

Analisis Klasifikasi Mobil Pada Gardu Tol Otomatis (GTO) Menggunakan Convolutional Neural Network (CNN)

Adinda Titania¹, Sayuti Rahman^{2*}, Arnes Sembiring³, Mufida Khairani⁴, Yessi Fitri Annisah Lubis⁵

^{1,2,3,4,5} Universitas Harapan Medan, Medan, Indonesia

¹dindabanurea09@gmail.com, ^{2*}masay.ram@gmail.com, ³arnessembiring@gmail.com,

⁴mufida.khairani@gmail.com, ⁵yessy.annisah@gmail.com

^{*}masay.ram@gmail.com

Abstrak— Konsep kota cerdas menjadi isu yang paling penting dalam aspek pengembangan kota-kota besar yang ada di dunia. Dimana kota harus menjanjikan hidup yang lebih nyaman, teratur, sehat dan efisien. *Smart transportation* merupakan bagian dari *smart city* yang berguna untuk meningkatkan tata kota yang lebih baik. *Smart transportation* juga berlaku di jalan tol, seperti otomatisasi pembayaran retribusi jalan tol. Gardu Tol Otomatis (GTO) di Indonesia masih menggunakan sensor. Namun, sensor sering salah dalam klasifikasi truk gandeng. Selain itu, penggunaan sensor juga membutuhkan biaya tambahan dalam instalasi dan perawatan. Saat ini setiap pintu tol sudah dilengkapi kamera untuk berbagai kepentingan. Dengan memanfaatkan kamera tersebut untuk klasifikasi jenis kendaraan akan menurangi biaya pada GTO. Oleh karena alasan tersebut, memanfaatkan kamera digital dengan visi komputer untuk klasifikasi jenis kendaraan menjadi solusi. *Convolutional Neural Networks* (CNN) merupakan teknik yang paling populer saat ini dalam menyelesaikan masalah visi komputer. Eksploitasi *existing CNN* dengan mengganti output *fully connected* terakhir sesuai jumlah kelas kendaraan. Hasil pengujian menunjukkan bahwa *mobilenet V2* lebih baik dalam klasifikasi jenis kendaraan, akurasi terbaik *Alexnet* sebesar 93,81% dan *Mobilenet* 96,19%. Visi komputer dengan memanfaatkan CNN diharapkan dapat menggantikan penggunaan sensor sehingga biaya implementasi lebih murah.

Kata Kunci: Pintu Tol Otomatis, Klasifikasi Mobil, Alexnet, Mobilnet V2, CNN

Abstract— The concept of a smart city is the most important issue in the development aspect of big cities in the world. Where the city must promise a more comfortable, organized, healthy and efficient life. *Smart transportation* is part of a smart city that is useful for improving better urban planning. *Smart transportation* also applies to toll roads, such as automating toll road retribution payments. Automatic Toll Gate (GTO) in Indonesia still uses sensors. However, sensors often misclassify trailers. In addition, the use of sensors also requires additional costs in installation and maintenance. Currently, every toll gate is equipped with cameras for various purposes. By utilizing the camera for vehicle type classification, the cost of the GTO will be reduced. For this reason, utilizing a digital camera with computer vision for vehicle type classification is the solution. *Convolutional Neural Networks* (CNN) is the most popular technique today in solving computer vision problems. Exploit the existing CNN by replacing the last fully connected output according to the number of vehicle classes. The test results show that *mobilenet V2* is better in the classification of vehicle types, the best accuracy is *Alexnet* 93.81% and *Mobilenet* 96.19%. Computer vision by utilizing CNN is expected to replace the use of sensors so that implementation costs are cheaper..

Keywords: Automatic Toll Gate, Car Classification, Alexnet, Mobilnet V2, CNN

1. PENDAHULUAN

Jumlah penduduk Kota Medan pada tahun 2020 berdasarkan data dari BPS Provinsi Sumatera Utara telah mencapai 2.524.321 jiwa. Sedangkan tingkat kepadatannya pada tahun 2020 sudah mencapai 9.522,22 jiwa/Km² dimana kota Medan menjadi sangat padat penduduknya di wilayah pulau Sumatera. Tingginya kepadatan penduduk ini ditambah dengan tingginya pertambahan jumlah kendaraan bermotor menyebabkan tingginya tingkat kepadatan kendaraan pribadi yang melintas di jalan.

