

PENGGUNAAN METODE *DEEP LEARNING EFFICIENTNET-B1* UNTUK MENGENALI SAMPAH ORGANIK DAN SAMPAH ANORGANIK

TUGAS AKHIR

Disusun Sebagai Salah Satu Syarat
Untuk Memperoleh Gelar Sarjana Teknik
Pada Jurusan Teknik Informatika

Oleh

MUHAMMAD KHAIRUNNAS

NIM. 11751101976



UIN SUSKA RIAU

FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SULTAN SYARIF KASIM RIAU
PEKANBARU
2021

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

LEMBAR PERSETUJUAN

PENERAPAN METODE *CONVOLUTIONAL NEURAL NETWORK* DENGAN ARSITEKTUR *EFFICIENNET-B4* UNTUK KLASIFIKASI PENYAKIT PNEUMONIA

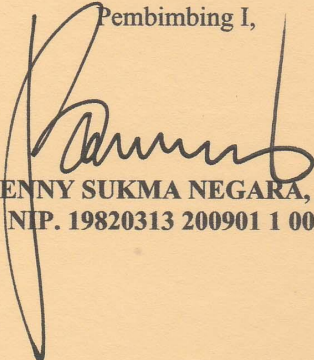
TUGAS AKHIR

Oleh

MUHAMMAD ALWI BASYIR
11750114891

Telah diperiksa dan disetujui sebagai Laporan Tugas Akhir
di Pekanbaru, pada tanggal 20 Desember 2021

Pembimbing I,



BENNY SUKMA NEGARA, S.T., M.T
NIP. 19820313 200901 1 009

Pembimbing II,



SURYA AGUSTIAN, S.T., M.Kom
NIP. 197608302011011003

LEMBAR PENGESAHAN

PENERAPAN METODE *CONVOLUTIONAL NEURAL NETWORK* DENGAN ARSITEKTUR *EFFICIENNET-B4* UNTUK KLASIFIKASI PENYAKIT PNEUMONIA

TUGAS AKHIR

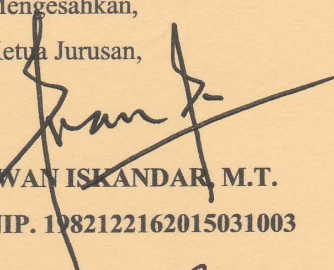
Oleh

MUHAMMAD ALWI BASYIR
11750114891

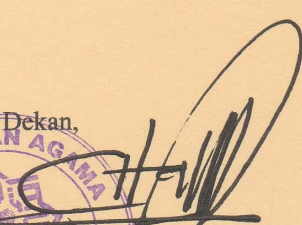
Telah dipertahankan di depan sidang dewan penguji sebagai salah satu syarat untuk memperoleh gelar sarjana Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau di Pekanbaru, pada tanggal 20 Desember 2021

Pekanbaru,

Mengesahkan,
Ketua Jurusan,

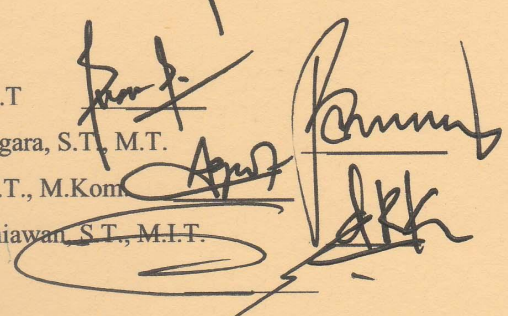

IWAN ISKANDAR, M.T.
NIP. 1982122162015031003

Dekan,


DR. HARTONO, M. Pd.
NIP. 19660604 199203 1 004

DEWAN PENGUJI

Ketua : Iwan Iskandar, M.T
Pembimbing I : Benny Sukma Negara, S.T., M.T.
Pembimbing II : Surya Agustian S.T., M.Kom
Penguji I : Dr. Rahmad Kurniawan, S.T., M.I.T.
Penguji II : Yusra, M.T



Hak Cipta Diindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Lampiran Surat :
Nomor : Nomor 25/2021
Tanggal : 10 September 2021

SURAT PERNYATAAN

Saya yang bertandatangan di bawah ini:

Nama : MUHAMMAD KHAIRUNNAS
NIM : 11751101976
Tempat/Tgl. Lahir : SELATPANJANG/03 MEI 1999
Fakultas/Pascasarjana : SAINS DAN TEKNOLOGI
Prodi : PROGRAM STUDI TEKNIK INFORMATIKA
Judul ~~Disertasi/Thesis/Skripsi/Karya Ilmiah lainnya~~ *:
PENGUNAAN METODE DEEP LEARNING EFFICIENTNET-B1
UNTUK MENGENALI SAMPAH ORGANIK DAN SAMPAH ANORGANIK

Menyatakan dengan sebenar-benarnya bahwa :

1. Penulisan ~~Disertasi/Thesis/Skripsi/Karya Ilmiah lainnya~~ * dengan judul sebagaimana tersebut di atas adalah hasil pemikiran dan penelitian saya sendiri.
2. Semua kutipan pada karya tulis saya ini sudah disebutkan sumbernya.
3. Oleh karena itu ~~Disertasi/Thesis/Skripsi/Karya Ilmiah lainnya~~ * saya ini, saya nyatakan bebas dari plagiat.
4. Apa bila dikemudian hari terbukti terdapat plagiat dalam penulisan ~~Disertasi/Thesis/Skripsi/Karya Ilmiah lainnya~~ * saya tersebut, maka saya bersedia menerima sanksi sesuai peraturan perundang-undangan.

Demikianlah Surat Pernyataan ini saya buat dengan penuh kesadaran dan tanpa paksaan dari pihak manapun juga.

Pekanbaru, 14 Januari 2021
buat pernyataan



Muhammad Khairunnas
NIM : 11751101976

* pilih salah satu sesuai jenis karya tulis

LEMBAR HAK ATAS KEKAYAAN INTELEKTUAL

Tugas Akhir yang tidak diterbitkan ini terdaftar dan tersedia di Perpustakaan Universitas Islam Negeri Sultan Syarif Kasim Riau adalah terbuka untuk umum dengan ketentuan bahwa hak cipta pada penulis. Referensi kepustakaan diperkenankan dicatat, tetapi pengutipan atau ringkasan hanya dapat dilakukan seizin penulis dan harus disertai dengan kebiasaan ilmiah untuk menyebutkan sumbernya.

Penggandaan atau penerbitan sebagian atau seluruh Tugas Akhir ini harus memperoleh izin dari Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau. Perpustakaan yang meminjamkan Tugas Akhir ini untuk anggotanya diharapkan untuk mengisi nama, tanda peminjaman dan tanggal pinjam.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

LEMBAR PERNYATAAN

Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya yang pernah diajukan untuk memperoleh gelar kesarjanaan di suatu Perguruan Tinggi, dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan didalam daftar pustaka.

Pekanbaru, 21 Desember 2021

Yang membuat pernyataan,

MUHAMMAD KHAIRUNNAS

11751101976

UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

LEMBAR PERSEMBAHAN

Alhamdulillahirabbil 'alamin

*Dengan mengucapkan syukur pada Allah subhanallah wa ta'ala,
telah kuselesaikan Tugas Akhir ini...*

Bismillahirrahmanirrahim..

~Kupersembahkan Tugas Akhir Ku Ini Untuk~

*Kedua Orang Tua Ku Tercinta yang telah berkorban, dan
mendo'akan untuk anaknya...*

Adik Ku Tercinta yang terus memberikan dukungan...

Serta,

Keluarga, Kerabat, sahabat dan Teman-Teman terdekat ku...

UIN SUSKA RIAU

- Hak Cipta Dilindungi Undang-Undang
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
 2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

ABSTRAK

Indonesia selalu muncul masalah lingkungan yang berkaitan dengan sampah. Pada tahun 2020 jumlah sampah di Indonesia mencapai 67,8 juta ton. Salah satu metode pengelolaan sampah yaitu metode *Organic Solid Waste*. *OSW* memiliki kekurangan diantaranya adalah efisiensi yang buruk, biaya yang tinggi, dan memiliki potensi terhadap ancaman kesehatan manusia yang melakukan pemilahan sampah. Untuk membantu hal tersebut perlu dibangun sebuah model yang bisa melakukan klasifikasi jenis sampah secara cepat, dan efisien, salah satu metode yang bisa digunakan yaitu *Convolutional Neural Network* (CNN). CNN memiliki arsitektur yang menjadi *state-of-the-art* yaitu *EfficientNet-B1* merupakan metode yang memiliki efisiensi, dan kinerja yang lebih baik dengan meningkatkan model menggunakan *tuning hyperparameter*. *Tuning hyperparameter* yang digunakan yaitu *learning rate*, *optimizer*, dan fungsi aktivasi. Akurasi tertinggi pada eksperimen 5 dengan *tuning hyperparameter*, menggunakan *split data* 90:10, fungsi aktivasi *Rectified Linear Unit*, *optimizer Adam*, dan *learning rate* 0.01 menghasilkan nilai *F1-Score* 99,68%. Pengujian aplikasi *web* terhadap model terbaik yang telah di-*deployment* berhasil melakukan prediksi terhadap data yang berbeda.

Kata Kunci : *Convolutional*, *EfficientNet-B1*, *F1-Score*, *Hyperparameter Tuning*, Sampah Organik

UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

ABSTRACT

Indonesia always has environmental problems related to waste. In 2020, the amount of waste in Indonesia reaches 67.8 million tons. One of the waste management methods is the Organic Waste method. OSW has drawbacks including poor efficiency, high cost, and the potential threat to human health by sorting waste. To solve that problem, it is necessary to build a model which can classify waste types quickly, and efficiently. One of methods, which can be used, is the Convolutional Neural Network (CNN). CNN has an architecture which becomes a state-of-the-art, namely EfficientNet-B1. That is a method which has efficiency, and better performance by improving the model using hyperparameter tuning. The tuning hyperparameters which are used are learning rate, optimizer, and activation function. The highest accuracy in experiment 5 with hyperparameter tuning, the use of 90:10 data splits, the activation function of Rectified Linear Unit, Adam's optimizer, and 0.01 learning rate resulted in an F1-Score value of 99.68%. Testing the web application against the best deployed model succeeded in making predictions on different data.

Keywords: *Convolutional, EfficientNet-B1, F1-Score, Hyperparameter Tuning, Organic Waste*

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

KATA PENGANTAR

Assalammu'alaikum wa rohmatullohi wa barokatuh.

Alhamdulillah robbil'amin, tak henti-hentinya kami ucapkan kehadiran Allah *Subhanahu wa ta'ala*, yang dengan rahmat dan hidayah-Nya kami mampu menyelesaikan Tugas Akhir ini dengan baik. Tidak lupa bershalawat kepada Nabi dan Rasul-Nya, Nabi Muhammad *Sholallohu 'alaihi wa salam*, yang telah membimbing kita sebagai umatnya menuju jalan kebaikan.

Tugas Akhir ini disusun sebagai salah satu syarat untuk mendapatkan gelar kesarjanaan pada jurusan Teknik Informatika Universitas Islam Negeri Sultan Syarif Kasim Riau. Banyak pihak yang telah membantu penulis dalam penyusunan laporan ini, baik berupa bantuan materi maupun berupa motivasi dan dukungan kepada penulis. Penulis menilai rasa terima kasih terlihat masih kurang jika dibandingkan dengan bantuan yang penulis terima, namun pada kesempatan ini penulis hanya dapat mengucapkan terima kasih kepada:

1. Bapak Prof. Dr. Khairunnas Rajab, M.Ag selaku Rektor Universitas Islam Negeri Sultan Syarif Kasim Riau.
2. Bapak Dr. Drs. Hartono, M.Pd. selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau
3. Bapak Iwan Iskandar, M.T. selaku Ketua Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau
4. Bapak Nazruddin Safaat Harahap, S.T., M.T. selaku Dosen Pembimbing Akademik yang telah memberikan nasehat selama perkuliahan.
5. Bapak Benny Sukma Negara, MT. selaku Dosen Pembimbing I Tugas Akhir yang selalu meluangkan waktu, memberikan ilmu, nasehat, saran, serta sabar membimbing penulis hingga tugas akhir ini selesai.



- Hak Cipta Dilindungi Undang-Undang
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
 2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

- © Hak cipta milik UIN Suska Riau
6. Bapak Surya Agustian, ST, M.Kom. selaku Dosen Pembimbing II Tugas Akhir yang selalu meluangkan waktu, memberikan ilmu, nasehat, saran, serta sabar membimbing penulis hingga tugas akhir ini selesai.
 7. Bapak Dr. Rahmad Kurniawan, S.T., M.I.T. selaku Dosen Penguji I yang telah banyak memberikan saran demi kemajuan dan penyempurnaan dalam pengerjaan tugas akhir ini.
 8. Ibu Eka Pandu Cynthia, S.T., M.Kom. selaku Dosen Penguji II yang telah banyak memberikan saran demi kemajuan dan penyempurnaan dalam pengerjaan tugas akhir ini.
 9. Seluruh Dosen Teknik Informatika Universitas Islam Negeri Sultan Syarif Kasim Riau yang banyak memberikan ilmu, dan arahan selama perkuliahan. Semoga ilmu yang bapak dan ibu berikan bermanfaat bagi penulis dan seluruh mahasiswa, Aamiin.
 10. Khususnya untuk kedua orang tua Ibunda Lisdawati, dan Ayahanda Hamidi, yang telah memberikan doa yang tulus, dukungan, semangat, kasih sayang, mendidik, dan seluruh kebaikan yang selalu diberikan sehingga telah sampai pada tahap ini. Semoga selalu sehat, dan semoga Allah SWT melimpahkan semua kebaikan Ayahanda, dan Ibunda kelak didunia maupun di akhirat kelak, Aamiin.
 11. Khususnya untuk Adik Nurul Hidayah dan Muhammad Asy-Shidiqi yang selalu memberikan semangat, dan dukungan agar penulis bisa menyelesaikan Tugas Akhir ini dengan cepat, semoga setiap impian yang diinginkan lekas tercapai, dan menjadi pilihan terbaik, Aamiin.
 12. Teman-teman seperjuangan yang telah menemani suka dan duka, menghiburku, mengisi waktuku, bertukar pikiran, mendukung, dan membantu selama masa kuliah hingga tugas akhir ini selesai (Muhammad Abdillah, Muhammad Hafizd Anshari, Ibnu Afdhal, Mahfuzon Akhiar, Muhammad Alwi Basyir, Alfandi Firnando, Kasuma Indra Suryawan Redho Hidayatullah, Wahyu Novriansah, Ihda Syurfi, Hayatul Husna Yaswir, Muhammad Ihsanul

Fikri, Juna Mikola, Muhammad Nur Anshari, Tommy Caniago, Habibi Arasyid, Hafif Saputra, Nanda Saputra) semoga kita semua bisa mencapai impian terbesar kita, semoga silaturahmi kita tetap terjalin, Aamiin.

14. Seluruh teman-teman TIF E 2017 dan angkatan TIF 2017 yang selalu menemani, memberi semangat, dan membantuku selama perkuliahan. Semoga kita semua sukses, semoga silaturahmi kita tetap terjalin, Aamiin.
15. Seluruh teman-teman ku yang selalu menemani ku selama masa-masa sekolah, serta mendukung ku, semoga silaturahmi kita selalu terjalin. Sukses dan semangat untuk kita semua, Aamiin.
16. Seluruh pihak yang belum penulis cantumkan, terima kasih atas dukungan baik material maupun spiritual.

Penulis menyadari bahwa dalam penulisan laporan ini masih terdapat banyak kesalahan dan kekurangan, oleh karena itu kritik, dan saran yang sifatnya membangun sangat penulis harapkan untuk kesempurnaan laporan ini. Akhir kata penulis berharap semoga laporan ini dapat memberikan sesuatu yang bermanfaat bagi siapa saja yang membacanya. Amin.

Wassalamu'alaikum wa rohmatullohi wa barokatuh.

