

Studi *Trade-off Semantic Segmentation* dan *Hardware Utilization* untuk Sistem Persepsi Kendaraan Otonom

Destya Rosa Mardiana^{*1}, Oskar Natan², Aufaclav Zatu Kusuma Frisky³

¹Program Studi Elektronika dan Instrumentasi, FMIPA UGM, Yogyakarta, Indonesia

²Departemen Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta, Indonesia

e-mail: ^{*1}destyarosamardiana@mail.ugm.ac.id, ²oskarnatan@ugm.ac.id,

³aufaclav@ugm.ac.id

Abstrak

Segmentasi semantik malam hari menjadi tantangan pada sistem persepsi kendaraan otonom akibat adanya domain shift antara data pelatihan siang hari dan dataset domain malam hari. Hal tersebut menyebabkan penurunan performa segmentasi ketika model yang terlatih pada dataset siang hari diterapkan pada dataset malam hari. Penelitian ini bertujuan membuktikan efektivitas metode unsupervised domain adaptation serta mengevaluasi trade-off antara akurasi segmentasi dan sistem komputasi pada lingkungan malam hari. Metode yang digunakan pada penelitian ini adalah *A One-Stage Domain Adaptation Network for Unsupervised Nighttime Semantic Segmentation (DANNet)* dengan backbone *PSPNet*, yang mengkombinasikan *relighting network* dan *adversarial learning* untuk mengatasi domain shift. Dataset yang digunakan adalah dataset UGM sebagai dataset target dan *Cityscapes* sebagai dataset sumber. Hasil penelitian menunjukkan bahwa model *DANNet* berhasil meningkatkan performa segmentasi dari 5.27% menjadi 9.29% pada konfigurasi 19 kelas, serta mencapai 22.09% pada konfigurasi 7 kelas. Konfigurasi 7 kelas menunjukkan efisiensi komputasi yang lebih baik dengan rata-rata 17.90 ± 0.60 FPS dan latensi 55.94 ± 1.91 ms tanpa peningkatan penggunaan memori GPU. Model konfigurasi 7 kelas dinilai lebih sesuai pada skenario near real-time, sedangkan konfigurasi 19 kelas tetap layak dan relevan untuk kebutuhan segmentasi yang lebih detail.

Kata kunci—Kendaraan Otonom, Adaptasi Domain, Segmentasi Semantik, Efisiensi Komputasi

Abstract

Nighttime semantic segmentation remains a critical challenge for autonomous driving perception system due to the domain shift, which leads to substantial performance degradation when models trained on daytime data are directly applied to low-light environments. This study investigates the effectiveness of unsupervised domain adaptation and analyses the trade-off between segmentation accuracy and computational efficiency in nighttime scenarios. This research adopts the *One-Stage Domain Adaptation Network for Unsupervised Nighttime Semantic Segmentation (DANNet)* with a *PSPNet* backbone, which integrates a *relighting network* and *adversarial learning* to mitigate domain shift. Experiments are conducted using *Cityscapes* at the source domain and a locally collected UGM dataset as the target domain. The result show that *DANNet* improves segmentation performance from 5.27% to 9.29% under the 19-class configuration and achieves 22.09% mIoU in the 7-class configuration. The 7-class setup also demonstrates better computational systems, achieving 17.90 ± 0.60 FPS and a latency 55.94 ± 1.91 ms, making it suitable for near real-time deployment, whereas the 19-class configuration remains relevant for applications requiring finer semantic granularity.

Keywords—Semantic Segmentation, Unsupervised Domain Adaptation, Autonomous Driving, Computational Efficiency

1. PENDAHULUAN

Perkembangan kendaraan otonom telah meningkat pesat dalam beberapa dekade terakhir karena kemampuan mengemudi tanpa intervensi manusia. Namun, mobil otonom masih mengalami banyak tantangan, salah satunya adalah permasalahan dalam mengenali lingkungan yang kompleks pada lingkungan malam hari. Kendaraan otonom sulit mengenali objek pada lingkungan malam hari karena keterbatasan jumlah foton yang diterima oleh sensor sehingga mengalami penurunan kontras dan peningkatan *noise* pada citra [1]. Dengan demikian, mengakibatkan proses anotasi citra yang dihasilkan pada lingkungan pencahayaan rendah kurang informatif dan tidak mempresentasikan objek sebenarnya secara tepat [2].