Berdasarkan data dari Badan Pusat Statistik (BPS), pada tahun 2019 mencatat jumlah kendaraan bermotor kota Medan meningkat sejumlah 81.371 unit dari tahun sebelumnya yaitu sebanyak 275.375 unit. Pada tahun 2018 naik 6,7 persen dari tahun 2017 sejumlah 194.004 unit [1]. Konsep kota cerdas (*Smart City*) menjadi isu yang sangat penting dalam aspek perkembangan kota-kota yang ada di dunia, dimana kota harus menjanjikan hidup yang lebih nyaman (*convenience of life*), teratur, sehat dan efisien dalam setiap aspek kehidupan masyarakat kota. Kenyamanan ini akan didukung dengan penggunaan teknologi guna mempercepat akses dan sarana yang dibutuhkan oleh masyarakat. Penggunaan teknologi juga berorientasi pada efisien dan efektif yang mengutamakan teknologi yang berbasis ramah lingkungan (*green technology*)[2].

Berbagai konsep tentang kota muncul untuk mengatasi segala permasalahan tersebut, salah satu konsep perencanaan pembentukan *Smart City* adalah *Smart Transportation*. *Smart Transportation* merupakan bagian dari *Smart City* yang paling penting untuk meningkatkan ekonomi perkotaan. Selain untuk menghemat waktu dan biaya, informasi lalu lintas pun dapat dengan mudah didapatkan oleh pengguna jalan. *Smart Transportation* juga berperan penting untuk melaporkan apa saja yang terjadi di jalan raya.

Pertumbuhan jumlah kendaraan di Indonesia menyebabkan masalah lalu lintas, termasuk jalan tol. Masalah kemacetan lalu lintas di jalan tol terjadi karena pengguna harus berhenti untuk melakukan pembayaran

di pintu tol. Pemerintah membangun penampungan Gerbang Tol Otomatis (atau Gardu Tol Otomatis/GTO) sebagai upaya untuk mengurangi masalah tersebut. Namun beberapa GTO di Indonesia masih memiliki sensor yang sering kali gagal untuk mendeteksi truk gandeng[3].

Dalam artikel ini, dikembangkan sistem yang dapat mengklasifikasikan semua jenis kendaraan sehingga GTO dapat digunakan untuk berbagai jenis kendaraan yang melintas di jalan tol dengan memanfaatkan kamera digital. Sistem ini diharapkan dapat mengklasifikasi jenis kendaraan serta meminimalkan biaya instalasi dan perawatan sistem di GTO. Hal ini dikarenakan visi komputer dengan memanfaatkan kamera digital dapat memantau beberapa kegiatan sekaligus[4].

Deep Learning dengan *Metode Convolutional Neural Network (CNN)* digunakan untuk klasifikasi jenis kendaraan. CNN merupakan arsitektur jaringan saraf tiruan yang sangat populer. CNN merupakan *multilayer perceptron* yang merupakan salah satu varian dari *Deep Neural Networks* yang sering digunakan sebagai metode untuk mengklasifikasikan data citra digital. Penelitian sebelumnya sudah melakukan percobaan dengan menggunakan metode CNN dan hasil yang diperoleh dari jaringan memiliki evaluasi yang akurat yaitu 73%. Percobaan tersebut menggunakan arsitektur MiniVGGNet yang menerapkan fungsi optimasi adadelta dan parameter citra 64x64 dan epoch 40 [5]. Existing CNN yang akan digunakan dalam penelitian ini antara lain adalah *Alexnet* dan *Mobilenet V2* yang telah berhasil mengklasifikasikan objek dengan baik. existing CNN ini didesain untuk mengklasifikasi 1000 objek pada dataset imagenet yang memerlukan komputasi dan ruang penyimpanan yang besar[6], [7]. *Tuning* terhadap Alexnet dan mobilenet V2 untuk klasifikasi jenis kendaraan dengan jumlah kelas kendaraan hanya 5, dapat memberi solusi pada GTO.