Pekanbaru, 21 Desember 2021

Penulis

UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

DAFTAR ISI

LEMBAR PERSETUJUAN.....	ii
LEMBAR PENGESAHAN	iii
LEMBAR HAK ATAS KEKAYAAN INTELEKTUAL.....	iv
LEMBAR PERNYATAAN	v
LEMBAR PERSEMBAHAN	vi
ABSTRAK	vii
ABSTRACT.....	viii
KATA PENGANTAR	ix
DAFTAR ISI.....	xii
DAFTAR GAMBAR	xvii
DAFTAR TABEL.....	xix
DAFTAR RUMUS	xx
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah.....	4
1.4 Tujuan Penelitian.....	4
1.5 Sistematika Penelitian	4
BAB 2 LANDASAN TEORI.....	6
2.1 Sampah	6
2.2 <i>Machine Learning</i>	7
2.2.1 <i>Supervised Learning</i>	9
2.2.2 <i>Unsupervised Learning</i>	9



2.3	<i>Artificial Neural Network (ANN)</i>	10
2.3.1	<i>Feedforward</i>	13
2.3.2	<i>Backpropagation</i>	14
2.4	<i>Deep learning</i>	15
2.5	<i>Data Augmentation</i>	16
2.6	<i>Convolutional Neural Network</i>	17
2.6.1	<i>Convolutional Layer</i>	18
2.6.2	<i>Pooling Layer</i>	21
2.6.3	<i>Batch Normalization</i>	22
2.6.4	<i>Flatening</i>	23
2.6.5	<i>Fully-connected Layer</i>	23
2.6.6	<i>Activation Layer</i>	24
2.6.7	<i>Resizing</i>	26
2.6.8	<i>Dropout Regularization</i>	26
2.7	<i>Data Splitting</i>	27
2.8	<i>Optimizer</i>	28
2.8.1	<i>Adaptive Moment Estimation (Adam)</i>	28
2.8.2	<i>Adaptive Moment Maximum (Adamax)</i>	29
2.9	<i>Confusion Matrix</i>	29
2.9.1	<i>Precision</i>	30
2.9.2	<i>Recall</i>	30
2.9.3	<i>F1-Score</i>	30
2.10	<i>Arsitektur Convolutional Neural Network (CNN)</i>	30
2.10.1	<i>EfficientNet</i>	31
2.11	<i>Penelitian Terkait</i>	36

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

- Hak Cipta Dilindungi Undang-Undang
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
 2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

BAB 3 METODOLOGI PENELITIAN	43
3.1 Pengumpulan Data	43
3.2 Analisa Data	43
3.3 Analisa Data	44
3.4 <i>Deep Learning</i>	44
3.4.1 <i>Feedforward</i>	45
3.4.2 <i>Backpropagation</i>	46
3.4.3 <i>Arsitektur EfficientNet-B1</i>	47
3.4.4 <i>Convolutional</i>	50
3.4.5 <i>Activation Function</i>	51
3.5 Evaluasi dan Analisa	52
3.5.1 <i>Precision</i>	52
3.5.2 <i>Recall</i>	52
3.5.3 <i>F1-Score</i>	53
3.6 <i>Deployment</i>	53
BAB 4 ANALISA DAN PERANCANGAN	54
4.1 Analisa.....	54
4.1.1 Analisa Kebutuhan Data	54
4.1.2 Analisa Kebutuhan Data	56
4.1.3 Analisa Kebutuhan Data	56
4.1.4 <i>Analisa Hyperparameter</i>	57
4.1.5 <i>Analisa Klasifikasi EfficientNet-B1 Noisy Student</i>	58
4.2 Perancangan.....	65
4.2.1 <i>Source Code</i> Augmentasi Data Eksternal	65
4.2.2 <i>Source Code</i> Masukan Data	65

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

4.2.3	<i>Source Code Variabel Parameter</i>	66
4.2.4	<i>Source Code Variabel Parameter</i>	66
4.2.5	<i>Source Code Split Data</i>	67
4.2.6	<i>Source Code Augementasi Pipline</i>	67
4.2.7	<i>Source Code EfficientNet-B1 Noisy Student</i>	68
4.2.8	<i>Source Code Pelatihan Data</i>	69
4.2.9	Skenario Eksperimen	69
BAB 5 IMPLEMENTASI DAN PENGUJIAN		72
5.1	Implementasi	72
5.1.1	Batasan Masalah	72
5.1.2	Lingkungan Implementasi	72
5.1.3	Implementasi <i>EfficientNet-B1 Noisy Student</i>	73
5.2	Pengujian	76
5.3	<i>Deployment</i>	87
5.3.1	<i>Flowchart</i>	87
5.3.2	Batasan <i>Deployment</i>	89
5.3.3	Lingkungan <i>Deployment</i>	89
5.3.4	Pengujian Aplikasi	90
BAB 6 PENUTUP		93
6.1	Kesimpulan	93
6.2	Saran	93
DAFTAR PUSTAKA		95
LAMPIRAN A		100
A.	Sampah Anorganik	100
B.	Sampah Organik	103



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



DAFTAR GAMBAR

Gambar 2.1 Sampah organik yang berasal dari makhluk hidup	6
Gambar 2.2 Sampah anorganik yang tidak berasal dari makhluk hidup.....	7
Gambar 2.3 Penerapan <i>machine learning</i> pada <i>computer vision</i> satu objek, dan dua objek	8
Gambar 2.4 Proses pada <i>machine learning</i> dari dahap masukan hingga keluaran .	8
Gambar 2.5 Proses <i>feedforward ANN</i> dari tahap masukan hingga fungsi aktivasi 10	
Gambar 2.6 Lapisan(Layer) pada ANN untuk <i>Multi Layer Perceptron</i>	12
Gambar 2.7 Alur <i>Feedforward</i> pada ANN dari unit masukan hingga unit keluaran	13
Gambar 2.8 Proses <i>Backpropagations</i> setelah <i>feedforward</i> dan perhitungan <i>loss</i>	14
Gambar 2.9 Perbedaan <i>machine learning</i> dan <i>deep learning</i> dari segi ekstraksi fitur.....	15
Gambar 2.10 Contoh teknik <i>Data Augmentation</i> pada gambar kucing	16
Gambar 2.11 Tahap-tahap <i>deep learning</i> dengan arsitektur CNN.....	17
Gambar 2.12 Proses <i>Convolutional</i> pada metode CNN perkalian antara matriks masukan dengan filter	19
Gambar 2.13 Proses pada CNN dengan <i>filter</i> menghasilkan <i>feature map</i> baru....	19
Gambar 2.14 <i>Feature Maps</i> pada metode CNN.....	20
Gambar 2.15 <i>Feature Maps</i> setelah dilakukan perkalian dengan <i>filter</i>	21
Gambar 2.16 (a) Proses <i>Max Pooling</i> yang mengambil nilai tertinggi (b) Proses <i>Average Pooling</i> mengambil nilai rata-rata	22
Gambar 2.17 Proses <i>Flattening</i> setelah dilakukan <i>pooling</i>	23
Gambar 2.18 Mekanisme <i>fully-connected layer</i> pada tahap klasifikasi	24
Gambar 2.19 Grafik fungsi aktivasi <i>non-linear ReLU</i>	25
Gambar 2.20 Grafik fungsi aktivasi <i>non-linear leaky ReLU</i>	26
Gambar 2.21 (a) Jaringan tanpa <i>dropout regulariztion</i> . (b) Jaringan dengan <i>dropout regularization</i>	27
Gambar 2.22 Pembagian data dengan <i>Data Splitting</i> dengan tiga bagian	28



Hak Cipta Dilindungi Undang-Undang
 1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
 2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Gambar 2.23 <i>Confusion Matrix Maps</i> untuk tahap klasifikasi	29
Gambar 2.24 Struktur metode <i>EfficientNet state-of-the-art</i> 2019.....	32
Gambar 2.25 Tingkat akurasi arsitektur <i>imagenet Top-1</i>	33
Gambar 2.26 Grafik Top-1 <i>Accuracy ImageNet noisy student</i>	35
Gambar 3.1 Metodologi Penelitian	43
Gambar 3.2 Alur tahap augmentasi data pada gambar sampah	44
Gambar 3.3 Arsitektur <i>EfficientNet</i> sub <i>EfficientNet-B1</i>	47
Gambar 5.1 (a) <i>Plotting loss</i> (b) <i>accuracy</i> setelah dilakukan pelatihan data pada eksperimen pertama	77
Gambar 5.2 Hasil <i>confusion matrix</i> terhadap prediksi data uji pada eksperimen pertama.....	78
Gambar 5.3 (a) Grafik <i>loss</i> . (b)Grafik <i>accuracy</i> pada eksperimen ke empat dengan menggunakan fungsi aktivasi <i>ReLU</i> , <i>optimizer adam</i> , <i>learning rate</i> 10^{-2}	83
Gambar 5.4 Evaluasi <i>confusion matrix</i> pada eksperimen pertama dengan fungsi aktivasi <i>ReLU</i> , <i>optimizer adam</i> , dan <i>learning rate</i> 10^{-2}	84
Gambar 5.5 (a) Grafik <i>loss</i> . (b)Grafik <i>accuracy</i> pada eksperimen keempat dengan fungsi aktivasi <i>Leaky ReLU</i> , <i>optimizer adam</i> , dan <i>learning rate</i> 10^{-2}	86
Gambar 5.6 Evaluasi <i>confusion matrix</i> pada eksperimen ke empat dengan fungsi aktivasi <i>Leaky ReLU</i> , <i>optimizer adam</i> , dan <i>learning rate</i> 10^{-2}	86
Gambar 5.7 <i>Flowchart</i> pada aplikasi web prediksi sampah	88
Gambar 5.8 Tampilan awal aplikasi web prediksi sampah.....	90
Gambar 5.9 Sampah anorganik yang telah dimasukkan	91
Gambar 5.10 Hasil prediksi dari kelas sampah anorganik.....	91
Gambar 5.11 Masukan gambar pada kelas sampah organik.....	92
Gambar 5.12 Hasil prediksi terhadap jenis sampah organik.....	92

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

DAFTAR TABEL

Tabel 2.1 Model-model arsitektur <i>EfficientNet</i>	33
Tabel 2.2 Hasil <i>F1-Score</i> pada klasifikasi jenis buah citra RGB.....	34
Tabel 2.3 Daftar Arsitektur <i>EfficientNet</i> model <i>training noisy student</i>	36
Tabel 2.4 Penelitian Terkait	37
Tabel 4.1 Pembagian dataset sampah.....	54
Tabel 4.2 Jenis-jenis sampah yang terkumpul	55
Tabel 4.3 Augmentasi data pada dataset sampah.....	56
Tabel 4.4 Daftar <i>library python</i>	56
Tabel 4.5 <i>Hyperparameter CNN</i>	57
Tabel 4.6 Klasifikasi detail <i>EfficientNet-B1 model noisy student</i>	60
Tabel 4.7 Eksperimen arsitektur <i>EfficientNet-B1</i>	69
Tabel 5.1 Hasil prediksi berdasarkan <i>tunning hyperparameter</i>	80

DAFTAR RUMUS

(3.1) Rumus <i>feedforward</i> pada <i>hidden layer</i> pertama.....	45
(3.2) Rumus <i>feedforward</i> pada <i>output layer</i>	45
(3.3) Rumus <i>loss backpropagation</i>	46
(3.4) Rumus konvolusi	50
(3.5) Rumus <i>activation function ReLU</i>	51
(3.6) Rumus <i>activation function leaky ReLU</i>	51
(3.7) Rumus <i>Precision</i>	52
(3.8) Rumus <i>Recall</i>	52
(3.9) Rumus <i>F1-Score</i>	53

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Indonesia selalu muncul masalah lingkungan yang berkaitan dengan sampah. Seiring dengan bertambahnya penduduk, maka permasalahan mengenai sampah pada lingkungan semakin bertambah [1]. Pada tahun 2020 jumlah sampah di Indonesia mencapai 67,8 juta ton, angka ini naik 0,8 juta ton jika dibandingkan dengan tahun 2019 yang berjumlah 67 juta ton [2]. Banyak upaya untuk mengurangi polusi sampah yang ada lingkungan, salah satunya adalah menggunakan metode *Organic Solid Waste* (OSW) [3].

Menurut Hao nan Guo (2020), OSW merupakan metode pengelolaan sampah menggunakan tenaga manusia untuk melakukan pemilahan sampah di tempat penampungan sampah. OSW memiliki kekurangan diantaranya adalah efisiensi yang buruk, biaya yang tinggi, dan memiliki potensi terhadap ancaman kesehatan manusia yang melakukan pemilahan sampah [3]. Kekurangan tersebut bisa dibantu dengan membangun sebuah model pintar yang mampu melakukan pemilahan sampah secara langsung, dan efisien di tingkat perumahan untuk meminimalisir jumlah zat kimia yang dikirim ke tempat pembuangan sampah, dan memungkinkan bahan yang bisa didaur ulang diolah sesuai dengan jenisnya [4].

Pemodelan terkait dengan pemilahan sampah telah dilakukan oleh Leonardo, Yohannes, dan Ery Hartati (2020), dengan membangun sebuah model yang mampu melakukan klasifikasi jenis sampah dengan menggunakan metode *Local Binary Pattern* (LBP) untuk ekstraksi fitur, dan *Support Vector Machine* (SVM) sebagai metode klasifikasi memperoleh nilai akurasi sebesar 87,82% [1]. Berdasarkan penelitian dari Xiangpo Wei (2019) metode *Local Binary Pattern* (LBP) terdapat kekurangan dalam waktu pelatihan karena fitur yang dibentuk oleh LBP lebih besar dari gambar masukan asli. Selain dari kekurangan dalam waktu

pelatihan, LBP memiliki akurasi rendah jika dibandingkan dengan beberapa metode ekstraksi fitur lain seperti *Convolutional Neural Network* (CNN) [5]. LBP menghasilkan akurasi sebesar 98,60% sedangkan CNN memperoleh lebih tinggi di atas 99% hal ini dinilai CNN lebih efektif dalam ekstraksi fitur dengan penggunaan jumlah data yang besar [6].

CNN merupakan metode yang mengganti pendekatan berbasis fitur pada *machine learning* memiliki efisiensi, dan kinerja yang lebih baik dalam melakukan klasifikasi secara *real-time* [7]. CNN mempunyai kemampuan untuk mempelajari fitur dari gambar tidak terstruktur sehingga menghasilkan gambar klasifikasi [8]. Beberapa penelitian terkait pemilahan sampah organik dan sampah anorganik yang menggunakan metode CNN, yaitu pada artikel *Design of a Convolutional Neural Network Based Smart Waste Disposal System*. Data yang digunakan adalah gambar yang terdiri dari 10 kelas dengan jumlah data hanya 100 gambar sampah. Model yang digunakan adalah model yang dibangun dengan arsitektur CNN *AlexNet*. Akurasi yang dihasilkan sebesar 96% [9]. Berdasarkan penelitian yang dilakukan oleh Krizhevsky(2012), *AlexNet* memiliki kekurangan dari waktu pelatihan data karena jumlah parameter yang besar sekitar 60 juta parameter sehingga membuat pelatihan menjadi lambat [10]. Untuk mengatasi parameter yang besar diperlukan arsitektur dengan parameter yang sedikit, memiliki waktu pelatihan yang lebih cepat, dan efisien salah satunya yaitu *EfficientNet* [11].

EfficientNet arsitektur baru yang memanfaatkan *depth, width, dan resolution* dari sebuah jaringan sehingga menghasilkan kinerja yang bagus, khususnya dari segi komputasi, dan ukuran parameter [11]. *EfficientNet-B1* merupakan sub arsitektur *EfficientNet* yang memiliki jumlah parameter 7,8 juta parameter, memperoleh hasil *matriks precision, recall, dan F1-Score* dengan hasil 95% pada penerapan klasifikasi jenis buah dengan citra gambar *Red Green Blue* (RGB) [12]. *EfficientNet* selanjutnya mengalami peningkatan akurasi yang signifikan berupa pemodelan yang disebut dengan *Noisy Student* [13].

Noisy Student merupakan pemodelan yang dirancang dengan memanfaatkan *dropout*, *stochastic depth*, dan *Random Augmentation* dalam proses pembelajarannya. *Noisy Student* tetap memanfaatkan jumlah parameter pada *EfficientNet* dengan *state-of-the-art* 88.4% pada awal tahun 2020. Model ini menjadikan arsitektur yang lebih baik dari arsitektur *EfficientNet* sebelumnya [13].

Arsitektur CNN seperti *EfficientNet* memiliki kemampuan untuk mengatasi *overfitting* pada data latih dengan memanfaatkan beberapa teknik pada *regularization* [14]. Selain menggunakan *regularization*, teknik yang bisa dilakukan yaitu *tuning hyperparameter* seperti mengatur *learning rate*, *optimizer*, dan *data splitting* untuk meningkatkan performa model yang lebih baik seperti peningkatan akurasi, dan jumlah waktu yang dibutuhkan untuk pelatihan data [15].

Tahap *regularization* untuk *data splitting* yang terbaik yaitu 90% untuk data latih, dan 10% untuk data validasi dengan akurasi terbaik 80,57% [16], dengan batas *data splitting* minimum yang disarankan 70:30, karena distribusi data latih lebih besar sehingga model tetap mempelajari banyak fitur [17]. Selain *data splitting*, *regularization* lain yang bisa digunakan yaitu *learning rate*. Ukuran *learning rate* bisa diatur dari 10^0 - 10^{-8} [18]. Walaupun ukuran *learning rate* bisa diatur, ada batas *learning rate* yang paling optimal yaitu dari 10^{-2} - 10^{-4} karena ukuran ini dinilai paling optimal [19]. Sedangkan untuk *optimizer* yang paling baik yaitu *adaptive moment estimation* (adam) karena *optimizer* ini merupakan gabungan dari *optimizer* sebelumnya yaitu *adaptive gradient* (adagrad), dan *Root Means Square Propagations* (RMSProp) yang mampu mengurangi nilai *cost function* hingga lebih kecil [20]. Dengan kelebihan tersebut *optimizer* akan menggunakan *learning rate* 10^{-2} - 10^{-4} .