Selain permasalahan tersebut, kendaraan otonom juga menghadapi permasalahan pada *domain shift*, yaitu penurunan performa model ketika model diterapkan pada distribusi data yang berbeda dari data pelatihan. Untuk mengatasi hal tersebut, digunakan pendekatan *unsupervised domain adaptation* agar model tetap efektif tanpa perlu anotasi label pada dataset target malam hari [3]. Salah satu model segmentasi semantik [4] kendaraan otonom yang menggunakan pendekatan *unsupervised domain adaptation* adalah DANNet (*A One-Stage Domain Adaptation Network for Unsupervised Nighttime Semantic Segmentation*). Model ini dirancang untuk proses segmentasi semantik kendaraan otonom pada lingkungan malam hari. Metode ini mengintegrasikan *relighting network* dan *adversarial learning* dalam satu tahap (*end-to-end*) yang efisien untuk mengatasi *domain shift* [5].

Penelitian sebelumnya [2] menunjukkan bahwa metode DANNet memiliki performa yang baik pada dataset Dark Zurich dalam proses adaptasi domain siang hari ke domain malam hari. Namun, dataset tersebut belum merepresentasikan kondisi lingkungan jalan raya di Indonesia, baik dari segi pencahayaan, infrastruktur, maupun tata letak kotanya. Oleh karena itu, penelitian ini difokuskan pada penerapan dataset lokal UGM pada DANNet untuk melihat generalisasi model ketika diterapkan pada distribusi data yang berbeda. Selain menganalisis performa segmentasi semantik kendaraan otonom pada malam hari, penelitian ini juga menganalisis terkait pemanfaatannya pada perangkat keras untuk menilai kelayakan dalam implementasi secara *real-time* [6].

Berdasarkan tinjauan penelitian sebelumnya [2], kajian mengenai segmentasi semantik malam hari umumnya belum secara eksplisit mengaitkan performa segmentasi semantik dengan pemanfaatan sumber daya perangkat keras pada sistem kendaraan otonom, khususnya pada konteks dataset lokal (UGM). Oleh sebab itu, penelitian ini dilakukan untuk mengevaluasi keterkaitan tersebut agar hasil yang diperoleh lebih relevan terhadap kebutuhan implementasi nyata.

2. METODE PENELITIAN

2.1 Analisis Sistem

Penelitian ini membahas segmentasi semantik kendaraan otonom pada kondisi pencahayaan rendah, khususnya lingkungan malam hari secara *end-to-end* dengan *unsupervised domain adaptation*. Model tersebut dikenal dengan DANNet. Selain menganalisis performa segmentasi semantik, penelitian ini juga menganalisis performa komputasinya untuk menilai kelayakan implementasi secara *real-time* pada penerapan dataset lokal UGM malam hari. Pada proses eksperimen, metode ini menggunakan dataset Cityscapes sebagai dataset sumber dan Dark Zurich sebagai referensi pembandingan terhadap hasil segmentasi semantik pada domain target.

Arsitektur sistem ini mengintegrasikan beberapa jaringan secara *end-to-end*, seperti *relighting network*, *segmentation network*, dan *discriminator network*. Arsitektur ini menggunakan *subnetwork image relighting* untuk mendistribusikan intensitas pencahayaan secara merata pada domain yang berbeda, lalu dilanjutkan dengan proses penyeimbangan bobot pada proses segmentasi untuk mendapatkan hasil prediksi segmentasi yang lebih optimal. Evaluasi pada sistem ini dilakukan untuk mengukur *trade-off* antara akurasi segmentasi dan

efisiensi komputasi. Akurasi segmentasi semantik diukur menggunakan metrik *mean Intersection over Union* (mIoU) yang merupakan standar dalam evaluasi segmentasi semantik. Sementara itu, efisiensi komputasi dievaluasi melalui beberapa parameter utama, yaitu kecepatan inferensi (FPS), latensi serta penggunaan dan pemanfaatan memori GPU (VRAM usage dan GPU utilization) [7]. Evaluasi dilakukan dengan cara *profiling* GPU pada perangkat *workstation* untuk menganalisis kelayakan model dalam implementasi *real-time* pada perangkat terbatas.

