memberikan gambaran menyeluruh tentang kemajuan terbaru dalam teknologi LPR berbasis *Deep Learning* dan potensinya untuk berbagai aplikasi.

Kata kunci: CNNs, Deep Learning, GANs, Image Processing, ITS, LPR

Abstract. This article reviews vehicle license plate recognition (LPR) using Deep Learning techniques, which have become essential in intelligent transportation systems, law enforcement, and parking management. Deep learning, particularly Convolutional Neural Networks (CNNs), has replaced traditional methods with more accurate and robust systems capable of handling diverse real-world conditions. The article explores various Deep Learning approaches in LPR, including fusion, two-stage, end-to-end, multi-branch, and generative methods. Fusion methods combine Deep Learning with traditional image processing to enhance accuracy. Two-stage methods separate the detection and recognition tasks into different models. End-to-end methods use a single model for both detection and recognition, improving efficiency and reducing errors. Multi-branch methods employ parallel neural network branches to handle different tasks simultaneously, such as plate detection and character recognition. Generative methods use Generative Adversarial Networks (GANs) to create realistic license plate images, boosting recognition performance. The article evaluates these methods on benchmark datasets and identifies challenges, such as improving robustness under extreme weather conditions, developing lightweight models for real-time processing on constrained devices, and addressing privacy and security concerns. This review offers a comprehensive overview of the latest advancements in deep learning-based LPR technology and its potential applications.

Keywords: CNNs, Deep Learning, GANs, Image Processing, ITS, LPR

1 Pendahuluan

Teknologi Pengenalan Plat Nomor, yang juga dikenal sebagai License Plate Recognition (LPR) atau Automatic Number Plate Recognition (ANPR), telah menjadi komponen penting dalam bidang visi komputer. Teknologi ini mengotomatisasi deteksi, segmentasi, dan pengenalan plat nomor kendaraan dari gambar atau video, sehingga memberikan dampak signifikan pada sistem transportasi cerdas, penegakan hukum, dan manajemen parkir. LPR meningkatkan efisiensi lalu lintas dan membantu dalam identifikasi kendaraan yang terlibat dalam aktivitas ilegal. Implementasi yang sukses dapat dilihat pada sistem Electronic Road Pricing (ERP) di Singapura serta berbagai program penegakan lalu lintas otomatis di kota-kota Eropa, yang secara efektif mengurangi pelanggaran lalu lintas (Castro-Zunti, Yepez, & Ko, 2020).

Secara tradisional, sistem Pengenalan Plat Nomor bergantung pada fitur buatan manusia dan algoritma berbasis aturan, yang sering kali menghadapi kesulitan dalam kondisi dunia nyata yang beragam dan menantang. Munculnya teknik pembelajaran mendalam, khususnya Convolutional Neural Networks (CNN), telah mengubah pendekatan ini. Berbeda dengan metode tradisional yang bergantung pada fitur yang telah ditentukan sebelumnya dan menghadapi kesulitan dengan variasi pencahayaan, sudut, dan penghalang, CNN mampu mempelajari fitur hierarkis secara otomatis dari gambar mentah. Hal ini memungkinkan CNN untuk beradaptasi dengan lingkungan kompleks, seperti jalan raya yang padat atau area parkir, yang menghasilkan sistem Pengenalan Plat Nomor yang lebih kuat dan akurat (Chen, Yan, Yin, & Shi, 2020).

Salah satu keunggulan utama dari pengenalan plat berbasis *Deep Learning* adalah kemampuannya untuk menangani berbagai gaya, bahasa, dan format plat di berbagai wilayah. Sebagai contoh, penelitian tentang plat nomor Indonesia menunjukkan adaptabilitas *Deep Learning* terhadap berbagai format dan tantangan lingkungan, seperti perbedaan font, kode regional, dan ukuran plat yang bervariasi. Meskipun tantangan tersebut ada, model *Deep Learning* menunjukkan hasil yang menjanjikan dalam mendeteksi dan mengenali plat nomor Indonesia secara akurat (Adytia & Kusuma, 2021).

Sistem Pengenalan Plat Nomor juga harus mampu berfungsi dengan baik di lingkungan alami dengan variasi orientasi, skala, dan kondisi pencahayaan yang berbeda-beda. Metode *Deep Learning* terbukti efektif dalam skenario seperti ini, seperti yang terlihat pada sistem pengawasan di kota-kota seperti London dan New York, di mana plat nomor dapat dideteksi dan dikenali dengan akurat bahkan dalam kondisi yang menantang (Wang, Liu, Liu, & Xiao, 2019). Untuk meningkatkan efisiensi dan skalabilitas, peneliti mengintegrasikan *Deep Learning* dengan kerangka akselerasi perangkat keras, seperti OpenVINO, yang mengoptimalkan kinerja waktu nyata yang sangat penting untuk aplikasi seperti pemantauan lalu lintas dan pengumpulan tol. OpenVINO meningkatkan inferensi model, mengurangi latensi, dan memungkinkan operasi yang efektif bahkan dalam lingkungan dengan permintaan tinggi (Castro-Zunti, Yepez, & Ko, 2020).