Berdasarkan uraian diatas, penelitian ini akan melakukan eksperimen untuk menentukan model terbaik dari arsitektur *EfficientNet-B1* model *noisy student* karena memiliki parameter yang sedikit, dan akurasi *F1-Score* terbaik. Eksperimen dilakukan dengan menggunakan *tuning hyperparameter* untuk

memperoleh model yang optimal. Model optimal tersebut akan digunakan untuk melakukan klasifikasi terhadap jenis sampah yang bersifat umum.

1.2 Rumusan Masalah

Rumusan masalah yang didapat berdasarkan latar belakang diatas adalah bagaimana menghasilkan model terbaik dari arsitektur *EfficientNet-B1* dalam pengklasifikasian sampah organik dan anorganik?

1.3 Batasan Masalah

Pada penelitian ini ditentukan batasan masalah agar cakupan tidak meluas, atau menyimpang dari yang telah direncanakan. Adapun batasan masalah pada penelitian ini yaitu dataset yang digunakan merupakan citra gambar RGB sebanyak 3.123 gambar.

1.4 Tujuan Penelitian

Adapun tujuan yang ingin dicapai dari penelitian ini adalah untuk menghasilkan model terbaik dari arsitektur *EfficientNet-B1* dalam pengklasifikasian sampah organik dan anorganik.

1.5 Sistematika Penelitian

Penulisan laporan tugas akhir ini tersaji dengan sistematika penulisan sebagai berikut:

Bab I Pendahuluan

Bagian ini berisi tentang deskripsi umum tugas akhir yang meliputi latar belakang, rumusan masalah, batasan masalah, tujuan penelitian dan sistematika penulisan.

Bab II Landasan Teori

Berisi penjelasan-penjelasan teori-teori yang mendukung terhadap penerapan metode. Teori tersebut antara lain adalah sampah, *Machine Learning*, *Artificial Neural Network*, *Deep Learning*, *Convolutional Neural Network* (CNN), Arsitektur CNN, dan penelitian terkait.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Bab III Metodologi Penelitian

Berisi pembahasan mengenai langkah-langkah yang dilakukan dalam penelitian ini. Langkah-langkah tersebut antara lain adalah pengumpulan data, *deep learning*, evaluasi dan analisis, kesimpulan.

Bab IV Analisa dan Perancangan

Bab ini Berisi tentang analisa dan perancangan penerapan metode CNN yang akan digunakan sebagai dasar tahap implementasi yang akan dilaksanakan berikutnya.

Bab V Implementasi dan Pengujian

Bab ini membahas mengenai penerapan metode CNN terhadap data. Bab ini juga meliputi pengujian dari hasil implementasi yang telah dibangun.

Bab VI Penutup

Bab ini berisi tentang kesimpulan dan saran dari hasil penelitian Tugas Akhir yang telah dilakukan.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

BAB 2

LANDASAN TEORI

2.1 Sampah

Sampah merupakan limbah yang bersifat padat yang terdiri dari bahan organik dan anorganik yang telah dianggap tidak berguna, dan harus dikelola dengan sebaik mungkin agar tidak membahayakan lingkungan hidup, dan melindungi investasi pembangunan [21].

Sampah terbagi menjadi dua jenis yaitu sampah organik dan sampah anorganik. Sampah organik merupakan sampah yang bahan-bahan penyusunnya berasal dari makhluk hidup. Baik itu diambil dari alam, maupun dari hasil kegiatan pertanian, perkebunan, dan perikanan. Sampah organik mudah diuraikan melalui proses yang alami, dan tidak membutuhkan waktu yang lama dalam proses penguraian. Contohnya yaitu sampah dedaunan kering, kayu, sayur, buah, dan jenis lainnya yang mudah terurai melalui proses yang alami[21].



Gambar 2.1 Sampah organik yang berasal dari makhluk hidup

Sampah anorganik adalah jenis sampah yang berasal dari sumber daya alam tidak bisa diperbarui seperti mineral dan minyak bumi atau dihasilkan dari proses produksi industri. Beberapa bahan tersebut biasanya tidak terdapat di alam, diantaranya yaitu plastik, aluminium, dan kaca. Sebagian zat anorganik secara

keseluruhan tidak dapat terurai di alam, sedangkan sebagian lainnya bisa diurai oleh alam, tetapi membutuhkan waktu yang lama dalam penguraiannya hingga benar-benar hancur. Contoh dari sampah anorganik ini yaitu botol kaca, botol plastik, styrofoam, kaleng, PVC(pipa), sedotan plastik, dan kantong plastik [21].



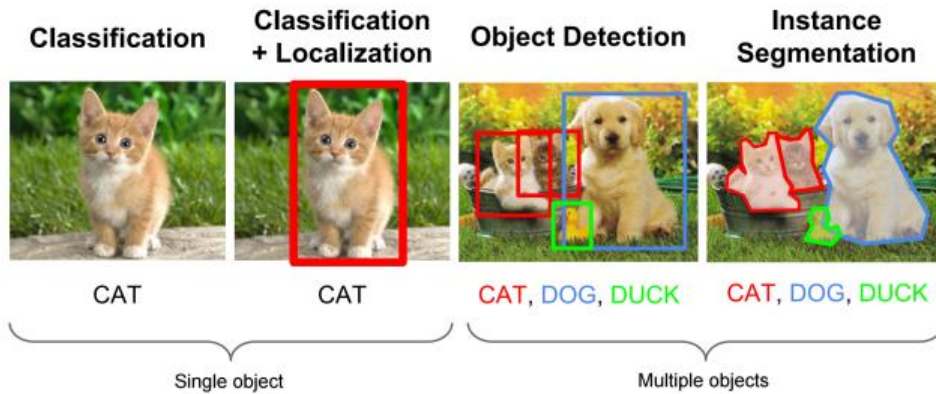
Gambar 2.2 Sampah anorganik yang tidak berasal dari makhluk hidup

2.2 *Machine Learning*

Machine Learning merupakan bidang studi yang memberikan kemampuan sebuah komputer untuk belajar tanpa perlu dilakukan pemrograman secara eksplisit [22]. Terdapat dua hal penyebab munculnya *machine learning* yaitu bagaimana cara membangun sistem komputer secara otomatis berdasarkan pengalaman yang dipelajari oleh komputer, dan penerapan hukum dasar teori statistik komputasi dan informasi yang mengatur sistem pembelajaran diantaranya komputer, manusia, dan organisasi, sehingga bisa diterapkan di banyak aplikasi [23].

Machine Learning telah berkembang secara pesat selama dua dekade terakhir. Mulai dari tahap penelitian di laboratorium, hingga pemanfaatannya terhadap teknologi praktis yang telah digunakan secara komersial. Dalam ilmu komputer *Artificial Intelligence*, *Machine Learning* muncul sebagai sebuah metode pengembangan perangkat lunak untuk penerapan *computer vision*, pengenalan suara, NLP, kontrol terhadap robot, dan penerapan aplikasi

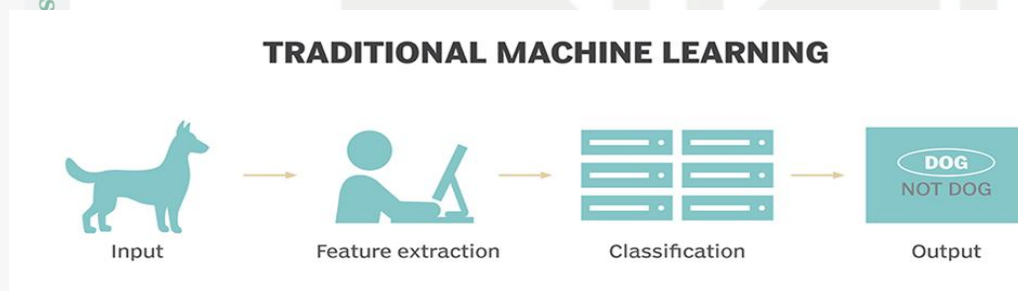
lainnya[24]. Salah satu penerapan dari *Machine Learning* dapat dilihat pada gambar berikut:



Gambar 2.3 Penerapan *machine learning* pada *computer vision* satu objek, dan dua objek
 (Sumber: <https://www.kdnuggets.com>)

Gambar 2.3 merupakan salah satu penerapan dari *Machine Learning* yang mampu mengenali sebuah objek berdasarkan fitur-fitur yang dimiliki pada gambar yang akan dipelajari oleh komputer.

Machine Learning memiliki beberapa proses dalam melakukan pembelajaran terhadap data sehingga menghasilkan keluaran yang diharapkan. Proses *Machine Learning* dapat dilihat pada gambar berikut:



Gambar 2.4 Proses pada *machine learning* dari dahap masukan hingga keluaran
 (Sumber: <https://www.tosall.com>)

Pada gambar 2.4 menunjukkan bahwa proses *Machine Learning* terbagi menjadi empat bagian. Empat bagian tersebut yaitu *input*, *feature extraction*, *classification*, dan *output*. *Input* merupakan data yang digunakan untuk



dilakukan pembelajaran mesin. *Feature Extraction* merupakan tahapan untuk menghasilkan fitur-fitur pada data yang telah dimasukan. Pada tahapan ini *machine learning* membutuhkan bantuan manusia dalam menghasilkan fitur-fitur pada sebuah data. *Classification* merupakan tahapan penentuan klasifikasi terhadap data yang telah mengalami *feature extraction*, hasil tersebut akan diubah kedalam bentuk *array*, *array* ini akan mengalami *fully-connected* untuk melakukan penentuan kelompok dari data yang telah dimasukan berdasarkan nilai yang paling dominan [25]. *Machine Learning* terbagi menjadi 4 bagian, diantaranya *Supervised Learning*, *Semi Supervised Learning*, *Unsupervised Learning*, dan *Reinforcement Learning* [26].

2.2.1 *Supervised Learning*

Supervised Learning disebut juga dengan pembelajaran terawasi, yang berarti pada pembelajaran ini terdapat guru yang mengajar dan siswa yang belajar. Metode pembelajaran ini disebut dengan *supervised* karena ada yang memberikan contoh jawaban.

Tujuan dari *supervised learning* umumnya berkaitan dengan klasifikasi. Dengan contoh klasifikasi sampah organik dan anorganik, klasifikasi penyakit tumor, klasifikasi jenis buah, dan lain sebagainya yang termasuk klasifikasi.

Klasifikasi pada supervised learning terbagi menjadi menjadi dua kategori yaitu *binary classification* (dua kelas atau dua kategori), *multi classification* (multi kelas atau kategori lebih dari dua). Selain itu tipe klasifikasi tambahan yaitu *multi label classification* yang berbeda dengan *multi classification*. Perbedaan *multi classification* yaitu satu sampel hanya berespondensi dengan satu kelas, sedangkan *multi label classification* satu sampel dapat berespondensi dengan lebih dari satu kelas [26].

2.2.2 *Unsupervised Learning*


Unsupervised Learning merupakan pembelajaran yang tidak ada guru yang bertugas sebagai pemberi petunjuk (mengajar). Contoh tugas dari *unsupervised learning* yaitu *clustering*. *Clustering* merupakan bentuk dari

unsupervised learning, yang bertugas mencari sifat-sifat yang menonjol dari properties data [26].

2.3 Artificial Neural Network (ANN)

Artificial Neural Network (ANN) disebut juga Jaringan Syaraf Tiruan (JST) adalah cabang dari kecerdasan buatan (*Artificial Intelligence*). ANN merupakan model matematika yang terinspirasi dari fitur fungsional dari jaringan saraf biologis pada otak manusia. Jaringan saraf memiliki sekumpulan neuron buatan yang terhubung, dan memproses informasi menggunakan bentuk koneksi dalam komputasinya. Umumnya ANN adalah sistem adaptif yang menyelaraskan organisasinya berdasarkan informasi dari luar atau informasi dari dalam yang berjalan menuju jaringan lain selama proses pembelajaran [27].

Neural Network yang terbaru adalah alat pemodelan data numerik non-linear. NN digunakan untuk pemodelan hubungan antara input dan output atau untuk menemukan pola pada data. ANN telah diterapkan di berbagai aplikasi. Diantaranya prediksi, pengenalan karakter pada tulisan tangan, dan evaluasi harga perumahan.




Gambar 2.5 Proses *feedforward* ANN dari tahap masukan hingga fungsi aktivasi

Gambar 2.5 diatas menunjukkan langkah *feed forward* pada jaringan ANN. b menandakan bias, w = merupakan *weight*, s = hasil penjumlahan perkalian linear, f = fungsi aktivasi. Proses yang dilalui yaitu nilai pada masing-masing neuron akan dikalikan dengan masing-masing *weight* yang terhubung dengan neuron, selanjutnya dijumlah dengan nilai bias, setelah dilakukan penjumlahan

bias hasil nilai yang diperoleh akan dilakukan perhitungan menggunakan fungsi aktivasi [28].

Pembelajaran ANN bisa diarahkan (*directed*) atau tidak diarahkan (*undirected*). Pelatihan terarah yaitu pelatihan yang memberikan jaringan saraf sekumpulan data sampel disertai dengan output yang diprediksi dari tiap-tiap sampel, saat pelatihan terarah berlanjut, jaringan saraf melewati tahap iterasi, atau epoch. Sehingga hasil output dari jaringan saraf sama dengan keluaran yang diprediksi, dengan hasil tingkat kesalahan yang lebih kecil. Pelatihan tidak terarah sama dengan pelatihan terarah, tetapi pada pelatihan tidak terarah tidak ada hasil output prediksi yang disediakan. Pelatihan ini terjadi karena jaringan saraf melakukan klasifikasi terhadap masukan menjadi beberapa kelompok. Pelatihan (*training*) merupakan proses dimana *weight* (bobot) koneksi ditetapkan. Sebagian besar algoritma pelatihan dimulai dengan menetapkan angka acak ke matriks *width*. Kemudian validasi jaringan saraf diperiksa. Setelahnya, *weight* diatur berdasarkan seberapa *valid* jaringan saraf telah dilakukan. Proses pelatihan ini akan dilakukan berulang sampai kesalahan validasi berada pada batas yang bisa diterima.

Validasi dilakukan setelah jaringan saraf terlatih dan harus dinilai untuk mengetahui apakah model telah siap digunakan. Tahap ini merupakan tahap penting agar bisa ditentukan apakah diperlukan latihan tambahan. Untuk memvalidasi jaringan saraf dengan benar, diperlukan sekitar 80% dari total sampel data digunakan untuk data latih, dan sisanya digunakan untuk data validasi [27].



Gambar 2.6 Lapisan(Layer) pada ANN untuk *Multi Layer Perceptron*

(Sumber: <https://medium.com/@ImadPhd>)

ANN terbagi menjadi tiga bagian yang neuronnya diatur dan terkait satu sama lain dapat dilihat pada gambar berikut.

1. *Input Layer*

Input Layer adalah lapisan yang mengambil masukan dari data sampel. Disebut *Visible Layer* karena bagian terluar jaringan yang terbuka. Selain itu jaringan saraf sering digambarkan berupa lapisan yang terlihat dengan satu neuron per nilai masukannya.

2. *Hidden Layer*

Lapisan setelah *Input Layer* adalah *Hidden Layer*. Disebut *Hidden Layer* karena lapisan ini secara langsung tidak langsung terhubung dengan masukan. Struktur jaringan yang paling sederhana adalah memiliki satu neuron di *hidden layer* dan pada layer tersebut langsung mengeluarkan nilai. *Hidden layer* sendiri bisa lebih terdiri dari satu *hidden layer*.


3. *Output Layer*

Output Layer merupakan lapisan terakhir dan berfungsi mengeluarkan nilai atau nilai vektor yang sesuai dengan format yang diperlukan untuk masalah tersebut. Pada *Output Layer* terdapat fungsi aktivasi (*activation function*) yang disesuaikan dengan masalah yang dihadapi, untuk menjadi model yang baik. Sebagai contoh, masalah regresi bisa memiliki neuron keluaran tunggal dan

neuron mungkin tidak memiliki fungsi aktivasi; masalah klasifikasi dengan dua kelas (*binary classification*) bisa memiliki neuron keluaran tunggal, dan menggunakan fungsi aktivasi *sigmoid* untuk mengeluarkan nilai antara 0 dan 1. Dengan tujuan untuk mewakili probabilitas dalam memprediksi nilai kelas utama; masalah klasifikasi dengan banyak kelas (*multiclass classification*) bisa memiliki banyak neuron di lapisan keluaran, dimana satu neuron untuk tiap kelasnya. Dalam hal ini, fungsi aktivasi *softmax* bisa digunakan untuk menghasilkan probabilitas dari jaringan yang memprediksi setiap nilai kelas. Dengan memilih nilai output yang memiliki nilai probabilitas tinggi, akan menghasilkan nilai klasifikasi kelas yang tepat [29].