2. METODE PENELITIAN

2.1 Dataset

Agar dapat mengenali jenis dari mobil dan truck, dibutuhkan data masukan berupa citra digital sebagai data latih dan data uji. Beberapa proses yang akan dilakukan adalah mengambil data masukan berupa citra mobil dan truk yang didapatkan dari CCTV dengan melalui teknik screenshot, lalu teknik cropping. Kemudian menyesuaikan citra yang sudah melalui teknik cropping ke dalam jenis dan kelasnya. Kelas-kelasnya antara lain: mobil, truk roda 4, truk roda 6, truk roda 8, truk roda 10. Penelitian ini berfokus pada menganalisis klasifikasi jenis mobil dengan menggunakan Existing CNN, yaitu Alexnet dan Mobilenet V2. Penelitian ini dilakukan agar mendapatkan hasil akurasi terbaik dalam pengklasifikasian mobil, dan dapat diterapkan pada Gardu Tol Otomatis (GTO), sehingga GTO dapat menentukan tarif tol secara otomatis sesuai dengan jenis dan kelas dari mobil yang akan melewati Tol.


Dataset merupakan kumpulan objek yang berasal dari data dan dikelola menjadi sebuah informasi. Data yang digunakan berupa gambar atau citra yang diambil dari data yang sudah tersedia pada penelitian sebelumnya dan data mentah yang di rekam dari CCTV jalan tol. Data citra yang digunakan untuk data uji sebanyak 631 citra, dan data latih sebanyak 1473 citra dengan kualitas gambar yang baik. Seluruh data berjumlah 2104 citra dengan pembagian citra. Berikut pembagian dataset disajikan pada tabel 1.

Tabel 1. Pembagian keseluruhan *dataset*

No	Dataset	Jumlah Data
1.	Data latih	1473
2.	Data uji	631

2.2 Arsitektur MobileNet V2 dan Alexnet

Alexnet merupakan arsitektur besar yang ditemukan oleh Krizhevsky dkk untuk mengklasifikasi 1000 kelas data Imagenet. Sebagai penyesuaian kami mengubah fully connected terakhir sesuai dengan jumlah kelas kendaraan yang akan diklasifikasi yaitu 5 (lima) kelas. Seperti terlihat pada Gambar 1.



Gambar 1. Alexnet 5 kelas untuk klasifikasi jenis kendaraan

Selain Alexnet, arsitektur yang digunakan adalah Mobilenet V2. Mobilenet merupakan salah satu arsitektur CNN yang dapat digunakan untuk mengatasi kebutuhan akan computing resource berlebih. Seperti namanya, mobile, para peneliti dari Google membuat arsitektur CNN yang dapat digunakan untuk ponsel. Mobilenet memiliki arsitektur yang ramping dan kompleksitas yang rendah, namun tetap mempertimbangkan akurasi dan kehandalan dalam klasifikasi objek. Perbedaan mendasar antara arsitektur Mobilenet dan arsitektur CNN pada umumnya adalah penggunaan lapisan atau layer konvolusi dengan ketebalan filter yang sesuai dengan ketebalan dari input image[14]. Arsitektur Mobilenet V2 dengan *fully connected* yang disesuaikan jumlah kelas kendaraan disajikan pada tabel 2.

Tabel 2. Arsitektur Mobilenet

Type/ Stride	Filler Shape	Input Size
Conv / s2	3 x 3 x 3 x 32	221 x 224 x 3
Conv dw / s 1	3 x 3 X 32 dw	112 x 112 x 32
Conv / s1	1 x 1 x 32 x 64	112 x 112 x 32
Conv dw / s2	3 x 3 x 64 dw	112 x 112 x 64
Conv / s1	1 x 1 x 64 x 128	56 x 56 x 64
Conv dw / s2	3 x 3 x 128 dw	56 x 56 x 128
Conv / s1	1 x 1 x 128 x 128	56 x 56 x 128
Conv dw / s2	3 x 3 x 128 dw	56 x 56 x 128
Conv / s1	1 x 1 x 128 x 256	28 x 28 x 128
Conv dw/s1	3 x 3 x 256 dw	28 x 28 x 256
Conv/s 1	1 x 1 x 256 x 256	28 x 28 x 256
Conv dw /s2	3 x 3 x 256 dw	28 x 28 x 256
Conv / s1	1 x 1 x 256 x 512	14 x 14 x 256
Conv dw /s1	3 x 3 x 512 dw	14 x 14 x 512
Conv / s1	1 x 1 x 512 x 512	14 x 14x 512
Conv dw / s2	3 x 3 x 512 dw	14 x 14 x 512
Conv / s1	1 x 1 x 512 x 1024	7 x 7 x 512
Conv dw /s2	3 x 3 x 1024 dw	7 x 7 x 1024
Conv / s1	1 x 1 x 1024 x 1024	7 x 7 x 1024
Avg Pool / s1	Pool 7 x 7	7 x 7 x 1024
FC / s1	1021 x 5	1 x 1 x 1024
Softmax / s1	Classifier	1 x 1 x 5

