

***ECO-FRIENDLY MOBILENET ARCHITECTURE
DENGAN CONVOLUTIONAL NEURAL NETWORKS
SEBAGAI PENGENAL CITRA PADA PERANGKAT
MOBILE DAN PERANGKAT TERTANAM***

TESIS

**Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Magister**



Oleh

**Barlian Khasoggi
09042621721002**

**PROGRAM STUDI MAGISTER TEKNIK INFORMATIKA
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
2018**

LEMBAR PENGESAHAN

***ECO-FRIENDLY MOBILENET ARCHITECTURE
DENGAN CONVOLUTIONAL NEURAL NETWORKS
SEBAGAI PENGENAL CITRA PADA PERANGKAT
MOBILE DAN PERANGKAT TERTANAM***

TESIS

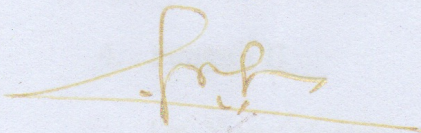
**Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Magister**

Oleh :

**Barlian Khasoggi
09042621721002**

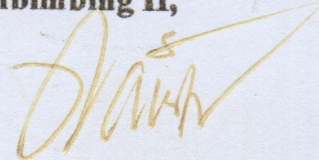
Palembang, Desember 2018

Pembimbing I,



**Dr. Ermatita, M.Kom.
NIP. 196709132006042001**

Pembimbing II,



**Samsuryadi, M.Kom., Ph.D.
NIP. 197102041997021003**

**Mengetahui,
Koordinator Prodi Magister Teknik Informatika**



**Dr. Ir. Sukemi, M.T.
NIP. 196612032006041001**

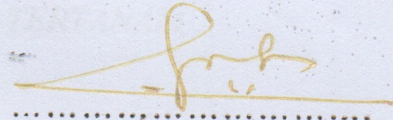
HALAMAN PERSETUJUAN

Pada hari rabu tanggal 19 Desember 2018 telah dilaksanakan ujian sidang tesis oleh Magister Teknik Informatika Fakultas Ilmu Komputer Universitas Sriwijaya.

N a m a : Barlian Khasoggi
N I M : 09042621721002
Judul : *ECO-FRIENDLY MOBILENET ARCHITECTURE DENGAN CONVOLUTIONAL NEURAL NETWORKS SEBAGAI PENGENAL CITRA PADA PERANGKAT MOBILE DAN PERANGKAT TERTANAM*

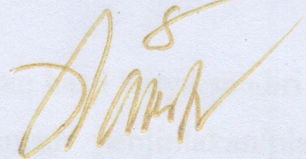
1. Pembimbing I

Dr. Ermatita, M.Kom.
NIP. 196709132006042001



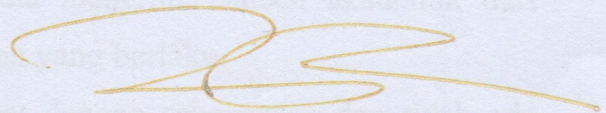
2. Pembimbing II

Samsuryadi, M.Kom., Ph.D.
NIP. 197102041997021003



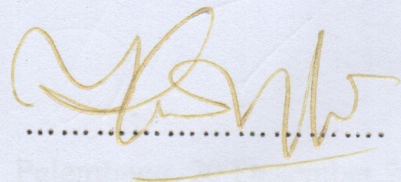
3. Penguji I

Dr. Ir. Sukemi, M.T.
NIP. 196612032006041001

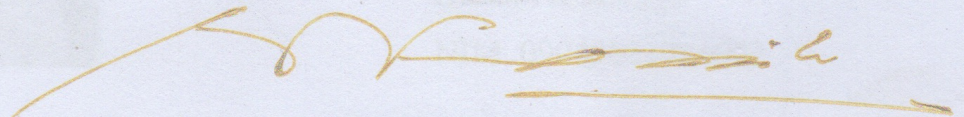


4. Penguji II

Dr. Yusuf Hartono, M.Sc.
NIP. 196411161990031002



**Mengetahui,
Koordinator Prodi Magister Teknik
Informatika**



Dr. Ir. Sukemi, M.T.
NIP. 196612032006041001

LEMBAR PERNYATAAN

Yang bertanda tangan di bawah ini :

