

Perbandingan Akurasi Klasifikasi Kendaraan Menggunakan Yolov8 Dan Faster R-CNN

^{1*}**Muhamad Helmi Khoirur Rizal, ²Julian Sahertian, ³Rony Heri Irawan**

^{1,2,3}Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail : *1muhamad.helmi.k.rizal@gmail.com, 2Juliansahertian@unpkediri.ac.id, 3Rony@unpkediri.ac.id

Penulis Koresponden : Muhamad Helmi Khoirur Rizal

Abstrak—Deteksi dan klasifikasi kendaraan merupakan tantangan penting dalam bidang visi komputer. Penelitian ini membandingkan dua metode deep learning populer, yaitu YOLOv8 dan Faster R-CNN, dalam hal akurasi klasifikasi kendaraan pada citra. Dataset yang digunakan terdiri dari gambar kendaraan dengan berbagai kelas seperti mobil, motor, truk, bus. Kedua model dievaluasi menggunakan metrik akurasi, presisi, dan mAP (mean Average Precision). Hasil pengujian menunjukkan bahwa Faster R-CNN memberikan akurasi yang lebih tinggi dibandingkan YOLOv8 pada seluruh kelas kendaraan yang diuji. Faster R-CNN menunjukkan performa klasifikasi yang lebih stabil, dengan akurasi tertinggi pada kelas truk (0.74) dan akurasi terendah pada kelas bus (0.56). sedangkan YOLOv8 mengalami penurunan akurasi terutama pada kelas motor (0.48) dan bus (0.48). YOLOv8 cenderung lebih sensitif terhadap objek berukuran besar, tetapi kurang optimal dalam membedakan objek kecil atau objek yang memiliki kemiripan visual dengan latar belakang. Studi ini bertujuan untuk memberikan wawasan mengenai keunggulan YOLOv8 dibandingkan metode two-stage seperti Faster R-CNN dalam konteks klasifikasi objek berbasis gambar.

Kata Kunci— akurasi, Faster R-CNN, klasifikasi kendaraan, visi komputer, YOLOv8

Abstract—*Vehicle detection and classification are critical challenges in the field of computer vision. This study compares two popular deep learning methods—YOLOv8 and Faster R-CNN—in terms of vehicle classification accuracy on images. The dataset used consists of vehicle images from various categories, including cars, motorcycles, trucks, and buses. Both models were evaluated using accuracy, precision, and mean Average Precision (mAP) metrics. The results show that Faster R-CNN achieves higher classification accuracy across all vehicle classes tested. It also demonstrates more stable performance, with the highest accuracy recorded on trucks (0.74) and the lowest on buses (0.56). In contrast, YOLOv8 experiences a drop in accuracy, particularly in the motorcycle and bus classes (both at 0.48). YOLOv8 tends to be more sensitive to large objects but performs less optimally in distinguishing small objects or those visually similar to the background. This study aims to provide insights into the strengths of YOLOv8 compared to two-stage methods like Faster R-CNN in the context of image-based object classification.*

Keywords—accuracy, computer vision, Faster R-CNN, vehicle classification, YOLOv8.

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Kemampuan mendeteksi dan mengklasifikasi kendaraan secara tepat sangat penting dalam berbagai aplikasi komputer vision. Dengan kemajuan teknologi *deep learning*, metode seperti YOLOv8 dan Faster R-CNN semakin banyak digunakan karena performanya yang menjanjikan. Namun, setiap metode memiliki kelebihan dan keterbatasan yang perlu dipahami secara mendalam, khususnya dalam konteks akurasi klasifikasi kendaraan. Oleh karena itu, evaluasi

perbandingan antara kedua metode ini menjadi langkah penting untuk menentukan pendekatan terbaik yang sesuai dengan kebutuhnya.