2.2 Alur Penelitian

Alur penelitian umumnya berisi tentang masukan, *proses* dan keluaran dari penelitian. Adapun tahapannya dibagi menjadi enam tahap sebagai berikut:

1. Pengumpulan Data

Pada tahapan pengumpulan data yang perlu di siapkan yaitu *dataset*, *dataset* yang digunakan berupa gambar atau citra yang diambil dari data yang sudah tersedia pada penelitian sebelumnya [5] dan data mentah yang direkam dari *CCTV* jalan tol, data diambil melalui rekaman *CCTV* yang berada di beberapa jalan tol balmera dan medan-binjai.

2. Pengelompokan data

Setelah data dikumpulkan, data akan dikelompokkan berdasarkan jenisnya atau kelasnya, seperti mobil, truk atau bus, truk roda 6, truk roda 8 dan truk roda10. Adapun pengelompokan data ini disajikan pada tabel 3.

Tabel 3. Pengelompokan data

No	Dataset	Jumlah Data
1.	Mobil	1009
2.	Truk dan bus roda 4	563
3.	Truk roda 6	285
4.	Truk roda 8	219
5.	Truk roda 10	28

3. Pre-processing data

Tahapan *pre-prosesing* data, tahapan ini merupakan tahap pengolahan citra dengan mengubah ukuran citra mobil menjadi ukuran yang sama bertujuan untuk menghasilkan citra yang baik.

4. Pembagian data

Selanjutnya dilakukan pembagian data menjadi 2 bagian yaitu data latih dan data uji, Proses data latih yang merupakan proses untuk melatih jaringan saraf tiruan, kemudian sistem membaca data yang di input dan melakukan preprosesing serta ekstraksi fitur untuk mengambil fitur yang akan digunakan sebagai data input, kemudian dilakukan konfigurasi *existing cnn*.

5. Training *CNN* data latih

Training CNN dengan data latih, tahap ini dilakukan proses *train* kembali data latih untuk mendapatkan hasil yang lebih baik, setelah di *tuning CNN* dengan mengganti output *fully connected* terakhir dengan 5 (lima) kelas. Data uji digunakan untuk data validasi sebagai mengukur akurasi saat proses pelatihan.


6. Hasil training dan *validation existing CNN*

Pada tahap selanjutnya akan menampilkan hasil *training* dan *validation existing cnn* dengan menunjukkan berapa persen tingkat akurasi untuk mengenali data yang di *input* dan hasil keluarannya mampu mengenali atau mendeteksi golongan jenis mobil. Jika akurasi sesuai maka proses akurasi *existing CNN* akan selesai, jika tingkat akurasi tidak sesuai maka proses akan kembali ke *konfigurasi existing CNN*.

3. HASIL DAN PEMBAHASAN


3.1 Pelatihan *Existing CNN*

Data mobil dan truk yang akan dilatih disimpan didalam folder data latih. Proses pelatihan dilakukan untuk melatih data yang telah dimasukkan, data gambar tersebut dilatih untuk mendapatkan bobot pembelajaran yang akan digunakan dalam proses deteksi gambar pada tahap pengujian, seperti pada gambar 2 dan gambar 3.



Gambar 2. Grafik akurasi dan loss *Alexnet*

Hasil dari pelatihan jaringan *Alexnet* dengan *epoch* 10 memiliki iterasi 1470 dengan iterasi *epochnya* 147. Waktu yang dibutuhkan untuk proses pelatihan jaringan yaitu 51 menit 5 detik, dengan banyaknya data gambar yang dilatih sebanyak 2104 citra berupa Mobil dan juga truk. Proses pelatihan jaringan *Alexnet* yang digunakan kali ini menghasilkan akurasi sebesar 92,71%.