Meskipun telah terjadi kemajuan yang signifikan, tantangan tetap ada dalam meningkatkan ketahanan model Pengenalan Plat Nomor di bawah kondisi cuaca ekstrem, pencahayaan buruk, dan gambar dengan resolusi rendah. Pengembangan model yang ringan untuk pemrosesan waktu nyata pada perangkat dengan sumber daya terbatas, serta penanganan masalah privasi dan keamanan, menjadi area penelitian penting di masa depan. Tinjauan literatur ini memberikan gambaran tentang teknologi Pengenalan Plat Nomor berbasis *Deep Learning* terkini, dengan membahas arsitektur kunci, mengevaluasi kinerja pada dataset acuan, dan mengidentifikasi celah penelitian serta arah penelitian selanjutnya.

2 Tinjauan Pustaka

Beberapa tinjauan literatur telah mengeksplorasi penerapan teknik *Deep Learning* dalam sistem Pengenalan Plat Nomor. Bagian ini menyajikan analisis komparatif dari tinjauan-tinjauan tersebut, menyoroti ruang lingkup, metodologi, dan temuan kritis yang dihasilkan. Beberapa tinjauan literatur berfokus pada evolusi pendekatan algoritmik, dengan menekankan transisi dari metode tradisional ke pembelajaran mendalam. Sebaliknya, tinjauan lain lebih berfokus pada aplikasi khusus, seperti manajemen lalu lintas atau penegakan hukum. Perbedaan dalam metodologi, termasuk kriteria seleksi studi dan metrik yang digunakan untuk mengevaluasi kinerja, memberikan wawasan unik tentang bidang ini. Tidak seperti tinjauan sebelumnya, analisis ini menawarkan perspektif yang lebih komprehensif dengan mengintegrasikan kemajuan terbaru dan mengidentifikasi kesenjangan dalam penelitian saat ini, khususnya di bidang pemrosesan real-time dan adaptasi terhadap kondisi


lingkungan yang beragam. Pendekatan ini mensintesis pengetahuan yang ada dan berkontribusi pada pemahaman yang lebih mendalam mengenai arah penelitian Pengenalan Plat Nomor di masa depan.

Salah satu survei komprehensif tentang pendekatan *Deep Learning* untuk deteksi kendaraan dan plat nomor membahas berbagai arsitektur *Deep Learning* yang digunakan dalam tugas Pengenalan Plat Nomor (Jørgensen, 2017). Survei ini menyoroti keunggulan signifikan *Deep Learning* dibandingkan teknik tradisional, terutama dalam mempelajari dan mengekstraksi fitur dari data mentah secara otomatis tanpa perlu rekayasa fitur manual. Berbeda dengan metode konvensional yang sering mengalami kesulitan dalam menangani variasi penampilan plat nomor, pencahayaan, dan kondisi lingkungan, arsitektur *Deep Learning* seperti Convolutional Neural Networks (CNN) dan Recurrent Neural Networks (RNN) telah menunjukkan kinerja yang lebih unggul dalam menghadapi kompleksitas ini. Demikian pula, tinjauan lain berfokus pada metode *Deep Learning* untuk sistem Automatic Number Plate Recognition (ANPR), yang mencakup berbagai tahap ANPR dan membandingkan kinerja berbagai model pembelajaran mendalam, serta menekankan keunggulan mereka dibandingkan metode tradisional (Bhujbal & Mane, 2019).

Selain itu, sebuah tinjauan sistematis menganalisis kinerja berbagai teknik pengenalan, termasuk pendekatan pembelajaran mesin konvensional dan *Deep Learning* (Al Awaimri, Fageeri, Moyaid, & Alhasanah, 2021). Tinjauan ini membahas faktor-faktor yang mempengaruhi akurasi pengenalan plat, seperti kualitas gambar, variasi plat, dan kondisi lingkungan. Misalnya, penelitian menunjukkan bahwa gambar dengan resolusi rendah atau yang diambil dalam kondisi pencahayaan buruk, seperti di malam hari atau saat hujan lebat, dapat secara signifikan mengurangi akurasi sistem pengenalan.

Untuk plat nomor Arab, yang menimbulkan tantangan tersendiri karena kompleksitas karakter Arab dan variasi format plat di berbagai negara Arab, sebuah tinjauan menekankan perlunya mengembangkan model *Deep Learning* yang khusus (Alkawsi, Baashar, Alkahtani, Kiong, Habeeb, & Aliubari, 2021). Model-model ini secara signifikan meningkatkan akurasi pengenalan ketika disesuaikan dengan karakteristik unik plat nomor Arab. Di luar Pengenalan Plat Nomor, sebuah tinjauan tentang metode berbasis *Deep Learning* dalam analisis gambar untuk deteksi kendaraan memberikan wawasan berharga dalam konteks yang lebih luas dari sistem transportasi cerdas (ITS) (Vishwakarma & Jain, 2023). Deteksi kendaraan yang akurat sering kali menjadi prasyarat untuk pengenalan plat yang berhasil, dan kemajuan di bidang ini berkontribusi pada solusi ITS yang lebih efisien dan dapat diskalakan, memungkinkan pemrosesan data real-time dan pengambilan keputusan di seluruh jaringan transportasi yang kompleks.