Seiring berkembangnya kebutuhan akan klasifikasi kendaraan yang akurat, pemanfaatan algoritma *deep learning* menjadi pilihan utama dalam berbagai proyek berbasis komputer vision. Di antara banyaknya metode yang tersedia, YOLOv8 dan Faster R-CNN sering dipertimbangkan karena performa dan karakteristik teknis yang berbeda, meski begitu, masing-masing metode memiliki kelebihan dan kekurangan yang perlu dipahami dengan baik agar hasil klasifikasi bisa optimal. Sebagai contoh, YOLOv8 dikenal karena kecepatan inferensinya yang tinggi, membuatnya cocok untuk aplikasi *real-time* yang membutuhkan respons cepat[1]. Di sisi lain, Faster R-CNN sering kali memberikan akurasi yang lebih baik pada objek kecil atau sulit dikenali, walaupun dengan waktu proses yang lebih lama[2]. Oleh karena itu, membandingkan kedua metode ini secara langsung pada dataset kendaraan yang sama sangat penting untuk menentukan pilihan yang tepat bagi pengembangan sistem klasifikasi kendaraan otomatis.

Salah satu tantangan utama dalam klasifikasi kendaraan memastikan model tetap akurat meskipun menghadapi variasi bentuk, ukuran, sudut pandang, dan kondisi pencahayaan[3]. Untuk menjawab tantangan ini, beberapa pendekatan deep learning telah dikembangkan dan dibandingkan YOLOv8 dikembangkan sebagai pengembangan lanjutan dari versi YOLO sebelumnya melalui berbagai optimalisasi arsitektur dan mekanisme ekstraksi fitur, dengan tujuan utama meningkatkan akurasi deteksi objek tanpa mengorbankan efisiensi komputasi maupun kecepatan inferensi[4]. Di sisi lain, Algoritma Faster R-CNN mengandalkan proses deteksi dua tahap yang terbukti efektif dalam mendeteksi objek berukuran kecil atau saling tumpang tindih [5]. Karakteristik inilah yang membuat keduanya menarik untuk dibandingkan secara langsung, khususnya dalam konteks akurasi klasifikasi pada dataset kendaraan.

Perbandingan antara YOLOv8 dan Faster R-CNN menjadi semakin relevan karena keduanya mewakili dua pendekatan yang berbeda dalam sistem deteksi objek. YOLOv8 sebagai metode *one-stage* menggabungkan proses deteksi dan klasifikasi dalam satu langkah, sehingga jauh lebih efisien dalam hal waktu pemrosesan[6]. Sebaliknya, Faster R-CNN memanfaatkan pendekatan dua tahap yang memisahkan proses proposal region dan klasifikasi objek. Pendekatan ini, meskipun lebih kompleks dibandingkan dengan model satu tahap, terbukti lebih efektif dalam mendeteksi objek berukuran kecil pada citra penginderaan jauh, meningkatkan akurasi deteksi terutama pada objek yang sulit dibedakan karena ukurannya[7]. Dalam konteks klasifikasi kendaraan, perbedaan struktur ini dapat mempengaruhi performa masing-masing model, tergantung pada karakteristik dataset yang digunakan.

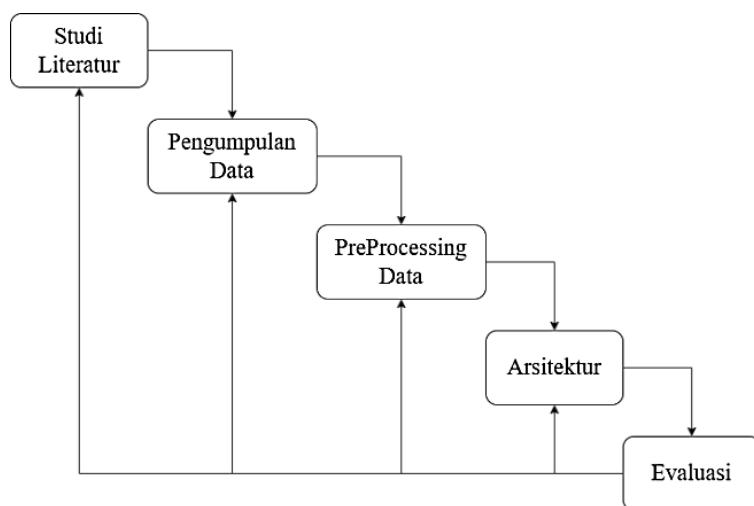
Meskipun keduanya merupakan metode yang berbeda dalam mendekati masalah deteksi objek, masih sedikit studi yang secara khusus membandingkan performa klasifikasi kendaraan antara YOLOv8 dan Faster R-CNN menggunakan dataset yang sama dan kondisi evaluasi yang setara. Sebagian besar penelitian sebelumnya hanya berfokus pada salah satu metode atau membandingkan versi YOLOv5 dengan model lain[8]. Padahal YOLOv8 membawa sejumlah perbaikan dan peningkatan dari segi arsitektur dan kemampuan generalisasi, yang penting untuk diuji dalam skenario nyata. Dengan adanya celah ini, penelitian yang secara langsung membandingkan akurasi klasifikasi kendaraan antara dua pendekatan tersebut menjadi penting untuk memberikan gambaran yang lebih objektif dan menyeluruh.