2.3.1 Feedforward

Feedforward adalah proses perhitungan nilai dari *input layer* ke *output layer*. Dengan memperhatikan nilai pada setiap neuron, nilai bobot pada *link* dan fungsi aktivasi pada *hidden layer*, dan *output layer*.



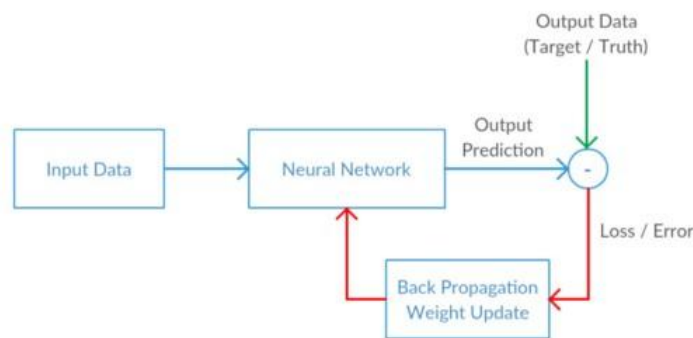
Gambar 2.7 Alur *Feedforward* pada ANN dari unit masukan hingga unit keluaran

Gambar 2.7 disebut juga dengan *Multilayer Perceptron* (MLP). MLP merupakan salah satu jaringan kompleks dari *Artificial Neural Network* (ANN) yang memiliki jumlah neuron lebih dari satu. MLP merupakan arsitektur jaringan yang akan diterapkan pada *deep learning*, MLP disebut juga dengan *Feedforward Neural Network*. Cara kerja dari *feedforward* yaitu *input layer* menerima nilai masukan tanpa melakukan operasi apapun. Jadi nilai pada *input layer* diperoleh

dari data awal. Kemudian nilai dari *input layer* akan diteruskan ke *hidden layer*. Pada *hidden layer*, nilai pada *input layer* akan diproses menggunakan fungsi aktivasi. Nilai dari perhitungan dengan fungsi aktivasi pada *hidden layer* akan diteruskan lagi ke *layer* berikut seterusnya.

2.3.2 Backpropagation

Backpropagation merupakan proses pembaruan nilai bobot dimana setiap keluaran jaringan akan dibandingkan dengan keluaran yang diharapkan dan menghitung kemungkinan kesalahan pada tiap *feedforward*. Kemudian kesalahan ini disebarkan kembali melalui jaringan, satu *layer* pada satu waktu. Proses ini dilakukan secara berulang dalam pelatihan dataset. Setiap satu putaran untuk memperbaiki jaringan pada seluruh dataset disebut dengan *epoch*, dimana jaringan tersebut dapat dilatih sebanyak puluhan, ratusan, hingga ribuan *epoch* [29].



Gambar 2.8 Proses *Backpropagations* setelah *feedforward* dan perhitungan *loss*


Pada gambar 2.8 merupakan proses dari *Backpropagation* proses yang dilakukan pada tahap *classification* menggunakan ANN. Tahapan-tahapan yang dilakukan yaitu ketika input data dari *input layer* akan di *feedforward* menuju *hidden layer*, setiap nilai pada neuron akan dikalikan dengan *weight* dan dijumlahkan dengan bias, kemudian dilakukan proses menggunakan fungsi aktivasi, proses ini berlangsung hingga pada tahap *output layer* kemudian ketika telah masuk di *output layer* setiap nilai yang telah diperoleh sebelumnya akan dilakukan pengecekan nilai *loss*.

2.4 Deep learning

Deep Learning merupakan konsep yang berawal dari pendekatan *Artificial Neural Network* (ANN) dimana jaringan saraf (*neural network*) digabungkan dengan banyak lapisan tersembunyi (*hidden layer*) sehingga dianggap sebagai jaringan saraf mendalam (*deep neural network*).

Deep Learning terdiri dari proses sederhana namun non-linear yang masing-masing unit merubah representasi atau fitur menjadi satu level (dimulai melalui input data sampel) menjadi representasi di tingkat yang lebih tinggi.

Deep Learning adalah metode representasi pembelajaran yang menghasilkan pembelajaran ganda dari tingkat fitur representasi rendah hingga fitur representasi tinggi. Contoh penerapan DL yaitu dalam mengenali objek gambar, DL bisa belajar informasi warna dari masukan yang berbentuk pixel-pixel di lapisan pertama (*input layer*) dan kemudian informasi warna tersebut diubah menjadi pola di dalam lapisan berikutnya [30].



Gambar 2.9 Perbedaan *machine learning* dan *deep learning* dari segi ekstraksi fitur

(Sumber: <https://lawtomated.com>)

Deep Learning merupakan bagian dari *Machine Learning*. Gambar 2.9 diatas menjelaskan, salah satu perkembangan dari *deep learning*, *ML* hanya

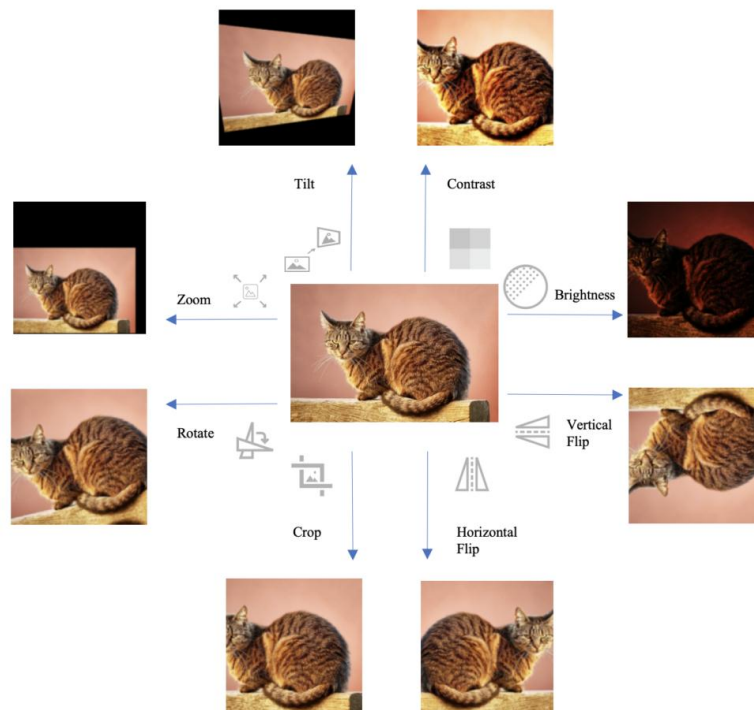
Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

berfokus pada *classification* sedangkan *feature extraction* didapat dari data pelatihan yang dilakukan oleh manusia. Sedangkan pada DL *Feature Extraction* disebut dengan *Feature Learning* karena penentuan *Feature Learning* yang menentukannya adalah mesin. Sehingga diperlukan perangkat keras yang optimal dalam melakukan pengembangan pada penelitian ini [31].

2.5 Data Augmentation

Data Augmentation merupakan salah satu dari teknik *regularization* yang berfungsi mencegah terjadinya *overfitting* pada proses pelatihan. *Data Augmentation* digunakan untuk melakukan ekstraksi fitur dari kumpulan fitur dari data asli dengan tujuan meningkatkan ukuran dataset pelatihan untuk memperoleh berbagai macam jenis informasi diantara beberapa jenis data augmentasi yang bisa digunakan yaitu *Geometric transformations*, *Flipping*, *Color space*, *Cropping*, *Rotation*, *Translation*, *Noise injection*, dan *Color space transformations* [14]. Berikut merupakan contoh menggunakan *data augmentation*.



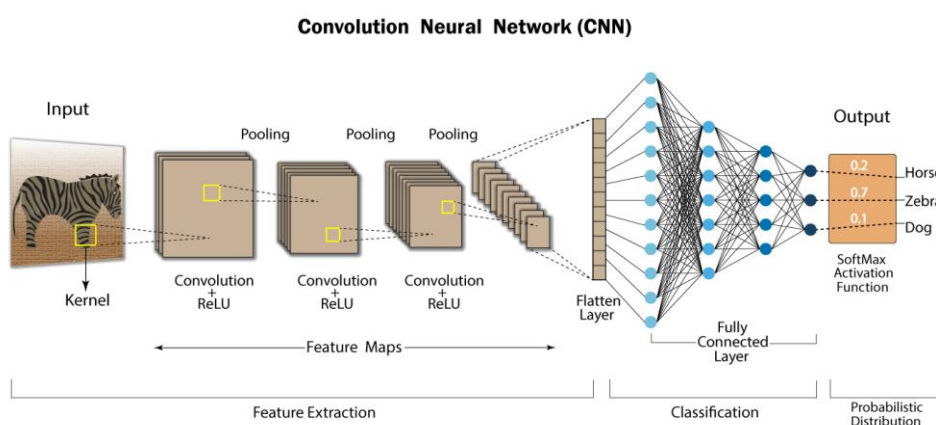
Gambar 2.10 Contoh teknik *Data Augmentation* pada gambar kucing

(Sumber: <https://learn.giotto.ai>)

Pada gambar 2.10 merupakan beberapa contoh dari *data augmentation* pada gambar kucing. Diantara *data augmentation* yang digunakan pada gambar tersebut yaitu *zoom*(pembesaran/pegecilan), *rotate*(perputaran), *crop*(pemotongan), *horizontal flip*(balik secara horizontal), *vertical flip*(balik secara vertikal), *brightness*(pencahayaan), dan *contrast*(kontras).

2.6 Convolutional Neural Network

Convolutional Neural Network (CNN) awalnya diusulkan oleh Lecun yang menjadi salah satu metode yang paling sukses pada bidang pengenalan pola. Dalam struktur ini, secara lokal pada tahap pelatihan filter digunakan untuk mengekstrak lebih banyak fitur visual pada masukan gambar. *Feature Maps* yang memiliki ukuran akan dikurangi pada operasi *pooling*. Proses ini akan terus berlanjut hingga ekstraksi fitur terdalam (*deep feature*). Setelah tahap ini, maka sebuah keputusan dibuat oleh classifier pada fitur ini. Sebuah CNN yang mendalam umumnya mengacu pada sebuah struktur yang melibatkan *convolutional layer*, *pooling layer*, dan sebuah *fully connected network*. Pada operasi ini *convolutional* digunakan untuk fitur ekstraksi, pada *fully-connected layer* bisa diakhiri dengan menggunakan fungsi aktivasi *softmax* untuk klasifikasi multi kelas, dan *sigmoid* untuk klasifikasi dua kelas pada *output layer*.



Gambar 2.11 Tahap-tahap *deep learning* dengan arsitektur CNN

(Sumber: <https://developersbreach.com/author/swapnake123/>)


1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Gambar 2.11 merupakan tahap-tahap arsitektur CNN pada umumnya. Tahap pertama arsitektur ini yaitu konvolusi dilakukan dengan menggunakan kernel (*filter*), dengan melakukan perkalian antara neuron masukan dengan kernel, setelah dilakukan perhitungan, pada tahap kedua, dilakukan proses perhitungan kembali dengan fungsi aktivasi. Umumnya fungsi aktivasi yang digunakan pada tahap terakhir yaitu *ReLU*. Setelah selesai perhitungan pada fungsi aktivasi, tahap ketiga yaitu *pooling* yang akan mengurangi ukuran *feature maps*. Kegiatan dari konvolusi ini hingga fungsi aktivasi berjalan secara berulang tergantung jenis arsitektur yang digunakan. Yang terakhir pada tahap *fully connected layer* di tentukanlah nilai yang dominan, ditambah dengan fungsi aktivasi seperti *sigmoid* untuk *binary classification* dan *softmax* untuk *multiclass classification* yang lain untuk menentukan target *class*.

CNN memiliki beberapa struktur arsitektur populer yang dibuat dengan memanfaatkan *layer-layer* ini di antaranya *AlexNet*, *OverFeat*, *GoogleNet*, *ResNet*, *VGG*, *MobileNet*, *EfficientNet*, *DenseNet*. Salah satu masalah terbesar yang akan dihadapi adalah *overfitting* pada tahap pelatihan. Masalah ini bisa cegah dengan memanfaatkan data augmentasi, *Dropout*, dan *DropConnect*.

2.6.1 Convolutional Layer

Convolutional layer adalah struktur dengan sejumlah filter yang memiliki ukuran tetap memungkinkan penerapan fungsi kompleks pada masukan gambar. Pada proses ini dilakukan dengan menggeser filter yang dilatih secara local. Setiap filter memiliki nilai bobot dan nilai bias yang sama pada seluruh gambar selama proses ini berlangsung. Mekanisme ini disebut mekanisme membagi bobot. Mekanisme ini juga menyediakan kemampuan untuk mempresentasikan beberapa fitur pada seluruh gambar [32].



Gambar 2.12 Proses *Convolutional* pada metode CNN perkalian antara matriks masukan dengan filter


(Sumber: <https://medium.com/@cdabakoglu>)

Gambar 2.12 diatas merupakan proses dari *convolutional* sehingga menghasilkan *feature maps* baru yang kemudian dimasukkan ke *function activation*.

Convolutional terdiri dari *filters* dan *feature maps* dan tidak bisa dipisahkan penggunaan *filter* dan *feature maps* diantaranya:

1. *Filters*

Filters merupakan hal dasar pada lapisan neuron. *Filter* dan neuron mempunyai bobot masukan dan menghasilkan sebuah hasil output yang sama dengan sebuah neuron. Ukuran dari masukan adalah sebuah persegi yang disesuaikan disebut dengan *patch*. Jika sebuah lapisan *convolutional* adalah lapisan masukan, maka lapisan inputnya sendiri diambil dari nilai pixel gambar. Jika pada jaringan arsitektur terdalam, maka nilai masukan diambil dari sebuah *feature maps* yang berada pada lapisan sebelumnya.



Gambar 2.13 Proses pada CNN dengan *filter* menghasilkan *feature map* baru

(Sumber: <https://towardsdatascience.com>)



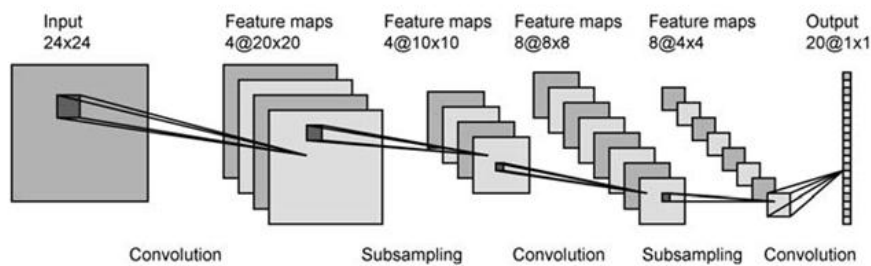
Hak Cipta Dilindungi Undang-Undang
 1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
 2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

© Hancu et al. / UIN Suska Riau
 State Islamic University of Sultan Syarif Kasim Riau

Pada gambar 2.13 diatas menjelaskan proses dari *convolutional* dengan *filtering* dengan masukan ukuran gambar 5×5 *pixel* dengan *filter* yang digunakan yaitu *filter* 3×3 sehingga dilakukan perkalian matriks menghasilkan 1 *pixel feature map*. Proses ini berlangsung hingga seluruh masukan gambar mengalami perkalian matriks dengan *filter* hingga selesai, setiap selesai perkalian matriks filter akan bergeser (mengalami *stride*) sebanyak satu langkah.

2. Feature Maps

Feature Maps adalah hasil keluaran dari penerapan *filter* terhadap lapisan sebelumnya. *Filter* tersebut diterapkan terhadap seluruh pixel pada lapisan sebelumnya. Kemudian *filter* akan berpindah satu pixel pada satu waktu. Setiap posisi pixel yang terhubung dengan *filter* menghasilkan aktivasi neuron, dan kemudian hasilnya dikumpulkan kedalam *feature maps*. Jika ukuran lapisan(*layer*) sebelumnya tidak dapat dibagi dengan ukuran *width* reseptif *filter* serta terhadap *stride*-nya maka dimungkinkan bidang(*field*) membaca tepi dari masukan *feature maps*. Hal ini dapat dilakukan dengan teknik tambahan yaitu *zero padding*, yaitu teknik menambah nilai 0 pada setiap pinggiran masukan sebelum diolah oleh *filter*.