2.2 Strategi Pemecahan Masalah Segmentasi Semantik Malam Hari

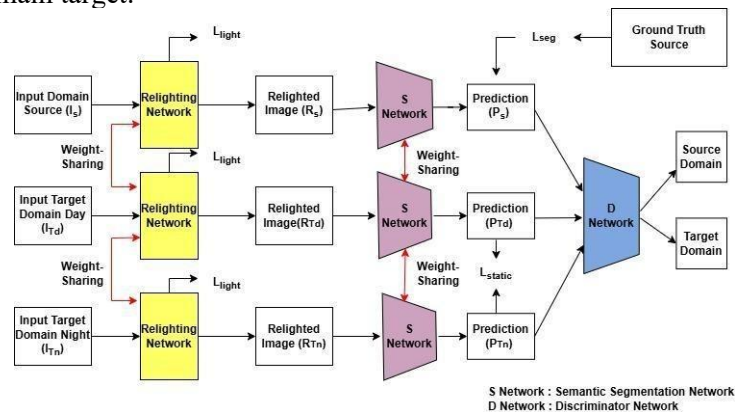
Permasalahan utama segmentasi semantik malam hari pada kendaraan otonom adalah adanya *domain shift* antara domain siang dan domain malam. Perbedaan intensitas pencahayaan, tingginya *noise*, dan kontras yang rendah menyebabkan hilangnya detail visual segmentasi saat dataset malam hari diterapkan langsung pada model telah dilatih pada data siang hari. Strategi pemecahan masalah tersebut pada metode DANNet menggunakan dua mekanisme utama yang diintegrasikan secara *end-to-end*, yaitu *relighting network* dan *adversarial learning*.

Modul adaptasi visual malam hari pada arsitektur DANNet dilakukan oleh jaringan *relighting*. Jaringan ini berperan dalam menyeimbangkan pencahayaan antara domain siang dan malam. Modul ini memproses citra malam hari agar memiliki distribusi intensitas pencahayaan yang lebih mendekati citra siang hari tanpa mengubah struktur geometris objek didalam citra. Oleh karena itu, detail penting citra, seperti batas objek, tekstur permukaan jalan, dan area vegetasi dapat dipertahankan dan menjadi lebih mudah diekstraksi oleh jaringan segmentasi.

Selain terletak pada tingkat visual, *domain shift* juga terjadi pada tingkat fitur, yaitu distribusi fitur antara domain sumber dan domain target menunjukkan perbedaan yang signifikan. Dalam mengatasi permasalahan tersebut, DANNet menggunakan mekanisme *adversarial learning* melalui jaringan *discriminator*. Mekanisme ini mendorong model dalam menyelaraskan distribusi fitur antar domain, sehingga model tetap memperoleh informasi supervisi dari domain sumber meskipun tidak tersedia anotasi manual pada domain target malam hari.

2.3 Perancangan Model

Model pada penelitian ini menggunakan arsitektur DANNet (*A One-Stage Domain Adaptation Network for Unsupervised Nighttime Semantic Segmentation*) yang dikembangkan oleh Xinyi Wu dan teman-temannya pada tahun 2021. Arsitektur ini dirancang untuk melakukan tugas segmentasi semantik pada kendaraan otonom dengan mekanisme *unsupervised domain adaptation* pada kondisi lingkungan malam hari. Arsitektur ini terdiri dari tiga komponen utama, yaitu *relighting network*, *semantic segmentation*, dan *discriminator*. Domain sumber pada metode ini menjadi referensi distribusi dalam proses *adversarial learning* untuk menyelaraskan representasi fitur domain target.



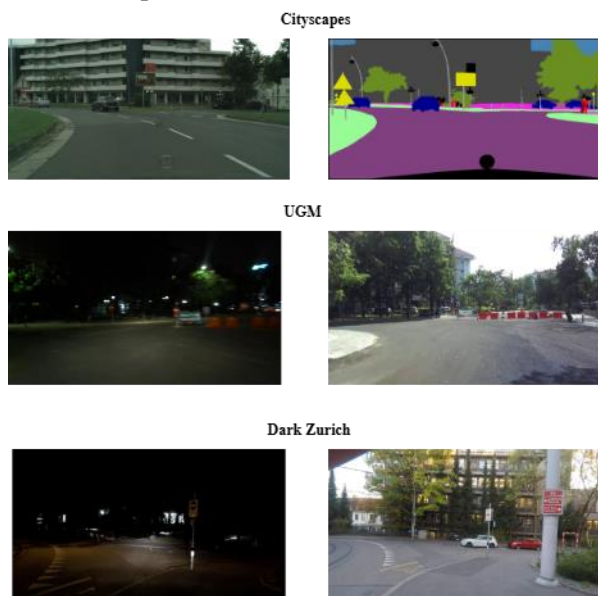
Gambar 1 Arsitektur Jaringan Model DANNet

Input citra baik dari domain sumber dan domain target dilakukan pelarasan intensitas pencahayaan pada *relighting network* untuk menstabilkan pencahayaan citra tanpa kehilangan struktur informasi pentingnya. Selanjutnya, proses ekstraksi fitur-fitur penting dilakukan pada jaringan segmentasi semantik. Jaringan segmentasi ini menggunakan *backbone* PSPNet ResNet-101 [8]. Hasil prediksi segmentasi yang dihasilkan diselaraskan distribusinya dengan *adversarial learning* pada *discriminator* untuk membedakan asal domain prediksi. Adanya fungsi *loss* pada proses pembelajaran berfungsi untuk mengarahkan proses optimasi model.