Nama : Barlian Khasoggi
NIM : 09042621721002
Program Studi : Magister Teknik Informatika
Judul Tesis : *ECO-FRIENDLY MOBILENET ARCHITECTURE
DENGAN CONVOLUTIONAL NEURAL NETWORKS
SEBAGAI PENGENAL CITRA PADA PERANGKAT
MOBILE DAN PERANGKAT TERTANAM*

Hasil Pengecekan Software iThenticate/Turnitin : 15 %

Menyatakan bahwa laporan tesis saya merupakan hasil karya sendiri dan bukan hasil penjiplakan/plagiat. Apabila ditemukan unsur penjiplakan/plagiat dalam laporan tesis ini, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya sesuai dengan ketentuan yang berlaku.

Demikian, pernyataan ini saya buat dengan sebenarnya dan tidak ada paksaan oleh siapapun.



Palembang, 20 Desember 2018



Barlian Khasoggi

NIM. 09042621721002

Motto dan Persembahan

Jika ingin jadi yang terbaik, maka belajarliah dari yang terbaik.

Knowledge is something, Act is everything, Knowledge plus Act is perfect thing.

Persembahan untuk:

1. Allah SWT.
2. Ibunda dan Ayahanda tercinta.
3. Istri tercinta.
4. Anak-anak tercinta, Fatimah Azzahra dan Nabila Azzahra.
5. Semua saudara/teman/kerabat/adik/kakak yang membaca dan/atau menjadikan tugas akhir ini sebagai referensi.

KATA PENGANTAR

Puji syukur penulis panjatkan atas kehadiran Allah SWT, karena atas Berkat dan Rahmat-Nya penulis dapat melaksanakan dan menyelesaikan Tesis yang berjudul “*ECO-FRIENDLY MOBILENET ARCHITECTURE DENGAN CONVOLUTIONAL NEURAL NETWORKS SEBAGAI PENGENAL CITRA PADA PERANGKAT MOBILE DAN PERANGKAT TERTANAM*”.

Dalam melaksanakan dan menyusun Tesis ini, penulis mengucapkan banyak terimakasih kepada :

1. Ibunda dan Ayahanda tercinta.
2. Istri dan anak-anak tercinta.
3. Ibu Ermatita selaku dosen pembimbing I.
4. Bapak Samsuryadi selaku dosen pembimbing II.
5. Bapak Jaidan Jauhari selaku Dekan Fakultas Ilmu Komputer Universitas Sriwijaya.
6. Bapak Sukemi selaku Koordinator Prodi Magister Teknik Informatika.
7. Seluruh teman-teman Magister Teknik Informatika Universitas Sriwijaya.

Penulis menyadari bahwa tesis ini masih belum sempurna, oleh sebab itu penulis sangat mengharapkan kritik dan saran yang bersifat membangun demi menyempurnakan tesis ini. Penulis berharap semoga Tesis ini dapat bermanfaat bagi kita semua.

Palembang, 20 Desember 2018

Barlian Khasoggi
NIM. 09042621721002

ECO-FRIENDLY MOBILENET ARCHITECTURE
DENGAN CONVOLUTIONAL NEURAL NETWORKS
SEBAGAI PENGENAL CITRA PADA PERANGKAT
MOBILE DAN PERANGKAT TERTANAM

Oleh

Barlian Khasoggi
09042621721002

ABSTRAK

Proses pengenalan citra menggunakan jutaan parameter dan data latih yang banyak serta komputasi tinggi dengan daya yang besar. *Machine Learning* telah mengubah paradigma komputasi, dari perhitungan kompleks dengan daya komputasi tinggi hingga teknologi ramah lingkungan yang efisien dan dapat memenuhi kebutuhan sehari-hari. Untuk mendapatkan model pelatihan yang baik, banyak studi menggunakan dataset dalam jumlah besar. Kompleksitas pada dataset yang besar membutuhkan perangkat yang besar dan membutuhkan daya komputasi yang tinggi. Oleh karena itu sumber daya komputasi yang besar tidak memiliki fleksibilitas yang tinggi terhadap kecenderungan interaksi manusia yang lebih mengedepankan efisiensi dan efektifitas dari computer vision. Penelitian ini menggunakan metode *Convolutional Neural Networks* (CNN) dengan arsitektur MobileNet untuk pengenalan citra pada perangkat *mobile* dan perangkat tertanam. Dilakukan pelatihan model dengan sumber daya yang terbatas dengan CPU berbasis ARM dan bekerja dengan jumlah data latih yang moderat (ribuan citra berlabel). Hasil penelitian ini menunjukkan bahwa arsitektur MobileNet v1 dapat melakukan klasifikasi citra dataset caltech101 dengan tingkat akurasi 92.4% menggunakan perangkat ms8pro. Dengan tingkat akurasi dan efisiensi sumber daya yang digunakan, diharapkan arsitektur MobileNet dapat mengubah paradigma *machine learning* sehingga memiliki tingkat fleksibilitas yang tinggi terhadap interaksi manusia yang lebih mengedepankan efisiensi dan efektifitas dari computer vision.