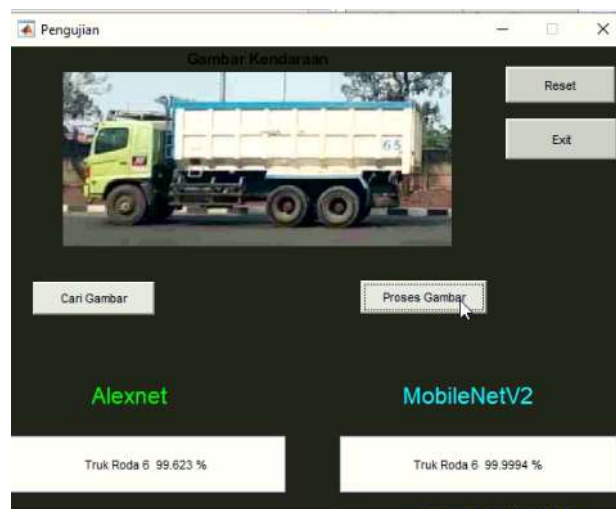


Gambar 3. Grafik akurasi dan loss *MobileNetV2*

Hasil dari pelatihan jaringan *Mobilenet V2* dengan *epoch* 10 memiliki iterasi 1470 dengan iterasi *epochnya* 147, seperti terlihat pada Gambar 8. Waktu yang dibutuhkan untuk proses pelatihan jaringan yaitu 54 menit 1 detik, dengan banyaknya data gambar yang dilatih sebanyak 2104 citra berupa Mobil dan juga truk. Proses pelatihan jaringan *Mobilenet V2* yang digunakan kali ini menghasilkan akurasi sebesar 93,98%.

3.2 Pengujian Sistem






Proses Pengujian dilakukan untuk mengetahui kerja jaringan. Pengujian dilakukan terhadap data uji. Dari hasil pengujian dapat dinilai kemampuan jaringan dalam mengenali data yang telah dimasukkan. Gambar 4 merupakan hasil pengujian sistem.



Gambar 4 Tampilan hasil proses

Pada Gambar 4 menampilkan citra yang diuji berhasil mengenali kelas dari kendaraan dan mendapatkan hasil akurasi yang bagus. Sebagai contoh ditampilkan beberapa pengujian terhadap citra uji mewakili setiap kelas yang disajikan pada Tabel 4.

Tabel 4 Pengujian jenis dan tingkat akurasi jenis mobil

Gambar	Kelas Gambar	<i>AlexNet</i>	<i>MobileNetV2</i>
		Akurasi	
	Mobil	99,98%	99,97%
	Truk dan Bus Roda 4	99,81%	99,61%
	Truk Roda 6	99,62%	99,99%
	Truk Roda 8	99,29%	99,47%
	Truk Roda 10	73,75%	94,35%
Rata-rata akurasi		94,48%	98,68%

3.3 Pengujian Terhadap Kombinasi Dataset

Dataset sangat pengaruh terhadap keberhasilan klasifikasi jenis kendaraan. Pembagian data latih dan data uji dilakukan untuk mendapatkan hasil yang terbaik. Dataset seluruhnya digabung dan dibagi secara acak. Sebagian data menjadi data latih dan sebagian lainnya sebagai data uji. Berikut pembagian dataset disajikan pada Tabel 5.

Tabel 5 Hasil akurasi dari perbandingan data

Perbandingan Data	<i>Alexnet</i>	<i>MobileNetV2</i>
50:50	92,52 %	92,95%
60:40	90,62%	92,64%

70:30	91,92%	95,40%
80:20	93,13%	94,55%
90:10	93,24%	95,71%

Pada Tabel 5 dapat dilihat data 50:50 artinya 50% data latih dan 50% data uji. Semua data dilatih dan diuji dengan kedua *existing CNN* dengan menggunakan epoch 8. Terlihat bahwa pembagian dataset 90% data latih dan 10% data uji menunjukan akurasi terbaik. Selanjutnya, untuk meningkatkan akurasi, epoch pelatihan dinaikan. Pengaruh epoch terhadap pembagian dataset 90:10 disajikan pada tabel 6.