Melalui perbandingan yang dilakukan secara langsung dan sistematis, diharapkan penelitian ini dapat memberikan pemahaman yang lebih dalam mengenai efektivitas masing-masing metode dalam mengklasifikasi kendaraan. Hasil evaluasi dari kedua pendekatan ini juga dapat menjadi dasar pertimbangan dalam memilih model deteksi objek yang sesuai dengan kebutuhan sistem

klasifikasi berbasis citra. Dengan begitu, kontribusi dari penelitian ini tidak hanya bersifat teoritis, tetapi juga aplikatif untuk pengembangan sistem berbasis komputer visiom di masa mendatang.

II. METODE

Penelitian ini menggunakan metode pengembangan waterfall, yaitu pendekatan sistematis yang terdiri dari beberapa tahapan berurutan, mulai studi literatur hingga evaluasi model. Metode ini dipilih karena sesuai untuk proyek yang membutuhkan alur kerja terstruktur, seperti perbandingan performa dua arsitektur model *deep learning*. Adapun tahapan yang dilakukan dalam penelitian ini sebagai berikut:



Gambar 1. Metode Waterfall

A. Studi literatur

Tahap awal dilakukan dengan menelaah berbagai referensi ilmiah terkait deteksi dan klasifikasi kendaraan berbasis deep learning. Penelitian sebelumnya yang menggunakan YOLO, Faster R-CNN, dan metode evaluasi seperti mAp, akurasi, presisi, dan recall menjadi dasar dalam menyusun strategi pelatihan serta pengujian model. Literatur juga dijadikan acuan dalam pemilihan parameter pelatihan, dan struktur dataset.

B. Pengumpulan data

Secara keseluruhan, jumlah dataset yang digunakan dalam penelitian ini adalah 3908 gambar. Seluruh gambar telah dianotasi dalam dua format, yaitu YOLO untuk digunakan pada model YOLOv8 dan COCO(JSON) untuk digunakan pada model Faster R-CNN.

Dataset yang digunakan dalam penelitian ini berasal dari rekaman video CCTV yang kemudian diambil per frame secara manual dan dikonversi menjadi gambar berformat jpg. Setiap gambar berisi objek kendaraan dengan variasi jenis dan posisi yang berbeda.

Proses anotasi dan pelabelan dilakukan menggunakan platform roboflow, dengan menandai objek kendaraan ke dalam empat kelas, motor, mobil, truk, bus. Data yang telah dilabeli kemudian dibagi menjadi tiga bagian:

Tabel 1. Pembagian Dataset

Folder	Jumlah
Train	3416
Test	164
Valid	328

C. Preprocessing data

Sebelum digunakan dalam proses pelatihan, gambar dataset terlebih dahulu diproses melalui beberapa tahapan preprocessing. Langkah pertama adalah penyesuaian ukuran gambar menjadi resolusi yang sesuai dengan kebutuhan masing-masing model. Untuk YOLOv8, gambar diubah menjadi 640x640 piksel, sementara untuk Faster R-CNN, ukuran gambar di-scale secara proposional dengan sisi pendek diubah menjadi 800 piksel dan sisi panjang dibatasi maksimal 1333 piksel, sesuai dengan konfigurasi bawaan model.

Selanjutnya, dilakukan proses augmentasi data untuk meningkatkan variasi dataset dan mengurangi resiko *overfitting*. Teknik augmentasi yang digunakan meliputi rotasi, *horizontal flipping*. Semua proses ini dilakukan menggunakan fitur bawaan dari platform Roboflow serta fungsi augmentasi dari masing-masing *framework* pelatihan.

Setelah proses augmentasi dan penyesuaian ukuran, seluruh data disimpan dalam struktur direktori dan format yang sesuai dengan masing-masing model, format YOLO untuk YOLOv8 dan format COCO(JSON) untuk Faster R-CNN.