ECO-FRIENDLY MOBILENET ARCHITECTURE WITH CONVOLUTIONAL NEURAL NETWORKS AS IMAGES RECOGNITION ON MOBILE DEVICE AND EMBEDDED DEVICE

By :

**Barlian Khasoggi
09042621721002**

ABSTRACT

The introduction of a modern image recognition that has millions of parameters and requires a lot of training data as well as high computing power that is hungry for energy consumption so it becomes inefficient in everyday use. Machine Learning has changed the computing paradigm, from complex calculations that require high computational power to environmentally friendly technologies that can efficiently meet daily needs. To get a good training model, many studies use large numbers of datasets. However, the complexity of large datasets requires large devices and requires high computing power. Therefore large computational resources do not have high flexibility towards the tendency of human interaction which prioritizes the efficiency and effectiveness of computer vision. This study uses the Convolutional Neural Networks (CNN) method with MobileNet architecture for image recognition on mobile devices and embedded devices with limited resources with ARM-based CPUs and works with a moderate amount of training data (thousands of labeled images). As a result, the MobileNet v1 architecture on the ms8pro device can classify the caltech101 dataset with an accuracy rate 92.4%. With the level of accuracy and efficiency of the resources used, it is expected that MobileNet's architecture can change the machine learning paradigm so that it has a high degree of flexibility towards the tendency of human interaction that prioritizes the efficiency and effectiveness of computer vision.

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
HALAMAN PENGESAHAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PERNYATAAN	iv
KATA PENGANTAR	v
ABSTRAK	vi
ABSTRACT	vii
DAFTAR ISI	viii
DAFTAR GAMBAR	x
DAFTAR TABEL	xii
BAB I. PENDAHULUAN	
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	2
1.3. Tujuan Penelitian.....	2
1.4. Manfaat Penelitian.....	3
1.5. Batasan Masalah.....	3
BAB II. TINJAUAN PUSTAKA	
2.1 <i>Convolutional Neural Networks</i>	4
2.1.1. <i>Deep Neural Networks</i>	8
2.1.2. <i>AlexNet</i>	8
2.1.3. <i>ZFNet</i>	10
2.1.4. <i>GoogLeNet</i>	11
2.1.5. <i>Microsoft ResNet</i>	14
2.1.6. <i>DenseNet</i>	15
2.1.7. <i>SENetworks</i>	15
2.2 <i>Arsitektur Mobile Net</i>	16
2.2.1. <i>Depthwise Separable Convolution</i>	17
2.2.2. <i>Struktur Network dan Training</i>	21
2.3 <i>Eco-friendly</i>	23
2.4 <i>Perangkat Mobile</i>	23
2.5 <i>Perangkat Tertanam</i>	23
BAB III. METODE PENELITIAN	
3.1. Sumber dan Jenis Data Penelitian.....	24
3.2. Metodologi Penelitian.....	24
3.2.1. <i>Feature Extraction</i>	25
3.2.1.1. <i>Convolutional Layer</i>	25
3.2.1.2. <i>Stride dan Padding</i>	25
3.2.1.3. <i>Pooling Layers</i>	27
3.2.1.4. <i>ReLU (Rectified Linear Units) Layers</i>	28
3.2.1.5. <i>Dropout Layers</i>	29
3.2.2. <i>Fully-Connected Layer (MLP)</i>	29
3.2.3. <i>Transfer Learning</i>	30
BAB IV. HASIL DAN PEMBAHASAN	
4.1. Pelatihan Model.....	31
4.1.1. <i>MobileNet</i>	31