2.4 Pengelolaan Data dan Preprocessing

Dataset yang digunakan pada penelitian ini terdiri dari dataset Cityscapes (domain sumber), dataset UGM (domain target), dan Dark Zurich (referensi pembandingan). Pada penelitian ini, dataset UGM digunakan sebagai domain target utama pada proses pelatihan dan pengujian DANNet. Proses pelatihan memerlukan pasangan citra antara domain malam hari dan siang hari untuk membantu distribusi fitur dan pencahayaan antara domain sumber dan domain target. Selain itu, pembagian dataset pada penelitian ini dibagi menjadi tiga subset, yaitu train, val, dan test. Subset tersebut dibagi dalam 80% sebagai dataset *train (training)* dan masing-masing 10% untuk dataset *validation* dan *testing*.

Penelitian ini menggunakan pendekatan *unsupervised domain adaptation* sehingga tidak memerlukan anotasi berlabel domain target pada proses pembelajaran. Namun, *ground truth* dari domain sumber (Cityscapes) sangat diperlukan sebagai acuan distribusi fitur dan prediksi segmentasi yang benar. Meskipun pada proses pelatihan tidak memerlukan *ground truth* domain target, penelitian ini tetap menyediakan *ground truth* domain target untuk digunakan proses penghitungan mIoU model. *Ground truth* tersebut menggunakan hasil inferensi dari model Refign. Hal ini karena model Refign [9] memiliki keunggulan dalam menghasilkan segmentasi semantik pada domain malam hari tanpa memerlukan anotasi manual tambahan.



Gambar 2 Contoh Dataset DANNet

2.5 Implementasi Pelatihan dan Pengujian Model

Eksperimen pada penelitian ini dirancang untuk memastikan proses pelatihan dan pengujian berjalan secara sistematis dan terkontrol. Seluruh proses pengujian dan pelatihan dilakukan dalam *environment* yang sama. Selain melatih model DANNet, eksperimen ini juga dilakukan pembelajaran pada model *baseline* PSPNet untuk melihat efek dari penggunaan mekanisme adaptasi domain pada DANNet.

Pelatihan *baseline* pada penelitian ini bertujuan untuk membangun model segmentasi yang optimal pada domain siang hari, khususnya pada dataset lokal UGM. Tahap pelatihan model *baseline* pada penelitian ini menggunakan aturan parameter yang telah disesuaikan untuk memastikan proses pembelajaran stabil dan adil sebagai pembandingan terhadap metode DANNet. Karena model DANNet memiliki komponen tambahan untuk mekanisme adaptasi domain, ada beberapa penyesuaian parameter iterasi dan *learning rate* untuk mendukung *unsupervised domain adaptation* dan dataset target yang digunakan. Baik model DANNet dan *baseline* PSPNet diberikan perlakuan yang sama, yaitu proses pembelajaran dilakukan dalam dua konfigurasi kelas, yaitu 7 dan 19 kelas.

Tabel 1 Konfigurasi dan Hyperparameter Pelatihan DANNet

Konfigurasi dan Hyperparameter	Nilai	
	DANNet (PSPNet backbone)	PSPNet (ResNet-101 backbone)
Arsitektur	DANNet (PSPNet backbone)	PSPNet (ResNet-101 backbone)
Optimizer Segmentasi	Stochastic Gradient Descent (SGD)	Stochastic Gradient Descent (SGD)
Optimizer Discriminator	Adam	-
Batch Size	2	2
Iter Size	1	1
Num Workers	2	2
Input Size	512 x 960	512 x 960
Learning rate	2.5e-4	1e-3
Skema Learning Rate	Polinomial Decay	Polinomial Decay
Learning rate_D	1e-4	-
Momentum	0.9	0.9
Weight Decay	0.0005	0.0005
Power	0,9	0.9
Jumlah Iterasi	50.000	30.000
Jumlah Kelas	19 kelas dan 7 kelas	19 kelas dan 7 kelas
Fungsi Loss	Cross-Entropy Loss	Cross-Entropy Loss

Pada tahap pengujian, model DANNet dan *baseline* diuji dengan menggunakan dataset UGM malam hari. Setiap model diuji dengan menggunakan parameter yang sama agar hasil performa dapat dianalisis secara adil. Mekanisme pengujian pada eksperimen ini dirancang agar secara otomatis model diinferensi sebanyak tiga kali. Hal ini bertujuan mendapatkan nilai rata-rata dan standar deviasi dari nilai FPS dan latensi agar mendapatkan nilai yang reliabilitas. Dengan demikian, selain memperhatikan untuk menghasilkan hasil performa segmentasi yang baik, eksperimen ini juga memperhatikan pula pengukuran metrik sistem komputasi dan penggunaan memori GPU dalam *environment* yang sama.