Tabel 6 Hasil akurasi dengan meningkatkan epoch

Epoch	Alexnet	MobilenetV2
5	90,00%	93,81%
10	93,33%	92,86%
15	91,43%	94,29%
20	93,81%	96,19%

Setelah dilakukan pelatihan ulang dari epoch yang berbeda, hasil terbaik yang didapatkan dengan epoch yang maksimal yaitu epoch 20, *alexnet* dengan akurasi 93,81% dan *mobilenetv2* dengan akurasi 96,91%.

4. KESIMPULAN

Tingkat akurasi MobileNetV2 lebih baik dari Alexnet dalam klasifikasi jenis kendaraan. Alexnet memiliki akurasi 93,81 dan 96,19% yang lebih unggul dari penelitian sebelumnya yaitu 73% dengan mini VGGNet. Pada penelitian ini juga diungkap bahwa banyaknya dataset dan epoch mempengaruhi tingkat akurasi, semakin besar dataset latih dan semakin banyak epoch maka tingkat akurasi semakin tinggi. Diharapkan penelitian ini dapat diterapkan pada GTO di Indonesia dan dapat ditingkatkan kecepatan klasifikasi pada penelitian yang akan datang.

REFERENCES

- [1] I. BPS, "www.bps.go.id Pada tanggal 24 Mei 2021," 2019. <https://www.bps.go.id/indicator/17/57/1/jumlah-kendaraan-bermotor.html>.
- [2] L. S. Hsb, P. Hariani, and J. S. Hsb, "City Smart Transportation Sebagai Strategi Medan Menuju Smart City," *J. Pembang. Perkota.*, vol. 5, no. 2, pp. 50–58, 2017.
- [3] W. G. Triatmojo, "Begini Cara Gerbang Tol Mendeteksi Jenis Dan Golongan Kendaraan," *widodogroho.com*, 2019. <https://www.widodogroho.com/2019/08/begini-cara-gerbang-tol-mendeteksi.html> (accessed Oct. 25, 2021).
- [4] S. Rahman, M. Ramli, F. Arnia, A. Sembiring, and R. Muharrar, "Convolutional Neural Network Customization for Parking Occupancy Detection," in *2020 International Conference on Electrical Engineering and Informatics (ICELTICs)*, 2020, pp. 1–6.
- [5] W. Swastika, M. F. Ariyanto, H. Setiawan, and P. L. T. Irawan, "Appropriate CNN Architecture and Optimizer for Vehicle Type Classification System on the Toll Road," in *Journal of Physics: Conference Series*, 2019, vol. 1196, no. 1, p. 12044.
- [6] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 4510–4520.
- [7] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Adv. Neural Inf. Process. Syst.*, vol. 25, pp. 1097–1105, 2012.
- [8] W. Fajariyah, "Penyelesaian wanprestasi pada perjanjian sewa-menyewa convolutional mobil di rental AR Malang tinjauan Kompilasi Hukum Ekonomi Syariah." Universitas Islam Negeri Maulana Malik Ibrahim, 2014.
- [9] A. Damuri, R. Anagora, G. Hendratna, and A. S. Putra, "Konsep Kota Pintar Yang Diterapkan Pada Sistem Gardu Tol Otomatis (Gto)," *IKRA-ITH Inform. J. Komput. dan Inform.*, vol. 4, no. 3, pp. 47–56, 2020.
- [10] W. Sugianto, Y. Kristian, and E. R. Setyaningsih, "Estimasi Arah Tatapan Mata Menggunakan Ensemble Convolutional Neural Network," *Teknika*, vol. 7, no. 2, pp. 94–101, 2018.
- [11] T. Nurhikmat, "Implementasi Deep Learning Untuk Image Classification Menggunakan Algoritma Convolutional Neural Network (CNN) Pada Citra Wayang Golek," 2018.
- [12] G. Aurélien, "Hands-on machine learning with scikit-learn & tensorflow," *Geron Aurélien*, 2017.
- [13] I. Putra, "Klasifikasi citra menggunakan convolutional neural network (CNN) pada caltech 101." Institut Teknologi Sepuluh Nopember, 2016.
- [14] A. G. Howard *et al.*, "MobileNets: Efficient convolutional neural networks for mobile vision applications," *arXiv*, 2017.



-
- [15] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep neural networks. *Advances in neural information processing systems*. 2012;25.