Gambar 2.14 *Feature Maps* pada metode CNN

Pada gambar 2.14 diatas merupakan bagian dari *Feature Maps*. Sebuah *layer* dikatakan *feature maps* jika telah mengalami proses *convolutional*, dan perhitungan menggunakan fungsi aktivasi. *Feature Maps* Dan akan berakhir sebelum masuk pada tahap *classification*.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Salah satu contoh *feature maps* yang telah dihasilkan pasca *convolutional* dapat dilihat pada gambar berikut:



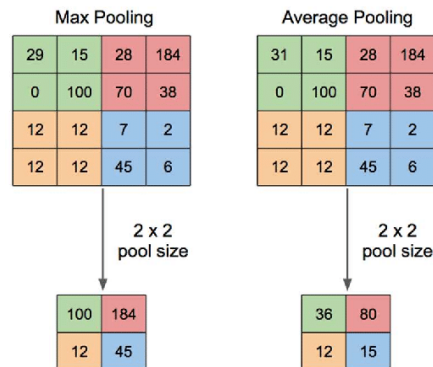
Gambar 2.15 *Feature Maps* setelah dilakukan perkalian dengan *filter*

(Sumber: <https://medium.com/@ardendertat>)

Gambar 2.15 diatas merupakan hasil dari *feature maps*. Hasil ini diperoleh dari proses perkalian matriks dengan filter yang digunakan. Hasil perkalian matriks tersebut berupa fitur-fitur dari gambar yang telah diekstrak. Hasil fitur ini akan digunakan kembali untuk proses konvolusi pada layer berikutnya.

2.6.2 Pooling Layer

Pooling(penggabungan) merupakan tahap yang diterapkan pada *feature maps* yang telah melewati tahap konvolusi dan fungsi aktivasi sehingga menghasilkan *feature maps* yang lebih kecil. *Pooling* merupakan ringkasan dari *feature maps* masukan. *Pooling* dilakukan dengan menggeser *window* pada gambar untuk dilakukan penerapan operasi *pooling* yang dipilih, diantara operasi *pooling* yaitu *max pooling* dengan memilih nilai maksimum pada nilai masukan yang terpilih, *average pooling* dengan mengambil nilai rata-rata dari nilai masukan, dan *L2 pooling* dengan menghitung norma pada L2 berikut merupakan salah operasi *max pooling* dan *average pooling*.



Gambar 2.16 (a) Proses Max Pooling yang mengambil nilai tertinggi (b) Proses Average Pooling mengambil nilai rata-rata

(Sumber: <https://www.researchgate.net>)

Gambar 2.16 diatas merupakan jenis-jenis dari proses *pooling* yang menggunakan nilai tertinggi (*max pooling*), dan menggunakan nilai rata-rata (*average pooling*). Pada gambar diatas bagian (a) proses *max pooling* yang dilakukan menggunakan ukuran *pool 2x2*, sehingga *pool* tersebut akan diterapkan pada *feature maps* dengan *2x2 pixel*. Dari *2x2 pixel feature maps* akan dicari nilai tertinggi, sehingga akan menghasilkan *feature maps* baru dengan *1x1 pixel*. Pada gambar diatas bagian (b) proses *average pooling* menggunakan ukuran *pooling 2x2*, sehingga *pool* tersebut akan diterapkan pada *feature maps* dengan *2x2 pixel*. Dari *2x2 pixel feature maps* akan dicari nilai rata-rata dari keempat *pixel*. Sehingga menghasilkan *feature maps* baru dengan *1x1 pixel*.

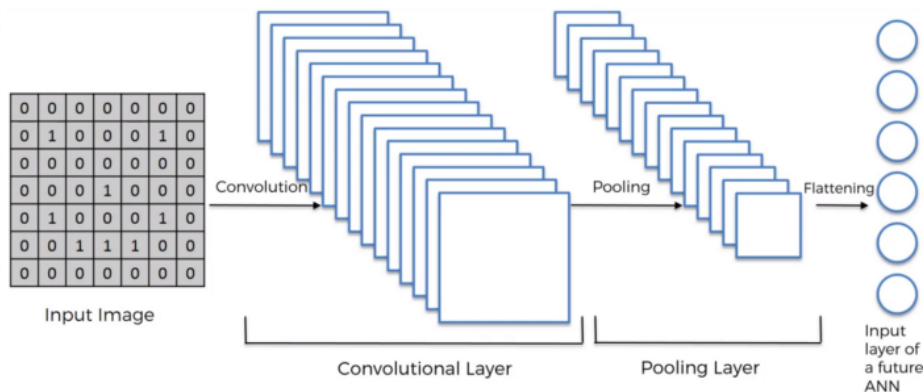
2.6.3 Batch Normalization

Batch normalization merupakan salah satu metode reparametrization adaptif, yang termotivasi dengan sulitnya melatih model yang sangat dalam tujuan dari penggunaan *batch normalization* adalah untuk melakukan optimasi pada jaringan neuron yang dalam.

Batch normalization melakukan reparametrizing hampir di seluruh kedalaman jaringan. Penerapan *reparametrization* secara signifikan akan mengurangi masalah koordinasi pembaruan di banyak lapisan. *Normalization* ini dapat diterapkan pada *layer masukan* atau *hidden layer* dalam jaringan [33].

2.6.4 Flatening

Flatening merupakan salah satu proses pada CNN yang mengkonversikan nilai dari *array* dua dimensi pada operasi *convolutional-pooling* menjadi sebuah vektor linear yang panjang dan bersambung, yang kemudian diteruskan ke tahap *fully-connected layer* [34].




Gambar 2.17 Proses *Flattening* setelah dilakukan *pooling*

(Sumber: <https://medium.com>)

Pada gambar 2.17 di atas menjelaskan tentang proses perubahan dari *input layer-convolutional-pooling* pada tahap CNN yang terakhir yaitu tahap *flattening*, pada tahap ini kumpulan layer akan diubah kedalam bentuk vektor linear. Vektor linear ini akan dijadikan sebagai masukan tahap *classification* menggunakan metode dari ANN.

2.6.5 Fully-connected Layer

Setelah tahap konvolusi dan penggabungan pada *convolutional layer* dan *pooling layer* data diubah menjadi vektor satu dimensi. Kemudian seluruh vektor ini akan dijadikan sebagai masukan untuk *fully-connected layer* (dapat dilihat pada gambar). Struktur *fully-connected* bisa berisi satu atau dua *hidden layer*. Setiap neuron mengalikan dengan jumlah koneksi dari bobot dengan data dari lapisan sebelumnya dan menambahkannya dengan nilai bias. Nilai yang telah dihitung akan masuk ke fungsi aktivasi sebelum dikirim ke lapisan berikutnya.



Gambar 2.18 Mekanisme *fully-connected* layer pada tahap klasifikasi

(Sumber: <https://www.researchgate.net/>)


Pada gambar 2.18 diatas menjelaskan mengenai proses pada *fully-connected* pada layer *fully-connected layer* setelah mengalami *flattening* nilai pada *fully-connected* layer akan menjadi masukan untuk proses klasifikasi dengan fungsi aktivasi yang digunakan, dengan mengambil nilai yang dominan pada setiap neuron.

2.6.6 Activation Layer

Activation layer merupakan lapisan penerapan fungsi aktivasi. Tujuan penggunaan fungsi aktivasi yaitu untuk melakukan pengaktifan terhadap neuron. Fungsi aktivasi terbagi menjadi dua jenis yaitu fungsi linear, dan non-linear. Pada kasus yang lebih kompleks fungsi aktivasi non-linear lebih disarankan untuk digunakan karena bisa menyusun konsep yang berbeda secara bersamaan. Sehingga mampu memecahkan masalah yang kompleks.

1. Rectified Linear Unit (ReLU)

Rectified Linear Unit (ReLU) merupakan salah satu fungsi aktivasi yang terkenal. *ReLU* adalah operasi antara sebuah input dengan jangkauan $0-\max(x,0)$. Memiliki properti dengan aturan pada bagian ujung dari garis gradient tidak menyentuh nilai 0, sehingga membantu kecepatan konvergensi dalam pelatihan jaringan saraf. Berikut merupakan grafik dari fungsi aktivasi *ReLU*:




Gambar 2.19 Grafik fungsi aktivasi *non-linear* ReLU

(Sumber: <https://medium.com/@opam22>)

2. *Leaky ReLU*

Fungsi aktivasi *ReLU* memiliki beberapa permasalahan berupa matinya beberapa neuron ketika output telah mencapai nilai 0. Menyebabkan setengah dari total keseluruhan neuron akan mati. Hal ini terjadi ketika mengatur kecepatan *learning rate* sebuah model dengan nilai yang besar, dan bobotnya di-*update* sehingga jumlah bobotnya akan bernilai negatif. Ketika bobot bernilai negatif, fungsi aktivasi *ReLU* akan mengatur nilai bobot negatif tersebut menjadi 0, sehingga penurunan *gradient descent* tidak berpengaruh sehingga menyebabkan neuron akan mati.

Untuk mengatasi hal tersebut muncul fungsi aktivasi baru yaitu *Leaky ReLU* (*Leaky Rectified Linear Unit*) merupakan perkembangan dari fungsi aktivasi *ReLU*. Perkembangan ini merupakan perbaikan dari *ReLU*, terkait kebocoran bobot yang bernilai negatif. *Leaky ReLU* akan menentukan hyperparameter a sebanyak jumlah fungsi yang bocor dengan kemiringan fungsi $z < 0$ dengan tingkat kemiringan yang kecil, sehingga mampu memastikan neuron-neuron terhadap bobot negatif tidak mati.



Gambar 2.20 Grafik fungsi aktivasi *non-linear leaky ReLU*

(Sumber: <https://medium.com>)

3. *Softmax*


Softmax merupakan salah satu fungsi aktivasi yang digunakan sebagai *classifier* berdasarkan tingkat probabilitas. *Softmax* merupakan fungsi aktivasi yang dikembangkan berdasarkan fungsi aktivasi *sigmoid*. Fungsi aktivasi ini digunakan sebagai *classifier multi-class classification* [28]. Selain itu *Softmax* bisa digunakan untuk *binary classification* karena sifatnya yang menggeneralisasi fungsi aktivasi dari *sigmoid* yang merupakan fungsi aktivasi untuk kasus *binary classification* [35].

2.6.7 *Resizing*

Resizing merupakan salah satu teknik dasar dari pengelolaan gambar dan merupakan langkah sebelum melakukan pemrosesan gambar yang penting dalam penerapan *deep learning*. Setiap nilai piksel pada gambar yang diubah ukurannya adalah rata-rata tertimbang dari kumpulan piksel yang sesuai [5].

2.6.8 *Dropout Regularization*

Dropout merupakan salah satu teknik yang berfungsi untuk mengurangi *overfitting*. Teknik ini bekerja dengan menghilangkan neuron yang dipilih secara acak kemudian dijadikan nilai 0 selama pelatihan. Setelah neuron dipilih, neuron akan diubah pada setiap iterasi pelatihan. Sehingga proses *learning* menjadi lebih handal. Penggunaan *dropout* dapat dilihat pada gambar berikut.



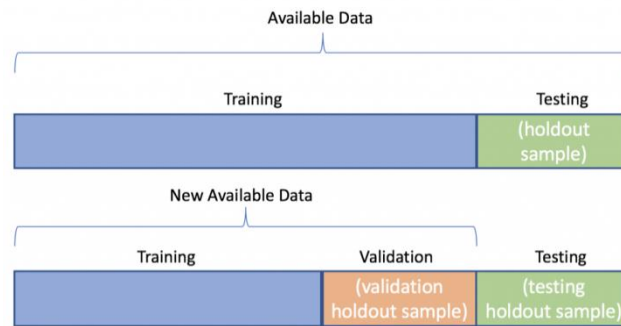
Gambar 2.21 (a) Jaringan tanpa *dropout regularization*. (b) Jaringan dengan *dropout regularization*

(Sumber: <https://www.baeldung.com>)

Gambar 2.21 merupakan salah satu penerapan dari penggunaan *dropout* pada gambar (a) menjelaskan sebuah jaringan memiliki neuron yang penuh, sehingga berpengaruh terhadap waktu komputasi, dan hasil akurasi dari sebuah model. Pengaruh komputasi yaitu banyaknya *weight* yang terhubung dengan seluruh *neuron* memungkinkan untuk menghitung masing-masing nilai, sedangkan untuk hasil akurasi juga akan berpengaruh apakah sebuah metode menjadi *overfitting* atau tidak. Sedangkan pada gambar (b) menunjukkan penerapan *dropout* dengan menghapus beberapa *neuron* yang dianggap tidak terlalu berpengaruh dengan hasil akhir nantinya, dengan syarat penggunaan *dropout* tidak disarankan menggunakan nilai lebih dari 50%. Penggunaan *dropout* yang terlalu besar akan menghapus beberapa *neuron* yang dianggap penting [29].

2.7 Data Splitting

Jumlah data yang besar dan memiliki kompleksitas model biasanya memerlukan waktu pelatihan yang sangat lama. Oleh karena itu, hal sederhana yang bisa digunakan yaitu dengan melakukan pemisahan terhadap dataset, antara data pelatihan, dan data validasi [29].



Gambar 2.22 Pembagian data dengan *Data Splitting* dengan tiga bagian

(Sumber: <https://www.kdnuggets.com>)

Gambar 2.22 merupakan penerapan dari pembagian data dengan metode *split data*. Pada sebuah dataset data yang telah tersedia umumnya telah terbagi menjadi dua bagian yaitu data latih dan data uji, dengan syarat data latih tidak boleh lebih kecil dari data uji. Kemudian data uji tersebut akan dibagi lagi menjadi dua bagian sehingga menghasilkan jenis data baru yaitu data validasi yang nantinya akan dimasukkan kedalam proses pelatihan pada proses pembelajaran mesin.

2.8 Optimizer

Optimizer merupakan salah satu algoritma optimisasi yang berfungsi untuk mengurangi fungsi *loss* pada fungsi numerikal dengan memanfaatkan kalkulasi nilai objektif pada kumpulan prognostikator yang perlu diakses dengan model. Parameter yang menjadi perhitungan pada *optimizer* adalah nilai *bias*, dan bobot (*weight*) yang digunakan untuk memperoleh hasil keluaran dari jaringan saraf. *Optimizer* merupakan algoritma yang sangat penting dalam mengurangi nilai *loss* pada proses pelatihan data [36]. Berikut merupakan *optimizer* yang digunakan dalam mengurangi nilai *loss*.

2.8.1 Adaptive Moment Estimation (Adam)

Adam merupakan *optimizer* yang menggunakan pendekatan yang efektif dalam meningkatkan gradien stokastik. *Adam* merupakan penggabungan antara *RMSProp*, dan *AdaGrad* yang tidak hanya memanfaatkan rata-rata dari momen

pertama, melainkan juga memanfaatkan rata-rata terhadap momen kedua gradien [20].

2.8.2 Adaptive Moment Maximum (Adamax)

Adamax merupakan variasi lanjutan dari adam, yang memanfaatkan peningkatan momentum secara maksimal tanpa akhir [36]. Adamax melakukan perubahan *Gradient Descent Optimization* (GDO) Adam yang sebelumnya melakukan pembaharuan bobot yang semula memiliki *norm* berskala kuadrat menjadi *norm* tidak terbatas.

2.9 Confusion Matrix

Confusion Matrix merupakan alat yang berfungsi untuk melakukan analisis pada mekanisme klasifikasi dalam mengenali tuple dan kelas yang berbeda. Nilai dari *True-Positive* dan *True-Negative* memberikan informasi pada *classifier* dalam melakukan klasifikasi yang benar, sedangkan *False-Positive* dan *False-Negative* memberikan informasi ketika *classifier* salah dalam melakukan klasifikasi data. Terdapat 4 aturan yang berfungsi mengenali tuple diantaranya yaitu:

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	<p>TP (True Positive)</p>	<p>FP (False Positive) <i>Type I Error</i></p>
	0 (Negative)	<p>FN (False Negative) <i>Type II Error</i></p>	<p>TN (True Negative)</p>

Gambar 2.23 Confusion Matrix Maps untuk tahap klasifikasi

(Sumber: <https://medium.com>)

1. *True Positive* (TP) yaitu jumlah data dengan nilai sebenarnya positif dan nilai prediksi positif.
2. *False Positive* (FP) yaitu jumlah data dengan nilai sebenarnya negatif dan nilai prediksi positif.

3. *False Negative* (FN) yaitu jumlah data dengan nilai sebenarnya positif dan nilai prediksi negatif.
4. *True Negative* (TN) yaitu jumlah data dengan nilai sebenarnya negatif dan nilai prediksi negatif [37].

2.9.1 Precision

Precision merupakan salah satu matriks yang diperoleh melalui analisa pada *confusion matrix*. Perhitungan dari *precision* berdasarkan tingkat probabilitas yang merepresentasikan sebuah objek ketika prediksi tes bernilai positif, dengan kata lain. Rasio dari jumlah prediksi Benar Positif dibandingkan dengan keseluruhan dari hasil prediksi yang bernilai Positif. *precision* juga disebut sebagai *positive predictive value* [38].

2.9.2 Recall

Recall merupakan salah satu matriks yang diperoleh melalui analisa pada *confusion matrix*, dengan perhitungan rasio dari prediksi benar positif, dibandingkan dengan keseluruhan data benar positif.