Tabel 2 Konfigurasi Pengujian DANNet

Konfigurasi Pengujian	Nilai
Perangkat	NVIDIA RTX 5000 Ada Generation
Resolusi Input	540 x 960
Batch size	1
Mode model	Evaluation (eval)
Augmentasi	Tidak digunakan

2.6 Implementasi Evaluasi Performa

Implementasi evaluasi performa setiap model pada penelitian ini tidak hanya fokus pada akurasi segmentasi model, tetapi pengukuran performa model berdasarkan beban komputasi dan pemanfaatan sumber daya juga perlu dilakukan. Tahap evaluasi penelitian ini dilakukan dengan mekanisme GPU *profiling* selama proses inferensi, proses ini mencerminkan kondisi penggunaan model secara nyata.

Evaluasi performa segmentasi semantik pada penelitian ini dilakukan dengan membandingkan hasil prediksi segmentasi terhadap *ground truth* pada tingkat piksel. Hasil perhitungan tersebut didapatkan nilai IoU untuk metrik setiap kelasnya dan mIoU untuk rata-rata dari seluruh kelas atau bisa disebut metrik segmentasi yang mewakili suatu model.

```
mIoUs = per_class_iu(hist)
for ind_class in range(num_classes):
    print('==>' + name_classes[ind_class] + ':\t' +
str(round(mIoUs[ind_class] * 100, 2)))
print('==> mIoU: ' + str(round(np.nanmean(mIoUs) * 100, 2)))
```

Selain itu, penelitian ini juga mengukur dari sisi komputasi dan penggunaan sumber dayanya. Untuk mengukur performa komputasi model dilakukan pengukuran FPS dan latensi model yang dilakukan dengan mencatat waktu eksekusi *forward pass* model. Nilai latensi dan FPS dihitung untuk setiap iterasi inferensinya yang kemudian dihitung rata-rata dan standar deviasinya.

```
torch.cuda.synchronize()
t0 = time.time()
[model bekerja]
torch.cuda.synchronize()
t1 = time.time()
lat = (t1 - t0) * 1000 # ms
latencies.append(lat)

gpu_utils.append(get_gpu_util())
vram_usages.append(get_vram_usage())
```

Untuk memantau pemanfaatan sumber daya GPU, penelitian ini mencatat GPU *utilization* dan VRAM *usage* dalam proses inferensi. Pengukuran tersebut dilakukan dengan

menggunakan *nvidia-smi* secara programatik pada setiap iterasi inferensi. Nilai yang dihasilkan merepresentasikan pemanfaatan sumber daya GPU secara global pada saat proses inferensi berlangsung. Mekanisme ini digunakan untuk memberikan estimasi realistis terhadap beban komputasi model ketika dijalankan dilingkungan komputasi nyata.

```
def get_gpu_util():
    try:
        out = subprocess.check_output(
            "nvidia-smi --query-gpu=utilization.gpu --
format=csv,noheader,nounits",
            shell=True
        )
def get_vram_usage():
    try:
        out = subprocess.check_output(
            "nvidia-smi --query-gpu=memory.used --
format=csv,noheader,nounits",
            shell=True
        )
```

3. HASIL DAN PEMBAHASAN

3.1 Hasil Evaluasi Kinerja Segmentasi Semantik

Masing-masing model dilakukan evaluasi dengan konfigurasi 7 kelas dan 19 kelas. Indikator performa kinerja segmentasi semantik pada penelitian ini berupa nilai IoU untuk setiap kelas dan mIoU untuk indikator performa keseluruhan model dalam mengenali berbagai kelas objek yang seimbang. Berikut hasil nilai IoU dan mIoU dengan konfigurasi 19 kelas.