4.1.2. SSD(<i>Single Shot Multibox Detector</i>) Mobilenet v1.....	37
4.2. Pengujian Model Pada Perangkat <i>Mobile</i>	40
4.2.1. Klasifikasi Citra Pada Perangkat <i>Mobile</i>	40
4.2.2. Deteksi Objek Pada Perangkat <i>Mobile</i>	45
4.3. Pengujian Model Pada Perangkat Tertanam.....	49
4.3.1. Klasifikasi Citra Pada Perangkat Tertanam.....	49
BAB V. KESIMPULAN DAN SARAN	
5.1. Kesimpulan.....	49
5.2. Saran.....	49
DAFTAR PUSTAKA	53

DAFTAR GAMBAR

	Halaman
Gambar 2.1. Ilustrasi neuron dan model matematisnya.....	5
Gambar 2.2. <i>Convolutional Neural Networks</i>	6
Gambar 2.3. 3 Dimensi CNNs (<i>width, height</i> dan <i>depth</i>).....	6
Gambar 2.4. <i>Multi Layer Perceptron (MLP)</i>	7
Gambar 2.5. Arsitektur AlexNet.....	8
Gambar 2.6. Arsitektur ZFNet	11
Gambar 2.7. Arsitektur GoogleLeNet.....	12
Gambar 2.8. <i>Inception Module</i>	12
Gambar 2.9. <i>Inception Module dengan 1x1 convolutions</i>	13
Gambar 2.10. <i>Residual learning: a building block</i>	14
Gambar 2.11. Blok <i>SE(Squeeze-and-Excitation)</i>	16
Gambar 2.12. <i>Standard Convolutional Filters</i>).....	20
Gambar 2.13. <i>Depthwise Filters</i>	20
Gambar 2.14. 1×1 <i>Convolutional Filters (Pointwise Convolution)</i> dalam konteks <i>Depthwise Separable Convolution</i>	20
Gambar 2.15. Kiri: Standar <i>convolutional layer</i> dengan <i>batchnorm (BN)</i> and <i>ReLU</i> . Kanan: <i>Depthwise Separable convolutions</i> dengan <i>Depthwise</i> dan <i>Pointwise layers</i> diikuti <i>batchnorm</i> dan <i>ReLU</i>	22
Gambar 3.1. (a): <i>7x7 input</i> dengan <i>1 stride</i> , (b): <i>5x5 output</i>	26
Gambar 3.2. (a): <i>7x7 input</i> dengan <i>2 stride</i> , (b): <i>3x3 output</i>	26
Gambar 3.3. <i>Max Pooling</i> , (a) <i>input (4x4)</i> dan (b) <i>output (2x2)</i>	28
Gambar 3.4. <i>Rectified Linear Units</i>	28
Gambar 4.1. Proses Pelatihan Model Mobilenet	32
Gambar 4.2. Grafik Akurasi	32
Gambar 4.3. Grafik <i>Loss Function</i> Model Mobilenet	33
Gambar 4.4. Histogram <i>update bobot final layer's</i>	33
Gambar 4.4. Histogram <i>update bobot final layer's</i>	33
Gambar 4.5. Proses Pelatihan Model Ssd Mobilenet v1.....	38
Gambar 4.6. Grafik <i>Loss Function</i> Model Ssd Mobilenet v1	39
Gambar 4.7. Histogram <i>Biases</i> Model Ssd Mobilenet v1	39
Gambar 4.8. Klasifikasi citra dengan label “butterfly”	40
Gambar 4.9. Klasifikasi citra dengan label “bass”	41
Gambar 4.10. Klasifikasi citra dengan label “motorbikes”	41
Gambar 4.11. Klasifikasi citra dengan label “revolver”	42
Gambar 4.12. Klasifikasi citra dengan label “barrel”	42
Gambar 4.13. Klasifikasi citra dengan label “brain”	43
Gambar 4.14. Klasifikasi citra dengan label “laptop”	43
Gambar 4.15. Klasifikasi citra dengan label “cellphone”.....	44
Gambar 4.16. Klasifikasi citra dengan label “cup”	44
Gambar 4.17. Deteksi objek dengan label “kursi”.....	45
Gambar 4.18. Deteksi objek dengan label “stapler”	45
Gambar 4.19. Deteksi objek dengan label “gunting”	46
Gambar 4.20. Deteksi objek dengan label “laptop”.....	46
Gambar 4.21. Deteksi objek dengan label “wajah”	47
Gambar 4.22. Deteksi objek dengan label “wajah” <i>multi box</i>	47