2.9.3 F1-Score

F1-Score merupakan salah satu matriks yang diperoleh dari penggabungan probabilitas rata-rata harmonik *precision* dan probabilitas *recall*. *F1-Score* akan memberlakukan nilai menjadi sama, dengan aturan jika nilai rata-rata harmonik memberikan bobot yang besar, maka nilai akan menjadi lebih rendah. Apabila nilai *precision* dan *recall* lebih tinggi pada tahap prediksi klasifikasi, maka probabilitas dari *F1-Score* akan ikut tinggi [38]. *F1-Score* sendiri digunakan untuk mengatur permasalahan data yang *imbalance* sehingga tidak semua matriks akurasi bisa diterapkan untuk beberapa kasus. Namun, *F1-Score* dinilai matriks terbaik karena tidak hanya memperhitungkan prediksi yang benar, melainkan juga memperhitungkan prediksi yang salah.

2.10 Arsitektur Convolutional Neural Network (CNN)

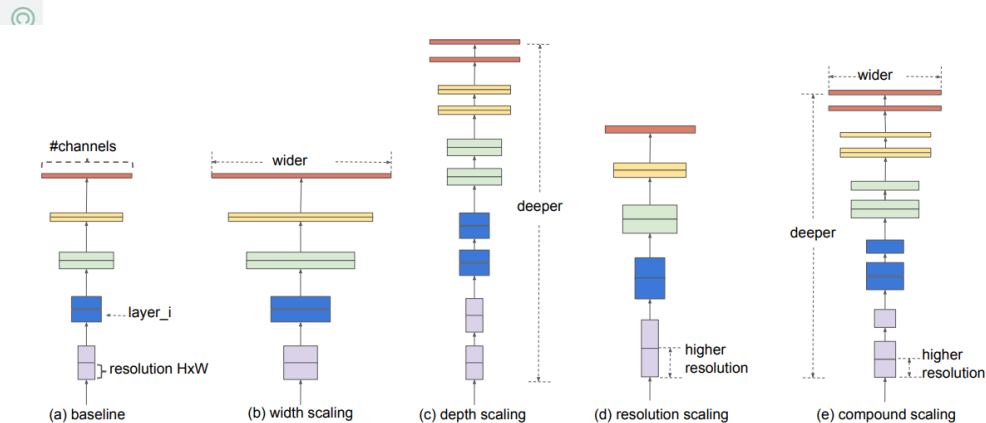
Melakukan pemodelan arsitektur CNN yang sempurna melibatkan banyak eksperimen dan penggunaan daya komputasi yang besar. Beberapa perusahaan

terkenal yang terlibat dalam pengembangan model arsitektur yaitu google dengan *googleNet*, *MobileNet*. Facebook Research AI, dan beberapa perusahaan yang bergerak dibidang *research* lainnya. Dengan dilakukannya pengembangan arsitektur tersebut mempermudah bagi para pengembang, peneliti, dan pihak lainnya dalam melakukan penerapan penggunaan *deep learning* di bidang.

2.10.1 *EfficientNet*

EfficientNet merupakan serangkaian model yang diturunkan dari jaringan dasar, dilakukan dengan pengaturan penskalaannya. Kelebihan dari *EfficientNet* yaitu memberikan akurasi yang tinggi, dan mampu memperbaiki efektivitas model, dengan melakukan pengurangan parameter dan *Floating Point Operations Per Second* (FLOPS) berikut merupakan struktur dari arsitektur *EfficientNet*.

EfficientNet melakukan pemodelan arsitektur baru yang memanfaatkan *depth*, *width*, dan *resolution* dari sebuah *network* sehingga menghasilkan kinerja yang bagus. Khususnya dari segi komputasi dan ukuran parameter, *EfficientNet-B7* mencapai *top-1 accuracy* dengan *state-of-the-art* 84,3%, atau 6,1 kali lebih cepat, dan 8,4 kali lebih kecil dibandingkan arsitektur *GPipe* yang merupakan *state-of-the-art ImageNet top-1 validation accuracy* pada tahun 2018, dengan tingkat akurasi sebesar 84,3% dan jumlah parameter 557 juta parameter. Arsitektur *EfficientNet-B1* berukuran 5,7 kali lebih cepat dan 7,6 kali lebih kecil dibandingkan *ResNet-152* yang merupakan pemenang *ILSVRC* pada tahun 2015 dengan jumlah parameter 60 juta parameter. Tingkat akurasi dan tingkat efisiensi yang tinggi, menjadikan arsitektur *EfficientNet* lebih baik dari arsitektur CNN sebelumnya [11]. Berikut merupakan struktur dari arsitektur *EfficientNet*.




Gambar 2.24 Struktur metode *EfficientNet state-of-the-art 2019*

EfficientNet mengadopsi metode skala penggabungan pada semua dimensi jaringan (*network*) diantaranya yaitu lebar (*width*) mengacu pada jumlah *channel* pada lapisan manapun, kedalaman (*depth*) mengacu pada jumlah lapisan di CNN, dan resolusi (*Resolution*) mengacu pada ukuran resolusi gambar yang digunakan. Selain itu *EfficientNet* mendapat perhatian khusus karena kemampuannya dalam melakukan prediksi. Intuisi menggunakan penskalaan gabungan merupakan penskalaan dimensi pada jaringan yang mampu meningkatkan akurasi, tetapi untuk model yang lebih besar, perolehan akurasi akan semakin berkurang. Untuk melakukan penskalaan dimensi jaringan secara sistematis, penskalaan gabungan menggunakan gabungan koefisien yang mampu mengontrol berapa banyak sumber daya yang bisa berfungsi dalam penskalaan model [39].

EfficientNet mengungguli hampir seluruh arsitektur CNN pada periode sebelumnya salah satu contoh yaitu *EfficientNet-B7* mencapai tingkat *top-1 accuracy* dengan nilai akurasi 84,3% yang berarti mengungguli berbagai arsitektur CNN lainnya. Jika dibandingkan dengan arsitektur yang merupakan arsitektur terbaik pada tahun 2018 yaitu *GPipe*, *EfficientNet* memiliki parameter 8,4 kali lebih kecil dari *GPipe*, dan 6,1 kali lebih cepat dari *GPipe*. Berikut diagram akurasi *EfficientNet* terhadap beberapa arsitektur lainnya.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Gambar 2.25 Tingkat akurasi arsitektur *imagenet Top-1*

Gambar 2.25 merupakan grafik tingkat akurasi dari arsitektur *EfficientNet*. Arsitektur *EfficientNet-B1* mengungguli dari tingkat akurasi yaitu 79,1%, dan akurasi *ResNet-152* sebesar 77,8%, yang berarti *EfficientNet-B1* 1,3% memiliki akurasi yang lebih tinggi. Selain itu *EfficientNet-B1* berukuran 5,7 kali lebih cepat dan 7,6 kali lebih kecil dari *ResNet-152* dari segi komputasi. Berikut beberapa pembagian model *EfficientNet*:

Tabel 2.1 Model-model arsitektur *EfficientNet*

Model	Top-1 Acc.	Top-5 Acc.	#Params	#FLOPs
<i>EfficientNet-B0</i>	77.1%	93.3%	5.3M	0.39B
<i>EfficientNet-B1</i>	79.1%	94.4%	7.8M	0.70B
<i>EfficientNet-B2</i>	80.1%	94.9%	9.2M	1.0B
<i>EfficientNet-B3</i>	81.6%	95.7%	12M	1.8B
<i>EfficientNet-B4</i>	82.9%	96.4%	19M	4.2B
<i>EfficientNet-B5</i>	83.6%	96.7%	30M	9.9B

<i>EfficientNet-B6</i>	84.0%	96.8%	43M	19B
<i>EfficientNet-B7</i>	84.3%	97.0%	66M	37B

Selain itu, *EfficientNet-B1* merupakan arsitektur yang memiliki hasil prediksi *F1-Score* terbaik pada gambar dengan citra RGB. Salah satu kasus penggunaannya yaitu pada klasifikasi jenis buah dengan menggunakan *Transfer Learning EfficientNet* [12]. Hasil prediksi *F1-Score* tersebut diperoleh hasil dengan tabel sebagai berikut:

Tabel 2.2 Hasil *F1-Score* pada klasifikasi jenis buah citra RGB

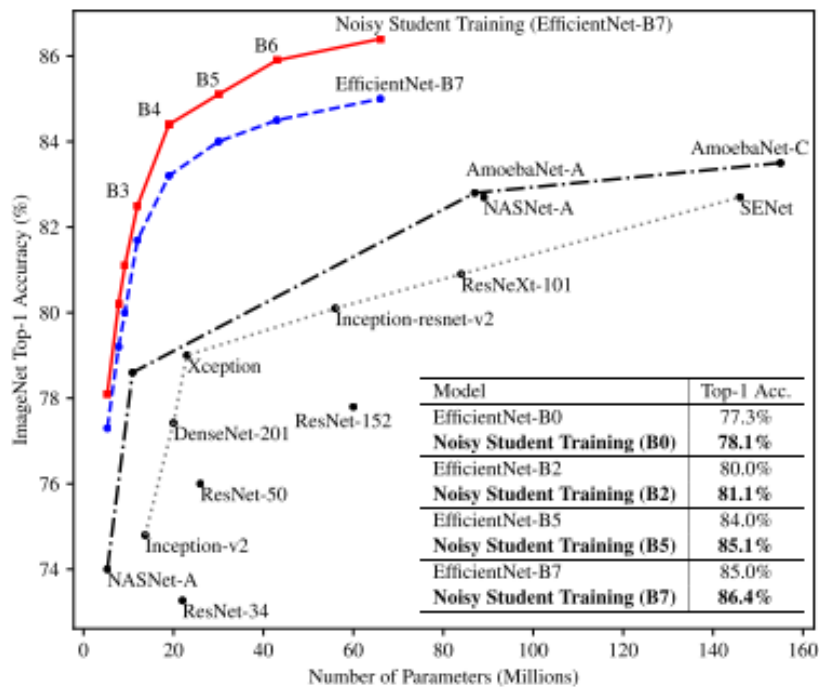
<i>Models</i>	<i>Transfer Learning</i>		
	ηP	ηR	$\eta F1$
<i>EfficientNet-B0</i>	94	93	92
<i>EfficientNet-B1</i>	95	95	95
<i>EfficientNet-B2</i>	94	94	93
<i>EfficientNet-B3</i>	94	94	93
<i>EfficientNet-B4</i>	94	94	93
<i>EfficientNet-B5</i>	94	93	92
<i>EfficientNet-B6</i>	91	89	85
<i>EfficientNet-B7</i>	89	80	76

EfficientNet mengalami perkembangan pemodelan. Pada tahun 2020 dilakukan penelitian untuk menemukan model terbaik dengan memanfaatkan arsitektur *EfficientNet*, model tersebut bernama *Noisy Student*. *Noisy Student* merupakan model yang dikembangkan berdasarkan hubungan pembelajaran dari guru ke murid, dengan memanfaatkan *dropout*, *stochastic depth*, dan *Random Augmentation*. *Random Augmentation* yang digunakan pada *noisy student*

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

bertujuan untuk memastikan konsistensi dari hasil prediksi pada seluruh gambar yang diperbesar. Sebagai contoh, guru akan membaca sebuah gambar yang bersih, kemudian menentukan label semu berkualitas tinggi, sedangkan murid akan diminta untuk menentukan label dari sebuah gambar yang diperbesar sebagai masukan. Sedangkan *dropout*, dan *stochastic depth* digunakan untuk membuat *noisy*-nya. Yaitu guru akan menemukan pencarian prediksi yang terbaik (ketika menghasilkan label semu). Sedangkan siswa akan berperilaku seperti model tunggal yang dipaksa mengikuti prediksi yang terbaik dari guru.



Gambar 2.26 Grafik Top-1 Accuracy ImageNet noisy student

Gambar 2.26 merupakan *state-of-the-art top-1 Accuracy ImageNet* dari beberapa arsitektur dengan nilai akurasi 86.4% yang dipegang oleh *EfficientNet-B7* yang mengalami penambahan akurasi dari arsitektur *EfficientNet-B0* - *EfficientNet-B7*, namun tetap mempertahankan jumlah parameter. Agar waktu komputasi tetap seimbang.

Tabel 2.3 Daftar Arsitektur *EfficientNet* model training noisy student

<i>Model</i>	<i>Top-1 Acc.</i>	<i>Top-5 Acc.</i>	<i>#Params</i>
<i>EfficientNet-B0 Noisy Student Training (B0)</i>	77.1% 78.1%	93.3% 94.2%	5.3M
<i>EfficientNet-B1 Noisy Student Training (B1)</i>	79.1% 80.2%	94.4% 95.2%	7.8M
<i>EfficientNet-B2 Noisy Student Training (B2)</i>	80.1% 81.1%	94.9% 95.5%	9.2M
<i>EfficientNet-B3 Noisy Student Training (B3)</i>	81.6% 82.5%	95.7% 96.4%	12M
<i>EfficientNet-B4 Noisy Student Training (B4)</i>	82.9% 84.4%	96.4% 97.0%	19M
<i>EfficientNet-B5 Noisy Student Training (B5)</i>	83.6% 85.1%	96.7% 97.3%	30M
<i>EfficientNet-B6 Noisy Student Training (B6)</i>	84.0% 85.9%	96.8% 97.6%	43M
<i>EfficientNet-B7 Noisy Student Training (B7)</i>	84.3% 86.4%	97.0% 97.9%	66M

Noisy Student tetap memanfaatkan jumlah parameter pada *EfficientNet*, namun mampu meningkatkan akurasi dari arsitektur *EfficientNet*. Peningkatan akurasi ini dibuktikan dengan perolehan nilai akurasi yang menjadi *top-1 accuracy* dengan *state-of-the-art* 88.4%. Model ini dibuat dengan melakukan eksperimen terhadap seluruh arsitektur yang masuk kedalam *state-of-the-art imagenet* dari tahun 2012 hingga 2019. Dengan nilai akhir, *accuracy* tertinggi dipegang oleh *EfficientNet* [13].

2.11 Penelitian Terkait

Tabel berikut ini merupakan tabel yang berisikan kumpulan jurnal-jurnal tentang penelitian terdahulu yang berkaitan dengan penelitian pada tugas akhir ini.

Tabel 2.4 Penelitian Terkait

No	Author	Tahun	Judul Penelitian	Metode	Kesimpulan
1.	Hannan, Muhammad A	2021	<i>SOC Estimation of Li-Ion Batteries With Learning Rate-Optimized Deep Fully Convolutional Network</i>	<i>LSTM, GRU, dan CNN</i>	Penerapan algoritma <i>CNN</i> untuk menghitung estimasi <i>Batteries Li-Ion</i> yang menghasilkan <i>RMSE</i> sebesar 0,85%
2.	Rima Dias Ramadhan i, Afandi Nur Aziz Thohari, Condro Kartiko, Apri Junaidi, Tri Ginanjar Laksana, dan Novanda Alim Setya Nugraha	2021	<i>Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah</i>	<i>CNN</i>	Penerapan metode <i>CNN</i> untuk klasifikasi jenis sampah yang dikumpul melalui <i>google</i> gambar dengan <i>tuning hyperparameter</i> dengan akurasi terbaik dengan <i>hyperparameter</i> sebesar 91,2%.
3.	Hao-na Guo, Shu-biao Wu, Yingg-jie Tian, Jun Zhang, Hong-tao Liu	2020	<i>Application of machine learning methods for the prediction of organic solid waste treatment and recycling process: A review</i>	<i>CCN+SVM</i>	Penerapan <i>Artificial Neural Network</i> terhadap pemilahan sampah organik dan daur ulang terhadap Dengan menggunakan <i>CNN+SVM</i> dengan Ukuran data 22.222 data dengan akurasi 99.95%

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

- Hak Cipta Dilindungi Undang-Undang
- © Hak cipta milik UIN Suska Riau
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
 2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

4.	Dipesh Gyawali, Alok Regmi, Aatish Shakya, Ashish Gautam, Surendra Shrestha	2020	<i>Comparative Analysis of Multiple Deep CNN Models for Waste Classification</i>	<i>VGG16, ResNet-18, ResNet-50</i>	Klasifikasi sampah dengan metode R-CNN dengan melakukan perbandingan antara <i>ResNet-18</i> , <i>ResNet-50</i> , dan <i>VGG16</i> dengan jumlah dataset 3102 gambar sampah. Yang terbagi menjadi 4 kelas. Metode yang memiliki akurasi tertinggi adalah <i>ResNet-18</i> dengan nilai <i>accuracy</i> 87.8 %
5.	Leonardo, Yohanner, Ery Hartati	2020	Klasifikasi Sampah Daur Ulang Menggunakan <i>Support Vector Machine</i> dengan Fitur <i>Local Binary Pattern</i>	LBP+SVM	Penerapan SVM dengan metode ekstraksi fitur menggunakan <i>Local Binary Pattern</i> , dengan dataset yang digunakan terdiri dari lima kelas yaitu <i>cardboard</i> , <i>glass</i> , <i>metal</i> , <i>paper</i> , dan <i>plastic</i> . Dengan jumlah dataset yang digunakan yaitu 2390 gambar. Dengan hasil akurasi dengan rata-rata 87.82%
6.	Linh Duong Tuan,	2020	<i>Automated Fruit recognition</i>	<i>CNN(Efficient Net</i> , dan <i>MixNet)</i>	Penerapan terhadap klasifikasi