Dengan membandingkan tinjauan-tinjauan ini, tampak jelas bahwa *Deep Learning* telah menjadi pendekatan dominan dalam sistem Pengenalan Plat Nomor. Tinjauan-tinjauan ini menyoroti kinerja superior model *Deep Learning* dibandingkan metode tradisional, terutama karena kemampuannya untuk secara otomatis mempelajari fitur hierarkis dari gambar input mentah. Makalah ini bertujuan untuk menyajikan klasifikasi kemajuan terbaru dalam penelitian di bidang ini, dengan fokus khusus pada peningkatan ketahanan model di bawah kondisi lingkungan ekstrem dan pengembangan model ringan untuk diterapkan pada perangkat dengan sumber daya terbatas. Selain itu, makalah ini juga memberikan gambaran komprehensif tentang kesenjangan penelitian yang ada, menawarkan wawasan mengenai area yang memerlukan eksplorasi lebih lanjut untuk memajukan generasi berikutnya dari sistem Pengenalan Plat Nomor yang lebih akurat, efisien, etis, dan dapat beradaptasi dengan berbagai skenario dunia nyata.



Gambar 1. Klasifikasi Percabangan Penelitian


3 Deep Learning Dalam Pengenalan Plat Nomor

Bagian ini menyajikan klasifikasi kemajuan penelitian terbaru dalam metode *Deep Learning* untuk Pengenalan Plat Nomor Otomatis (ALPR) yang ditampilkan pada Gambar 1.

3.1 Metode Fusi

Pendekatan fusi menggabungkan teknik *Deep Learning* dengan visi komputer klasik dan teknik pemrosesan citra. Pendekatan ini menerapkan metode *Deep Learning* dalam tugas deteksi objek dan pengenalan karakter, kemudian menggabungkannya dengan teknik penyaringan, transformasi, dan morfologi untuk tugas pra-pemrosesan dan tugas terkait lainnya. Penelitian terbaru berfokus pada pendekatan fusi yang melibatkan teknik *Deep Learning* dengan visi komputer klasik untuk mengenali plat nomor kendaraan. Penelitian telah menunjukkan bahwa integrasi *Deep Learning* dengan pustaka industri visi komputer menghasilkan hasil yang menjanjikan. Misalnya, sebuah studi menunjukkan tingkat akurasi sebesar 96,7% (Wu et al., 2020). Penelitian lain memperkenalkan sistem berbasis *Deep Learning* yang berhasil mencapai tingkat akurasi deteksi plat sebesar 98%, sedangkan pengenalan huruf mencapai 97% (Arsenovic et al., 2017).

Perkembangan selanjutnya terkait pendekatan ini diterapkan dalam konteks regional tertentu. Misalnya, pendekatan berbasis fusi yang menggunakan YOLO untuk segmentasi dan berbagai teknik fusi data untuk pengenalan karakter menunjukkan kinerja yang unggul pada plat nomor Aljazair, seperti yang ditunjukkan oleh Zibani et al. pada tahun 2022. Contoh lain menggabungkan segmentasi dengan langkah OCR melalui bantuan YOLO, yang mencapai akurasi sebesar 99,2% pada plat nomor Iran menurut penelitian oleh Rashtehroudi et al. pada tahun 2020.




Gambar 2. Metode Fusi

3.2 Metode Deep Learning Dua Tahap

Penelitian terbaru telah membuktikan efisiensi metode *Deep Learning* dua tahap dalam pengenalan plat nomor. Metode-metode ini biasanya melibatkan penggunaan model deteksi objek seperti YOLO untuk lokalisasi plat nomor, diikuti oleh pengenalan karakter menggunakan CNN (Lin & Sie, 2019; Yonetsu et al., 2019; Laroca et al., 2018). Metodologi ini dapat memberikan akurasi yang sangat tinggi pada berbagai dataset dan kondisi yang menantang, termasuk latar belakang yang kompleks dan variasi pencahayaan. Tingkat keberhasilan yang dilaporkan oleh penelitian yang menggunakan metode ini cukup tinggi.

Sebagai contoh, Lin dan Sie (2019) melaporkan tingkat deteksi plat nomor sebesar 98,23% dan tingkat pengenalan karakter sebesar 97,38%. Metode dua tahap ini terbukti andal dalam mendeteksi beberapa plat nomor di berbagai jalur serta dalam kasus plat nomor kecil atau kabur pada kendaraan yang bergerak (Lin & Sie, 2019). Beberapa peneliti lebih lanjut mengintegrasikan metode untuk meningkatkan akurasi dalam skenario dengan kondisi yang kompleks. Di antaranya adalah mekanisme jangkar vertikal dan long short-term memory (LSTM) dua arah (Zhang et al., 2019).




Gambar 3. Metode *Deep Learning* Dua Tahap

3.3 Metode *Deep Learning* End-to-end

Metode *Deep Learning* end-to-end menggunakan satu model untuk mendeteksi dan mengenali plat nomor secara bersamaan, sehingga menghilangkan kebutuhan akan tahapan yang terpisah dan mengurangi risiko propagasi kesalahan. Beberapa hasil penelitian dalam beberapa tahun terakhir menunjukkan hasil yang menggembirakan dalam pendekatan *Deep Learning* end-to-end untuk deteksi dan pengenalan plat nomor. Pendekatan ini menggunakan satu jaringan saraf terintegrasi untuk lokalisasi plat nomor dan pengenalan karakter guna menghindari akumulasi kesalahan serta meningkatkan kecepatan pemrosesan (Li et al., 2017; Li et al., 2019). Berbagai model YOLO yang diadaptasi dan model berbasis jaringan saraf tiruan klasik, seperti CNN, telah diajukan (Tourani et al., 2020; Taleb Soghadi & Suen, 2020). Model-model ini menunjukkan tingkat akurasi yang tinggi pada banyak dataset, dengan akurasi end-to-end yang diumumkan berkisar antara 88,5% hingga 98,04% (Taleb Soghadi & Suen, 2020), dan bahkan mencapai 95,05% untuk plat nomor Iran yang menantang (Tourani et al., 2020).