Gambar 4.23. Klasifikasi citra pada perangkat tertanam.....47

DAFTAR TABEL

	Halaman
Tabel 2.1 Arsitektur <i>MobileNet</i>	17
Tabel 2.2 Penggunaan <i>resource</i> pada masing-masing <i>layers</i>	19
Tabel 4.1 Hasil Pengujian Model Arsitektur Mobilenet.....	34
Tabel 4.2 Klasifikasi dataset caltech101 dengan model mobilenet v1	3

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Convolutional neural networks (CNNs) merupakan arsitektur *state of the art* saat ini dan banyak digunakan sebagai solusi klasifikasi citra (Krizhevsky, Sutskever, dan Hinton, 2012). CNNs memberikan sumbangan penting bagi kemajuan besar dalam visi komputer, terutama dalam aplikasi dan kegunaan sehari-hari seperti *self driving car*, robotika, drone, diagnosa medis, dan perawatan untuk gangguan penglihatan.

Pelatihan model *Convolutional Neural Networks (CNNs)* (LeCun, Huang dan Bottou, 2004), (Pinto *et al*, 2009) membutuhkan model dengan kapasitas pembelajaran yang besar sehingga membutuhkan perangkat yang besar dan membutuhkan daya komputasi yang tinggi. Oleh karena itu sumber daya komputasi yang besar tidak dapat memenuhi kebutuhan untuk menyelesaikan permasalahan pengenalan citra di rumah ataupun kantor dengan daya listrik yang rendah. Dalam pelatihannya, perangkat harus terhubung ke sumber daya komputasi yang besar melalui jaringan internet, sehingga tidak dapat menyelesaikan permasalahan untuk daerah yang belum terjangkau internet (*blank spot area*). Diharapkan model yang akan dikembangkan dapat menjadi solusi guna menyelesaikan permasalahan yang ada dengan mengedepankan efisiensi dan efektifitas dari visi komputer serta dapat memenuhi kriteria *eco-friendly* yang mencakup efisiensi sumber daya, mencegah polusi (udara, air dan tanah) serta hemat energi.

CNN melakukan filter terhadap rangkaian data mentah (*raw pixel*) dari suatu citra untuk mengekstrak dan mempelajari fitur dalam tingkat yang lebih mendalam, yang kemudian dapat digunakan oleh model untuk klasifikasi (Szegedy *et al*, 2015). Untuk meningkatkan performa *network*, banyak penelitian menggunakan dataset yang lebih besar, model learning yang lebih baik, serta teknik yang lebih baik untuk mencegah *overfitting* (Donahue *et al*, 2013). Namun penelitian tersebut menggunakan daya komputasi yang tinggi sehingga pelatihan

yang dilakukan akan memerlukan sumberdaya yang besar. Pada penelitian yang sudah dilakukan dengan dataset citra berukuran relatif kecil dengan label yang terdiri dari puluhan ribu hingga jutaan citra seperti DeCAF (Donahue *et al*, 2013), NORB (LeCun, Huang dan Bottou, 2004), Caltech-101/256 (Fei-Fei, Fergus dan Perona, 2007), dan CIFAR-10/100 (Krizhevsky, 2009) dapat menyelesaikan tugas-tugas sederhana dengan hasil pengenalan citra yang baik, terutama jika ditambah dengan transformasi *label-preserving*. Salah satu hasil penelitian yang sangat baik dengan tingkat kesalahan paling rendah saat ini adalah pada tugas pengenalan digit MNIST (<0,3%) mendekati kinerja manusia (Cires, Meier dan Schmidhuber, 2012). Hasil dari penelitian ini diharapkan dapat menjadi solusi pengenalan citra yang memiliki tingkat fleksibilitas yang tinggi terhadap interaksi manusia yang lebih mengedepankan efisiensi dan efektifitas dari visi komputer.