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

7.	Claudio Di Sipio, Phuong Nguyen, dan Davide Di Ruscio		<i>using EfficientNet and MixNet</i>		kelompok buah dengan menggunakan arsitektur <i>EfficientNet-B0-B7</i> , dan arsitektur <i>MixNet</i> diperoleh nilai <i>F1-Score</i> tertinggi yaitu 95% pada <i>EfficientNet-B1</i>
7.	M Fadhilur Rahman, dan Bambang	2020	Deteksi Sampah pada Real-time Video Menggunakan Metode <i>Faster R-CNN</i>	<i>R-CNN</i>	Penerapan metode <i>faster R-CNN</i> dalam melakukan klasifikasi secara <i>real-time</i> terhadap 100 gambar yang menghasilkan akurasi 74%
8.	Achmad Bisri, dan Rinna Rachmatika	2019	Integrasi <i>Gradient Boosted Trees</i> dengan <i>SMOTE</i> dan <i>Bagging</i> untuk Deteksi Kelulusan Mahasiswa	Gradient Boosted Trees	Penerapan algoritma <i>GBT</i> untuk melakukan klasifikasi terhadap kelulusan mahasiswa dengan hasil <i>AUC 0,958</i>
9.	Mingxing Tan, Quoc V.Le	2019	<i>EfficientNet: Rethinking Model Scaling for Convolutional Meural Networks</i>	CNN	Penerapan terhadap data dari <i>imageNet</i> untuk membuat arsitektur baru yang mengadopsi pelebaran <i>channel</i> , kedalaman <i>layer</i> , dan resolusi gambar sehingga

- Hak Cipta Diindungi Undang-Undang
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
 2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

10	Qizhe Xie, Quoc V. Le, Minh-Thang Luong, Eduard Hovy, Google Reserch, Brain Team, Carnegie Mellon University	2020	<i>Self-training with Noisy Student improves ImageNet classification</i>	CNN	menghasilkan arsitektur baru bernama <i>EfficientNet</i> . Penerapan metode <i>EfficientNet</i> model <i>Noisy Student</i> untuk klaisifikasi dataset dari <i>ImageNet</i> tanpa menambah jumlah parameter <i>EfficientNet</i> namun tetap meningkatkan akurasi <i>state-of-the-art</i> 2020 86,4%.
11	Vi Nguyen Thanh Le, Selam Ahderom, dan Kamal Alameh	2020	<i>Performance of the LBP Based Algorithm over CNN Models for Detecting Crops, and Weeds with Similar Morphologies</i>	<i>LBP, VGG-16, VGG-19, ResNet-50, dan InceptionV3</i>	Eksperimen dilakukan terhadap data gulma yang telah dikumpulkan dari ladang pertanian dengan hasil akurasi untuk <i>LBP</i> 98,60%, dan rata-rata arsitektur CNN memperoleh rata-rata akurasi diatas 99%
12	ANH H. VO, LE HOANG SON, MINH THANH VO, AND TUONG LE	2019	<i>A Novel Framework for Trash Classification Using Deep Transfer Learning</i>	<i>ResNext, RecycleNet, ResNet_Ruiz, DNN-TC, Densenet121_Aral</i>	Penerapan <i>DNN-TC</i> yang merupakan arsitektur diatas <i>Resnext</i> . Dengan jumlah dataset 5904 gambar yang terdiri dari tiga

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

© Hak cipta milik UIN Suska Riau				kelas yang berbeda organik, anorganik, dan sampah medis dengan <i>accuracy</i> 94% dan 98% <i>accuracy</i> untuk <i>TrashNet</i> dan <i>VN-trash</i> .
13.	Md. Samiul Haque Sunny, Debopriya Roy Dipta, Shifat Hossein, Hossain Mansur Resalat Faraque, Eklas Hossain	2019	<i>Design of a Convolutional Neural Network Based Smart Waste Disposal System</i>	<i>AlexNet</i> Penerapan arsitektur <i>AlexNet</i> pada metode CNN untuk tempat sampah pintar. Dengan jumlah dataset yang digunakan yaitu 200 gambar yang terdiri dari 10 kelas. Dengan akurasi 96%
14.	Xiangpo Wei, Xuchu Yu, Bing Liu, and Lu Zh	2019	<i>Convolutional Neural Network and local binary patterns for hyperspectral image classification</i>	<i>CNN, LBP</i> Penerapan terhadap metode <i>CNN</i> , dan <i>LBP</i> dalam mengekstrak fitur pada data <i>Indian Pines</i> , <i>Pavia of University</i> , dan <i>Salnas</i> . Masing-masing menghasilkan skor akurasi 98,52%, 99,54%.
15.	Stephenn L. Rabano, Melvin K. Cabatuan, Edwin Sybingco,	2018	<i>Common Garbage Classification Using MobileNet</i>	<i>MobileNet</i> Klasifikasi sampah menggunakan arsitektur <i>MobileNet</i> dengan



Elmer P. Dadios, Edwin J. Calilung				perolehan tingkat akurasi 87.2%
------------------------------------	--	--	--	---------------------------------

© Hak cipta milik UIN Suska Riau

State Islamic University of Sultan Syarif Kasim Riau

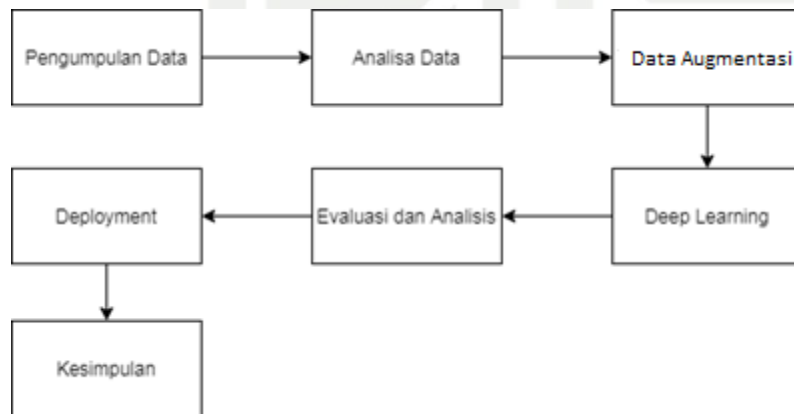
Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



BAB 3 METODOLOGI PENELITIAN

Metodologi penelitian adalah tahapan yang nantinya akan dilakukan dalam penelitian. Metodologi penelitian bertujuan sebagai acuan dalam melakukan penelitian agar tujuan yang diharapkan dapat tercapai. Metodologi penelitian dilakukan secara terurut.



Gambar 3.1 Metodologi Penelitian

3.1 Pengumpulan Data

Pengumpulan data pada penelitian ini dilakukan dengan menggunakan data yang diambil secara langsung dari Tempat Pembuangan Sampah (TPS) kota Selatpanjang. Data yang dikumpulkan berupa gambar bahan-bahan rumahan dan industri sebanyak 1.041 citra yang terbagi menjadi 2 kelas, yaitu kelas organik dan anorganik(*recycle*), setiap kelas terdiri dari sebagai berikut: bahan organik memiliki 556 gambar, sedangkan bahan anorganik(*recycle*) memiliki gambar 485 gambar.


3.2 Analisa Data

Analisis dilakukan untuk melihat bentuk dan struktur dari gambar dataset yang telah diperoleh. Berdasarkan dataset jenis sampah, jumlah data yang dimiliki yaitu *balance dataset*. Hal ini terlihat dari jumlah data dari kelas organik

berjumlah 556 dan kelas anorganik (*recycle*) berjumlah 485. Dari jumlah tersebut hanya memiliki perbedaan data yang tidak signifikan sehingga masih bisa dinilai data yang telah terkumpulkan merupakan data yang *balance*.

3.3 Analisa Data

Pada penelitian ini, dilakukan untuk memudahkan mendapatkan nilai *feature extraction*. Augmentasi data digunakan untuk memperkaya jumlah data dengan banyaknya *feature* yang terbentuk. Dari dataset yang telah diperoleh, dilakukan beberapa tindakan augmentasi yaitu *rotation 90*, *vertical flip*, dan *rotation vertical flip*. Gambar dataset yang digunakan dinilai masih kurang, dan perlu penambahan variasi dari setiap data dengan menggunakan augmentasi yang berpengaruh terhadap pengambilan nilai *feature extraction*. Berikut merupakan alur augmentasi data:



Gambar 3.2 Alur tahap augmentasi data pada gambar sampah

3.4 Deep Learning

Penerapan *deep learning* pada penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *EfficientNet-B1*. Setelah dilakukan proses augmentasi data tahap selanjutnya yaitu melakukan eksperimen.

3.4.1 Feedforward

Feedforward merupakan salah satu perhitungan nilai terhadap *neuron-neuron* pada proses *Artificial Neural Network* (ANN) yang diterapkan pada MLP *deep learning*, dihitung menggunakan rumus:

$$o_j = \sigma \left(\sum_{k=1}^K x_k w_{k,j} + \beta_j \right) \quad (3.1)$$

$$v_j = \sigma \left(\sum_{j=1}^J o_j u_{j,i} + \gamma_i \right) = \sigma \left(\sum_{j=1}^J \sigma \left(\sum_{k=1}^K x_k w_{k,j} + \beta_j \right) u_{j,i} + \gamma_i \right) \quad (3.2)$$

Keterangan:

o_j = Keluaran *hidden layer* pertama

v_j = Keluaran pada *output layer*

σ = Fungsi aktivasi

K, J = Banyak unit masukan

x = Nilai masukan

w, u = Bobot

β, γ = Bias

Persamaan rumus 3.1 merupakan rumus yang digunakan pada proses *feedforward* dimana o_j merupakan hasil output yang akan dijadikan nilai input untuk tiap-tiap neuron pada *output layer*. x merupakan nilai pada neuron *input layer*. w , dan u merupakan *weight* (bobot) yang menjadi *learning parameters*. β_j dan γ_i adalah nilai bias. K merupakan banyaknya *input layer*, dan J banyaknya *hidden layer*. σ melambangkan fungsi aktivasi. v_j merupakan hasil output dari *output layer*.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

3.4.2 Backpropagation

Tahap ini merupakan tahap yang dilakukan pada proses *deep learning* untuk melakukan *update weight*(bobot), untuk menghasilkan tingkat *loss* terkecil. Sehingga model menjadi lebih baik.

$$Loss = (Output Target - Output Prediction)^2 \quad (3.3)$$

Keterangan:

Loss = Nilai *loss* untuk perubah bobot, dan bias

Output target = Kelas yang sebenarnya


Output prediction = Kelas hasil prediksi setelah *feedforward*

Dari rumus 3.3 diatas akan diperoleh jika nilai *Loss* yang diperoleh memiliki nilai yang lebih besar, maka mesin akan melakukan *backpropagation* dengan melakukan *update* terhadap *weight* pada *layer* sebelumnya. Proses ini berlangsung hingga nilai *loss* yang diperoleh bernilai kecil.

Hak Cipta Diindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

3.4.3 Arsitektur *EfficientNet-B1*



Gambar 3.3 Arsitektur *EfficientNet* sub *EfficientNet-B1*

Pada gambar diatas menjelaskan tahapan arsitektur *EfficientNet-B1* yang akan diterapkan pada penelitian ini untuk klasifikasi jenis sampah. Berikut ini adalah tahapan-tahapan arsitektur *EfficientNet-B1* dalam melakukan klasifikasi gambar:

- © Hak cipta milik UIN Suska Riau
1. Data gambar bahan organik dan anorganik yang telah dilakukan augmentasi data dengan ukuran 240 x 240 digunakan sebagai data masukan.
2. *Stage 1* :
- Pada tahap ini dilakukan operasi *convolutional* filter 3 x 3 menghasilkan *feature maps* 32 channel.
 - Dilakukan proses *Batch Normalization*.
 - Kemudian dilakukan proses *activation function* menggunakan ReLU.
3. *Stage 2*:
- Pada tahap ini dilakukan operasi *Deep Wise Convolutional* menghasilkan *feature maps* filter 3 x 3 menghasilkan *feature maps* 16 channel.
 - Dilakukan proses *batch normalization*
 - Kemudian dilakukan proses *activation function* menggunakan ReLU.
 - Kemudian dilakukan *Global Average Pooling*
 - Kemudian dilakukan *reshape*
 - Kemudian dilakukan 3 kali *convolutional* dengan filter 3 x 3 menghasilkan *feature maps* channel 16 channel.
 - Kemudian dilakukan *batch normalization*.
4. *Stage 3*:
- Pada tahap ini dilakukan operasi *convolutional* filter 3 x 3 menghasilkan *feature maps* 24 channel.
 - Dilakukan proses *batch normalization*.
 - Kemudian dilakukan *activation function* menggunakan ReLU.
 - Kemudian dilakukan proses pada MBConv1 dengan *filter* 3x3.
 - Kemudian dilakukan *dropout*
5. *Stage 4*:
- Pada tahap ini dilakukan operasi *convolutional* filter 5 x 5 menghasilkan *feature maps* 40 channel.
 - Dilakukan proses *batch normalization*.
 - Kemudian dilakukan *activation function* menggunakan ReLU.
 - Kemudian dilakukan proses pada MBConv1 dengan *filter* 5 x 5.

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

- e. Kemudian dilakukan *dropout*
6. *Stage 5:*
 - a. Pada tahap ini dilakukan operasi *convolutional* filter 3 x 3 menghasilkan *feature maps* 80 *channel*.
 - b. Dilakukan proses *batch normalization*.
 - c. Kemudian dilakukan *activation function* menggunakan *ReLU*.
 - d. Kemudian dilakukan proses pada MBConv1 dengan *filter* 3 x 3.
 - e. Kemudian dilakukan *dropout*
 7. *Stage 6:*
 - a. Pada tahap ini dilakukan operasi *convolutional* filter 5 x 5 menghasilkan *feature maps* 112 *channel*.
 - b. Dilakukan proses *batch normalization*.
 - c. Kemudian dilakukan *activation function* menggunakan *ReLU*.
 - d. Kemudian dilakukan *activation convolutional* filter 5 x 5.
 - e. Kemudian dilakukan *dropout*
 8. *Stage 7:*
 - a. Pada tahap ini dilakukan operasi *convolutional* filter 5 x 5 menghasilkan *feature maps* 192 *channel*.
 - b. Dilakukan proses *batch normalization*.
 - c. Kemudian dilakukan *activation function* menggunakan *ReLU*.
 - d. Kemudian dilakukan *activation convolutional* filter 5 x 5.
 - e. Kemudian dilakukan *dropout*
 9. *Stage 8:*
 - a. Pada tahap ini dilakukan operasi *convolutional* filter 3 x 3 menghasilkan *feature maps* 320 *channel*.
 - b. Dilakukan proses *batch normalization*.
 - c. Kemudian dilakukan *activation function* menggunakan *ReLU*.
 - d. Kemudian dilakukan proses pada MBConv1 dengan *filter* 3 x 3.
 - e. Kemudian dilakukan *dropout*
 10. *Stage 9:*

- a. Pada tahap ini dilakukan *convolutional dimensi* dengan *filter* 3 x 3 menghasilkan *feature maps* 1280 *channel* .
- b. Dilakukan proses *batch normalization*.
- c. Kemudian dilakukan *activation function* menggunakan *ReLU*.
- d. Pada tahap ini dilakukan *convolutional 2 dimensi* dengan *filter* 1 x 1 menghasilkan *feature maps* 640 *channel* .
- e. Pada tahap *flatten* dilakukan perubahan output dari *convolutional filter* 1 x 1 menjadi *array* 1 dimensi.
- f. Output dari proses *flatten* akan dilakukan proses *fully connected layer*.
- g. Dilakukan pembuatan layer baru dengan jumlah 320 neuron
- h. Dilakukan proses *batch normalization*.
- i. Kemudian dilakukan *activation function* menggunakan *ReLU*.
- j. Melakukan pengurangan neuron dengan *dropout regularitation*.
- k. Kemudian dilakukan proses klasifikasi dengan *activation function softmax* untuk penentuan target kelas sampah organik atau sampah anorganik.

3.4.4 Convolutional

Arsitektur *EfficientNet-B1* model *noisy student* di atas menggunakan proses konvolusi (*convolution*). Dari *stage* 1, hingga tahap klasifikasi. Hasil dari konvolusi disebut dengan *feature maps* dan dimensi *feature maps* bisa dihitung menggunakan rumus *convolutional* yaitu:

$$\text{Output} = \frac{W - F + 2P}{S} + 1 \quad (3.4)$$

Keterangan:

W Ukuran gambar

F ukuran *filter*

P masukan *padding* yang digunakan

S ukuran pergeseran (*Stride*)

Operasi konvolusi diatas yaitu W sebagai ukuran gambar jika gambar berukuran 4×4 , filter 3×3 , tanpa padding ($P=0$), dan *stride default* ($S=1$). Maka hasil output yang diperoleh *feature maps* 2×2 .