Sistem ini telah menunjukkan ketahanan dalam berbagai kondisi cuaca, pencahayaan, dan jenis kendaraan yang berbeda. Beberapa implementasinya bahkan mencapai kinerja real-time, memproses gambar hanya dalam waktu 119,73 ms, sehingga membuatnya praktis untuk digunakan dalam sistem transportasi cerdas.




Gambar 4. Metode *Deep Learning* End-to-End

3.4 Metode Deep Learning Multi-Cabang

Model *Deep Learning* multi-cabang telah menjadi salah satu konsep yang paling banyak digunakan dalam tugas pengenalan plat nomor. Model seperti ini dapat dilatih untuk menangani beberapa tujuan secara bersamaan, seperti deteksi kendaraan, lokalisasi plat nomor, dan pengenalan karakter, dalam satu arsitektur (Chen et al., 2020; Gonçalves et al., 2018). Beberapa cabang yang digunakan untuk setiap tugas berbeda memiliki kemampuan untuk mengoptimalkan beberapa tujuan secara simultan, sehingga meningkatkan akurasi dan efisiensi (Guo et al., 2020). Sebagai contoh, tingkat akurasi tinggi dalam mendeteksi kendaraan dan plat nomor secara bersamaan berhasil dicapai oleh jaringan saraf perhatian multi-cabang (Chen et al., 2020). Pendekatan lain menggunakan metode berbasis Faster R-CNN untuk deteksi kendaraan pada langkah pertama, kemudian lokalisasi plat nomor pada langkah kedua, yang menunjukkan peningkatan kinerja di lingkungan yang menantang (Khan et al., 2021).


Biasanya, model multi-cabang ini secara komprehensif mengungguli rekan-rekannya yang berbasis satu cabang, selalu mendapatkan keunggulan dalam situasi dunia nyata di mana kondisi sering berubah. Meskipun demikian, mengoptimalkan interaksi antara cabang-cabang tersebut dan menangani kompleksitas komputasi yang dihasilkan tetap menjadi tantangan utama dalam penerapan model-model ini (Guo et al., 2020; Chen et al., 2020).



Gambar 5. Metode *Deep Learning* Multi-Cabang


3.5 Metode Deep Generative

Penelitian terbaru telah membuktikan bahwa *Deep Learning* yang dikombinasikan dengan teknik generatif memungkinkan pengenalan plat nomor. Tingkat akurasi dan recall yang tinggi dalam skenario dunia nyata telah dicapai dengan menggunakan CNN yang dilatih hanya dengan data sintesis yang dihasilkan oleh GAN (Björklund et al., 2017). Sebuah GAN yang sadar-struktur, yang disebut PixTextGAN, telah diusulkan untuk menyintesis gambar plat nomor yang realistis, yang secara substansial meningkatkan akurasi pada dataset yang menantang untuk pengenalan (Wu et al., 2019). Teknik ini juga telah diterapkan untuk menghasilkan dataset pelatihan berskala besar, dan dikombinasikan dengan jaringan saraf konvolusional mendalam serta jaringan saraf rekuren, berhasil meningkatkan akurasi pengenalan secara signifikan (Wang et al., 2017). Selain itu, super-resolution GAN dapat diterapkan untuk meningkatkan kualitas gambar input yang rendah, menangani masalah seperti pencahayaan yang buruk dan obstruksi yang sering terjadi dalam deteksi plat nomor di dunia nyata (Boby & Brown, 2022). Kemajuan ini menunjukkan sejauh mana teknik generatif dapat berkontribusi dalam meningkatkan ketahanan pengenalan plat nomor melalui augmentasi data pelatihan.



Gambar 6. Metode Deep Generative

4 Potensi dan Arah Penelitian



Gambar 7. Ranah Penelitian

Mengatasi tantangan dan meningkatkan kinerja sistem Pengenalan Plat Nomor Otomatis (ALPR) memerlukan penelitian terfokus di beberapa area utama yang ditunjukkan pada Gambar 7.

4.1 Menangani Skenario Kompleks

Sistem Pengenalan Plat Nomor Otomatis (ALPR) sering menghadapi kesulitan dalam menangani obstruksi, pantulan, dan distorsi pada area plat nomor. Misalnya, di lingkungan perkotaan dengan lalu lintas padat, plat nomor dapat sebagian tertutup oleh kendaraan lain, sehingga menyulitkan sistem untuk mendeteksi dan mengenali karakter dengan akurat. Demikian pula, pantulan dari permukaan jalan basah atau lampu depan kendaraan dapat menyebabkan silau yang mengganggu visibilitas plat nomor. Selain itu, kondisi cuaca seperti hujan lebat, kabut, atau salju dapat membuat plat nomor menjadi kabur, sementara sudut kamera yang bervariasi, seperti dari kamera yang dipasang di atas atau di samping, dapat menimbulkan distorsi perspektif yang mempersulit proses pengenalan. Tantangan-tantangan ini secara signifikan dapat mempengaruhi akurasi sistem.