D. Arsitektur

Penelitian ini menggunakan dua metode deteksi dan klasifikasi objek berbasis deep learning, yaitu YOLOv8 dan Faster R-CNN. Kedua metode dipilih karena mewakili dua pendekatan arsitektur yang dalam sistem deteksi objek, yaitu *one-stage* dan *two-stage detector*.

YOLOv8(You Only Look Once Version 8) merupakan algoritma deteksi objek berbasis one-stage, yang secara langsung memprediksi *bounding box* dan kelas objek dalam satu proses. Model ini dikenal karena kecepatan inferensinya tinggi, menjadikannya sangat efisien untuk aplikasi *real-time*. YOLOv8 juga membawa peningkatan dari versi sebelumnya dalam hal arsitektur backbone dan head yang lebih ringan serta akurat[9].

Faster R-CNN(Region-Based Convolutional Neural Network) adalah algoritma *two-stage detector*, dimana proses deteksi dilakukan melalui dua tahap, pertama menghasilkan region proposals menggunakan *Region Proposal Network* (RPN), lalu dilanjutkan dengan klasifikasi dan regresi *bounding box*. Pendekatan ini memungkinkan deteksi yang lebih teliti, terutama pada objek kecil atau saling tumpah tindih[10]

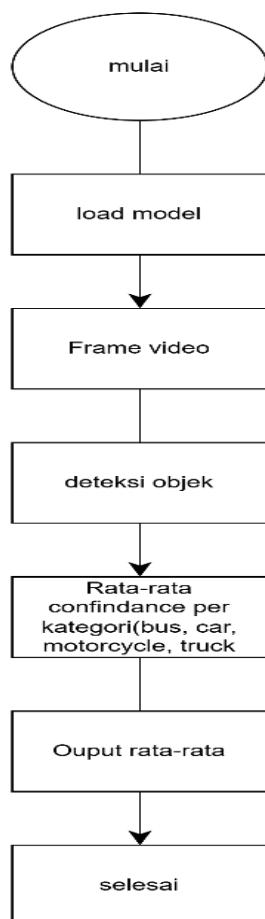
Melalui perbandingan dua metode dengan pendekatan yang berbeda ini, peneliti diharapkan dapat memberikan gambaran yang menyeluruh mengenai kelebihan dan kekurangan masing-masing metode dalam konteks klasifikasi kendaraan berbasis citra.

III. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil implementasi sistem klasifikasi kendaraan berbasis citra menggunakan dua metode deteksi objek,yaitu YOLOv8 dan Faster R-CNN. Berdasarkan proses

pelatihan dan pengujian yang telah dilakukan terhadap dataset berisi empat kelas kendaraan (bus, mobil, motor, dan truk), kedua model menunjukkan performa yang cukup baik. Evaluasi dilakukan berdasarkan confusion matrix, yang menggambarkan kemampuan masing-masing model dalam mengklasifikasikan objek secara tepat maupun kesalahan prediksi yang terjadi. Adapun rincian hasil klasifikasi dan pembahasannya disajikan sebagai berikut:

A. Rancangan Sistem



Gambar 2. Flowchart Sistem

Pada gambar 2, menggambarkan alur kerja sistem deteksi kendaraan berbasis video. Proses dimulai pada tahap inisialisasi, yang ditandai dengan pemanggilan perintah “mulai” sebagai titik awal eksekusi program. Tahap berikutnya adalah pemanggilan model, di mana sistem memuat model deteksi objek yang telah melalui proses pelatihan sebelumnya. Model yang digunakan berupa Faster R-CNN dan YOLOv8

Setelah model berhasil dibuat, sistem melanjutkan ke tahap pembacaan video, yaitu dengan membuka berkas video dan membaca setiap frame secara berurutan. Pada setiap frame, dilakukan proses deteksi objek untuk mengidentifikasi jenis-jenis kendaraan yang termasuk dalam kategori tertentu, seperti mobil, bus, sepeda motor, dan truk. Hasil deteksi ini kemudian disaring berdasarkan nilai confidence. Tahap selanjutnya adalah perhitungan nilai rata-rata *confidence* untuk masing-masing kategori kendaraan. Nilai ini dihitung berdasarkan akumulasi *confidence* dari objek yang terdeteksi sejauh proses berjalan. Hasil rata-rata tersebut

kemudian ditampilkan secara langsung pada video dalam tahap penyajian keluaran (output). Seluruh proses ini berlangsung secara *real-time* hingga seluruh frame dalam video selesai diproses atau pengguna menghentikan program secara manual. Proses diakhiri dengan tahap terminasi, di mana seluruh aktivitas sistem dihentikan dan sumber daya seperti jendela tampilan video ditutup dengan semestinya.