Tabel 3 Hasil Evaluasi Performa Segmentasi Konfigurasi 19 Kelas

Kelas	Dataset UGM-val			DANNet (Dark Zurich-val)
	PSPNet		DANNet	
	Day	Night		
mIoU	45.93	5.27	9.29	36.76
Road	89.16	42.09	63.75	90.93
Sidewalk	55.88	5.26	9.24	59.35
Building	65.43	14.82	6.53	77.08
Wall	38.96	0.73	2.86	37.8
Fence	46.72	0.96	6.46	40.35
Pole	25.31	0.28	0.76	14.08
Traffic Light	39.76	0	0	39.97
Sign	36.30	0.2	0.84	14.15
Vegetation	88.21	22.23	45.92	68.26
Terrain	45.65	3.45	3.78	28.61
Sky	90.39	0.31	23.5	82.91
Person	18.09	0.3	0.14	21
Rider	60.66	1.03	1.52	25.45


Car	71.98	6.89	8.87	46.99
Truck	25.73	0.01	0.09	0
Bus	14.81	0.02	0	0
Train	0	0	0	0
Motorcycle	53.32	1.6	0.94	10.22
Bicycle	6.36	0	1.31	41.33

Model PSPNet mengalami penurunan performa yang sangat tajam dengan nilai mIoU 45.93% (siang) menjadi 5.27% (malam). Namun, model DANNet mampu meningkatkan mIoU pada kondisi malam hari menjadi 9.29% meskipun tanpa menggunakan *ground truth*. Hal ini artinya penurunan performa segmentasi semantik malam hari yang terjadi pada *baseline* PSPNet berhasil ditingkatkan oleh model DANNet dengan mekanisme *unsupervised domain adaptation*. Berdasarkan penelitian sebelumnya yang dilakukan oleh Wu dan teman-temannya, model DANNet berhasil mencapai nilai mIoU 36.76% pada dataset Dark Zurich. Perbedaan yang jauh tersebut karena dataset UGM memiliki variasi keadaan lingkungan dan pencahayaan yang lebih menantang dan realistis seperti adanya pedagang kaki lima saat malam hari, mobilitas kendaraan yang lebih rama dan *noise* pencahayaan yang kompleks.

Tabel 4 Hasil Evaluasi Performa Segmentasi Konfigurasi 7 Kelas

Kelas	Dataset UGM-val		
	PSPNet		DANNet
	Day	Night	
mIoU	70.22	17.97	22.92
Road	90.08	46.27	69.79
Sidewalk	60.22	8.55	11.36
Building	74.57	11.81	14.91
Pole	30.2	0.22	0.23
Vegetation	92.08	50.29	53.28
Car	75.68	7.32	9.52
Motorcycle	68.74	1.34	1.36

Pada hasil performa dengan konfigurasi 7 kelas, model DANNet berhasil meningkatkan performa yang lebih stabil pada kondisi malam hari dengan nilai mIoU sebesar 22.92%. Hal ini menunjukkan bahwa mekanisme reduksi jumlah kelas kedalam kelas tertentu dapat meningkatkan mIoU secara keseluruhan. Mekanisme tersebut disebabkan karena model hanya fokus mempelajari fitur untuk kelas-kelas tertentu terhadap skenario kendaraan otonom.



Gambar 3 Visualisasi Segmentasi Semantik Konfigurasi 7 dan 19 Kelas

3.2 Evaluasi Efisiensi Komputasi dan Hardware Resource Utilization

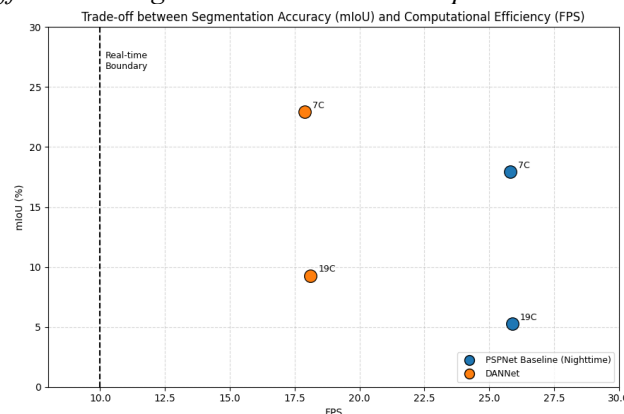
Analisis evaluasi ini dilakukan pada model *baseline* dan DANNet dengan konfigurasi 7 dan 19 kelas. Parameter yang diamati meliputi kecepatan inferensi (FPS), latensi inferensi, penggunaan memori GPU (VRAM Usage), dan Tingkat pemanfaatan GPU (GPU Utilization). Seluruh pengujian dilakukan pada perangkat dan dalam kondisi yang sama untuk memastikan perbandingan berjalan secara adil. Tabel berikut menyajikan pengukuran efisiensi komputasi dan *hardware resources utilization* pada setiap model yang diuji.