Oleh karena itu, pengembangan teknik adaptif untuk meningkatkan kinerja di bawah kondisi lingkungan yang bervariasi sangat penting. Penelitian harus berfokus pada penciptaan algoritma yang kuat yang dapat secara dinamis merespons perubahan ini, seperti menggunakan teknik peningkatan citra canggih untuk mengurangi silau atau menggunakan sintesis gambar multi-sudut

untuk mengatasi distorsi perspektif. Selain itu, model pembelajaran mesin dapat dilatih pada dataset yang mencakup berbagai skenario lingkungan, memungkinkan mereka untuk lebih baik menggeneralisasi kondisi yang berbeda dan mempertahankan akurasi tinggi bahkan di lingkungan yang paling menantang.

4.2 Integrasi Tugas Lokalisasi dan Pengenalan

Mengintegrasikan lokalisasi plat nomor dan pengenalan karakter ke dalam satu arsitektur yang terlatih secara end-to-end secara signifikan meningkatkan efisiensi dan akurasi sistem ALPR. Metode dua tahap tradisional sering kali mengalami masalah propagasi kesalahan, yang dapat mengurangi kinerja keseluruhan. Teknik-teknik canggih seperti mekanisme perhatian (attention mechanism) dan model transformer, yang awalnya dikembangkan untuk pemrosesan bahasa alami, telah diadaptasi untuk visi komputer karena kemampuannya dalam menangkap dependensi jarak jauh dan informasi kontekstual. Dalam ALPR, transformer menangani variabilitas desain plat nomor, termasuk perbedaan dalam font, ukuran, warna, dan orientasi, dengan menggunakan mekanisme perhatian diri (self-attention) yang fokus pada bagian relevan dari plat nomor. Hal ini meningkatkan akurasi lokalisasi dan pengenalan dengan menyesuaikan secara dinamis terhadap variasi plat.

Transformer unggul dalam skenario kompleks di mana plat nomor sebagian tertutup atau terdistorsi, dengan cara mengintegrasikan informasi dari berbagai bagian gambar untuk mengurangi efek obstruksi atau kualitas gambar yang buruk. Ketika dilatih pada dataset besar dan beragam, transformer menunjukkan kemampuan generalisasi yang superior pada berbagai jenis plat nomor, termasuk plat yang tidak standar atau khusus (vanity plates). Dengan menghilangkan kebutuhan untuk tahapan terpisah antara lokalisasi dan pengenalan, serta memanfaatkan kemampuan pembelajaran kontekstual dari transformer, sistem ALPR dapat mencapai akurasi dan ketahanan yang lebih tinggi, menjadikan arsitektur berbasis transformer sebagai kemajuan penting dalam pengenalan plat nomor otomatis.

4.3 Adaptabilitas dan Generalisasi

Agar sistem ALPR efektif di berbagai wilayah dan kondisi, mereka harus sangat adaptif dan mampu melakukan generalisasi. Adaptabilitas ini melibatkan penyesuaian dan kustomisasi model untuk mengakomodasi berbagai gaya plat nomor, orientasi, dan kondisi lingkungan yang unik di wilayah geografis tertentu. Misalnya, di wilayah dengan iklim ekstrem seperti suhu sangat dingin atau panas, plat nomor mungkin mengalami kerusakan yang mengubah tampilannya, sehingga model harus dilatih pada data yang mencakup variasi tersebut. Di daerah tropis, hujan yang sering dan kelembapan tinggi dapat menyebabkan silau atau kabut pada lensa kamera, sehingga memerlukan model yang dapat menangani kondisi dengan visibilitas rendah secara efektif.

Arsitektur *Deep Learning* yang lebih adaptif perlu dieksplorasi untuk mengatasi tantangan ini. Teknik seperti domain adaptation sangat berguna ketika model yang dilatih di satu domain disesuaikan untuk domain lain yang terkait. Sebagai contoh, model yang dilatih untuk plat nomor Amerika Utara dapat diadaptasi untuk mengenali plat nomor Eropa dengan melakukan fine-tuning pada dataset kecil yang berisi plat nomor Eropa. Selain itu, pembelajaran multitugas dapat meningkatkan kemampuan generalisasi sistem, memungkinkan model untuk melakukan beberapa tugas terkait secara bersamaan, seperti mendeteksi plat nomor, mengenali karakter, dan menilai kualitas gambar. Optimisasi multi-objektif, yang menyeimbangkan metrik kinerja seperti akurasi, kecepatan, dan ketahanan, dapat membuat model lebih serbaguna dan tahan terhadap berbagai skenario.

Penelitian menunjukkan bahwa model yang diadaptasi untuk berbagai kondisi lingkungan dapat secara signifikan meningkatkan kinerja ALPR. Misalnya, pelatihan model pada dataset yang mencakup gambar sintesis yang meniru kondisi cuaca berbeda, seperti salju atau hujan, meningkatkan akurasi pengenalan di lingkungan tersebut. Demikian pula, di wilayah dengan format plat nomor yang tidak standar, seperti di India, model telah berhasil disesuaikan untuk menangani berbagai desain di berbagai negara bagian. Dengan mengintegrasikan teknik-teknik canggih ini, sistem ALPR dapat menjadi lebih tangguh dan praktis, memastikan kinerja yang andal di berbagai kondisi geografis dan iklim.