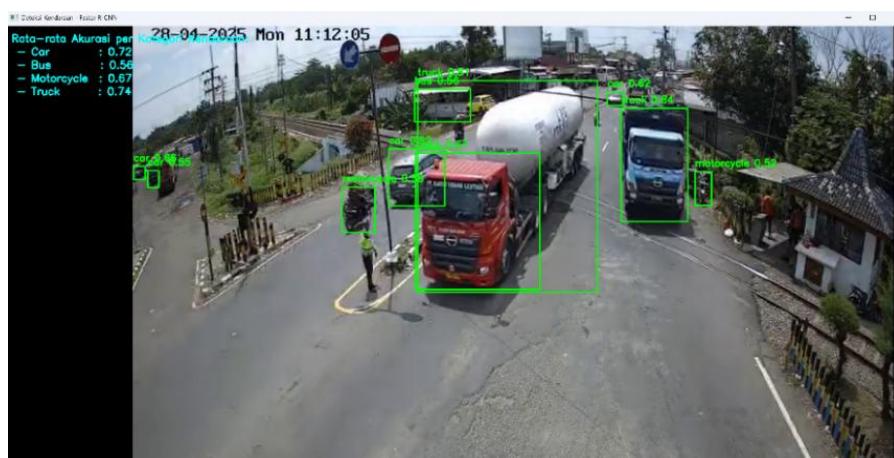
B. Pengujian model

Pengujian dilakukan untuk mengevaluasi performa model Faster R-CNN dan YOLOv8 dalam mengklasifikasikan kendaraan berdasarkan data uji sebanyak 164 gambar.

Tabel 2. Hasil Nilai akurasi

Kategori Kendaraan	Faster R-CNN	YOLOv8
Bus	0.56	0.48
Mobil	0.072	0.55
Motor	0.67	0.48
Truk	0.74	0.53

Berdasarkan Tabel 2, model Faster R-CNN menunjukkan performa klasifikasi yang cukup stabil, terutama pada kategori truk (0.74) dan motor (0.67), sedangkan akurasi kelas bus berada pada nilai 0.56. Namun, akurasi untuk kategori mobil sangat rendah (0.072), mengindikasikan bahwa model mengalami kesulitan dalam membedakan kendaraan yang memiliki karakteristik visual mirip, seperti mobil dan bus. Visualisasi hasil deteksi Faster R-CNN ditampilkan pada Gambar 3, yang menunjukkan bounding box dan label kelas dari setiap objek kendaraan yang terdeteksi.



Gambar 3. Hasil deteksi model Faster R-CNN

Sementara itu, model YOLOv8 memberikan distribusi akurasi yang lebih merata sebagaimana ditunjukkan pada Tabel 2. Akurasi tertinggi terdapat pada kategori mobil (0.55), disusul oleh truk (0.53), sedangkan bus dan motor memiliki akurasi yang sama (0.48). Hasil deteksi YOLOv8 ditampilkan pada Gambar 3, di mana sebagian besar objek kendaraan

berhasil diklasifikasikan dengan benar. Namun, model ini masih menunjukkan kesalahan pada objek berukuran kecil atau yang memiliki latar belakang yang kompleks, seperti ditunjukkan pada gambar 4. Jika dibandingkan, Faster R-CNN cenderung lebih akurat pada kendaraan besar dan jelas, sedangkan YOLOv8 lebih efisien dan cepat namun rentan terhadap kesalahan pada kondisi visual yang rumit.