Tabel 5 Hasil Pengukuran Efisiensi Komputasi dan Hardware Resource Utilization

Model	Kelas	Parameter	FPS	Mean Latency (ms)	VRAM Usage (MB)	GPU Util (%)
PSPNet Baseline (Night)	19	70,433,254	25.90 ± 0.80	38.64 ± 1.19	16,559.00	28.80 ± 8.46%
	7	70,420,942	25.81 ± 0.65	38.78 ± 1.00	13,325.00	32.67 ± 7.25%
DANNet	19	74,732,649	18.12 ± 0.25	55.20 ± 0.76	17,208.99	23.20 ± 0.66%
	7	74,720,337	17.90 ± 0.60	55.94 ± 1.91	10,139.00	41.29 ± 9.32%

Berdasarkan tabel 5 menunjukkan bahwa parameter dari konfigurasi 7 dan 19 kelas relatif sebanding, sehingga perbedaan performa lebih dipengaruhi oleh mekanisme adaptasi domain daripada kompleksitas arsitekturnya. Pada tabel, menunjukkan PSPNet *baseline* memiliki performa inferensi yang lebih cepat dengan FPS sekitar 25.9 dan latensi ±38 ms, namun tanpa kemampuan adaptasi domain. Sebaliknya, DANNet mengalami penurunan FPS mencapai 18.12 (19 kelas) dan 17.90 (7 kelas) dengan latensi 55 ms akibat adanya tambahan komponen seperti *relighting* dan *adversarial learning*. Meskipun demikian, konfigurasi DANNet 7 kelas menunjukkan penggunaan VRAM yang lebih efisien (10.139 MB) dibandingkan konfigurasi 19 kelas (17.209 MB), serta peningkatan GPU *utilization* hingga 41.29%, yang mengindikasikan pemanfaatan komputasi GPU yang lebih optimal.

3.3 Analisis Trade-Off Akurasi Segmentasi dan Beban Komputasi



Gambar 4 Grafik Trade-off mIoU vs FPS

Gambar 3 menunjukkan *trade-off* antara akurasi segmentasi (mIoU) dan efisiensi komputasi (FPS) pada model PSPNet *baseline* dan DANNet untuk konfigurasi 19 dan 7 kelas. PSPNet *baseline* mencapai FPS yang lebih tinggi, namun dengan penurunan akurasi yang signifikan pada kondisi malam hari, terutama pada konfigurasi 19 kelas. Sebaliknya, DANNet mampu mempertahankan peningkatan mIoU yang konsisten pada kedua konfigurasi kelas dengan sedikit penurunan FPS akibat tambahan proses adaptasi domain. Konfigurasi DANNet 7 kelas menempati posisi yang paling seimbang, berada pada wilayah akurasi yang lebih tinggi dengan FPS yang masih berada dalam batas *near real-time*, sehingga menunjukkan kompromi optimal antara kualitas segmentasi dan beban komputasi untuk aplikasi persepsi kendaraan otonom pada kondisi pencahayaan rendah.

Penilaian kelayakan *real-time* tidak hanya dilihat dari nilai FPS, tetapi hasil evaluasi gabungan dari beberapa aspek performa juga perlu diperhatikan. Penelitian sebelumnya [10] menunjukkan bahwa sistem dengan kecepatan inferensi sekitar 12 FPS masih dapat dikategorikan *real-time feasible* jika didukung dengan latensi yang stabil, kompleksitas model yang terkendali dan kualitas segmentasi yang memadai. Berdasarkan evaluasi yang telah dilakukan, penelitian ini tidak hanya menilai dari aspek FPS dan akurasi segmentasi saja, analisis rata-rata latensi, penggunaan memori GPU dan GPU *utilization* juga disertakan pada penelitian ini. Hasil eksperimen menunjukkan bahwa konfigurasi DANNet pada penelitian ini mampu dikategorikan sebagai *near real-time feasible* untuk persepsi kendaraan otonom pada kondisi malam hari dataset UGM.

Dalam penelitian ini, *trade-off* antara akurasi dan pemanfaatan perangkat keras dinilai berdasarkan evaluasi terpadu dari performa segmentasi (mIoU) serta metrik efisiensi komputasi dan penggunaan memori GPU, meliputi FPS, latensi, VRAM *usage* dan GPU *utilization*. Suatu konfigurasi dapat dikatakan seimbang apabila peningkatan akurasi segmentasi tidak diikuti oleh peningkatan yang signifikan pada kinerja komputasi, serta tetap memenuhi kebutuhan inferensi mendekati *real-time*.