4.4 Efisiensi Arsitektur Multi-Cabang

Pendekatan *Deep Learning* multi-cabang memiliki potensi yang menjanjikan untuk ALPR, namun efisiensinya masih dapat dioptimalkan lebih lanjut. Meningkatkan interaksi dan berbagi fitur antara cabang-cabang dengan menggunakan mekanisme perhatian (attention mechanisms) dan model transformer dapat menghasilkan integrasi yang lebih efektif dari cabang-cabang yang berspesialisasi. Misalnya, dalam sistem pemantauan lalu lintas yang diterapkan di kota pintar, di mana kendaraan dari berbagai wilayah dengan gaya plat nomor yang berbeda sering kali melintas, kemampuan arsitektur multi-cabang yang secara dinamis fokus pada fitur-fitur relevan dapat secara signifikan meningkatkan akurasi pengenalan. Pengembangan strategi pembobotan cabang adaptif dan pemilihan cabang dinamis akan memungkinkan sistem menangani dengan lebih baik gaya plat nomor dan kondisi lingkungan yang bervariasi, seperti plat dengan jenis huruf, warna yang berbeda, atau yang terlihat di bawah kondisi pencahayaan yang bervariasi.

Pendekatan ini dapat memberikan manfaat pada aplikasi dunia nyata, seperti sistem pengumpulan tol atau pos pemeriksaan perbatasan. Lingkungan-lingkungan ini sering kali memerlukan pemrosesan volume kendaraan yang besar secara cepat dan akurat, di mana arsitektur multi-cabang dapat mengoptimalkan keseimbangan antara kecepatan dan akurasi dengan memprioritaskan cabang-cabang tertentu berdasarkan konteks spesifik. Sebagai contoh, dalam sistem tol, model dapat secara dinamis memprioritaskan cabang yang bertanggung jawab untuk mendeteksi plat nomor reflektif saat malam hari, atau dalam skenario pos pemeriksaan perbatasan, sistem dapat menyesuaikan dengan format plat nomor yang berbeda dari negara-negara tetangga dengan memanfaatkan cabang-cabang yang sesuai dengan tugas spesifik. Dengan memanfaatkan teknik pembelajaran multitugas dalam konteks ini, kinerja keseluruhan sistem dapat ditingkatkan dengan secara efisien memanfaatkan tugas-tugas pelengkap, seperti mengenali plat nomor dan mendeteksi jenis atau warna kendaraan secara bersamaan. Dengan mengintegrasikan strategi canggih ini, arsitektur *Deep Learning* multi-cabang dapat disesuaikan untuk memenuhi tuntutan aplikasi dunia nyata yang kompleks, memastikan ketangguhan dan efisiensi.

4.5 Teknik *Deep Learning* Lanjutan

Teknik *Deep Learning* mutakhir, seperti Generative Adversarial Networks (GANs), menawarkan potensi yang signifikan untuk meningkatkan kinerja ALPR dengan menghasilkan data sintetis untuk memperkaya set pelatihan dan meningkatkan integrasi fitur. Selain itu, teknik-teknik canggih lainnya seperti mekanisme perhatian (attention mechanisms) dan model transformer dapat lebih menyempurnakan metode ALPR, sehingga lebih mampu menangani skenario kompleks serta meningkatkan akurasi lokalisasi dan pengenalan. Di luar GANs, teknik seperti Capsule Networks (CapsNets) dan Graph Neural Networks (GNNs) juga muncul sebagai alat yang berharga dalam bidang ini. CapsNets mampu mempertahankan hierarki spasial antar fitur dan memberikan pengenalan karakter yang lebih akurat, terutama dalam kasus di mana plat nomor terdistorsi atau dilihat dari sudut tertentu. Di sisi lain, GNN dapat memodelkan hubungan antara berbagai bagian gambar, yang sangat berguna dalam skenario di mana informasi kontekstual dan relasional sangat penting, seperti membedakan karakter yang tampak serupa atau menangani obstruksi.

Dengan mengintegrasikan metode-metode baru ini, sistem ALPR dapat mencapai ketahanan yang lebih baik, generalisasi yang lebih baik di berbagai gaya plat nomor dan lingkungan, serta kinerja keseluruhan yang lebih unggul.

4.6 Ketangguhan dan Keandalan

Memastikan bahwa sistem ALPR tetap tangguh dan andal di bawah berbagai kondisi yang menantang sangatlah penting. Pengembangan solusi komprehensif yang mampu mempertahankan kinerja tinggi meskipun ada obstruksi, pantulan, dan distorsi adalah hal yang esensial. Sebuah studi kasus yang patut dicatat adalah penerapan sistem LPR di Inggris untuk zona pengenaan kemacetan di kota-kota seperti London, di mana sistem ini harus mampu mengenali plat nomor secara akurat dalam kondisi seperti hujan lebat, kabut, dan silau di malam hari dari lampu depan kendaraan. Sebaliknya, penelitian di negara berkembang, di mana infrastruktur pengawasan sering kali suboptimal, menyoroti tantangan tambahan seperti kualitas kamera yang rendah dan pencahayaan yang tidak konsisten. Faktor-faktor ini secara signifikan mempengaruhi kinerja sistem LPR, terutama di lingkungan dengan sumber daya terbatas. Temuan-temuan tersebut menekankan perlunya model

yang tangguh yang dapat beradaptasi dengan keterbatasan ini, sehingga memastikan kinerja yang andal bahkan dalam kondisi yang kurang ideal.