3.4.5 Activation Function

1. ReLU

Fungsi Aktivasi (*Activation Function*) yang digunakan yaitu fungsi aktivasi *ReLU*. *ReLU* merupakan bawaan dari arsitektur *EfficientNet-B1* dengan fungsi persamaan sebagai berikut:

$$f(x) = \max(0, x) \quad (3.5)$$

Keterangan :

$f(x)$ = Fungsi aktivasi

x = Nilai masukan

Rumus 3.5 diatas merupakan aturan yang diterapkan pada *ReLU*. Dimana x adalah nilai masukan. Ketika nilai $x < 0$ maka hasil *output* yaitu bernilai 0. Dan ketika nilai $x \geq 0$ maka *output* yang diperoleh yaitu 1.

2. Leaky ReLU

Fungsi aktivasi yang digunakan pada tahap klasifikasi yaitu *Leaky ReLU*. Karena *Leaky ReLU* dinilai bisa mempertahankan nilai negatif sehingga tetap menjaga *feature* yang terbentuk. Karena sifatnya yang tidak akan menonaktifkan *neuron* ketika hasil masukan bernilai negatif.

$$f(x) = \max(ax, x) \quad (3.6)$$

Keterangan :

$f(x)$ = Fungsi ativasi

x = Nilai masukan

Rumus 3.6 diatas merupakan rumus dari *Leaky ReLU*, yang menggunakan nilai α sebagai pengali untuk masukan x . α merupakan tingkat toleransi kebocoran umumnya bernilai $\alpha=0.2$ (*huge leak*), dan $\alpha=0.01$ (*small leak*).

3.5 Evaluasi dan Analisa

Tahap evaluasi merupakan tahap pemeriksaan akurasi, dan penerapan data asli terhadap klasifikasi jenis sampah dengan melakukan eksperimen yang telah di desain menjadi beberapa skenario pengujian. Hasil eksperimen tersebut kemudian dilakukan analisis untuk diambil kesimpulan.

Tahap evaluasi terhadap akurasi dilakukan menggunakan matriks klasifikasi yaitu *confusion matrix*, dengan melakukan penilaian dari segi *precision*, *recall*, dan *F1-Score*.

3.5.1 Precision

Precision merupakan evaluasi akurasi pada *confusion matrix* terhadap hasil prediksi yang bernilai positif.

$$Precision = \frac{TP}{TP + FP} \quad (3.7)$$

Keterangan:

TP = jumlah data dengan nilai sebenarnya positif dan nilai prediksi positif.

FP = jumlah data dengan nilai sebenarnya negatif dan nilai prediksi positif.

Rumus 3.7 merupakan perhitungan untuk nilai *precision* dari probabilitas prediksi. Diketahui *True Positive* (TP), dan *False Positive* (FP).

3.5.2 Recall

Recall merupakan evaluasi *confusion matrix* terhadap nilai aktual yang bernilai positif.

$$Recall = \frac{TP}{TP + FN} \quad (3.8)$$

Keterangan:

TP = jumlah data dengan nilai sebenarnya positif dan nilai prediksi positif.

FN = jumlah data dengan nilai sebenarnya positif dan nilai prediksi negatif.

Rumus 3.8 merupakan perhitungan untuk nilai *precision* dari probabilitas prediksi. Diketahui *True Positive* (TP), dan *False Negative* (FN).

3.5.3 F1-Score

F1-Score merupakan evaluasi penilaian akurasi terhadap probabilitas rata-rata antara nilai *precision*, dan *recall*.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3.9)$$

Rumus 3.9 merupakan perhitungan untuk memperoleh nilai *F1-Score*.

Nilai *precision* diperoleh dari rumus *precision* yaitu $precision = \frac{TP}{TP+FP}$.

Sedangkan nilai *recall* diperoleh dari rumus *recall* yaitu $recall = \frac{TP}{TP+FN}$.

3.6 Deployment

Tahap *deployment* merupakan tahap penerapan model terbaik yang dibuat dalam bentuk aplikasi sehingga bisa digunakan, dengan tujuan untuk melakukan pembuktian bahwa model tersebut berjalan, dan beroperasi dengan baik.

BAB 6

PENUTUP

6.1 Kesimpulan

Berdasarkan implementasi dan pengujian arsitektur *EfficientNet-B1* model *Noisy Student* terhadap klasifikasi jenis sampah organik, dan anorganik yang telah dilakukan, maka diperoleh kesimpulan sebagai berikut:

1. Proses pelatihan arsitektur *EfficientNet-B1* model *noisy student* menggunakan data sampah organik, dan anorganik yang telah mengalami augmentasi memperoleh akurasi tertinggi pada eksperimen 5 dengan *tuning hyperparameter*, menggunakan pembagian dataset 90:10, fungsi aktivasi *Rectified Linear Unit (ReLU)*, *optimizer* yang digunakan yaitu *Adaptive Moment Estimation (Adam)*, dengan aturan *learning rate* 0.01 menghasilkan nilai *F1-Score* 99,68%.
2. Berdasarkan pengamatan dari visualisasi pada grafik terhadap proses pelatihan, tidak ditemukan indikasi terjadinya *underfitting*, maupun *overfitting* yang signifikan karena jarak antara *loss train*, dan *loss validation* hanya berbeda tipis.
3. *Learning rate* dengan ukuran 10^{-2} memperoleh nilai *F1-score* terbaik untuk masing-masing sub eksperimen pada pembagian *dataset* 90:10, dan 10^{-3} pada *dataset* 70:30.
4. Pengujian aplikasi *web* yang telah di-*deployment* berhasil melakukan prediksi terhadap data yang berbeda dengan *dataset*.
5. Beberapa pengujian aplikasi *web* yang melakukan prediksi, tidak memperoleh prediksi yang tepat, karena model yang terbaik dengan nilai *F1-Score* 99,68% tidak memprediksi gambar dengan hasil yang 100% akurat.

6.2 Saran

Penulis memberikan beberapa saran yang bisa dijadikan bahan untuk pengembangan terhadap penelitian ini. Saran tersebut yaitu:

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

© Hak cipta milik UIN Suska Riau

1. Melakukan eksperimen untuk memperoleh model komputasi yang lebih cepat dengan menggunakan *regularization* yang lain.
2. Menambah satu kelas baru selain organik, dan anorganik yang berisi data selain sampah agar model mampu melakukan klasifikasi data selain sampah organik, dan anorganik.
3. Melakukan penerapan model terbaik yang telah dilatih dalam bentuk perangkat keras(*hardware*) seperti tempat sampah pintar yang bisa memisahkan sampah sesuai dengan jenisnya secara *real-time*.



DAFTAR PUSTAKA

- [1] Leonardo, Yohannes, and E. Hartati, "Klasifikasi Sampah Daur Ulang Menggunakan Support Vector Machine dengan Fitur Local Binary Pattern," *J. Algoritm.*, vol. 1, no. 1, pp. 78–89, 2020, [Online]. Available: <http://jurnal.mdp.ac.id/index.php/algoritme/article/view/440>.
- [2] indonesian.go.id, "Indonesia.go.id - Membenahi Tata Kelola Sampah Nasional," 2020. <https://indonesia.go.id/kategori/indonesia-dalam-angka/2533/membenahi-tata-kelola-sampah-nasional> (accessed Apr. 07, 2021).
- [3] H. nan Guo, S. biao Wu, Y. jie Tian, J. Zhang, and H. tao Liu, "Application of machine learning methods for the prediction of organic solid waste treatment and recycling processes: A review," *Bioresour. Technol.*, vol. 319, no. July 2020, p. 124114, 2020, doi: 10.1016/j.biortech.2020.124114.
- [4] G. E. Sakr, M. Mokbel, A. Darwich, M. N. Khneisser, and A. Hadi, "Comparing deep learning and support vector machines for autonomous waste sorting," *2016 IEEE Int. Multidiscip. Conf. Eng. Technol. IMCET 2016*, pp. 207–212, 2016, doi: 10.1109/IMCET.2016.7777453.
- [5] X. Wei, X. Yu, B. Liu, and L. Zhi, "Convolutional neural networks and local binary patterns for hyperspectral image classification," *Eur. J. Remote Sens.*, vol. 52, no. 1, pp. 448–462, 2019, doi: 10.1080/22797254.2019.1634980.
- [6] V. N. T. Le, S. Ahderom, and K. Alameh, "Performances of the lbp based algorithm over cnn models for detecting crops and weeds with similar morphologies," *Sensors (Switzerland)*, vol. 20, no. 8, pp. 1–18, 2020, doi: 10.3390/s20082193.
- [7] H. Alaskar, N. Alzhrani, A. Hussain, and F. Almarshed, "The Implementation of Pretrained AlexNet on PCG Classification," *Lect. Notes*

- Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 11645 LNAI, pp. 784–794, 2019, doi: 10.1007/978-3-030-26766-7_71.
- [8] D. Gyawali, A. Regmi, A. Shakya, A. Gautam, and S. Shrestha, “Comparative Analysis of Multiple Deep CNN Models for Waste Classification,” 2020, [Online]. Available: <http://arxiv.org/abs/2004.02168>.
- [9] S. H. Sunny, “Design of a Convolutional Neural Network Based Smart Waste Disposal System,” no. December, 2019, doi: 10.1109/ICASERT.2019.8934633.
- [10] A. S. E. Krizhevsky, “ImageNet Classification with Deep Convolutional Neural Networks,” pp. 1–9, 2012, doi: 10.1201/9781420010749.
- [11] M. Tan and Q. V. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, 2019.
- [12] L. T. Duong, P. T. Nguyen, C. Di Sipio, and D. Di Ruscio, “Automated fruit recognition using EfficientNet and MixNet,” *Comput. Electron. Agric.*, vol. 171, no. August, 2020, doi: 10.1016/j.compag.2020.105326.
- [13] Q. Xie, M. T. Luong, E. Hovy, and Q. V. Le, “Self-training with noisy student improves imagenet classification,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 10684–10695, 2020, doi: 10.1109/CVPR42600.2020.01070.
- [14] C. Shorten and T. M. Khoshgoftaar, “A survey on Image Data Augmentation for Deep Learning,” *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [15] F. Hutter, J. Lücke, and L. Schmidt-Thieme, “Beyond Manual Tuning of Hyperparameters,” *KI - Kunstl. Intelligenz*, vol. 29, no. 4, pp. 329–337, 2015, doi: 10.1007/s13218-015-0381-0.



- [16] A. Bisri and R. Rachmatika, "Integrasi Gradient Boosted Trees dengan SMOTE dan Bagging untuk Deteksi Kelulusan Mahasiswa," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 8, no. 4, p. 309, 2019, doi: 10.22146/jnteti.v8i4.529.
- [17] V. Gholami, J. Torkaman, and P. Dalir, "Simulation of precipitation time series using tree-rings , earlywood vessel features , and artificial neural network," pp. 1939–1948, 2019.
- [18] M. D. Zeiler, "ADADELTA: An Adaptive Learning Rate Method," 2012, [Online]. Available: <http://arxiv.org/abs/1212.5701>.
- [19] M. A. Hannan *et al.*, "SOC Estimation of Li-ion Batteries with Learning Rate-Optimized Deep Fully Convolutional Network," *IEEE Trans. Power Electron.*, vol. 36, no. 7, pp. 7349–7353, 2021, doi: 10.1109/TPEL.2020.3041876.
- [20] D. P. Kingma and J. L. Ba, "Adam: A method for stochastic optimization," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–15, 2015.
- [21] M. Nadiasa, D. K. Sudarsana, and I. N. Yasmara, "Manajemen Pengangkutan Sampah Di Kota Amlapura," *J. Ilm. Tek. Sipil*, vol. 13, no. 2, pp. 120–135, 2009.
- [22] F. Hutter, *Automated Machine Learning*, vol. 498. 2019.
- [23] M. I. Jordan and T. M. Mitchell, "Science-ML-2015," vol. 349, no. 6245, 2015.
- [24] M. I. Jordan and T. M. Mitchell, "Machine learning: Trends, perspectives, and prospects," vol. 349, no. 6245, 2015.
- [25] K. Reddy Bokka, S. Hora, T. Jain, and M. Wambugu, *Deep Learning for Natural Language Processing*. Birmingham: Packt Publishing Ltd, 2019.
- [26] J. W. G. Putra, "Pengenalan Konsep Pembelajaran Mesin dan Deep

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Learning,” vol. 4, pp. 1–235, 2019, [Online]. Available: <https://www.researchgate.net/publication/323700644>.

- [27] I. M. Nasser and S. S. Abu-naser, “Predicting Tumor Category Using Artificial Neural Networks,” vol. 3, no. 2, pp. 1–7, 2019.
- [28] I. Zafar, G. Tzanidou, R. Burton, N. Patel, and L. Araujo, *Hands-On Convolutional Neural Networks with TensorFlow*. 2018.
- [29] J. Brownlee, *Deep Learning With Python*, V1.7. 2016.
- [30] L. Zhang, J. Tan, D. Han, and H. Zhu, “From machine learning to deep learning: progress in machine intelligence for rational drug discovery,” *Drug Discov. Today*, vol. 22, no. 11, pp. 1680–1685, 2017, doi: 10.1016/j.drudis.2017.08.010.
- [31] Y. Xin *et al.*, “Machine Learning and Deep Learning Methods for Cybersecurity,” *IEEE Access*, vol. 6, pp. 35365–35381, 2018, doi: 10.1109/ACCESS.2018.2836950.
- [32] B. M. O. M. S. M. Avci, “Differential Convolutional Neural Network,” 2019.
- [33] I. G. and Y. B. and A. Courville, “Deep learning,” *Nature*, vol. 29, no. 7553, pp. 1–73, 2016.
- [34] S. Sumahasan, “Object Detection using Deep Learning Algorithm CNN,” *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 8, no. 7, pp. 1578–1584, 2020, doi: 10.22214/ijraset.2020.30594.
- [35] Z. Qin and D. Kim, “Rethinking softmax with cross-entropy: Neural network classifier as mutual information estimator,” *arXiv*, 2019.
- [36] S. Vani and T. V. M. Rao, “An experimental approach towards the performance assessment of various optimizers on convolutional neural network,” *Proc. Int. Conf. Trends Electron. Informatics, ICOEI 2019*, no. Icoei, pp. 331–336, 2019, doi: 10.1109/ICOEI.2019.8862686.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

- [37] M. F. Fibrianda and A. Bhawiyuga, “Analisis Perbandingan Akurasi Deteksi Serangan Pada Jaringan Komputer Dengan Metode Naïve Bayes Dan Support Vector Machine (SVM),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 9, pp. 3112–3123, 2018.
- [38] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow*. Gravenstein Highway North, Sebastopol, CA: O’Reilly Media, 2019.
- [39] N. K. Chowdhury, M. A. Kabir, M. M. Rahman, and N. Rezoana, “ECOVNet: An Ensemble of Deep Convolutional Neural Networks Based on EfficientNet to Detect COVID-19 From Chest X-rays,” 2020, [Online]. Available: <http://arxiv.org/abs/2009.11850>.
- [40] H. Zhang, L. Zhang, and Y. Jiang, “Overfitting and Underfitting Analysis for Deep Learning Based End-to-end Communication Systems,” *2019 11th Int. Conf. Wirel. Commun. Signal Process. WCSP 2019*, pp. 1–6, 2019, doi: 10.1109/WCSP.2019.8927876.

LAMPIRAN A

A: Sampah Anorganik



© Hak ciptam

IN ka

ate

ic


rsi

u

arif Kasim Riau


Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengemukakan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



©

ch

h

h

h

h


h

h


Riau

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



B Sampah Organik



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



©

c

n

l

s

k

a

n

u

h

u

te

ni

re

df

n

n

f

Riau


Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



DAFTAR RIWAYAT HIDUP

Muhammad Khairunnas lahir di Selatpanjang pada tanggal 03 Mei 1999. Muhammad Khairunnas merupakan anak pertama dari pasangan Bapak Hamidi dan Ibu Lisdawati.

Muhammad menyelesaikan Pendidikan sekolah dasar di SD Negeri 4 pada tahun 2011 berlanjut ke bangku MTS Negeri Selatpanjang yang selesai pada tahun 2014. Lalu dilanjutkan di SMA Negeri 2 Tebing Tinggi. Pada tahun 2017 Muhammad Khairunnas melanjutkan pendidikannya ke jenjang perguruan tinggi di Universitas Islam Negeri Sultan Syarif Kasim Riau dengan mengambil program studi Teknik Informatika pada Fakultas Sains dan Teknologi. Muhammad Khairunnas melakukan penelitian mengenai Deep Learning di Lab Pusat Teknologi Informasi dan Pangkalan Data yang ada di Universitas Islam Negeri Sultan Syarif Kasim Riau