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, penerapan DANNet dengan *backbone* PSPNet terbukti mampu mengurangi penurunan performa akibat *domain shift* antara domain asing dan malam hari tanpa memerlukan anotasi manual pada domain target. Penerapan dataset lokal UGM pada DANNet secara konsisten memberikan performa yang lebih baik dibandingkan model *baseline* PSPNet pada kondisi lingkungan malam hari.

Analisis *trade-off* pada konfigurasi 7 dan 19 kelas memiliki efisiensi komputasi yang relatif sebanding, namun menawarkan tingkat detail semantik yang berbeda. Konfigurasi 7 kelas menghasilkan akurasi segmentasi yang lebih tinggi secara kuantitatif, serta performa inferensi yang mendekati *real-time*, sehingga lebih sesuai untuk skenario pengaplikasian kendaraan otonom di lingkungan nyata. Sedangkan itu, konfigurasi 19 masih tetap layak dan relevan untuk kebutuhan analisis semantik yang lebih detail meskipun dengan tingkat akurasi numeric yang lebih rendah. Secara keseluruhan, penelitian ini menyimpulkan bahwa DANNet mampu mencapai keseimbangan yang baik antara akurasi segmentasi dan pemanfaatan perangkat keras pada skenario segmentasi semantik malam hari.

5. SARAN

Berdasarkan hasil eksperimen yang dilakukan, saran untuk penelitian selanjutnya yang dapat dilakukan, yaitu pengembangan anotasi *ground truth* malam hari secara manual pada sebagian data untuk memvalidasi kualitas *pseudo-label ground truth*, sehingga evaluasi model menjadi lebih andal, perluas variasi *backbone* yang lebih ringan dan efisien untuk meningkatkan kelayakan *real-time* pada perangkat tertanam, dan eksplorasi lebih mendalam adaptasi domain malam hari yang lebih adaptif dengan variasi lingkungan lokal (UGM) sehingga dapat meningkatkan generalisasi model.

DAFTAR PUSTAKA

- [1] Zhang, Yi, et al. "Illumination-Guided Progressive Unsupervised Domain Adaptation for Low-Light Instance Segmentation." *Neural Networks*, vol. 183, 29 Nov. 2024, p. 106958, www.sciencedirect.com/science/article/abs/pii/S0893608024008876, <https://doi.org/10.1016/j.neunet.2024.106958>.
- [2] Wu, Xinyi, et al. "DANNet: A One-Stage Domain Adaptation Network for Unsupervised Nighttime Semantic Segmentation." *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2021, <https://doi.org/10.1109/cvpr46437.2021.01551>.
- [3] Toldo, Marco, et al. "Unsupervised Domain Adaptation in Semantic Segmentation: A Review." *Technologies*, vol. 8, no. 2, June 2020, p. 35, <https://doi.org/10.3390/technologies8020035>. Accessed 22 Apr. 2021.
- [4] Abramov, Michael. "Semantic Segmentation vs Object Detection: Differences." *Keymakr*, 29 Jan. 2024, keymakr.com/blog/semantic-segmentation-vs-object-detection-understanding-the-differences/.
- [5] Wu, Xinyi, et al. "A One-Stage Domain Adaptation Network with Image Alignment for Unsupervised Nighttime Semantic Segmentation." *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, pp. 1–0, <https://doi.org/10.1109/tpami.2021.3138829>. Accessed 30 Aug. 2022.
- [6] Elhassan, Mohammed A. M., et al. "Real-Time Semantic Segmentation for Autonomous Driving: A Review of CNNs, Transformers, and Beyond." *Journal of King Saud University - Computer and Information Sciences*, vol. 36, no. 10, Elsevier, Nov. 2024, p. 102226, <https://doi.org/10.1016/j.jksuci.2024.102226>.
- [7] Papadeas, Ilias, et al. "Real-Time Semantic Image Segmentation with Deep Learning for Autonomous Driving: A Survey." *Applied Sciences*, vol. 11, no. 19, Sept. 2021, p. 8802, <https://doi.org/10.3390/app11198802>. Accessed 21 Oct. 2021.
- [8] Zhao, Hengsuang, et al. "Pyramid Scene Parsing Network," *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 2017, pp. 6230-6239, doi: 10.1109/CVPR.2017.660.
- [9] Bruggemann, David, et al. "Refign: Align and Refine for Adaptation of Semantic Segmentation to Adverse Conditions." *2023 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, Jan. 2023, <https://doi.org/10.1109/wacv56688.2023.00319>.
- [10] Son, H., and J. Weiland, "Semantic Segmentation Optimized for Low Compute Embedded Devices," in *IEEE Access*, vol. 10, pp. 96514-96525, 2022, doi: 10.1109/ACCESS.2022.3199418.