Sistem tersebut menjalani pelatihan dan pengujian yang ekstensif untuk mengatasi tantangan ini dengan menggunakan dataset yang beragam, termasuk gambar yang diambil dalam berbagai kondisi cuaca, skenario pencahayaan, dan sudut kamera. Meskipun upaya-upaya ini dilakukan, tantangan seperti distorsi karakter akibat permukaan reflektif atau obstruksi dari kotoran dan puing-puing pada plat nomor masih menjadi hambatan signifikan terhadap akurasi. Fokusnya harus pada penciptaan model yang secara konsisten memberikan hasil yang akurat, terlepas dari faktor eksternal. Teknik-teknik seperti augmentasi data sintetis, di mana gambar buatan yang merepresentasikan kondisi yang menantang digunakan untuk melengkapi dataset pelatihan, dan algoritma adaptif yang dapat menyesuaikan secara dinamis dengan kondisi lingkungan yang berubah, sangat penting untuk meningkatkan ketangguhan dan keandalan sistem LPR. Dengan belajar dari penerapan dunia nyata dan terus menyempurnakan model berdasarkan wawasan tersebut, industri dapat mengembangkan sistem LPR yang tangguh dan efektif di berbagai lingkungan operasional.

4.7 Kustomisasi Model End-to-End

Kustomisasi model *Deep Learning* end-to-end untuk konteks spesifik dapat secara signifikan meningkatkan kinerja ALPR. Penyesuaian model agar lebih mampu menangani plat nomor dari berbagai wilayah dengan desain yang bervariasi, adaptasi model terhadap kondisi lingkungan yang berbeda dan pengaturan kamera, serta penggabungan pengetahuan spesifik domain, semuanya sangat penting. Kustomisasi ini memastikan bahwa model disesuaikan dengan tantangan spesifik yang akan dihadapinya, sehingga meningkatkan akurasi dan keandalannya. Mengatasi kesenjangan penelitian ini dapat membawa kemajuan signifikan dalam sistem ALPR, serta meningkatkan efisiensi, akurasi, dan keandalannya. Fokus pada area-area penting ini akan memungkinkan pengembangan solusi ALPR yang lebih tangguh dan adaptif, yang mampu berkinerja baik di bawah berbagai kondisi dan tantangan.

5 Kesimpulan

Pengenalan plat nomor otomatis (ALPR) melalui visi komputer telah menggunakan berbagai teknik pembelajaran mendalam, dengan pendekatan klasik yang menyeimbangkan antara akurasi dan efisiensi untuk lingkungan dengan keterbatasan sumber daya. Model dua tahap meningkatkan akurasi dengan memisahkan tugas deteksi dan pengenalan, namun hal ini dapat menyebabkan latensi. Sebaliknya, model end-to-end menyederhanakan proses dengan mengintegrasikan kedua tugas tersebut, meskipun membutuhkan daya komputasi lebih besar dan data pelatihan yang ekstensif. Arsitektur multi-cabang, yang sering menggunakan GAN untuk augmentasi data, unggul dalam skenario kompleks dengan memanfaatkan cabang-cabang yang berspesialisasi, sehingga menawarkan ketangguhan dan fleksibilitas.

Menggabungkan model end-to-end dengan deteksi anomali dalam keamanan publik memungkinkan pemantauan real-time yang efisien dan respons cepat. Meskipun sistem ALPR telah mencapai akurasi hingga 95%, tantangan seperti obstruksi, pantulan, serta adaptasi terhadap berbagai gaya plat nomor dan kondisi lingkungan tetap ada. Penelitian di masa depan harus mengeksplorasi pendekatan hibrida, yang mengintegrasikan *Deep Learning* dengan metode tradisional, seperti model Transformer yang digabungkan dengan CNN untuk menangani berbagai gaya plat, Capsule Networks untuk mempertahankan hierarki spasial, dan Reinforcement Learning untuk mengoptimalkan arsitektur multi-cabang. Peningkatan GAN untuk menghasilkan data sintetis dan penerapan teknik transfer gaya juga dapat meningkatkan kualitas data pelatihan. Arah penelitian yang sedang berkembang ini, termasuk mekanisme perhatian dan optimisasi multi-objektif, merupakan kunci untuk mengembangkan sistem ALPR yang lebih tangguh, adaptif, dan efisien.

Referensi

Castro-Zunti, R. D., Yopez, J., & Ko, S.-B. (2020). License plate segmentation and recognition system using Deep Learning and OpenVINO. *IET Intelligent Transport Systems*, 14(2), 119–126.