Gambar 4. Hasil deteksi model YOLOv8

IV. KESIMPULAN

Penelitian ini telah membandingkan dua metode deteksi dan klasifikasi kendaraan berbasis citra, yaitu YOLOv8 dan Faster R-CNN. Kedua model diuji pada dataset yang terdiri dari empat kelas kendaraan: bus, mobil, motor, dan truk. Berdasarkan hasil pelatihan dan pengujian yang dilakukan, dapat disimpulkan beberapa hal sebagai berikut:

1. Faster R-CNN menunjukkan performa klasifikasi yang lebih stabil, dengan akurasi tertinggi pada kelas truk (0.74) dan akurasi terendah pada kelas bus (0.56). Confusion matrix memperlihatkan hasil klasifikasi yang hampir sempurna dengan kesalahan sangat minim.
2. YOLOv8 unggul dari sisi efisiensi dan kecepatan inferensi, namun mengalami penurunan akurasi pada kelas motor (0.48) dan bus (0.48). Model ini lebih sensitif terhadap objek besar namun kurang optimal dalam membedakan objek kecil atau yang berdekatan dengan latar belakang.
3. Berdasarkan visualisasi hasil prediksi dan nilai akurasi rata-rata, Faster R-CNN lebih cocok digunakan pada sistem klasifikasi kendaraan yang membutuhkan ketelitian tinggi, sedangkan YOLOv8 lebih sesuai untuk aplikasi real-time dengan kecepatan deteksi sebagai prioritas utama.

Dengan demikian, pemilihan metode yang digunakan harus disesuaikan dengan kebutuhan sistem. Apabila fokus pada kecepatan dan efisiensi, maka YOLOv8 menjadi pilihan utama. Namun, jika akurasi dan presisi lebih diutamakan, maka Faster R-CNN memberikan hasil yang lebih unggul.

DAFTAR PUSTAKA

- [1] “Implementasi YOLO Dalam Deteksi Jumlah”.
- [2] D. I. Mulyana and M. A. Rofik, “Implementasi Deteksi Real Time Klasifikasi Jenis Kendaraan Di Indonesia Menggunakan Metode YOLOV5.”
- [3] T. Taufiqurrahman, A. P. Hadi, and R. E. Siregar, “Evaluasi Performa Yolov8 Dalam Deteksi Objek Di Depan Kendaraan Dengan Variasi Kondisi Lingkungan,” *Jurnal Minfo Polgan*, vol. 13, no. 2, pp. 1755–1773, Nov. 2024, doi: 10.33395/jmp.v13i2.14228.
- [4] T. Xie, M. Yin, X. Zhu, J. Sun, C. Meng, and S. Bei, “A Fast and Robust Lane Detection via Online Re-Parameterization and Hybrid Attention,” *Sensors*, vol. 23, no. 19, Oct. 2023, doi: 10.3390/s23198285.
- [5] N. Hanun, M. Sarosa, and R. Andrie Asmara, “Pemanfaatan Algoritma Faster R-CNN ResNet-101 Untuk Deteksi Potongan Tubuh Manusia,” *Jurnal Elektronika dan Otomasi Industri*, vol. 10, no. 1, pp. 94–103, May 2023, doi: 10.33795/elkolind.v10i1.2754.
- [6] M. T. Audina, F. Utaminingrum, and D. Syauqi, “Sistem Deteksi dan Klasifikasi Jenis Kendaraan berbasis Citra dengan menggunakan Metode Faster-RCNN pada Raspberry Pi 4B,” 2021. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [7] Y. Ren, C. Zhu, and S. Xiao, “Small object detection in optical remote sensing images via modified Faster R-CNN,” May 18, 2018, *MDPI AG*. doi: 10.3390/app8050813.
- [8] H. Gibran, B. Purnama, and G. Kosala, “Pengoptimasian Pengukuran Kepadatan Jalan Raya Dengan Cctv Menggunakan Metode Yolov8,” *Technomedia Journal*, vol. 9, no. 1, pp. 31–45, Feb. 2024, doi: 10.33050/tmj.v9i1.2216.
- [9] J. PARDEDE and H. HARDIANSAH, “Deteksi Objek Kereta Api menggunakan Metode Faster R-CNN dengan Arsitektur VGG 16,” *MIND Journal*, vol. 7, no. 1, pp. 21–36, Jun. 2022, doi: 10.26760/mindjournal.v7i1.21-36.
- [10] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” Jun. 2015, [Online]. Available: <http://arxiv.org/abs/1506.01497>