1.2. Rumusan Masalah

Pelatihan CNN dengan sumber daya komputasi yang besar tidak dapat menyelesaikan masalah pengenalan citra di rumah ataupun kantor dengan daya listrik yang rendah. Pada proses pelatihan, perangkat harus terhubung ke sumber daya komputasi yang besar melalui jaringan internet. Dari masalah tersebut, pertanyaan penelitian ini adalah :

1. Apakah model arsitektur mobilenet dapat berjalan pada perangkat yang memiliki sumber daya yang terbatas dengan CPU berbasis ARM ?
2. Apakah model arsitektur CNN dapat berjalan pada perangkat dengan daya yang rendah ?
3. Apakah model arsitektur dapat berjalan pada *Local Area Network* (LAN) ?

1.3. Tujuan Penelitian

Tujuan penelitian ini adalah :

1. Mengembangkan suatu model baru dengan arsitektur CNN sebagai pengenalan citra yang dapat berjalan pada perangkat dengan CPU berbasis ARM;
2. Mengembangkan suatu model baru yang dapat dilatih dengan perangkat yang dapat berjalan dengan daya listrik yang rendah;

3. Mengembangkan suatu model baru yang dapat dilatih dalam *local area network* (LAN).

1.4. Manfaat Penelitian

Penelitian ini dapat memberikan manfaat sebagai berikut :

1. Model dapat berjalan dengan sumber daya yang terbatas dengan CPU berbasis ARM dan bekerja dengan jumlah data latih yang moderat (ribuan citra berlabel);
2. Model bermanfaat untuk menyelesaikan masalah pengenalan citra pada rumah ataupun kantor dengan daya listrik yang rendah;
3. Model yang diciptakan dapat berjalan dalam *local area network* (LAN) sehingga dapat menyelesaikan permasalahan untuk daerah yang belum terjangkau internet (*blank spot area*).

1.4. Batasan Masalah

Batasan masalah pada penelitian ini adalah terbatas pada pengembangan suatu model arsitektur MobileNet agar dapat dilatih pada perangkat berbasis ARM dengan daya listrik yang rendah dan menggunakan dataset Caltech101 yang terdiri dari 8,677 citra digital. Pembuatan model dan *training* data menggunakan bahasa pemrograman *python*. Perangkat yang digunakan yaitu *Raspberry PI3* dan *Android device box*. Model yang telah dibuat akan dilakukan *transfer learning* ke perangkat android. Untuk melakukan testing, dijalankan aplikasi android yang dibuat dengan bahasa pemrograman JAVA dengan *API 24 (Nougat)*.

DAFTAR PUSTAKA

- C.Szegedy, V.Vanhoucke, S.Ioffe, J.Shlens, and Z.Wojna. Rethinking the inception architecture for computer vision. arXiv preprint arXiv:1512.00567, 2015.
- Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich. Going Deeper with Convolutions. arXiv preprint arXiv:1409.4842, 2014.
- D. Cireş an, U. Meier, and J. Schmidhuber. Multicolumn deep neural networks for image classification. Arxiv preprint arXiv:1202.2745, 2012.
- F.Chollet. Xception: Deep learning with depthwise separable convolutions. arXiv preprint arXiv:1610.02357v2, 2016.
- F.N.Iandola, M. W. Moskewicz, K. Ashraf, S. Han, W. J. Dally, and K. Keutzer. Squeezenet: Alexnet level accuracy with 50x fewer parameters and 1mb model size. arXiv preprint arXiv:1602.07360, 2016.
- G.Griffin, A. Holub, and P. Perona. Caltech-256 object category dataset. Technical Report 7694, California Institute of Technology, 2007.
- Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger. Densely Connected Convolutional Networks. arXiv preprint arXiv:1608.06993, 2016.
- H.Lee, R. Grosse, R. Ranganath, and A.Y. Ng. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations. In Proceedings of the 26th Annual International Conference on Machine Learning, pages 609–616. ACM, 2009
- J.Jin,A.Dundar, E.Culurciello. Flattened convolutional neural networks for feedforward acceleration. arXiv preprint arXiv:1412.5474, 2014.
- Jeff Donahue, Yangqing Jia, Oriol Vinyals, Judy Hoffman, Ning Zhang, Eric Tzeng, Trevor Darrell. DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition. Arxiv preprint arXiv: 1310.1531v1, 2013
- Jie Hu, Li Shen, Gang Sun. Squeeze-and-Excitation Networks. arXiv preprint arXiv:1709.01507, 2017.
- K. Simonyan and A. Zisserman. Very deep convolutional networks for large scale image recognition. arXiv preprint arXiv:1409.1556, 2014.
- Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. Deep Residual Learning for Image Recognition. arXiv preprint arXiv:1512.03385, 2015.
- Karen Simonyan, Andrew Zisserman. Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint arXiv:1409.1556, 2014.
- Kesha A. Pane, Suryono. Kajian Prinsip *Eco-friendly Architecture*. Jurnal Arsitektur UNSRAT Manado. 2012
- Krizhevsky A., Sutskever, I., and Hinton, G. E. ImageNet classification with deep convolutional neural networks. In NIPS, 2012.
- Krizhevsky A.. Convolutional deep belief networks on cifar-10. Unpublished manuscript, 2010.
- Krizhevsky A.. Learning multiple layers of features from tiny images. Master's thesis, Department of Computer Science, University of Toronto, 2009.