- Chen, Z., Yan, L., Yin, S., & Shi, Y. (2020). Vehicle license plate recognition system based on Deep Learning in natural scene. *Journal of Artificial Intelligence*, 2(4), 167.
- Adytia, N. R., & Kusuma, G. P. (2021). Indonesian license plate detection and identification using deep learning. *International Journal of Emerging Technology and Advanced Engineering*, 11(7), 1–7.
- Wang, J., Liu, X., Liu, A., & Xiao, J. (2019). A deep learning-based method for vehicle license plate recognition in natural scene. *APSIPA Transactions on Signal and Information Processing*, 8, e16.
- Jørgensen, H. (2017). Automatic license plate recognition using Deep Learning techniques (Master's thesis, NTNU).
- Bhujbal, A., & Mane, D. (2019). A survey on Deep Learning approaches for vehicle and number plate detection. *International Journal of Scientific & Technology Research*, 8(12), 1378–1383.
- Al Awaimri, M., Fageeri, S., Moyaid, A., & ALhasanat, A. (2021). Vehicles number plate recognition systems: A systematic review. In *2020 International Conference on Computer, Control, Electrical, and Electronics Engineering (ICCCEEE)* (pp. 1–6). IEEE.
- Alkaws, G., Baashar, Y., Alkahtani, A. A., Kiong, T. S., Habeeb, D., & Aliubari, A. (2021). Arabic vehicle licence plate recognition using Deep Learning methods. In *2021 11th IEEE International Conference on Control System, Computing and Engineering (ICCSCE)* (pp. 75–79). IEEE.
- Vishwakarma, P. K., & Jain, N. (2023). Deep learning-based methods in image analytics for vehicle detection: A review. In *2023 6th International Conference on Information Systems and Computer Networks (ISCON)* (pp. 1–6). IEEE.
- Wu, T., Liao, H., & Lim, Z. (2020). Integration of Deep Learning and Industrial Computer Vision Library for Motorcycle and Vehicle License Plate Recognition. *Proceedings of the 2020 3rd International Conference on Image and Graphics Processing*.
- Arsenovic, M., Sladojević, S., Anderla, A., & Stefanović, D. (2017). Deep Learning Driven Plates Recognition System.
- Zibani, R., Sebbak, F., Boudaren, M.E., Mataoui, M., Touabi, M., & Hfaifia, H. (2022). A New Fusion-Based Approach for License Plate Recognition: An Application to the Algerian Context. *Communication Systems and Applications*.
- Rashtehroudi, A.R., Shahbahrani, A., & Akoushideh, A. (2020). Iranian License Plate Recognition using Deep Learning. *2020 International Conference on Machine Vision and Image Processing (MVIP)*, 1-5.
- Zhang, J., Li, Y., Li, T., Xun, L., & Shan, C. (2019). License Plate Localization in Unconstrained Scenes Using a Two-Stage CNN-RNN. *IEEE Sensors Journal*, 19, 5256-5265.
- Lin, C., & Sie, Y. (2019). Two-Stage License Plate Recognition System using Deep learning. *2019 8th International Conference on Innovation, Communication and Engineering (ICICE)*, 132-135.
- Yonetsu, S., Iwamoto, Y., & Chen, Y. (2019). Two-Stage YOLOv2 for Accurate License-Plate Detection in Complex Scenes. *2019 IEEE International Conference on Consumer Electronics (ICCE)*, 1-4.
- Laroca, R., Severo, E., Zanlorensi, L.A., Oliveira, L., Gonçalves, G.R., Schwartz, W.R., & Menotti, D. (2018). A Robust Real-Time Automatic License Plate Recognition Based on the YOLO Detector. *2018 International Joint Conference on Neural Networks (IJCNN)*, 1-10.
- Chen, S., Yang, C., Ma, J., Chen, F., & Yin, X. (2020). Simultaneous End-to-End Vehicle and License Plate Detection With Multi-Branch Attention Neural Network. *IEEE Transactions on Intelligent Transportation Systems*, 21, 3686-3695.

- Gonçalves, G.R., Diniz, M.A., Laroca, R., Menotti, D., & Schwartz, W.R. (2018). Real-Time Automatic License Plate Recognition through Deep Multi-Task Networks. 2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI), 110-117.
- Guo, P., Lee, C., & Ulbricht, D. (2020). Learning to Branch for Multi-Task Learning. ArXiv, abs/2006.01895.
- Khan, K., Imran, A., Rehman, H.Z., Fazil, A., Zakwan, M., & Mahmood, Z. (2021). Performance enhancement method for multiple license plate recognition in challenging environments. EURASIP Journal on Image and Video Processing, 2021.
- Björklund, T., Fiandrotti, A., Annarumma, M., Francini, G., & Magli, E. (2017). Automatic license plate recognition with convolutional neural networks trained on synthetic data. 2017 IEEE 19th International Workshop on Multimedia Signal Processing (MMSP), 1-6.
- Wu, S., Zhai, W., & Cao, Y. (2019). PixTextGAN: structure aware text image synthesis for license plate recognition. IET Image Process., 13, 2744-2752.
- Wang, X., Man, Z., You, M., & Shen, C. (2017). Adversarial Generation of Training Examples: Applications to Moving Vehicle License Plate Recognition. arXiv: Computer Vision and Pattern Recognition.
- Boby, A., & Brown, D. (2022). Improving Licence Plate Detection Using Generative Adversarial Networks. Iberian Conference on Pattern Recognition and Image Analysis.