- L.Fei-Fei, R. Fergus, and P. Perona. Learning generative visual models from few training examples: An incremental bayesian approach tested on 101 object categories. *Computer Vision and Image Understanding*, 106(1):59–70, 2007.
- L.Sifre. Rigid motion scattering for image classification. PhD thesis, Ph. D. thesis, 2014.
- M.Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, et al. Tensorflow: Large scale machine learning on heterogeneous systems, 2015. Software available from tensorflow.org, 1, 2015.
- M.Guan, W.Weii, B.Ying. A Monitoring System Based on Embedded Internet Technology for Embedded Devices. *International Conference on Computer Science and Software Engineering*. 2008.
- M.Wang, B. Liu, and H. Foroosh. Factorized convolutional neural networks. arXiv preprint arXiv:1608.04337, 2016.
- Matthew D Zeiler, Rob Fergus. Visualizing and Understanding Convolutional Networks. arXiv preprint arXiv:1311.2901, 2013.
- N.Pinto, D. Doukhan, J.J. DiCarlo, and D.D. Cox. A highthroughput screening approach to discovering good forms of biologically inspired visual representation. *PLoS computational biology*, 5(11):e1000579, 2009.
- S.C.Turaga,J.F.Murray,V.Jain,F.Roth,M.Helmstaedter,K.Briggman,W.Denk,andH.S.Seung.Convolutional networks can learn to generate affinity graphs for image segmentation. *Neural Computation*, 22(2):511–538, 2010.
- S.Ioffe and C. Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. arXiv preprint arXiv:1502.03167, 2015.
- Stéfan van der Walt, S. Chris Colbert, Gael Varoquaux. The NumPy array: a structure for efficient numerical computation. arXiv preprint arXiv:1102.1523, 2011.
- T.Tieleman and G. Hinton. Lecture 6.5 rmsprop: Divide the gradient by a running average of its recent magnitude. *COURSERA: Neural Networks for Machine Learning*, 4(2), 2012.
- V.Sindhwani, T. Sainath, and S. Kumar. Structured transforms for small-footprint deep learning. In *Advances in Neural Information Processing Systems*, pages 3088–3096, 2015.
- Y.Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama, and T. Darrell. Caffe: Convolutional architecture for fast feature embedding. arXiv preprint arXiv:1408.5093, 2014.
- Y.Le Cun, B. Boser, J.S. Denker, D. Henderson, R.E. Howard, W. Hubbard, L.D. Jackel, et al. Hand written digit recognition with a backpropagation network. In *Advances in neural information processing systems*, 1990.
- Y.LeCun, F.J. Huang, and L. Bottou. Learning methods for generic object recognition with invariance to pose and lighting. In *Computer Vision and Pattern Recognition*, 2004. *CVPR 2004. Proceedings of the 2004 IEEE Computer Society Conference on*, volume 2, pages II–97. IEEE, 2004.
- Z.Yang, M. Moczulski, M. Denil, N. de Freitas, A. Smola, L. Song, and Z. Wang. Deep fried convnets. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 1476–1483, 2015.